

# 高精地圖標準及智能移動測繪技術發展工作案(109-110)

## High Definition Map Standard and Intelligent Mobile Mapping Technology Development Project (109-110)

主管單位：內政部地政司

江凱偉 <sup>1</sup>	曾義星 <sup>1</sup>	莊智清 <sup>2</sup>	洪榮宏 <sup>1</sup>
Kai-Wei Chiang <sup>1</sup>	Yi-Hsing Tseng <sup>1</sup>	Jyh-Chin Juang <sup>2</sup>	Jung-Hong Hong <sup>1</sup>
郭重言 <sup>1</sup>	王驥魁 <sup>1</sup>	呂學展 <sup>1</sup>	郭佩茶 <sup>1</sup>
Chung-Yen Kuo <sup>1</sup>	Chi-Kuei Wang <sup>1</sup>	Hsueh-Chan Lu <sup>1</sup>	Pei-Fen Kuo <sup>1</sup>

<sup>1</sup> 國立成功大學測量及空間資訊學系

<sup>2</sup> 國立成功大學電機工程學系

### 摘要

測繪與空間資訊相關應用領域，由於移動測繪系統的機動性、多元感測資訊以及對數位影像處理與蒐集的能力，可以明顯節省過去傳統測量所需要的人力及時間。故除了傳統的空間資訊與測繪應用以外，隨著移動裝置的普及、無人載具的發展與自駕車技術的研究，預期結合現有移動測繪技術、室內圖資建置技術、物聯網空間資訊應用將有效支撐適地性服務急速擴張的需求，這對深化空間資訊領域產業的發展有正面的助益。另一方面，隨著智慧型運輸系統的發展，自動駕駛汽車成為未來全新的交通方式。自駕車用地圖在自駕車運行具有不可或缺之地位，提供自駕車決策系統輔助，降低技術門檻及所需經費，並且提升安全性。國內已累積多年發展與應用車載移動製圖技術之經驗，並具備成熟的資料處理技術，惟對於產製自駕車用高精地圖並無統一標準製作程序、精度規範與地圖格式，恐會造成廠商格式不相符無法流通，導致重複資源投入並衍生行車安全與國安議題。

本案在內政部支持下持續推動高精地圖標準及智能移動測繪技術發展，並獲致相當之成果，於本案能夠在既有成果上持續更進一步探討，並往應用面推廣，本案於過去二年中如實如質與如期完成包含下列與新一代測繪技術相關之議題。建立高精地圖標準及指引項目中，持續修正高精地圖圖資內容標準、製圖作業指引及驗證流程指引並發布作業指引英文版，建立自駕車用動態地圖之圖資內容標準(草案)、作業指引(草案)及更新驗證指引(草案)，並將草案內容提送臺灣資通產業標準協會。發展高精地圖自動化生產及群眾外包製圖技術項目中，發展高精地圖自動化生產技術，開發自動化工具，針對路面邊緣、車道線、車道中心線、交通號誌與特定交通標誌圖徵進行特徵提取，建立自駕車群眾外包之高精地圖製圖(含自駕車平臺)系統及流程，完成針對特定交通號誌與交通標誌的變異偵測與更新，並確定製圖系統符合動態更新使用。發展移動裝置室內外智慧製圖技術項目中，研發應用人工智慧技術之室內外影像匹配輔助行人慣性導航定位技術，提出誤差修正算法，最佳的角度

分群法可以使得位置誤差下降約 20%。高精地圖國際事務推動項目中，參與國際自駕車相關組織活動與國際學術研討會，持續研提或協助引進國外產製高精地圖之多平臺製圖技術，推廣我國高精地圖相關事宜。

**關鍵詞：**移動測繪系統、高精地圖、群眾外包、行人慣導定位、人工智慧

### **Abstract**

In the application related to surveying and mapping, the mobile mapping systems can significantly save the workforce and time required. Based on hardware improvements, mobile sensors are becoming more diverse, smaller, and cheaper, while the accuracy is improving. On the other hand, with intelligent transportation systems, autonomous vehicles have become a new way of transportation in the future. The map for autonomous vehicles is indispensable in the operation of autonomous vehicles. It assists in autonomous vehicle decision-making systems and lowers the technical threshold. High-definition maps (HD maps) for autonomous vehicles mainly rely on the onboard sensors to obtain point clouds and images and is produced through feature extraction and manual assistance methods. However, if there is no unified standard production process, specification, and map formats for producing HD maps for autonomous vehicles, it may cause inconsistent format issues, resulting in unnecessary resource investment and safety issues of autonomous vehicles.

This team has promoted the development of HD map standards and mobile mapping technology with the Ministry of the Interior's support and has achieved significant results. It is expected that this project can continue to explore the existing results further and promote them to the application side, including the following and new issues related to the next generation of surveying and mapping technology. In establishing HD map standards and guidance projects, continue to revise the high-precision map standards, mapping guidelines, and verification process guidelines and publish the English version standards and guidelines. Meanwhile, the drafts of dynamic map standards, production guidelines for dynamic maps, and the verification and update guidelines of dynamic maps for autonomous vehicles will be proposed in this project. They were all submitted to TAICS for reviewing and publishing procedure. In developing automated HD map production and crowdsourcing mapping technology projects, develop automated HD map production technology, develop automated mapping tools to extract the features, such as road edges, road lines, road center lines, traffic signs and specific traffic signs. In establish certified crowdsourcing of HD map updates systems and procedures, complete changing detection and update for specific traffic signs and traffic signs. In developing indoor and outdoor intelligent mapping technology for mobile devices, research and development of indoor and outdoor image matching assisted pedestrian inertial navigation technology using artificial intelligence technology, and propose an enhancement algorithm, which can reduce the position error by 20%. In the HD map

international affairs promotion project, participate in international self-driving-related organizations, attending virtual international academic conferences, continue to research or assist in introducing international HD map technology, and promoting Taiwan's HD map developments.

**Keywords : Mobile mapping system, High definition map, Crowdsourcing, Pedestrian inertial navigation indoor positioning, Artificial intelligence**

## 一、前言

配合國家科技發展重點政策，落實測繪及空間資訊科技自主化，內政部地政司於民國 101 年至 107 年先後執行「多平台製圖技術工作案」與「移動載台測量製圖技術發展工作案」，在國內既有測繪技術基礎上，擴大各項測繪相關技術之本土研發面向，並深化自主性研究能量，厚植測繪軟硬體實力，最終目的乃在輔助國家經濟建設與社會貢獻產出。藉由辦理相關成果發表會議及協助推動國際測繪合作事務，以擴大空間測繪技術流通應用，並以科學外交形式輔助國際事務媒合，以期於本案研究推動下培養國內科技專業人力累積移動測繪之技術能量，同時協助我國產業轉型技術服務輸出營利模式，帶動整體空間資訊產業之創新與發展。

隨著智慧型運輸系統(Intelligent Transport System, ITS)的發展，自動駕駛汽車成為未來全新的交通方式。我國因具備車電產業基礎且感測系統供應鏈完備，極具發展自動駕駛技術車輛潛力；為因應世界發展自駕車潮流，我國也積極研發自駕車相關「感知」、「決策」、「控制」關鍵技術，期盼能逐步實現自駕系統國產化願景，促使臺灣成為全球自動駕駛次系統關鍵產業鏈及服務技術輸出國，其中自駕車用地圖或稱高精地圖在自駕車運行具有不可或缺之地位，高精地圖的資料包含豐富且準確的場景語義資訊、即時路況資訊及駕駛經驗訊息用以輔助環境感知、車輛定位與規劃控制，實現當前情況下最優駕駛策略，提供自駕車決策系統輔助，降低技術門檻及所需經費，並且提升安全性。

易言之，本案除基於「108 年度自駕車用地圖標準及移動測繪技術發展工作案」既有延續研究工項外，將持續探討自駕車用動態高精地圖標準、利用人工智慧精進自駕車用地圖製圖技術、建置自駕車用地圖圖資管理及供應機制、提升自駕車定位精度、進行高精地圖檢核及品質管控、發展室內外智慧化製圖技術，期望透過本工作案完成高精地圖標準及作業流程指引、發展高精地圖自動化生產及群眾外包製圖技術、高精地圖國際事務推動、發展移動裝置室內外智慧製圖技術，以提升自駕車用高精地圖產製的效率及正確性，同時及早制定標準有助於我國自駕車用高精地圖之產業規格統一，達到資源共享的願景，更藉由本案持續參與世界自駕車的相關國際組織，進一步確保本案所建立之高精地圖地圖標準符合實際需求並與國際接軌，以利我國產業及早進行自駕車測試及前瞻技術布局，未來政府單位評估組建國家級圖資產業聯盟具有正面助益。

## 二、研究地區與研究方法

本案工作項目可分為「高精地圖自動化生產及群眾外包製圖技術」以及「移動裝置室內外智慧製圖技術發展」兩大部分。首先，「高精地圖自動化生產及群眾外包製圖技術」即透過整合來自多台自駕車分別運行於不同路線的物件偵測結果，來提升高精地圖變異物件辨識的準確率，並於臺南沙崙地區進行適地性服務案例試辦；再者，「移動裝置室內外智慧製圖技術發展」研發應用人工智慧技術之室內外影像匹配輔助行人慣性導航定位技術，結合現有多平台移動測繪技術、室內圖資建置技術、物聯網、穿戴裝置等，組成綿密的空間資訊應用網格，提升室內定位成果，也基於此定位技術開發更完善的適地性服務。

## 2.1 高精地圖自動化生產及群眾外包製圖技術

在 LDM (Local Dynamic Map) 中之靜態地圖為當前製圖之重點，必須符合高精地圖之需求：須達到平面 20 公分且三維 30 公分之精度、建置於三維空間中、豐富道路資訊、與現實世界等比例建置。這類高精地圖之變異情形較低，因此更新頻率的需求也相對較低。為了獲取高精度之環境資訊，現今製圖作業多以高精度定位定向移動式測繪系統(Mobile Mapping System, MMS)掃瞄施測場域，獲取感測器採集之空間資訊，如軌跡、影像、光達點雲，經由資料前處理後，必須先進行資料精度檢核之驗證程序，確保由測繪業者掃瞄之資料滿足高精地圖製圖作業指引之精度要求，進而透過人工數化程序，完成高精度的圖資產製作業程序。利用移動式測繪平臺技術能快速且有效率的處理龐大的空間資訊，然而人工數化的過程往往需要耗費數月以及投入龐大人力資源才得以完成，倘若施測範圍越大，所需耗費的人力及時間資源也越多，間接造成圖資更新的困難。為了提升高精地圖產製效率且降低更新成本，勢必要發展自動化產製高精地圖的工具，最後再經由人工編修的方式確保圖資的正確性，然而現實世界中的道路環境複雜且存在差異性，因此本團隊針對特定需耗費大量人力的圖徵進行自動化產製，其餘圖徵則以人工方式產製，以降低後續人工檢核修正的成本。因此高精地圖生產流程如圖 1 所示，可以區分成環境資料採集、自動化與人工產製道路環境圖徵、產製成果之檢核及驗證程序，最後再依據終端使用者所需之高精地圖格式進行圖資格示轉換，目前國內推動基於 OpenDRIVE 格式訂定的臺灣高精地圖標準，以其作為國內統一的高精地圖格式，各家車廠能開發圖資轉換工具，將臺灣高精地圖格式轉換成車廠自駕車可使用的地圖格式，其中國內車廠使用的圖資格式以 Autoware 為大宗，故本工項開發自動化生產符合 OpenDRIVE 與 Autoware 圖資格式之高精地圖工具，以利自動駕駛技術之發展。綜合上述所及，本團隊利用測繪車採集的感測器資訊，針對特定圖徵，包含路面邊緣、車道線、車道中心線、交通號誌、交通標誌，半自動化產製工具開發，另一方面，本團隊邀請詮華國土測繪有限公司以及興創知能股份有限公司進行自動化生產符合 OpenDRIVE 與 Autoware 圖資格式之高精地圖工具研發，雙方合作同意書參閱附錄七，同時本團隊與日本名古屋大學 Dr. Hatem Darweesh 研究團隊，合作開發圖資格式轉檔工具及圖資轉檔服務事項，並完成特定場域之高精地圖格式轉檔測試。



圖 1、高精地圖生產流程圖

於半自動化高精地圖產製工具，本團隊從測繪車採集的道路環境感知資訊，包含點雲與影像資訊，自動化萃取特定道路元素，包含路面邊緣、車道線、車道中心線、交通號誌與特定交通號誌，開發針對特定道路元素之高精地圖產製工具，提供讓使用者淺顯易懂的操作介面，提升高精地圖產製效率。演算法可概略分成地面特徵與非地面特徵兩類，於地面特徵物(如：路面邊緣、車道線)處理方面，本團隊參考 Yadav 等人(2017)提出的演算法，於沙崙臺灣智駕測試實驗場之路段進行車道線萃取，採集測試區之點雲資料為使用 RIEGL VMX-250 移動式測繪系統獲取點雲密度符合高精地圖製圖作業指引中  $400 \text{ pt/m}^2$  的需求，臺灣智駕測試實驗場全區的萃取成果如圖 3 所示，由於柏油路面的點雲強度值較低，可先利用強度值濾波器獲取柏油路面，接著基於局部區域生長濾波演算法(Region growing-based filtering)得到路面範圍(圖 3 (a))，上述過程為了定義路面範圍會先將強度值高的點雲(如：路面標記)剔除，因此必須進行路面點雲還原(Road point recovery)，如圖 3(b)所示，根據上述步驟能大幅減少非路面點雲的干擾，獲取更準確的路面標記，有利於後續特徵物之建模，有了完整的路面資訊後，即能定義路面邊緣的位置，如圖 3 (d)所示。為了獲取車道線，必須將萃取之路面標記進行分類，然而點雲相較於影像缺乏視覺屬性的資訊，因此本團隊使用 510 張臺灣智駕測試實驗場的影像進行特徵標記，進而利用 Unet 深度學習演算法將車道線分成白線與黃線兩種類別，以此模型進行影像辨識，並將辨識後之影像屬性賦予上述處理後之路面標記點雲上，圖 2 為標記影像與模型辨識成果示意圖，表 1 則為 Unet 於 100 張測試影像的辨識精度，可以發現在 Precision 的成果都可以達到 88% 以上，但是 Recall 的成果相對來說較低，有鑑於提升模型訓練成果並降低非目標物之雜訊干擾，只保留路面範圍的影像作為訓練模型的來源，因此當預測整幅影像時，會造成非地面物的誤判如圖 2(b)之紅框所示，此外由於指向線的特徵和白實線相似，故也會有誤判的情形，但上述這些問題都能藉由結合點雲分類後的路面標記之幾何資訊排除誤判的情形，將路面標記區分成黃色車道線、白色車道線、指向線、斑馬線、停止線等。由於萃取的車道線點雲為由一系列點雲組成的線形特徵物，這些點雲必須經過疏化並利用數學式進行擬合，除了能降低圖資的資料量，也有助於後續產製特定高精地圖格式圖資之程序，圖 3(c)展示疏化後附含屬性資訊的車道線，圖 3(c)中黃色代表白色車道線、紅色代表黃色車道線、藍色則代表影像辨識後不屬於車道線的點雲。

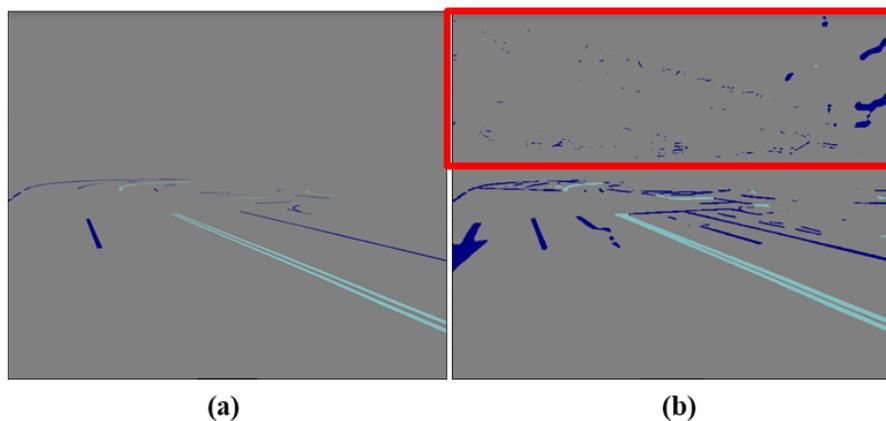


圖 2、(a)Unet 車道線影像標記真值；(b)Unet 預測成果

表 1、Unet 車道線預測精度

Index	白實線	黃實線
Precision	95.4%	88.1%
Recall	23.7%	58.5%

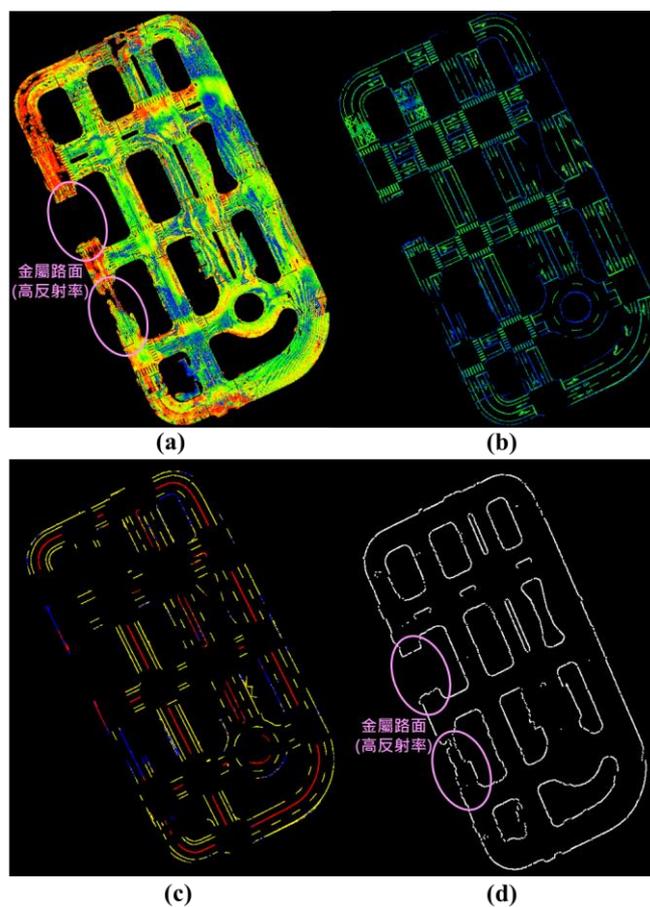


圖 3、臺灣智駕測試實驗場全區的萃取成果：(a)路面點雲；(b)經點雲還原演算法得到的路面標記點雲；(c)疏化後的車道線；(d)路面邊緣

從圖 3 成果中可以發現路面標記大部分皆能被完整保留，車道線的線型也很清晰，有利於後續資料擬合，但是其中有些路面因為鋪面為金屬材質，其反射率很高，如圖 3(a)中圓圈標記處所示，導致進行強度值濾波時無法有效保留此塊路面，進而導

致此處的路面標記遺失。同理，此處的路面邊緣也會因為路面不完整導致路面邊緣缺漏，另一方面，(c)中這些沒有屬性的點雲也發生在前述提及之金屬路面的位置，這是因為此區的影像嚴重曝光導致辨識成果不佳，但整體而言，測試區的车道線都能被完整萃取，至於车道線遺漏的部分，仍可透過拟合演算法彌補，藉由相鄰路段的车道線資訊，利用三次樣條插值(Cubic Spline Interpolation)演算法進行拟合，以補足缺失的路段。圖 4 展示的是經拟合之车道線套疊驗證後的高精地圖成果，雖然紅框註記的位置因為路面標記較為複雜或是停止線和车道線沒有完全分割，導致部分车道線成果有缺漏或不理想，但整體车道線拟合的成果和高精地圖的向量圖是吻合的。有了车道線拟合的資訊後，即可透過任兩條车道線進行內插，產製中心線成果，如圖 5 所示。從成果可以發現紅色標記位置的中心線有缺漏，這是來自於车道線拟合成果的影嚮，因此中心線和车道線的成果是相輔相成。

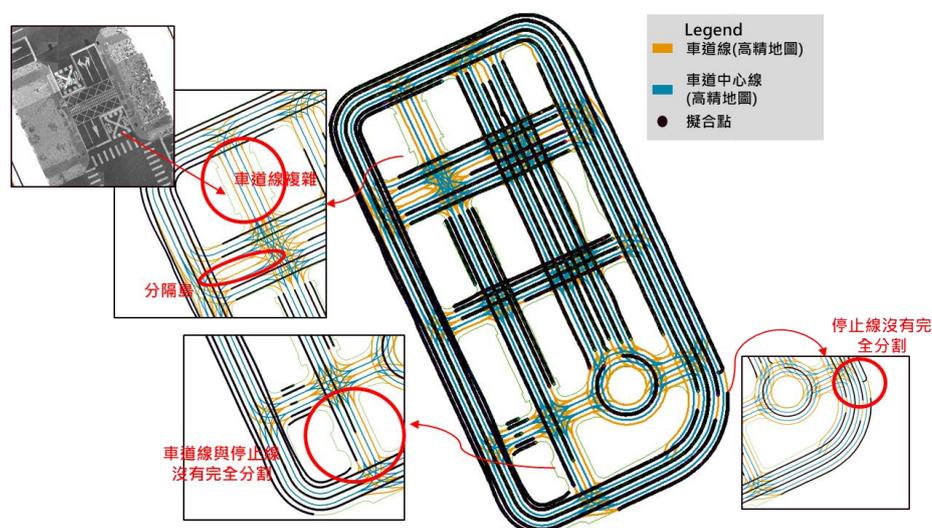


圖 4、车道線拟合成果套疊高精地圖

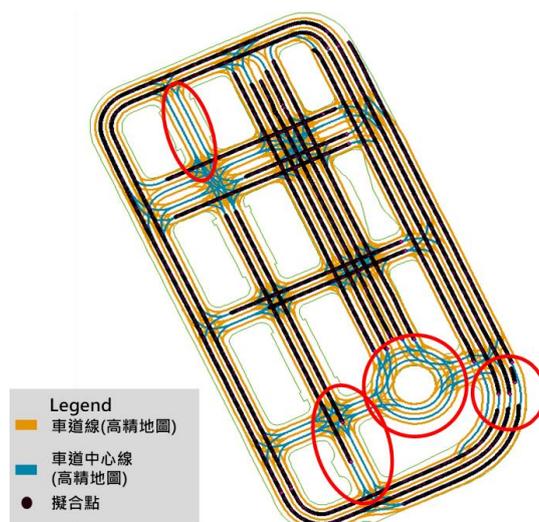


圖 5、中心線內插成果套疊高精地圖

從上述圖 4 與圖 5 的成果可以發現尚未處理交叉路口處線段連接的問題，經評估

後原本使用的三次樣條插值(Cubic Spline Interpolation)演算法不適用於路段連接的線型，故改採用 B-spline 演算法處理路口連接線，其演算法的概念是透過給定的控制點控制線段的彎曲程度，於本案的應用中可以藉由欲連接的兩條路口線段生成控制點，來建立兩線段的連接線已完成路口的接合，B-spline 於路口的連接示意圖如圖 6(a)所示，最後連接成果如圖 6(b)所示，其中左圖的白色線為實際透過沙崙測試場點雲線段的連接成果，右圖則為連接線段與高精地圖套疊的成果。

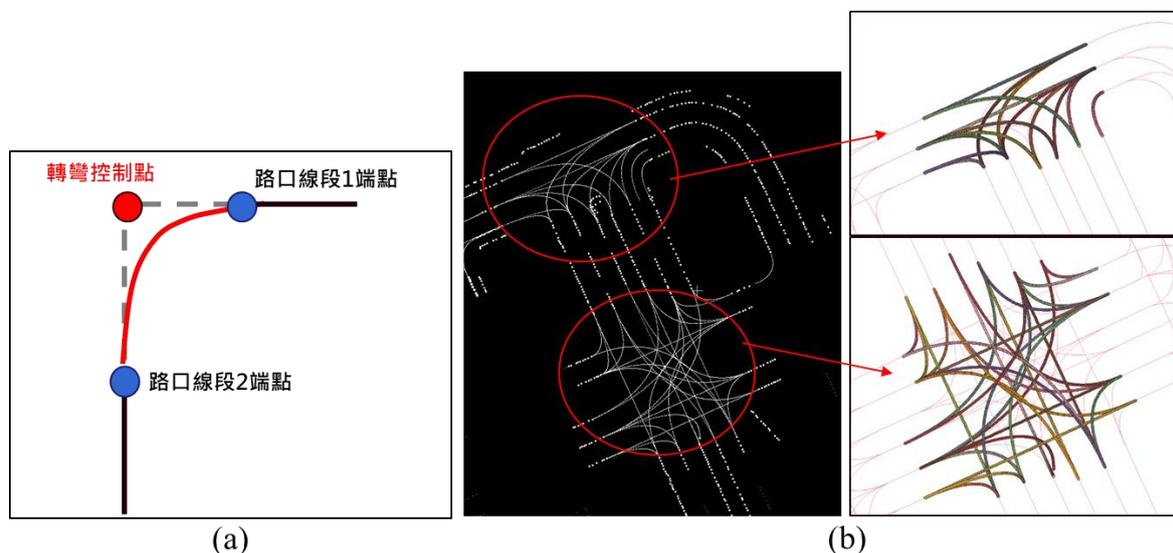


圖 6、路口線段接合成果：(a)B-spline 路口接合示意；(b)路口線段連接成果示意圖

另一方面，將圖 3(d)的路面邊緣萃取成果進行擬合，成果如圖 7 所示，圖中紅色框註記之處為路面萃取不完整所導致擬合錯誤或遺漏的區塊，但整體來說，一般道路情境下的路面輪廓都能被很好的提取。

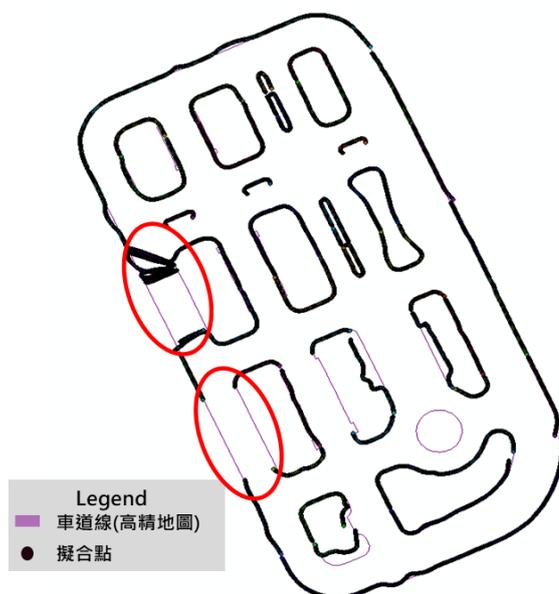


圖 7、路面邊緣擬合成果套疊高精地圖

排除因為路面材質導致路面缺漏之問題，將經過檢核之高精地圖視為真值，並進行精度分析，表 2 為車道線、車道中心線與路面邊緣之三維精度成果，從表中可以得

知於車道線與車道中心線的成果皆符合高精地圖定義之精度需求，然而路面邊緣的精度卻明顯下降，這是因為此場域之路面邊緣較不如車道線為明顯清晰的特徵，會受到雜草、泥土之雜訊導致部分區域擬合情形不佳，以至於整體精度下降，針對此問題未來可以嘗試相關雜訊剔錯之演算法以提升路面邊緣的精度。

表 2、地面特徵擬合成果之精度分析表

	車道線	車道中心線	路面邊緣
Mean	0.116 m	0.078 m	0.455 m
RMSE	0.203 m	0.110 m	0.744 m
Max error	1.196 m	0.866 m	3.095 m

於半自動化高精地圖工具之非地面特徵的部分，由於單靠點雲資訊無法進一步獲取交通標誌的語義資訊，因此結合了影像辨識的演算法，協助交通號誌與交通標誌的萃取，首先利用高程濾波濾除地面點雲資訊，僅保留非地面點雲加速運算處理，接著利用強度值濾波，去除不屬於號誌與標誌的雜訊點雲，再利用歐幾里得群聚法將點雲進行分群，完成點雲預處理步驟，接著透過相機內、外方位參數資訊將點雲投影至經辨識後的影像上，以獲取點雲分群的屬性資訊，最後再依照高精地圖標準中所訂定之規範產出所需之資訊，產製包含標誌與號誌的中心點坐標、屬性的向量圖層，圖 8 錯誤! 找不到參照來源。為從交通號誌與標誌點雲中萃取的中心點成果。

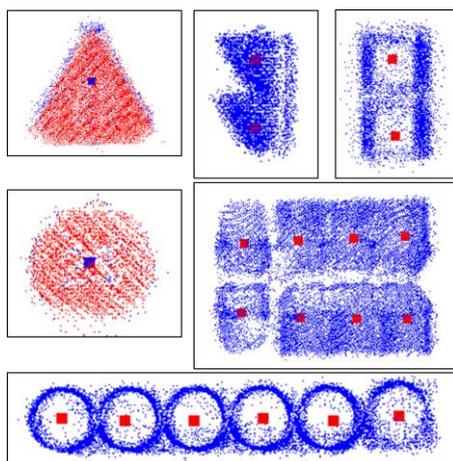


圖 8、交通號誌與交通標誌中心點萃取成果

為了讓使用者能更直觀且有效率的產製高精地圖，本團隊將上述提及的萃取與擬合演算法包裝成半自動化高精地圖產製工具，並進行工具的功能優化，其介面如圖 9 所示。圖 9(a)為非地面特徵產製工具介面，圖 9(b)則為地面特徵產製的介面，萃取後的成果皆可從「檢視成果」開啟成果存放的資料夾位置，進一步檢視成果，其中執行完地面特徵萃取的步驟後可進行擬合程序。圖 10 為將萃取成果進行擬合的介面，可以從介面上的小視窗選擇欲擬合的線段，並提供檔名輸入欄位讓使用者進行成果命名，車道線擬合後即可進行中心線內插的步驟，其視窗會顯示先前擬合完成的車道線，提供使用者選取任兩條車道線進行內插，最後即能獲取中心線，此外車道線與車道中心線也提供路口連接的功能，以補足路口線段。

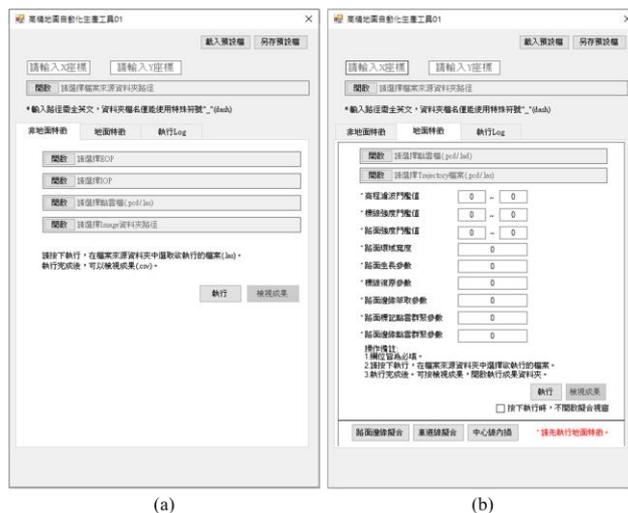


圖 9、自動化高精地圖產製工具特徵萃取介面-I

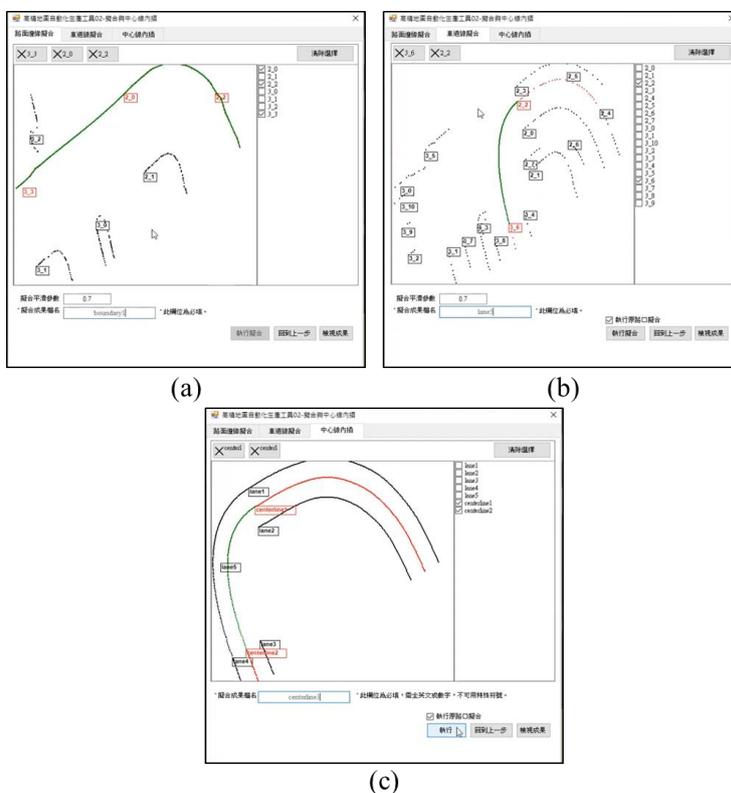


圖 10、自動化高精地圖產製工具特徵萃取介面-II：(a)路面邊緣擬合；(b)車道線擬合；(c)中心線內插

為了讓此高精地圖產製工具更符合使用者需求，本團隊邀請兩家測繪廠商進行此工具的測試，並針對工具的介面、演算法適用性、人力與時間成本進行工具修正建議與未來改進的方向，本團隊根據測繪廠商的建議進行工具的修正，並提出此工具未來可持續優化的策略，修正後介面如圖 11 所示。綜合測繪廠商測試之回饋以及本團隊針對演算法本身自動化的程度，演算法本身自動化程度約為 80%，除了線型擬合的部分需人工介入，其餘演算法皆以自動化方式完成，然而考量後續仍須經由人工修正位置與屬性資訊的程序以確保圖資的正確性，本團隊評估此自動化工具之自動化程度對於

製圖程序約提升 40%。

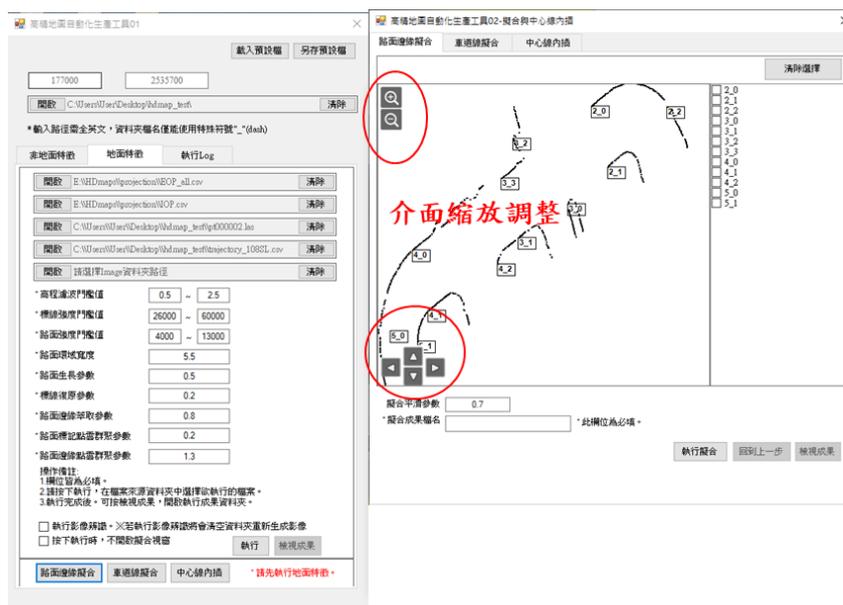


圖 11、自動化高精地圖產製工具介面功能修正

於高精地圖圖資格轉換工具，本團隊與日本名古屋大學 Dr. Hatem Darweesh 研究團隊合作開發高精地圖圖資格轉檔工具及圖資轉檔服務，針對臺灣智駕測試實驗室與臺中水湳兩個自駕車測試場的 OpenDRIVE 圖資進行圖資格轉換，其圖資轉檔工具可支持多種地圖格式，包含 OpenDRIVE、Google earth kml、kml、Lanelet2、vector map，圖 12 為轉檔工具介面展示與兩處自駕車試驗場的 OpenDRIVE 圖資展示圖，從介面上點選圖資節點或線形可以獲取詳細的位置與屬性資訊，透過轉檔工具將兩處測試場圖資轉換成 Google earth kml 格式的成果如圖 13 所示，此外為了提供目前車端上常用的圖資，利用此工具將 OpenDRIVE 轉換成目前 Autoware 支援的 Lanelet2 格式，可再進一步轉換成舊版 Autoware 使用的 vector map，轉檔成果如圖 14 與圖 15 所示，藉由圖資轉檔工具能快速且有效率的將高精地圖轉換成所需要的格式，滿足不同使用者的需求。

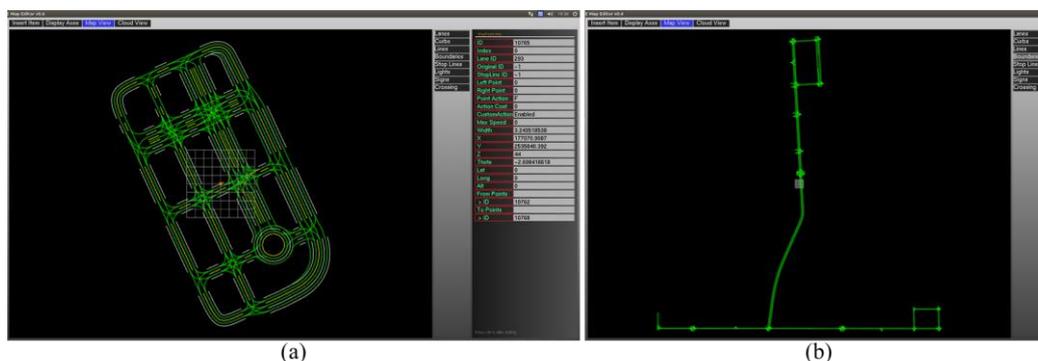


圖 12、圖資轉檔工具介面與 OpenDRIVE 地圖展示：(a)臺灣智駕測試實驗室；(b)臺中水湳測試場

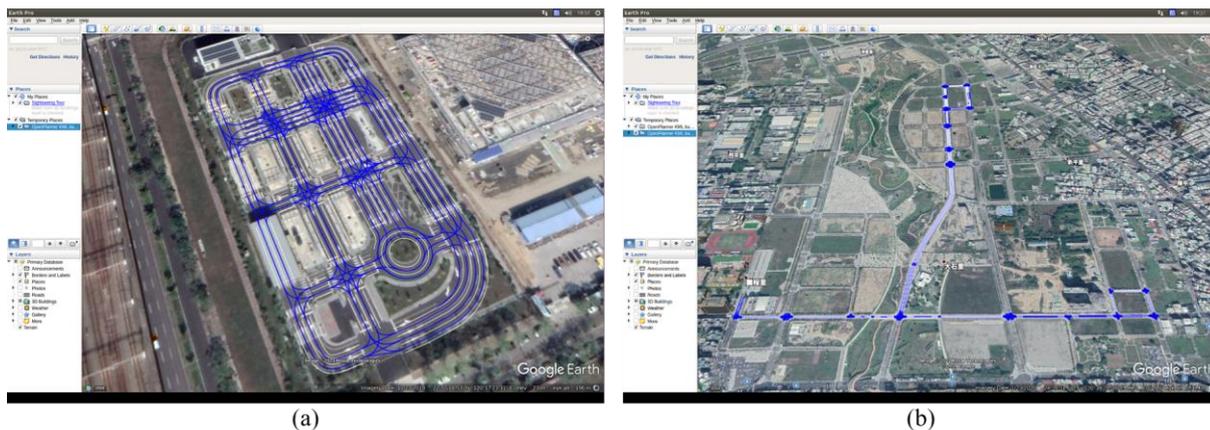


圖 13、轉檔後的 Google earth kml 圖資：(a)臺灣智駕測試實驗室；(b)臺中水湳測試場

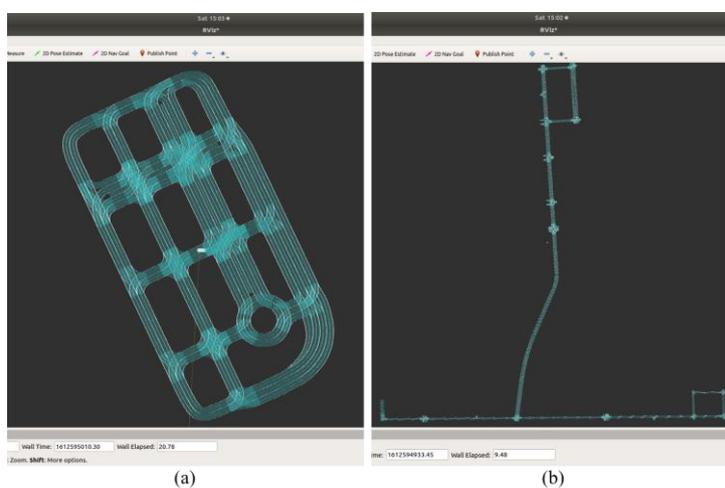


圖 14、轉檔後的 Lanelet2 圖資：(a)臺灣智駕測試實驗室；(b)臺中水湳測試場

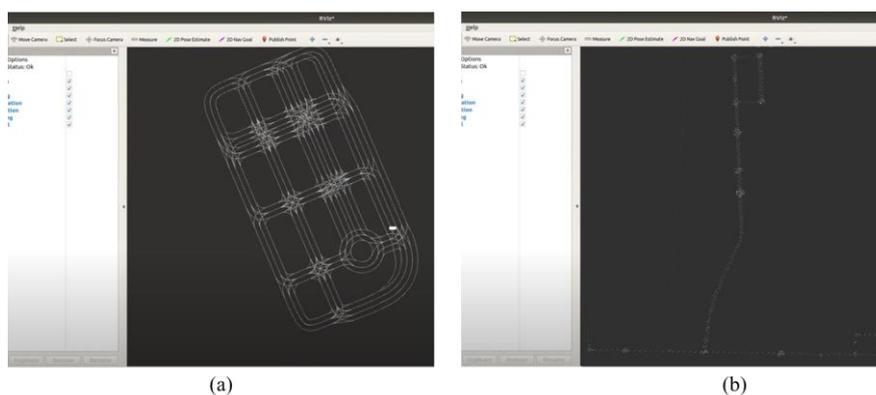


圖 15、轉檔後 vector map 圖資：(a)臺灣智駕測試實驗室；(b)臺中水湳測試場

自駕車群眾外包即透過整合來自多台自駕車分別運行於不同路線的物件偵測結果，來提升高精地圖變異物件辨識的準確率。具體而言，可藉由自駕車收集到的感知資訊進行自動化的物件偵測，並與已建置的靜態高精地圖進行比較以達到變異物件辨識的目的。然而，由於感測器觀測視野、物體遮蔽及物件偵測演算法的限制，單一自駕車無法完整且準確地偵測道路上所有的目標物件，而導致錯誤的變異物件辨識結

果，也因此本案引入群眾外包技術來克服上述問題，圖 16 所示為自駕車群眾外包進行高精地圖變異物件辨識及更新之流程。

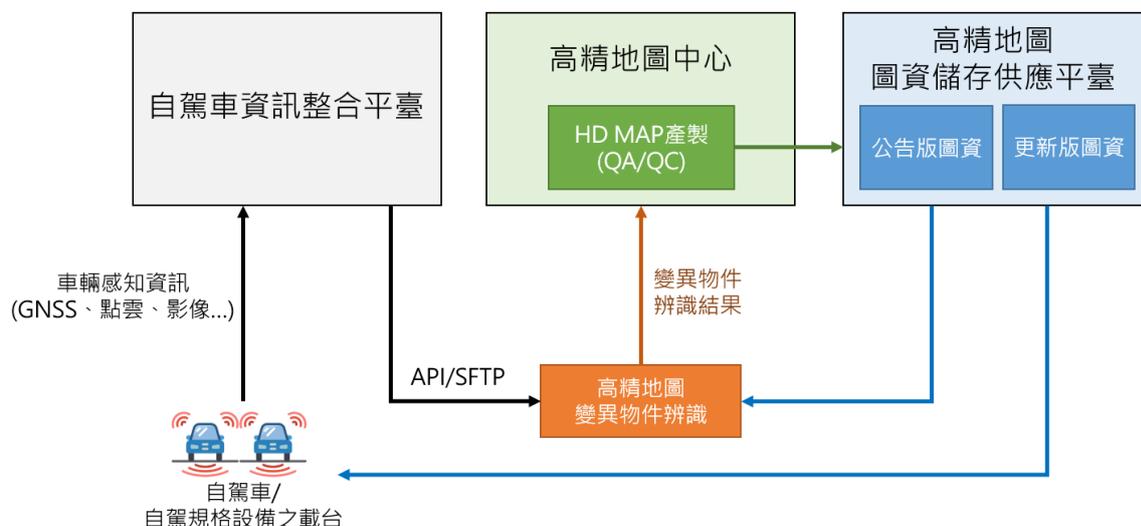
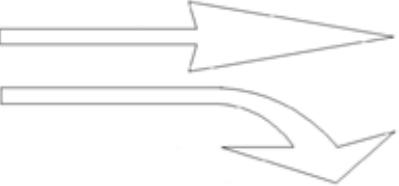
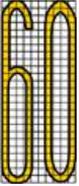


圖 16、靜態高精地圖變異物件辨識及更新流程

為確保偵測成果達一定準確度以符合動態更新使用，本案採用認證第三方車輛進行資料蒐集，此處「第三方」即本案所提之「群眾」，其概念表示對於自駕車或同等規格之資料採集車，其感測器規格、率定精度等須符合相關訂定規範，才可用於進行圖資更新。未來除自駕車或自建車隊外，已具有一定規模且營運中的車隊皆可作為認證第三方之資料採集車，如物流業者、計程車、公車等，這些車隊不受自駕車行駛場域限制，可加大地圖更新範圍與頻率，是較有潛力之群眾對象。表 3 為本案辨識之物件類別，包含紅綠燈、行人穿越燈、限制標誌、禁止標誌、警告標誌、指向線、車道標線中的「虛線」及標字中的「速限」等八種類別，各個類別皆會融合影像及點雲得到最終辨識成果。

表 3、本案辨識類別

類別 (資料來源)	圖示	說明
紅綠燈 (影像及點雲)		以橫向且圓形的紅綠燈為主。
行人穿越燈 (影像及點雲)		以直向且方形的行人穿越燈為主。
限制標誌 (影像及點雲)		以紅色外框的圓形標誌為主，包含限速、限高等。

類別 (資料來源)	圖示	說明
		
禁止標誌 (影像及點雲)		以紅色外框且有斜線的圓形標誌為主，包含禁止停車與禁止轉彎等。
警告標誌 (影像及點雲)		以紅色外框的三角形標誌為主，包含當心行人與轉彎提醒等。
指向線 (影像及點雲)		車道上之白色箭頭。
車道標線(虛線) (影像及點雲)		包含行車分向線(黃虛線)、車道線(白虛線)。
標字(速限) (影像及點雲)		路面速限標字。

目前自駕車的感知資訊主要為影像及光達點雲，其中點雲雖然可提供目標物件的三維坐標以及強度值資訊，但由於點雲密度較為稀疏，因此不足以識別所有的目標物；另一方面，影像雖然具備光達所缺少的視覺屬性而可以進行物件的辨識與分類，但卻無法提供準確的三維坐標訊息。因此，本團隊認為僅有結合影像及點雲的處理結果、融合兩者的優點，才能達到物件辨識及變異偵測的目的。而在相關文獻中，主要可分為兩類融合方法：基於影像或基於點雲的方法。

影像處理部分，本案透過類神經網路辨識紅綠燈、行人穿越燈、限制標誌、禁止標誌、警告標誌、指向線及速限標字這七種類別。至於車道標線，由於細長形目標不適合以類神經網路為基礎的物件辨識模型進行偵測，故針對此類別本案使用其他影像

處理如 Canny 邊緣偵測、霍夫測線法(Hough Lines)等技術進行處理。

現今使用類神經網路進行物體偵測已非常普遍，包含 Mask R-CNN、YOLO 等網路，其目的除了對影像進行辨識與分類，也能標示出該物體在影像中的相對位置，因此於影像處理方面，本案使用 Mask R-CNN 類神經網路來偵測自駕車系統畫面上之紅綠燈以及交通標誌等，將這些物件進行類別辨識並且在畫面上標示，完整過程包含資料蒐集、資料處理、模型訓練、實際測試，如圖 17 所示。

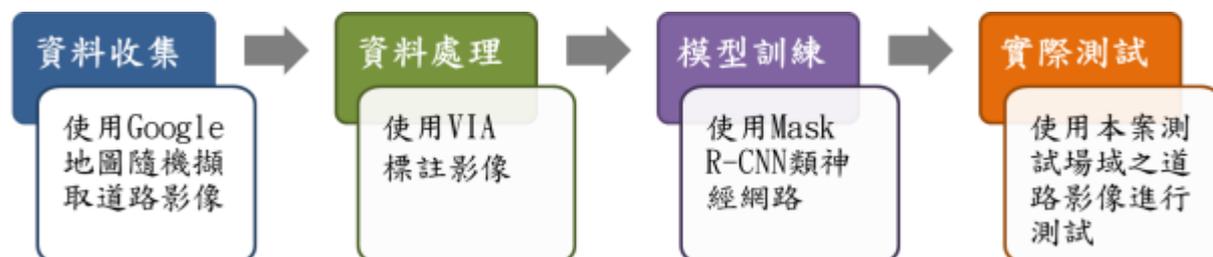


圖 17、類神經網路偵測流程圖

在資料蒐集及處理的部分，由於目前國內並無相關的資料庫，本案以隨機的方式在 Google 地圖上擷取道路影像，蒐集臺中、桃園及臺南的道路影像，影像尺寸至少為 400 x 400，總共 3,725 張影像，其中含有速限標字之道路影像找了 709 張(訓練樣本為 550 張，檢核樣本為 159 張)，其餘六種類別之道路影像找了 3,016 張(訓練樣本為 2,423 張，檢核樣本為 596 張)。透過圖像標註工具 VGG Image Annotator (VIA)，標註包含紅綠燈及交通標誌等類別，由於在真實影像中，物體不會是完美的圓形或四邊形，所以在標註影像時需要使用大量的點形成多邊形以完整的框選物體，才得以清晰且正確的標記大量影像，提供神經網路作為訓練的樣本，最後在所框選的物體上標註類別名稱，如圖 18 所示。輸出檔案的格式為 JSON，包含檔案名稱、檔案大小、物體的輪廓點位與物體類別。



圖 18、使用 VIA 標註影像並輸入類別名稱

圖 19 為 Mask R-CNN 執行接近像素等級的遮罩之示意圖，其主要的做法為一次計算出整張影像的特徵值，對應由類神經網路產生的候選區域，並從對應的實際位置取出各自區域的特徵值，使用雙線性插值法(在兩個方向分別進行一次線性插值)，此時輸出的像素值為四周像素強度的加權平均，像素值相對連續，遮罩位置也更加精準，Mask R-CNN 將此方法稱為 RoIAlign (He et al., 2017)，如圖 20 所示。



圖 19、由 Mask R-CNN 產生之遮罩(摘錄自 He et al., 2017)

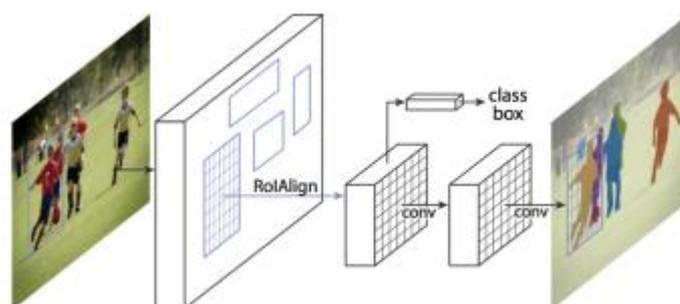


圖 20、RoIAlign 使用雙線性插值法提升遮罩位置(摘錄自 He et al., 2017)

在模型訓練及測試的部分，訓練的設定參數如表 4，設定總類別數，讀取訓練資料的標記檔案取得訓練影像及標記資料，接下來根據訓練參數(初始學習率及總迭代次數)的設定訓練模型，最後輸出模型到存檔位置。檢查影像標註的資料並完成類神經網路的訓練之後，以本案之臺南沙崙測試場域進行神經網路模型的測試，並檢驗其分類精度。根據以往經驗，在 RTX 2080 Ti 顯示卡上執行 Mask R-CNN 的 FPS 為 4，即每秒辨識 4 張影像。

表 4、訓練設定參數說明

參數名稱	說明
NUM_CLASSES	總類別數
DATASET_DIR	訓練資料的檔案位置
ANNOTATIONS	訓練資料的標記檔案
LEARNING_RATE	初始學習率
EPOCHS	總迭代次數
LOGS_DIR	存檔位置

在模型準確度評估部分，本案使用 mAP (Mean Average Precision)來做為評估指標。首先，讀取測試結果檔案及真值標記檔案：(1)測試結果檔案包含偵測框位置、其類別及類別信心值，類別信心值為衡量模型在預測類別時的準確性，即有多少比例的信心來說明影像上的物件為該類別。在讀取檔案時可透過設定信心值門檻值過濾偵測框；(2)真值標記檔案包含標記框位置及其類別。mAP 與 IoU (Intersection over Union)、

Precision、Recall 和 AP (Average Precision)這四個指標有關。

首先讀取測試結果檔案及真值標記檔案，測試結果檔案包含偵測框位置、其類別及類別信心值，在讀取檔案時可透過設定信心值門檻值過濾偵測框，真值標記檔案包含標記框位置及其類別。接下來計算辨識正確的物件數，輸入一偵測框後，會對同影像上所有類別相同的真值標記框計算 IoU 並取其中的最大值，然後判斷此 IoU 值是否大於等於門檻值，若大於等於門檻值則辨識正確，小於則辨識錯誤，在本案中 IoU 門檻值皆設為 0.5。輸入完所有偵測框後即可得到辨識正確的物件數量，再計算偵測框與標記框總數即可計算 Precision 和 Recall。

點雲資料處理方面，由於一般自駕車的點雲掃瞄密度較低，因此需先將自駕車原始點雲與高精地圖進行匹配並轉換至法定坐標系統(如 TWD97)後，藉由拼接連續掃瞄的點雲以提升點雲密度，如圖 21 及圖 22 所示。在圖 21 中，本團隊使用 NDT Matching (Magnusson, 2009)演算法將本團隊實驗車蒐集之點雲匹配至臺南沙崙高精地圖中，而圖 22 則是利用本團隊蒐集之連續掃瞄點雲產製的拼接成果。

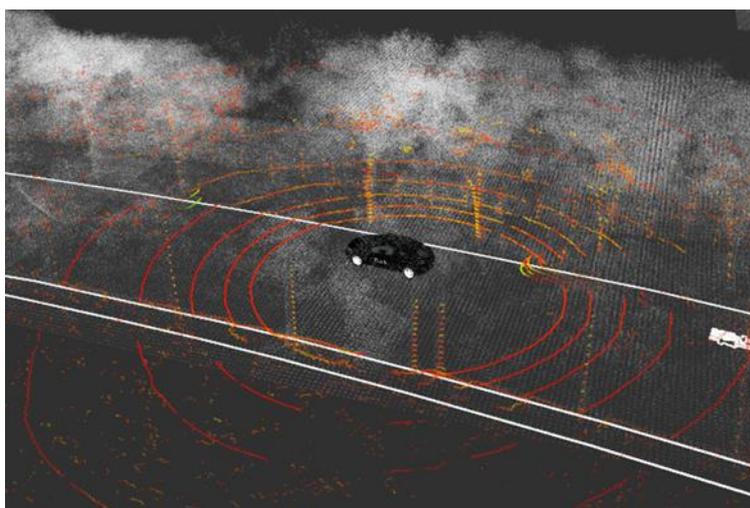


圖 21、NDT Matching 匹配點雲至臺南沙崙高精地圖示意圖

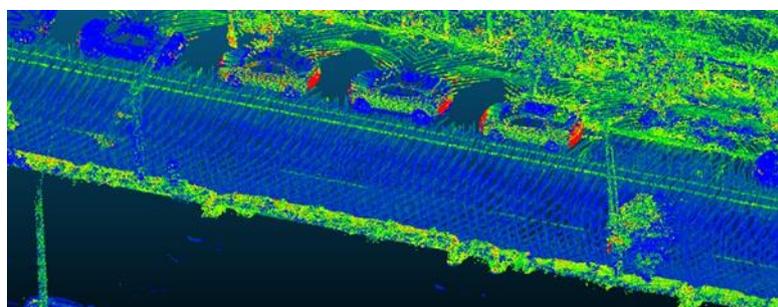


圖 22、連續掃瞄之點雲拼接示意圖

下一步則透過 Cloth Simulation Filter (Zhang et al., 2016)分類出地面與非地面點雲(圖 23)，接著依據不同目標物件設定對應的點雲強度門檻值，並利用 Intensity Filter (Rusu and Cousins, 2011)初步萃取出目標物件之候選點雲，如圖 24 所示。

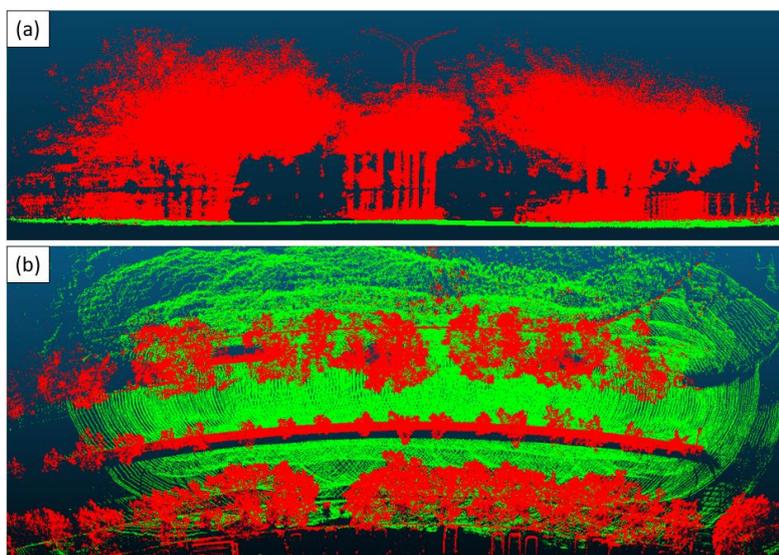


圖 23、地面點分類示意圖，其中綠色點為地面點：(a)側視圖；(b)俯視圖

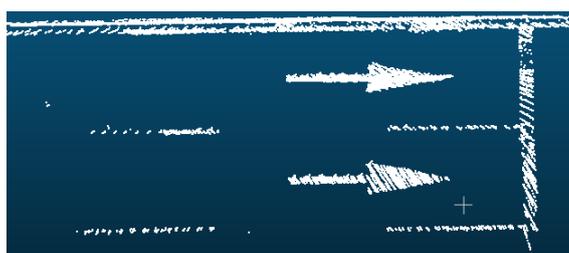


圖 24、Intensity Filter 過濾出地面標線示意圖

為了達到最佳的點雲處理效果，針對指向線及速限標字類別，本團隊進一步使用 DBScan (Ester et al., 1996)進行點雲分群，如圖 25 所示，並根據其法定規範尺寸剔除不合規範之分群。接著，將分群點雲投影為二值影像，並利用模板影像(Template Image)進行基於旋轉的模板匹配(Soilán et al., 2017；Yao et al.,2018)，當匹配之 IoU 超過門檻值便將該分群分類為指向線或速限標字，如圖 26 及圖 27 所示。而針對虛線標線類別，本團隊則使用 Euclidean Clustering (Rusu and Cousins, 2011)進行點雲分群後，根據各分群之長、寬、Rectangularity 等幾何特徵進行篩選與分類(Yao et al.,2018)，其中 Rectangularity 為點雲之凸包(Convex Hull)面積與邊界框面積之比值，如圖 28 所示。最終，為了獲取目標物件之語義及三維坐標資訊，前述之影像及點雲成果進行融合處理，以下針對不同類別的融合策略進行分項說明。

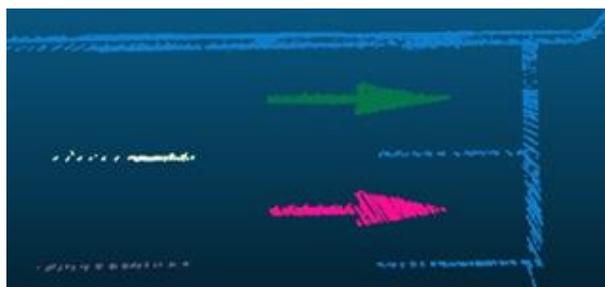


圖 25、DBScan 分群示意圖，其中不同顏色表示不同分群

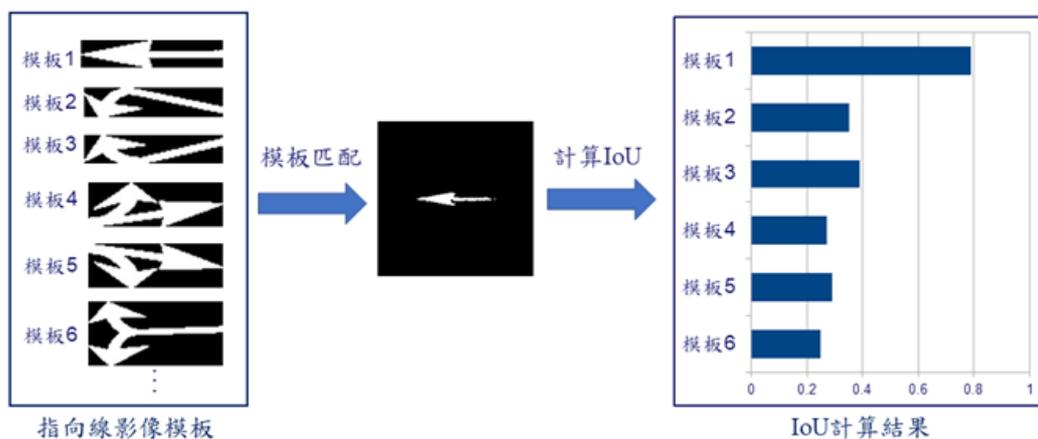


圖 26、模板匹配進行指向線分類

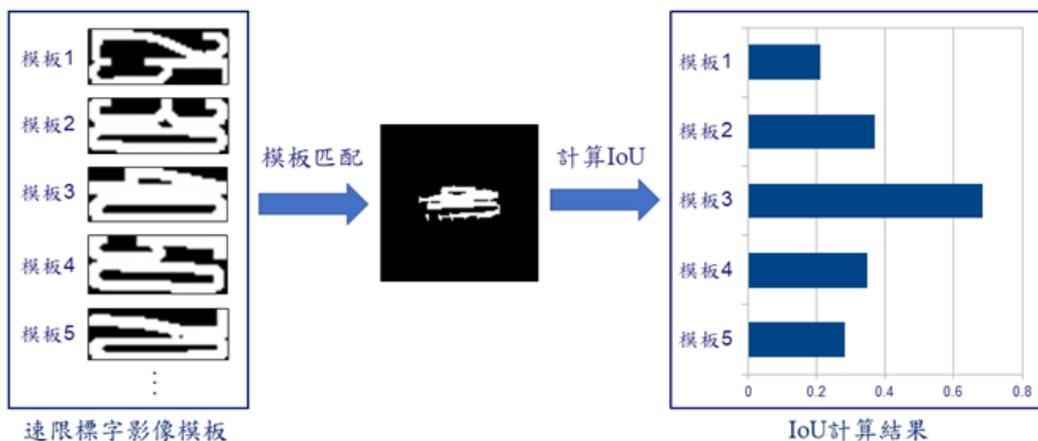


圖 27、模板匹配進行速限標字分類



圖 28、虛線標線之幾何特徵示意圖。紅色點為虛線標線之點雲

對於紅綠燈、行人穿越燈、限制標誌、禁止標誌及警告標誌等類別，本團隊首先經由 Intensity Filter 處理之非地面點雲投影回影像中，並萃取位於 Mask R-CNN 邊界框中的投影點雲來計算物件之三維坐標，如圖 29 所示。在圖 29 中，藍色框為 Mask R-CNN 偵測結果，紫色點為投影至影像中的點雲，綠色框則為物件投影點雲之邊界框。為了

避免不同深度之點雲投影回相同的邊界框中，本團隊使用 Euclidean Clustering 對投影點雲進行分群，並以距離相機最近之分群作為物件三維坐標的計算依據。

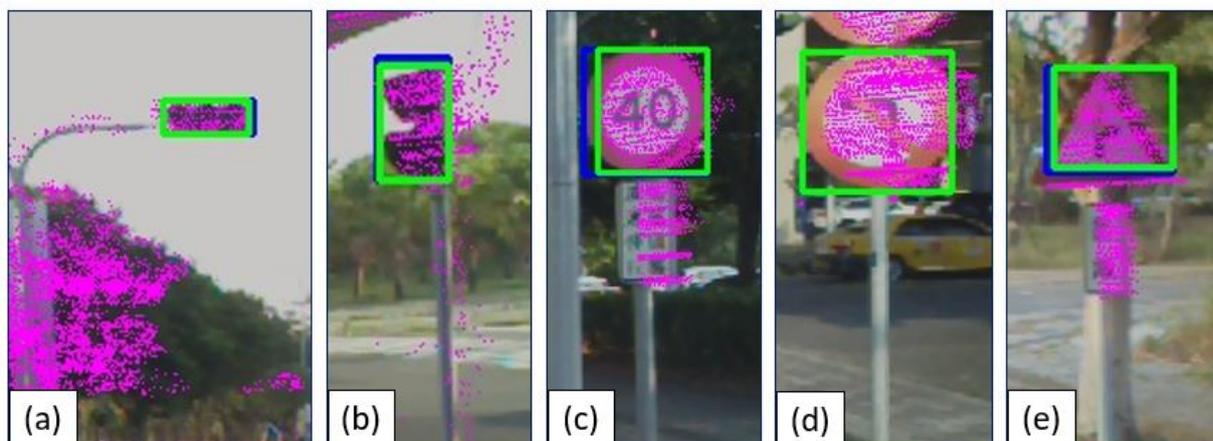


圖 29 影像辨識與點雲投影至影像示意圖：(a)紅綠燈；(b)行人穿越燈；(c)限制標誌；(d)禁止標誌；(e)警告標誌

對於指向線、速限標字及虛線標線類別，雖然在點雲處理流程中可獲得不錯的偵測準確率，但當車輛行經剛性鋪面時，可能因路面與標線點雲之強度值過於相近，而無法獲得準確的 Intensity Filter 過濾成果，如圖 30(a)所示；或是當標線繪製距離較近或重疊時，無法獲取正確的點雲分群成果，如圖 30(b)所示。因此針對這類情形，本團隊透過地面點雲投影回影像上，並與影像的偵測結果進行融合，來輔助偵測上述之類別，如圖 31 錯誤! 找不到參照來源。所示。在圖 31 中，綠色框為影像偵測之邊界框，紫色點為投影至影像的地面點雲，此時會利用投影在邊界框內的點雲來計算物件的三維坐標。

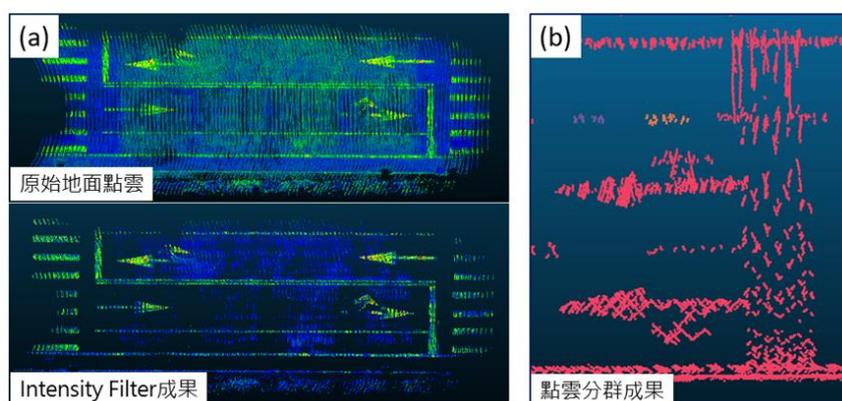


圖 30、(a)剛性鋪面之 Intensity Filter 成果；(b)不準確的點雲分群成果(以不同顏色表示不同分群)

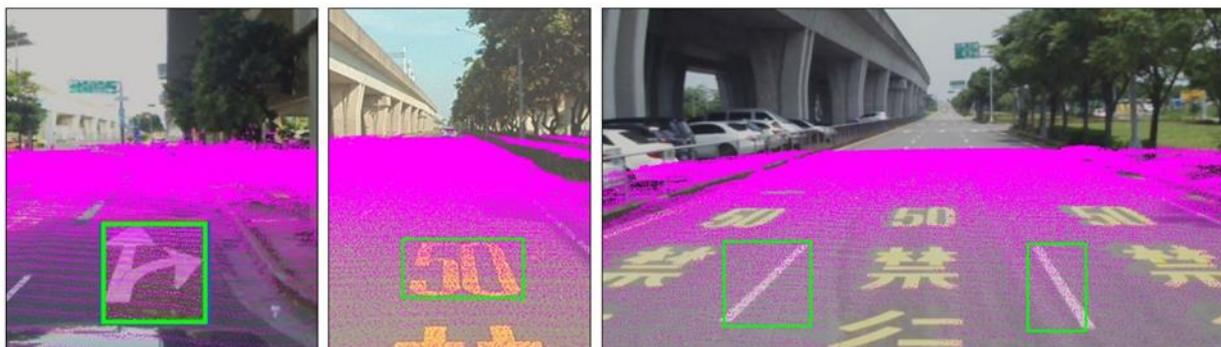


圖 31、投影地面點至影像進行物件偵測示意圖，左至右依序為指向線、速限標字、虛線標線

在完成前述之物件偵測流程後，便可將偵測結果與高精地圖進行比較，以找出變異處。在高精地圖中，物件變異事件可分成四種：新增、移除、移動、無變異，其中移動可視為移除後新增的物件，因此本案僅將物件變異事件區分成新增、移除和無變異三類。

對於新增事件，單一台自駕車的物件偵測結果會與高精地圖中所有目標物件進行比較，當以偵測結果為中心的一定範圍內無目標物件時，則判定該偵測結果處發生新增事件，反之則表示該物件已存在於地圖中，因此判定無變異。由於利用自駕車等級之感測器量測的結果並不精確，因此可利用 Distance-based Clustering 演算法合併來自多輛自駕車的物件辨識結果以提升量測精度(Jo et al., 2018)。接著，本團隊以投票方式進一步確認該新增事件的可信度，只有當事件成功被偵測與未被偵測的次數比例大於門檻值時，演算法才會判定該處確實發生新增事件(Kim et al., 2021)。

而對於移除事件，由於自駕車的感知範圍有限，因此需先從高精地圖中蒐集行駛路線周遭的目標物件做為比對項目，當蒐集的目標物件與物件偵測結果距離小於門檻值時為無變異，否則判定該目標物件處發生移除事件。接著，多輛自駕車的變異偵測結果進行投票，只有當移除與無變異的次數比例大於門檻值時，該目標物件處才會被判定確實發生移除事件，否則無變異事件。

為了驗證本團隊提出之物件偵測演算法及變異存在性偵測之群眾外包投票機制，本案由本團隊實驗車、成大自駕車、理立自駕公車及國土測繪中心測繪車運行於規劃場域，並針對紅綠燈、行人穿越燈、限制標誌、禁止標誌、警告標誌、指向線、車道標線中的「虛線」及標字中的「速限」等八項類別進行測試，以驗證不同的自駕車系統及測繪車同樣可符合動態更新使用。

## 2.2 移動裝置室內外智慧製圖技術發展

定位技術大致可分為航位推算、無線訊號定位、特徵匹配以及影像定位，各自技術皆有其缺點。航位推算技術會隨著使用時間增加持續累積誤差，造成最後的定位精

度不佳；無線訊號定位在大規模的複雜空間中，會因為訊號容易受到干擾阻擋等不穩定因素，導致定位精度不盡理想；特徵匹配雖有不錯的定位精度，但其缺點在於需要大量特徵數據庫及有效篩選特徵點之方法，龐大的計算量會使得室內外定位服務難以實現即時性；影像定位技術是透過幾何原理解算相機與影像已知坐標的相對關係，進而取得相機位置，相對於其它三種定位技術，影像定位的影像資料容易取得。然而影像室內定位技術仍需要高規格的硬體以支援耗時的匹配、特徵萃取和後方交會計算。

深度類神經網路在過去幾年之發展中，有大量成功透過網路大數據進行學習之類神經網路，本案透過這些已建置類神經網路的預測，除了自動化偵測製圖之物件屬性，也可將影像紋理圖資整合光達室內製圖系統，類神經網路如卷積神經網路(Convolution Neural Network, CNN)、循環神經網路(Recurrent Neural Network, RNN)等方式對於影像識別上皆有所貢獻，尤其以卷積神經網路為最有名的方法，其優勢在於可針對局部區域提取高分辨率的特徵點，藉由這些特徵點作為人類的視覺基礎，使識別錯誤率有效降低。Kendall 等人在 2015 年使用室內以及室外資料庫進行學習與測試，該法可預測相機六自由度(位置與姿態)，該法提出一種名為 PoseNet 之卷積神經網路架構，屬於監督式學習，其架構參考 Szegedy 等人(2015)提出的 GoogLeNet 深度神經網路，必須利用特殊方法獲取可靠值以做為答案訓練類神經網路。本案使用 PoseNet 之類神經網路測試室內定位系統的精度，並且針對適地性服務試辦區域之故宮南院展區選用室內移動製圖平台來採集更多實驗場域相關環境之數據庫，實際流程架構如圖 32 所示。

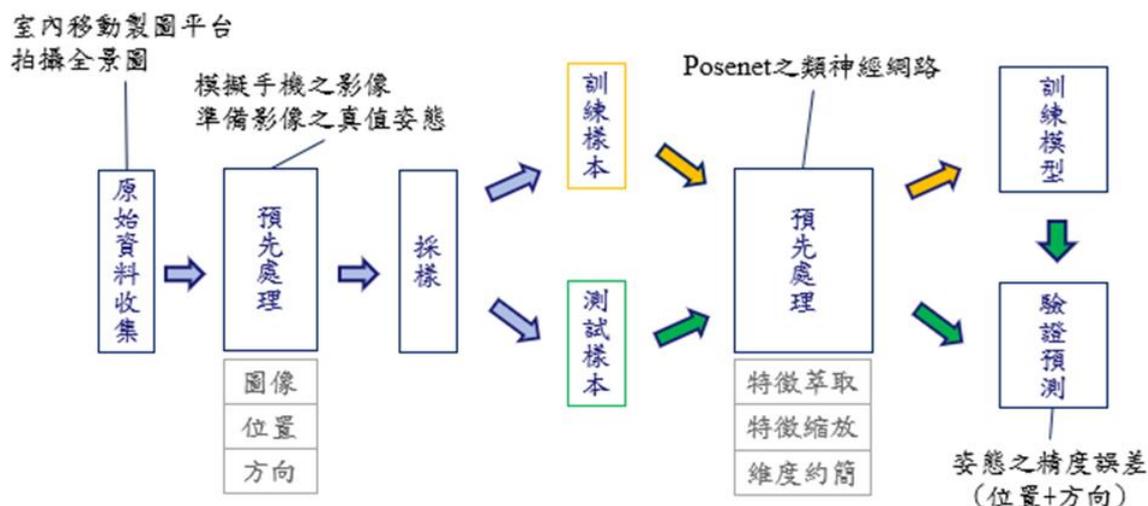


圖 32、作業流程架構圖

本案針對影像前處理格式、調整損失函數前後與搭配轉移學習這三種去設計不同參數與影像尺寸對於類神經網路最終之中值誤差結果。以下說明各種影像尺寸的設置，每個字符代表不同意思，M 為本案使用的 PoseNet 模型架構，L 為使用預訓練模型。影像前處理格式分為 C、R 及 N：C 代表在訓練階段前將影像先縮放至 455x256 像素，再中心裁切成 244x224 像素當作輸入值；R 代表直接將影像縮放至 224x224 像素當作輸入值；N 代表直接將影像縮放至 NxN 像素當作輸入值，範圍從 100 至 400。損失函數分為 PO 和 P：PO 代表損失函數計算位置和方向損失；P 代表僅計算位置損失。

- $M_{C+PO+L}$ ：原始 PoseNet 論文設置，影像先縮再切成 224x224 像素，損失函數計算位置及方向損失，加載預訓練模型。
- $M_{R+PO+L}$ ：更動影像預處理，影像直接縮放成 224x224 像素。
- $M_{C+P+L}$ ：更動損失函數，僅計算位置損失。
- $M_{R+P+L}$ ：影像預處理及損失函數皆更動。
- $N \times N$ ：影像預處理直接縮放成  $N \times N$  像素，其中  $N$  為矩形影像邊長，範圍從 100 至 400。

實驗結果如圖 33 及圖 34 所示。圖 33 為在有加載預訓練模型且影像尺寸皆為 224x224 像素的前提下，不同參數設置之位置中值誤差結果，與原始 PoseNet 論文設置相比， $M_{R+P+L}$  方法的整體精度獲得大大地提升。圖 34 為在沒有加載預訓練模型的前提下，影像前處理直接縮放  $N \times N$  像素當作輸入值，類神經網路之位置中值誤差結果。橘色長條代表每張測試影像的位置誤差在 1 公尺以內占整個測試集的比例，黃色長條則是誤差在 0.5 公尺以內的比例。從結果來看，雖然影像尺寸越大，其中值誤差有趨緩下降，不過相對的，所需的模型訓練時間也越長。因此整體而言，對於故宮南院之數據集來說，在沒有預訓練模型輔助的情況下，影像尺寸大小對於整體精度沒有太大差別。

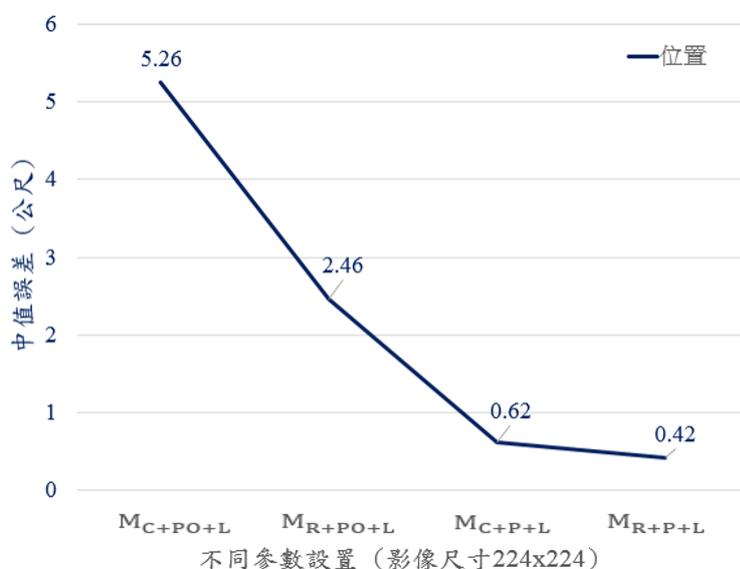


圖 33、不同參數設置之中值誤差結果(有預訓練模型)

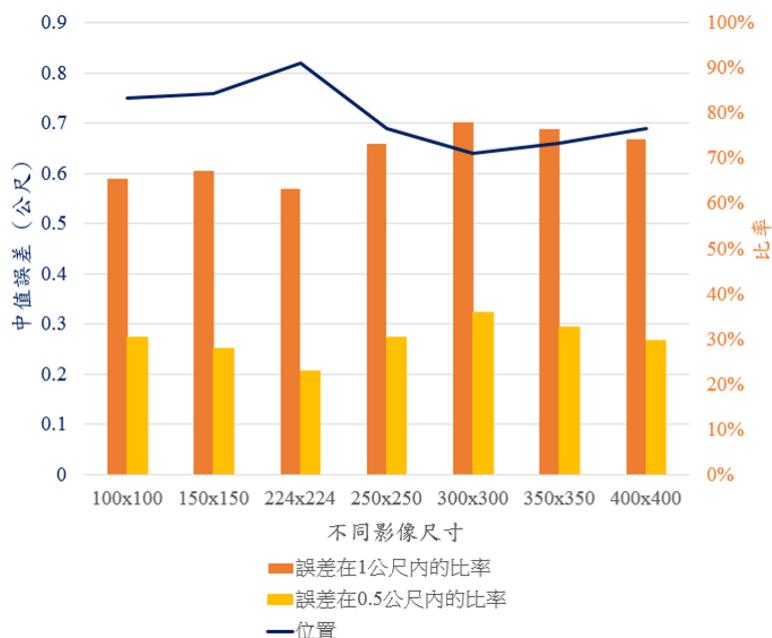


圖 34、不同影像尺寸之中值誤差結果(直接縮，無預訓練模型)

上述實驗結果已得知在同條件下， $M_{R+P+L}$  能得到較好的精度，因此後續其他實驗本團隊也將使用此法進行。接著，本團隊也認為小區域之學習模型會更加準確，因此針對故宮南院場域做三種區域切割，分別考量了繞圈、彎曲行走和來回走之軌跡，如圖 35 所示。除了探討小區域外，也實驗不同重疊程度之軌跡對於類神經網路最終之中值誤差結果。

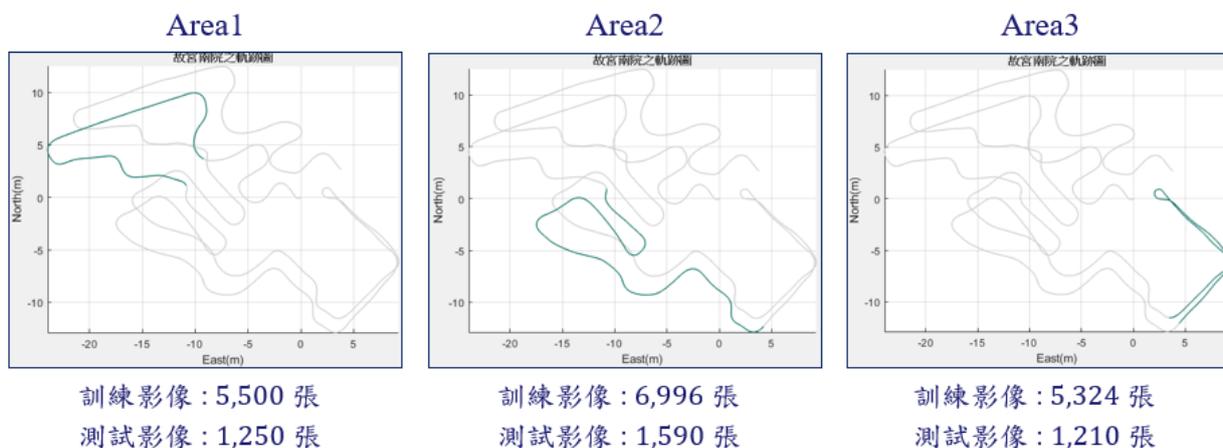


圖 35、繞圈、彎曲行走和來回走之軌跡

每一類神經模型訓練約 4.1 小時，其實驗結果如表 5 所示，可以得知縮小場域範圍能讓整體位置誤差下降約 60% 左右的精度。且無論是繞行環狀的軌跡、曲線彎曲式的軌跡或是重疊式來回行走的軌跡，三種切割區域之間的位置中值誤差沒有太大的起伏。因此本團隊認為在蒐集影像以及地理位置資訊時，並不需要設計特定的軌跡，測試樣本只需要被包覆在訓練樣本裡即可得到不低的位置精度。圖 36 以繞圈的切割區域 Area1 來做為數據集，測試樣本總共 1,250 張影像，黃點為所有測試樣本的位置預測值，圖中顯示測試樣本的位置預測值幾乎貼近真實軌跡。

表 5、不同區域大小對於精度的影響(以故宮為例)

位置中值誤差(m)				誤差在 1 公尺內所占的比例			
Area1	Area2	Area3	All	Area1	Area2	Area3	All
0.15	0.17	0.12	0.42	99.0 %	98.7 %	97.4 %	91.3 %

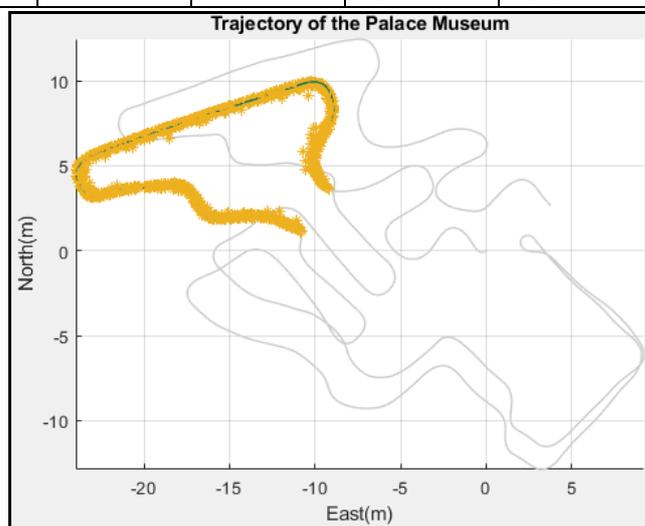


圖 36、Area1 訓練模型之測試結果(黃點為測試影像之位置預測值)

因應實際應用中，每個使用者所持有的手機各有不同，因此今年度本團隊除了模擬上述提及的手機視角之影像(Zenfone2)，也額外模擬其他三台手機型號之影像(R11s、Tango 和 Zenfone3)以實驗不同手機影像對於精度的影響。

此外本案設計誤差修正之方法去校正深度學習模型輸出之初始位置預測值。本案設計一種使用已知角度去分群，其設計理念為發現不同角度的測試樣本，其誤差結果會有不同分布的位移。本團隊經過初步實驗測試後，將可能的固定分布劃分為一群，每一群影像的三軸位置預測值與真值相減得到三軸位置誤差值，再進行平均取得每群的誤差平均值。角度分群在計算完各自群中的誤差平均值之後，初始位置誤差值會根據當時拍攝的角度，並依據角度落在哪一角度分群中，使用剛剛計算的誤差平均值來進行各自的誤差修正。其計算方式為初始預測值減去誤差平均值，真值再減去修正後的預測值，最後計算歐幾里德距離，取得校正後之位置誤差。

本團隊設計了五種誤差修正的角度分群組合(圖 37)，G1 為直觀做法，全部角度一起做平均。G2 到 G4 的設計理念是根據初步實驗結果，發現 60 到 120 度和 240 到 300 度區間中的測試樣本再透過 CNN 模型回歸位置後，其推估的位置在空間上相對於真值沒有固定分布，因此設計三種不同的分群來進行實驗。G5 則不將 60 到 120 度和 240 到 300 度區間劃分到任何一區，自己為一個分群。以下說明各種角度分群的細節：

- G1：第一種為不分群，所有的角度一起做平均誤差值，這種組合最直觀，修正的誤差結果比起其他組合也降得比較少。
- G2：每個顏色為一群，例如 0 到 120 度之間的角度為一群。總共分為 4 群，並且每群各自進行平均誤差值計算。
- G3：一樣分為 4 群，特別的是 60 到 120 度以及 240 到 300 度之間的角度不計算平均誤差值。不過這兩個區間的角度會使用從 0 到 60 度以及 180 到 240 度所計算的平均誤差值來進行修正。

- G4：每個顏色為一群，例如 60 到 120 度和 300 到 0 度區間的角度為一群。總共分為 4 群，並且每群各自進行平均誤差值計算。
- G5：60 到 120 度以及 240 到 300 度之間的角度各自為一個分群，總共 6 群，每群各自進行平均誤差值計算。

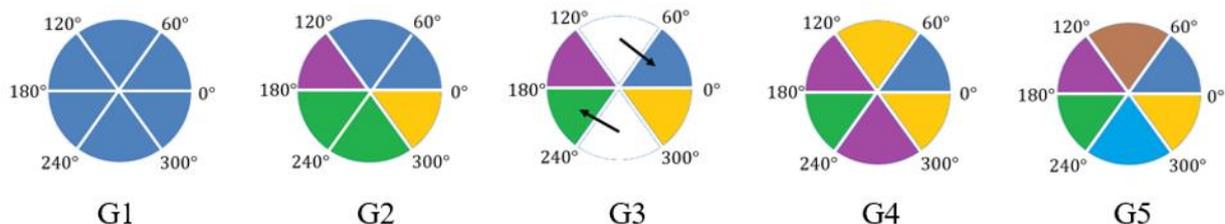


圖 37、用於校正的五種角度分群組合

### 三、研究成果

#### 3.1 自駕車群眾外包製圖技術適地性服務案例試辦

本案規劃高精地圖群眾外包試辦區位於臺南沙崙地區，其位置及規劃路線如圖 38 所示，共包含五條路線，總長約為 13.7 公里。此範圍鄰近臺南高鐵站、臺灣智駕測試實驗場域(又稱臺南沙崙自駕車場域)與行控中心、綠能科技聯合研究中心、綠能科技示範場域、中研院南部院區、國立陽明交通大學臺南校區等，為新創產官學研聚落園區。此區適合從事新創研發事項，之後因規劃搭配自駕車運行，若能將智慧交通搭配即時動態地圖，將是未來智慧城市藍圖的一角。規劃測試車輛包含本案實驗車、成大自駕車、理立自駕公車、國土測繪中心測繪車等如圖 39 所示。



圖 38、適地性服務之群眾外包運行規劃路線圖



類別	紅綠燈	行人穿越燈	限制標誌	禁止標誌	警告標誌	指向線	標字(速限)	車道標線(虛線)	平均值
Precision (%)	91.2	46.7	71.4	65.9	92.1	93.4	60.4	91.5	6.6
Recall (%)	84.0	62.7	64.2	64.4	87.2	91.2	78.6	84.5	7.1

對於所有的誤判情形來說，其原因包含三種情況：(1)影像辨識錯誤；(2)錯誤的投影點雲；(3)點雲辨識錯誤。在第一種情況中，可能因為外型或顏色相似，使得演算法錯誤地將影像中的其他物件辨識為目標物件，圖 40 展示了常見的誤判種類，如長條狀的路牌被辨識為紅綠燈；黃黑相間的反光標記被誤判為行人穿越燈；非本案辨識類別的標誌牌被誤判為限制標誌或禁止標誌；紅色交通錐被誤判為警告標誌；地面標字被誤判為指向線、速限標字；枕木紋行人穿越道被誤判為虛線標線等。

在第二種情況中，雖然影像辨識結果正確，但因目標物件受到其他物體遮擋導致投影點雲有誤，而錯誤計算物件的三維坐標，如圖 41(a)所示。在圖 41(a)中，因紅綠燈受到前方桿柱遮擋，因此紅綠燈之輸出坐標被誤判為桿柱位置。在第三種情況中，部分分群點雲因為符合演算法門檻值，而被錯誤辨識為目標物件，此種情況容易發生在虛線標線類別，在圖 41(b)中，停車格線的點雲即被誤判為虛線標線。

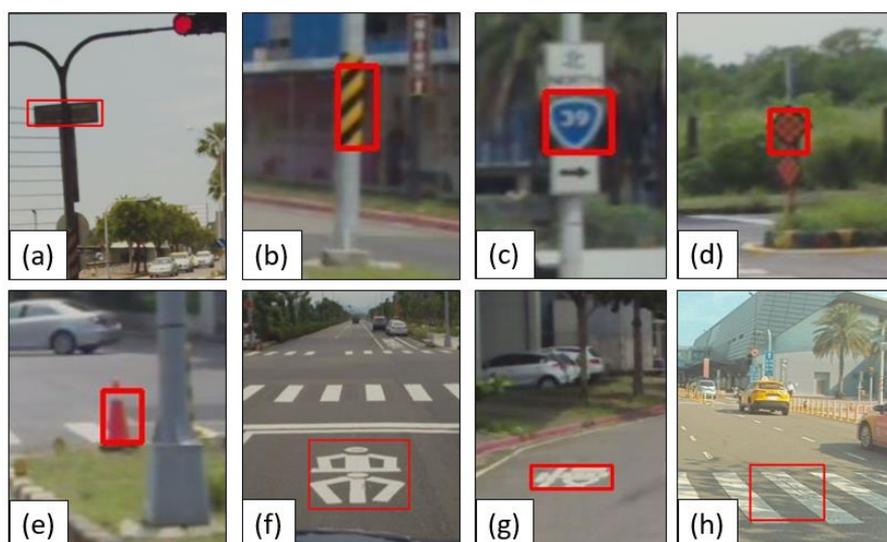


圖40、影像誤判範例(紅框處)：(a)至(g)依序被誤判為紅綠燈、行人穿越燈、限制標誌、禁止標誌、警告標誌、指向線、標字(速限)、車道標線(虛線)

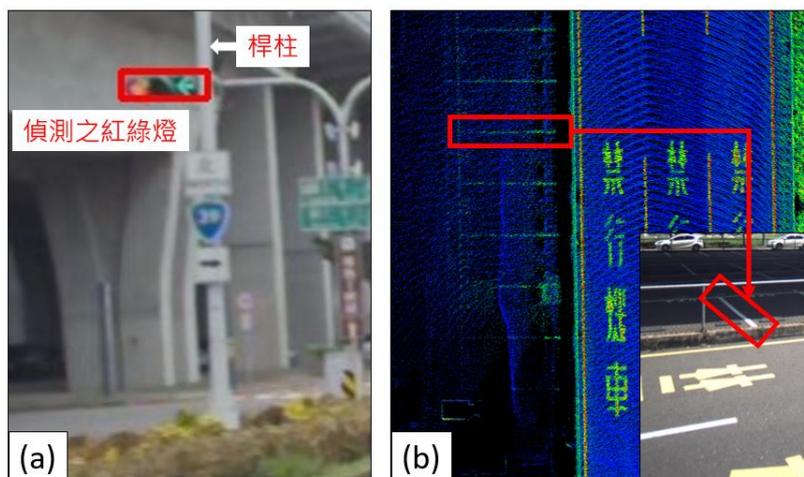


圖41、點雲誤判範例：(a)紅綠燈輸出坐標誤判為桿柱位置；(b)停車格線(紅框處)之點雲被誤判為虛線標線，小圖為實景圖

對於漏判情形，其原因可分為三種情況：(1)影像無辨識結果或辨識錯誤；(2)車輛並未收蒐集到該物件的影像；(3)錯誤的點雲分群。

接著，在群眾外包之變異存在性偵測中，本案透過投票機制整合各群眾之偵測結果，以找出確實發生之變異處。表 8 及表 9 分別為新增事件及移除事件偵測成果，其中，「真實事件」為確實發生變異處；「誤判」為演算法判定發生變異，但實際上無變異處；「漏判」則為實際上有變異，但演算法判定無變異處；「N/A」則表示該類別因為無發生變異事件，而不適用於精度指標之計算。

對於新增事件及移除事件，由於物件偵測之誤判及漏判數較多，因此 Precision 平均值最高僅達到 50.4%，但即便如此，兩者的 Recall 平均值仍達到 99.1% 及 100.0%，此結果說明演算法可偵測出絕大多數的真實變異事件，並可輔助更新高精地圖，惟誤判之成果仍須透過人工檢核進行剔除。表 10 展示了部分類別之變異處實景圖以及 109 年度以前之街景對照圖，包含紅綠燈、限制標誌、虛線標線、速限標字等。

表 8、新增事件偵測成果

類別	真實新增事件	誤判	漏判	Precision (%)	Recall (%)
紅綠燈	6	3	0	66.7	100.0
行人穿越燈	0	16	0	0.0	N/A
限制標誌	3	4	0	42.9	100.0
禁止標誌	0	3	0	0.0	N/A
警告標誌	1	0	0	100.0	100.0
指向線	23	10	0	69.7	100.0
標字(速限)	3	1	0	75.0	100.0

車道標線(虛線)	55	57	3	49.1	94.8
平均值				<b>50.4</b>	<b>99.1</b>

表 9、移除事件偵測成果

類別	真實移除事件	誤判	漏判	Precision (%)	Recall (%)
紅綠燈	0	4	0	0.0	N/A
行人穿越燈	0	11	0	0.0	N/A
限制標誌	0	1	0	0.0	N/A
禁止標誌	0	1	0	0.0	N/A
警告標誌	0	1	0	0.0	N/A
指向線	4	4	0	50.0	100.0
標字(速限)	6	3	0	66.7	100.0
車道標線(虛線)	14	14	0	50.0	100.0
平均值				<b>20.8</b>	<b>100.0</b>

表 10、適地性服務場域內之變異處(紅框處)範例

類別	街景圖(109 年度以前)	實景圖(110 年度)	變異事件
紅綠燈			新增
限制標誌			新增

類別	街景圖(109 年度以前)	實景圖(110 年度)	變異事件
車道 標線 (虛線)			移除
標字 (速限)			移動 (移除+ 新增)

### 3.2 移動裝置室內外智慧製圖技術適地性服務案例試辦

為驗證本案所提出之人工智慧技術之室內影像匹配輔助行人慣導定位技術效能，本案使用開發之程式將移動製圖平台所拍攝之全景影像圖模擬成手機視角之影像，完成數據樣本之影像、位置及方向角度後，採樣樣本分成訓練樣本及測試樣本，每張影像再根據實驗的不同設置輸入類神經網路並且加以測試誤差精度。本案之硬體設備將使用單顆 GeForce GTX 1080 Ti 之 GPU 顯示卡加快類神經網路運行訓練與測試，於適地性服務試辦區域之故宮南院展區進行測試，訓練迭代次數設置 30,000 次，模型依不同參數與影像尺寸所需的訓練時間不同，每張影像測試需要 0.2 秒。

此外，為使訓練過程加速收斂，幫助類神經網路快速學習局部特徵，本案採用轉移學習為基礎加載預訓練模型。並針對影像前處理格式、調整損失函數前後與搭配轉移學習這三種去設計不同參數與影像尺寸對於類神經網路最終之中值誤差結果。實驗結果表明，比起使用原始 PoseNet 論文的設置，更動影像前處理及損失函數後，其整體精度獲得大大地提升。另外，本案也探討不同區域大小對於精度的影響，針對故宮南院場域做三種區域切割，分別考量了繞圈、彎曲行走和來回走之軌跡。實驗結果表明，縮小場域範圍能讓整體位置誤差下降約 60% 左右的精度。另外，三種切割區域之間的位置中值誤差沒有太大的起伏，因此本案認為在蒐集影像以及地理位置資訊時，並不需要設計特定的軌跡，測試樣本只需要被包覆在訓練樣本裡即可得到不低的位置精度。

因應實際應用中，每個使用者所持有的手機各有不同，因此今年度本案除了模擬上述提及的手機視角之影像(Zenfone2)，也額外模擬其他三台手機型號之影像(R11s、

Tango 和 Zenfone3)以實驗不同手機影像對於精度的影響。表 11 為每台模擬手機影像進行訓練，測試同一台模擬手機之位置中值誤差(單位：公尺)。從四台模擬手機測試整個場域的結果得知，Zenfone2 手機的位置中值誤差為最小，三種切割區域誤差為 0.12 ~ 0.15 公尺，97.4 ~ 99%的測試樣本誤差在 1 公尺內，而 R11s 手機的誤差為最大，誤差為 0.31 ~ 0.4 公尺，77.7 ~ 87.3%的測試樣本誤差在 1 公尺內，甚至全路徑只有 43.6%的測試樣本誤差在 1 公尺內。其原因可能跟手機影像尺寸與焦距有關，Zenfone2 手機之影像距離物體較遠，影像中包含之資訊多，深度學習模型得以依靠有用的資訊推算精準的位置。反之，P11s 手機之影像距離物體太近，有時只拍攝到物體的局部區域，深度學習模型難以依靠這些局部特徵推算精準的位置。

表 11、四台模擬手機之同平臺模型測試結果

Training model	Position error (m)				Proportion (< 1m)			
	Area1	Area2	Area3	All	Area1	Area2	Area3	All
Zenfone2	0.15	0.17	0.12	0.42	99.0 %	98.7 %	97.4 %	91.3 %
R11s	0.31	0.37	0.40	1.14	87.3 %	77.7 %	77.7 %	43.6 %
Tango	0.19	0.17	0.14	0.47	97.8 %	95.4 %	96.7 %	87.3 %
Zenfone3	0.18	0.20	0.18	0.58	94.7 %	92.3 %	92.6 %	80.2 %

圖 42 顯示以四台模擬手機為模型，推算同平臺模擬手機的位置預測值，黃色為所有測試樣本的位置預測值。本團隊以表 11 其中一欄數據作範例，使用繞圈的切割區域 Area1 來做為數據集，測試樣本總共 1,250 張影像。從圖中可以得知 Zenfone2 手機的位置預測值幾乎貼近真實軌跡，Tango 和 Zenfone3 手機的位置預測值也大多貼近軌跡，只有少許的測試樣本誤差大。相較於其他三台手機，R11s 的位置預測值很多距離真實軌跡很遠，造成位置中值誤差上升。造成誤差這麼大的原因可能是因為 R11s 手機的影像所包含的有用特徵太少，影像中包含物件太過於局部，神經網路難以判斷完整的位置訊息，因此造成有些測試樣本被錯誤估計而導致整體的中值誤差上升。

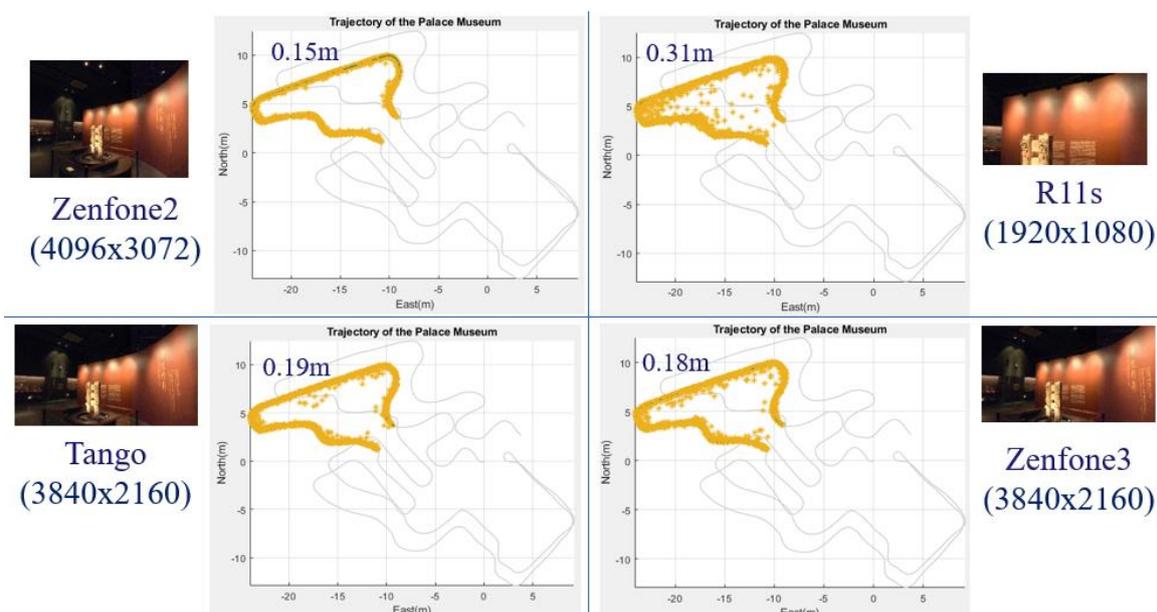


圖 42、使用四部模擬手機作為訓練模型，計算同平臺手機的位置預測值

接著本團隊測試跨平臺手機之間的精度，其意義為以 A 手機為訓練樣本進行模型訓練，再以 B 手機做為測試樣本進行回歸位置，分析跨相機之間的位置誤差結果。表 12 為每台模擬手機影像以三種切割區域為數據集進行訓練，測試跨平臺手機之間的位置中值誤差(單位：公尺)，表中呈現的數據為三種切割區域之平均值。從結果得知，比起 R11s 手機，Zenfone2、Tango、Zenfone3 這三台手機之間的跨平臺測試之位置中值誤差沒有相差很多，而在測試 R11s 手機之影像時，誤差卻上升到 3~4 公尺。反之以 R11s 手機為訓練模型，測試其他三台手機之影像也上升到 3~4 公尺。造成誤差這麼大的原因可能是因為 R11s 手機之影像與其他三台手機之影像相差太大，也就是說影像包含的特徵信息相差太多。以三台手機為訓練模型，神經網路學習到完整影像區域，但是 R11s 手機之影像太過局部，神經網路難以匹配其特徵，因此造成誤差上升。反之，以 R11s 手機為訓練模型，神經網路最多只能學習到那些局部的特徵，因此難以區分更大範圍的影像以及位置。

表 12、以三種切割區域為數據集，其模擬手機跨平臺測試結果(測試結果為三種切割區域之平均值)

Training model	Test data	Position error (m)	Proportion (< 1m)	Proportion (< 0.5m)
Zenfone2	Zenfone2	0.15	98.4 %	92.2 %
	R11s	4.31	7.7 %	2.5 %
	Tango	0.36	87.0 %	65.1 %
	Zenfone3	1.01	49.4 %	24.6 %
R11s	Zenfone2	4.18	4.6 %	1.4 %
	R11s	0.36	80.9 %	62.3 %
	Tango	3.95	6.1 %	1.6 %
	Zenfone3	3.14	11.7 %	4.2 %
Tango	Zenfone2	0.26	94.1 %	77.4 %
	R11s	3.89	9.4 %	4.0 %
	Tango	0.17	96.6 %	88.9 %
	Zenfone3	0.55	76.7 %	46.4 %
Zenfone3	Zenfone2	0.77	62.2 %	31.7 %
	R11s	3.41	11.8 %	4.4 %
	Tango	0.47	82.9 %	52.7 %
	Zenfone3	0.19	93.2 %	83.4 %

本團隊將表 12 中的一小部分實驗以所有測試樣本的位置預測圖呈現，圖 43 顯示以 Zenfone2 手機作為訓練模型，推算四台模擬手機的位置預測值。Zenfone2 手機的位置預測值幾乎貼近真實軌跡，Tango 和 Zenfone3 手機的位置預測值也大多貼近軌跡。而因為 R11s 的影像與其他三台模擬手機的影像相差太多，因此很多測試樣本的位置預測值誤差很大。

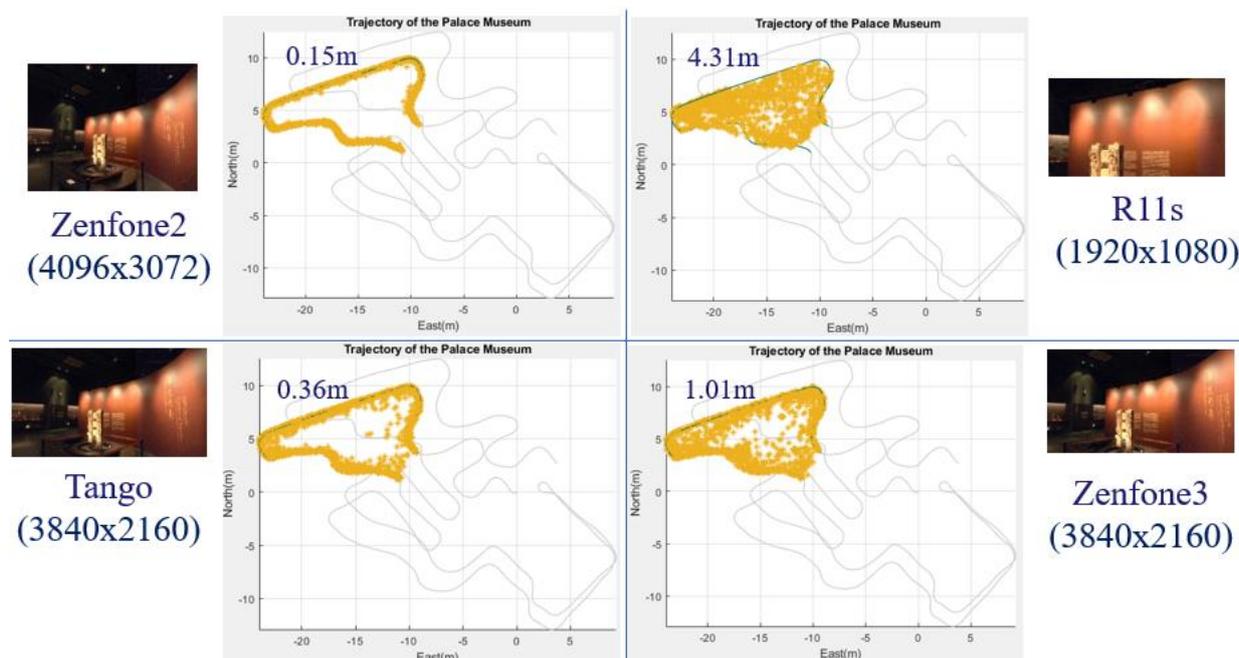


圖 43、以 Zenfone2 手機為訓練模型，計算四台模擬手機的位置預測值

從上述實驗得知跨平臺測試之誤差精度會上升，尤其 R11s 與其他三台模擬手機測試的誤差皆高達 3~4 公尺，因此本案設計誤差修正之方法去校正深度學習模型輸出之初始位置預測值。本案設計一種使用已知角度去分群，其設計理念為發現不同角度的測試樣本，其誤差結果會有不同分布的位移。本團隊經過初步實驗測試後，將可能的固定分布劃分為一群，每一群影像的三軸位置預測值與真值相減得到三軸位置誤差值，再進行平均取得每群的誤差平均值。角度分群在計算完各自群中的誤差平均值之後，初始位置誤差值會根據當時拍攝的角度，並依據角度落在哪一角度分群中，使用剛剛計算的誤差平均值來進行各自的誤差修正。其計算方式為初始預測值減去誤差平均值，真值再減去修正後的預測值，最後計算歐幾里德距離，取得校正後之位置誤差。

本團隊設計了五種誤差修正的角度分群組合(圖 44)，G1 為直觀做法，全部角度一起做平均。G2 到 G4 的設計理念是根據初步實驗結果，發現 60 到 120 度和 240 到 300 度區間中的測試樣本再透過 CNN 模型回歸位置後，其推估的位置在空間上相對於真值沒有固定分布，因此設計三種不同的分群來進行實驗。G5 則不將 60 到 120 度和 240 到 300 度區間劃分到任何一區，自己為一個分群。以下說明各種角度分群的細節：

- G1：第一種為不分群，所有的角度一起做平均誤差值，這種組合最直觀，修正的誤差結果比起其他組合也降得比較少。
- G2：每個顏色為一群，例如 0 到 120 度之間的角度為一群。總共分為 4 群，並且每群各自進行平均誤差值計算。
- G3：一樣分為 4 群，特別的是 60 到 120 度以及 240 到 300 度之間的角度不計算平均誤差值。不過這兩個區間的角度會使用從 0 到 60 度以及 180 到 240 度所計算的平均誤差值來進行修正。
- G4：每個顏色為一群，例如 60 到 120 度和 300 到 0 度區間的角度為一群。總共分為 4 群，並且每群各自進行平均誤差值計算。

■ G5：60 到 120 度以及 240 到 300 度之間的角度各自為一個分群，總共 6 群，每群各自進行平均誤差值計算。

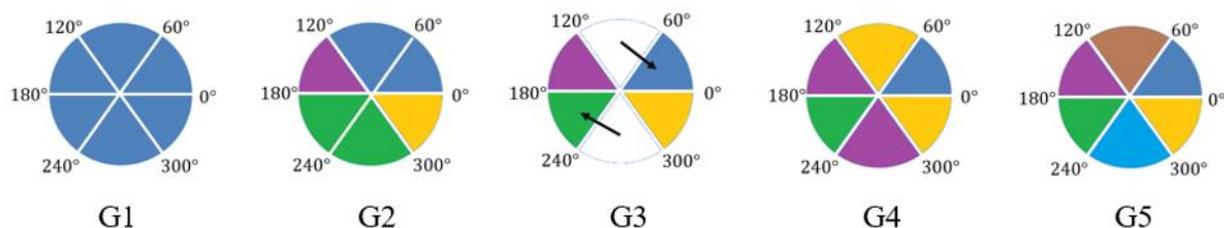


圖 44、用於校正的五種角度分群組合

每種角度分群組合所要進行平均運算的樣本數不能太過少，取樣的範圍也不能太過集中，最好的方式是整段軌跡平均取樣。滿足以上條件，得到誤差平均值才能有效修正初始預測位置。舉例來說，如圖 45 所示，數據集採用繞圈之切割區域 Area1，訓練樣本為 Zenfone2 手機之影像，總計 5,500 張，而測試樣本為 R11s 手機之影像，總計 1,250 張。使用隨機 10 個位置點，每個位置點有 10 張方向影像，總計 100 個樣本去進行分群組合平均。

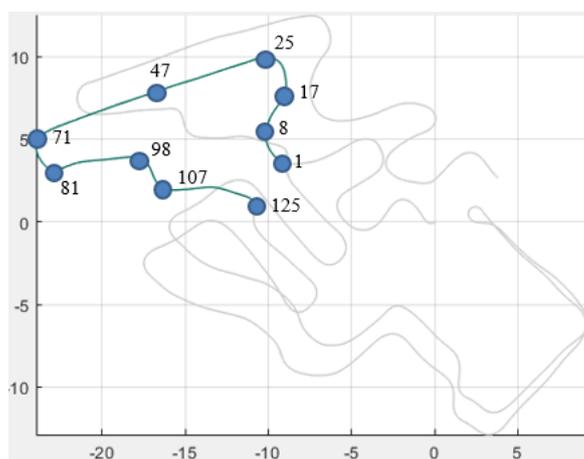


圖 45、平均分群組合的樣本數(藍點為位置點，每一位置點有 10 個方向)

已知角度有 30、90、150、210、330 度，沿用上述提及之舉例來進行實驗，訓練樣本為 Zenfone2 手機之影像，測試樣本為 R11s 手機之影像，其初始位置中值誤差為 4.73 公尺，使用本團隊設計的五種角度分群進行實驗，其實驗結果如下所示：

- G1：修正後之位置中值誤差為 4.44 公尺，改善率為 6.1%。
- G2：修正後之位置中值誤差為 3.74 公尺，改善率為 20.8%。
- G3：修正後之位置中值誤差為 3.73 公尺，改善率為 21.1%。
- G4：修正後之位置中值誤差為 3.97 公尺，改善率為 16%。
- G5：修正後之位置中值誤差為 3.72 公尺，改善率為 21.3%。

在圖 46 中，本團隊分別將兩個位置點的 10 張測試影像進行位置預測，並且使用 G5 的方式進行誤差修正。左圖為切割區域 Area1 起點的實驗結果，而右圖為終點的實驗結果。黑色加號為起終點的真值，圓形為初始位置預測值，而三角形為誤差修正後的位置預測值。從圖中可以發現經過誤差修正後的位置預測值，整體結果往真值靠近，證實本案的誤差修正方法能有效校正位置預測值。

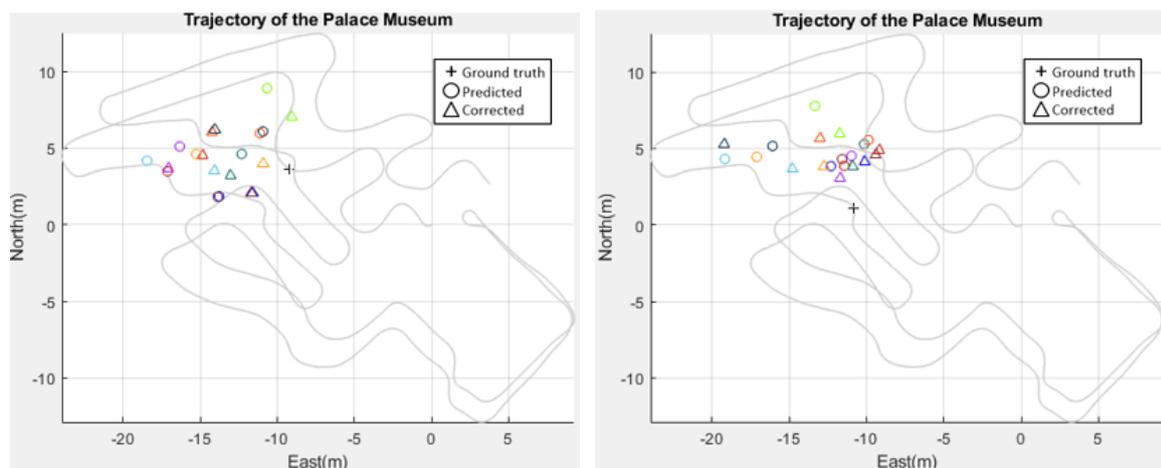


圖 46、使用 G5 方法對起點(左)和終點(右)的初始位置預測進行誤差修正

至此，本案為了求得更好的精度嘗試了許多實驗，PoseNet 的原始設置為回歸位置與方向，因此損失函數會同時計算位置與方向的損失。為了同時得到好的位置與方向，作者勢必得平衡這兩者之間的權重，從實驗中也證實了作者方法得到的位置誤差一定比只計算位置損失的位置誤差還要來的高。本團隊認為使用者所持有的手機本身就帶有感測器，並且藉由感測器中的陀螺儀就能取得方向角，因此不需要特別使用神經網路去預測方向。基於這個原因本案調整 CNN 架構，使損失函數僅計算位置的權重，最後預測使用者的位置。在不同影像尺寸的實驗中，證明提出的新方法能有效提高定位精度約 30%。而與 PoseNet 的原始設置比較起來，本團隊的新方法更有效提高定位精度約 90%。在切割場域的實驗中，數據集的場域縮小有助於讓整體的位置誤差下降，並且本案認為不需要特別去設計軌跡來採集數據也能進行實驗。此外，考量實際應用時影像多半來自不同型號的手機的問題，若訓練影像資料與實際定位時的拍攝影像是來自不同手機的話，容易造成不同平臺間的誤差。在跨平臺的實驗中，本團隊發現影像的大小與焦距對於神經網路來說影響很大，影像中涵蓋的物件與區域是造成位置誤差上升的主要原因。最後，為了使位置誤差能更進一步降低，本團隊提出誤差修正算法。透過角度分群的方式，計算每一群中的初始位置誤差的誤差量，並且進行平均來做為修正誤差的校正值。實驗表明本團隊提出的五種角度分群法可以有效降低誤差，最佳的角度分群法可以使得位置誤差下降約 20%。

目前本案提出的誤差修正算法能將初始位置誤差 4.73 公尺修正至 3.72 公尺，雖然已有效下降 21.3%，然而 3.72 公尺的誤差還是很高，還有很大的改善空間，未來本團隊可從以下 4 點著手：(1)更改深度神經網路的骨幹網路(如 ResNet-50)，ResNet 架構比起 GoogLeNet 架構來說來得更深能學習更多特徵，且為了防止神經網路過深而導致梯度消失，ResNet 具有殘差網路之特性可有效解決此問題。(2)使用其他預訓練模型，Places 數據庫有 476 種場景，但其實可考慮 ImageNet 數據庫，ImageNet 為目前最大的數據庫，故使用此數據庫可讓神經網路預先學習更多資訊，再接著進行訓練的話可更快地收斂。(3)更改影像正規化方法，目前所使用的方法為減去平均影像，可嘗試看看其他正規化方法。(4)若未來還是需要讓神經網路回歸方向的話，那重點就會是位置權重以及方向權重之間的平衡，這時可考量使用具有可學習權重函數平衡位置和方向的

尺度差異。至此，相信藉由以上 4 點想法會讓室內定位技術能更加順利發展以及精度更加精確。

#### 四、結論與建議

隨著智慧型運輸系統(Intelligent Transport System, ITS)的發展，自動駕駛汽車成為未來全新的交通方式，稱高精地圖在自駕車運行具有不可或缺之地位，精進測繪車之高精地圖製圖技術，發展高精地圖自動化生產技術，及建立自駕車群眾外包之高精地圖製圖(含自駕車平台)系統及流程刻不容緩。對於高精地圖自動化生產技術，本案完成開發半自動化高精地圖產製工具與自動化高精地圖轉檔工具，針對路面邊緣、車道線、車道中心線、交通號誌與特定交通標誌圖徵進行特徵提取，並產製符合高精地圖標準定義之屬性內容的向量圖徵，並經由測繪廠商針對此工具進行測試，本案亦針對廠商建議進行工具的優化，並給予未來高精地圖產製工具可精進的建議，同時，完成臺灣智駕測試實驗室與臺中水湳兩個自駕車測試場的 OpenDRIVE 圖資格式轉換至 Autoware 使用之 Lanelet2 與 Asian map 格式的測試，以滿足不同使用者的需求。

本案於群眾外包資料處理方面，影像處理完成除了車道標線，其餘 7 種類別之 VIA 標註，其中紅綠燈、行人穿越燈、限制標誌、禁止標誌、警告標誌、指向線、速限標字類別完成模型訓練，在模型準確度評估部分，本案使用 mAP 來做為評估指標。經實驗與分析後，總共有兩個模型，一為紅綠燈、行人穿越燈、限制標誌、禁止標誌、警告標誌、指向線這 6 種類別；二為速限標字的 3 種速限類別(速限 50 至速限 70)，其中在速限標字模型的準確度評估上 mAP 可高達 87.62%。本案使用影像處理：Canny 邊緣偵測、霍夫測線法(Hough Lines)等技術處理車道標線，經反覆實驗與改良後，本案設計的車道標線偵測方法在沙崙自駕車、本案實驗車和理立自駕公車之測試影片皆有不錯的偵測結果。除此之外，本案也完成所有類別之點雲處理與影像融合偵測流程，以及群眾外包之變異存在性偵測方法及輸出格式，同時利用實際蒐集之感知資訊進行各項類別的偵測與分析，驗證本案變異存在性偵測流程之可行性。

對於自駕車群眾外包製圖技術適地性服務案例試辦，本案透過多趟運行於試辦區來模擬群眾外包情境，並透過模擬之變異事件驗證群眾外包之變異存在性偵測的可行性。本案透過本案實驗車、成大自駕車、理立自駕公車及國土測繪中心測繪車於試辦區蒐集多趟感知資訊，並在物件偵測的測試中獲得平均 76.6%之 Precision 與平均 77.1%之 Recall，後續於群眾外包之變異存在性偵測評估中，新增及移除事件之 Recall 平均值分別達到 99.1%及 100.0%，說明了本案提出之演算法可偵測出絕大多數的真實變異事件，並可用於輔助更新高精地圖，惟誤判之成果仍須透過人工檢核進行剔除。

對於移動裝置室內外智慧製圖技術之工作，本案使用故宮南院數據集進行 PoseNet 之類神經網路的精度測試，藉由設計不同參數設置與影像尺寸來進行實驗，實驗結果表明，比起使用原始 PoseNet 論文的設置，更動影像前處理及損失函數後，其整體精度獲得大大地提升。本案亦探討不同區域大小對於精度的影響，針對故宮南院場域做三種區域切割，分別考量了繞圈、彎曲行走和來回走之軌跡。實驗結果表明，縮小場域範圍能讓整體位置誤差下降約 60%左右的精度。另外，三種切割區域之間的位置中

值誤差沒有太大的起伏，因此本案認為在蒐集影像以及地理位置資訊時，並不需要設計特定的軌跡，測試樣本只需要被包覆在訓練樣本裡即可得到不低的位置精度。因應實際應用中，每個使用者所持有的手機各有不同，本案使用四台手機型號之影像作為數據集，展示四台模擬手機之模型測試結果。本案也分析跨相機的位置誤差結果，發現影像的大小與焦距對於神經網路來說影響很大，影像中涵蓋的物件與區域是造成位置誤差上升的主要原因。最後，為了使位置誤差能更進一步降低，本案提出誤差修正算法，最佳的角度分群法可以使得位置誤差下降約 20%。

## 參考文獻

1. Ester, M., Kriegel, H.P., Sander, J., and Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. In *Kdd*, 96(34), pp.226-231.
2. He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pp.2961-2969.
3. Jo, K., Kim, C., and Sunwoo, M. (2018). Simultaneous localization and map change update for the high definition map-based autonomous driving car. *Sensors*, 18(9), 3145.
4. Kendall, A., Grimes, M., and Cipolla, R. (2015). PoseNet: A convolutional network for real-time 6-dof camera relocalization. In *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2938-2946.
5. Kim, K., Cho, S., and Chung, W. (2021). Hd map update for autonomous driving with crowdsourced data. *IEEE Robotics and Automation Letters*, 6(2), pp.1895-1901.
6. Magnusson, M. (2009). The three-dimensional normal-distributions transform: an efficient representation for registration, surface analysis, and loop detection (Doctoral dissertation, Örebro universitet).
7. Rusu, R.B., and Cousins, S. (2011, May). 3d is here: Point cloud library (pcl). In *2011 IEEE international conference on robotics and automation*, pp.1-4, IEEE.
8. Soilán, M., Riveiro, B., Martínez-Sánchez, J., and Arias, P. (2017). Segmentation and classification of road markings using MLS data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 123, pp.94-103.
9. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going Deeper with Convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1-9.
10. Yadav, M., Singh, A.K., and Lohani, B. (2017). Extraction of road surface from mobile LiDAR data of complex road environment. *International Journal of Remote Sensing*, 38(16), pp.4655-4682.
11. Yao, L., Chen, Q., Qin, C., Wu, H., and Zhang, S. (2018). Automatic Extraction of Road Markings from Mobile Laser-Point Cloud Using Intensity Data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 3.

12. Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., and Yan, G. (2016). An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 8(6), 501.