

監督式機器學習於土地覆蓋分類效益之研究

范慶龍*

論文收件日期：109年09月29日
論文修稿日期：110年02月01日
論文接受日期：110年03月31日

摘 要

無人飛行載具 (Unmanned Aerial Vehicles, UAV) 之遙測影像相較於衛星影像有快速、機動取得地表資訊之能力，並具有低成本、高空間與時間之解析度，以及影像資料較不受雲霧干擾之特性，已廣泛地運用在小區域之監測與調查作業。本研究運用UAV高效率的遙測取像方式，並結合支持向量機 (Support vector machine, SVM)、最大概似法 (Maximum likelihood, ML) 及隨機森林 (Random forest, RF) 三種監督式機器學習方法實施地表特徵樣本訓練及測試，再評估五種土地覆蓋 (樹木、草地、裸露地、建築物及道路) 之分類效益。旨在比較和找到最合適的分類器，以有效率地用於UAV影像之土地覆蓋分類。在鄉村地區研究結果顯示SVM的分類準確率為88%、曲線下面積 (Area under the curve, AUC) 為0.88、Kappa值為0.83及Gain為96.8% (前50%測試集)，其綜合評估的分類效益最佳。另外，選擇地物較複雜的都市地區進行測試，SVM的分類準確率為85.4%，也是三種分類器中最佳的，尤其對於道路能正確地預測 (分類)。本研究所使用之機器學習是基於RGB做出預測，無論是在鄉村或都市地區的土地覆蓋分類均有良好的成果，且三種監督式機器學習 (分類器) 準確率都大於78.6%以上。整體而言，三種分類器能清楚區分各種土地特徵的差異，並分析人為 (building、road) 與自然 (tree、grassland、land) 的不同光譜組成與特性，且正確的執行土地覆蓋分類。

關鍵詞：土地覆蓋、分類、無人飛行載具、監督式機器學習

* 助理教授，陸軍軍官學校土木工程學系，TEL：(07)7456290#205，E-mail：p93228001@ntu.edu.tw。

Research on the Benefits of Supervised Machine Learning in Land Cover Classification

Ching-Lung Fan*

ABSTRACT

Compared with that realized through satellites, remote sensing images conducted using unmanned aerial vehicles (UAV) can yield land surface information more promptly and flexibly. Moreover, this sensing involves a low cost and has a high spatial and temporal resolution. In addition, the obtained image data involve less interference pertaining to clouds and fog. UAVs have been widely used in small area monitoring and investigation operations. In this study, the high-efficiency remote sensing image method based on UAVs is adopted, and three supervised machine learning methods, namely, support vector machine (SVM), maximum likelihood (ML), and random forest (RF), are combined to implement training and testing of the land surface feature samples. Subsequently, the classification benefits of five types of land cover (tree, grassland, land, building, and road) are evaluated to identify the most suitable classifier to be used for efficient land classification for the images obtained using the UAV. For the SVM in rural areas, the classification accuracy, an area under the curve (AUC), Kappa coefficient, and Gain are 88%, 0.88, 0.83, and 96.8% (first 50% of the test set), respectively. This classifier achieves the highest classification benefit. Next, a city area with more complex features is selected for testing. The SVM classification accuracy is 85.4%, which is the maximum among the three classifiers. In particular, the SVM classifier can accurately predict (classify) roads. The machine learning approach performs predictions based on RGB. Satisfactory land classification results are obtained both in rural and urban areas. The accuracy of all three supervised machine learning classifiers is greater than 78.6%. In general, all the classifiers can clearly distinguish the land features, analyze the different spectral compositions and characteristics of artificial (building and road) and natural (tree, grassland, and land), and accurately perform land cover classification.

Key words: Classification, Land cover, Unmanned aerial vehicles, Supervised machine learning

* Assistant professor, Department of Civil Engineering, the Republic of China Military Academy, TEL: +886-7-7456290#205, E-mail: p93228001@ntu.edu.tw.

一、前言

無人飛行載具 (Unmanned Aerial Vehicles, UAV) 是指在無駕駛人員的情況下操作輕型飛行器，配備觀察感測器 (observation sensor)，並結合各種地面控制系統 (Nex and Remondino, 2014)。根據飛行器的機翼形狀，UAV 可分為定翼型 (Fixed wing) 和旋翼式 (Rotary wing)。定翼 UAV 在航空攝影中具有相對較長的飛行時間和穩定性的優點。由於定翼 UAV 要有一定著陸區域或跑道的需求，難以在城市地區進行起飛與降落操作，雖然也有些定翼型 UAV 具有垂直起降或拋 (彈) 射起飛的功能，這意味著這種定翼型 UAV 的價格會比旋翼型 UAV 昂貴許多。由於旋翼 UAV 的操控性與飛行技術的進步，可以前後、左右、上下方向飛行及盤旋，並適合在都會區內垂直起降。它具有定點停滯遙測，不受航拍位置與角度的限制，即使在短的飛行時間內也能在特定點記錄近距離影像。另外，有些旋翼 UAV 能夠自主躲避障礙物之自動避障系統，以降低操作失誤所造成的各種意外事件。然而，旋翼型 UAV 缺點為電池容量限制，以致於航拍時間約 20~30 分鐘左右，較無法從事大範圍監測與空拍任務。

UAV 最初主要用於軍事用途之軍事目標的無人駕駛檢查、監視和偵察 (Rhee et al., 2018)。近來年，UAV 之研究與應用已在世界各國蓬勃發展，逐漸具備取代「人員駕駛航空器」從事特殊任務工作之條件，並且從軍事用途逐漸轉移至環境監測、農漁業應用及危險任務等民生範疇 (盧衍良等, 2012)。UAV 在科學研究與實務應用上也扮演重要角色，已經被廣泛運用於生態觀測 (Colomina and Molina, 2014)、森林調查 (Getzin et al., 2014)、農業勘災 (周巧盈等, 2018)、地形與地籍測繪 (邱式鴻等, 2014; Ramadhani et al., 2018)、洪水損害評估 (Anders et al., 2020)，以及陡坡監測 (Huang et al., 2017)。同時，UAV 的遙測加速了資料收集和監測任務 (Unger et al., 2014)。基於 UAV 的遙測技術在空間和時間解析度方面的提高，在小區域之動態變化監測與地物調查方面已經具有顯著的優勢。

由於 UAV 是近幾年才發展出來的新興空拍飛行器；因此，目前國內、外使用 UAV 遙測影像用於地物分類的研究案例相對較少，大部分仍以衛星影像資料為主 (黃韋凱等, 2010; Jensen et al., 2001; Suh et al., 2003)。此外，衛星影像分類通常以單一的地 (作) 物為研究之對象，例如：山崩的辨識 (鄒明城與孫志鴻, 2004)、崩塌地分析 (壽克堅等, 2010)、森林植生偵測 (王素芬等, 2014)、茶園的識別 (Chuang and Shiu, 2016)、道路的提取 (Riahi Bakhtiari et al., 2017)，以及屋頂形狀分類 (Castagno and Atkins, 2018) 等。從衛星影像中自動分類地物是

土地使用分析等應用的重要方式；然而，利用安裝在航空平台上的照相機，對大片土地表面進行直接遙感觀測，從而能夠及時和具有成本效益的模式繪製土地覆蓋（Sharma et al., 2017）。而UAV遙測取像方式可以提供便利的影像來源的另一種選擇。衛星影像通常擁有紅外光或近紅外光波段，與UAV主要以RGB影像的地物分類方式不同。由於地土覆蓋各種不同和複雜的地物，在進行多元分類需考量較多的因素，例如：地物種類、數量、範圍、形狀、紋理、色調及顏色等特性，才能夠有效地分析其光譜反映。有些特徵物的光譜性質相近，不易區分，導致誤判或分類錯誤機率高，相對於單一地物之分類準確率也較差，如何提升分類之準確率是多元分類技術要克服的重點之一。

遙測感測器之解析度與資料方便性的提升，同時配合分類理論的精進，應用衛星影像進行土地覆蓋分類作業技術已日趨成熟（陳承昌與史天元，2007）。然而，衛星遙測不能經常重訪同一個地區，以致於時間解析度較差（Anderson and Gaston, 2013; Suomalainen et al., 2014）。在空間解析度方面，Jensen et al.（2001）指出提取土地覆蓋資訊方面，通常需要相對較高的空間解析度資料，以進行數化處理。UAV影像基本上是超過衛星影像（Vetrivel et al., 2015）。空間解析度是關係分類細節和準確性的重要因素（Chen et al., 2004），並影響分類方法的選擇（Atkinson and Aplin, 2004）。Yao et al.（2019）認為UAV資料的明顯優點是空間解析度高，在採集和感測器整合方面具有靈活性，並且在電腦視覺和機器學習中開發的高級資料分析技術提高了UAV自動資料分析的能力。

Forsyth and Ponce（2011）指出電腦視覺技術應用多學科方法，包括：光學成像、影像處理、人工智慧和機器學習來獲取有意義的資訊，並從影像獲得高層次的理解。近幾年，已經開發出電腦視覺和機器學習的技術，應用在土地覆蓋之分類逐漸越來越普遍。因此，最近有一些研究者使用UAV遙測影像與機器學習演算法進行土地分類（Kalantar et al., 2017; Liu and Abd-Elrahman, 2018; Al-Najjar et al., 2019），以降低成本和提高準確率。此外，遙測資料的選擇要考量使用者的需求、研究區域的規模、經濟條件和分析師的技能（Lu and Weng, 2007）。對許多使用者而言衛星影像的取得並不容易，且影像資料的費用也不低廉，導致相關應用的推廣受到限制。為解決上述缺點，本研究運用UAV遙測取像的方式，以相對較佳的機動性與低成本、高空間與時間之解析度，以及影像資料較不受雲霧干擾（飛行高度低）之特性，作為本研究土地覆蓋分類的實驗，嘗試運用監督式機器學習進行五種地物之分類，訓練空間樣本與測試分類結果分析，以評估土地覆蓋之分類效益。

二、文獻探討

監督式影像分類的主要操作步驟，包括：確定合適的分類系統、訓練樣本（區）的選擇、影像預處理、分類方法的選定、特徵提取、分類後處理和效益評估。其中，選定適宜之分類方法，會直接影響到分類的結果。Lu and Weng（2007）認為在選擇使用的分類方法時，必須考慮許多因素，例如：遙測資料的空間解析度與不同的資料來源。衛星遙測資料是大面積土地覆蓋資訊的有用來源，因為它們週期性地提供多光譜反射資料（Hwangbo and Yu, 2010）。基於遙測技術可以更有效地收集土地覆蓋，並已成為在大面積土地覆蓋資料集的主要工具（Pagliarella et al., 2016; Kadavi and Lee, 2018）。利用數值影像處理技術從衛星遙測資料中提取土地利用/土地覆蓋資訊表現出極大的興趣（Lulla and Dessinoy, 2000）。因此，過去已經有學者（Franklin and Wulder, 2002）使用中等空間解析度遙測資料，以進行土地覆蓋分類方法的評估。

然而，在過去的幾十年之中，已經逐漸開發出具有更高空間和光譜解析度的遙測資料；充分利用這種發展，分類已成為許多領域中最常用的技術。在很大程度上，傳統的土地覆蓋分類方法已被現在新方法所取代，包括：類神經網路和決策樹方法（Pal and Mather, 2003）。這些新方法是泛指各種機器學習（Machine learning）方法。機器學習在各領域研究也已經取得重大成就，例如：自動駕駛車、語音與圖像辨識、機器翻譯等。機器學習是讓電腦能夠自行從大量資料中學習關於某個任務和一些績效衡量的技術，並能隨經驗逐步改善這項技術。而監督式機器學習是由已經事先定義好的方向，或是要找尋的問題，可以由訓練資料中學到或建立一個模式，並依此模式推測新的實例；使用者可依誤差矩陣（error matrix）與收益圖（Gain chart）來判斷結果（分類模型）的好壞。

分類（classification）是通過添加標註（label）將資料集劃分為不同類別或組別的過程。其目的為檢視所有資料的特性，並依照預先定義的類別法則將資料分成數類，最終能自動產生可預期未來新資料的分類模式。分類也是傳統監督式機器學習常使用的影像判釋之技術。監督式分類主要的原理係利用地面真實資料進行光譜形式辨別，並先決定所需要區分的地物類別，再選取各類別之訓練樣區（training area），依據各樣區之光譜統計值（包括像元式與物件式）進行為影像分類（周巧盈等，2018）。分類模型常使用的機器學習方法有決策樹（Decision tree, DT）、類神經網路（Artificial neural network, ANN）、支持向量機（Support vector machine, SVM）、最大概似法（Maximum likelihood, ML）與隨機森林（Random forest, RF）。

最初用於土地覆蓋分類的演算法為ANN，主要使用基於影像資料統計的監督或非監督之分類，以克服統計分析的局限性（Cho et al., 2017）。有研究者採用ANN與其他監督式分類器進行分析比較，例如：林世峻等人（2008）使用倒傳遞類神經網路（Back Propagation Neural Network, BPNN）與ML進行植被、裸露地及水域之分類準確率比較。Amorós López et al.（2011）將ANN、SVM、分類與迴歸樹（Classification and Regression Tree, CART）三種分類器結合起來，以區分柑橘樹與許多其他不同的樹種；Rokni et al.（2015）應用ANN、SVM、ML分類技術從影像中來提取和識別地表水的變化。SVM是幾十年來最常被運用於地表影像分類與辨識的方法。由於SVM對於高維度空間具有高分類精度和可用性（Pal and Foody, 2010）。所以對於複雜的地形或多類地物往往具有較佳的分類能力。例如：La et al.（2015）選擇五個地物類別（樹、草、水、農業和人造結構）進行SVM分類程序，從高光譜影像中提取樹區域，結果顯示低密度森林區可檢測出92%。Mohajeri et al.（2018）針對瑞士日內瓦66,811棟建築物，使用SVM識別六種類型的屋頂形狀，其最佳分類之類型為平屋頂（flat roof-shape），可以達到94%之準確率。

單一分類器有時不能有效處理分類與迴歸問題，需組合數種不同的學習方法，藉以達到比原本單一方法更佳的结果，並可增加模型的穩健性與準確率，稱為集成學習（Ensemble learning）。RF是由CART所集合構成的分類器，屬於集成學習的一種技術。它可以用較少的計算處理高維度的特徵空間（Belgiu and Dragut, 2016）。因為RF能夠在大型資料集上高效運行，並為每個類別提供特徵重要性的量測，所以才會被選為分類器（Guo et al., 2011）。因此，RF已經被廣泛應用於各種影像分類與監測問題（Gessner et al., 2013; Pham et al., 2016）。其他用於地物影像分類還有ML（Suh et al., 2003; Ahmad, 2012）。ML是一種基於貝式定理的監督式分類方法，它是利用判別函數（discriminant function）將像元（pixels）分配給具有最大概似（the maximum likelihood）的類別，也就是利用訓練樣本推導出最佳化機率模型進行分類。當有足夠的訓練樣本可用，並且資料集的特徵是常態分佈時，ML可以產生準確的分類結果（Lu et al., 2004）。

三、研究方法與影像分類

(一) 機器學習演算法

傳統上，影像分類包括監督式分類與非監督式分類。監督式分類需以人工的方式選取訓練樣區，再進一步利用分類演算法將其餘未選到的區域分類（Gonzalez and Woods, 2008）；這種監督特徵學習方法可以直接從影像像元值中學習資料特定的特徵及其表現（Bengio et al., 2013）。非監督式分類則不需要選取訓練樣區，依據影像像元的自然分佈特性，用群集演算的方法聚集成類組，理論基礎為性質相同的個體具有聚集成群的趨勢，便可自動將全區影像分類（Lillesand and Kiefer, 2000）。常用的監督式分類有SVM、ML、RF及DT；非監督式分類有群集分析（Clustering analysis）。

1. 支持向量機（SVM）

SVM是由Vapnik（1995）根據統計學習理論所提出來的一種機器學習方法，屬於監督式分類的演算法。它的原理是在樣本空間中，劃分超平面的線性方程式如（1）。其中，訓練樣本集 $D = \{x_i, y_i\}$ ； $y_i = \{-1, +1\}$ ，以及 $w = (w_1, w_2, \dots, w_n)$ 為法向量，可決定超平面的方向； b 為偏差值，可決定超平面與原點之間的距離；樣本空間的任一點 x 到超平面的距離為 r 。

若這些訓練資料是線性可分的，可以選擇分離兩類資料的兩個平行超平面，這兩個超平面分別為 $w^T x + b = 1$ 及 $w^T x + b = -1$ （圖1）。兩個超平面範圍內的區域稱為




圖1 支持向量機與超平面（改繪自Cho et al., 2017）

「間隔 (margin)」，其距離是 $2 / \|w\|$ ；使得它們之間的距離儘可能大，需要最小化 $\|w\|$ 。在最大間隔正中間的超平面即「最佳超平面 (Optimal hyperplane)」。同時為了使得樣本資料點都在超平面的間隔區以外，需要保證對於所有的訓練樣本滿足方程式 (1) 其中的一個條件。欲找到最大間隔超平面，就是要求得滿足方程式 (2) 中的參數 w 、 b ，並使 $2 / \|w\|$ 的值最大。

$$w^T x + b = 0 \dots\dots\dots (1)$$

$$\begin{cases} w^T x_i + b \geq +1, y_i = +1 \\ w^T x_i + b \leq -1, y_i = -1 \end{cases} \dots\dots\dots (2)$$

2. 最大概似法 (ML)

最大概似分類是遙測中最常用的分類方法之一，ML將具有最大可能性的像元被分類到相應的類別中。ML是從貝氏定理導出的監督分類方法，用以表示後驗分佈 $P(i | \omega)$ ，也就是具有特徵向量 ω 的像元屬於類別 i 的機率，如方程式 (3) 所示 (Ahmad, 2012)。

$$P(i | \omega) = \frac{P(\omega | i) P(i)}{P(\omega)} \dots\dots\dots (3)$$

其中 $P(\omega | i)$ 是概似函數 (likelihood function)； $P(i)$ 是先驗資訊，即類別 i 出現在研究區域的機率； $P(\omega)$ 是觀察到 ω 的概率，通常被視為正規化常數。最大概似分類假定每個波段中所有類別的統計資料是常態分佈，並計算給定像元屬於特定類別的機率。每個像元被分配給具有最高機率的類別 (即 the maximum likelihood)。如果最高機率小於指定的閾值，則像元保持未分類或未知。因此，可藉由計算影像中的每個像元判別函數 (4) 來實現最大概似分類 (Richards, 1999)。

$$g_i(x) = \ln p(\omega) - \frac{1}{2} \ln \left| \sum_i \left| -\frac{1}{2} (x - m_i)^T \sum_i^{-1} (x - m_i) \right. \right| \dots\dots\dots (4)$$

其中， i 為類別、 m 是類別的數量、 x 是 n 維影像資料 (n 是波段數)、 $P(\omega_i)$ 是類別 ω_i 出現在影像中的機率，並假設所有類別都相同。 $|\Sigma_i|$ 是類別 ω_i 數據的協方差矩陣 (covariance matrix) 的行列式； Σ_i^{-1} 是反矩陣 (inverse matrix)、 m_i 是均值向量 (mean vector)。這些訓練像元可提供估計所使用光譜波段的均值和協方差，並用這些資訊將像元分配給特定的類別。ML對未知像元進行分類時，須同時考慮光譜特徵的變異量與協方差，以及計算類別之機率值，資料的分配可藉由均值向量與協方差矩陣計算各像元被分類為某一種土地覆蓋類別之條件機率，並以最大機率作為分類像元所屬類別之依據。

3. 隨機森林 (RF)

監督式機器學習係藉由訓練組資料之學習，以便在測試組（新樣本）中也能夠表現出較佳的模型。如果訓練模型過於複雜，就會導致過擬合；反之，如果模型過於簡單，就會導致欠擬合，監督式機器學習要面對過擬合和欠擬合的問題，使兩者之間的差異都儘可能最小化。而RF分類器是透過所收集的整體知識對過擬合具有較佳的彈性。RF是由Breiman (2001) 結合Bagging與random subspace method建構許多個決策樹，進行分類或迴歸，並透過各個決策樹預測值進行投票或平均，以獲得最後預測結果。RF建構流程如圖2所示：

- (1) 從N個樣本（M個變數或特徵）的訓練集中，使用Bootstrap aggregating (Bagging) 隨機抽取k次bags（稱為隨機子集），每個bags有n個樣本，每一次抽取之樣本再放回訓練集。將n個樣本組成訓練資料，並建構k棵分類樹，每次未被抽到的樣本組成k個袋外（Out-Of-Bag, OOB）數據，RF之OOB約占訓練集36.8%，其平均值可用來評估模型的錯誤率。
- (2) 每個訓練資料生成不同的隨機變數 θ_k ，並使用random subspace method隨機選擇m個變數（ $m < M$ ），嘗試對每個變數都進行分割，選擇其中最佳分割能力的變數。也就是選擇達到最小的Gini係數作為決策樹的分支。
- (3) 決策樹建構過程不進行修剪（Pruning），而是讓每一棵樹以最大限度地生長。

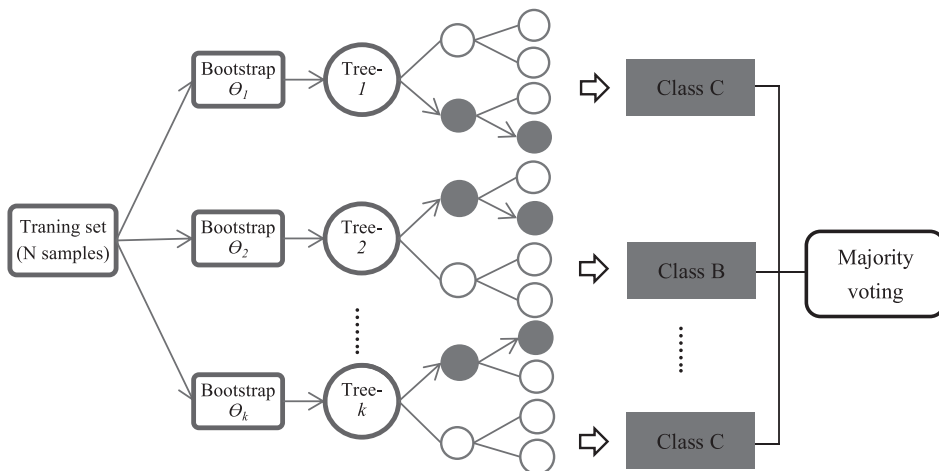


圖2 隨機森林之建構概念與流程（改繪自Belgiu and Drăguț, 2016）

將 k 棵決策樹組成隨機森林，並對 k 棵樹的結果執行分類或迴歸任務：若為分類，則使用多數投票法（majority voting），若為迴歸則是使用平均法。RF演算法基於CART的概念，在CART的訓練過程中進行隨機選擇屬性，從樹的節點之屬性集合中隨機選擇一個包含 k 個屬性的子集，然後再從這個子集中選出一個最佳屬性用於分割，有別於傳統的決策樹在選擇分割屬性時，是以當前節點的屬性集合（假設有 d 個屬性）中選出一個最佳屬性；若 $k = d$ 為傳統的決策樹、 $k = 1$ 則是隨機選擇一個屬性用於分割，一般建議 $k = \log_2 d$ （Breiman, 2001）。

RF是結合多個弱學習器來建構一個強健的模型。集成模型建構決策樹時，由訓練集中取樣再放回，並從隨機子集上隨機抽取的數個變數中，選取最佳的變數作為分支屬性。通過集成學習創造非線性決策邊界，這是一種在訓練資料的隨機子集上訓練許多決策樹的技術，森林係由創造和訓練的許多決策樹代表，最終分類是樹收集預測的統計模式（Castagno and Atkins, 2018）。Meyer et al.（2018）指出為了區分樹之間的相關性，在每個分割中隨機選擇預測變數的子集，隨機子集中的最佳預測變數在相應的分割處對資料進行分區，以便在資料不足和過度學習之間獲得最佳權衡。

（二）研究區域

本研究所使用的空中遙測之UAV為DJI Phantom-3（旋翼型），具備自動導航與起降之功能，藉由地面人員遙控操作方式飛行，並掛載1,200萬像素之影像感測器，能記錄地面影像資料（RGB）與座標、高度等三維空間資訊，並結合GPS定位與地圖顯示功能，僅須於手機APP設定導航點、飛行高度與路徑，即可實施自動起飛與降落、空拍攝影與安全返航，適合從事小區域地物調查之作業。




圖3 研究區域空拍圖（鄉村地區）

在選擇遙測資料類型時，解析度是一個重要的考慮因素（Hwangbo and Yu, 2010）；尤其，高空間解析度在土地覆蓋分類是首選。因此，透過旋翼UAV具有快速、機動取得地表資訊之能力，以及高解析度影像（約5至10公分）的特性；成本效益方面也優於航空攝影測量（有人駕駛飛機）或衛星影像，可確保位置精度和空間解析度。UAV其他優勢包括：製造和維護成本低，在非常艱鉅而複雜的測量任務中具有靈活性和機動性，並且在自主飛行模式下均具有可控制性（Zakeri et al., 2017）。

研究區域中景觀的複雜性、選擇的遙測資料，以及影像處理和分類方法，可能會影響分類的成功（Lu and Weng, 2007）。因此，本研究選定高雄市鳳山區之「鄉村地區」為研究區域，緯度22°37'05.2''N到22°37'01.9''N及經度120°22'25.6''E到120°22'31.4''E（如圖3），土地覆蓋為多元地物種類，包含；人造之建築物、道路，以及自然之樹、草地及裸露地等五種地物。航拍範圍為長度205公尺、寬度154公尺，面積約為31,570 m²，飛行高度約60公尺，飛行時間約5分鐘。另外，在選擇「都市地區」實施分類驗證。

（三）UAV 影像處理與分類

在航拍作業之前，需針對UAV系統姿態進行校準（calibration），並以感測器X、Y、Z三軸為基準旋轉UAV，直至感測器指示燈號由紅燈轉變成綠燈即完成校準，或是由操控的畫面確認校準狀態。DJI Phantom-3內建提供wi-fi功能，可透過智慧型手機連線至操控畫面，進行UAV各種參數的設定，包括：航高、航速、航線、攝影鏡頭角度、拍攝模式、拍攝間隔、影像重疊率等。本研究將DJI Phantom-3飛行高度設定離地面60 m，並將飛行速度固定在2.5~3.0 m/s，兩幅影像之間的最小拍攝時間間隔約為兩秒鐘，帶內的影像前後重疊為75%（end lap），側向重疊率為70%（side lap）。使用之相機型號為FC300C（焦距4 mm），每一張影像解析度為4000 × 3000 pixel，共計使用81張影像產製成正射影像圖，研究區內的平均正鑲嵌影像密度為15 images/pixel，地面解析度約為2.02 cm/pixel。UAV遙測時與相機光軸約與地面約90°之傾斜角，由於航拍過程會受到高空側風與飛行晃動影響，其傾角約有±5°的誤差。

UAV感測器所獲取之影像的特點是三個channels（RGB），所拍攝的相片均可紀錄經度、緯度與高度（X、Y、Z三維座標），並選擇大地座標格式（WGS84），以進行地理座標投影之修正。正射影像處理作業係利用航拍相片之座標實施空中三角測量解算，運用已知地面控制點進行影像校正（orthorectified）

及產製正射影像，並結合絕對地理座標使得UAV高解析度影像與GIS系統（ESRI ArcGIS）整合。之後，再針對樹木（tree）、草地（grassland）、裸露地（land）、建築物（building）及道路（road）之土地覆蓋進行分類。

本研究為執行三種監督式機器學習（分類器）之土地覆蓋分類，其作業流程區分四個部分：（1）訓練集：監督式機器學習需要以UAV之RGB影像作為基線，再從影像中選取五種特徵物區域當作訓練像元，使分類器從訓練像元中學習分類特徵，其訓練樣區分布，如圖4（a）所示（樹木為淡藍色、草地為淺綠、裸露地為棕色、建築物為粉紅色及道路為灰色），並隨機從研究區中產生501個地真（Ground-Truth）檢核點。（2）以人工標註五種真實之土地覆蓋作為標準樣區，可評估分類器對這五種特徵物分類的效益，如圖4（b）。（3）測試集：依據內不同的特徵物具有不同之RGB組成特性，從影像中計算預測變數（五種特徵物），使用測試集之像元測試SVM、ML及RF三種演算法，如圖4（c）、（d）、（e）所示，樹木為S1、草地為S2、裸露地為S3、建築物為S4及道路為S5。（4）最後，對UAV影像進行分類，三種分類器之土地覆蓋預測結果如圖4（f），SVM預測為藍色圓形、ML預測為黃色圓形及RF預測為橘色圓形。

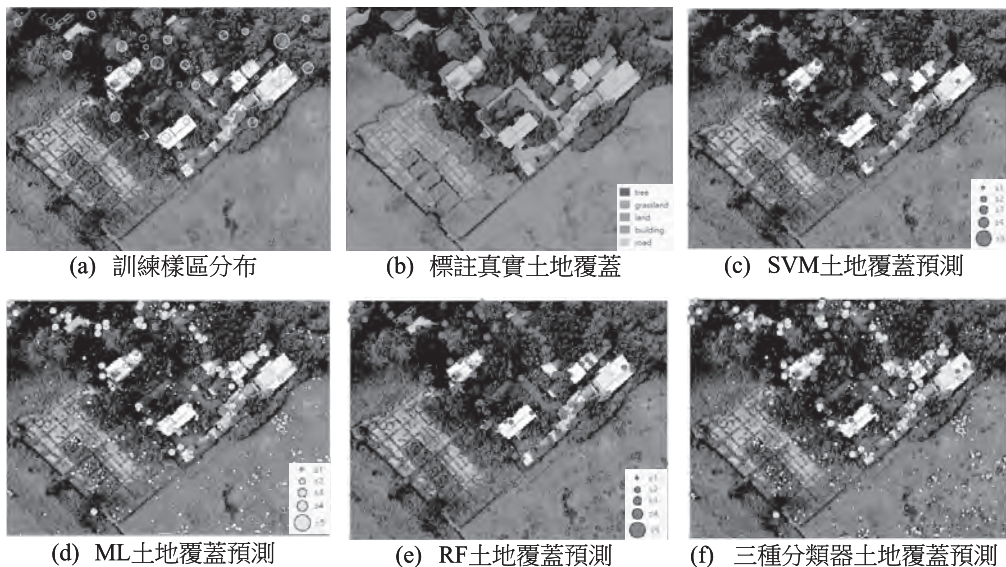


圖4 土地覆蓋分類流程與影像資訊

四、結果與結論

(一) 土地覆蓋之分類成果

監督式分類主要依使用者選取的訓練樣區進行分類測試，分類的準確率相對於非監督式分類較為穩定。然而，土地覆蓋分類受限於使用者是否具有專業之訓練水準，且訓練樣區選取也受到地表的複雜性而有所不同。即使有大量的訓練樣本，選擇適合特定資料、研究領域、應用的特徵和呈現策略也至關重要 (Vettrivel et al., 2016)。

本研究使用SVM、ML及RF三種監督式機器學習方法進行的土地覆蓋分類，共分成五種類別：樹木 (tree, 深綠色)、草地 (grassland, 淺綠色)、裸露地 (land, 黃色)、建築物 (building, 橘色) 及道路 (road, 紅色)。SVM、ML及RF之分類結果如圖5 (a)、(b)、(c) 所示；在視覺呈現上三種監督式分類差

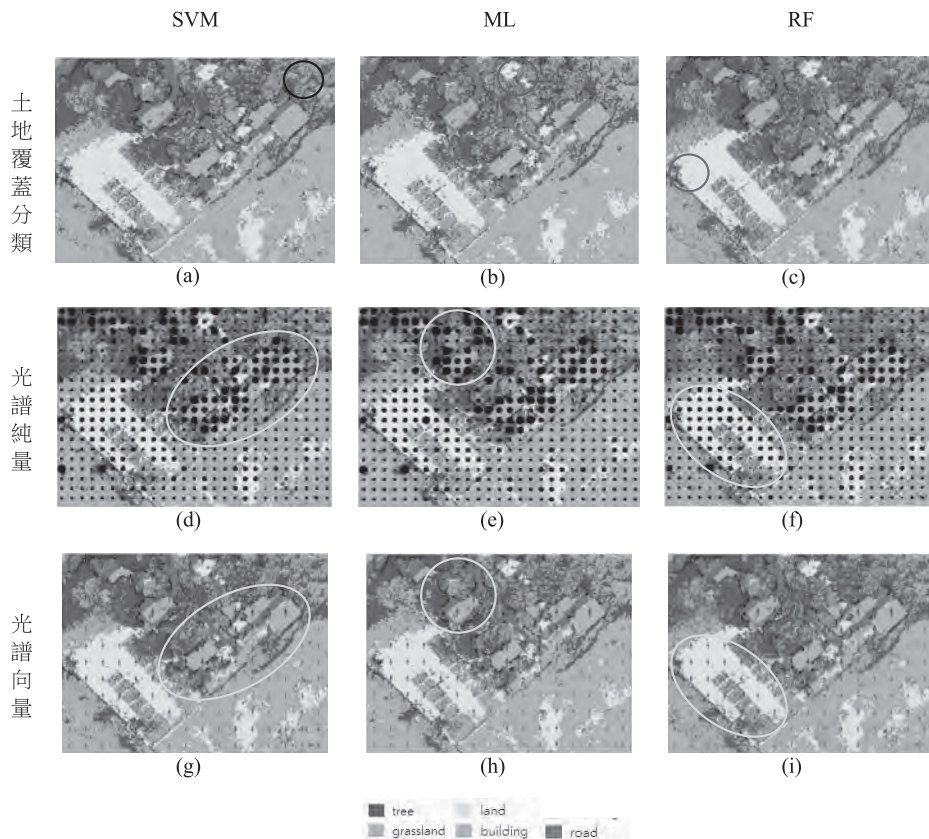


圖5 機器學習方法對土地覆蓋之分類分析圖

異不明顯，錯誤分類的土地覆蓋也都很相似，例如：淺色樹木分類成草地（棕色圓圈）、水泥屋頂建築物分類成裸露地（紫色圓圈）、深色裸露地分類成道路（藍色圓圈）。另外，ML、SVM及RF對於光譜的純量（scalar）大小（圖4（d）、（e）、（f））及光譜的向量（vector）方向（圖5（g）、（h）、（i））大致相近，均集中在人為之建築物及道路，其次是裸露地。

（二）分類模型之評估

誤差矩陣（error matrix）是評估分類準確率最常用的方法（Foody, 2002）。誤差矩陣是將分類模型預測的資料與實際的資料進行對比，以度量該模型的分類結果，用於評估監督式分類的方法。一個「理想分類」模型是實際覆蓋物（Ground-Truth）屬於類別A，也預測（Predicted）成A，屬於類別B，也就預測成B。事實上，大多數的分類器是無法百分之百的準確預測，所以需要使用誤差矩陣分析模型的分類效益。

分類模型預測的變數（類別）若僅二個類別或0與1兩個值，為二元分類（Binary classification）；若是二個類別以上，則為多元分（Multi-class classification）。假設分類模型有二個類別為A與B，分類模型預測結果與實際類別一致，則稱之為「真（True）」；若不一致則稱為「偽（False）」，也就是分類錯誤（誤判）。分類錯誤有二種，一種是實際為A，但卻預測為B（False Negative, FN），應分類成A卻未分入之誤差，稱之為「漏授誤差（Omission Error, OE）」；另一種是實際為B，但卻預測為A（False Positive, FP），不應分類成A卻分入之錯誤，稱之為「誤授誤差（Commission Error, CE）」。分類正確也有二種，一種是實際為A，且預測也為A（True Positive, TP）；另一種是實際為B，且預測也為B（True Negative, TN）。根據表1之分類結果，可計算出模型的準確率（Accuracy）、生產者精度（Producer's accuracy, PA）、使用者精度（User's accuracy, UA）、Kappa及曲線下面積（the area under the curve, AUC）。

準確率是指所有預測類別中，有多少比率是實際屬於該類別，如方程式（5）。準確率愈高，則表示類別誤判比率愈低。一個分類模型的好壞，除了以準確率來衡量外，當某一類別的比率相對較少，且需要被更注意時，代表該類別的重要性可能不同，若僅使用準確率會偏向類別比率較多的一方；然而，少數的類別反而可以發掘到有價值的資訊，可經由計算生產者精度（PA）當作評估的指標。PA表示實際為某類別的結果中，同時被正確判別為某類別的比率，如方程式（6）。

此外，接收器操作特性（the Receiver Operating Characteristic, ROC）之曲線反

映了分類器避免錯誤分類 (false classification) 的能力。在模型性能分析中，ROC 曲線下面積值 (AUC) 越接近1越好，隨著曲線和參考線之間的距離增加，測試精度也會提高，如方程式 (7)。此外，Kappa係數用於檢驗某一種方法在重覆施測時的一致性，或衡量兩種方法在分類結果上的一致性與精度。Kappa係數的計算是基於誤差矩陣的總體統計一致性，將誤差矩陣之非對角線之類別考慮在內，如方程式 (8)。因此，Kappa值是被認為分析單個誤差矩陣或比較各種誤差矩陣之間差異的有效方法 (Foody, 2004)；並且可以被用作解釋分類的漏授誤差和漏授誤差的準確率 (Fung and LeDrew, 1988)。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots\dots\dots (5)$$

$$PA = \frac{TP}{TP + FN} \text{ or } \frac{TN}{FP + TN} \dots\dots\dots (6)$$

$$AUC = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{FP + TN} \right) \dots\dots\dots (7)$$

$$Kappa = \frac{Accuracy - Pe}{1 - Pe} \dots\dots\dots (8)$$

$$Pe = \frac{[(TP + FP) \times (TP + FN)] + [(FN + TN) \times (FP + TN)]}{(TP + TN + FP + FN)^2}$$

表1 分類模型的誤差矩陣

機器學習方法	分類成果 (Predicated)		生產者精度 PA (%)	漏授 OE (%)	
	A	B			
實際 (Ground- Truth)	A	True Positive (TP)	False Negative (FN)	$TP / (TP + FN)$	$FN / (TP + FN)$
	B	False Positive (FP)	True Negative (TN)	$TN / (FP + TN)$	$FP / (FP + TN)$
使用者精度 UA (%)	$TP / (TP + FP)$	$TN / (FN + TN)$	AUC = Mean PA	Accuracy = $(TP + TN) / (TP + TN + FP + FN)$	
誤授 CE (%)	$FP / (TP + FP)$	$FN / (FN + TN)$			

收益圖 (Gain chart) 是一種最普遍使用的分類模型之評估圖，可用來分析模型的分類效益，有助於在多個模型中找到最佳預測模型。藉由比較多個具有相同可預測屬性之模型的精確度；或者評估單一結果的預測精確度。收益圖的橫軸百分比是依據機率從低至高排序，代表測試資料集的百分比；縱軸則是代表預測實際值

(總陽性)的百分比。也就是評估分類模型對於測試集在總陽性中產生一定百分比收益所需的比例，可以進一步了解到測試集50%實際值的有效性。收益圖曲線越向上彎曲，表示模型效益愈好，若是模型的Gain曲線呈現45度分布時，即代表該模型是隨機模型，無分類預測的效益。

(三) 結果分析

本研究土地覆蓋為多元分類，由表2可計算出SVM的生產者精度與準確率。準確率是指所有預測類別中，有多少比率是實際屬於該類別。準確率愈高，則表示該類別誤判比率愈低，例如：SVM正確預測五種土地覆蓋之樹木、草地、裸露地、建築物和道路 (tree、grassland、land、building、road) 之數量分別為113、172、112、34及10個，除以總數501個，所以準確率為88.0% (表2)。ML及RF準確率分別為85.8%及85.6%。透過真實土地覆蓋 (Ground-Truth) 可評估監督式機器學習方法之分類精度。

PA = 正確預測類別數 / 實際類別總數，例如：ML預測建築物 (building) 為29個，除以47個建築物之實際總數，所以PA為61.7% (表3)。本研究三種分類器預測建築物的PA較差 (平均為68.08%)，推測每個建築物之影像RGB差異性最大，建築物屋頂有混凝土及鐵皮加蓋，其材質與顏色各異，且具有較高的可變性質 (variable nature)，容易將建築物 (混凝土) 錯誤分類成道路 (road)。然而，三種分類器對道路都能正確的預測 (PA = 100%)，顯示道路與其他自然覆蓋物

表2 SVM土地覆蓋分類之誤差矩陣

	SVM tree	Predicated					PA (%)	OE (%)
		grassland	land	building	road			
Ground- Truth	tree	113	16	7	0	0	83.09	16.91
	grassland	18	172	1	0	0	90.05	9.95
	land	1	4	112	0	0	95.73	4.27
	building	0	0	4	34	9	72.34	27.66
	road	0	0	0	0	10	100.0	0.0
UA (%)		85.61	89.58	90.32	100.0	52.63	Accuracy = 88.0%	
CE (%)		14.39	10.42	9.68	0.0	47.37	AUC = 0.88 Kappa = 0.83	

表3 ML土地覆蓋分類之誤差矩陣

	ML tree	Predicated					PA (%)	OE (%)
		grassland	land	building	road			
Ground-Truth	tree	112	17	7	0	0	82.35	17.65
	grassland	18	173	0	0	0	90.58	9.42
	land	7	3	106	1	0	90.60	9.40
	building	0	0	5	29	13	61.70	38.30
	road	0	0	0	0	10	100.0	0.0
UA (%)		81.75	89.64	89.83	96.67	43.48	Accuracy = 85.8%	
CE (%)		18.25	10.36	10.17	3.33	56.52	AUC = 0.85 Kappa = 0.80	

表4 RF土地覆蓋分類之誤差矩陣

	RF tree	Predicated					PA (%)	OE (%)
		grassland	land	building	road			
Ground-Truth	tree	112	19	5	0	0	82.35	17.65
	grassland	23	165	3	0	0	86.39	13.61
	land	4	2	109	1	1	93.16	6.84
	building	0	0	5	33	9	70.21	29.79
	road	0	0	0	0	10	100.0	0.0
UA (%)		80.58	88.71	89.34	97.06	50.0	Accuracy = 85.6%	
CE (%)		19.42	11.29	10.66	2.94	50.0	AUC = 0.86 Kappa = 0.80	

(tree、grassland、land) 及建築物 (building) 之間有明顯的光譜異質性。此外，樹木 (tree) 與草地 (grassland) 兩者互相誤判的情形很類似，原因可能是樹木與草地的RGB反射值相似，具有高度一致的光譜特徵 (spectral signature)，造成兩者的可分性最差。

AUC是用來驗證分類模型性能。尤其在樣本不均衡的情況下使用AUC也能準確評估模型的好壞；AUC為PA之平均值，代表分類器所預測土地覆蓋類別之中，真實類別比率的平均值；因此，AUC越接近1，則分類效益越佳。本研究SVM之

AUC為0.88最佳，其次為RF的0.86，以及ML的0.85。Kappa值通常是介於0~1之間，可分成五種一致性：0.0~0.20「極差的 (slight)」一致性、0.21~0.40「一般的 (fair)」一致性、0.41~0.60「中等的 (moderate)」一致性、0.61~0.80「高度的 (substantial)」一致性，以及0.81~1幾乎完全一致 (almost perfect)」。SVM的Kappa為0.83，屬於幾乎完全一致，ML及RF的Kappa皆為0.8，屬於高度的一致性（表2~4）。最後本研究採用收益圖 (Gain chart) 評估測試資料的前50%的效果，五種土地覆蓋分類以SVM最佳；SVM、ML及RF三種機器學習方法在測試集50%時，分別可以預測96.8%、91.6%及88.9%的地真（圖6）。




圖6 三種監督式機器學習之收益圖（鄉村地區）

（四）都市地區模型測試

都市地區是人類活動的主要區域，地物種類相較於鄉村地區更加複雜與多樣；尤其，建築物的屋頂加蓋在台灣是很普遍，而建築物屋頂的顏色、材質與斜度各異；因此，都市地區執行土地分類或辨識，困難度通常較鄉村地區為高。為驗證監督式機器學習於都市地區之分類有效性，本文選擇高雄市鳳山區之「都市地區」進行五種土地覆蓋的測試，該地區的土地覆蓋主要為建築物及道路，而鄉村地區則是以樹木、草地與裸露地。測試區範圍：長度為190公尺、寬度為165公尺，面積約為31,350 m²。使用同一台UAV機型（DJI Phantom-3）與相機型號，相關參數設定、飛行高度、速度，以及兩幅影像之間的最小拍攝時間間隔均與航拍「鄉村地區」相

同，帶內前後的影像重疊為75%，側向重疊率為70%。每一張影像解析度為4000 × 3000 pixel，共計使用80張影像產製成正射影像圖，詳如圖7 (a)，研究區內的平均正鑲嵌影像密度為12 images/pixel，地面解析度約為1.95 cm/pixel。

SVM、ML及RF對都市地區土地覆蓋之分類結果分別如圖7 (b)、(c) 及 (d)。從視覺上很難區別三者之間的差異，故需藉由誤差矩陣等指標，比較這三種監督式機器學習方法之分類效益。首先，使用準確率評估分類地物的正確性，SVM準確率為85.4%，ML和RF則分別為82.6%及78.6% (圖8)；這三種機器學習方法在都市地區分類準確率均低於鄉村地區，研判建築物屋頂多樣性高於鄉村地區自然之地物所致。其次，SVM、ML和RF之AUC分別為0.81、0.79和0.75 (圖8)，代表在地真中正確預測的平均值。最後，SVM、ML和RF之Kappa係數分別為0.78、0.74和0.68 (圖8)，三種方法均屬於「高度的」一致性 (Kappa介

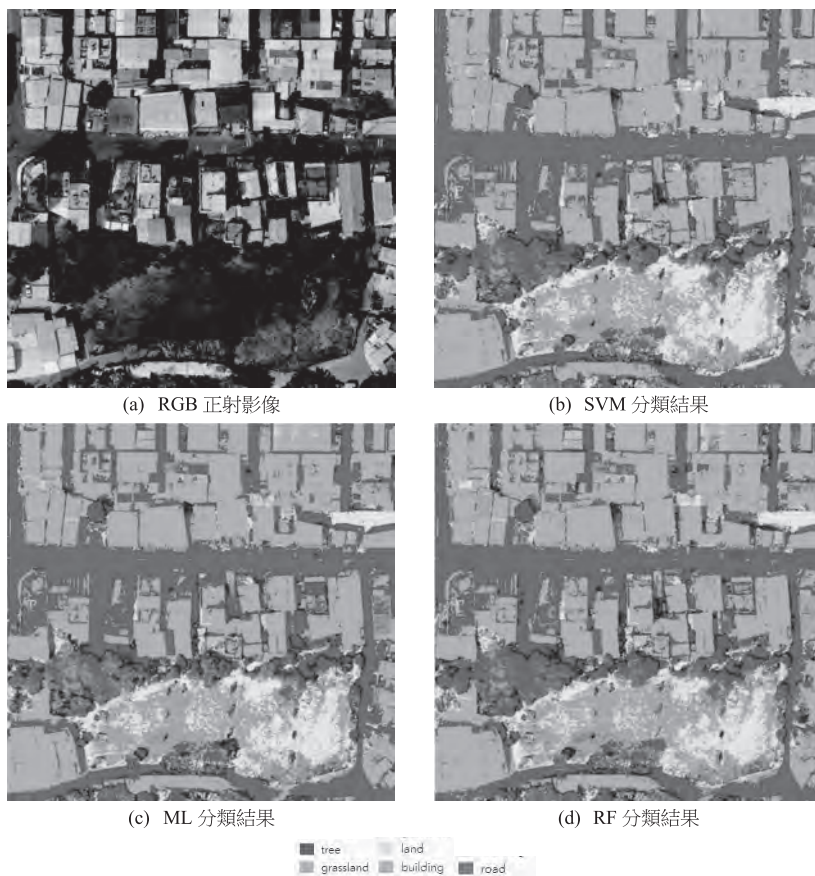


圖7 三種監督式機器學習於都市地區之分類結果

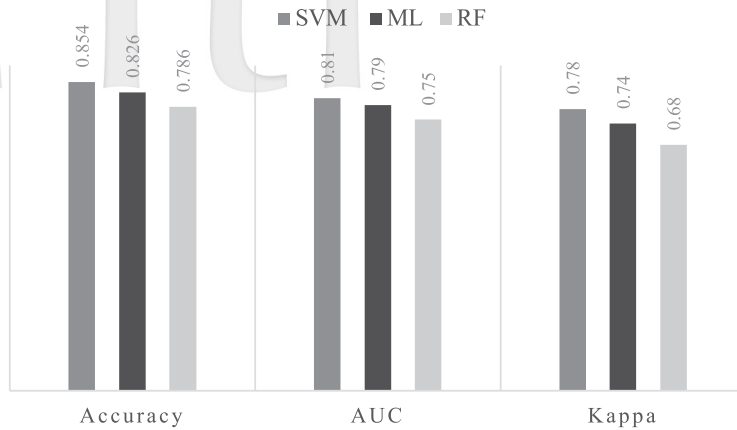


圖8 監督式機器學習之三種評估指標圖

於0.61~0.80)。另外，藉由收益圖可以從多個模型中找到最佳的預測精確度；SVM對於測試樣區中預測總陽性的比例最高，在測試樣區50%之實際值的比例為95.8%，ML和RF則分別為88.5%及78.5%（圖9）。

以上評估指標數值均低於「村鄉地區」，結果顯示三種監督式機器學習在「村鄉地區」土地覆蓋之分類效益優於「都市地區」（圖10）。另外，因為科學界使用數值影像處理技術從數值多光譜資料獲得最佳準確率，並已經習慣接受大約70~80%的準確率（Jensen, 1996）。本研究僅使用RGB影像測試鄉村與都市地區之五種不同的土地覆蓋比例，所獲得分類準確率均在78.6%以上，證明三種監督式機器學習符合實務上應用需求。

人對於影像判釋是基於與未知物體或區域相關的全部資訊，包括：色調、顏色、大小、形狀、陰影、紋理、圖案、高度、位置和背景情況與關聯，並不會將影像解釋為由單個像元所組成。然而，機器學習方法對於影像的分類會根據資料的類型或分類方案顯示出不同的性能，例如：光譜帶、輔助資料和研究區域的性質等因素，所有的分類方法都會產生不同的結果，除了分類方法之外，影像的特徵在分類的性能中扮演著至關重要的作用（Vetrivel et al., 2016）。Lloyd et al. (2004)認為通常要進行不同分類器的比較研究，才能夠找到特定研究的最佳分類結果。因此，本研究採用上述四種評估指標（Accuracy、AUC、Kappa、Gain），以進行監督式機器學習方法之綜合性分類比較，其結果顯示SVM對土地覆蓋的分類效益較佳，其次為ML及RF，但是三者差異不大。整體而言，本研究所使用之監督式機器學習對於土地覆蓋分類之準確率都大於78.6%以上，無論是在鄉村或都市地區均顯

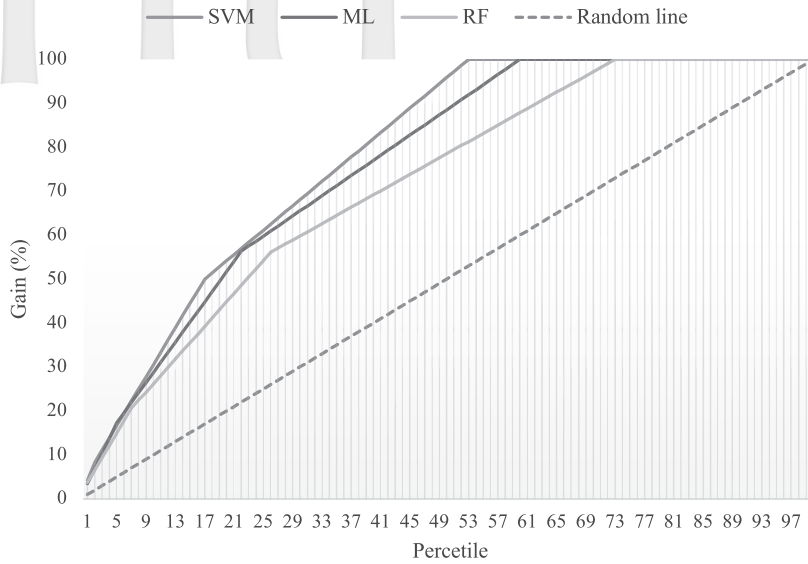


圖9 三種監督式機器學習之收益圖（都市地區）

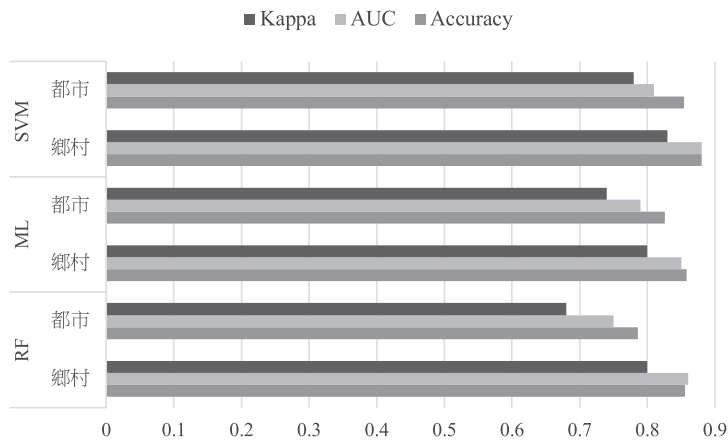


圖10 鄉村與都市地區綜合評估之比較圖

示出良好的分類效益。三種類器能清楚區分各種土地覆蓋的差異，並分析人為（building及road）與自然（tree、grassland、land）特徵物的不同光譜組成與分部特性，並基於RGB做出正確的判別結果，以有效進行研究區內的土地覆蓋分類。

五、結 論

有效運用高解析度的遙測影像和選擇合適的分類方法，對於提高分類的準確率尤其重要。一些研究者嘗試開發先進的分類方法和技術（如機器學習或深度學習）用於改善分類的效益，並針對這些分類方法進行研究與分析比較，對於選擇適合特定的分類程序將是非常有價值。分類結果也是許多環境生態和社會經濟應用的基礎，並有益於土地資源管理與規劃。

因此，本研究使用UAV遙測影像及機器學習方法構建五種土地覆蓋：樹木（tree）、草地（grassland）、裸露地（land）、建築物（building）及道路（road）之分類模型，主要目的是運用高解析度影像與機器學習自動及快速分類方法，以計算地物的影像資料特徵，並且將這些特徵用於分類的基礎。之後，使用各種評估指標驗證分類模型的準確性與效益。本研究分類成果顯示，三種監督式機器學習方法之中，SVM的準確率、AUC、Kappa及Gain都是最佳。雖然SVM之綜合評估得知對土地覆蓋分類的效益最佳；然而，與ML及RF的分類效益差異不大。

此外，UAV是從空中採用垂直地面的俯視角度進行空拍，其遙測影像具備簡易、機動與經濟性的快速取像方式，能進行高效率及高解析度之影像拍攝作業，且透過機器學習方法有利於各種土地覆蓋分類與判釋，準確的分類模型可用於各種地物之應用。隨著UAV的操作門檻與成本會越來越降低，有利於大規模的調查、監測、勘查作業，結合各種自動機器學習方法，可即時預測分類或判釋的成果，提供給相關單位於實質上的運用。

未來將持續透過UAV影像分析與影像處理系統的開發，增加UAV遙測影像的光譜分類、地物辨識與地面紋理分類的運算能力。透過UAV高解析度的影像，可清楚呈現地表特徵物之紋理（texture）、顏色，有助於進行正確的分類。並整合不同機器學習的優點，進行各種空間特徵物資料的訓練與測試，以獲得更精確的面積、數量、種類、位置及大小等影像相關資料。

參考文獻

- 王素芬、余佳樺、劉雅婷，2014，衛星影像前處理對植生變遷偵測影響之探討，地理學報，第 75 期，頁 81-99。
- 林世峻、莊智璋、何世華、林昭遠，2008，植生指標對影像分類準確度影響之研究，水土保持學報，第 40 卷，第 2 期，頁 315-327。

- 邱式鴻、顏怡和、丁育群，2014，旋翼型 UAV 影像局部重測都市區千分之一地形圖之研究，*台灣土地研究*，第 17 卷，第 2 期，頁 57-88。
- 周巧盈、巫思揚、陳琦玲，2018，應用無人飛機航拍影像協助農業勘災—以香蕉災損影像判釋為例，*航測及遙測學刊*，第 23 卷，第 2 期，頁 83-101。
- 陳承昌、史天元，2007，支持向量機應用於水稻田辨識之研究，*航測及遙測學刊*，第 12 卷，第 3 期，頁 225-240。
- 黃韋凱、林銘郎、陳良健、林彥享、蕭震洋，2010，物件導向分析方法應用於遙測影像之分區及崩塌地與人工設施分類，*航測及遙測學刊*，第 15 卷，第 1 期，頁 29-49。
- 鄒明城、孫志鴻，2004，資料探勘技術在集集大地震引致山崩之研究，*地理學報*，第 36 期，頁 117-131。
- 壽克堅、吳秋靜、許惠瑛，2010，以 SPOT 衛星影像探討 1999 集集地震後之崩塌行為，*航測及遙測學刊*，第 15 卷，第 1 期，頁 17-28。
- 盧衍良、林清一、邱釋輝，2012，無人飛行載具從事台灣災區搜救任務之飛安問題研究，*航空、太空及民航學刊系列 B*，第 44 卷，第 1 期，頁 21-30。
- Ahmad, A., 2012, Analysis of maximum likelihood classification on multispectral data applied, *Mathematical Sciences*, 6(129), pp. 6425-6436.
- Al-Najjar, H. A. H., B. Kalantar, B. Pradhan, V. Saeidi, A. A. Halin, N. Ueda, and S. Mansor, 2019, Land cover classification from fused SM and UAV images using convolutional neural networks, *Remote Sensing*, 11(12), 1461.
- Amorós López, J., E. Izquierdo Verdiguier, L. Gómez Chova, J. Muñoz Marí, J. Z. Rodríguez Barreiro, G. Camps Valls, and J. Calpe Maravilla, 2011, Land cover classification of VHR airborne images for citrus grove identification, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(1), pp. 115-123.
- Anders, N., M. Smith, J. Suomalainen, E. Cammeraat, J. Valente, and S. Keesstra, 2020, Impact of flight altitude and cover orientation on Digital Surface Model (DSM) accuracy for flood damage assessment in Murcia (Spain) using a fixed-wing UAV, *Earth Science Informatics*, 13, pp. 391-404.
- Anderson, K. and K. J. Gaston, 2013, Lightweight unmanned aerial vehicles will revolutionize spatial ecology, *Frontiers in Ecology and the Environment*, 11(3), pp. 138-146.

- Atkinson, P. M. and P. Aplin, 2004, Spatial variation in land cover and choice of spatial resolution for remote sensing, *International Journal of Remote Sensing*, 25(18), pp. 3687-3702.
- Belgiu, M. and L. Drăguț, 2016, Random forest in remote sensing: A review of applications and future directions, *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, pp. 24-31.
- Bengio, Y., A. Courville, and P. Vincent, 2013, Representation learning: A review and new perspectives, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), pp. 1798-1828.
- Breiman, L., 2001, Random forests, *Machine Learning*, 45(1), pp. 5-32.
- Castagno, J. and E. Atkins, 2018, Roof shape classification from LiDAR and satellite image data fusion using supervised learning, *Sensors*, 18(11), 3960.
- Chen, D., D. A. Stow, and P. Gong, 2004, Examining the effect of spatial resolution and texture window size on classification accuracy: An urban environment case, *International Journal of Remote Sensing*, 25(11), pp. 2177-2192.
- Cho, G. S., N. Gantulga, and Y. W. Choi, 2017, A comparative study on multi-class SVM & kernel function for land cover classification in a KOMPSAT-2 image, *KSCE Journal of Civil Engineering*, 21(5), pp. 1894-1904.
- Chuang, Y. C. M. and Y. S. Shiu, 2016, A comparative analysis of machine learning with WorldView-2 pan-sharpened imagery for tea crop mapping, *Sensors*, 16(5), 594.
- Colomina, I. and P. Molina, 2014, Unmanned aerial systems for photogrammetry and remote sensing: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 92(6), pp. 79-97.
- Foody, G. M., 2002, Status of land cover classification accuracy assessment, *Remote Sensing of Environment*, 80(1), pp. 185-201.
- Foody, G. M., 2004, Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy, *Photogrammetric Engineering and Remote Sensing*, 70(5), pp. 627-633.
- Forsyth, D. and J. Ponce, 2011, *Computer Vision: A Modern Approach*, London: Pearson.
- Fung, T. and E. LeDrew, 1988, The determination of optimal threshold levels for change detection using various accuracy indices, *Photogrammetric Engineering and Remote Sensing*, 54(10), pp. 1449-1454.

- Franklin, S. E. and M. A. Wulder, 2002, Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas, *Progress in Physical Geography: Earth and Environment*, 26(2), pp. 173-205.
- Gessner, U., M. Machwitz, C. Conrad, and S. Dech, 2013, Estimating the fractional cover of growth forms and bare surface in savannas. A multi-resolution approach based on regression tree ensembles, *Remote Sensing of Environment*, 129(15), pp. 90-102.
- Getzin, S., R. S. Nuske, and K. Wiegand, 2014, Using unmanned aerial vehicles (UAV) to quantify spatial gap patterns in forests, *Remote Sensing*, 6(8), pp. 6988-7004.
- Gonzalez, R. C. and R. E. Woods, 2008, *Digital Image Processing*, New Jersey: Prentice Hall.
- Guo, L., N. Chehata, C. Mallet, and S. Boukir, 2011, Relevance of airborne Lidar and multispectral image data for urban scene classification using random forests, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(1), pp. 56-66.
- Huang, H., J. Long, H. Lin, L. Zhang, W. Yi, and B. Lei, 2017, Unmanned aerial vehicle based remote sensing method for monitoring a steep mountainous slope in the Three Gorges Reservoir, China, *Earth Science Informatics*, 10, pp. 287-301.
- Hwangbo, J. W. and K. Yu, 2010, Decision support system for the selection of classification methods for remote sensing imagery, *KSCE Journal of Civil Engineering*, 14(4), pp. 589-600.
- Jensen, J. R., 1996, *Introductory Digital Image Processing: A Remote Sensing Perspective*, Upper Saddle River: Prentice-Hall Inc.
- Jensen, J. R., F. Qiu, and K. Patterson, 2001, A neural network image interpretation system to extract rural and urban land use and land cover information from remote sensor data, *Geocarto International*, 16(1), pp. 21-30.
- Kadavi, P. and C. Lee, 2018, Land cover classification analysis of volcanic island in Aleutian Arc using an artificial neural network (ANN) and a support vector machine (SVM) from Landsat imagery, *Geosciences Journal*, 22(4), pp. 653-665.
- Kalantar, B., S. B. Mansor, M. I. Sameen, B. Pradhan, and H. Z. M. Shafri, 2017, Drone-based land-cover mapping using a fuzzy unordered rule induction algorithm integrated into object-based image analysis, *International Journal of Remote Sensing*, 38, pp. 2535-2556.

- La, H. P., Y. D. Eo, A. Chang, and C. Kim, 2015, Extraction of individual tree crown using hyperspectral image and LiDAR data, *KSCE Journal of Civil Engineering*, 19(4), pp. 1078-1087.
- Lillesand, T. M. and R. W. Kiefer, 2000, *Remote Sensing and Image Interpretation*, New York: John Wiley & Sons.
- Liu, T. and A. Abd-Elrahman, 2018, An object-based image analysis method for enhancing classification of land covers using fully convolutional networks and multi-view images of small unmanned aerial system, *Remote Sensing*, 10, 457.
- Lloyd, C. D., S. Berberoglu, P. J. Curran, and P. M. Atkinson, 2004, A comparison of texture measures for the per-field classification of Mediterranean land cover, *International Journal of Remote Sensing*, 25(19), pp. 3943-3965.
- Lu, D., P. Mausel, M. Batistella, and E. Moran, 2004, Comparison of land-cover classification methods in the Brazilian Amazon Basin, *Photogrammetric Engineering and Remote Sensing*, 6, pp. 723-731.
- Lu, D. and Q. Weng, 2007, A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, 28(5), pp. 823-870.
- Lulla, K. P. and L. V. Dessinov, 2000, *Dynamic Earth Environments: Remote Sensing Observations from Shuttle-Mir missions*, New York: John Wiley & Sons.
- Meyer, H., C. Reudenbach, T. Hengl, M. Katurji, and T. Nauss, 2018, Improving performance of spatio-temporal machine learning models using forward feature selection and target-oriented validation, *Environmental Modelling & Software*, 101, pp. 1-9.
- Mohajeri, N., D. Assouline, B. Guibouda, A. Bill, A. Gudmundsson, and J. L. Scartezzini, 2018, A city-scale roof shape classification using machine learning for solar energy application, *Renewable Energy*, 121, pp. 81-93.
- Nex, F. and F. Remondino, 2014, UAV for 3D mapping applications: A review, *Applied Geomatics*, 6(1), pp. 1-15.
- Pagliarella, M. C., L. Sallustio, G. Capobianco, E. Conte, P. Corona, L. Fattorini, and M. Marchetti, 2016, From one-to two-phase sampling to reduce costs of remote sensing-based estimation of land-cover and land-use proportions and their changes, *Remote Sensing of Environment*, 184, pp. 410-417.

- Pal, M. and G. M. Foody, 2010, Feature selection for classification of hyperspectral data by SVM, *IEEE Transactions on Geoscience and Remote Sensing*, 48(5), pp. 2297-2307.
- Pal, M. and P. M. Mather, 2003, An assessment of the effectiveness of decision tree methods for land cover classification, *Remote Sensing of Environment*, 86(4), pp. 554-565.
- Pham, L. T. H., L. Brabyn, and S. Ashraf, 2016, Combining QuickBird, LiDAR, and GIS topography indices to identify a single native tree species in a complex landscape using an object-based classification approach, *International Journal of Applied Earth Observation and Geoinformation*, 50, pp. 187-197.
- Ramadhani, S. A., R. M. Bennett, and F. C. Nex, 2018, Exploring UAV in Indonesian cadastral boundary data acquisition, *Earth Science Informatics*, 11, pp. 129-146.
- Rhee, D. S., Y. D. Kim, B. Kang, and D. Kim, 2018, Applications of unmanned aerial vehicles in fluvial remote sensing: An overview of recent achievements, *KSCE Journal of Civil Engineering*, 22(2), pp. 588-602.
- Riahi Bakhtiari, H. R., A. Abdollahi, and H. Rezaeian, 2017, Semi automatic road extraction from digital images, *The Egyptian Journal of Remote Sensing and Space Sciences*, 20(1), pp. 117-123.
- Richards, J., 1999, *Remote Sensing Digital Image Analysis*, Berlin: Springer-Verlag.
- Rokni, K., A. Ahmad, K. Solaimani, and S. Hazini, 2015, A new approach for surface water change detection: Integration of pixel level image fusion and image classification techniques, *International Journal of Applied Earth Observation and Geoinformation*, 34, pp. 226-234.
- Sharma, A., X. Liu, X. Yang, and D. Shi, 2017, A patch-based convolutional neural network for remote sensing image classification, *Neural Networks*, 95, pp. 19-28.
- Suh, Y., H. Zhao, and R. Shibasaki, 2003, Road network extraction from high-resolution satellite image for GIS applications, *KSCE Journal of Civil Engineering*, 7(5), pp. 595-602.
- Suomalainen, J., N. Anders, S. Iqbal, G. Roerink, J. Franke, P. Wenting, D. Hünninger, H. Bartholomeus, R. Becker, and L. Kooistra, 2014, A lightweight hyperspectral mapping system and photogrammetric processing chain for unmanned aerial vehicles, *Remote Sensing*, 6(11), pp. 11013-11030.

- airiti
- Unger, J., M. Reich, and C. Heipke, 2014, UAV-based photogrammetry: Monitoring of a building zone, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 5, pp. 601-606.
- Vapnik, V., 1995, *The Nature of Statistical Learning Theory*, New York: Springer-Verlag.
- Vetrivel, A., M. Gerke, N. Kerle, and G. Vosselman, 2015, Identification of damage in buildings based on gaps in 3D point clouds from very high resolution oblique airborne images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, pp. 61-78.
- Vetrivel, A., M. Gerke, N. Kerle, and G. Vosselman, 2016, Identification of structurally damaged areas in airborne oblique images using a Visual-Bag-of-Words approach, *Remote Sensing*, 8(3), 231.
- Yao, H., R. Qin, and X. Chen, 2019, Unmanned aerial vehicle for remote sensing applications—A review, *Remote Sensing*, 11(12), 1443.
- Zakeri, H., F. M. Nejad, and A. Fahimifar, 2017, Image based techniques for crack detection, classification and quantification in asphalt pavement: A review, *Archives of Computational Methods in Engineering*, 24, pp. 935-977.