

110-078-5494
MOTC-IOT-109-IDB008

應用人工智慧技術進行交通數據蒐集 暨號誌控制之研究



交通部運輸研究所

中華民國 110 年 7 月

110-078-5494
MOTC-IOT-109-IDB008

應用人工智慧技術進行交通數據蒐集 暨號誌控制之研究

著者：吳沛儒、曾明德、林良泰、蘇昭銘、王晉元、
吳毅成、黃培書、何國豪、郭松庭、黃啟倡、
程楷祐、倪文哲、陳怡君、林孟潔、李敏聞、
楊喻幀、吳姿潔、施彥妤、吳東凌、周家慶

交通部運輸研究所

中華民國 110 年 7 月

國家圖書館出版品預行編目(CIP)資料

應用人工智慧技術進行交通數據蒐集暨號誌控制之研究/吳沛儒,曾明德,林良泰,蘇昭銘,王晉元,吳毅成,黃培書,何國豪,郭松庭,黃啟倡,程楷祐,倪文哲,陳怡君,林孟潔,李敏聞,楊喻幀,吳姿潔,施彥好,吳東凌,周家慶等著. -- 初版. -- 臺北市:交通部運輸研究所,民110.7

面;公分

ISBN 978-986-531-321-0 (平裝)

1.交通管理 2.人工智慧

557

110011063

應用人工智慧技術進行交通數據蒐集暨號誌控制之研究

著者:吳沛儒、曾明德、林良泰、蘇昭銘、王晉元、吳毅成、黃培書、何國豪、郭松庭、黃啟倡、程楷祐、倪文哲、陳怡君、林孟潔、李敏聞、楊喻幀、吳姿潔、施彥好、吳東凌、周家慶

出版機關:交通部運輸研究所

地址:105004 臺北市松山區敦化北路 240 號

網址:www.iot.gov.tw (中文版>數位典藏>本所出版品)

電話:(02)2349-6789

出版年月:中華民國 110 年 7 月

印刷者:全凱數位資訊有限公司

版(刷)次冊數:初版一刷 57 冊

本書同時登載於交通部運輸研究所網站

定價:260 元

展售處:

交通部運輸研究所運輸資訊組•電話:(02)2349-6789

五南文化廣場:400002 臺中市區中山路 6 號•電話:(04)2226-0330

國家書店松江門市:104472 臺北市中山區松江路 209 號•電話:(02)2518-0207

GPN:1011000971 ISBN:978-986-531-321-0 (平裝)

著作財產權人:中華民國(代表機關:交通部運輸研究所)

本著作保留所有權利,欲利用本著作全部或部分內容者,須徵求交通部運輸研究所書面授權。

交通部運輸研究所合作研究計畫出版品摘要表

出版品名稱：應用人工智慧技術進行交通數據蒐集暨號誌控制之研究			
國際標準書號（或叢刊號） ISBN 978-986-531-321-0 (平裝)	政府出版品統一編號 1011000971	運輸研究所出版品編號 110-078-5494	計畫編號 109-IDB008
本所主辦單位：運輸資訊組 主管：吳東凌 計畫主持人：吳東凌 研究人員：周家慶 聯絡電話：(02) 23496756 傳真號碼：(02) 25450426	合作研究單位：逢甲大學 計畫主持人：吳沛儒 研究人員：曾明德、林良泰、蘇昭銘、王晉元、 吳毅成、黃培書、何國豪、郭松庭、 黃啟倡、程楷祐、倪文哲、陳怡君、 林孟潔、李敏聞、呂治國、楊喻幀、 吳姿潔、施彥妤 地址：407802 臺中市西屯區文華路 100 號 聯絡電話：(04)24517250		研究期間 自 109 年 4 月 至 至 109 年 12 月
關鍵詞：人工智慧；強化學習；交通號誌控制			
<p>摘要：</p> <p>交通壅塞問題為都市交通管理的一大挑戰，從蒐集車流資料至研擬號誌控制策略，往往耗費大量人力與物力資源。近年來人工智慧(AI)技術快速發展，如何藉由 AI 深度學習之類神經網路模式解決交通問題為交通領域當前之重要課題。因此，本計畫透過 AI 蒐集重要交通數據，進而藉由 AI 方式進行交通號誌控制。本計畫以臺中市太平區「樂業-十甲東」、「樂業-東英」兩路口做為實驗場域，導入 AI 影像辨識設備進行交通數據之蒐集，並建構 AI 號誌控制架構，利用 AI 影像辨識技術所獲得之交通參數，透過經學習後的 AI 號誌控制模式，依即時交通量來選取與執行適當時制計畫。</p> <p>在 AI 號誌控制模式部分，考量強化學習於尋找最適號誌控制時，需耗費大量試誤的探索時間才會收斂，致使較無實務環境之應用案例，本計畫利用時制最佳化分析軟體 PaSO，先行針對實驗範圍產生考量幹道續進之最佳化時制計畫，以及時段參數來進行 AI 強化學習，最後將學習後之 AI 號誌控制模式，於現場進行實際運作。本計畫事先透過微觀交通模擬軟體 SUMO 建構實驗場域模擬環境，進而產生 AI 號誌控制之模擬績效，最後在實測場域上進行實測。實測結果顯示，可改善實驗場域尖峰時段車流績效均達 10% 以上。</p>			
出版日期	頁數	定價	本出版品取得方式
110 年 7 月	222	260	凡屬機密性出版品均不對外公開。普通性出版品，公營、公益機關團體及學校可函洽本所免費贈閱；私人及私營機關團體可按定價購買。
備註：本研究之結論與建議不代表交通部之意見。			

PUBLICATION ABSTRACTS OF RESEARCH PROJECTS
 INSTITUTE OF TRANSPORTATION
 MINISTRY OF TRANSPORTATION AND COMMUNICATIONS

TITLE: Preliminary Study of Artificial Intelligence in Traffic Data Collection and Urban Traffic Signal Control			
ISBN (OR ISSN) ISBN 978-986-531-321-0 (pbk.)	GOVERNMENT PUBLICATIONS NUMBER 1011000971	IOT SERIAL NUMBER 110-078-5494	PROJECT NUMBER 109-IDB008
DIVISION: Information Systems Division DIVISION DIRECTOR: Tun-Ling Wu PRINCIPAL INVESTIGATOR: Tun-Ling Wu PROJECT STAFF: Ja-Ching Chou PHONE: 886-2-23496756 FAX: 886-2-25450426			PROJECT PERIOD FROM April 2020 TO December 2020
RESEARCH AGENCY: Feng Chia University PRINCIPAL INVESTIGATOR: Pei-Ju Wu PROJECT STAFF: Ming-Te Tseng, Liang-Tay Lin, Jau-Ming Su, Jin-Yuan Wang, I-Chen Wu, Pei-Shu Huang, Kuo-Hao Ho, Sung-Ting Kuo, Chi-Chang Huang, Kai-You Cheng, Wen-Che Ni, Yi-Chun Chen, Meng-Chieh Lin, Min-Wen Li, Lu.Mark, Yu-Chen Yang, Tzu-Chien Wu, Yen-Yu Shih ADDRESS: No. 100, Wenhwa Rd., Seatwen, Taichung, Taiwan 40724, R.O.C. PHONE: (04)24517250#6642			
KEY WORDS: Artificial intelligence; reinforcement learning; traffic signal control			
ABSTRACT: Traffic jam problems have been a great challenge for the urban traffic management, from traffic-flow data collection to signal-control strategy development, which depletes many human and material resources. As the integration of artificial intelligence (AI) in systems grows, the utilization of AI deep learning neural networks to tackle traffic problems has become an important topic. Hence, this project has collected important traffic data to control signals by means of AI. The Leye-Shijia intersection and Leye-Dongying intersection in Taichung City were chosen as the testing sites of the project. Specifically, this project collected traffic data through AI image recognition equipment and used it to establish a framework of AI signal control. The trained AI signal control model can select and implement an appropriate timing plan based on real-time traffic flow. Regarding AI signal control models, reinforcement learning requires considerable trial-and-error time to find the best timing plan, which engenders few real case studies. Accordingly, this study uses traffic signal timing and phase optimization software, PaSO, to generate the best timing plan of arterial road progression based on the scope of the test, as well as utilizes a time-of-day parameter to carry out AI reinforcement learning. Finally, the trained AI signal control model is applied to the testing sites. Furthermore, this study initially adopts micro traffic simulation software, SUMO, to create a simulation environment of the testing sites and to generate the simulation performance of AI signal controls, and finally test the proposed method in the testing sites. The results of the tests reveal that the proposed method can enhance the traffic flow performance by more than 10% during peak hours.			
DATE OF PUBLICATION July 2021	NUMBER OF PAGES 222	PRICE 260	
The views expressed in this publication are not necessarily those of the Ministry of Transportation and Communications.			

目錄

目錄.....	I
圖目錄.....	V
表目錄.....	X
第一章 緒論.....	1
1.1 研究背景與目的.....	1
1.2 研究範圍與對象.....	1
1.3 研究內容.....	2
1.4 研究流程.....	2
第二章 文獻回顧.....	5
2.1 AI 發展主要技術.....	5
2.1.1 人工智慧發展與應用.....	5
2.1.2 人工智慧相關技術.....	8
2.2 應用 AI 技術於交通資料蒐集.....	13
2.3 應用 AI 於號誌控制.....	17
2.4 綜合探討.....	23
第三章 AI 交通資料蒐集與應用.....	25
3.1 研究場域說明.....	25
3.2 交通特性資料調查.....	26
3.2.1 設備偵測架設及偵測規劃.....	26
3.2.2 事前車流量調查.....	32
3.3 AI 影像偵測精進.....	40
3.3.1 分車道各車種交通流量.....	42
3.3.2 路口各車種轉向交通量.....	43
3.3.3 佔有率.....	57
3.3.4 延滯.....	58
3.3.7 綜合探討.....	61
第四章 AI 路口號誌控制.....	69
4.1 AI 號誌控制之規劃與設計.....	69
4.1.1 實驗場域的交通問題分析.....	69
4.1.2 時制計畫設計.....	70
4.1.3 強化學習規劃設計.....	86
4.2 AI 號誌控制之模擬分析.....	98
4.2.1 SUMO 模擬軟體.....	98

4.2.2 AI 號誌控制模擬績效分析	99
4.3 AI 號誌控制系統之實測規劃.....	103
4.3.1.AI 路側設備硬體架構	103
4.3.2. AI 動態號誌監控平臺.....	104
4.3.3 系統上線流程說明.....	106
4.3.4 交通管理儀表板.....	111
4.4 績效評估與分析.....	116
4.4.1 績效評估方法.....	116
4.4.2 改善前後績效分析.....	117
4.4.3 延滯績效分析.....	139
4.5 AI 號誌控制未來發展.....	139
第五章 我國交通運輸未來導入 AI 應用探討	149
5.1 適合 AI 應用的環境分析	149
5.2 回顧 2020 運輸政策白皮書-智慧運輸	151
5.3 AI 在交通運輸應用探討.....	152
5.4 AI 交通運輸應用之短中長期發展探討	162
第六章 結論與建議.....	165
6.1 結論.....	165
6.2 建議.....	166
參考文獻.....	169
附件一、期中報告審查意見處理情形表.....	177
附件二、期末報告審查意見處理情形表.....	193

圖目錄

圖 2.1.1 人工智慧歷史.....	6
圖 2.1.2 機器學習分類.....	9
圖 2.1.3 強化學習架構.....	10
圖 2.1.4 Actor-Critic 架構概念圖	11
圖 2.2.1 日本 NEC 交通物件影像辨識	14
圖 2.2.2 日本 NEC 交通資料分析	15
圖 2.2.3 車種日間分類狀況.....	15
圖 2.2.4 車種夜間分類狀況.....	16
圖 2.3.1 以 0-1 矩陣表示交通狀態	18
圖 2.3.2 周遭交通環境與目標路口	20
圖 2.3.3 八種不同時相之動作.....	21
圖 2.3.4 以八時相做為動作.....	21
圖 3.2.1 攝影機裝設位置(號誌桿燈箱旁).....	27
圖 3.2.2 攝影機偵測範圍限制.....	27
圖 3.2.3 偵測設備主機及通訊模組箱體畫面	27
圖 3.2.4 偵測設備布設一覽圖.....	28
圖 3.2.5 車流調查.....	33
圖 3.2.6 臨時性設備使用流程一覽圖	35
圖 3.2.7 臨時性設備現場偵測線劃設	35
圖 3.2.8 臨時性設備準確率.....	35
圖 3.2.9 樂業路東行，機車右轉準確率較低圖示	36
圖 3.2.10 樂業路東行，機車左轉準確率較低圖示	37
圖 3.2.11 樂業路西行，各式車輛準確率較低圖示.....	37
圖 3.2.12 十甲東路南行準確率較低圖示	38
圖 3.2.13 十甲東路北行，機車右轉準確率較低圖示	38
圖 3.2.14 樂業路東行，機車左轉準確率較低圖示	38
圖 3.2.15 第二次偵測線劃設方式	39
圖 3.2.16 第一次與第二次準確率比較圖	39
圖 3.3.1 分車道各車種交通流量的進入與離開區域劃分	42
圖 3.3.2 分車道各車種交通流量的偵測畫面	42
圖 3.3.3 人行道人流量的夜晚偵測畫面	43
圖 3.3.4 人行道人流量的雨天偵測畫面	43
圖 3.3.5 AI 影像測之轉向交通量偵測線	44

圖 3.3.6	樂業路西行機車被誤判為右轉	52
圖 3.3.7	轉向量偵測異常分析.....	52
圖 3.3.8	固定式與臨時性拍攝範圍比較	53
圖 3.3.9	轉向交通量修正偵測邏輯	53
圖 3.3.10	佔有率偵測(右方偵測區域).....	57
圖 3.3.11	佔有率偵測邏輯.....	57
圖 3.3.12	延滯偵測畫面.....	60
圖 3.3.13	雨水遮蔽主要車道與鏡頭	62
圖 3.3.14	雨水遮蔽鏡頭.....	62
圖 4.1.1	交通問題現況.....	69
圖 4.1.2	時制計畫設計流程圖.....	70
圖 4.1.3	「樂業-十甲東」平日晨昏峰轉向量	71
圖 4.1.4	「樂業-十甲東」平假日離峰轉向量	72
圖 4.1.5	「樂業-東英」平日晨昏峰轉向量	72
圖 4.1.6	「樂業-東英」平假日離峰轉向量	73
圖 4.1.7	改善前時制時空圖.....	74
圖 4.1.8	時相調整原因說明.....	75
圖 4.1.9	PaSO 時制計畫產生軟體之樂業路幹道	75
圖 4.1.10	SUMO 模擬軟體之樂業路幹道	76
圖 4.1.11	樂業路空拍往市區方向壅塞回堵.....	76
圖 4.1.12	研究範圍之 PaSO 模擬路網之空間績效定義示意	77
圖 4.1.13	車間距統計分析.....	79
圖 4.1.14	時制計畫與流量對應關係圖	80
圖 4.1.15	演示法之深度 Q 學習	87
圖 4.1.16	號誌控制之強化式學習	89
圖 4.1.17	AI 號誌控制之深度 Q 學習.....	90
圖 4.1.18	網路訓練更新演算法流程	92
圖 4.1.19	多時段時制計畫演示法深度 Q 學習示意圖.....	92
圖 4.1.20	訓練資料採樣示意圖.....	93
圖 4.1.21	單一時制計畫深度 Q 網路更新過程.....	94
圖 4.1.22	初始網路之評估.....	94
圖 4.1.23	訓練 5M 回網路之評估	95
圖 4.1.24	訓練 12M 回網路之評估	95
圖 4.1.25	AI 號誌控制整體訓練架構圖	96

圖 4.1.26 AI 號誌控制特別抽樣訓練資料產生流程圖	96
圖 4.1.27 專家與 AI 號誌控制比較	97
圖 4.1.28 類神經網路大小與決策準確率	97
圖 4.2.1 模擬與訓練系統架構.....	98
圖 4.2.2 流量校估說明.....	99
圖 4.2.3 機車駕駛行為.....	100
圖 4.2.4 SUMO 輸出績效原始檔.....	100
圖 4.2.5 路網及路段編號圖.....	100
圖 4.2.6 研究場域路網路徑說明	101
圖 4.3.1 AI 號誌控制代理人暨路側設備傳輸示意	104
圖 4.3.2 AI IPC 硬體規格	104
圖 4.3.3 AI 動態號誌控制監控平臺	105
圖 4.3.4 「樂業-東英」與「樂業-十甲東」實際同亮畫面.....	107
圖 4.3.5 晨峰虛擬測試 AI 與專家之號誌時制規劃	108
圖 4.3.6 離峰虛擬測試 AI 與專家之號誌時制規劃	109
圖 4.3.7 昏峰虛擬測試 AI 與專家之號誌時制規劃	109
圖 4.3.8 偵測器異常下之 AI 號誌控制應變措施	110
圖 4.3.9 AI 號誌控制實地場域運作之 9 個階段及其作業時程	111
圖 4.3.10 AI 交通管理儀表板系統_預設畫面	112
圖 4.3.11 AI 交通管理儀表板系統_功能架構圖.....	112
圖 4.3.12 AI 交通管理儀表板系統_轉向量報表查詢	113
圖 4.3.13 AI 交通管理儀表板系統_流量比較查詢 (5 分鐘)	114
圖 4.3.14 AI 交通管理儀表板系統_流量比較查詢 (15 分鐘)	115
圖 4.4.1 旅行時間績效分析範圍	117
圖 4.4.2 週一晨峰績效(下匝道→長福路).....	118
圖 4.4.3 週一晨峰績效(東平 777→長福路).....	118
圖 4.4.4 週一晨峰績效(長福路→喬城三街).....	118
圖 4.4.5 週一離峰績效(下匝道→長福路).....	119
圖 4.4.6 週一離峰績效(東平 777→長福路).....	119
圖 4.4.7 週一離峰績效(長福路→喬城三街).....	119
圖 4.4.8 週一昏峰績效(下匝道→長福路).....	120
圖 4.4.9 週一昏峰績效(東平 777→長福路).....	120
圖 4.4.10 週一昏峰績效(長福路→喬城三街).....	121
圖 4.4.11 週二晨峰績效(下匝道→長福路).....	121

圖 4.4.12	週二晨峰績效(東平 777→長福路).....	122
圖 4.4.13	週二晨峰績效(長福路→喬城三街).....	122
圖 4.4.14	週二離峰績效(下匝道→長福路).....	123
圖 4.4.15	週二離峰績效(東平 777→長福路).....	123
圖 4.4.16	週二離峰績效(長福路→喬城三街).....	123
圖 4.4.17	週二昏峰績效(下匝道→長福路).....	124
圖 4.4.18	週二昏峰績效(東平 777→長福路).....	124
圖 4.4.19	週二昏峰績效(長福路→喬城三街).....	124
圖 4.4.20	週三晨峰績效(下匝道→長福路).....	125
圖 4.4.21	週三晨峰績效(東平 777→長福路).....	125
圖 4.4.22	週三晨峰績效(長福路→喬城三街).....	126
圖 4.4.23	週三離峰績效(下匝道→長福路).....	126
圖 4.4.24	週三離峰績效(東平 777→長福路).....	127
圖 4.4.25	週三離峰績效(長福路→喬城三街).....	127
圖 4.4.26	週三昏峰績效(下匝道→長福路).....	128
圖 4.4.27	週三昏峰績效(東平 777→長福路).....	128
圖 4.4.28	週三昏峰績效(長福路→喬城三街).....	128
圖 4.4.29	週四晨峰績效(下匝道→長福路).....	129
圖 4.4.30	週四晨峰績效(東平 777→長福路).....	129
圖 4.4.31	週四晨峰績效(長福路→喬城三街).....	129
圖 4.4.32	週四離峰績效(下匝道→長福路).....	130
圖 4.4.33	週四離峰績效(東平 777→長福路).....	130
圖 4.4.34	週四離峰績效(長福路→喬城三街).....	131
圖 4.4.35	週四昏峰績效(下匝道→長福路).....	131
圖 4.4.36	週四昏峰績效(東平 777→長福路).....	132
圖 4.4.37	週四昏峰績效(長福路→喬城三街).....	132
圖 4.4.38	週五晨峰績效(下匝道→長福路).....	133
圖 4.4.39	週五晨峰績效(東平 777→長福路).....	133
圖 4.4.40	週五晨峰績效(長福路→喬城三街).....	133
圖 4.4.41	週五離峰績效(下匝道→長福路).....	134
圖 4.4.42	週五離峰績效(東平 777→長福路).....	134
圖 4.4.43	週五離峰績效(長福路→喬城三街).....	134
圖 4.4.44	週五昏峰績效(下匝道→長福路).....	135
圖 4.4.45	週五昏峰績效(東平 777→長福路).....	135

圖 4.4.46 週五昏峰績效(長福路→喬城三街).....	136
圖 4.4.47 週六離峰績效(下匝道→長福路).....	136
圖 4.4.48 週六離峰績效(東平 777→長福路).....	137
圖 4.4.49 週六離峰績效(長福路→喬城三街).....	137
圖 4.4.50 週日離峰績效(下匝道→長福路).....	138
圖 4.4.51 週日離峰績效(東平 777→長福路).....	138
圖 4.4.52 週日離峰績效(長福路→喬城三街).....	138
圖 4.5.1 AI 號誌控制發展規劃架構	140
圖 4.5.2 多路口多代理人運作狀況	141
圖 4.5.3 本計畫 AI 號制控制交通模型學習環境	143
圖 4.5.4 模擬車流學習環境.....	144
圖 4.5.5 DQfD 於真實環境學習概況	144
圖 4.5.6 本計畫 AI 強化學習號誌控制之架構	147
圖 5.1.1 職業特性象限圖-與人互動	150
圖 5.1.2 職業特性象限圖-勞力	150
圖 5.1.3 AI 適合環境特性.....	151
圖 5.2.1 2020 運輸政策白皮書-智慧運輸之願景、政策目標、政策與策略	152
圖 5.3.1 2020 運輸政策白皮書-智慧運輸之三大應用層面	153
圖 5.3.2 AI 於資料蒐集與環境偵測面向之 AI 導入潛在應用	156
圖 5.3.3 資訊提供與預測面向之 AI 導入潛在應用	159
圖 5.3.4 交通改善與營運管理面向之 AI 導入潛在應用	162

表目錄

表 2.1-1 常見機器學習技術.....	9
表 2.2-1 AI 物件偵測使用方法彙整表.....	17
表 2.3-1 應用 AI 於號誌控制文獻彙整表	22
表 3.1-1 研究場域討論及施工紀錄.....	26
表 3.2-1 AI 影像偵測設備布設一覽表.....	28
表 3.2-2 e-Tag 設備布設一覽表.....	31
表 3.2-3 臨時性設備與人工調查之各工作項目比較	36
表 3.3-1 SSD 模型精進比較表	40
表 3.3-2 偵測車種與行人說明.....	41
表 3.3-3 分車道各車種各情境的交通流量偵測準確度	43
表 3.3-4 轉向交通量判別邏輯(偵測技術精進前).....	45
表 3.3-5 路口各車種轉向交通量偵測(白天)(Nvidia Nano)(技術精進前)..	45
表 3.3-6 路口各車種轉向交通量偵測(白天)(Nvidia Tx2)(偵測技術精進前)	46
表 3.3-7 路口各車種轉向交通量偵測(雨天)(Nvidia Nano)(技術精進前)..	47
表 3.3-8 路口各車種轉向交通量偵測(雨天)(Nvidia Tx2)(偵測技術精進前)	48
表 3.3-9 路口各車種轉向交通量偵測(夜間)(Nvidia Nano)(技術精進前)..	49
表 3.3-10 路口各車種轉向交通量偵測(夜間)(Nvidia Tx2)(偵測技術精進前)	50
表 3.3-11 不同硬體規格之直行車流偵測率比較.....	51
表 3.3-12 不同型號之主要硬體比較.....	51
表 3.3-13 不同偵測線判定邏輯之轉向交通量判別邏輯比較表	53
表 3.3-14 不同偵測線判定邏輯之準確率比較.....	54
表 3.3-15 佔有率前後偵測邏輯比較.....	57
表 3.3-16 佔有率偵測準確度.....	58
表 3.3-17 延滯偵測準確率.....	60
表 3.3-18 AI 影像偵測精進過程.....	62
表 3.3-19 各車流參數與偵測邏輯彙整.....	64
表 4.1-1 平日尖峰 PaSO 最佳化時制計畫內容(樂業-十甲東)	77
表 4.1-2 平日尖峰 PaSO 最佳化時制計畫內容(樂業-東英)	77
表 4.1-3 平日尖峰事前事後 PaSO 模擬績效(延滯).....	78
表 4.1-4 平日尖峰時制計畫組合(粗體與底線者為基礎時制計畫).....	79

表 4.1-5 離峰 PaSO 擬定時制計畫內容(樂業-十甲東)	83
表 4.1-6 離峰 PaSO 擬定時制計畫內容(樂業-東英)	83
表 4.1-7 離峰 PaSO 擬定時制績效結果-延滯	83
表 4.1-8 離峰(平日及週日)時制計畫組合	84
表 4.1-9 週六離峰 PaSO 擬定時制計畫內容(樂業-十甲東)	84
表 4.1-10 週六離峰 PaSO 擬定時制計畫內容(樂業-東英)	85
表 4.1-11 週六離峰 PaSO 擬定時制績效結果-延滯	85
表 4.1-12 週六(離峰)時制計畫組合	85
表 4.2-1 平日晨峰模擬績效	102
表 4.2-2 平日離峰模擬績效	102
表 4.2-3 平日昏峰模擬績效	102
表 4.2-4 週六昏峰模擬績效	103
表 4.2-5 平日昏峰模擬績效	103
表 4.3-1 虛擬測試階段各情境 AI 與專家之差異率	108
表 4.3-2 車當量轉換設定表	113
表 4.3-3 AI 交通管理儀表板系統_轉向量報表	113
表 4.3-4 流量比較設備清單	114
表 4.3-5 AI 交通管理儀表板系統_流量比較報表 (5 分鐘)	115
表 4.3-6 AI 交通管理儀表板系統_流量比較報表 (15 分鐘)	116
表 4.4-1 事前事後績效蒐集時程規劃	117
表 4.4-2 週一晨峰各路徑績效彙整	118
表 4.4-3 週一離峰各路徑績效彙整	120
表 4.4-4 週一昏峰各路徑績效彙整	121
表 4.4-5 週二晨峰各路徑績效彙整	122
表 4.4-6 週二離峰各路徑績效彙整	123
表 4.4-7 週二昏峰各路徑績效彙整	125
表 4.4-8 週三晨峰各路徑績效彙整	126
表 4.4-9 週三離峰各路徑績效彙整	127
表 4.4-10 週三昏峰各路徑績效彙整	128
表 4.4-11 週四晨峰各路徑績效彙整	130
表 4.4-12 週四離峰各路徑績效彙整	131
表 4.4-13 週四昏峰各路徑績效彙整	132
表 4.4-14 週五晨峰各路徑績效彙整	133
表 4.4-15 週五離峰各路徑績效彙整	135

表 4.4-16 週五昏峰各路徑績效彙整.....	136
表 4.4-17 週六離峰各路徑績效彙整.....	137
表 4.4-18 週日離峰各路徑績效彙整.....	138
表 4.4-19 總延滯績效彙整.....	139
表 4.5-1 逐週期與逐時相之優缺點比較.....	141
表 5.4-1 AI 於交通運輸之三大目標與潛在應用	163
表 5.4-2 AI 於交通運輸應用之短中長期時程劃	164

第一章 緒論

1.1 研究背景與目的

隨著都市蓬勃發展，都市車流日趨龐大，交通壅塞為都市交通管理的一大挑戰，由於定時控制之號誌時制無法即時因應車流狀況進行調整，為提升號誌化路口使用效率，路口控制策略已逐漸發展至全動態之適應性號誌控制。適應性號誌控制可以更快速地因應交通狀況變化，調整符合交通需求之號誌時制，提升道路績效。然而，如何根據交通車流特性，並據以動態地調控交通號誌，為當前適應性號誌控制於實務運籌上之重要課題與挑戰。

傳統適應性號誌控制策略往往受限於車輛偵測器之穩定度、無通用之數學模式、部分參數需時時更新，以致難以推廣使用。適應性號誌控制之困境主要包括：(1)進行適應性號誌控制策略，其偵測器之運作穩定度需達一定水準，而傳統車輛偵測器又以環路線圈式運作最穩定，惟其維修與成本均較高；此外，策略實施亦受限於所蒐集之交通參數種類與品質，致使控制成效難有明顯突破；(2)控制邏輯設計大多以數學模式計算處理適應性控制問題，但因應(3)傳統適應性控制策略實施後，路口車流特性亦將會有相關變化，而原先規劃之參數恐已無法符合實施後之車流特性，進而使績效不佳，故實施後之參數亦應依照即時資訊加以調整。

近年來人工智慧(Artificial Intelligence, AI)技術快速發展，如何藉由 AI 深度學習(Deep Learning, DL)之類神經網路(Artificial Neural Network, ANN)模式解決交通問題為交通領域當前之重要課題。根據文獻資料，AI 強化學習(Reinforcement Learning, RL)已有許多學術研究，惟仍鮮少有實務應用，因此本計畫將主要目的在於利用 AI 技術所蒐集交通參數(交通量)，將之應用於以 AI 強化學習為基礎的動態號誌制所需交通數據，進而藉由以模仿學習(Imitation Learning, IL)與以週期為基礎的 AI 強化學習，來選擇最適號誌時制計畫，以及下載至路口執行，以即時反應車流變化與提高號誌化路口運作效率。

1.2 研究範圍與對象

為延續本案前期(108 年)執行成果，以及考量 AI 號誌控制導入號誌化路口實作風險本計畫於臺中市太平區樂業路與十甲東路、樂業路與東英路兩處路口進行模擬與實測。AI 號誌控制學習與測試工作於實驗室進行，最後將學習後之 AI 號誌控制模式，搭配現場 AI 車輛偵測器與工業用電腦，

進行車流參數偵測、運算、號誌控制等工作。

1.3 研究內容

依據計畫需求說明書，本計畫主要研究內容與工作項目可重點摘錄如後，達成情形如表 1.3-1 所示。

1. 國內外應用 AI 進行交通資料蒐集，以及號誌控制相關文獻蒐集與回顧
2. 草擬我國未來 5 年 AI 於交通領域之整體規劃
3. 利用 AI 影像辨識技術進行資料蒐集
 - (1) 研擬辨識技術，使設備可於日、夜、雨天等各種情境下，辨識行人、機車、小型車、大型車、聯結車等不同車種。
 - (2) 執行路口 AI 號誌控制可能使用之交通車流資料偵測，相關參數包括：分車道各車種交通流量、路口各車種轉向交通量、車流密度(單位路段長度內之車輛數)、佔有率(一特定時間內(如 1 分鐘或 5 分鐘)一小路段被車輛佔據的時間百分比)、停等車輛疏解資料(每號誌週期紅燈停等車輛於綠燈疏解時通過停止線時間)、路口停等延滯(每車加入紅燈停等車隊至因下游車輛疏解而開始加速之時間)。
4. 依據偵測設備蒐集之資料，執行路口 AI 動態號誌控制。
5. 進行實測之效益評估
6. 應用 AI 影像辨識技術進行交通控制之後續探討。

1.4 研究流程

本計畫流程如圖 1.4.1 所示，重要流程內容說明如下。

1. 文獻回顧：回顧「AI 發展主要技術」、「應用 AI 技術於交通資料蒐集」以及「應用 AI 於號誌控制」之相關文獻。
2. AI 交通資料蒐集：分析實驗場域、研擬交通特性資料調查計畫、驗證 AI 蒐集之交通資料。
3. AI 路口號誌控制：規劃 AI 號誌控制、研擬時制計畫、設計 AI 號誌控制之強化學習、建立 SUMO (Simulation of Urban MObility) 模擬環境、模擬 AI 號誌控制於 SUMO 之運作、實證分析 AI 號誌控制於實驗場域之運作。
4. 我國未來 5 年 AI 於交通領域之整體規劃。

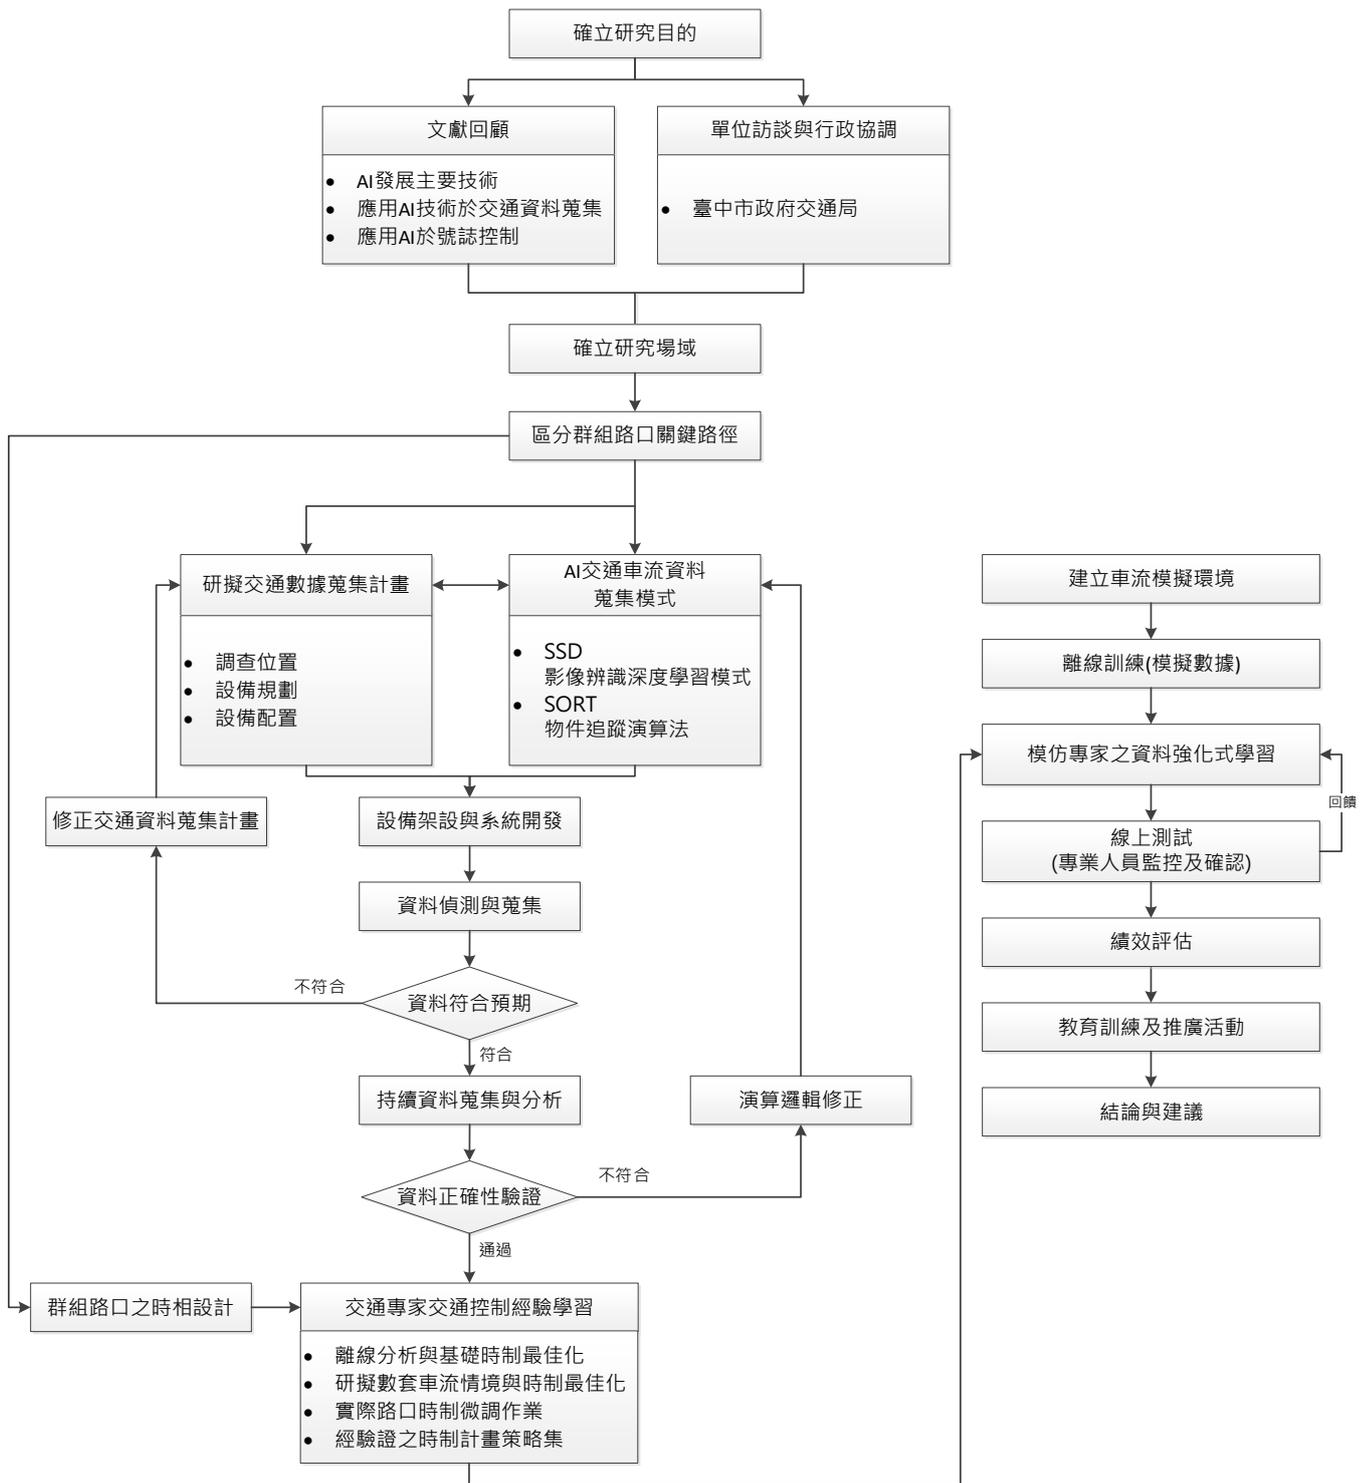


圖 1.4.1 研究流程圖

第二章 文獻回顧

2.1 AI 發展主要技術

本節主要探討 AI 發展及應用，並深度探討人工智慧之相關技術。

2.1.1 人工智慧發展與應用

本節內容彙整自陸化普(2019)之「智能交通系統主要技術的發展」、科技報導 37(6)期(第 27-35 頁)，以及維基百科之人工智慧。

1. 人工智慧歷史

人工智慧一詞在 1956 年的達特茅斯夏季人工智慧研究計畫(Dartmouth Summer Research Project on Artificial Intelligence)中被首次提出。與會者集思廣益，認為若是能精確描述學習的特徵，就可以使機器模擬它。接者，人工智慧經歷了幾次黃金發展期與寒冬期的循環，以下依照年份整理人工智慧的歷史，整體發展如圖 2.1.1 所示。

(1) 第一次黃金期(1956-1974 年)

在人工智慧一詞被提出後，許多學者趨之若鶩的研究，並在短時間內使用電腦解決代數詞的問題、證明了幾何定理並學會了說英語。許多私人企業相繼大力資助這項新科技，使得當時對於人工智慧的未來發展抱持樂觀的想法。

(2) 第一次寒冬期(1974-1980 年)

在過於樂觀的氛圍下，人們的期待水漲船高，但並未意識到其所面臨的問題其實具高難度，且當時的科技仍無法在合理的時間處理龐大的資訊量，以至於無法達到預期結果，相關資金也因此逐漸流失。再加上開始有一些哲學家提出對人工智慧的道德質疑，使得發展逐漸停滯。

(3) 第二次黃金期(1980-1987 年)

在此階段，出現幾大亮點：人工智慧與統計的結合、專家系統、反向傳播法(Backpropagation, BP)、與支持向量機(Support Vector Machine, SVM)。當加入了統計的思維之後，使原本只能判斷二元答案的人工智慧有了量化的功能，可以描述發生事件的機率。

專家系統(Expert Systems)的概念被提出，嘗試從專業知識中找出邏輯規則，並回答該領域的問題。此系統在當時被廣泛應用於許

多領域，各方投入許多資源構建與專家系統有關的知識庫與規則庫，並致力於發展各種規則推論與產生的各項技術。

1986 年 Hinton 等人提出反向傳播法，解決了類神經網路所需的龐大計算量問題，使得類神經網路廣泛獲得各方的重視。但後續發現此法面臨梯度消失問題，類神經網路熱潮再次退散。此同時，淺層深度學習-支持向量機(SVM)與決策樹逐漸興起，可以有效完成如分類垃圾郵件的功能，因此 SVM 與決策術的技術開始廣受矚目，也開始應用在部分適合的課題上。

(4) 第二次寒冬期(1987-1993 年)

由於專家系統的維運成本偏高，所需要建立的知識庫與規則庫會隨著時間的增加而變得龐大且無效率，再加當時的電腦計算能力尤其侷限，因此在實際應用的成效有限，因此各方對於人工智慧的投資金額持續下降。直到 1993 年底超過 300 家人工智慧公司倒閉，使這一波人工智慧(專家系統)實際應用的嘗試再度宣告失敗。

(5) 第三次黃金期(1993 至今)

2006 年 Hinton 提出了限制玻爾茲曼機(Restricted Boltzmann Machine, RBM)模型與深度信念網路(Deep Belief Network, DBN)的觀念，有效地完成多層神經網路的訓練，並將多層神經網路命名為深度學習(Deep Learning, DL)。配合著硬體計算能力的大幅提升，深度學習在語音辨識與視覺辨識方面的成效良好，不僅準確率高，且可以在可以接受的時間內完成辨識，因此再度帶動人們對於人工智慧應用的期待與想像。

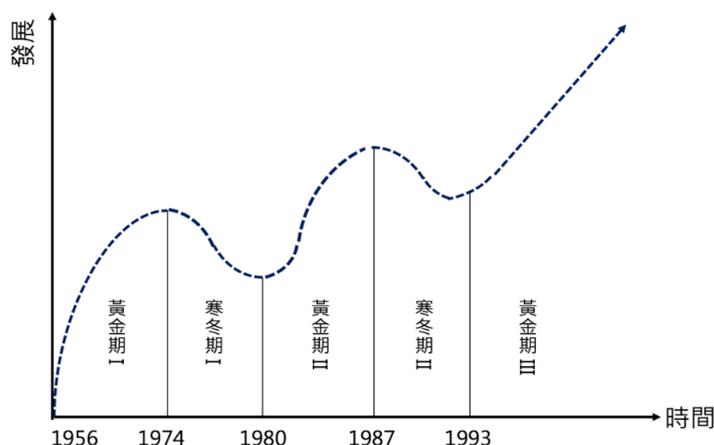


圖 2.1.1 人工智慧歷史

資料來源：本計畫整理

綜觀人工智慧的歷史，可以發現隨著科技進步，人工智慧的發展也能隨之突破。近年 5G 商用時代來臨，大數據分析發展快速，將更加速人工智慧的發展與創新。此外，外界投資的資金也是非常重要的因素，目前世界各地雖然對於人工智慧所涉及的隱私權有所疑慮，但仍對其研究普遍抱持樂觀的態度。目前技術進步一日千里，討論熱度不減，加上龐大的資金挹注，配合明確的應用，人工智慧的未來發展非常樂觀。

2. 目前人工智慧應用層面

目前人工智慧技術發展快速，應用層面廣闊，舉凡時間序列分析、圖像處理、音訊處理等，各大產業開始引進人工智慧技術，希望能達到優化程序、減低成本等目的。人工智慧的基本精神為利用電腦學習人類的行為，目前依照技術大致可以分為感知能力、認知能力、創造力、和自主智慧力等四個應用層面，以下將逐一說明。

(1) 感知能力(Perception)

指運用機器學習人類透過感官收到的環境刺激，包含聽、說、讀、寫和看的能力。此層面是目前人工智慧技術發展最為純熟的一塊，也已經在日常生活中隨處可見。例如：語音辨識、語音與文字的轉換、自然語言處理、機器翻譯、電腦視覺、圖像辨識等等。

(2) 認知能力(Cognition)

指運用機器學習人類瞭解訊息和知識的過程。是目前發展人工智慧的第二個焦點層面。人類受到環境刺激後，大腦會執行一系列複雜的運算，接者做出相對應的反應。因此，此層面又可依序細分成學習、分析、判斷與預測四種能力。

①學習能力

人工智慧透過不同的學習能力來模仿人類的大腦是如何學習新知，例如：機器學習、深度學習、強化式學習。透過大量的輸入資料訓練機器，以達到接近人腦的學習能力於近年運算速度大幅提升，加上演算法的改良與研發，各式學習能力被應用在許多商業環境中，且有良好的表現。

②分析能力

人工智慧在學習完資料後，能進一步分辨新的資料並進行分類。例如：產品推薦、消費行為分析等。此能力可以達成個人化

的訊息推播，使用者體驗能更完善，也能幫助企業找出潛在消費者。

③判斷能力

人工智慧分析完資料後，開始學會自己下決定並執行。如同人類能在分析完收到的環境刺激後，決定該執行何種動作。例如：下圍棋、自動駕駛車、癌症判斷等。

④預測能力

人工智慧在學習了大量的歷史資料後，能達到預測未來的能力。透過演算法，人工智慧可以運用歷史資料預測未來計算出未來可能發生的事件或現象，有助於相關單位提前進行防治。例如：天然災害預測等。

(3) 創造力(Creativity)

指運用機器學習人類產生新思想，創造新事物的能力。由於較無固定的邏輯可循，並且依賴人類主觀的判斷，因此此層面目前仍無法被人工智慧完全取代，例如：作曲、文學創作等。

(4) 自主智慧力(Wisdom)

指運用機器學習人類的自我意識、自我認知與價值觀，由於其中涉及許多複雜的面向，目前人工智慧還未觸及此層面。未來若發展至此，法令與倫理道德，將可能受巨大的挑戰。目前人工智慧以感知能力與認知能力的發展較為成熟，尤其是感知能力中的影像辨識部分，許多產業開始引進此技術，以進行精確的監控與節省成本。由於人工智慧為一個較為廣泛的概念，近年隨著科技持續進步，發展出更進一步的實現方法，如機器學習(Machine learning, ML)與深度學習(Deep learning, DL)。

2.1.2 人工智慧相關技術

人工智慧(Artificial Intelligence, AI)主要以電腦模仿人類思考進而模擬人類的行為，通常藉由電腦學習數據資料，建立模型來給予反饋，因此，人工智慧其主要藉由機器學習(Machine Learning, ML)來構成。機器學習可分為三大領域，分別為監督式學習(Supervised Learning, SL)、非監督式學習(Unsupervised Learning, UL)及強化學習(Reinforcement Learning, RL)，如圖 2.1.2 所示。

監督式學習之訓練資料集經由監督者標記，AI 透過訓練標記與資料集間的關聯建立相對應網路以預測新資料的標籤，如將機器學習應用於圖片分類。非監督式學習則為以未經過標記之資料集對 AI 進行訓練，AI 透過訓練後能建立網路擷取資料集中有用特徵並分析其結構，自動找出資料結構，如將機器學習應用於異常檢測。強化學習為訓練 AI 與環境互動，透過提供 AI 適當獎勵，以令其能做出期望之行為於新輸入資料集，強化式學習所輸入訓練資料集為未經過標記，如機器學習應用於機械手臂控制 (Silver, 2015 與吳毅成，2019)。

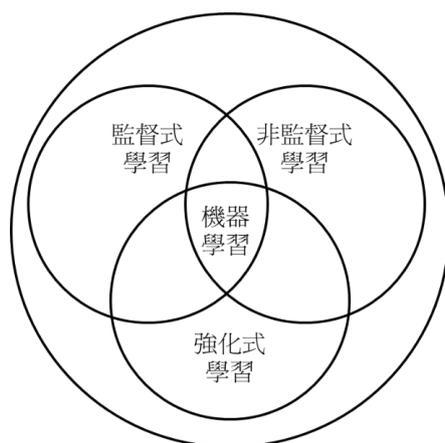


圖 2.1.2 機器學習分類

資料來源： Silver(2015)，本計畫整理。

表 2.1-1 列出目前較為常見的機器學習方法與其目的，並且在目前最廣被使用的 python 語言中有對應可使用的套件。由此表可知目前機器學習主要能達成的技術，利於後續探討於交通領域的相關應用。

表 2.1-1 常見機器學習技術

	常見機器學習技術	目的	對應 python 套件
監督式學習	線性迴歸(Linear Regression)	迴歸	Sklearn.linear_model
	多項式迴歸(Polynomial Regression)	迴歸	PolynimialFeatures
	羅吉斯迴歸(Logistic Regression)	分類	sklearn.linear_model 的 LinearRegression()
	Tree-based 方法 (例如：decision tree、random forest...)	分類	sklearn.tree 的 DecisionTreeClassifier()
	K-nearest neighbor	分類	sklearn.neighbors 的 KNeighborsClassifier()
	支持向量機(support vector machine)	分類	sklearn.svm 的 SVC()

	常見機器學習技術	目的	對應 python 套件
	單純貝氏分類(Naive Bayes Model)	分類	sklearn.naive_bayes
非監督式學習	集群分析 (例如：cluster, k-means...)	聚類	sklearn.cluster 的 KMeans()
	關聯規則探索 (Association Rule Discovery)	聚類	apriori
	神經網路 (例如：ANN, DNN, CNN, BPNN...)	聚類	keras、tensorflow
強化學習	Q-learning	自我學習	keras、tensorflow

資料來源：本計畫整理

強化學習目的為代理人(Agent)對環境(Environment)進行一連串的動作，使得整個過程中可以獲得的累積獎勵(Cumulative Reward)最大化，如圖 2.1.3。基本的 RL 包含以下這些元素：環境狀態的集合、動作的集合、狀態間轉換的規則、獎勵給予的規則及代理人可以觀察到的內容，訓練主旨為改善目前的策略(Policy)，並且希望經由不斷的訓練，可以得到最佳的策略(Optimal Policy)，學習的方式為對環境執行動作(Action)後，環境會回傳獎勵(Reward)和新的狀態(State)給代理人，此程序不斷地進行，逐漸優化策略。因此，代理人可藉由控制號誌之動作，由環境中獲知交通狀況，最終自適性調整策略以達最順暢交通。其中，常見的優化策略運作機制包含 Q-learning、Deep Q Network(DQN)、Actor-Critic、DDPG、A3C...等，各優化策略運作機制摘要說明如後(Sutton, 2018、吳毅成，2019)。

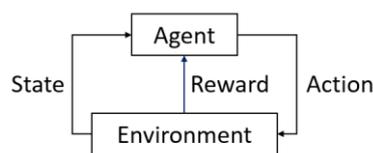


圖 2.1.3 強化學習架構

資料來源：Sutton et al.(2018)

Q-learning 目標為訓練出準確的評估函式(evaluation function) $Q^\pi(s, a) \approx Q^*(s, a)$ ， Q^* 為最佳的(optimal)評估函式、 π 為採取的策略(policy)，而評估函式的作用為評估預期得到的總獎勵(expected total reward)。評估函式 $Q^\pi(s, a) = E[r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots | s, a]$ ，其中， r_t 為在不同的時間點 t 所獲的獎勵，而 γ 為一個折扣因子(discount factor)(吳毅成，2019)。

Deep Q Network(DQN)是基於 Q-learning 的一種網路架構。將 Q-learning 與深度類神經網路結合後，深度類神經網路的使用和函式逼近

(function approximation)有相同的效果，函式逼近是讓 $Q^\pi(s, a)$ 使用特徵和權重來計算，而特徵的抽取和權重的調整，深度類神經網路會於學習過程中習得。由於 $Q^\pi(s, a)$ 值是深度類神經網路提供，為了方便表達，將 $Q^\pi(s, a)$ 改寫為 $Q^\pi(s, a, w)$ ， w 為深度類神經網路的權重(weight)。訓練方法為代理人(agent)與環境(Environment)進行互動，透過執行動作(Action)得到獎勵(reward)和新的狀態(State)，計算出誤差值 $= (r + \gamma Q^\pi(s', a', w) - Q^\pi(s, a, w))^2$ ，式子中的前半部為目標(Target)，後半部為當前評估值，算出兩者誤差值來調整深度類神經網路(吳毅成，2019)。

DQN 中的 max 操作可能導致輸出的 Q 值大於實際上能獲得的未來期望獎賞(overestimate)，而 Double DQN(Hasselt et al., 2016)就是用來解決此問題的。在計算用於更新的 Q 值時，原本 DQN 在 max 操作中使用會使用 Target 網路 $Q(s, a|\theta^-)$ 所認為的最好動作，而不是 Behavior 網路 $Q(s, a|\theta)$ 策略下的最好動作，使得在計算出來的 Q 值，會有過度估計的現象。解決辦法就是在計算更新用的 Q 值時，也是用 Behavior 網路 $Q(s, a|\theta)$ 的策略來決定即可(吳毅成，2019)。

Actor-Critic 為強化學習(RL)的一個演算法，其概念為訓練兩個模型，Actor 與 Critic，如圖 2.1.4。Actor 負責決定在當前狀態下(State)決定動作(Action)，而 Critic 模型會接收當前狀態(State)與 Actor 依據狀態所決定的動作(Action)給出一個評分，我們稱為動作價值(Action Value)，即是常見的 Q 值(Q-Value)，意義為預測在此狀態下做此動作，預期未來可以獲得的獎勵總和，再透過對環境採取 Actor 的動作所獲得的真實獎勵來訓練 Critic 與 Actor，直至收斂。Actor-Critic 演算法可以產生離散動作空間(discrete action space)中的動作，例如：上下左右 4 種選項(吳毅成，2019)。

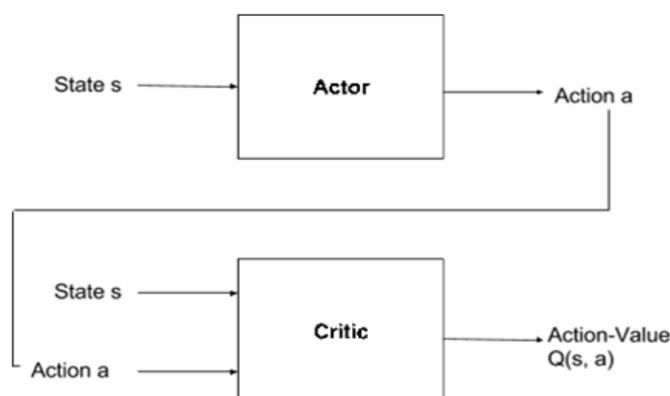


圖 2.1.4 Actor-Critic 架構概念圖

資料來源：Sutton et al. (2018)

DDPG 演算法如同 Actor-Critic，由兩個神經網路模型 Actor 和 Critic 組成，其不同處在於 Actor 所輸出的動作空間是連續性。神經網路的更新方法也與 Actor-Critic 不同，Actor 由輸出動作機率分佈變為 Deterministic 動作，使得更新公式改變如下： s 表示狀態， μ 為 Actor 策略函式， θ 為 Actor 的參數， ω 為 Critic 的參數(吳毅成，2019)。

$$\text{Critic 更新公式：} L(s_t, \mu(\theta)|w) = E[(r_{t+1} + Q(w) - Q(w))^2]$$

$$\text{Actor 更新公式：} \nabla_{\theta} \mu \cong E_{\mu}[\nabla_a Q(\omega) \nabla_{\theta} \mu(s_t|\theta)]$$

Google DeepMind 在 2016 年提出的 A3C 為一個結合異步方法 (Asynchronous Method)、優勢價值(Advantage Value)與 DDPG (Mnih et al., 2016)的方法，有效提高模型探索率並獲得更加良好的收斂結果。異步方法 (Asynchronous Method)中，模型被分為全域模型(Global)與數個工作者模型 (Worker)。因為對環境的探索工作由原本的一個模型執行轉變為多個工作者模型平行執行，對於環境的探索率也因此提昇，此外，在異步方法的訓練下，全域模型的收斂結果也比單一模型來的更好(吳毅成，2019)。

有些時候比起未來期望得分，我們更想得知在當前狀態下不同動作間彼此的優劣，優勢價值(Advantage Value)即在表達此概念，透過計算不同動作的動作價值與狀態價值差值，來呈現執行不同動作時彼此的優劣排序，藉此來協助策略的學習。公式為 $A(s, a) = Q(s, a) - V(s)$ ，其中 $A(s, a)$ 表示優勢價值函式， $Q(s, a)$ 為動作價值函式， $V(s)$ 為狀態價值函式， s 指當前狀態， a 表達所選擇之動作(吳毅成，2019)。

用 Behavior 網路 $Q(s, a|\theta)$ 的策略來決定，可解決因為 DQN 在 max 操作中使用 Target 網路 $Q(s, a|\theta^-)$ 所認為的最好動作而導致計算出來 Q 值過度估計現象。DDPG 演算法與 Actor-Critic 其不同處在於 Actor 所輸出的動作空間是連續性。神經網路的更新方法也不同，Actor 由輸出動作機率分佈變為 Deterministic 動作。為有效提高模型探索率並獲得更加良好的收斂結果，可使用 A3C 結合異步方法 (Asynchronous Method)、優勢價值(Advantage Value)與 DDPG(Mnih et al., 2016)的方法。

吳毅成(2019)指出，A3C 方法可直接適合應用於 Lightweight 類型，若應用於真實環境，需要注意訓練初期不穩定問題。在典型機器學習訓練上，多採以從頭訓練方式，於此訓練過程上，無可避免，初期模型可能無法輸出較佳動作，並且需要較長訓練過程及大量訓練資料，因此大幅限制於真實世界任務之應用。模仿學習 (Imitation Learning, IL) 為一透過利用人類經

驗數據以提升模型訓練效率之方法，基於專家演示之數據，訓練所得之模型將依專家經驗輸出動作。

基礎的模仿學習(IL)包含以下這些元素：環境狀態的集合、動作的集合與代理人可以觀察到的內容。訓練主旨為學習演示數據的策略(Policy)，並且希望經由不斷的訓練，可以達到跟演示數據一樣的決策。學習的方式為給定代理人可以觀察到的內容，代理人需要調整其策略，使其對環境執行動作(Action)與演示數據的動作相同，此程序不斷地進行，逐漸使代理人的策略與演示數據的策略相同，此類成功的例子如行為複製(Behavior Cloning)在自駕車的 ALVINN。然而，模仿學習的成效極度仰賴專家演示數據的品質，並且無法處理沒有在訓練過程中的情況；另外，如果演示數據與實際應用時有差異存在(如模擬環境與真實環境存在差異)，模仿學習所建立之模型會輸出品質較差之動作。

Hester et al.(2018)提出 DQfD (Deep Q-learning from Demonstrations)，DQfD 為基於 DQN 架構，在訓練 DQN 時，所採用的資料有一部分比例是使用專家示範所產生的資料，例如人類在模擬器或遊戲中動作的紀錄。於訓練初期時，以人類動作紀錄為學習目標訓練，而後再逐漸加入代理人與環境互動的紀錄，以獲取最大分數為目標來訓練，其結合時間差異結合監督式分類於網路更新利用演示數據大幅加速學習過程，其結果顯示 DQfD 於 42 種 Atari 遊戲中的 27 種上都得到更佳之平均獎勵。Xiong et al.(2019)參考 DQfD 於號誌控制，其使用 Actor-Critic (AC)的架構，並以 SOTL 的演示為基礎來幫助訓練，藉由強化學習增進其在模擬器上的成效。

Huo et al.(2019)擴展 DQN，控制路網中多個路口，避免維數災難。其設計 CNN 中共享參數權重的子集，使其可更近似真實之 Q 函數，並處理較大的離散空間，將多路口的交通資訊以單一張量作為表示，以資料集聚合(Dataset Aggregation)方式使用模仿學習當作預先訓練，再使用 PPO 做進一步的微調，最後輸出一簡單表示多路口狀態控制的布林陣列，該方法在 SUMO 模擬器上達到優秀的成效。以上方法均需仰賴專家演示完整至少一回合動作序列及蒐集該動作序列之獎勵，於實作時相當困難。

2.2 應用 AI 技術於交通資料蒐集

在應用 AI 技術於交通資料蒐集上，通常使用 AI 深度學習(Deep Learning Neural Network, DNN)之卷積神經網路模型(Convolutional Neural Network, CNN)辨識各類型交通資料。

Son 與 Baek(2015)發展智慧駕駛輔助系統的即時交通資訊系統和智慧攝影設備，應用電腦視覺演算法進行圖像辨識，並使用動態模糊法來處理動態區域，根據車輛彼此間距、車速、鄰近車輛數等交通資訊，預測交通壅塞。

阿里雲(2018)利用實時城市數據資源，包含車流量、號誌、公共運輸、地圖資訊…等，對城市公共資源進行優化，即時修正城市運輸或大眾設備運轉缺陷，主要是利用物連網技術及電腦視覺技術偵測路面車輛之車速、車流量及交通事件，可針對事故或是車流派遣交通執法人員前往處理或即時調整號誌系統，疏濬車流。

Luo 等人(2018)利用高速公路、市區道路上監控攝影機拍攝的影像，辨識特定圖像可能性，提出不同 CNN，及利用特徵點(Feature Point)和支援向量迴歸法(Support Vector Regression, SVR)來分割出道路、汽車、背景，和預測交通密度不同類別交通圖像。

Hem(2018)表示加拿大 Miovision 公司於加拿大安大略省運用深度學習技術打造 SmartSense 傳感器，用以偵測車輛，行人和自行車騎士之位置與移動方向，並利用此數據改善交通壅塞和安全性。

NEC(2019)利用 CCTV 蒐集資料並傳輸至雲端進行交通物件電腦視覺影像辨識(如圖 2.2.1 所示)以及車流量計算、車種分類、違停偵測和等候線偵測之交通車流資料分析(如圖 2.2.2 所示)。

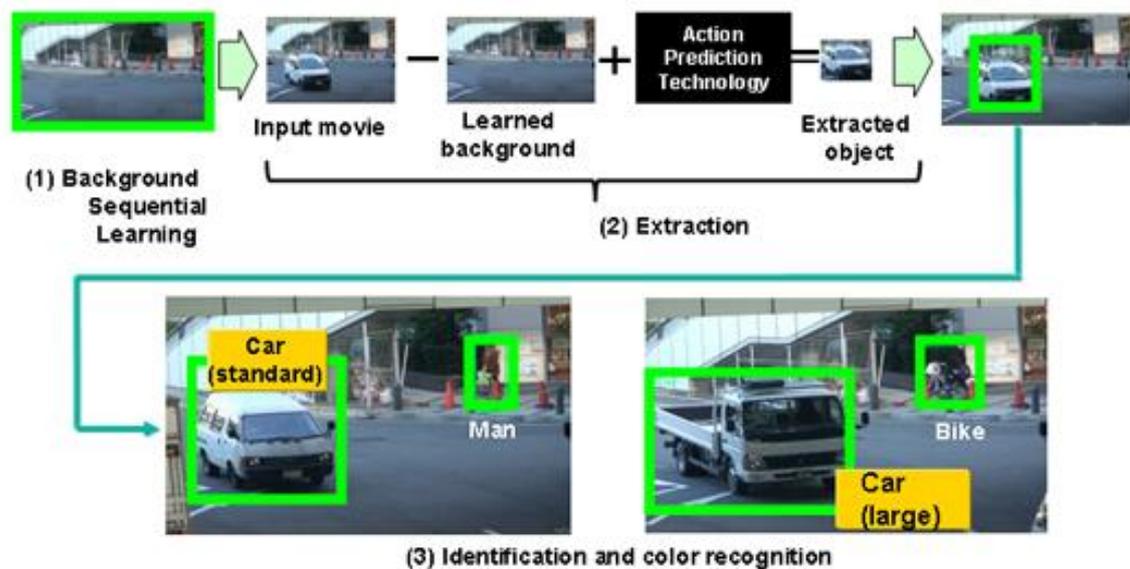


圖 2.2.1 日本 NEC 交通物件影像辨識

資料來源：NEC 官方網站

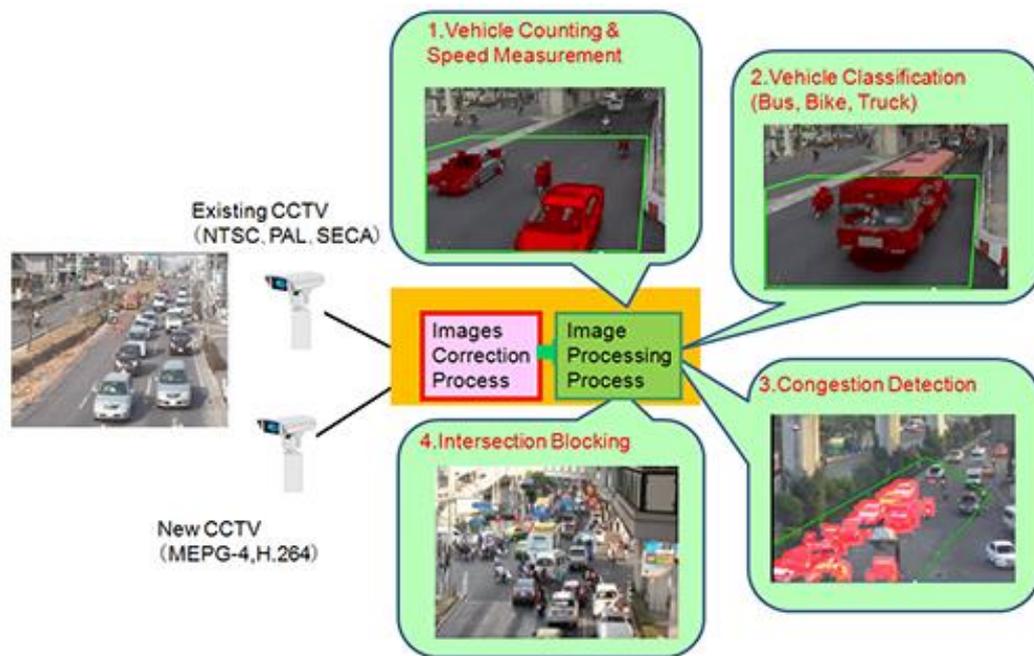


圖 2.2.2 日本 NEC 交通資料分析

資料來源：NEC 官方網站

Aleksandr et al.(2019)藉由 Faster R-CNN 以及 SORT，並加強 Faster R-CNN 的基線性能，包含焦點損失，自適應特徵池化(Pooling)、附加掩碼層及錨點優化。為了訓練和校估偵測器，該研究總計蒐集 982 個影像畫格，其中有超過 60,000 個物件在各種條件下呈現。分析結果顯示，該研究所提出的系統可以計算車流量並在尖峰時段對其行駛方向進行分類，平均絕對百分比誤差小於 10%，相關辨識畫面如圖 2.2.3 與圖 2.2.4 所示。



圖 2.2.3 車種日間分類狀況

資料來源：Aleksandr et al.(2019)



圖 2.2.4 車種夜間分類狀況

資料來源：Aleksandr et al.(2019)

Xu et al.(2017)藉由無人機進行汽車通過號誌交叉路口之影像辨識，Faster R-CNN 分析結果顯示汽車於號誌交叉路口之準確率為 98.43%。Luo et al. (2018)提出利用低幀監控影像準確預測特定交通圖像可行性研究，該研究運用卷積神經網路提取特徵點(Feature Point)並運用支援向量迴歸(Support Vector Regression, SVR) 辨識並分割不同類別交通圖像，例如道路、汽車、背景，結果顯示分析交通密度之準確率最高可達 97.24%。Gkolias 與 Vlahogianni (2019)藉由卷積神經網路影像偵測都市路邊可用之停車位數，結果顯示平均偵測之準確率約為 90%。吳沛儒等人(2019)建構單次多重目標檢測器(Single Shot MultiBox Detector, SSD)之深度神經網路，進行交通車流參數之偵測，在車流量方面，白天大車、小車及機車之準確率分別為 84%、94%及 97%；夜間大車、小車及機車之準確率分別為 95%、98%及 83%；雨天大車、小車及機車之準確率分別為 89%、95%及 92%。

在應用 AI 技術於交通資料蒐集研究上，本所曾進行「交通事件資訊整合服務與精進計畫(1/2)」、「交通事件資訊整合服務與精進計畫(2/2)」及「應用人工智慧(AI)影像辨識技術進行交通數據蒐集與分析之研究」等三項研究。交通物件偵測主要使用的技術為 AI 深度學習之卷積神經網路模型，並採用結構較簡潔且速度快的單次多重目標檢測器之深度學習神經網路模式。吳沛儒等人(2020)進一步指出在交通事件之偵測上，須先對交通物件進行偵測(detection)，再進行物件追蹤(tracking)，物件偵測主要是預測物件所在的位置(Bounding Box)以及其所屬類別(Class)；物件偵測上主要採用單次多重目標檢測器(Single Shot MultiBox Detector, SSD)之深度學習神

經網路模式，物件追蹤則採用 SORT (Simple Online and Realtime Tracking) 演算法 (Maher *et al.*, 2018)，相關文獻使用方法彙整如表 2.2-1。

表 2.2-1 AI 物件偵測使用方法彙整表

作者	使用方式
Aleksandr <i>et al.</i> (2019)	Faster R-CNN 與 SORT
Xu <i>et al.</i> (2017)	Faster R-CNN
Luo <i>et al.</i> (2018)	CNN
Gkolias 與 Vlahogianni (2019)	CNN
吳沛儒等人(2019)	SSD

2.3 應用 AI 於號誌控制

在人工智慧應用於號誌控制相關文獻中，大多採用強化學習(RL)技術。交通運輸模式往往需要在很多假設前提下(實務問題簡化)才可運作，導致難以應付複雜的交通情境(Wei *et al.*, 2019; Xiong *et al.*, 2019; Chen *et al.*, 2020)。而以規則為基礎的號誌控制方法，隨著環境複雜度增加，大幅地增加計算複雜度，進而影響到運作績效(Huo *et al.*, 2019)。而強化學習其可觀察環境變化，與環境互動，以決定該採取何種號誌控制方式，故較適合做為號誌控制之學習模式(Chen *et al.*, 2020)。

Hua *et al.* (2020)提到，強化學習可讓代理人在狀態與動作間交互循環，並以獎勵之回饋，讓 AI 掌握其動作的好壞，藉由不斷循環來提升代理人。而在號誌控制中，亦可使用此架構來訓練代理人，舉凡狀態可以為等候線長度，動作可以為是否切換燈號，獎勵則為交通壅塞狀況變化，而使用者亦可選擇合適可取得之參數做為狀態、獎勵與動作。而在 RL 模式方面，可概分為 Value-based methods 與 Policy-based methods 兩方式。Value-based methods 近似於狀態值函數或狀態動作值函數，並且策略是從學習的價值函數中隱式獲得的，其結合策略評估與控制，但其為離散動作，且當 ϵ 達到一個很小數值時，結果將不再變化；Policy-based methods 為嘗試了解特定狀態下不同操作的概率分佈，其優勢為動作可以為非離散，且學習隨機策略，持續探索任何有益的動作。

資策會(2020)還原實驗區域現場交通狀態，並根據 VISSIM 即時輸出結果，進行 III 3DQN 號誌最佳化運算，以松山路/永吉路及新生南路/和平東路兩實際路口之調查交通資料進行測試，模擬結果顯示絕大部分情況下，III 3DQN 號誌最佳化模式優於既有定時號誌控制(TOD)，若在在限制週期長度下，運算結果更好。

許添本(2020)採用深度強化學習建構號誌控制，藉由 VISSIM 做為訓練資料環境，建立符合臺灣混合車流特性之號誌化路口環境，其狀態包含採格位狀態的車輛位置與速率，以及當時的時相狀態，並以卷積神經網路(Convolutional Neural Network, CNN)為基礎，預測各動作價值，獎勵由車輛停等時間、路口通過量、切換時相所產生之紓解時間損失組合而成，模擬結果顯示其運作績效較定時號誌控制(TOD)為佳。

黃銘崇(2020)與桃園市政府交通局(2020)於桃園市大園區中正東路東匝至民生南路之 5 處路口實施 AI 號誌控制，利用 VISSIM 構建 AI 學習環境供代理人進行訓練，並將訓練成熟之代理人進行落地試驗，其狀態包含即時交通與號誌資訊，並輸出時相秒數，獎勵則採用各方向停等延滯及系統最佳目標函數，結果顯示其多路口全 AI 號誌控制藉由即時計算時相秒數、動態調整週期與時比與時差情況下，平均停等延滯約減少 9.6 秒(-19.4%)，幹道旅行時間西向減少 15.7 秒(-13.3%)、東向減少 25.8 秒(-12.9%)。

Jin et al. (2015)發展單一路口之強化學習號誌控制，強化學習之代理人為交通號誌，狀態為「佔有率、綠燈時間、目前時制、最大綠燈時間」之組合，動作為停止或延長綠燈時間，獎勵為延滯時間；該研究透過 SUMO 模擬軟體進行號誌控制模擬分析，結果顯示適應性的號誌控制可以有效處理動態交通環境。

Pol and Oliehoek (2016)發展多代理人之號誌控制深度 Q 學習(Deep Q-learning, DQN)，藉由強化學習進行多路口號誌控制；強化學習之代理人為交通號誌，狀態為路口之車輛數與目前時制(如圖 2.3.1 所示)，動作為兩種不同的時制計畫，獎勵為綜合「延滯、車輛等候時間、車禍/擁塞、緊急停等」；該研究透過 SUMO 模擬軟體進行號誌控制模擬分析，結果顯示強化學習號誌控制可有效減少旅行時間。

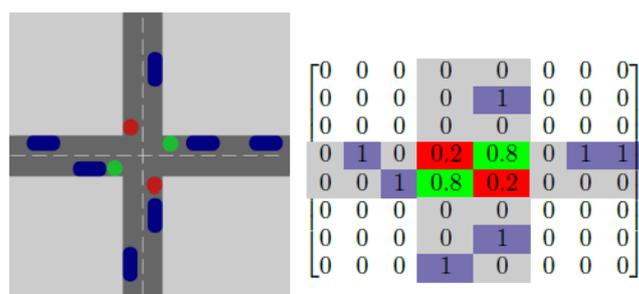


圖 2.3.1 以 0-1 矩陣表示交通狀態

資料來源：Pol and Oliehoek(2016)

Genders et al. (2016)以 Deep Q-network traffic signal control agent

(DQTSCA)進行單一路口 4 個方向之號誌控制，強化學習之代理人為交通號誌，狀態為「車輛位置、車速、目前號誌時相」，動作為號誌時相(例如：NSG 代表北南向綠燈、EWG 代表東西向綠燈、NSLG 代表北南向左轉早綠、EWLG 代表東西向左轉早綠)，獎勵為累積車輛延滯之變化；該研究透過 SUMO 模擬軟體進行號誌控制模擬分析，結果顯示平均累積延滯可減少 82%、平均排隊長度可減少 66%、平均旅行時間可減少 20%。

Liu et al (2017)提出合作式深度強化學習方法(Cooperative Deep Reinforcement Learning, Coder)進行多路口之號誌控制，強化學習之代理人為交通號誌，狀態為「不同方向的車輛位置、車速、交通號誌時相」之組合，並使用 0 和 1 表示車輛存在與否，0 表示不存在、1 表示存在。動作為號誌時相(NSG, EWG, NSLG, EWLK)，獎勵為平均延滯時間及停等車隊長度；該研究透過 SUMO 模擬軟體進行號誌控制模擬分析，結果顯示 Coder 可減少 30% 停等車輛數。

Xiaoyuan et al. (2018)採用 Double Dueling DQN 演算法，以路口車輛位置及速度做為環境狀態，車輛等待時間為獎勵，增減時制分配時間長短為動作，代理人以 DRL 學習最佳時制分配，該研究於 SUMO 模擬平臺上以合成資料驗證其技術相較於傳統時制計畫，可降低平均停等時間。

Hua et al.(2018)採用 DQN 演算法搭配時相選擇器，同時訓練兩組網路，於上線時透過時相選擇對應網路為策略基礎輸出動作，該研究以路段等待車隊長度、區域車輛數目、車輛等待時間，以及號誌時相做為環境狀態。路口單位時間通行車輛、各路段等待車輛長度總和、各車輛旅行時間權重加總做為獎勵。時相適應性(adaptive)為動作。代理人以 DRL 學習最佳號誌適應性，該研究除使用合成資料做為模擬驗證外，亦使用實際於中國大陸不同車流抵達率(arrival rate)下進行模擬驗證，模擬結果顯示其模型可適應不同時段交通狀況。

Rusheng et al.(2018)針對在不同車輛偵測率(detection rate)狀況下，探討深度強化機器學習應用於號誌控制時的可靠程度，透過該研究分析發現只要車輛偵測率與訓練時的車輛偵測率差異不要過大，強化學習所建立之單一模型可應用於不同的車輛偵測率環境。

Wei et al (2018)透過深度 Q 學習(DQN)進行單一路口 4 個方向之號誌控制，以交通號誌做為強化學習之代理人(Agent)，道路長度、車輛數、車道數等為強化學習之狀態(State)，號誌時相的轉換為強化學習之動作

(Action), 車輛停等時間及車輛數構成之交通順暢度做為此強化學習之獎勵 (Reward), SUMO 模擬分析結果指出停等長度、延滯時間都可有效地獲得改善。

Zheng et al (2019)表示流量可能會因為白天與晚上偵測效果不同, 導致差異非常大, 故嘗試分析不同交通動作之間的關係, 包括: (1)較大的交通流量表示對綠燈的需求越大, (2)當兩種交通方式發生衝突時, 應優先考慮需求較高的一方。該研究發展以 DQN 為基礎之 FRAP (Flipping Rotation All Phase)方法, 進行單一路口 4 個方向之號誌控制, 強化學習之代理人為交通號誌, 狀態為各方向之交通流量, 動作為時相選擇, 獎勵為路口各方向的平均等候長度;最後該研究藉由 CityFlow 模擬軟體進行號誌控制模擬分析, 結果指出強化學習方法可以有效地因應複雜的交通狀況。

Wei et al (2019)發展以 DQN 為基礎之最大壓力(Max Pressure, MP)幹道號誌控制方法, 讓路口的壓力最小化, 亦即最小化進入車道車輛數與離開車道的車輛數的不平衡程度;強化學習之代理人為交通號誌, 狀態為以某路口出入口車道的車輛數, 動作為從 4 個時相中選擇一個時相, 獎勵為整體路網旅行時間;最後該研究藉由 CityFlow 模擬軟體進行號誌控制模擬分析, 結果顯示 MP 強化學習法優於其它傳統交通控制方法。

Wei et al. (2019)同時指出傳統事先計算路口彼此間時差之號誌控制難以適用於動態之交通環境, 故提出圖形式注意力網路(Graph Attention Network)為基礎之多代理人強化學習—CoLight 號誌控制, 考量周遭交通環境對於目標路口之影響;如圖 2.3.2 所示, A 與 B 為兩個目標路口;強化學習之代理人為交通號誌, 狀態為每車道之車輛數, 動作為時相, 獎勵為等候長度, 該研究透過 CityFlow 模擬軟體進行號誌控制模擬分析, 結果顯示 CoLight 績效優於其他號誌控制方法。

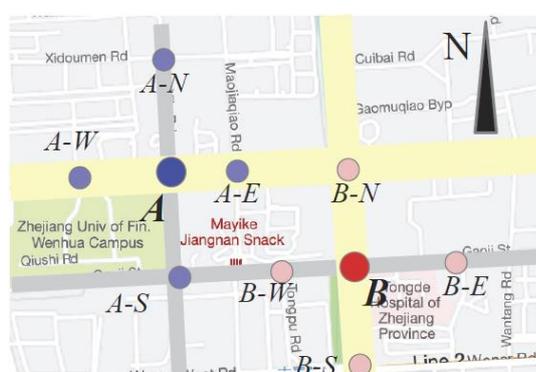


圖 2.3.2 周遭交通環境與目標路口

資料來源: Wei et al.(2019)

Lee et al. (2020)以強化學習結合交通影像資料進行 AI 號誌控制，並藉由 VISSIM 進行測試與驗證。Zang et al (2020)則提出以強化學習為基礎之 MetaLight 架構，進行單一路口 4 個方向之號誌控制，強化學習之代理人為交通號誌，狀態為不同方向的車輛數與時相，動作為從八個時相中選擇一個時相(如圖 2.3.3 所示)，獎勵為路口各方向的平均等候長度；該研究透過 CityFlow 模擬軟體進行號誌控制模擬分析，結果顯示 MetaLight 績效優於其他號誌控制方法。

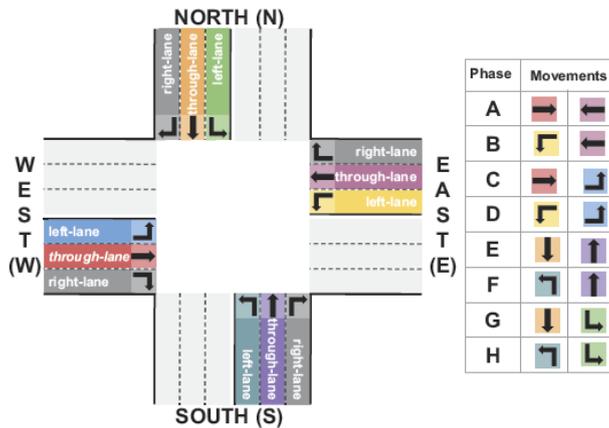


圖 2.3.3 八種不同時相之動作

資料來源：Zang et al(2020)

Chen et al. (2020)為了因應在大規模都市路網上號誌難以協調控制之問題，以交通壓力(Pressure)的概念設計多代理人之 DQN 強化學習，分析數以千計的號誌控制；強化學習之代理人為交通號誌、狀態為目前時相以及交通流向的壓力、動作為從八個時相中選擇一個時相(如圖 2.3.4 所示)、獎勵為路口壓力(進入路口排隊車輛數合以及離開路口排隊車輛數合之差異)；該研究透過 CityFlow 模擬軟體進行號誌控制模擬分析，結果顯示該方法之績效優於其他號誌控制方法。

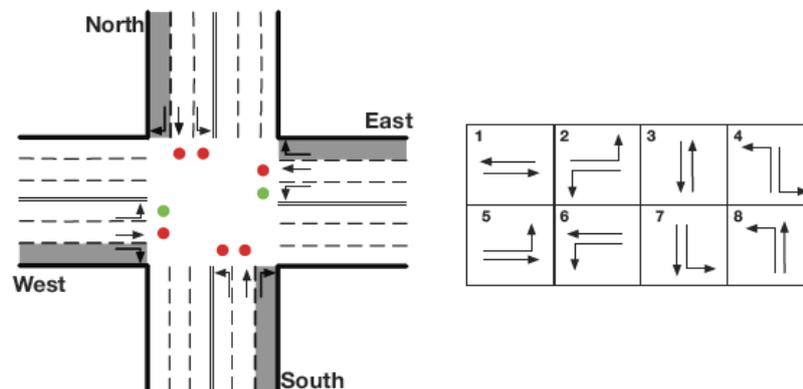


圖 2.3.4 以八時相做為動作

資料來源：Chen et al.(2020)

在以強化學習進行 AI 號誌控制之績效分析上，許多研究主要以德國 Aerospace Center 之開源微觀交通模擬軟體 SUMO (Simulation of Urban MObility)進行分析。Jin and Ma(2019)以多代理人之強化學習進行 AI 號誌控制，並藉由 SUMO 進行測試驗證。Yang et al.(2019)以強化學習於多路口進行 AI 協同式號誌控制(Cooperative Traffic Signal Control)，並藉由 SUMO 進行測試驗證。Genders and Razavi(2020)以強化學習進行 AI 適應性號誌控制(Adaptive Traffic Signal Control)，並藉由 SUMO 進行測試驗證。Kim and Jeong(2020)以強化學習於多路口進行 AI 協同式號誌控制(Cooperative Traffic Signal Control)，並藉由 SUMO 進行測試驗證。Chu et al.(2020)以多代理人之強化學習進行大規模之 AI 號誌控制，並藉由 SUMO 進行測試驗證，並主要以逐時相變換為主，惟唯一落地之案例為採逐週期(變動週期)之方式，相關文獻彙整如表 2.3-1。

表 2.3-1 應用 AI 於號誌控制文獻彙整表

作者	控制路口數	模擬軟體	是否落地	方法	變換頻率
資策會(2020)	1	VISSIM	否	III 3DQN	逐週期
許添本(2020)	1	VISSIM	否	深度強化學習	逐時相
黃銘崇及桃園市政府交通局(2020)	5	VISSIM	是	強化學習	逐時相
Jin et al. (2015)	1	SUMO	否	強化學習	逐時相
Pol and Oliehoek (2016)	多路口	SUMO	否	DQN	逐時相
Genders et al.(2016)	1	SUMO	否	DQN	逐時相
Liu et al (2017)	多路口	SUMO	否	合作式深度強化學習	逐時相
Xiaoyuan et al. (2018)	1	SUMO	否	Double Dueling DQN	逐時相
Wei et al (2018)	1	SUMO	否	DQN	逐時相
Zheng et al (2019)	1	CityFlow	否	DQN	逐時相
Wei et al (2019)	多路口	CityFlow	否	DQN	逐時相
Lee et al. (2020)	1	VISSIM	否	DQN	逐時相
Zang et al (2020)	1	CityFlow	否	強化學習	逐時相
Chen et al. (2020)	1	CityFlow	否	DQN	逐時相

強化學習在深度學習神經網路發展上會面臨許多挑戰。最主要在於真實環境之應用上，學習過程中易耗費大量成本(吳毅成，2019)。在尋找最適解時，需耗費大量試誤(trial-and-error)的探索(exploration)時間才會收斂

(Huo et al., 2019; Xiong et al., 2019)。有鑑於此，一些研究建議可先學習專家的經驗，讓強化學習模式有基本的知識，在一定的基礎上再去搜尋最佳解。例如：演示法之深度 Q 學習 (Deep Q-learning from Demonstrations, DQfD) (Xiong et al., 2019) 或將強化學習結合模仿學習 (Imitation Learning) (Huo et al., 2019)。因此，本計畫在強化學習的模式發展上，採取學習專家經驗之強化學習號誌控制技術，並在實務運作前先透過 SUMO 模擬來評估 AI 號誌控制績效。

2.4 綜合探討

在應用 AI 技術於交通資料蒐集上，主要使用 AI 深度學習之卷積神經網路模型，辨識各類型交通資料，通常需先對交通物件偵測，再進行物件追蹤。適應性號誌控制可以更快速地因應交通狀況變化，調整符合交通需求之號誌時制，提升道路績效。然而，如何有效地蒐集即時交通車流數據，並據以動態地調控交通號誌，為當前適應性號誌控制於實務運籌上之重要課題與挑戰。

AI 應用於交通號誌控制上，有多種 AI 的方法可以使用，但由於交通複雜的特性，大多文獻建議可採用深度強化式機器學習技術，藉由獲悉即時交通狀況，動態調整交通號誌控制策略，以達最適宜的交通管理目標。但目前既有文獻鮮少將深度強化式機器學習實行於實際路網上進行號誌控制，依據相關演算法，本計畫評估 DQfD 與 A3C 均有可能可以應用於交通號誌控制上，以下說明本計畫採用以 DQfD 之運作機制為基礎之考量。

1. A3C是在線策略(on-policy)，其更新方式是須要蒐集目前訓練出的AI對環境互動所產生的資料，若資料樣本數不夠，無法訓練出良好品質的AI號誌控制模式，但受限於研究時程，本計畫無法蒐集足夠訓練資料。此外，當AI號誌控制模式更新後，已蒐集的資料因不適用於新的AI號誌控制策略，在線策略(on-policy)方式須要捨去所用過的訓練資料，造成資料浪費。因此採取離線策略(off-policy)的DQfD，利用PaSO最佳化軟體扮演專家角色來產生最佳化時制計畫做為訓練基礎。
2. 成效與架構更符合欲處理的問題：A3C是policy-based演算法，而DQfD是屬於value-based演算法，於諸多文獻探討上，value-based在離散動作環境下的成效都是比policy-based佳，這點可以從Atrai games目前得高分的方法看出(目前是Agent57，是DQN系列的方法)；相反，policy-based大多是處理連續動作環境下的問題(如：機器人關節轉動的角度)，這點可以從機器人操作的方法看出。由於在交通號誌

控制問題，無論是制定時制計畫(plan)或是秒數分配，應該都屬於離散動作。因此本計畫採用value-based演算法。

本計畫延伸 DQfD 運作機制，提出深度強化學習演算法 DQfB (DQN from Base-model)於號誌控制策略模型建立。相較於 DQfD 僅單純使用示範的行為與其互動的資料進行一般強化學習訓練，本計畫所設計之 DQfB 使用不同獎勵形式，達到有模仿學習的效果，並且仍保留精進的空間，使得最後學習的決策可以超過基礎模型的決策，4.1.3 節將詳細說明深度強化學習演算法 DQfB (DQN from Base-model)應用於號誌控制內容。

第三章 AI 交通資料蒐集與應用

3.1 研究場域說明

本計畫考量 AI 號誌控制現場實作之可能風險，因此選定延續前期於臺中市太平區太平匝道下游交通環境較單純之樂業路與十甲東路、樂業路與東英路兩路口做為實驗場域。樂業路主線車流量大，但樂業路與十甲東路、樂業路與東英路兩路口並未能與上游的太平匝道號誌控制連鎖，因而台 74 太平匝道下匝道車流往臺中市區車流之續進仍有改善空間。同時十甲東路與東英路支道車流量相較於較樂業路幹道為低，但仍有一定之車流量，因此仍具備展示 AI 號誌控制之可行性。本處各車道配置均為一快車道及一慢車道，路口說明如圖 3.1.1 與圖 3.1.2 所示，相關研究場域區域路網問題說明如 4.1 節，討論與施工紀錄如表 3.1-1 所示。



圖 3.1.1 研究場域



圖 3.1.2 研究場域空拍影像

表 3.1-1 研究場域討論及施工紀錄

日期	主題	說明
109.05.04	研究場域討論 1	方案 1.樂業東英與樂業十甲路口 方案 2.太平環中與太平甲堤 方案 3.台 74 太原匝道週邊兩路口
109.05.15	研究場域討論 2	先以兩個單一路口及固定週期長度為主，經討論後，採方案一(樂業十甲與樂業東英路口)。
109.05.27	第一次會勘	多數裝設於號誌桿之偵測設備均較無裝設問題，惟原規劃於路段中架設 AI 偵測設備，因引電困難，再行評估其它點位。
109.06.05	流量調查	進行轉向交通量調查
109.06.24	第二次會勘	與相關單位進行會勘，確認設備裝設位置
109.07.02	e-Tag 施工	廠商進場開始裝設 e-Tag。
109.07.14	AI 偵測設備施工	
109.07.23	e-Tag 天線校正	針對 e-Tag 發射角度進行校正。
109.07.24	AI 偵測設備上線	本案 15 組 AI 偵測設備上線。
109.08.17	異常設備更換	設備疑似遭到雷擊而故障，進行更換。
109.09.10	上線測試前會議	
109.09.30	AI IPC 安裝	安裝 AI IPC 及設定與號誌控制器之通訊。
109.10.07	新時制計畫下傳	
109.10.13	虛擬測試	於該週進行 3 天虛擬測試
109.10.30	系統測試	於現場進行 AI IPC 之系統上線測試
109.11.02	系統上線	正式上線運行

資料來源：本計畫整理

3.2 交通特性資料調查

3.2.1 設備偵測架設及偵測規劃

為利有效產生兩路口之控制策略，需即時掌握進入兩路口之實際需求，故本次藉由 AI 影像設備掌握外圍進入之需求流量，並同時利用路口 4 個方向延滯做為績效衡量參數；此外，同步裝設 e-Tag 讀取器來掌握主要關鍵路徑之旅行時間，做為績效指標，由於現場並無法布設光纖網路，故各項設備，包含 AI 影像偵測設備、e-Tag 讀取器、號誌控制器及 AI IPC 均以 4G 無線通訊方式，進行資料傳輸及號誌控制指令下傳。

在 AI 影像偵測設備布設規劃部分，本計畫採用 Nvidia Nano 運算晶片

之偵測設備，透過邊緣運算所進行之 SSD 深度學習神經網路模式的物件偵測，以及 SORT 演算法的物件追蹤。關於物件偵測 SSD 深度學習神經網路以及 SORT 演算法之細節，可參考吳沛儒等人 (2019, 2020) 之相關研究。

有關 AI 影像偵測設備架設部分，攝影機除轉向偵測設備因需要掌握路口畫面而架設於號誌桿彎桿處，其餘均架設於號誌桿燈箱旁(如圖 3.2.1)，架設高度約為 5.5 公尺(臺中市號誌桿高度)，在此架設高度下，有效辨識距離約為 20 至 40 公尺，左右寬度有效影像辨識距離約為 15 公尺(如圖 3.2.2)，同時將 AI 運算電腦令打造設備箱附掛於號誌桿上(如圖 3.2.3)，使所有 AI 運算電腦可集中放置，並便於引電及通訊，本計畫整體設備規劃說明如圖 3.2.4、表 3.2-1 及表 3.2-2。



圖 3.2.1 攝影機裝設位置(號誌桿燈箱旁)

資料來源：本計畫整理

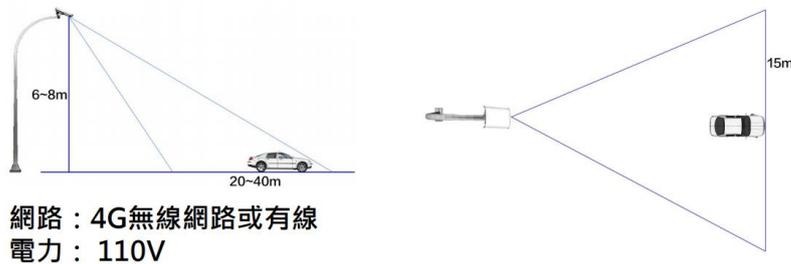


圖 3.2.2 攝影機偵測範圍限制

資料來源：本計畫整理



圖 3.2.3 偵測設備主機及通訊模組箱體畫面

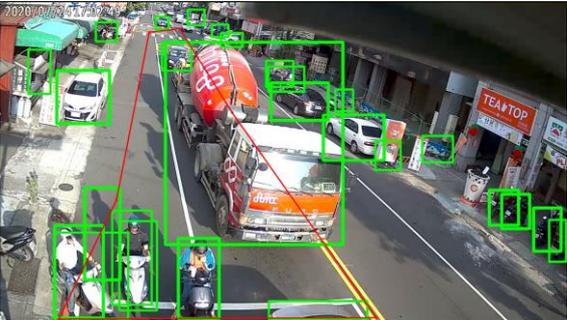
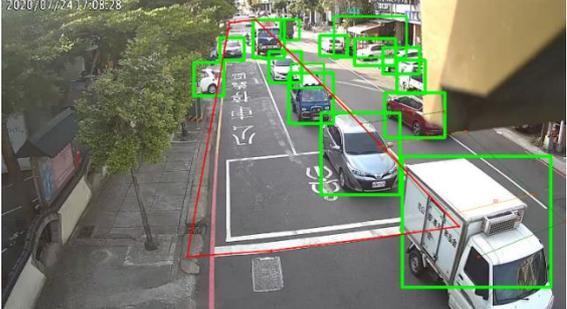
資料來源：本計畫整理

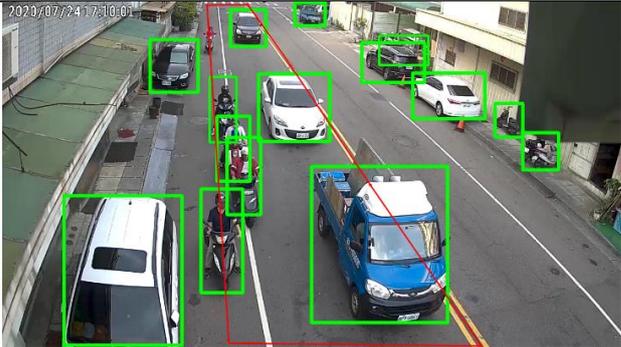
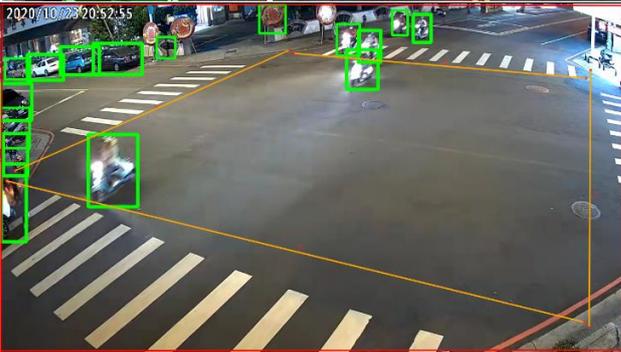
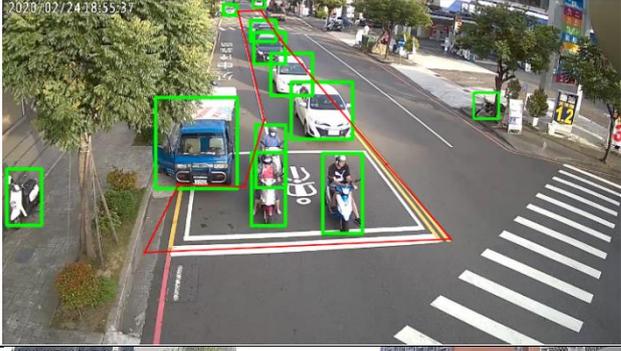
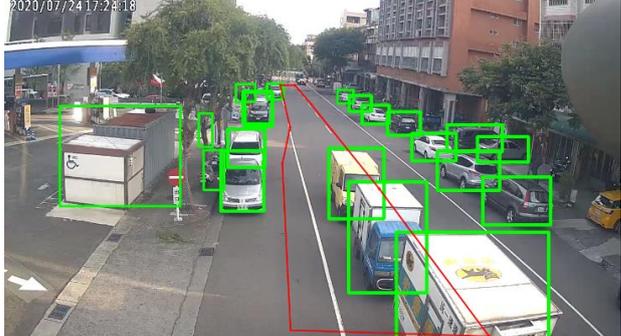


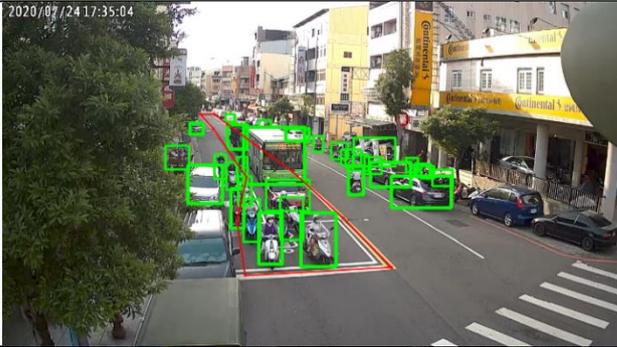
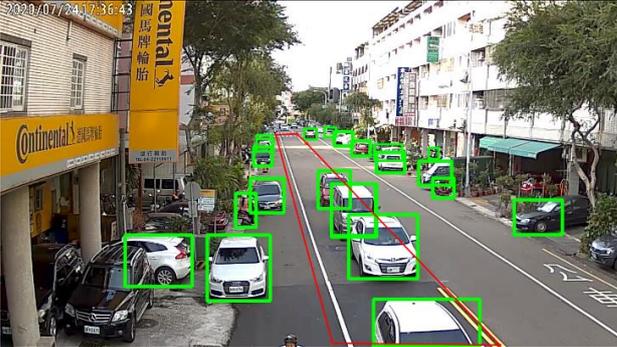
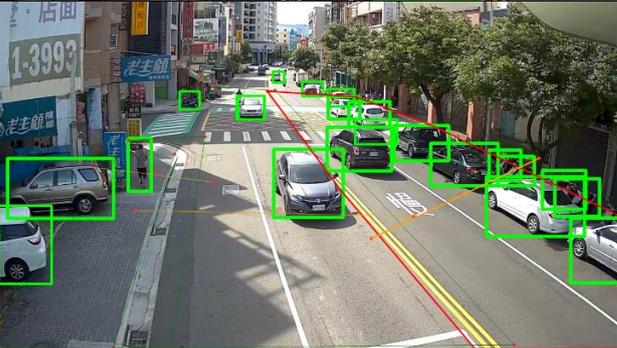
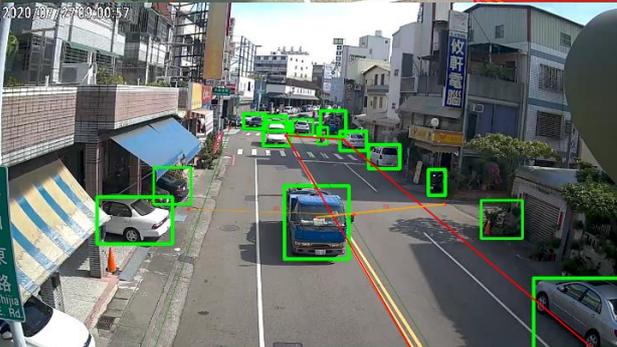
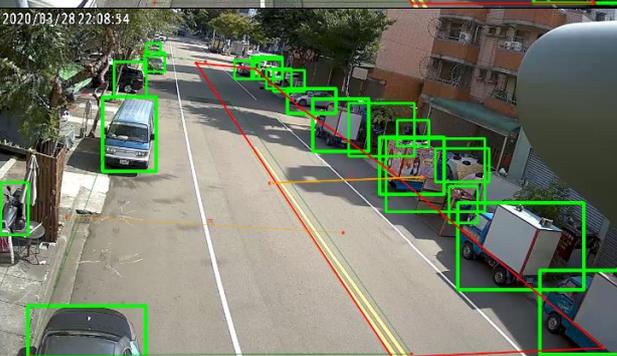
圖 3.2.4 偵測設備布設一覽圖

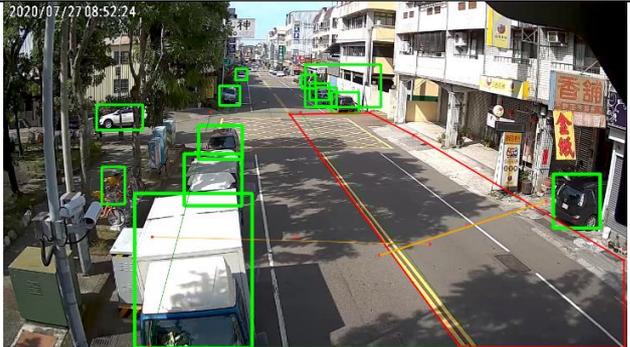
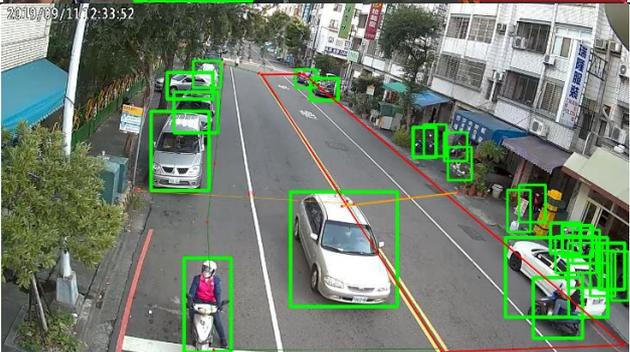
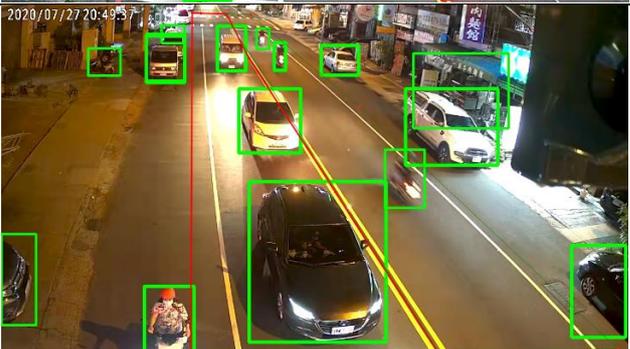
資料來源：本計畫整理

表 3.2-1 AI 影像偵測設備布設一覽表

編號	說明	偵測畫面
1	<ul style="list-style-type: none"> ● 樂業路與十甲東路口，往西。 ● 偵測西行車輛之延滯。 	
2	<ul style="list-style-type: none"> ● 樂業路與十甲東路口，往北。 ● 偵測北行車輛之延滯。 	
3	<ul style="list-style-type: none"> ● 樂業路與十甲東路口，往東。 ● 偵測東行車輛之延滯。 	

編號	說明	偵測畫面
4	<ul style="list-style-type: none"> ● 樂業路與十甲東路口，往南。 ● 偵測南行車輛之延滯。 	
5	<ul style="list-style-type: none"> ● 樂業路與十甲東路口。 ● 偵測樂業路西行、十甲東路北行之轉向交通量。 	
6	<ul style="list-style-type: none"> ● 樂業路與十甲東路口。 ● 偵測樂業路東行、十甲東路南行之轉向交通量。 	
7	<ul style="list-style-type: none"> ● 樂業路與東英路口，往西。 ● 偵測西行車輛之延滯。 	
8	<ul style="list-style-type: none"> ● 樂業路與東英路口，往北。 ● 偵測北行車輛之延滯。 	

編號	說明	偵測畫面
9	<ul style="list-style-type: none"> ● 樂業路與東英路口，往東。 ● 偵測東行車輛之延滯。 	
10	<ul style="list-style-type: none"> ● 樂業路與東英路口，往南。 ● 偵測南行車輛之延滯。 	
11	<ul style="list-style-type: none"> ● 樂業路與長福路口，往東。 ● 偵測東行進入樂業路之流量。 	
12	<ul style="list-style-type: none"> ● 十甲東路與東英二街路口，往北。 ● 偵測北行進入樂業路與十甲東路口之流量。 	
13	<ul style="list-style-type: none"> ● 東英路與東英五街路口，往北。 ● 偵測北行進入樂業路與東英路口之流量。 	

編號	說明	偵測畫面
14	<ul style="list-style-type: none"> ● 十甲東路與東英六街路口，往南。 ● 偵測南行進入樂業路與十甲東路口之流量。 	 <p>2020/07/27 08:52:24</p>
15	<ul style="list-style-type: none"> ● 東英路與早溪街口，往南。 ● 偵測南行進入樂業路與東英路口之流量。 	 <p>2020/09/11 12:33:52</p>
16	<ul style="list-style-type: none"> ● 樂業路與喬城三街口，往西。 ● 偵測西行進入樂業路之流量。 	 <p>2020/07/27 20:49:37</p>

資料來源：本計畫整理

表 3.2-2 e-Tag 設備布設一覽表

編號	說明	偵測示意圖
1	<ul style="list-style-type: none"> ● 東平路與東平路 777 巷。 ● 偵測西行進入樂業路之車輛。 	 <p>東平 777巷往西近國城話 編號: 1 Google</p>

編號	說明	偵測示意圖
2	<ul style="list-style-type: none"> ● 東平路與東平路 777 巷。 ● 偵測東行離開研究場域之車輛。 	
3	<ul style="list-style-type: none"> ● 樂業路與喬城三街路口。 ● 偵測雙向樂業路之車輛。 	
4	<ul style="list-style-type: none"> ● 樂業路與十甲東路口。 ● 偵測雙向樂業路之車輛。 	
5	<ul style="list-style-type: none"> ● 樂業路與長福路口。 ● 偵測雙向樂業路之車輛。 	

料來源：本計畫整理

3.2.2 事前車流量調查

受限於偵測設備裝設牽涉引電、布線及現場施工，無法於短時間內完成，為有效爭取時間建立研究場域之模型，並訓練 AI 號誌控制模式，本計畫藉由本所於前期計畫所開發之臨時性偵測設備，並同步搭配人工架設攝影機記錄現場車流，於事後以人工方式及 AI 車流偵測方式進行車流調查。整體調查規劃如圖 3.2.5 所示，本次調查資料主要以進入兩研究路口之流量為主，以掌握實際需求流量，調查時間為 109 年 6 月 5 日星期五

07:00~09:00 (晨峰)、13:00~15:00 (離峰)、16:00~19:00 (昏峰)、109 年 6 月 6 日及 7 日之 13:00~15:00，相關調查成果及分析請參閱 4.1.1 節。



圖 3.2.5 車流調查

資料來源：本計畫整理

1. 研究場域車流資料

本計畫以人工架設攝影機記錄現場車流(於調查路口之號誌桿或路燈桿等桿件架設類似 GoPro 之小型攝影機)，由於單以人工方式之架設高度有限，高度將影響拍攝視野，故本計畫回收架設之攝影機後，先行評估攝影機畫面中欲偵測之車流是否遭到遮蔽(如違規停車)，並評估偵測車流是否清晰可見，在達成以上條件後，本計畫先嘗試將影片匯入 AI 偵測設備，於 AI 偵測設備畫設相關偵測區域後，觀察其偵測數據是否正確，若正確，則採用 AI 偵測設備進行調查。

本次車流調查共計調查 10 處路口，其中共計 4 處路口因影像能夠於 AI 偵測設備獲得可靠之調查數據，而採用 AI 偵測設備讀取拍攝影像進行調查，以節省人力成本。以此種方式雖需要再進行相關檔案轉置，且由於一般攝影機其影像編碼格式並不若 AI 偵測設備其可同時達成維持影像畫質及降低檔案大小之優勢(AI 偵測設備 1 小時影片之檔案大小約 600MB，一般攝影機 1 小時影片之檔案大小約 4G)，造成資料存取需要花費大量時間，但後續影像處理及匯入 AI 偵測設備之時間遠低於以人工重新查看影片調查車流之時間，故此方式仍十分具有競爭力，相關車流資料已彙整於 4.1.1 節。

2. 利用臨時性設備(運算晶片為 Nvidia TX2)進行車流調查

本計畫利用前述臨時性偵測設備偵測樂業路與十甲東路口之轉向交通量，臨時性設備實際使用流程圖如圖 3.2.6 所示，本次臨時性偵測設備架設於圖 3.2.7 右下角處之轉角人行道上，偵測準確率如圖 3.2.8 所示，準確率計算係以人工方式確認影片之車流量與臨時性設備之車流量進行比較。惟本次因為首次以此方式於現場進行偵測，初期偵測線劃設不如預期，因臨時性設備係透過車輛通過任意兩條偵測線，判定其轉向，因而造成部分車輛偵測準確度偏低；此外，現場亦有諸多車輛於跨越偵測線時遭到遮蔽，致使無法判別，但由於臨時性設備於偵測同時亦同步進行錄影，藉由後續偵測線調整，已達到良好成果。

在使用流程部分，使用臨時性設備約需要 1 小時之作業時間(包含載運至現場再至從現場載回，不包含交通時間，因其與人工調查交通時間基本相同)，但並不需要人工之調查時間，故在需要較多人力時間調查之項目中，臨時性設備有其相當優勢，臨時性設備與人工調查作業方式比較如表 3.2-3 所示。

- (1)載運設備：臨時性設備重量約 120 公斤，其底部設有輪子可供移動，但仍需租用可升降貨斗之貨車，於放置於貨斗時，須妥善固定，本過程約需 5~10 分鐘，並建議於搬運過程中需要至少 2 人進行。
- (2)放置設備：設備載運至調查點後，將設備運下並定位，其設備輪子可固定，並可視現場環境狀況，裝設底部固定支架並以繩索固定，本過程約需 5~10 分鐘，並建議至少 2 人進行。
- (3)裝設攝影機與攝影機支架：組裝攝影機固定桿，並放置攝影機，本過程約需 5 分鐘，並建議至少 2 人進行。
- (4)架設攝影機：將攝影機固定桿與設備箱體進行組裝，並盡可能與號誌桿同高，本過程約需 3 分鐘，並建議至少 2 人進行。
- (5)偵測規劃：確認偵測畫面是否涵蓋欲偵測之項目與範圍，嘗試劃設偵測線確認數據是否正常，本過程約需 10 分鐘，可 1 人進行。
- (6)偵測完畢：設備關機、拆卸、放置回車上及從設備存放地放置回倉庫，載運收工，本過程約需 15 分鐘，並建議至少 2 人進行。



圖 3.2.6 臨時性設備使用流程一覽圖

資料來源：本計畫整理



圖 3.2.7 臨時性設備現場偵測線劃設

資料來源：本計畫整理

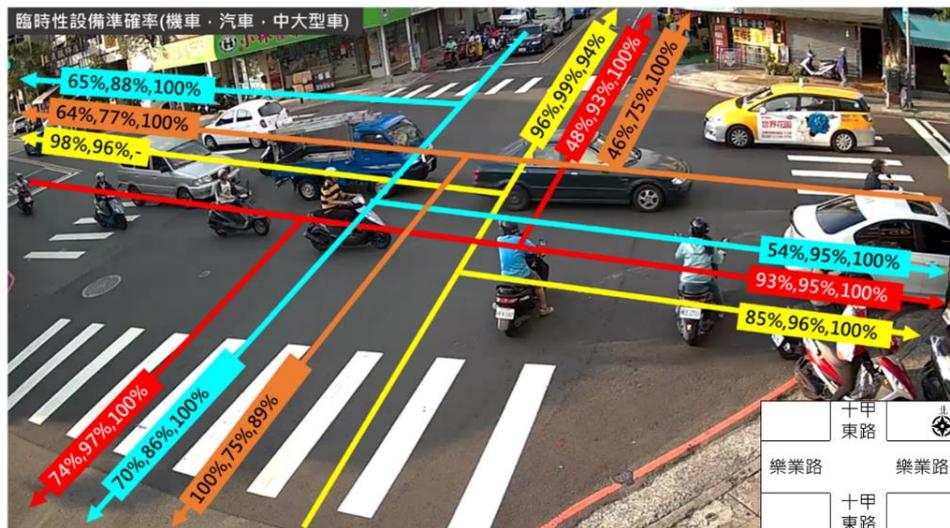


圖 3.2.8 臨時性設備準確率

資料來源：本計畫整理

表 3.2-3 臨時性設備與人工調查之各工作項目比較

項目	臨時性設備	現場人工調查	架設攝影機調查
設備載運	5~10 分/設備	0 分	0 分
設備放置與安裝	13~18 分/路口	0 分	5~10 分/路口
偵測線劃設	10 分/路口	0 分	0 分
設備拆卸	10 分	0 分	
人工調查車流	0 分/路口	12 人小時/路口	12 人小時/路口
資料轉換為電子數據	0 分	10 分/路口	於調查時已轉換
人力數量	2~3 人 (架設設備)	2 人×路口數 (現場數車流)	2 人 (架設攝影機)
設備數量	1 設備×路口數	0	2 設備×路口數
備註：			
1. 調查時間為 6 小時。			
2. 臨時性設備其若車輛數可載運多台設備，則並不需要增加人力，且於設備架設完畢，人員即可離開。			
3. 目前人工調查通常使用架設攝影機錄影後，再調派人力觀看影片計算車流(人力可較少，且可不必連續性)。			

相關偵測率檢討說明如後。

1. 樂業路東行：

- ① 直行：機車與汽車準確率均達 93% 以上，中大型車準確率達到 100%，符合水準。
- ② 右轉：汽車與中大型車準確率均達 97% 以上，惟機車右轉因偵測線畫設過短，致使許多機車於進入路口時並未通過偵測線，致使未被判別，未來偵測線畫設應畫設至路口紅線處，以減低此情形。



圖 3.2.9 樂業路東行，機車右轉準確率較低圖示

資料來源：本計畫整理

- ③左轉：汽車與中大型車準確率均達 93% 以上，機車左轉則因其亦遭汽車遮蔽，致使無法偵測，若加高拍攝高度，應可改善。



圖 3.2.10 樂業路東行，機車左轉準確率較低圖示

資料來源：本計畫整理

2. 樂業路西行：

- ①直行：多數車輛於通過第一條偵測線即遭到遮蔽，致使無法偵測，應僅能於對角線再裝設一偵測設備，方能解決此問題。
- ②右轉：由於上方偵測線太過靠近路口處，致使直行汽車多數被判定為右轉，改善方向須將上方偵測線移至更上方，方能降低誤判率。
- ③左轉：多數車輛於通過第一條偵測線即遭到遮蔽，致使無法偵測，應僅能於對角線再裝設一偵測設備，方能解決此問題。



圖 3.2.11 樂業路西行，各式車輛準確率較低圖示

資料來源：本計畫整理

3. 十甲東路南行：

- ①直行：部分車輛因通過進入路口之偵測線遭到其它車輛遮蔽，尤以機車遭到汽車遮蔽最為嚴重，致使準確率較低，改善方法為調整拍攝角度。

- ②右轉：除車輛於通過第一條偵測線遭遮蔽未判別外，部分直行車輛於右轉時會跨過右轉偵測線致使誤判，改善方法為調整右轉偵測線。
- ③左轉：車輛於路口中心準備左轉時，因遭到其他車輛遮蔽時間較長，致使 AI 判別其為不同車輛，造成誤判，改善方法為調整拍攝角度。



圖 3.2.12 十甲東路南行準確率較低圖示

資料來源：本計畫整理

4. 十甲東路北行：

- ①直行：各式車輛準確率均達 94% 以上。
- ②右轉：因轉角處有諸多機車右轉時並未通過第一條偵測線，致使無法判別，惟此較屬於非不可抗力因素。



沒通過第一條偵測線，僅通過第二條

圖 3.2.13 十甲東路北行，機車右轉準確率較低圖示

資料來源：本計畫整理

- ③左轉：各式車輛準確率均達 96% 以上。



於路口或通過偵測線遭遮蔽
改進方向：需改變拍攝角度

圖 3.2.14 樂業路東行，機車左轉準確率較低圖示

資料來源：本計畫整理

本計畫依據上述問題，針對偵測線進行調整，期望可透過偵測設備掌握 4 個方向車流，調整後之偵測線劃設如圖 3.2.15 所示。數據顯示(如圖 3.2.16 所示)，除十甲東路往南(圖片中由上往下車流)、樂業路往西(圖片中由右至左車流)之數據因偵測線往上，致使辨識緩衝區域降低，同時降低準確度外，其餘均有提升，尤以十甲東路往北(圖片中由下往上車流)、樂業路往東(圖片中由左往右車流)改善最多。故建議轉向量調查一攝影機在號誌桿之高度下，應僅能偵測其鄰近，較不會被其它遮蔽之兩方向(以本案而言，則為十甲東路往北、樂業路往東)，建議未來除針對偵測線進行調整外，應再於對角線加裝一臨時性偵測設備，方能大幅改善偵測率較低之問題。

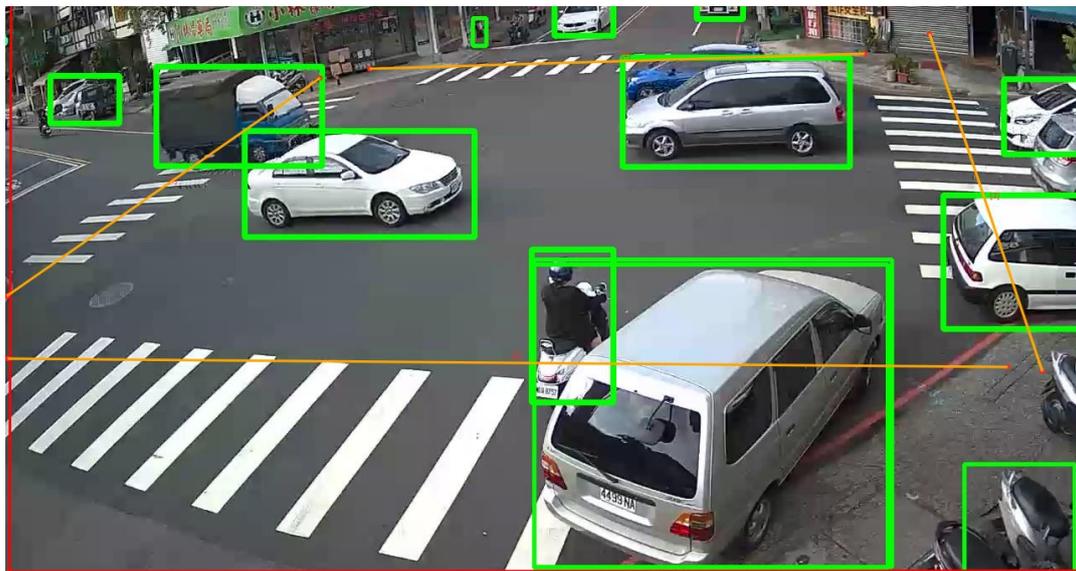


圖 3.2.15 第二次偵測線劃設方式

資料來源：本計畫整理

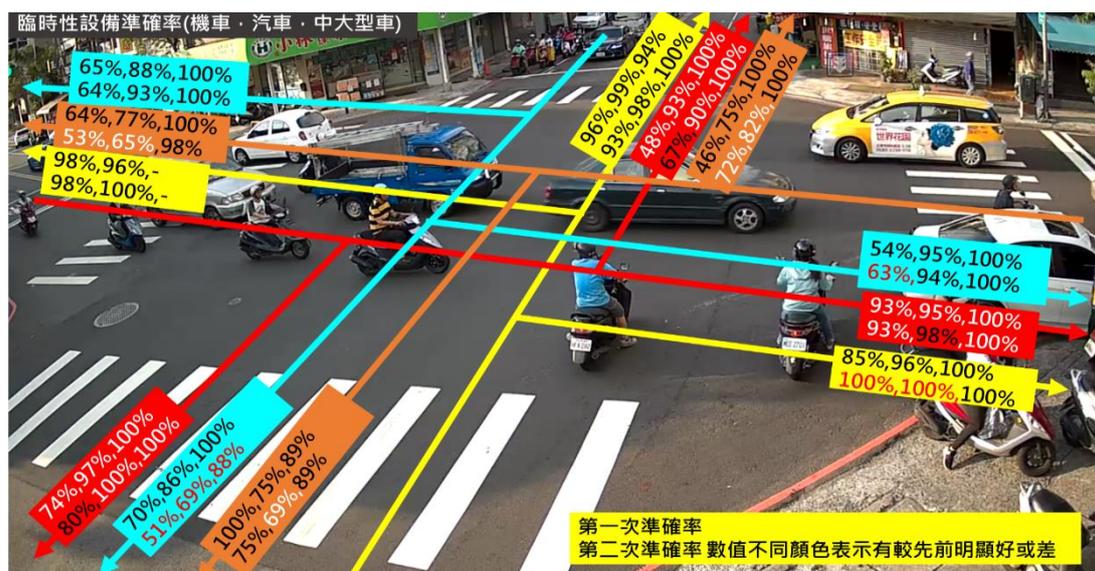


圖 3.2.16 第一次與第二次準確率比較圖

資料來源：本計畫整理

3.3 AI 影像偵測精進

本計畫針對 AI 影像偵測設備應用於交通參數資料蒐集，針對模型進行以下改進，茲就 AI 影像偵測精進方式說明如後。另於偵測準確率計算部分，本計畫納入下列 2 項處理方式，當實際車輛(人工判斷)樣本數大於 5，方列入準確率計算，否則均標示「N/A」；同時由於本計畫使用運算能力較為低階 AI 運算晶片(Nvidia Nano)，造成在車輛偵測的效果較為不穩定，因此對於依目前計算公式所得準確率為負值者，均標示為「誤差過大/無法使用」。

1. SSD 模型改進

本計畫新增諸多不同案場圖片，特別是過往較為缺少的大貨車及腳踏車樣本，且修正過往訓練集中的錯誤標註，由於 AI 在偵測一張影像之物件中不可能只偵測到一種物件，故一般在深度學習驗證模型優劣常以在 mAP (Average Precision) 做為評估指標，其中 AP 值為 PRC (precision-recall curve) 曲線下之面積，Precision (PR) 之計算公式為 $TP/(TP+FP)$ ，Recall (RC) 之計算公式為 $TP/(TP+FN)$ ，上述 TP (True Positive, 真陽性) 為正確預測出真實結果之個數；FP (False Positive, 偽陽性) 為型 I 誤差之個數，FN (False Negative, 偽陰性) 為泛型 II 誤差之個數，mAP 為每一種物件 AP 值之平均。目前 mAP (mean Average Precision, 及各類別 AP 的平均值，用於評斷系統之好壞程度) 結果如表 3.3-1 所示，各項車種細部說明如表 3.3-2 所示。

表 3.3-1 SSD 模型精進比較表

種類	本計畫前期(108 年「應用人工智慧(AI)影像辨識技術進行交通數據蒐集與分析之研究」)	本計畫
腳踏車	0.125	0.148
機車	0.512	0.547
小客車	0.681	0.699
中型車	0.445	0.444
大客車	0.603	0.633
大貨車	0.537	0.578
行人	0.185	0.200
mAP	0.441	0.464

資料來源：本計畫整理

表 3.3-2 偵測車種與行人說明

類別	車身長度的	舉例說明
腳踏車	最小	腳踏車、電瓶車、三輪車、人力車(含騎士)
機車	近似腳踏車	機車、電動機車、重機(含騎士)
小客車	<5m	一般轎車、跑車、敞篷車、休旅車、吉普車(jeep)、計程車、警車
中型車	>5m, <12m	皮卡車(pickup truck)、小型貨卡車、中小型拖吊車、廂型車(work van)、九人座、搬家用小貨車、復康巴士、救護車
大客車	>12m	巴士、雙層巴士、公車、遊覽車、超過九人以上的大客車
大貨車	>12m	非巴士的所有大型車輛: 貨櫃車、聯結車、砂石車、大卡車、大吊車、怪手、推土機、水泥車、油罐車、壓路機、大型消防車
行人	N/A	行人(含其穿戴的衣物、帽子、背包以及撐開的雨傘)

2. 追蹤偵測改進

本計畫將原本計算量較高的追蹤方式改換成計算量較低用簡單邏輯判斷的追蹤方式，以大幅提升整體流程速度，針對停等時遭其他車輛遮擋造成追蹤中斷問題，特別依據物件運動速度設定追蹤等待時間，若物件於停等狀態則容許大的追蹤時間，藉以提升偵測率。

3. 偵測區域邊緣判定

由於慢車道較靠近畫面邊緣，機踏車類經過時其偵測框中心較易通過邊界造成追蹤丟失狀況，針對此問題，本計畫將越界的追蹤物件暫時儲存之後，再將其和區域內偵測框進行比對還原，以改善追蹤丟失狀況。由於偵測框中心與路面邊線存在高度差，本計畫改取從底部算起 1/4 位置做為物件判斷通過偵測線之標準。

4. 佔有率偵測模式改良

目前佔有率偵測模式採偵測框中心(通常為車輛中心)停留在區域內時間比例，但此定義往往造成佔有率偏低，尤其畫面較平時中心易超出區域邊界造成漏算。因此計畫在框內平均增加取樣點，只要任何一點還在區域內即符合佔有定義反映實際情況。本計畫已於 109 年 7 月 24 日完成所有設備上線，並針對「分車道各車種交通流量」、「路口各車種轉向交通量」、「車流密度」、「佔有率」、「停等車輛疏解」、「延滯」各項交

通參數蒐集白天、雨天及夜間等三種情境進行分析，並採用 1-MAPE 做為準確率評估指標。

3.3.1 分車道各車種交通流量

本項目係透過劃設偵測區域(通常以車道為單位,若僅有一車道,則通常畫設至路緣處或畫設至停車格前)及偵測線,當車輛通過偵測線時,即會被偵測與計數,而路邊停車由於其並未移動,故不會被偵測。本項目驗證方式係以人工查看原始影片,並比對 AI 影像偵測設備之調查資料,比對相差之數量,以 1-MAPE 做為準確率評估指標。

本計畫以研究場域中之 AI 影像偵測設備做為驗證說明,本路口之 AI 影像偵測設備同時偵測進入研究路口及離開研究路口,而進入研究路口因為攝影機架設於近端號誌桿燈箱旁,致使該拍攝角度為斜向拍攝,機車將較易被遮蔽,故本計畫同時驗證正向拍攝之畫面做為對照,相關偵測畫面如圖 3.3.1 至 3.3.4 所示,相關偵測成果說明如表 3.3-3。結果顯示,各項偵測成果中,均已有足夠之水準,而正向拍攝之準確度在機車部分有明顯差異,相關偵測車種說明如下表。

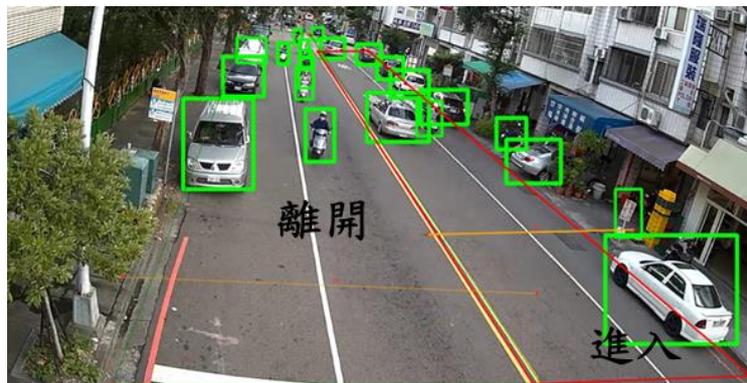


圖 3.3.1 分車道各車種交通流量的進入與離開區域劃分

資料來源：本計畫整理

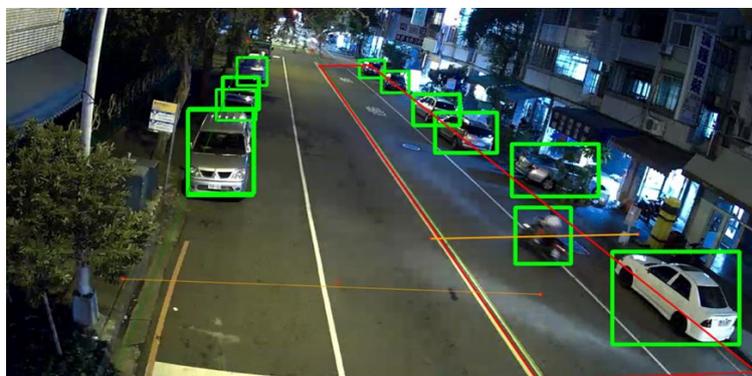


圖 3.3.2 分車道各車種交通流量的偵測畫面

資料來源：本計畫整理



圖 3.3.3 人行道人流量的夜晚偵測畫面

資料來源：本計畫整理



圖 3.3.4 人行道人流量的雨天偵測畫面

資料來源：本計畫整理

表 3.3-3 分車道各車種各情境的交通流量偵測準確度

拍攝角度	方向	車種與行人	白天			雨天			夜間		
			AI (輛)	人工 (輛)	準確率	AI (輛)	人工 (輛)	準確率	AI (輛)	人工 (輛)	準確率
斜向拍攝	進入	機車	1894	2668	71%	716	1611	44%	1032	1440	72%
		小客車	1064	1096	97%	1235	1300	95%	749	739	99%
		中型車	203	176	85%	191	217	88%	58	66	88%
		大客車	13	13	100%	17	19	89%	13	13	100%
		大貨車	27	20	65%	18	14	71%	20	15	67%
正向拍攝	離開	機車	2531	2974	85%	1279	1422	90%	1211	1392	87%
		小客車	1208	1270	95%	1488	1534	97%	873	975	90%
		中型車	278	215	71%	293	218	66%	59	42	60%
		大客車	16	15	93%	31	24	71%	17	16	94%
		大貨車	12	19	63%	5	12	42%	7	5	60%
		行人	17	17	100%	7	13	54%	34	37	92%

資料來源：本計畫整理

3.3.2 路口各車種轉向交通量

本項目係透過劃設偵測區域及偵測線，利用車輛通過兩條偵測線判定其轉向(如圖 3.3.5 及表 3.3-4 所示)，過往均採用一偵測設備偵測一方向之轉向量。本次研究為使可利用更少之偵測設備掌握路口轉向交通量，依據

先前經驗嘗試規劃於單一十字路口採用兩組 AI 影像偵測設備，一個偵測設備各偵測兩方向轉向量規劃方式，並於本次計畫驗證此方式之可行性，相關偵測畫面如圖 3.3.5 所示。偵測成果如表 3.3-5 至 3.3-10 所示（偵測技術精進前），轉向判定邏輯如表 3.3-4 所示，實作過程發現此架構存有下列偵測課題。

1. 偵測線劃設位置太靠近畫面邊緣，直行車速快容易在越線後才被偵測到從而造成遺漏，例如：從十甲東路南行直行，需要偵測到該車輛通過 1 與 3 才會判定直行，但 AI 影像偵測未偵測到該車輛通過 1 號偵測線，致使無法判別，相關說明如圖 3.3.6 所示。
2. 偵測線太過偏向路口，如偵測線 3 號劃設位置太過偏向路口，樂業路西行直行機車常觸碰後消失在畫面造成誤算成 0->3(樂業路西行右轉)，相關說明如圖 3.3.7 所示。
3. 車輛數過多且過多追蹤判別，效能不足致使 AI 影像偵測捨棄部分畫面，致使無法完全記錄，本計畫同時採用較高運算能力 Nvidia TX2 晶片進行相同情境偵測，結果顯示，Nvidia TX2 於轉向交通量偵測結果明顯優於 Nvidia Nano，如表 3.3-11 所示(兩硬體規格比較表如表 3.3-12 所示)，故建議未來若於偵測轉向交通量時，其建議選擇運算能力較高之晶片，以因應大量計算問題。
4. 號誌桿燈箱位置太過靠近路口，本計畫曾利用臨時性設備於同一路口進行偵測，惟其攝影機架設位置距離路口較遠，可拍攝較完整之路口畫面，然而為使設備可適應不同路口環境，且均可於號誌桿燈箱旁安裝，此問題必須克服，但對於 AI 影像偵測而論，路口可拍攝越為完整，則偵測效果越好，圖 3.3.8 呈現不同位置下之拍攝範圍，臨時性設備可有更多車輛進入路口之偵測緩衝區域。

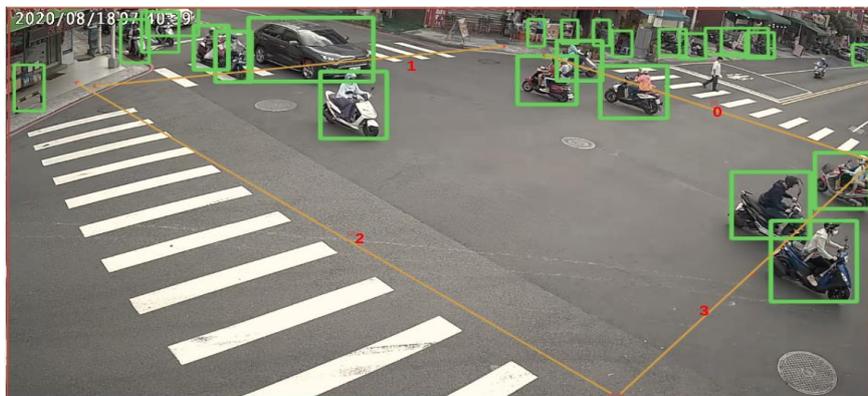


圖 3.3.5 AI 影像測之轉向交通量偵測線

資料來源：本計畫整理

表 3.3-4 轉向交通量判別邏輯(偵測技術精進前)

偵測線判定邏輯	車行方向	轉向判別
0 至 1	樂業路西行	右轉
0 至 2	樂業路西行	直行
0 至 3	樂業路西行	左轉
1 至 2	十甲東路南行	右轉
1 至 3	十甲東路南行	直行
1 至 0	十甲東路南行	左轉
2 至 3	樂業路東行	右轉
2 至 0	樂業路東行	直行
2 至 1	樂業路東行	左轉
3 至 0	十甲東路北行	右轉
3 至 1	十甲東路北行	直行
3 至 2	十甲東路北行	左轉

資料來源：本計畫整理

表 3.3-5 路口各車種轉向交通量偵測(白天)(Nvidia Nano)(技術精進前)

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
樂業往西 右轉	AI	0	45	23	11	0	0
	實際車輛數	1	30	25	9	0	0
	準確率	N/A	50%	92%	78%	N/A	N/A
樂業往西 直行	AI	1	416	308	68	4	2
	實際車輛數	6	890	366	82	4	5
	準確率	17%	47%	84%	83%	N/A	N/A
樂業往西 左轉	AI	0	10	14	8	0	1
	實際車輛數	0	5	15	8	0	1
	準確率	N/A	0%	93%	100%	N/A	N/A
十甲往南 左轉	AI	1	46	31	9	0	1
	實際車輛數	0	43	33	7	0	1
	準確率	N/A	93%	94%	71%	N/A	N/A
十甲往南 右轉	AI	2	55	19	8	0	0
	實際車輛數	1	51	21	6	0	0
	準確率	N/A	92%	90%	67%	N/A	N/A
十甲往南 直行	AI	8	245	142	32	0	4
	實際車輛數	5	440	151	33	0	3
	準確率	40%	56%	94%	97%	N/A	N/A
樂業往東 直行	AI	0	320	251	43	2	3
	實際車輛數	0	630	275	34	2	2
	準確率	N/A	51%	91%	74%	N/A	N/A
樂業往東	AI	1	7	16	4	0	1
	實際車輛數	0	8	17	4	0	1

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
左轉	準確率	N/A	88%	94%	N/A	N/A	N/A
樂業往東 右轉	AI	0	23	9	3	0	1
	實際車輛數	0	11	14	5	0	0
	準確率	N/A	誤差過大/ 無法使用	64%	60%	N/A	-
十甲往北 右轉	AI	1	41	3	0	0	1
	實際車輛數	0	14	29	3	0	1
	準確率	N/A	誤差過大/ 無法使用	10%	N/A	N/A	100%
十甲往北 直行	AI	0	16	49	5	1	2
	實際車輛數	0	308	102	27	1	1
	準確率	N/A	5%	48%	19%	N/A	0%
十甲往北 左轉	AI	0	14	9	2	0	1
	實際車輛數	0	30	10	3	0	1
	準確率	N/A	47%	90%	N/A	N/A	100%

資料來源：本計畫整理

表 3.3-6 路口各車種轉向交通量偵測(白天)(Nvidia Tx2)(偵測技術精進前)

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
樂業往西 右轉	AI	0	40	24	12	0	0
	實際車輛數	1	30	25	9	0	0
	準確率	N/A	67%	96%	67%	N/A	N/A
樂業往西 直行	AI	0	588	305	76	4	2
	實際車輛數	6	890	366	82	4	5
	準確率	0%	66%	83.33%	93%	N/A	40%
樂業往西 左轉	AI	0	11	18	7	0	0
	實際車輛數	0	5	15	8	0	1
	準確率	N/A	誤差過大/ 無法使用	80.0%	88%	N/A	N/A
十甲往南 左轉	AI	0	44	32	8	0	1
	實際車輛數	0	43	33	7	0	1
	準確率	N/A	98%	97%	86%	N/A	N/A
十甲往南 右轉	AI	1	60	19	7	0	1
	實際車輛數	1	51	21	6	0	0
	準確率	N/A	82%	90%	83%	N/A	N/A
十甲往南 直行	AI	5	396	147	35	0	3
	實際車輛數	5	440	151	33	0	3
	準確率	100%	90%	97%	94%	N/A	N/A
樂業往東	AI	0	566	270	40	2	1
	實際車輛數	0	630	275	34	2	2

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
直行	準確率	N/A	90%	98 %	82%	N/A	N/A
樂業往東 左轉	AI	0	7	16	4	0	1
	實際車輛數	0	8	17	4	0	1
	準確率	N/A	88%	94%	100%	N/A	N/A
樂業往東 右轉	AI	0	46	13	4	0	1
	實際車輛數	0	11	14	5	0	0
	準確率	N/A	誤差過大/ 無法使用	93%	80%	N/A	N/A
十甲往北 右轉	AI	1	39	5	0	0	0
	實際車輛數	0	14	29	3	0	1
	準確率	N/A	誤差過大/ 無法使用	17%	N/A	N/A	N/A
十甲往北 直行	AI	0	58	67	12	1	1
	實際車輛數	0	308	102	27	1	1
	準確率	N/A	19%	66%	44%	100%	100 %
十甲往北 左轉	AI	0	21	10	4	0	1
	實際車輛數	0	30	10	3	0	1
	準確率	N/A	70%	100%	N/A	N/A	N/A

資料來源：本計畫整理

表 3.3-7 路口各車種轉向交通量偵測(雨天)(Nvidia Nano)(技術精進前)

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
樂業往西 右轉	AI	0	76	39	4	0	1
	實際車輛數	0	59	34	5	0	0
	準確率	N/A	71%	85%	80%	N/A	N/A
樂業往西 直行	AI	0	160	333	30	4	3
	實際車輛數	2	293	385	53	6	3
	準確率	N/A	55%	86%	57%	67%	N/A
樂業往西 左轉	AI	0	12	26	3	0	0
	實際車輛數	0	4	29	4	0	0
	準確率	N/A	誤差過大/ 無法使用	90%	75%	N/A	N/A
十甲往南 左轉	AI	0	24	22	5	0	2
	實際車輛數	1	19	25	5	0	0
	準確率	N/A	74%	88%	100%	N/A	N/A
十甲往南 右轉	AI	5	23	24	3	1	1
	實際車輛數	0	18	21	2	1	0
	準確率	N/A	72 %	86%	N/A	N/A	N/A
十甲往南	AI	4	157	144	32	0	4
	實際車輛數	3	266	149	35	0	4

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
直行	準確率	N/A	59%	97%	91%	N/A	N/A
樂業往東 直行	AI	0	210	271	55	4	7
	實際車輛數	0	419	281	61	4	5
	準確率	N/A	50%	96%	90%	N/A	60%
樂業往東 左轉	AI	0	6	20	3	0	2
	實際車輛數	0	5	21	5	0	1
	準確率	N/A	80%	95%	60%	N/A	N/A
樂業往東 右轉	AI	0	23	15	3	1	2
	實際車輛數	0	6	18	2	1	1
	準確率	N/A	誤差過大/ 無法使用	83%	N/A	N/A	N/A
十甲往北 右轉	AI	0	37	5	2	0	1
	實際車輛數	0	11	29	11	0	0
	準確率	N/A	誤差過大/ 無法使用	17%	18%	N/A	N/A
十甲往北 直行	AI	0	24	63	2	0	0
	實際車輛數	3	327	186	31	0	1
	準確率	N/A	7%	34%	6%	N/A	N/A
十甲往北 左轉	AI	0	12	13	3	0	0
	實際車輛數	0	16	15	5	0	0
	準確率	N/A	75%	87%	60%	N/A	N/A

資料來源：本計畫整理

表 3.3-8 路口各車種轉向交通量偵測(雨天)(Nvidia Tx2)(偵測技術精進前)

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
樂業往西 右轉	AI	0	78	36	7	0	1
	實際車輛數	0	59	34	5	0	0
	準確率	N/A	68%	94%	60%	N/A	N/A
樂業往西 直行	AI	0	283	338	28	6	4
	實際車輛數	2	293	385	53	6	3
	準確率	N/A	97%	88%	53%	100%	N/A
樂業往西 左轉	AI	0	8	22	5	0	0
	實際車輛數	0	4	29	4	0	0
	準確率	N/A	N/A	76%	N/A	N/A	N/A
十甲往南 左轉	AI	0	20	20	6	0	1
	實際車輛數	1	19	25	5	0	0
	準確率	N/A	95%	80%	80%	N/A	N/A
十甲往南 右轉	AI	2	25	23	6	1	1
	實際車輛數	0	18	21	2	1	0
	準確率	N/A	61%	90%	-100%	N/A	N/A

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
十甲往南 直行	AI	2	230	147	36	0	5
	實際車輛數	3	266	149	35	0	4
	準確率	N/A	86%	99%	97%	N/A	N/A
樂業往東 直行	AI	0	346	275	52	4	9
	實際車輛數	0	419	281	61	4	5
	準確率	N/A	83%	98%	85%	N/A	N/A
樂業往東 左轉	AI	1	9	18	4	0	2
	實際車輛數	0	5	21	5	0	1
	準確率	N/A	20%	86%	80%	N/A	N/A
樂業往東 右轉	AI	0	40	15	3	1	2
	實際車輛數	0	6	18	2	1	1
	準確率	N/A	誤差過大/ 無法使用	83%	N/A	N/A	N/A
十甲往北 右轉	AI	0	48	14	4	0	0
	實際車輛數	0	11	29	11	0	0
	準確率	N/A	誤差過大/ 無法使用	48%	36%	N/A	N/A
十甲往北 直行	AI	0	61	104	13	1	0
	實際車輛數	3	327	186	31	0	1
	準確率	N/A	19%	56%	42%	N/A	N/A
十甲往北 左轉	AI	0	16	12	4	0	0
	實際車輛數	0	16	15	5	0	0
	準確率	N/A	100%	80%	80%	N/A	N/A

資料來源：本計畫整理

表 3.3-9 路口各車種轉向交通量偵測(夜間)(Nvidia Nano)(技術精進前)

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
樂業往西 右轉	AI	1	36	41	4	0	0
	實際車輛數	2	30	41	4	0	0
	準確率	N/A	80%	100%	N/A	N/A	N/A
樂業往西 直行	AI	0	228	325	18	2	0
	實際車輛數	3	396	355	28	4	0
	準確率	N/A	58%	92%	64%	N/A	N/A
樂業往西 左轉	AI	0	8	16	2	0	0
	實際車輛數	0	5	14	3	0	0
	準確率	N/A	40%	86%	N/A	N/A	N/A
十甲往南 左轉	AI	0	34	17	3	0	0
	實際車輛數	0	26	20	2	0	0
	準確率	N/A	69%	85%	N/A	N/A	N/A
	AI	2	51	15	2	0	0

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
十甲往南 右轉	實際車輛數	0	49	13	1	0	0
	準確率	N/A	96%	85%	N/A	N/A	N/A
十甲往南 直行	AI	8	148	112	7	0	2
	實際車輛數	2	253	118	9	0	1
	準確率	N/A	59%	95%	78%	N/A	N/A
樂業往東 直行	AI	1	359	252	19	1	1
	實際車輛數	3	549	261	25	1	0
	準確率	N/A	65 %	97%	76%	N/A	N/A
樂業往東 左轉	AI	0	9	19	0	0	1
	實際車輛數	0	6	19	0	0	1
	準確率	N/A	50%	100%	N/A	N/A	100%
樂業往東 右轉	AI	2	13	13	2	0	0
	實際車輛數	0	6	17	1	0	0
	準確率	N/A	誤差過大/ 無法使用	76 %	N/A	N/A	N/A
十甲往北 右轉	AI	0	20	7	0	0	0
	實際車輛數	1	20	23	4	0	0
	準確率	N/A	100%	30%	N/A	N/A	N/A
十甲往北 直行	AI	0	29	70	3	0	1
	實際車輛數	5	292	120	4	0	0
	準確率	0 %	10%	58%	N/A	N/A	N/A
十甲往北 左轉	AI	0	12	15	2	0	0
	實際車輛數	0	18	15	0	0	0
	準確率	N/A	67%	100%	N/A	N/A	N/A

資料來源：本計畫整理

表 3.3-10 路口各車種轉向交通量偵測(夜間)(Nvidia Tx2)(偵測技術精進前)

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
樂業往西 右轉	AI	0	33	40	4	0	0
	實際車輛數	2	30	41	4	0	0
	準確率	N/A	90%	98%	N/A	N/A	N/A
樂業往西 直行	AI	0	310	337	21	4	1
	實際車輛數	3	396	355	28	4	0
	準確率	N/A	78%	95%	75 %	N/A	N/A
樂業往西 左轉	AI	1	11	14	2	0	0
	實際車輛數	0	5	14	3	0	0
	準確率	N/A	誤差過大/ 無法使用	100%	N/A	N/A	N/A
十甲往南	AI	0	30	17	4	0	0
	實際車輛數	0	26	20	2	0	0

方向	項目	腳踏車	機車	小客車	中型車	大客車	大貨車
左轉	準確率	N/A	85%	85%	N/A	N/A	N/A
十甲往南 右轉	AI	0	51	15	2	0	1
	實際車輛數	0	49	13	1	0	0
	準確率	N/A	96%	85%	N/A	N/A	N/A
十甲往南 直行	AI	1	213	118	11	0	3
	實際車輛數	2	253	118	9	0	1
	準確率	N/A	84%	100%	78%	N/A	N/A
樂業往東 直行	AI	2	506	258	24	1	1
	實際車輛數	3	549	261	25	1	0
	準確率	N/A	92%	99%	96%	100%	N/A
樂業往東 左轉	AI	0	6	20	0	0	1
	實際車輛數	0	6	19	0	0	1
	準確率	N/A	100%	95%	N/A	N/A	N/A
樂業往東 右轉	AI	2	22	15	2	0	0
	實際車輛數	0	6	17	1	0	0
	準確率	N/A	誤差過大/ 無法使用	88%	N/A	N/A	N/A
十甲往北 右轉	AI	0	26	8	0	0	0
	實際車輛數	1	20	23	4	0	0
	準確率	N/A	70%	35%	N/A	N/A	N/A
十甲往北 直行	AI	0	101	101	5	0	1
	實際車輛數	5	292	120	4	0	0
	準確率	0%	35%	84%	N/A	N/A	N/A
十甲往北 左轉	AI	0	18	15	2	0	0
	實際車輛數	0	18	15	0	0	0
	準確率	N/A	100%	100%	N/A	N/A	N/A

資料來源：本計畫整理

表 3.3-11 不同硬體規格之直行車流偵測率比較

方向	項目	Nvidia Nano	Nvidia Tx2
樂業往西 直行	AI	92	126
	實際車輛數	188	188
	準確率	49%	67%
十甲往南 直行	AI	76	124
	實際車輛數	141	141
	準確率	54%	88%
樂業往東 直行	AI	102	211
	實際車輛數	232	232
	準確率	44%	91%

資料來源：本計畫整理

表 3.3-12 不同型號之主要硬體比較

項目/型號	TX2	Nano
CPU	Nvidia Jetson Tegra X2	Nvidia Jetson Nano
Memory	8GB LPDDR4	4GB LPDDR4
eMMC	32GB eMMC	16GB eMMC

資料來源：本計畫整理

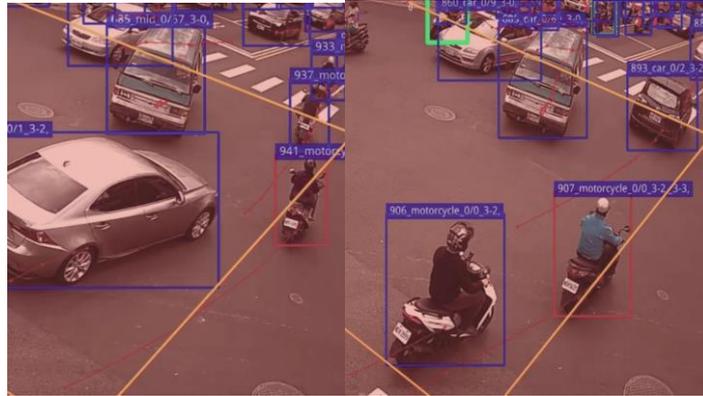


圖 3.3.6 樂業路西行機車被誤判為右轉

資料來源：本計畫整理

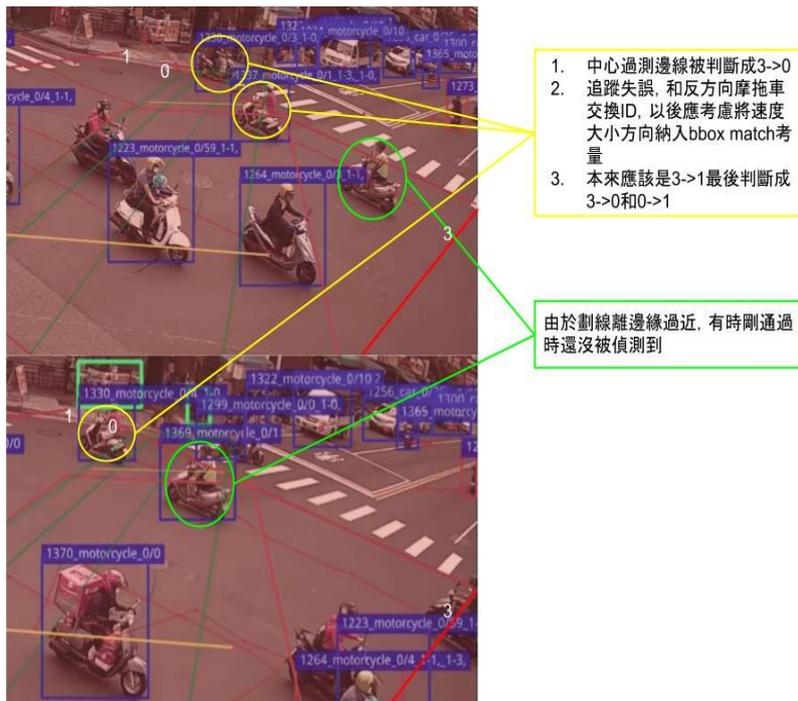


圖 3.3.7 轉向量偵測異常分析

資料來源：本計畫整理

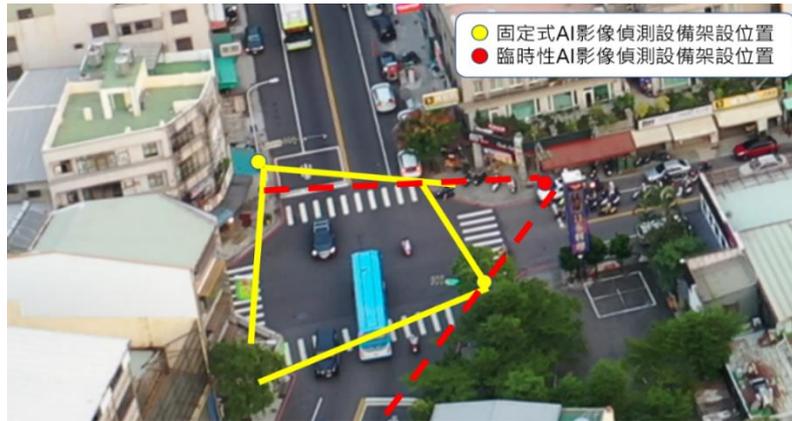


圖 3.3.8 固定式與臨時性拍攝範圍比較

資料來源：本計畫整理

為改善上述偵測問題，嘗試利用邏輯之改變來突破硬體限制並提升準確率，相關說明如下。調整後之偵測線布設如圖 3.3.9 所示，轉向交通輛判別邏輯如表 3.3-13 所示，同時本計畫針對主要車種進行準確率比較，如表 3.3-14 所示，結果顯示新偵測線布設邏輯可提升偵測準確率。

1. 將直行車判定線和轉彎車輛判定線分開劃設(增設直行車判斷線 4、5、6、7，轉彎判斷線維持原 0、1、2、3 但 3 號線位置方向有略為調整)：轉彎車輛車速較慢，靠近邊緣也不會有太多遺漏；直行車速較快，因此將劃線靠近中央減少遺漏，且由於轉彎車就算誤觸直行線後會再碰觸下一條轉彎判定線，按照現有程式邏輯還是會判斷成轉彎而非直行。
2. 修正原 0 號線方向使其和直行車方向一致。
3. 增設偵測線 8 號，並將原 0->3 和 3->0 替換成 0->8 和 8->0 以避免遺漏；原 2->3 和 3->2 不變，因此不會將直行車輛納入造成誤算。



圖 3.3.9 轉向交通量修正偵測邏輯

資料來源：本計畫整理

表 3.3-13 不同偵測線判定邏輯之轉向交通量判別邏輯比較表

原始偵測線判定邏輯	改良偵測線判定邏輯	車行方向	轉向
0 至 1	0 至 1	樂業路西行	右轉
0 至 2	4 至 6	樂業路西行	直行
0 至 3	0 至 8	樂業路西行	左轉
1 至 2	1 至 2	十甲東路南行	右轉
1 至 3	5 至 7	十甲東路南行	直行
1 至 0	1 至 0	十甲東路南行	左轉
2 至 3	2 至 3	樂業路東行	右轉
2 至 0	6 至 4	樂業路東行	直行
2 至 1	2 至 1	樂業路東行	左轉
3 至 0	8 至 0	十甲東路北行	右轉
3 至 1	7 至 5	十甲東路北行	直行
3 至 2	3 至 2	十甲東路北行	左轉

資料來源：本計畫整理

表 3.3-14 不同偵測線判定邏輯之準確率比較

情境	車行方向	項目	原始偵測線判定邏輯			改良偵測線判定邏輯		
			小客車	中型車	機車	小客車	中型車	機車
白天	樂業往西 直行	AI	51	10	122	58	9	157
		實際車輛數	68	16	188	68	16	188
		準確率	75.00%	62.50%	64.89%	85.29%	56.25%	83.51%
	樂業往東 直行	AI	50	11	185	52	11	203
		實際車輛數	60	10	232	60	10	232
		準確率	83.33%	90.00%	79.74%	86.67%	90.00%	87.50%
	十甲往南 直行	AI	30	10	117	31	10	141
		實際車輛數	32	8	141	32	8	141
		準確率	93.75%	75.00%	82.98%	96.88%	75.00%	100.00%
	十甲往北 直行	AI	16	3	8	22	3	51
		實際車輛數	24	4	60	24	4	60
		準確率	66.67%	N/A	13.33%	91.67%	N/A	85.00%
雨天	樂業往西 直行	AI	57	5	21	62	5	25
		實際車輛數	75	6	27	75	6	27
		準確率	76.00%	83.33%	77.78%	82.67%	83.33%	92.59%
	樂業往東 直行	AI	48	6	39	49	7	38
		實際車輛數	56	6	47	56	6	47
		準確率	85.71%	100.00%	82.98%	87.50%	83.33%	80.85%
	十甲往南 直行	AI	22	7	39	23	7	41
		實際車輛數	21	8	43	21	8	43
		準確率	95.24%	87.50%	90.70%	90.48%	87.50%	95.35%
	十甲往北 直行	AI	22	0	13	27	4	35
		實際車輛數	30	4	35	30	4	35

情境	車行方向	項目	原始偵測線判定邏輯			改良偵測線判定邏輯		
			小客車	中型車	機車	小客車	中型車	機車
夜間	樂業往西 直行	AI	65	1	66	66	1	76
		實際車輛數	72	5	91	72	5	91
		準確率	90.28%	20.00%	72.53%	91.67%	20.00%	83.52%
	樂業往東 直行	AI	56	3	97	56	4	101
		實際車輛數	60	5	115	60	5	115
		準確率	93.33%	N/A	84.35%	93.33%	80.00%	87.83%
	十甲往南 直行	AI	31	3	37	32	3	44
		實際車輛數	31	2	44	31	2	44
		準確率	100.00%	N/A	84.09%	96.77%	N/A	100.00%
	十甲往北 直行	AI	23	0	20	24	0	55
		實際車輛數	27	0	55	27	0	55
		準確率	85.19%	N/A	36.36%	88.89%	N/A	100.00%
白天	十甲往南 右轉	AI	5	1	9	5	1	8
		實際車輛數	7	0	9	7	0	9
		準確率	71.43%	N/A	100.00%	71.43%	N/A	88.89%
	十甲往南 左轉	AI	6	1	13	6	1	10
		實際車輛數	8	1	13	8	1	13
		準確率	75.00%	N/A	100.00%	75.00%	N/A	76.92%
	樂業往東 左轉	AI	3	0	0	3	0	0
		實際車輛數	3	0	0	3	0	0
		準確率	N/A	N/A	N/A	N/A	N/A	N/A
	樂業往西 右轉	AI	0	5	6	0	5	6
		實際車輛數	1	4	8	1	4	8
		準確率	N/A	N/A	75.00%	N/A	N/A	75.00%
	樂業往西 左轉	AI	1	1	1	1	1	3
		實際車輛數	1	1	0	1	1	0
		準確率	N/A	N/A	N/A	N/A	N/A	N/A
	十甲往北 左轉	AI	0	0	4	0	0	4
		實際車輛數	0	0	6	0	0	6
		準確率	N/A	N/A	66.67%	N/A	N/A	66.67%
十甲往北 右轉	AI	0	0	5	0	0	2	
	實際車輛數	9	0	3	9	0	3	
	準確率	0.00%	N/A	N/A	0.00%	N/A	N/A	
樂業往東 右轉	AI	0	0	15	0	0	0	
	實際車輛數	1	1	1	1	1	1	
	準確率	N/A	N/A	N/A	N/A	N/A	N/A	
雨天	十甲往南 右轉	AI	5	0	2	5	0	1
		實際車輛數	5	0	2	5	0	2
		準確率	100.00%	N/A	N/A	100.00%	N/A	N/A
十甲往南	AI	3	2	2	3	3	2	

情境	車行方向	項目	原始偵測線判定邏輯			改良偵測線判定邏輯		
			小客車	中型車	機車	小客車	中型車	機車
日間	左轉	實際車輛數	5	2	2	5	2	2
		準確率	60.00%	N/A	100.00%	60.00%	N/A	N/A
		AI	2	1	1	2	1	1
	樂業往東左轉	實際車輛數	4	1	1	4	1	1
		準確率	N/A	N/A	N/A	N/A	N/A	N/A
		AI	8	1	3	7	2	2
	樂業往西右轉	實際車輛數	7	2	4	7	2	4
		準確率	85.71%	N/A	N/A	100.00%	N/A	N/A
		AI	4	1	0	4	1	0
	樂業往西左轉	實際車輛數	6	1	0	6	1	0
		準確率	66.67%	N/A	N/A	66.67%	N/A	N/A
		AI	3	0	1	3	0	0
	十甲往北左轉	實際車輛數	4	0	0	4	0	0
		準確率	N/A	N/A	N/A	N/A	N/A	N/A
		AI	5	0	3	2	1	1
	十甲往北右轉	實際車輛數	5	2	4	5	2	4
		準確率	100.00%	N/A	N/A	40.00%	N/A	N/A
		AI	2	1	1	0	0	0
樂業往東右轉	實際車輛數	5	0	0	5	0	0	
	準確率	40.00%	N/A	N/A	0.00%	N/A	N/A	
	AI	4	0	10	4	0	10	
十甲往南右轉	實際車輛數	3	0	9	3	0	9	
	準確率	N/A	N/A	88.89%	N/A	N/A	88.89%	
	AI	5	3	4	7	2	4	
十甲往南左轉	實際車輛數	8	1	7	8	1	7	
	準確率	62.50%	N/A	57.14%	87.50%	N/A	57.14%	
	AI	2	0	2	2	0	1	
樂業往東左轉	實際車輛數	2	0	1	2	0	1	
	準確率	N/A	N/A	N/A	N/A	N/A	N/A	
	AI	6	1	12	6	1	8	
樂業往西右轉	實際車輛數	7	1	8	7	1	8	
	準確率	85.71%	N/A	50.00%	85.71%	N/A	100.00%	
	AI	2	1	3	2	1	1	
樂業往西左轉	實際車輛數	3	1	3	3	1	3	
	準確率	N/A	N/A	N/A	N/A	N/A	N/A	
	AI	3	1	1	3	0	1	
十甲往北左轉	實際車輛數	3	0	1	3	0	1	
	準確率	N/A	N/A	N/A	N/A	N/A	N/A	
	AI	1	0	4	0	0	2	
十甲往北右轉	實際車輛數	4	1	4	4	1	4	

情境	車行方向	項目	原始偵測線判定邏輯			改良偵測線判定邏輯		
			小客車	中型車	機車	小客車	中型車	機車
			準確率	N/A	N/A	N/A	N/A	N/A
樂業往東 右轉		AI	3	0	2	2	0	0
		實際車輛數	3	0	0	3	0	0
		準確率	N/A	N/A	N/A	N/A	N/A	N/A

3.3.3 佔有率

本項目係透過劃設偵測區域方式，偵測區域包含車輛偵測區(紅色區域)與佔有率偵測區(兩條偵測線所夾之區域)，AI 影像偵測將會偵測區域內被車輛占有之時間，為時間占用率，並可自行設定統計間隔，相關偵測畫面如圖 3.3.10 所示，偵測成果分析如表 3.3-15 示。本計畫佔有率曾嘗試採用只看偵測框中點是否在佔有率計算範圍內，但此架構造成數值嚴重低估，尤其是當大型車停等時車頭車尾長時間佔據狀況，故最終改採偵測框中平均取樣多點做為判斷標準，且由於初期偵測範圍之 AI 辨別之緩衝區域過短，最終分析結果建議應有足夠之偵測前緩衝區域，相關占有率計算與偵測框示意如圖 3.3.11 所示，前後成果說明如表 3.3-16 所示。



圖 3.3.10 佔有率偵測(右方區域)

資料來源：本計畫整理

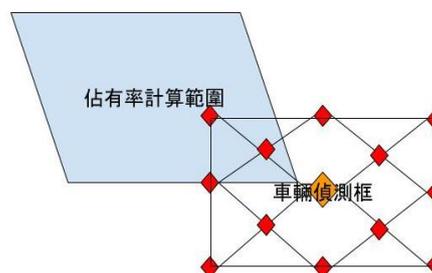


圖 3.3.11 佔有率偵測邏輯

資料來源：本計畫整理

表 3.3-15 佔有率前後偵測邏輯比較

說明	示意圖
偵測前之緩衝區域過短，且採車輛中間點判斷之方式，車輛剛進入偵測區域並未被計算。	

延長偵測前之緩衝區域，改為偵測框中平均取樣，當車輛進入佔有率偵測範圍時，可正常偵測。

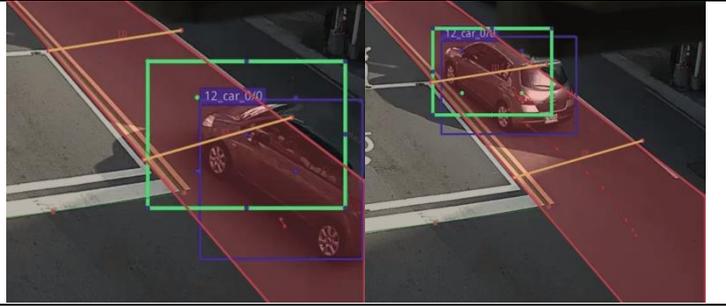


表 3.3-16 佔有率偵測準確度

序號	項目	白天	雨天	夜間
1	AI	0.245	0.119	0.234
	實際佔有率	0.277	0.118	0.198
	準確率	88.55%	98.95%	81.87%
2	AI	0.194	0.318	0.161
	實際佔有率	0.181	0.258	0.139
	準確率	92.64%	76.61%	83.75%
3	AI	0.2	0.09	0.209
	實際佔有率	0.207	0.107	0.239
	準確率	96.70%	84.44%	87.54%
4	AI	0.214	0.33	0.277
	實際佔有率	0.25	0.293	0.24
	準確率	85.74%	87.24%	84.52%
5	AI	1.205	0.05	0.077
	實際佔有率	1.137	0.098	0.269
	準確率	94.06%	50.95%	28.63%
6	AI	0.391	0.315	0.218
	實際佔有率	0.426	0.283	0.16
	準確率	91.79%	88.62%	63.98%
7	AI	0.834	0.328	0.232
	實際佔有率	0.599	0.362	0.112
	準確率	60.88%	90.55%	-7.17%
8	AI	0.329	0.216	0.245
	實際佔有率	0.314	0.144	0.186
	準確率	95.24%	50.36%	68.59%
9	AI	0.669	0.235	0.111
	實際佔有率	0.51	0.251	0.336
	準確率	68.75%	93.51%	33.03%
10	AI	0.197	0.183	0.292
	實際佔有率	0.194	0.177	0.246
	準確率	98.44%	96.79%	81.47%

資料來源：本計畫整理

3.3.4 延滯

本項目係透過劃設偵測區域方式，AI 偵測設備將會偵測進入偵測區域

內且車速接近停止之車輛其停等時間，直到該車輛開始加速，由於其偵測方式車輛停車亦會被記錄，故偵測區域畫設應避免劃設至停車格或常有車輛停放之區域。本項目驗證方式，係比對原始影片，以人工方式判斷每一部車輛其實際從速度減速至接近停止至再加速時間是否一致。

傳統延滯調查通常以人工方式，每 15 秒計算停等車輛數，概算所計數之車輛總停等時間；本計畫採用 AI 影像偵測設備，其可針對每一部車輛偵測其速度，判斷車輛是否停等，邏輯為：偵測車輛準備靜止直到再加速之間隔時間，故其計算比傳統人工調查方式可更全盤掌握車輛延滯之時間，亦較人工調查方式精準，且並非採取固定間隔紀錄，而是當有車輛準備停等至離開時，均會有一筆該車輛之紀錄，對於微觀車輛績效評估更具代表性，相關偵測畫面如圖 3.3.12 所示。

延滯偵測準確率說明如表 3.3-17 所示，由於影像偵測設備其受限於攝影機拍攝之有效距離約 30 公尺，又以小客車停車格長度為 5.5 公尺，概估可等候之車輛數約為 5~6 輛車，故其可有效偵測之等候線長度約為 5~6 輛車。由於影像設備受限於車輛若遭遮的，則其判別率將大幅降低，故以下探討之準確率將排除車輛遭遮蔽之情況，經驗證(白天樣本為 109 年 8 月 12 日 7:30-7:40，夜間樣本為 19:00-19:10，雨天樣本為 17:30-17:40)，於白天情境在等候線長度在 6 輛車以內時(含 6 輛車)，準確率大於 9 成，於超過 6 輛車時，則準確率大幅降低至 6 成以下；於夜間情境在等候線長度在 5 輛車以內時(含 5 臺車)，準確率大於 9 成，於 6 輛車時則降低為 7 成，於超過 7 輛車時，則準確率大幅降低至 4 成以下；於雨天情境在等候線長度在 3 輛車以內時(含 3 輛車)，準確率大於 9 成，於 4 輛車時則降低為 8 成，於超過 5 輛車時，則準確率大幅降低至 5 成以下，此實證與攝影機硬體限制相呼應。

由於延滯之掌握勢必得掌握車隊末端方能有效做為評估指標，故建議未來若採用影像式偵測設備偵測停等延滯，建議可於中間路段加裝設備，透過累計方式掌握整條路段之延滯，抑或是評估僅裝設於末端，掌握末端之延滯。



圖 3.3.12 延滯偵測畫面

資料來源：本計畫整理

表 3.3-17 延滯偵測準確率

情境	車輛 停等位置	總 樣本數	準確率		遭遮蔽而誤 判之比例		無法正常判定 之比例	
白天	第 1 輛	46	46	100%	0	0%	0	0%
	第 2 輛	44	39	89%	5	11%	0	0%
	第 3 輛	42	36	86%	6	14%	0	0%
	第 4 輛	31	27	87%	4	13%	0	0%
	第 5 輛	29	19	66%	10	34%	0	0%
	第 6 輛	22	12	55%	9	41%	1	5%
	第 7 輛	15	2	13%	6	40%	7	47%
	第 8 輛	10	3	30%	3	30%	4	40%
	第 9 輛	9	2	22%	2	22%	5	56%
	第 10 輛	5	2	40%	0	0%	3	60%
	第 11 輛	5	2	40%	0	0%	3	60%
夜間	第 1 輛	29	29	100%	0	0%	0	0%
	第 2 輛	26	25	96%	1	4%	0	0%
	第 3 輛	20	19	95%	1	5%	0	0%
	第 4 輛	15	13	87%	2	13%	0	0%
	第 5 輛	12	8	67%	3	25%	1	8%
	第 6 輛	7	4	57%	1	14%	2	29%
	第 7 輛	3	1	33%	0	0%	2	67%
	第 8 輛	1	0	0%	0	0%	1	100%
雨天	第 1 輛	45	39	87%	3	7%	3	7%
	第 2 輛	39	33	85%	4	10%	2	5%
	第 3 輛	34	30	88%	2	6%	2	6%
	第 4 輛	23	14	61%	5	22%	4	17%

情境	車輛 停等位置	總 樣本數	準確率		遭遮蔽而誤 判之比例		無法正常判定 之比例	
	第 5 輛	16	5	31%	3	19%	8	50%
	第 6 輛	10	3	30%	1	10%	6	60%
	第 7 輛	6	0	0%	0	0%	6	100%
	第 8 輛	4	2	50%	0	0%	2	50%
	第 9 輛	2	1	50%	0	0%	1	50%
	第 10 輛	1	0	0%	0	0%	1	100%

資料來源：本計畫整理

3.3.7 綜合探討

本計畫使用在各種車流參數偵測上，透過實測來評估 Nvidia 不同運算晶片較高階的 Tx2 與基本款的 Nano 晶片，來評估運算效能與辨識成果。同時經過各個不同場景的不同參數測試，發現在實務運作上有些情形會影響人工智慧交通參數資料蒐集之問題，茲就主要問題點闡述如後，並將整體精進過程彙整如表 3.3-18。

1. 攝影機角度過低：若攝影機角度太低，照射較遠處角度會過平而產生物件互相遮擋情況，對模型物件偵測及追蹤造成困難，延滯偵測之偵測設備架設高度於現有號誌桿燈旁位置，於偵測到第六臺車時，準確率大幅下降，此可藉由提升高度，或是於路段中間加裝設備，偵測第六臺車以後之車輛，以符合實際交通資料蒐集之需求。
2. 偵測線劃設太靠近畫面邊緣：若偵測區域靠近畫面邊緣，許多車輛(尤其速度較快的車種)通過邊線後才被模型偵測到，造成計算轉向量時的遺漏，故偵測線宜距離畫面邊緣一段距離，且針對直行與左右轉分別劃設不同之偵測線。
3. 佔有率偵測邏輯：本計畫曾嘗試使用車輛中心點判別佔有率，以期望降低系統資源，惟經測試結果與實際佔有率有大幅落差，故目前改採偵測框中平均取樣多點做為判斷標準，平均佔有率準確率最好可達 97%，且亦可減低硬體使用資源。
4. 硬體效能：需要進行大量車輛追蹤的交通參數(如交通量、轉向量)，若硬體效能不夠好，將造成程式運行時需捨棄連續畫面，使追蹤時偵測框配對困難，因此建議若功能需要即時追蹤，如交通量和轉向量則宜使用 Nvidia Tx2 運算晶片，尤其於車輛多或雨天環境，若 AI 影像偵測可掌握完整之車輛移動軌跡，則受到車輛遮蔽而短暫中斷或雨水遮蔽而短

暫中斷仍可有效記錄；反之在較不需即時反應的部分如交通統計、滯留、淹水偵測等功能可用 Nvidai Nano 運算晶片以節省成本。

5. 雨天影響：於雨天時，倘若雨水或污漬遮擋鏡頭，則小型車（小客車、機車）偵測影響甚大，相關偵測畫面如圖 3.3.13 及 3.3.14 所示，為提升因雨水或污漬遮蔽鏡頭所造成無法有效辨識之影響，建議未來可朝攝影機鏡面處理著手。



圖 3.3.13 雨水遮蔽主要車道與鏡頭

資料來源：本計畫整理



圖 3.3.14 雨水遮蔽鏡頭

資料來源：本計畫整理

6. 正面拍攝部分車種誤判現象：本計畫發現在正面拍攝大貨車、小客車與中型車容易有相互混淆情形，進一步探討發現，大貨車在距離鏡頭較遠時或只露出正面車頭時較容易與中型車混淆；中型車離鏡頭較近特別是車頭正對鏡頭時有可能被辨識成大型車，而大貨車和大客車雖然尺寸較接近但外型還是有一定差異，大客車幾何形狀較難與小客車、小貨車混淆，但在斜向拍攝之情況下，相關問題大幅縮減，未來亦將持續增加訓練資料，以利減少判別錯誤之情形。

表 3.3-18 AI 影像偵測精進過程

序號	遭遇問題	過程說明
1	部分車種容易辨識錯誤，舉凡大貨車誤判為小貨車、小	由於大貨車、小貨車、中型車及小客車，車身若僅露出車頭，其外型相近，易造成混淆，本計畫新增諸多不同案場圖片，特別是過往較為缺少的大貨車及腳踏車樣本，且修正過

序號	遭遇問題	過程說明
	客車，且不同情境易有誤判問題。	往訓練集中的錯誤標註，提升 SSD 模型，相關模型精進說明如表 3.3-1。
2	佔有率偵測所需效能較高，Nvidia Nano 運算晶片效能吃緊。	<p>(1) 由於本計畫使用之偵測設備硬體規格為 Nvidia Nano 運算晶片，其運算效能有相關限制，故本計畫於初期期望降低運算效能，使設備較為穩定，故將物件偵測調整為中心點偵測，此方式雖降低運算資源，但同時也使準確率大幅降低。</p> <p>(2) 為兼顧佔有率偵測之準確率，改採偵測框中平均取樣多點做為判斷標準，平均佔有率準確率最好可達 97%，且亦可減低硬體使用資源。</p>
3	轉向交通量準確率較低	<p>(1) 本計畫嘗試使用 Nvidia Nano 運算晶片偵測設備偵測兩流向之轉向交通量，於設備架設完畢初期，準確率十分低。</p> <p>(2) 經觀察，諸多車輛於通過第一條偵測線時並未被偵測，致使準確率偏低，本計畫嘗試調整諸多偵測範圍，在拍攝範圍涵蓋較多路口之情況下，且在車輛進入路口前有較長之緩衝區時，可有效提升準確率，但各車種、各流向轉向之準確率均未達良好水準。</p> <p>(3) 經觀察，若單一路口僅劃設四條偵測線判別轉向，則直行車輛易被判斷為右轉(如圖 3.3.6)，故本計畫將直行與左右轉判別分別劃設(如圖 3.3.9)，已可有效提升。</p> <p>(4) 經觀察，轉向偵測其所需之硬體效能較高，在效能不足之情況下，偵測設備並沒辦法針對所有畫面均進行判別，故本計畫嘗試使用較高效能之 Nvidia Tx2 運算晶片進行相同影像之運算，tx2 之準確率明顯提升。</p> <p>(5) 建議轉向交通量偵測應分別針對左右轉與直行化社不同偵測線，且應密切關注硬體運算效能。</p>

本計畫應用 AI 於交通資料蒐集，普遍於各項交通參數已有不錯結果，相關模式偵測邏輯彙整如表 3.3-21，而經過本計畫探討，各項偵測項目普遍需要有較充裕之偵測前置空間，以使車輛到達辨識區域能有較好的效果，

說明如後。

1. 分車道各車種交通流量：本計畫於設備架設後即幾無調整相關設定，機車於各情境準確率達 72% 以上之合理效果，小客車則達 90% 以上之優良成果，且藉由追蹤偵測方式，在鏡頭稍微汙損或是車輛稍被遮蔽情況下，仍可計數，對於車流量調查應已有足夠之可靠度與方便性。
2. 路口各車種轉向交通量：本計畫嘗試使用兩偵測設備掌握路口四方向之轉向交通量，經過多種方式之嘗試，發現轉向偵測之攝影機架設位置應盡可能離路口較遠，以使 AI 能有較充裕之時間辨別車輛，掌握其轉向；此外，車輛在直行與左右轉行跡軌跡特性嚴重影響偵測之準確率，無法單純針對路口以四個偵測線來做為偵測邏輯，故最終於偵測線布設依據直行與左右轉分別劃設數條偵測線(如圖 3.3.9 所示)其成果較為理想，但此也需要較高之硬體效能方能有更好的成果。
3. 佔有率：本計畫佔有率曾為考量降低硬體需求，嘗試採用只看偵測框中點是否在佔有率計算範圍內，但此架構造成數值嚴重低估，尤其是當大型車停等時車頭車尾長時間佔據狀況，故最終改採偵測框中平均取樣多點做為判斷標準，以達到減少硬體需求並同時兼顧佔有率偵測。
4. 延滯：本計畫所採用之攝影機拍攝有效距離約為 30 公尺，又以小客車停車格長度為 5.5 公尺，故其可有效偵測之等候線長度約為 5~6 台車，經驗證，於白天情境之臨界偵測車隊數約在 6 台車(準確率 9 成以上)，超過 6 台車，則準確率將降低至 6 成以下；夜間則約為 5 台車；雨天則約為 3 台車，此實證與攝影機硬體限制相呼應，故若需掌握完整路段之停等延滯，應於中間路段增設設備，或更換解析度較好之望遠鏡頭。

表 3.3-19 各車流參數與偵測邏輯彙整

車流參數	偵測邏輯
分車道各車種交通流量	劃設偵測區域與偵測線，車輛於進入偵測區域後，開始辨識其車種，於通過偵測線時進行計數。
路口各車種轉向交通量	劃設偵測區域與偵測線，車輛於進入偵測區域後，開始辨識其車種，並依據通過任兩條偵測線判別其轉向，使用者可自行指定通過任兩條偵測線之判別轉向資訊。
佔有率	劃設偵測區域與偵測線，並可設定欲納入占有率計算之車種(舉凡可僅偵測小客車)，車輛於進入偵測區域後，開始辨識其車種，並計算其通過兩條偵測線之時間。

車流參數	偵測邏輯
延滯	劃設偵測區域，車輛於進入偵測區域且接近停等時，開始計算其停等時間，直至車輛加速離開。

3.4 應用 AI 影像辨識技術進行交通控制之後續探討

隨著偵測技術演進，透過 AI 影像辨識可偵測出傳統資料蒐集方式無法蒐集之交通特性資料，像是起訖、延滯或是其他微觀資訊，且在即時蒐取資料後，可利用這些資訊提供號誌控制不同面向之策略應用。

透過車牌辨識之方式，偵測器可抓取車輛之起訖位置及時間，藉此在號誌控制之策略上，可以判別路網中各個路徑之壅塞狀況，以調整路網號誌快速紓解壅塞路段；停等車隊偵測也可用於紓解路段車流；延滯時間做為旅行時間之替代指標，可以用於評估路口及路段之運行績效，當延滯時間逐漸升高時，表示車流無法有效流動，當前的號誌控制策略需做調整，故延滯時間可做為即時評估路況之指標，以提前進行改善避免塞車發生。在多時相之路口中，轉向量常用以做為計算各時相時比之資訊，然而車流到達具有隨機性，事前求解之時制未必能符合當前的車流環境，若有即時之轉向量資料則可以對於路口時制進行微調，且轉向量資料也可用於計算相鄰路口流入之車流量，故可控制相鄰路口之流入量以避免大量車輛瞬間進入，導致發生路口過飽和之情形。

將上述參數可透過加權計入 AI 強化學習號誌控制的獎勵函數或目標式之設計中，以最佳化車流之流動紓解在影像辨識的技術上，由於拍攝道路路口中各項狀況，故許多微觀之交通特性資料皆可以即時獲得，像是即時車輛位置、即時車速等，這些詳細的資訊可提供給 AI 號誌控制做為判別目前車流狀況之資訊，透過訓練之後，AI 號誌控制也可做為傳統號誌控制之角色，自我發展出符合路口特性之控制邏輯，依據當前的車流狀況進行時相之轉換，取代義交於路口手動操燈之功能，減少人力的耗費。

3.5 AI 應用於交通管理之資訊安全議題初步探討

隨著 5G 技術發展，資料傳輸便為更為快速且延遲訊號低，已成為智慧城市之發展利基，而人工智慧將結合資訊通訊的 5G 技術，可更為廣泛地應用於自駕車、車流特徵分析、交通行為及交通事件偵測等交通管理領域。但 AI 應用亦挾帶著大量資料之處理與分析，近年來網路攻擊手法更是推陳出新，舉凡以 AI 加速攻擊效率、惡意軟體與電子郵件亦結合「額外資料」來騙過機器學習系統，使安全機制無法偵測，更甚者則直接複製安全廠商之模型，以 AI 學習訓練，打造針對此安全機制量身打造的攻擊檔

案，資訊安全議題，已受各界關注。

張光宏(2020)指出，生成 AI (Generative AI)其使用神經網路來建立逼真的人工製品，如相片、聲音和文字。這種手法也被稱為深度偽造 (Deepfake)，且其已應用於自動化的網路詐騙、網路釣魚、電話詐騙，且難以防禦，因為其源頭即是經由自動化對抗的方法產生的，必須建構強大的政策和系統來克服人為失敗的情形。

毛敬豪(2020)指出，在高度便利下，交通運輸工具連結應用程式、交通號誌等，其中可能承受高度風險。當駭客駭入交通系統，可能面臨霸佔或免費使用交通設施，也可能導致運具油門失去作用或關閉安全防護措施甚至為癱瘓號誌...等，引發出更嚴重的交通安全問題。此外，目前由於資安領域人力短缺的問題，所以需要在資安工具中導入 AI，而 AI 也能提高偵測和反應的速度，降低其中的損失。

張庭瑜引述 IBM Security CTO 兼 VP Koos Lodewijkx (2018)對於 AI 資安應用之看法，其指出目前最常見的 AI 資安應用是「預測分析」(predictive analytics)，藉由機器學習分析大量數據，從中找出異常。第二類則是智能強化 (Intelligence consolidations)，將資安研究工作交給 AI，由 AI 學習資安技術。第三種則是智能回應 (intelligence response)，目標在於提高一定時間內的分析效率，使相關資安警示項目可更為快速地被發現。

Lodewijkx (2019)更提出五大資安防護攻略，包含(1)資訊安全部門應先了解自身最重要的資產，才能選擇合適的資安防護手段，(2)洞悉潛在威脅，透由情蒐先掌握攻擊動機及情境，研擬防護策略，(3)確保建立一個更安全且穩定可靠的資安基礎設施環境，以便能隨時監控企業內部網路的即時運作狀況，(4)進行資安演練及攻擊測試，針對各種威脅因應的準備，(5)資安防護是打團隊戰，應有完善資安團隊，並相互合作。

此外，在保護資訊之安全同時，亦需要針對其所含之個資制定相關法規，潘俊良(2017)指出，在互聯網個體車輛用戶聚集而成的交通資訊，其中由於自駕車黑盒子內括及數位存取資料會有相互傳送，可能會涉及個人資料的辨識及利用，故國家必須設立相關個人資料保護法進行保護。

政府機關基於確保相關設施可不被外界攻擊，多數均採取封閉網路 (GSN VPN)，以實體方式區隔外網，故在全部封閉網路的環境中，並無法受外部駭客攻擊，但仍需要防堵可連接至此封閉網路之使用者，此使用者將會成為駭客之攻擊跳板，陳健亮(2019)指出為防止內部資料遭竊取或竄

改，需要有效記錄所有行為，並實時檢測與警報，分析用戶資料行為，並做好權限管理。盧惠光(2019)指出自我整體安全體系結構應涵蓋法規與政策面，並細部分為預測、防止、檢測及應對，於預測階段應掌握風險級別及潛在威脅，防止部分則須針對預測之問題強化系統與隔離系統，檢測則時時監測，及時發現問題，確認和區分風險，於應對階段，則提出修復、調查事故與回顧性分析，且更改設計或模型策略，並不斷循環。

綜上所述，並依據本所 98 年「標準化都市交通管理之通訊協定研發(一)」研究案相關資訊安全議題規劃，我國資訊安全管理機制可包含資訊安全政策制定及評估、資訊安全組織推動及權責、人員安全管理及教育訓練、電腦系統安全管理，本計畫彙整 AI 應用於交通管理課題如下。

1. 資訊安全政策制定及評估：政府權責單位應依據其資安政策，要求相關維運廠商提出「資訊安全聲明」，並配合相關法規，以確保基本資訊安全。
2. 資訊安全組織推動及權責：系統承商就承攬範圍與都市交控系統權責單位之資訊單位、業務對與政風單位協調相關資訊安全事宜。
3. 人員安全管理及教育訓練：應組成資安團隊，且針對相關人員簽署個人資訊保密義務、承商專案人員素行調查、委外工作地區限制、排除外國人參與專案等規定。
4. 電腦系統安全管理：目前交通部門網路傳輸多以 GSN VPN 為主，在完全封閉之網路情況下，若能確保無漏洞供駭客成為攻擊跳板，則其安全風險十分低，然而諸多交通設施均放置於戶外，有心人士若能取得相關設備以實體線路連上通訊模組，則其可輕易進入此封閉網路，且亦有可能由內部人員做為跳點攻擊，故應進行以下策略：

- (1) 相關設備均應進行電腦病毒及惡意軟體之防範。
- (2) 利用 AI 監控異常設備聯入。
- (3) 利用 AI 針對所有使用者進行行為分析，因各項交通設施通常是每日均重複執行相同動作，故其網路與資料傳輸特性將十分相似，當掌握到不同的網路行為或是異常的資料傳輸，則需進一步探查該設備是否發生問題，舉凡比對其封包特性，進一步掌握問題。
- (4) 由於目前設備逐步朝向邊緣運算，當掌握相關非法入侵之狀況，應即斷開該遭入侵設備與其他設備之網路連線，以避免安全問題。
- (5) AI 設備應用方面，目前於物聯網、攸關交通的車聯網及偵測設備

均導入諸多 AI 議題，同時也蒐集諸多個資訊息，目前歐盟採取制訂完善法規，同時輔以該網路環境進行保護。林俊秀(2019)指出，我國目前於物聯網所牽涉之殭屍網路 Mirai 名列被攻擊國家第八名，且我國安控大廠亦因為具有嚴重安全性漏洞遭到美國 FTC (Federal Trade Commission)控告，故針對相關 AI 設備尤其牽涉資訊安全課題，應以標準與制度帶動資安水準，同時提升貿易限制加強國際競爭力。

目前我國亦逐年增修資安標準，包含於 107 年、108 年持續修訂物聯網影像監控系統資安標準(含網路攝影機 V2.0、影像錄影機 V1.0、網路儲存裝置 V1.0)，智慧巴士車載資通訊系統資安標準(車載機、智慧站牌)...等，目前亦委託資策會與台灣資通產業標準協會，共同制訂「物聯網資安認證制度規章」，建議未來 AI 應用於交通管理，在設備硬體方面，亦須要確保其通過資安認證，以確保基本之資訊安全。

- (6) 完善個人資料保護法、妨害電腦使用罪及資通安全管理法，從法源做為遏止手段，透由確保網路環境為封閉環境、設備為通過資安驗證，並輔以即時監控掌握異常行為，研擬自我整體安全體系結構，降低資訊安全風險，而在 AI 應用於交通管理所蒐集之個人資料方面，藉由相關法規完善，做為遏止與懲罰機制。

第四章 AI 路口號誌控制

前 2.4 節已說明本計畫延伸 AI 號誌控制 DQfD 運作機制，提出深度強化學習演算法 DQfB (DQN from Base-model)於號誌控制策略模型建立。DQfB 透過預先設計的示範資料來進行 AI 號誌控制策略模型建立，而示範資料即為利用本計畫範圍利用最佳化時制計畫產生軟體所產生之不同流量組合下之時制計畫。因此 4.1.2 節在研究範圍平假日尖離峰利用 PaSO 軟體產生最佳化時制計畫過程，同步產生 DQfB 號誌控制策略模型學習所需之訓練資料。

4.1 AI 號誌控制之規劃與設計

4.1.1 實驗場域的交通問題分析

「樂業-喬城三」至「樂業-長福」路口間原有配置為雙向各為一車道，現況為幹道往市區每小時最高約有 780 輛的車流量(編號 1)，相較於反向往太平區方向每小時最高 590 輛的車流量(編號 2)之差距約 190 輛，並經由現場觀察及調查數據，往市區方向主要來源為上游路口群組「下匝道車流」(編號 3)及「往市區車流」(編號 4)，如圖 4.1.1 所示。



圖 4.1.1 實驗場域交通問題現況

資料來源：本計畫整理

除上述往市區車流較大外，「樂業-十甲東」及「樂業-東英」週期亦與上游群組不同，尖峰時段各為 120 秒與 150 秒，最小公倍數為 600 秒，故 10 分鐘上下游群組才會連鎖 1 次，因此容易產生車流回堵情形，如圖 4.1.1 右側所示之樂業路往市區方向。

本計畫嘗試解決幹道車流量大與太平匝道群組週期不同問題，並考量

計畫範圍周邊支道車流量進入本區域的情形，從汽車車輛數進行判斷(機車疏解能力較好);依據檢視南北向車流數據，每小時最高約 420 輛的車流量，支道於某些時候應有秒數可轉換至幹道方向。

4.1.2 時制計畫設計

依據計畫範圍針對「樂業-十甲東」、「樂業-東英」兩處路口進行時制設計，並考量受影響之鄰近路口，包含「東平匝道群組」、「樂業-長福」、「東英-東英五」等，一併納入車流模擬當中，利用 PaSO 與 SUMO 分別進行巨觀之時制最佳化分析與微觀之車流績效分析。若有必要時，則調整時制計畫，並依據路口間距離、車速與停等長度...等參數，微調時差。另考慮計畫採用偵測設備有備料與安裝時間，因此先根據此調查資料進行時制計畫設計評估，進而再依蒐集之資料進行調整，相關流程如圖 4.1.2 所示。

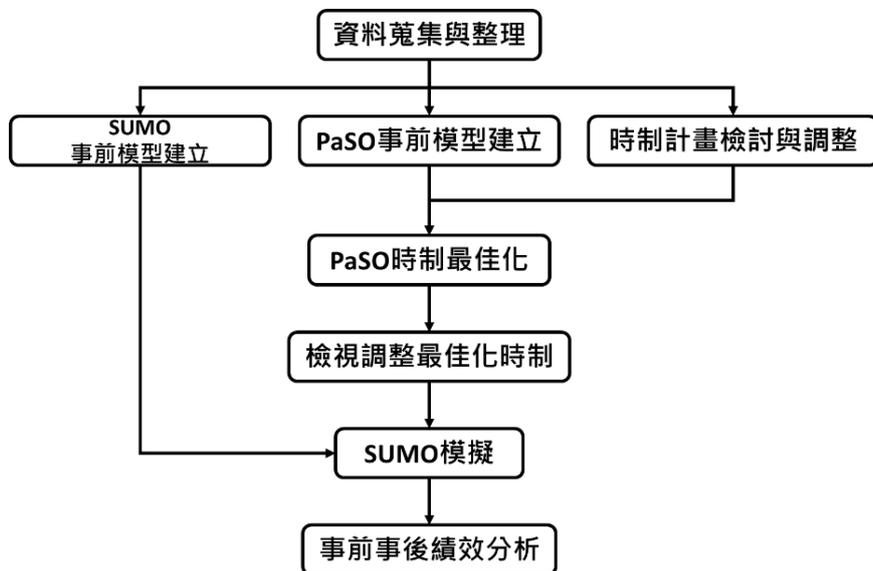


圖 4.1.2 時制計畫設計流程圖

資料來源：本計畫整理

1. 時制計畫檢討

路網事前週內日(DOW)切分如下：

- 平日：週一至週五(時段編號 1)
- 假日：週六(時段編號 2)
- 假日：週日(時段編號 3)

每個週內日區分不同時段為尖峰，分別如下：

- 平日尖峰(週期 120)：0700-0900、1600-1900
- 週六尖峰(週期 120)：0700-0900、1200-1900
- 週日全天離峰(週期 100)

實作時段範圍說明如下：

- 平日尖峰：0700-0900、1600-1900
- 平日離峰：1300-1500
- 假日離峰：1300-1500

「樂業-十甲東」及「樂業-東英」兩路口轉向量如圖 4.1.3 所示。

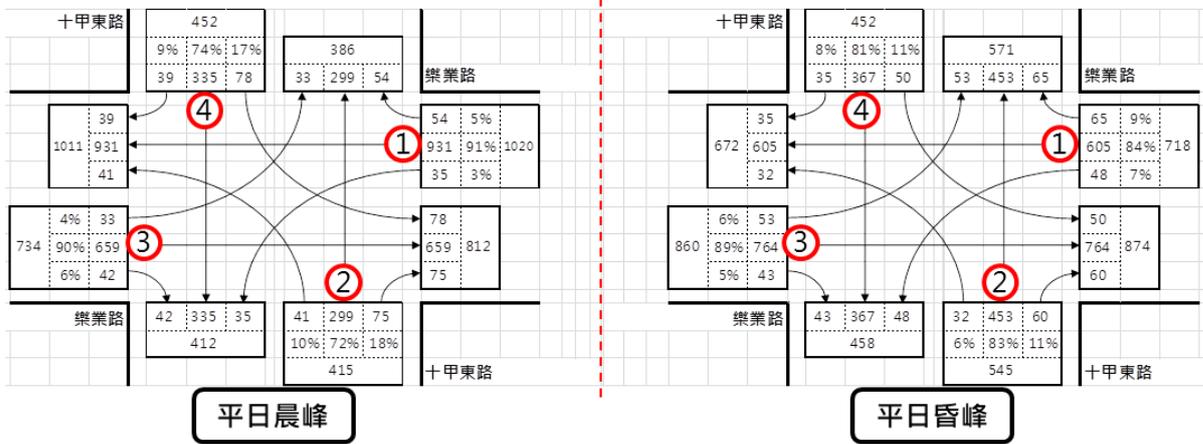
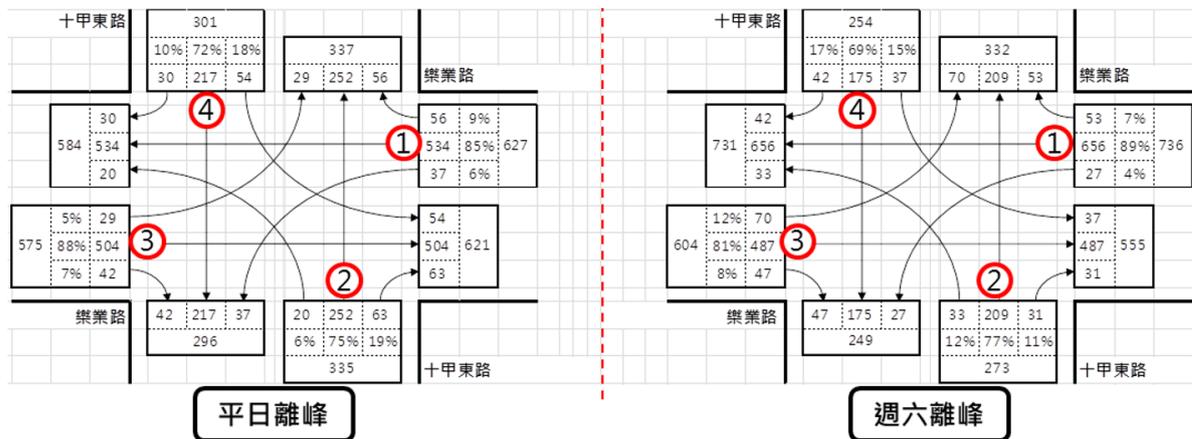


圖 4.1.3 「樂業-十甲東」平日晨昏峰轉向量

資料來源：本計畫整理

關於「樂業-十甲東」路口，為方便說明，以編號做為代號進行說明，圖 4.1.3 中編號 1 及 3 分別為由樂業路往市區與太平方向，為車輛最多之方向，機車量亦十分龐大，其晨昏峰以方向最大總量差異為 160 pcu/hr (1020 與 860 pcu/hr)，上下午皆以直行最高，顯示其在晨峰幹道方向車輛較多，但不會差異太大。再檢視編號 2 及 4，總量上，以車流最大方向差異 93 pcu/hr，轉向比晨昏峰皆是以直行為主，表示支道車流量在昏峰時，相較之下高於晨峰，因此晨昏峰幹支道車流互有增長，故此路口晨昏峰使用相同時制週期，再配合後續動態時比調整應可舒緩其交通問題。



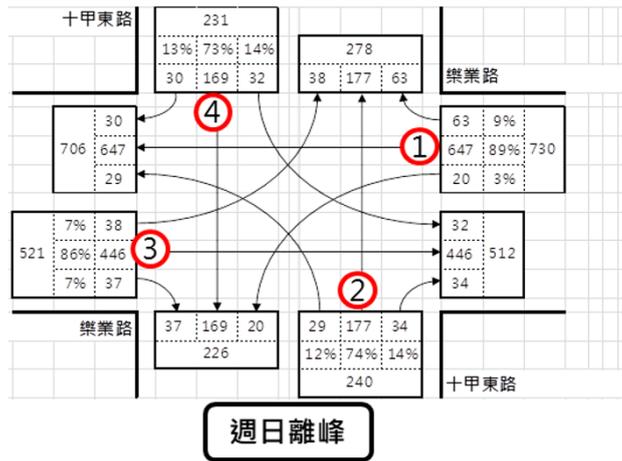


圖 4.1.4 「樂業-十甲東」平假日離峰轉向量

資料來源：本計畫整理

關於「樂業-十甲東」路口，圖 4.1.4 中編號 1 及 3 分別為由樂業路往市區與太平方向，為車輛最多之方向，假日編號 1 方向車流稍多(736 pcu/hr)，與平日差異 109 pcu/hr，但不會差異太大。編號 2 及 4 為十甲東路南北向車流，以平日 335 pcu/hr 較多，而假日介於 231 pcu/hr 至 273 pcu/hr 之間，因此平假日離峰使用相同時制計畫應可應付。但由於平日及週日離峰皆為 100 秒、週六離峰週期為 120 秒，故配合附近路口週期與號誌連鎖，後續將分開處理時制計畫。

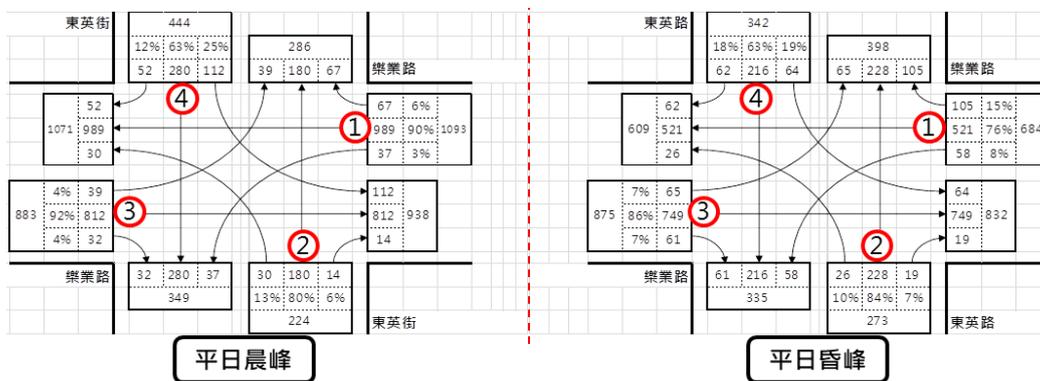


圖 4.1.5 「樂業-東英」平日晨昏峰轉向量

資料來源：本計畫整理

關於「樂業-東英」路口，圖 4.1.5 中編號 1 及 3 分別為由樂業路往市區與太平方向，為車輛最多之方向，機車量也大，可以發現晨昏峰以方向最大總量差異 218 pcu/hr (1093 與 875 pcu/hr)，上下午皆以直行最高，表示在晨峰幹道方向車輛會較多，稍微有些差異。再檢視編號 4，總量上差異 102 pcu/hr，轉向比晨昏峰皆是以直行為主，左轉次之，表示在晨峰編號 4 此方向車輛會較多，因此晨峰幹支道流量皆較昏峰稍多，但考量「樂業-東

英」路口與「樂業-十甲東」路口距離近且車流有相依性，故此路口晨昏峰使用相同週期，再配合後續動態時比調整應可處理。

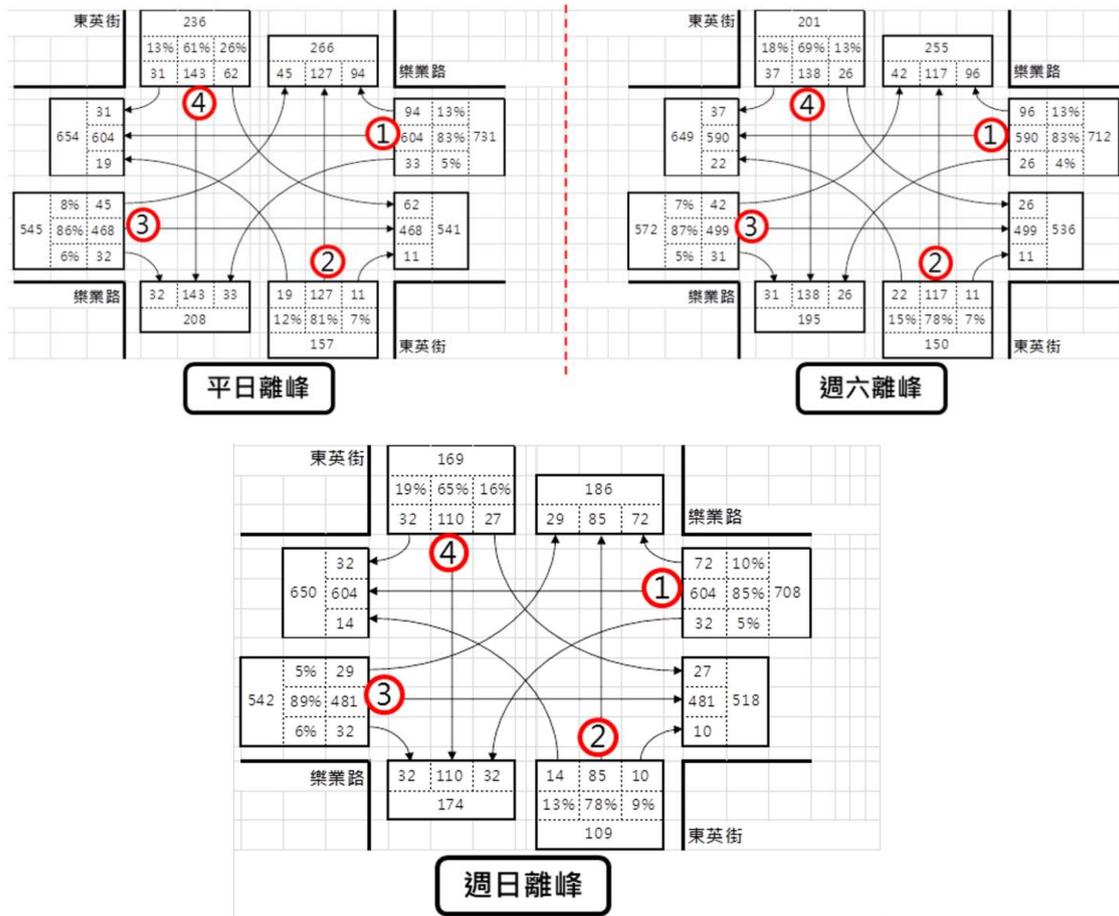


圖 4.1.6 「樂業-東英」平假日離峰轉向量

資料來源：本計畫整理

關於「樂業-東英」路口，圖 4.1.6 中編號 1 及 3 分別為由樂業路往市區與太平方向，為車輛最多之方向，編號 1 方向車流較多，且平假日差異不大。編號 2 及 4 為東英路南北向車流，以平日 236 pcu/hr 較多，而假日介於 169 pcu/hr 至 201 pcu/hr 之間，因此平假日離峰使用相同時制應可應付，但由於平日及周日離峰皆為 100 秒、週六離峰週期為 120 秒，故配合附近路口週期與號誌連鎖，後續將分開處理時制計畫。本計畫進而根據所蒐集之車流特性進行時相分析，並繪製時空圖(如圖 4.1.7 所示)探討其車流運作情況。

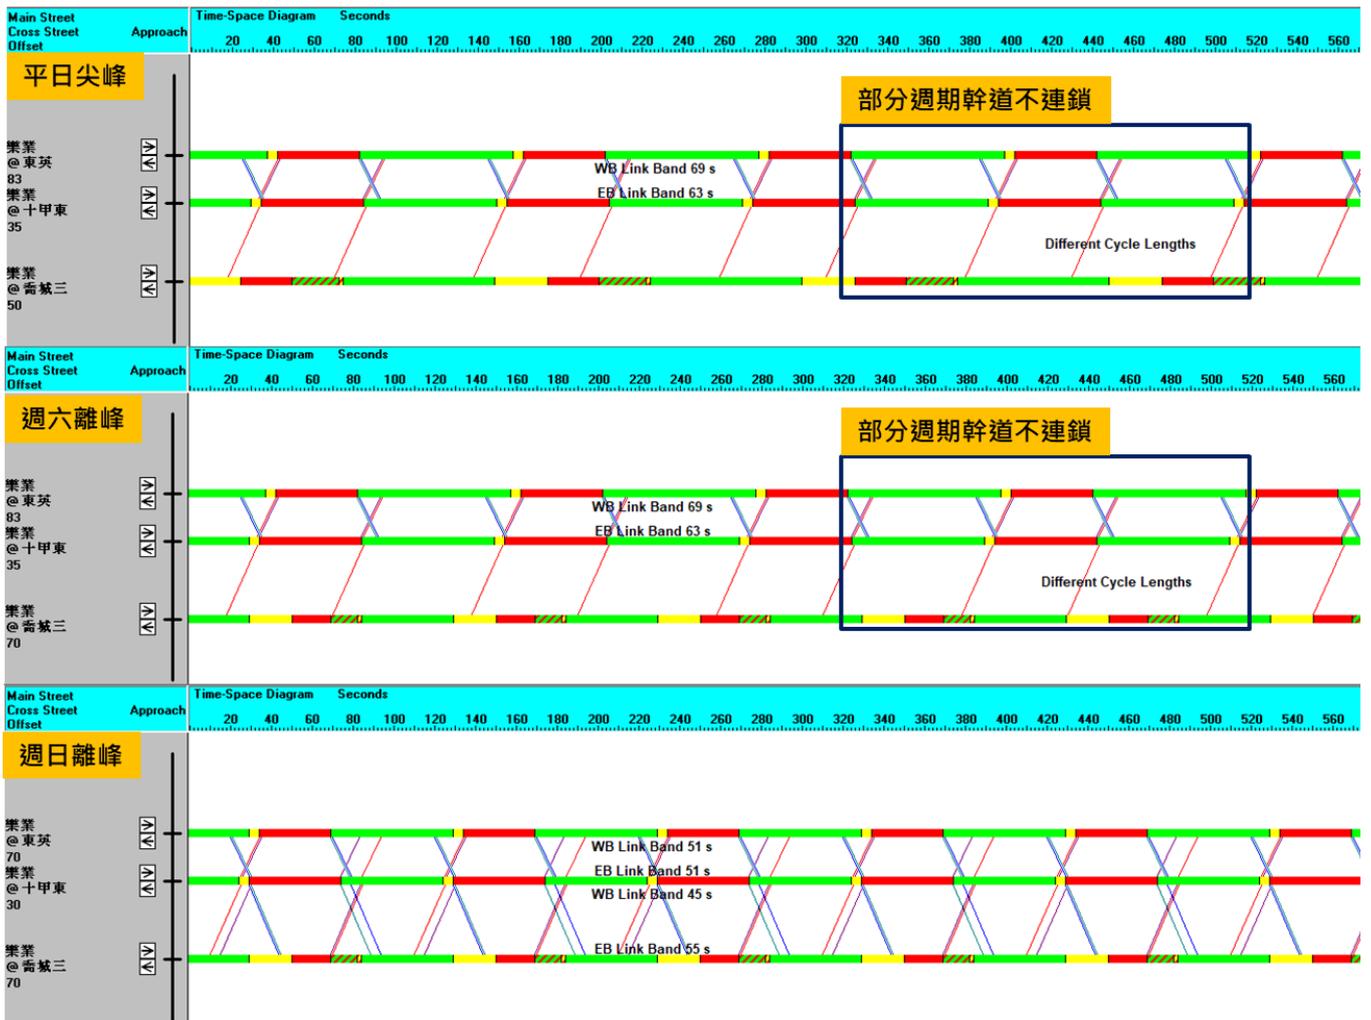


圖 4.1.7 改善前時制時空圖

資料來源：本計畫整理

由時空圖可觀察到因現況於平日尖峰及週六離峰時段有幹道號誌周期不同現象，因此每隔一段時間就有幹道號誌不連鎖與車流續進不佳現象，嚴重時發生車流壅塞回堵，此現象於尖峰時段之樂業路往市區方向較為嚴重。另由流量調查發現，各時段支道車流亦有所差異(多至 100 pcu/hr 以上)，但全天僅有一套時制計畫，可能產生綠燈秒數浪費或不足之情形，因此透過週期大小的調整，以及依據各時段支道車流變化調整對應的時比，應可改善上述問題。

2. 時相檢討

為使台 74 線太平匝道往臺中市區的關鍵路徑車流能疏解順暢，因而調整「樂業-十甲東」路口的時相順序與時差，原分相 1 為十甲東路支道疏解時間，分相 2 為樂業路幹道疏解時間；調整時相主要因為當時比變動時，如圖 4.1.8 樂業-十甲東的第一個週期為例，分相 1 與分相 2 間會因時

比變動造成分相 1 減少(左移)或增加(右移)，此時若右移，對分相 2(幹道)會較原時制晚綠燈，反之則早亮綠燈，導致每次時比變動時的起點位置不同，而產生不同的時差，因而使上下游路口的續進能力受影響。故調整分相順序後，幹道的綠燈起點位置變為固定，因此當幹道變更為第一分相後，即不再受時比變動而影響幹道起始綠燈的時差

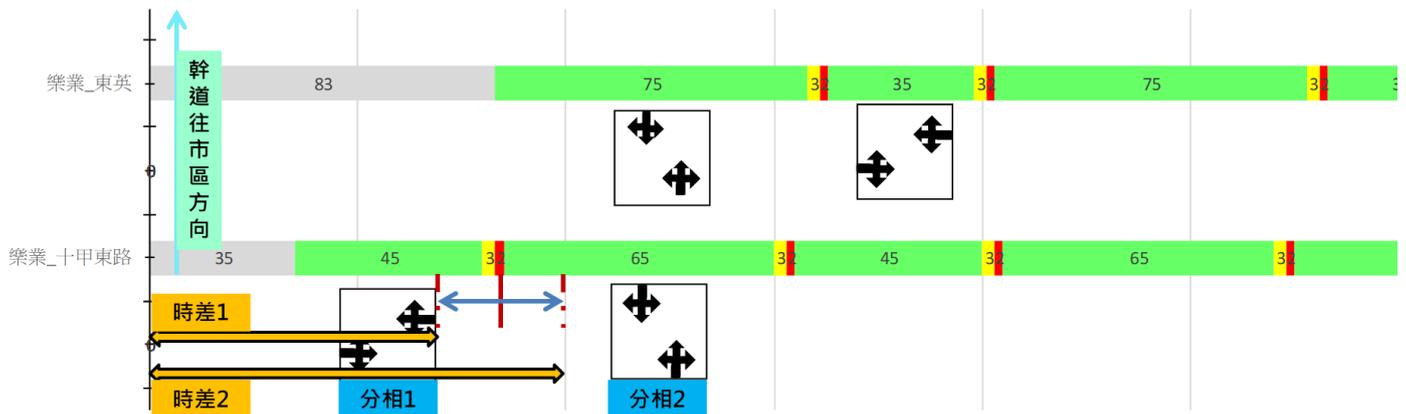


圖 4.1.8 時相調整原因說明

資料來源：本計畫整理

3. PaSO 最佳化時制計畫產生與 SUMO 事前模擬模型建立

本計畫採用交通部發展的號誌時制軟體 PaSO 來產生最佳化時制計畫，做為 AI 號誌控制強化學習模式的訓練資料。並利用既有「樂業-十甲東」以及「樂業-東英」兩路口調查轉向量與臺中市交通局提供之現況時制計畫，來建立 PaSO 以及 SUMO 兩套軟體之路網模型，在 SUMO 模擬軟體中進行事前事後的模擬績效分析。

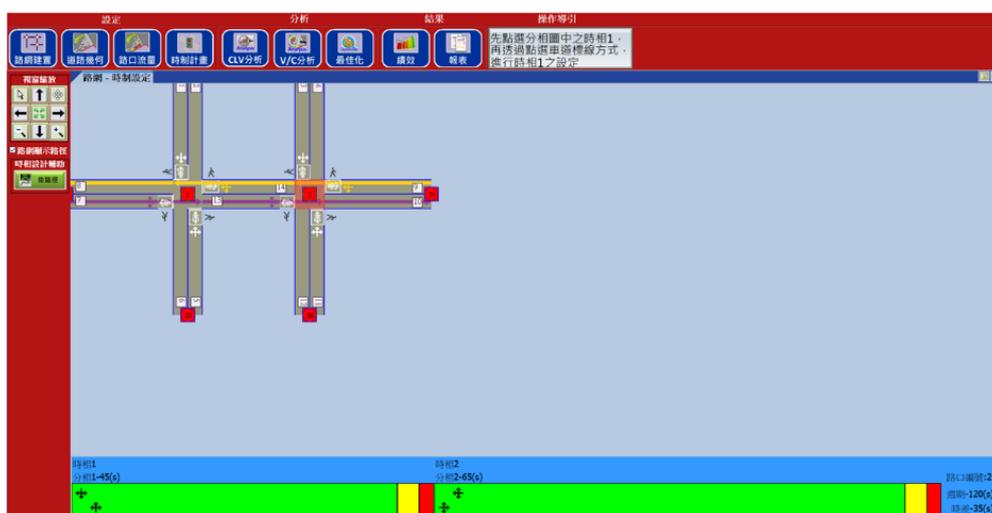


圖 4.1.9 PaSO 時制計畫產生軟體之樂業路幹道

資料來源：本計畫整理

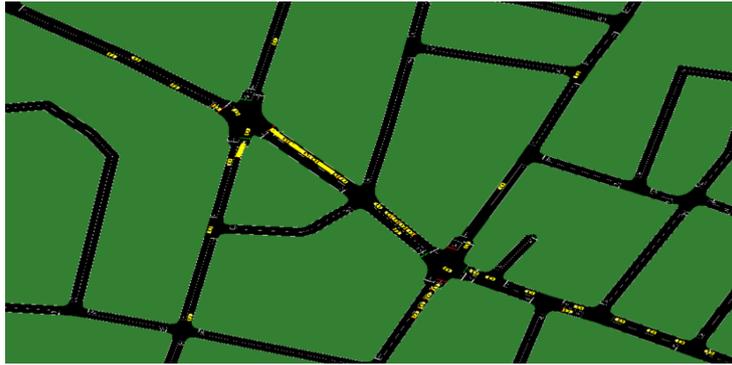


圖 4.1.10 SUMO 模擬軟體之樂業路幹道

資料來源：本計畫整理

在模擬路網建立完成後首先進行事前績效模擬，初步分析可以發現幹道未有過飽和情況，並且樂業路往市區的流量、模擬狀況與空拍機實際拍攝之現況有些出入，因此再重新檢視路口攝影機與至現場統計車流量，並針對往市區部分，依據重新檢視計算結果進行調整，以求符合現況。



圖 4.1.11 樂業路空拍往市區方向壅塞回堵

資料來源：本計畫整理

4. 時制計畫最佳化

本計畫針對平日尖峰、平日離峰及假日離峰進行時制最佳化設計，說明如下。

(1) 平日尖峰

① 基礎時制計算

透過 PaSO 進行兩路口(樂業-十甲東、樂業-東英)幹道優先時制最佳化設計，由於鄰近的太平路口群組週期採 150 秒，

往市區流量高且距離近，因此採用相同週期 150 秒進行時比擬定，運算結果如表 4.1-1 與表 4.1-2 所示。此最佳化時制計畫亦計算出績效值，以下定義績效路段如圖 4.1.12 所示，並於表 4.1-3 列出相關績效值。

表 4.1-1 平日尖峰 PaSO 最佳化時制計畫內容(樂業-十甲東)

時差為 65 秒	分相 1	分相 2	分相 3	分相 4
時相圖			-	-
綠燈秒數	90 秒	50 秒	-	-
黃燈秒數	3 秒	3 秒	-	-
紅燈秒數	2 秒	2 秒	-	-
週期	15 秒 0			

表 4.1-2 平日尖峰 PaSO 最佳化時制計畫內容(樂業-東英)

時差為 65 秒	分相 1	分相 2	分相 3	分相 4
時相圖			-	-
綠燈秒數	85 秒	55 秒	-	-
黃燈秒數	3 秒	3 秒	-	-
紅燈秒數	2 秒	2 秒	-	-
週期	150 秒			

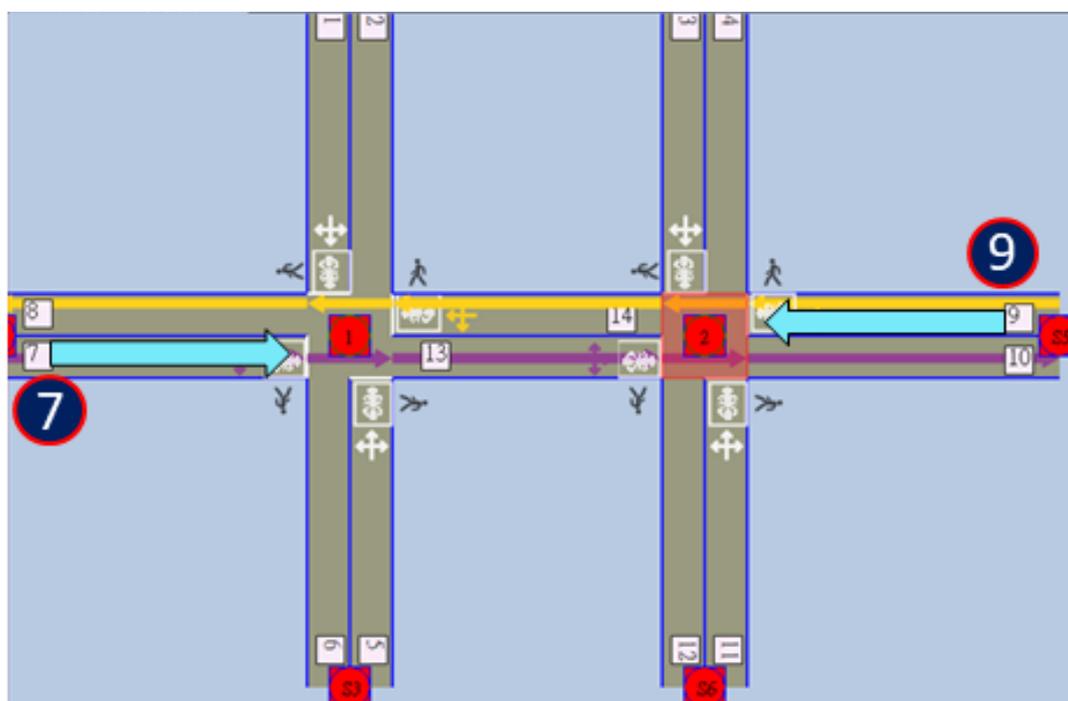


圖 4.1.12 研究範圍之 PaSO 模擬路網之空間績效定義示意

表 4.1-3 平日尖峰事前事後 PaSO 模擬績效(延滯)

平均延滯						
ID	事前 (機車)	事後 (機車)	改善率% (機車)	事前 (小客車)	事後 (小客車)	改善率% (小客車)
7	7.23	13.23	-83%	9.95	17.16	-72%
9	11.05	10.89	1%	82.01	25.42	69%
樂業-東英	11.00	14.97	-36%	10.53	15.94	-51%
樂業-十甲東	12.86	15.07	-17%	49.27	23.67	52%
總延滯						
路網延滯	100719.82	87999.79	13%			

資料來源：本計畫整理

主要觀察績效項目為延滯，包含幹道方向、路口與整體路網的延滯，因 PaSO 主要能夠分別提供機車與汽車的績效，能看到較細緻的資訊。首先檢視平均延滯，可以發現路段 7 (幹道往東路段) 的汽機車延滯皆有微幅增加 6 至 8 秒左右，但路段 9 (幹道往西路段) 的汽車延滯有大幅降低約 56 秒左右，有顯著的績效改善；以路口而言，樂業-東英的汽機車延滯有增加約 4 至 5 秒，樂業-十甲東的汽車延滯降低約 25 秒。另外檢視總延滯，整體路網延滯降低 13%，有較好的改善績效。

②擴充實務流量型態下之時制計畫組合

本計畫 AI DQfB 動態號誌控制仿真學習，主要基於基礎時制計畫，該基礎時制計畫內容為預擬號誌週期固定下的幹支道方向不同時比之時制計畫組合。以本計畫而言，即為變動「樂業-十甲東」及「樂業-東英」的分相 1 與分相 2，以因應各方向偵測器所偵測兩路口的外圍流入車流量變化，提供 AI DQfB 動態號誌控制來學習此時比變換(對應不同時制計畫組合)。當「樂業-十甲東」的分相 1 減少 15 秒時，分相 2 會增加 15 秒，以周期固定方式，來避免號誌運作不會發生號誌控制器補償現象。

為求流量組合可以涵蓋以樂業路幹道續進口優先各種情境，本計畫依據下列原則來設計流量組合：

- 時比變動應維持幹支道行人通行之最小綠燈秒數；現況「樂業-十甲東」及「樂業-東英」兩路口的道路幾何相似，幹支道路幅均約為 15 公尺，本計畫以高齡者與幼童

行走均速 0.8 秒/公尺計算，換算最小行人綠燈時間約為 20 秒。

- 綠燈秒數變動間隔，依據車間距做為調整基礎；綠燈秒數調整間隔以疏解兩輛汽車為考量，依據圖 4.1.13 疏解間距統計，於第 10 輛車至第 16 輛為較穩定疏解時間，約落為 2 秒左右，故為確保可使 2 輛車通過路口，以 5 秒做為調整基礎。
- 依據車流量，篩選符合實際現況之時制計畫；依據流量調查，可以發現各時段的幹道流量皆大於支道，因此設定幹道綠燈大於支道綠燈時間。

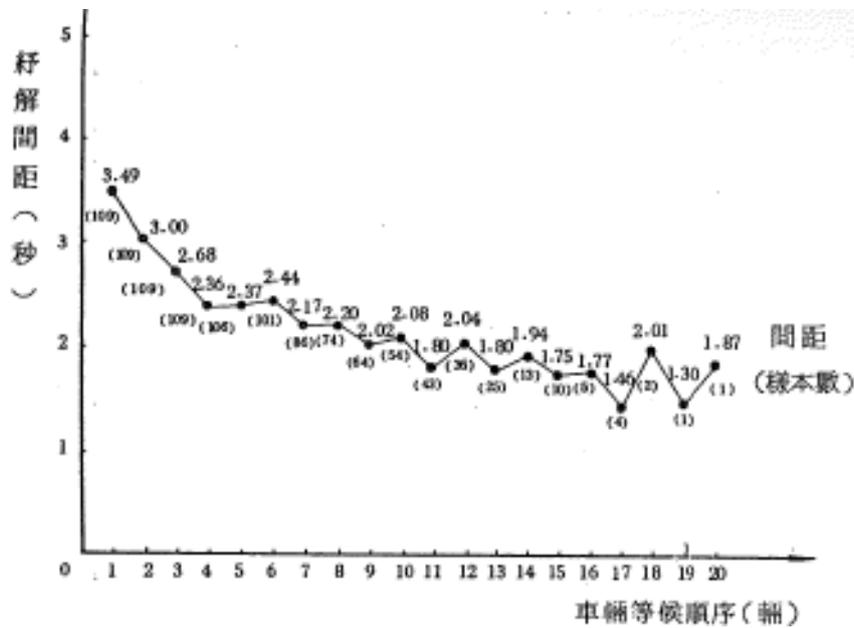


圖 4.1.13 車間距統計分析

資料來源：蔡輝昇(1990)，交通控制理論與實務

本計畫以上述基礎時制為基礎，搭配流量組合設計原則，擬定尖峰時段各時比組合之時制計畫如表 4.1-4 所示，以做為本計畫 DQfB 動態號誌控制仿真學習的時制計畫組合。

表 4.1-4 平日尖峰時制計畫組合(粗體與底線者為基礎時制計畫)

編號	樂業-十甲東		樂業-東英	
	分相 1	分相 2	分相 1	分相 2
時相圖				
1	80	70	80	70
2	85	65	85	65
3	90	60	90	60

4	95	55	95	55
5	100	50	100	50
6	105	45	105	45
7	110	40	110	40
8	115	35	115	35
9	120	30	120	30
10	125	25	125	25
週期	150			

資料來源：本計畫整理

③ 流量與時制對應關係

在求得平日尖峰時段週期為 150 秒時制計畫組合後，本計畫依此各時制計畫來反求對應之流量組合。本計畫暫將研究範圍「樂業-十甲東」及「樂業-東英」兩個路口視為一個「單元」，僅考量流入該「單元」之外部(上游)流量 V_1 至 V_6 ，暫不考量「樂業-十甲東」(a)及「樂業-東英」(b)路口間之可能互動，其概念示意如圖 4.1.14。

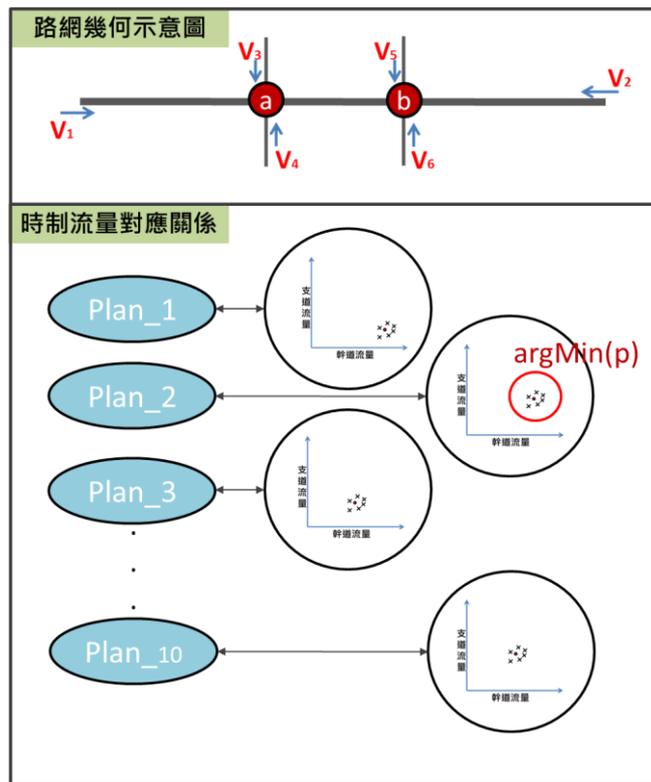


圖 4.1.14 時制計畫與流量對應關係圖

資料來源：本計畫整理

時制計畫與流量對應的計算方式，主要依據幹支道之綠燈需求長度進行調整，首先分別給予幹支道基礎之綠燈時間，當流量超過基礎需求時，給予其較多綠燈時間，反之則減少；

然而週期長度為固定，故幹支道所求解之綠燈需求，則再依比例分配以符合週期長度即可找出對應之時制。

本計畫假設 a 與 b 兩路口間的車流量為號誌控制下的車流量，不屬於變數，因此在進行 a 路口的流量求解時，輸入鍵畫範圍外圍之流量 V1、V2、V3、V4，並針對(V1、V2)及(V3、V4)分別找出主幹道與支道之最大值，依據流量大小調整基礎時制計畫之綠燈時間，再與各時制計畫的幹支道綠燈比值找出最接近者，即可找出 a 路口對應時制計畫，公式如式(1)所示，並以表 4.1-4 樂業-東英路口為例說明如後。

再依據流量大小調整基礎之綠燈時間，再與各時制計畫的幹支道綠燈比值找出最接近者，即可找出 a 路口對應時制計畫，公式如式(1)所示。

$$P_a = \arg \min \left(\left| \frac{g_1^i}{g_2^i} - \frac{85 + (25 - 20) * 2}{55 + (13 - 9) * 2} \right| \right)$$

$$P_a = \arg \min \left(\left| \frac{g_1^i}{g_2^i} - \frac{95}{63} \right| \right)$$

$$P_a = \arg \min \left(\left| \frac{g_1^i}{g_2^i} - 1.51 \right| \right), \text{ 與樂業東英第 3 組時制比值最接近}$$

$$P_a = \arg \min \left(\left| \frac{g_1^i}{g_2^i} - \frac{g_1 + (\max(V1, V2) - f_1) * h}{g_2 + (\max(V3, V4) - f_2) * h} \right| \right) \quad (1)$$

- h: 車頭距(例如：2 秒)
- f_1 : 幹道基礎流量(依據偵測器長期資料，採該時段之平均流量/週期)
- f_2 : 支道基礎流量(依據偵測器長期資料，採該時段之平均流量/週期)
- g_1 : 幹道基礎綠燈時間(例如：表 4.1-4 樂業-東英路口基礎時制 85 秒：扣除清道秒數)
- g_2 : 支道基礎綠燈時間(例如：表 4.1-4 樂業-東英路口基礎時制 55 秒：扣除清道秒數)
- g_1^i : 第 i 個時制計畫之幹道綠燈時間(例如：表 4.1-4)
- g_2^i : 第 i 個時制計畫之支道綠燈時間(例如：表 4.1-4)
- P_a : 路口 a 之時制計畫(例如：表 4.1-4，每組時制計畫皆可求得自己的幹支道綠燈比值，與公式(1)中以當下流量計算綠燈比值最接近表 4.1-4 中的其中一組時制計畫即為該時制

計畫)

接著針對 b 路口的流量進行求解，亦比照 a 路口，假設 a 與 b 兩路口間的車流量為號誌控制下的車流量，不屬於變數，因此在進行 b 路口的流量求解時，輸入鍵畫範圍外圍之流量 V1、V2、V3、V4，並針對(V1、V2)及(V3、V4)分別找出主幹道與支道之最大值，再依據流量大小調整基礎時制計畫之綠燈時間，再與各時制計畫的幹支道綠燈比值找出最接近者，即可找出 b 路口對應時制計畫，公式如式(2)所示。其餘參數均參考 a 路口。

$$P_b = \arg \text{Min} \left(\left| \frac{g_1^i}{g_2^i} - \frac{g_1 + (\max(V1, V2) - f_1) * h}{g_2 + (\max(V5, V6) - f_2) * h} \right| \right) \quad (2)$$

- h: 車頭距；
- f_1 : 幹道基礎流量
- f_2 : 支道基礎流量
- g_1 : 幹道基礎綠燈時間
- g_2 : 支道基礎綠燈時間
- g_1^i : 第 i 個時制計畫之幹道綠燈時間
- g_2^i : 第 i 個時制計畫之支道綠燈時間
- P_b : 路口 b 之時制計畫

本計畫為使 a 與 b 路口之幹道能有良好的續進效益，進行路口 a 與 b 之時制計畫協調，即所謂將上述各自求得之時制，從中挑選一個做為兩路口之共同時制計畫，如式(3)所示。

$$(P, P) = \text{Min GB}(P_a, P_b) \quad (3)$$

$$P = \begin{cases} P_a, & \text{if } g_1^a < g_1^b \\ P_b, & \text{if } g_1^b < g_1^a \end{cases}$$

- GB: 綠寬帶
- g_1^a : a 路口之幹道綠燈時間
- g_1^b : b 路口之幹道綠燈時間

(2)離峰(平日及週日)

①基礎時制計算

透過 PaSO 進行兩路口(樂業-十甲東、樂業-東英)時制最

佳化，由於鄰近路口群組週期採 100 秒，並避免號誌不連鎖情形，因此採用相同週期 100 秒進行時比擬定，運算結果如表 4.1-5 及表 4.1-6 所示，相關績效如表 4.1-7 所示。

表 4.1-5 離峰 PaSO 擬定時制計畫內容(樂業-十甲東)

時差：85	分相 1	分相 2	分相 3	分相 4
時相圖			-	-
綠燈秒數	60	30	-	-
黃燈秒數	3	3	-	-
紅燈秒數	2	2	-	-
週期	100			

資料來源：本計畫整理

表 4.1-6 離峰 PaSO 擬定時制計畫內容(樂業-東英)

時差：85	分相 1	分相 2	分相 3	分相 4
時相圖			-	-
綠燈秒數	60	30	-	-
黃燈秒數	3	3	-	-
紅燈秒數	2	2	-	-
週期	100			

資料來源：本計畫整理

表 4.1-7 離峰 PaSO 擬定時制績效結果-延滯

平均延滯						
ID	事前 (機車)	事後 (機車)	改善幅度% (機車)	事前 (小客車)	事後 (小客車)	改善幅度% (小客車)
7	7.21	7.21	0%	9.50	8.97	+6%
9	11.61	7.20	+38%	17.26	10.51	+39%
Int. 1(樂業-東英)	9.05	9.49	-5%	8.39	8.75	-4%
nt. 2(樂業-十甲東)	11.37	10.88	+4%	14.43	12.01	+17%
Total 延滯						
路網延滯	25110.99	23547.01	+6%			

資料來源：本計畫整理

檢視平均延滯，可以發現路段 7(幹道往東路段)的汽車延滯有微幅減少 6%，路段 9(幹道往西路段)的汽機車延滯皆有大幅降低約 38%，有顯著的績效改善；以路口而言，樂業-東英(Int.1)之汽機車延滯有微幅增加 4%，樂業-十甲東(Int.2)的汽車延滯降低約 17%。另檢視總延滯，整體路網延滯降低 6%。

②擴充各流量組合之時制

本計畫依據前述三原則並以基礎時制做為基準，擬定離峰(平日及週日)時比組合之時制計畫，如表 4.1-8 所示。

表 4.1-8 離峰(平日及週日)時制計畫組合

編號	樂業-十甲東		樂業-東英	
	分相 1	分相 2	分相 1	分相 2
時相圖				
1	55	45	55	45
2	60	40	60	40
3	65	35	65	35
4	70	30	70	30
5	75	25	75	25
週期	100			

資料來源：本計畫整理

③流量與時制對應關係

平日離峰時段的週期為 100 秒，並依據該時段 V1 至 V6 的流量組合對應適當的時制計畫，V1 至 V6 係指從計畫範圍上游所進入的車流量，再依序上述公式(1)至(3)即可求得。

(3)離峰(週六)

①基礎時制計算

透過 PaSO 進行兩路口(樂業-十甲東、樂業-東英)時制最佳化，由於鄰近路口群組週期採 120 秒，並避免號誌不連鎖情形，因此採用相同週期 120 秒進行時比擬定，運算結果如表 4.1-9 及表 4.1-10 所示，相關績效如 4.1-11 所示。

表 4.1-9 週六離峰 PaSO 擬定時制計畫內容(樂業-十甲東)

時差：35	分相 1	分相 2	分相 3	分相 4
時相圖			-	-
綠燈秒數	70	40	-	-
黃燈秒數	3	3	-	-
紅燈秒數	2	2	-	-
週期	120			

資料來源：本計畫整理

表 4.1-10 週六離峰 PaSO 擬定時制計畫內容(樂業-東英)

時差：80	分相 1	分相 2	分相 3	分相 4
時相圖			-	-
綠燈秒數	80	30	-	-
黃燈秒數	3	3	-	-
紅燈秒數	2	2	-	-
週期	120			

資料來源：本計畫整理

表 4.1-11 週六離峰 PaSO 擬定時制績效結果-延滯

平均延滯						
ID	事前 (機車)	事後 (機車)	改善幅度% (機車)	事前 (小客車)	事後 (小客車)	改善幅度% (小客車)
7	7.60	6.04	+21%	9.43	7.44	+21%
9	11.57	9.74	+16%	16.08	13.41	+17%
Int. 1(樂業-東英)	9.59	9.66	-1%	10.91	10.63	+3%
Int. 2(樂業-十甲東)	13.55	13.88	-2%	15.63	15.22	+3%
總延滯						
路網延滯	30608.93	30223.51	+1%			

資料來源：本計畫整理

檢視平均延滯，可以發現路段 7(幹道往東路段)的汽機車延滯皆有降低約 21%，路段 9(幹道往西路段) 的汽機車延滯亦皆有降低約 16%，有顯著的績效改善；以路口而言，Int.1 的汽車延滯有降低 3%，Int.2 的汽車延滯亦降低約 3%。另檢視總延滯，整體路網延滯降低 1%。

②擴充各流量組合之時制

本計畫依據前述三原則，並以基礎時制做為基準，擬定週六離峰時段時比組合之時制計畫，如表 4.1-12 所示。

表 4.1-12 週六(離峰)時制計畫組合

編號	樂業-十甲東		樂業-東英	
	分相 1	分相 2	分相 1	分相 2
時相圖				
1	65	55	65	55
2	70	50	70	50

3	75	45	75	45
4	80	40	80	40
5	85	35	85	35
6	90	30	90	30
7	95	25	95	25
週期	120			

資料來源：本計畫整理

③ 流量與時制對應關係

於平日離峰時段的週期為 120 秒，並依據該時段 V1 至 V6 的流量組合對應適當的時制計畫，V1 至 V6 係指從計畫範圍上游所進入的車流量，再依序上述公式(1)至(3)即可求得。

4.1.3 強化學習規劃設計

目前國外應用 AI 強化學習於號誌控制多透過模擬環境(例如：VISSIM, SUMO, CityFlow)進行，學習訓練所需資料則透過實際車流資料蒐集將之轉化為 AI 強化學習之所需，尚較少於實際場域進行實測與驗證。為減少 AI 強化學習於訓練過程的樣本數不足，以及實測過程可能發生之預期外動作，亦有部分研究透過專家(例如：Synchro 或 PaSO 時制最佳化產生軟體)產生的時制計畫，做為 AI 強化學習訓練資料的類監督式學習。

藉由蒐集專家時制計畫於狀態序列上，所執行之連續動作及動作所取得之獎勵，以專家狀態-動作-獎勵序列記錄，監督式學習方式更新類神經網路模型，以令 AI 強化學習模型能複製專家時制計畫，然而此類方法實作於號誌控制時所面臨問題，須長時間蒐集專家時制計畫於號誌控制上之大量序列記錄，始能更新模型。其次，透過此類監督式學習方式所建立之行為複製模型較難以進一步使類神經網路模型與環境互動，演進出更佳之策略。

1. 強化式學習架構

本計畫延伸 DQfD (DQN from Demonstration)，提出一新穎深度強化學習演算法 DQfB (DQN from Base-model)於號誌控制策略模型建立。於 DQfD 設計為蒐集一些示範，並以這些示範來幫助模型做訓練，以克服深度強化學習訓練初期不易學習出好的策略的問題。然而如能建立一近似最佳化模型提供近似最佳動作範例，代理人可以透過與此基礎模型 (base-model) 互動，於互動過程全面性學習基礎模型輸出之各種示範。相較於示範資料集只是整個群體中的子集合，透過與基礎模型互動可以對整體環境學習近最佳化控制策略。

相較於 DQfD 僅單純使用示範的行為與其互動的資料進行一般強化學習訓練，本計畫所設計之 DQfB 使用不同獎勵形式 (R_B)，達到有模仿學習的效果，並且仍保留精進的空間，使得最後學習的決策可以超越基礎模型的決策。

訓練初期將基礎模型之動作行為輸出為初期學習對象，以相似程度(similarity)做為訓練獎勵，已達到有模仿學習的效果；此外可以佐以實際環境之獎勵做訓練，透過調整比重參數(ω)，使得代理人能學習到超越基礎模型的決策。在訓練初期，可透過設定比重參數為 0 ($\omega = 0$) 來使得代理人學習基礎模型的決策方式；待代理人已學習基礎模型的決策方式，或欲導入真實獎勵方式，則可將比重參數為 1 ($\omega = 1$) 來著重真實獎勵，使得代理人以最大化真實獎勵的決策為目標去學習。若此學習到的決策方式與基礎模型的決策方式不同，則表示代理人學習到超越基礎模型的決策。

$$R_B = \omega \cdot R_{real} + (1 - \omega) \cdot \text{similarity}$$

惟本計畫暫不考慮實際環境獎勵，僅使用與初期學習對象的相似程度(similarity)，因此 ω 為 0；本計畫於基礎模型互動訓練過程中採用專家基礎模型及與代理人之動作相似度做為強化學習之獎勵以更新網路，因此不需要長時間蒐集大量專家控制記錄便可即時更新網路，其架構如圖 4.1.15 所示。另一方面，在 buffer 使用方式上，原本 DQfD 是把 buffer 切成兩部分，一部分是固定存專家的演示資料，另一部分是 AI 與環境互動的資料(會不斷更新)，在訓練時，依照一定的比例來抽取樣本作訓練，而本計畫目前訓練資料是以專家的演示資料為基礎，因此並無與環境互動的資料部分。

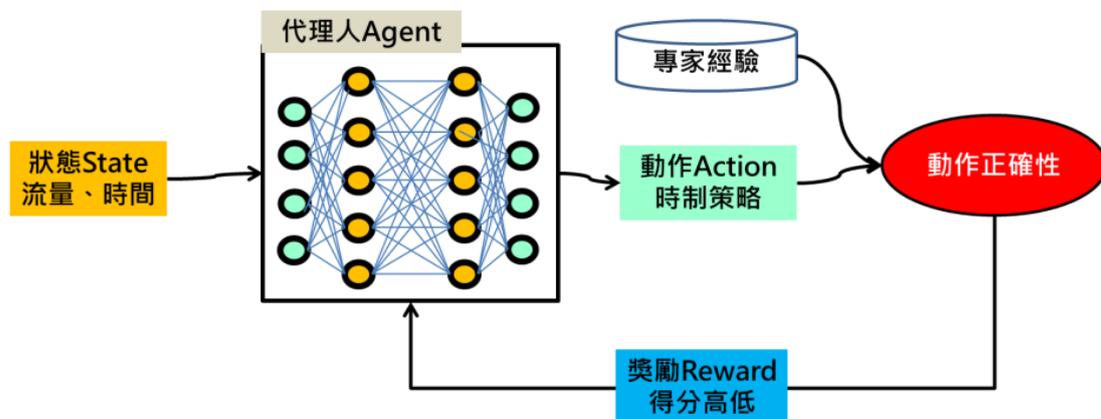


圖 4.1.15 演示法之深度 Q 學習

資料來源：本計畫整理

2. 號誌控制之強化式學習

圖 4.1.16 說明 AI 應用於號誌控制，圖上半部演示實際或虛擬環境中所接受到的「狀態(外部車流)」及相對應作出的「動作(號誌時制)」之關係，圖下半部表示代理人(決策者)實際輸入與輸出的相關參數，代理人(決策者)會依據尖離峰時段與流量，選擇對應的時制計畫，此決策過程類似傳統的號誌控制動態查表。

本計畫以「樂業-十甲東」及「樂業-東英」兩路口外圍 6 個方向之「車流量及對應時間」做為網路之狀態輸入，深度 Q 網路根據輸入狀態運算，選擇相同週期之預先利用 PaSO 產生最佳化基礎時制，並擴充擬定之候選時制計畫組合群中(如表 4.1-4、4.1-8、4.1-12)挑選出一最趨近於專家所會採用之「時制計畫組合」做為動作輸出，而專家之選擇時制依據，則利用流量與時制對應關係選擇適當之時制計畫(流程請參閱 4.1.2 節及圖 4.1.14)。候選時制計畫組合是由基礎時制擴充而得，流量及時段組成狀態，AI 依狀態從候選時制計畫組合中挑選最適時制計畫。輸入各方向流量後，經由 AI 運算輸出時制計畫為動作。

在獎勵函數之設計上，本計畫主要測試過的獎勵函數包含二元、線性、指數、指數 10 倍等。二元獎勵係為若代理人與專家動作相符，獎勵=1，反之，獎勵=0。線性獎勵係為獎勵=normalize(代理人與專家動作相似度)。指數獎勵係為獎勵=normalize[exp(代理人與專家動作相似度)]。指數 10 倍獎勵係為獎勵=normalize[exp(10*代理人與專家動作相似度)]。二元獎勵只有在代理人與專家動作相符時才會得分，反之都無法得分，此設計當動作空間較大時會需要探索比較久。線性獎勵會依代理人與專家動作之時制秒數差異作反比得分，越正確會得越高分，如此可指引代理人往正確方向收斂。然當動作偏離太大時仍有得分，所以收斂速度較慢。指數獎勵與線性獎勵相似，差別於將秒數差異作反比再取指數，此為目前最佳設計，代理人可有效率地往正確答案收斂。指數 10 倍獎勵與指數獎勵相似，差別為秒數差異會乘 10 倍，然因此種設計動作偏離太大時幾乎都無得分，所以收斂速度較慢。經綜合評估後，本計畫最終採用指數型之獎勵函數。

以價值為基礎(value-based)的決策方式，使選擇價值函數最高的動作去執行，每次的訓練，藉由反向傳遞的方式，將誤差(error)用於

參數更新上，使其可以修正價值函數的分數。藉由多次的訓練更新後，在同一個狀態下，價值函數對於專家的決策會有較高的分數，因此會去採取專家的決策，藉由累積獎勵最佳化網路更新，最終可建立一網路使代理人輸出近似專家之決策，以達到本計畫離線學習專家的目的。

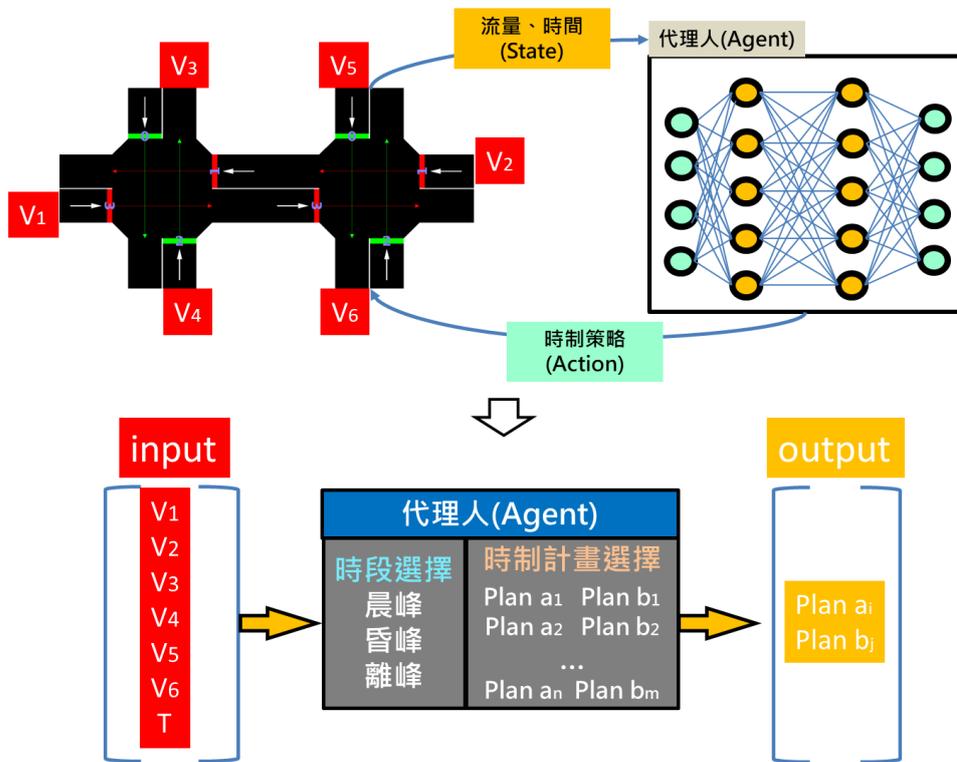


圖 4.1.16 號誌控制之強化式學習

資料來源：本計畫整理

本計畫實驗設計分兩階段進行，第一階段為單純模仿專家於時制計畫上之決策，第二階段擴充模仿專家於離尖峰及平假日採以不同時制計畫之評斷。最終建立之模型上，代理人可於實際樂業-十甲東及樂業-東英路口上，依時間與交通環境，採用趨近專家時制計畫控制號誌。

第一階段之代理人網路訓練流程如圖 4.1.17 所示，首先藉由隨機取樣出 6 個方向之車流量，查詢此車流量 6 元組對應於專家應用 PaSO 所擬訂之時制計畫；同時，同一車流量 6 元組亦輸入代理人之深度 Q 網路做為狀態，進而比對兩者選訂之時制計畫差異做為網路更新獎勵。在類神經網路之設計上，本計畫首先採用 2 層 10 單元全連結類神經網路，爾後分別針對 2 層 100 單元及 2 層 200 單元全連結類神經網路進行實驗分析。實驗結果發現，在較複雜之動作環境下，提高神經原數量可有效提高動作正確率。本計畫分別在晨峰與

昏峰改變神經元 10 倍與 20 倍進行探討，結果顯示 20 倍神經元在昏峰時可有效提高 AI 決策準確率。

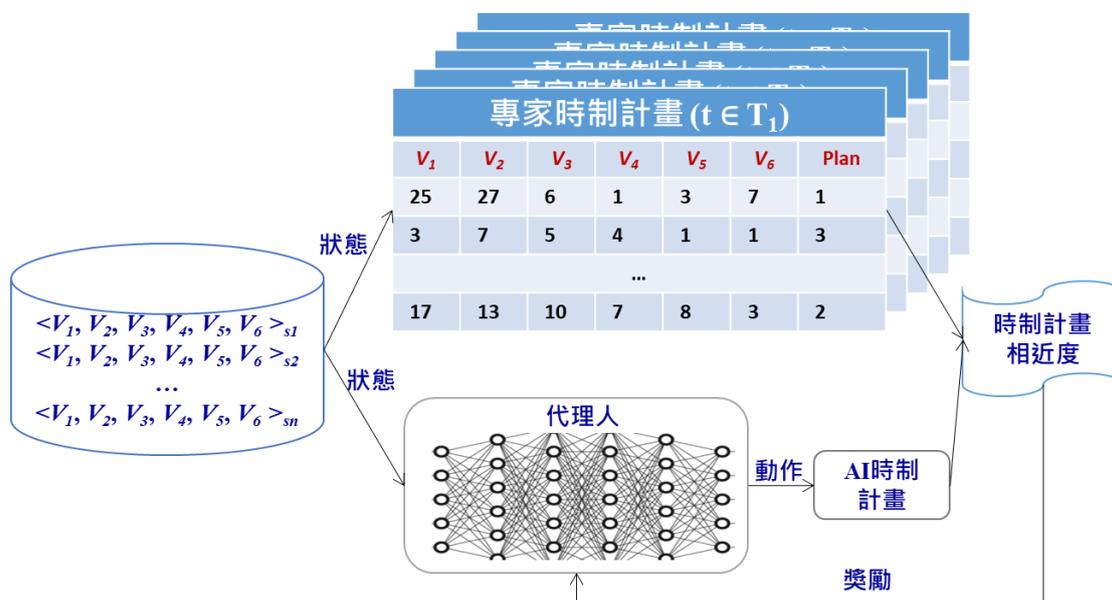


圖 4.1.17 AI 號誌控制之深度 Q 學習

資料來源：本計畫整理

第一階段網路更新之演算法運作流程如圖 4.1.18 所示，在網路初始化後，代理人不斷接收輸入狀態與輸出動作，並進行與專家動作相似度比較計算獎勵，待蒐集到預設的狀態-動作-獎勵數量，預設學習率以時間分差方式更新網路，直到代理人達到指定獎勵為止。其中時間分差更新公式為 $Q_{new}(s_t, a_t) := Q(s_t, a_t) + \alpha[r_{t+1} + \gamma \max_{a_i} Q(s_{t+1}, a_i) - Q(s_t, a_t)]$ ，其中 a 為動作， s 為狀態， α 為學習率， γ 為折扣因子。學習率 (α) 與折扣因子 (γ) 皆使用常見的訓練設定數值：學習率為 0.0001 (i.e. $\alpha = 0.0001$)，折扣因子為 0.99 (i.e. $\gamma = 0.99$)。

第一階段訓練初期，本計畫代理人的首要目標為學習專家模型之決策，已達到低風險與有效率的訓練。但若採取模仿學習，或是直接用專家決策等方式，此訓練出的代理人決策最佳仍為專家的決策方式，因此無法學習出超越專家模式的決策方法。因此，為克服此限制，如前述，本計畫 DQfB 在不同訓練目標採用的不同獎勵形式 (R_B)，已達到可學習專家模式的同時，也有機會學習到超越專家的決策。在訓練初期，本計畫 DQfB 採用的獎勵形式為 $R_B = \text{similarity}$ (相似度)，以專注學習專家決策。如同模仿學習，其學習資料為在此狀態 (s_t) 下應該採取何種動作 (a_t)，進行監督式學習，並

未需要在此狀態下採取某動作後對環境影響的下一個狀態 (s_{t+1})。因此，在此期間的時間分差更新公式為

$$\begin{aligned} Q_{new}(s_t, a_t) &:= Q(s_t, a_t) + \alpha[R_B - Q(s_t, a_t)] \\ &:= Q(s_t, a_t) + \alpha[\text{similarity} - Q(s_t, a_t)] \end{aligned}$$

若欲導入實際真實獎勵以學習超越專家的決策，則本計畫的DQfB採用的獎勵形式可改為 $R_B = \omega \cdot R_{real} + (1 - \omega) \cdot \text{similarity}$ 。此外，對於時間分差(Time difference, TD)更新公式中的更新時間分差目標(TD target)，其意義為估算未來可以得到的價值分數。Similarity(相似度)為 $1/e^{\text{abs}(\text{人工智慧模式輸出與專家時制之綠燈時間差})}$ 。當人工智慧模式輸出與專家時制之綠燈時間相同時，Similarity(相似度)為 $1/1=1$ ；當人工智慧模式輸出與專家時制之綠燈時間差愈大，Similarity(相似度)數值愈小。

若將真實獎勵以交通績效中的延滯為目標，則可參考相關延滯公式，例如：美國公路容量手冊(HCM)之 $d=DF \cdot d_1 + d_2$ 或 $d=d_1 \cdot PF + d_2 + d_3$ ，或為我國相關研究所校估之延滯公式；延滯公式具有適當地反映各種不同運行情況之實際車流移動與現場實際幾何、控制資料等特性，延滯的估計，一般依其影響變數與到達型態不同而提出不少估計方程式，一般考慮的影響因素主要有到達率、飽和流率、週期長度、有效綠燈時間、到達率...等。故其可依據容量與流量狀態反應交通特性，並可以迅速地建構相關模式，以使代理人可以針對所有流量狀態尤其是過飽和進行訓練，達到代理人的泛用性；而採用模擬軟體亦可為獎勵參數依據，但其需要較多的事前資料設定，採用真實資料則有相關風險考量。以計算在不同流量輸入下路網的最終延滯績效，當作估算在此狀態下做此時制計畫動作，所得到未來延滯獎勵的價值分數。因此，若以延滯為真實獎勵，並引入前述延滯公式，則此階段的时间分差(TD)更新公式可改為

$$\begin{aligned} Q_{new}(s_t, a_t) &:= Q(s_t, a_t) + \alpha[R_B - Q(s_t, a_t)] \\ &:= Q(s_t, a_t) + \alpha[\omega \cdot R_D(s_t, a_t) + (1 - \omega) \cdot \text{similarity} \\ &\quad - Q(s_t, a_t)] \\ R_B &= \omega \cdot R_D(s_t, a_t) + (1 - \omega) \cdot \text{similarity} \end{aligned}$$

其中 $R_D(s_t, a_t)$ 為延滯公式所計算的延滯獎勵。引入延滯公式的延滯獎勵，可以巨觀之車流角度計算路網延滯，避免強化學習直接與微觀車流環境互動蒐集資料，加速訓練效率，以完成時間分差(TD)

更新的疊代計算。另因以流量與時制計畫估算「路口延滯」，因此可以快速且均勻的對不同流量狀態皆進行訓練，而非以模擬的方式進行模擬，以達到代理人的泛用性。

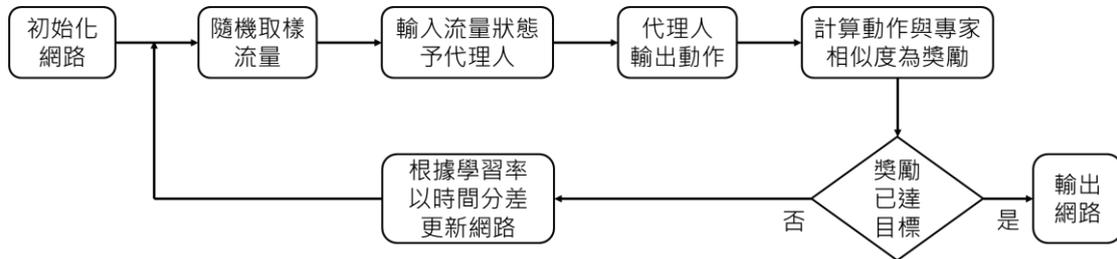


圖 4.1.18 網路訓練更新演算法流程

資料來源：本計畫整理

第二階段網路設計，代理人網路包含雙層結構，第一層由輸入之時間決定採用之時制計畫總週期長，第二層結合車流量與第一層之輸出以挑選在指定時間上與專家相近之時制計畫，如圖 4.1.19 所示。第二層之網路設計與第一階段之代理人網路設計相似，而第一層時段辨析前處理器為另一獨立之類神經網路，其輸入為時間(日、時、分)，輸出為時段分類，分類目前時間屬於三種時段中之哪一個，訓練時段辨析前處理器之網路時，會輸入時間，其動做為時段選擇，獎勵為二元獎勵，代理人正確選擇時段時才會得分。

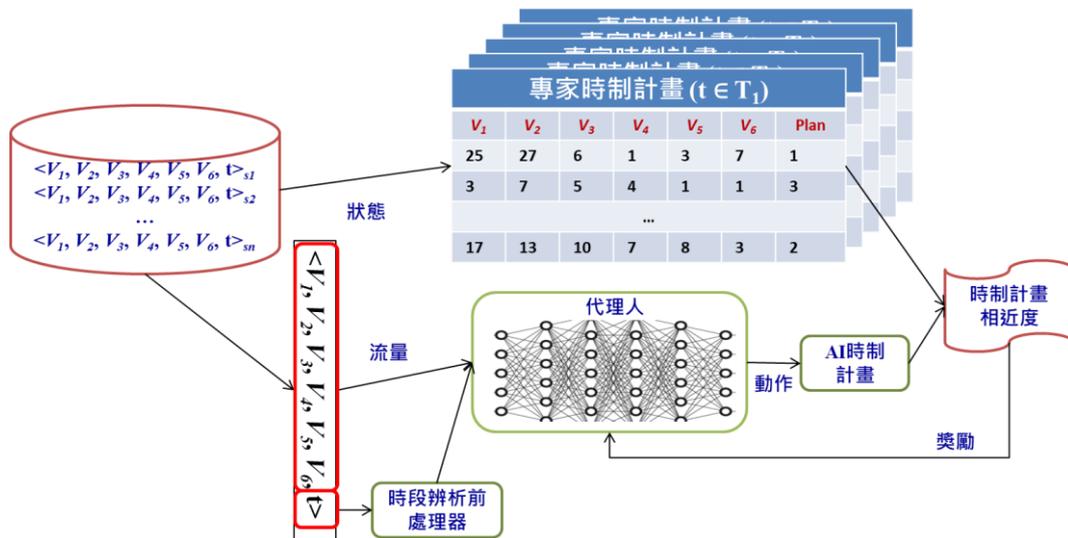


圖 4.1.19 多時段時制計畫演示法深度 Q 學習示意圖

資料來源：本計畫整理

3.AI 號誌控制強化式學習訓練之分析結果

本計畫使用之訓練資料集包含兩路口 6 個方向之車流量，各別時段資料集於每個方向之流量共有 0 至 44 共 45 種。此 45 種組合設定係依據現場流量調查結果，根據現有最大綠燈時間及調查車間距，

掌握每個方向每個最大綠燈時相長度最多可通過之車輛數為 45 部，為加速訓練，故將流量上限定為 45 部車；因此，共計有 45^6 種流量組合。訓練過程中會對每個方向之流量進行均勻採樣(Uniform Sampling)， 45^6 種流量組合中每一種流量組合被取樣機率均等，如圖 4.1.20 所示。於模仿專家之訓練，需令代理人能對於每一種狀態皆能採取與專家相近之動作，因此必須對完整狀態空間採以均勻採樣。

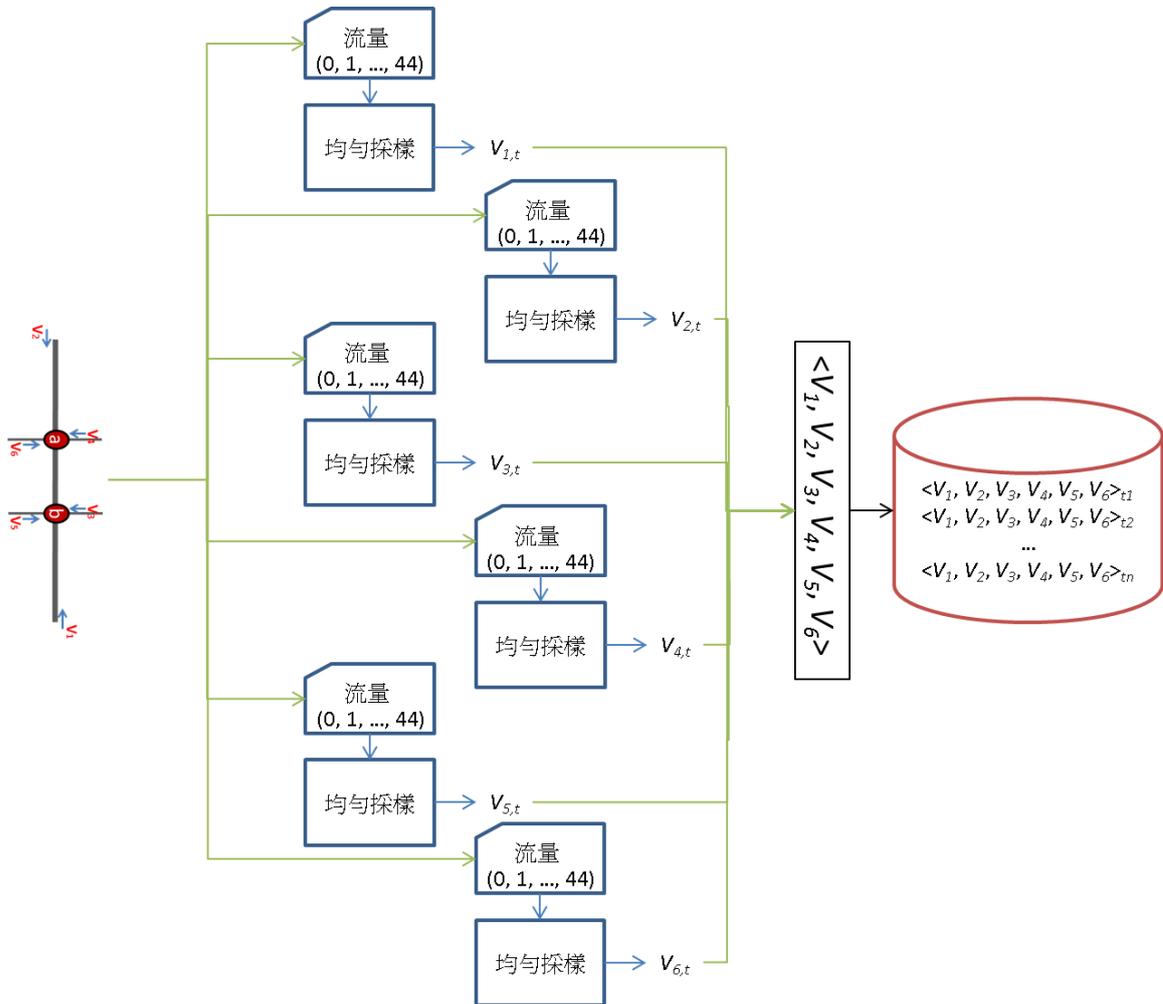


圖 4.1.20 訓練資料採樣示意圖

資料來源：本計畫整理

訓練一回合的定義是一個變換(transition)，包含目前狀態(state)，在這狀態下做的動作(action)，與得到的分數(reward)和下一個狀態(next state)的資訊。DQN 的訓練是在蒐集到一定程度的資料後 (本計畫為蒐集 100 個變換)，之後的每一回都會去蒐集資料的重現暫存區 (replay buffer)，隨機抽取一小部分的變換 (本計畫為 50 個變換) 對 model 做更新。另外，重現暫存區的資料量有數量限制，新的資料會取代舊的資料，本計畫設定的上限是 500 筆變換。所以訓練 1M

次在 DQN 是指做了約 1 百萬次的更新 (實際是 1M-100 次, 因為需要扣除一開始先蒐集 100 筆資料), 使用了約為 50 * 1M 的資料量 (當中有重複的資料) 來訓練模型。

經過 1M 回訓練, 代理人可取得 0.965 分獎勵, 繼續訓練至 5M 回, 代理人可取得 0.98 分獎勵, 繼續訓練至 12M 回, 代理人可取得 0.99 分獎勵, 如圖 4.1.21 所示。由於在本實驗設計與專家相符動作始得 1 分獎勵, 因此平均 0.99 分獎勵意謂訓練期 99% 可與專家一樣採取相同號誌控制策略。此外, 分析訓練至 5M 回之網路所使用的訓練之資料集中, 因本計畫採取均勻採樣, 故在所有流量組合中, 同時包含一些於實際交通上不常見的流量組合, 因此有以下現象: 在常採用之流量組合(專家常採用之時制計畫), 代理人可輸出與專家完全相同決策; 然而於訓練之資料集中, 代理人面對不常見情況下, 即專家不常採用之時制計畫(<3%), 代理人有 20% 機率輸出與專家不同決策。

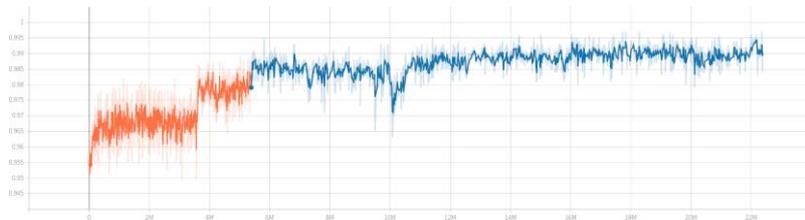


圖 4.1.21 單一時制計畫深度 Q 網路更新過程

資料來源: 本計畫整理

圖 4.1.22 至圖 4.1.24 說明各階段對於代理人之網路評估, 分別為初始網路、經 5M 回訓練之網路、經 12M 回訓練之網路之獎勵。由結果可發現代理人於訓練程序可不斷精進, 訓練的流量與時制對應關係之組合愈多, 其選擇到與專家相同的時制機率愈高, 輸出與專家更相似動作, 此亦證實設計之訓練演算法可行。

```
(base) payton@payton-C7X99-0CE-F:~/ittraffic/Ray_Regression_Controls$ python3 DQN_Six_MultiS
lz4 not available, disabling sample compression. This will significantly impact RLlib perf
2020-07-28 02:18:21,278 INFO resource_spec.py:212 -- Starting Ray with 11.96 GiB memory av
y=<bytes>, object_store_memory=<bytes>).
2020-07-28 02:18:21,393 WARNING services.py:923 -- Redis failed to start, retrying now.
2020-07-28 02:18:21,626 WARNING services.py:923 -- Redis failed to start, retrying now.
2020-07-28 02:18:21,868 INFO services.py:1165 -- View the Ray dashboard at localhost:8266
2020-07-28 02:18:23,279 INFO trainer.py:585 -- Tip: set framework=tfe or the --eager flag
2020-07-28 02:18:23,279 INFO trainer.py:612 -- Current log level is WARN. For more informa
2020-07-28 02:18:24,951 WARNING util.py:37 -- Install gputil for GPU system monitoring.
2020-07-28 02:18:26,703 WARNING util.py:37 -- Install gputil for GPU system monitoring.
Training...1 Ep reward: 0.711
Training...2 Ep reward: 0.959
Training...3 Ep reward: 0.947
Training...4 Ep reward: 0.946
Training...5 Ep reward: 0.953
Training...6 Ep reward: 0.954
Training...7 Ep reward: 0.94
Training...8 Ep reward: 0.951
Training...9 Ep reward: 0.943
Training...10 Ep reward: 0.944
2020-07-28 02:19:31,800 INFO trainable.py:423 -- Restored on [140, 112, 167, 16] from checkpoi
```

圖 4.1.22 初始網路之評估

資料來源: 本計畫整理

```

Training...1    Ep reward: 0.97
Training...2    Ep reward: 0.984
Training...3    Ep reward: 0.985
Training...4    Ep reward: 0.981
Training...5    Ep reward: 0.975
Training...6    Ep reward: 0.987
Training...7    Ep reward: 0.981
Training...8    Ep reward: 0.986
Training...9    Ep reward: 0.99
Training...10   Ep reward: 0.99
2020-07-28 02:33:04,188 INFO train
-4912
2020-07-28 02:33:04,188 INFO train
Current state: [19 40 14 18 16 35]
Action: 0; Plan: 0; Reward: 1
Current state: [ 4 25 19 28  9 20]
Action: 0; Plan: 0; Reward: 1
Current state: [44  3 35  1 23 38]
Action: 0; Plan: 0; Reward: 1
Current state: [12 30 27 44 38  0]
Action: 0; Plan: 0; Reward: 1
Current state: [ 8 28  2 33 13  3]
Action: 0; Plan: 0; Reward: 1
Current state: [43 33 17  1 36  5]
Action: 0; Plan: 0; Reward: 1
Current state: [27 28 15 20 19 44]
Action: 0; Plan: 0; Reward: 1
Current state: [34  3 34 25 14 38]
Action: 0; Plan: 0; Reward: 1
Current state: [38 35 42 19 40 18]
Action: 0; Plan: 0; Reward: 1
Current state: [44 35 35 10 16  8]
Action: 0; Plan: 0; Reward: 1

```

圖 4.1.23 訓練 5M 回網路之評估

資料來源：本計畫整理

```

Training...1    Ep reward: 1.0
Training...2    Ep reward: 0.983
Training...3    Ep reward: 0.985
Training...4    Ep reward: 0.981
Training...5    Ep reward: 0.995
Training...6    Ep reward: 0.984
Training...7    Ep reward: 0.986
Training...8    Ep reward: 0.991
Training...9    Ep reward: 0.987
Training...10   Ep reward: 0.988
2020-07-28 02:24:58,813 INFO traina
t-22314
2020-07-28 02:24:58,813 INFO traina
}
Current state: [ 0 31 20 29 29 29]
Action: 0; Plan: 0; Reward: 1
Current state: [ 1 42  5 14  3 36]
Action: 0; Plan: 0; Reward: 1
Current state: [10 44 41 20  3  1]
Action: 0; Plan: 0; Reward: 1
Current state: [30 17 20 38 23 18]
Action: 0; Plan: 0; Reward: 1
Current state: [12 34 10 37 29 28]
Action: 0; Plan: 0; Reward: 1
Current state: [ 7  5 35 40 29 30]
Action: 0; Plan: 0; Reward: 1
Current state: [34 35 36 41  5 35]
Action: 0; Plan: 0; Reward: 1
Current state: [ 2 10  2 41 17 37]
Action: 0; Plan: 0; Reward: 1
Current state: [24 43 28 35 21 33]
Action: 0; Plan: 0; Reward: 1
Current state: [29 38  3 35 18 41]
Action: 0; Plan: 0; Reward: 1

```

圖 4.1.24 訓練 12M 回網路之評估

資料來源：本計畫整理

本計畫設計特別抽樣之強化學習訓練，由於部分流量組合在均勻採樣下較不易拜訪到，且由於均勻採樣之因素，主要道路車流遠高於次要道路之情境鮮少出現，致使部分情境無法有效訓練，故本計畫針對特殊情境研擬特別抽樣訓練流程，整體流程如圖 4.1.25 及 4.1.26 所示，圖 4.1.25 呈現採樣系統架構，圖 4.1.26 說明取樣流程。本計畫針對樂業路兩主要路徑(V1 及 V2)、其他四支道路徑(V3~V6)，分別進行主要與次要路徑之流量採均勻採樣、邊界設定（透過設定流量上限，以使得的取樣之流量組合能符合實際環境之流量比），並以此產生相關流量組合，以針對主要道路流量遠高於次要道路之情境產生，加強特定情境之訓練。

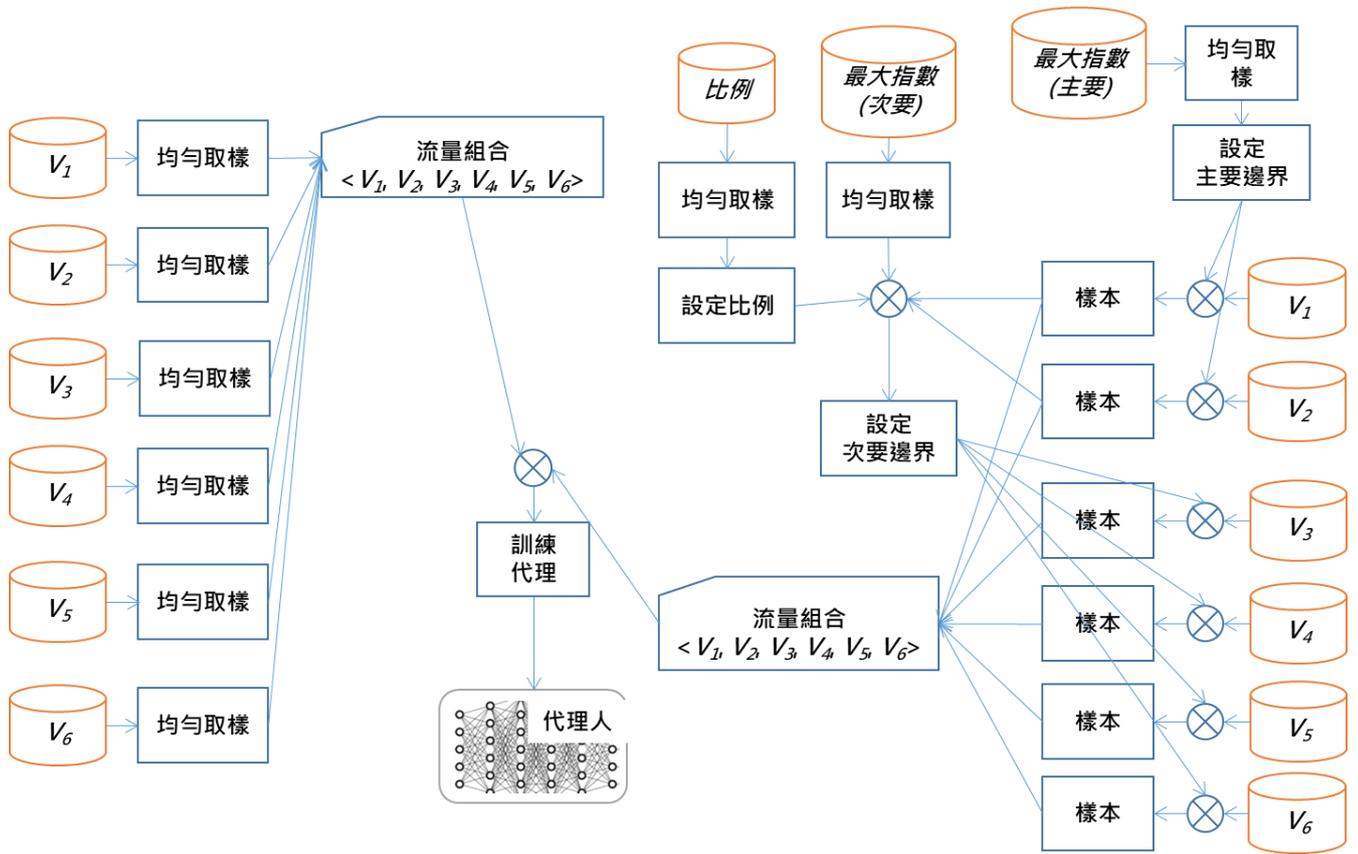


圖 4.1.25 AI 號誌控制整體訓練架構圖

資料來源：本計畫整理

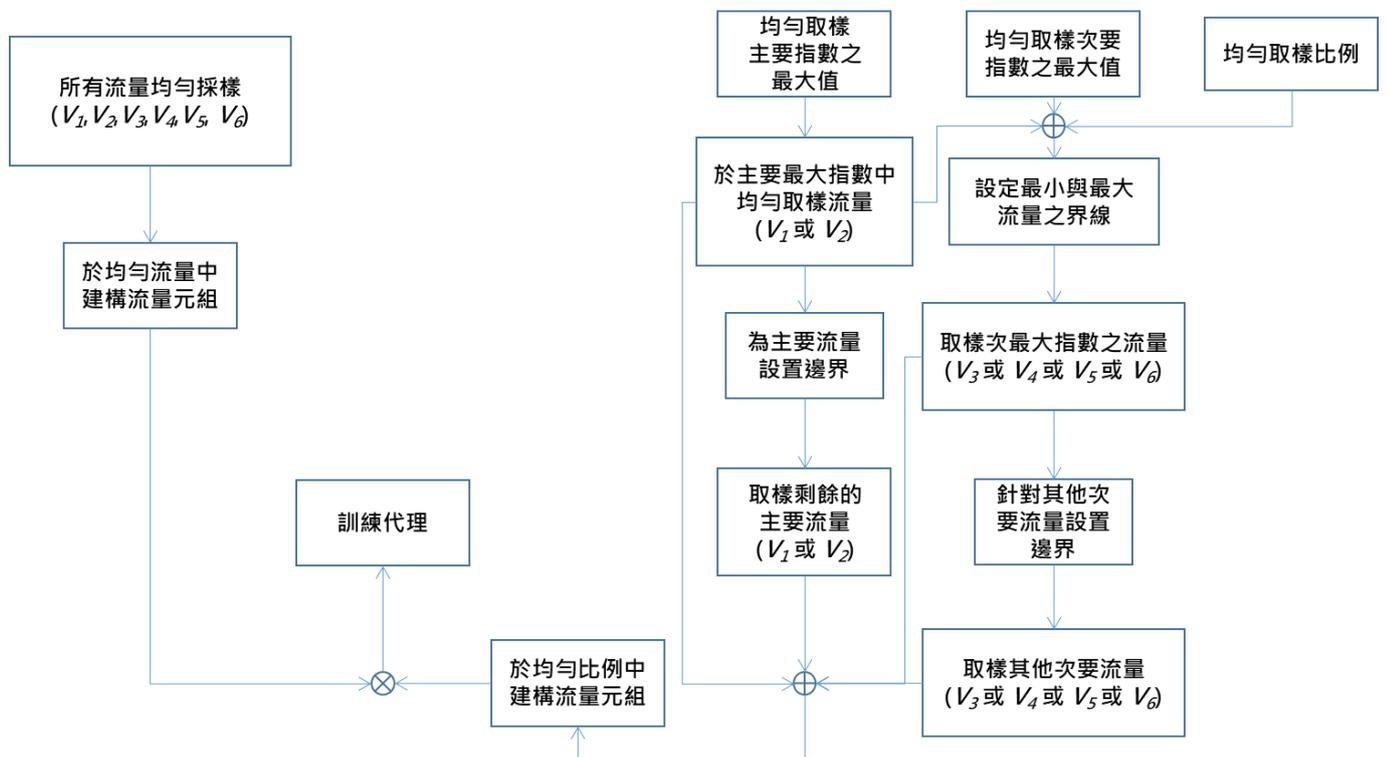


圖 4.1.26 AI 號誌控制特別抽樣訓練資料產生流程圖

資料來源：本計畫整理

4.AI 與專家經驗決策結果比較說明

本計畫統計「樂業-十甲東」及「樂業-東英」單一時段連續 12 週期車流量以作績效評估，其中幹道車流如圖 4.1.27 實線所示，將此流量分別進行專家時制計畫查詢及 AI 號誌控制輸出，於 12 個週期中僅有第 4 週期相異，並且之相異時制計畫於幹道綠燈秒數上差異僅 5 秒。

由上述試驗成果得知，本計畫已初步將 AI 號誌控制模式逼近於 PaSO 所產生最佳化石治計畫的專家決策能力，後續可透過增加訓練回合數，使 AI 號誌控制模式決策能力再微幅往上提升。本計畫亦針對類神經網路之架構進行調整並實驗測試準確率，如圖 4.1.28 所示，當類神經網路之寬度加大(增加全連接層的 node 數量)後，代理人能夠做出更為準確之決策，特別是對於平日晨峰與平日昏峰，此時段交通狀態較為複雜，成效更為顯著。

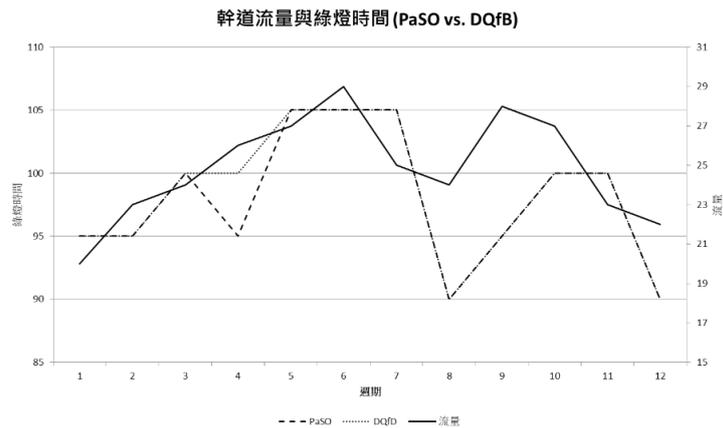


圖 4.1.27 PaSO 最佳化號誌時制與 AI 模式學習成果比較

資料來源：本計畫整理

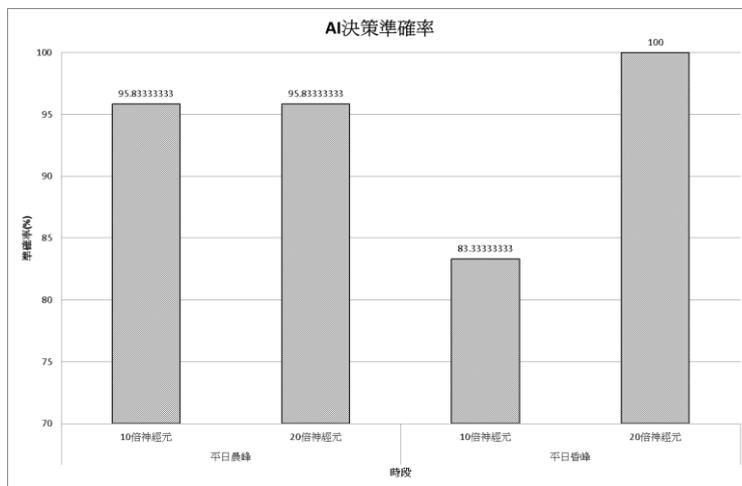


圖 4.1.28 類神經網路大小與決策準確率

資料來源：本計畫整理

4.2 AI 號誌控制之模擬分析

4.2.1 SUMO 模擬軟體

SUMO 是 Simulation of Urban MObility 的縮寫，由德國 Aerospace Center 開發，於西元 2001 年提供開源且免費使用的微觀交通模擬軟體，並可應用 TraCI (Traffic Control Interface) 控制介面，以 C++ 或 Python 語言撰寫所需邏輯運用其中。此軟體尚可模擬車輛在連續空間(Space-continuous)及離散時間(time-discrete)移動，設定不同車種的參數，讓車輛行駛在多車道行駛與變換車道，且能建立路口號誌，或設定道路上不同的路權，模擬結果將產出績效數據，做為評估交通路網運作效率。

本計畫模擬及訓練之系統架構如圖 4.2.1 所示，以交通微觀模擬軟體 SUMO 建立路網並進行進行不含機車的車流行為模擬、號誌控制模擬及定時時制與/依 AI 號誌控制模式之動態控制模擬，相關模式參數亦採用預設參數。於各路口之交通流量，首先採人工調查每分鐘路口實際流量，並將此流量資訊輸入 SUMO 予以模擬，並再與真實情況進行比對與微調相關參數。演示法之深度 Q 學習訓練運用 Ray V0.9.0 版函式庫，Ray 為開源機器學習函式庫(包括強化學習)，包含 RLlib 及 OpenAI Gym，提供多樣介面自訂訓練環境，並提供分散式訓練架構，透過 Ray 可更有效率建立訓練環境，以訓練代理人網路。該系統架構於 Linux Ubuntu 18.04.4 LTS 作業系統環境，以及採用 Python V3.6.8。本計畫尚未實作 SUMO TraCL。

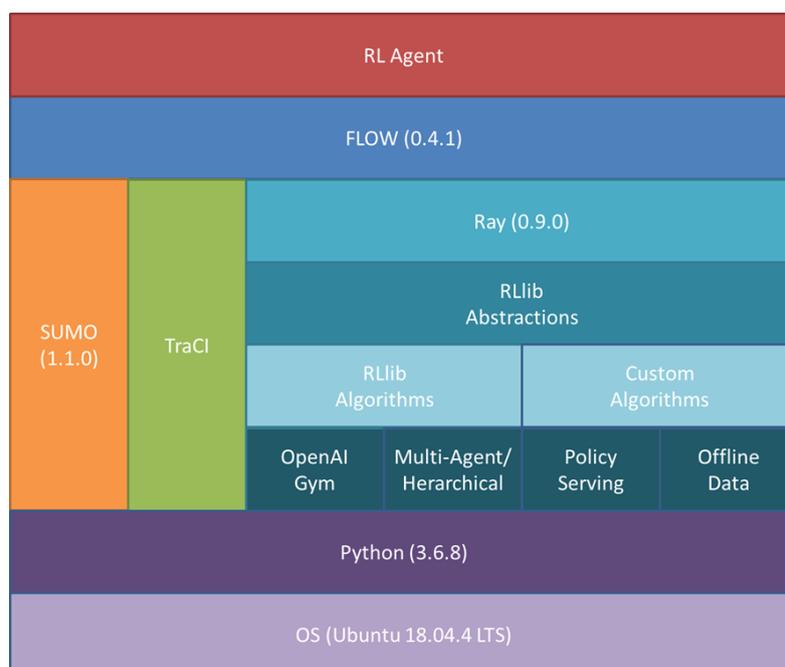


圖 4.2.1 模擬與訓練系統架構

資料來源：本計畫整理

4.2.2 AI 號誌控制模擬績效分析

1.道路幾何

SUMO 可透過外部地圖進行模擬環境建立，僅須再針對路口幾何，如車道數、車道寬等，進行調整。

2.時制計畫

調查現況路口時制計畫，且依據實際時制計畫內容輸入至 SUMO，檢視模擬環境中各路口號誌燈態、秒數及時差是否一致，確保後續車流在疏解時，能與現況時制計畫有相同的疏解效果。

3.交通流量

本計畫範圍為「樂業-十甲東」及「樂業-東英」，於人工流量調查階段以計畫範圍外圍上游流量進行調查，並以每分鐘紀錄進入之流量，詳細調查位置如圖 4.2.2 紅色箭頭所示。因此應用上述所調查的車流資料，同樣的方式在 SUMO 模擬環境中呈現，以相同節點(位置)與每分鐘流入的量進行輸入及校估，確保與真實環境中一致。此外，亦針對此兩路口進行交通轉向量調查，瞭解各方向的車流轉向比例，並在模擬環境中，將轉向比輸入至對應的方向，以符合實際車流轉向情形。



圖 4.2.2 流量校估說明

資料來源：本計畫整理

SUMO 中另有模擬機車模式，因其參數調校較為複雜，以目前調校參數狀況，其駕駛行為會與現實中差異較大，主要差異為部分機車會行駛內側，如圖 4.2.3 所示，與實際行為不同，亦會干擾車輛行進，因此考慮機車相對汽車疏解效率高，對整體車流影響較小，故本模擬以汽車流量為主。

5.改善前與改善後以 SUMO 模擬之績效分析

本計畫藉由 SUMO 進行事前與事後之模擬，由於兩路口時制計畫已於 PaSO 進行連鎖之規劃，故績效探討並不探討兩路口間之績效，而是探討樂業路主線之績效。

在平日尖峰號誌週期由 120 秒調整為 150 秒，離峰與假日控制時段之號誌週期則維持現狀，其主線與整體路網(主線為樂業路雙向，整體路網範圍如圖 4.2.6 箭頭範圍)。

- 平日晨峰部分，計畫範圍樂業路主線總延滯改善 61%(下匝道往西)、20%(往匝道方向)，整體路網總延滯改善 15%，總旅行時間改善 9%；
- 平日昏峰部分，計畫範圍樂業路主線總延滯改善 41%(下匝道往西)、17%(往匝道方向)，整體路網總延滯改善 15%，總旅行時間改善 15%；
- 平日離峰部分，計畫範圍樂業路主線總延滯改善 19%(下匝道往西)、20%(往匝道方向)，整體路網總延滯改善 12%，總旅行時間改善 5%；
- 週六離峰部分，計畫範圍樂業路主線總延滯改善 4%(下匝道往西)、增加 4%(往匝道方向)，整體路網總延滯增加 4%，總旅行時間增加 1%；
- 週日離峰部分，計畫範圍樂業路主線總延滯改善 31%(下匝道往西)、59%(往匝道方向)，整體路網總延滯改善 30%，總旅行時間改善 17%，相關路網路徑說明如圖 4.2.6 所示。

整體係指路網間各流向(含離開路口)之績效彙整，各情境模擬績效如表 4.2-1 至表 4.2-5 所示。綜上所述，根據路口 AI 號誌控制之 SUMO 模擬分析結果，本計畫提出利用 PaSO 所產生最佳化時制計畫的人工智慧號誌控制模，可有效改善實驗場域之總延滯與總旅行時間。



圖 4.2.6 研究場域路網路徑說明

資料來源：本計畫整理

表 4.2-1 平日晨峰模擬績效

路徑	總旅行時間			總延滯		
	事前	事後	前後變化	事前	事後	前後變化
1	62033	43566	30%	26385	10189	61%
2	51240	45563	11%	22384	17869	20%
3	42448	23574	44%	23814	7437	69%
4	12504	12572	-1%	4536	4571	-1%
5	3584	5637	-57%	3586	5646	-57%
6	8819	11091	-26%	5743	8212	-43%
7	7228	10583	-46%	5738	9418	-64%
8	6286	8108	-29%	3920	6277	-60%
整體	153133	138628	9%	68107	57915	15%

資料來源：本計畫整理

表 4.2-2 平日離峰模擬績效

路徑	總旅行時間			總延滯		
	事前	事後	前後變化	事前	事後	前後變化
1	42847	39013	9%	17882	14457	19%
2	31476	28818	8%	12296	9827	20%
3	27846	21660	22%	14383	8674	40%
4	9227	9965	-8%	3128	3854	-23%
5	9189	6855	25%	7108	4674	34%
6	3316	3603	-9%	2075	2370	-14%
7	7688	9682	-26%	5225	7164	-37%
8	7624	7412	3%	4391	4669	-6%
整體	123648	116915	5%	49665	43706	12%

資料來源：本計畫整理

表 4.2-3 平日昏峰模擬績效

路徑	總旅行時間			總延滯		
	事前	事後	前後變化	事前	事後	前後變化
1	68491	53403	22%	33071	19480	41%
2	91686	82140	10%	51808	43147	17%
3	50894	32707	36%	29942	13910	54%
4	29321	27555	6%	16193	14810	9%
5	33783	27641	18%	26886	21897	19%
6	13928	13733	1%	10356	10448	-1%
7	19793	22938	-16%	14621	18148	-24%
8	12803	13703	-7%	8097	9393	-16%
整體	274211	246883	10%	145834	123457	15%

資料來源：本計畫整理

表 4.2-4 週六昏峰模擬績效

路徑	總旅行時間			總延滯		
	事前	事後	前後變化	事前	事後	前後變化
1	43546	42942	1%	16579	15911	4%
2	23785	24367	-2%	9829	10203	-4%
3	28611	26960	6%	14573	13049	10%
4	7400	7610	-3%	2617	2728	-4%
5	2350	2295	2%	2903	2874	1%
6	2175	2056	5%	1763	1612	9%
7	4327	5107	-18%	3555	4566	-28%
8	3983	4707	-18%	2865	3811	-33%
整體	91693	93023	-1%	37804	39286	-4%

資料來源：本計畫整理

表 4.2-5 平日昏峰模擬績效

路徑	總旅行時間			總延滯		
	事前	事後	前後變化	事前	事後	前後變化
1	44261	36184	18%	16317	11186	31%
2	38212	24106	37%	19081	7807	59%
3	26549	20924	21%	12683	7341	42%
4	14873	7164	52%	7469	1970	74%
5	1578	1667	-6%	1519	1580	-4%
6	2872	3072	-7%	1987	2487	-25%
7	3828	4564	-19%	2838	4034	-42%
8	3731	4573	-23%	2545	3572	-40%
整體	105254	86900	17%	44504	30959	30%

資料來源：本計畫整理

4.3 AI 號誌控制系統之實測規劃

4.3.1. AI 路側設備硬體架構

在動態號誌控制實行於實際路網上，AI 影像偵測設備、e-Tag 讀取器與 AI 代理人(工業用電腦)間採用 Web API 進行狀態與動作資料之傳輸(如圖 4.3.1 所示)。AI 代理人工業用電腦硬體規格，如圖 4.3.2 所示；代理人會於設定取樣期間，對 AI 影像偵測設備與 e-Tag 讀取器發送狀態之 GET 需求，AI 影像偵測設備與 e-Tag 讀取器會回報所蒐集與統計路口交通參數(如車流量)。其後代理人會將該狀態輸入以經過訓練之 AI 類神經網路，並輸出決策之動作，最後將此動作轉換為號誌控制訊號傳送至號誌控制器。當完成此流程後，代理人會再發送 GET 需求，以進行下一階段之決策流程。

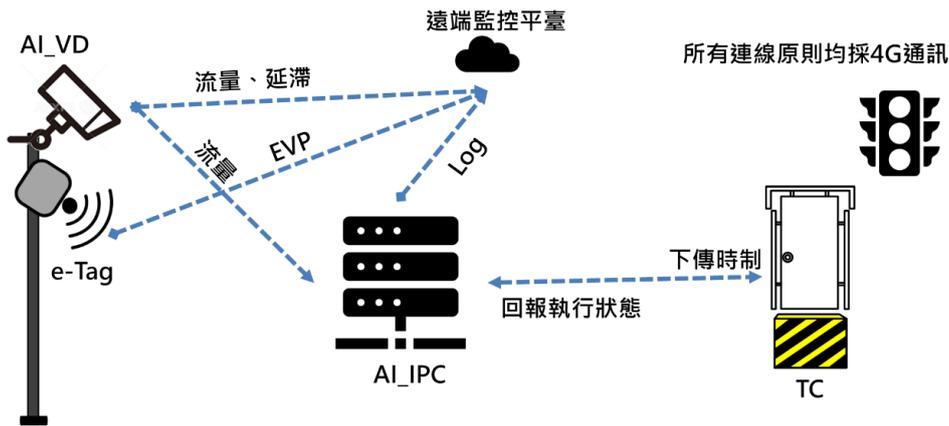


圖 4.3.1 AI 號誌控制代理人暨路側設備傳輸示意

資料來源：本計畫整理

Specifications

Model Name		ARK-1551-S6A1
Processor System	CPU	Intel® Core i5-8365UE
	Frequency	1.6 GHz, turbo burst up to 4.1 GHz
	Core Number	4
	L3 Cache	6MB
	BIOS	AMI UEFI 256Mbit
Memory	Technology	DDR4 2400MHz
	Max capacity	32GB, each memory slot support up to 16GB
	Socket	2 x 260-pin SO-DIMM
Graphics	Chipsset	Intel UHD Graphics 620
	Graphic Engine	Gen9 Low Power; 24 (UHD 620) /12(UHD 610) Execution Units Media Codec Supported: H.264, MPEG2, MVC, VC-1, WMV9, H.265 / HEVC 3D HW Acceleration: OpenGL 4.5, DirectX* 11.3/12, OpenCL* 2.1
	Display Interface	HDMI: 1 x HDMI 1.4b, 4096 x 2160@30Hz VGA: 1 x VGA, 1920 x 1080@60Hz DP: 1 x DP 1.2, 4096 x 2304 @ 60Hz (*co-lay with VGA, by project support with MOQ = 30)
	Dual Display	HDMI + VGA (Default) ; HDMI + DP (By project support, MOQ 30)
Ethernet	LAN1	10/100/1000 Mbps Intel i210GbE, support Wake On LAN
	LAN2	10/100/1000 Mbps Intel i219GbE, support Wake On LAN
Audio	Interface	Realtek AL C892, High Definition Audio, Mic-in or Line-out
I/O Interface	Serial Ports	4 x RS-232/422/485 support from 50 bps to 921.6 kbps, with auto flow control. COM3 with 5V/12V power, by jumper setting
	USB Ports	4 x USB 3.1 Gen2, Type A connector
	GPIO	8-bit programmable DIO
Expansion	Mini PCIe	1 x full-size mPCIe with 1x nano SIM holder (PCIe x2, USB 2.0x1, UIM, SATA x1)
	M.2	1 x M.2 2230 E key for WiFi module (PCIe x2, USB 2.0x1)
Storage	SSD/HDD	1 x Swappable 2.5" SATAIII drive bay (compatible with 7mm height)
	mSATA	1 x full-size mSATA (share with mPCIe slot)
	PCIe	Support 2x Advantech SQF PCIe2 NVMe storage (1 x M.2 2230 E Key + 1 x mPCIe)
Other	WatchDog Timer	255 levels timer interval, setup by software
	TPM	SLB9665XQ2.0
	Case Open	Support
Software Support	Microsoft Windows	Windows 10 Enterprise
	Linux	Support by project
Power Requirement	Power Type	ATX/AT
	Power Input Voltage	12 ~ 24 V _{DC} @ -10%/+20%
	Power Adaptor	Celeron 4305UE: AC to DC, 90W (Optional) i5-8365UE: AC to DC, 90W for 0 ~ 40 °C (Optional) AC to DC, 120W for -20 ~ 55 °C (Optional)
Power Consumption	Typical	13.87 Watt
	Max.	47.12Watt
Mechanical	Construction	Aluminum housing
	Mounting	Wall Mounting (Default); VESA & DIN-Rail Mounting (Optional)
	Dimensions (W x H x D)	195 x 55 x 140 mm (7.68" x 2.16" x 5.52")
	Weight	Net Weight: 1.9KG; Gross Weight: 2.6KG
Environment	Operating Temperature	With extended temp. peripherals: -20 ~ 55 °C (-4 ~ 131 °F) with 0.7 m/s air flow With 2.5 inch hard disk: 0 ~ 40 °C (32 ~ 104 °F) with 0.7 m/s air flow
	Storage Temperature	-40 ~ 85 °C (-40 ~ 185°F)
	Relative Humidity	95% @ 40 °C (non-condensing)
	Vibration during Operation	With SSD: 3 Grms, IEC60068-2-64, random, 5~500 Hz, 1hr/axis
	Shock during Operation	With SSD: 30 G, IEC-60068-2-27, half sine, 11 ms duration
	EMC	CE/FCC Class B, CCC, BSMI
	Safety	UL, CB, CCC and BSMI

圖 4.3.2 AI IPC 硬體規格

資料來源：本計畫整理

4.3.2. AI 動態號誌監控平臺

為呈現 AI 號誌控制運行即時資訊本，研究透過儀表板方式進行呈現，

除提供 AI 號誌控制運作結果，同時顯示系統是否正常運作，以為相關因應。圖 4.3.3 為監控平臺運作儀表板，面板各部分說明如下。

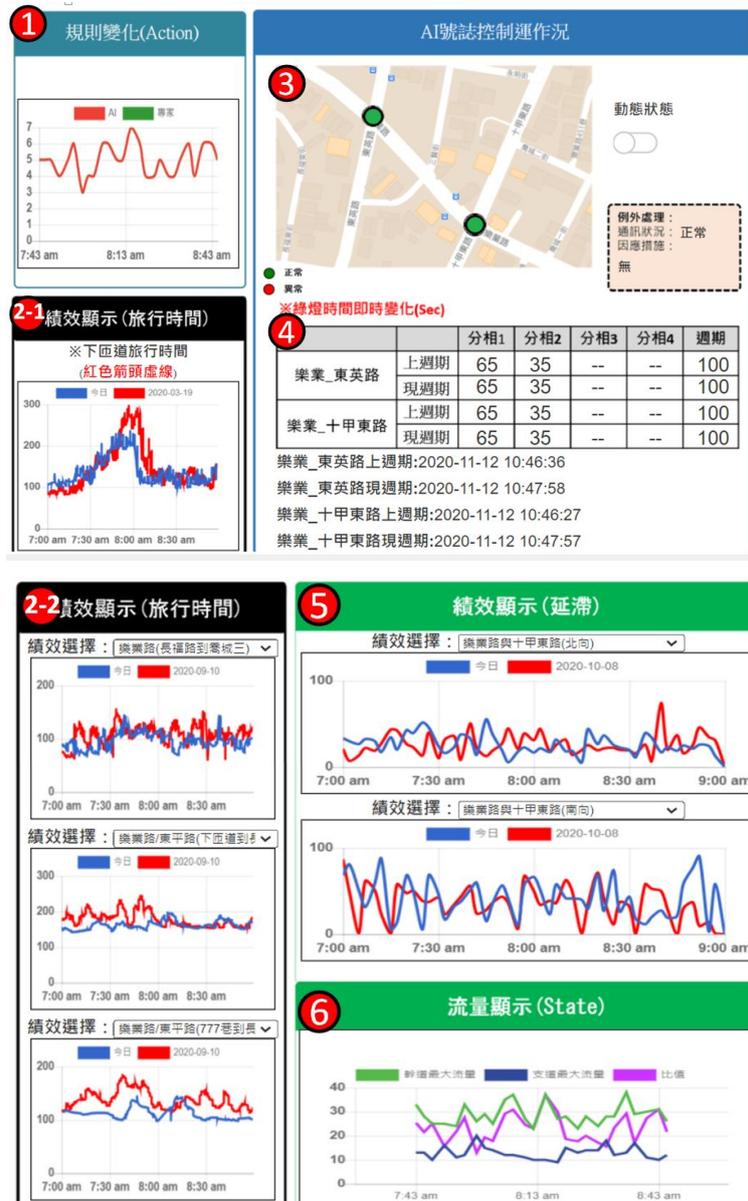


圖 4.3.3 AI 動態號誌控制監控平臺

資料來源：本計畫整理

● 面板 1 - 規則(時制策略)變化

縱座標為時制計畫編號，編號愈大表示幹道綠燈秒數愈多，橫向座標為時間序列，表示該時段由第一週期至最末週期；主要檢視 AI 與專家於該時段所執行時制策略之結果，即為目前輸出之時制計畫編號，並可比對兩者間之差異，使管理者掌握目前 AI 號誌控制運作之狀況。

● 面板 2 - 績效顯示-旅行時間

提供即時績效運作比較折線圖，績效項目可提供選擇顯示，折線圖顯示即時績效項目以及事前尚未運作 AI 號誌控制時抓取某天資料做為比較基準，以確定目前運作效果是否持續有效。

2-1 主要顯示匝道上游車流之旅行時間，以瞭解匝道上車流的壅塞狀況；2-2 顯示本計畫主要路徑旅行時間，分別為樂業路(長福路→喬城三)、樂業路(下匝道→長福路)、樂業路(777 巷→長福路)等三段路徑的即時資訊，讓管理者掌握主要路徑之車流順暢狀況。

- 面板 3 - 地理位置

地圖示意圖主要是讓使用者能夠有其方位概念，並在檢視資訊時能夠有所對照；地圖中可顯示號誌控制器的即時連線狀況。右邊提供動態控制開關，提供使用者在特殊情況下能夠關閉控制讓系統能夠切換回定時時制。下方則顯示目前運作的設定參數值與例外處理，例外處理顯示系統是否因為某些問題而已切回定時制，例如最常見的問題為通訊問題，當所有需求設備有一處斷訊，可能影響系統判斷與運作，則系統會自動取消動態控制切回定時制，此時在例外處理區塊則會顯示通訊異常與因應措施為關閉動態，切回原時段之定時時制。

- 面板 4 - 運作狀況

畫面最下方為顯示目前所執行各路口時制計畫內容，其中包含本週期與上週期各時相的運作秒數與週期大小(含紅黃秒數)，並且每週期更新目前執行的策略，以方便檢視系統控制狀況；本區塊下方為時制計畫所更新之時間，瞭解系統運作執行狀況。

- 面板 5 - 績效顯示-延滯

提供即時偵測之延滯比較折線圖，折線圖顯示即時績效項目以及事前尚未運作動態控制時抓取某天資料做為比較基準，以確定目前運作效果是否持續有效。

- 面板 6 - 流量資訊顯示

提供即時偵測之幹道最大流量(於樂業路往市區及往太平兩方向車流量取最大者)、支道最大流量(於兩路口南北雙向 4 處支道車流量取最大者)與幹支道最大流量比值(原比值乘以 10 倍便於觀察)，可瞭解幹支道車流變化狀況。

4.3.3 系統上線流程說明

為使 AI 號誌控制實際運作時之風險降至最低，本計畫將實作劃分為 9

個階段，包含：事前績效蒐集，以及 AI 號誌控制內部測試、設備安裝、時制計畫設定、虛擬測試、時制微調、上線測試、上線運作及事後績效蒐集。各階段說明如後。

1. 事前績效蒐集：利用相關設備，蒐集延滯、旅行時間...等相關數據蒐集，並藉由空拍畫面掌握相關車流狀況。
2. AI 號誌控制內部測試：測試偵測器資料、號誌控制程式、AI 演算法與號誌控制器之間的程序穩定度。
3. AI 相關設備安裝：內部測試穩定後，將 AI_IPC 安裝於現場，並進行連線測試與程式檢測。
4. 時制設定：委託臺中市政府交通局協助相關路口號誌控制器之時制計畫設定。
5. 時制微調：針對各時段之基礎時制進行現場微調，本計畫業已於 109 年 10 月 7 日由臺中市政府交通局維修隊協助設定完成並開始運行。本計畫於 109 年 10 月 12 日開始進行為期一週之時制微調，經現場勘查與利用現場攝影機進行人工判別整體路網車流狀況，各路口號誌運作符合設定參數，舉凡「樂業-東英」與「樂業-十甲東」之基礎時制設定為同亮，現場觀察於 16:31:04 兩張截圖畫面中(如圖 4.3.4 所示)，可發現相同時間由紅燈變換為綠燈，車輛通行符合預期，且鄰近路口時差設定符合車流特性，故不進行調整。



圖 4.3.4 「樂業-東英」與「樂業-十甲東」實際同亮畫面

資料來源：本計畫整理

6. AI 號誌控制虛擬測試：本計畫針對 AI 號誌控制進行為期 3 日之虛擬測試，期間 AI 號誌控制將蒐集相關偵測設備數據並進行策略研擬，但不執行下傳時制計畫之動作，僅記錄 AI 所運算之時制計畫結果，並驗證此結果與設備是否穩定，若穩定且策略符合預期，則在進行下傳之動作。本計畫藉由 AI 產出之時制與專家進行比對，判別 AI 選擇是否與專家差異過大，虛擬測試過程相似度均達 8 成以上，AI 選擇與專家

選擇之時制差異，普遍均在一個分相時間差異 5 秒，在總計 21 小時 (576 個週期) 測試中，包含晨峰 6 小時(144 個週期)、離峰 6 小時(216 個週期)、昏峰 9 小時(216 個週期)，僅兩次 AI 時制選擇與專家選擇分相秒數差異達 20 秒。此虛擬測試可驗證 AI 時制選擇已達一可靠程度，後續將再進行持續訓練，降低差異率，各情境每日差異率請參閱表 4.3-1 及圖 4.3.5 至圖 4.4.7。

表 4.3-1 虛擬測試階段各情境 AI 與專家之差異率

情境\序號	一	二	三	平均
晨峰(07:00~09:00)	89.58%	87.50%	83.33%	86.81%
離峰(13:00~15:00)	98.61%	95.83%	97.22%	97.22%
昏峰(16:00~19:00)	86.11%	90.28%	93.06%	89.82%

資料來源：本計畫整理

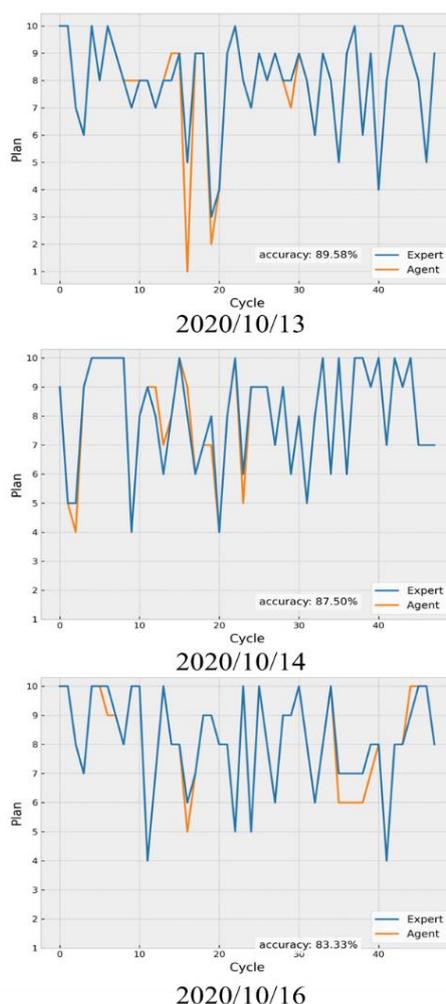
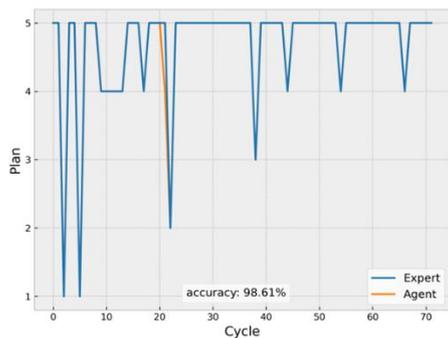
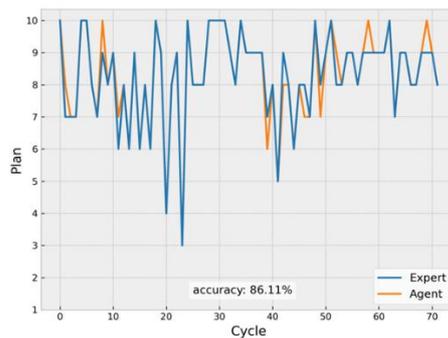


圖 4.3.5 晨峰虛擬測試 AI 與專家之號誌時制規劃

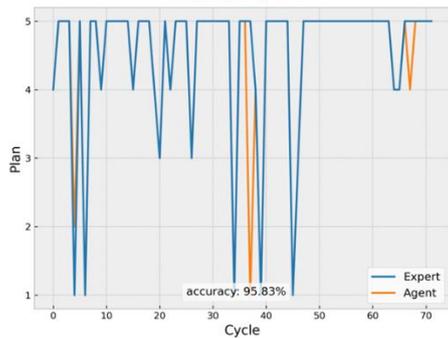
資料來源：本計畫整理



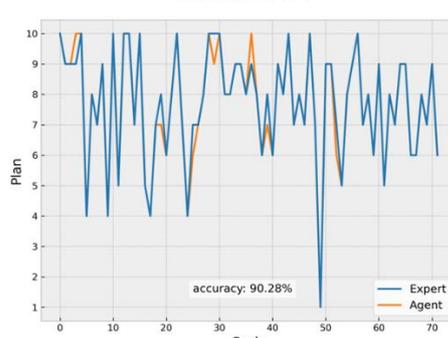
2020/10/12



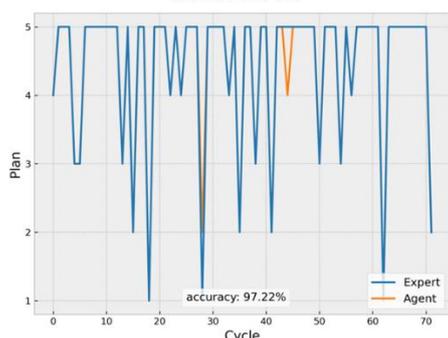
2020/10/12



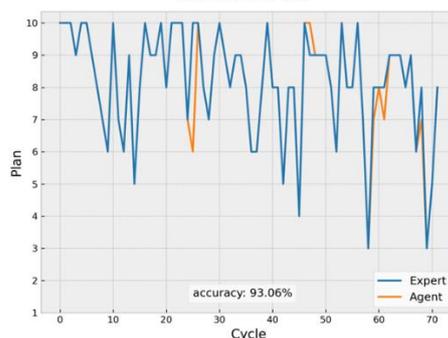
2020/10/13



2020/10/13



2020/10/14



2020/10/14

圖 4.3.6 離峰虛擬測試 AI 與專家之號誌時制規劃

圖 4.3.7 昏峰虛擬測試 AI 與專家之號誌時制規劃

資料來源：本計畫整理

資料來源：本計畫整理

針對突發狀況因應，本計畫 AI 號誌控制下傳均採用交通部都市交通通訊協定 3.0 版，於運作階段，透過 5F10 訊息啟動動態控制策略，並利用 5F18 訊息設定執行時制，藉由 5F44 訊息與 5F45 訊息掌握執行狀態，且每一時制計畫編號下傳，均有設定其有效執行時間。在各時制計畫編號內容均已存放於號誌控制器，可將切換時制之風險降到最低，即便無法成功下傳，執行內容將為該時段之定時號誌控制時制內容。倘若幹道上游偵測器異常，則將自動恢復定時時制。當發生通訊中斷時，例如：關鍵 AI 影像偵測器無法回報流量資訊，則停止動態控制；當 5F10 訊息的執行時效過後，即恢復定時時制。

若為非關鍵設備(支道上游偵測器)通訊異常,則 AI 號誌控制正常運作,原偵測流量將改用歷史調查資料做為流量輸入預設值;此外,監控平臺中亦可藉由交管人員手動啟閉 AI 號誌控制系統,圖 4.3.8 呈現本計畫手動關閉一幹道偵測器, AI 號誌控制之應變措施,在掌握到幹道偵測器異常時,隨即自動關閉動態控制,並回復原 TOD 定時時制。

Time	V1	V2	V3	V4	V5	V6	Expert	Agent
2020/10/13 07:30	17	24	12	6	12	10	8	8
2020/10/13 07:32	23	26	10	9	14	8	7	7
2020/10/13 07:35	24	31	8	2	8	15	8	8
2020/10/13 07:37	13	29	13	12	12	11	8	9
2020/10/13 07:40	21	26	6	9	10	7	9	9
2020/10/13 07:42	19	28	12	9	19	6	5	1
2020/10/13 07:45	22	30	10	7	4	12	9	9
2020/10/13 07:47	21	31	9	6	13	5	9	9
2020/10/13 07:50	17	29	4	10	25	8	3	2
2020/10/13 07:52	24	23	4	6	18	18	4	4
2020/10/13 07:55	25	37	5	5	16	10	9	9
2020/10/13 07:57	11	31	6	7	6	6	10	10
2020/10/13 08:00	14	31	16	5	11	7	8	8
2020/10/13 08:02	11	27	9	5	15	8	7	7
2020/10/13 08:05	18	35	14	4	0	15	9	9
2020/10/13 08:07	16	25	12	10	1	8	8	8
2020/10/13 08:10	19	32	5	5	12	8	9	9
2020/10/13 08:12	19	35	12	5	16	14	8	8
2020/10/13 08:15	16	27	9	7	10	14	8	7
2020/10/13 08:17	13	26	5	9	11	10	9	9
2020/10/13 08:20	11	27	14	6	10	13	8	8
2020/10/13 08:22	16	34	6	8	22	8	6	6
2020/10/13 08:25	13	32	10	6	12	7	9	9
2020/10/13 08:27	8	27	7	5	13	7	8	8
2020/10/13 08:30	10	22	9	6	15	6	5	5
2020/10/13 08:32	11	25	8	1	10	8	9	9
2020/10/13 08:35	16	26	7	3	6	6	10	10
2020/10/13 08:37	6	28	17	7	9	8	6	6
2020/10/13 08:40	20	28	11	5	9	7	9	9
2020/10/13 08:42	14	數據異常	5	11	20	6		資料異常系統停止運作 並回復定時時制

圖 4.3.8 偵測器異常下之 AI 號誌控制應變措施

資料來源：本計畫整理

7. AI 號誌控制上線測試：於非尖峰時段測試 AI 號誌控制下傳時制計畫程序是否可正常運作,採用不同編號但相同時制內容進行測試),現場亦委由義交配合突發狀況協助交通疏導。
8. AI 號號誌控制上線實際運作：遠端觀察運作狀況,必要時派員至現場處理或調整號誌控制運作,同時系統亦已包含相關應變措施。
 - (1) AI 號誌控制時制下傳採用通訊協定 3.0 版之 5F10 訊息啟動動態控制,以及 5F18 訊息設定執行時制。
 - (2) 當關鍵設備(幹道上游偵測器)異常,則所採取之策略為恢復定時,

待 5F10 訊息執行時效過後即恢復定時時制。

(3) 當關鍵設備(支道上游偵測器)異常，AI 號誌控制維持正常運作，其偵測流量將該採歷史調查資料做為流量輸入之預設值。

(4) 監控平臺可手動啟閉 AI 號誌控制。

9. 事後績效蒐集：利用相關設備，蒐集延滯、旅行時間...等相關數據蒐集，並藉由空拍畫面掌握相關車流狀況。

AI 號誌控制實地場域運作之前述 9 個階段及其作業時程，彙整如圖 4.3.9。

編號	工項	9/14-9/20	9/21-9/27	9/28-10/4 (中秋節)	10/5-10/11 (國慶日)	10/12-10/18	10/19-10/30	11/02-11/15
1	事前績效蒐集							
2	AI號誌內部測試							
3	AI設備安裝							
4	時制設定							
5	時制微調					10/13開始		
	平日晨峰、離峰與昏峰 三時段現場車流觀察(確認 時差、時比)							
	假日現場車流觀察(確認 時差、時比)							
6	AI號誌虛擬測試							
	比對RL與模式計算之時 制計畫結果							
	模擬設備異常AI號誌因 應機制							
7	AI號誌上線測試							
8	AI號誌上線運作							
9	事後績效蒐集							
	備註					10月16日提送 虛擬測試報告至 運研所與交通局	10月23日提送 測試計畫書至運 研所與交通局	11月02日正式 上線

圖 4.3.9 AI 號誌控制實地場域運作之 9 個階段及其作業時程

資料來源：本計畫整理

4.3.4 交通管理儀表板

交通管理儀表板主要用於偵測設備監控及資料查詢功能，內容包括「現行設備狀況畫面」、「路口/路段速度變化」、「系統運作妥善率」、「事件列表」、「系統相關統計報表」等五大項，本計畫針對 AI 影像偵測設備所蒐集之路段車流量及轉向交通量於「系統相關統計報表」中進行擴充，新增轉向量報表，且亦同時考量未來可能需要多種不同數據得比較，以利後續管理者可參看相關數據資料，故新增「統計資料比較查詢」功能，監控儀表板首頁如圖 4.3.10 所示，系統架構如圖 4.3.11 所示。



圖 4.3.10 AI 交通管理儀表板系統_預設畫面

資料來源：本計畫整理

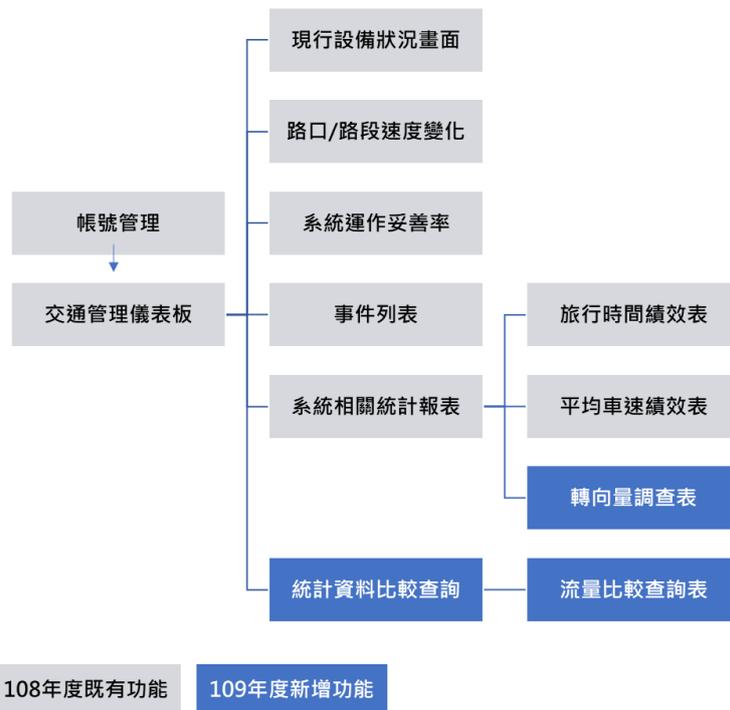


圖 4.3.11 AI 交通管理儀表板系統_功能架構圖

資料來源：本計畫整理

1. 轉向交通量報表

本報表主要針對已完成安裝之設備進行偵測後取得的車種數量進行轉換後產出之各方向轉向數據。目前已納入之設備為「樂業十甲往西北」、「樂業十甲往東南」，在前端頁面上僅可以查詢日前三個月資料，最小查詢區間以時段區分，如欲查詢 8/12 資料，須至 8/13 始可以查詢，後端資料則是每日每時產生一個一分鐘的檔案，以檔案方式讀取，當使用者進行搜尋後即可動態產出對應的轉向量圖，也可提供報表匯出的資料，目前車當量轉換設定則如表 4.3-2 所示，而系統相關畫面如圖 4.3.12、表 4.3-3 所示。

表 4.3-2 車當量轉換設定表

車種	大型車 (truck、bus)			小型車 (car、mid)			機車 (motorcycle)		
	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉
PCE	2.3	1.8	2.7	1.5	1.0	1.08	0.5	0.42	0.45

資料來源：本計畫整理



圖 4.3.12 AI 交通管理儀表板系統_轉向量報表查詢

資料來源：本計畫整理

表 4.3-3 AI 交通管理儀表板系統_轉向量報表

路口轉向交通量調查資料表																				
車類	方向	時間	大型車(左轉)	大型車(直行)	大型車(右轉)	小型車(左轉)	小型車(直行)	小型車(右轉)	機車(左轉)	機車(直行)	機車(右轉)	PCU(左)	PCU(直)	PCU(右)	路口-進出車計	路口-進入車計	路口-出向車計	路口-進出車計	路口-進入車計	
1	1	00:00-00:05	0	0	0	2	3	2	0	0	0	3	3	216	816	0	0	1503	816	0
2	2	00:00-00:05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1503	0	816
3	3	00:00-00:05	0	0	0	0	0	0	1	1	3	0	0	0	3	0	0	1503	3	0
4	4	00:00-00:05	0	0	0	0	3	0	0	0	0	0	0	0	3	0	0	1503	3	0
5	1	00:01-00:02	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	484	10	2
6	2	00:01-00:02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	484	10	2
7	3	00:01-00:02	0	0	0	0	4	2	0	2	0	0	0	0	484	216	7	2	10	7
8	4	00:01-00:02	0	0	0	0	1	0	0	0	0	0	0	0	1	0	1	10	1	0
9	1	00:02-00:03	0	0	0	0	6	0	0	0	0	0	0	0	6	0	6	284	121	6
10	2	00:02-00:03	0	0	0	0	2	0	0	1	0	0	0	0	2	0	2	684	121	6
11	3	00:02-00:03	0	0	0	0	2	0	0	2	0	0	0	0	284	0	284	6	121	6
12	4	00:02-00:03	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	684	121	6
13	1	00:03-00:04	0	0	0	0	4	0	0	0	0	0	0	0	4	0	4	968	4	968
14	2	00:03-00:04	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	968	4	968
15	3	00:03-00:04	0	0	0	0	4	0	0	4	0	0	0	0	968	0	968	4	968	0
16	4	00:03-00:04	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	968	0	968
17	1	00:04-00:05	0	0	0	0	5	0	1	0	0	0	0	0	5	5	0	744	1294	5
18	2	00:04-00:05	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	744	0	1294
19	3	00:04-00:05	0	0	0	0	1	0	0	7	0	0	0	0	394	0	394	5	1294	5
20	4	00:04-00:05	0	0	0	1	0	0	4	0	0	0	0	0	3	0	3	1294	5	0
21	1	00:05-00:06	0	0	0	0	2	0	0	0	0	0	0	0	2	0	2	984	1932	2
22	2	00:05-00:06	0	0	0	0	3	0	2	2	0	1	1	1	984	0	984	1932	2	984
23	3	00:05-00:06	0	0	0	0	2	0	0	2	0	0	0	0	284	3	284	3	1932	2
24	4	00:05-00:06	0	0	0	0	0	0	0	2	0	0	0	0	984	0	984	1932	2	984
25	1	00:06-00:07	0	0	0	0	2	0	0	0	0	0	0	0	2	0	2	632	1332	2
26	2	00:06-00:07	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	632	0	1332
27	3	00:06-00:07	0	0	0	0	4	0	0	6	0	0	0	0	632	2	632	2	1332	2
28	4	00:06-00:07	0	1	0	2	0	0	0	0	0	0	0	0	48	0	48	0	1332	48
29	1	00:07-00:08	0	0	0	0	2	0	0	0	0	0	0	0	2	0	2	1442	642	2
30	2	00:07-00:08	0	0	0	0	3	0	0	0	0	0	0	0	3	0	3	642	3	0
31	3	00:07-00:08	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	642	0	1442
32	4	00:07-00:08	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	642	0	1442

資料來源：本計畫整理

2. 流量比較報表

本報表主要針對已完成安裝之設備進行偵測後取得的車流量進行比較，使用者可以進行不同時間的查詢，不同天比較至多可選四日同一時段下的流量比較，其資料於後端儲存 2 年的時間，如今天是 2020.09.15，可以查到的部分就是 2019.01.01~2020.09.14，背景計算時則是以每六個小時

一個區間做報表彙整，包括：00:00-06:00、06:00-12:00、12:00-18:00、18:00-00:00，流量則可查看 5、15 分鐘之區間。而本處主要抓取設備清單如表 4.4.3 所示。

表 4.3-4 流量比較設備清單

位置編號	監控的設備名稱	監控路段名稱
02-LyHzRE	樂業路與環中東路四段(遠端)(東向)	02-LyHzRE 樂業路與環中東路四段(遠端)(東向)
109-11-LyCf-E	樂業路與長福路口(東向)	109-11-LyCf-E-Traffic
109-11-LyCf-E	樂業路與長福路口(西向)	109-11-LyCf-W-Traffic
109-12-SjDy2-N	十甲東路與東英二街(北向)	109-12-SjDy2-N-Traffic
109-12-SjDy2-N	十甲東路與東英二街(南向)	109-12-SjDy2-S-Traffic
109-13-DyDy5-N	東英路與東英五街(北向)	109-13-DyDy5-N-Traffic
109-13-DyDy5-N	東英路與東英五街(南向)	109-13-DyDy5-S-Traffic
109-14-SjDy6-S	十甲東與東英六街(南向)	109-14-SjDy6-S-Traffic
109-14-SjDy6-S	十甲東與東英六街(北向)	109-14-SjDy6-N-Traffic
109-15-DyHx-S	東英路與早溪街(南向)	109-15-DyHx-S-Traffic
109-15-DyHx-S	東英路與早溪街(北向)	109-15-DyHx-N-Traffic

資料來源：本計畫整理

本項目之使用者查詢流程如下，相關畫面則如圖 4.3.13、4.3.14，及產出如表 4.3-5、4.3-6 所示。首先選擇日期 1 與選擇日期 2，接下來選擇起迄時間，包括 00:00-06:00、06:00-12:00、12:00-18:00、18:00-00:00，最後為選擇流量間隔，包括 5 分與 15 分。



圖 4.3.13 AI 交通管理儀表板系統_流量比較查詢 (5 分鐘)

資料來源：本計畫整理

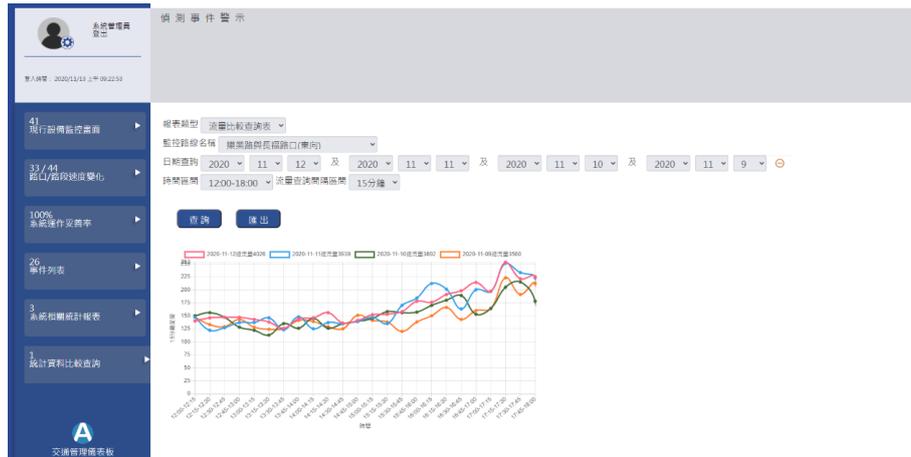


圖 4.3.14 AI 交通管理儀表板系統_流量比較查詢 (15 分鐘)

資料來源：本計畫整理

表 4.3-5 AI 交通管理儀表板系統_流量比較報表 (5 分鐘)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	路段交通流量調查表													
2														
3														
4	序號	設備編號	設備IP	rgn_id	設備偵測路段	方向	車道	日期	時間	大型車	小型車	大客車	機車	總計
5	1	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:00-12:05	1	1	33	10	45
6	2	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:05-12:10	6	0	24	19	49
7	3	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:10-12:15	4	0	22	20	46
8	4	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:15-12:20	2	0	28	21	51
9	5	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:20-12:25	1	1	31	17	50
10	6	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:25-12:30	2	1	29	13	45
11	7	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:30-12:35	3	1	37	13	54
12	8	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:35-12:40	3	0	19	18	40
13	9	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:40-12:45	3	0	29	21	53
14	10	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:45-12:50	4	0	28	17	49
15	11	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:50-12:55	1	2	26	18	47
16	12	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:55-13:00	3	3	23	22	51
17	13	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:00-13:05	3	1	27	14	45
18	14	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:05-13:10	3	2	31	16	52
19	15	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:10-13:15	3	0	32	11	46
20	16	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:15-13:20	1	1	28	16	46
21	17	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:20-13:25	1	0	30	16	47
22	18	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:25-13:30	1	1	31	12	45
23	19	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:30-13:35	4	0	28	13	45
24	20	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:35-13:40	3	0	14	14	31
25	21	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:40-13:45	1	0	37	12	50
26	22	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:45-13:50	3	2	29	18	52
27	23	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:50-13:55	0	1	34	20	55
28	24	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:55-14:00	2	0	25	10	37
29	25	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:00-14:05	4	0	25	17	46
30	26	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:05-14:10	1	1	34	18	54
31	27	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:10-14:15	2	0	26	18	46
32	28	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:15-14:20	2	0	24	15	41
33	29	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:20-14:25	4	1	37	18	60

資料來源：本計畫整理

表 4.3-6 AI 交通管理儀表板系統_流量比較報表 (15 分鐘)

A	B	C	D	E	F	G	H	I	J	K	L	M	N
路段交通流量調查表													
序號	設備編號	設備IP	rgn_id	設備偵測路段	方向	車道	日期	時間	大型車	小型車	大客車	機車	總計
1	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:00-12:15	11	1	79	49	140
2	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:15-12:30	5	2	88	51	146
3	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:30-12:45	9	1	85	52	147
4	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	12:45-13:00	8	5	77	57	147
5	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:00-13:15	9	3	90	41	143
6	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:15-13:30	3	2	89	44	138
7	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:30-13:45	8	0	79	39	126
8	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	13:45-14:00	5	3	88	48	144
9	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:00-14:15	7	1	85	53	146
10	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:15-14:30	9	2	91	54	156
11	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:30-14:45	0	0	86	50	136
12	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	14:45-15:00	6	6	82	47	141
13	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	15:00-15:15	11	3	83	55	152
14	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	15:15-15:30	12	1	87	53	153
15	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	15:30-15:45	2	1	99	56	158
16	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	15:45-16:00	8	3	104	63	178
17	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	16:00-16:15	2	1	101	72	176
18	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	16:15-16:30	3	3	110	75	191
19	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	16:30-16:45	4	2	120	72	198
20	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	16:45-17:00	4	3	101	106	214
21	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	17:00-17:15	5	2	110	80	197
22	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	17:15-17:30	7	1	129	116	253
23	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	17:30-17:45	6	2	134	79	221
24	109-11-LyCf-E	10.3.1.210:4047_1	1	樂業路與長福路口(東向)	東	1	2020/11/12	17:45-18:00	1	1	120	103	225

資料來源：本計畫整理

4.4 績效評估與分析

4.4.1 績效評估方法

效益評估方式主要利用偵測器所獲取之資料進行評估，本計畫採用旅行時間做為評估項目，並考量改善前往市區方向車隊長度往往會有一定機率由十甲東路回堵至環中路，甚至導致環中路口無法淨空，因此納入上游路口群組範圍。另改善前往太平方向之上游無發現車流溢流而產生回堵跡象，因此針對計畫範圍延伸上下游各一個路口，即上游至長福路口與下游至喬城三路口納入分析範圍。整體範圍以針對下匝道左轉車流往西至長福路(路徑 1)、東平 777 巷口往西至長福路(路徑 2)、長福路口往東至喬城三路(路徑三)等三大關鍵路徑進行分析，詳細績效分析範圍如圖 4.4.1 所示；詳細分析結果彙整於 4.4.2 節。

另針對計畫範圍兩路口：樂業-東英、樂業-十甲東進行延滯績效分析，透過偵測器蒐集兩處路口各方向停等延滯，並加總各方向延滯做為改善前後績效比對；然因目前因偵測器位置設於路口號誌近端處(受限於施工考量)且偵測範圍限制因素，當車隊長度超過偵測區域時，即無法計算超出範圍之車輛延滯，故本績效僅供作參考；詳細分析結果彙整於 4.4.3 節。

本計畫應用偵測器蒐集改善前績效為既有定時號誌控制運行之事前

資料，改善後為 AI 號誌控制系統運作之事後資料，兩者相互比較之績效為運作 AI 號誌控制之效果。



圖 4.4.1 旅行時間績效分析範圍

資料來源：本計畫整理

4.4.2 改善前後績效分析

本系統運作績效分析，主要以事前及事後資料各為期兩週進行分析，然部分日期受雨天及事故影響，故暫不納入分析，詳細時間如表 4.4.1。

表 4.4-1 事前事後績效蒐集時程規劃

旅行時間	日期	備註
事前資料蒐集(2週)	2020/09/07-2020/09/20	9/12-9/13 雨天。
事後資料蒐集(2週)	2020/11/02-2020/11/15	11/7-11/8 系統調整未執行;11/11 離峰有事故發生;11/13 昏峰雨天。

資料來源：本計畫整理

一、週一績效分析

(1) 晨峰

週一晨峰事前事後之三大路徑績效如圖 4.4.2、圖 4.4.3、圖 4.4.4 所示，整體趨勢可以看見事前的旅行時間大多高於事後，路徑一事前之平均旅行時間為 166 秒，事後之平均旅行時間為 102 秒，路徑二事前之平均旅行時間為 214 秒，事後之平均旅行時間為 158 秒，路徑三事前之平均旅行時間為 124 秒，事後之平均旅行時間為 90 秒(如表 4.4.2)，將三大路徑之旅行時間整理為表 4.4.2，表中可以看到週一晨峰在三大路徑上皆有超過 20% 的改善幅度。



圖 4.4.2 週一晨峰績效(下匝道→長福路)

資料來源：本計畫整理



圖 4.4.3 週一晨峰績效(東平 777→長福路)

資料來源：本計畫整理

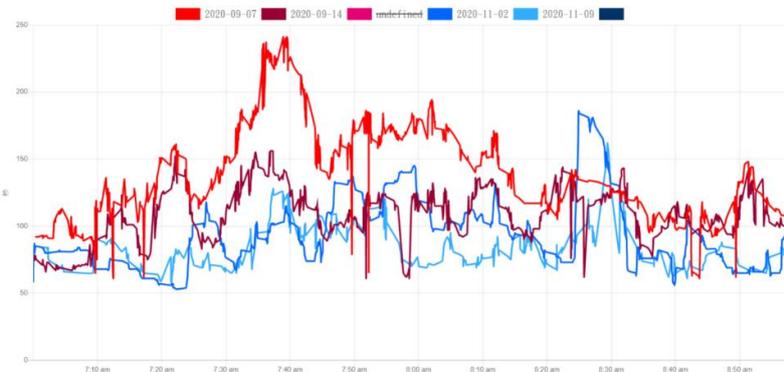


圖 4.4.4 週一晨峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-2 週一晨峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	166	35.55	0.21	102.6	9.04	0.09	-38%
Path2	214	44.72	0.21	158.9	13.06	0.08	-26%
Path3	124	31.06	0.25	90.2	22.94	0.25	-27%

資料來源：本計畫整理

(2) 離峰

週一離峰事前事後之三大路徑績效如圖 4.4.5、圖 4.4.6、圖 4.4.7 所示，整體趨勢可以看見事前的旅行時間與事後之旅行時間並無明顯之差異，故進一步進行分析，路徑一事前之平均旅行時間為 135 秒，事後之平均旅行時間為 133 秒，路徑二事前之平均旅行時間為 193 秒，事後之平均旅行時間為 176 秒，路徑三事前之平均旅行時間為 112 秒，事後之平均旅行時間為 104 秒(如表 4.4.3)，表中可以看到週一離峰在三大路徑上有些為改善。



圖 4.4.5 週一離峰績效(下匝道→長福路)

資料來源：本計畫整理

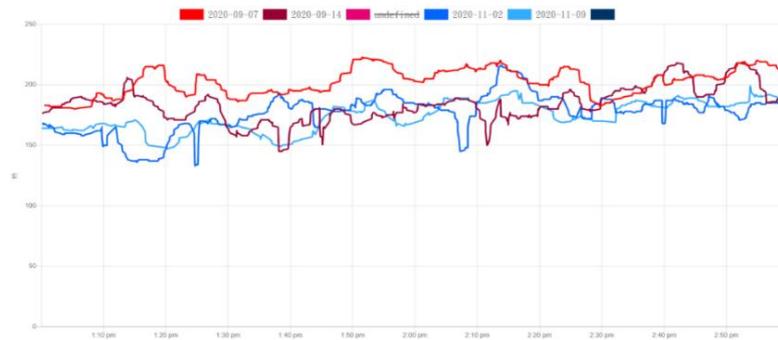


圖 4.4.6 週一離峰績效(東平 777→長福路)

資料來源：本計畫整理

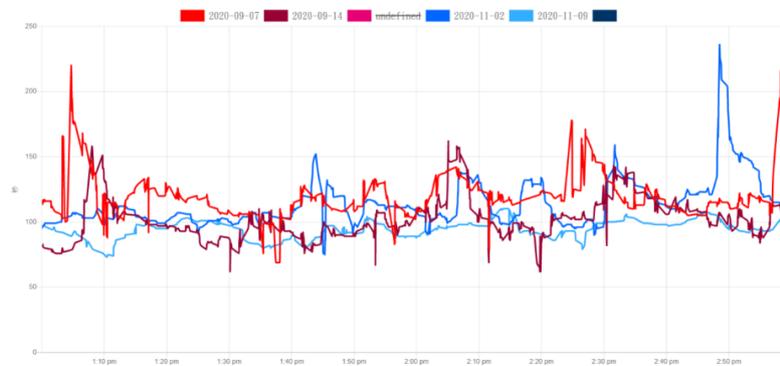


圖 4.4.7 週一離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-3 週一離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	135	16.67	0.12	133	13.95	0.10	-1%
Path2	193	15.94	0.08	176	14.30	0.08	-9%
Path3	112	20.33	0.18	104	16.87	0.16	-7%

資料來源：本計畫整理

(3) 昏峰

週一昏峰事前事後之三大路徑績效如圖 4.4.8、圖 4.4.9、圖 4.4.10 所示，整體趨勢可以看見事前的旅行時間大多明顯高於事後，路徑一事前之平均旅行時間為 213 秒，事後之平均旅行時間為 111 秒，路徑二事前之平均旅行時間為 257 秒，事後之平均旅行時間為 175 秒，路徑三事前之平均旅行時間為 161 秒，事後之平均旅行時間為 106 秒(如表 4.4.4)，表中可以看到週一昏峰在三大路徑上皆有超過30%的改善幅度。

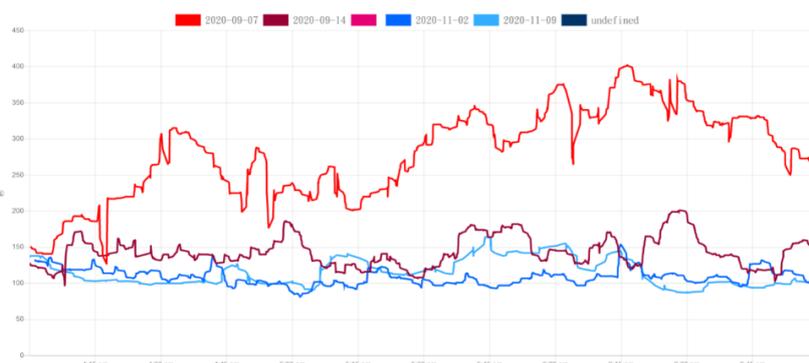


圖 4.4.8 週一昏峰績效(下匝道→長福路)

資料來源：本計畫整理

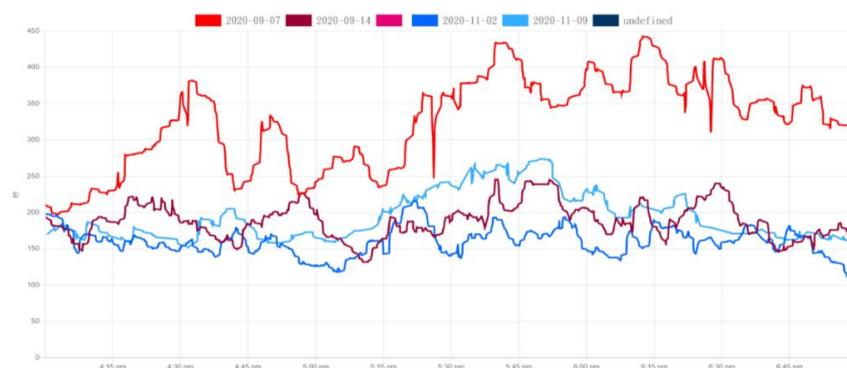


圖 4.4.9 週一昏峰績效(東平 777→長福路)

資料來源：本計畫整理

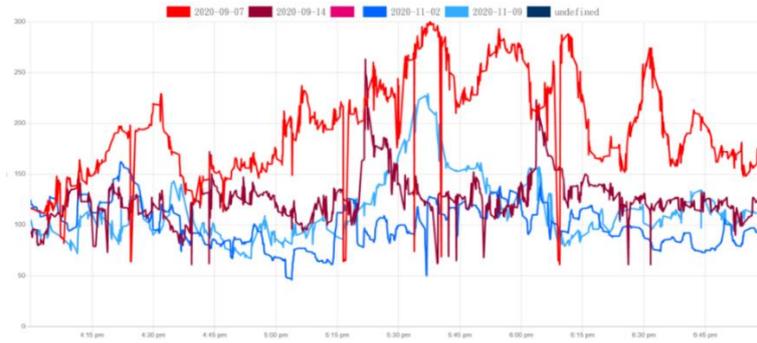


圖 4.4.10 週一昏峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-4 週一昏峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	213	82.63	0.39	111	15.06	0.14	-48%
Path2	257	84.34	0.33	175	30.69	0.18	-32%
Path3	161	50.59	0.31	106	25.65	0.24	-34%

資料來源：本計畫整理

二、週二績效分析

(1) 晨峰

週二晨峰事前事後之三大路徑績效如圖 4.4.11、圖 4.4.12、圖 4.4.13 所示，整體趨勢可以看見事後之旅行時間大多是低於事前之旅行時間之下，路徑一事前之平均旅行時間為 167 秒，事後之平均旅行時間為 125 秒，路徑二事前之平均旅行時間為 207 秒，事後之平均旅行時間為 170 秒，路徑三事前之平均旅行時間為 128 秒，事後之平均旅行時間為 100 秒(如表 4.4.5)，表中可以看到週二晨峰在三大路徑上皆有 20% 左右的改善幅度。



圖 4.4.11 週二晨峰績效(下匝道→長福路)

資料來源：本計畫整理

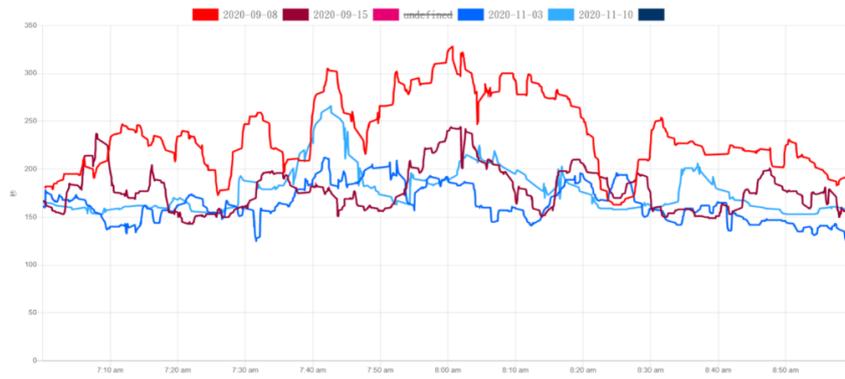


圖 4.4.12 週二晨峰績效(東平 777→長福路)

資料來源：本計畫整理

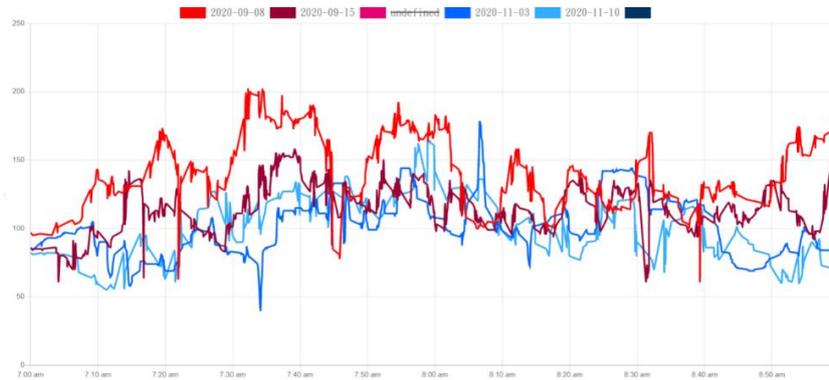


圖 4.4.13 週二晨峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-5 週二晨峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	167	39.70	0.24	125	27.89	0.22	-25%
Path2	207	42.52	0.21	170	22.65	0.13	-18%
Path3	128	25.73	0.20	100	21.30	0.21	-21%

資料來源：本計畫整理

(2) 離峰

週二離峰事前事後之三大路徑績效如圖 4.4.14、圖 4.4.15、圖 4.4.16 所示，整體趨勢可以看見事前的旅行時間大多高於事後，且事後之旅行時間浮動趨勢相較平穩，路徑一事前之平均旅行時間為 142 秒，事後之平均旅行時間為 125 秒，路徑二事前之平均旅行時間為 197 秒，事後之平均旅行時間為 164 秒，路徑三事前之平均旅行時間為 108 秒，事後之平均旅行時間為 95 秒(如表 4.4.6)，表中可以看到週二離峰在三大路徑上皆有超過 10% 的改善幅度。

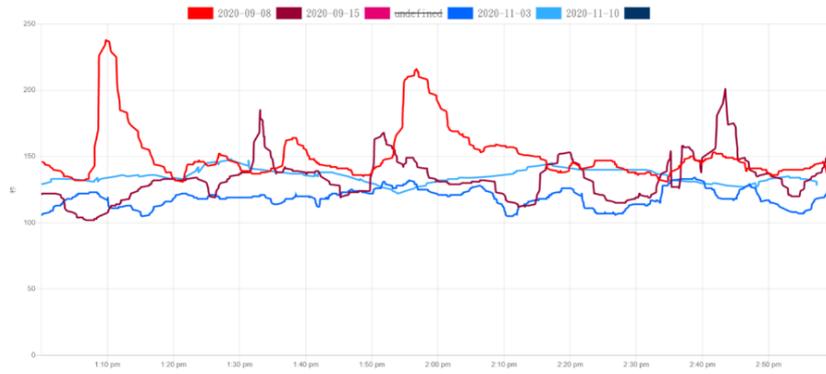


圖 4.4.14 週二離峰績效(下匝道→長福路)

資料來源：本計畫整理

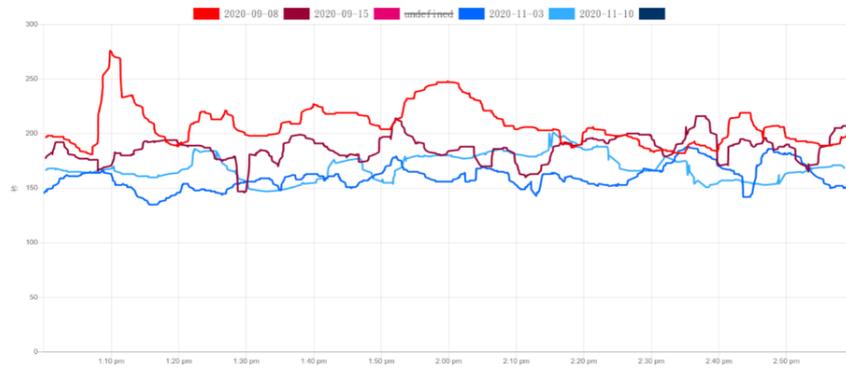


圖 4.4.15 週二離峰績效(東平 777→長福路)

資料來源：本計畫整理

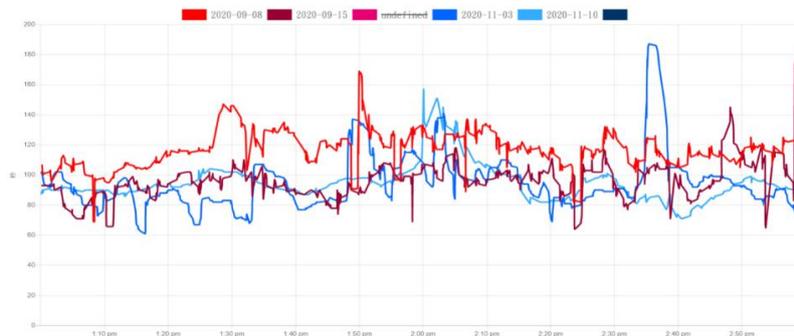


圖 4.4.16 週二離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-6 週二離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	142	20.53	0.14	125	10.08	0.08	-12%
Path2	197	18.70	0.09	164	12.33	0.08	-17%
Path3	108	16.08	0.15	95	16.08	0.17	-12%

資料來源：本計畫整理

(3) 昏峰

週二昏峰事前事後之三大路徑績效如圖 4.4.17、圖 4.4.18、圖 4.4.19 所示，整體趨勢可以看見事前的旅行時間大多高於事後，僅在路徑二上兩者差異較不明顯，路徑一事前之平均旅行時間為 144 秒，事後之平均旅行時間為 118 秒，路徑二事前之平均旅行時間為 191 秒，事後之平均旅行時間為 182 秒，路徑三事前之平均旅行時間為 122 秒，事後之平均旅行時間為 106 秒(如表 4.4.7)，表中可以看到週二昏峰在路徑一、三有超過 10% 的改善幅度，路徑二則有些許改善。

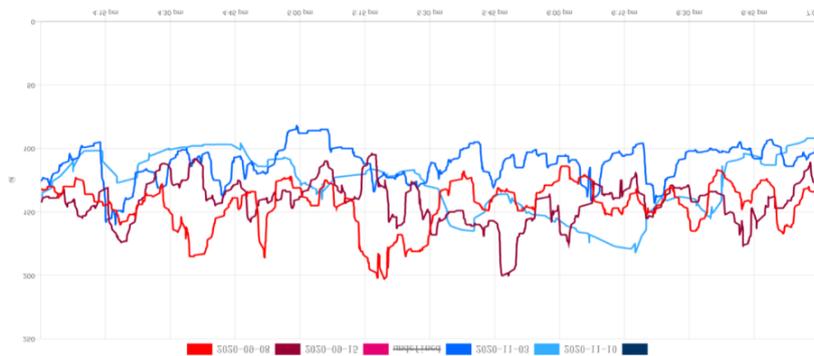


圖 4.4.17 週二昏峰績效(下匝道→長福路)

資料來源：本計畫整理



圖 4.4.18 週二昏峰績效(東平 777→長福路)

資料來源：本計畫整理

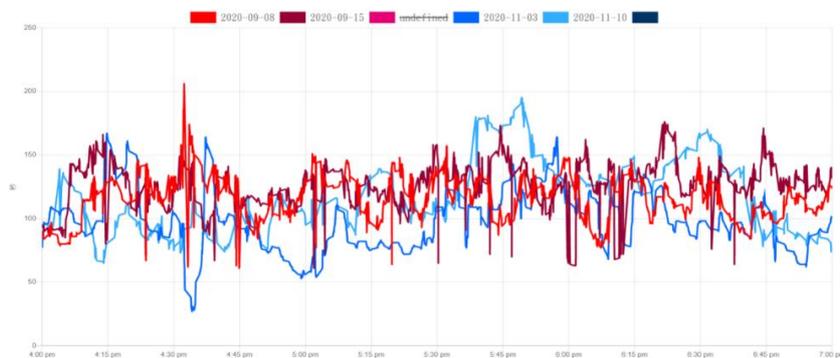


圖 4.4.19 週二昏峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-7 週二昏峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	144	17.17	0.12	118	19.31	0.16	-18%
Path2	191	21.08	0.11	182	32.10	0.18	-5%
Path3	122	16.55	0.14	106	26.97	0.25	-13%

資料來源：本計畫整理

三、週三績效分析

(1)晨峰

週三晨峰事前事後之三大路徑績效如圖 4.4.20、圖 4.4.21、圖 4.4.22 所示，整體趨勢可以看見事前的旅行時間在大多時間上高於事後旅行時間，路徑一事前之平均旅行時間為 143 秒，事後之平均旅行時間為 118 秒，路徑二事前之平均旅行時間為 180 秒，事後之平均旅行時間為 165 秒，路徑三事前之平均旅行時間為 115 秒，事後之平均旅行時間為 84 秒(如表 4.4.8)，表中可以看到週三晨峰在路徑一、三上皆有接近 20%的改善幅度，路徑二則有接近 10%之改善程度。

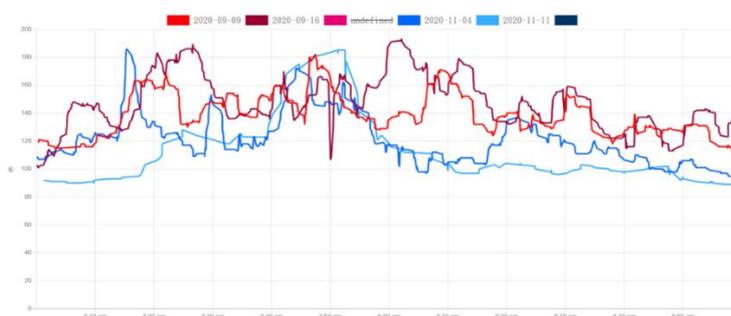


圖 4.4.20 週三晨峰績效(下匝道→長福路)

資料來源：本計畫整理



圖 4.4.21 週三晨峰績效(東平 777→長福路)

資料來源：本計畫整理

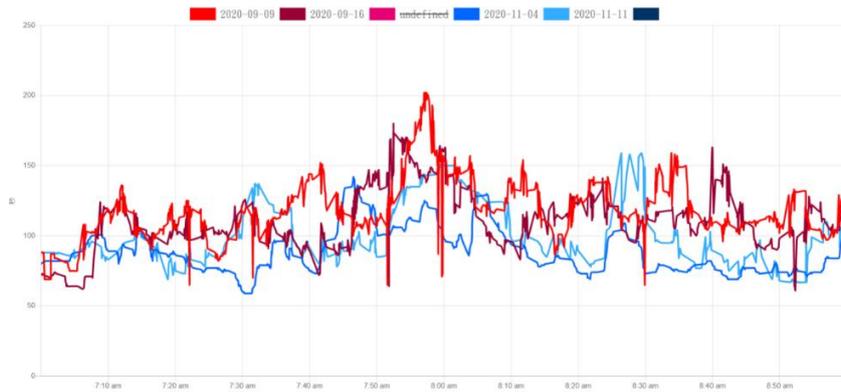


圖 4.4.22 週三晨峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-8 週三晨峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	143	17.75	0.12	118	20.73	0.18	-18%
Path2	180	22.34	0.12	165	27.23	0.16	-8%
Path3	115	20.65	0.18	84	18.62	0.20	-18%

資料來源：本計畫整理

(2) 離峰

週三離峰事前事後之三大路徑績效如圖 4.4.23、圖 4.4.24、圖 4.4.25 所示，在整體趨勢上事前及事後並無明顯差異，路徑一事前之平均旅行時間為 128 秒，事後之平均旅行時間為 122 秒，路徑二事前之平均旅行時間為 184 秒，事後之平均旅行時間為 163 秒，路徑三事前之平均旅行時間為 98 秒，事後之平均旅行時間為 101 秒(如表 4.4.9)。

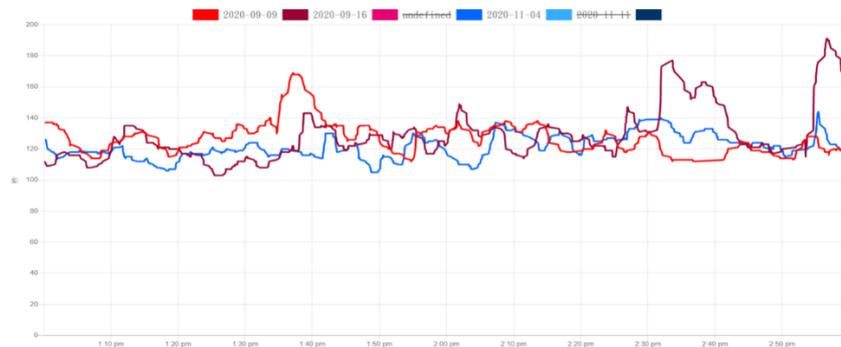


圖 4.4.23 週三離峰績效(下匝道→長福路)

資料來源：本計畫整理

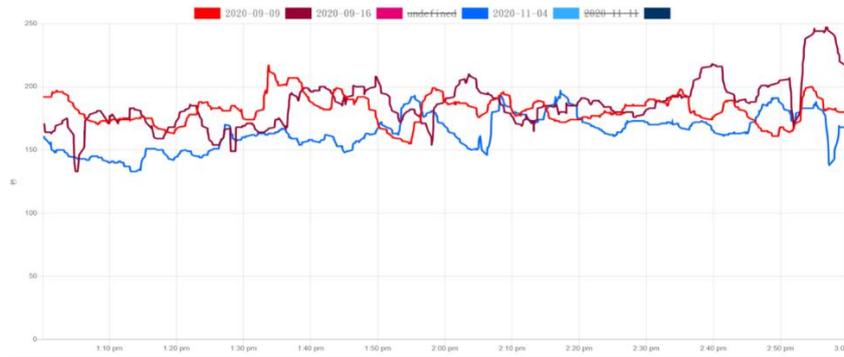


圖 4.4.24 週三離峰績效(東平 777→長福路)

資料來源：本計畫整理

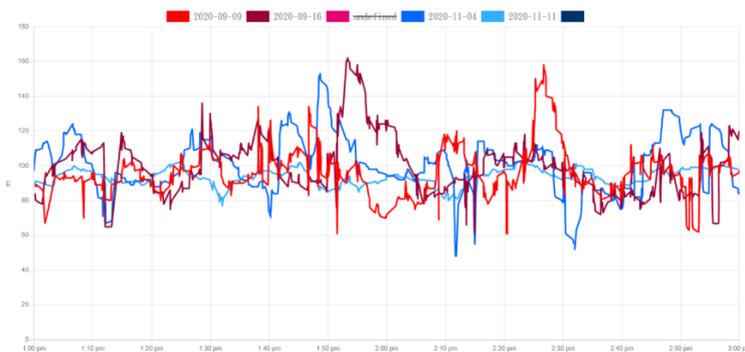


圖 4.4.25 週三離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-9 週三離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	128	14.21	0.11	122	7.60	0.06	-5%
Path2	184	15.31	0.08	163	13.82	0.08	-11%
Path3	98	14.96	0.15	101	15.75	0.16	+3%

資料來源：本計畫整理

(3) 昏峰

週三昏峰事前事後之三大路徑績效如圖 4.4.26、圖 4.4.27、圖 4.4.28 所示，整體趨勢上事前事後之差異並不明顯，且在部分時間點上皆會有旅行時間突然上升之狀況，路徑一事前之平均旅行時間為 142 秒，事後之平均旅行時間為 122 秒，路徑二事前之平均旅行時間為 190 秒，事後之平均旅行時間為 186 秒，路徑三事前之平均旅行時間為 128 秒，事後之平均旅行時間為 114 秒(如表 4.4.10)，表中可以看到週三昏峰在路徑一、三上皆有 10% 的改善幅度，路徑二則些微改善 4%。



圖 4.4.26 週三昏峰績效(下匝道→長福路)

資料來源：本計畫整理

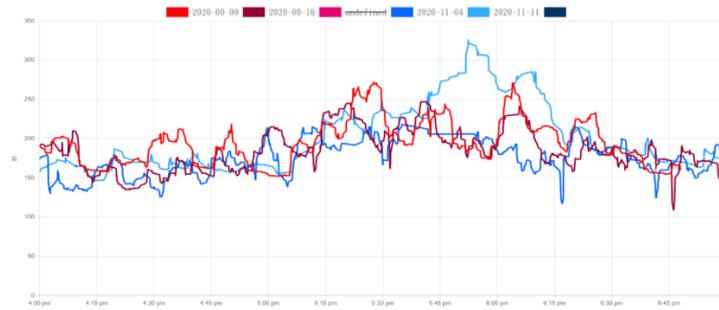


圖 4.4.27 週三昏峰績效(東平 777→長福路)

資料來源：本計畫整理

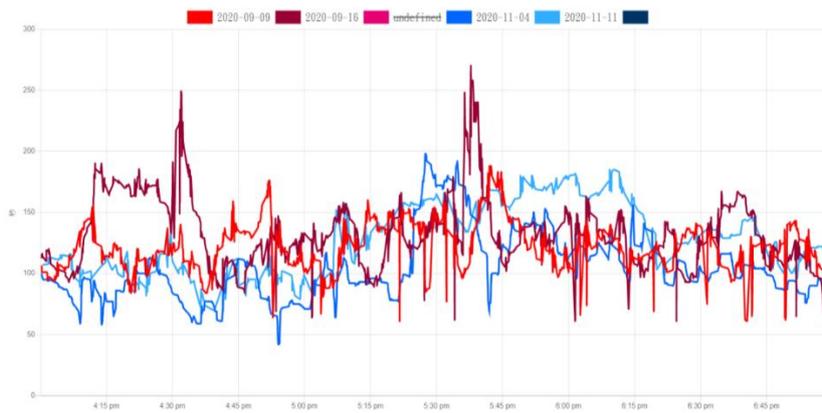


圖 4.4.28 週三昏峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-10 週三昏峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	142	19.90	0.14	122	23.15	0.19	-14%
Path2	190	27.78	0.15	186	36.50	0.20	-3%
Path3	128	24.62	0.19	114	30.23	0.26	-10%

資料來源：本計畫整理

四、週四績效分析

(1)晨峰

週四晨峰事前事後之三大路徑績效如圖 4.4.29、圖 4.4.30、圖 4.4.31 所示，部分事後旅行時間明顯低於事前旅行時間，路徑一事前之平均旅行時間為 136 秒，事後之平均旅行時間為 117 秒，路徑二事前之平均旅行時間為 174 秒，事後之平均旅行時間為 163 秒，路徑三事前之平均旅行時間為 113 秒，事後之平均旅行時間為 98 秒(如表 4.4.11)，表中可以看到週四晨峰在路徑一、三上改善幅度都有高過 10%，路徑二上也有 6%之改善。



圖 4.4.29 週四晨峰績效(下匝道→長福路)

資料來源：本計畫整理



圖 4.4.30 週四晨峰績效(東平 777→長福路)

資料來源：本計畫整理

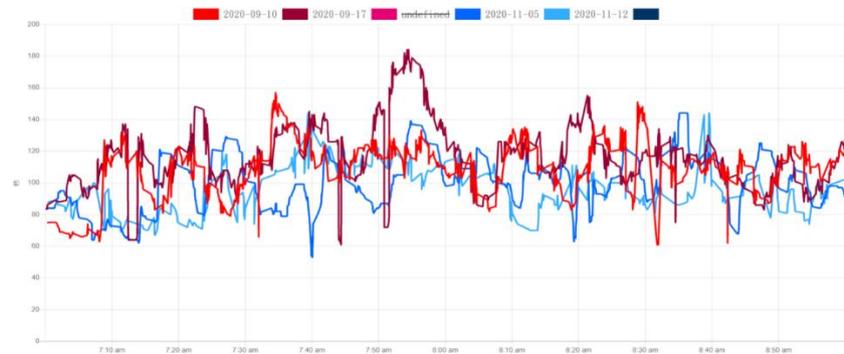


圖 4.4.31 週四晨峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-11 週四晨峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	136	16.04	0.12	117	13.14	0.11	-14%
Path2	174	21.26	0.12	163	15.693	0.10	-6%
Path3	113	18.45	0.16	98	15.88	0.16	-13%

資料來源：本計畫整理

(2)離峰

週四離峰事前事後之三大路徑績效如圖 4.4.32、圖 4.4.33、圖 4.4.34 所示，路徑一事前之平均旅行時間為 133 秒，事後之平均旅行時間為 128 秒，路徑二事前之平均旅行時間為 187 秒，事後之平均旅行時間為 171 秒，路徑三事前之平均旅行時間為 103 秒，事後之平均旅行時間為 100 秒(如表 4.4.12)，表中可以看到週四離峰在三大路徑上改善幅度皆不大，僅路徑二上有近 10%之改善。

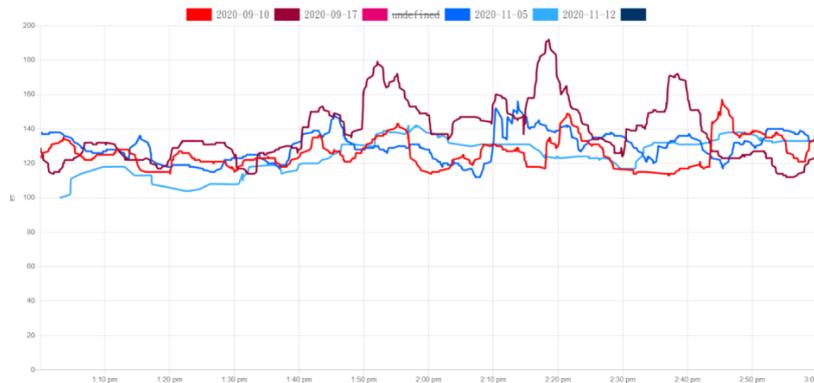


圖 4.4.32 週四離峰績效(下匝道→長福路)

資料來源：本計畫整理

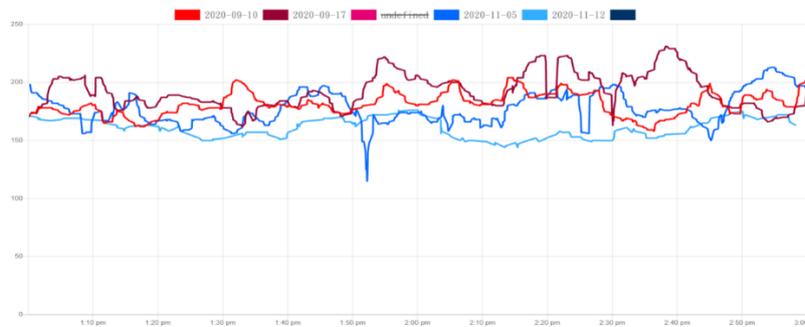


圖 4.4.33 週四離峰績效(東平 777→長福路)

資料來源：本計畫整理

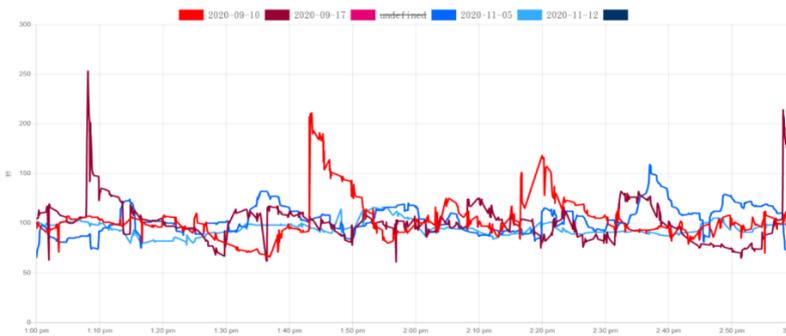


圖 4.4.34 週四離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-12 週四離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	133	15.06	0.11	128	9.33	0.07	-3%
Path2	187	13.84	0.07	171	14.37	0.08	-9%
Path3	103	19.85	0.19	100	12.21	0.12	-3%

資料來源：本計畫整理

(3) 昏峰

週四昏峰事前事後之三大路徑績效如圖 4.4.35、圖 4.4.36、圖 4.4.37 所示，整體趨勢上，路徑一、二可以明顯看出事前的旅行時間大多高於事後，路徑一事前之平均旅行時間為 141 秒，事後之平均旅行時間為 122 秒，路徑二事前之平均旅行時間為 184 秒，事後之平均旅行時間為 165 秒，路徑三事前之平均旅行時間為 125 秒，事後之平均旅行時間為 113 秒(如表 4.4.13)，表中可以看到週四昏峰在三大路徑上皆有超過 10% 的改善幅度。

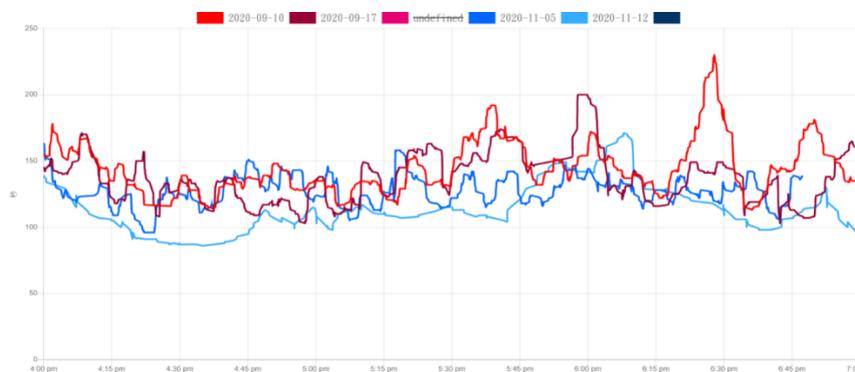


圖 4.4.35 週四昏峰績效(下匝道→長福路)

資料來源：本計畫整理

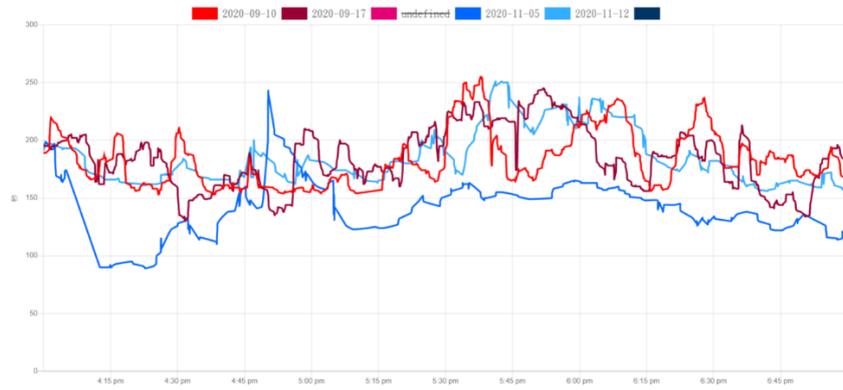


圖 4.4.36 週四昏峰績效(東平 777→長福路)

資料來源：本計畫整理

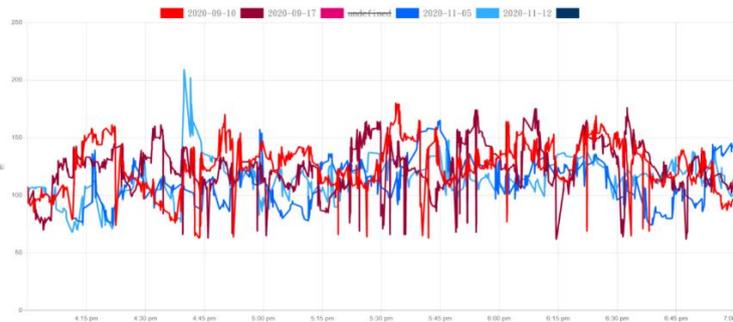


圖 4.4.37 週四昏峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-13 週四昏峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	141	19.92	0.14	122	16.53	0.14	-13%
Path2	184	24.74	0.13	165	32.76	0.20	-11%
Path3	125	19.09	0.15	113	17.33	0.15	-10%

資料來源：本計畫整理

五、週五績效分析

(1)晨峰

週五晨峰事前事後之三大路徑績效如圖 4.4.38、圖 4.4.39、圖 4.4.40 所示，除路徑一事前行時間明顯高於事後，其餘路徑則不明顯，路徑一事前之平均旅行時間為 143 秒，事後之平均旅行時間為 107 秒，路徑二事前之平均旅行時間為 179 秒，事後之平均旅行時間為 163 秒，路徑三事前之平均旅行時間為 112 秒，事後之平均旅行時間為 96 秒(如表 4.4.14)，表中可以看到週五晨峰在在路徑一上皆有顯著之改善，路徑三也有超過 10%

之改善，路徑三則有接近 10% 之改善。



圖 4.4.38 週五晨峰績效(下匝道→長福路)

資料來源：本計畫整理

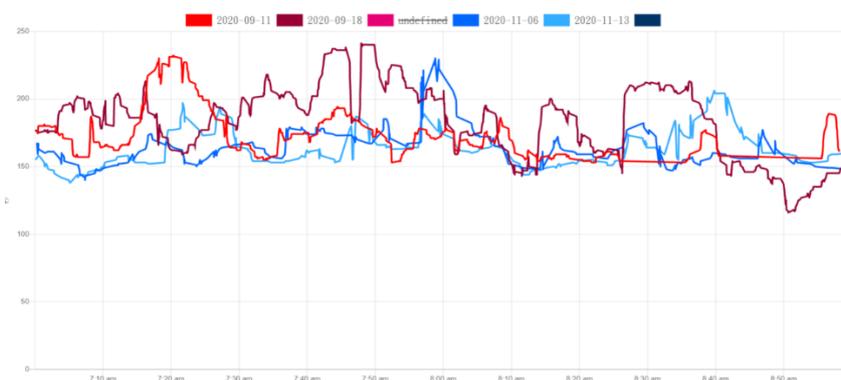


圖 4.4.39 週五晨峰績效(東平 777→長福路)

資料來源：本計畫整理

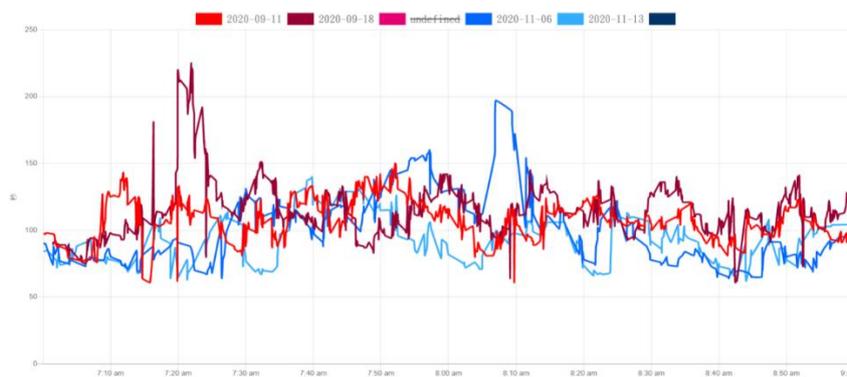


圖 4.4.40 週五晨峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-14 週五晨峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	143	18.51	0.13	107	10.24	0.10	-25%
Path2	179	23.90	0.13	163	13.94	0.09	-9%
Path3	112	18.26	0.16	96	21.88	0.23	-14%

資料來源：本計畫整理

(2)離峰

週五離峰事前事後之三大路徑績效如圖 4.4.41、圖 4.4.42、圖 4.4.43 所示，整體趨勢上，事前與事後之差異不大，但可以明顯看出事後旅行時間變動之趨勢相較平穩，路徑一事前之平均旅行時間為 133 秒，事後之平均旅行時間為 135 秒，路徑二事前之平均旅行時間為 188 秒，事後之平均旅行時間為 171 秒，路徑三事前之平均旅行時間為 106 秒，事後之平均旅行時間為 99 秒(如表 4.4.15)，表中可以看到週五離峰在路徑二、三上皆有近 10%之改善，路徑一則是與事前差異甚小。



圖 4.4.41 週五離峰績效(下匝道→長福路)

資料來源：本計畫整理

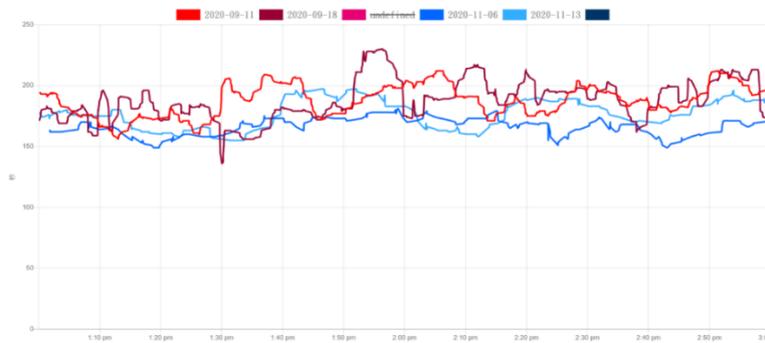


圖 4.4.42 週五離峰績效(東平 777→長福路)

資料來源：本計畫整理

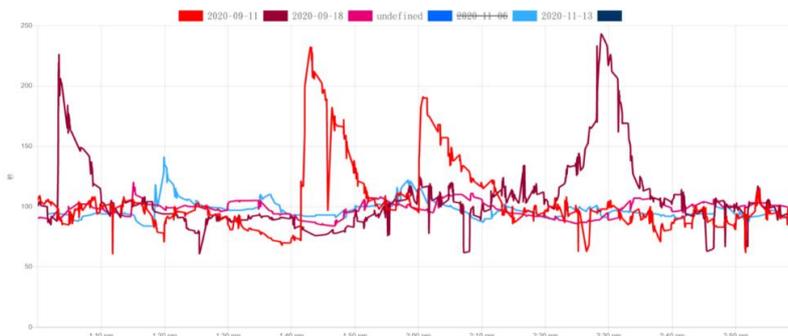


圖 4.4.43 週五離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-15 週五離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	133	19.64	0.15	135	8.03	0.06	+1%
Path2	188	14.73	0.08	171	11.37	0.07	-9%
Path3	106	28.46	0.27	99	8.30	0.08	-7%

資料來源：本計畫整理

(3) 昏峰

週五昏峰事前事後之三大路徑績效如圖 4.4.44、圖 4.4.45、圖 4.4.46 所示，整體趨勢，僅路徑一上可以看見事前的旅行時間大多高於事後，路徑一事前之平均旅行時間為 162 秒，事後之平均旅行時間為 134 秒，路徑二事前之平均旅行時間為 211 秒，事後之平均旅行時間為 215 秒，路徑三事前之平均旅行時間為 129 秒，事後之平均旅行時間為 116 秒(如表 4.4.16)，表中可以看到週五昏峰在路徑一、三上皆有超過 10% 之改善幅度，路徑二則較事前略為劣化但差異不大。



圖 4.4.44 週五昏峰績效(下匝道→長福路)

資料來源：本計畫整理



圖 4.4.45 週五昏峰績效(東平 777→長福路)

資料來源：本計畫整理

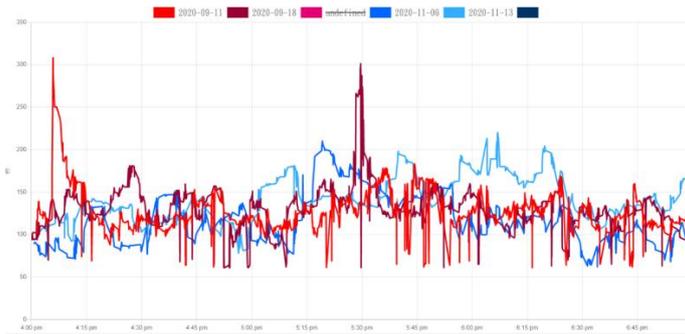


圖 4.4.46 週五昏峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-16 週五昏峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	3 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	162	22.00	0.14	134	22.69	0.17	-17%
Path2	211	32.89	0.16	215	44.28	0.20	+2%
Path3	129	23.39	0.18	116	29.70	0.26	-10%

資料來源：本計畫整理

六、週六績效分析

(1)離峰

週六離峰事前事後之三大路徑績效如圖 4.4.47、圖 4.4.48、圖 4.4.49 所示，整體趨勢上事前事後並無明顯之差異，但事後之變動趨勢則是相較平穩，路徑一事前之平均旅行時間為 133 秒，事後之平均旅行時間為 131 秒，路徑二事前之平均旅行時間為 174 秒，事後之平均旅行時間為 167 秒，路徑三事前之平均旅行時間為 106 秒，事後之平均旅行時間為 98 秒(如表 4.4.17)，表中可以看到週六離峰在三大路徑上改善程度皆不大，皆介於 1 至 10%之間。

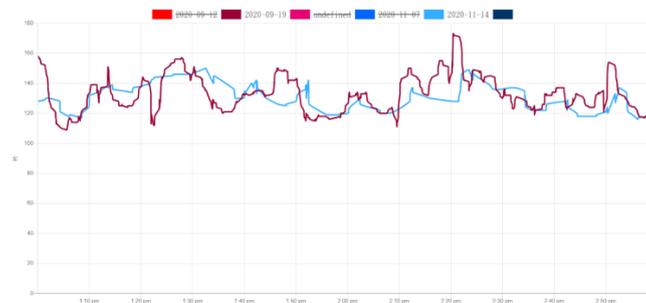


圖 4.4.47 週六離峰績效(下匝道→長福路)

資料來源：本計畫整理

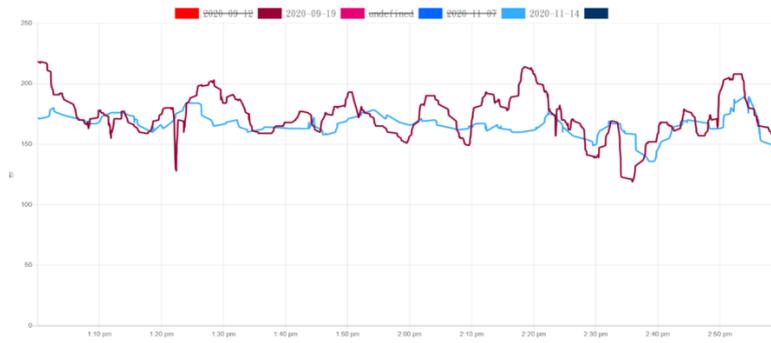


圖 4.4.48 週六離峰績效(東平 777→長福路)

資料來源：本計畫整理



圖 4.4.49 週六離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-17 週六離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	133	11.90	0.09	131	8.91	0.07	-1%
Path2	174	17.24	0.10	167	9.04	0.05	-4%
Path3	106	15.42	0.14	98	9.79	0.10	-8%

資料來源：本計畫整理

七、週日績效分析

(1)離峰

週日離峰事前事後之三大路徑績效如圖 4.4.50、圖 4.4.51、圖 4.4.52 所示，整體趨勢上事前事後並無明顯之差異，但事後之變動趨勢則是相較平穩，路徑一事前之平均旅行時間為 123 秒，事後之平均旅行時間為 128 秒，路徑二事前之平均旅行時間為 182 秒，事後之平均旅行時間為 162 秒，路徑三事前之平均旅行時間為 96 秒，事後之平均旅行時間為 95 秒(如表 4.4.18)，表中可以看到週日離峰在三大路徑上事後與事前的差異不大，

僅在路徑二有明顯之改善。

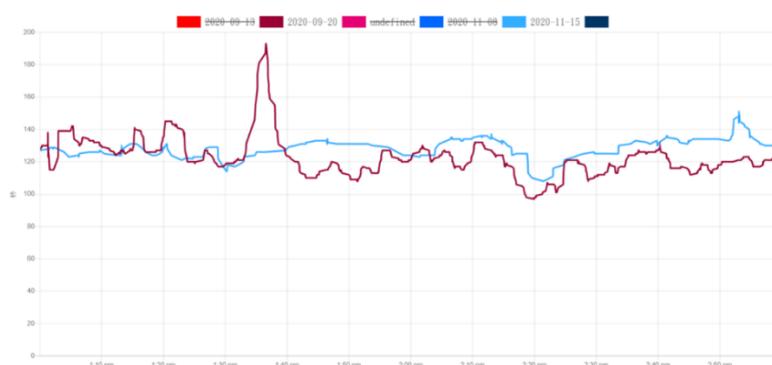


圖 4.4.50 週日離峰績效(下匝道→長福路)

資料來源：本計畫整理

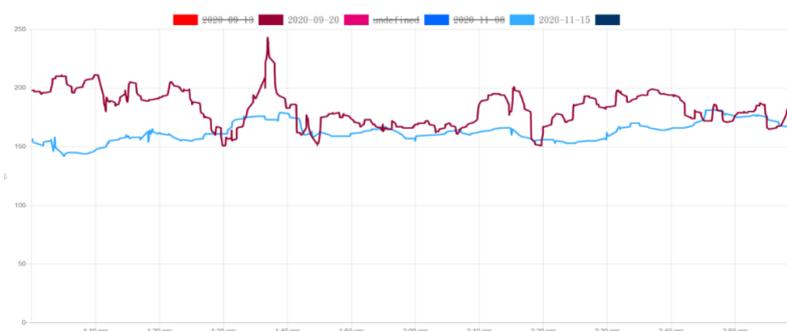


圖 4.4.51 週日離峰績效(東平 777→長福路)

資料來源：本計畫整理

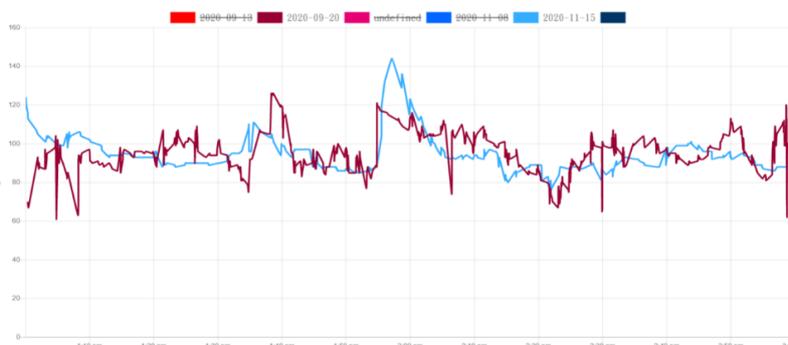


圖 4.4.52 週日離峰績效(長福路→喬城三街)

資料來源：本計畫整理

表 4.4-18 週日離峰各路徑績效彙整

路徑	事前			事後			旅行時間 前後變化
	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	2 小時平 均旅行時 間(秒/車)	標準 差	變異 係數	
Path1	123	12.22	0.10	128	6.06	0.05	+4%
Path2	182	14.14	0.08	162	8.05	0.05	-11%
Path3	96	9.72	0.10	95	10.40	0.11	-1%

資料來源：本計畫整理

4.4.3 延滯績效分析

針對計畫範圍兩處路口之各方向停等延滯加總，並分析事前與事後績效，彙整結果如表 4.4-19。

一、平常日時段

週一晨峰及週五昏峰總延滯分別降低 7.63% (減少 4872 秒)及 11.91% (減少 12396 秒)，一般日晨峰及昏峰總延滯分別降低 4.83% (減少 3038 秒)及 5.36% (減少 5320 秒)，一般日離峰總延滯則降低 10.22%(減少 4568 秒)。

二、假日時段

週六離峰總延滯降低 4.98% (減少 2251 秒)，而週日離峰總延滯微幅增加 0.69% (增加 258 秒)。

表 4.4-19 總延滯績效彙整

情境	週一晨峰	週五昏峰	一般日晨峰	一般日離峰	一般日昏峰	週六離峰	週日離峰
事前	63881	104120	62852	44694	99207	45201	37197
事後	59009	91724	59814	40126	93887	42950	37455
前後比較	-7.63%	-11.91%	-4.83%	-10.22%	-5.36%	-4.98%	0.69%
備註	一般日指週二至週四						

資料來源：本計畫整理

4.5 AI 號誌控制未來發展

AI 及號誌控制的結合會面臨各方面之挑戰，故在發展 AI 號誌控制時，首先必須界定欲解決之問題，並採用合適之 AI 演算法，才可以有效結合 AI 協助號誌控制進行決策。本計畫階段性地以模仿專家模型之號誌時制最佳化為主，同時考量實務執行面之需求，例如：上游幹道連鎖與續進，惟強化學習仍在狀態、動作、獎勵等上須要交通領域專業進行模式構建，方能於實作上可被應用。因此 AI 號誌控制未來發展上，可以本計畫階段成果為基礎，分別從路網型態、控制模式，以及強化學習的代理人數量、動作、獎勵、方法、訓練資料及環境等面向進行探討。根據本計畫執行階段行成果，初擬 AI 強化學習號誌控制的後續發展架構，如圖 4.5.1 所示。

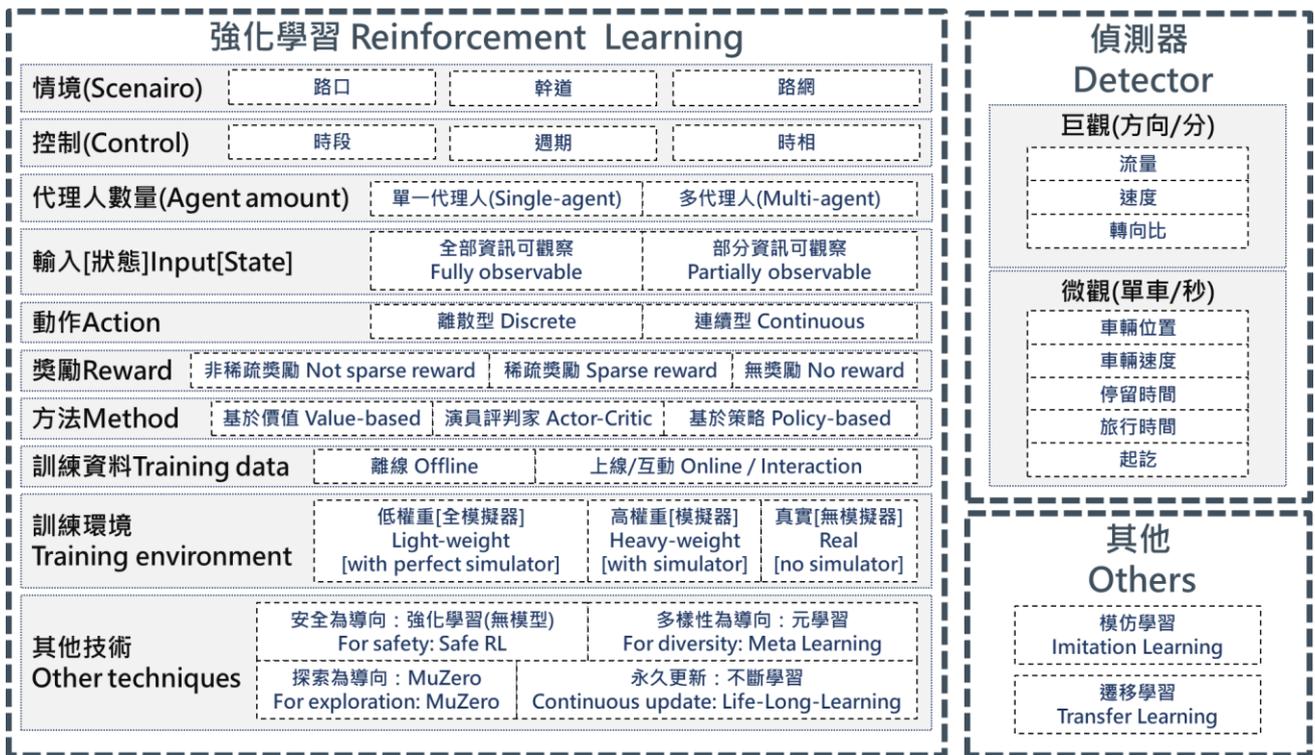


圖 4.5.1 AI 號誌控制發展規劃架構

資料來源：本計畫整理

1. 情境方面

應用 AI 強化學習號誌控制時，首先須先界定運作範圍。若針對單一路口進行運作，AI 號誌控制可依據其所獲得的資訊，學習此路口之最佳號誌控制邏輯；然可能忽略與其它上下游相鄰路口之連鎖關係，導致車流不易續進，進而造成其他交通問題。因此須先從號誌控制專業角度考量該單一路口之獨立性，若其與上下游相鄰路口存在某種關聯性，則須以幹道或路網方式進行 AI 強化學習號誌控制模式構建。當進行幹道或路網方式進行 AI 強化學習號誌控制模式構建，將面臨狀態空間增加的 AI 強化學習有效率學習，以及各個路口 AI 強化學習號誌控制代理人如何進行溝通的挑戰，此挑戰可透過交通工程師之經驗給予 AI 強化學習號誌控制模擬模式正確學習方向。

2. 控制方面

控制表示 AI 強化學習在號誌控制器中之運作邏輯模式，AI 強化學習可針對車流環境做出適當之決策。而依每次決策之頻率大致可分為逐秒及逐週期之控制方式，逐秒為固定秒數間隔進行決策，逐週期則為每一週期進行一次決策。在情境及考量不同的狀況下，兩者會有各自之優劣產生，整理如表 4.5.1 所示。

表 4.5-1 逐週期與逐時相之優缺點比較

	時段	週期	時相
優點	<ul style="list-style-type: none"> ● 交通工程師可協助及微調 ● 可整合較多傳統交通知識 ● 易擴充到幹道及路網/較適合過飽和 ● 網路頻寬、偵測器偵測參數成本較低 		<ul style="list-style-type: none"> ● 單一路口適應環境能力高 ● 非過飽和且流量變異高路口效益佳
缺點	<ul style="list-style-type: none"> ● 單一路口調整彈性小 ● 非飽和且流量變異高之路口效益較差 ● 為時段之平均策略，較無法滿足短時間之交通變異 	<ul style="list-style-type: none"> ● 單一路口調整彈性小 ● 非飽和且流量變異高之路口效益較差 	<ul style="list-style-type: none"> ● 交通工程師介入空間小 ● 不易與相鄰路口進行協控/寬帶不易延續 ● 過飽和效益不佳 ● 網路頻寬、偵測器偵測參數成本高

資料來源：本計畫整理

3. 代理人數量方面

代理人(Agent)的數量多寡主要取決於問題的複雜度，當欲控制的項目越多，單一代理人在學習上可能會越加困難，故可將不同項目分別交給不同的代理人進行學習，以避免單一代理(Single-agent)輸出的決策太多而使學習過久或是難以收斂。在多代理人方式中，各個代理人的目標可以分為局部(local)及整體(global)獎勵，局部獎勵各自給予各個代理人，整體獎勵則是所有代理人共同取得，好的決策即是需要兼顧兩者。另外，當多代理人同時進行決策時，環境會變得更加不穩定，未來之狀況也會變得難以預測，故代理人間可透過溝通之功能，以盡量避免此種情況發生。

在交通號誌控制上，多代理人的狀況可以適用於多路口號制控制上，每個路口由單一號誌代理人進行控制，代理人之間可以互相傳遞訊息。透過代理人間的訊息傳遞，各代理人可以相互配合，使車流可以順利續進，而非僅考慮單一路口之紓解，多代理人彼此間之運作過程如圖 4.5.2 所示。

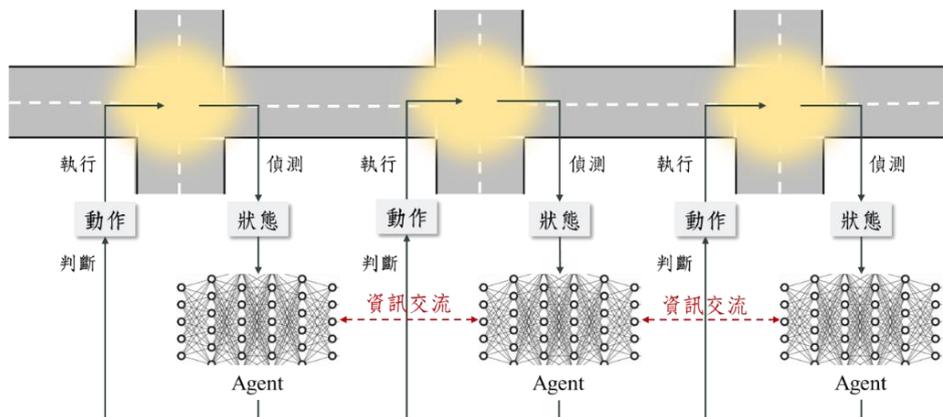


圖 4.5.2 多路口多代理人運作狀況

資料來源：本計畫整理

4. 狀態方面

在狀態方面可分為全部資訊可觀察(Fully observable)及部分資訊可觀察(Partially observable)，全部資訊可觀察表示代理人可以完全觀察整個環境，部分資訊可觀察則表示代理人僅能看到部分的環境狀態。以車隊長度為例，若偵測器偵測範圍可覆蓋整個車道為全部資訊可觀察，然而若偵測器僅能偵測車道上特定範圍內之車隊，其餘未偵測範圍之車隊即為代理人無法觀測之部分，代理人必須依靠部分之觀察作出判斷，則為部分資訊可觀察。

5. 動作方面

代理人在進行控制時，其決策可分為離散型或是連續型，離散型動作表示代理人需在固定的決策中，挑選一最佳之決策執行，連續型動作則是輸出一最佳數值進行號誌控制執行。號誌控制中常見之離散型動作像是時相切換、多時相擇一、挑選時制計畫等，連續型則像是決定下一週期之長度、時相長度、續進號誌中之時差。離散或是連續型之動作也影響代理人之學習方式，在學習方式中分為基於價值(value-based)、基於策略(policy-based)及兩種混合之演員評論家(Actor-Critic)等 3 類型；基於價值的方式，適合用於離散型的決策，而基於策略的方式則可處理連續型之決策，但易收斂於局部最佳解。

6. 獎勵方面

在代理人獎勵的獲取中，所要考量的是獎勵取得的難易程度，當代理人無法獲得足夠之獎勵時，可能造成代理人學習緩慢甚至無法有效學習。然而現實中許多問題皆是稀疏獎勵，獎勵並非是可以即時取得，或是即時取得會造成成本過大，故可採用其他技術解決稀疏獎勵之問題，例如：獎勵重塑(Reward reshaping)或分層強化學習(Hierarchical Reinforcement learning)等。

7. 訓練資料方面

訓練資料中分為離線(offline)以及上線(online)，主要差別是在訓練時，離線為利用一個批次的經驗進行訓練更新權重，故每次與環境互動的經驗需另外儲存，在需要時才從儲存的經驗中取樣一定數量進行訓練。上線則是每次與學習模擬環境(通常並非真實環境，因風險過高)互動即進行訓練，即每次的互動，代理人皆會更新其權重，兩種方式皆有各自的優點，離線較能避免代理人因一次錯誤的經驗而學習錯誤，上線的學習速度則是較快。

8. 訓練環境方面

在 AI 號制控制的訓練環境中，依據環境的不同可分為三類，低權重的模擬器表示環境的狀態變化不大，可透過探索將環境所有的狀態遍歷過，而高權重的模擬器則是環境的動態變化，使得代理人即使耗費相當大之時間成本也未必能遍歷全部狀態。真實環境則是不透過模擬器，直接與真實的環境進行互動並訓練。然而真實環境中，狀態變數不受模擬器限制，且運行時間也較模擬器慢，蒐集代理人訓練資料也會較慢，因此直接在真實環境中訓練並不一定為最佳選擇。

在交通號制控制上，過往有許多研究針對路口或是路網建構交通模型，以求解最佳號誌時制，此種交通模型可透過參數調整，應用於不同類型路口，做為 AI 號制控制學習環境。其優勢為可藉由過往多年研究經驗做為代理人學習基礎，AI 較不會做出預期外行為。且由於過程中無須微觀車流運行狀態，相較於微觀車流模擬環境，所需訓練時間較短，但此種方式中存在較多對於交通參數假設，使得 AI 號制控制學習仰賴於交通參數假設之準確度，本計畫交通模型學習狀況概念如圖 4.5.3 所示。

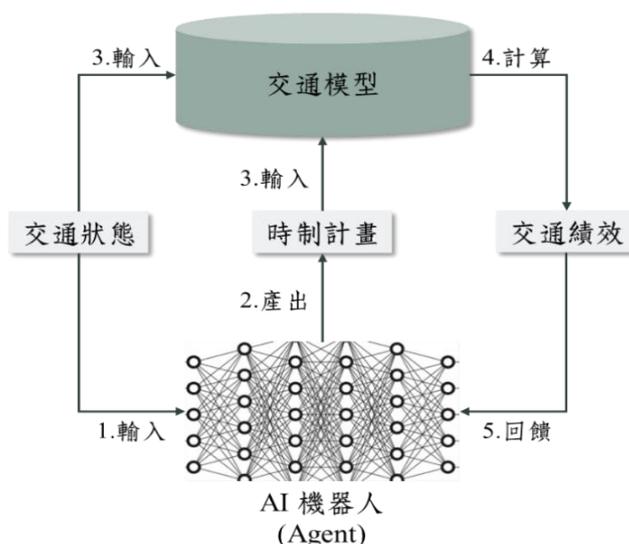


圖 4.5.3 本計畫 AI 號制控制交通模型學習環境

資料來源：本計畫整理

微觀車流模擬軟體為模擬真實車流運行狀況，時間流動的速度較真實環境快，可以快速產生大量樣本，且可觀察決策對於車流環境影響，故剛好符合 AI 強化學習號制控制需要大量訓練樣本條件。在過程中，也可觀察是否朝預期方向，進行學習與微調，績效的偵測也依照交通工程師之需求做模擬，而不需建置之成本。微觀車流模擬軟體提供許多資訊，幫助 AI 強化學習號制控制需進行學習，惟當模擬運行或偵測狀況與真實現象不盡

相符時，將導致 AI 強化學習號制控制的決策產生落差，而無法適用於真實環境之中，模擬車流學習環境概念，如圖 4.5.4 所示。

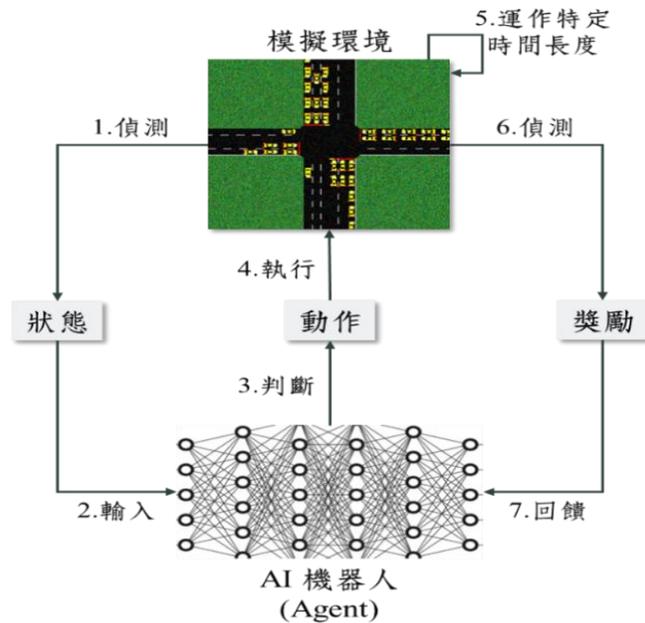


圖 4.5.4 模擬車流學習環境

資料來源：本計畫整理

為避免 AI 學習錯誤資訊，最理想的方式即是讓 AI 強化學習號制控制於真實環境中學習，然而如前面所述，在真實環境之訓練成本與對交通衝擊過大。目前有許多研究在嘗試解決此一問題，圖 4.5.5 的 DQfD 演算法即為其中一種處理方式，透過兩階段的模仿與自我學習，在增強適應真實環境的車流特性能力。

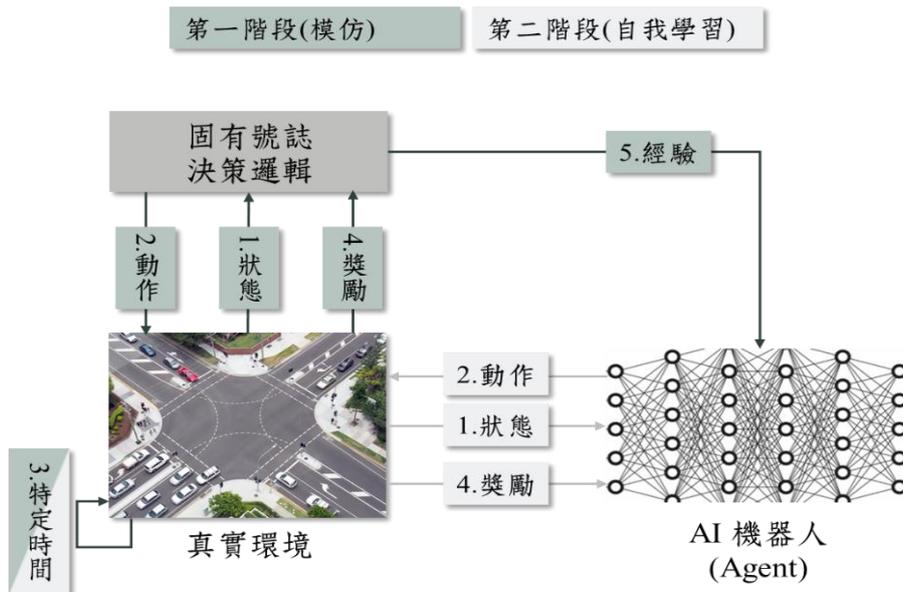


圖 4.5.5 DQfD 於真實環境學習概況

資料來源：本計畫整理

9. 其他學習方面

AI 強化學習號制控制在學習初期時，必須大量的探索環境，以找到正確學習之方向，然而在探索過程，可能會花費大量時間，且導致環境狀況惡化。故可透過學習其它專家之經驗，使 AI 強化學習號制控制在與環境進行互動之前就能先有較良好之表現。另外，當所訓練 AI 強化學習號制模式欲移植至其它車流環境時，亦可透過遷移學習(Transfer learning)技術，將先前任務所學習知識(knowledge)，應用於新任務(交通環境)中。

10. 車流偵測器方面

AI 強化學習號制控制在學習的過程中，主要包含狀態、動作及獎勵等三個部分，其中狀態及獎勵的取得皆須依靠車流偵測器。車流偵測器所能偵測的績效分為巨觀以及微觀，巨觀績效所涵蓋的範圍及時間較大，像是每分鐘流量、各方向速度及車道佔有率等；微觀績效則是較為及時且針對單一車輛，像是車輛於車道中位置、車輛速度、車輛停留時間、旅行時間等。當偵測之績效越多，AI 強化學習號制控制則可以越清楚判斷目前之交通狀況，然而考量設備之建置成本，車流偵測器必須有效益地布設。針對不同號制控制需求，所需績效可能也略微不同。例如：逐周期的控制方式需要巨觀績效，以預測未來趨勢，逐秒控制則是必須及時偵測績效，以應變交通狀態變化。

本計畫原先欲路口延滯績效做為強化學習的獎勵，然而受實務環境中無法將車流偵測器架設於路段中的限制，故未採用此績效，最終考量下列因素，單純採用流量做為 AI 強化學習之狀態輸入。

- (1) 車流偵測器裝設位置：因無法裝設於路段中與完整偵測車隊長度，故將車流偵測器裝設於上游路口，偵測流入路口之流量，以掌握進入 AI 控制路口之需求特性，推估其等候特性。
- (2) 上游流入流量與路口紓解流量偵測之差異：在時間內路口紓解流量為路口紓解能力，若路口車流飽和時，車隊將殘留於路段上卻未被納入考量，故無法真實反映路口之需求，故採用上游車流偵測器輸入之流量。
- (3) 車流偵測器偵測範圍與誤差：受限於車流偵測器偵測範圍僅能偵測接近路口之車輛，若以延滯或停等時間做為狀態，則於路段中之車輛狀態可能會被忽視，導致在求解號制時制之誤判。

- (4) 交通易取得之參數：流量為交通常用參數，且有許多車流偵測器皆能偵測流量，未來若要套用本計畫 AI 號誌控制模式，則不應受限於車流偵測器型態。

基於以上考量，本計畫 AI 強化學習號誌控制架構，如圖 4.5.6 中深色方塊流程所示。本計畫針對幹道中兩路口進行控制，每次週期結束前，依據時段型態，首先挑選適當號制週期長度，再選擇下一週期之時制計畫，此動作為基於價值方式訓練的離散型。狀態為幹道中各個方向之流入流量，故為全部資訊均為可觀察。在獎勵上，在每次選擇時制計畫後皆與專家時制進行比對並以相似度做為對應之獎勵，故屬於非稀疏獎勵。同時本計畫在經驗累積一定數量後才取樣進行訓練，因此為離線訓練。而在模擬器部分，採用流量輸入並輸出專家時制，且六個方向之流量皆在固定範圍，因此訓練環境屬於低權重。

未來在 AI 號誌控制架構的發展上，可逐漸由路口與路段，往路網發展，並調整為多代理人共同進行幹道運作。而若考量控制之穩定性，採用逐週期方式可以有更佳穩定性，且在路網協控上也較易進行。狀態部分，若在路網中各個區域皆裝設車流偵測器，可能導致建置成本過高，故可考量車流偵測器僅裝設在重點路段上。動作部分，則是需要考量代理人控制行為，會依據不同目的來選擇離散型或是連續型，並搭配相關之訓練方式，以求解最佳策略。在訓練的環境上，則可搭配微觀車流模擬器提供代理人不同交通績效，且可依據需求搭配不同強化學習技術，以期 AI 號誌控制可順利運作於真實環境。

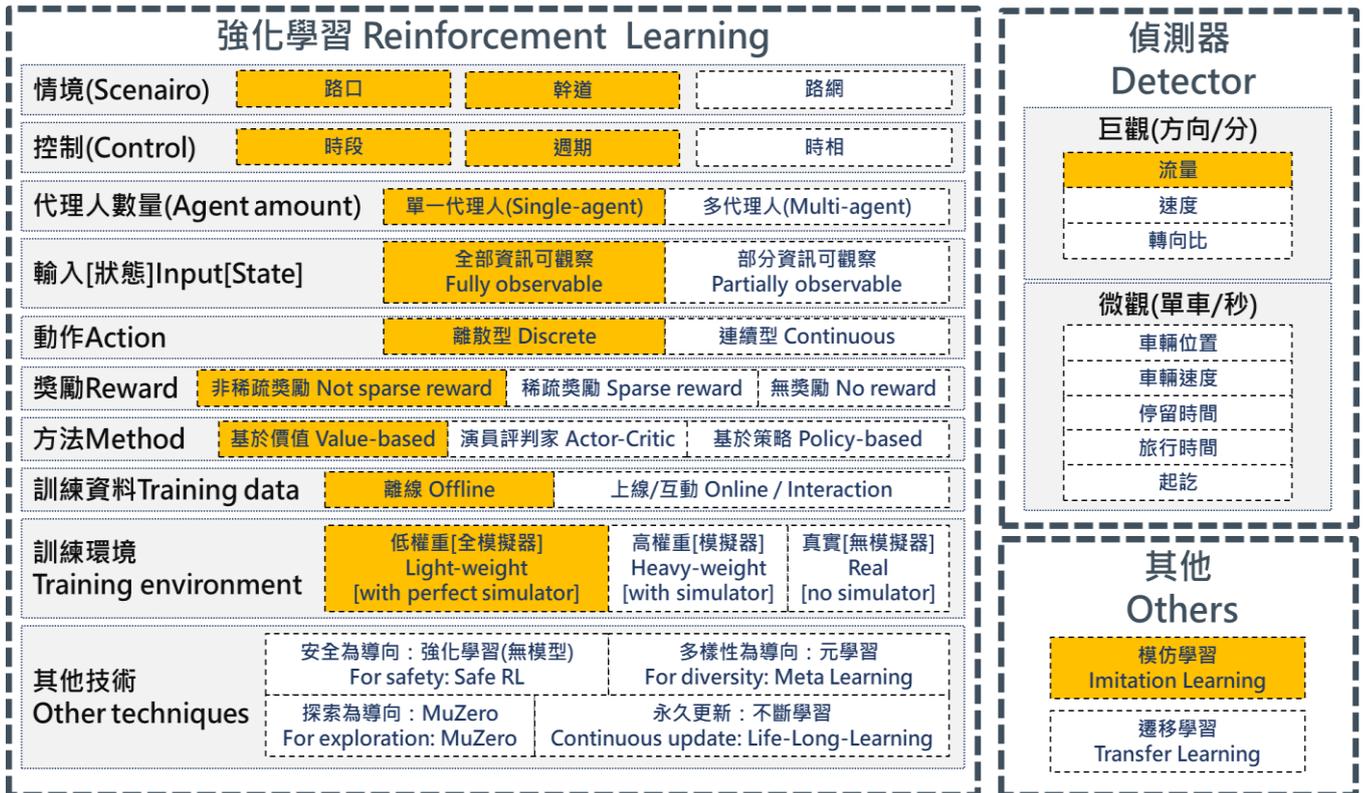


圖 4.5.6 本計畫 AI 強化學習號誌控制之架構

資料來源：本計畫整理

第五章 我國交通運輸未來導入 AI 應用探討

隨著人工智慧(AI)相關技術在近年來的快速發展，特別是在資料蒐集、分析、預測等面向都有良好的成果，若將這些 AI 技術應用於交通領域，可望有效改善解決交通問題的能力，提升整體交通效率。因此本章探究本所未來導入 AI 於交通領域應用，期望藉由引進人工智慧使我國的交通日益進步。

本章依據文獻回顧來彙整人工智慧在技術面發展與目前應用情形，來做為我國未來 AI 於交通領域之整體規劃基礎，與探討未來可能的發展方向。5.1 節分析人工智慧技術較適合處理哪些類型的問題，5.2 節回顧交通部 2020 的運輸政策白皮書，希望本計畫規劃方向能與上位政策接軌，5.3 節分析 AI 在交通運輸領域的適合應用，5.4 節針對前述提出的應用，

5.1 適合 AI 應用的環境分析

本節從 AI 目前的發展分析適合應用的環境。目前人工智慧技術可以處理人類感知與認知能力，但仍無法完成主觀的創造力與產生自我意識，因此本計畫整理 AI 適合在具有以下特性的環境下進行應用。

1. **重複性高**：指工作內容重複性高，學習一次之後即可多次應用。AI 最大的優勢之一就是不會疲勞，但相對較無創造與創新能力，因此非常適合不斷重複的工作。
2. **與人互動低**：AI 適合應用在不需與人有太多互動的環境，例如：服務業。由於互動程度高的工作，需要因應對象的不同反應或感受，而有不同程度的因應，這是目前機器難以達成與取代。
3. **勞力密集**：相較於腦力密集需要大量且快速思考與判斷的工作，勞力密集的工作更適合 AI 應用。相較於人類，AI 不會疲累，也不會因為生理或心理的因素而在作業上有所誤差，因此能更有效率且準確的處理勞力密集的工作。

從圖 5.1.1 與圖 5.1.2 的職業特性象限圖中可看出，第二象限皆為最容易被 AI 取代的工作類別，重複性高且與人互動低，例如洗碗人員、初級翻譯人員、倉管員...等；勞力密集且重複性高，例如：清潔人員、保全人員...等。第四象限因為是需要高度社交行為或創意的非重複性工作，屬於較不容易被 AI 取代者，例如：心理醫生、老人照護、髮型設計師...等；或者知

識密集且重複性低的工作，例如：運輸規劃、路線設計...等。

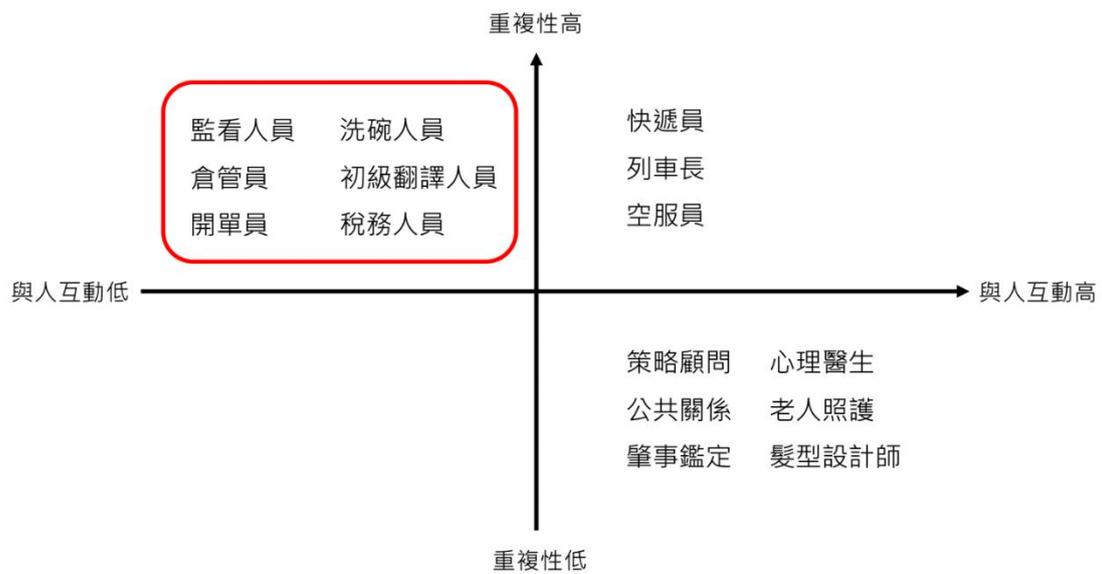


圖 5.1.1 職業特性象限圖-與人互動

資料來源：林祥生(2018)，交通大學運管系專題演講

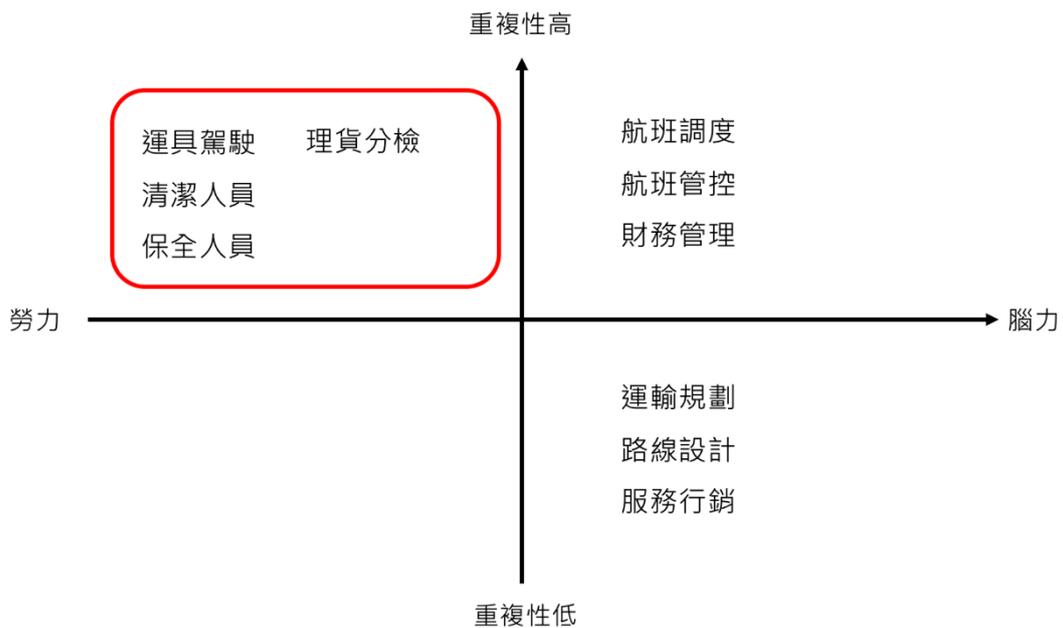


圖 5.1.2 職業特性象限圖-勞力

資料來源：林祥生(2018)，交通大學運管系專題演講

綜合上述分析，人工智慧適合應用在「問題結構化」、「程序重複化」、與「資料密集化」的應用方向，如圖 5.1.3 所示。資料密集化代表可以蒐集到足夠的資料，可以做為人工智慧學習的來源。問題結構化代表問題可以明確定義，且解決問題的方法具有規律性。通常人工智慧機器學習的方法，擅長對於明確定義問題找出因應規則。程序重複化代表對腦力或是隨機應

變的要求比較低，對於人工智慧的技術而言，是比較適合的應用面向。



圖 5.1.3 AI 適合環境特性

資料來源：本計畫整理

人工智慧適合應用在交通產業，交通運輸相關規劃與管理針對的是運具、號誌、道路設施等，較不需與人面對、交流，屬於社交性弱的產業。且交通決策行為每天不斷重複發生，例如：號誌時制的調整，每個路口每個週期皆在重複；大眾運輸業的排班調度亦是每日循環重複，因此具有重複性高的特性。再加上臺灣地區交通繁忙，每日皆產生大量資料，包含 ETC、車流偵測、閉路電視、電信信令資料等，屬於資料密集產業。因此交通產業是適合利用機器學習來進行分析。

5.2 回顧 2020 運輸政策白皮書-智慧運輸

交通部 2020 年版運輸政策白皮書的智慧運輸章節提到許多未來願景，本計畫依此探討 AI 在未來五年交通整體規劃，以期接軌白皮書的展望。2020 年版運輸政策白皮書中提及目前交通面臨六大課題分別為：需求轉型、科技轉型、服務模式、交通安全、交通管理、執行環境，以下簡要說明。

1. 需求轉型：由於民眾對於智慧運輸服務的需求逐漸改變，應著重於即時交通資訊、行動化應用服務、整合性交通服務層面，以符合民眾需求。
2. 科技轉型：新興科技發展，交通單位應思考如何藉由新科技，提升交通安全、管理效率及服務績效。
3. 服務模式：為促進多元應用服務之發展，應持續推動數據整合與資料開放、鼓勵業者改變既有營運模式進行異業聯盟、推動智慧化機場提升機場效率等。
4. 交通安全：為提升道路交通安全，駕駛安全輔助及事故防護須加以改善。

5. 交通管理：管理層面有交通資訊資訊涵蓋面不足、事故通報資料不夠完善的問題，且為了改善交通壅塞需持續精進智慧化管理措施，並需加強跨機關跨運具的管理協調與整合，提升整體管理效率。
6. 執行環境：政府應與民間合作，降低新科技發展與實際應用之間的落差，使推動更為順利。同時政府也需建立相關法規與技術標準與世界接軌。並且，為了強化智慧運輸的服務效益，應建立跨單位協調平臺。

此六大課題可以整理成四大政策目標：交通安全、交通順暢、交通無縫與產業發展，並共提出包含人工智慧在內之 13 項策略，如圖 5.2.1 所示。

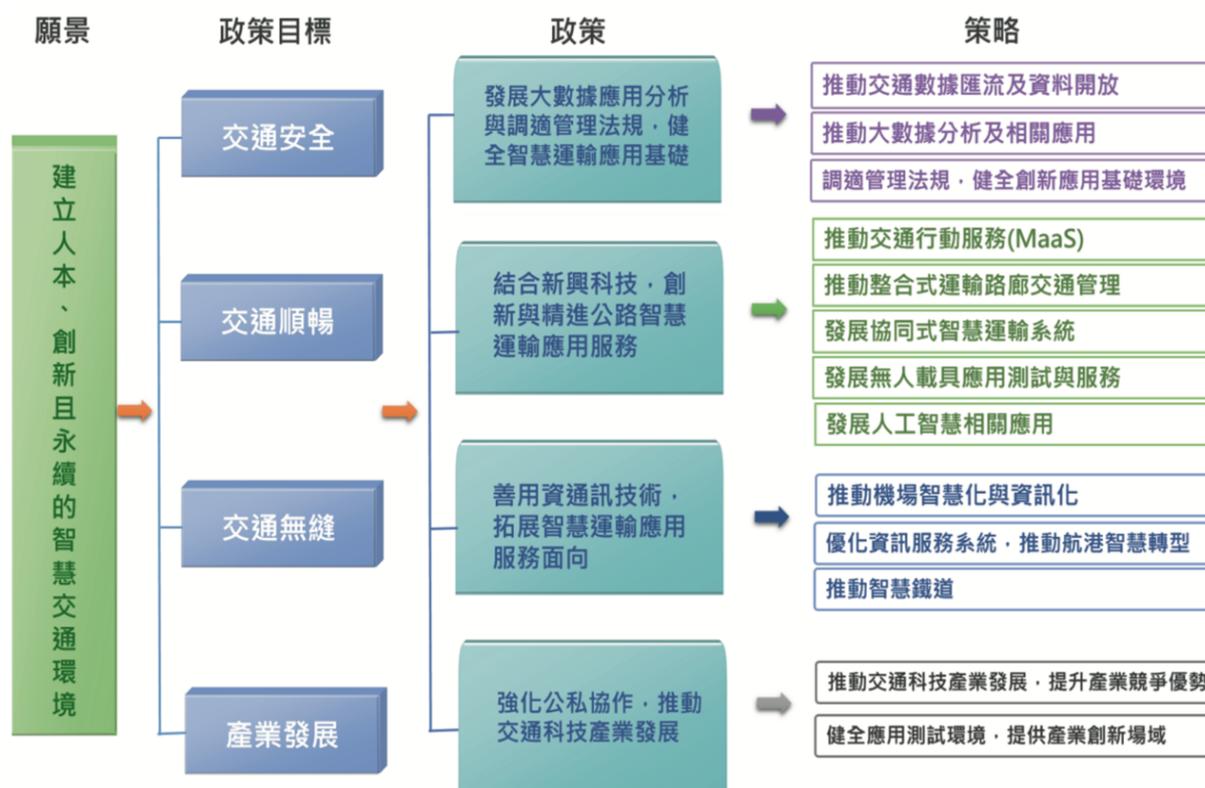


圖 5.2.1 2020 運輸政策白皮書-智慧運輸之願景、政策目標、政策與策略
資料來源：2020 運輸政策白皮書-智慧運輸

四大政策目標中，本計畫認為「交通安全」、「交通順暢」、及「交通無縫」的相關策略較適合透過人工智慧實現。因此，本計畫將以此三大目標為方向規劃 AI 未來五年之發展，將於 5.3 節中將詳細說明。

5.3 AI 在交通運輸應用探討

交通運輸領域非常廣泛，為求應用方向的收斂與掌握，同時也與智慧運輸發展的主要方向相契合，因而本計畫主要以陸運為導入人工智慧對象，並將應用層面分為資料蒐集與環境偵測、資訊提供與預測、以及交通改善與營運管理等三個應用層面。圖 5.3.1 為三大應用層面對應前節「交通安

全」、「交通順暢」、及「交通無縫」等三大目標方向，以及探究導入 AI 技的預期成果。

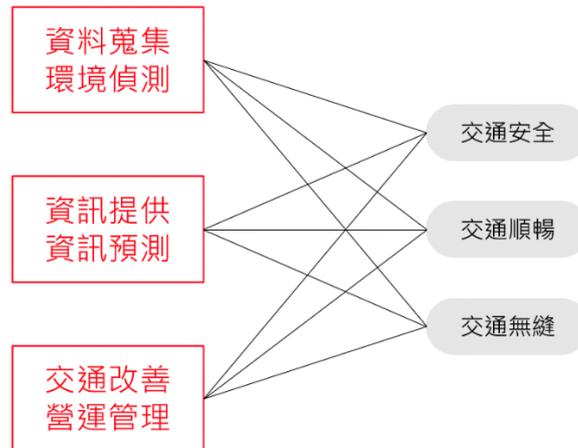


圖 5.3.1 2020 運輸政策白皮書-智慧運輸之三大應用層面

資料來源：本計畫整理

1. 資料蒐集與環境偵測

進行任何分析、策略制定、與管理方案擬定，第一步就是需要可靠的資料來源。除此之外，為了可以達到有效管理與決策支援目標，也必須對相關運輸環境進行偵測，才能夠應用外在環境的變化，做出有效的對應措施。在目前人工智慧的發展中，影像辨識技術相對成熟，因此希望未來能用此技術針對交通進行各種面向的資料蒐集與偵測。

圖 5.3.2 為此面向之 AI 導入潛在應用，將「資料蒐集與環境分析」的應用層面分別就「交通安全」、「交通順暢」、及「交通無縫」三大目標分別擬定建議的功能，茲說明如後。

(1) 交通安全

以下針對有關「交通安全」之「資料蒐集與環境偵測」相關建議發展方向進行說明。

① 異常駕駛行為

在運具內安裝攝影機，利用影像辨識技術，針對一般小客車、客運和物流車輛駕駛的駕駛行為進行偵測，了解其是否有異常或分心行為。例如：駕駛途中使用電子產品、駕駛途中進食等有礙安全駕駛的行為。目前已有業者正在研究此部分的應用，導入 AI 影像辨識後預期能準確的辨識異常駕駛行為。

② 行人路口通行安全

此部份可根據應用目的的不同，可將攝影機架設於行人穿越道

附近或運具內。導入 AI 影像辨識後，預期利用行人穿越道的攝影機，透過影像辨識技術，偵測正在穿越行穿線的行人，並計算行人的行走速度與通過路口的所需時間。本項資訊可做為日後設計與調整最短綠燈時間之用，也可提供相關警示系統之用。此外，運具內的攝影機則預期可以偵測車輛周遭的行人，並提供資訊給相關的警示系統，以提醒駕駛注意，可以避免發生不必要的事故。

③ 違規偵測

導入 AI 影像辨識後，預期利用道路上的攝影機，透過物體辨識，偵測車輛以及行人的違規舉動，提供相關單位後續處理的依據。例如車輛違規停車、車輛違規穿越雙黃線、行人隨意跨越馬路等。

④ 事故偵測

利用道路上裝設的攝影機，隨時偵測道路上發生的事故，並且與警消單位連線，縮短通報時間，即時反應，將傷亡降至最低，也能減少事故造成的交通阻塞時間。

⑤ 交通設施檢測

利用 AI 辨識技術，偵測路面、橋樑、隧道、軌道等交通基礎設施，是否有狀況需要關注或改善。例如偵測道路鋪面情況、偵測橋樑健康程度、隧道健康程度、軌道健康程度等。

⑥ 自駕車相關偵測

除了上述五點利用架設於各處攝影機所蒐集的資料，自駕車的發展也是未來 AI 應用的一大領域。因此可嘗試將攝影機架設於運具上，利用 AI 技術，預期蒐集與四周車輛的相對位置、偵測道路上各式標線、標誌、號誌等，從運具內部對環境進行全方位的偵測。

(2) 交通順暢

以下針對有關「交通順暢」之「資料蒐集與環境偵測」相關建議發展方向進行說明。

① 交通數據蒐集

利用架設在適合位置 AI 攝影機，準確偵測各類交通數據，例如：流量、路口轉向比、各車種比例、機慢車比例、紅燈車輛等候長度、延滯時間等。以此資料為依據，可進行許多交通資訊分析，以及做為相關的交通控制的基礎。

②車牌辨識

利用道路上的攝影機，搭配文字辨識技術，偵測通過的各類運具之車牌，可以知道每一車輛的移動軌跡與旅行時間。以此資料為依據，後續可以進行相關的分析，以及做為相關的交通控制的基礎，也可以整合物流業者的相關資料，針對物流車輛進行追蹤與分析。

③車輛到達時間

將 AI 攝影機架設於興趣區域，例如：旅遊熱區、學校、科學園區等，偵測車輛到達與離開之時間。預期可以了解興趣區域的車輛到離尖離峰分佈。以此資料為依據，後續可以做為相關交通與旅運管理的基礎。

④車輛停留時間

將 AI 攝影機架設於興趣區域，例如：旅遊熱區、學校、科學園區等，預期利用車牌辨識，偵測每台車輛在該地停留之時間。可以做為停車需求分析之依據。

⑤商業用車臨停狀況

利用架設於道路上的 AI 攝影機，特別針對商業用車，例如：超商物流車，偵測其路邊臨時停車的狀況。例如：臨時停車時間數量、臨時停車時間長度、臨時停車尖峰時段等，預期可做為未來訂定相關法規的依據。

(3) 交通無縫

以下針對有關「交通無縫」之「資料蒐集與環境偵測」相關建議發展方向進行說明。

①使用者到達時間

將 AI 攝影機架設在公共運輸場站(公車站牌、捷運站入口)，偵測每位使用者到達站點時間，以了解各個場站的人潮尖離峰時段。

②等候人數

利用公共運輸場站的 AI 攝影機，偵測排隊等候服務之人數，可做為未來場站擴建或設施增設的依據，也可以做為優化場站服務流程的基礎。

③等候時間

利用公共運輸場站的 AI 攝影機，偵測每位使用者的等候時間，可做為未來班次調整的依據，也可以做為優化場站服務流程的基礎。

④ 公共運輸服務流程處理時間

利用公共運輸場站的 AI 攝影機，偵測服務每位旅客所需的時間，例如：報到櫃台所需時間、安檢櫃台所需時間、自助報到機所需時間等，預期可以獲得準確的資訊，做為未來流程改善之用。



圖 5.3.2 AI 於資料蒐集與環境偵測面向之 AI 導入潛在應用

資料來源：本計畫整理

2. 資訊提供與預測

此層面旨在將上一層面中所蒐集的資料轉換成有用的資訊且進行需要的預測，並將其結果提供給需要的管理者與用路人。管理者可以了解未來可能的道路狀況，以利提早進行規劃，而用路人能提早評估與規劃出行時間。

圖 5.3.3 為此面向之 AI 導入潛在應用，將「資料提供與預測」的應用層面分別就「交通安全」、「交通順暢」、及「交通無縫」三大目標分別擬定建議的功能，茲說明如後。

(1) 交通安全

以下針對有關「交通安全」之「資料提供與預測」相關建議發展方向進行說明。

① 疲勞偵測

利用運具內的攝影機偵測駕駛行為，分析行為中的呵欠與眨眼次數等身體反應，判斷其精神狀態是否為疲勞駕駛。對於小客車、客運車輛與物流車輛駕駛，亦皆可進行疲勞偵測，並將結果納入第③點之駕駛員評鑑。

②安全警示

此部份根據應用目的的不同，可將攝影機架設於運具，針對駕駛視線死角或內輪差等範圍進行危險事件偵測與分析，當偵測到危險，例如：出現行人或機慢車時，立即警示駕駛。對於架設於道路上的攝影機，則可判斷路口是否有被臨停車輛或其他障礙物擋住視線，若有安全疑慮則進行警示或通報。

③駕駛員評鑑

透過運具上的攝影機蒐集的駕駛行為資料，輔以其他設施(如數位式行車記錄器、車載診斷系統)可以提供的資料，可以對駕駛員進行評鑑，找出需要進一步輔導的駕駛。對於客運車輛與物流車輛駕駛更是須要審慎評估，由於其駕駛之運具為大型車輛，需要更嚴格之評鑑，以確保道路交通安全。

④危險警示

透過道路上的 AI 攝影機所蒐集的道路交通狀況、路口現況與車輛違規次數等資料，利用機器學習方法分析時常發生交通意外的地點。更進一步則可以利用上述資料預測可能發生危險的地區，並提早警示管理者，讓管理者能夠提早發現需注意的路段，避免事故發生。

⑤車輛異常預測

利用車載診斷系統(On-Board Diagnostics, OBD)回傳的資料，應用機器學習分析法分析並預測有狀況的車輛，提早告知駕駛或管理者，及早進行維修，防止事故發生。

(2) 交通順暢

以下針對有關「交通順暢」之「資料提供與預測」相關建議發展方向進行說明。

①行駛速率預測

使用道路上的 AI 攝影機蒐集之交通數據資料，訓練 AI 機器學習模型，例如：類神經網路、卷積神經網路等方法，使用車牌辨識等資料分析，並預測未來道路行駛車速。

②旅行時間預測

使用道路上的 AI 攝影機蒐集之交通數據資料，建立 AI 機器學習模型，分析並預測旅行時間，更進一步可以做到預測起訖點旅行時間，此資訊將能提供用路人規劃出行時間。

③路況預報

運用 AI 攝影機所蒐集的資料，在路口及高速公路上進行未來時間的路口預測。相關的管理單位，可以利用這些未來時間的預測資料，未雨綢繆，在擁擠發生前提早部署，可有效減少交通擁擠發生的機率或嚴重程度。對於物流車輛駕駛，也可以透過路況預報的資訊提前規劃與更改行駛路線，使物流運送更為順暢。

④人數預測

運用興趣區域的 AI 攝影機所蒐集的資料，提供目前人潮警示，並且建立機器學習模型預測未來此地可能的人潮，供欲前往該地的用路人參考與規劃。另外也可將範圍擴大，提供附近交通狀況的預測資訊，有效進行用路人分流。

⑤停車空間預測

運用興趣區域的 AI 攝影機所蒐集的資料，提供目前停車資訊，並且建立機器學習模型預測未來此地可能的車潮，與剩餘停車位預測，供前往該地的用路人參考。

(3) 交通無縫

以下針對有關「交通無縫」之「資料提供與預測」相關建議發展方向進行說明。

①等候人數預測

利用公共運輸場站內的 AI 攝影機所蒐集之資料，例如等候人數、使用者到達時間等，預測未來等候人數，並公告給需要的民眾，用以分流人潮。

②等候時間預測

利用公共運輸場站內的 AI 攝影機所蒐集之資料，例如：等候人數、處理時間等，建立機器學習模型，進行等候時間預測，並將結果公告給需要的民眾，進行分流。此資訊亦可讓管理單位進行場站優化。

③旅客旅次時空分析

由於我國電信基地台覆蓋率高，且大眾運輸票證整合成功，因此可以利用信令資料與票證資料，搭配機器學習方法的應用進行旅客旅次時空分析。了解旅客轉乘熱點、旅遊熱點等資訊。此資訊可以使管理單位更了解民眾的旅運需求，未來更可以此為依據進行交通優化，達到交通無縫之目的。

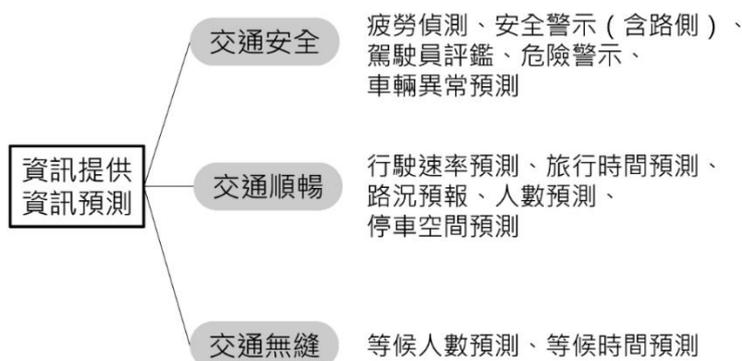


圖 5.3.3 資訊提供與預測面向之 AI 導入潛在應用

資料來源：本計畫整理

3.交通改善與營運管理

利用前兩層面所蒐集的資料與產生或預測的資訊，可以做為交通改善與營運管理的基礎。圖 5.4.4 為此面向之 AI 導入潛在應用，將「交通改善與營運管理」的應用層面分別就「交通安全」、「交通順暢」、及「交通無縫」三大目標分別擬定建議的功能，茲說明如下：

(1) 交通安全

以下針對有關「交通安全」之「交通改善與營運管理」相關建議發展方向進行說明：

① 駕駛員排程

根據駕駛員評鑑的結果，在滿足相關規定(如駕駛工時)的前提下，進行駕駛人員排程優化。

② 緊急煞車

當運具內或道路上的攝影機出現安全預警時，除了即時警示駕駛外，也能自動執行緊急煞車的動作，避免反應不及發生意外。

③ 變換車道輔助

當道路前方出現事故警示資訊，可結合智慧 CMS，輔助後方駕駛預先變換車道，不但可以減少突然變換車道的風險，也能舒緩事故所產生的壅擠問題。

④維護基礎設施

當管理單位收到道路、橋樑、隧道、軌道等基礎設施的狀況偵測所發出的危險區域警示時，可以立即前往進行基礎設施維護，及早排除危險狀況，避免重大意外。

⑤車輛檢修與維護

相關業者透過車輛異常預測，提早找出可能發生意外的車輛，進行維修檢測。

⑥自駕車研發

根據前述蒐集之資料，配合物聯網與基礎設施的建置，進行自駕車的研發與精進。使得道路上車輛皆能遵守法律規範，並且消除疲勞駕駛所產生的道路威脅。進而達成交通安全的最終目的。

(2) 交通順暢

以下針對有關「交通順暢」之「交通改善與營運管理」相關建議發展方向進行說明：

①號誌控制

利用路口狀態預測等資訊，應用本計畫的強化式學習進行交通號誌控制，在路段發生擁擠之前先採取措施，降低擁擠。依照實驗場域可再細分為三個步驟：

- 第一步：用於獨立路口：將運用 AI 影像辨識所蒐集之資料，訓練出適合單一獨立路口的 AI 號誌控制模型，並配合政府單位再適合的獨立路口進行落地實驗。分析並精進績效，以利下一步使用。
- 第二步：擴充至幹道連鎖：將獨立路口擴充至幹道連鎖路口，以獨立路口的模型為基礎，擴充所需參數，將模型應用至幹道連鎖的多路口。期望達成幹道順暢的目的。

- 第三步：擴充至整個路網：接者持續擴大場域，將多組幹道連鎖路段相互連結，最終達成整個路網順暢的目的。

②時空疏導

利用道路路況預測資訊，推薦用路人最適出行時間。利用預測結果告知用路人最適合的出發時間與行駛道路，有效分散車潮，也能減少旅行時間。

③調撥車道

利用興趣區域的車輛到達時間、道路路況預測等資訊，設計實施調撥車道，例如：分析並預測尖峰時段的科學園區附近的交通狀況，進而實施調撥車道，以疏散通勤旅次。

④替代道路

利用路口狀態預測等資訊，進行塞車地點警示、替代道路推薦。例如：將未來可能塞車的路段提早告訴用路人，並推薦替代道路，減緩可能造成的擁擠，也減少用路人的旅行時間。

⑤優先通行車輛

根據事件偵測資訊，建立警消優先指示燈號，讓駕駛能更容易發現警消車輛並且順利讓道加快救援速度，且優先號誌也能避免救援途中發生事故。

(3) 交通無縫

以下針對有關「交通無縫」之「交通改善與營運管理」相關建議發展方向進行說明：

①班表優化

透過分析與預測站點等候人數、旅客到達時間等資訊，管理單位及相關業者可以清楚旅客的旅運需求，根據資訊嘗試以機器學習方法進行班表優化，預期達成減少時間縫隙的目的。

②流程優化

利用旅客等待時間、旅客處理時間等資訊，進行場站的優化。相關業者透過資訊，可以簡化服務流程、調整旅客動

線等，預期使整體服務流程更順暢，提升服務水準。

③旅運行為分析（票證、信令）

利用票證資料、手機信令等資料，分析旅客的旅運行為，並以此為依據設計為更無縫的班表。

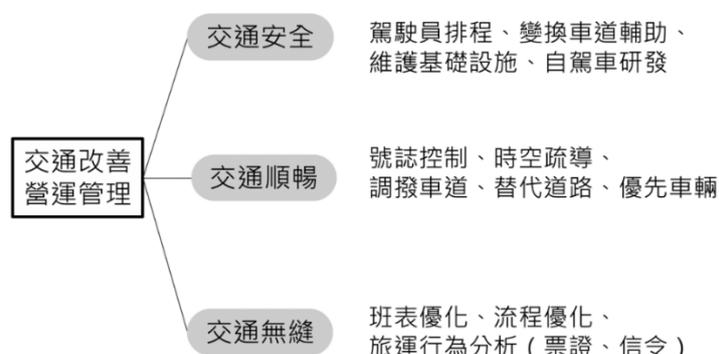


圖 5.3.4 交通改善與營運管理面向之 AI 導入潛在應用

資料來源：本計畫整理

5.4 AI 交通運輸應用之短中長期發展探討

在 AI 於交通運輸應用之三大目標（交通安全、交通順暢、交通無縫）與潛在應用對照部分，本計畫初擬如表 5.4.1 所示。該表列舉 5.3 節中提及之不同目標可以蒐集與偵測的資料，並將其對應到可提供與預測的資訊，最後則是該資訊能進行的交通改善與營運管理。

在 AI 交通運輸應用之短中長期時程上，本計畫依「AI 應用適合度」與「交通運輸需求迫切度」來進行規劃。「AI 應用適合度」所指為分析該交通運輸問題是否有重複性高、與人互動低和資料高度結構化的特性，探討該問題是否適合應用 AI 人工智慧來解決，越適合應用 AI 來解決者，會盡量安排在短期或近期內來發展。「交通運輸需求迫切度」所指為考慮目前最迫切需要解決的交通運輸問題，分析改善各種交通運輸問題後，哪些能使整體社會福利有效提升。以此為據，可按照迫切度高低進行排程，迫切程度越高者，則盡量安排在短期或近期內來發展。

表 5.4.2 為本計畫依此原則將 AI 於交通運輸應用之短中長期時程劃。本計畫利用「AI 應用適合度」與「交通需求迫切度」兩面向，來審視每個關心課題，並分別給予 1~5 的分數（得分越高表示 AI 應用適合度越高、交通需求迫切度越高）。例如：行人穿越[5,5]，中括號裡的兩個數字依序分別為 AI 應用適合度與交通需求迫切度的得分。將兩項得分加總後，由高而低排序，並且配合表 5.4-1 中所示三大目標中的先後順序，進行發展時

程規劃。

表 5.4-1 AI 於交通運輸之三大目標與潛在應用

	資料蒐集/環境偵測	資訊提供/資訊預測	交通改善/營運管理
交通安全	異常駕駛行為	疲勞偵測、駕駛員評鑑	駕駛員排程
	行人穿越	安全警示	緊急煞車系統
	違規偵測	駕駛員評鑑	<ul style="list-style-type: none"> ● 駕駛員教育訓練 ● 緊急煞車系統 ● 變換車道輔助
	事故偵測	安全警示	<ul style="list-style-type: none"> ● 緊急煞車系統 ● 變換車道輔助 ● 優先車輛(交通順暢)
	狀況偵測：道路、橋樑、隧道、軌道	危險警示	相關單位維護基礎設施
	車上診斷系統	車輛異常預測	相關單位檢修維護車輛
	自駕車相關偵測		自駕車研發
交通順暢	交通數據	行駛速率預測、旅行時間預測、路況預報	<ul style="list-style-type: none"> ● 號誌控制 ● 時空疏導 ● 調撥車道 ● 替代道路
	車牌	旅行時間預測	
	車輛到達時間	人數預測、停車空間預測	
	車輛停留時間	人數預測、停車空間預測	
	商業用車臨停狀況		
交通無縫	使用者到達時間	預測人車潮	班表優化
	等候人數	等候人數預測	班表優化
	等候時間	等候時間預測	流程優化
	處理時間	等候時間預測	流程優化
	票證資料、手機信令	旅客時空分析	班表優化、旅運行為分析

資料來源：本計畫整理

表 5.4-2 AI 於交通運輸應用之短中長期時程劃

	資料蒐集/環境偵測	資訊提供/資訊預測	交通改善/營運管理
短期	行人穿越[5,5] 違規偵測[5,5] 事故偵測[5,5] 狀況偵測+[5,5] 交通數據+[5,5] 車牌+[5,4] 票證資料、手機信令[5,4] 異常駕駛行為+[4,5] 車上診斷系統[4,5] 使用者到達時間+[4,4] 等候人數[4,4] 等候時間[4,4] 處理時間[4,4]	安全警示[5,5] 危險警示[5,5] 旅行時間預測+[5,4] 行駛速率預測+[5,4] 路況預報+[5,4] 旅客時空分析+[5,3]	NA
中長期	車輛到達時間[4,4] 車輛停留時間[4,4] 商業用車臨停狀況[4,4] 自駕車相關偵測+[3,4]	疲勞偵測[4,5] 駕駛員評鑑[4,4] 預測人車潮+[3,4] 等候人數預測[3,4] 等候時間預測[3,4] 車輛異常預測[4,3] 人數預測+[3,3] 停車空間預測[3,3] 自駕車研發+[3,4]	駕駛員排程[5,4] 緊急煞車系統+[5,5] 變換車道輔助+[4,4] 優先車輛+[4,4] 相關單位維護基礎設施+[4,4] 駕駛員教育訓練[4,3] 商用車輛法規訂定+[4,2] 旅運行為分析+[3,2] 班表優化+[4,3] 流程優化+[4,3] 相關單位檢修維護車輛[2,3] 號誌控制[2,3] 時空疏導[2,3] 調撥車道[2,3] 替代道路[2,3]
備註： +：建置與進行可能需多於一年 [a,b]：兩大排年期原則之得分			

資料來源：本計畫整理

第六章 結論與建議

交通壅塞問題為都市交通管理的一大挑戰，從蒐集車流資料至研擬號誌控制策略，往往耗費大量人力與物力資源。近年來人工智慧(AI)技術快速發展，如何藉由 AI 深度學習之類神經網路模式解決交通問題為交通領域當前之重要課題。因此，本計畫強化前期 AI 影像車流偵測技術蒐集，並將之應用於 AI 仿真學習的都市號誌控制上，以下為本計畫提出下列幾點結論與建議。

6.1 結論

1. 本計畫以臺中市「樂業-十甲東」、「樂業-東英」兩路口做為實驗場域，導入 AI 影像辨識設備進行交通數據之蒐集，並建構 AI 號誌控制架構，利用 AI 影像辨識技術所獲得之交通參數，透過經學習後的 AI 號誌控制模式，依即時交通量來選取與執行適當時制計畫。
2. 本計畫應用 AI 影像辨識技術於交通車流偵測與資料蒐集，在車輛偵測上主要採用 SSD 之深度學習神經網路模式，物件追蹤則採用 SORT 演算法。本計畫透過臺中市「樂業-十甲東」、「樂業-東英」兩路口進行實證分析，「分車道各車種交通流量」、「路口各車種轉向交通量」、「佔有率」、「延滯」各項交通參數偵測結果說明如下：
 - (1) 分車道各車種交通流量偵測部分，在主要控制策略所使用之車種部分，小客車不分情境(包含白天、夜間及雨天)與拍攝方向，均可達 90% 以上，機車於各情境準確率達 72% 以上。
 - (2) 路口各車種轉向交通量偵測部分，在改良偵測線判定邏輯後，觀察小客車之直行準確率各情境(包含白天、夜間及雨天)多在 82.67%~96.88% 間，左右轉準確率在各情境則較不穩定，約在 40%~75% 間；機車之直行準確率各情境(包含白天、夜間及雨天)均有 83.51%~100.00% 間，左右轉準確率在各情境約在 57.14%~88.89% 間。目前針對轉向偵測部分，由於其偵測運行需要較高的運算效能方能有效偵測，故建議未來採用較高運算能力之 AI 運算晶片，同時針對所偵測畫面，應儘可能涵蓋整個路口。
 - (3) 佔有率偵測部分，於各情境(包含白天、夜間及雨天)30 個測試樣本中，準確率多在 80% 以上，可是亦有 4 個樣本準確率未達 60%。
 - (4) 延滯偵測部分，於白天在第 4 台車之車輛其準確率為 87%，於第 5

輛車時為 66%；雨天於第 3 輛車為 88%，於第 4 輛車時為 61%；
夜間於第 4 台時為 87%，第 5 台時為 67%。

3. AI 應用於號誌控制為近年來熱門議題，但因強化學習於尋找最適號誌控制時，需耗費大量試誤的探索時間才會收斂，致使較無真實環境之應用案例。本計畫利用時制最佳化分析軟體 PaSO，先行針對實驗範圍產生考量幹道續進之最佳化時制計畫與時段參數，來進行 AI 仿真學習，最後將學習後之 AI 號誌控制模式，於現場進行實際運作。
4. 本計畫事先透過微觀交通模擬軟體 SUMO 建構臺中市「樂業-十甲東」、「樂業-東英」兩路口之交通環境，進而產生 AI 號誌控制之模擬績效，最後在實測場域上進行實測。模擬與實測結果顯示，本計畫所提作法，可改善實驗場域之幹道旅行時間。星期一晨峰部分，主要路徑旅行時間改善 30%；星期五昏峰部分，主要路徑旅行時間改善 7%；一般日晨峰部分，主要路徑旅行時間改善 16%；一般日昏峰部分，主要路徑旅行時間改善 10%；星期六離峰部分，主要路徑旅行時間改善 4%；星期日離峰部分，主要路徑旅行時間改善 4%。
5. 在我國未來應用 AI 於交通運輸部分，可應用領域包括陸運、海運、空運、複合運輸之客貨運運輸，範圍非常廣。本計畫先歸納 AI 較適合之環境為重複性高、與人互動低及勞力密集。本計畫先以我國 2020 運輸政策白皮書之智慧運輸為範疇，來歸納 AI 於交通運輸應用之三大目標，包含交通安全、交通順暢及交通無縫等，進一步以陸運為分析對象，將應用層面歸納為為資料蒐集與環境偵測、資訊提供與資訊預測、交通改善與營運管理等。最後依據 AI 應用適合度及交通需求迫切度兩大原則，來規劃研擬 AI 於陸運發展的短中長期規劃。

6.2 建議

1. 在 AI 影像辨識於交通參數蒐集上：
 - (1) 應用 AI 影像辨識技術於交通資料蒐集時，其偵測邏輯首先須追蹤偵測區域內每一輛車輛動態，當車流量越多情況，所需硬體運算資源較多；同時目前智慧城市發展朝向現場設備共桿或智慧感的發展，影像攝影機的角色與功能更為多元，因此建議宜配置適當運算能力之 AI 運算晶片，以符合實務應用所需。
 - (2) 根據本計畫實測數據，AI 影像偵測在小客車直行交通量準確率可達實務應用需求，惟在左右轉轉向交通量與機車部分較為不穩定；

同時受限時測試時間，大型車輛樣本數不足，且部分準確率變異過大，因此本計畫於偵測準確率計算時參考實務作法，實際車輛(人工判斷)樣本數大於 5，方列入準確率計算，同時對於依計算公式所得準確率為負值者，均標示為「誤差過大/無法使用」。建議後續宜配置適當運算能力之 AI 運算晶片與進行演算法精進，來提高各車種於不同環境下之準確率，以進一步符合實務所需。

- (3) 受限於實測現場的攝影機佈設限制，本計畫 AI 影像偵測設備在延滯偵測時，攝影機影像無法“看到”等候車隊尾端，因此建議對於路段較長且等候車段較長地點，可於路段中再新設一組攝影機，透過 2 台攝影機之 AI 影像辨識與資料融合將可提高其適用性。

2. 在 AI 號誌控制後續研究方向上：

- (1) 本計畫針對臺中市太平區 2 個路口，設計單一代理人(single-agent)週期型態(cycle-based)，以小客車為基礎的 AI 號誌控制模式，為適應我國都會區複雜的車流環境，後續建議導入混合車流、多代理人，以及以時相為基礎等的 AI 號誌控制模式。
- (2) 本計畫在 AI 號誌控制學習上，先透過時制最佳化產生軟體 PaSo 產生最佳化時制計畫，搭配時段參數來訓練 AI 號誌控制模式，並藉由相似度來評估學習效果。後續建議參考國際 AI 強化學習主流作法，在 AI 號誌控制學習(或訓練)過程導入車流模擬軟體，先藉由模擬軟體來重現實驗場域車流行為，再將之與 AI 號誌控制模式的學習與測試，以利於模擬環境中，增加不同交通模式(例如：延滯公式、號誌連鎖、...)與 AI 模式參數(例如：獎勵、...)，在 AI 號誌控制模式構建過程之彈性與擴充性。

參考文獻

1. 陸化普(2019),「智能交通系統主要技術的發展」,清華大學交通研究所,北京。
2. 科學月刊,「科技報導」,37(6),27-35。
3. 維基百科,「人工智慧」,檢自 <https://zh.wikipedia.org/zh-tw/%E4%BA%BA%E5%B7%A5%E6%99%BA%E8%83%BD>
4. 吳毅成(2019),「深度強化式學習技術之應用研究」,科技部。
5. 阿里雲 ET(2018),「ET 大腦詳情頁 -- 城市大腦」,
<https://et.aliyun.com/brain/city?spm=a2c17.92424.936384.3.79411a434uGzaG>
6. 吳沛儒、陳其華、蘇昭銘、吳東凌、黃啟倡、鍾俊魁、何毓芬(2019),「人工智慧之交通事件影像偵測模式與實域驗證」,運輸計畫季刊,48(3),頁159-178,2019-09。
7. 蘇昭銘等人(2020),「交通事件資訊整合服務與精進計畫(1/2)期末修正報告書」,交通部運輸研究所。
8. 蘇昭銘等人(2020),「交通事件資訊整合服務與精進計畫(2/2)期末修正報告書」,交通部運輸研究所。
9. 林良泰等人(2020),「應用人工智慧(AI)影像辨識技術進行交通數據蒐集與分析之研究期末修正報告書」,交通部運輸研究所。
10. 吳沛儒、蘇昭銘、吳東凌、林良泰、黃啟倡、鍾俊魁、張和盛、何毓芬、簡君麟,「建構交通事件之人工智慧物件偵測邏輯與實證研究」,運輸學刊,32(3),299-320,2020-09。
11. 資策會(2020),「AI 制慧交通控制技術與應用發展」,資策會制慧運輸系統中心。
12. 許添本、程楷祐(2020),「以深度強化學習方式建構混合車流之 AI 最佳化號誌時制計畫」,中華民國運輸年會 109 年學術論文研討會。
13. 黃銘崇(2020),「Vissim 應用分享:人工智慧適應性號誌控制」,中台灣智慧運輸及人車流模擬分析模型分享會,2020/12/07。
14. 桃園市政府交通局(2020),「桃園市大園區 AI 智慧控制控制試辦計畫成果摘要」,桃園市政府交通局。
15. 蔡輝昇(民 79),「交通控制理論與實務」,生合成。
16. 人工智慧大歷史,民 108, Retrieved 27 June 2020, from <https://bit.ly/2ZbMIoR>
17. 人工智能(2018), Retrieved 27 June 2020, from <https://bit.ly/383kmBa>

18. 李開復(2019),「AI 新世界」,天下文化。
19. 張光宏(2020),「AI 成資安新戰場 自動化工具反成威脅」,網管人。
20. 張庭瑜(2018),「當 AI 防禦遇上 AI 攻擊,「以子之矛,攻子之盾」正在資安界上演」,數位時代。
21. 潘俊良(2017),「歐盟和德國對於自動駕駛及智慧交通系統之個人資料保護發展」,科技法律透析。
22. 陳健亮(2019),「日房夜防,家賊難防,如何防止內部攻擊與資料失竊」,臺灣資安大會。
23. 盧惠光,「數位新時代-智能資安內外攻防教戰」,臺灣資安大會。
24. 林俊秀(2019),「我國物聯網資安產業標準與檢測認證推動策略與發展」,臺灣資安大會。
25. Koos Lodewijkxy(2019),「提點最佳資安攻略! IBM CISO 為您拆解五大生存招勢和五大應避免之錯誤」,臺灣資安大會。
26. 林祥生(2018),交通大學運管系專題演講,演講日期:2018.10.08。
27. Reynoso, R., “A Complete History of Artificial Intelligence”, Retrieved 27 June 2020, from <https://bit.ly/3g0NfAG>(2020).
28. AlphaGo. Retrieved 27 June 2020, from <https://zh.wikipedia.org/wiki/AlphaGo>
29. David Silver, “UCL Course on RL,” 2015,from <https://www.davidsilver.uk/teaching/>
30. Sutton, Richard S./ Barto, Andrew G., “Reinforcement Learning: An Introduction,” 2018, Bradford Book.
31. H. Van Hasselt, A. Guez, and D. Silver, “Deep reinforcement learning with double q-learning,” in Thirtieth AAAI conference on artificial intelligence, 2016.
32. Todd Hester, Matej Vecerik, Olivier Pietquin, Marc Lanctot, Tom Schaul, Bilal Piot, Dan Horgan, John Quan, Andrew Sendonaris, Gabriel Dulac-Arnold, Ian Osband, John Agapiou, Joel Z. Leibo, Audrunas Gruslys, “Deep Q-learning from Demonstrations,” AAAI 2018.
33. Zheng, G., Xiong, Y., Zang, X., Feng, J., Wei, H., Zhang, H., Li, Y., et al. (2019), “Learning Phase Competition for Traffic Signal Control”, Proceedings of the 28th ACM International Conference on Information and Knowledge Management, presented at the CIKM '19: The 28th ACM International Conference on Information and Knowledge Management,

- ACM, Beijing China, pp. 1963–1972.
34. Yusen Huo, Qinghua Tao, Jianming Hu, “Tensor-based Cooperative Control for Large Scale Multi-intersection Traffic Signal Using Deep Reinforcement Learning and Imitation Learning,” arXiv:1909.13428,2019.
 35. Son, S., and Y. Baek., "Design and Implementation of Real-Time Vehicular Camera for Driver Assistance and Traffic Congestion Estimation.," Sensors, Vol. 15, No. 8, 2015, pp. 20204–20231.
 36. Luo, Z., Jodoin, P.-M., Su, S.-Z., Li, S.-Z., & Laroche, H.(2018)., “Traffic Analytics With Low-Frame-Rate Videos. IEEE Transactions on Circuits and Systems for Video Technology,” 28(4), 878–891. <https://doi.org/10.1109/TCSVT.2016.2632439>
 37. Brad Hem(2018)., “Miovision Uses Artificial Intelligence to Turn Traditional Intersections into Smart Intersections,” Business Wire. Retrieved April 17, 2019, Retrieved from <https://www.businesswire.com/news/home/20180322005443/en/Miovision-Artificial-Intelligence-Turn-Traditional-Intersections-Smart>
 38. NEC(2019), “Image Analysis,” Retrieved from https://hk.nec.com/en_HK/solutions/bysolutions/video_analytics/image_analysis.html
 39. NEC(2019), “NEC’s Recommendation to utilize video surveillance system with image processing traffic congestion alleviation but also safety & security,” Retrieved from https://th.nec.com/en_TH/solution/safetysocial/cctv.html
 40. Aleksandr Fedorov, Kseniia Nikolskaia, Sergey Ivanov, Vladimir Shepelev & Alexey Minbaleev(2019), “Traffic flow estimation with data from a video surveillance camera,” Journal of Big Data volume 6, Article number: 73.
 41. Xu, Y., Yu, G., Wang, Y., Wu, X. and Ma, Y.(2017), “Car detection from low-altitude UAV imagery with the faster R-CNN,” Journal of Advanced Transportation, Vol. 2017, pp. 1–10.
 42. Gkolas, K. and Vlahogianni, E.I.(2019), “Convolutional Neural Networks for On-Street Parking Space Detection in Urban Networks,” IEEE Transactions on Intelligent Transportation Systems, Vol. 20 No. 12, pp. 4318–4327.
 43. Chen, C., Wei, H., Xu, N., Zheng, G., Yang, M., Xiong, Y., Xu, K., et al.

- (2020), “Toward A Thousand Lights: Decentralized Deep Reinforcement Learning for Large-Scale Traffic Signal Control”, Proceedings of the AAAI Conference on Artificial Intelligence, Vol. 34 No. 04, pp. 3414–3421.
44. Hua Wei, Zhenhui Li, Vikash Gayah (2020), "Deep Reinforcement Learning for Traffic Signal Control," IEEE ITSC 2020.
 45. Jin, J. and Ma, X. (2015), “Adaptive Group-Based Signal Control Using Reinforcement Learning with Eligibility Traces”, 2015 IEEE 18th International Conference on Intelligent Transportation Systems, presented at the 2015 IEEE 18th International Conference on Intelligent Transportation Systems - (ITSC 2015), IEEE, Gran Canaria, Spain, pp. 2412–2417.
 46. Pol, E. van der and Oliehoek, F.A. (2016), “Coordinated Deep Reinforcement Learners for Traffic Light Control”, presented at the 30th Conference on Neural Information Processing Systems, Barcelona, Spain, available at: [/paper/Coordinated-Deep-Reinforcement-Learners-for-Traffic-Pol-Oliehoek/47632b66387d00d19b66e71560ba462847b78006](#) (accessed 15 November 2020).
 47. Genders, W. and Razavi, S. (2016), “Using a Deep Reinforcement Learning Agent for Traffic Signal Control”, ArXiv:1611.01142 [Cs], available at: <http://arxiv.org/abs/1611.01142> (accessed 28 October 2020).
 48. Liu, M., Deng, J., Xu, M., Zhang, X. and Wang, W. (2017), “Cooperative Deep Reinforcement Learning for Traffic Signal Control”, presented at the The 6th International Workshop on Urban Computing, Halifax, Canada.
 49. Xiaoyuan Liang, Xunsheng Du, Guiling Wang and Zhu Han, “A Deep Reinforcement Learning Network for Traffic Light Cycle Control,” IEEE Transactions on Vehicular Technology, 2019.
 50. Rusheng Zhang, Akihiro Ishikawa, Wenli Wang, Benjamin Striner and Ozan Tonguz (2019), “Intelligent Traffic Signal Control: Using Reinforcement Learning with Partial Detection,” IEEE ITS transaction, 2018.
 51. Wei, H., Zheng, G., Yao, H. and Li, Z. (2018), “IntelliLight: A Reinforcement Learning Approach for Intelligent Traffic Light Control”, Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, presented at the KDD '18: The 24th

- ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, London United Kingdom, pp. 2496–2505.
52. Wei, H., Chen, C., Zheng, G., Wu, K., Gayah, V., Xu, K. and Li, Z. (2019), “PressLight: Learning Max Pressure Control to Coordinate Traffic Signals in Arterial Network”, Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, presented at the KDD '19: The 25th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, ACM, Anchorage AK USA, pp. 1290–1298.
 53. Wei, H., Xu, N., Zhang, H., Zheng, G., Zang, X., Chen, C., Zhang, W., et al. (2019), “CoLight: Learning Network-level Cooperation for Traffic Signal Control”, Proceedings of the 28th ACM International Conference on Information and Knowledge Management, pp. 1913–1922.
 54. Lee, J., Chung, J. and Sohn, K.(2020), “Reinforcement Learning for Joint Control of Traffic Signals in a Transportation Network”, Ieee Transactions on Vehicular Technology, Ieee-Inst Electrical Electronics Engineers Inc, Piscataway, Vol. 69 No. 2, pp. 1375–1387.
 55. Zang, X., Yao, H., Zheng, G., Xu, N., Xu, K. and Li, Z. (2020), “MetaLight: Value-Based Meta-Reinforcement Learning for Traffic Signal Control”, Proceedings of the AAAI Conference on Artificial Intelligence, Vol. 34 No. 01, pp. 1153–1160.
 56. Jin, J. and Ma, X.(2019), “A Multi-Objective Agent-Based Control Approach With Application in Intelligent Traffic Signal System”, Ieee Transactions on Intelligent Transportation Systems, Ieee-Inst Electrical Electronics Engineers Inc, Piscataway, Vol. 20 No. 10, pp. 3900–3912.
 57. Yang, S., Yang, B., Wong, H.-S. and Kang, Z.(2019), “Cooperative traffic signal control using Multi-step return and Off-policy Asynchronous Advantage Actor-Critic Graph algorithm”, Knowledge-Based Systems, Elsevier, Amsterdam, Vol. 183, p. 104855.
 58. Genders, W. and Razavi, S.(2020), “Policy Analysis of Adaptive Traffic Signal Control Using Reinforcement Learning”, Journal of Computing in Civil Engineering, Asce-Amer Soc Civil Engineers, Reston, Vol. 34 No. 1, p. 04019046.
 59. Kim, D. and Jeong, O.(2020), “Cooperative Traffic Signal Control with Traffic Flow Prediction in Multi-Intersection”, Sensors, Mdpi, Basel, Vol.

20 No. 1, p. 137.

60. Chu, T., Wang, J., Codeca, L. and Li, Z.(2020), “Multi-Agent Deep Reinforcement Learning for Large-Scale Traffic Signal Control”, *Ieee Transactions on Intelligent Transportation Systems*, Ieee-Inst Electrical Electronics Engineers Inc, Piscataway, Vol. 21 No. 3, pp. 1086–1095.
61. Hua Wei, Chacha Chen, Guanjie Zheng, KanWu, Vikash Gayah, Kai Xu, Zhenhui Li(2019), “PressLight : Learning Max Pressure Control to Coordinate Traffic Signals in Arterial Network,” in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019, pp. 1290-1298.
62. W. Genders and S. Razavi, “Using a deep reinforcement learning agent for traffic signal control,” *arXiv preprint arXiv:1611.01142*, 2016.
63. Na Xiao, Dan Liu, Ailing Luo, Xiangwei Kong, Tianshe Yang, Nan Xing , Fangzheng Li, “Adaptive feature extraction based on Stacked Denoising Auto-encoders for asynchronous motor fault diagnosis,” *2016 9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics* ,2016.
64. Huazhe Xu, Yang Gao, Fisher Yu, Trevor Darrell, “End-To-End Learning of Driving Models From Large-Scale Video Datasets,” *IEEE Conference on Computer Vision and Pattern Recognition*,2017.
65. X. Liang, X. Du, G. Wang, and Z. Han, “Deep reinforcement learning for traffic light control in vehicular networks,” *arXiv preprint arXiv:1803.11115*, 2018.
66. H. Wei, G. Zheng, H. Yao, and Z. Li, “Intellilight: A reinforcement learning approach for intelligent traffic light control,” in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018, pp. 2496-2505.
67. R. Zhang, A. Ishikawa, W. Wang, B. Striner, and O. Tonguz, “Intelligent traffic signal control: Using reinforcement learning with partial detection,” *arXiv preprint arXiv:1807.01628*, 2018.
68. H. Van Hasselt, A. Guez, and D. Silver, “Deep reinforcement learning with double q-learning,” in *Thirtieth AAAI conference on artificial intelligence*, 2016.
69. T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, et al.,

“Continuous control with deep reinforcement learning” arXiv preprint arXiv:1509.02971, 2015.

70. Yuanhao Xiong, Guanjie Zheng, Kai Xu, Zhenhui Li, “Learning Traffic Signal Control from Demonstrations,” The 28th ACM International Conference on Information and Knowledge Management, 2019.
71. Lewis. (1982). “Control of body segment differentiation in drosophila by the bithorax gene complex”. Embryonic development, Vol.1, pp. 269-288.

附件一、期中報告審查意見處理情形表

審查委員	審查意見	審查意見回覆	主辦單位意見
吳玉珍委員	P.29，倒數兩行說明目前偵測成果，顯示 AI 車輛偵測成果大致已有足夠水準，惟於 P.30 表 3.3-1 中，中型車白天偵測準確率較低，請說明原因，另請再針對中型車與大型車定義進行說明。	謝謝委員的寶貴建議，本研究車種分類請參閱表 3.3-2，有關中型車白天偵測準確率較低課題，經分析發現與樣本數量有關，本研究場域裝設之設備抽樣範圍普遍白天中行車數量遠多於夜間，故評估為母體不同所造成差異。	同意
	P.31，轉向車流偵測成果並不理想，報告書中認為主要與拍攝角度有關，致使轉向車流偵測產生死角，惟夜間直行機車偵測率亦不高，請再細部進行探討與說明。	謝謝委員的寶貴建議，本研究經多個邏輯調整探討，建議未來轉向交通量偵測攝影機放置應距離路口較遠，且針對不同轉向有不同偵測線劃設，以提升準確率，詳細內容請參閱 3.3.2 節。	同意
	P.35 表 3.3-3，請補充車流密度的單位，另目前準確率僅單純以正確與錯誤而論，而 P.37 表 3.3-3，序號 5 夜間情境僅有 3 部車輛情況下，即少偵測 2 台車輛，比例似乎較高，請研究團隊探討原因，並說明如何改善。	謝謝委員的寶貴建議，車流密度單位為偵測區域內車輛數(不含機踏車)。經探討原因，初步判斷為未被偵測之車輛，其因與前車過近，致使被判定為與前車是同一臺車，建議改善方式為加高拍攝高度避免車輛遭到遮蔽及更換較好之攝影機。另因受限於現場設備佈設受限因素，車流密度不列入評估。	同意
	P.43，請補充說明停等延滯的單位，另所提到車輛停等位置較遠，偵測設備未能偵測到該車輛之相關建議是否可行？對於偵測不到的尾端車流改善構想為何？	謝謝委員的寶貴建議，停等延滯單位為秒，偵測邏輯為每車加入紅燈停等車隊至因下游車輛疏解而開始加速之時間。偵測設備未能偵測到車輛主要為車輛距離較遠或是遭到前車遮蔽，建議改善方式為加高拍攝高度避免車輛遭到遮蔽及更換較好之攝影機。針對偵測不到的尾端車流，相關未來建議請參閱 3.3.7 節。	同意
	P.73，因 SUMO 機車駕駛行為模式與我國差異較大，故本研究並未採用其機車模式；然 SUMO 中機車靠內側行駛，其是否有可能是因為其車輛型式為重型機車，或是違規行為？	謝謝委員的寶貴建議，SUMO 交通模擬軟體包含重型機車與普通重型機車，原始設計為將機車做為與汽車相同物件進行模擬，但普通重型機車之車流行為與我國不同，且歐盟多個會員國其機車環境與我國明顯不同，致使如欲精準模擬機車行為，須修改 SUMO 原始碼，超出研究範圍。	同意
	本研究提到 AI 若其訓練成果與時制最佳化產軟體 PaSO 一致，則是較好的，但判斷一致之依據是一個週期均相同或是一段時間均相同；此外，產生之結果可能不會是整	謝謝委員的寶貴建議，目前本研究 AI 模式僅由時制計畫表挑選下一階段之時制計畫，故判斷一致係判定 AI 與 PaSO 對於該流量情境是否選擇相同之時制計畫，相關強化學習規劃設計，請參閱 4.1.3 節。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	數，或是差異不大，這樣是否認定為相同？請補充說明操作方式。		
	當 AI 產生的時制計畫可能較 PaSO 為佳時之因應機制為何？	謝謝委員的寶貴建議，現階段 AI 學習機制為模仿學習，若 AI 模式所挑選時制計畫較 PaSO 佳時，後續可透過獎勵值回饋來更新 AI 模式。	同意
陳勁甫委員	請於文獻回顧部分，再補充說明應用 AI 在交通號誌技術、時制發展與相關案例。	謝謝委員的寶貴建議，已補充於 2.3 節。	同意
	本研究受限於樂業/十甲東與樂業/東英路無法與太平匝道控制策略達到連鎖，未來績效評估部分是否會採用連鎖號誌來估計？號誌連鎖是否為本研究之重要目標？	謝謝委員的寶貴建議，目前有考慮連鎖與機制；號誌連鎖非本研究對象。	同意
	本研究對於測試路口選定是否有特定選擇基準？因為該兩路口車流特性相較於需要進行適應性控制之路口而言，似乎較為單純。	謝謝委員的寶貴建議，本研究為避免實作上發生問題，因此選擇路口車流較為單純，藉以進行我國在 AI 號誌控制的實作探討。	同意
	P.30，偵測範圍內的路邊停車是否也會被偵測，因而造成誤判？	謝謝委員的寶貴建議，本研究偵測區域僅劃設於快車道，可避免偵測到路邊停車車輛。	同意
	請補充說明 AI 號誌控制章節之 PaSO、SUMO、DQfD 等之關聯與相關設計，例如：PaSO 所產生時制計畫是否為最佳、DQfD 採用何種邏輯進行動態適應性號誌控制。	謝謝委員的寶貴建議，PaSO 產生最佳化時制計畫以為 AI 模式訓練資料，SUMO 用來評估事前事後績效、DQfD 提供 AI 模式訓練。	同意
	請補充說明 SUMO 模擬績效定義的各時段模擬，是否為兩路口一同探討？抑為個別論？	謝謝委員的寶貴建議，由於兩路口距離近，因此為一同探討。	同意
	吳木富委員	請再補充說明計畫目的與範圍，是否包括路口/路段自動學習辨識車流狀態、自動產生適合之時制計畫，以及是針對單一路口或多路口進行時制計畫產生。	謝謝委員的寶貴建議，本研究透過 PaSO 產生多路口最佳化時制計畫以為 AI 模式訓練資料，並考量實驗場域 2 個路口群組的連鎖與上下游續進。
	請補充說明 3.2 節設置 15 支 CCTV、5 處 e-Tag 偵測器，是否本研究 AI 號誌控制所需？建議與傳統適應性號誌控制之車輛偵測器在成本、效益、準確性等面向進行比較分析。	謝謝委員的寶貴建議，本研究所佈設路側測設備均為計畫執行所需，在車輛偵測器準確性部分進行量化分析，由於 AI 影像偵測技術尚持續發展，因此本研究尚未就成本面進行評估。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	建議提出以 AI 建置適應性號誌之設備與軟體之設置需求或標準。	謝謝委員的寶貴建議，已將執行 AI 號誌控制之 IPC 規格補充於 4.3.1 節。	同意
	P.25 圖 3.2.5，建議標示街路名與方向，以利閱讀。	謝謝委員的寶貴建議，已標示與補充。	同意
	P.33，在車流密度偵測時，劃設偵測區域長度可涵蓋實際車流之最長停等長度嗎？若無法涵蓋時之處理方式為何？請補充說明表 3.3-3 每一偵測序號間隔多長時間。	謝謝委員的寶貴建議，於停等車隊數較長之方向，受限於攝影機拍攝範圍有限，並無法完全涵蓋。有關偵測序號時間間隔，當偵測到有停等車輛時才會記錄。另因受限於現場設備佈設受限因素，車流密度不列入評估。	同意
	P.42 表 3.3-6，在路口停等延滯偵測時，因停等區外無法偵測以致產生誤差，是否有解決方案？偵測距離遠近應該與攝影機架設高度有關。相較於傳統車輛偵測器，請補充說明本研究所使用 AI 偵測器在車流停等延滯之差異與優缺點。	謝謝委員的寶貴建議，針對上游無法偵測部分，建議解決方式為於上游加裝偵測設備，並於後臺加總兩處資料。相較於傳統車輛偵測器，本研究 AI 偵測可針對個別車輛進行速度、停等、延滯等偵測。	同意
	目前 P.54 表 4.1-3 與 P.59 表 4.1-7 平均延滯改善幅度 +/- 之表示方式，例如：改善幅度+38%，恐無法了解是變好或變壞，易生誤解，建議再加以檢討，或可改為增減多少百分比方式呈現。	謝謝委員的寶貴建議，已加以調整。	同意
	P.71，倒數第 2 段第 2 行，請補充說明「提供開源且免費使用...」之意義，另 Traci 應為 TraCI。	謝謝委員的寶貴建議，SUMO 開放原始碼，為開源軟體，已更正 Traci 為 TraCI。	同意
	請補充說明 P.73 使用 SUMO 模擬軟體構建模式時對於相關車流行為參數，例如：變換車道、車距...等，以及模式參數的校估方式。	謝謝委員的寶貴建議，SUMO 入口流量每分鐘流量直接採人工調查每分鐘流量。其它機車與汽車關車流參數，均採用 SUMO 預設值。	同意
	第五章未來五年 AI 於交通領域整體規劃，請補充說明預計規劃範圍，建議加以適當限縮與聚焦。	謝謝委員的寶貴建議，遵照辦理。	同意
	P.5 第三段，請補充說明阿里雲(民 107)利用實時城市數據之意義。	謝謝委員的寶貴建議，已進行補充。	同意
許添本委	P.13 頁所提的 A3C 作法有可能適用於號誌控制應用，建議研究團隊加以評估。	謝謝委員的寶貴建議，依吳毅成老師對 RL 分類，A3C 方法可直接適合應用於 Lightweight 類型，若應用於 Real World 類型，需要注意訓練初期不穩定問題。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
委員		<p>A3C 相關的作法確實有可能可以應用於交通號誌控制上，然而基於以下兩點因素，本研究採用 DQfD。</p> <p>1. A3C 是在線策略 (on-policy)，其更新的方式是需要蒐集目前訓練出的 AI 對環境互動所產生的資料。若資料樣本數不夠，無法訓練出良好品質 AI。另當 AI 更新後，已蒐集的資料因不適用於新 AI 策略，將會被捨去，造成資料利用性的浪費。因此採取離線策略 (off-policy) 的 DQfD，以 PaSO 扮演專家產生基礎資料做為訓練之用。</p> <p>2. A3C 是 policy-based 演算法，DQfD 是屬於 value-based 的演算法。於諸多文獻探討上，value-based 在離散動作環境下的成效都是比 policy-based 佳，而 policy-based 大多是處理連續動作環境下的問題。至於制定時制計畫或是秒數分配，都屬於離散動作環境。</p>	
	<p>PaSO 所產生最佳化時制計畫如何轉為代理人，並成為 AI 學習模式神經網路的輸入 (Input) 訓練；PaSO 應該只是幫助 AI 剛開始訓練時比較有效率，但本研究以 AI 學習結果與 PaSO 結果一致為最好，此作法似與 DQfD 不盡相同，請再進一步加以釐清與說明。</p>	<p>謝謝委員的寶貴建議，本研究所進行 DQfD 方式係藉由輸入在某個狀態(車流狀態)，以與專家的動作(選取最佳化時制計畫)的相似度當作回饋，來訓練 AI 模式。受限於計畫時程，突破模仿學習的作法，建議列入後續年度計畫工作事項。</p>	同意
	<p>請補充說明本研究所使用 AI 影像偵測技術所需處理之訓練 (Training) 與標示 (Labeling) 是否都已處理完成，以及 Intersection over Union (IoU) 的設定方式。另外，對於交通量偵測通常繪製偵測線，但對於本研究的轉向交通量偵測如何進行，以同時取得該路口各流向的交通量。</p>	<p>謝謝委員的寶貴建議，AI 偵測影像技術之訓練與標示已於運研所前期相關計畫進行，本研究於實驗場域亦進行進一步學習與訓練工作，另所採用 IoU 設定為大於 0.5。針對轉向交通量部，分藉由劃設數條偵測線，透由車輛通過指定之兩條偵測線，以判定其轉向，相關偵測模式邏輯請參閱 3.3-21。</p>	同意
	<p>本研究是否有車輛追蹤需求，影像辨識是否使用 YOLO V4，若皆有，但 YOLO V4 的追蹤能力並不好，因此在車輛追蹤時，若因遮蔽而中斷之處理方式為何？</p>	<p>謝謝委員的寶貴建議，目前並無使用 Yolo4，於偵測時物件遭遮蔽仍會維持偵測數個 frame，若車輛在偵測範圍內被追蹤到，則會回復。</p>	同意
	<p>夜間車輛偵測有可見光與不可見光的偵測技術，對於夜間面對大量</p>	<p>謝謝委員的寶貴建議，由於逆光與眩光其影像相似，且逆光影響遠大於炫光，故主</p>	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	對向車輛所形成炫光之處理方式為何？	要調整攝影機減少逆光的效果，若仍偵測不好，則會蒐集實驗場域影像加強訓練。	
	AI 影像偵測設備學習過程應該不在邊緣端(Edge)進行，而是須將影像上傳雲端進行運算後，在回傳至路側端，此流程攸關號誌控制的即時性，請補充說明此處理流程，以及說明在不同時間區間之偵測交通量誤差。	謝謝委員的寶貴建議，本研究之 AI 影像偵測設備其辨識均於邊緣端即完成，輸出之資料僅傳送數據資料，故其可給予號誌控制較為穩定之資料源。針對不同時間區間之偵測交通量之誤差，本研究將於實測進行前完成測試與評估。	同意
	P.39 每分鐘佔有率是時間占用率或是空間占用率？延滯是採用停等延滯(Stop delay)或旅行時間延滯(Travel delay)？中國大陸相關研究採用是旅行時間做為獎勵(Reward)，而非延滯，本研究在實務運作時將如何進行獎勵設計？	謝謝委員的寶貴建議，本研究所採用之佔有率係為 1 分鐘中，一小路段被車輛占據的時間百分比。延滯採用停等延滯(每車加入紅燈停等車隊至因下游車輛疏解而開始加速之時間)。本研究 AI 模式以與專家相似度做為獎勵值，後續將嘗試不同獎勵值之影響。	同意
	PaSO 時制計畫產生軟體是依基因演算法來產生考量機車車流特性的最佳化時制計畫，但不具備學習機制，因此在本研究中如何將之轉換代理人(Agent)角色，應於報告中加以說明；同時強化式學習在學習初始階段較可能發散，因此透過適當機制有助於學習效率提升，因此請補充說明如何將 PaSO 導入 DQfD 的整個運作架構或流程。	謝謝委員的寶貴建議，已補充於期末報告 4.1.3 節。	同意
	簡報 P.25 右下方仍是 DQN 架構，如何產生 AI 號誌時制？是否有濾波器(Filter)的設計課題？請補充整個類神經網路架構與相關參數設定方式。	謝謝委員的寶貴建議，本研究之類神經網路架構為 2 層 10 單元全連結類神經網路，輸入流量，輸出選擇之時制計畫。訓練期間以與專家選擇最接近為目標，因此在訓練後之類神經網路，包含於給定流量的情況下，運算輸出時制計畫選擇。在號誌控制之類神經網路並不包含濾波器。	同意
	本研究現階段以 PaSO 所產生最佳化時制計畫為學習對象，如此一來，似乎就屬監督式學習，而無需要使用強化式學習的 DQfD，請團隊加以釐清與說明。	謝謝委員的寶貴建議，以 DQfD 的方法而言，PaSO 是提供訓練資料，協助完成模仿階段成果，代理人可以透過與此基礎模型(base-model)互動，於互動過程全面性學習基礎模型輸出之各種示範。規劃於後續年度計畫中，透過新增延滯等資訊回饋，使得代理人能學習到超越基礎模型的決策。	同意
	SUMO 為開源軟體如果要處理國內交通特性的機車問題應該可行，	謝謝委員的寶貴建議，針對處理機車問題，其需牽涉 SUMO 原始碼之改寫，本研究評	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	並非如報告所言無法調整，比較關鍵的是本研究如何將 SUMO 與 AI 結合，請補充說明 Action(動作)定義，也就是如何進行各時相秒數的增減方式(例如：5 秒)來影響週期，或是週期不變而調整時比，時差又如何處理？整個實務運作過程獎勵如何納入決策？獎勵的回饋頻率為何？每 5 秒或是每個號誌週期？建議對於學習過程的獎勵處理再加以補充說明。	估實驗場域之機車特性尚不影響其它車種車流運行，因此 SUMO 模式未納入機車。Action 的定義是一套完整的時制計畫(包括各時相紅綠燈時間)。因為目前計畫範圍須搭配週圍路口，所以週期時差採配合相鄰群組方式，採週期時差固定不變而調整時比。 本研究之動作，係指 AI 所選擇及執行之時制計畫，並採取逐週期調整之方式，時差部分於 PaSO 最佳化時制計畫產生階段即以加以考量；針對學習過程的說明，將於期末報告進行補充。	
劉瑞麟委員	請補充說明車流偵測設備之架設位置高度與方式，因為設備攝影機拍攝長度是固定的，相關限制應加以說明。	謝謝委員的寶貴建議，本研究之偵測設備(除轉向量偵測設備)架設位置與高度均為號誌桿之燈箱旁，轉向量偵測設備由於期望藉由兩偵測設備掌握路口轉向量，故裝設於號誌桿彎桿處，相關細節已補充於 3.2 節。	同意
	請補充說明現場設備之軟硬體與通訊方式，以執行本研究所設計之 AI 號誌控制。	謝謝委員的寶貴建議，本研究之設備通訊方式採 4G 無線傳輸，所有設備資料均傳輸至現場之 IPC。	同意
	本研究利用 PaSO 軟體產生最佳化時制計畫，其輸入內容包含所有車種之車輛數，或是已轉換為 PCU？對於機車基本上若在機車停等區，綠燈一開始即可機車車流即可快速紓解。但本研究提到十甲東路與太平匝道有續進問題，目前並未放入，是否是於後續實證階段才會連結下匝道車流？此外，目前 PaSO 最佳時置計畫產生是否為獨立路口方式，還是包含太平匝道車流續進或隨機到達，未來實證應要注意匝道的前進模式是否會影響績效，尤其是續進課題。	謝謝委員的寶貴建議，本研究在 PaSO 軟體產生最佳化時制計畫過程僅採用小客車車輛數，並納入下匝道車流續進考量。	同意
	本研究在 AI 號誌控制似乎僅是簡單的動態查表，因為是簡單二時相，所以沒有多時相學習問題，同時處理上限縮只用汽車、限縮週期長度、限縮時比變化幅度為 5 秒，在實務上應為可行，但恐失去研究意義；建議在 AI 號誌控制學習階	謝謝委員的寶貴建議，本研究為求實務運作之可行性，以及減少新號誌模式對於現況之衝擊，因此採取較保守設計，建議於後續年度計畫提高更多的運作彈性。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	段，應可讓 AI 學習充滿各種可能，待最後於現場執行時加入適當限制。		
	請補充說明於 AI 學習階段，當計畫範圍兩路口的車流量若無法紓解時，如何進行淨空與量化績效？如何定義量化績效的時間區間？	謝謝委員的寶貴建議，本研究目前尚未納入車流過飽和與法紓解之 AI 模式學習與訓練，建議可納為後續計畫的探討課題。	同意
	建議第五章未來五年 AI 於交通領域整體規劃可加以適當限縮於特定領域，以免課題過於廣泛。	謝謝委員的寶貴建議，遵照辦理。	同意
黃文鑑委員	部分檢核樣本數(報告書 P.40 與 41)過於不足，所做出之準確率無法判斷是否有效，如表 3.3-5，請再加以補充。	謝謝委員的寶貴建議，對於檢核樣本數不足 5 筆者，不納入準確率評估。	同意
	路口蒐集資料應注意是否有路邊停車場、路外停車場、公車站、自行車道、慢車道、超商臨時停車、加油站等因素。從辨識圖片中有路邊停放車輛(機車)被框住、路口停車購物機車及號誌燈桿標誌牌遮蔽影像等狀況，顯見 AI 需要訓練過濾雜訊(排除非移動車輛)，以及選取優良架設攝影機位置。	謝謝委員的寶貴建議，本研究偵測區域僅劃設於快車道，可避免偵測到路邊停車車輛。	同意
	應用 PaSO 軟體是否能反應最佳真實的交控策略，而成果是否優於現況，或能比較他交通分析軟體，請於期末報告中加以說明。	謝謝委員的寶貴建議，本研究透過 PaSO 進行時制最佳化時制計畫設計，並藉由 SUMO 交通模擬軟體進行事前事後量化效益分析。	同意
	P.41，3.3.6 節路口停等延滯之 Parking 偵測模式似乎較接近 Stopping 偵測模式，請再加以確認。	謝謝委員的寶貴建議，Parking 模式為偵測設備之模式名稱，已依據委員提示更正報告文字說明。	同意
	本報告對於 AI 號誌控制尚未見具體說明，只提到應用 SUMO 模擬軟體，如果只是將資料輸入，而得到答案方式，可能離 AI 有一段距離。	謝謝委員的寶貴建議，AI 號誌控制邏輯，詳細可參考期中報告第 4 章，於本研究為建類神經網路，以於各種交通流量狀態下，進行學習與訓練，最後產生與專家相近之決策。	同意
	AI 號誌控制可以從獨立控制、區域控制及網路控制三層面討論，建議本研究能夠從區域控制(2 個路口)來討論，透過即時偵測資料及比對歷史資料(及歷史控制成果)，能夠調整下一個時段控制參數與	謝謝委員的寶貴建議，本研究藉由蒐集外圍六大路徑車流量來進行 AI 模式之建立與訓練，另由於實驗場域兩路口相當鄰近，因此須納入續進考量。對於委員所建議相關資料的進一步研析，建議納入後續年度計畫辦理。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	權重、更新號誌時段、或是延長燈號(例如：左轉、或全紅清空路口等),亦即應用人工智慧,有如交通警察或義交能針對實際狀況給予現場處置,如此 AI 才有應用價值。		
	P.59, PaSO 時制計畫表格中,「紅燈秒數」,建議改為「全紅秒數」,因為就東西向交通紅燈秒數為 2 秒,南北向交通紅燈秒數為 35 秒,看起來「紅燈秒數」即是「全紅秒數」。	謝謝委員的寶貴建議,遵照辦理。	同意
	簡報 P.32-37 的改善績效似乎從調整或犧牲支道延遲而來,是否能夠改善整體幹支道效率?報告 P.54 表 4.1-3,機車改善幅度為負號,整體路網卻為+13%,請再補充說明。	謝謝委員的寶貴建議,由於幹支道車流差異龐大(樂業十甲路口平日晨峰西行與難行比例為 2.27),故主要策略將會以主幹為優先,同時確保支道之車流紓解並不會與事前差異過大,後續將依委員建議,再評估整體路網績效。	同意
臺北市 政府 交通 局	請補充說明本研究在 AI 號誌控制學習過程如何將行人路口通行最短綠燈時間需求納入考量。	謝謝委員的寶貴建議,本研究於 PaSO 時制計畫設計時,即已考量行人通行所需最小綠燈秒數。	同意
	請補充說明 AI 號誌控制如何將特殊事件,例如:車禍,納入考量。	謝謝委員的寶貴建議,於本研究暫不考量特殊事件。	同意
	請補充說明本研究所使用 AI 偵測設備之雨天辨識之數據。	謝謝委員的寶貴建議,已補充於 3.3 節。	同意
	請補充說明 AI 影像偵測設備之架設位置與角度,以及實務上布設之作業邏輯和流程。	謝謝委員的寶貴建議,已已補充於 3.3 節。	同意
新 北 市 政 府 交 通 局	智慧型 CCTV 在辨識車流時大多係日間準確率高於夜間,惟報告書 P.33 十甲東路往北右轉機車準確率大幅低於夜間,係誤植還是因為有其它因素。	謝謝委員的寶貴建議,經確認,當機車右轉時車流量較多時(重疊),則較有被誤判之可能。	同意
	本案有規劃 AI 影像結合 eTag 旅行時間,建議可再補充於進行適應性號誌控制時, AI 影像資訊及 eTag 旅行時間參數係如何結合應用。	謝謝委員的寶貴建議, AI 影像分析偵測所得車流量係用於號誌控制之用,而 e-Tag 讀取器則是用來蒐集路段旅行時間與評估道路績效使用。	同意
	本案在進行時制計畫設計時係利用 PaSO 及 SUMO 求得最佳時制方案與進行車流模擬,請問此方式與一般利用 Synchro 求得時制方	謝謝委員的寶貴建議,利用 PaSO 及 SUMO 求得最佳時制方案與進行車流模擬,與利用 Synchro 求得時制方案帶入 VISSIM 模擬車流之作法並無差異,只是號誌時制產生與模擬分析的工具與環境不同。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	<p>案帶入 VISSIM 模擬車流之差異為何？</p> <p>本案提出深度 Q 學習的強化式學習架構的號誌控制，由代理人 (Agent) 取得現場流量及時間，並依此產生時制計畫，此方式與一般適應性號誌控制的差異為何？而實際應用於路口時，代理人取得流量後係多久產生一套時制計畫下載至現場？</p>	<p>謝謝委員的寶貴建議，一般適應性號誌控制為模式 (Model) 導向，而 AI 號誌控制則是透過訓練與學習來使強化學習代理人 (Agent) 具備”知識”來進行號誌控制。實際應用於路口時，考量實際運作順暢度，代理人取得流量後係每週期內 (依據該時段週期長度) 下達將要執行之策略至控制器，如當時 AI 決定週期為 100 秒時，則會於 100 秒內下達時制計畫至控制器，以利下個週期可執行較符合當時車流之時制策略。</p>	<p>同意</p>
<p>桃園市政府交通局</p>	<p>桃園市目前亦正進行 AI 號誌控制計畫，目前主要是進行 AI 車流辨識與 AI 號誌控制，建議團隊多加留意 AI 號誌控制下達指令至號誌控制器時，指令是否可以正常下達並執行。</p>	<p>謝謝委員的寶貴建議，後續會於實測時特別注意此課題。</p>	<p>同意</p>
<p>臺中市府交通局</p>	<p>P.47，本研究實作範圍擬於平日尖峰、平日離峰、假日離峰進行號誌控制，請說明為何實作範圍僅選定部分時段進行，非實作範圍之時制計畫為何？實作範圍的時段選定標準為何？建議未來實作時採全日運行方式。</p>	<p>謝謝委員的寶貴建議，AI 模式訊聯與學習內容包括評價日間離峰時段車流資訊與對應之最佳化號誌時制計畫，後續將評估全日運行之可行性。</p>	<p>同意</p>
	<p>P.53，本研究透過 PaSO 進行兩路口時制最佳化產生，查該路口為簡單二時相，在週期與樂業路綠燈時間均增加情況下，路段七 (樂業路往東) 延滯增加原因為何？另若該兩路口號誌週期調整，計畫範圍之上下游路口是否需一併調整週期時間？建議未來進行實作前與本局研議相關配套措施。</p>	<p>由於樂業路與早溪東路往西為另一個號誌控制群組，與樂業路及長福路口之週期群組不同，故當研究路口週期時間增加，而樂業路與早溪東路口之週期時間未隨之因應調整，則早溪東路往東之車流會有部分週期無法銜接，造成車輛自早溪東路進入樂業長福路口前會有停等狀況，使延滯提升；但此部分經由實際觀察，車輛於樂業長福路口綠燈後，即可迅速通過數個路口，且現況車流並不會回堵至早溪東路口，由於處理此問題需要針對早溪東路往西之路口進行時制重整，故於初期討論時，建議在未造成車流溢流狀況下，建議不做調整，</p>	<p>同意</p>

審查委員	審查意見	審查意見回覆	主辦單位意見
		後續實做過程中亦將會持續與貴局討論調整。	
臺南市 政府 交通 局	臺南市目前亦正進行 AI 車流偵測，並使用傳統動態查表的號誌控制，先做查表再跑出績效，目前亦都有好的成果，並期望之後研究團隊能提供相關 AI 號誌控制成果參考，做為後續規劃方向。	謝謝委員的寶貴建議。	同意
通	本研究 AI 車流偵測已經可以計算延滯與等候線長度，請補充說明是否可以此做為號誌控制效益指標？	謝謝委員的寶貴建議，延滯與等候線長度是可以做為號誌控制效益指標，為目前容量手測是以延滯做為指標。	同意
	在路口轉向量調查方面，臺南市經驗為當將攝影機架設於路口 8 至 9 公尺高度處，即可避免大車遮蔽小車，且有良好成果，提供本研究參考。	謝謝委員的寶貴建議。	同意
	建議補充說明 P.23 臨時性設備進行車流量調查時之相關細節，以及可能之進行模式，例如：採用租借或購買方式，以及是否需要額外訓練。	謝謝委員的寶貴建議，後續將補充於報告。	同意
	報告書 P.16 圖 3.2.1 建議改為彩色，以方便閱讀。	遵照辦理。	同意
	本案 AI 號誌控制調整號誌時制內容的方式為何？係採路側辨識、資料回傳中心演算新的時制計畫下載至現場路口控制，或是由兩路口直接演算後於路側連鎖下載執行？是以各路口總合最低停等延滯為目標式嗎？2 個控制路口及其他路口車流量影像偵測如何影響 AI 號誌控制？各影像偵測器所偵測的資料如何傳輸？系統是否可偵測路口過飽和或飽和狀況，兩者於時制計畫產出其評估指標是否有差異？以上皆請補充說明。	謝謝委員的寶貴建議，本研究採邊緣端偵測交通參數資料，並主要透過外圍之六大路徑進入兩路口之車流量，藉由 4G 無線傳輸至邊緣端之 AI IPC，由 AI IPC 評估適合之時制計畫，再藉由 4G 傳輸至號誌控制器下達與執行指令。現階段以樂業路主線雙向旅行時間最低為目標。目前本研究所使用 AI 偵測設備尚無法進行路口過飽和狀況偵測，因此採用偵測上游進入車流量，以盡可能反映真實需求。	同意
	本案 AI 號誌控制路口周邊現況的交通壅塞問題為何？建議加以補充，以利後續各縣市類似應用場域導入之擴散。	謝謝委員的寶貴建議，後續將補充於報告。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	AI 影像辨識準確率僅抽取 10 分鐘影像驗證是否足夠？建議可再拉長。偵測情境亦缺乏兩天結果驗證，請補充說明。	謝謝委員的寶貴建議，已補充於 3.3 節，另受限於見場因素，對於樣本數不足 5 筆者，不納入準確率評估。	同意
	針對 AI 影像辨識偵測資料驗證，建議可細分為準確率、漏報率、誤報率等。	謝謝委員的寶貴建議，本研究於 SSD 模型改進部分已有將準確率、漏報率、誤報率等納入探討，並採用 mAP(Average Precision)做為評估指標(請參閱 3.3 節)，以驗證模型基本能力。	同意
	兩號誌控制路口均裝設 2 組攝影機做車流轉向量偵測，同一路口兩組攝影機可能會偵測到同一進入路口方向的車流轉向量，兩組不同攝影機的偵測數據是否可進行比對以提高偵測準確率？	謝謝委員的寶貴建議，雖裝設兩支偵測設備，惟兩者涵蓋範圍不同，因此無法進行比對。	同意
運輸	請說明簡報 P.16 與 P.17 之準確率計算方式。	謝謝委員的寶貴建議，後續將補充於報告。	同意
安全組	AI 偵測車流量之 4 輛機車與人工驗證所看到的 4 輛機車是否為同一輛機車？	謝謝委員的寶貴建議，AI 偵測設備於偵測車輛通過加入計數時，亦會同時擷取照片並標註其判別的車輛，故本研究以其所擷取的照片與數據進行比對，當車輛在正確判別時(即正確判別車種)，則其所偵測的車輛是與影片中為同一部，但當其無法正常判別車種時，如將大型車誤判為中型車，則其數值為不同部。	同意
	AI 在偵測機車辨識率較低，是否為遮蔽問題導致，若遮蔽因素，人工驗證時應也看不到。	謝謝委員的寶貴建議，由於 AI 偵測係透過偵測線計算車流量，故當車輛於通過偵測線時無法辨識，則其則無法偵測，但人工可透過軌跡來判斷。	同意
運輸資訊組	2.2 節應用 AI 於號誌控制部分， 目前僅著重於探討以強化式學習(Reinforcement learning, RL)為基礎的 AI 號誌控制，惟在 AI 號誌控制演算法仍有多項不同作法，例如：美國 Carnegie Mellon University Stephen Smith 教授實驗室所發展之 Surtrac、Siemens、IBM、我國桃園市與高雄市預計導入 AI 號誌控制、臺灣大學的「基於類神經網路方法之最大化幹道續進動態號誌控制策略」、逢甲大學的「以小	謝謝委員的寶貴建議，已補充於 2.3 節以及 4.1.3 節。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	波倒傳遞類神經網路設計紅綠燈號誌的時間」、清華大學的「利用自我映射組織圖與增強式學習法於可調式交通號誌控制系統的機器學習模型」，因此請強化此部分文獻資料蒐集廣度，以及加強為何選用強化式學習(RL)之論述。		
	請再進一步強化在強化式學習(RL)介紹的邏輯性與學習過程說明，以及補充各英文所寫之全名與各公式參數定義。	謝謝委員的寶貴建議，已補充於 4.1.3 節。	同意
第三章 AI 交通資料蒐集部分，			
	本研究在車流 AI 偵測技術係延續自前期計畫成果，請補充說明本期計畫在軟硬體功能上與前期之差異與精進之處。	謝謝委員的寶貴建議，本期計畫硬體方面與上一期相同，均為 Nano，軟體方面之相關調整請參閱 3.3 節。	同意
	請補充說明事前交通調查計畫內容。	謝謝委員的寶貴建議，已補充於 3.2.2 節及 4.1.1 節。	同意
	請補充說明本案所使用 AI 車輛偵測器在「日、夜、雨天等各種情境下，能辨識行人、機車、小型車、大型車、聯結車等不同車種」辨識與所偵測各種交通參數之準確度。	謝謝委員的寶貴建議，請參閱 3.3 節。	同意
	請補充說明 P.33 表 3.3-2 對於機車偵測準確率低於 60%與汽車低於 90%之可能原因與改善方式。	謝謝委員的寶貴建議，請參閱 3.3 節。	同意
	請補充說明 P.35 表 3.3-3 之車流密度單位。	謝謝委員的寶貴建議，車流密度單位為偵測區域內之車輛數(不含機踏車)。	同意
	請補充說明 P.39 與 P.41 中 AI 車輛偵測器之 Traffic Complex 與 Parking 偵測模式內容及其差異，以及實務應用上限制。	謝謝委員的寶貴建議，前者主要藉由兩條偵測線判定車輛通過兩條線之時間，後者為計算車輛停等時間，實務上應用部分，前者可做為轉向量偵測、通過停止線時間偵測，後者可做為違規停車偵測、停等延滯偵測、車流密度偵測。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	請補充說明 P.43 表 3.3-6 中何謂「車輛於較遠於準備停等時未判斷到」？其它「正常」的偵測距離為何？是否表示本研究使用 AI 車輛偵測器在路口停等延滯有距離上的限制？	謝謝委員的寶貴建議，「車輛於較遠於準備停等時未判斷到」，目前未被判斷到之車輛多屬於距離偵測設備較遠，而較遠時，則其亦受限於影像較小，或是遭到前車遮蔽，致使無法被判別。 AI 影像偵測器其是藉由影像做為判斷基礎，故若影像範圍無法涵蓋所有路段、解析度不清之情況下，即無法偵測，目前普遍可有效偵測範圍為 30 公尺。	同意
	請補充說明本研究所使用 AI 車輛偵測器之偵測事件內容與應用方式。	謝謝委員的寶貴建議，目前將藉由佔有率判定壅塞，做為事件偵測，並可掌握道路績效問題。	同意
	請補充說明利用臨時性車流偵測設備進行交通量調查時與人工作業之各面向(例如：設備架設與校估時間)量化比較。	謝謝委員的寶貴建議，請參閱表 3.2-3。	同意
第四章 AI 路口號誌控制部分，			
	請補充說明 P.46「依據路口間距離、車速與停等長度...等，微調時差」之具體使用參數項目。	謝謝委員的寶貴建議，由於本研究採用之流量資料係為外圍 6 個路口之流量資料，故本研究藉由兩路口之轉向量校估六大路徑之流量，已解決匯入流量於中間路段停等或轉向之車流量差異。	同意
	請補充說明本研究 2 個路口的現況號誌時制計畫內容。	謝謝委員的寶貴建議，續將補充於報告。	同意
	請補充說明 SUMO 模式在模擬本研究 2 個路口事前績效之誤差程度，所使用之績效值為何？如何進行 P.52 所敘述之「往市區部分特別調整通過量」調整工作？	謝謝委員的寶貴建議，SUMO 分析內容與績效請參閱 4.2.2 節；另關於往市區流量調整部分，因路口流量調查結果為當下號誌控制之結果(紓解量)，並非實際需求量，因此透過攝影機與現場觀察，計算上游實際需求量，進而修正並增加該方向車流量。	同意
	請補充說明 P.54 表 4.1-3 之事前事後模擬績效值係由 PaSO 或 SUMO 產生？以及此改善幅度之合理性。	謝謝委員的寶貴建議，該績效值由 PaSO 產出；方向 9 為往市區方向，事前常回堵至環中路口，因此改善效果顯著，方向 7 為往太平方向，由於週期增加，期停等延滯秒數亦略為增加，因此 PaSO 所產出績效有反映出現況。	同意
	請補充說明 P.57~P.58 之時制流量對應計算方式之參考資料來源，以及先前使用案例。	謝謝委員的寶貴建議，參考 Webster 路口時制最佳化求解程序。先前使用案例，可參考 PasO 使用案例。	同意
	P.63 敘述本研究在訓練過程採用專家及與代理人之動作相似	謝謝委員的寶貴建議，受限於時程本研究無法納入，建議納入後續年度計畫工作。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	度做為強化學習之獎勵方式，建議在後續演算法設計上，評估納入實際道路之改善(例如：旅行時間縮短、延滯降低、停等次數減少)參數為獎勵項目。		
	請補充說明 P.64 的兩階段實驗設計所採用之交通參數內容，以及 P.66 在 AI 號誌控制強化學習 456 種流量組合下，如何利用 PaSO 產生對應之時制計畫進行學習？抑是有進行降維(Dimension reduction)程序？若有，請補充說明。	謝謝委員的寶貴建議，本研究係利用 PaSO 產生時制計畫，再由代理人學習專家之行為選擇時制計畫，依據各種可能組合之流量進行學習訓練(無降維)。	同意
	P.67 之「分析訓練至 5M 回之網路，於訓練之資料集中專家常採用之時制計畫代理人可輸出與專家完全相同決策，然而於訓練之資料集中專家不常採用之時制計畫(<3%)，代理人有 20% 機率輸出與專家不同決策」語意不清，請再加強說明。	謝謝委員的寶貴建議，請參閱 4.1.3 節。	同意
	請補充說明 P.68~P.70 表 4.1.22~表 4.1.24 之內容。	謝謝委員的寶貴建議，請參閱 4.1.2 節。	同意
	請再加強說明 P.71 利用幹道旅行時間做為本研究 2 個路口績效評估之合理性。	謝謝委員的寶貴建議，請參閱 4.4.1 節。	同意
	本章對於如何應用 PaSO, SUMO, Ray, Python, TraCL 來構建本研究導入 RL 或仿真學習之說明略為凌亂，請再加強說明。	謝謝委員的寶貴建議，本研究中，PaSO 為輔助專家建立時制計畫工具；Ray 提供建立強化學習之函式庫來建立訓練環境，以訓練代理人網路；SUMO 為交通模擬平台，可提供績效驗證，並且代理人可透過 TraCI 動態於 SUMO 中取得交通狀態，並對 SUMO 中之號誌進行控制；本研究使用之程式語言為 Python。	同意
	請補充說明本研究如何納入與前期研究幹道介接之號誌連鎖或續進考量。	謝謝委員的寶貴建議，前期改善時段為晨峰及昏峰，且週期改為 150 秒，因此本研究於尖峰時段配合前期週期進行調整，以達到號誌連鎖與續進之目的。	同意
	請補充說明本研究所研提 RL 演算法與美國賓州大學 Hua Wei 的單一路口(IntellLight)與	謝謝委員的寶貴建議，本研究透過 PaSO 為輔助專家見立時制計畫，以利本研究 AI 模式進行仿真學習，並於實際路口進行運作，	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	幹道路口 (PressLight) 演算法之差異。	所指文獻則透過模擬環境進行 AI 模式學習與訓練。	
	4.3 節對於 AI 號誌控制之短中長期規劃內容，請再從可實務解決或紓解路口交通壅塞進行探討與規劃。	謝謝委員的寶貴建議，請參閱 4.5 節。	同意
	「第五章我國未來 5 年 AI 於交通領域之整體規劃」部分請再從更廣泛的面向進行探討，非僅限於道路交通之辨識、預測策略與規劃。	謝謝委員的寶貴建議，請參閱第五章。	同意
	有關報告初稿中錯別字、格式錯誤、圖表清晰度不夠與資料來源未敘明部分，請於會後洽本所。	遵照辦理。	同意
主席	請補充說明 AI 強化式學習文獻回顧在國內外號誌控制發展情形，以及相關技術之實作與實證。	遵照辦理。	
	在號誌模擬模式、AI 號誌控制強化式學習之軟體構建環境等在紓解實務上路口交通壅塞課題，請再加以強化說明。	遵照辦理。	
	請補充說明 AI 車輛偵測及人工驗證誤差原因，以及其克服方式。	遵照辦理。	
	請補充說明現階段在何種限制下，採用 DQfD 演算法與搭配 PaSO 進行學習的作法，以及本研究預期階段性成果；後續若在研究資源充足下，可以達到的 AI 號誌控制較完整未來發展架構與期望成果。	遵照辦理。	
	對於我國未來五年 AI 在交通運輸應用的整體發展規劃，除在影像辨識與號誌控外，請研究團隊在範圍不受限進行 AI 在交通運輸應用的探討。	遵照辦理。	
	為利期末報告初稿準備與提送，請於期中審查會議結束後，每次工作會議前提送階段性成果報告予本所審視，併於工作會議中討論。	遵照辦理。	
	請逢甲大學依各委員與單位出席代表審查意見，研提處理情形答覆意見送本所審查後，做為修正報告之依據，本次期中審查原則通過。	遵照辦理。	

附件二、期末報告審查意見處理情形表

審查委員	審查意見	審查意見回覆	主辦單位意見
吳玉珍委員	在 AI 影像偵測精進過程所獲得經驗是寶貴資訊，因此請補充說明精進過程之失敗或準確率較低案例，或精進前的狀況及現象。	感謝委員建議，已補充相關精進過程於表 3.3-20。	同意
	請進一步探討 P.45 表 3.3-3 大客車白天與夜間 MAPE 均為 0(偵測表現良好)，但相似車型的大貨車卻較為不好的原因。	謝謝委員的寶貴建議，大貨車和大客車雖然尺寸較接近但外型還是有一定差異：大客車幾何形狀較難與小客車、小貨車混淆；反觀大貨車在距離鏡頭較遠時或只露出正面車頭時較容易與中型車混淆，相關議題亦已補充於 3.3.7 節。	同意
	請補充說明為何中型車尺寸介於小客車與大貨車之間，但辨識效果不如小客車，以及在夜間的辨識效果比白天為佳的可能原因。	謝謝委員的寶貴建議，中型車離鏡頭較近特別是車頭正對鏡頭時有可能被辨識成大型車。天候部份雨天通常光線較暗且鏡頭因雨滴變得較模糊，因而辨識率普遍有降低情形，特別是小型車的部份(機車、小客車)；夜晚部份因為車輛開車燈反而使得與背景特徵差異變得較大，加上夜間車流降低，車輛互相遮擋機會也降低，因此會較容易正確偵測，相關議題已補充於 3.3.7 節。	同意
	在 AI 影像偵測精進前的 P.47 表 3.3-5 與表 3.3-6 的 MAPE 特別高，P.48 測試二的 AI 影像偵測車輛數是實際的 2 倍，請補充說明原因。	謝謝委員的寶貴建議，此錯誤發生原因如圖 3.3.6，由於原 3 號線畫設未平行於車道，導致直行機車碰觸後被判斷成轉彎(樂業往西左轉和樂業往東右轉皆有此問題，機車均被大量多算)，此問題已於重新畫設後改善，相關精進過程可參閱表 3.3-20。	同意
	根據經驗，目前各業者應用 AI 影像偵測在左右轉車流量偵測效果均不佳，而 P.58 表 3.3-14 的 AI 影像偵測精進後比較僅有直行不同車種車流量數，並無左右轉資料，請補充說明本研究在轉向交通量之偵測成果。	謝謝委員的寶貴建議，已補充於表 3.3-14。	同意
	請補充說明 P.62 表 3.3-15，車流密度驗證表中序號 5 兩台車均未偵測到(MAPE 為 100%)的原因。	謝謝委員的寶貴建議，經確認，應為未偵測到 1 台車，該序號為第一台車，因已幾乎超出偵測畫面而未被偵測。	同意
	請再補充說明 P.107 SUMO 雖有機車模式，但本研究未納入探討是否因為行駛內側為重型機車，或是違規行為的考量。	謝謝委員的寶貴建議，SUMO 之機車包含重型機車與普通重型機車，其車流行為與我國不同，本研究並未探討此課題。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	請補充說明 P.194 AI 產生時制計畫可能比 PaSO 結果更好的因應機制，以及用文字陳述或案例說明來釐清利用獎勵值來更新路網的機制。另後續研究之進一步精進建議為何？	謝謝委員的寶貴建議，透過 PaSO 計算出基礎時制做為定時時制，AI 號誌控制則依據偵測器即時交通資料，決策出一套最佳時制，以符合現況車流，因此較 PaSO 之定時時制佳。另獎勵值的更新機制以補充於 4.1.3 節，第 111 頁。	同意
許添本委員	簡報 P.33 中有 Q-Learning 架構，請補充說明 Action 在做選擇時是用 PaSO 產生的 Dataset？還是隨機的 Dataset？State 是交通量，依據交通量挑選一個時制，而在使用 Webster 公式時，於數值接近 1 會產生無限大的狀況，是否可以使用其它公式？	謝謝委員的寶貴建議，Action 在做選擇時是採用 PaSO 所產生的時制計畫 Dataset。Webster 為舉例說明，實作階段並未採用。	同意
	第二階段是要比 PaSO 結果更好，但目前作法 State 並不會改變交通量，並沒有 State 跟 Action 的互動，兩者間如何相互影響？同時請補充說明第二階段學習過程 (Learning) 之收斂情形。	謝謝委員的寶貴建議，目前 Action 的選擇受 State 影響，當 Action 決定後即可收到模型回饋之 Reward；本研究以仿真學習進行，訓練過程搭配不同交通量組合做為訓練樣本。	同意
	文獻回顧中本人所發表文章的學習機制是直接寫在 VISSIM 模擬軟體，而非利用 VISSIM 進行驗證，請修正。	謝謝委員的寶貴建議，已進行修正。	同意
	目前 AI 號誌控制作法有二種，分別是以週期及以時相為單位作 Action，而其中困難點在於如何導入交通專業。目前適應性號誌控制間隔可為 2 秒，而本研究為 5 秒，建議再思考論述方式與加以補充。	謝謝委員的寶貴建議，本研究利用 DQfB 將交通專家(PaSo 扮演)與 AI 模式進行結合，使 AI 模式可以在既有一定的基礎上進行學習更加精進，為確保能增加 2 輛車以上通過該路口，在現場車頭距通常大於 2 秒情況下，為確保實際營運效率，因此採用 5 秒間隔做為 AI 號誌控制策略其時制計畫間之時間。	同意
	P.98 對於本案的 AI 號誌控制深度 Q 學習論述應可以再詳細論述。	謝謝委員的寶貴建議，已進一步詳細論述 AI 號誌控制深度 Q 學習，請參閱 4.1.3 節。	同意
	本研究並沒有做到人工智慧的號誌控制，故題目應加以修改為宜，因為並沒有用人工智慧去做號誌控制，請修正。	謝謝委員的寶貴建議，本研究採用 DQfB 模型，廣義地來說亦屬於人工智慧的一種。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	<p>也許利用人工智慧去號誌控制的原因，是因為當你想要在交通狀況改變的時候，你能夠透過 learning 去傳遞結果取產生一個因應當時交通的號誌，這時候就發揮作用，他可能比適應性號誌更適應。國外文獻真正落地的並沒有，現在台灣真正落地的，直接用 IPC 直接在路側端直接學習，所以輸入資料是直接影像辨識，直接將所有資料當成 State 放入原本已經訓練好的模式，若有資料重疊，他會自動連鎖，不用自己設定時差。建議真的可以讓交通跟 AI 兩者去互動，找出可修正的部分。</p>	<p>謝謝委員的寶貴建議，建議納為後續年度計畫之執行參考。</p>	<p>同意</p>
	<p>因為並沒有用 SUMO 來進行機器學習(Machine Learning, ML)進行互動，這部分應加以補充修正。</p>	<p>謝謝委員的寶貴建議，本研究應用 SUMO 進行事前 AI 號誌控制績效評估，已於第四章補充說明。</p>	<p>同意</p>
	<p>因為其 learning 的 state 及 action 與 reward 並有互動關係，故並非 DQN，也不是 RL，更不是 DQfD [可參考文獻 5,48] 故建議報告也內容將這些名詞刪去，另報告的 P.98 的 Q function 無法運作。</p> $Q_{new}(s_t, a_t) = Q(s_t, a_t) + \alpha \left[r_{t+1} + \gamma \max_{a_t} Q(s_{t+1}, a_t) - Q(s_t, a_t) \right]$	<p>謝謝委員的寶貴建議，當 γ 為 0 時，表示動作之選擇不考慮未來之變化，其 Q function 即與委員提出之公式相同。</p>	<p>同意</p>

審查委員	審查意見	審查意見回覆	主辦單位意見
	<p>本研究的方法無法將車流量(s)時在不同的號誌時制(a)之下 s 與 a 進行互動，若要互動必須如各參考文獻所提的將 learning 的 procedure 使用程式跟 SUMO 或 VISSIM 互動才能做到，例如：此本研究報告的參考文獻 [6,7, 24,27,43....]，建議再加以修正；另對於其中的參數 α：學習率，決定網路更新的步伐大小(0~1)，過小導致收斂速度慢；過大將難以收斂，γ：折扣因子，未來獎勵對當前狀態-動作價值的影響(0~1)，請再加以檢討最佳值為何？</p>	<p>謝謝委員的寶貴建議，折扣因子 γ 是介於 0 至 1 之數值，在本研究之模式中，狀態為流量，獎勵為與專家之相似度，故本研究 γ 採用 0；本研究採用 Adam 做為優化器，是一種在學習率上可依據梯度的大小對學習率進行加強或是衰減之方法。</p>	<p>同意</p>
	<p>因為目前是輸入交通量，用 PaSO 求解最佳化時制計畫之後，再學習 PaSO 產生的時制計畫，因此只要直接用 PaSO 時制計畫就好，實在沒有必要多此一舉；另再用 PaSO 所產生時制計畫，並利用 SUMO 來模擬跟現況的定時號誌控制進行比較，如此不是 DQfD，更不是人工智慧，請修正。</p>	<p>謝謝委員的寶貴建議，本研究採用 DQfB 模型，廣義地來說亦屬於強化式學習的一種。</p>	<p>同意</p>
	<p>在車流量使用表 4.3-2 的 PCE 轉換，因為 PaSO 可以解含機車交通量，而不用 PCE 換算為 PCU 的做法，故目前本研究作法雖是設法找跟 PaSO 一樣的答案，但又比原來 PaSO 可以解含機車的更不適用，請修改。</p>	<p>謝謝委員的寶貴建議，本研究使用實際車流量，並非轉換成 PCU。</p>	<p>同意</p>
	<p>本研究方法類似動態查表概念，並非由實際動態偵測到的交通狀況，輸入到訓練好的時制計畫產生的模式來即時產生時制計畫，並導入改變控制器的時制計畫，達成真正的 AI 號誌控制，建議補充說明。</p>	<p>謝謝委員的寶貴建議，本研究考量 AI 模式的訓練所需時間，若時制計畫皆由 AI 模式產生(AI 輸出可能包含週期、時比及時差)，其訓練時間可能增加數倍，甚至未必能有效收斂，故先給予其基礎時制作選擇，未來可再依這些時至進行擴充調整。</p>	<p>同意</p>
<p>陳勁甫委員</p>	<p>第二章文獻回顧部分，建議強化所回顧的文獻內容及技術發展，收斂為本研究所採用之技術與演算法之強力支持。另 2.2 節應用 AI 技術於交通資料蒐集及 2.3 節</p>	<p>謝謝委員的寶貴建議，已進行補充。</p>	<p>同意</p>

審查委員	審查意見	審查意見回覆	主辦單位意見
	應用 AI 於號誌控制之回顧，建議列表彙整比較。		
	第三章 AI 交通資料蒐集與應用，因屬本研究主要工項且內容涉及不同狀況之因應與修正，建議將本研究所執行之過程以流程圖方式，以利說明執行過程與內涵。另 MAPE 以 20%-50% 為合理，似乎對於精準度過於寬鬆。	謝謝委員的寶貴建議，相關流程圖已補充於表 3.3-20，針對準確率指標，為利與其他號誌偵測器準確率指標通用，已調整為 1-MAPE。	同意
	P.110 表 4.2-1 不同路徑有不同績效，那整體績效是怎麼去進行計算的，請再加以說明。其中有些-57%、-46%的樣本，如何去處理那些個體，有些績效若用平均概念去看，可能會把很多細節忽略，可能會影響後續發展，此外，SUMO 扮演的角色為何，應再說明清楚。	謝謝委員的寶貴建議，總體績效係由個體績效加總所得，如總延滯為每輛車的延滯加總。本研究模擬績效分析皆以總體來看，而百分比則是呈現改善前後的績效變化；使用 SUMO 之目的，主要可以在實際上線前，透過模擬接近真實環境條件下，驗證 AI 號誌控制之運作，是否可以符合預期之運作成效。	同意
	儀表板的想法很好，但不確定是否為本研究最終所期待的，儀表板應是呈現 AI 運作狀況或是績效或是要呈現什麼？目前所呈現的績效(事前與事後)感覺並不是控制中心所要的資訊，控制中心所要的是那個路口的績效，包含車速、延滯，而不是比較；假設是這樣，未來控制中心的人，看到路口績效變糟了，如果是 AI 號誌控制出來結果，產生過大的延滯或車流停下來，該如何處置？AI 有辦法解決嗎？	謝謝委員的寶貴建議，儀表板主要目的要能讓管理者瞭解即時 AI 號誌控制運作狀況與通訊情形外，也能掌握即時運作績效。受限於現場施工不易因素，在臺中市政府交通局協助於主要路徑上佈設 e-Tag 蒐集旅行時間下，掌握改善前後路徑旅行時間的變化。若是現場發生異常導致決策誤判時，則須由監控人員手動關閉系統，恢復原設定之定時時制計畫。	同意
	目前 AI 學習專家是以現有最佳化時制產生軟體做為專家，但是並不是最佳的解，感覺不像 AI 對於路口問題的真正的解決，應該還能再尋優。想像中的儀表板，應該可以針對指標利用殘差項比較，並有一個可接受的信賴區間，讓監控人員可以掌握運作之狀況。	謝謝委員的寶貴建議，未來可透過替換本研究 AI 模式獎勵值方式，持續發展，提升績效。有關儀表板規劃部分，感謝委員建議，建議納入後續年度計畫執行參考。	同意
	績效評估會針對太平、市區方向去做檢測，有一點點是從原來這個路口去測路徑績效，為何使用 AI 後為何有比他好或是比他更差	謝謝委員的寶貴建議，本研究的專家為由 PaSO 扮演，AI 模式學習 PaSO”知識”，時制計畫則是預先採 PaSO 擬定於不同情境流量下，所對應產出一最佳時制解，因此	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	的問題，照理來講應該要符合原來的時制。	AI 號誌控制會依據當下車流狀況，擇一較優時制於路口執行。	
	3.5 節 AI 應用於交通管理之資訊安全議題初步探討之內容，比較像文獻回顧，建議應擬定與本案相關議題，並進行論述為宜。	謝謝委員的寶貴建議，本研究回顧 AI 應用於交通管理相關作法，且針對未來號誌控制牽涉之議題進行分析，包含通訊、設備與法規，請參閱 3.5 節。	同意
	4.1.3 節強化學習規劃設計，其訓練結果是否有使用 SUMO 軟體進行之？因為 4.2 節 AI 號誌控制之分析乙節才介紹 SUMO 模擬軟體，在流程上不易釐清，建議以流程圖表示本章之分析工作與內容。	謝謝委員的寶貴建議，相關流程請參閱圖 4.1.2，SUMO 績效模擬請參閱 4.2.2 節，本研究採用 SUMO 模擬軟體來模擬其運作績效。	同意
	改善前與改善後之 SUMO 模擬制績效分析中，關於整體績效之計算方式，建議加以說明與釐清。	謝謝委員的寶貴建議，整體績效由 SUMO 產生各路段延滯進行加總。	同意
	AI 動態號誌監控平台所呈現的績效是否為透過 AI 號誌控制後的績效？並請說明如果發現儀表板上的指標績效過差之情形，應如何因應？	謝謝委員的寶貴建議，平台所呈現之績效同時包含 AI 即時運作資料與事前資料做為績效比較，倘若即時績效過差，為避免現場車流無法紓解，監控人員可直接藉由儀表板關閉 AI 號誌控制，使現場號誌恢復 TOD，並再進行後續原因探討。	同意
	因本研究僅就選定之路口進行測試，建議提供未來根據本研究測試結果與經驗如何擴充到更多不同類型進行 AI 號誌控制之程序、技術與相關做為，已達其一般化之適用性。	謝謝委員的寶貴建議，擴充到更多不同類型的程序，大致如下：在 AI 模式建構中，先定義 state、action 和 reward，其中 state 和 reward 皆受限於偵測器所能偵測之交通狀態，故首先必須先考慮偵測器所能偵測之狀態，再考慮欲解決之交通問題以設計 AI 號誌控制。	同意
	我國未來 5 年 AI 於交通領域之整體規劃內容，似乎涵蓋範圍過廣，建議以本研究主題為主要範圍，提出 AI 在交通數據蒐集及號誌控制上之 5 年整體規劃，以利聚焦並做為後續推動相關政策之重要參考。	謝謝委員的寶貴建議，後續探討將著重於陸運領域。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
劉瑞麟委員	本案蒐集文獻回顧後，採用 DQFD 之模式，惟文獻回顧並未對 DQFD 著墨太多，且各種模式之優缺點分析及最後挑選此種模式，並無強烈之連結，建議可再加強。	謝謝委員的寶貴建議，DQFD 之優勢為基於專家之展示，再與環境進行互動前，先學習到一定基礎之水準，再開始與環境互動，相較於其他演算法，皆是從零開始學習，DQFD 可減去 AI 初期探索之過程，加強之論述參閱 4.1.3 節。	同意
	本案採用臨時性設備進行現況資料調查，P.37 至 P.40 頁亦有提及部分路口部分流向之車流，因為偵測區存在偵測線畫設方式及拍攝角度遮蔽等問題。如未來路口轉向量及路口延滯調查以 AI 設備調查取代人工調查，前述 AI 影像校估期程、準確率驗證標準及設備限制是否可克服？另路口延滯僅能計算攝影機拍攝範圍之停等車輛，是否計算會有誤差？建議以本次之執行之經驗或後續需克服之議題，再加以整理說明。	謝謝委員的寶貴建議，有關轉向量調查，若採一流向由一偵測設備偵測，其準確率應較高，若一偵測設備偵測兩流向，則攝影機畫面應盡可能涵蓋整個路口且至偵測流向之停止線，方能有較好成果，而臨時性偵測設備由於其可機動移動，故可較不受既有號誌桿之影響。 路口延滯調查與攝影機拍攝範圍密切相關，本研究嘗試使用其他攝影機進行測試，初步測試成果已較本次實驗有明顯提升(該攝影機有效拍攝範圍比本次使用之攝影機長)，若所有車輛均可被攝影機有效拍攝且被 AI 偵測，則計算誤差應較低。相關後續議題已補充於 3.3.7 節。	同意
	建議本案蒐集之路口轉向量、AI 影像辨識技術蒐集之車流密度、佔有率、停等車量紓解及延滯計算之邏輯、資料儲存之格式(動靜態資料表格式)及傳輸協定(因無 V3.0 協定)可整理清楚，做為後續其他計畫之參考。	謝謝委員的寶貴建議，本案之偵測設備傳輸方式係藉由設備所提供之 API 進行串接，藉由 API 即時接收資料或是查詢資料，相關資料儲存格式可依據使用者之使用需求自行定義。針對相關偵測模式補充如表 3.3-21。	同意
	建議第 4 章 AI 路口號誌控制，可以簡要先以圖表摘述 AI 路口號誌控制之主要架構，包括輸入之資料、輸出之資料、使用之演算法及學習之方式(使用之真值)，再就各項細節項目深入進行說明，以方便報告書之閱讀。	謝謝委員的寶貴建議，已針對第四章開頭補充本章各小節所述內容，利於讀者可概略瞭解本章節之大綱順序與內容。	同意
	本案如有使用 AI 學習之專業名詞(如強化式學習、代理人、專家基礎模型、獎勵方式及均勻採樣等)，建議應於備註簡要說明，以利非相關領域之人員容易閱讀。	謝謝委員的寶貴建議，本案已針對部分項目進行補充，以利閱讀。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	本案輸入車流參數僅使用流量，是否有無法判定為壅塞或真實無車之情形？	謝謝委員的寶貴建議，因並無偵測設備可偵測是否壅塞，故本研究於控制路口的上游裝設車流量偵測設備，以供 AI 號誌控制系統掌握實際需求，由於車流量偵測設備至控制路口的路段間較無支道車流，故較不會發生真實無車的狀況，但當車流壅塞回堵至偵測範圍外，則無法判別是否為壅塞。	同意
	本案以 PaSO 模擬軟體模擬結果挑選之時制，做為真值訓練，惟 PaSO 模擬軟體之結果並非真的為車流最佳之結果，且如果僅以 PaSO 模擬結果做為真值訓練，是否直接使用 PaSO 做為號誌控制之依據即可？且 AI 學習之結果無法超越 PaSO 之效益之問題，是否可用實際調查之車流數據，如旅行時間、延滯及停等車隊長度等，做為加強學習之回饋。	謝謝委員的寶貴建議，本研究採用 PaSO 扮演專家來計算最佳時制計畫，亦可改用其它時制最佳化軟體；本團隊考量 AI 號誌控制模式落地的可行性，現階段為模仿專家模型為主，因此執行績效暫不會超越專家本身，但未來可更換獎勵函數，如偵測器所蒐集之延滯等，以突破既有運作能力限制。	同意
	P.109 第 3 行提及僅考慮樂業路主線之績效，建議應以整體路網之績效(含支道)一併考量，否則儘量延長主線秒數即可明顯改善，易有失真之情形。	謝謝委員的寶貴建議，本處係指不單獨探討樂業十甲至樂業東英中間路段之績效，而是以樂業路主幹之績效做為探討，於 SUMO 模擬階段，亦已探討整體路網績效變化。	同意
	P.112 AI 號誌控制策略是中心端或現場端處理的說明不清楚，建議文中提及代理人、邊緣裝置等應進一步敘明為圖中的何種設備。	謝謝委員的寶貴建議，已補充於 4.3.1 節。	同意
	P.158 4.5 節 AI 號誌控制未來發展，探討之內容與本案執行之過程連結性不足，建議再加強說明。	謝謝委員的寶貴建議，已補充於 4.5 節。	同意
高速公路局	建議補充說明 AI 影像偵測技術的車流偵測與交通參數產生，在高速公路應用之可行性。	謝謝委員的寶貴建議，有關車流偵測與交通參數產生，請參閱 3.3 節，針對高速公路之應用，可採用一偵測設備同時偵測車流量、車速、佔有率及停等車輛數。	同意
公路總局	P.24 建議簡述本研究兩路口「樂業-十甲東」及「樂業-東英路」之道路特性(如車道數、路口範圍等)。	謝謝委員的寶貴建議，已補充於 3.1 節，並新增圖 3.1.1 及 3.1.2 細部說明場域範圍與場域特性。	同意
公路總局	P.26 有關攝影機架設高度為 5.5 公尺部分，其高度是否會有大車遮	謝謝委員的寶貴建議，本高度若為正面拍攝，則會有大車遮蔽小車之問題(可參閱表 3.3-3)，斜向拍攝則汽車較不易被遮蔽，然	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	蔽小車或有效偵測距離不足等問題。	而機車之偵測準確率校正向拍攝低；正向拍攝在無大車遮蔽下，本攝影機偵測距離約為 30 公尺，並可評估更換可偵測更長之攝影機，以提升偵測距離。	
	P.41 請詳述表 3.3-1 有關 mAP 值及各類 AP 平均值用於評斷系統好壞程度之結果及相關意義。	謝謝委員的寶貴建議，已補充於 3.3 節。	同意
	P.45 表 3.3-3 分車道各車種各情境交通流量偵測準確率表中，AI 偵測數量多較人工計數為低，惟中型車部分，卻是 AI 偵測數量明顯高於人工計數結果(如斜向及正向拍攝-白天等)，建議可補充說明其原因。	謝謝委員的寶貴建議，經細部探討，由於中型車、小客車與貨車之車頭相近，當大貨車在距離鏡頭較遠時或只露出正面車頭時較容易與中型車混淆，致使中型車數量較多。	同意
	P.47 表 3.3-5 路口各車種轉向交通量偵測(白天)，十甲往北右轉的 MAPE 值遠高於其他路口，是有何特別原因?	謝謝委員的寶貴建議，十甲東路往北右轉因拍攝範圍較為清楚，且較無死角，故偵測準確率較高。	同意
	P.56 本研究各 AI 偵測設備，多係附掛於現有號誌桿，並因號誌設置地點影響其偵測結果(如圖 3.3.8)，未來建議可考量設置於路側路燈桿之可行性。	謝謝委員的寶貴建議，本研究於設備布設規劃曾評估架設於路段中間之路燈桿，惟受限於引電問題(白天不供電)，經與臺中市政府交通局討論後，無法附掛於路燈桿，但若要偵測末端車隊之延滯，路段中間之路燈桿為最為合適之位置，惟須克服跨單位協調與引電問題。	同意
	P.58 表 3.3-14 中，經改善後多數準確率多有所提升，僅有雨天-樂業往東直行機車之準確率係呈現下降，且中型車亦有較實際車輛數多 1 之情形，建議補充說明相關原因。	謝謝委員的寶貴建議，由於雨天之情境，攝影機容易因為畫面不清造成部分畫面偵測中斷(本研究驗證之雨天多為暴雨時段)，故雨天之影響因素多受畫面遮蔽而造成誤差；中型車部分，由於中型車、小客車與貨車之車頭相近，當大貨車在距離鏡頭較遠時或只露出正面車頭時較容易與中型車混淆，致使中型車數量較多。	同意
	P.59 車流密度部分，僅提及白天及夜間有優良成果，建議可補充說明雨天偵測結果，並提出相關檢討或改善做為。	謝謝委員的寶貴建議，經查為未於內文說明雨天之準確率，雨天之準確率為 94%，應已達一定水準。	同意
	P.61 表 3.3-15 中雨天 24 及 26 備註鏡頭模糊，請補充說明何謂鏡頭模糊?	謝謝委員的寶貴建議，有關鏡頭模糊說明，請參閱 3.3.7 綜合探討第 5 點雨天影響及圖 3.3.15 與圖 3.3.16，當鏡頭遭到雨水或污漬遮蔽，以致於無法清楚辨識時，則屬於鏡頭模糊。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	P.69 3.3.7 節綜合探討部分，因雨天準確率較低，建議可增加雨天部分相關之探討內容。	謝謝委員的寶貴建議，本研究持續探討追蹤偵測課題，使雨天影響畫面中物件移動之連續性中斷可被忽視，如圖 3.3.4 所示，行人行走於暴雨中藉由追蹤偵測方式，當行人行走至畫面不清楚之路段時，仍可有效辨識，但若遮蔽時間過長，則追蹤偵測功能亦將無法有效運作，本研究將持續精進。	同意
臺北市 政府	未來若要將人工智慧廣泛應用於號誌控制，勢必需考慮到多個路口號誌採用動態號誌控制可能會造成的連帶影響，後續建議可往此一方向研究。	謝謝委員的寶貴建議，可參閱 4.5 節，建議納入後續年度計畫執行參考。	同意
交通 局	以影像辨識進行車流偵測，於機車之辨識效果較差，若於機車用路人較多之城市區域實施本研究所行之號誌控制，是否會有影響？	謝謝委員的寶貴建議，本研究所使用之 AI 偵測設備偵測機車績效於正向拍攝情況下，其 MAPE 為 10%~15%，應已達一般使用之標準，惟在車流型態改變之下，本研究所探討之 AI 模式須要重新學習與訓練。	同意
	若所蒐集之歷史數據足夠，以此建立 AI 預測相關交通量模式 (Model) 提供號誌控制強化學習模式，是否達到效果，建議可進一步研究或說明。	謝謝委員的寶貴建議，本研究執行時程不長，無法進行此探討，建議納入後續年度計畫執行參考。	同意
新 北 市 政 府 交 通 局	新北市於今年利用 AI 應用部分，進行路口流量與停等長度做即時偵測與動態調整號誌時制，對於沒有 AI 影像偵測部分是利用 e-Tag 推算來進行動態 TOD 號誌控制，請補充說明本研究是否有利利用所安裝 eTag 讀取器所獲得旅行時間做為動態號誌控制之參數之一？	謝謝委員的寶貴建議，e-Tag 僅做為績效分析之資料來源，並未做為 AI 號誌控制訓練與控制之資料。	同意
	請補充說明本所究使用臨時性設備進行事前交通量調查時之偵測車流，此設備是否須要再先前經過訓練，才能使用？	謝謝委員的寶貴建議，本研究此次使用臨時性偵測設備偵測其偵測模式已於過往計畫訓練完成，本次使用並無再經過訓練即正常使用，惟此次採用一部設備偵測路口四方向轉向偵測，造成有諸多車輛遮蔽問題使偵測率不佳，已將相關未來偵測建議補充說明於 3.2.2 節與 3.3.2 節。	同意
	請補充釐清轉向量儀表板顯示內容資料為即時資料，或為歷史資料？若為歷史資料，建議改採即時資料顯示方式。	謝謝委員的寶貴建議，本研究所規劃之轉向量儀表板僅做統計資料，供後續分析使用，針對即時資料部分，可直接進入 AI 偵測設備之監控畫面，即可即時掌握。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
桃園市政府交通	P.76 提到時制週期由 120 秒調整為 150 秒，看起來先進行以幹道續進為目標的時制重整，因此本案目前績效是否有包含時制重整所產生績效？如此一來，AI 號誌控制的績效是否會被忽視？	謝謝委員的寶貴建議，本研究並未先進行時制重整號再進行 AI 號誌控制。	同意
通局	績效第二點，旅行時間是從匝道下，一路到樂業與長福路口，但其實中間只有進行兩個路口的號誌控制，中間會經過許多其它路口，績效可能會受到中間路口的影響，未來評估效益是否可以建議使用實作路口上下游，才能最準確地進行分析。	謝謝委員的寶貴建議，績效會以上游下匝道處做為起點，主要因為改善前往市區方向車隊長度往往會有一定機率由十甲東路回堵至環中路，甚至導致環中路口無法淨空，因此納入該下匝道路口群組範圍；若僅考量上下游路口，會導致往市區方向車流，會有部分車隊未被計算到，如事前回堵車流由喬城三至環中路段上的車流。	同意
	P.87 本案 AI 號誌控制演算法，以車間距 5 秒做為時制計畫組合產生，惟本研究範圍路口均為簡單二時相，未來若是多時相，將如何進行 5 秒分配？請再補充說明。	謝謝委員的寶貴建議，若為多時相路口，則以數個關鍵路徑經過各路口所使用之時相或分相做為調整對象；以 5 秒做為調整基礎，主要確保能增加 2 輛車以上通過該路口，故針對競爭時相/分相於同週期下，兩者間以 5 秒為間距進行增減。	同意
	P.89 本研究採用外圍 6 個流入交通量做為輸入值，但中間兩個控制路口 A 與 B 的車流型態並未探討，路口 A 與 B 路口的時制計畫與紓解率間應互為因果關係，P.90 似將此兩個路口當作一個路口在處理，請再加以釐清與補充說明？	謝謝委員的寶貴建議，以本研究範圍，車流僅會由外圍進入到本系統，兩路口間的車流是由外圍進入所產生的，因此僅以外圍六個方向進入之車流做為控制考量。兩路口取同一個時制計畫之目的，是為了彼此間的綠寬帶保持一致，而不會使其中一個路口產生瓶頸，且兩路口距離較近，因此可視為一虛擬路口。	同意
	本研究僅使用 AI 車輛偵測器的時間與流量資料做為 AI 號誌控制模式的輸入項有點可惜，建議未來模擬過程可增加更多交通參數。	感謝提供寶貴的建議，本研究原本想採用停等長度或延滯做為控制使用，然受限於建置點位因施工不易，因此於折衷考量下，採用上游流量做為控制參數。若未來可克服施工、時程等問題，應可嘗試使用多元交通參數做為號誌控制使用。	同意
臺中市	整體而言，本次研究具有改善效益，實測初期因本研究調整樂業路主幹道號誌週期，導致與周邊路口產生號誌周期不一致情形，致使接獲民眾反映，後來經處理後獲得改善。	感謝臺中市政府交通局之協助與指導，以使本研究可順利進行。有關跨群組問題藉由 AI 號誌進行調和，建議納入後續年度計畫執行參考。	同意
政府交通	本局	謝	同

審查委員	審查意見	審查意見回覆	主辦單位意見
	流不多情形下，號誌控制可調整的幅度相對有限，因此在假日的運作績效較不顯著。	AI 號誌控制於車流順暢之時段運作時，其控制策略通常亦為基礎時制，或是與基礎時制相近，故其績效較不明顯，即便有些時段 AI 號誌控制績效較差，但觀察旅行時間差異，亦十分微小，AI 號誌控制於近飽和狀況下則有明顯差異。	
	建議本研究後續將號誌控制連鎖群組劃分、AI 號誌控制的訓練過程與維運成本的各縣市政府實務考量，以及單一代理人與多代理人訓練成果差異及適用範疇(如適用之路口數)的評估等，納為探討課題。	謝謝委員的寶貴建議，相關內容已補充於 4.5 節。	同意
	目前實驗設備均安裝於路側，有些設備並非臺中市交控維護案會使用到的，未來接管會需要執行團隊提供維護方案與流程，以及相關操作說明，以利進行相關維護管理作業。	遵照辦理，後續將與貴局及相關維運團隊進行溝通討論。	同意
高雄市	請補充說明本研究利用 AI 影像辨識偵測車流，並透過 PaSo 及 SUMO 軟體做現場號誌即時控制的作法，能否複製到其它縣市？	謝謝委員的寶貴建議，AI 號誌控制架構可複製於其他縣市，但由於各地交通狀況不同，仍須重新訓練，方能於上線時有較好的績效。	同意
府交通局	本案採用深度 Q 學習進行 AI 號誌控制，此種方法與傳統透過 Model 進行適應性號誌控制，兩者在實際使用上績效差異為何？是否有使用情境上的差異。	謝謝委員的寶貴建議，適應性號誌控制邏輯十分複雜與多樣，目前於研究期間並無針對相同樣本與 AI 進行績效比較，情境上本研究評估需要更嚴謹認證，故尚無法提供使用上的情境差異。	同意
運輸資訊組	第一章部分，請於 1.4 節補充執行流程圖。	謝謝委員的寶貴建議，已補充於圖 1.4.1。	同意
	第二章部分，		
	請補充說明 2.1 節人工智慧歷史與應用內容，以及相關演算法敘述之文獻來源。	謝謝委員的寶貴建議，已進行補充。	同意
	P.10 未見文中「常見的優化策略的運作機制可彙整如後」之彙整內容，請加以補充；同時與 Q-learning 目標後續說明缺乏連貫性，請再加強說明。	謝謝委員的寶貴建議，已進行修正。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	請補充說明所列公式或函式之各變數說明，對於部分演算法名稱縮寫，請補充全名。	遵照辦理，請參閱第 2 章。	同意
	請再補充 Reinforcement Learning for Traffic Signal Control (traffic-signal-control.github.io)網站的強化式學習在號誌控制文獻回顧。	謝謝委員的寶貴建議，已補充網站內重點簡報與文獻回顧，請參閱第 19 頁。	同意
	請再強化 P.14 2.1 節最後一段有關 Huo 的研究內容說明。	謝謝委員的寶貴建議，已補充，請參閱第 15 頁。	同意
	請補充桃園市政府與資策會在 AI 號誌控制研究內容，並加以簡要評析。	謝謝委員的寶貴建議，已補充，請參閱第 19 頁。	同意
第三章部分，			
	請具體補充說明利用臨時性車流偵測設備進行交通量調查時與人工作業之各面向(例如：設備架設與校估時間)量化比較。	謝謝委員的寶貴建議，已進行補充，請參閱表 3.2-3。	同意
	P.35 與 P.37 間之文章說明中斷，請再加以補充。	謝謝委員的寶貴建議，已進行修正。	同意
根據 3.2 節與 3.3 節說明，本研究同步探討不同 Nvidia 運算晶片在各種車流參數偵測之性能，同時藉由偵測線繪製邏輯之精進來提高車流參數偵測之準確率，請補充說明下列各點：			
	此 Nvidia 運算晶片與偵測線繪製邏輯之探討與分析，是否可擴充或沿用至其它影像分析演算法或僅適用於本案所採用設備？	謝謝委員的寶貴建議，Nvidia 運算晶片分析部份可延伸到其它運算需求較大的演算法，當運算量提高時，TX2 和 Nano 之間的差異會更明顯；偵測線繪製的部份則僅適用於本演算法功能。	同意
	3.2 節說明除因遮蔽因素無法偵測外之汽機車偵測準確度可達 93% 以上，惟 3.3 節下列各項車流參數則改用 MAPE，且有不同準確度表現，請再進一步說明採用不同指標緣由，以及改採用各單位交控系統車輛偵測器準確度計算方式，以探討在不同交通管理或控制應用之可行性。	謝謝委員的寶貴建議，已調整為各單位交控系統車輛偵測器準確度計算方式。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	3.4 節建議後續擴充 AI 影像辨識技術於車牌辨識部分，現行車牌辨識技術已相當成熟，同時本研究所採用影像偵測技術亦可處理轉向交通量，因此請再進一步釐清 3.4 節第 2 段各車流參數未來應用之論述。	遵照辦理，請參照 3.4 節。	同意
	3.5 節 AI 應用於交通管理資訊議題探討部分，		
	請再從本案 AI 車流偵測與號誌控制採現場處理之邊緣運算架構，來探討端點遭入侵之資訊安全議題。	謝謝委員的寶貴建議，已補充，目前相關資訊安全監控，透過大數據方式已可逐步掌握異常入侵，當設備遭入侵時，可輔以斷開該設備與其他設備之連線，避免後續危害。	同意
	請參考本所 98 年「標準化都市交通管理之通訊協定研發(一)」研究案之「第四章 都市交控資通訊安全管理研究」，來探討本議題。	謝謝委員的寶貴建議，已參考相關內容並結合近年來 AI 應用於資安技術進行補充。	同意
	第四章部分，		
	請再確認 P.95 所提強化學習演算法 DQfB 於號誌控制模型建立中，本研究所研提創新之處為強化學習演算法 DQfB，抑是將之應用於號誌控制模型。	謝謝委員的寶貴建議，兩者均是。	同意
	請補充說明 AI 號誌控制模式之詳細輸出入參數，以及類神經網路本身之參數。	本研究之類神經網路輸入為 6 個方向交通流量，輸出為時制計畫代號。類神經網路之學習率為 10^{-4} 、批尺寸為 50、緩衝區大小為 500、寬度為 200、更新率為 10。	同意
	P.97 表示「實驗結果發現，在較複雜之動作環境下，提高神經原數量可有效提高動作正確率」，請再進一步說明本案實驗內容與實際數據結果。	遵照辦理，請參閱 4.1.3 節第 4 部份。	同意
	請再強化 P.98 有關第二階段「多時段時制計畫演示法深度 Q 學習」，以及圖 4.1.19 中的時段辨析前處理器。	遵照辦理，請參閱 4.1.3 節第 2 部份。	同意
	請再詳細說明圖 4.1.25 整體訓練流程與圖 4.1.26 特別抽樣訓練流程詳細流程，以及兩者間之關聯。	遵照辦理，請參閱 4.1.3 節第 3 部份。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	請再進一步補充說明 4.2 節 AI 號誌控制之模擬分析過程，例如：在人工調查每分鐘路口實際流量輸入 SUMO 下，進行與「真實情況」的比對與微調相關參數，此處之「真實情況」所指為何？4.1 節訓練後之強化學習號誌控制模式如何與 SUMO 結合進行模擬？例如：SUMO 如何接收強化學習號誌控制模式所輸出之號誌時制計畫內容或編號。	本研究首先於實驗場域搜集各時段各方向之實際交通流量，而後將此實際流量輸入 SUMO 進行模擬，此處之真實情況即指實際交通流量。在將實際交通流量設定進 SUMO 後，啟動代理人與 SUMO 模擬，代理人會透過 TraCI，定期由 SUMO 中取得六方向流量，運算過後輸出時制計畫代號，透過 TraCI 設定兩路口之時制。	同意
	請補充說明 P.117 倒數第 2 行將再「進行持續訓練，降低差異率」之訓練情形與最終差異率。	謝謝委員的寶貴建議，請參閱表 4.3-1 及圖 4.3.5 至圖 4.4.7	同意
	本研究 AI 號誌控制基本上採用學習與逼近專家(PaSo 軟體最佳時制計畫)決策，因此從號誌控制角度觀之，4.4 節事後運作績效應可視為 PaSo 所產生最佳時制計畫成果，而非 AI 號誌控制直接績效；4.5 節探討 AI 號誌控制未來發展，請補充說明若以本案實作範圍為案例，欲超越專家(PaSo 軟體最佳時制計畫)或不受限於專家的未來可能作法。	謝謝委員的寶貴建議，本研究在逼近專家決策後，即可進入第二階段，增加其他交通績效，以使 AI 可利用績效超過專家。	同意
	第五章部分，		
	請就所提「AI 應用適合度」與「交通需求迫切度」兩個面向，來審視表 5.4-2 之「五年期工作事項規劃」內容。	謝謝委員的寶貴建議，已補充，請參閱 5.4 節。	同意
	對於表 5.4-2「五年期工作事項規劃」，請針對各工作事項摘要說明現況作法，以及預期導入 AI 後之可能效益。	謝謝委員的寶貴建議，已補充於 5.3 節各工作項目的文字敘述中。	同意
	第六章結論與建議，在第二章文獻回顧補充 Reinforcement Learning for Traffic Signal Control (traffic-signal-control.github.io) 網站內容後之本案研究方式與其差異分析。	謝謝委員的寶貴建議，網站內容為各種不同 AI 形式，包含單一及多代理人；多代理人採取分散式，單一代理人採取時相切換為主，與本研究之單一代理人集中週期式不同。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	請再全面審視附件一「期中報告審查意見處理情形表」中所回覆內容，可具體對應本期末報告初稿之章節或圖表或頁數，對於非屬計畫範圍之意見，亦應具體說明。	遵照辦理。	同意
	有關報告初稿中錯別字、格式錯誤、圖表清晰度不夠與資料來源未敘明部分，請於會後洽本所。	遵照辦理。	同意
主席	請逢甲大學依各委員與單位出席代表審查意見，研提處理情形答覆意見送本所審查後，做為修正報告之依據，並請於 109 年 12 月 23 日前完成修正定稿之提送。	遵照辦理。	
	本次期末審查原則通過。	遵照辦理。	