



深度學習於高精地圖產製之應用

徐百輝／國立臺灣大學土木工程學系 助理教授、台灣地理資訊學會 理事長

莊宗易／中山科學研究院飛彈火箭研究所 助理研究員

高精地圖是專為自駕車應用而特別測製的地圖，其相關內容之設計、測繪之正確性、以及圖資精度等都將直接影響到自駕車行駛時的安全性。在產製高精地圖時，為了確保圖資內容之正確性及精度，通常需要耗費大量的人力及時間進行道路語意特徵的辨識及屬性編輯。本文首先簡單介紹高精地圖之內容、標準、規範、及產製作業程序等，最後嘗試應用不同的深度學習算法進行道路語意特徵的自動化萃取，以期提升高精地圖之品質及作業效能。

簡介

在日常生活中，交通系統為人類移動、貨物流通、經濟交流的重要基礎建設，隨著資通訊技術的快速發展，交通系統智慧化已成為智慧城市（Smart City）發展中不可或缺的一環，而在智慧交通（Intelligent Transportation）中，又屬自駕車（Autonomous Vehicles）的發展最受矚目。為達到自動駕駛的目的，自駕車透過衛星定位系統及各種感測設備即時掌握車子本身的空間位置及其周遭道路環境的狀況，除了自動導航之外，尚能自動遵守交通規則以及避免碰撞事故之風險。然而受限於汽車感測器的有效感測距離、物體遮蔽、以及即時運算效能等因素影響，欲達到完全自動駕駛的目標仍有其難度。解決這些問題的一種方式是透過事先測製精準且具有豐富道路資訊的地圖，以提供自駕車與即時感測資料進行比對後迅速達到定位及導航的目的，此預先測製的精密地圖便是所謂的高精地圖（High Definition Maps, HD Maps）。

與傳統電子導航地圖相比，高精地圖無論是在地圖內容或精密程度上皆有很大的差異。簡單地說，傳統電子導航地圖是設計給「人」看的，且大多為二維平面地圖，而高精地圖則是專門為自動駕駛目的而設計，主要是給車上的「電腦」看的，且是具有高程資訊的

三維地圖。傳統電子導航地圖雖具有「路徑規劃」及「方向指引」的功能，但最終仍是由人類依據其駕駛經驗自主判斷道路狀況並決定汽車駕駛的方向，因此地圖內容主要以交通路網及地標為主，對於精度也無太高的要求。高精地圖則是車載電腦用來與即時感測資料，如影像（Images）或點雲（Point Cloud）等進行比對的參考依據，除了精度要求較高之外，高密度的三維點雲地圖（3D Point Cloud Map）以及與交通規則相關的道路語意特徵地圖（Traffic Rule-related Semantic Feature Map）為其主要內容^[1]。

由於高精地圖是專為自駕車應用而特別測製的地圖，其相關內容之設計、測繪之正確性、以及圖資精度等都將直接影響到自駕車行駛時的安全性。為了讓高精地圖能廣泛地使用於各廠牌自駕車或其他相關應用，需要有一套共同且符合國際標準的高精地圖內容及資料格式，因此本文首先針對高精地圖之主要內容進行描述，並說明目前國內於高精地圖標準制訂之進展；接著本文將針對高精地圖製作之主要程序及方法進行說明，為了確保高精地圖資料內容的品質及一致性，許多測製程序常需耗費大量人力及時間，其中以語意特徵地圖的製作最為耗時耗力。為了提升高精地圖語意特徵萃取之效能，許多研究採用機器學習（Machine Learning）演算

法進行語意特徵的自動萃取，再由人進行驗證^[1]。本研究則嘗試應用不同的深度學習方法從點雲資料中自動學習並萃取語意特徵，期待未來能進一步降低產製高精地圖之人力及製作經費之門檻。

高精地圖之主要內容

一個完整的高精地圖主要包含一個三維點雲地圖、以及一個用來儲存語意特徵的 GIS 向量圖層，兩者具有同樣的空間坐標，如圖 1 所示。點雲資料主要利用車載光達系統 (Mobile LiDAR System) 掃描而得，除了當作自駕車即時定位用之參考資料外，亦是用來製作語意特徵地圖的主要依據。高精地圖向量圖層則包含了車道等級的道路資訊及各種交通設施，並包含了路面及路邊之各種物體。根據「高精地圖檢核及驗證指引」的內容，高精地圖向量圖層的主要種類如圖 2 所示，包含道路、車道、交通號誌、交通標誌、標線及物體等。道路及車道部分的主要內容包括三維的車道等級地圖，自駕車可獲得車道中心線、車道線、道路邊緣等道路資訊，由於是具高程資訊的三維資料，因此可提供坡度、曲率等傳統平面地圖所缺乏的資訊。另外還包含交通號誌、

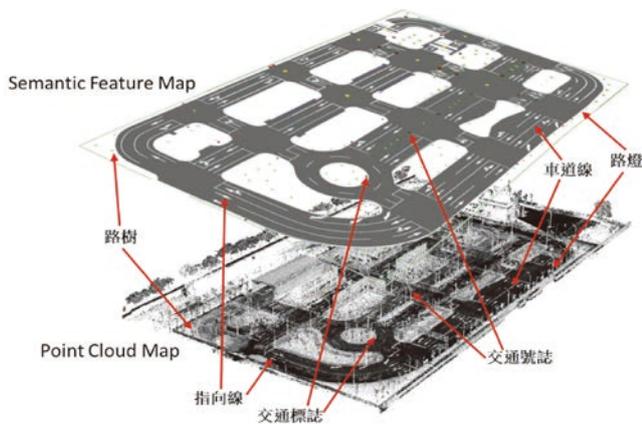


圖 1 台灣高精地圖之主要內容



圖 2 台灣高精地圖語意特徵主要種類 (標誌、號誌、標線及物體僅為舉例)

標誌、標線等交通管理設施，以及其他道路上之物體。有了這些豐富圖資內容，再搭配其他感測器，自駕車即可進行各種車輛行駛決策。

以下對於重要的向量圖層的幾何位置進行介紹：

1. 路面邊緣：道路路面之邊緣，以柏油路面做為主要認定的邊界，若道路具有路緣石，就以緣石外側視為路面邊緣。
2. 車道線：車道線作為車道兩旁的邊界，具有寬度、顏色及樣式等屬性，車道線以路面的標記為主，量測時取車道線的中心線。
3. 車道中心線：車道中心線是虛擬線，在道路測繪時以車道兩側的車道線取中心線。
4. 標線、標線範圍、標線實形：由於道路上的標線相當多，尤其國內的標線比國外來的更多，因此依據不同的標線類型，分成三個圖層。標線 (MarkLine) 是以一條線為其代表位置，並加上寬度屬性，用以描述其面狀之範圍，例如路面邊緣、停止線、車道線皆屬於此類型，也最為單純；標線範圍 (MarkArea) 記錄標線之外圍面狀範圍，例如停車格、禁止停車區、機車停等區、槽化線等皆屬於此類型，可辨識標線外圍邊界而繪製出一空間範圍。標線實形 (MarkGraph) 則以多邊形繪製出標線的實際形狀。以圖 3 為例，行人穿越道為例，MarkArea 繪製紅色之範圍。MarkGraph 繪製綠色範圍，MarkGraph 的數量依照實際情況而定。
5. 停止線：停止線的位置是取停止線之中心線，並記錄寬度內容。
6. 停車格：停車格為車輛的停放位置，記錄停車格的多邊形。
7. 物體：除了桿狀物體的其他各種路面或路邊物體，皆記錄在物體圖層。測繪時須量測其底部三維空間範圍，另外於屬性內記錄物體最高點的橢球高。由此可知高精地圖並不記錄物體的實際三維複雜形體，而是由底部範圍及高度表現物體的概略空間位置。
8. 隧道、橋梁：隧道、橋梁皆量測平面的底部範圍多邊形，並記錄隧道及橋樑之名稱，並可記錄相關車道之識別碼。概念與物體相同，僅記錄隧道與橋樑的概略空間位置。
9. 標誌：量測牌面中心位置三維點坐標，並記錄其標誌牌面法向量與正北之角度、標誌所在的桿柱及標誌種類。並且記錄涵蓋標誌的包圍矩形，記錄其左下及右上坐標。

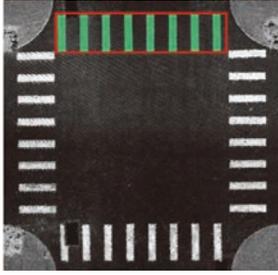


圖 3 MarkArea 與 MarkGraph 示意圖 [3]

10. 號誌、號誌燈號：號誌分為兩個部分，每一個號誌皆以一個三維點坐標記錄號誌的概略中心位置，並記錄屬性；對於號誌上的每一個燈號，則另記錄三維點坐標及屬性，屬性包含燈號意義、燈號鏡面之半徑等資料。
11. 桿柱：記錄桿狀物體的基底中心三維點坐標，並記錄頂點的高度，以及桿柱類型。

高精地圖的國際標準及相關發展

智慧駕駛與自駕車相關領域的發展，需要有一套共同的高精地圖資料格式及內容，並且品質必須通過檢驗，以輔助智慧駕駛車或自駕車進行車道等級的定位，進而發展先進駕駛輔助系統。為了確保資料內容及品質的一致性，訂定相關的產業標準與規範成為不可或缺的重要工作。目前高精地圖在內容及格式上的國際標準有 OpenDRIVE、Autoware、NDS (Navigation Data Standard) 等不同之標準資料格式，部分組織在發展資料格式的時候會連同軟體平台一起開發，例如 Autoware 是一整套的開源應用平台。Autoware 因具有開源應用平台，內建許多技術程式，讓自駕車研發單位在導入相關技術時可大大地降低成本，因此廣泛為許多研發單位及發展業者採用，國內有許多業者採用 Autoware 平台。NDS 則是會員制，採用之會員需固定繳交費用，採用其平台最新技術及內容，歐洲有許多車廠皆是 NDS 會員。

各國家對於車商、自駕車產業的投資程度不同，有些由業者主導，有些則從國家扶植的角度進行合作，因此推動方式也有所差異。歐、美、韓國的車商規模較大，投入自駕車之資金較多，有另一個現象是由車商及車用圖資商主導高精地圖的發展，例如 HERE 及 TomTom 等圖資商與國外相關車廠合作，發展出不同的高精地圖，各自具有不同的圖資內容及格式，直接整合在車輛系統內。

另外的發展模式則是訂定國家級的資料標準，目前有部分國家選用一種國際標準去訂定國家的高精地圖資料標準，或自行研發新的資料格式，例如中國以 OpenDRIVE 為基礎而開發 Apollo，修改擴充了 OpenDRIVE 的內容；而台灣與日本較為相似，主要由政府出資主導，並推動自己國家的高精地圖產業標準。日本做法是由政府與車廠共同成立企業 (DMP-Data Management Platform)，並且發展國家等級的高精地圖內容，而台灣則是政府出資，推動計畫後由國內專家承接進行研發規劃，以 OpenDRIVE 為基礎而訂定國家之高精地圖標準。

國內高精地圖的標準發展情形

我國由內政部於 2018 年正式啟動台灣高精地圖標準規範之制定與製作計畫，並委託成功大學高精地圖研究發展中心訂定相關標準及指引，目前已於台灣資通產業標準協會 (TAICS) 發佈中英文版之高精地圖圖資內容與資料標準、中英文版之高精地圖製圖作業指引及高精地圖檢核及驗證指引，如表 1 所示。另外，目前已提案並進入審閱流程的文件包含高精地圖更新作業及檢核指引—靜態圖資、高精地圖圖資內容及格式標準英文版以及自駕車高精地圖輔助與事件標準，如表 2 所示。

根據前述的相關內容，高精地圖的生產具有一系列的程序與指引，並且需要通過相關的檢核。首先由

表 1 已發佈之標準、指引文件

文件名稱	文件編號	發佈日期
高精地圖製圖作業指引 v2	TAICS TR-0010 (E) v2.0	108/10/17
高精地圖檢核及驗證指引	TAICS TR-0016 v1.0	109/06/05
高精地圖圖資內容及格式標準 v1.1	TAICS TS-0011 v1.1	109/06/12
高精地圖製圖作業指引英文版： HD Maps operation guidelines v2	TAICS TR-0010 (E) v2.0:2021	110/07/30
高精地圖檢核及驗證指引英文版： Verification and validation guidelines for HD Maps	TAICS TR-0016 (E) v1.0	110/07/30
高精地圖圖資內容及格式標準 v1.1 英文版： HD Maps data contents and formats standard v1.1	TAICS TS-0024 (E) v1.0	110/08/26

表 2 審閱中之標準、指引文件

文件名稱	送審日期
高精地圖更新作業及檢核指引－靜態圖資	110/04/16
自駕車高精地圖輔助與事件資料標準	110/08/06

測繪業者駕駛測繪車進行量測，得到道路的點雲資料，測繪業者再依據規範而製作向量圖層。「高精地圖檢核及驗證指引」規定了高精地圖的向量圖層相關內容，包含空間資訊與屬性資料，如車道邊界、車道曲率、車道標線、交通標誌及號誌等資訊。而「高精地圖圖資內容及格式標準」，則以 OpenDRIVE 標準為基礎而發展，並且依據國內的交通設施法規及應用情境進行內容擴充，例如汽車機車混流、特有的標誌與號誌，稱為台灣高精地圖 OpenDRIVE+Extension，藉此作為車載高精地圖的中介流通格式。

高精地圖產製程序

高精地圖之產製大致可分為四個程序，包括 (1) 外業資料收集；(2) 高精地圖之製作；(3) 品質檢核與驗證；(4) 維護及更新等 [2]。

在外業資料收集方面，具有直接地理定位能力的車載行動測繪系統 (Mobile Mapping System, MMS) 是用來蒐集製作高精地圖所需資料的主要工具，MSS 本身搭載有精密的 INS/GNSS 定向定位整合系統、光學攝影機、及光達掃描儀等多種感測器，其中攝影機所拍攝的影像及光達點雲資料皆隱含有製作高精地圖所需之幾何及語意資訊，而 INS/GNSS 所記錄的定位定向資訊則賦予了前兩項資料精確的空間坐標。在進行外業資料蒐集之前，尚必須實施任務規劃、實地踏勘、控制測量、系統檢測、系統初始對準等作業，以確保所蒐集資料的正確性及品質。

在高精地圖製作方面，主要是從 MMS 所蒐集的影像及光達點雲資料中萃取出道路及各種交通設施之幾何、語意及屬性等資訊，並依據前述標準規範製作成高精地圖之向量圖層。此項工作主要包含四個步驟，如圖 4 所示，包括 INS/GNSS 定向定位資料整合、影像及點雲資料之融合及定位、道路及交通設施等語意特徵之辨識及定位、以及賦予特徵屬性資訊等。其中語意特徵之辨識、定位、以及語意與屬性之賦予大都借助於商業軟體之輔助，以人工方式對高精地圖圖資之各項內容進行數化，圖 5 所示為道路標線及交通號誌之數化成果範例 [3,4]。

高精地圖製作完成後，需進行品質檢核與驗證，以確保所產製之圖資精度及屬性正確性可以符合高精地圖製作規範之要求。此外，高精地圖亦須定期維護

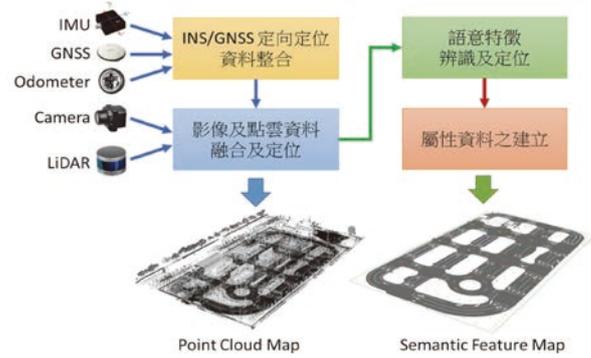
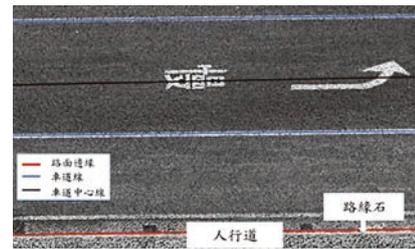
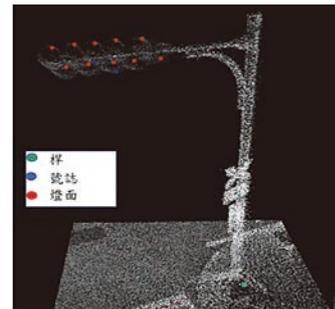


圖 4 高精地圖之製作程序



(a) 車道線、路面邊緣以及車道中心線示意圖



(b) 號誌、燈面、桿數化位置示意圖

圖 5 高精地圖數化成果範例 [3]

及更新，以確實圖資內容能夠呈現道路環境的變化。此兩項作業之詳細內容及工作流程可參考下一篇文章：「高精地圖檢核驗證與更新作業」(第 21-29 頁)。

深度學習應用高精地圖語意特徵之辨識

由上一小節可知，高精地圖的測製是一件非常耗時費力的工作，尤其是在道路相關語意特徵及屬性資料的萃取方面，此通常需要大量的人工判識作業，也使得高精地圖的製作經費相當昂貴。最近許多研究開始探討如何利用機器學習 (Machine Learning, ML) 進行道路資訊的自動化萃取，以提升高精地圖之產製效能 [1,5]。機器學習是人工智慧 (Artificial Intelligence, AI) 的一個分支，其主要模仿人類從經驗中學習的概念，不同的是，機器學習是讓電腦從資料中自我學習，以最佳化的方式找到解決問題的一個最佳解，且無需事先了解太多資料的特性或依賴任何預先建立的模式 [6]，通常用來學習的已知樣本越多，機器學習的效能越佳。

由於光達系統為自駕車上最主要的感測器，如何利用機器學習演算法快速且精確地從光達點雲資料中辨識出上述高精地圖之內容也成為近年來主要的研究議題。為了隨時因應道路環境的變化，同時提升一般機器學習的準確度，製作高精地圖時常採取互動式學習方法 (Interactive Learning)，也就是藉由「Human-in-the-Loop (HitL)」的概念^[5]，讓人可以在適當的時機介入機器學習的歷程，以迭代的方式持續地改善模型的效能，使模型的預測更加精準。理論上，圖 2 所示高精地圖的主要種類 (包含道路線、車道線、交通標誌、交通號誌、標線及物體等) 大都可透過機器學習確定其空間位置、語意及屬性等相關資訊。

點雲資料係由大量不規則分佈的離散點所組成，運用傳統的機器學習演算法進行分類時，須先透過特定的統計規則或幾何限制條件進行手工特徵的萃取 (Handcrafted Feature Extraction)，再從中選出重要的特徵做為點雲分類的依據。然而要建構有用的手工特徵通常需要依賴特定的領域知識或具有豐富的經驗。近年來深度學習 (Deep Learning, DL) 中的卷積神經網路 (Convolutional Neural Networks, CNN) 因具有自動萃取二維影像中局部特徵的能力，在許多應用中已獲得不錯的成果，可以說是最受矚目，也被廣泛使用的一種機器學習方法^[7]。若能將 CNN 應用於光達點雲資料分類，不僅不須光達幾何分布的先驗資訊，也不須事先以人為介入的方式萃取特定的幾何特徵，應可改善點雲分類的準確性，提升點雲分類之效能。

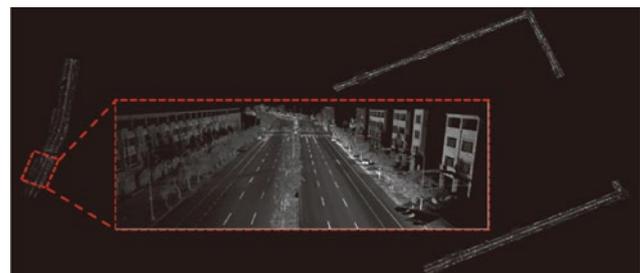
為了測試深度學習應用於高精地圖測製之可行性，本研究採用三種具不同複雜度的深度學習模型進行車載光達點雲資料分類的實驗。第一個為具開創指標性的 PointNet 模型^[8]，其特點是參數少、模型較為簡單、訓練速度快，但對局部特徵的萃取能力較為不足，因此本研究對其進行了改善，於點雲坐標之後加入了特定的手工特徵一起輸入模型中進行訓練，以強化其局部特徵萃取之能力；另外以 PointNet 為基礎而改進的 PointNet++ 模型^[9]為本研究所採用的第二個模型，其透過階層式的架構獲取點雲的局部特徵，雖可提升整體的分類準確度，但需要較多的計算時間。本研究所採用的第三個模型為 KPConv^[10]，不同於 PointNet 與 PointNet++ 利用多層感知器 (mult-layer perceptron, mlp) 進行特徵萃取，KPConv 定義了一個具有空間核 (spatial kernels) 的點卷積 (point convolutions) 直接對點雲進行三維特徵萃取。KPConv 在許多公開的點雲資料集中常獲得最佳的分類成果，但卻必須花更久的時間進行特徵學習。

本研究的實驗資料為台南沙崙高鐵車站附近之車載

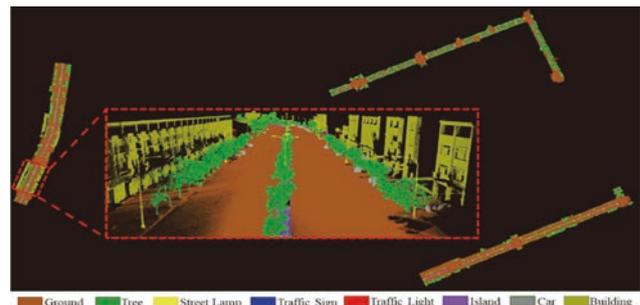
光達點雲資料，其由 Optech Lynx-M1 光達掃描儀掃描而成，點雲密度約為 2000 pt/m²，如圖 6(a) 所示。根據高精地圖之應用目的，該場景的地物可大致區分為八個類別，即地面 (Ground)、樹 (Tree)、路燈 (Street Lamp)、交通標誌 (Traffic Sign)、交通號誌 (Traffic Light)、分隔島 (Island)、車輛 (Car)、以及建物 (Building) 等，如圖 6(b) 所示。本研究即以此八個類別作為分類標的，進行上述三個深度學習模型的訓練及測試。

除了上述三種深度學習模型以外，本研究亦同時測試了隨機森林法 (Random Forest, RF) 及商用軟體 LiDAR360 的機器學習分類工具在點雲分類上之效能。測試成果以總體準確度 (Overall Accuracy)、平均召回率 (Average Recall)、平均精確率 (Average Precision) 及平均 F1-Score 等效能指標繪製直方圖比較，如圖 7 所示。總體來說，傳統機器學習的隨機森林演算法表現最差，接著依序為商用軟體 LiDAR360、加入手工特徵的 PointNet、PointNet++，而 KPConv 則有最佳的表現。

圖 8 為上述點雲分類成果以視覺化的方式呈現，對於地面、樹木及車輛的判識上，各模型都有不錯的表現，其中可看出 LiDAR360 將大量分隔島判識為地面點，將交通標誌分類成車輛，或是將路燈及交通號誌分類成樹木等；而改善後的 PointNet 及 PointNet++ 則明顯地改善大量 LiDAR360 判識錯誤的地方，但兩者還是存在著容易將分隔島誤判為地面點、將路燈及紅綠燈分類成樹木、或是無法正確分類出物體較小且點雲數量少的交通標誌等問題。若與 PointNet 相比，PointNet++ 因考慮更詳細的局部特徵，故比較不會有將



(a) 以強度顯示的原始點雲資料



(b) 以類別顯示的原始點雲資料

圖 6 沙崙車載光達資料

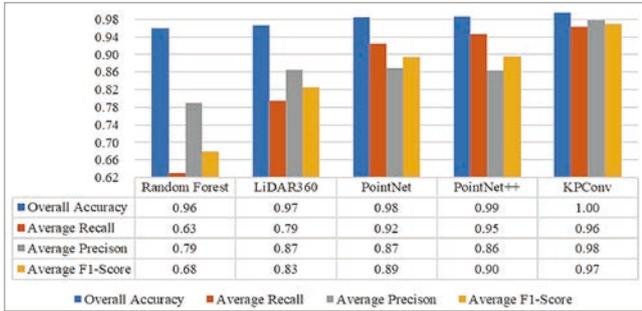
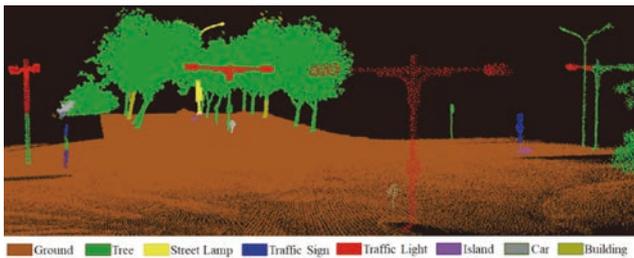
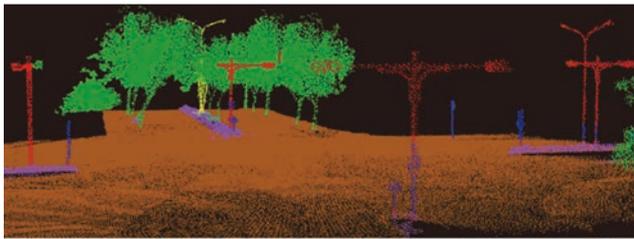


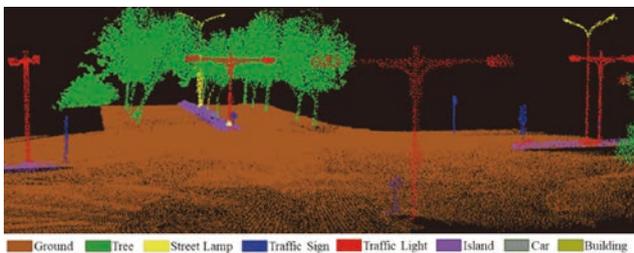
圖 7 不同模型之點雲分類成果比較



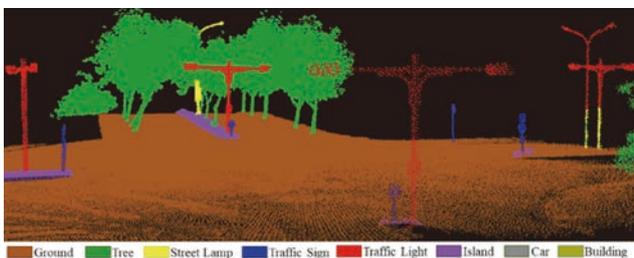
(a) Lidar360 分類成果



(b) PointNet 分類成果



(c) PointNet++ 分類成果



(d) KPConv 分類成果

圖 8 不同模型分類成果之視覺化比較

路燈分類成交通號誌的情形，但在燈桿的判識上，因為形狀都一樣，所以還是存在桿狀區域誤判之情形；最後是 KPConv，其成果不論在分隔島還是交通標誌等各項類別的判識上均呈現最佳的分類表現，但在桿狀物或是孤立建物牆面的判識上還是有少許錯誤，這是未來可以改善的地方。

結論及未來發展

高精地圖係專為自駕車所設計之地圖，主要提供自駕車定位、導航、駕駛決策時之主要參考依據，為了確保自駕車之駕駛安全，高精地圖的內容及精度皆訂有完整且一致的標準及規範。本文首先簡單介紹了高精地圖的內容，並針對國內外高精地圖格式標準及規範之相關發展進行了說明，此外也簡單描述了高精地圖之測製及作業程序。為了提升高精地圖產製之作業效能，本研究嘗試應用深度學習演算法對點雲資料進行分類，以萃取出具有語意及屬性資訊的道路特徵，實驗結果顯示深度學習確實可以達到自動萃取出道路語意特徵的目的，但仍有改善的空間。

未來除了持續優化深度學習網路架構以提升道路語意特徵萃取之效能外，也可嘗試以機器學習演算法進行自駕車上各種感測器之資料融合、點雲套合、自駕車定位、及駕駛行為自動決策等工作。此外，高精地圖除了提供自駕車使用之外，未來亦可作為交通及道路資訊管理、維護、及規劃等之重要參考圖資。

參考文獻

- Chen, S., Liu, B., Feng, C., Vallespi-Gonzalez, C., Wellington, C., (2021). 3D Point Cloud Processing and Learning for Autonomous Driving: Impacting Map Creation, Localization, and Perception. IEEE Signal Processing Magazine 38, 68-86.
- 台灣資通產業標準協會 (2019)，高精地圖製圖作業指引 v2，TAICS TR-0010 v2.0。
- 台灣資通產業標準協會 (2020a)，高精地圖檢核及驗證指引，TAICS TR-0016 v1.0。
- 台灣資通產業標準協會 (2020b)，高精地圖圖資內容及格式標準 v.1.1，HD MAPS TS-0011 v.1.1。
- Jiao, J. (2018). Machine Learning Assisted High-Definition Map Creation, 2018 IEEE 42nd Annual 7. Computer Software and Applications Conference (COMPSAC). IEEE, Tokyo, Japan.
- Sarkar, D., Bali, R., Sharma, T. (2018). Practical Machine Learning with Python: A Problem-Solver's Guide to Building Real-World Intelligent Systems. Apress, Berkeley, CA.
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep Learning. Nature 521, 436-444.
- Qi, C.R., Su, H., Kaichun, M., Guibas, L.J. (2017a). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017). IEEE, Honolulu, HI, USA, pp. 77-85.
- Qi, C.R., Yi, L., Su, H., Guibas, L.J. (2017b). PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space, in: Guyon, I., Luxburg, U.V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., Garnett, R. (Eds.), 31st International Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA, pp. 5105-5114.
- Thomas, H., Qi, C.R., Deschaud, J.-E., Marcotegui, B., Goulette, F., Guibas, L. (2019). KPConv: Flexible and Deformable Convolution for Point Clouds, 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea (South), pp. 6410-6419.