



利用無人機影像實現交通車流之智慧偵測

台灣世曦工程顧問股份有限公司地理空間資訊部工程師 / 李冠毅
台灣世曦工程顧問股份有限公司地理空間資訊部工程師 / 楊軒
台灣世曦工程顧問股份有限公司地理空間資訊部工程師 / 周孜恆
台灣世曦工程顧問股份有限公司地理空間資訊部技術經理 / 吳錫賢

關鍵字：無人機、深度學習、車輛偵測、車輛追蹤

摘要

隨著無人機載具軟硬體技術不斷進步，利用高解析度相機搭載於無人載具上能夠拍攝寬闊道路區域之影像。此類使用無人機視訊（Video）影像為基礎之方法，用於地面交通工具辨識和流量計算，相對於路側單元（Roadside Unit）方式，更具出色之機動性和拍攝範圍，因而具備顯著優勢。為加強空間資訊技術於交通管理領域之應用，台灣世曦採獨立研發方法利用無人機針對交通車流進行高空動態影像拍攝，並運用深度學習（Deep Learning）技術，成功開發車輛偵測及車輛追蹤技術，為輔助偵測道路上車速及流量準確檢測提供創新解決方案。

本研究聚焦於無人機視訊影像（UAV-based Video）之交通工具物件辨識，包含車輛偵測及車輛追蹤技術開發，以提供更精確的交通參數。研究過程中，車輛偵測技術用來自動識別車輛，並將其分類為不同類型，而車輛追蹤技術則追蹤同一輛車在連續影像中的位置，以供後續車速計算使用。透過前述技術應用，能夠萃取出移動中車輛之準確空間資訊，將有助於精確分析交通路況資訊以利交通管理應用。

一、前言

人工智慧應用於近幾年呈顯著成長，從影像辨識領域到大型語言模型的成功商業

化，隨機器學習（Machine Learning）模型參數不斷呈指數型成長，機器學習商業化應用的高門檻顯已形成。以搭載高畫素相機之無人機進行道路影像擷取，對比傳統路側單元，無人機以高機動性及廣闊拍攝範圍更勝一籌。因此，作為新型解決方案，利用無人機辨識交通工具相當具有潛力。台灣世曦自主研發此項技術並透過深度學習影像辨識演算法開發出車輛偵測及車輛追蹤技術。深度學習為機器學習的一項分支，主要使用人工神經網路的分層演算法結構，能夠發揮最近似於人類思考邏輯的人工智慧功能。透過車輛偵測技術，能夠自動識別交通工具並進行分類，搭配車輛追蹤技術，能夠在連續影像中追蹤同一輛車的位置，並利用道路長度及通過時間反算車速。

透過此簡便方法得到精確之交通參數來投入交通管理領域中，未來透過車輛之空間資訊有助於精確分析交通路況，期望能帶給城市交通管理更便捷及精確之解決方案。本研究目標為反演車輛相關交通參數，目標以無人機進行視訊影像蒐集，透過深度學習發展自動化無人機視訊影像之車輛判識及追蹤，以強化空間定位。研究主要包含三個核心研究項目（圖1）：對位

（Georeferencing）、偵測（Detection）、追蹤（Tracking），對應的研發項目包含視訊影像穩定化處理及地理坐標對位、車輛偵測及種類識別、車輛追蹤及反演車輛軌跡與車速。全程工作目標為核心技術開發、測製流程建立、區域執行實際實驗。

二、研究方法

伴隨無人機方便地獲取視訊影像，衍生大量的影像需進行車輛辨識（Recognition），若以人工判識將大幅增加測製成本，因此以深度學習進行自動辨識是本研究之關鍵發展技術，其中包含影像穩定化處理、車輛追蹤及其軌跡與車速計算。相關工作條列及說明如下：

（一）地理空間對位

1. 視訊影像穩定化處理

以旋翼型無人機固定視角及高度，對國道路段側向拍攝影片，同時記錄靜態與動態交通工具之資訊。由於無人機懸停（Hovering）空中進行拍攝時，氣流擾動容易影響機身穩定使影像產生模糊，因此，空拍影片於進行車輛辨識及追蹤前需透過穩定



圖1 核心研究項目

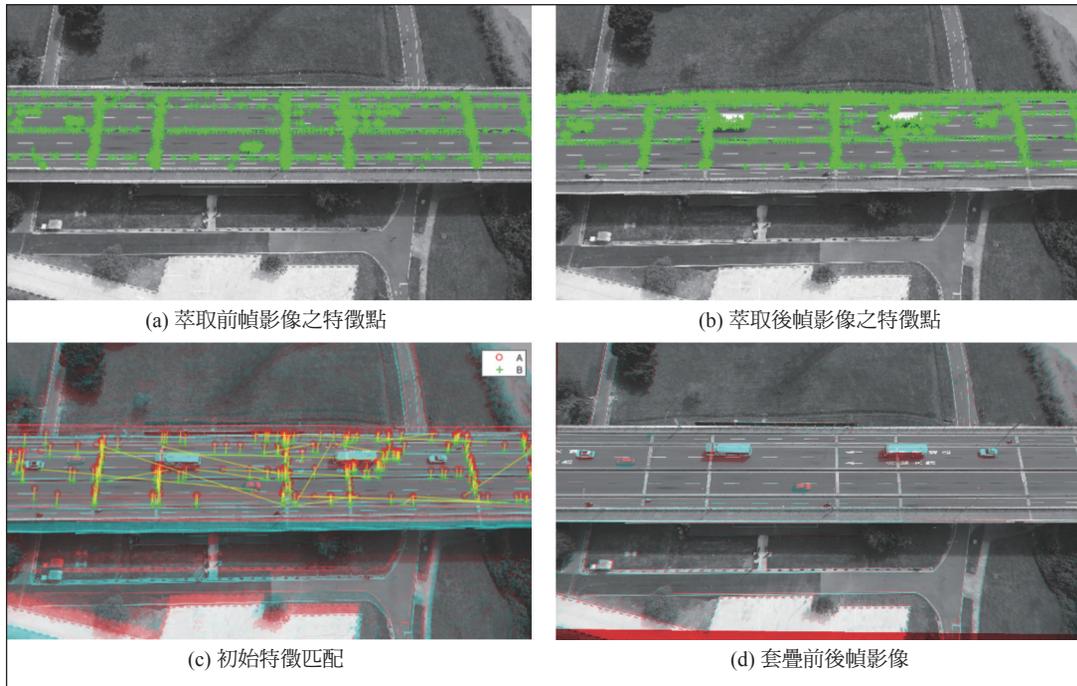


圖 2 視訊影像穩定化處理程序

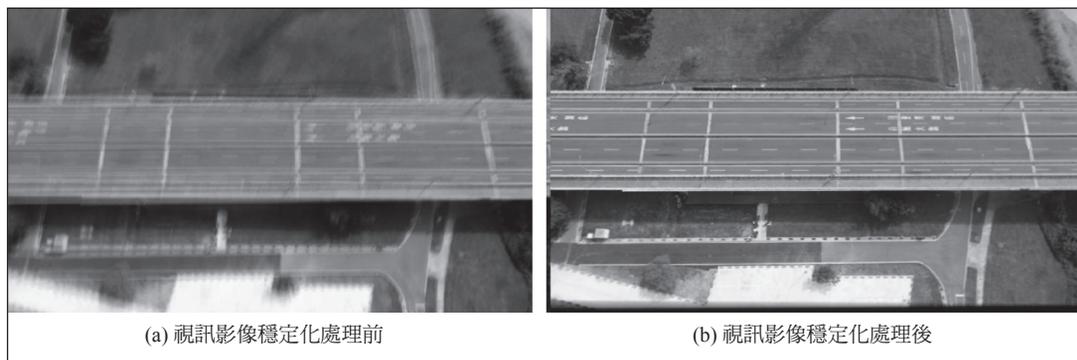


圖 3 視訊影像所有像幅之疊加及平均

化處理來消除模糊現象。首先劃定國道部分路段作為目標區並將影片轉為多幀單一影像，接著提取時間序列中前兩幀影像，利用加速穩健特徵演算法（Speeded Up Robust

Features, SURF）（Bay et al., 2006）在特徵空間尺度中萃取影像對之特徵點，完成初始匹配並濾除雜訊後，計算像對視差，輔進前後幀影像之套合作業（圖2）。圖3為視訊影

像所有像幅之疊加及平均，以視訊影像穩定化處理之前後差異作為比較，經過穩定化處理，可明顯提升各幀影像的一致性。

2. 視訊影像地理空間化處理

經過視訊影片穩定化處理後，接下來為空間化處理，目標使每幀影像坐標 (S, L) 均具有地理坐標 (E, N)。本研究以參考正射影像為底圖並作為基準，人工量測首幀影像及正射影像之路面控制點，再以最小二乘平差法計算之轉換係數 ($a_{11} \sim c_{12}$) (式1)，同一視訊影片之各幀影像均使用同一轉換參數，地理坐標對位成果詳圖4。

$$E = \frac{a_{11}S + a_{12}L + a_{13}}{c_{11}S + c_{12}L + 1} \quad (\text{式1})$$
$$N = \frac{b_{11}S + b_{12}L + b_{13}}{c_{11}S + c_{12}L + 1}$$

(二) 交通工具物件識別

本案交通工具物件識別部分著眼於大型與小型車輛，演算法部分採用Faster-RCNN (Ren et al, 2015)。該法由RCNN (Region CNN) (Girshick et al., 2014) 及Fast-RCNN (Girshick, 2015) 演進而來。其中RCNN部分使用Selective Search演算法，從輸入影像中萃取大量的候選區塊 (Region Proposal)，

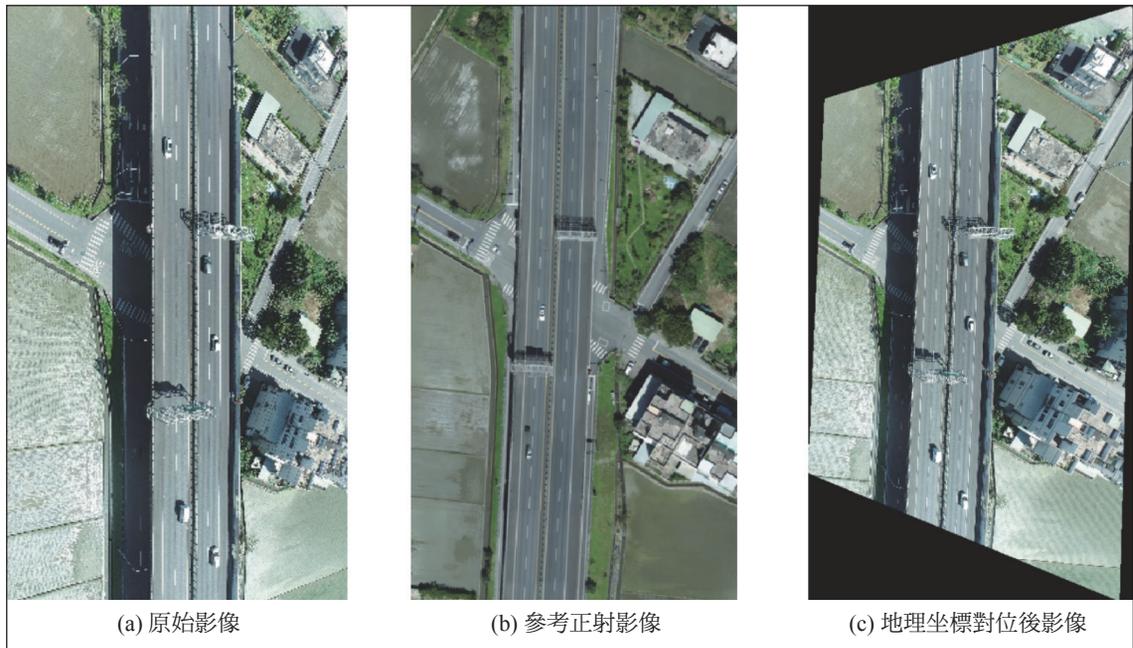


圖 4 地理坐標對位成果示意圖

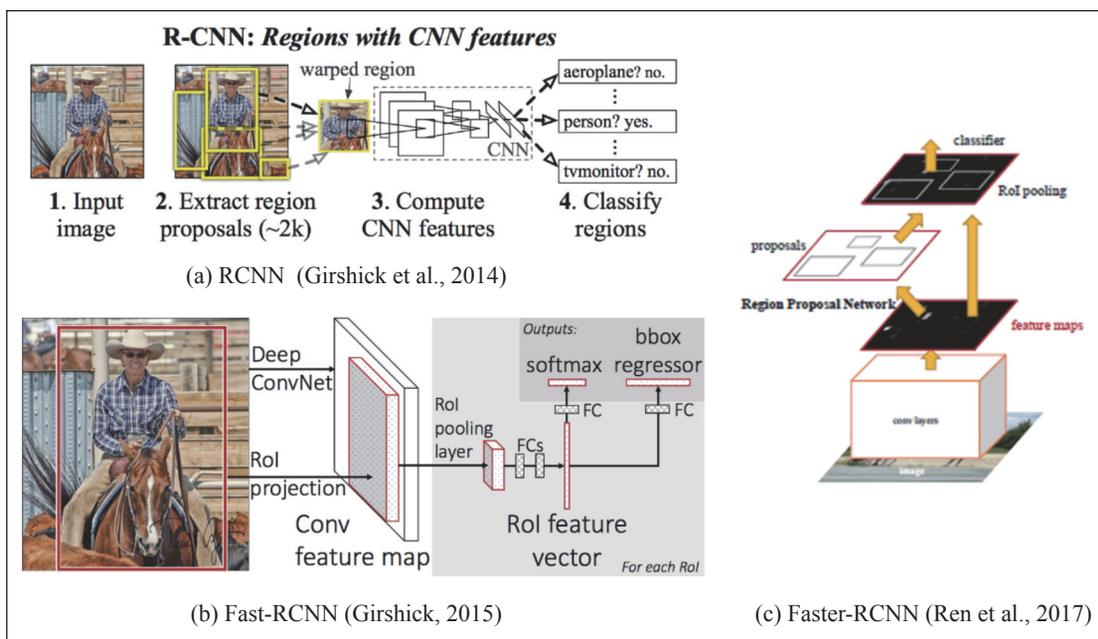


圖 5 RCNN, Fast-RCNN 及 Faster-RCNN 架構圖

接續透過CNN (Convolutional Neural Network) 以卷積特性對其萃取特徵，再利用SVM (Support Vector Machine) 分類器進行分類，對分類作目標物的多重外框進行線性回歸，最終獲得目標物的外框 (Boundary Box) (圖5(a))。Fast-RCNN僅進行一次完整影像的CNN特徵提取，並使用RoI pooling (Region of Interest Pooling) 將選取的 region proposal映射到CNN的特徵圖上。之後，這些特徵經過各自的全連接層 (Fully Connected Layer) 進行分類和邊界框線性回歸，最終生成目標物體的外框 (圖5(b))。Faster-RCNN則更進一步改進了RCNN的 Selective Search演算法，用於提取區域建議

區塊。與RCNN的Selective Search演算法相比，Faster-RCNN使用了Region Proposals Network (RPN) 以及Anchor box，以進一步增強RCNN的效能 (圖5(c))。

(三) 車輛追蹤

本研究使用物件追蹤方法為DeepSORT (Wojke et al., 2017) (圖6)，其採用Faster-RCNN進行車輛偵測獲取其邊界框，再對框內目標進行表面特徵與運動特徵提取，透過級聯匹配 (Matching Cascade) 的方式，將最新且頻繁出現的目標優先進行匹配，增加其可靠性，若結果吻合，則更新卡爾曼

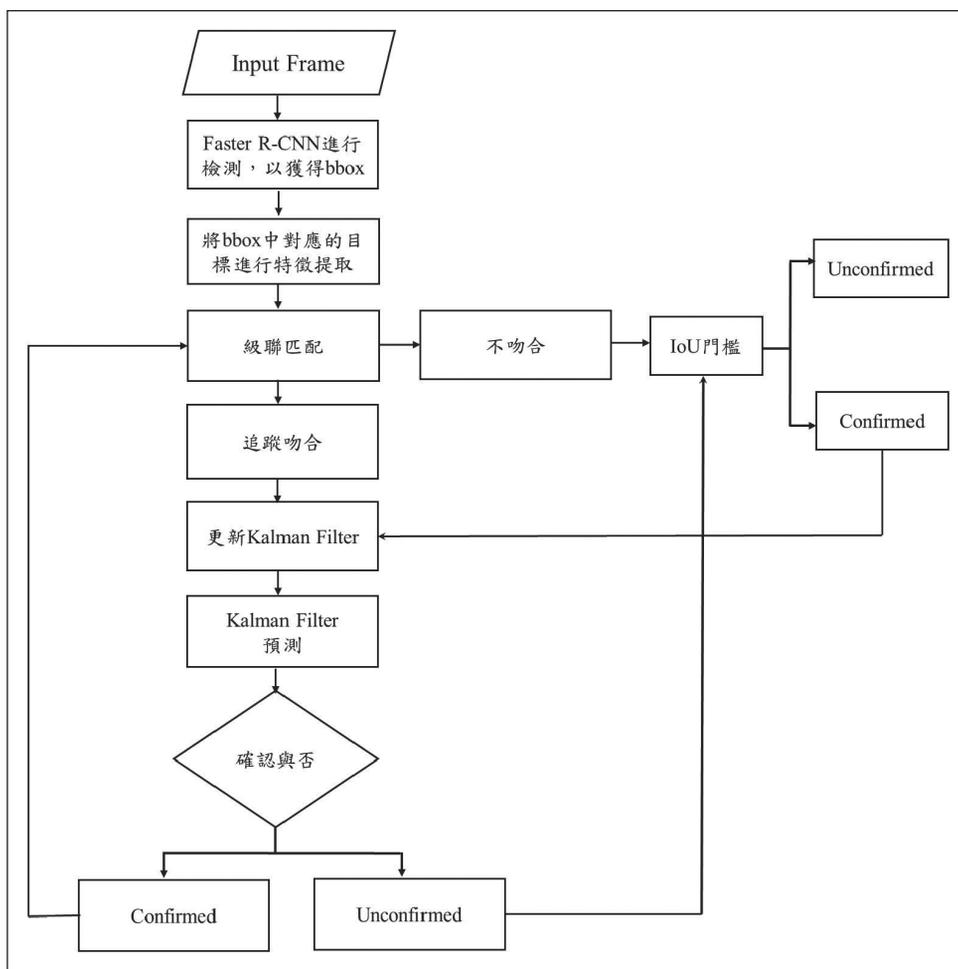


圖 6 Deep SORT 流程圖

濾波 (Kalman Filter)，並透過卡爾曼濾波器預測其位置，若正確則持續進行匹配，若不正確則透過匈牙利演算法 (Hungarian algorithm) 將卡爾曼濾波器預測到的框與當前偵測到的框進行 Intersection over Union (IoU) 匹配，獲得數據的相關性，因有設定其最小的IoU交集與相似度門檻進行篩選，若目標物短時間被遮蔽，依然可以在重新出現

時，可持續被追蹤，追蹤成功後再更新卡爾曼濾波器，再次匹配不成功則可能被視為新追蹤物或是刪除。

(四) 車輛軌跡及車速

為使車輛追蹤成果得以應用於交通分析，故將車輛追蹤成果搭配影像空間化，將影像坐



標 (S, L) 轉化為作絕對坐標 (E, N) (參考式 (1))，再行軌跡追蹤及車速反演。

$$\Delta D = \sqrt{(E_i - E_0)^2 + (N_i - N_0)^2} \quad \text{式 (2)}$$

$$V = \frac{\Delta D}{\Delta t} = \frac{\Delta D}{\Delta \text{frame} * \text{frameRate}} \quad \text{式 (3)}$$

將車輛的坐標轉換至物空間坐標後，利用標定車輛坐標之時間序列，由起訖坐標計算距離 (式 (2))，再除上時間間隔即可轉換得速度 (式 (3))，成果展示尚可透過繪製Space-Time圖予以表示，Space-Time圖中的橫軸代表時間，縱軸代表空間，即距離，斜率則代表車輛的速度，若速度越快，則線段會越趨近於垂直；若車速越慢，線段越趨近於水平，當線段水平時，則有可能是車輛已停止，如等紅綠燈或有路況問題而停留於原地。

三、研究成果

各項研發成果分別為資料收集 (UAV Video)、影像穩定化暨空間化處理 (Video Stabilize & Geo-Projection)、交通工具物件識別 (Detection)、車輛追蹤 (Tracking)、交通參數計算與分析 (Traffic Parameter Extraction) 等步驟，最終得到交通數據參數 (Traffic Parameters)。整體資料處理流程如圖7所示。

(一) 資料蒐集

1. 物件偵測訓練資料集

為建立深度學習之偵測車輛 (Vehicle) 所需樣本，本研究採用VAID (Vehicle Aerial Imaging from Drone) (Lin et al., 2020 ; Li &

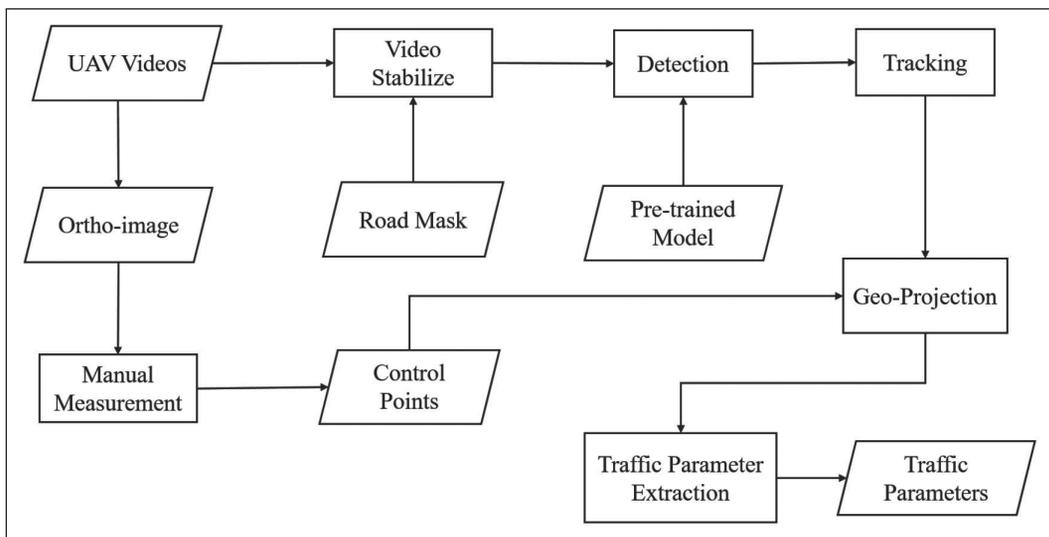


圖 7 研究流程

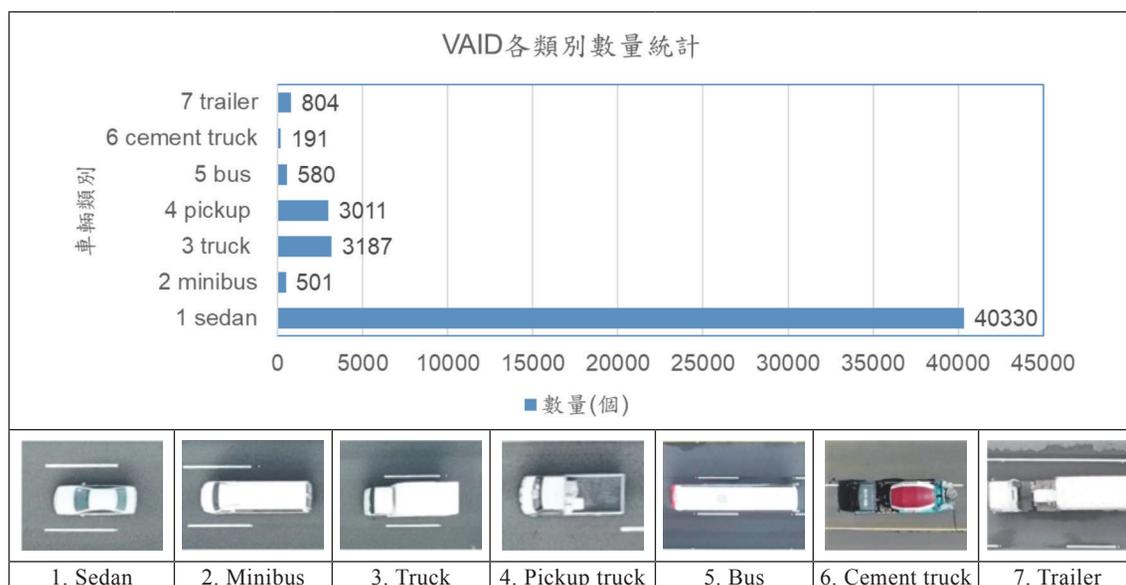
Lin, 2020) 資料集作為深度學習模型訓練資料集之基底。VAID使用臺灣本地拍攝之無人機影像，相關研究亦多應用於車輛偵測，建置資料方式為使用無人機 (DJI Mavic Pro) 於市區、郊區及大學校園內拍攝不同交通狀態的影片，影片幀率設為23.98 fps，經處理後將影片轉換為1137 × 640 pixels的影像 (空間解析度約12.5 cm)，以JPEG格式儲存，總計約14,809張影像。蒐集資料時無人機於道路上方固定視角懸停對路面拍攝，依拍攝時的光照條件將資料分為晴天、傍晚和陰天等三種影像。另外，為了使車輛在所有影像中的尺寸一致，將飛行高度保持離地約90至95公尺。資料屬性標註由專業人士將車輛分為7類，如表1所示，由左至右分別為轎車、小型巴士、卡車、輕便客貨兩用車 (Pickup

truck)、公車、混凝土攪拌車 (Cement truck) 及拖車 (Trailer) 等，其中數量最多者為轎車 (Sedan) 40330輛；最少者是混凝土攪拌車 (Cement truck) 191輛。以上所述之VAID資料集拍攝方式與本研究實驗配置相近，且資料集車種樣式與本研究路段內車種略同，因此VAID資料集非常適合作為訓練資料集之基底。

2. 高速公路視訊影片

高速公路影片同樣以DJI Phantom 4 RTK無人機進行資料收集，影片像幅大小為3840 × 2160 pixels，取樣頻率為每秒30幀 (30 fps)，資料獲取日期為2022/03/09，實驗區為位於宜六線與縣191交會處路口上方之國道五號，全區道路長度為230公尺，單一影片道路長度

表 1 VAID 資料集車輛類別 (Lin et al., 2020)



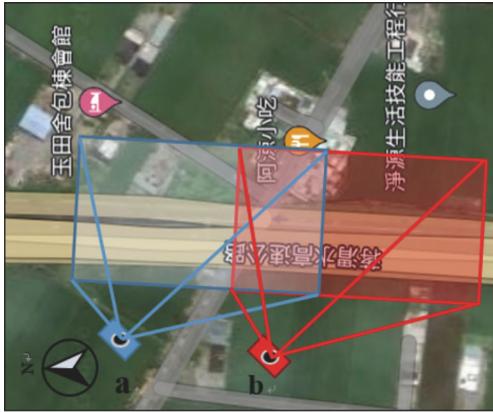


圖 8 a、b 攝影站位置

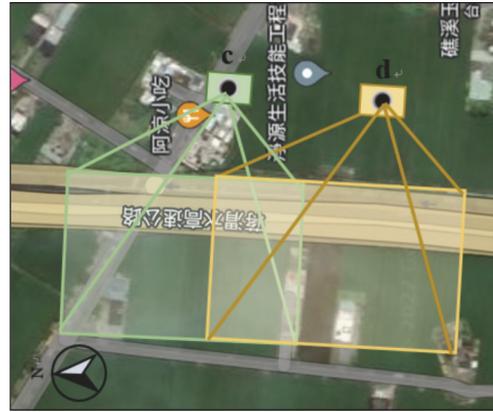


圖 9 c、d 攝影站位置

約為130 m，如圖8及9所示。所收集的資料包含共12個MOV錄像檔（取樣時長均約2分鐘），分別由兩個相鄰的拍攝位置以不同方向進行定點蒐集，離地航高包含100、80及60 m等拍攝高度，分別編號為A01、A02、A03、B01、B02、B03、C01、C02、C03、D01、D02及D03（數字01、02、03分代表代表航高100、80及60 m）。

3. 擴增物件偵測訓練資料集

由於本研究使用的無人機視訊影像可能與訓練資料集有不同的特性，故人工數化擴充訓練資料集為必要措施。本次作業選用LabelImg作為影像標註工具，LabelImg是一款用於影像標註之開源軟體，不需下載與安裝程式即可執行，標註之矩形能夠以多種方式紀錄物件屬性，包含文字、影像、複選框及下拉選單等。完成標註的檔案得以XML格式儲存與輸出。本研究針對2022/03/09高速

公路視訊影片進行人工數化成為CECI0309資料集，補標註油罐車Oiltruck並將其加入Trailer類別，補足VAID不足之處，其中Oiltruck車體為圓柱狀如鋼瓶，共新增43個Oiltruck，表2為各類別示意圖，表3為擴增訓練資料之數量。

(二) 影像穩定化暨空間化處理

無人機懸停拍攝視訊影片時，受側風等因素影響，造成視訊影片內容晃動，本研究透過視訊影像穩定化處理鎖定道路區域進行對位，以減少因無人機載台的飄移及晃動，使不同時間各像幅之間具有一致的相對關係。圖10係以A拍攝點之3個視訊影片展示穩定化處理成果，每一視訊影片左圖是穩定化處理前影片之平均值，而右圖則是穩定化處理後影片之平均值，此資料處理程序可提供更為清晰且相對關係一致的影片平均值，故

表 2 車輛偵測類別列表

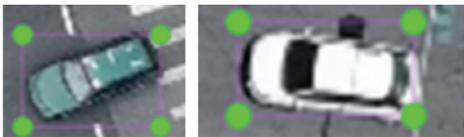
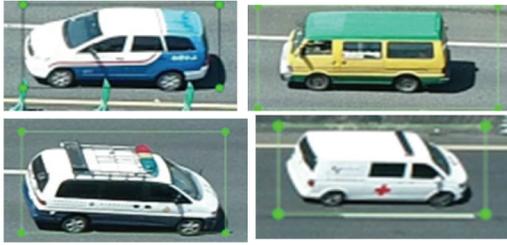
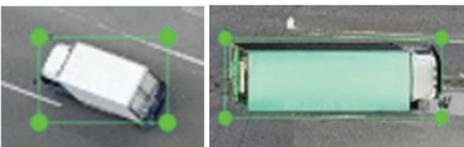
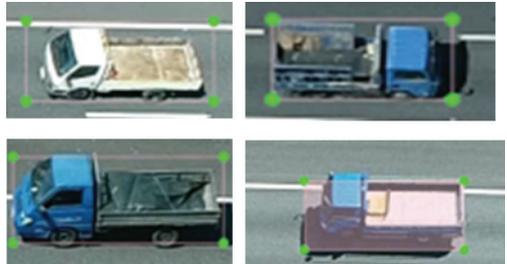
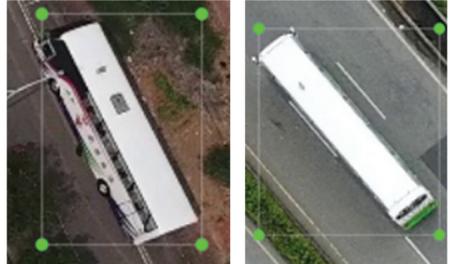
	
<p>Sedan</p>	<p>Minibus</p>
	
<p>Truck</p>	<p>Pickup truck</p>
	
<p>Bus</p>	<p>Cement truck</p>
	
<p>Truck and trailer</p>	<p>Oiltruck</p>



表 3 CECI 擴增訓練資料集統計表

Category	1	2	3	4	5	6	7	8	Total
VAID	40330	501	3187	3011	580	191	804	0	48604
Augment	9381	92	596	719	119	19	368	43	11337
Total	49711	593	3783	3730	699	210	1172	43	59941

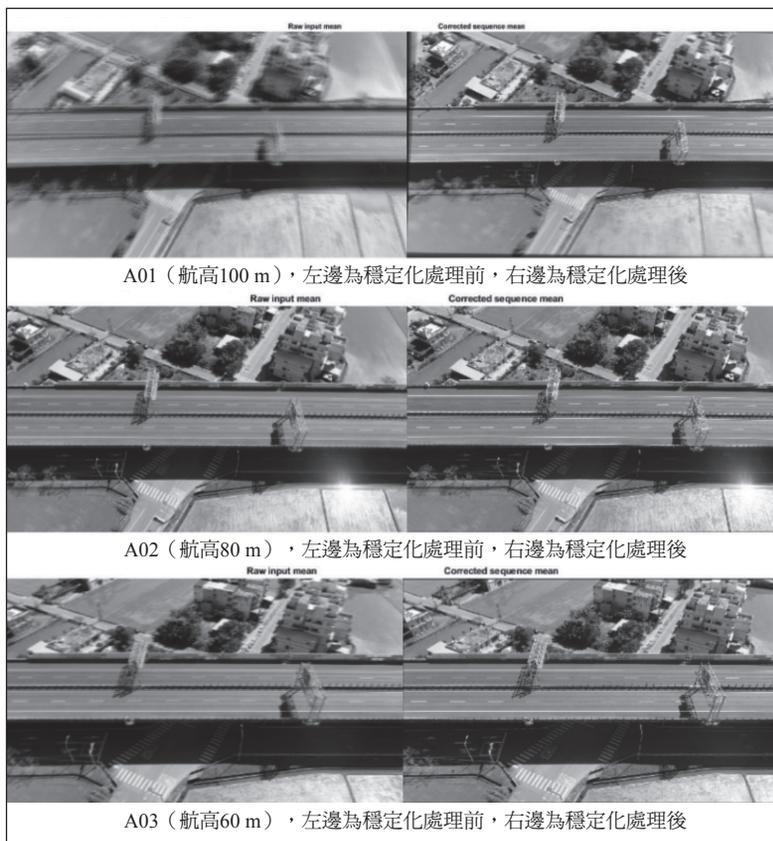


圖 10 視訊影像穩定化處理成果

可證實本研究發展的視訊影像穩定化處理可落實於實際視訊影像。

影像穩定化處理後，同一視訊影像各個

像幅已具有一致的坐標，因此可將視訊影像的第1幀影像為基準，進行空間化處理。從第1幀影像與參考正射影像量測控制點執行坐標轉換，將視訊影像空間坐標 (S, L) 投影至

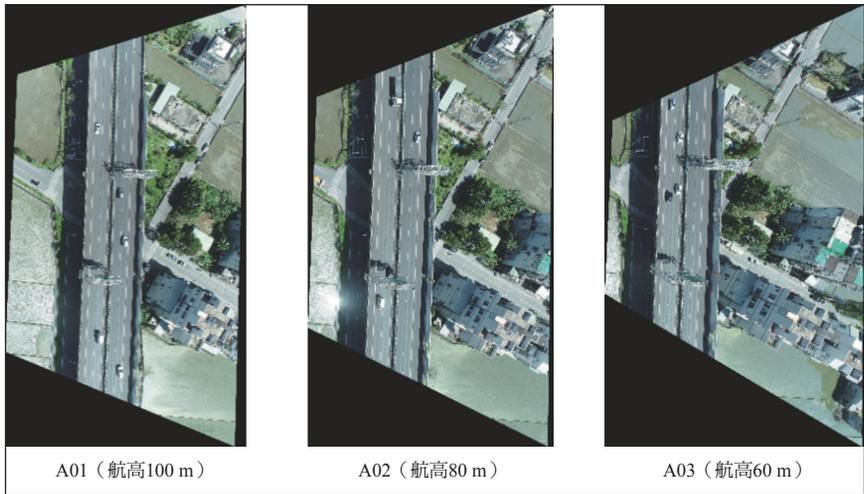


圖 11 視訊影像穩定化處理成果

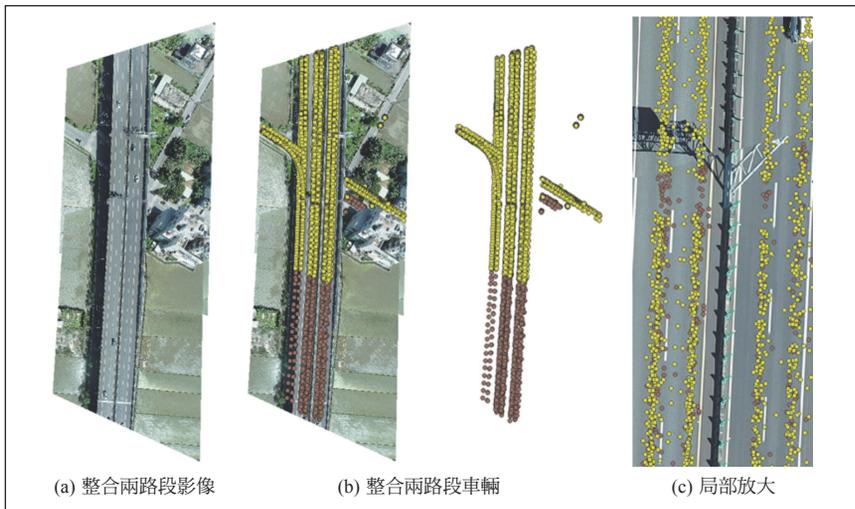


圖 12 空間化物件偵測成果優勢

物空間坐標 (E, N) 位置，下圖亦以A拍攝點之三部影像之首幀為代表，展示視訊影像之地理定位之成果（如圖11所示）。

原影像物件偵測成果將由像空間轉為物

空間，4拍攝點資料最終不僅整合兩路段的影像，亦整合兩路段的車輛，如圖12，黃色為A01資料集所獲取的車輛資料，咖啡色為B01所獲取的車輛資料，並且可以透過縮小放大仔細進行檢視。



(三) 交通工具物件識別

為增加訓練樣本，以提升模型預測精度，本項工作將VAID資料集及人工數化CECI0309資料集整合，以利提升Faster-RCNN之訓練成效，其中隨機抓取80%的資料作為訓練 (Train) 資料集，其餘20%則為測試 (Test) 資料集，其主要應用於獨立檢驗，分別命名為Mixed_train資料集 (6059張影像) 及Mixed_test資料集 (1514張影像)，如表4。同研究方法所述共分為七個類別：Sedan、Minibus、Truck、Pickup truck、Bus、Cement truck、Trailer (包含Oiltruck)，而Mixed_train資料集再細分為Train及Validation。

1. 建立深度學習模型：Mixed_train資料集

本研究考量開源訓練資料集樣本數之不足，故整合VAID及CECI0309人工編修訓練資料集，以提升車輛偵測能力，另箱型車類的Minibus合併進入Sedan，僅保留軸距較長的Minibus並再進一步除去分類錯誤。驗證分析部分則透過AP (Average Precision) (式4) 來評估模型。

$$AP = \frac{1}{11} \sum_{recall(i \in \{0.0, 0.1, 0.2, \dots, 1\})} Max(precision(i)) \quad (式4)$$

經由迭代計算可得獲取模型之total loss及validation loss，觀察loss function收斂的情況均為遞減且穩定，續採用AP進行成果驗證之統計 (表5)。觀察模型擬合成果之AP，本研

表 4 統計模型訓練資料各類別數量

Distribution of instances among all 7 categories (Train)							
Category	Sedan	Minibus	Truck	Pickup truck	Bus	Cement truck	Trailer
Instances	31553	364	2406	2430	431	128	722
Total	38034						
Distribution of instances among all 7 categories (Validation)							
Category	Sedan	Minibus	Truck	Pickup truck	Bus	Cement truck	Trailer
Instances	8172	109	616	636	119	40	162
Total	9856						

表 5 模型收斂後各類別之最終 AP

Per-category bbox AP							
Category	Sedan	Minibus	Truck	Pickup truck	Bus	Cement truck	Trailer
AP	72.133	72.257	65.675	59.643	77.340	63.589	74.547

表 6 模型收斂後各類別之最終 AP

Evaluation result for bbox					
AP	AP50	AP75	APs	APm	API
69.312	93.785	87.480	47.667	71.393	58.804

究採用整合VAID與LabelImg人工標記所建立的模型，可在AP50 (IoU 0.5) 時達93.785% (表6)。

1. 獨立驗證分析：Mixed_test資料集

獨立驗證分析採用Mixed_test資料集，以矩形外框為單元的Object Detection深度學習精度分析使用三種各類別評估指標，Precision (式5)、Recall (式6)、F1-Score (式7)。

$$\text{Precision(準確率)} = \frac{TP}{TP+FP} \quad (\text{式 } 5)$$

$$\text{Recall(召回率)} = \frac{TP}{TP+FN} \quad (\text{式 } 6)$$

$$F1 - \text{Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{式 } 7)$$

其中，TP (True Positive) 為真實情況「有」，模型判識作「有」的正確個數；FN (False Negative) 是真實情況「有」，模

型卻判識「沒有」的錯誤個數；FP (False Positive) 是真實情況「沒有」，模型而判識「有」的錯誤個數。透過模型進行Mixed_test的預測結果如下方計算式，可得漏授為261個 (Omission)、誤授為262個 (Commission)。其Recall、Precision、F1-Score分別計算如表7，F1-Score值域範圍為0到1，而0.97的成果可知模型預測精度相當高。(Recall代表模型能夠正確地預測出多少事實為真的樣本，Precision代表模型預測為陽性的樣本中有多少樣本是事實為真，而F1-Score則代表模型的總體表現)：

物件偵測上述訓練模型進行測試，此模型可同時應用於本研究高速公路視訊影像及原始VAID資料集，模型預測成果展示如圖13。

表 7 獨立驗證資料集之誤差矩陣

		真實		參數計算
		事實為真 (Positive)	事實為假 (Negative)	
預測	預測為陽性 (Positive)	TP = 9564	FP = 262	Precision = 0.97 Recall = 0.97 F1 - Score = 0.97
	預測為陰性 (Negative)	FN = 261		



圖 13 模型預測成果展示

(四) 車輛追蹤

為使每幀影像中的車輛具連貫性，進而獲取車輛運行軌跡，且可同時對多部車輛進行追蹤。本研究透過Faster-RCNN執行影像物件偵測，框選每張影像上的目標物件，接著DeepSORT在連續影像中比對框選區域特徵，將相同目標物給與單一編號，如圖14之案例。追蹤不同影像間的另一物件給予相同編號Sedan-8。

(五) 地理空間定位

為了反推的軌跡及車速，將追蹤的成果進行坐標轉換，由影像坐標 (S, L) 空間轉換至物空間坐標 (E, N)。首先須人工量測控制點，各影片控制點量測數量如表8，統計13個視訊影像地理空間化在E及N方向的RMSE (Root-Mean-Square Error) 均小於0.1 m，可滿足車輛定位之需求。



圖 14 前後幀影像進行比對

表 8 空間化精度分析表

Video ID	Number of Control Point	RMSE (m)	
		ΔE	ΔN
A01_60_100	10	0.049	0.042
A02_60_80	9	0.028	0.040
A03_60_60	9	0.045	0.049
B01_30_100	8	0.058	0.048
B02_60_80	9	0.051	0.030
B03_60_60	8	0.048	0.017
C01_60_100	10	0.055	0.047
C02_60_80	10	0.056	0.033
C03_60_60	8	0.049	0.022
D01_60_100	10	0.058	0.022
D02_60_80	8	0.054	0.025
D03_60_60	8	0.066	0.025
D04_60_50	8	0.068	0.024

將轉換後的車輛軌跡匯入QGIS，並套疊在正射影像中，軌跡如圖15。其中，因為ID457的車輛位於平面道路，車速低於每小

時60公里，因此軌跡為藍色，其速度與位置皆符合常理。計算圖中三輛車的平均速度，ID457的橋下車輛平均速度約為每小時32.17

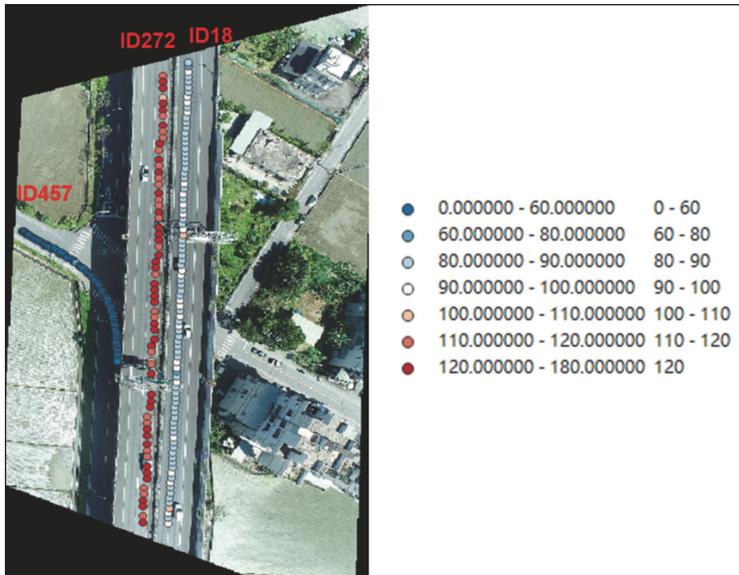


圖 15 車輛軌跡圖

公里，ID18的車輛為平均速度每小時88.42公里，ID272的車輛為平均速度每小時121.43公里，如圖16。

(六) 交通參數計算與分析

本實驗著眼於高速公路範圍內車輛（未含平面道路車輛），為便於解析交通概況，須將無人機所拍攝的結果進行交通參數的運算，導出成果包含Space-time圖表、各類車輛的總數、各類別車輛的平均速度、最快速度、最慢速度及速度標準差，以利輔助後續交通規劃、車流疏散等交管措施。

1. Space-Time Diagram

Space-Time Diagram的每一條線代表每

一部被追蹤成功的車輛，其線段的斜率即代表車速，線段間的斜率若一致，係代表車速相近，然而線段的斜率若相差越大，則代表車輛間的行駛速度有所差異，而同一路段各車輛速度不一致之情況，將容易導致車禍，抑或是發生塞車等情形，對於用路人而言須多加注意路況。本小節以相同航高（60 m）之4個拍攝點的Space-Time Diagram進行成果展示（圖17），可觀察得：此筆直且平穩的高速公路且於該錄影時間區段內，無發生車輛間速度差異甚大之問題。

2. 各類別車輛數量統計

統計各類車輛數量將能分析該路段的常見車種，以利未來交通規劃、路面結構設計等相關議題。針對本研究12部影片進行各類

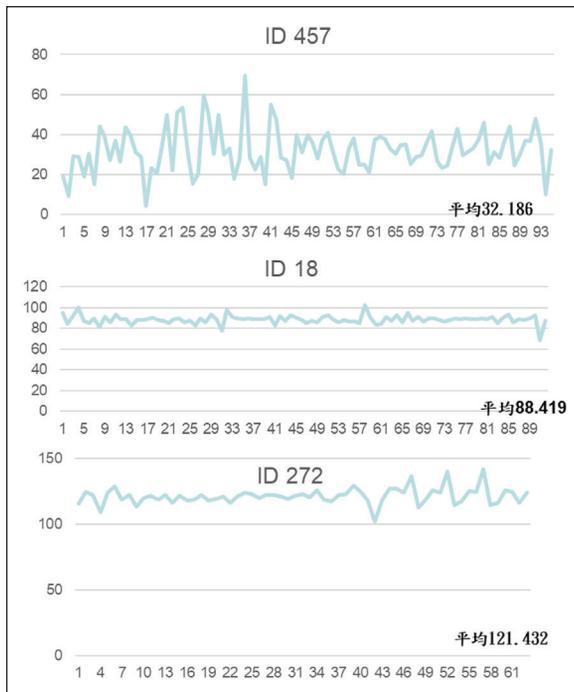


圖 16 三輛車之時間速度圖，其中 ID457 為平面道路車輛，ID18 及 ID272 為高速公路車輛

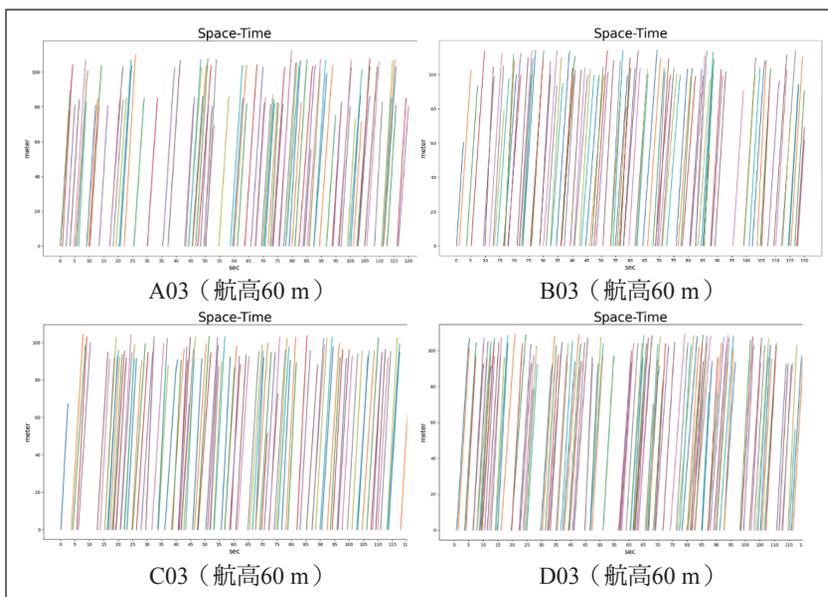


圖 17 Space-Time Diagram



別車輛統計，以Sedan數量為最多（平均92輛），其次為Truck（平均66輛），Minibus數量僅有一台，而Cement truck則完全未偵測到。另直接觀察影片內容，A01及D03影片中的車輛最多，A03、B01與C01車輛相對較少，而偵測成果亦吻合現況（圖18）。

3. 各類別平均速度統計

觀察各車種統計速度（圖19），Sedan在12個影片當中是平均車速最快，平均速度為每小時93.37公里；其次為Truck，其平均速度為每小時91.26公里；最慢的車種為Bus，其平均速度為每小時84.90公里，由於Cement

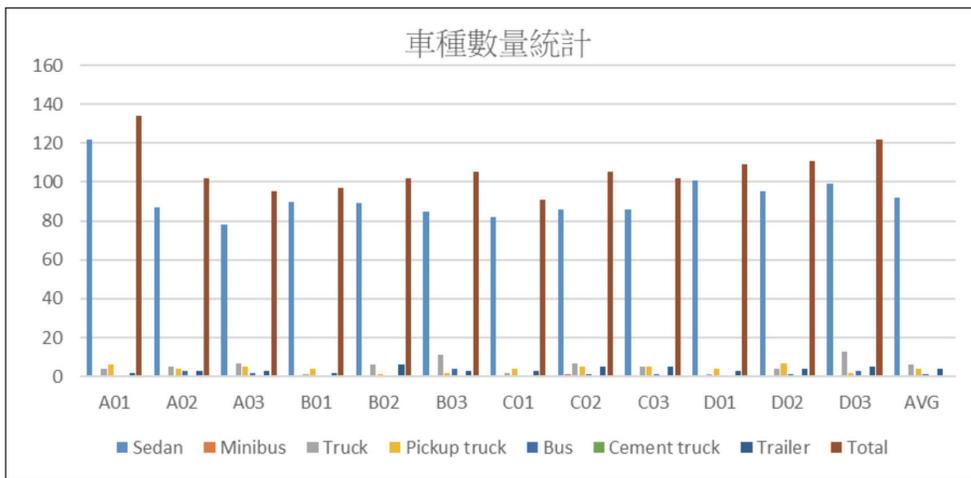


圖 18 各類別車輛統計（單位：輛）

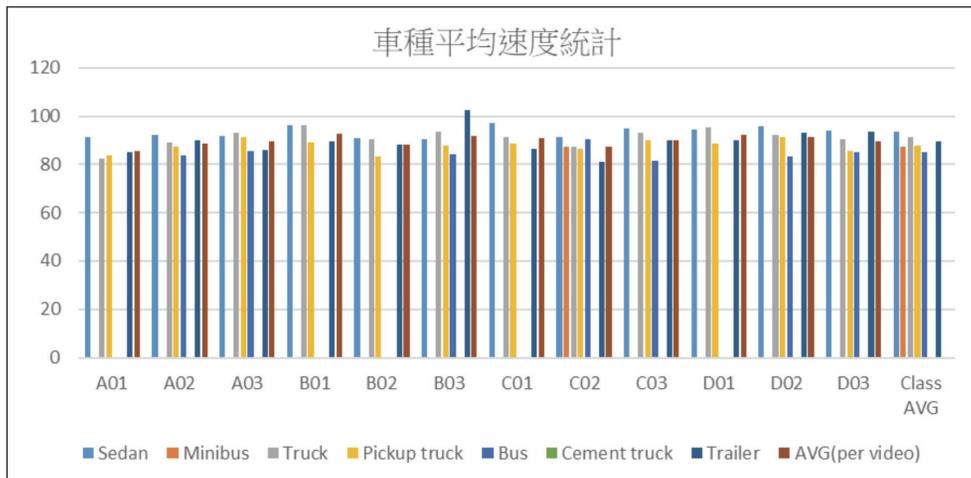


圖 19 各類別平均速度統計（單位：km/hr）



truck數量過少，因此忽略不計。至於各影片的平均速度的部分，則為B01速度最快（每小時92.72公里），藉此可以推測車流量較少，與前一小節「3-6-2各類別車輛數量統計」結論一致。綜合以上來看，每類別的平均車速皆落在約每小時90公里亦於國道速限規範值內。

3. 各類別最高速度統計

統整各車種於12錄像中所計算得之最高速度（如圖20），相同地不論於何種錄像，在各類別車輛當中，最快者亦為Sedan，另以各類別平均來看，同為Sedan最快（最高速度之平均為每小時126.71公里），第二快者為Truck（最高速度之平均為每小時102.43公里）。以各影片之各車種最高車速而言，B02影片當中的最高速度之平均為最快，達

每小時109.26公里，而C01影片的最高速度之平均為每小時99.97公里，為所有實驗影片中最慢者。

4. 各類別速度標準差統計

統整各車種於12影片中所計算得之速度標準差（圖21），觀察各車種平均標準差，Sedan標準差為最大（平均每小時9.96公里）；其次為Truck（平均每小時7.97公里）；而標準差最小者為Bus（平均每小時1.46公里），主因為巴士作為大型載運交通工具，因此重視安全性其行車速度變化較小，且多固定行駛於外側車道，無頻繁加減速之行為，據此該統計成果合乎基本邏輯，另小巴士Minibus與Cement truck數量過少，因此不納入分析。

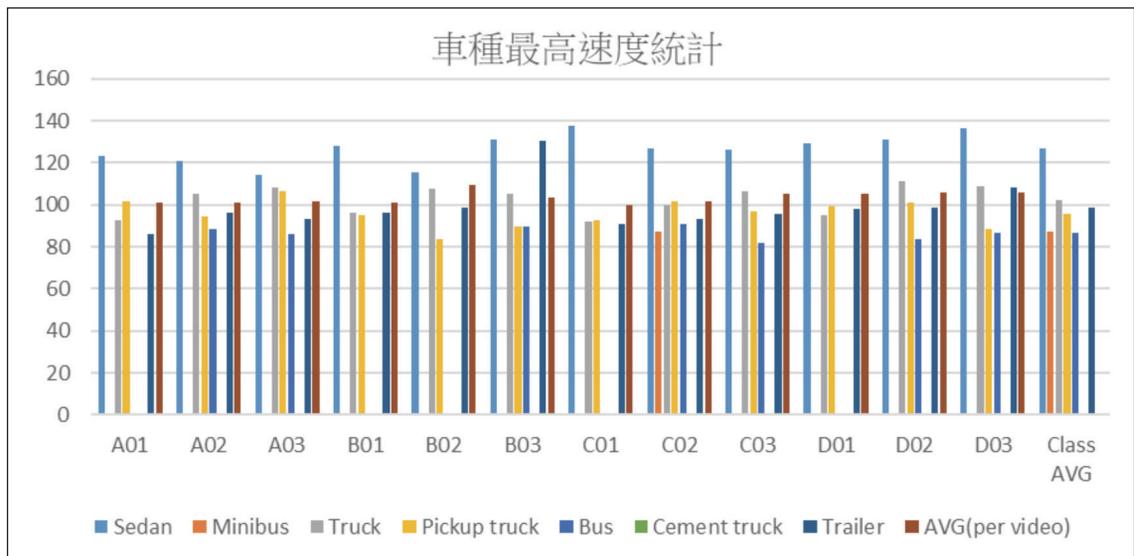


圖 20 最高速度統計（單位：km/hr）

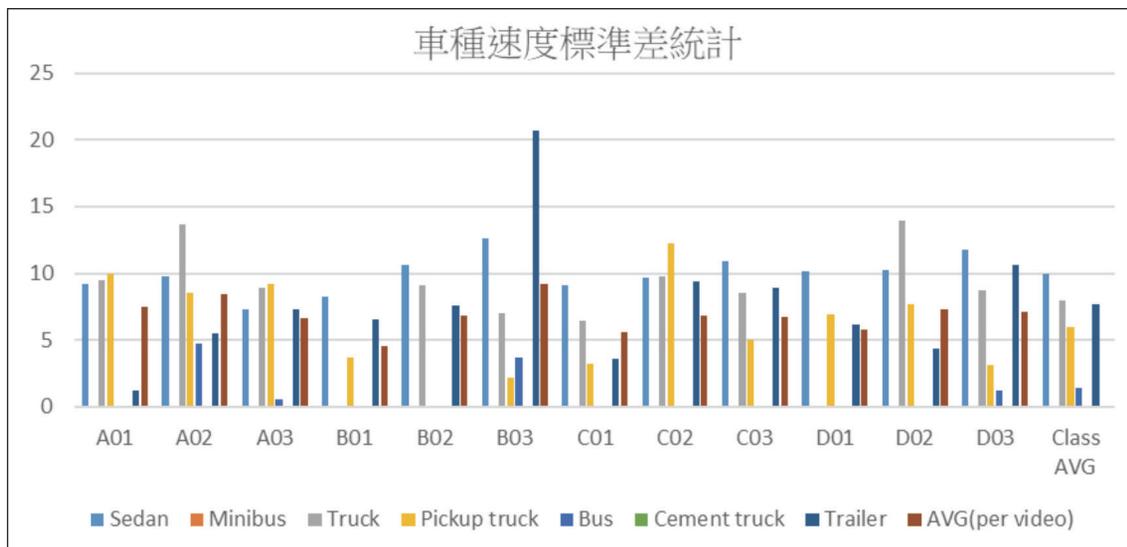


圖 21 各類別速度標準差統計 (單位: km/hr)

四、結論與未來建議

本研究使用無人機視訊影像成功偵測及追蹤車輛，也展示影像穩定化的效果理想具實用性，其中小轎車的偵測能力為最佳，而皮卡車及大卡車的偵測能力較差，未來建議仍需要增加這類交通工具的訓練樣本。本研究主要成果包含開發視訊影像穩定化前處理程序，再經由投影轉換將影像坐標轉換到絕對坐標；增加訓練資料集，建立台灣世曦獨有之車輛資料集；透過Faster-RCNN建立深度學習模型，經過精度分析，獨立檢核區之Precision、Recall及F1-Score均達到0.97，驗證車輛偵測模型具有高辨識能力；開發車輛追蹤程序，可追蹤同一台車在連續影像中的位置；利用控制點進行影像坐標(S, L)轉換

至物空間坐標(E, N)的參數計算，以取得影像中的比例尺資訊；將各類別、各區域車輛進行交通參數計算與分析，如平均車速、各類別車輛統計、Space-Time Diagram等。

本研究旨在透過便利且機動性高之無人機獲取交通車流資訊，但相對地也受到無人機本身之限制，例如：無法於雨天或風力過強之天候下飛行、無人機續航力有限故無法長時間監控車流狀況、無人機需具備安全起降地點等。總而言之，科技發展快速，機器學習演算法也不斷地疊代更新，本研究為無人機影像實現交通車流之智慧偵測方法奠定基礎。未來將持續改進作業流程，以提升車輛偵測模型精度及應用價值。



五、誌謝

本研究承蒙國立陽明交通大學土木工程學系張智安教授研究團隊技術諮詢，謹此致謝。

參考文獻

1. Bay, H., Tuytelaars, T., & Van Gool, L. (2006). Surf: Speeded up robust features. In European conference on computer vision, pp. 404-417. Springer, Berlin, Heidelberg.
2. Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition , pp. 580-587.
3. Girshick, R. (2015). Fast r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 1440-1448) .
4. Li, C. Y., & Lin, H. Y. (2020). Vehicle Detection and Classification in Aerial Images using Convolutional Neural Networks. In VISIGRAPP (5: VISAPP), pp. 775-782.
5. Lin, H. Y., Tu, K. C., & Li, C. Y. (2020). VAID: An Aerial Image Dataset for Vehicle Detection and Classification. IEEE Access, 8, 212209-212219..
6. Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. In Advances in neural information processing systems, pp. 91-99.