



公開

密件、不公開

執行機關(計畫)識別碼：130301e300

行政院農業委員會林務局102年度科技計畫研究報告

計畫名稱：**高解析度多光譜影像於森林資源調查之應用
(第1年/全程1年)**

(英文名稱)**Application of High Spatial Resolution
Multispectral Imagery on Forest
Resources Inventory**

計畫編號：**102農科-13.3.1-務-e3**

全程計畫期間：自 102年1月1日至 102年12月31日

本年計畫期間：自 102年1月1日至 102年12月31日

計畫主持人：**林金樹**

研究人員：**任玄、吳昭正、陳獻廷、李品儀、陳怡玲、洪格爾、劉哲
瑋、王子嘉、陳玠樺、蔡幸芸**

執行機關：**嘉義大學**



1022149



一、執行成果中文摘要：

本研究整合大氣校正以及影像全色態影像銳化處理(融合)技術，建立高空間解析的WorldView-2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為訓練及分類對象，所建立的組類物件特徵對於土地被覆型可以達到100%準確度的訓練準確度，經過分層隨機取樣評估樣區評估結果，總體的分類準確度高達89%；此一準確度可以達到99%信賴水準，顯示本研究所建立的土地被覆型分類機制應足可滿足大尺度的土地被覆型測繪精度需求。高空間解像力影像在像元尺度上所提供的光譜訊息足以代表單純物質，換言之，所提供的訊息應以單純林型(例如：針葉樹、闊葉樹、竹類、草地、以及農地等)為導向；物件基礎的支持向量機分類法所得的分類準確度卻較低於像元基礎的最大概似法(PB-MLC)，評估樣區所得的PB-MLC最佳準確度只有60%，此一準確度雖可滿足95%統計取樣的信賴水準，但是總體準確度偏低，以第四次資源調查林型圖多邊型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OB-SVM兩種機制的分類準確度約只有23%，因此，本研究建議仍需進行深入研究，以建構穩定可行的林型分類機制提供未來資源調查的應用。

二、執行成果英文摘要：

This study applied the techniques of atmospheric correction and image pansharpening to derive high-spatial resolution WorldView-2 multispectral image (0.5m/pixel) for land use land cover (LULC) and forest type classification. The LULC classes such as forest, farmland, grassland, bareland, wetland, and building area were assigned based on the IPCC system. The forest types such as conifer, broadleaf, bamboo, bamboo-conifer mixed, bamboo-broadleaf mixed, bamboo-conifer-broadleaf mixed, and conifer-broadleaf mixed forest were assigned as the major targets for forest type mapping. Classifications were implemented using pixel-based maximum likelihood classifier (PB-MLC) and object-based support vector machine (OB-SVM). Results showed that the OB-SVM had better performance in training and test samples of LULC classification with an overall accuracy 100% and 89% respectively. Due to the accuracy was evaluated by stratified random sampling method at the level of 0.01 significant probability, the proposed OB-SVM classification strategy can be definitely applied for nation-wide LULC mapping. Unfortunately we failed to duplicate the strength of OB-SVM in LULC classification. The best overall accuracy evaluated based on the test samples was 60% and 53% for PB-MLC and OB-SVM based on the pure-forest evaluation for conifer, broadleaf, bamboo, grassland, and farm. The performance decreased sharply





to 23% for both PB-MLC and OB-SVM in the classification of mixed-forest types including conifer, broadleaf, bamboo, bamboo-conifer mixed, bamboo-broadleaf mixed, bamboo-conifer-broadleaf mixed, and conifer-broadleaf mixed forest, grassland, and farmland. This indicates that further intensive studies should be continuously supported in order to lead the remote sensing mapping of forest types becoming practical for nation-wide inventory in short future.

三、計畫目的：

1. 研究並評估單一影像於國土土地被覆型分類的可行性。
2. 研究並評估單一影像於森林資源調查林型分類之可行性。
3. 研究並建立高解析度多光譜影像於林型分類之作業流程。

四、重要工作項目及實施方法：

本計畫的主要目的在於以國家森林資源調查遙測實務應用為導向，以第四次森林資源調查利用航照判釋技術所繪製的林型圖為依據，研究高空間解析的Worldview-2多光譜影像於林型圖分類的應用特性。規劃的研究地區以涵蓋山區及平原地區的森林，預定本計畫的主要工作項目為：

1. 取得研究用影像資料與資源調查地真資料，本研究資料由林務局農林航空測量所提供的研究南投林區以及嘉義林區的WorldView-2衛星影像全色態影像、多譜態影像以及二種影像資料的融合影像。並請林務局提供第四次森林資源調查所繪製完成的試驗區範圍內之林型、照片樣點與地面調查有關資料。
2. 融合影像與原始影像的光譜訊號同質性分析。
3. 影像前期處理。
4. 土地被覆型(地類)分類以及導出地類的光譜訊號特徵評估。以IPCC分類機制為基礎，將土地被覆型分類為林地、農田、草地、濕地、定居地、以及裸地(其他土地)等六大類。
5. 以像元導向技術為基礎的林型分類，並建立各林型的光譜訊號特徵。林型分類基礎係以第四次森林資源調查所規劃的類別為基礎，包含針葉樹純林、針葉樹混淆林、闊葉樹純林、闊葉樹混淆林、針闊葉樹混淆林、竹林、竹闊混淆林、竹闊混淆林、竹針混淆林、竹針闊混淆林。
6. 以物件導向技術為基礎的林型分類，並分析各林型物件的光譜訊號變異特徵。
7. 多層級的林型分類策略評估以及分類架構研擬。為推行遙測實務應用於森林資源調查，有關林型分類準確度不宜低於85%。本研究將依據像元導向分類法以及物件導向分類法之分類結果，檢討可行的林型分類層級與實行機制，建立森林資源調查林型分類的標準作業流程。
8. 依據林務局第四次森林資源調查成果資料，將樣區資料等量隨機分成訓練樣區及評估樣區，利用MLC、SVM、NN分類法進行監督式分類。準確度之評估以Overall





Accuracy、Kappa Accuracy、User Accuracy、Producer Accuracy為計量基準，評估各種分類法的林型分類準確度；於林務局樣區外，另設20個地面監測樣點，代表獨立樣本，評估前列四種影像分類準確度，相對於林務局第四次森林資源調查的評估樣區分類準確度，據以評估影像分類法的穩定性。

五、結果與討論：

(一) 土地被覆型

1. 根據全色態銳化轉換結果可知GA法對於Grassland、Urban、Water保有最高的辨識能力，且由NDVI之結果發現GA法具有保持波段間相對比例的能力，使影像可保有較高的原始光譜特性，避免影像失真造成分類上的錯誤。
2. 由光譜分離度表評估可知經過全色態銳化的FLAASH影像不僅能去除大氣中影響分類的雜訊，更同時具有高解析度(0.5m)的特性，可準確的依據物體特性來圈選樣區提升影像分類的準確度，因此為本研究中最佳的影像處理組合。
3. 經過大氣校正全色態銳化的PB-MLC影像雖具較佳的分類結果(84.86%)，但因為PB-MLC中的像元數量會隨著解析度提升而急遽增加，使得影像中異譜或同譜異質等不確定性問題大幅增加，其結果便是導致訓練樣區選取的困難度增加及分類後椒鹽效應(salt and pepper effect)增加等一連串之問題(雷祖強等，2009)，因此後續發展受到限制。

反之，在物件導向的分類中會先進行影像分割(image segmentation)，依據色彩、紋理、形狀這三種視覺上的特徵來描述影像的內容，之後分別對各區塊給予適當形式的表示和描述再根據區塊特性進行分類。同時根據過往研究結果顯示OB-SVM的分類法結果往往較像元導向的分類法為佳(Foody and Mathur, 2004；Melgani and Bruzzone, 2004；黃明哲、李良輝，2005；許晉嘉等，2005；鄭雅文等，2008)，顯示確實具有發展上的潛力。最後，KNN在評估樣區中的準確度則不論何種處理皆不合理想，因此不納入後續的林型研究之中

(二) 林型

1. 研究結果顯示在林型分類上經Lee濾波器處理後可得較佳的分類準確度(63.97%)，但仍較傳統衛星影像分類準確度為差，因此在Lee濾波器的設定上仍有值得持續進行測試的必要。
2. WV2影像雖具有高解析度的優勢，卻同時具有資料量龐大的缺點，因此雖然直接以原始未裁切之影像進行分類會使處理時間大幅度拉長使得效率極低，同時若必須進行不同設定值之測試則時間花費浩大，因此仍建議先就目標位置進行裁切以減少資料處理量，同時配合本研究所建立之作業流程達到提高WV2影像使用益本比的目的。
3. 研究結果顯示PB-MLC在林型分類上具有較佳的分類準確度(63.97%)，其原因可能在於林分中的立木生長受環境因子的影響，故即使是同一林型但位於不同生育地之林分常有明顯的生長差異，而混淆林型內之變異程度更高使得常無法完整切割出樹木的形狀，因此OB-SVM便無法準確依據樹木的外型進行分類，故準確度明顯較像元





分類法為差。而PB-MLC的分類關鍵應該是地真資料的合理性，訂正前後的準確度相差可達10%左右，因此建議在使用PB-MLC進行WV2影像分類時，須先進行地真資料的比對以降低不合理性所帶來的誤差。在混淆林分類上則兩種分類法皆無法進行有效分類(PB-MLC：20~23%、OB-SVM：18~24%)。

六、結論：

WV2影像因具有高空間解析度地特性，故可滿足大尺度土地被覆型分類上之需求，同時其所提供的光譜訊息應可準確應用於單純林型分類之上，且配合資源調查結果應可再對混淆林型進行分類，對於森林資源經營提供具參考價值的分類結果，而根據本研究之結果顯示目前僅能滿足土地被覆型分類的需求，對於單純林型及混淆林型的分類則有待進一步的深入研究，建構可行的林型分類機制供未來森林資源調查之用，以彌補SPOT影像解析度不足的缺點。

七、參考文獻：

- 內政部城鄉發展分署網站<http://wetland-tw.tcd.gov.tw/WetLandWeb/index.php>
- 王駿發、林博川、王家慶、宋豪靜（2005）以支援向量機為基礎之新穎語者切換偵測演算法。1-20頁。第十七屆自然語言與語音處理研討會。中華民國計算語言學學會，台北。
- 吳季桓（2010）自動分類的實作：KNN與SVM。國立中正大學資訊工程研究所碩士論文，49頁。
- 林金樹（1999）森林植生季節性光譜特性之研究。台灣林業科學14(3): 289-305。
- 林金樹（2001）影像參數加權統計法PN指標於土地利用型高光譜特徵選粹上之研究。航測及遙測學刊6(3): 1-20。
- 林金樹（2004）GIS概論與MajorGIS快速入門。新文京開發出版股份有限公司，474頁。
- 邱彥璋（2012）混合式多光譜影像全色態銳化之方法探討。國立台灣大學工學院土木工程學系碩士論文，66頁。
- 張伯辰、連偉志、楊建民（2013）適用於雲端分散儲存架構下的KNN平行演算法。1-10頁。第二屆服務與科技管理研討會。國立台北科技大學服務與科技管理研究所，台北。
- 許晉嘉（2006）應用支援向量機法於高解析度衛星影像分類之研究。逢甲大學環境資訊科技研究所碩士論文，68頁。
- 許晉嘉、雷祖強、周天穎（2005）應用支援向量機法於衛星影像分類之研究，農業工程研討會。
- 陳承昌（2006）支持向量機及Plausible Neural Network於水稻田辨識之研究。國立交通大學土木工程學系碩士論文，122頁。
- 黃明哲、李良輝（2005）支持向量機應用於空載雷射掃瞄資料地物分類之研究，電





子計算機於土木水利應用研討會。

黃冠中 (2007) 應用KNN演算法之文件分類平台實作。第六屆離島資訊技術與應用研討會

黃凱翔 (2008) 利用支持向量機於機載高光譜感測影像之分類。中興大學土木工程系碩士論文，62頁。

楊元琪 (2007) 綜合法則歸納系統之延伸研究。國立中山大學資訊管理學系碩士論文，85頁。

雷祖強、李哲源、葉惠中、萬綯 (2009) 以區塊化物件分類法萃取ADS-40 影像中水稻田塊資訊之研究。航測及遙測學刊 14(2)：127-140。

蔡豫學 (2011) 應用支持向量機預測水庫乾旱。屏東科技大學水土保持系碩士論文，157頁。

鄭雅文、史天元、蕭國鑫 (2008) 物件導向分類於高解析度影像自動判釋。航測及遙測學刊13(4)：273-284。

Abdallah, C., J. Chorowicz, R. Bou Kheir and M. Khawlie (2005) Detecting major terrain parameters relating to mass movements' occurrence using GIS, remote sensing and statistical correlations, case study Lebanon. *Remote Sensing of Environment* 99:448-461.

Ajeng A., and C. Lin (2011) Application of SAM and SVM techniques to burned area detection for Landsat TM images in forests of south Sumatra. Proceeding of the ICEST 2011. IPCBEE vol. 6 (v2):160-164. IACSIT Press, Singapore.

Allaby M. (1998) A dictionary of plant sciences. 2nd ed. Oxford University Press, Oxford, UK. 508pp.

Baatz, M., and Schäpe, A. (2000) Multiresolution segmentation - an optimizaiton approach for high quality multi-scale image segmentation. pp.12-23. In: Strobl, J. et al., eds. *Angewandte Geographische Informationsverarbeitung XII*. Wichmann, Heidelberg. 553pp.

Baesens, B., Viaene, S., Van Gestel, T., Suykens, J.A.K., Dedene, G., De Moor, B., and Vanthienen, J. (2000) An empirical assessment of kernel type performance for least squares support vector machine classifiers. pp.313-316. In: *Knowledge-Based Intelligent Engineering Systems and Allied Technologies*, 2000. Proceedings. Fourth International Conference on, Vol 1. 457pp.

Burges, C. J. C. (1998) A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery* 2:121-167.

Chen, S.Y., Y.C. Ouyang, C. Lin, and C.I. Chang. (2011) Iterative support vector machine for hyperspectral image classification. The Proceeding of Geoscience and Remote Sensing Symposium (IGARSS), 2011 IEEE International. p.1712-1715. DOI:10.1109/IGARSS. 2011.6049565.





- Cohen, J. (1960) A coefficient of agreement for nominal scales. *Educational Psychological Measurement* 20:37-46.
- Congalton, R. G. and K. Green (2009) Assessing the accuracy of remotely sensed data: Principles and Practices. CRC Press, Boca Raton, FL.
- Ramsar Secretariat (1971) Convention on Wetlands of International Importance especially as Waterfowl Habitat. Ramsar, Iran.
- Cristianini, N. and J. Shawe-Taylor (2000) An introduction to support vector machines and other kernel-based learning methods. Cambridge University Press. 189pp.
- de Carvalho, O. A. Jr, and Meneses, P. R. (2000) Spectral Correlation Mapper (SCM): An improvement on the Spectral Angle Mapper (SAM). Summaries of the 9th Airborne Earth Science Workshop. Jet Propulsion Laboratory 00-18.
- Du, Q., N. H. Younan, R. King and V. P. Shah (2007) On the performance evaluation of Pan-Sharpening techniques. *IEEE Geoscience and Remote SensinG Letters* 4(4):518-522.
- Foody, G. M. and A. Mathur (2004) A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42 (6):1335-1343.
- Gaspar, P., Carbonell, J., and Oliveira, J. L. (2012) On the parameter optimization of Support Vector Machines for binary classification. *Journal of Integrative Bioinformatics*, 9(3):201.
- Haralick, R. M., K. Shanmugam and I. Dinstein (1973) Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics* 3(6):610-621.
- Hermas, E., S. Leprince and I. A. El-Magd (2012) Retrieving sand dune movements using sub-pixel correlation of multi-temporal optical remote sensing imagery, northwest Sinai Peninsula, Egypt. *Remote Sensing of Environment* 121:51-60.
- Hoffbeck, J. P. and D. A. Landgrebe (1996) Covariance matrix estimation and classification with limited training data. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 18(7):763-767.
- Hsu, C. W., and Lin, C. J. (2002) A comparison of methods for multiclass support vector machines. *IEEE Trans. Neural Networks* 13: 415-425.
- Hsu, C. W., C. C. Chang and C. J. Lin (2009) A practical guide to support vector classification. Technical Note, Department of Computer Science and Information Engineering, National Taiwan University, Taiwan.
- Hsu, C. W., Chang, C. C., and Lin, C. J. (2010) A practical guide to support vector classification. Technical report. Department of Computer





Science and Information Engineering, National Taiwan University.

Huang, C., Davis, L. S., and Townshend, J. R. G. (2002) An assessment of support vector machines for land cover classification. International Journal of Remote Sensing 23(4): 725-749.

Hughes, G. F. (1968) On the mean accuracy of statistical pattern recognizers. IEEE Transactions on Information Theory IT-14:55-63.

James, M. (1985) Classification algorithms. John Wiley and Sons, Inc. London, United Kingdom. 211p.

Jensen, C. S., J. Kolar, T. B. Pedersen, and I. Timko (2003) Nearest neighbor queries in road networks. in Proceedings of the ACM GIS, New Orleans, Louisiana, USA.

Jia, X. and Richards, J. A. (1994) Efficient maximum likelihood classification for imaging spectrometer data sets. IEEE Transactions on Geoscience and Remote Sensing 32(2):274-281.

Laben, C. A. and B. V. Brower (2000) Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. United States Patent 6011875. 8p.

Lam, W. and C. Y. Ho (1998) Using a generalized instance set for automatic text categorization. Proceedings of the 21st Annual International ACM-SIGIR Conference on Research and Development in Information Retrieval. pp.81-89.

Lee, C. and Landgrebe, D. A. (1993) Analyzing high-dimensional multispectral data. IEEE Transactions on Geoscience and Remote Sensing 31(4):792-800.

Leeuw, M. R. and Carvalho L. M. T. (2009) Performance evaluation of several adaptive speckle filter for SAR imaging. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, pp.7299-7305.

Lewis, J. P. (1995) Fast template matching. Vision Interface 95:120-123.

Lin, C. and D. Trianingsih (2012) Evaluation of the reliability of classifiers for the mapping of mangrove forest using landsat TM Images. The 2nd International Conference on Electric Technology and Civil Engineering (ICETCE 2012). May 18-21, 2012. Three Gorges, YiChang, China.

Matthew, M. W., S. M. Adler-Golden, A. Berk, S. C. Richtsmeier, R. Y. Levine, L. S. Bernstein, P. K. Acharya, G. P. Anderson, G. W. Felde, M. P. Hoke, A. Ratkowski, H.-H. Burke, R. D. Kaiser, and D. P. Miller (2000) Status of atmospheric correction using a MODTRAN4-based algorithm. SPIE Proceedings, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI. Vol. 4049, pp. 199-207.



- Meenakshi and Punitham (2011) Performance of speckle noise reduction filter on active radar and SAR images. International Journal of Technology And Engineering System 2(1):111-114.
- Melgani, F. and L. Bruzzone (2004) Classification of hyperspectral remote sensing Images with support vector machines, IEEE Transactions on Geoscience and Remote Sensing 42 (8):1778-1790.
- Mercier, G., and Lennon, M. (2003) Support vector machines for hyperspectral image classification with spectral-based kernels. In Proc. IGARSS, Toulouse, France, July 21-25, 2003.
- Ozdarici, A. and Akyurek Z. (2010) A comparison of SAR filtering techniques on agricultural area identification. pp.730-739. In: American Society for Photogrammetry and Remote Sensing Annual Conference 2010. Curran Associates. San Diego, California, USA. 1107pp.
- Pouteau, R., J.-Y. Meyer, R. Taputuarai and B. Stoll (2012) Support vector machines to map rare and endangered native plants in Pacific islands forests. Ecological Informatics 9:37-46.
- Qiu, F., J. Berglund, J. R. Jensen, P. Thakkar and D. Ren (2004) Speckle noise reduction in SAR imagery using a local adaptive median filter. GIScience and Remote Sensing 41(3):244-266.
- Ranchin, T. and L. Wald (2000) Fusion of high spatial and spectral resolution images: The ARSIS concept and its implementation. Photogrammetric Engineering and Remote Sensing 66(1):49-61.
- Rudjord and Trier (2012) Evaluation of FLAASH atmospheric correction. Project number: 220512. TropSkogTanz, Norsk Regnesentral, Oslo.
- Samadzadegan, F., F. Fathollahi and M. Rezaee (2012) Comparing different IHS-based pan-sharpening techniques for worldview-2 high resolution satellite imagery. IEEE Geoscience and Remote Sensing Symposium 2296-2299.
- Schölkopf and A. J. Smola (2002) Learning with Kernels. Cambridge, MA, MIT Press.
- Shahabi, C., M. R. Kolahdouzan and M. Sharifzadeh (2003) A road network embedding technique for k-nearest neighbor search in moving object databases. Geoinformatica 7(3):255-273.
- Swain, P. H. and Davis, S. M. (1978) Remote sensing: The Quantitative Approach. NY: McGraw-Hill. 396pp.
- Tu, T. M., C. H. Chen, J. L. Wu and C. I. Chang (1998) A fast two-stage classification method for high-dimensional remote sensing data. IEEE Transactions on Geoscience and Remote Sensing 36(1):182-191.
- Tu, T. M., C. L. Hsu, P. Y. Yu and C. H. Lee (2012) An adjustable Pan-





- Sharpening approach for IKONOS/QuickBird/GeoEye-1/WorldView-2 imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 5(1):125-134.
- Tzotsos, A., and Argialas, D. (2008) Support vector machine classification for object-based image analysis. pp.663-677. In Blaschke, T., Lang, S., and Hay, G.J., edited, Object-Based Image Analysis-Lecture Notes in Geoinformation and Cartography. Berlin, Germany: Springer Berlin Heidelberg. 817pp.
- Vapnik, V. (1982) Estimation of dependences based on empirical data. Springer-Verlag. 399pp.
- Vapnik, V. (1995) The Nature of Statistical Learning Theory. Springer-Verlag. 314pp.
- Wald, L., T. Ranchin, and M. Mangolini (1997) Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images. Photogrammetric Engineering and Remote Sensing 63(6):691-699.
- Welch, R. and W. Ehlers (1987) Merging multiresolution SPOT HRV and Landsat TM data. Photogrammetric Engineering and Remote Sensing, 53(3):301-303.
- Widjaja, D., Varon, C., Dorado, A. C., Suykens, J. A., and Van Huffel, S. (2012) Application of kernel principal component analysis for single-lead-ECG-derived respiration. IEEE Trans Biomed Eng 59(4):1169-1176. doi: 10.1109/TBME.2012.2186448.
- Wolf, A. (2010) Using worldview2 Vis-NIR MSI imagery to support land mapping and feature extraction using normalized difference index ratios. Digital Globe 8-Band Challenge 13pp.
- Xiao, J., J. Li and A. Moody (2003) A detail-preserving and flexible adaptive filter for speckle suppression in SAR imagery. International Journal of Remote Sensing 24(12):2451-2465.
- Zhang, Y. (2004) Understanding Image Fusion. Photogrammetric Engineering & Remote Sensing 70(6):657-661.





目錄

一、 前言	1
二、 研究材料	2
三、 研究流程及方法	3
(一) 土地被覆型	3
1. 原始衛星影像裁切	3
2. 大氣校正	3
3. 全色態銳化	7
4. 樣區選取	8
5. 影像分類	9
6. 準確度評估	9
7. 應用	9
(二) 林型分類	10
1. 影像前處理	11
2. 影像濾波	11
3. 林型樣區選取	12
4. 分類及準確度評估	12
5. WV2 影像林型分類作業建議方案	12
(三) 分類器概述	13
1. 最大概似法	13
2. 支持向量機	13
3. 最近相鄰法	15
(四) 訓練樣區及評估樣區之決定	16
1. 土地被覆型	17
2. 林型	23
四、 結果與討論	26
(一) 土地被覆型	27
1. 大氣校正及影像全色態銳化	27
(1) 大氣校正：	27
(2) 大氣校正對 NDVI 值之影響	28
(3) 全色態銳化法	29
2. 分類及準確度評估	34
(1) 未經大氣校正處理之原始影像分類	34
I. 未全色態銳化	34
II. 已全色態銳化	36
(2) 大氣校正處理後之分類	38
I. 未全色態銳化	38





II. 已全色態貌化.....	40
3. 準確度分析	43
(1) PB-MLC	43
(2) OB-SVM.....	44
(3) KNN	45
(二) 林型.....	46
1. 影像前處理	46
2. 影像濾波	47
3. 分類及準確度評估.....	47
(1) 單純林型分類.....	47
I. PB-MLC	49
II. OB-SVM.....	59
(2) 混淆林型分類.....	68
I. PB-MLC	68
II. OB-SVM.....	70
4. WV2 影像林型分類作業建議方案	72
五、 結論	73
(一) 土地被覆型	73
(二) 林型.....	74
六、 參考文獻	74





圖次

圖 1 研究影像位置	2
圖 2 裁切後之影像	3
圖 3 土地被覆型分類研究流程	5
圖 4 FLAASH 使用者介面	6
圖 5 林型分類流程圖	10
圖 6 SVM 二元組類分類器理論示意圖	15
圖 7 土地被覆型分類影像區域	17
圖 8 訓練樣區分佈	17
圖 9 全色態銳化處理後影像局部放大	19
圖 10 評估樣區位置圖	21
圖 11 訓練樣區挑選位置(一)	24
圖 12 訓練樣區挑選位置(二)	25
圖 13 訓練樣區分類型樹狀圖	26
圖 14 FLAASH 大氣校正處理後之 WV2 影像	27
圖 15 影像處理前後光譜比較	28
圖 16 大氣校正前後之 NDVI 結果圖	28
圖 17 G-S 法處理之影像	29
圖 18 PC 法處理之影像	29
圖 19 GA 法處理之影像	30
圖 20 原始影像且未經全色態銳化處理之 PB-MLC 分類結果	34
圖 21 原始影像且未經全色態銳化處理之 OB-SVM 分類結果	35
圖 22 原始影像且未經全色態銳化處理之 KNN 分類結果	35
圖 23 原始影像經全色態銳化處理後之 PB-MLC 分類結果	36
圖 24 原始影像經全色態銳化處理後之 OB-SVM 分類結果	37
圖 25 原始影像經全色態銳化處理後之 KNN 分類結果	37
圖 26 大氣校正後未經全色態銳化處理之 PB-MLC 分類結果	38
圖 27 大氣校正後未經全色態銳化處理之 OB-SVM 分類結果	39
圖 28 大氣校正後未經全色態銳化處理之 KNN 分類結果	39
圖 29 大氣校正後經全色態銳化處理後之 PB-MLC 分類結果	40
圖 30 大氣校正全色態銳化處理影像之物件基礎 SVM 分類結果	41
圖 31 大氣校正後經全色態銳化處理後之 KNN 分類結果	41
圖 32 經影像前處理之 WV2 各林型樣區接合圖	46
圖 33 5*5 濾波器處理結果	47
圖 34 分類結果與地真資料比對(灌木林)	47
圖 35 分類結果與地真資料比對(裸露地)	48
圖 36 分類結果與地真資料比對(茶園)	48





圖 37 分類結果與地真資料比對(果樹).....	48
圖 38 分類結果與地真資料比對(建物-1).....	48
圖 39 分類結果與地真資料比對(建物-2).....	48
圖 40 分類結果與地真資料比對(建物-3).....	48
圖 41 PB-MLC Gamma 分類結果(3*3)	49
圖 42 PB-MLC Gamma 分類結果(5*5)	50
圖 43 PB-MLC Lee 分類結果(3*3NV1)	53
圖 44 PB-MLC Lee 分類結果(3*3NV10)	53
圖 45 PB-MLC Lee 分類結果(3*3NV20)	53
圖 46 PB-MLC Lee 分類結果(5*5NV1)	54
圖 47 PB-MLC Lee 分類結果(5*5NV10)	54
圖 48 PB-MLC Lee 分類結果(5*5NV20)	54
圖 49 PB-MLC Lee 分類結果(7*7NV1)	55
圖 50 PB-MLC Lee 分類結果(7*7NV10)	55
圖 51 PB-MLC Lee 分類結果(7*7NV20)	55
圖 52 PB-MLC Lee 分類結果(9*9NV1)	56
圖 53 PB-MLC Lee 分類結果(9*9NV10)	56
圖 54 PB-MLC Lee 分類結果(9*9NV20)	56
圖 55 PB-MLC Local sigma 分類結果(5*5)	57
圖 56 PB-MLC Local sigma 分類結果(7*7)	58
圖 57 OB-SVM Gamma 分類結果(3*3)	59
圖 58 OB-SVM Gamma 分類結果(5*5)	60
圖 59 OB-SVM Lee 分類結果(3*3 NV1)	63
圖 60 OB-SVM Lee 分類結果(3*3 NV10).....	63
圖 61 OB-SVM Lee 分類結果(3*3 NV20).....	63
圖 62 OB-SVM Lee 分類結果(5*5 NV1)	64
圖 63 OB-SVM Lee 分類結果(5*5 NV10).....	64
圖 64 OB-SVM Lee 分類結果(5*5 NV20).....	64
圖 65 OB-SVM Lee 分類結果(7*7 NV1)	65
圖 66 OB-SVM Lee 分類結果(7*7 NV10).....	65
圖 67 OB-SVM Lee 分類結果(7*7 NV20).....	65
圖 68 OB-SVM Lee 分類結果(9*9 NV1)	66
圖 69 OB-SVM Lee 分類結果(9*9 NV10).....	66
圖 70 OB-SVM Lee 分類結果(9*9 NV20).....	66
圖 71 OB-SVM Local sigma 分類結果(5*5).....	67
圖 72 OB-SVM Local sigma 分類結果(7*7).....	68
圖 73 WV2 林型分類建議作業流程	72





表次

表 1. 季節-緯度地表溫度模式	6
表 2. 水蒸氣量標準表	7
表 3. 能見度近似值	7
表 4. 不同濾波器設定之組合	11
表 5. 物件導向屬性設定	16
表 6. 原始影像土地被覆型光譜分離度	20
表 7. FLAASH 影像土地被覆型光譜分離度	20
表 8. 訓練樣區及評估樣區選取像元數一覽表	22
表 9. 各波段 CV 計算	22
表 10. 大氣校正前後之 NDVI 數值變化	28
表 11. G-S 法之各類別於各波段之 RMSE 值	32
表 12. G-S 法之各類別於各波段之 Correlation 值	32
表 13. PC 法之各類別於各波段之 RMSE 值	32
表 14. PC 法之各類別於各波段之 Correlation 值	33
表 15. GA 法之各類別於各波段之 RMSE 值	33
表 16. GA 法之各類別於各波段之 Correlation 值	33
表 17. 不同處理之 PB-MLC 分類法準確度評估	43
表 18. 不同處理之 OB-SVM 分類法準確度評估	44
表 19. 不同處理之 KNN 分類法準確度評估	45
表 20. PB-MLC 之 Gamma 分類準確度	49
表 21. PB-MLC 之 Lee 分類準確度(3*3)	51
表 22. PB-MLC 之 Lee 分類準確度(5*5)	51
表 23. PB-MLC 之 Lee 分類準確度(7*7)	52
表 24. PB-MLC 之 Lee 分類準確度(9*9)	52
表 25. PB-MLC 之 Local sigma 分類準確度	57
表 26. OB-SVM 之 Gamma 分類準確度	59
表 27. OB-SVM 之 Lee 分類準確度(3*3)	61
表 28. OB-SVM 之 Lee 分類準確度(5*5)	61
表 29. OB-SVM 之 Lee 分類準確度(7*7)	62
表 30. OB-SVM 之 Lee 分類準確度(9*9)	62
表 31. OB-SVM 之 Local sigma 分類準確度	67
表 32. PB-MLC Gamma 混淆林分類表(5*5)	68
表 33. PB-MLC Lee 混淆林分類表(9*9 NV20)	69
表 34. PB-MLC Local sigma 混淆林分類表(7*7)	69
表 35. OB-SVM Gamma 混淆林分類表(5*5)	70
表 36. OB-SVM Lee 混淆林分類表(5*5 NV20)	70





表 37. OB-SVM Local sigma 混淆林分類表(7*7) 71

VI





附錄

附錄 1 土地被覆型隨機取樣之樣點座標位置一覽	80
附錄 2 土地被覆型型訓練樣區各類別各波段直方圖表	82
附錄 3 野外林型勘查作業成果	86
附錄 4 林型分類不同濾波器設定之光譜值	91
附錄 5 林型分類下不同濾波器處理之分離度	92





摘要

本研究整合大氣校正以及影像全色態影像銳化處理(融合)技術，建立高空間解析的WorldView-2(WV2)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為訓練及分類對象，所建立的組類物件特徵對於土地被覆型可以達到100%準確度的訓練準確度，經過分層隨機取樣評估樣區評估結果，總體的分類準確度高達89%；此一準確度可以達到99%信賴水準，顯示本研究所建立的土地被覆型分類機制應足可滿足大尺度的土地被覆型測繪精度需求。高空間解像力影像在像元尺度上所提供的光譜訊息足以代表單純物質，換言之，所提供的訊息應以單純林型(例如：針葉樹、闊葉樹、竹類、草地、以及農地等)為導向；物件基礎的支持向量機分類法所得的分類準確度卻較低於像元基礎的最大概似法(PB-MLC)，評估樣區所得的PB-MLC最佳準確度只有60%，此一準確度雖可滿足95%統計取樣的信賴水準，但是總體準確度偏低，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OB-SVM兩種機制的分類準確度約只有23%，因此，本研究建議仍需進行深入研究，以建構穩定可行的林型分類機制提供未來資源調查的應用。

【關鍵字】土地被覆型、林型、物件基礎的影像分類、像元基礎的影像分類、遙測

Abstract

This study applied the techniques of atmospheric correction and image panchromatic sharpening to derive high-spatial resolution WorldView-2 multispectral image (0.5m/pixel) for land use land cover (LULC) and forest type classification. The LULC classes such as forest, farmland, grassland, bareland, wetland, and building area were assigned based on the IPCC system. The forest types such as conifer, broadleaf, bamboo, bamboo-conifer mixed, bamboo-broadleaf mixed, bamboo-conifer-broadleaf mixed, and conifer-broadleaf mixed forest were assigned as the major targets for forest type mapping. Classifications were implemented using pixel-based maximum likelihood classifier (PB-MLC) and object-based support vector machine (OB-SVM). Results showed that the OB-SVM had better performance in training and test samples of LULC classification with an overall accuracy 100% and 89% respectively. Due to the accuracy was evaluated by stratified random sampling method at the level of 0.01 significant probability, the proposed OB-SVM classification strategy can be definitely applied for nation-wide LULC mapping. Unfortunately we failed to duplicate the strength of OB-SVM in LULC classification. The best overall accuracy evaluated based on the test samples was 60% and 53% for PB-MLC and OB-SVM based on the pure-forest evaluation





for conifer, broadleaf, bamboo, grassland, and farm. The performance decreased sharply to 23% for both PB-MLC and OB-SVM in the classification of mixed-forest types including conifer, broadleaf, bamboo, bamboo-conifer mixed, bamboo-broadleaf mixed, bamboo-conifer-broadleaf mixed, and conifer-broadleaf mixed forest, grassland, and farmland. This indicates that further intensive studies should be continuously supported in order to lead the remote sensing mapping of forest types becoming practical for nation-wide inventory in short future.

Key words: land use land cover, forest types, object-based image classification, pixel-based image classification, remote sensing.





一、前言

林務局自2008年開始進行第四次全國森林資源調查作業，調查對象普及於國有林事業區以及區外的林地，主要目標在取得台灣全島林地完整的森林利用資訊，包含全國森林面積、全國森林資源現狀、建立森林資源監測系統以及推估全國森林碳吸存量。第四次森林資源調查作業主要涵蓋照片樣點判釋、地面樣區調查以及林型圖繪製，主要核心工作包含地面調查以及航照判釋，利用系統取樣方法調查樣區資料推估森林蓄積及碳吸存量。

近期遙測工業發展出關鍵的遙測感測器，利用衛星太空取像方法，可以快速取得高空間解析力的衛星多光譜影像資料，例如IKONOS、QuickBird衛星，可以提供像元大小為公尺以下的多光譜影像，有效地提升以遙測方法檢測地面細部資訊的能力；相較於一般的多光譜衛星影像，WorldView-2(WV2)衛星影像涵蓋可見光至近紅外光光譜區域，新增的光譜波段可以提供較為精細的可見光光譜訊號，包含藍邊、黃光、紅邊等光譜，WV2單幅影像涵蓋寬度(swath width)為16.4km，以條帶方式連續的接收地面反射光能量成像，單一條帶影像的涵蓋面積為16.4km x 360km，提供像元大小約為2m的8個波段多光譜影像資料(藍邊、藍、綠、黃、紅、紅邊、兩個近紅外光)，以及像元大小約0.5m的單波段全色態影像資料，有利於大面積的森林資源環境監測的應用(Wolf, 2010；Samadzadegan *et al.*, 2012；Tu *et al.*, 2012)。衛星影像具有大面積涵蓋範圍、短期再訪能力以及可提供多光譜特性，對於大面積森林資源調查的需求上，相對地優於航照資料，因此，妥善利用WV2的高空間解析力多光譜影像，對於提高森林資源調查測繪土地被覆型(land cover)及林型圖(forest type)、降低資源調查工作人力以及經費負擔，提升繪製林型圖的時間效能應具有正面幫助。

遙測技術發展迄今已數十年，我國在衛星影像的森林資源遙測應用研究上，雖經多年努力，仍未能實質的將衛星遙測技術實際應用於第四次森林資源調查作業上。可能原因為傳統的多光譜影像所含有的光譜訊號相對的較為不足，尚不足以提供多元林型種類的潛在光譜變異，特別是缺乏利用高空間解析力影像進行林型圖繪製的標準作業流程尚未建立，以致未能建立足夠的信心水準。因此，本計畫的主要目的在於以國家森林資源調查遙測實務應用為導向，以第四次森林資源調查利用航照判釋技術所繪製的林型圖為依據，研究高空間解析多光譜影像於林型圖分類的應用特性。主要研究目的在於項目有下列幾項：

1. 研究並評估單一影像於國土土地被覆型分類的可行性。
2. 研究並評估單一影像於森林資源調查林型分類之可行性。
3. 研究並建立高解析度多光譜影像於林型分類之作業流程。





二、研究材料

(一) 研究地點概述

本研究資料由林務局農林航空測量所提供的研究南投林區以及嘉義林區的WV2衛星影像全色態影像、多譜態影像以及二種影像資料的全色態銳化影像。並請林務局提供第四次森林資源調查所繪製完成的試驗區範圍內之林型、照片樣點與地面調查有關資料。依據歷年可用的WV2影像涵蓋區以及排除雲覆蓋區(圖1)，本計畫所取得之影像範圍共區分為兩個區域，包含南投林區管理處轄管的濁水溪、埔里、丹大以及巒大等四個事業區的局部國有林地(右上角)以及嘉義林區管理處轄管大埔及玉井事業區局部國有林地(左下角)。

南投林區：

影像拍攝日期：2011年8月18日

時間：05：47：4631

影像座標(TWD97)：左上角 243877，2650866

右下角 261089，2623902

影像大小：10194*14700 pixels

嘉義林區：

影像拍攝日期：2011年11月30日

時間：02：48：3820

影像座標(TWD97)：左上角 191858，2595234

右下角 212444，2517296

影像大小：11031*39068 pixels

以上影像的解析度分別為2m(8個波段的多光譜影像資料)以及0.5m(單波段全色態影像資料)。

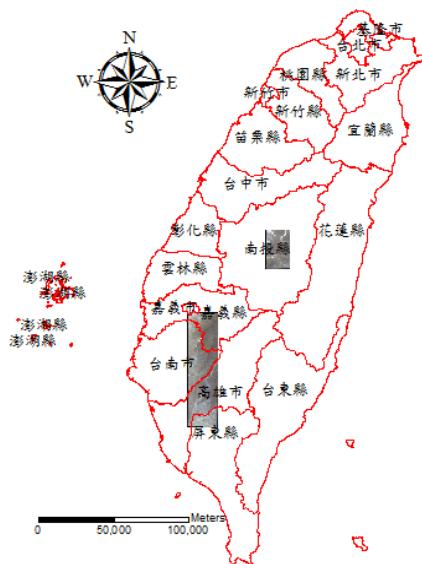


圖 1 研究影像位置





(二) 研究設備

1. 研究用軟體：Geomatica、Envi、ArcGIS、eCognition Developer
2. 電腦配備：
 - CPU：Intel Core I7-2630QM，2.0GHz
 - Memory：4GB
 - OS：Win 7 Premium
 - Video Card：Geforce GT540M CUDA 2GB

三、研究流程及方法

本計畫之研究可分為兩階段，分別為：土地被覆型分類及林型分類，首先以IPCC六類土地被覆型進行各種不同類型影像處理組合分析，藉以獲取最佳之影像處理流程。第二階段則以最佳影像處理流程進行林型分類，並建立林型分類作業程序。

(一) 土地被覆型

本階段的研究流程如下(圖 3)：

1. 原始衛星影像裁切

由於原始影像範圍廣闊解析度高，且各土地被覆型分布不一，若以原始影像進行處理相當耗時費工，因此在本研究中以同一張影像中可同時包含各土地被覆型、林型為原則將原始影像進行裁切，並依據本次研究目的裁切出包含各土地被覆型影像(圖 2)，而後再以此為基礎進行後續影像處理、分類及準確度評估作業。



圖 2 裁切後之影像

2. 大氣校正

衛星感測器所接收之輻射值，往往代表地面物體反射之特性，然而可能受地形效應、太陽照射等外在因素，導致感測器接受之輻射值有所差異，又衛星影像因為載台高程遠，受到大氣散射與當時狀態等因素影響比航空照片明顯，而且大氣中許多氣體如：水蒸氣、氧氣、臭氧、一氧化碳、二氧化碳、和甲烷都會產生散射現象，造成不正確光譜反射強度，並導致影像分類上的誤差，而波長越短，





越容易受到大氣中氣溶膠所散射。同時，本研究所取得的影像位於不同的地點及拍攝時間，因此為了使影像真實表現出正確地表物的光譜資訊，回復地表反射特性、增加影像灰度值範圍和對比效果，所以在進行分類前便須先以 FLAASH 進行大氣校正處理。

FLAASH 可處理任何高光譜、衛星和航照影像(860nm/1135nm)，同時校正垂直成像資料和測試成像資料，其採用 MODTRAN 4+ 輻射傳輸模型的代碼(Matthew *et al.*, 2000)由像元級的校正處理由於漫反射引起的連帶效應，包含卷雲和不透明雲層的分類圖並調整由於人為抑止而導致的波譜平滑，能有效消除大氣和光照等因素對地物反射的影響，獲得較為準確的地物反射率和輻射率、地表溫度等真實物理模型參數。

FLAASH 所使用的計算公式如下：

$$L = \left(\frac{A\rho}{1-\rho_e S} \right) + \left(\frac{B\rho_e}{1-\rho_e S} \right) + L_a \quad (1)$$

其中 L 為在感應器像元中的光譜輻射， ρ 為像元的地表反射率， ρ_e 為像元和周圍區域的平均表面反射率， S 為大氣的球型反照率， L_a 為大氣的反向散射輻射率， A 、 B 為取決於大氣和幾何條件的係數。

在本研究中 FLAASH 的參數設定依據影像取得的各項數值進行設定，包含季節、緯度、時間、水蒸氣量等，設定細節如圖 5 所示，其中大氣模式(Atmospheric model)是以季節-緯度地表溫度模式(seasonal-latitude surface temperature model，表 1)為基礎，依據本研究所採用影像之緯度(23.10750008)及拍攝月份(Nov)進行選取”Tropical”作為設定。使用 WV2 影像時無法使用”water retrieval”的選項，因此必須設定”Water column multiplier”，而根據水蒸氣量標準表(The standard column water vapor amount)可知數值應設定為”4.11”(表 2)。

在大氣溶膠模式(Aerosol model)的設定中，因本研究所切割之影像中的建物甚少而不會受到大氣溶膠的強烈影響所以選擇”Rural”作為設定。氣溶膠反演(Aerosol Retrieval)的值需要由 Kaufman-Tanre (KT) upper channel(波長 2100-2500)所取得，而本研究中並無此波長的波段故設定選擇”None”，因此”Multispectral Setting”中對於 KT 的設定也同樣採用預設值。初始可見(Initial Visibility)因本次影像並無明顯受雲霧影響而可見度高，可視為”Clear”狀態故設定為 40(表 3)。而在”Advanced Setting”中由於並沒有”Aerosol Scale Height (km)”和”CO₂ Mixing Ratio (ppm)”的實際數據，因此採用預設值的 1.5km 和 390ppm。



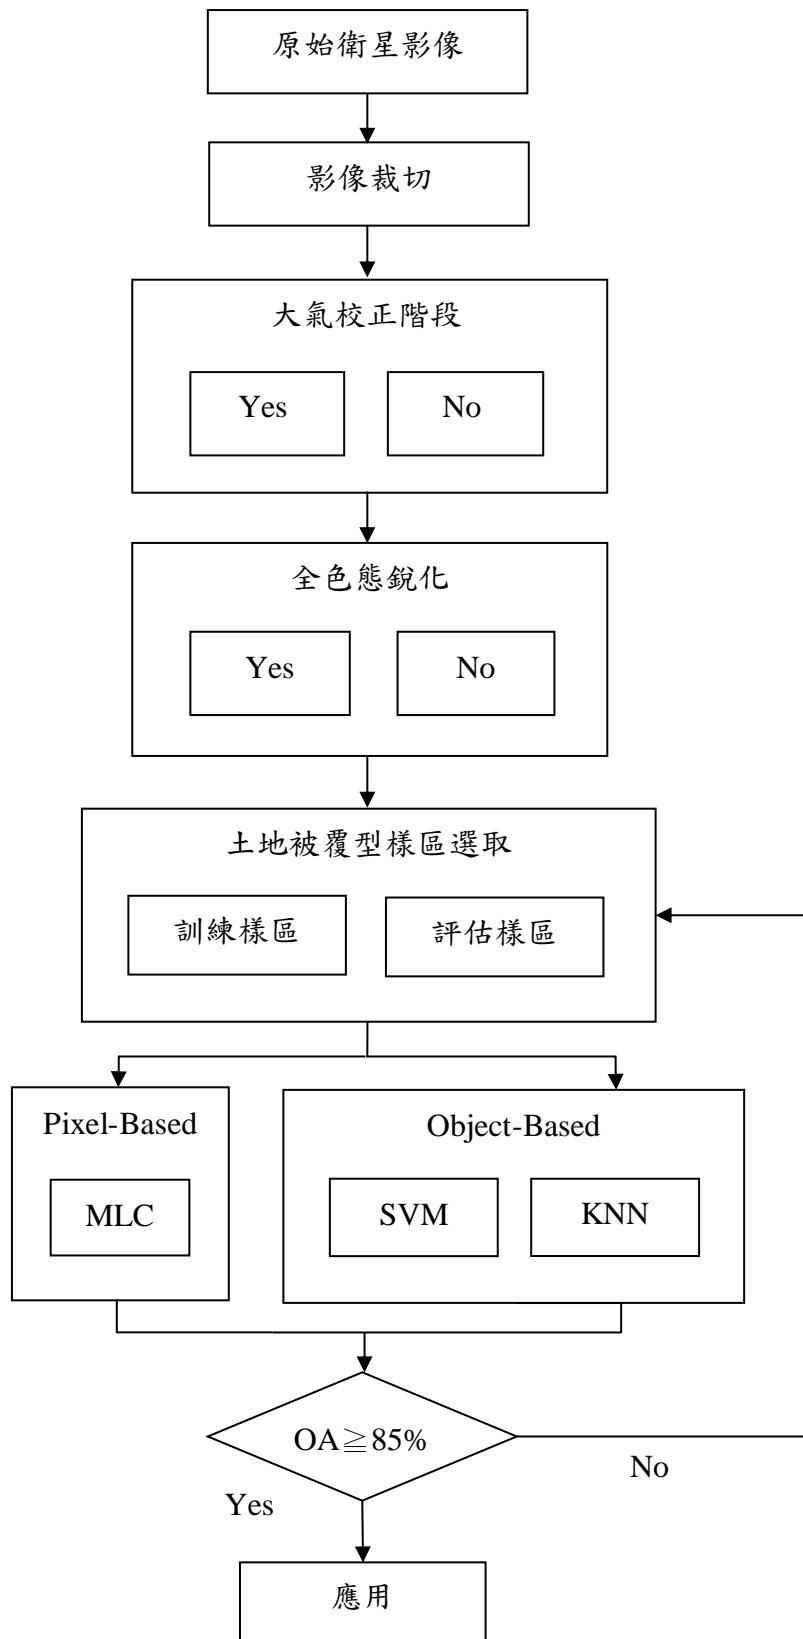


圖 3 土地被覆型分類研究流程





Input Radiance Image	D:\project\17c2\image\17c2rad_BIP			
Output Reflectance File	C:\Users\USER\Desktop\test for flasch			
Output Directory for FLAASH Files	D:\project\Output for FLAASH\			
Rootname for FLAASH Files	17c2_			
Scene Center Location DD <-> DMS		Sensor Type	WorldView-2	Flight Date
Lat 23.10750008		Sensor Altitude (km)	770.000	Nov 30 2011
Lon 120.53309631		Ground Elevation (km)	0.120	Flight Time GMT (HH:MM:SS)
		Pixel Size (m)	2.000	2:48:38
Atmospheric Model Tropical		Aerosol Model	Rural	
Water Retrieval No	Up/Down	Aerosol Retrieval	None	
Water Column Multiplier 4.11		Initial Visibility (km)	40.00	
Apply	Cancel	Help	Multispectral Settings...	Advanced Settings... Save... Restore...

圖 4 FLAASH 使用者介面

表 1. 季節-緯度地表溫度模式

Latitude (°N)	Jan	March	May	July	Sept	Nov
80	SAW	SAW	SAW	MLW	MLW	SAW
70	SAW	SAW	MLW	MLW	MLW	SAW
60	MLW	MLW	MLW	SAS	SAS	MLW
50	MLW	MLW	SAS	SAS	SAS	SAS
40	SAS	SAS	SAS	MLS	MLS	SAS
30	MLS	MLS	MLS	T	T	MLS
20	T	T	T	T	T	T
10	T	T	T	T	T	T
0	T	T	T	T	T	T
-10	T	T	T	T	T	T
-20	T	T	T	MLS	MLS	T
-30	MLS	MLS	MLS	MLS	MLS	MLS
-40	SAS	SAS	SAS	SAS	SAS	SAS
-50	SAS	SAS	SAS	MLW	MLW	SAS
-60	MLW	MLW	MLW	MLW	MLW	MLW
-70	MLW	MLW	MLW	MLW	MLW	MLW
-80	MLW	MLW	MLW	MLW	MLW	MLW





表 2. 水蒸氣量標準表

Model Atmosphere	Water Vapor (std atm-cm)	Water Vapor (g/cm ²)	Surface Air Temperature
Sub-Arctic Winter (SAW)	518	0.42	-16°C (3°F)
Mid-Latitude Winter (MLW)	1060	0.85	-1°C (30°F)
U.S. Standard (US)	1762	1.42	15°C (59°F)
Sub-Arctic Summer (SAS)	2589	2.08	14°C (57°F)
Mid-Latitude Summer (MLS)	3636	2.92	21°C (70°F)
Tropical (T)	5119	4.11	27°C (80°F)

表 3. 能見度近似值

Weather Condition	Scene Visibility
Clear	40 to 100 km
Moderate Haze	20 to 30 km
Thick Haze	15 km or less

3. 全色態銳化

本研究所使用的WV2影像為像元大小約為2m的8個多光譜影像波段(藍邊、藍、綠、黃、紅、紅邊以及兩個近紅外光波段)，與像元大小約0.5m的單波段全色態影像資料，為了獲得高空間解析的多光譜影像資料，便需要將兩種影像進行影像融合(image fusion)，以期提供研究區域較詳細的土地被覆型資訊。

影像融合是將不同來源或性質的影像，依照後續應用之需求來擷取各影像的優點，並加以合成的一種方法，使經過融合後的影像兼具來源影像之優點，並適用於各種特定的領域，而其中全色態銳化法(pansharpening)是影像融合中，特別針對同感測器的全色態與多光譜影像融合的研究議題(邱彥瑋，2012)。

全色態銳化法為影像融合中新的處理技術，以統計原理為基礎並利用最小二乘法對參與融合波段的灰度值進行最佳匹配及調整單個波段的灰度分佈以減少全色態銳化結果顏色偏差的方法，另外對所有輸入的波段進行一系列的統計運算以消除全色態銳化結果對資料集的依賴性並提高全色態銳化過程的自動化程度(Zhang, 2004)。

在本研究中將採用的全色態銳化程序包含：革蘭氏施密特光譜銳化法(Gram-Schmidt Spectral Sharpening, G-S, Laben and Brower, 2000)、PC光譜銳化法(PC Spectral Sharpening, PC, Welch and Ehlers, 1987)以及GA全色態銳化法(Geomatica Advanced Pan Sharpening, GA, Zhang, 2004)，並就影像融合的結果進行比較以選取較佳的處理結果。





(1) 草蘭氏-施密特光譜銳化法(G-S)

處理程序如下：

- I. 從較低空間解析度的光譜波段來模擬全色態波段。
- II. 在模擬的全色波段和光譜波段上執行草蘭氏-施密特轉換，模擬的全色態波段被視為第一波段。
- III. 將高空間解析度的全色態波段與草蘭氏-施密特波段進行交換。
- IV. 應用反草蘭氏-施密特轉換以形成全色態銳化的光譜波段。

(2) PC 光譜銳化法法(PC)

處理程序如下：

- I. 在多光譜資料上執行 PC 光譜銳化法。
- II. 將 PC 第一波段替換為高解析度波段，然後縮放高解析度影像的比例以匹配 PC 第一波段，如此一來便不會發生光譜訊號失真的現象。
- III. 執行反轉換。
- IV. 使用最鄰近法(nearest neighbor)重新採樣多光譜資料至高解析度的像元大小。

(3) GA 全色態銳化法(GA)

即 Zhang 於 2004 年發表的具單一流程(one-step process)全自動影像處理程序，並假設如果原始多光譜影像和全色態影像間具有地理參照，則重新取樣的流程能一併完成，同時全部的多光譜波段也可全部一次融合。

4. 樣區選取

土地被覆型樣區的選取以IPCC(Intergovernmental Panel on Climate Change)分類機制為基礎，分為林地、農田、草地、濕地、定居地、以及裸地(其他土地)等六大類。依據國際濕地保護公約(Ramsar Secretariat, 1971)對於濕地的定義為「沼澤、沼泥地、泥煤地或水域等地區，不管其為天然或人為、永久或暫時、死水或活水、淡水或海水、或兩者混合、以及海水淹沒地區，其水深在低潮時不超過6公尺者」，一般而言可分為沿海濕地以及內陸濕地，前者可再分為紅樹林濕地(例如：嘉義東石、好美寮、台南北門、七股)、河口三角洲濕地(例如：曾文溪口濕地)、潟湖濕地(例如：台南北門三寮灣、七股網子寮汕)、鹹水沼澤濕地(例如：嘉義鰲鼓濕地)、海灘濕地(例如：西南沿海潮間帶)、小型島嶼濕地(例如：澎湖貓嶼、大倉嶼、員貝嶼)、鹽田濕地(例如：台南七股、北門鹽田、嘉義白水湖)。後者則可分為淡水湖泊濕地(例如：墾丁龍鑾潭、美濃中正湖、台南葫蘆埤、番子田埤、高雄觀音湖)、溪流濕地(例如：高屏溪、東港溪、曾文溪、八掌溪等河川行水區及洪水平原)(內政部城鄉發展分署網站)。

同時依據濕地的重要性分為國際級、國家級和地方級等三類別，但實際上許多未正式納入濕地的海岸或河岸地區仍舊具有濕地功能，因此只要符合濕地定義





的地區皆可視為濕地。因此本研究所使用的影像範圍內所包含的濁水溪、高屏溪流域及諸多人工水源(灌溉渠道、高爾夫球場水池、蓄水池等)皆可視為濕地的一種。

將土地被覆型依據上述定義選取訓練樣區後，利用轉換分離度(transformed divergence, TD)方法計算評估各樣區光譜分離度指數試驗，以評估各影像處理組合對於樣區的敏感度，公式如下：

$$TD_{ij} = 2000 \left(1 - \exp \left(\frac{-D_{ij}}{8} \right) \right) \quad (2)$$

$$D_{ij} = \frac{1}{2} \text{tr} \left((C_i - C_j)(C_i^{-1} - C_j^{-1}) \right) + \frac{1}{2} \text{tr} \left((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T \right) \quad (3)$$

其中 i 、 j 為兩個類別的比較， C_i 為 i 類別的協變方矩陣， C_j 為 j 類別的協變方矩陣， μ_i 為 i 類別的平均向量， μ_j 為 j 類別的平均向量， tr 為矩陣對角線總和。此外，根據附錄二可以發現本研究所選之各類別訓練樣區在各波段均為常態分布且無 Singular error，因此所選訓練樣區之光譜特性足可代表各類別。

5. 影像分類

本研究利用最大概似法(Maximum Likelihood Classifier, MLC)、支持向量機(Support Vector Machine, SVM)以及最近相鄰法(Nearest Neighbor, NN)三種分類器進行土地被覆型的分類研究。最大概似法係以像元為基礎進行組類光譜特徵的訓練及分類，故本研究稱之為像元基礎的最大概似法分類(pixel-based maximum likelihood classifier)，以下均以 PB-MLC 代表之，而支持向量機係以物件為基礎的方式進行組類光譜特徵的訓練及分類，故本研究稱之為物件基礎的支持向量機分類(object-based support vector machine)，並以 OB-SVM 代表之，最近相鄰法(nearest neighbor, NN)以空間中的點表示資料，並假設屬於同類別的點之間的距離會比較接近(James, 1985)，於「(三)分類器概述」中有更深入之探討。

6. 準確度評估

將各組合之分類結果以整體精度(Overall Accuracy, OA)、Kappa 係數、生產者精度(Producer Accuracy, PA)、使用者精度(User Accuracy, UA) (Cohen, 1960、Congalton and Green, 2009)等四種方法進行交叉比對以確認最佳準確度。

生產者精度(PA)為針對單一類別的精度表示，任一種類中，分類正確的像元數量除以參考資料中屬於此一種類的像元總和。其公式為 $(1-\text{Omission}) * 100$ 。

使用者精度(UA) 和生產者精度同樣為針對單一類別的精度表示。採用任一種類別中分類正確的像元除以分類後被歸為此種類別的像元總和，其公式為 $(1-\text{Commission}) * 100$ 。

7. 應用

分類準確度高之流程將應用於下一階段的林型分類上。





(二) 林型

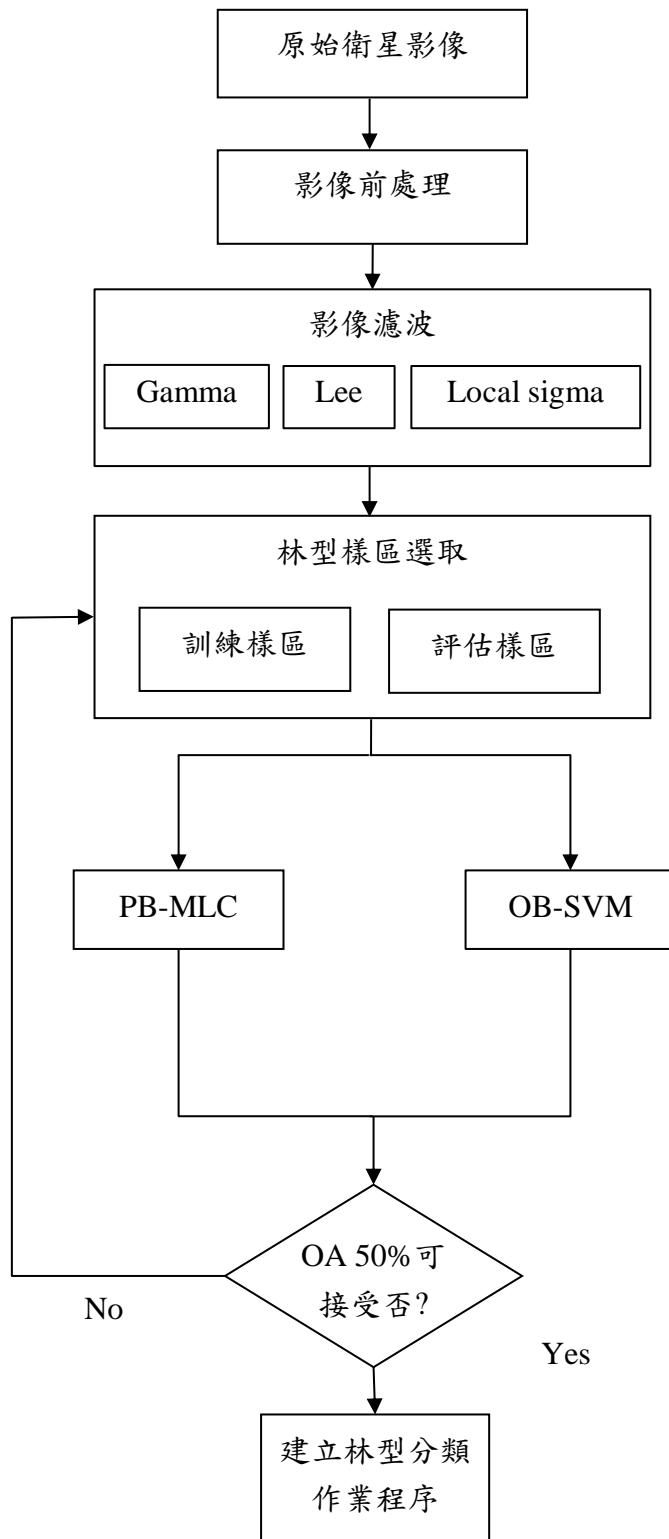


圖 5 林型分類流程圖





1. 影像前處理

本階段研究首先將 WV2 影像依據先前所獲得的最佳處理流程，同樣以 WV2 中之 8 個波段進行大氣校正及全色態銳化處理，同時因 WV2 影像範圍中各林型的分布相當分散，因此以[第四次森林資源調查]的林型圖為依據，根據計劃目標的 7 種林型裁切出 400m*400m 的影像各 3 個共 21 個影像範圍，最後將裁切出之影像接合成一張影像以提升後續分類作業的效率。

2. 影像濾波

從土地被覆型的研究可知經全色態銳化後之影像具有高解析度之特性，但同時影像也會因像元數增加而使物體邊緣產生破碎化現象，使得在進行分類時易因光譜訊號的不同而造成錯誤的分類。而影像濾波具有使影像中產生破碎化之物體平滑化的作用，使得物體具有較為純粹之紋理特徵而較易產生正確的分類(Xiao et al., 2003; Oiu et al., 2004; Leeuw and Carvalho, 2009; Ozdarici and Akyurek, 2010 ; Meenakshi and Punitham, 2011)。

在本階段的影像濾波採用 Gamma、Lee 及 Local sigma 等三種濾波器，其下再分為像元大小 3*3、5*5、7*7、9*9，而 Lee 各種像元大小下再細分 NV 1、10、20 等不同組合，詳細組合如表 19：

表 4. 不同濾波器設定之組合

Gamma	3*3				
	5*5				
Lee	3*3	NV 1	3*3	NV 1	
		NV 10		NV 10	
		NV 20		NV 20	
	5*5	NV 1	5*5	NV 1	
		NV 10		NV 10	
		NV 20		NV 20	
	7*7	NV 1	7*7	NV 1	
		NV 10		NV 10	
		NV 20		NV 20	
Local sigma	9*9	NV 1	9*9	NV 1	
		NV 10		NV 10	
		NV 20		NV 20	
Local sigma	3*3				
	5*5				





(1) Gamma

Gamma 濾波器可以保留影像邊緣，是以增減的平均數和變數為參數用於增加的雜訊模式。

(2) Lee

Lee 濾波器是一個基於標準差的濾波器，用於平滑強度跟圖像密切相關的雜訊資料。它對基於獨立濾波視窗中計算的統計圖資料進行濾波。Lee 濾波器在壓制雜訊的同時，保留了圖像的尖銳和細節。被濾掉的像元將用周圍像元計算的值代替。

(3) Local sigma

Local sigma 濾波器運用濾波器盒(filter box)計算局部標準差，判定在濾波器視窗內的有效像元。它只用濾波器盒裡的有效像元平均值代替參與濾波的像元。這一濾波甚至在對比度低的區域，也能很好地保留細節和有效地減少斑點雜訊。

3. 林型樣區選取

將林型依據針葉樹林、闊葉樹林、針闊葉樹混淆林、竹林、竹闊混淆林、竹針混淆林、竹針闊混淆林等 7 種林型進行訓練樣區選取，利用轉換分離度(transformed divergence, TD)方法計算評估各樣區光譜分離度指數試驗，以評估各影像處理組合對於樣區的敏感度，同時在訓練樣區外另選取評估樣區以確認各分類型在自動分類下的準確度。

4. 分類及準確度評估

根據土地被覆型分類結果，在本階段研究中將分類結果不佳的 KNN 剔除，因此以 PB-MLC 及 OB-SVM 兩種分類法進行分類比較。進行分類處理後將各組合之分類結果以整體精度(Overall Accuracy, OA)、Kappa 係數、生產者精度(Producer Accuracy, PA)、使用者精度(User Accuracy, UA)等四種方法進行交叉比對，以確認哪種處理過程及分類法可獲得最佳的準確度。

5. WV2影像林型分類作業建議方案

根據各種處理組合之分類結果，建立 WV2 影像之林型分類方式，做為日後該類衛星影像在林型分類上的處理依據。





(三) 分類器概述

最大概似法、支持向量機及最近相鄰法三種分類器概述如下：

1. 最大概似法

最大概似法(MLC)係一種統計學為基礎的監督式分類方法，應用該法必須先就影像中之各種組類，選擇部分像元為樣本，用以訓練各種組類光譜空間之特徵參數，均值向量為 μ_j 及共變異數矩陣為 Σ_j ，再依據影像中待分類像元之光譜值，計算其隸屬某一組類之概似值(likelihood)，再將其分類為具最大概似值之組類(林金樹 2001)。設 $\{\omega_j\}_{j=1}^c$ 為 C 種土地利用型之集合，又設對某一土地利用型 ω_j ，其具有一已知的條件機率密度函數 $p(x|\omega_j)$ ，可以表示樣本 x 屬於 ω_j 之概似值，如果樣本 x 滿足公式(4)條件時，則最大概似法將該樣本 x 分類為 $\omega^{*(x)}$ 組類。

$$\omega^{*(x)} = \arg \left\{ \max_{1 \leq j \leq c} p(x|\omega_j) \right\}, \text{ i.e., } p(x|\omega^{*(x)}) = \max_{1 \leq j \leq c} p(x|\omega_j) \quad (4)$$

當 $p(x|\omega_j)$ 具有高斯分佈特性時，其均值向量為 μ_j ，共變異矩陣 Σ_j ，則(1)式即可改寫成高斯最大概似分類法則(Gaussian ML classifier) (公式 5)。

$$\omega^{*(x)} = \arg \left\{ \min_{1 \leq j \leq c} [(x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j)] \right\} \quad (5)$$

MLC 法早期曾廣泛應用於多譜影像資料之分類，同時也成功應用於高光譜資料分類上(Lee et al., 1993; Jia and Richard, 1994; Hoffbeck and Landgrebe, 1996; Tu et al., 1998)。利用 MLC 法分類時，各組類之訓練樣本最少必需大於波段數，若欲避免某一組類 ω_j 因樣本數太少，導致其共變異數矩陣 Σ_j 為 singular (Herstein and Winter, 1988)，無法求得該組類共變異矩陣之逆矩陣 Σ_j^{-1} ，該組類在分類過程中將被其他光譜特徵相似的組類所涵蓋(dominate)，因而降低分類準確度，則宜以波段數之 10~100 倍的像元數作為訓練樣本，同時可以降低或避免發生 Hughes 現象(Hughes, 1968; Swain and Davis, 1978; Jia and Richards, 1994; Hoffbeck and Landgrebe, 1996; Schowengerdt, 1997)。

2. 支持向量機

是一種基於線性判別的學習機，是一種應用於二元組類分類的理論。一般以統計方法為基礎的分類器，例如 MLC，需要較多的訓練樣本，才能取得具有較佳統計特性的光譜特徵；但是，SVM 可以不受樣本數量的限制，它只需要少數的關鍵樣本就足以在既有的光譜空間上建構一個超平面(hyperplane)，進而根據該超平面，將所有的等待分類的資料，就其所在的光譜空間上的位置，將其分類





到超平面的兩側，決定所有資料的所屬組類，這種分類器特稱為 SVM 二元分類器(binary SVM classifier)，一般均稱為 SVM。

假設有一組訓練資料 $\{x_i, y_i\}$, $i=1, 2, \dots, N$, 其中 N 代表訓練樣本的數量, $y_i \in \{-1, 1\}$, $y_i=+1$ 代表組類 ω_1 、 $y_i=-1$ 代表組類 ω_2 ，則至少有一個可能是線性的或非線性的超平面，可以兩個組類的資料分開(圖 6)。公式(6)所示為 SVM 二元分類器的一般化公式，它將所提供的訊量光譜向量分派到一個高維度的特徵空間，並在該空間上建立一個組類分離最適化的超平面；公式中的 λ_i 為拉格朗日乘子(Lagrange multiplier)， x_i 是對應於 λ_i 的支持向量(support vectors)， x 是待分類的輸入向量， w_0 是訓練樣本配適超平面的誤差項， $K(x_i, x)$ 為核函數(公式 7)代表支持向量於決定待分類像元所屬組類時的影響力或權重。

$$f(x) = \sum_{i=1}^N \lambda_i y_i K(x_i, x) + w_0, \quad \sum_{i=1}^N \lambda_i y_i = 0 \quad \text{and} \quad \lambda_i \geq 0, i = 1, 2, \dots, N. \quad (6)$$

$$K(x_i, x) = \exp(-\gamma \|x_i - x\|^2), \quad \gamma > 0 \quad (7)$$

比較普遍應用的核函數(kernel functions)有線性函數(linear function)、多項式函數(polynomial function)、徑向基核函數(radial basis function, RBF)以及 S 型函數(sigmoid function)。Hsu(2010)指出 SVM 分類時選用 RBF kernel 是很合理的選擇，因為它可以將訓練樣本資料映射到一個較高維度的空間，同時可以處理組類值與組類屬性為非線性關係資料，Tzotsos and Argalias (2008)依據 Huang *et al.*, (2002) 及 Mercier and Lennon (2003)的研究結果也提出：RBF 在遙測資料分類上可以非常有效益且準確，許多相關研究均印證了 RBF 在資料分類上的優勢(Baesens *et al.*, 2000; de Carvalho *et al.*, 2000; Hsu *et al.*, 2010; Widjaja *et al.*, 2012; Gaspar *et al.*, 2012)；在森林資源遙測研究上的應用上，例如火災跡地分類(Ajeng and Lin, 2011)以及紅樹林分佈的分類(Lin and Trianingsih, 2012)，均顯示 RBF 在 SVM 分類器的應用價值。因此，本研究採用 RBF 於 WV2 影像的土地被覆型以及林型的物件分類研究。



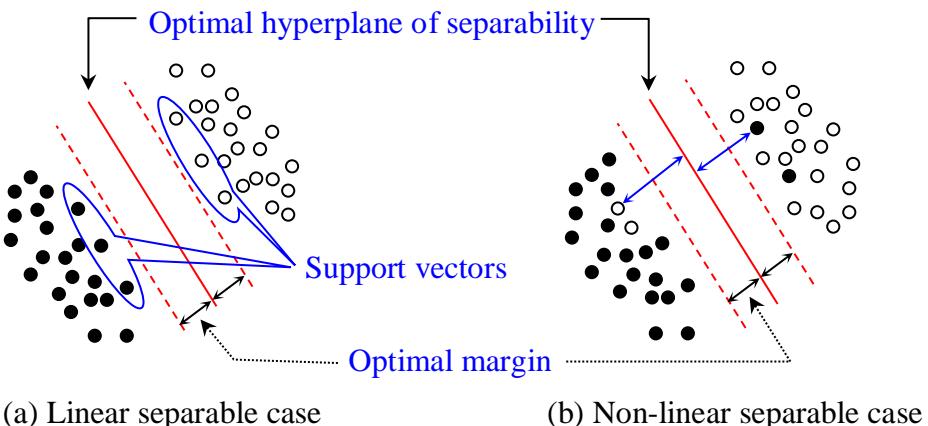


圖 6 SVM 二元組類分類器理論示意圖(修自 Mercier and Lennon 2003)

一般而言，土地被覆型以及林型分類係屬於多元組類的分類問題(multiclass classification)，SVM 二元分類器在多元組類的分類上係採用「多組」SVM 二元分類器(稱為 SVM 多元分類器)的方式完成分類工作。SVM 多元分類器的運作機制有一對多(one-against-all)、一對一(one-against-one)、不循環有向圖(directed acyclic graph, DAG)等三種主要方式。Hsu and Lin (2002)的研究顯示一對一以及不循環有向圖兩種方式的工作效率相似，兩種方法均比一對多的方法更適合於多元組類的實務應用。假設一個影像含有 k 個組類，則以一對一方式建構二元組類的超平面時，至少要建立 $k(k-1)/2$ 對。所以，本研究為物件基礎的 SVM 分類(OB-SVM)係以一對一方式，建立所有訓練樣本每兩個不同組類為一組的 SVM 二元組類超平面，再利用 Max-Wins Policy (Tzotzos and Argialas 2008) 決定待分類物件的所屬組類。物件分類時所採用的特徵包含光譜(spectral or color features)、紋理(textural features)以及形狀(shape or spatial features)三項特徵，在本研究所使用的各種物件特徵請詳見表 5。光譜特徵是由影像中每一個輸入的波段來計算，而特定像元群集(pixel cluster)的特徵值是從輸入的波段來計算，其中分割影像用的標籤(label)具有相同數值。紋理特徵的計算有兩個步驟，首先對於輸入的影像波段應用預先定義大小的方形核心參數，該特徵會計算核心視窗中的所有像元並且其結果會參照核心的中心像元，接著會平均像元群集中每個穿過的像元以對每個波段的分割標籤建立特徵值。形狀特徵是由計算多邊形來定義像元群集的邊界，因此不需要用到波段。

3. 最近相鄰法

最近相鄰法以空間中的點表示資料，並假設屬於同類別的點之間的距離會比較接近。因此，對於一筆未知類別的測試資料，只要尋找在訓練資料中和該資料距離最接近的點，便可決定該筆資料和此最接近的點屬於同類別。由於使用簡易，因此具有許多相關的研究(Lam and Ho, 1998 ; Jensen *et al.*, 2003 ; Shahabi *et al.*,





2003；黃冠中，2007；楊元琪，2007；吳季桓，2010；張伯辰等，2013)。

通常，在訓練資料具有很多雜訊的情況下，若只用最靠近的資料來決定測試資料的類別時，可能會導致分類的效果不彰。常見的做法為先取與該筆測試資料最接近的 K 個訓練資料點，再依據其對應的 K 個類別進行投票(Voting)或加權投票(Weighted Voting)以決定最後的類別。此方法稱為 KNN((K-nearest neighbor)。

KNN 中經常使用歐基里德距離(Euclidean Distance)對兩點間或兩類別中心之距離進行衡量，其假設 K 維的空間中有兩點存在， $x=[x_1, x_2, \dots, x_K]$ ， $y=[y_1, y_2, \dots, y_K]$ ，則兩點間的歐基里德距離為 $d(x, y)$ ：

$$d(x, y) = \sqrt{\sum_{i=1}^k (y_i - x_i)^2} \quad (9)$$

表 5. 物件導向屬性設定

	Attribute	Description
Spectral	Spectral_Mean	在 x 波段中含有像元區域的平均值
	Spectral_Max	在 x 波段中含有像元區域的最大值
Texture	Texture_Range	核心內部含有像元區域的平均數據範圍
	Texture_Mean	核心內部含有像元區域的平均數據範圍
	Texture_Variance	核心內部含有像元區域的平均變異量
Shape	Compactness	多邊形緊緻性(Compactness)測量。 $Compactness = (4 * \text{多邊形面積} / \pi)^2 / \text{外部輪廓長度}$
	Roundness	將多邊形面積與多邊形最大直徑平方進行比較的測量方式。“最大直徑”是封閉多邊形之方向包圍盒(oriented bounding box)的主軸長度 $\text{Roundness} = 4 * (\text{多邊形面積}) / (\pi * \text{主軸長度}^2)$
	Form_Factor	將多邊形面積與總周長平方進行比較的測量方式。 $\text{Form_Factor} = 4 * \pi * (\text{多邊形面積}) / (\text{總周長})^2$
	Rectangular_Fit	表示如何由矩形來說明形狀。這項屬性將多邊形面積與封閉多邊形之方向包圍盒進行比較。矩形的數值=1，非矩形數值<1。 $\text{Rectangular_Fit} = \text{多邊形面積} / (\text{主軸長度} * \text{短軸長度})$
	Main_Direction	多邊形長軸與 x 軸的夾角。主要的取值範圍由 0-180 度。90 度代表北/南，0-180 度代表西/東。

(四) 訓練樣區及評估樣區之決定





1. 土地被覆型

在本階段研究為選取影像中具有多數土地被覆型的範圍作為土地被覆型分類的研究區域(紅框)，並由其中選取具各項土地被覆型的部分作為本階段土地被覆型分類之用(綠框)(圖7)，樣區座標及影像大小如下：

樣區座標(TWD97)：左上角200076 2542472

右下角204600 2539942

影像大小 9052*5062 pixels

土地被覆型以IPCC分類機制為基礎，將土地被覆型分類為林地、農田、草地、濕地、定居地、以及裸地(其他土地)等六大類。訓練樣區的選取如圖8所示。



圖 7 土地被覆型分類影像區域



圖 8 訓練樣區分佈





訓練樣區選取完畢之後，根據處理組合的不同可分為原始影像、全色態銳化之原始影像、FLAASH 大氣校正影像、全色態銳化之 FLAASH 影像共四種影像處理格式，並進行各土地被覆型光譜分離度分析，以確認哪種影像處理對於土地被覆型樣區有較佳的辨識能力。原本的土地被覆型共有六類，但在光譜分離度分析上有些分類型中所具有的物體種類較為複雜(水體、裸露地)或易因外觀、顏色、特徵上的相近而產生誤判(農田)，這些區域由人眼進行辨識時可主觀將其區分，但進行分類時卻可能因光譜訊息相近而被分為一類，因此需要額外將這些分類再細分為次分類(sub-classes)以確定在何種處理下具有較佳的分類準確度，評估之後再將這些次分類回歸至原本的分類之中。在各土地被覆型中，森林、草地和定居地(Urban)可以由普通的反射率特徵來進行分類，但農田、裸露地和濕地則因為較為複雜而需要再分為數種次分類。在本研究中以人工辨識為依據將農田再細分為農業用地(Agriculture，具有綠色植群的地區)和建物(Agri_man，位於農地附近的綠色屋頂建物)，濕地細分為水體(Water，例如高爾夫球場水池、魚塭)和河流(River)，裸露地細分為裸露土壤(Bare_soil，沒有植群覆蓋的農地)、沙地(Sand)和石頭地(Stone，河岸)，總計共有 10 種組類。利用 PB-MLC 法分類時，各組類之訓練樣本最少必需大於波段數，若欲避免某一組類 ω_j 因樣本數太少，導致其共變異數矩陣 Σ_j 為 singular，無法求得該組類共變異矩陣之逆矩陣 Σ_j^{-1} ，該組類在分類過程中將被其他光譜特徵相似的組類所涵蓋(dominate)，因而降低分類準確度，則宜以波段數之 10~100 倍的像元數作為訓練樣本，同時可以降低或避免發生 Hughes 現象(林金樹，2001)。因此本研究所選擇的各組類訓練樣區的像元數均大於 80 個像元，並檢核樣本資料的分佈，以及評估各組類的光譜分離度。在本研究中將光譜分離度的間距範圍定為 0~2000 之間，越接近 2000 代表光譜分離度越大，越能區別該分類型，一般而言光譜分離度 ≥ 1900 即可視為能有效分類，(1900, 1700)代表有機率進行有效的分類， ≤ 1700 代表無法產生有效的分類(Jensen, 1986；林金樹，1999)。

依據上述的標準可以發現原始影像、FLAASH 大氣校正和全色態銳化之 FLAASH 影像這三種類型影像的分類型區分度皆高達 1999~2000(表 12、13)，顯示不論何種土地被覆型皆能有效的區分，而全色態銳化之原始影像土地被覆型的光譜分離度卻有相當大的起伏，舉例來說除 Forest 和 Sand 具有較高的光譜分離度外，其他分類型的光譜分離度大部分介於 1700~1900，顯示在分類上只能有機率進行有效的分類，而部分分類型的光譜分離度低於 1700 則無法產生有效的分類。探究其原因可能在於 2m 的多光譜影像雖較包含較多光譜訊息但因解析度低而較無法顯示出其特徵，而在執行全色態銳化處理後便會因解析度提升使光譜訊號特徵被放大(林金樹，2004)，因此進行分類時同一區域物體便易因包含其他訊號特徵而遭到誤判，由此可推論進行影像分類時並不適合使用直接進行全色態銳化處理的原始影像，以確保各分類型之間具有較佳的光譜分離度。

原始影像與大氣校正影像對於各分類型雖具有相當高的光譜分離度，但其解析度僅達 2m 水準，在樣區圈選上易因影像物體無法清楚辨識而圈選至錯誤的區





域，而後進行影像分類時便可能因此產生誤判的現象。相反的，經過全色態銳化處理後可以得到空間解析度達 0.5m 的光譜影像，能有效提升物體的辨識率並依據影像特徵進行樣區選取，同時減少圈選至錯誤區域的機率以增加影像分類上的準確度(圖 9)。



圖 9 全色態銳化處理後影像局部放大(以 GA 法為例，左為處理前，右為處理後)





表 6. 原始影像土地被覆型光譜分離度(上方為未全色態銳化、下方為已全色態銳化)

	Forest	Sand	Grassland	Water	River	Stone	Urban	Ba
Forest		2000	2000	2000	2000	2000	2000	20
Sand	1979		2000	2000	2000	2000	2000	20
Grassland	1999	1987		2000	2000	2000	2000	20
Water	1999	1998	1746		2000	2000	2000	20
River	1999	1999	1561	1811		2000	2000	20
Stone	1999	1999	1993	1996	1576		2000	20
Urban	1999	1991	1752	1812	1157	1890		20
Bare_soil	1999	1938	1873	1874	1925	1998	1522	
Agriculture	1999	1998	1678	1954	1367	1831	1447	17
Agri_man	1999	1999	1994	1997	1955	1778	1985	19

表 7. FLAASH 影像土地被覆型光譜分離度(上方為未全色態銳化、下方為已全色態銳化)

	Forest	Sand	Grassland	Water	River	Stone	Urban	Ba
Forest		20000	2000	2000	2000	2000	2000	20
Sand	2000		2000	2000	2000	2000	2000	20
Grassland	2000	2000		2000	2000	2000	2000	20
Water	2000	2000	2000		2000	2000	2000	20
River	2000	2000	2000	2000		2000	2000	20
Stone	2000	1999	2000	2000	2000		2000	20
Urban	2000	2000	2000	2000	2000	2000		20
Bare_soil	2000	2000	2000	2000	2000	2000	2000	
Agriculture	1999	2000	1999	2000	2000	2000	2000	20
Agri_man	2000	2000	2000	2000	2000	2000	2000	20





為確保分類結果之準確度及可信度，因此依據隨機取樣方法決定 100 個評估樣點(各評估樣點座標詳見附錄 1)，並以每個樣點為核心擴大為 19*19 的小區域為評估樣區(圖 10)，總計樣本像元數量為 35876(各評估樣區大小詳見表 8)。



圖 10 評估樣區位置圖(上為隨機樣點，下為以隨機樣點為核心擴大的評估樣區)





表 8. 訓練樣區及評估樣區選取像元數一覽表

類別	訓練樣區	評估樣區
FOREST	7020	6480
SAND	933	併於 BARELAND
GRASSLAND	4061	4392
WATER	5790	3249
RIVER	8209	併於 WATER
STONE	6413	併於 BARELAND
URBAN	6931	4370
BARELAND	7542	6433
FARM	6572	7342
GREENHOUSE	3597	3610
TOTAL	57068	35876

依據隨機不置還取樣理論，其取樣樣本數公式如下式 10：

$$n \geq \frac{N \cdot t_{\alpha}^2 (CV)^2}{N \cdot E^2 + t_{\alpha}^2 (CV)^2} \quad (10)$$

N：所有像元數(未融合)2864958(已融合) 49439808

T：根據自由度(n-1)在 t 表上依照所定顯注水準查出為 2.33(顯注水準右單尾 1% 自由度無限大的情況下)

E：誤差率 E%(0.01)

CV：變異係數

變異係數(CV)=標準差(SD)/平均值(Mean)

表 9. 各波段 CV 計算

波段	標準差	平均值	CV
BAND1	35.568	359.987	0.098804
BAND2	51.01	293.604	0.173737
BAND3	84.656	358.434	0.236183
BAND4	106.348	310.269	0.342761
BAND5	80.159	180.211	0.444806
BAND6	109.874	456.516	0.240679
BAND7	183.230	544.289	0.336641
BAND8	156.198	459.83	0.339686





由於族群變異度愈大，所需樣本數也愈大，為提高分類結果評估準確度，採 8 波段中變異係數最大值 0.445 來計算。

因此，根據以上公式在無限族群 1% 取樣誤差亦即 99% 信賴水準下，評估樣本數量至少要 10749 點，本研究隨機選取的評估像元數量為 35876 點 > 10749 點，故評估所得各種處理組合分類之全區分類準確度及 kappa 同意度係數具有 99% 的信賴水準。

2. 林型

由資源調查的資料可知土地被覆的類型相當複雜易產生混淆現象，所以在分類上先就特徵明顯的純林型進行分類，之後再以分類結果進行混合林辨識作業，期滿足計畫中對於各類混淆林分(針闊、竹闊、竹針、竹針闊)進行分類之目標。

(1) 純林型分類

訓練樣區的選取主要以地真資料為基礎進行選取，從兩區域影像中選出了 18 種分類型(竹、針、闊、針闊、竹闊、竹針、竹針闊、造林地、茶園、果園、檳榔、農田、灌木、草地、水體、道路、建物、裸地)，然從圖 11、12 可以發現由於兩區域影像的拍攝時間不同導致同一分類型會產生不同的光譜訊號、顏色，因此需要根據地真資料將某一分類型再細分為具有不同分類特徵的次分類型，以確保同一分類型可獲得正確的分類，最後共選出 27 個分類型進行分離度試驗，其細分如圖 13。

根據 Gamma、Lee、Local sigma 處理組合後之訓練樣區分離度表(附錄 4)，可以發現數值集中在 1900~2000 之間，顯示所選取的各分類型訓練樣區能有效地進行分類，少數位於 1700 以下而未能有效分類，因此所選取的訓練樣區皆可視為能有效進行區分出為何種分類型。確認訓練樣區可有效分離之後便可將次分類型進行結合，最後剩下主要的 8 種分類型(竹、針、闊、水體、農田、草地、建物、裸地)進行後續 PB-MLC、OB-SVM 分類。

(2) 混淆林辨識

混淆林辨識以純林分類結果為基礎，只保留地真資料中的林型屬性並根據其林型比例是否 > 20% 來分辨該地區是否為混淆林(Michael Allaby, 2006)。其步驟為先將包含除林型外之分類型(建物、裸地、農田等等)比例 $\geq 80\%$ 之區域剔除，之後就包含林分區域進行林型類別比例計算並與原始地真資料進行交叉比對，再計算其 OA、Kappa、PA 及 UA 以確認混淆林之辨識結果是否具可信度。



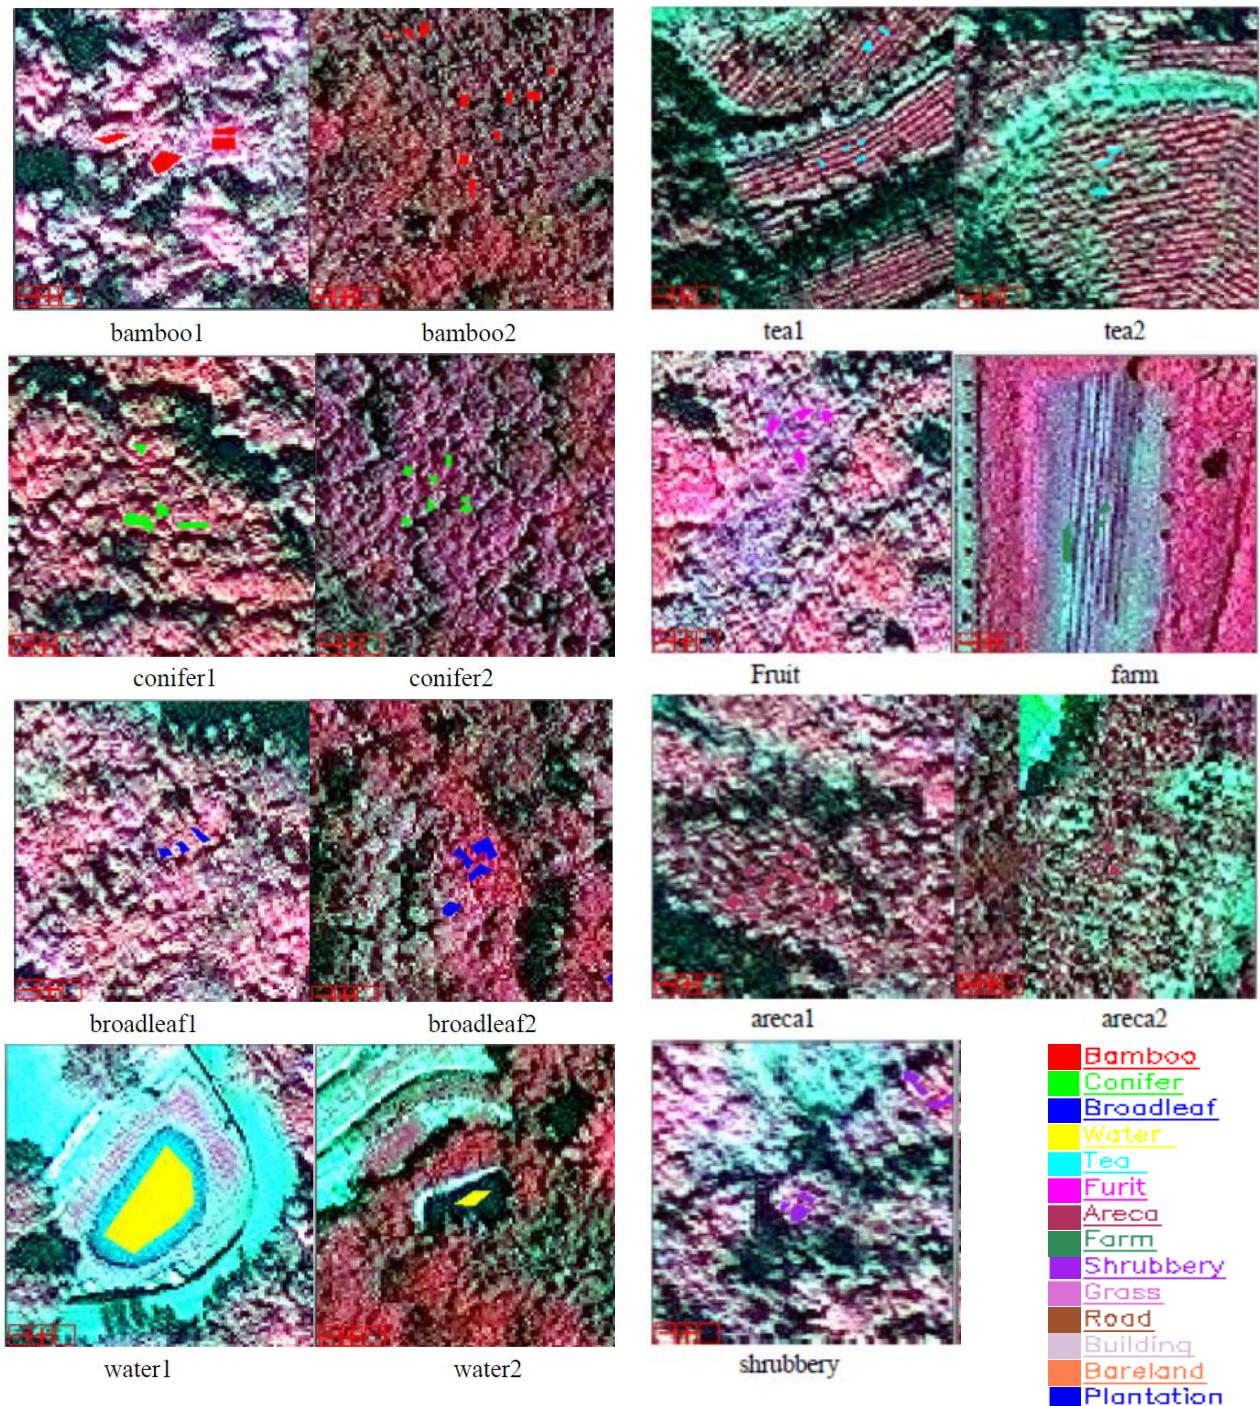


圖 11 訓練樣區挑選位置(一)



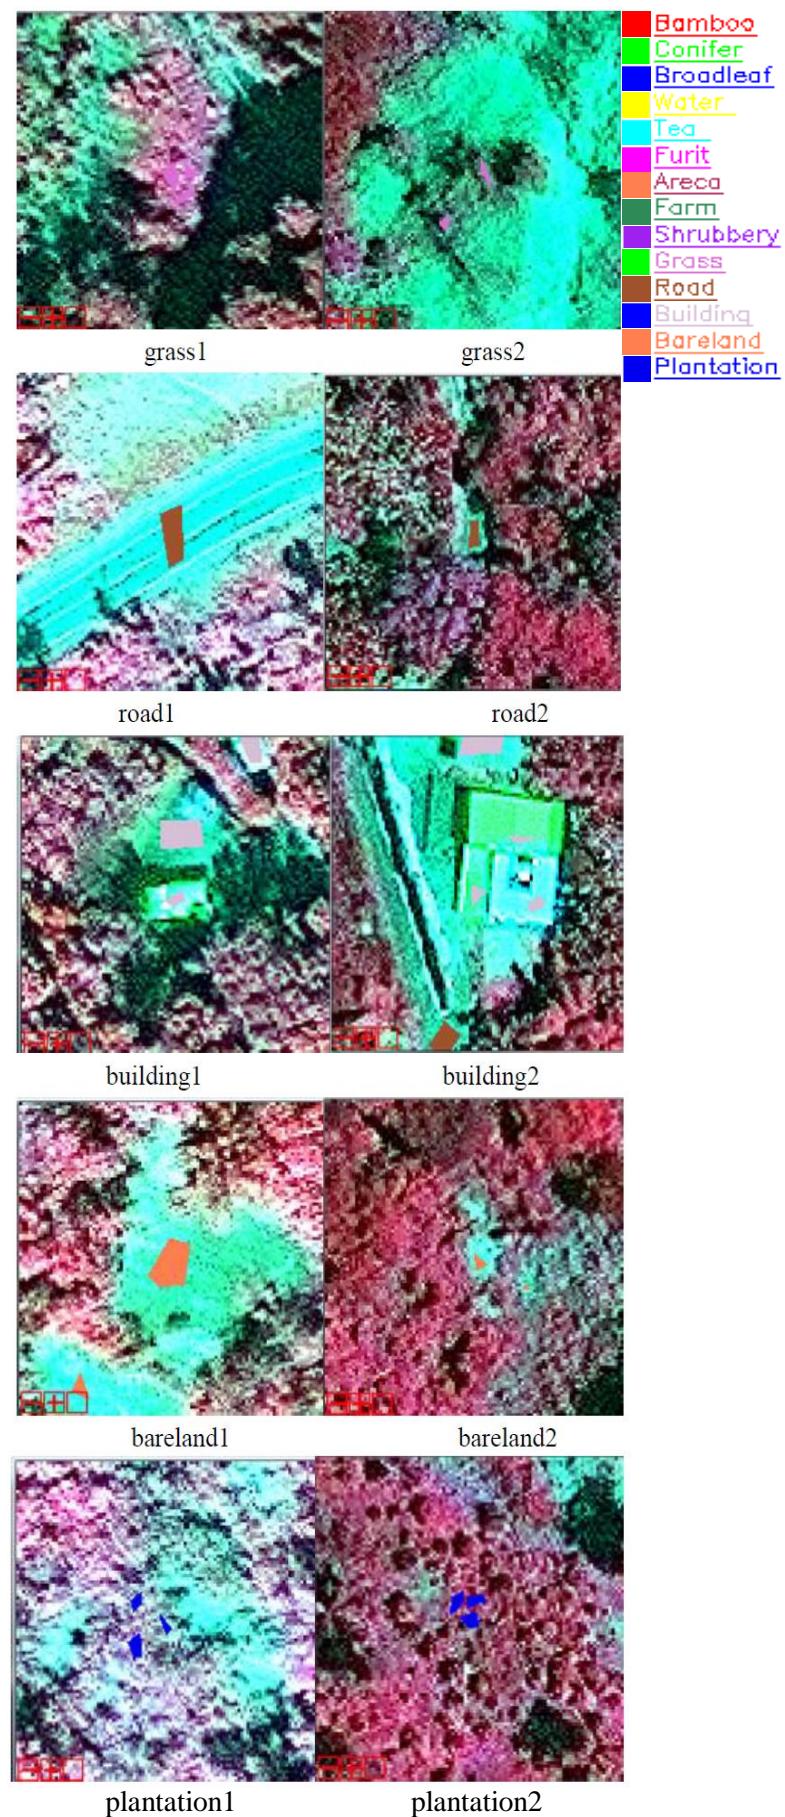


圖 12 訓練樣區挑選位置(二)



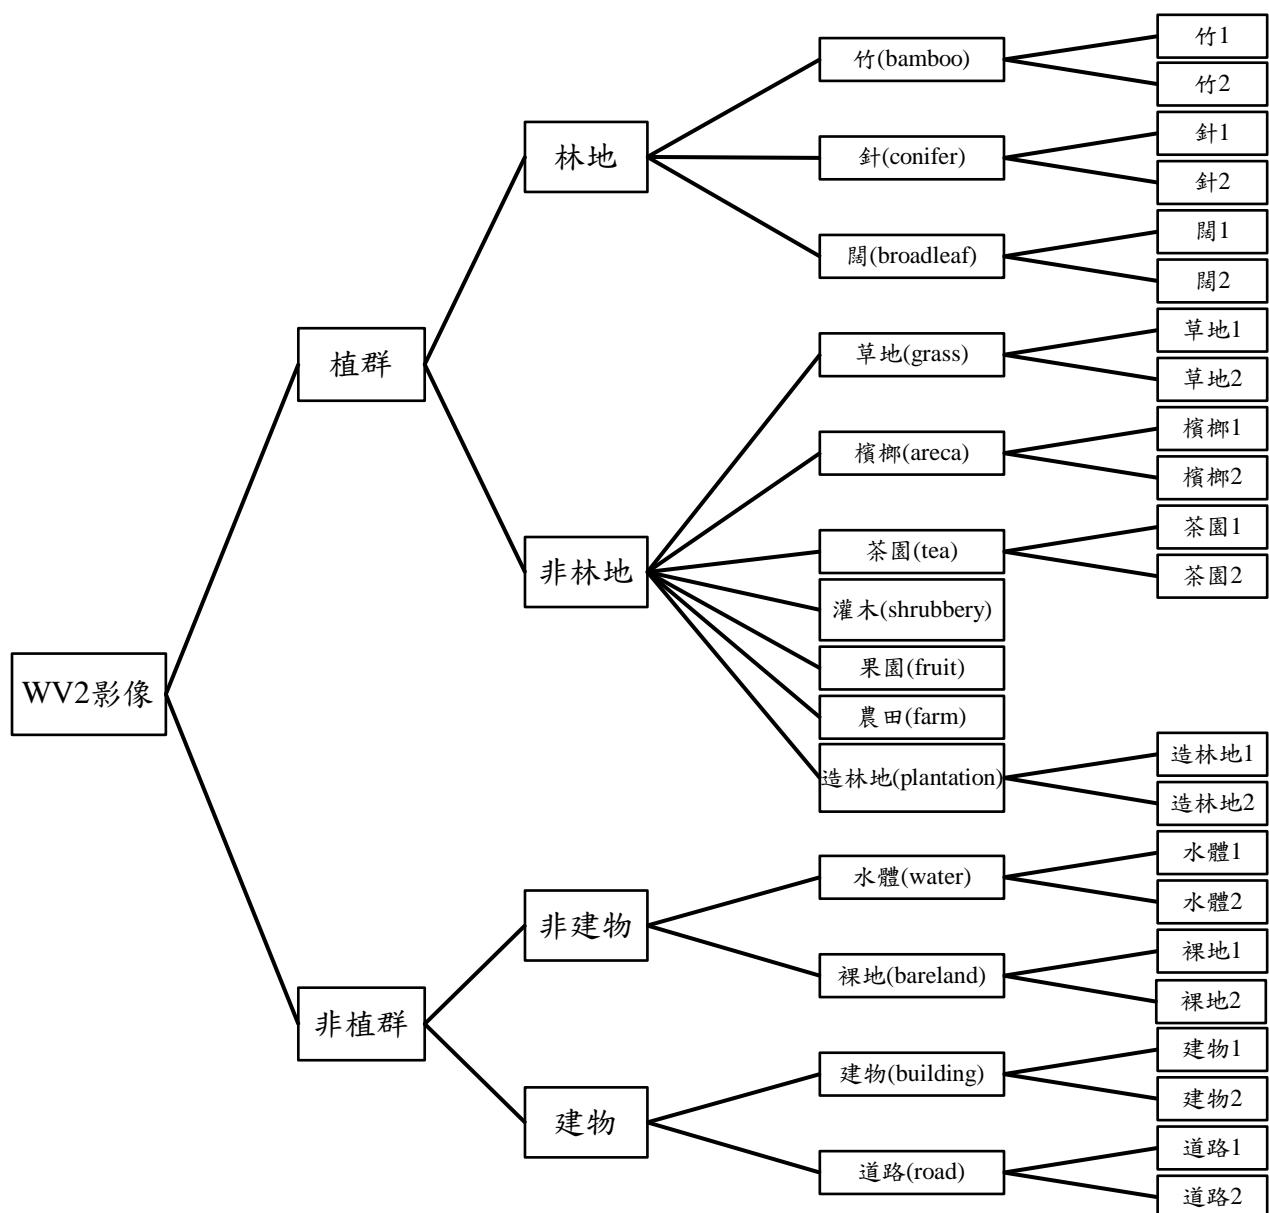


圖 13 訓練樣區分類型樹狀圖





四、結果與討論

(一) 土地被覆型

1. 大氣校正及影像全色態銳化

(1) 大氣校正：

根據處理前後的影像不容易看出校正的前後差異(圖 14)，然而根據 Rudjord and Trier (2012)的研究結果顯示在有雲的區域中，減少氣溶膠散射而來的強烈藍光可能會被視為一些影像上的改善。因此我們選擇影像中綠色農地區域進行處理前後光譜值的比較，但 Reflectance 的數值僅介於 0~1 之間，故將取得的數值放大 10000 倍以利於觀察數值的變化，從圖 15 中可發現影像校正之藍光波段有明顯的下降，並清楚的表現出葉綠素在綠色波段的預期高峰。波長最長的近紅外光 ($0.91\mu\text{m}$) 在 FLAASH 大氣校正後也同樣明顯下降。



圖 14 FLAASH 大氣校正處理後之 WV2 影像(以波段 5, 3, 2 進行 RGB 組合，上圖為處理前，下圖為處理後)



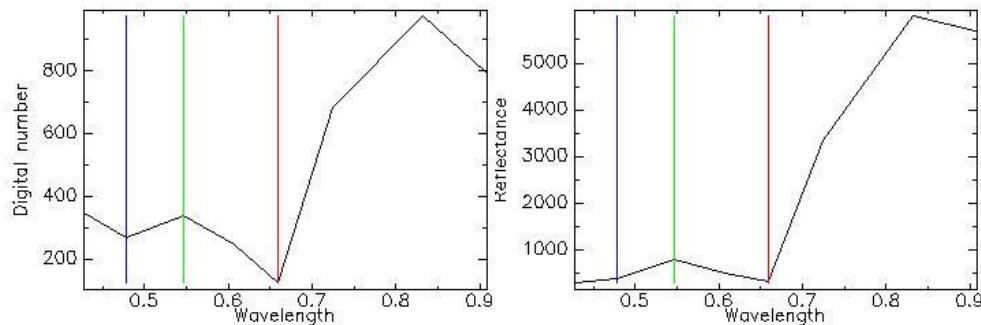


圖 15 影像處理前後光譜比較(圖左為原始影像，圖右為 FLAASH 大氣校正後)

(2) 大氣校正對 NDVI 值之影響

從處理前後之 NDVI 變化可發現，Min 值變小使得非植群部分不易產生誤判 (-0.3716 → -0.5874)，Max 值變大使得植群特徵更為明顯(0.8356 → 0.9375)，Mean 值增加則代表植群的整體辨識度提高(0.4750 → 0.5660)(表 10)，此外由處理前後之結果圖(圖 16)也可發現植群部分的亮度更高，由此可知經大氣校正具明顯提升對植群判釋並有效降低誤判機率的效果。

表 10. 大氣校正前後之 NDVI 數值變化

	Min	Max	Mean	Median	Mode	Std. Dev
處理前	-0.3716	0.8356	0.4750	0.5480	0.6800	0.2390
處理後	-0.5874	0.9375	0.5660	0.6813	0.8541	0.3050

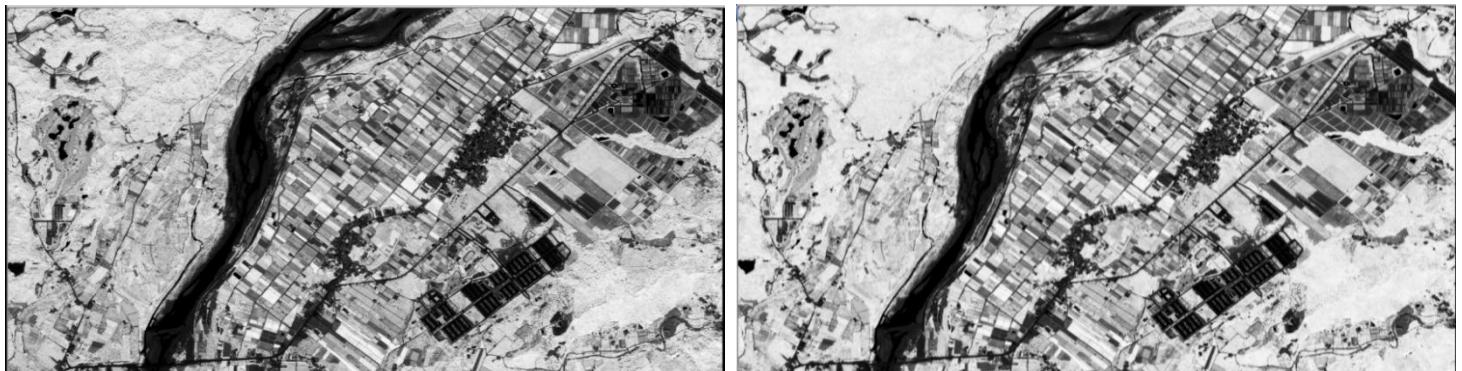


圖 16 大氣校正前後之 NDVI 結果圖(左圖為處理前、右圖為處理後)





(3) 全色態銳化法

I. 莱蘭氏-施密特光譜銳化法(G-S)

將處理結果與原始裁切影像相比，除解析度提升外，主要的改變在於影像的明亮度，原本較為陰暗的山區變得明亮，可清楚分辨山區的地形，但其他區域如農田、建物、河川等原本就較為明亮的區域則顯得過於明亮，有校正過度的疑慮。



圖 17 G-S 法處理之影像

II. PC 光譜銳化法(PC)

與原始影像進行比較，可發現森林與農田部分的亮度較低，而其他地區如建物、河川、草地等的色澤顯得相對較亮，因此仍可能有影像失真的現象發生。



圖 18 PC 法處理之影像





III. GA 全色態銳化法 (GA)

森林及農田在處理過後的結果較另外兩種處理的色澤為深，有校正過度的可能性，但草地、建物、水體的色澤相對較淡，反較為符合實際的色澤而沒有影像失真的疑慮。



圖 19 GA 法處理之影像

由於單從處理後之影像無法判斷何者具有較佳的結果，因此需要將原始影像與各處理結果的 8 個波段數值進行比對，由於 RMSE(root mean square error)法經常以計算像元數值的變化來來比較原始影像和全色態銳化影像間之差異(Wald *et al.*, 1997；Ranchin and Wald, 2000；Du *et al.*, 2007)，因此在本研究中便以 RMSE 法判斷偏差值，其中數值越小代表與原始影像光譜數據偏差越小，同時以 NDVI(normalized difference vegetation index)分析波段在轉換前後的變動比例，此外由於 Correlation analysis 廣為應用於影像轉換前後波段的相關性評估(Haralick *et al.*, 1973；Lewis, 1995；Abdallah *et al.*, 2005；Hermas *et al.*, 2012)，因此在本研究中也納入計算並觀察轉換前後波段對於分類型間之相關性。

結果顯示 G-S 法的 RMSE 最小值集中在 Red edge、NIR1、NIR2 這三個波段(表 11)，但經過 NDVI 處理後的 RMSE 僅有兩個最小值(Bareland、Water)，顯示經 G-S 法轉換後影像波段間之相對比例有一定程度上的改變，因此在進行後續影像分類時便容易因物體組成波段比例的變化而造成分類上的誤判，而在 Correlation 中發現同樣以 Red edge、NIR1、NIR2 這三個波段與所有分類型間皆具有高度的相關性，但其他波段對於植群(Fores、Grassland、Farm)的相關性偏低(表 12)，表示經 G-S 轉換前後之波段在植群的變動量大，因此不適於應用在植群的分類上，。PC 法之 RMSE 最小值集中在前 4 個波段的 Forest 和 Farm 之上(表 13)，因此轉換之後仍能有效的辨識出森林以及農田，但根據 NDVI 值可知轉換後波段間之相對比例的變化為三種處理中之最大，顯示經 PC 法處理之影像的波段失真最為嚴重，因此若以此進行影像分類則可能有相當高的誤判率，在 Correlation 方面可發現其各波段在轉換後對於 Farm 之相關性皆不佳，而其 NDVI





值僅與 Grassland 有高度相關，對於其他植群及分類型皆無顯著的相關性(表 14)。GA 法處理之 RMSE 最小值集中於前五個波段中的 Grassland、Urban、Water 這三項，而其他分類型則有一定程度的失真，但其 NDVI 的 RMSE 却明顯較另外兩種處理為佳(表 15)，顯示影像轉換前後的波段變動比例小，因此在提升影像解析度的同時也能維持波段間的相對比例，因此進行影像分類時對於物體的辨識將較為準確，此一結果與過往的研究結果相近(Du *et al.*, 2007)，在 Correlation 方面其相關性集中於 Red edge、NIR1、NIR2 這三個波段上，但就 NDVI 值來說 GA 法轉換後之波段對於植群的相關性較佳，表示轉換後的植群光譜訊號變異相當小，也就不易產生誤判現象(表 16)。據此，本研究將採用經 GA 法處理之影像進行後續影像分類作業，以確保分類結果準確度。





表 11. G-S 法之各類別於各波段之 RMSE 值

	Coastal	Blue	Green	Yellow	Red	Red edge	NIR
Forest	19.10	27.87	49.72	61.44	44.91	38.51	10.1
Grassland	5.36	7.78	13.87	17.08	12.52	10.66	2.8
Urban	39.26	57.37	102.28	126.29	92.31	79.20	20.9
Bareland	10.55	15.54	27.69	34.19	25.04	21.46	5.6
Farm	14.39	20.98	37.42	46.33	33.91	29.02	7.6
Water	8.84	12.94	23.07	28.50	20.82	17.86	4.6

表 12. G-S 法之各類別於各波段之 Correlation 值

	Coastal	Blue	Green	Yellow	Red	Red edge	NIR
Forest	0.20	0.37	0.50	0.33	0.30	0.95	1.0
Grassland	0.31	0.33	0.62	0.69	0.86	0.99	1.0
Urban	0.94	0.93	0.92	0.87	0.84	0.90	0.9
Bareland	0.70	0.80	0.81	0.78	0.80	0.98	1.0
Farm	-0.04	0.07	0.22	0.04	0.10	0.92	1.0
Water	0.99	0.99	0.99	0.99	0.98	0.92	0.9

表 13. PC 法之各類別於各波段之 RMSE 值

	Coastal	Blue	Green	Yellow	Red	Red edge	NIR
Forest	15.32	22.83	25.19	45.14	38.18	118.57	234.1
Grassland	6.25	9.35	9.69	18.17	16.00	47.24	94.1
Urban	51.70	76.37	96.78	139.79	114.58	274.54	561.1
Bareland	13.00	19.83	20.19	38.07	33.03	99.30	200.1
Farm	13.69	20.58	21.25	39.72	34.03	105.13	211.1
Water	20.46	30.16	31.21	58.06	49.95	152.92	309.1





表 14. PC 法之各類別於各波段之 Correlation 值

	Coastal	Blue	Green	Yellow	Red	Red edge	NIR
Forest	0.67	0.56	0.83	0.68	0.60	0.73	0.6
Grassland	0.40	0.23	0.86	0.74	0.84	0.84	0.8
Urban	0.94	0.92	0.94	0.89	0.82	0.92	0.8
Bareland	0.95	0.97	0.99	0.97	0.96	0.95	0.9
Farm	0.33	0.16	0.32	0.13	0.16	0.57	0.4
Water	1.00	1.00	1.00	1.00	0.99	0.96	0.7

表 15. GA 法之各類別於各波段之 RMSE 值

	Coastal	Blue	Green	Yellow	Red	Red edge	NIR
Forest	16.27	23.39	39.74	49.39	36.96	64.61	113.1
Grassland	5.29	7.63	13.65	16.94	12.86	26.64	41.1
Urban	35.97	49.67	78.51	97.12	74.82	81.92	109.1
Bareland	10.63	15.75	26.79	35.32	27.82	35.35	58.1
Farm	19.59	27.98	48.47	58.18	43.22	79.72	130.1
Water	8.41	12.23	20.88	25.24	18.67	48.02	76.1

表 16. GA 法之各類別於各波段之 Correlation 值

	Coastal	Blue	Green	Yellow	Red	Red edge	NIR
Forest	0.02	0.20	0.44	0.27	0.16	0.79	0.8
Grassland	0.47	0.64	0.60	0.80	0.88	0.95	0.9
Urban	0.95	0.95	0.95	0.92	0.89	0.88	0.7
Bareland	0.55	0.64	0.67	0.61	0.61	0.86	0.7
Farm	0.06	0.10	0.27	0.17	0.19	0.56	0.6
Water	0.96	0.97	0.97	0.96	0.95	0.80	0.1





2. 分類及準確度評估

為瞭解何種影像處理方式可獲得較佳的分類準確度，因此將影像分為原始影像及 FLAASH 大氣校正，其下再依有無經全色態銳化作業共分為 4 種，每種組合再使用 PB-MLC 以及 OB-SVM、KNN 影像分類處理，共有 12 種不同處理組合之土地被覆型分類結果。資料處理組合所得的土地被覆型準確度之評估則

(1) 未經大氣校正處理之原始影像分類

I. 未全色態銳化

i. PB-MLC

從 MLC 的分類結果發現圖形相對完整(圖 20)，可根據分類結果進行不同土地被覆型的判釋，但就分類結果與圖例進行比對時，可發現 PB-MLC 的分類會把裸露地(bareland)分類為建物(urban)或沙地(Sand)，此一現象在河川地以及農地中最為明顯，因此分類的結果並不甚理想。

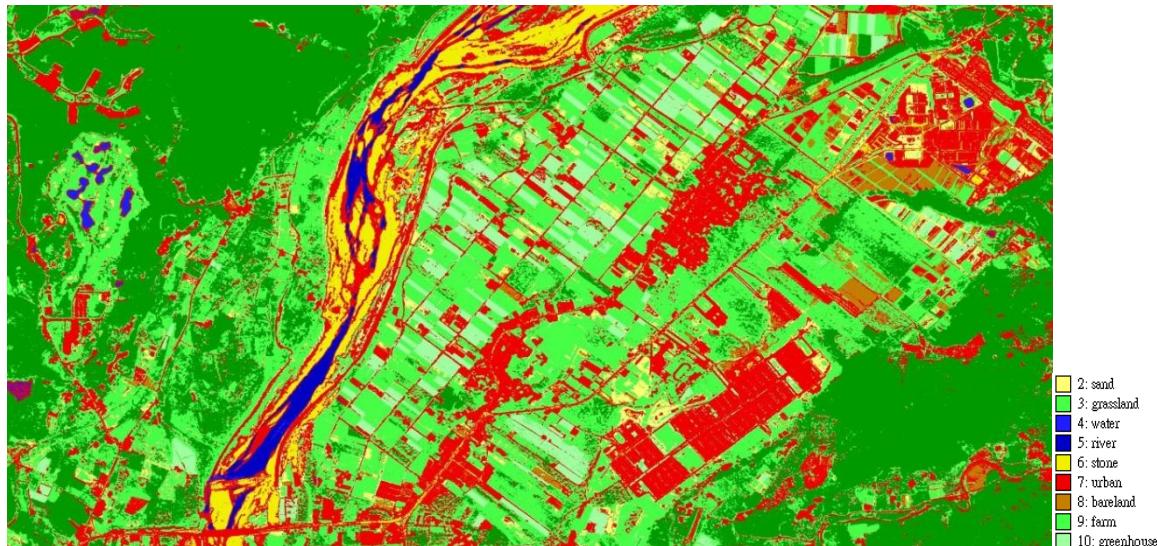


圖 20 原始影像且未經全色態銳化處理之 PB-MLC 分類結果

ii. OB-SVM

與 PB-MLC 相比 OB-SVM 的分類結果(圖 21)顯得較為破碎，使得在判釋上無法清楚的分辨出物體的範圍及形狀，然而與圖例進行比較可發現 OB-SVM 會依據物件的細部特徵進行分類，因此可以正確的分類出沙地及裸露地的位置，但在森林(forest)、草地(grassland)、農地(farm land)的分類上，不論 PB-MLC 或是 OB-SVM 皆有明顯分類錯誤的現象，顯示在植群分類上仍有進步的空間。



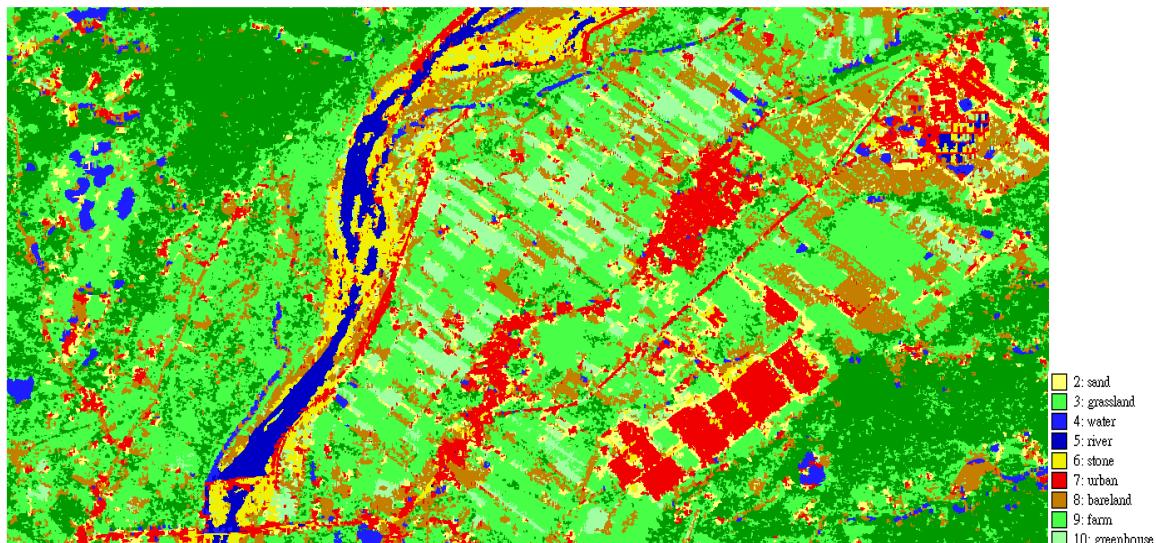


圖 21 原始影像且未經全色態銳化處理之 OB-SVM 分類結果

iii. KNN

在 KNN 的處理結果中包含許多未分類區域(unclassified)，主要原因該物件範圍的光譜紋理以及形狀特徵與物件訓練樣區的特徵差異太大，因此無法歸類於已知的各種土地被覆型，而未分類區域屬於影像中成像較暗的部分，如陰影、物體本身顏色(建物、地貌、植群)等，顯示 KNN 分類法對於影像中陰暗部分的處理效果不佳，使得分類結果明顯不適用。

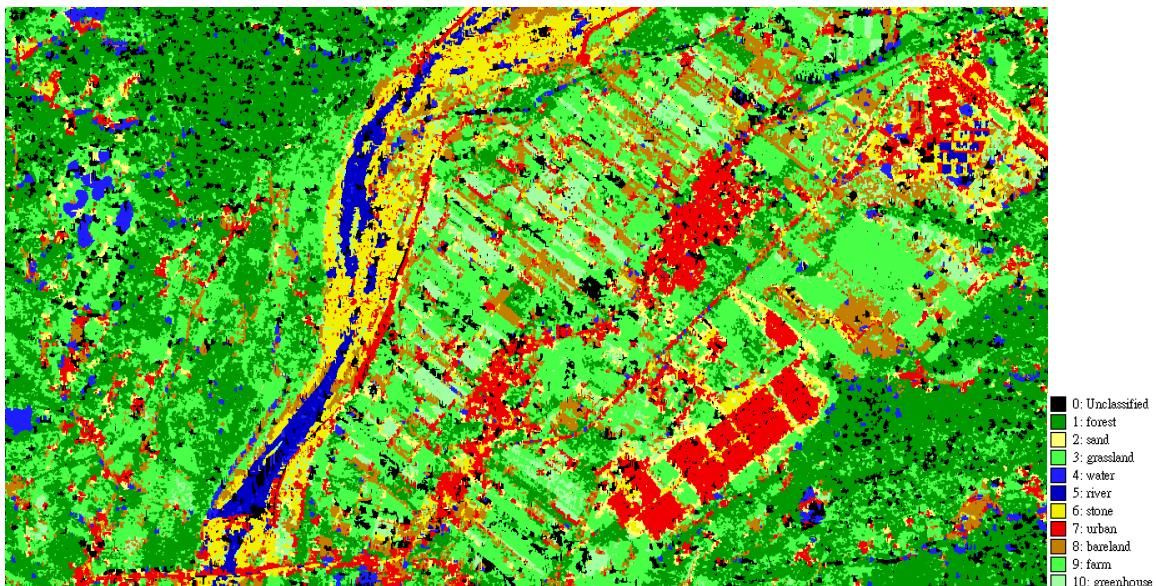


圖 22 原始影像且未經全色態銳化處理之 KNN 分類結果



II. 已全色態銳化

i. PB-MLC

由 MLC 的分類結果可以發現有嚴重誤差的出現，此現象尤其發生於河川、農田、建物以及部分森林區域，從圖 23 中可以明顯發現將河川沿岸的沙地(sand)，裸露地(bare land)以及建物(urban)分類為水體，農田則有許多區塊被分類為沙地或石頭地(stone)，而影像右下角區域之森林部分則被分類為與森林混合的建物與沙地，此外也有部分裸露地被分類為建物，顯示經分類結果相當不佳。

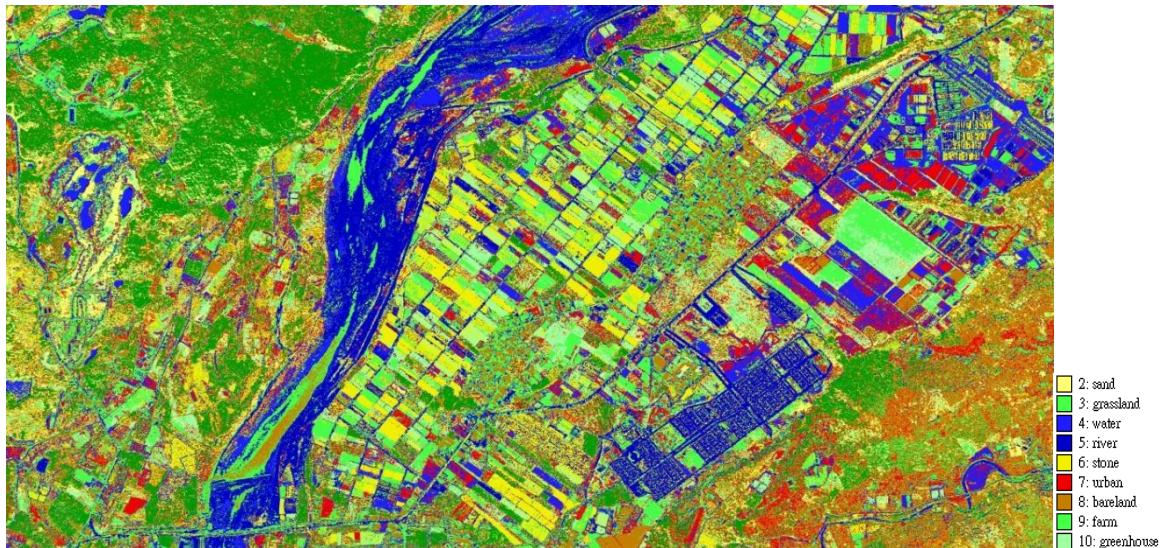


圖 23 原始影像經全色態銳化處理後之 PB-MLC 分類結果

ii. OB-SVM

OB-SVM 的分類結果則明顯較 PB-MLC 之結果為佳，且影像中區塊的輪廓也較未全色態銳化之結果為清晰，因此可清楚分辨出細部的建物、水體、沙地、裸露地，都市區域也因解析度提高而不會單純只分類為建物，然其分類上的主要問題出現在植群的判釋上，因為由圖 24 中可明顯發現在原始影像中為森林的區域有混入其他植群分類型的現象，顯示在各種植群間應有更加明確的定義，以提升 OB-SVM 在植群分類上的準確度。



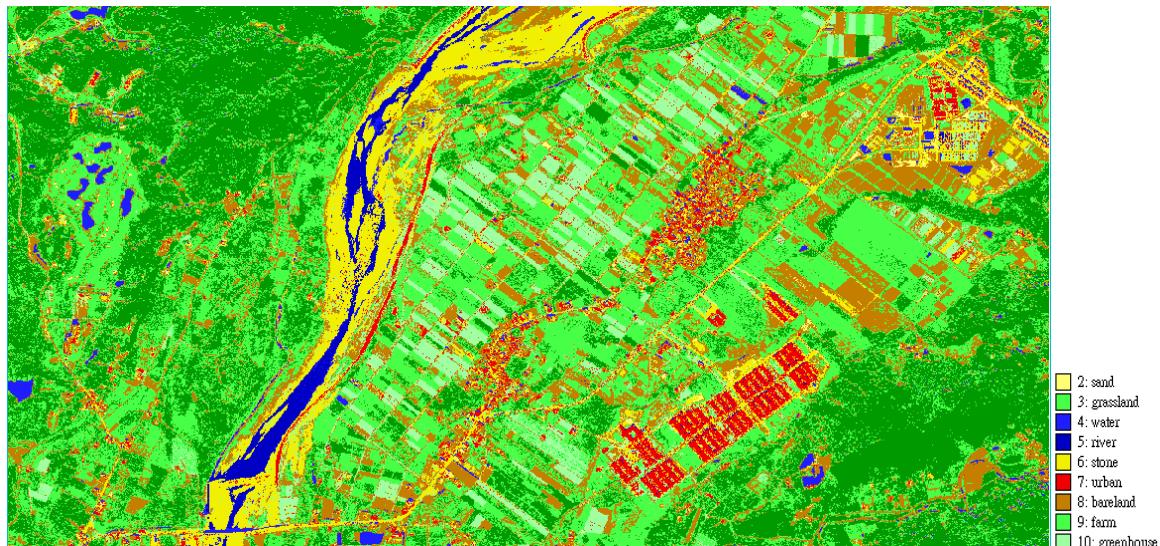


圖 24 原始影像經全色態銳化處理後之 OB-SVM 分類結果

iii. KNN

KNN 的分類結果與 SVM 相近，同樣可以具有區塊輪廓清晰的特性，但在植群的分類上則較 SVM 為差，因為在森林區域中有明顯被分類為水體的部分(圖 25)，且森林與其他植群分類型的混雜程度相當嚴重，因此無法明確地分辨出森林的範圍，圖中仍有大量的未分類區域存在，顯示 KNN 分類法的判釋能力明顯不佳。

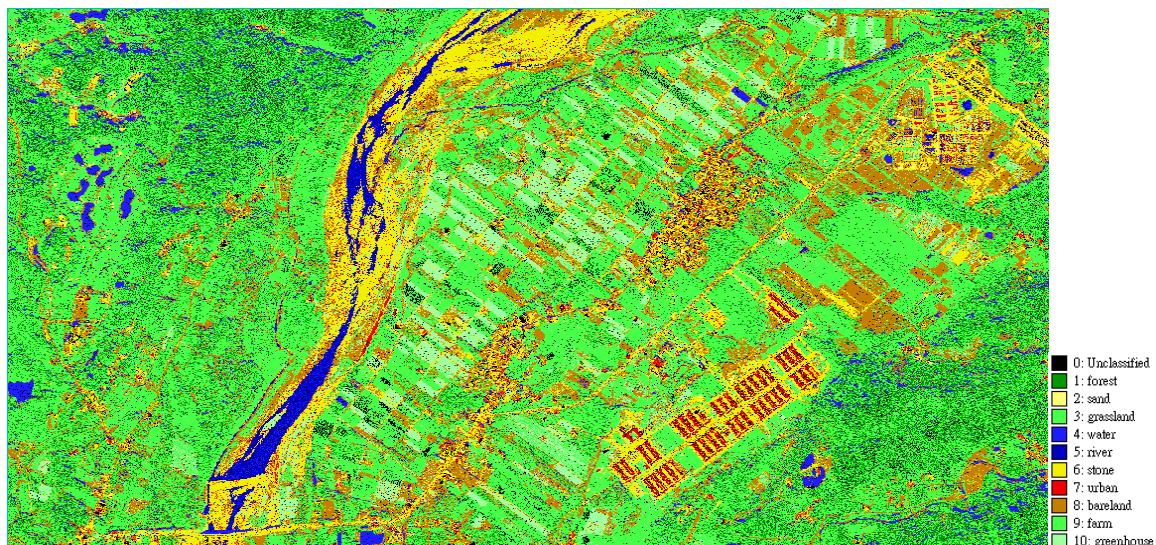


圖 25 原始影像經全色態銳化處理後之 KNN 分類結果



(2) 大氣校正處理後之分類

I. 未全色態貌化

將分類結果與圖 20 相比可發現在河川地的分類上略有進步，但仍將許多部份分類為建物，而在其他區域則在物體的輪廓分辨上略有改善(圖 26)，因此整體而言經 PB-MLC 分類的大氣校正影像雖然在區塊的判釋上略有進步，但對於建物、裸露地、沙地、石頭地的判釋能力仍然不佳。

i. PB-MLC

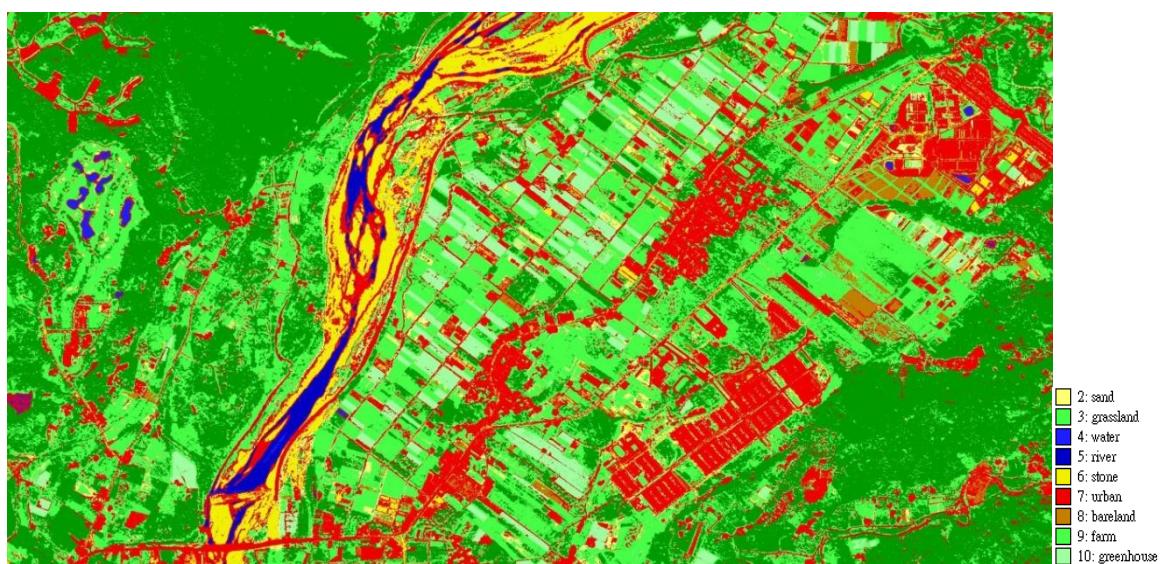


圖 26 大氣校正後未經全色態貌化處理之 PB-MLC 分類結果

ii. OB-SVM

與 PB-MLC 的分類結果相比，OB-SVM 能夠準確的依據物體特性將水體、沙地、裸露地區分出來(圖 27)，而非單純分類為建物，因此分類上並沒有太大的誤差存在，同時分類上的主要問題也同樣為植群分類型的判釋錯誤，使得部分森林被分類為其他植群分類型，但仍與圖 21 存在相同的問題，即分類的結果相當破碎，以至於僅能大略知道物體的範圍及形狀，而無法完整的判釋出該物體為何種分類型，因此分類結果仍不甚理想。



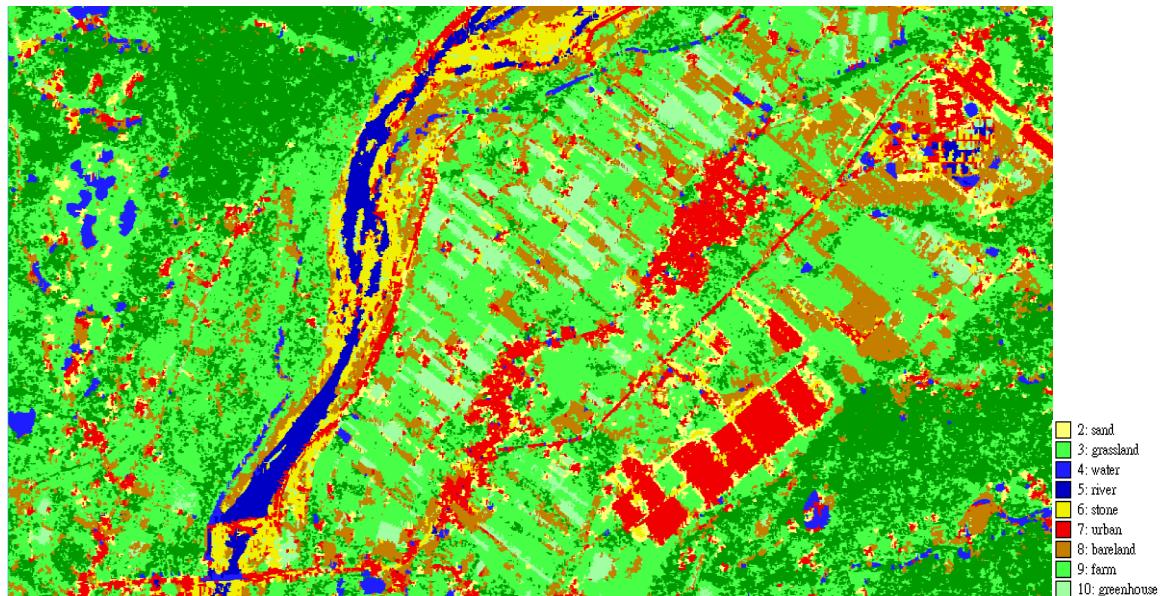


圖 27 大氣校正後未經全色態銳化處理之 OB-SVM 分類結果

iii. KNN

單就分類型的判釋而言，KNN 分類的結果與 OB-SVM 相近(圖 28)，且在影像左半邊的森林區域分類明顯較佳，但仍有許多未分類區域存在，顯示在分類判釋上仍嚴重受到陰影或是物體色澤偏暗部分的影響，且此一現象在全影像皆有發生，使得分類結果在判釋上存在許多不確定因素。

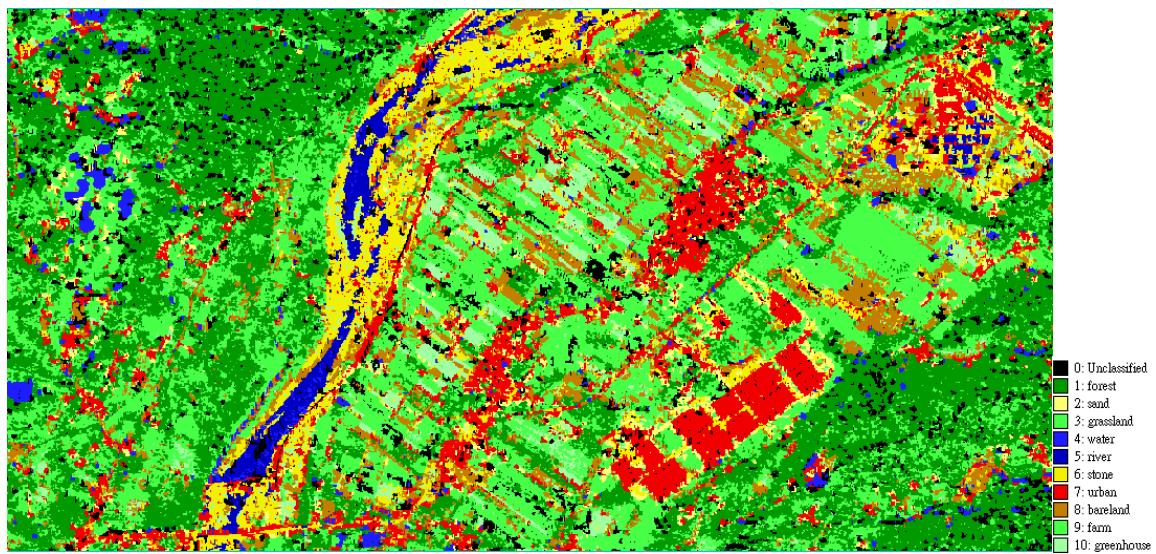


圖 28 大氣校正後未經全色態銳化處理之 KNN 分類結果



II. 已全色態銳化

i. PB-MLC

與前幾種處理組合之 PB-MLC 結果比較，本處理之 PB-MLC 分類結果由於影像解析度提升加上經過大氣校正處理，因此能將河川的沙地更準確的分類出來而非誤判為建物，但在森林與其他植群分類型的區分上則稍有不足(圖 29)，與圖 26 相比可發現左半邊森林被分類為草地的區域明顯增加，推測可能的原因在於單位面積的像元數量增加，因此增加可能的誤判機率。

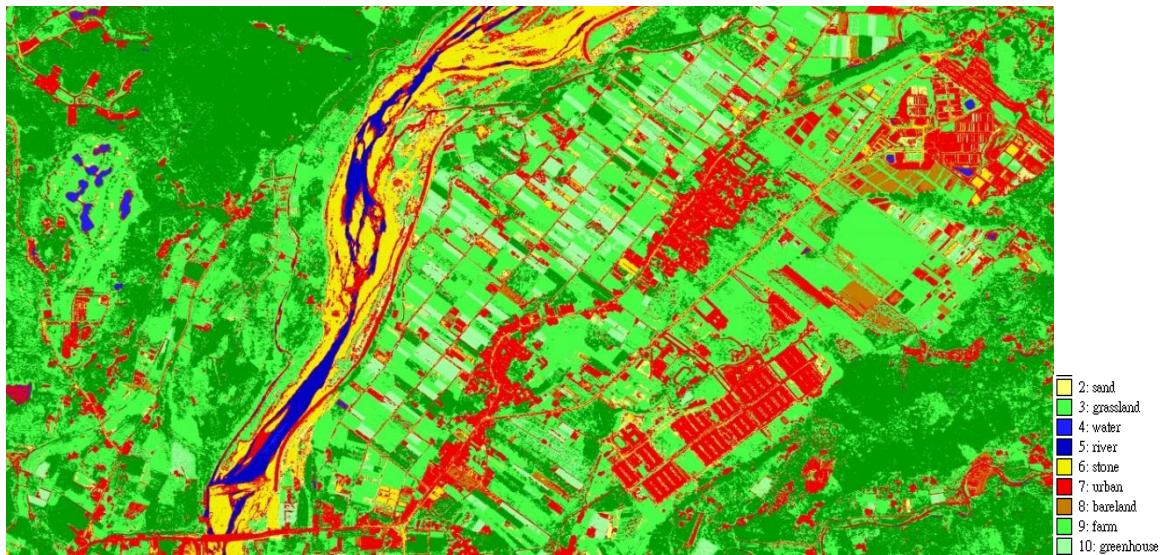


圖 29 大氣校正後經全色態銳化處理後之 PB-MLC 分類結果

ii. OB-SVM

與前幾種處理組合之 OB-SVM 比較，大氣校正全色態銳化處理影像之 OB-SVM 分類(圖 30)可明顯提升物體輪廓的細緻程度，使得物體具有完整可供判釋的外觀同時保有正確的分類結果，且在都市區域的分類上仍可維持其組成的複雜度而非像 PB-MLC 法一樣單純分成建物，此外森林區域誤判現象也有一定程度的改善，但仍需進一步就森林與其他植群分類型的特徵進行分析，以提升植群的分類準確度。



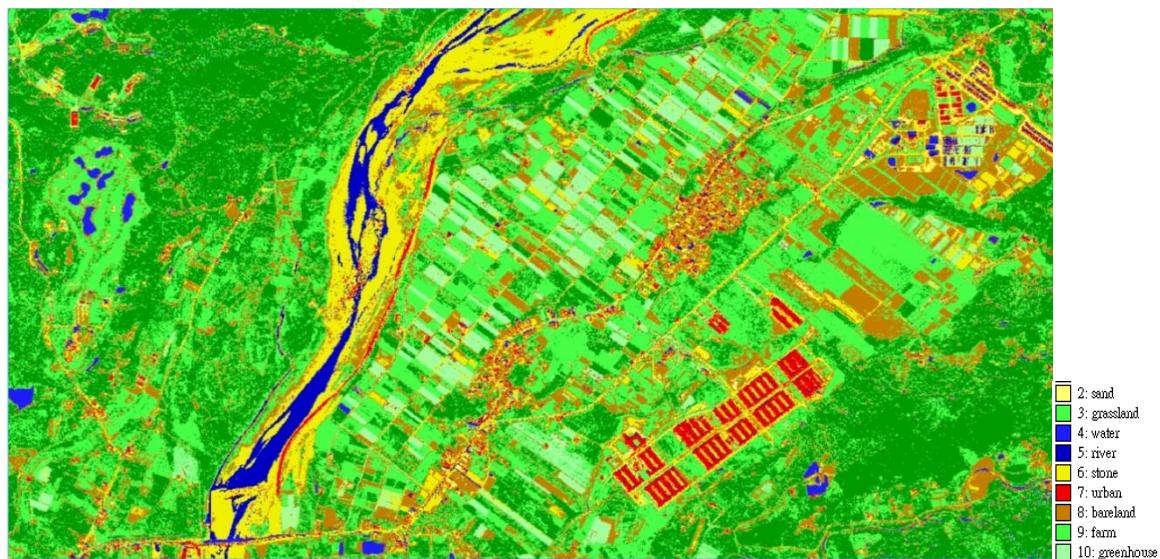


圖 30 大氣校正全色態銳化處理影像之物件基礎 SVM 分類結果

iii. KNN

與先前的 KNN 分類法相同，本處理之 KNN 仍然有未分類區域的存在，且森林誤判的現象仍然相當嚴重，明顯被誤判為草地、水體(圖 31)，因此此分類的可信度相當的低。

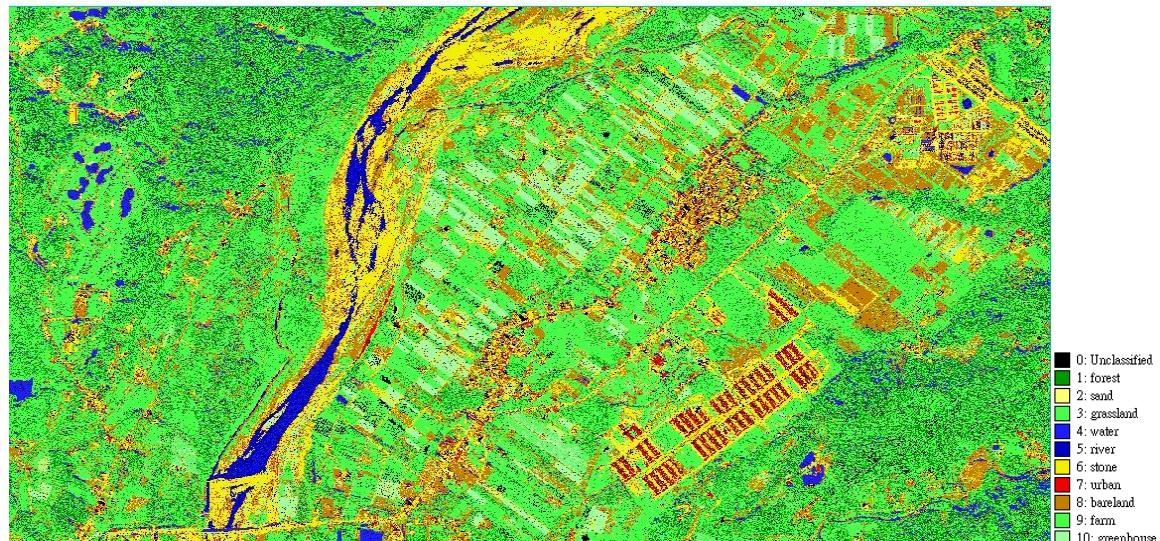


圖 31 大氣校正後經全色態銳化處理後之 KNN 分類結果



綜觀各種影像處理及分類的組合可發現，PB-MLC 法對於建物、沙地、裸露地的判釋能力不佳，使得河川岸邊及中央布滿建物，且在「原始影像經全色態銳化處理」的組合中，其分類結果出現嚴重的誤差，同時在分類上對於物體細部上的處理也較為不佳，由不同物體所組成的區域往往只會被歸納至一個分類型中，使得分類結果無法作為細部判釋之用。OB-SVM 法在未經全色態銳化的組合中，其結果皆顯得相當的破碎且粗糙，但對於建物、裸露地、沙地、水體的分辨能力較 PB-MLC 法為高，因此較能準確的分辨出地面特徵，但對於森林的判釋上卻存有相當程度的誤差，使得部分森林區域被分類為草地而造成誤判，經過全色態銳化處理的組合由於解析度提升，使得物體細部輪廓更為清晰，因此可使物體在分類上更為細緻，解決先前分類結果破碎、粗糙的問題，且可改善森林被誤判的現象。KNN 法則不論何種處理組合皆有未分類區域的問題發生，除此之外在經過全色態銳化處理的組合中，皆明顯可發現森林被誤判為水體，或是被誤判為草地的現象，而在未全色態銳化的組合中森林被誤判的現象較少，但未分類區域也相對較大並進而影響判釋品質，因此在本研究中不論哪種組合皆不宜以 KNN 法進行分類。





3. 準確度分析

各種分類組合之結果以生產者精度、使用者精度、整體精度、Kappa 係數來確認準確度，其結果如下：

(1) PB-MLC

在訓練樣區的準確度中以未大氣校正但經全色態銳化之準確度最低(OA：59.63%、Kappa：0.5479)，而其他三種組合以原始影像未全色態銳化之影像具最佳的準確度(OA：99.24%、Kappa：0.9914)，表示圈選的訓練樣區具有足夠的代表性，而 FLAASH 經全色態銳化之影像的準確度略低(OA:97.86%、Kappa:0.9759，表 17)，其可能原因在於 MLC 分類為像元導向的分類法，而未經處理的原始影像包含過多的雜訊，單一像元在解析度低時，其內含有多種地物的機會就增大，反之解析度高時，其內只含有單一地物的機會就大增(林金樹，2004)。因此轉換後之影像的單一像元包含單一屬性的機會雖然較大，但由於未經過大氣校正去除大氣中的雜訊，因此若直接轉換使解析度提高會造成雜訊的影響被放大，使得訓練樣區中所包含的屬性複雜化，而無法準確依據訓練樣區的光譜特性進行分類。經過大氣校正之影像因去除大氣中的雜訊，使得轉換後之影像不受雜訊放大的干擾，因此準確度明顯提升。

在原始影像的評估樣區中可以發現經全色態銳化處理的分類準確度皆較未全色態銳化之處理為高(原始影像：78.32%→81.05%、大氣校正：78.99→82.44)，其中全色態銳化之原始影像的準確度大幅提升，顯示以人為方式圈選之樣區雖會受到雜訊放大的影響，但若以隨機樣點為核心放大的評估樣區進行分類時，則明顯未受到雜訊放大的影響，因此準確度可達 81.05%。而將原始影像與大氣校正影像的結果相比較可發現若不進行全色態銳化處理，則有無執行大氣校正對於準確度並無明顯的影響，但如希望繪製高空間解析度的土地被覆型，則需要進行大氣校正以避免全色態銳化後導引出細部雜訊造成分類訊息的誤差。

將各分類型以 Producer Accuracy(PA)和 User Accuracy(UA)進行準確度評估的結果發現，經全色態銳化之影像分類準確度大致為增加狀態但其變化的差異並不明顯，而從各分類型的數據上來觀察可知在各處理組合中皆有分類較差的部分，但整體來說以經全色態銳化之大氣校正的 PU(71.82%~100%)及 UA(65.96%~99.20%)具有較佳的準確度。

表 17. 不同處理之 PB-MLC 分類法準確度評估(左為 OA，右為 Kappa)

	原始影像				大氣校正			
	未全色態銳化		全色態銳化		未全色態銳化		全色態銳化	
訓練樣區	99.24%	0.9914	59.63%	0.5479	98.33%	0.9812	97.86%	0.9759
評估樣區	78.32%	0.7434	81.05%	0.7756	78.99%	0.7509	82.44%	0.7920
	PA	UA	PA	UA	PA	UA	PA	UA
forest	93.99%	86.23%	96.58%	88.49%	91.80%	88.49%	97.49%	85.20%





grassland	70.29%	49.77%	78.34%	57.33%	88.39%	46.79%	84.54%	62.50%
water	100%	78.39%	100%	85.10%	100%	81.19%	100%	84.61%
urban	57.94%	99.08%	63.02%	98.17%	55.00%	99.29%	64.10%	99.20%
greenhouse	96.76%	87.67%	92.96%	87.78%	87.43%	62.47%	71.82%	91.04%
farm	74.31%	84.49%	72.71%	87.33%	71.38%	88.71%	90.43%	65.96%
bareland	78.68%	63.39%	85.06%	65.12%	99.48%	84.21%	95.43%	91.36%

(2) OB-SVM

由準確度評估可知無論哪種組合的訓練樣區準確度皆接近 100%，顯示在 OB-SVM 中只要能夠依據物件特性正確圈選樣區，便能獲得相當優良的分類準確度，其中以 FLAASH 全色態銳化組合之影像準確度達 100% 為最高。在評估樣區中則可發現無論是在原始影像或是大氣校正影像中，其準確度在經過全色態銳化後皆有顯著的提升(原始影像：73.03% → 88.40%，大氣校正：75.17% → 89.36%，表 18)，顯示經全色態銳化後之影像可提供較完整的物件概念，同時可發現有無大氣校正處理對於分類準確度並無影響。

以 PA 及 UA 進行各分類型準確度評估可發現全色態銳化後之影像普遍具有較高的準確度，且原始影像與大氣校正影像間之分類準確度互有優劣。

表 18. 不同處理之 OB-SVM 分類法準確度評估(左為 OA，右為 Kappa)

	原始影像				大氣校正			
	未全色態銳化		全色態銳化		未全色態銳化		全色態銳化	
訓練樣區	99.79%	0.9975	99.95%	0.9994	99.75%	0.9971	100%	1
評估樣區	73.03%	0.6848	88.40%	0.8622	75.17%	0.7056	89.36%	0.8735
	PA	UA	PA	UA	PA	UA	PA	UA
forest	100%	69.41%	97.75%	96.33%	98.03%	66.05%	98.93%	98.36%
grassland	57.79%	63.32%	88.10%	59.52%	65.36%	63.02%	87.62%	62.18%
water	87.28%	88.89%	99.45%	88.61%	91.71%	88.89%	98.73%	88.49%
urban	86.59%	86.57%	97.75%	82.56%	87.18%	89.31%	92.78%	84.35%
greenhouse	60.68%	82.08%	81.62%	91.39%	63.20%	88.78%	83.84%	92.49%
farm	64.33%	57.72%	81.27%	94.29%	63.29%	65.55%	80.28%	93.79%
bareland	78.82%	78.56%	84.68%	98.89%	86.60%	72.16%	94.73%	98.56%





(3) KNN

訓練樣區之結果與 SVM 相同，各種組合之準確度皆相當高，其中以 FLAASH 全色態銳化之組合準確度達 100% 為最高，顯示依據所圈選樣區之物件特性進行分類可獲得相當優良的準確度。但相較於 SVM 法，在評估樣區中之準確度下降相當嚴重，即使為準確度最佳的原始影像未全色態銳化組合準確度也下滑 20%，其中以 FLAASH 全色態銳化組合準確度下滑 41% 多最為嚴重(表 19)，顯示若以電腦自動化進行分類時，其分類結果之可信度相當的低落。

以 PA 及 UA 進行各分類型準確度評估可發現各個處理組合中皆有數種分類不佳的分類型，因此不論選擇哪種組合皆無法有效的進行分類。

表 19. 不同處理之 KNN 分類法準確度評估(左為 OA，右為 Kappa)

	原始影像				大氣校正			
	未全色態銳化	全色態銳化	未全色態銳化	全色態銳化	未全色態銳化	全色態銳化	未全色態銳化	全色態銳化
訓練樣區	99.72%	0.9967	99.89%	0.9988	99.66%	0.9961	100%	1
評估樣區	57.72%	0.5096	58.56%	0.5114	57.35%	0.5043	60.36%	0.5337
	PA	UA	PA	UA	PA	UA	PA	UA
forest	88.04%	57.59%	89.14%	20.91%	89.00%	54.81%	88.72%	27.19%
grassland	47.80%	45.01%	57.62%	42.51%	49.37%	44.88%	62.78%	47.20%
water	87.84%	86.46%	99.46%	84.89%	92.77%	75.44%	99.11%	85.72%
urban	63.71%	59.54%	85.60%	37.28%	60.62%	60.73%	81.81%	37.67%
greenhouse	53.66%	62.54%	64.86%	80.57%	56.47%	65.06%	65.16%	80.34%
farm	49.07%	39.10%	44.07%	70.96%	49.90%	46.49%	47.42%	71.70%
bareland	79.05%	74.63%	68.47%	83.27%	80.60%	65.04%	70.80%	81.88%





(二) 林型

1. 影像前處理

將經大氣校正及全色態銳化 GA 法處理之原始影像裁切並接合的成果如下圖(32)，其中竹針闊林型在影像中僅能兩個林分，因此共有 20 個 400m*400m 的影像區域，同時為確認區域選取的準確程度，因此就每一選取的區塊中以地真資料為基礎，選擇具該林型之區域進行野外林型勘查作業，以確保林型選取區域的可信度(附錄 3)。

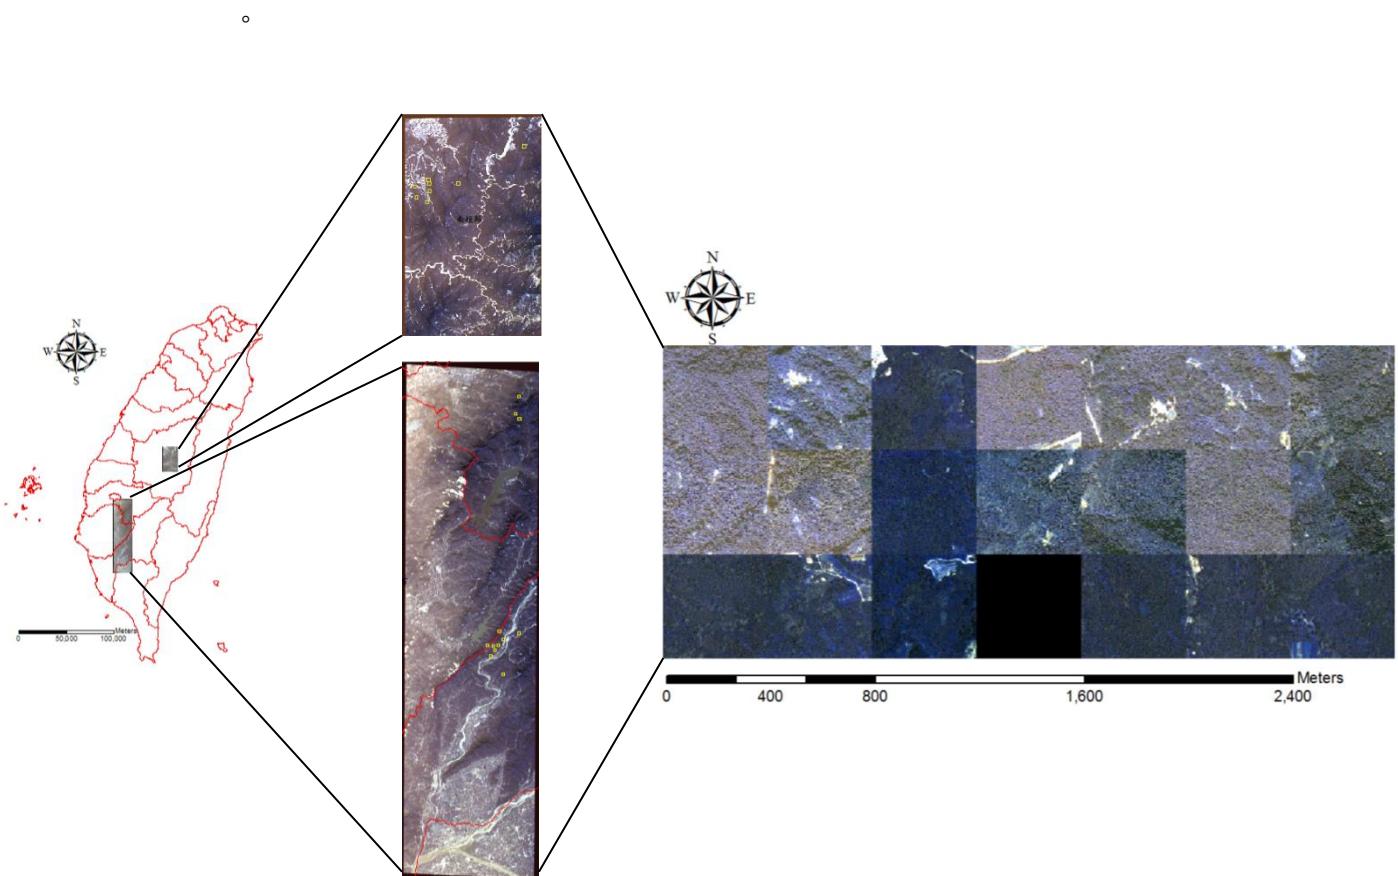


圖 32 經影像前處理之 WV2 各林型樣區接合圖





2. 影像濾波

濾波具有使影像平滑化而得到較純粹紋理的效果，進而提升影像分類的準確度，在此以像元大小 5*5 處理為例子展示 Gamma、Lee、Local sigma 三種濾波器之處理結果(圖 33)，結果發現以 Gamma 和 Lee 濾波器處理明顯可得到較平滑的影像。

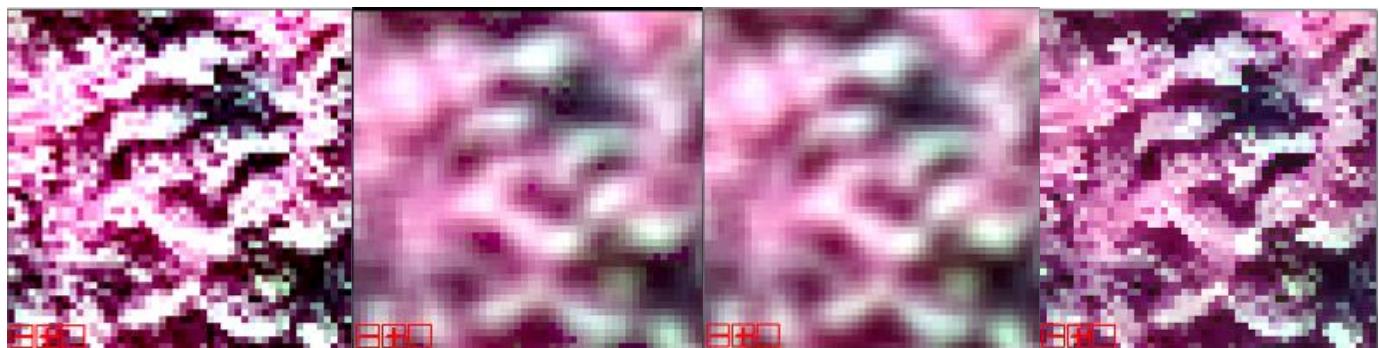


圖 33 5*5 濾波器處理結果(由左至右依序為原始影像、Gamma、Lee、Local sigma)

3. 分類及準確度評估

(1) 單純林型

根據土地被覆型分類結果，將林型訓練樣區以 PB-MLC 及 OB-SVM 兩種分類法處理並以評估樣區確認影像在自動分類下的準確度。由下列 PB-MLC 及 OB-SVM 的各種分類組合結果可知分類結果不盡理想(PB-MLC : 50.63~54.32%；OB-SVM : 31.25~53.12%)，因此由「第四次資源調查」的地真資料開始檢查誤差為何，檢查後發現地真資料有些許不合理的現象發生(如圖 34~40)，主要問題在於部分地真資料並沒有將影像中的地表特徵完全標出，因此進行樣區選取的時候易因此出現錯誤，所以需要進行人工訂正作業逐步將資料調整正確後並進行訂正後之評估。



圖 34 分類結果與地真資料比對(灌木林)



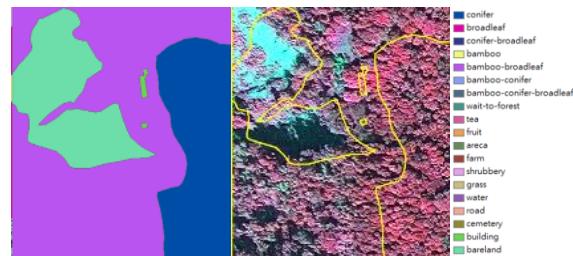


圖 35 分類結果與地真資料比對(裸露地)

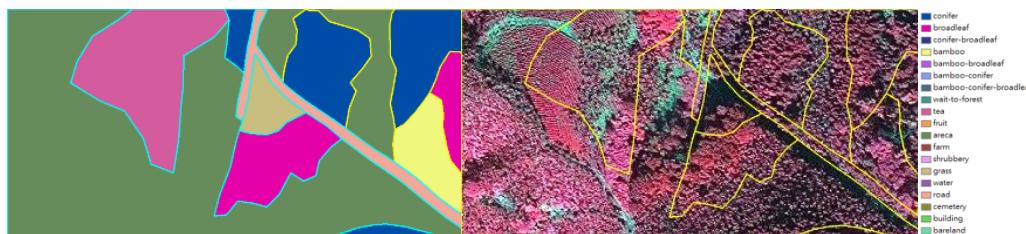


圖 36 分類結果與地真資料比對(茶園)



圖 37 分類結果與地真資料比對(果樹)



圖 38 分類結果與地真資料比對(建物-1)



圖 39 分類結果與地真資料比對(建物-2)



圖 40 分類結果與地真資料比對(建物-3)



I. PB-MLC

i. Gamma

根據表 20 可知訓練樣區 3*3 OA : 93.17%、Kappa : 0.9086, 5*5 OA : 94.81%、Kappa : 0.9305。從評估樣區的 OA 及 Kappa 可知，像元大小 3*3 和 5*5 之間的準確度差異並不大，OA 介於 51.13~51.99%，Kappa 介於 0.1901~0.2080。相較於原始評估樣區分類準確度，經地真資料訂正後之分類準確度明顯較高(3*3 : 51.13% → 60.54%、5*5 : 51.99% → 61.80%)，從各分類型的 PA、UA 變化可知除水體、農地有明顯下降外，其他各分類型之準確度大致上皆呈現增加的現象，整體而言以訂正後之 5*5 具有較佳之準確度(圖 41、42)。

表 20. PB-MLC 之 Gamma 分類準確度

	3*3				5*5			
	OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	93.17%	0.9086			94.81%	0.9305		
評估樣區	51.13%	0.1901	60.54%	0.3772	51.99%	0.2080	61.80%	0.3987
	PA	UA	PA	UA	PA	UA	PA	UA
bamboo	60%	24%	79%	48%	60%	26%	78%	51%
conifer	28%	33%	53%	12%	32%	37%	69%	78%
broadleaf	59%	75%	68%	77%	60%	75%	31%	64%
water	100%	100%	34%	36%	100%	100%	71%	12%
farm	98%	17%	100%	88%	100%	13%	37%	39%
grass	10%	8%	14%	16%	14%	10%	100%	88%
building	17%	23%	100%	45%	15%	22%	100%	34%
bareland	9%	1%	32%	60%	0%	0%	21%	19%

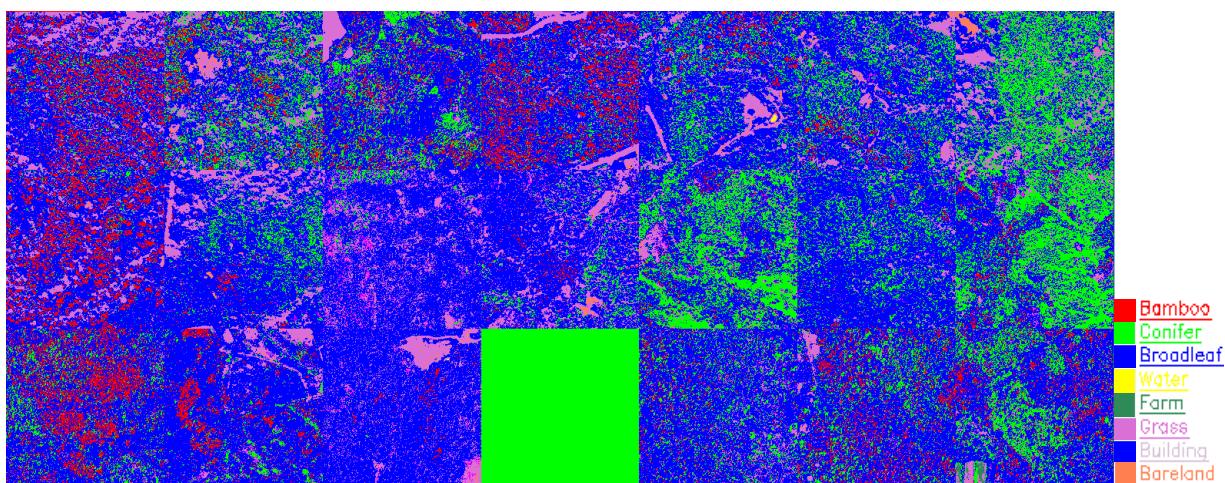


圖 41 PB-MLC Gamma 分類結果(3*3)



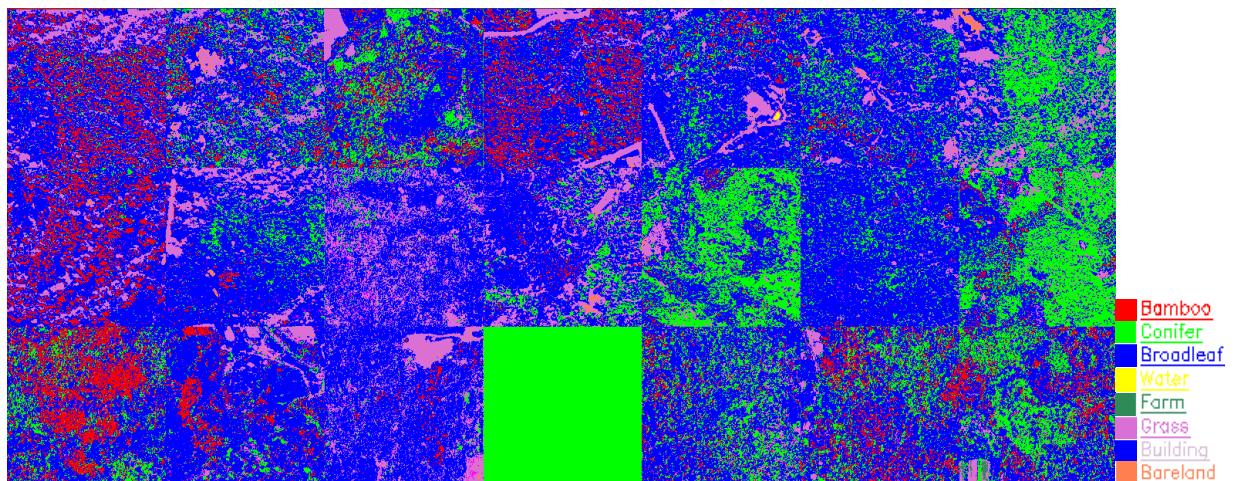


圖 42 PB-MLC Gamma 分類結果(5*5)





ii. Lee

根據各分類組合準確度表的訓練區(表 21~24)可知 3*3 OA:92.17%~92.99%、Kappa:0.8954~0.9063, 5*5 OA:93.56%~94.89%、Kappa:0.9137~0.9315, 7*7 OA:94.51%~95.82%、Kappa:0.9264~0.9439, 9*9 OA:95.11%~96.97%、Kappa:0.9345 0.9593。

從原始評估樣區的 OA 及 Kappa 可知，在各種像元大小組合中 NV1、NV10、NV20 這三種參數設定的 OA 及 Kappa 的差異均不大，OA 介於 50.63~54.32%，Kappa 則介於 0.1767~0.2583 之間。經地真資料訂正之 OA(60.58~63.97%)及 Kappa(0.3698~0.4320)在任一組合中皆呈現明顯的增加，同時各分類型的 PA 及 UA 都有一定幅度的增加，而在各分類組合中以訂正後之 9*9 NV 20 具有較佳之準確度(OA：63.97%、Kappa：0.4320)(圖 43~54)。

表 21. PB-MLC 之 Lee 分類準確度(3*3)

3*3	NV 1				NV 10				NV 20			
	OA	Kappa	訂正後		OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	92.17%	0.8954			92.99%	0.9063			92.95%	0.9057		
評估樣區	51.45%	0.1855	60.58%	0.3698	50.63%	0.1767	60.85%	0.3772	51.10%	0.1846	60.76%	0.3779
	PA	UA										
竹類	59%	24%	78%	48%	60%	23%	77%	47%	58%	24%	78%	47%
針葉	28%	29%	33%	31%	27%	32%	35%	37%	28%	32%	34%	36%
闊葉	59%	77%	67%	79%	58%	75%	67%	78%	59%	76%	68%	78%
水體	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
農田	94%	14%	97%	39%	100%	17%	100%	45%	100%	16%	100%	43%
草地	11%	9%	17%	16%	9%	8%	12%	13%	10%	9%	14%	16%
建物	16%	23%	32%	61%	18%	21%	36%	61%	18%	21%	35%	61%
裸地	0%	0%	47%	10%	10%	1%	58%	11%	0%	0%	52%	10%

表 22. PB-MLC 之 Lee 分類準確度(5*5)

5*5	NV 1				NV 10				NV 20			
	OA	Kappa	訂正後		OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	93.56%	0.9137			94.73%	0.9293			94.89%	0.9315		
評估樣區	52.42%	0.2003	61.99%	0.3899	51.94%	0.1996	62.27%	0.4022	52.12%	0.2047	62.79%	0.4102
	PA	UA										
竹類	60%	25%	79%	49%	57%	25%	78%	50%	61%	26%	80%	51%
針葉	31%	30%	37%	33%	32%	34%	39%	40%	32%	35%	40%	40%
闊葉	98%	78%	68%	80%	99%	76%	69%	79%	99%	76%	69%	79%





水體	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
農田	93%	15%	96%	41%	100%	14%	100%	36%	100%	14%	100%	37%
草地	10%	8%	16%	15%	14%	10%	19%	16%	12%	10%	15%	13%
建物	16%	23%	33%	62%	16%	22%	33%	64%	16%	22%	32%	64%
裸地	0%	0%	53%	11%	0%	0%	66%	13%	0%	0%	68%	11%

表 23. PB-MLC 之 Lee 分類準確度(7*7)

7*7	NV 1				NV 10				NV 20			
	OA	Kappa	訂正後		OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	94.51%	0.9264			95.72%	0.9426			95.82%	0.9439		
評估樣區	53.03%	0.2097	62.17%	0.3952	53.33%	0.2254	63.65%	0.4225	53.45%	0.2286	63.48%	0.4227
	PA	UA										
竹類	62%	27%	79%	51%	60%	29%	78%	53%	62%	30%	77%	54%
針葉	32%	29%	38%	33%	36%	34%	41%	37%	36%	34%	43%	38%
闊葉	60%	79%	68%	80%	61%	78%	70%	80%	61%	78%	70%	80%
水體	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
農田	94%	14%	99%	40%	100%	12%	100%	38%	100%	12%	100%	37%
草地	12%	7%	24%	19%	17%	9%	39%	20%	15%	8%	33%	20%
建物	15%	24%	32%	64%	13%	22%	30%	65%	13%	22%	28%	64%
裸地	0%	0%	50%	11%	0%	0%	75%	14%	6%	1%	69%	16%

表 24. PB-MLC 之 Lee 分類準確度(9*9)

9*9	NV 1				NV 10				NV 20			
	OA	Kappa	訂正後		OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	95.11%	0.9345			96.53%	0.9534			96.97%	0.9593		
評估樣區	52.81%	0.2141	62.17%	0.3988	54.10%	0.2484	63.73%	0.4266	54.32%	0.2583	63.97%	0.4320
	PA	UA										
竹類	65%	29%	81%	51%	65%	33%	78%	53%	67%	35%	79%	53%
針葉	32%	30%	39%	34%	37%	34%	45%	36%	38%	35%	45%	38%
闊葉	60%	78%	69%	79%	62%	78%	70%	80%	63%	77%	71%	80%
水體	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
農田	100%	11%	98%	38%	100%	11%	100%	39%	100%	11%	100%	40%
草地	8%	5%	20%	17%	12%	7%	30%	20%	13%	8%	30%	18%
建物	14%	24%	29%	63%	12%	26%	27%	65%	12%	27%	26%	65%
裸地	0%	0%	60%	14%	10%	1%	77%	16%	0%	0%	81%	17%



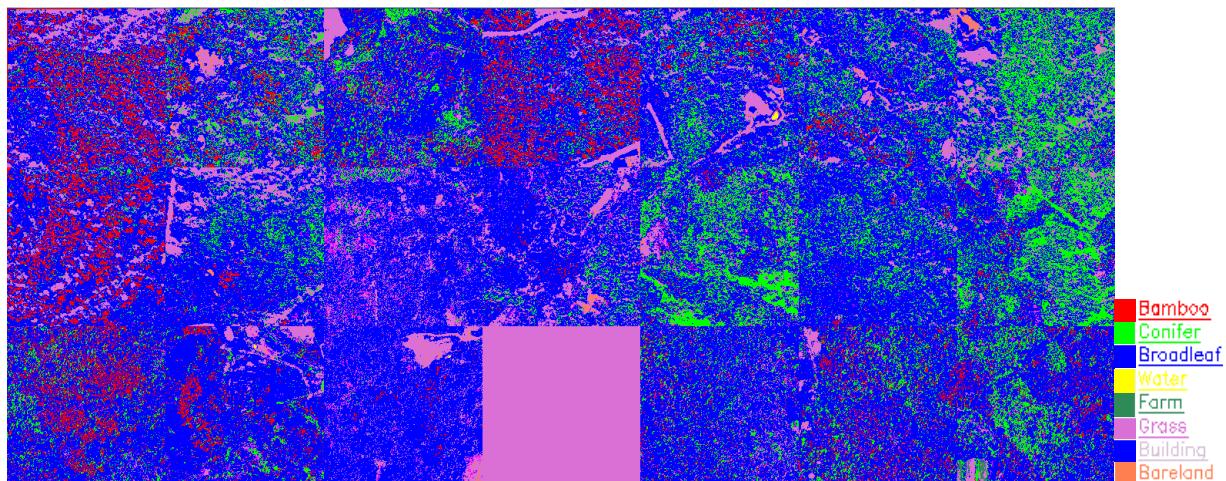


圖 43 PB-MLC Lee 分類結果(3*3NV1)

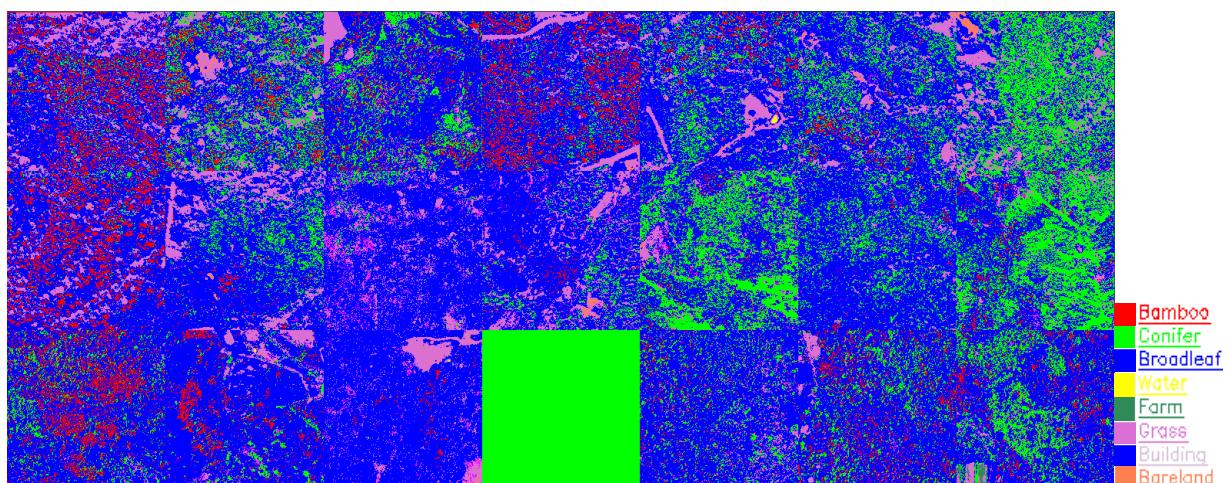


圖 44 PB-MLC Lee 分類結果(3*3NV10)

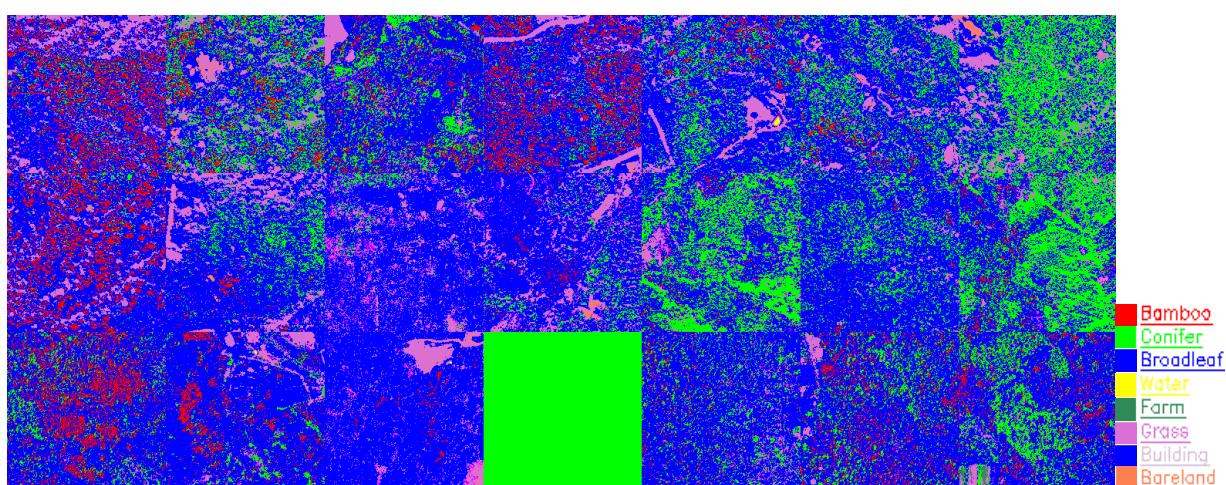


圖 45 PB-MLC Lee 分類結果(3*3NV20)

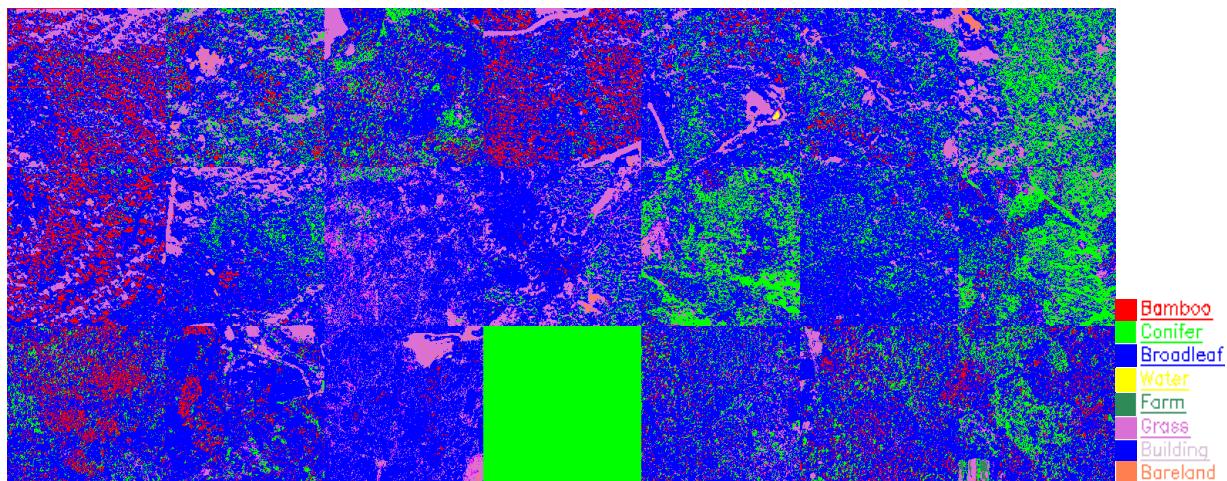


圖 46 PB-MLC Lee 分類結果(5*5NV1)

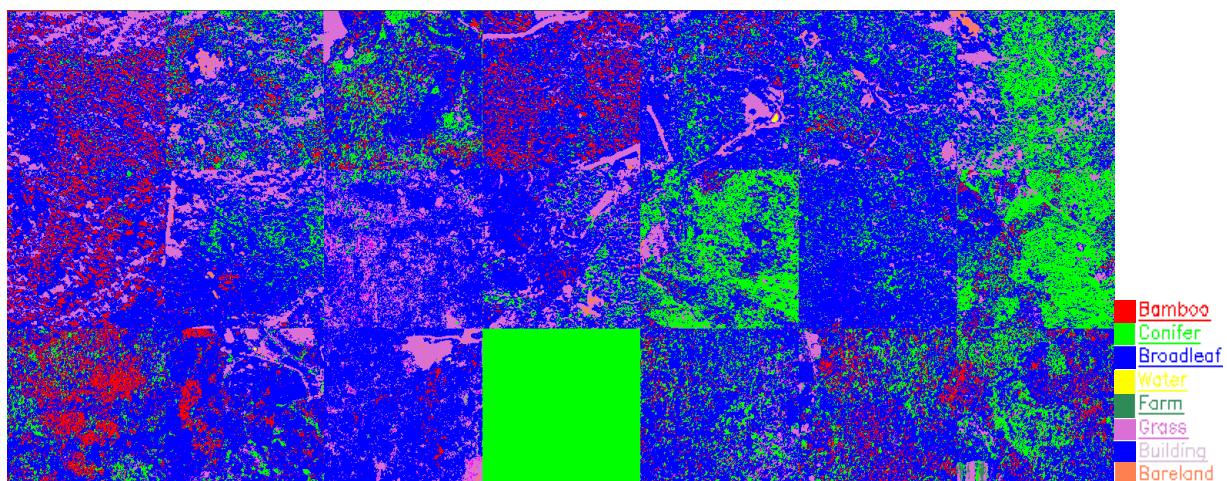


圖 47 PB-MLC Lee 分類結果(5*5NV10)

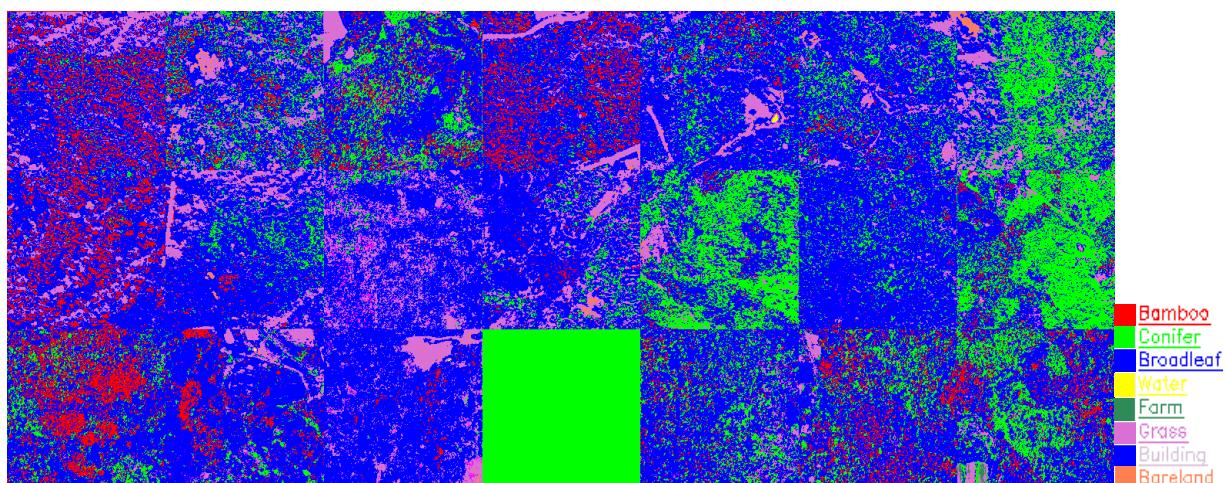


圖 48 PB-MLC Lee 分類結果(5*5NV20)



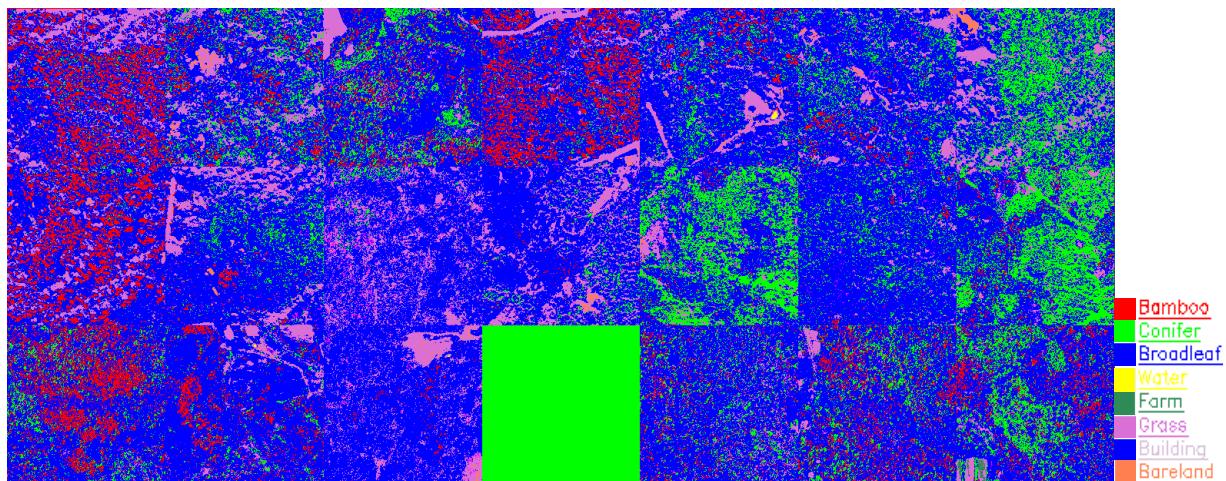


圖 49 PB-MLC Lee 分類結果(7*7NV1)

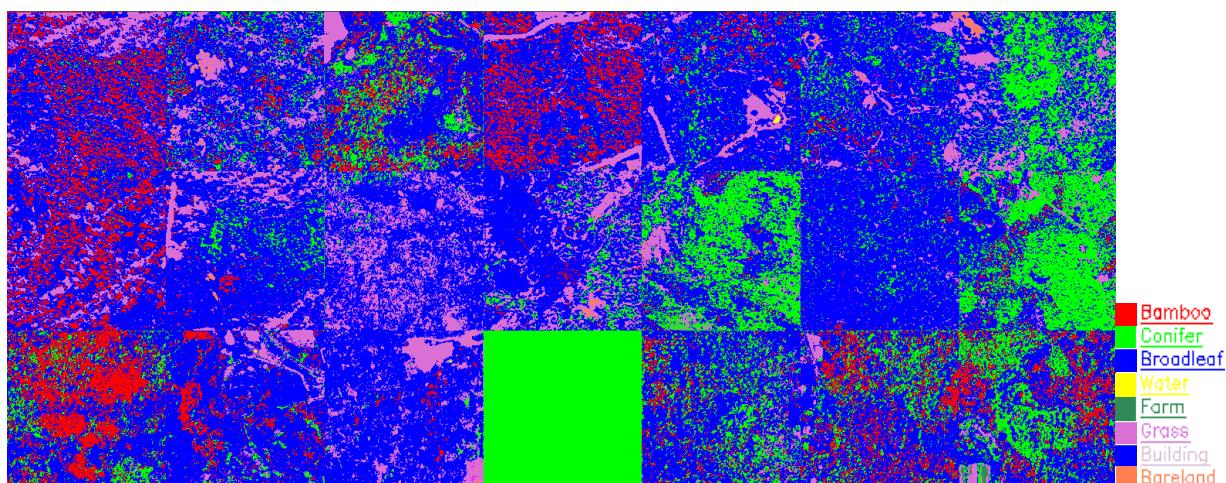


圖 50 PB-MLC Lee 分類結果(7*7NV10)

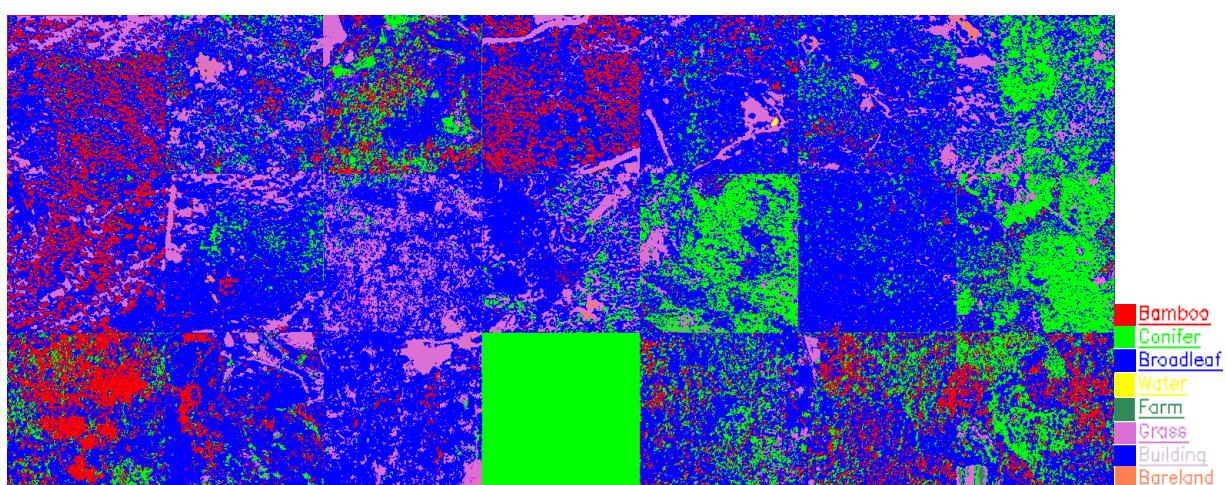


圖 51 PB-MLC Lee 分類結果(7*7NV20)

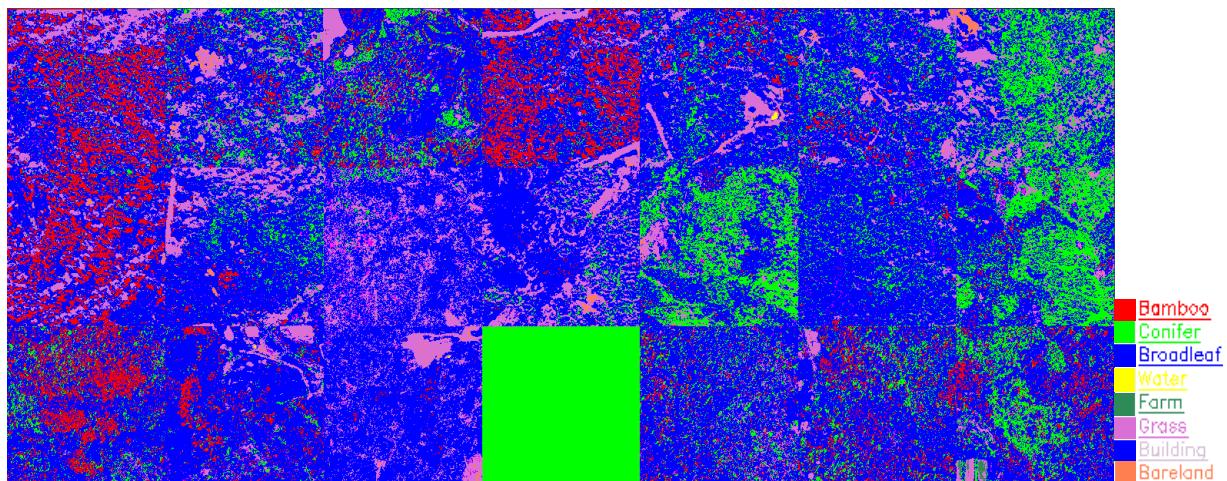


圖 52 PB-MLC Lee 分類結果(9*9NV1)

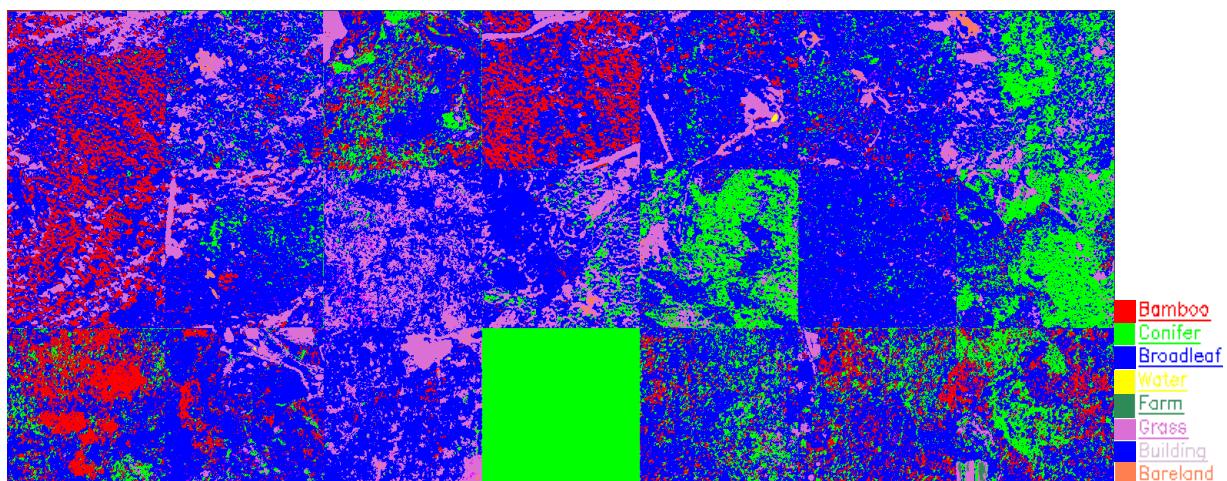


圖 53 PB-MLC Lee 分類結果(9*9NV10)

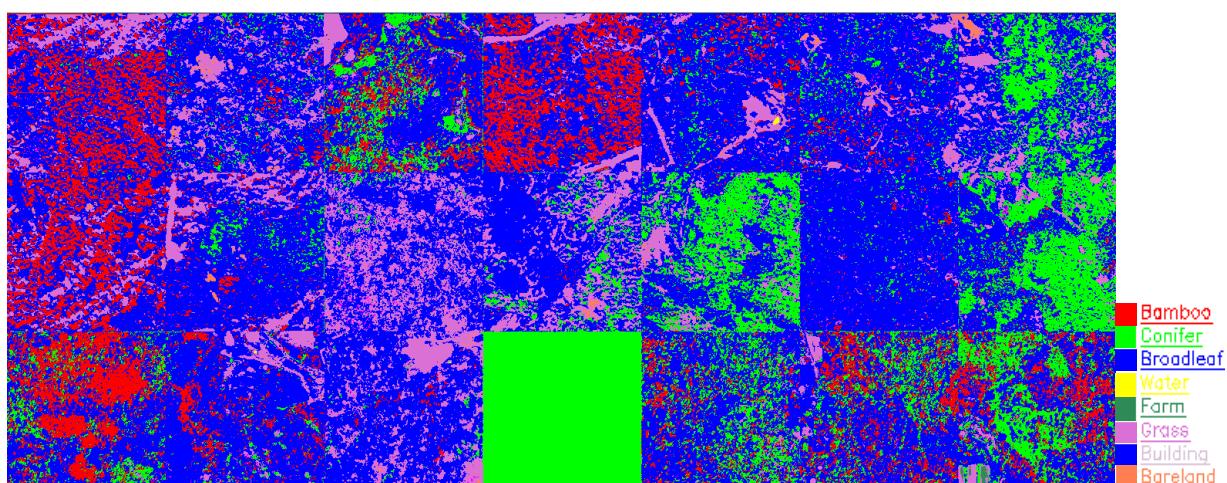


圖 54 PB-MLC Lee 分類結果(9*9NV20)



iii. Local sigma

根據表 25 可知訓練樣區準確度為 5*5 OA:89.99%、Kappa:0.8540, 7*7 OA : 90.01、Kappa : 0.8673。由評估樣區 OA(51.64~52.21%)及 Kappa(0.1808~0.1945) 可知像元大小 5*5、7*7 的差異並不大(表 22)。經過訂正後之分類準確度呈現增加狀態(5*5 OA : 51.64~60.19% 、7*7 OA : 52.21~61.06%)，且各分類型之 PA、UA 基本上也都維持增加狀態(圖 55、56)。

表 25. PB-MLC 之 Local sigma 分類準確度

	5*5				7*7			
	OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	88.99%	0.8540			90.01%	0.8673		
評估樣區	51.64%	0.1808	60.19%	0.3544	52.21%	0.1945	61.06%	0.3710
	PA	UA	PA	UA	PA	UA	PA	UA
竹類	58%	23%	77%	46%	63%	25%	80%	47%
針葉	29%	27%	31%	25%	30%	30%	32%	29%
闊葉	58%	78%	65%	79%	59%	78%	66%	79%
水體	100%	100%	100%	88%	100%	100%	100%	100%
農田	92%	18%	96%	53%	94%	19%	96%	54%
草地	9%	10%	19%	28%	9%	10%	20%	27%
建物	18%	20%	38%	52%	17%	19%	41%	56%
裸地	15%	2%	36%	14%	6%	1%	38%	13%

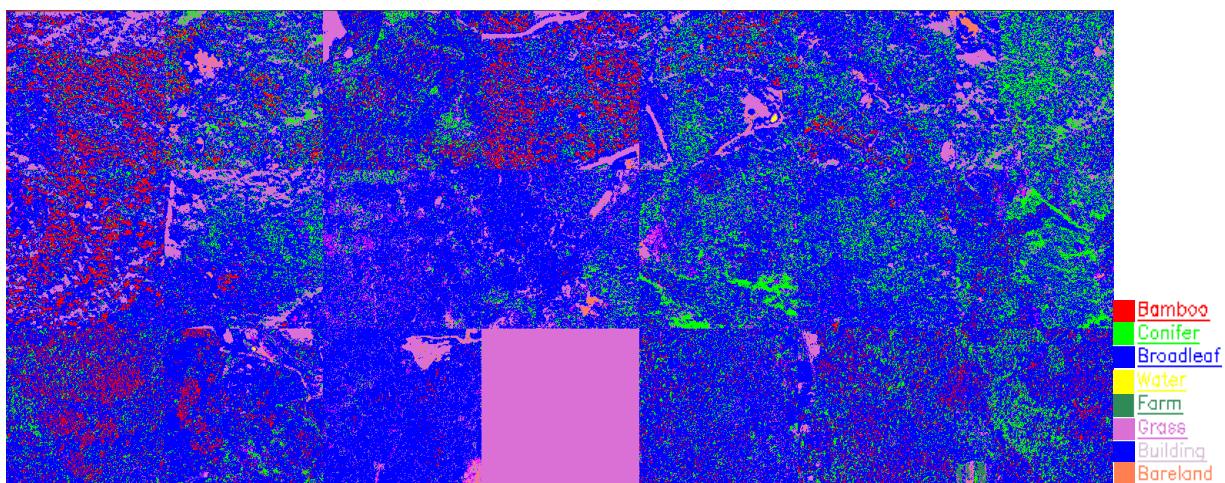


圖 55 PB-MLC Local sigma 分類結果(5*5)



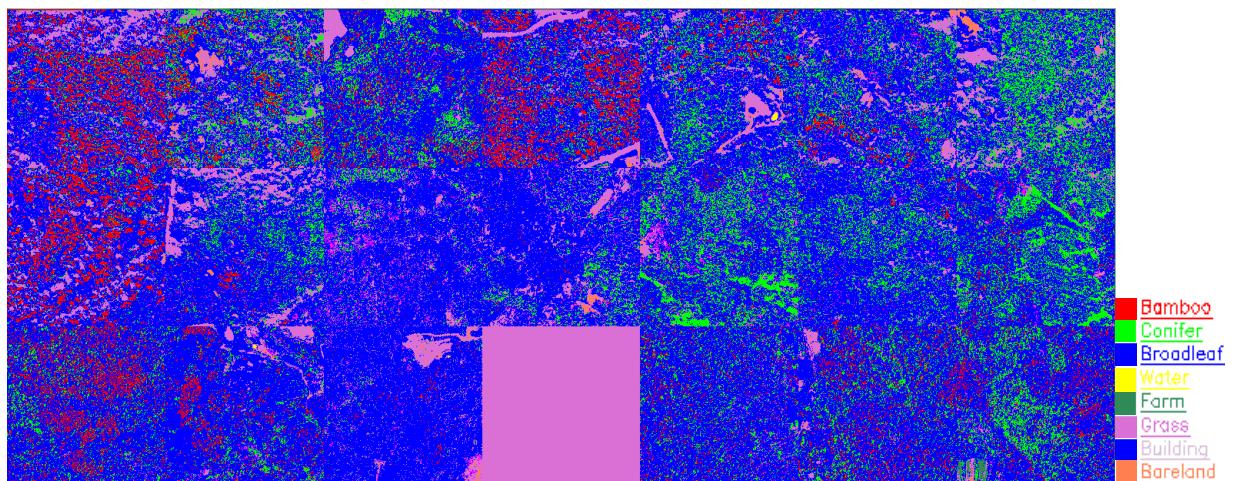


圖 56 PB-MLC Local sigma 分類結果(7*7)



II. OB-SVM

i. Gamma

從表 26 中可以發現經訂正後之分類皆可得到較高的 OA($3*3$: 33.32% ~37.58%、 $5*5$: 49.19%~54.35%)及 Kappa($3*3$: 0.0595~0.1266、 $5*5$: 0.1590~0.2592)，其中對於農田的分類準確度提升幅度最高(圖 57、58)。

表 26. OB-SVM 之 Gamma 分類準確度

	3*3				5*5			
	OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	69.81%	0.6103			84.22%	0.7865		
評估樣區	33.32%	0.0595	37.58%	0.1266	49.19%	0.1590	54.35%	0.2592
	PA	UA	PA	UA	PA	UA	PA	UA
竹類	30%	19%	42%	32%	30%	8%	45%	17%
針葉	14%	53%	16%	46%	27%	44%	31%	47%
闊葉	55%	40%	57%	41%	58%	73%	61%	74%
水體	11%	100%	9%	100%	21%	100%	12%	100%
農田	0%	0%	80%	3%	100%	0%	100%	82%
草地	23%	11%	0%	0%	28%	13%	100%	0%
建物	18%	8%	64%	45%	70%	4%	63%	43%
裸地	27%	1%	43%	26%	100%	52%	70%	10%

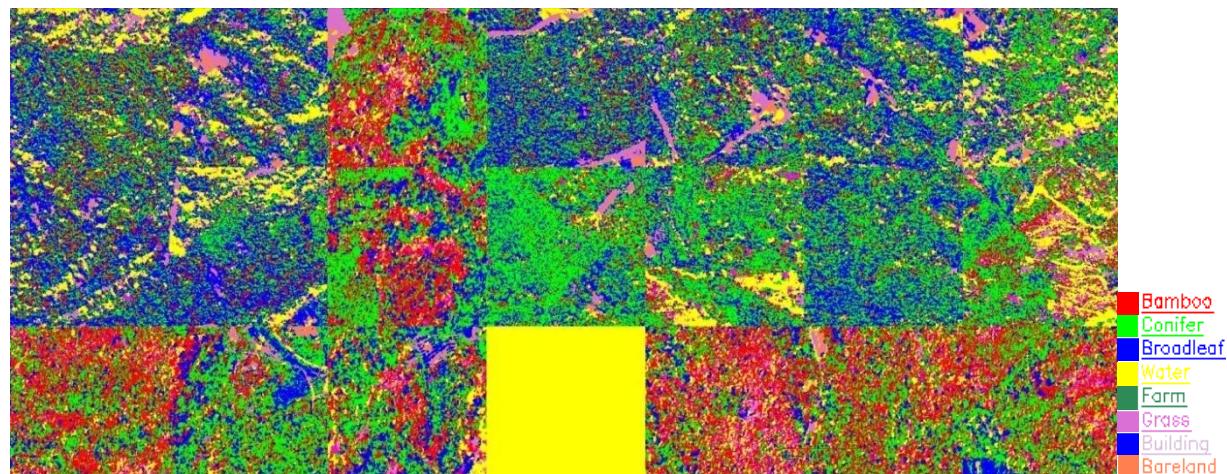


圖 57 OB-SVM Gamma 分類結果($3*3$)



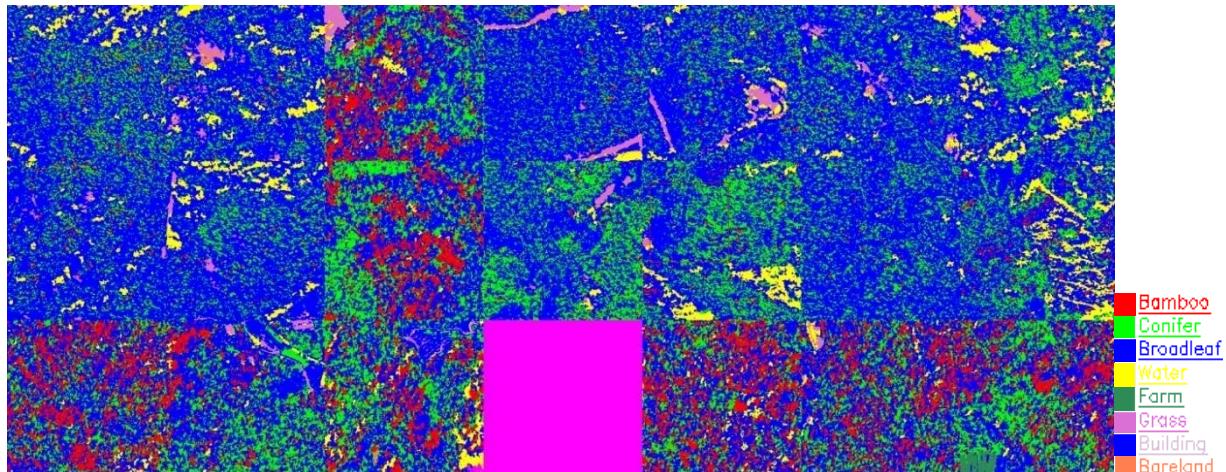


圖 58 OB-SVM Gamma 分類結果(5*5)

ii. Lee

由 3*3 的原始分類結果可知 OA : 31.25% ~40.77% 、 Kappa : 0.0571~0.0699(表 27) , 而經過訂正後之準確度則有明顯的提升 , 其中以 NV 1 具有最佳的 OA 及 Kappa 值 , 而對於農田的 PA 也有最明顯的提升。 5*5 原始分類的 OA : 43.21% ~53.12% 、 Kappa : 0.1394~0.1727(表 28) , 經過訂正後之準確度則提升為 OA : 48.11% ~60.30% 、 Kappa : 0.2208~0.3186 , 雖然準確度有提升但對於草地的 PA 却反而下降 , 顯示草地被誤判為其他分類型的情況相當嚴重。 7*7 原始分類的 OA : 41.08%~44.96% 、 Kappa : 0.0771~0.1632(表 29) , 經訂正後之準確度提升為 OA : 48.58%~50.45% 、 Kappa : 0.1951~0.2487 , 在分類型中以 NV 1 的草地改變量最大 PA : 100% → 0% , 顯示經訂正後之分類反而無法將草地分出。 9*9 原始分類的 OA : 42.83%~49.10% 、 Kappa : 0.1040~0.2088(表 30) , 經訂正後之準確度提升為 OA : 47.93%~55.43% 、 Kappa : 0.1969~0.3395 , 其分類型與 7*7 有相同的問題 , 即 NV 1 草地在訂正之後的 PA : 100% → 0% , 表示無法將草地分類出來(圖 59~70) 。





表 27. OB-SVM 之 Lee 分類準確度(3*3)

3*3	NV 1			NV 10			NV 20					
	OA	Kappa	訂正後	OA	Kappa	訂正後	OA	Kappa	訂正後			
訓練樣區	69.32%	0.5988		71.49%	0.6289			71.12%	0.6306			
評估樣區	40.77%	0.0571	45.28%	0.1404	33.79%	0.0632	40.70%	0.1544	31.25%	0.0699	37.18%	0.1386
	PA	UA										
竹類	35%	15%	49%	26%	29%	21%	42%	34%	26%	20%	38%	32%
針葉	15%	30%	14%	25%	15%	45%	16%	39%	16%	43%	17%	39%
闊葉	53%	60%	56%	61%	54%	40%	59%	45%	57%	36%	59%	40%
水體	33%	100%	17%	100%	9%	100%	8%	100%	2%	100%	2%	100%
農田	0%	0%	97%	46%	100%	0%	100%	41%	99%	29%	100%	38%
草地	37%	7%	0%	0%	23%	14%	0%	0%	0%	0%	0%	0%
建物	42%	17%	77%	30%	62%	5%	48%	48%	18%	18%	45%	43%
裸地	97%	32%	43%	27%	100%	29%	69%	16%	61%	14%	65%	23%

表 28. OB-SVM 之 Lee 分類準確度(5*5)

5*5	NV 1			NV 10			NV 20					
	OA	Kappa	訂正後	OA	Kappa	訂正後	OA	Kappa	訂正後			
訓練樣區	74.41%	0.6723		85.77%	0.8094		81.73%	0.7522				
評估樣區	43.95%	0.1481	48.11%	0.2208	43.21%	0.1394	50.95%	0.2631	53.12%	0.1727	60.30%	0.3186
	PA	UA										
竹類	34%	99%	45%	41%	30%	16%	48%	32%	41%	19%	55%	32%
針葉	21%	99%	21%	30%	18%	35%	22%	37%	20%	14%	27%	17%
闊葉	60%	100%	63%	60%	61%	60%	65%	63%	59%	84%	64%	87%
水體	44%	100%	67%	100%	15%	100%	9%	100%	13%	100%	12%	100%
農田	95%	99%	95%	45%	56%	52%	75%	87%	89%	55%	96%	87%
草地	0%	99%	0%	0%	100%	0%	0%	0%	100%	0%	0%	0%
建物	31%	99%	61%	32%	20%	22%	45%	55%	30%	6%	66%	40%
裸地	9%	99%	10%	23%	0%	0%	0%	0%	26%	8%	37%	11%





表 29. OB-SVM 之 Lee 分類準確度(7*7)

7*7	NV 1			NV 10			NV 20					
	OA	Kappa	訂正後	OA	Kappa	訂正後	OA	Kappa	訂正後			
訓練樣區	79.05%	0.7216		80.18%	0.7391		83.54%	0.7839				
評估樣區	44.96%	0.0771	50.45%	0.1951	42.64%	0.1386	48.88%	0.2487	41.08%	0.1632	48.58%	0.2688
	PA	UA										
竹類	36%	15%	52%	30%	48%	11%	68%	26%	32%	17%	71%	42%
針葉	21%	27%	21%	25%	23%	60%	26%	63%	23%	40%	29%	49%
闊葉	54%	70%	59%	71%	57%	56%	63%	57%	63%	54%	66%	66%
水體	22%	100%	18%	100%	5%	100%	4%	100%	1%	100%	11%	100%
農田	89%	13%	100%	30%	100%	47%	100%	77%	88%	67%	68%	82%
草地	100%	0%	0%	0%	20%	9%	21%	9%	7%	10%	2%	1%
建物	27%	12%	57%	45%	29%	7%	67%	26%	14%	15%	63%	44%
裸地	1%	1%	2%	2%	0%	0%	8%	3%	31%	7%	9%	7%

表 30. OB-SVM 之 Lee 分類準確度(9*9)

9*9	NV 1			NV 10			NV 20					
	OA	Kappa	訂正後	OA	Kappa	訂正後	OA	Kappa	訂正後			
訓練樣區	72.72%	0.6470		83.08%	0.7733		75.82%	0.6873				
評估樣區	42.83%	0.1040	47.93%	0.1969	49.10%	0.1887	57.49%	0.3395	48.52%	0.2088	55.43%	0.3290
	PA	UA										
竹類	32%	13%	48%	28%	46%	16%	70%	37%	58%	21%	71%	42%
針葉	21%	47%	21%	41%	28%	43%	32%	48%	28%	51%	29%	49%
闊葉	55%	60%	59%	61%	59%	69%	65%	70%	61%	65%	66%	66%
水體	100%	100%	100%	100%	12%	100%	15%	100%	8%	100%	11%	100%
農田	89%	36%	95%	49%	100%	54%	100%	88%	57%	46%	68%	82%
草地	100%	0%	0%	0%	0%	0%	0%	0%	5%	5%	2%	1%
建物	45%	8%	72%	34%	22%	26%	38%	51%	28%	12%	63%	44%
裸地	22%	8%	26%	22%	18%	7%	30%	11%	7%	8%	9%	7%



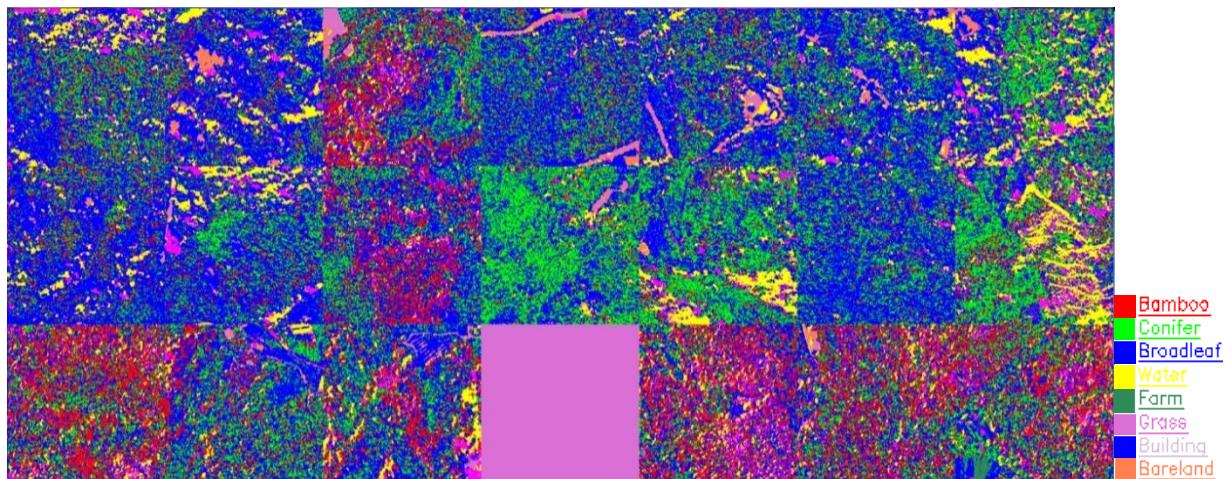


圖 59 OB-SVM Lee 分類結果(3*3 NV1)

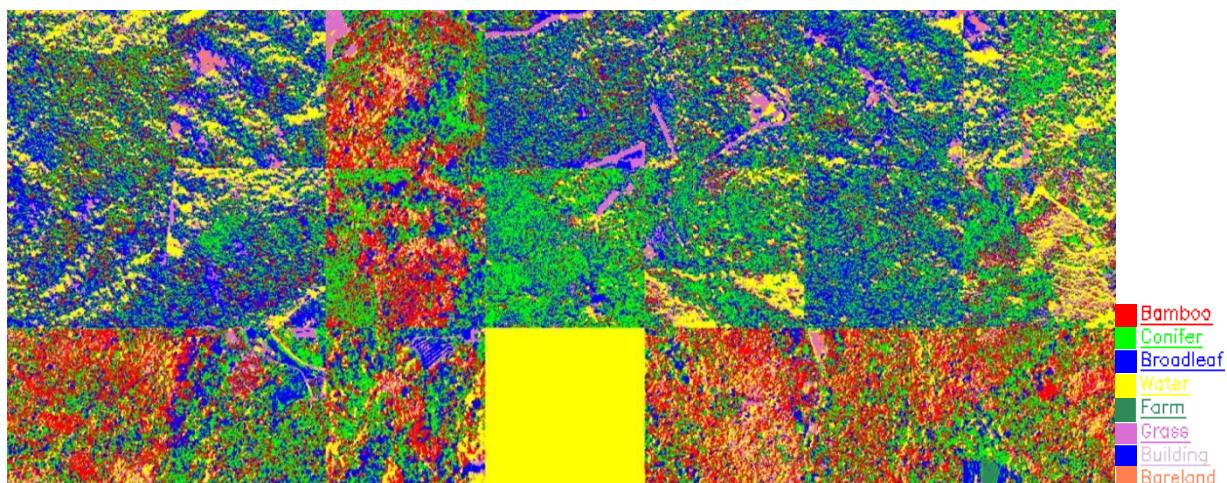


圖 60 OB-SVM Lee 分類結果(3*3 NV10)

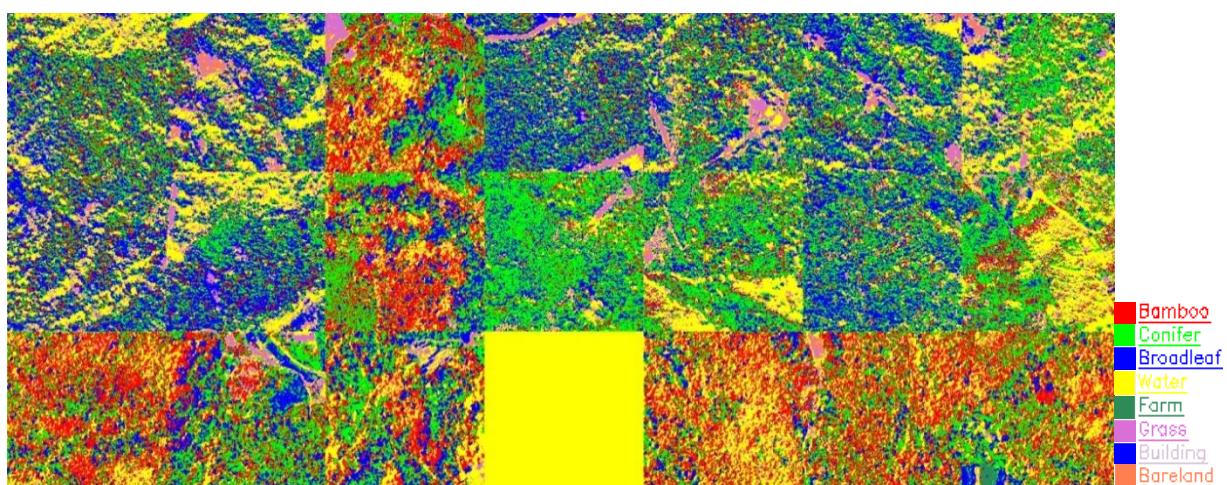


圖 61 OB-SVM Lee 分類結果(3*3 NV20)



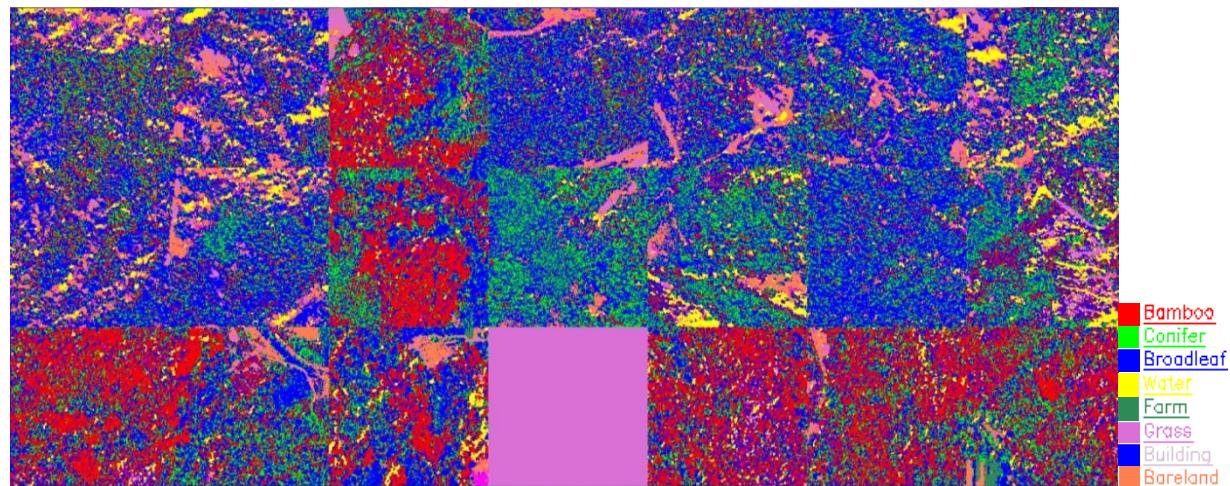


圖 62 OB-SVM Lee 分類結果(5*5 NV1)

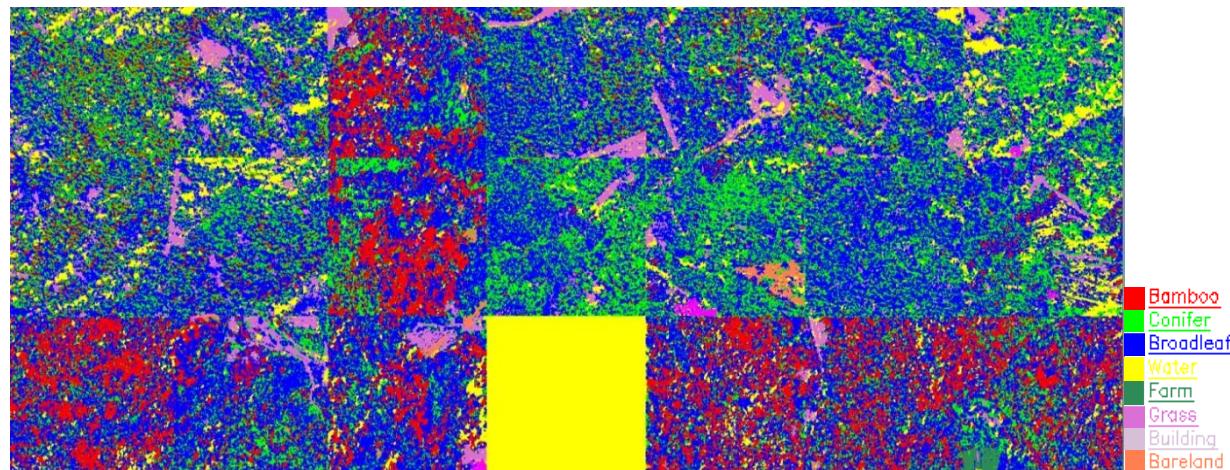


圖 63 OB-SVM Lee 分類結果(5*5 NV10)

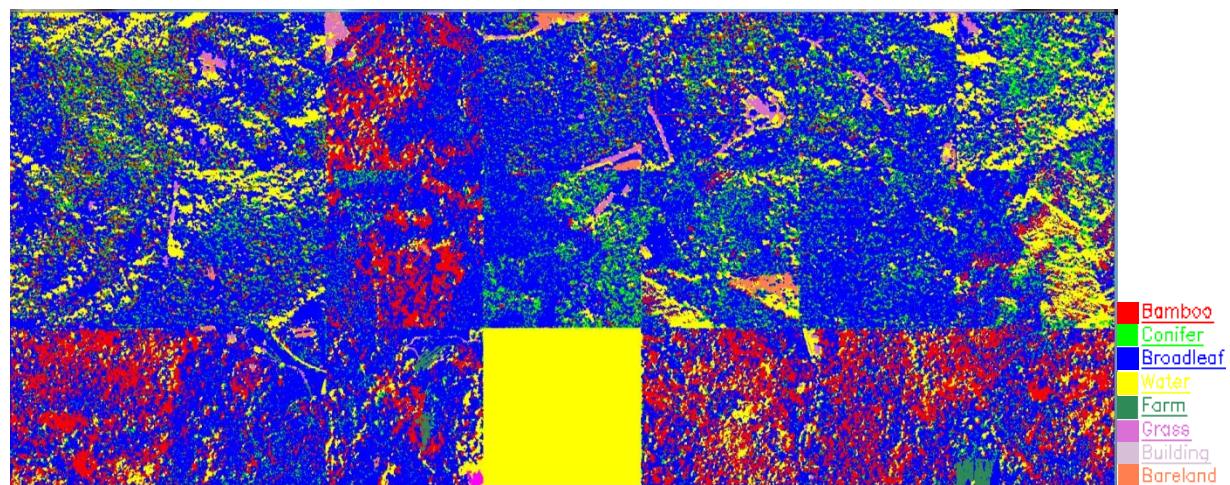


圖 64 OB-SVM Lee 分類結果(5*5 NV20)



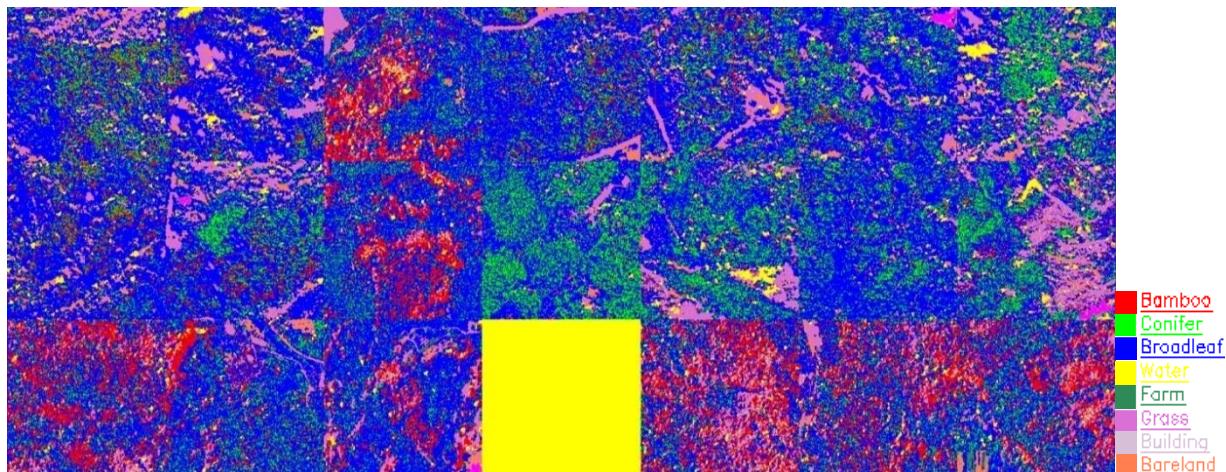


圖 65 OB-SVM Lee 分類結果(7*7 NV1)

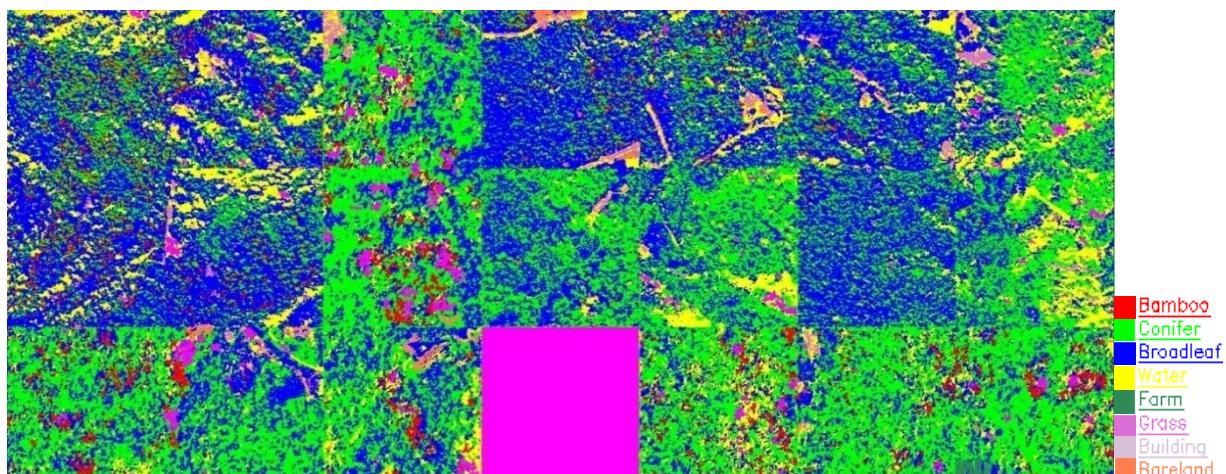


圖 66 OB-SVM Lee 分類結果(7*7 NV10)

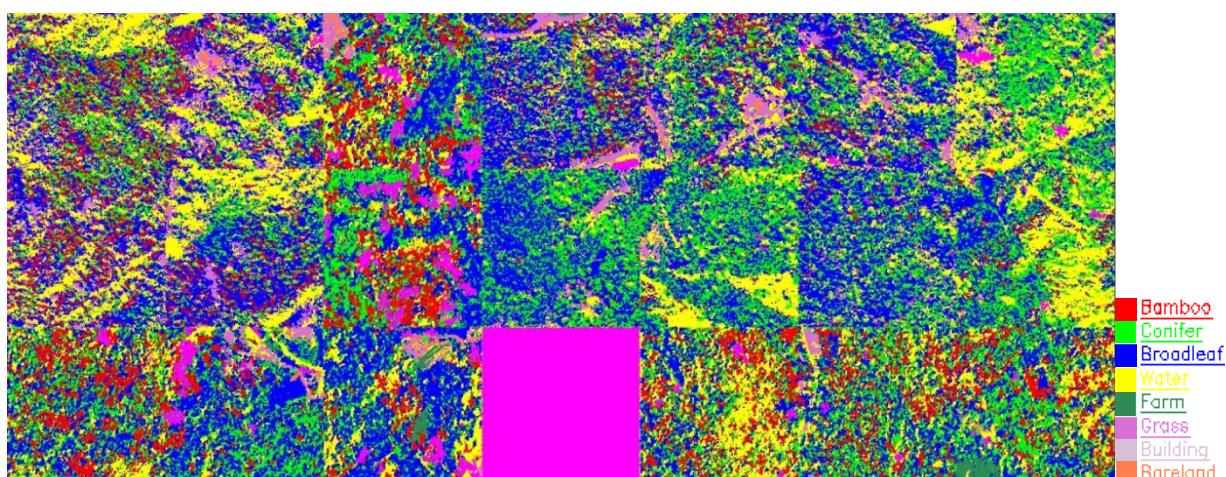


圖 67 OB-SVM Lee 分類結果(7*7 NV20)



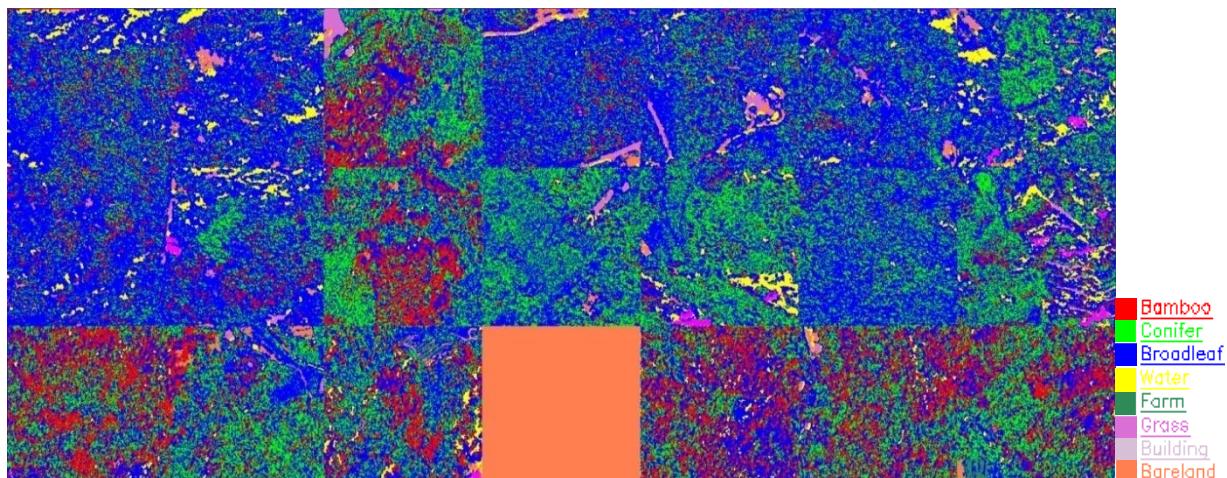


圖 68 OB-SVM Lee 分類結果(9*9 NV1)

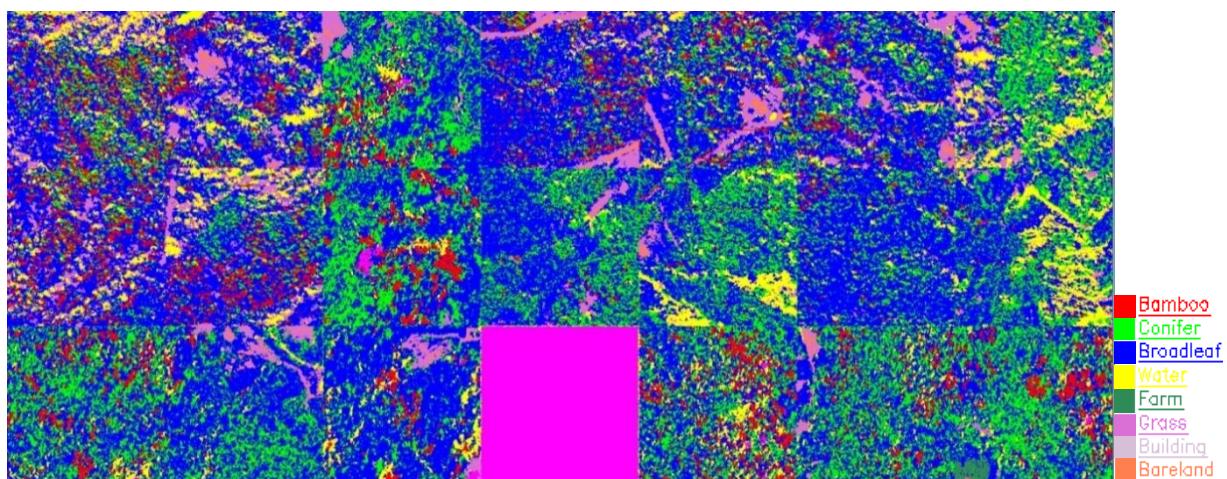


圖 69 OB-SVM Lee 分類結果(9*9 NV10)

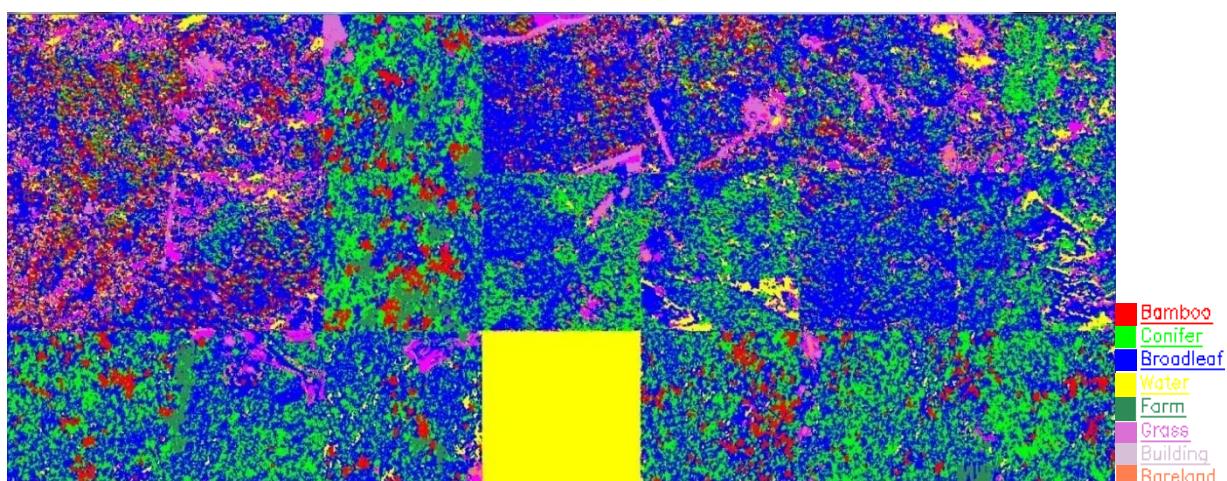


圖 70 OB-SVM Lee 分類結果(9*9 NV20)



iii. Local sigma

從表 31 中可知原始分類結果的 OA:34.93%~42.41%、Kappa:0.074~0.0604，訂正後的分類準確度僅有些微提升 OA:38.80%~46.68%、Kappa:0.1040~0.1378，在分類型中的 PA、UA 大致上皆呈現增加現象，僅草地下降至幾乎無法被分類出來的狀況(圖 71、72)。

表 31. OB-SVM 之 Local sigma 分類準確度

	5*5				7*7			
	OA	Kappa	訂正後		OA	Kappa	訂正後	
訓練樣區	65.32%	0.5595			73.91%	0.6560		
評估樣區	34.93%	0.0604	38.80%	0.1040	42.41%	0.074	46.68%	0.1378
	PA	UA	PA	UA	PA	UA	PA	UA
竹類	37%	19%	47%	29%	35%	14%	49%	24%
針葉	18%	58%	17%	49%	20%	33%	21%	29%
闊葉	52%	42%	53%	45%	54%	64%	56%	67%
水體	100%	100%	73%	100%	100%	100%	100%	100%
農田	73%	3%	100%	4%	21%	4%	43%	5%
草地	100%	0%	0%	0%	3%	7%	2%	4%
建物	75%	8%	94%	23%	38%	12%	68%	40%
裸地	24%	17%	32%	28%	38%	7%	31%	10%

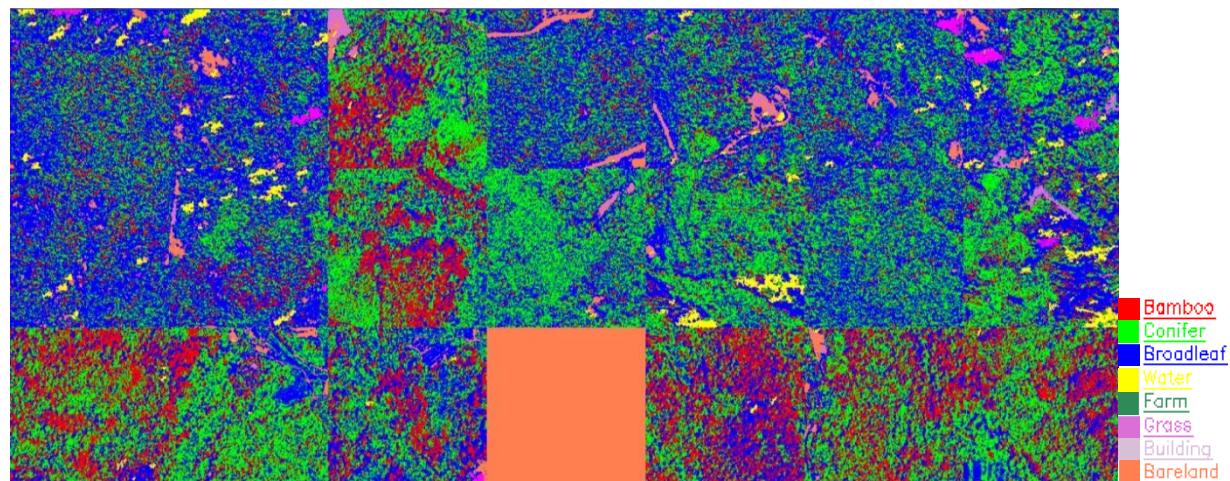


圖 71 OB-SVM Local sigma 分類結果(5*5)



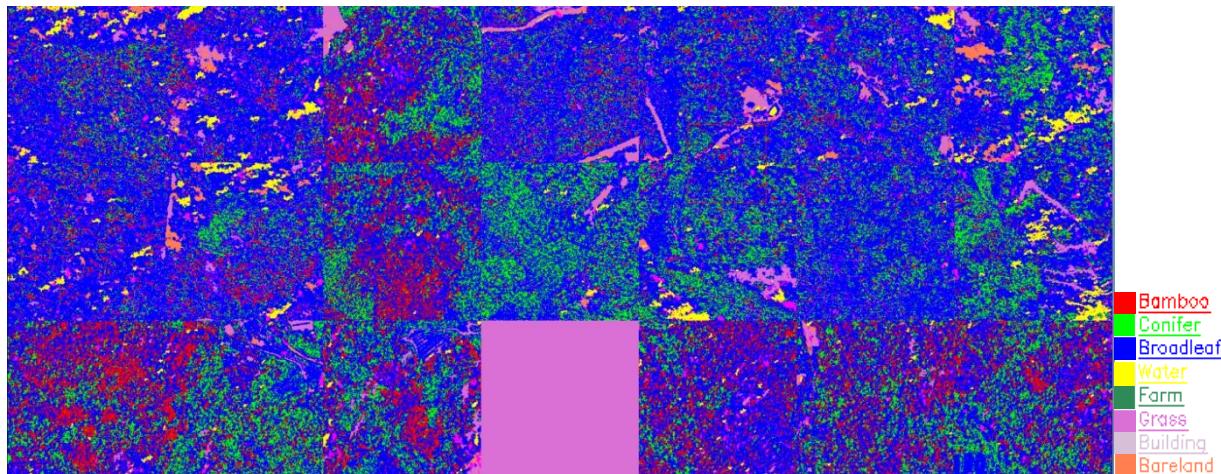


圖 72 OB-SVM Local sigma 分類結果(7*7)

(2) 混淆林型

混淆林辨識階段以 PB-MLC 及 OB-SVM 在純林型分類結果較佳的六個組合為基礎(PB-MLC: Gamma 5*5、Lee 9*9 NV20、Local sigma 7*7 ; OB-SVM: Gamma 5*5、Lee 5*5 NV20、Local sigma 7*7)進行混淆林的辨識及準確度計算。

I. PB-MLC

根據表 32~34 顯示不論以哪種分類組合進行混淆林辨識的結果都不理想(20~23%)，Kappa 值介於 0.1937~0.2214 也顯示分類精度相當的差，同時各林型的 PA 及 UA 也顯示誤判及漏判的比例相當高。由此可知在混淆林光譜訊號混雜嚴重的情況下，即使從原本分類結果較佳的組合進行處理也無法得到具可信度的混淆林分類結果。

表 32. PB-MLC Gamma 混淆林分類表(5*5)

	針	闊	針闊	竹	竹闊	竹針	竹針闊	農田	草地	水體	建物	裸地	PA
針葉樹林型	3	6	8										21%
闊葉樹林型	2	11	10		3		1				2		41%
針闊葉樹混淆林	2	3	5		2		3						38%
竹林	2	3	9		7		1						0%
竹闊混淆林	1	6	8		2		1						12%
竹針混淆林	1		2										0%
竹針闊混淆林	1	1											0%
農田													100%
草地		3	1								1		0%
水													100%
建物		4	3		1						5		38%
裸地			1										0%





UA	25%	30%	11%	100%	13%	100%	0%	100%	100%	100%	63%	100%	
OA : 21%							Kappa : 0.1979						

表 33. PB-MLC Lee 混淆林分類表(9*9 NV20)

	針	闊	針闊	竹	竹闊	竹針	竹針闊	農田	草地	水體	建物	裸地	PA
針葉樹林型	3	5	9				2						19%
闊葉樹林型	2	32	23		6		2				2		49%
針闊葉樹混淆林	1	3	5		5		3						31%
竹林	1	7	8		7		1						0%
竹闊混淆林	2	6	7		3		3						16%
竹針混淆林		2	1				1						0%
竹針闊混淆林	1	1			1								0%
農田			1										0%
草地		4	2	1									0%
水		1											0%
建物		19	7		2						2		7%
裸地		4	1										0%
UA	30%	38%	8%	0%	13%	100%	0%	100%	100%	100%	50%	100%	
OA : 23%							Kappa : 0.2214						

表 34. PB-MLC Local sigma 混淆林分類表(7*7)

	針	闊	針闊	竹	竹闊	竹針	竹針闊	農田	草地	水體	建物	裸地	PA
針葉樹林型		10	9										0%
闊葉樹林型	3	37	16	3	2						2		62%
針闊葉樹混淆林	1	13											0%
竹林	1	8	8		7								0%
竹闊混淆林	1	12	7										0%
竹針混淆林		4											0%
竹針闊混淆林	1	5											0%
農田			1										0%
草地		4	2		1								0%
水		1											0%
建物		21	7								2		7%





裸地	5												100%
UA	0%	32%	0%	0%	0%	100%	100%	100%	100%	100%	50%	100%	
OA : 20%							Kappa : 0.1937						

II. OB-SVM

從表 35~37 可知混淆林的分類準確度僅介於 18~24% 之間，Kappa 最高僅達 0.2419(Lee 5*5 NV20)，PA、UA 結果也與 PB-MLC 一樣相當的不理想，顯示各林型分類型被錯誤分類的機率相當的高，因此分類結果對於混淆林分類並不具有可信度。

表 35. OB-SVM Gamma 混淆林分類表(5*5)

	針	闊	針闊	竹	竹闊	竹針	竹針闊	農田	草地	水體	建物	裸地	PA
針葉樹林型		4	8		2	1	4						0%
闊葉樹林型	1	27	22		7		7		2		1		41%
針闊葉樹混淆林		1	5		8		2		1				29%
竹林		7	12		2		1		1		1		0%
竹闊混淆林		3	12		4		1		1				19%
竹針混淆林			1		1		2						0%
竹針闊混淆林		1	1						1				0%
農田		1											0%
草地		4	3										0%
水		1											0%
建物		21	8							1			0%
裸地		4	1										0%
UA	0%	36%	7%	100%	17%	0%	0%	100%	0%	0%	0%	100%	
OA : 18%							Kappa : 0.1790						

表 36. OB-SVM Lee 混淆林分類表(5*5 NV20)

	針	闊	針闊	竹	竹闊	竹針	竹針闊	農田	草地	水體	建物	裸地	PA
針葉樹林型		4	6		7		2						0%
闊葉樹林型		41	6		16					3	1		61%
針闊葉樹混淆林		2	2		12					1			12%
竹林		8	8		7					1			0%
竹闊混淆林		4	10		6					1			29%
竹針混淆林			1		3								0%
UA	0%												





竹針闊混淆林		1	1							1			0%
農田		1											0%
草地		9											0%
水		1											0%
建物		24	2	1	2		1						0%
裸地		5											0%
UA	100%	41%	6%	0%	11%	100%	0%	100%	100%	0%	0%	100%	
OA : 24%							Kappa : 0.2419						

表 37. OB-SVM Local sigma 混淆林分類表(7*7)

	針	闊	針闊	竹	竹闊	竹針	竹針闊	農田	草地	水體	建物	裸地	PA
針葉樹林型		6	7		4		2						0%
闊葉樹林型		32	20		10		2				3		48%
針闊葉樹混淆林		5	2		9						1		12%
竹林		11	6		6						1		0%
竹闊混淆林		8	8		4						1		19%
竹針混淆林			1		3								0%
竹針闊混淆林		1	1								1		0%
農田			1										0%
草地		5	2										0%
水		1											0%
建物		28	1		1								0%
裸地		5											0%
UA	100%	31%	4%	100%	11%	100%	0%	100%	100%	100%	0%	100%	
OA : 19%							Kappa : 0.1889						

由分類結果可以發現兩種分類法的結果皆相當不理想，推測可能的原因首先在於混淆林的光譜訊號非常混淆，因此即使先根據單純林型分類以萃取竹、針、闊林型的光譜特徵，也不容易根據各林型的光譜特徵進行混淆林型的分類，其次由於混淆林型的分類是以單純林型的分類結果進行二次分類，所以在單純林分類準確度僅約 60%左右的情況下，混淆林分類結果勢必無法有更佳的準確度出現，因此如何提升單純林型的準確度即成為應用 WV2 高空間解析影像於林型分類之價值的關鍵。





4. WV2影像林型分類作業建議方案

根據上述對於 Gamma、Lee、Local sigma 的 PB-MLC 及 OB-SVM 的分類結果，可以知道就林型分類而言以 PB-MLC 法具有較佳的分類結果 (OA:63.97%)。因此欲使用 WV2 影像進行林型分類時的建議流程如下(圖 73)：

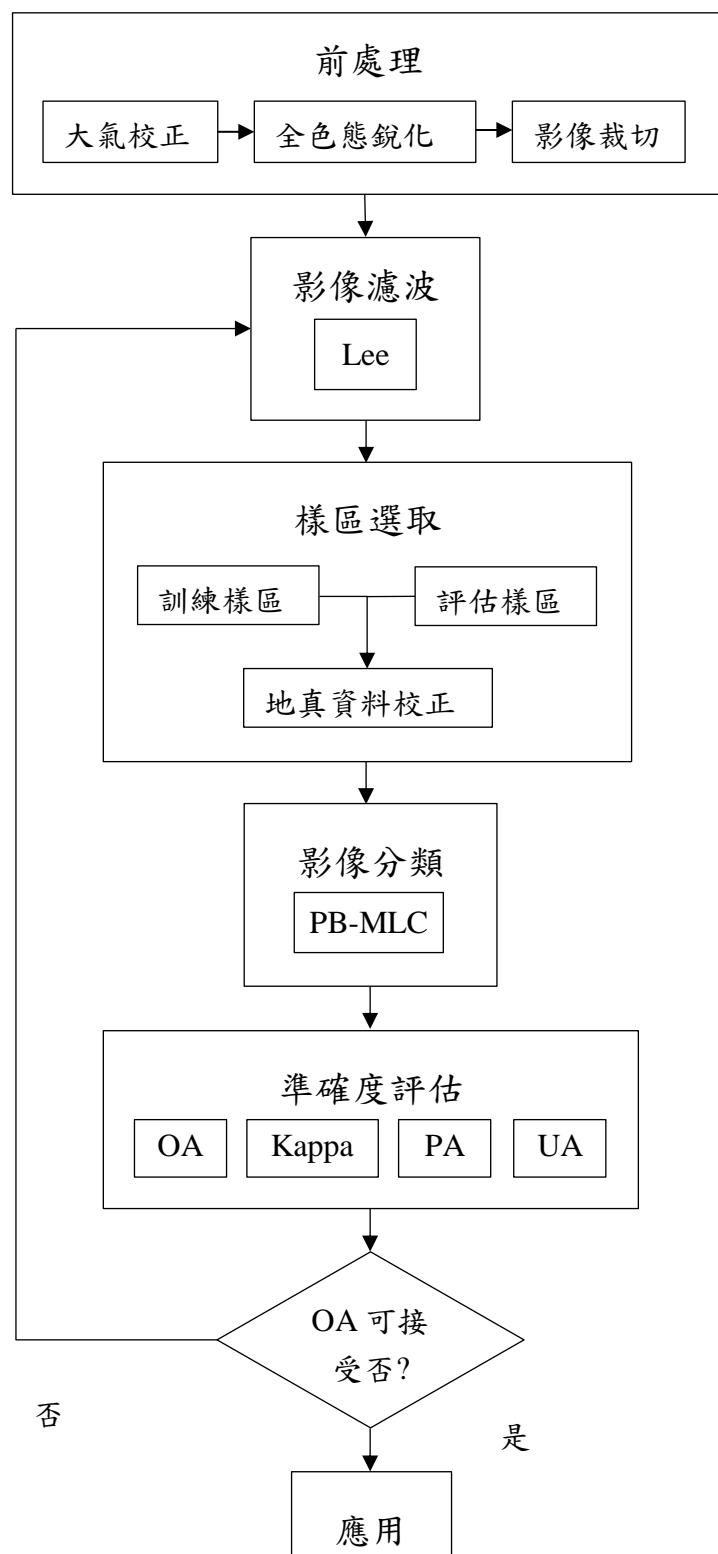


圖 73 WV2 林型分類建議作業流程





- (1) 首先將 WV2 影像進行大氣校正以去除大氣中各種會影響光線反射的因素，之後將 2m 的 8 波段之多光譜影像與 0.5m 單波段之全色態影像進行全色態銳化(GA 法)，以獲得具 0.5m 高空間解析度的多光譜影像，之後再就調查區域進行影像裁切以減少因資料量龐大而產生的時間耗費。
- (2) 經濾波器處理後可使影像平滑，減少因光譜訊號放大而產生的破碎化現象。
- (3) 由於影像為高解析度之多光譜影像，物體間之些微差異皆會被放大，因此在訓練樣區及評估樣區的應選取位於不同區域之相同分類型以減少誤判的可能性。同時根據研究結果可知地真資料的合理性對於 PB-MLC 的分類有顯著的影響，因此建議在樣區選取時可一併就地真資料進行檢核。
- (4) 準確度以 OA、Kappa、PA、UA 進行評估，除了可確認準確度外(OA)亦可同時判斷分類的精度(Kappa)及分類後對於物體誤授、漏授的機率。根據目前的研究結果可知分類準確度達 63.97%，因此在本作業流程中以 OA : 60% 作為評估標準，以判斷分類結果是否具應用價值。
- (5) 根據研究結果可推測濾波器數值的調整與地真資料訂正是提升準確度的可行方式之一，因此若要提升準確度可朝此一目標進行研究。

五、結果與討論

(一) 土地被覆型

1. 根據全色態銳化轉換結果可知 GA 法對於 Grassland、Urban、Water 保有最高的辨識能力，且由 NDVI 之結果發現 GA 法具有保持波段間相對比例的能力，使影像可保有較高的原始光譜特性，避免影像失真造成分類上的錯誤。
2. 由光譜分離度表評估可知經過全色態銳化的 FLAASH 影像不僅能去除大氣中影響分類的雜訊，更同時具有高解析度(0.5m)的特性，可準確的依據物體特性來圈選樣區提升影像分類的準確度，因此為本研究中最佳的影像處理組合。
3. 經過大氣校正全色態銳化的 PB-MLC 影像雖具較佳的分類結果(84.86%)，但因為 PB-MLC 中的像元數量會隨著解析度提升而急遽增加，使得影像中異譜或同譜異質等不確定性問題大幅增加，其結果便是導致訓練樣區選取的困難度增加及分類後椒鹽效應(salt and pepper effect)增加等一連串之問題(雷祖強等，2009)，因此後續發展受到限制。

反之，在物件導向的分類中會先進行影像分割(image segmentation)，依據色彩、紋理、形狀這三種視覺上的特徵來描述影像的內容，之後分別對各區塊給予適當形式的表示和描述再根據區塊特性進行分類。同時根據過往研究結果顯示 OB-SVM 的分類法結果往往較像元導向的分類法為佳(Foody and Mathur, 2004；Melgani and Bruzzone, 2004；黃明哲、李良輝，2005；許晉嘉等，2005；鄭雅文等，2008)，顯示確實具有發展上的潛力。最後，KNN 在評估樣區中的準確度則不論何種處理皆不理想，因此不納入後續的林型研究之中。





(二) 林型

1. 研究結果顯示在林型分類上經 Lee 濾波器處理後可得較佳的分類準確度(63.97%)，但仍較傳統衛星影像分類準確度為差，因此在 Lee 濾波器的設定上仍有值得持續進行測試的必要。
2. WV2 影像雖具有高解析度的優勢，卻同時具有資料量龐大的缺點，因此雖然直接以原始未裁切之影像進行分類會使處理時間大幅度拉長使得效率極低，同時若必須進行不同設定值之測試則時間花費浩大，因此仍建議先就目標位置進行裁切以減少資料處理量，同時配合本研究所建立之作業流程達到提高 WV2 影像使用益本比的目的。
3. 研究結果顯示 PB-MLC 在林型分類上具有較佳的分類準確度(63.97%)，其原因可能在於林分中的立木生長受環境因子的影響，故即使是同一林型但位於不同生育地之林分常有明顯的生長差異，而混淆林型內之變異程度更高使得常無法完整切割出樹木的形狀，因此 OB-SVM 便無法準確依據樹木的外型進行分類，故準確度明顯較像元分類法為差。而 PB-MLC 的分類關鍵應該是地真資料的合理性，訂正前後的準確度相差可達 10%左右，因此建議在使用 PB-MLC 進行 WV2 影像分類時，須先進行地真資料的比對以降低不合理性所帶來的誤差。在混淆林分類上則兩種分類法皆無法進行有效分類(PB-MLC：20~23%、OB-SVM：18~24%)。

六、結論

WV2 影像因具有高空間解析度地特性，故可滿足大尺度土地被覆型分類上之需求，同時其所提供的光譜訊息應可準確應用於單純林型分類之上，且配合資源調查結果應可再對混淆林型進行分類，對於森林資源經營提供具參考價值的分類結果，而根據本研究之結果顯示目前僅能滿足土地被覆型分類的需求，對於單純林型及混淆林型的分類則有待進一步的深入研究，建構可行的林型分類機制供未來森林資源調查之用，以彌補 SPOT 影像解析度不足的缺點。

七、參考文獻

- 內政部城鄉發展分署網站 <http://wetland-tw.tcd.gov.tw/WetLandWeb/index.php>
- 王駿發、林博川、王家慶、宋豪靜 (2005) 以支援向量機為基礎之新穎語者切換偵測演算法。1-20 頁。第十七屆自然語言與語音處理研討會。中華民國計算語言學學會，台北。
- 吳季桓 (2010) 自動分類的實作：KNN 與 SVM。國立中正大學資訊工程研究所碩士論文，49 頁。
- 林金樹 (1999) 森林植生季節性光譜特性之研究。台灣林業科學 14(3): 289-305。
- 林金樹 (2001) 影像參數加權統計法 PN 指標於土地利用型高光譜特徵選粹上之研究。航測及遙測學刊 6(3): 1-20。
- 林金樹 (2004) GIS 概論與 MajorGIS 快速入門。新文京開發出版股份有限公司，





474 頁。

- 邱彥瑋 (2012) 混合式多光譜影像全色態銳化之方法探討。國立台灣大學工學院
土木工程學系碩士論文，66 頁。
- 張伯辰、連偉志、楊建民 (2013) 適用於雲端分散儲存架構下的 KNN 平行演算
法。1-10 頁。第二屆服務與科技管理研討會。國立台北科技大學服務與科技
管理研究所，台北。
- 許晉嘉 (2006) 應用支援向量機法於高解析度衛星影像分類之研究。逢甲大學環
境資訊科技研究所碩士論文，68 頁。
- 許晉嘉、雷祖強、周天穎 (2005) 應用支援向量機法於衛星影像分類之研究，農
業工程研討會。
- 陳承昌 (2006) 支持向量機及 Plausible Neural Network 於水稻田辨識之研究。國
立交通大學土木工程學系碩士論文，122 頁。
- 黃明哲、李良輝 (2005) 支持向量機應用於空載雷射掃瞄資料地物分類之研究，
電子計算機於土木水利應用研討會。
- 黃冠中 (2007) 應用 KNN 演算法之文件分類平台實作。第六屆離島資訊技術與
應用研討會
- 黃凱翔 (2008) 利用支持向量機於機載高光譜感測影像之分類。中興大學土木工
程學系碩士論文，62 頁。
- 楊元琪 (2007) 綜合法則歸納系統之延伸研究。國立中山大學資訊管理學系碩士
論文，85 頁。
- 雷祖強、李哲源、葉惠中、萬綯 (2009) 以區塊化物件分類法萃取 ADS-40 影像
中水稻田坵塊資訊之研究。航測及遙測學刊 14(2)：127-140。
- 蔡豫學 (2011) 應用支持向量機預測水庫乾旱。屏東科技大學水土保持系碩士論
文，157 頁。
- 鄭雅文、史天元、蕭國鑫 (2008) 物件導向分類於高解析度影像自動判釋。航測
及遙測學刊 13(4)：273-284。
- Abdallah, C., J. Chorowicz, R. Bou Kheir and M. Khawlie (2005) Detecting
major terrain parameters relating to mass movements' occurrence using
GIS, remote sensing and statistical correlations, case study Lebanon.
Remote Sensing of Environment 99:448-461.
- Ajeng A., and C. Lin (2011) Application of SAM and SVM techniques to burned area
detection for Landsat TM images in forests of south Sumatra. Proceeding of the
ICEST 2011. IPCBEE vol. 6 (v2):160-164. IACSIT Press, Singapore.
- Allaby M. (1998) A dictionary of plant sciences. 2nd ed. Oxford University Press,
Oxford, UK. 508pp.
- Baatz, M., and Schäpe, A. (2000) Multiresolution segmentation - an optimizaiton
approach for high quality multi-scale image segmentation. pp.12-23. In: Strobl, J.
et al., eds. Angewandte Geographische Infor-mationsverarbeitung XII.





Wichmann, Heidelberg. 553pp.

- Baesens, B., Viaene, S., Van Gestel, T., Suykens, J.A.K., Dedene, G., De Moor, B., and Vanthienen, J. (2000) An empirical assessment of kernel type performance for least squares support vector machine classifiers. pp.313-316. In: Knowledge-Based Intelligent Engineering Systems and Allied Technologies, 2000. Proceedings. Fourth International Conference on, Vol 1. 457pp.
- Burges, C. J. C. (1998) A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery* 2:121-167.
- Chen, S.Y., Y.C. Ouyang, C. Lin, and C.I. Chang. (2011) Iterative support vector machine for hyperspectral image classification. The Proceeding of Geoscience and Remote Sensing Symposium (IGARSS), 2011 IEEE International. p.1712-1715. DOI:10.1109/IGARSS.2011.6049565.
- Cohen, J. (1960) A coefficient of agreement for nominal scales. *Educational Psychological Measurement* 20:37-46.
- Congalton, R. G. and K. Green (2009) Assessing the accuracy of remotely sensed data: Principles and Practices. CRC Press, Boca Raton, FL.
- Ramsar Secretariat (1971) Convention on Wetlands of International Importance especially as Waterfowl Habitat. Ramsar, Iran.
- Cristianini, N. and J. Shawe-Taylor (2000) An introduction to support vector machines and other kernel-based learning methods. Cambridge University Press. 189pp.
- de Carvalho, O. A. Jr, and Meneses, P. R. (2000) Spectral Correlation Mapper (SCM): An improvement on the Spectral Angle Mapper (SAM). Summaries of the 9th Airborne Earth Science Workshop. Jet Propulsion Laboratory 00-18.
- Du, Q., N. H. Younan, R. King and V. P. Shah (2007) On the performance evaluation of Pan-Sharpening techniques. *IEEE Geoscience and Remote SensinG Letters* 4(4):518-522.
- Foody, G. M. and A. Mathur (2004) A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42 (6):1335-1343.
- Gaspar, P., Carbonell, J., and Oliveira, J. L. (2012) On the parameter optimization of Support Vector Machines for binary classification. *Journal of Integrative Bioinformatics*, 9(3):201.
- Haralick, R. M., K. Shanmugam and I. Dinstein (1973) Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics* 3(6):610-621.
- Hermas, E., S. Leprince and I. A. El-Magd (2012) Retrieving sand dune movements using sub-pixel correlation of multi-temporal optical remote sensing imagery,



- northwest Sinai Peninsula, Egypt. *Remote Sensing of Environment* 121:51-60.
- Hoffbeck, J. P. and D. A. Landgrebe (1996) Covariance matrix estimation and classification with limited training data. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 18(7):763-767.
- Hsu, C. W., and Lin, C. J. (2002) A comparison of methods for multiclass support vector machines. *IEEE Trans. Neural Networks* 13: 415-425.
- Hsu, C. W., C. C. Chang and C. J. Lin (2009) A practical guide to support vector classification. Technical Note, Department of Computer Science and Information Engineering, National Taiwan University, Taiwan.
- Hsu, C. W., Chang, C. C., and Lin, C. J. (2010) A practical guide to support vector classification. Technical report. Department of Computer Science and Informaiton Engineering, National Taiwan University.
- Huang, C., Davis, L. S., and Townshend, J. R. G. (2002) An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing* 23(4): 725-749.
- Hughes, G. F. (1968) On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory* IT-14:55-63.
- James, M. (1985) Classification algorithms. John Wiley and Sons, Inc. London, United Kingdom. 211p.
- Jensen, C. S., J. Kolar, T. B. Pedersen, and I. Timko (2003) Nearest neighbor queries in road networks. in Proceedings of the ACM GIS, New Orleans, Louisiana, USA.
- Jia, X. and Richards, J. A. (1994) Efficient maximum likelihood classification for imaging spectrometer data sets. *IEEE Transactions on Geoscience and Remote Sensing* 32(2):274-281.
- Laben, C. A. and B. V. Brower (2000) Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. United States Patent 6011875. 8p.
- Lam, W. and C. Y. Ho (1998) Using a generalized instance set for automatic text categorization. Proceedings of the 21st Annual International ACM-SIGIR Conference on Research and Development in Information Retrieval. pp.81-89.
- Lee, C. and Landgrebe, D. A. (1993) Analyzing high-dimensional multispectral data. *IEEE Transactions on Geoscience and Remote Sensing* 31(4):792-800.
- Leeuw, M. R. and Carvalho L. M. T. (2009) Performance evaluation of several adaptive speckle filter for SAR imaging. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, pp.7299-7305.
- Lewis, J. P. (1995) Fast template matching. *Vision Interface* 95:120-123.
- Lin, C. and D. Trianingsih (2012) Evaluation of the reliability of classifiers for the mapping of mangrove forest using landsat TM Images. The 2nd International





Conference on Electric Technology and Civil Engineering (ICETCE 2012). May 18-21, 2012. Three Gorges, YiChang, China.

- Matthew, M. W., S. M. Adler-Golden, A. Berk, S. C. Richtsmeier, R. Y. Levine, L. S. Bernstein, P. K. Acharya, G. P. Anderson, G. W. Felde, M. P. Hoke, A. Ratkowski, H.-H. Burke, R. D. Kaiser, and D. P. Miller (2000) Status of atmospheric correction using a MODTRAN4-based algorithm. SPIE Proceedings, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI. Vol. 4049, pp. 199-207.
- Meenakshi and Punitham (2011) Performance of speckle noise reduction filter on active radar and SAR images. International Journal of Technology And Engineering System 2(1):111-114.
- Melgani, F. and L. Bruzzone (2004) Classification of hyperspectral remote sensing Images with support vector machines, IEEE Transactions on Geoscience and Remote Sensing 42 (8):1778-1790.
- Mercier, G., and Lennon, M. (2003) Support vector machines for hyperspectral image classification with spectral-based kernels. In Proc. IGARSS, Toulouse, France, July 21-25, 2003.
- Ozdarici, A. and Akyurek Z. (2010) A comparison of SAR filtering techniques on agricultural area identification. pp.730-739. In: American Society for Photogrammetry and Remote Sensing Annual Conference 2010. Curran Associates. San Diego, California, USA. 1107pp.
- Pouteau, R., J.-Y. Meyer, R. Taputuarai and B. Stoll (2012) Support vector machines to map rare and endangered native plants in Pacific islands forests. Ecological Informatics 9:37-46.
- Qiu, F., J. Berglund, J. R. Jensen, P. Thakkar and D. Ren (2004) Speckle noise reduction in SAR imagery using a local adaptive median filter. GIScience and Remote Sensing 41(3):244-266.
- Ranchin, T. and L. Wald (2000) Fusion of high spatial and spectral resolution images: The ARSIS concept and its implementation. Photogrammetric Engineering and Remote Sensing 66(1):49-61.
- Rudjord and Trier (2012) Evaluation of FLAASH atmospheric correction. Project number: 220512. TropSkogTanz, Norsk Regnesentral, Oslo.
- Samadzadegan, F., F. Fathollahi and M. Rezaee (2012) Comparing different IHS-based pan-sharpening techniques for worldview-2 high resolution satellite imagery. IEEE Geoscience and Remote Sensing Symposium 2296-2299.
- Schölkopf and A. J. Smola (2002) Learning with Kernels. Cambridge, MA, MIT Press.
- Shahabi, C., M. R. Kolahdouzan and M. Sharifzadeh (2003) A road network





- embedding technique for k-nearest neighbor search in moving object databases. *Geoinformatica* 7(3):255-273.
- Swain, P. H. and Davis, S. M. (1978) Remote sensing: The Quantitative Approach. NY: McGraw-Hill. 396pp.
- Tu, T. M., C. H. Chen, J. L. Wu and C. I. Chang (1998) A fast two-stage classification method for high-dimensional remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing* 36(1):182-191.
- Tu, T. M., C. L. Hsu, P. Y. Yu and C. H. Lee (2012) An adjustable Pan-Sharpening approach for IKONOS/QuickBird/GeoEye-1/WorldView-2 imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5(1):125-134.
- Tzotsos, A., and Argialas, D. (2008) Support vector machine classification for object-based image analysis. pp.663-677. In Blaschke, T., Lang, S., and Hay, G.J., edited, *Object-Based Image Analysis-Lecture Notes in Geoinformation and Cartography*. Berlin, Germany: Springer Berlin Heidelberg. 817pp.
- Vapnik, V. (1982) Estimation of dependences based on empirical data. Springer-Verlag. 399pp.
- Vapnik, V. (1995) *The Nature of Statistical Learning Theory*. Springer-Verlag. 314pp.
- Wald, L., T. Ranchin, and M. Mangolini (1997) Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images. *Photogrammetric Engineering and Remote Sensing* 63(6):691-699.
- Welch, R. and W. Ehlers (1987) Merging multiresolution SPOT HRV and Landsat TM data. *Photogrammetric Engineering and Remote Sensing*, 53(3):301-303.
- Widjaja, D., Varon, C., Dorado, A. C., Suykens, J. A., and Van Huffel, S. (2012) Application of kernel principal component analysis for single-lead-ECG-derived respiration. *IEEE Trans Biomed Eng* 59(4):1169-1176. doi: 10.1109/TBME.2012.2186448.
- Wolf, A. (2010) Using worldview2 Vis-NIR MSI imagery to support land mapping and feature extraction using normalized difference index ratios. *Digital Globe 8-Band Challenge* 13pp.
- Xiao, J., J. Li and A. Moody (2003) A detail-preserving and flexible adaptive filter for speckle suppression in SAR imagery. *International Journal of Remote Sensing* 24(12):2451-2465.
- Zhang, Y. (2004) Understanding Image Fusion. *Photogrammetric Engineering & Remote Sensing* 70(6):657-661.





附錄 1 土地被覆型隨機取樣之樣點座標位置一覽

ClSaa_Name	X	Y
water	204238.73	2542009.05
water	200403.23	2541663.05
water	200432.23	2541538.05
water	200406.73	2541503.55
urban	204158.73	2542099.55
urban	204458.73	2541412.05
urban	202432.73	2541189.05
urban	203158.23	2541046.05
urban	200706.73	2540861.05
urban	203320.73	2540713.05
urban	202233.73	2540696.55
urban	203451.73	2540642.55
urban	204570.16	2540357.26
urban	200456.23	2540130.05
urban	201927.23	2540075.55
urban	201419.73	2540075.05
stone	202602.73	2542423.55
stone	202238.73	2542237.05
stone	202107.23	2542205.55
stone	201727.73	2541210.05
stone	201642.73	2541087.05
stone	203193.73	2540695.55
stone	201128.23	2540193.55
stone	201657.73	2540100.05
sand	200565.23	2541802.05
sand	200510.23	2541431.55
sand	200517.73	2541355.55
river	202161.73	2542454.55
river	202547.23	2542346.05
river	201565.23	2541721.05
river	201305.23	2540615.55
river	201320.73	2540354.55
greenhouse	203545.73	2542410.55

greenhouse	203809.73	2542338.05
greenhouse	202982.23	2542113.05
greenhouse	203408.23	2542060.05
greenhouse	204132.73	2541755.05
greenhouse	202575.73	2541526.55
greenhouse	202009.23	2540946.05
greenhouse	201862.73	2540719.55
greenhouse	202478.23	2540325.05
grassland	200319.73	2542452.55
grassland	203523.73	2542370.55
grassland	200108.73	2542285.55
grassland	204063.23	2542046.05
grassland	200378.73	2541830.55
grassland	203276.23	2541725.55
grassland	200297.23	2541679.05
grassland	200534.73	2541563.05
grassland	203323.23	2541392.55
grassland	200307.73	2540971.55
grassland	203255.23	2540912.55
grassland	202862.73	2540553.05
grassland	202809.73	2540176.55
forest	204481.73	2542415.55
forest	202875.73	2542390.55
forest	201864.23	2542358.05
forest	201751.73	2542290.55
forest	202964.23	2542286.55
forest	203231.73	2542278.05
forest	201108.73	2542232.55
forest	201204.73	2542135.05
forest	200183.73	2542024.55
forest	200563.73	2541887.55
forest	202149.73	2541613.55
forest	200774.23	2541474.55
forest	203256.23	2541355.05
forest	204385.73	2541204.05
forest	201160.73	2541032.55



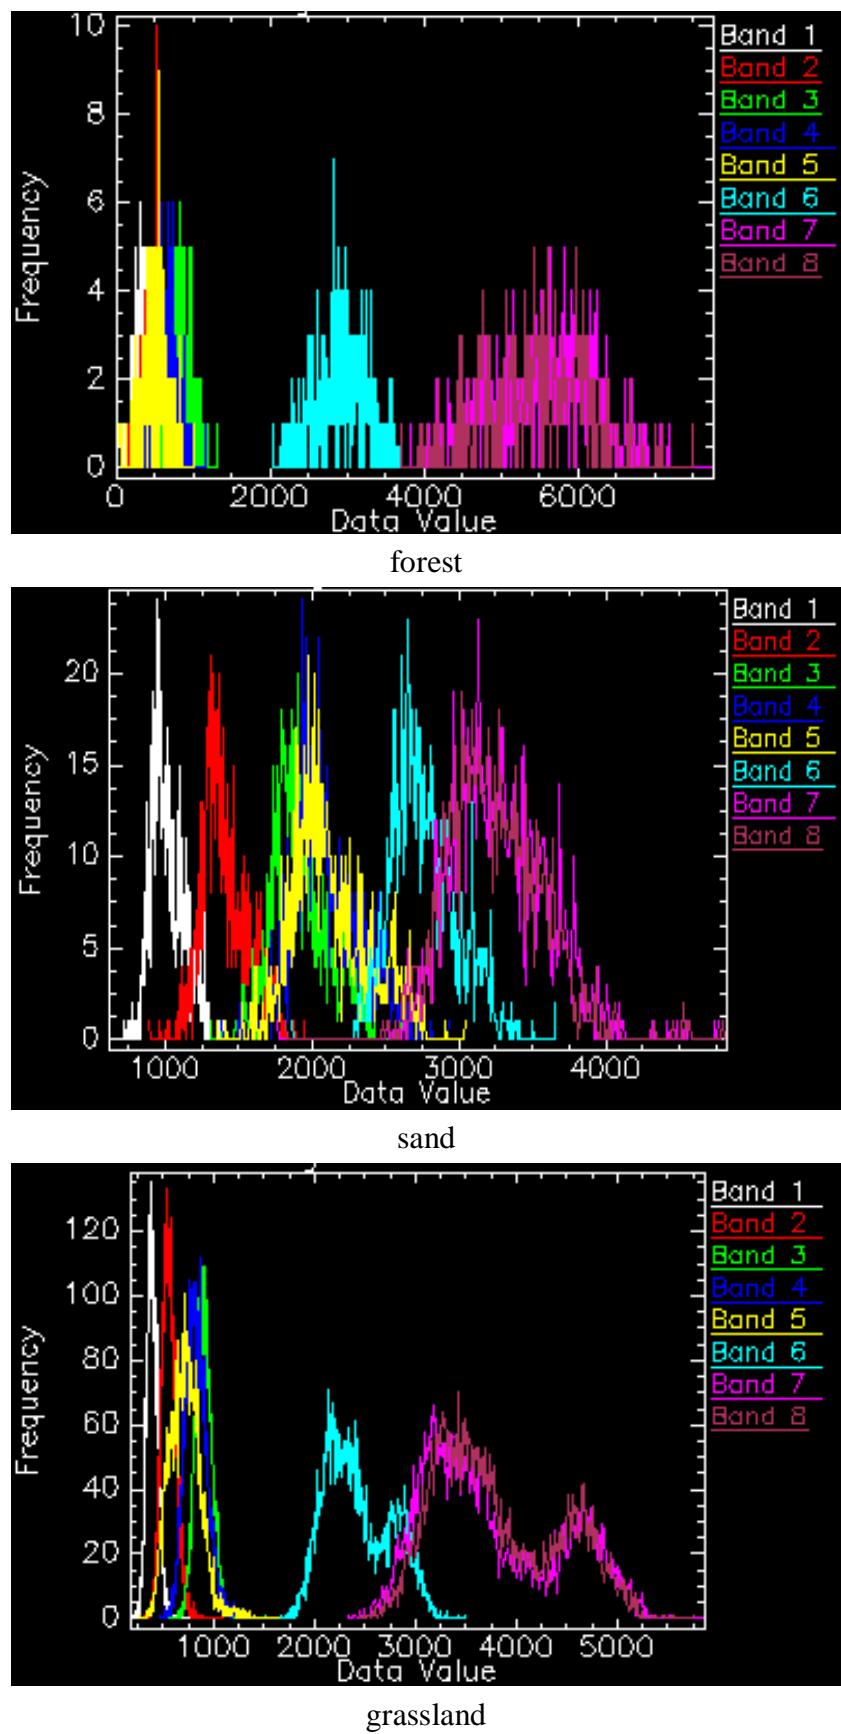


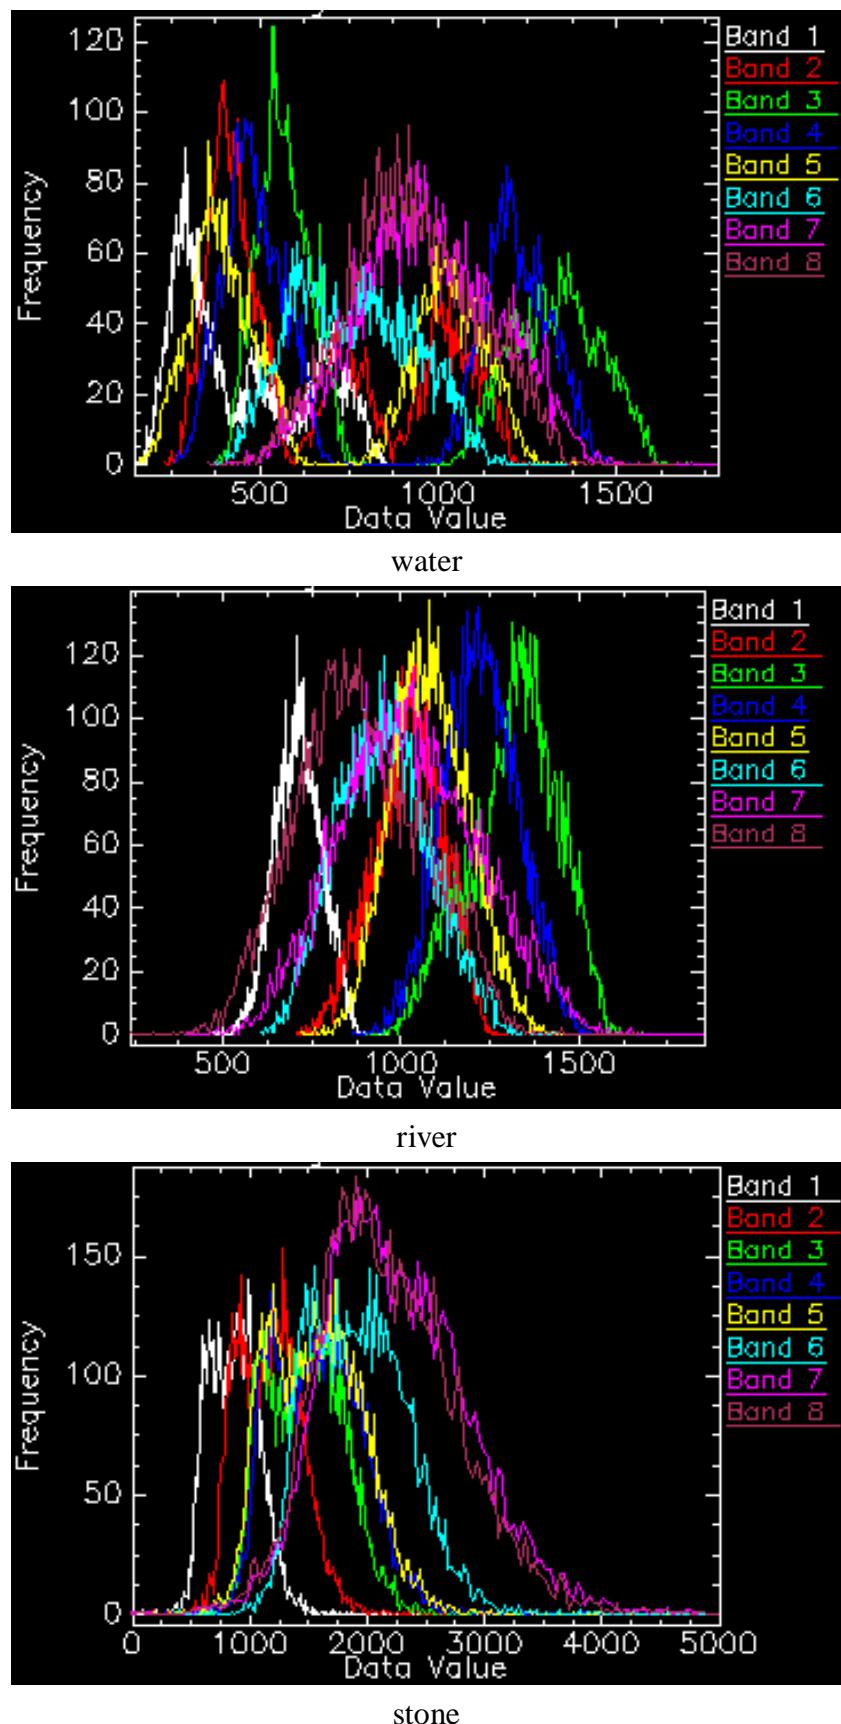
forest	200930.73	2540698.55
forest	200531.73	2540058.05
forest	203844.73	2539961.55
farm	203377.73	2542273.55
farm	202879.23	2542233.05
farm	203698.23	2542210.55
farm	202873.23	2542209.05
farm	203912.23	2542146.05
farm	203057.73	2542129.05
farm	203225.23	2542007.05
farm	203336.23	2542004.55
farm	203577.23	2541808.55
farm	202655.73	2541620.05
farm	202046.23	2541584.05
farm	202816.23	2541565.55
farm	202886.23	2541537.55
farm	202595.73	2541283.05
farm	202933.23	2541230.55
farm	201891.73	2541158.05
farm	202341.23	2540839.55
farm	202820.23	2540636.55
farm	203836.23	2540179.05
farm	200145.73	2540007.55
bareland	202659.73	2542279.55
bareland	201263.23	2541323.55
bareland	200343.73	2541318.55
bareland	203772.23	2541004.55
bareland	200588.23	2540974.55
bareland	203351.23	2540900.05
bareland	202693.23	2540633.05

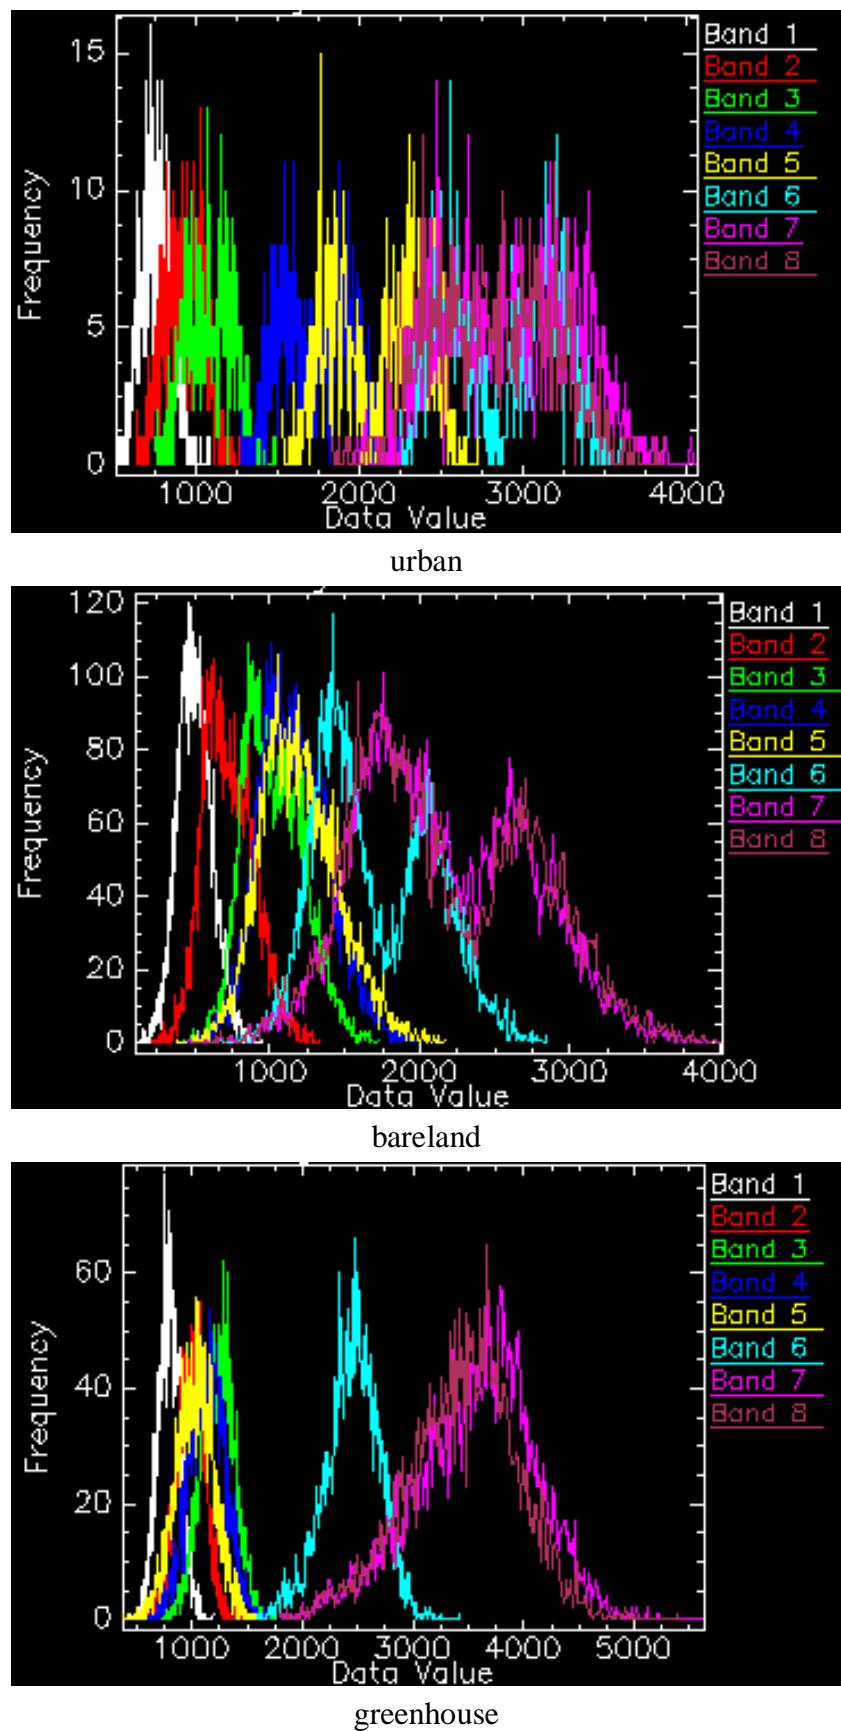


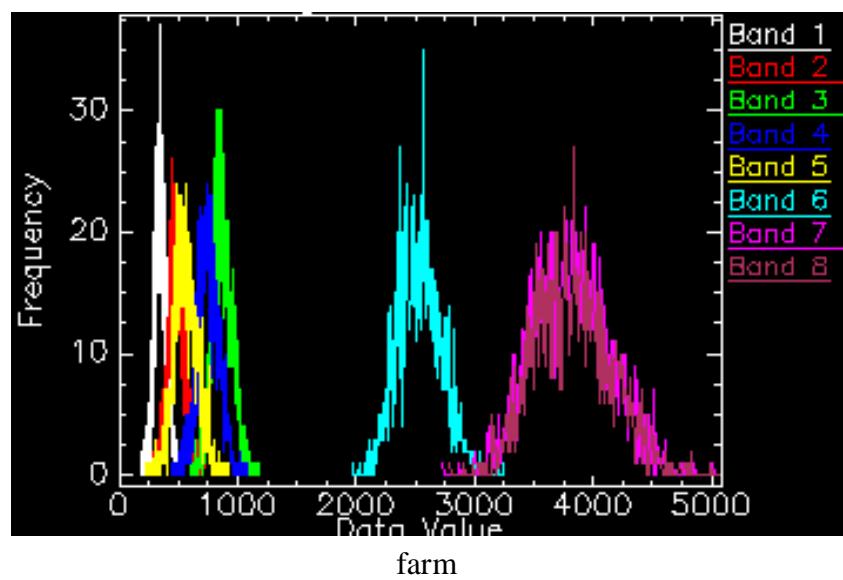


附錄 2 土地被覆型訓練樣區各類別各波段直方圖表











附錄 3 野外林型勘查作業成果

樣區	位置	勘查結果	照片
針闊葉(一)	地點：嘉義中埔 座標：208807, 2587412	樣點附近僅見闊葉林及檳榔樹，未發現針葉樹。	
針、闊葉(二)	地點：台南南化、高雄甲仙交界 座標：205361, 2552172	位於廟宇後方之山坡地上，可見闊葉樹及稀疏針葉樹	
針、闊葉(三)	位置：南投埔里 座標：245500, 2640827	可見密集針葉樹及闊葉樹	
針葉(一)	地點：嘉義中埔 座標：209672, 2589765	颱風導致道路坍方故無法進入拍攝，因此以其他地區的針葉林代替。	



針葉(二)	地點：嘉義中埔 座標：209408, 2590242	位於檳榔園邊界可見密集針葉樹林	
針葉(三)	地點：高雄甲仙 座標：206867, 2554976	位於坍塌林道旁可見針葉樹林	
針葉(四)	地點：埔里 座標：247141, 2642685	位於滯洪池左方	
竹林(一)	地點：台南南化、高雄 甲仙交界 座標：205525, 2551644	樣點位於道路旁的下坡面	
竹林(二)	地點：高雄甲仙 座標：206890, 2547838	位於產業道路周邊	



竹林(三)	地點：南投埔里 座標：247076, 2642614	位於九族文化村周邊	
竹、針、闊葉(一)	地點：台南南化、高雄甲仙交界 座標：204975, 2550716	位於台 21 線旁的半山腰上，僅可見竹濶混合林。	
竹、針、闊葉(二)	地點：南投埔里 座標：243318, 2642885	位於私人檳榔園之後山，大多為竹林，僅少數針、闊葉樹。	
竹、闊葉(一)	地點：台南南化、高雄甲仙交界，座標：204411, 2552397	位於南化水庫旁的山坡上	
竹、闊葉(二)	地點：高雄甲仙 座標：209551, 2554188	位於道路旁	



竹、闊葉(三)	地點：埔里 座標：247126,2640334	位於檳榔園後方的山丘上，有家犬看守故僅遠拍竹闊混林狀況。	
闊葉(一)	地點：台南南化、高雄甲仙交界 座標：206464,2552325	私人土地中，故僅由遠方拍攝樣點所在位置。	
闊葉(二)	地點：台南南化、高雄甲仙交界 座標：206941,2553392	樣點位於下方山坡，周遭有緊急處理工程，可俯視甲仙大橋。	
闊葉(三)	地點：南投埔里 座標：247029,2643040	位於產業道路旁。	
竹、針葉(一)	地點：南投埔里 座標：245403,2642217	位於道路旁邊，接近民宅。	

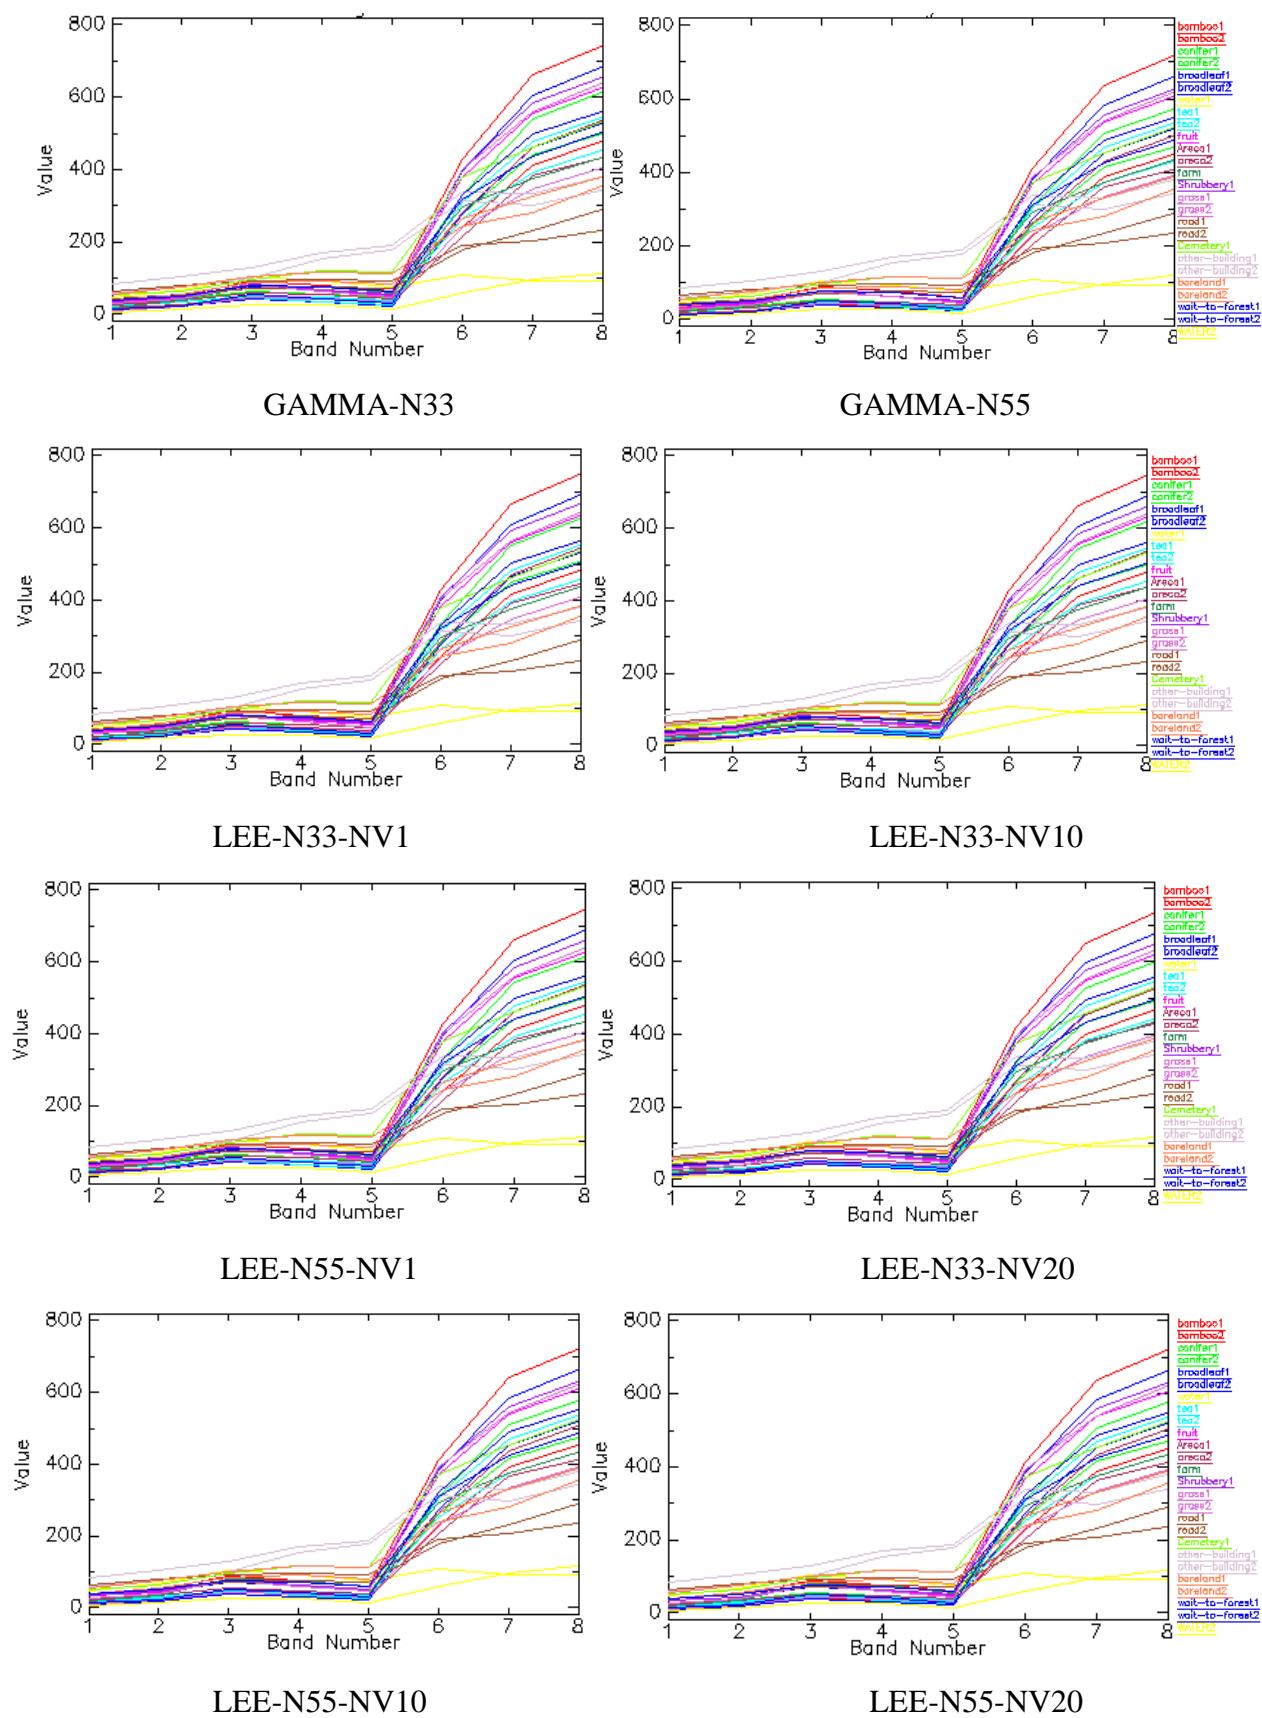


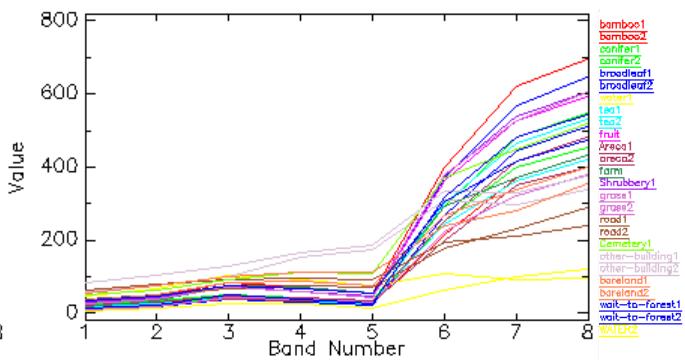
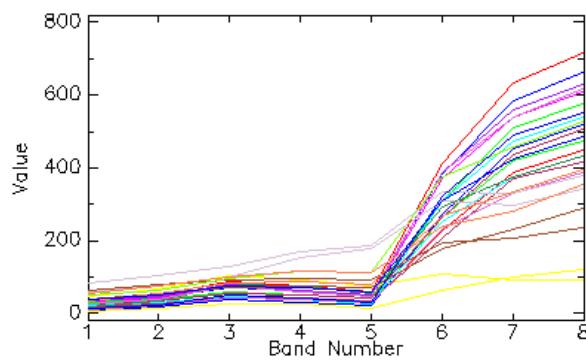
竹、針葉(一)	地點：埔里， 座標：250716,2642553	多數為針葉樹，竹類少數。	
竹、針葉(三)	地點：埔里 座標：258961,2647043	前排為竹林後方少數針葉樹。	





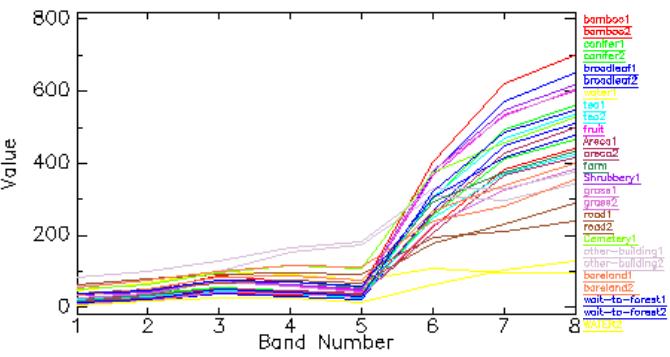
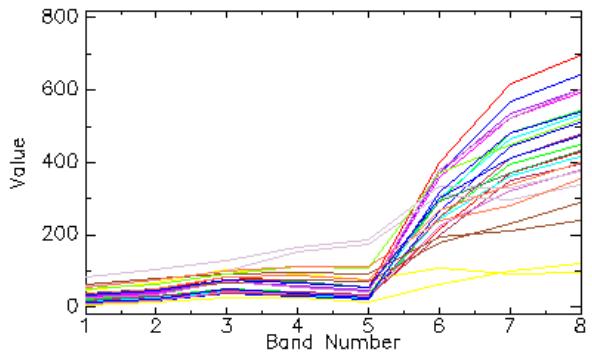
附錄 4 林型分類不同濾波器設定之光譜值





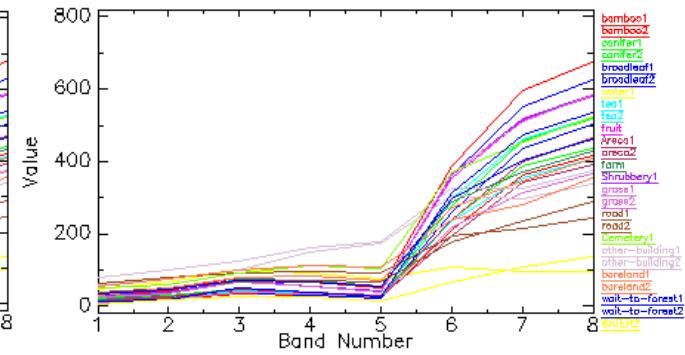
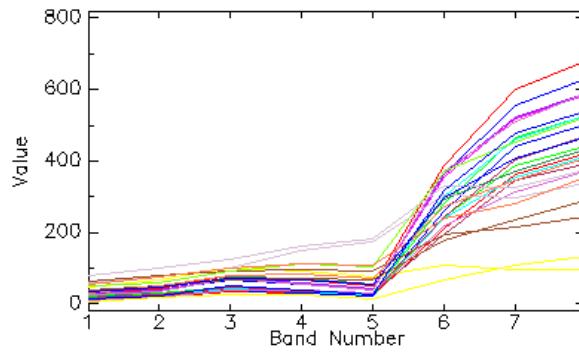
LEE-N77-NV1

LEE-N77-NV10



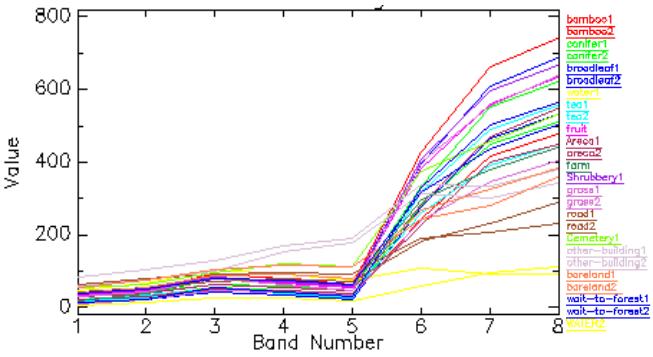
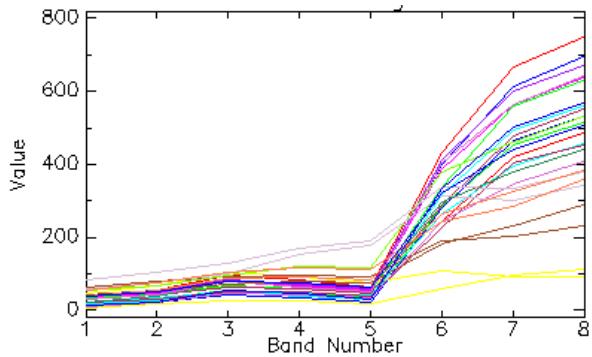
LEE-N77-NV20

LEE-N99-NV1



LEE-N99-NV10

LEE-N99-NV20



LOCAL-SIGMA-N55

LOCAL-SIGMA-N77





附錄 5 林型分類下不同濾波器處理之分離度

Gamma 3*3

	bamboo1	bamboo2	conifer1	conifer2	broadleaf1	broadleaf2	water1	tea1	tea2	furn1	Areca1	areca2	farm	Shrubbery1	grass1	grass2	road1	road2	Cemetery1	building1
bamboo1		1999	1982	1998	1878	1999	2000	2000	2000	1977	1999	2000	2000	1999	1999	2000	2000	2000	2000	2000
bamboo2	1999		1999	1807	1999	1890	2000	2000	2000	1999	1759	1965	2000	1999	2000	2000	2000	2000	2000	2000
conifer1	1982	1999		1970	1641	1986	2000	1999	2000	1888	1961	1999	2000	1999	1999	2000	2000	2000	2000	2000
conifer2	1998	1807	1970		1996	1884	2000	1999	2000	1992	1915	1999	2000	1999	1999	2000	2000	2000	2000	2000
broadleaf1	1878	1999	1641	1996		1999	2000	1999	2000	1368	1994	2000	2000	1958	1998	2000	2000	2000	2000	2000
broadleaf2	1999	1890	1986	1884	1999		2000	1999	2000	1999	1918	1999	2000	2000	1999	1999	2000	2000	2000	2000
water1	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
tea1	2000	2000	1999	1999	1999	1999		2000	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
tea2	2000	2000	2000	2000	2000	2000		1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
furn1	1977	1999	1888	1992	1368	1999	2000	2000	2000		1999	2000	2000	1766	1968	2000	2000	2000	2000	2000
Areca1	1999	1759	1961	1915	1994	1919	2000	2000	2000	1999		1995	2000	1999	1999	2000	2000	2000	2000	2000
areca2	2000	1965	1999	1999	2000	1999	2000	2000	2000	2000	1995		2000	2000	2000	1999	2000	2000	2000	2000
farm	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000
Shrubbery1	1999	2000	1999	1999	1958	2000	2000	2000	2000	1766	1999	2000	2000		1998	2000	2000	2000	2000	2000
grass1	1999	1999	1999	1999	1998	1999	2000	2000	2000	1968	1999	2000	2000	1998		2000	2000	2000	2000	2000
grass2	2000	2000	2000	1999	2000	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000
road1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
road2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
Cemetery1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	1934
bareland1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
bareland2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
wait-to-forest1	1994	1999	1987	1996	1854	1999	2000	2000	2000	1894	1999	2000	1992	1999	2000	1999	2000	2000	2000	2000
wait-to-forest2	2000	1999	1999	1999	1998	2000	2000	2000	2000	1999	1999	2000	2000	1999	2000	2000	2000	2000	2000	2000
shadow1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
shadow2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
water2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000

Gamma 5*5

	bamboo1	bamboo2	conifer1	conifer2	broadleaf1	broadleaf2	water1	tea1	tea2	furn1	Areca1	areca2	farm	Shrubbery1	grass1	grass2	road1	road2	Cemetery1	building1
bamboo1		1999	1992	1999	1894	1999	2000	2000	2000	1987	1999	2000	2000	1999	1999	2000	2000	2000	2000	2000
bamboo2	1999		1999	1865	1999	1944	2000	2000	2000	1999	1869	1985	2000	2000	2000	2000	2000	2000	2000	2000
conifer1	1992	1999		1983	1823	1998	2000	1999	2000	1960	1988	2000	2000	1999	1999	2000	2000	2000	2000	2000
conifer2	1999	1865	1983		1999	1956	2000	1999	2000	1999	1948	1999	2000	1999	1999	2000	2000	2000	2000	2000
broadleaf1	1894	1999	1823	1999		1999	2000	2000	2000	1999	1940	1999	2000	1975	1999	2000	2000	2000	2000	2000
broadleaf2	1999	1944	1998	1956	1999		2000	2000	2000	1999	1971	1999	2000	1999	1999	2000	2000	2000	2000	2000
water1	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
tea1	2000	2000	1999	1999	2000	2000		2000	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
tea2	2000	2000	2000	2000	2000	2000		1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
furn1	1987	1999	1960	1999	1490	1999	2000	2000	2000		1999	2000	2000	1797	1982	2000	2000	2000	2000	2000
Areca1	1999	1869	1988	1948	1999	1971	2000	2000	2000	1999		2000	2000	2000	2000	2000	2000	2000	2000	2000
areca2	2000	1985	2000	1999	2000	1999	2000	2000	2000	2000	1998		2000	2000	2000	2000	2000	2000	2000	2000
farm	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000
Shrubbery1	1999	2000	1999	1999	1975	2000	2000	2000	2000	1797	2000	2000	2000		1999	2000	2000	2000	2000	2000
grass1	1999	2000	1999	1999	1999	2000	2000	2000	2000	1982	2000	2000	2000	1999		2000	2000	2000	2000	2000
grass2	2000	2000	2000	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
road1	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
road2	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
Cemetery1	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building1	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building2	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	1974
bareland1	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
bareland2	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
wait-to-forest1	1998	1999	1998	1999	1907	1999	2000	2000	2000	1936	1999	2000	1998	1999	2000	1999	2000	2000	2000	2000
wait-to-forest2	2000	1999	1999	1999	2000	1999	2000	2000	2000	2000	1999	2000	2000	2000	2000	1999				



Lee 3*3 NV1

Lee 3*3 NV10



Lee 3*3 NV20

Lee 5*5 NV1

Lee 5*5 NV10

	bamboo1	bamboo2	conifer1	conifer2	broadleaf1	broadleaf2	water1	tea1	tea2	furi1	Areca1	areca2	farm2	shrubbery	grass1	grass2	road1	road2	cemetery1	building1	
bamboo1		2000	1994	1999	1893	1999	2000	2000	2000	1985	1999	2000	2000	1999	1999	2000	2000	2000	2000	2000	
bamboo2	2000		1999	1843	1999	1935	2000	2000	2000	1999	1866	1981	2000	2000	2000	2000	2000	2000	2000	2000	
conifer1	1994	1999		1985	1783	1998	2000	1999	2000	1956	1989	2000	2000	1999	1999	2000	2000	2000	2000	2000	
conifer2	1999	1843	1985		1999	1952	2000	1999	2000	1999	1950	1999	2000	1999	1999	1999	2000	2000	2000	2000	
broadleaf1	1893	1999	1783	1999		1999	2000	2000	2000	1459	1999	2000	2000	1977	1999	2000	2000	2000	2000	2000	
broadleaf2	1999	1935	1998	1952	1999		2000	2000	2000	1999	1975	1999	2000	2000	1999	1999	2000	2000	2000	2000	
water1	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	
tea1	2000	2000	1999	1999	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	
tea2	2000	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	
furi1	1985	1999	1956	1999	1459	1999	2000	2000	2000		1999	2000	2000	2000	1815	1986	2000	2000	2000	2000	2000
Areca1	1999	1866	1989	1950	1999	1975	2000	2000	2000	1999		1998	2000	1999	2000	2000	2000	2000	2000	2000	2000
areca2	2000	1981	2000	1999	2000	1999	2000	2000	2000	2000	1998		2000	2000	2000	2000	2000	2000	2000	2000	2000
farm2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000
shrubbery1	1999	2000	1999	1999	1977	2000	2000	2000	2000	1815	1999	2000	2000		1999	2000	2000	2000	2000	2000	2000
grass1	1999	2000	1999	1999	1999	1999	2000	2000	2000	1986	2000	2000	2000	1999		2000	2000	2000	2000	2000	2000
grass2	2000	2000	1999	2000	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
road1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
road2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
cemetery1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
bareland1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
bareland2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
wait-to-forest1	1998	1999	1997	1999	1901	1999	2000	2000	2000	1938	1999	1999	2000	1998	1999	2000	1999	2000	2000	2000	2000
wait-to-forest2	2000	1999	1999	1999	2000	1999	2000	2000	2000	2000	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
shadow1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
shadow2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
water2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000

Lee 5*5 NV20

	bamboo1	bamboo2	conifer1	conifer2	broadleaf1	broadleaf2	water1	tea1	tea2	furi1	Areca1	areca2	farm2	shrubbery	grass1	grass2	road1	road2	cemetery1	building1	
bamboo1		2000	1993	1999	1891	1999	2000	2000	2000	1988	1999	2000	2000	1999	1999	2000	2000	2000	2000	2000	
bamboo2	2000		1999	1861	1999	1948	2000	2000	2000	1999	1898	1987	2000	2000	2000	2000	2000	2000	2000	2000	
conifer1	1993	1999		1981	1803	1999	2000	2000	2000	1958	1990	2000	2000	1999	1999	2000	2000	2000	2000	2000	
conifer2	1999	1861	1981		1999	1951	2000	2000	2000	1999	1954	1999	2000	1999	1999	2000	2000	2000	2000	2000	
broadleaf1	1891	1999	1803	1999		1999	2000	2000	2000	1999	1941	1999	2000	1983	1999	2000	2000	2000	2000	2000	
broadleaf2	1999	1948	1999	1951	1999		2000	2000	2000	1999	1977	1999	2000	2000	1999	2000	2000	2000	2000	2000	
water1	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	
tea1	2000	2000	1999	1999	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	
tea2	2000	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	
furi1	1988	1999	1958	1999	1491	1999	2000	2000	2000		1999	2000	2000	1840	1899	2000	2000	2000	2000	2000	2000
Areca1	1999	1898	1990	1954	1999	1977	2000	2000	2000	1999		1999	2000	2000	2000	2000	2000	2000	2000	2000	2000
areca2	2000	1987	2000	1999	2000	1999	2000	2000	2000	1999		2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
farm2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000	2000	2000	2000
shrubbery1	1999	2000	1999	1999	1983	2000	2000	2000	2000	1840	2000	2000		1999	2000	2000	2000	2000	2000	2000	2000
grass1	1999	2000	1999	1999	1999	1999	2000	2000	2000	1899	2000	2000	2000		1999	2000	2000	2000	2000	2000	2000
grass2	2000	2000	1999	1999	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000		2000	2000	2000	2000	2000	2000
road1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
road2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
cemetery1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
building2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
bareland1	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
bareland2	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000	2000
wait-to-fore1	1998	1999	1997																		



Lee 7*7 NV1

Lee 7*7 NV10



Lee 7*7 NV20

Lee 9*9 NV1



Lee 9*9 NV10

Lee 9*9 NV20



Local sigma 5*5

Local sigma 7*7



期初報告審查意見答覆

委員意見	答覆
建議可測試利用 WV2 影像之 coastal 波段區分溼地。	研究目標為土地被覆型及林型分類，濕地為土地被覆型之一，本研究同時考量所有類別的分類效能，使用 WV2 的可能資訊。依據研究結果顯示：coastal 影像對於此六大類土地被覆型並不是理想的光譜特徵。
因 WV2 具有 8 個波段，建議慎選 pan-sharpening 的方法，若直接以多光譜影像來分析，仍需提出不同 pan-sharpening 方法對於 8 個波段波譜影響之分析結果，供本所參考。	已完成評估。
建議於研究過程中，測試 object-based image analysis 方法分類 feature 的各種參數設定，可供所內參考使用。	請參考問題 8
建議挑選時間較接近之地真資料與研究影像，以免造成分類準確度之誤差。	影像資料為 2012 年，非常接近林務局提供的第四次資源調查時間(近三年完成的資料)。
因目前 IPCC 土地被覆型之溼地的定義仍有爭議，請特別敘明本研究溼地的定義。	本研究濕地包含內陸型及河川型濕地。
建議於本計畫之 IPCC 土地被覆型或第四次森林資源調查林型分類準確度應視影像分析情形而定，或可利用本研究來訂定 WV2 土地被覆型及林型分類之準確度。	將依據研究結果提出建議值。
請說明本研究之 object-based image analysis 評估方法為何？	利用像元為基礎。
請說明於 object-based image analysis 之步驟中之 scale parameter 如何設定。	依據嘗試錯誤法學習認知 scale parameter 設定對於分類的影響。SP 值越小，影像將被切割為非常細碎的物件，我們發現對於土地被覆型分類而言，SP 值以 500 較為適當，其中光譜特徵(color criterion)及形狀特徵(shape criterion)的權重各為 0.9 及 0.1，compactness 及 smoothness criteria 對土地被覆型物件分割與分類沒有明顯的影響。
請說明本研究使用之影像分析及處理軟體為何？	ENVI 及 eCognition
請問期初報告書 p5 之研究區域總面積為何？	影像大小為 2263x1266 像元，約 11.46 km ²
請統一報告中之專有名詞，如 pan-sharpening 及 object-based image analysis。	pan-sharpening 譯為全色態銳化，object-based image analysis 譯為物件基礎





	的影像分類。
請彙整國內外前人研究，並整理參考文獻，但國外影像分類文獻之研究方法不一定適用於臺灣地形，建請參酌。	謝謝建議。
請修正報告中影像分類研究流程，以免誤導讀者將土地被覆型型及林型分類視為 2 個不同的研究方向。	土地被覆型與林型分類基本上為影像分類，核心的研究概念基本上是一致的，均以地類製圖為標的。我們將依據土地被覆型分類結果，導出適當的分類機制，做為林型分類的基準，以避免浪費人力及時間。
報告書中 p6(8)提及 20 個地面樣點，其數量及分佈為何？是否與報告書設定之訓練樣區或評估樣區相同？	報告書所設定的 20 個樣區數量為林型分類的檢核樣區。我們將依據第四次資源調查的林型分佈資料，分層取樣，將 20 個檢核樣區平均分佈於各類林型。
請修正 p6(8)之文字敘述，並詳述本研究之實施方法及流程。	已修正。
請修正計畫預定進度表，納入現場調查之時程。	已規劃預定於 8 月中旬之前完成地面調查樣點的林型調查作業。
請修正第四次森林資源調查之林型項目，其項目為針葉樹林、闊葉樹林、針闊葉樹混淆林、竹林、竹闊混淆林、竹針混淆林、竹針闊混淆林共 7 項。	已修正。建議請農航所提供的第四次資源調查的地面樣區調查資料以及較高解析的 DEM 資料，以供林型分類研究之應用。





期中報告意見審查答覆

委員意見	答覆
因目前研究選取之影像大部份為農田及開發區域，建議後續選取研究影像時，應以涵蓋大部份林地分類項目之區域為主，以符合合約規範（森林資源調查林型分類及準確度評估二式）。	於林型分類部份已從新選取適合的樣區。
請詳細敘述本研究進行大氣校正之必要性。	因為兩張影像為不同時期之影像，透過大氣校正使其有相同基礎的反射率
建議可以探討進行大氣校正後對影像 NDVI 的變異及平均值落點之影響，對後續分析上會有很大的幫助。	感謝委員提供意見。但此意見內容不在此次研究計畫內容中。故無於期末報告中加入此部分。
請說明 ENVI 之 FLASSH 模組中 3 階段參數如何設定？並請提供參數設定之建議。	參數設定皆依據影像取得的各項數值進行設定，於報告中已有詳述。
請說明研究區域之影像是否有做地形校正。	所取得之 WV2 影像已經為標準化之影像，因此無須再進行地形校正。
本研究方法是先做影像融合再提升其解析度，與其他前人研究之方式相異，請提出支持本研究方法之參考文獻或相關研究數據或結果。	影像融合以及提升其解析度是屬於同一個動作，影像融合係將低解析度影像融合為高解析度(提升解析度)
因不同 pan-sharpening 方法，其取樣的數量及方式皆不一樣，請詳述本研究中，訓練樣區（訓練像元）及檢核樣區（檢核像元）之取樣方式、數量及分佈。	由於影像中各分類型的分布範圍及數量不一致，因此以人為判釋進行訓練樣區選取，具以確保各分類型皆有一定數量之樣區。 檢核樣區則以隨機取樣方式取 100 個樣點，並以樣點為核心擴大為 19*19 的小區域樣區。
目前大部份研究皆使用 correlation 來探討各處理對光譜間的差異，請說明本計畫使用 RMSE 而不使用 correlation 之原因。	RMSE 也是一種評估錯誤量的方式，且於國外也有學者使用此方式來評估，祥如參考文獻 Wald et al.,1997; Ranchin and Wald, 2000 ; Du et al., 2007.
P25 表 9~11 結果顯示未全色態銳化之原始影像分類準確度較其他處理為佳，試說明本研究利用 SVM 分類方法進行後續研究之原因。	因為解析度的提升，會使得影像中異譜或同譜異質等不確定性問題大幅增加，導致訓練樣區選取的困難度增加及分類後椒鹽效應。 物件分類的優點在於依據物體的色彩、紋理、形狀來進行描述，之後分別對各區塊給予適當形式的表示和描述再根據區塊特性進行分類，因此空間解析度高之影像反而適合使用物件分類。
若 SVM 為較佳之分類方法，建議可以於	本研究以過往研究所得較佳的 RBF 作為核心





SVM 分類方法中針對不同 kernel function 進行測試。	參數，以提升作業效率。
請說明利用 SVM 及 KNN 分類之 object feature 設定為何，是否有加入 shape、index、NDVI 或 texture 等參數設定，請分別詳述之。	將於教育訓練時教學
請說明為何分類成果中無”unclassified”之類別的原因。	在分類時有強迫分類，故無此類別
建議本計畫可嘗試解決 SPOT 影像在土地被覆型分類的問題。	感謝委員提供意見。但此意見內容與使用材料均不在此次研究計畫內容中。故無於期末報告中加入此部分。
地面調查資料之精度可能會與影像分類之精度有所差異，於檢核比對時請多加留意。	感謝委員所提供的建議，於野外地面調查時將更謹慎留意
因目前研究團隊之設備及軟體處理小區域的影像已相當吃力，試探討未來若需處理大面積影像之解決方式。	需透過小面積處理後再合併的方式來解決
目前研究使用多種影像處理軟體，請思考未來如何整合並於期末提供所內更方便之影像分類流程。	因無法使用單一軟體達成所有研究有關處理，且不同軟體有其各自不同的強項，因此才會利用不同軟體來執行各個不同階段的影像處理
以上委員建議，無論測試結果是否達預期，應列入報告書中，其結果及建議仍具研究之參考價值。	已訂正新增於修訂後期中報告
各縮寫於第一次出現時請寫全名（包含摘要）。	已訂正
請敘明研究影像拍攝時間，並註明所使用之軟硬體設備及各步驟所需之處理時間。	已訂正新增於修訂後期中報告
請於報告中詳述研究方法及細節，包括所使用之波段、各演算法公式及參考文獻，並統一各階段研究成果之比例尺、圖例及名詞（如：大氣校正）。	已訂正
請將報告書中之內文修正為目前慣用之專有名詞及用法，如 p12(3)先進基礎地理信息全色態銳化法。	已訂正
請將結果討論之內容與研究結果之圖表做相對應連結及註記，以方便讀者閱讀。	已訂正
請研究團隊日後之報告書及簡報列入委員意見回覆。	已加入於修正後期中報告書





工作會議審查委員意見答覆

委員意見	答覆
建議先匯整國內外前人研究，並整理參考文獻，利用目前可行且普遍使用之方法來分析，應可縮短測試的時間。	感謝委員建議，已增加參考文獻。
建議研究方法需系統化，自建立分類體系開始至最後評估樣本及準確度分析等基本步驟，皆需於報告書完整敘明。	已建立系統化分類方式，在逐步將無法分類的類別合併。
建議訓練樣本及檢核樣本可以交叉選取，以利後續檢核比對，並在報告中完整敘明所選取樣本之像元數、位置分佈及座標等基本資訊。	感謝委員的建議，已附上樣區選取位置圖。
建議影像分類時使用階層式分類法(hierarchical classification)，先分出 IPCC 六類後，再以前述林地分類像墓區分出森林資源調查之 7 種林型。	感謝委員提供意見，在此報告中我們是已先分類出各最底層類別，再將會混淆之類別合併。
建議先分析各分類項目之光譜特徵或不同排列組合波段之光譜特徵(不需將所有波段納入分析)，若分類項目之光譜特徵標準差重疊者，應可剔除部分無法區分之項目。	感謝委員建議。
利用物件為基礎之影像分析時，建議可加入紋理指標可得到較好分類成果。	感謝委員建議。
請敘明野外調查之目的為何，並說明若野外調查之實際林型與第四次森林資源調查結果衝突時應如何解決。	若野外調查與第四次森林資源調查結果有衝突時，已目前最新調查的地真資料為優先。
希望研究團隊盡可能測試林型分類，若可將某幾類項目增加分類準確度，將對遙測的應用有很大的幫助，並請於期末報告探討 WV2 影像分析土地被覆型、林型及自動化分類之可行性。	已於期末報告內補充。
請參考 SPOT-2 緑蔽率計畫報告，其 IPCC 分類準確度已達 85% 以上，建議本計畫可利用 WV2 高解析度影像，可嘗試解決 SPOT-2 影像在土地被覆型分類無法解決之問題。	感謝委員提供意見。但此意見內容與使用材料均不在此次研究計畫內容中。故無於期末報告中加入此部分。
建議修正工作會議之簡報順序及補充說明投影片內容。	已補充及訂正簡報順序。





期末報告意見審查答覆

委員意見	答覆
請修正報告書摘要、前言及結論，使研究目的、研究方法、結果及結論相互呼應。	以重新撰寫及調整文章內容以符合前後呼應原則。
請修正 p3 表 1 之文字段落。	已修正
請更新報告書中縣市界圖層及統一比例尺單位。	已修正並更新圖層
請於報告書中彙整近期 WV2 影像應用於林型分類之相關文獻	已修正於前言中
請於報告書中詳述研究方法、理論基礎及分析結果，並適當加入參考文獻，如溼地、濾波方法等段落，並註明每一個研究階段使用影像之波段及檢核的地真資料來源。	已修正
請修正簡報中之流程圖，並將報告書之流程圖修正為一般慣用的圖形。	已修正流程圖
因地真資料獲取之時間及空間尺度與 WV2 影像拍攝時間有差異，建議先分析選取樣區之光譜變異度，若其光譜差異大，表示在分類上容易混淆，其樣區則不適合繼續做分析。	由光譜分離度試驗可知所選取的各分類型樣區皆可有效地進行分離，因此並不易產生混淆現象。
請於報告書中詳細記錄研究團隊利用不同 kernel function 測試之結果，並補充支持目前研究方法的原因及理論基礎。	已補充，同時根據過往研究結果顯示以 RBF 進行 OB-SVM 分類的結果較其他 kernel function 為佳，因此本研究直接以此進行分類。
建議利用不同光譜銳化法於各波段之 RMSE 可改計算為 correlation，可較易觀察出每個波段之變化。	已新增 correlation 已分析轉換前後波段的變化量。
表 4 物件導向屬性設定，建議可以整理出對分類較有幫助的項目。	本研究所列出的物件導向屬性皆使用在研究當中。
請確認並統一引用公式及符號、專有名詞及參考文獻，並重新檢視各理論之引用敘述，如之 MLC 方法之引用文獻、shape 屬性配合…才具有意義、huges 之敘述、原始影像的像素大解析度低且雜訊多之敘述。	已修正
請更正圖 7 影像處理前後光譜比較（右圖），y 軸 reflectance 數值應介於 0~1 之間。	由於 reflectance 的數值小不易表現，因此在本研究終將其數值乘上 10000 倍以增加數值辨識度。
第四次森林資源調查之林型分類為 7 種類別，本報告僅涵蓋到 3 種，請補上其他林型之分類結果。	已修正其他混淆林的分類結果。





請於報告書中敘明為何研究材料需要裁切成 400m * 400m，並說明如何解決裁切後的影像光線等條件差異大的問題及如何應用於原始未裁切之衛星影像上。	由於影像圖幅範圍相當大，因此就地真資料依所需林型進行切割，減少分類所耗費的時間。此外由於影像來源時間不同使得相同分類型具有不同光譜特徵，因此同一林型皆選取不同地區之影像以減少誤判的機率。WV2 包含的資料訊息相當龐大，因此不建議以原始影像直接進行分類。
於林型分類中，因闊葉樹及針葉樹之紋理不同，建議可設定較大尺度來測試。	在研究過程中有針對此一情況進行不同切割尺度的測試，但至計畫截止日仍無法產出具可信度之分類結果。
請修正林型判釋標準作業流程之表達方式。	已修正
請於結論敘明 WV2 影像對於林業應用之可行性，另因本計畫影像解析度較 SPOT 影像高，試探討利用本計畫解決 SPOT 影像在土地利用型分類的問題或給予未來研究之建議。	WV2 影像在林業上之優勢在於高空間解析度，因此若能建立有效分類的流程，則對資源調查的準確度明顯會較 SPOT 影像為高。
請重新檢視參考文獻之引用方式及參考文獻之格式。	已修正
請修正先前會議紀錄回覆，並將依委員建議修正的部份整理到報告書中。	已修正

