114-048-5533
IOT-113-IC002

我國人工智慧車聯網之號誌控制(2/2)-匝道儀控與平面道路號誌協控實作

交通部運輸研究所

中華民國 114 年 7 月

114-048-5533
IOT-113-IC002

我國人工智慧車聯網之號誌控制(2/2)-匝道儀控與平面道路號誌協控實作

著者：蕭偉政、許添本、謝秉均、董尚義、陳煒騰、黃業傑、
林小淳、郭哲維、黃祖瑜、張益城、吳東凌、周家慶

交通部運輸研究所

中華民國 114 年 7 月

國家圖書館出版品預行編目(CIP)資料

我國人工智慧車聯網之號誌控制. (2/2) : 匝道儀控與平面道路號誌協控實作/蕭偉政, 許添本, 謝秉均, 董尚義, 陳煒騰, 黃業傑, 林小淳, 郭哲維, 黃祖瑜, 張益城, 吳東凌, 周家慶著. -- 初版. -- 臺北市 : 交通部運輸研究所, 民 114.07
面 ; 公分
ISBN 978-986-531-688-4(平裝)

1.CST: 人工智慧 2.CST: 交通號誌 3.CST: 標示系統 4.CST: 交通管理

557.822 114009338

我國人工智慧車聯網之號誌控制(2/2)-
匝道儀控與平面道路號誌協控實作

著　　者：蕭偉政、許添本、謝秉均、董尚義、陳煒騰、黃業傑、林小淳、郭哲維、黃祖瑜、張益城、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 114 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：340 元
展 售 處：
交通部運輸研究所運輸科技及資訊組・電話：(02)2349-6789
五南文化廣場：400002 臺中市中區中山路 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：1011400693　　ISBN：978-986-531-688-4（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

<table>
<tr><td colspan="4">出版品名稱：我國人工智慧車聯網之號誌控制(2/2)-匝道儀控與平面道路號誌協控實作</td></tr>
<tr><td>國際標準書號（或叢刊號）
ISBN 978-986-531-688-4 (平裝)</td><td>政府出版品統一編號
1011400693</td><td>運輸研究所出版品編號
114-048-5533</td><td>計畫編號
113-IC002</td></tr>
<tr><td>本所主辦單位：運輸科技及資訊組
主管：張益城
計畫主持人：吳東凌(前主管)
研究人員：周家慶
聯絡電話：(02)23496756
傳真號碼：(02)25450426</td><td colspan="2">合作研究單位：資拓宏宇國際股份有限公司
計畫主持人：蕭偉政
研究人員：謝秉均、董尚義、許添本、陳煒騰、黃業傑、林小淳、郭哲維、黃祖瑜
地址：22041 新北市板橋區縣民大道 2 段 7 號 6 樓
聯絡電話：(02) 8969-1969</td><td>研究期間
自 113 年 4 月
至 113 年 12 月</td></tr>
<tr><td colspan="4">關鍵詞：AI 號誌控制模式；AI 號誌協控模式；多目標強化學習；集中訓練分散執行機制</td></tr>
<tr><td colspan="4">摘要：
本計畫延續 112 年「我國人工智慧車聯網之號誌控制(1/2)-都會區幹道實作與交流道區域模式發展探討」之研究計畫，發展符合我國主要交通環境下之人工智慧號誌控制模型，藉由與實務單位結合進行不同場域(包含都會區幹道號誌控制與交流道區域號誌協控)之實測，來探討號誌控制與管理需求、以及人工智慧號誌控制維護機制與場域需求，以提升車流運作效率及交通安全，特別有助於紓緩因交通號誌控制不夠智慧，導致民眾行的痛點。

本計畫持續盤點人工智慧強化學習在號誌控制相關應用，在「都會區幹道強化學習號誌控制」部分，透過導入多任務強化學習演算法，以及通用環境之探討與建置，規劃以實測探討各時段與車流情境之泛用性，期望能提升人工智慧號誌控制模式之運作效率。在「交流道區域強化學習號誌協控」部分，以集中訓練/分散執行(CTDE)機制訓練多代理人，同時協調控制平面道路號誌與匝道儀控率，完成高速公路交流道匝道儀控與平面道路路口號誌協控之人工智慧強化學習號誌控制模型的發展與實作，及其運作量化效益分析，實測績效顯示：(1)臺北市中「中山北路與德行西路周邊 3 個路口」平日離峰與假日昏峰時段的路口平均停等延滯相較現況定時號誌控制平均改善 15%；(2)臺南市「台 86 與台 19 甲路口」的整體路口延滯多優於現況動態時段號誌控制約 2.5%；(3)中壢交流道周邊道路 8 個路口的整體路口停等延滯平均降低 15%，均優於現況定時號誌控制。</td></tr>
</table>

出版日期	頁數	定價	本出版品取得方式
114 年 7 月	284	340	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價購。

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: Study of Artificial Intelligence Traffic Signal Control (2/2) -Implementation of Integrated Ramp Metering and Surface Road Signal Coordination

ISBN (OR ISSN)	GOVERNMENT PUBLICATIONS NUMBER	IOT SERIAL NUMBER	PROJECT NUMBER
ISBN 978-986-531-688-4 (pbk.)	1011400693	114-048-5533	113-IC002

DIVISION: Transportation Technology and Information Systems Division
DIVISION DIRECTOR: Yi-Cheng Chang
PRINCIPAL INVESTIGATOR: Tung-Ling Wu (Former Division Director)
PROJECT STAFF: Ja-Ching Chou
PHONE:886-2-23496756
FAX:886-2-25450426

PROJECT PERIOD

FROM April 2024
TO December 2024

RESEARCH AGENCY: International Integrated Systems, Inc.
PRINCIPAL INVESTIGATOR: Wei-Cheng Hsiao
PROJECT STAFF: Ping-Chun Hsieh, Shang-Yee Tung, Tien-Pen Hsu, Wei-Teng Chen, Yeh-Chieh Huang, Hsiao Chun Lin, Che-Wei Kuo, Tsu-Yu Huang
ADDRESS: 6F., No. 7, Sec. 2, Xianmin Blvd., Banqiao Dist., New Taipei City 22041, Taiwan (R.O.C.)
PHONE: (02) 8969-1969

KEY WORDS:
AI-Based Traffic Signal Control Model, AI-Based Coordinated Traffic Signal Control Model, Multi-Objective Reinforcement Learning (MORL), Centralized Training and Decentralized Execution (CTDE) Mechanism

ABSTRACT:

This project is a continuation of the previous project, “Study of Artificial Intelligence Traffic Signal Control (1/2) - Urban Main Roads and Highway Interchange Areas Implementation” aiming to develop AI traffic signal control models tailored to Taiwan’s primary traffic environment. By collaborating with practical units and conducting field tests in different scenarios—including urban arterial signal control and interchange area signal coordination—the project seeks to explore signal control and management requirements, AI-based signal control and maintenance mechanisms, and site-specific demands. Ultimately, this effort aims to improve traffic flow efficiency and road safety, addressing public concerns caused by insufficiently intelligent traffic signal control.

This project continues to survey the applications of artificial intelligence (AI) reinforcement learning (RL) in traffic signal control. In the area of “Reinforcement Learning-Based Signal Control for Urban Arterials,” the project incorporates multi-task reinforcement learning algorithms and explores the development of a generalized environment. Field experiments have been carried out to evaluate the generalizability of the approach across various time periods and traffic flow scenarios, with the goal of enhancing the operational efficiency of AI-based signal control models.

In the area of “Reinforcement Learning-Based Coordinated Signal Control for Interchange Areas,” a centralized training/distributed execution (CTDE) mechanism is used to coordinate multiple agents. These agents are designed to simultaneously coordinate the control of surface street signals and ramp metering rates, leading to the development and implementation of an AI reinforcement learning signal control model that coordinates freeway interchange ramp metering and surface intersection signal control. Quantitative performance analyses were also conducted, with field test results showing: (1) in Taipei City, at three intersections around Zhongshan North Road and Dexing West Road, the average delay due to stopping at signals during weekday off-peak and weekend evening peak periods was reduced by approximately 15% compared to current fixed-time signal control; (2) in Tainan City, at the intersection of Provincial Highway 86 and Provincial Highway 19A, overall intersection delays improved by about 2.5% compared to existing dynamic time-of-day signal control; (3) in the Zhongli Interchange area, across eight intersections, the average stop-and-wait delay at intersections was reduced by 15%, outperforming current fixed-time signal control.

DATE OF PUBLICATION	NUMBER OF PAGES	PRICE
July 2025	284	340

The views expressed in this publication are not necessarily those of the Ministry of Transportation and Communications.

目錄

第一章　計畫概述 1

1.1 計畫背景與目的 1
1.2 計畫工作流程 1
1.3 研究內容與工作項目 3

第二章　文獻回顧與關鍵課題 5

2.1 國內外號誌控制策略探討 5
2.1.1 平面道路號誌控制 5
2.1.2 平面道路與交流道匝道號誌協控 10
2.2 強化學習於號誌控制之應用 16
2.2.1 強化學習於平面道路號誌控制 17
2.2.2 強化學習於平面道路號誌與交流道匝道協控 20
2.2.3 國內近期動態號誌控制研究計畫成果 27
2.3 人工智慧強化學習(Reinforcement learning, RL)模式 32
2.3.1 強化學習架構與演算法 32
2.3.2 多模態強化學習演算法 48
2.3.3 多代理人集中訓練分散執行架構 52
2.3.4 強化學習演算法應用比較分析 54
2.3.5 總結 56
2.4 人工智慧強化學習在號誌控制應用之關鍵課題 57

第三章　強化學習號誌控制模型實測成果 59

3.1 實驗場域特性分析與模擬環境建置 59
3.1.1 單一路口場域(臺南市「台 86 線-台 19 甲線」路口) 59
3.1.2 多路口幹道場域(臺北市「中山北路-德行東路」) 61
3.2 都會區人工智慧號誌控制模型優化與精進 64
3.2.1 臺北市實驗場域模擬模式校估與驗證 64
3.2.2 都會區 AI 號誌控制模型精進 71
3.2.3 訓練環境程式與軟硬體說明 78
3.2.4 訓練結果 78
3.2.5 模擬績效分析 82
3.3 實測績效分析 96
3.3.1 實驗場域偵測設備 96
3.3.2 動態模擬測試 99
3.3.3 號誌控制核心運作模組與監控介面 111
3.3.4 實測計畫與歷程 116
3.3.5 事前事後量化績效評估 121

3.3.6 小結 133
第四章　強化學習號誌協控模型設計、訓練與實測成果 135
4.1 號誌協控實驗場域特性分析與模擬環境建置 135
4.1.1 實驗場域特性分析 135
4.1.2 實驗場域模擬環境建置 138
4.2 號誌協控模型訓練 142
4.2.1 協控實驗場域模擬環境構建 142
4.2.2 AI 號誌協控模型架構說明 155
4.2.3 訓練環境程式與軟硬體說明 159
4.2.4 訓練結果 159
4.2.5 模擬績效分析 161
4.3 實測績效分析 167
4.3.1 實驗場域偵測設備 167
4.3.2 動態模擬測試 169
4.3.3 號誌控制核心運作模組與監控介面 179
4.3.4 實測計畫與歷程 182
4.3.5 事前事後量化績效評估 185
4.3.6 小結 194
第五章　結論與建議 195
5.1 結論 195
5.2 建議 197
參考文獻 199
附錄一 期中審查意見回覆表 205
附錄二 期末審查意見回覆表 219
附錄三 臺北市實驗場域路口轉向交通量 247

圖目錄

圖 1.2-1 計畫執行流程 2
圖 2.1.1-1 設置逆向左轉車道路口以及路口時相示意圖 6
圖 2.1.1-2 單方向設置逆向左轉車道路口圖以及路口時相示意圖 7
圖 2.1.1-3 半觸動號誌邏輯 7
圖 2.1.1-4 適應性號誌控制於多路口車流推進之分段示意圖 10
圖 2.1.2-1 匝道儀控與速率控制協控系統 11
圖 2.1.2-2 主線速率控制系統設施設置說明圖 11
圖 2.1.2-3 高速公路速率控制與匝道儀控最佳化協控之控制邏輯架構圖 12
圖 2.1.2-4 高速公路速率控制與匝道儀控最佳化協控模擬之求解流程圖 13
圖 2.1.2-5 ALINEA 邏輯架構圖 14
圖 2.1.2-6 上匝道與都市間號誌協控模式流程圖 15
圖 2.1.2-7 下匝道與都市間協作模式流程圖 16
圖 2.2.2.1-1 ACTM 或浴缸模型之 Agent 示意圖 21
圖 2.2.2.1-2 非對稱細胞傳遞模型示意圖(ATCM) 21
圖 2.2.2.1-3 浴缸模型示意圖(bathtub) 21
圖 2.2.2.1-4 TTS result 22
圖 2.2.2.1-5 SD(TWT) result 22
圖 2.2.2.1-6 高速公路主線與匝道協控策略模型示意圖 23
圖 2.2.2.1-7 狀態輸入示意圖 23
圖 2.2.2.1-8 主線儀控率 24
圖 2.2.2.1-9 匝道儀控率 24
圖 2.2.2.1-10 主線速率流量關係圖 24
圖 2.2.2.1-11 高速公路匝道與交通瓶頸之訓練模型架構圖 25
圖 2.2.2.1-12 主線儀控率 26
圖 2.2.2.1-13 匝道儀控率 26
圖 2.2.2.1-14 匝道與高速公路之號誌控制訓練模型 26
圖 2.2.2.1-15 不同控制方法針對匝道回堵次數與持續時間之統計圖 27
圖 2.2.2.1-16 不同控制方法針對停等時間之統計圖 27
圖 2.3.1-1 強化學習概念示意圖 32
圖 2.3.1-2 號誌控制架構基本模型 33
圖 2.3.1-3 DDPG 運作架構 37
圖 2.3.1-4 DDPG 演算法 37
圖 2.3.1-5 RL 代理人類型 39
圖 2.3.1-6 PPO 的目標式L^{Clip}與$r(\theta)$的關係圖 40
圖 2.3.1-7 PPO 運作架構圖 40
圖 2.3.1-8 PPO 演算法 41
圖 2.3.1-9 SAC 演算法 42
圖 2.3.1-10 兩目標馬可夫決策過程之 Pareto front 與 CCS 示意圖 43

圖 2.3.1-11 PGMORL 之搜索概念示意圖 44
圖 2.3.1-12 Conditioned Network 架構示意圖 45
圖 2.3.1-13 Q-Pensieve 運作架構圖 47
圖 2.3.1-14 Q-Pensieve 演算法 47
圖 2.3.2-1 單模態任務目標參數示意圖 48
圖 2.3.2-2 多模態任務目標參數示意圖 48
圖 2.3.2-3 MMAML 架構示意圖 49
圖 2.3.2-4 Task Network 訓練虛擬碼 50
圖 2.3.2-5 多任務強化學習訓練架構 51
圖 2.3.2-6 推理網絡架構 51
圖 2.3.2-7 Pearl 離線策略運作架構圖 52
圖 2.3.2-8 Pearl 訓練架構圖 52
圖 2.3.3-1 CTDE 多智能體強化學習架構圖 54
圖 2.3.3-2 MADDPG 之 CTDE 架構示意圖 54
圖 2.3.4-1 強化學習演算法之歸納與衍生 55
圖 3.1.1-1 臺南市「台 86 線-台 19 甲線」路口位置示意圖 59
圖 3.1.2-1 臺北市「中山北路-德行東路」幹道位置示意圖 62
圖 3.2.2-1 臺南市晨峰時段之模型訓練架構圖 74
圖 3.2.2-2 臺南市實驗場域離峰/昏峰/假日昏峰模型訓練架構圖 75
圖 3.2.2-3 臺北市實驗場域模型訓練架構圖 77
圖 3.2.4-1 臺南市實驗場域晨峰時段 Q-Pensieve 收斂 79
圖 3.2.4-2 臺南市實驗場域(離峰、昏峰、假日昏峰)時段之 Pearl 演算法收斂圖 79
圖 3.2.4-3 臺北市實驗場域晨峰時段收斂圖 79
圖 3.2.4-4 臺北市實驗場域離峰時段收斂圖 80
圖 3.2.4-5 臺北市實驗場域昏峰時段收斂圖 80
圖 3.2.4-6 臺北市實驗場域假日昏峰時段收斂圖 80
圖 3.2.5.2-1 本期 AI 號誌控制模型平日晨峰模擬各分相秒數合理性分析圖 84
圖 3.2.5.2-2 本期 AI 號誌控制模型平日晨峰模擬各分相秒數穩定性分析圖 85
圖 3.2.5.2-3 本期 AI 平日離峰模型模擬各分相秒數合理性分析圖 86
圖 3.2.5.2-4 本期 AI 號誌控制模型平日離峰模擬各分相秒數穩定性分析圖 86
圖 3.2.5.2-5 本期 AI 平日昏峰模型模擬各分相秒數合理性分析圖 87
圖 3.2.5.2-6 本期 AI 號誌控制模型平日昏峰模擬各分相秒數穩定性分析圖 88
圖 3.2.5.2-7 本期 AI 號誌控制模型假日昏峰模擬各分相秒數合理性分析圖 89
圖 3.2.5.2-8 本期 AI 號誌控制模型假日昏峰模擬各分相秒數穩定性分析圖 90
圖 3.2.5.3-1 平日晨峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖 91
圖 3.2.5.3-2 平日離峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖 93
圖 3.2.5.3-3 平日昏峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖 94
圖 3.2.5.3-4 平日昏峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖 96
圖 3.3.1-1 臺南市「台 86 線-台 19 甲線」偵測設備位置 97
圖 3.3.1-2 臺北市「中山北路-德行東路」偵測設備位置 98

圖 3.3.2.1-1 SUMO 路網編輯介面示意圖 100
圖 3.3.2.1-2 VISSIM 模擬路網示意圖 101
圖 3.3.2.2-1 平日晨峰動態模擬各分相秒數合理性及穩定性分析圖 103
圖 3.3.2.2-2 平日離峰動態模擬各分相秒數合理性及穩定性分析圖 104
圖 3.3.2.2-3 平日昏峰動態模擬各分相秒數合理性及穩定性分析圖 105
圖 3.3.2.2-4 假日昏峰動態模擬各分相秒數合理性及穩定性分析圖 106
圖 3.3.2.3-1 平日晨峰本期 AI 號誌控制模型各分相秒數合理性分析圖 107
圖 3.3.2.3-2 平日晨峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖 107
圖 3.3.2.3-3 平日離峰本期 AI 號誌控制模型各分相秒數合理性分析圖 108
圖 3.3.2.3-4 平日離峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖 108
圖 3.3.2.3-5 平日昏峰本期 AI 號誌控制模型各分相秒數合理性分析圖 109
圖 3.3.2.3-6 平日昏峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖 110
圖 3.3.2.3-7 假日昏峰本期 AI 號誌控制模型各分相秒數合理性分析圖 111
圖 3.3.2.3-8 假日昏峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖 111
圖 3.3.3-1 號誌控制核心運作模組架構 112
圖 3.3.3-2 AI 智慧號誌控制系統執行流程 112
圖 3.3.3-3 資料串接架構規劃 113
圖 3.3.3-4 實測監控畫面-GIS 監控圖台 114
圖 3.3.3-5 實測監控畫面-系統管理 114
圖 3.3.3-6 實測監控畫面-「智慧號誌控制運行時制計畫」查詢頁面 115
圖 3.3.3-7 實測監控畫面-「車流偵測資料」查詢頁面 115
圖 3.3.3-8 實測監控畫面-「系統運作異常紀錄」查詢頁面 115
圖 3.3.4-1 臺南市實驗場域觀測重點 118
圖 3.3.4-2 臺北市實驗場域觀測重點 118
圖 3.3.4.2-1 台 86 線晨峰東向車流現況 119
圖 3.3.4.2-2 台 86 線昏峰西向車流現況 120
圖 3.3.4.2-3 德行西路西向車流現況 121
圖 3.3.5.1-1 11/14(四)臺南市場域實測各分相綠燈秒數趨勢圖 122
圖 3.3.5.1-2 11/15(五)臺南市場域實測各分相綠燈秒數趨勢圖 122
圖 3.3.5.1-3 11/17(日)昏峰臺南市場域實測各分相綠燈秒數趨勢圖 122
圖 3.3.5.1-4 11/14(四)臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較 123
圖 3.3.5.1-5 11/15(五)臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較 123
圖 3.3.5.1-6 11/17(日)昏峰臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較 123
圖 3.3.5.1-7 平日 AI 號誌控制與 TOD 旅行時間績效示意圖 127
圖 3.3.5.1-8 假日 AI 號誌控制與 TOD 旅行時間績效示意圖 127
圖 3.3.5.2-1 11/20(三)中山北路/克強路實測各分相綠燈秒數趨勢圖 127
圖 3.3.5.2-2 11/21(四)中山北路/克強路實測各分相綠燈秒數趨勢圖 128
圖 3.3.5.2-3 11/20(三)中山北路/195 巷實測各分相綠燈秒數趨勢圖 128
圖 3.3.5.2-4 11/21(四)中山北路/195 巷實測各分相綠燈秒數趨勢圖 128
圖 3.3.5.2-5 11/20(三)中山北路/德行西路實測各分相綠燈秒數趨勢圖 128

圖 3.3.5.2-6 11/21(四)中山北路/德行西路實測各分相綠燈秒數趨勢圖 128
圖 3.3.5.2-7 11/23(六)假日 3 處路口實測各分相綠燈秒數趨勢圖 129
圖 3.3.5.2-8 11/20(三)臺北市場域 AI 實測與 TOD 各分相綠燈秒數比較 129
圖 3.3.5.2-9 11/21(四)臺北市場域 AI 實測與 TOD 各分相綠燈秒數比較 129
圖 3.3.5.2-10 11/23(六)昏峰臺北市場域 AI 實測與 TOD 各分相綠燈秒數比較 129
圖 3.3.5.2-11 平日 AI 號誌控制與 TOD 旅行時間績效示意圖 130
圖 3.3.5.2-12 假日 AI 號誌控制與 TOD 旅行時間績效示意圖 131
圖 3.3.5.2-13 平日晨峰 AI 號誌控制與 TOD 續進績效比較示意圖 131
圖 3.3.5.2-14 平日離峰 AI 號誌控制與 TOD 續進績效比較示意圖 132
圖 3.3.5.2-15 平日昏峰 AI 號誌控制與 TOD 續進績效比較示意圖 132
圖 4.1-1 高速公路匝道與平面道路中壢交流道實驗場域示意圖 136
圖 4.1.2.2-1 路口轉向交通量調查示意圖 139
圖 4.1.2.2-2 中壢交流道實驗場域 VD 設備點位圖 140
圖 4.1.2.2-3 中壢交流道實驗場域 eTag 設備點位圖 140
圖 4.1.2.2-4 中壢交流道平面道路車流偵測設備點位圖 141
圖 4.1.2.2-5 GVP 旅行時間蒐集路段示意圖-以中壢交流道範圍為例 142
圖 4.2.1.1-1 SUMO 路網編輯介面示意圖-以中壢交流道為例 142
圖 4.2.1.1-2 SUMO 圖像化時相動線設定及文字矩陣時相動線設定 143
圖 4.2.1.1-3 VISSIM 中號誌時制設定範例 143
圖 4.2.1.1-4 SUMO 交通需求設定範例 144
圖 4.2.1.1-5 VISSIM 交通需求設定範例 144
圖 4.2.2-1 號誌協控模式訓練架構圖 158
圖 4.2.4-1 中壢交流道晨峰時段 AI 號誌控制模型收斂圖 160
圖 4.2.4-2 中壢交流道離峰時段 AI 號誌控制模型收斂圖 160
圖 4.2.4-3 中壢交流道昏峰時段 AI 號誌控制模型收斂圖 160
圖 4.2.4-4 中壢交流道假日昏峰時段 AI 號誌控制模型收斂圖 160
圖 4.2.5-1 民族路/文化路 8 巷(X4)平日晨峰模擬分相秒數合理性圖 163
圖 4.2.5-2 民族路/北上匝道(X5)平日晨峰模擬分相秒數合理性圖 163
圖 4.2.5-3 民族路/南出匝道(X6)平日晨峰模擬分相秒數合理性圖 163
圖 4.2.5-4 民族路/文化路 8 巷(X4)平日離峰模擬分相秒數合理性圖 164
圖 4.2.5-5 民族路/北上匝道(X5)平日離峰模擬分相秒數合理性圖 164
圖 4.2.5-6 民族路/南出匝道(X6)平日離峰模擬分相秒數合理性圖 165
圖 4.2.5-7 民族路/文化路 8 巷(X4)平日昏峰模擬分相秒數合理性圖 165
圖 4.2.5-8 民族路/北上匝道(X5)平日昏峰模擬分相秒數合理性圖 166
圖 4.2.5-9 民族路/南出匝道(X6)平日昏峰模擬分相秒數合理性圖 166
圖 4.2.5-10 民族路/文化路 8 巷(X4)假日昏峰模擬分相秒數合理性圖 166
圖 4.2.5-11 民族路/北上匝道(X5)假日昏峰模擬分相秒數合理性圖 167
圖 4.2.5-12 民族路/南出匝道(X6)假日昏峰模擬分相秒數合理性圖 167
圖 4.3.1-1 中壢交流道平面道路車流偵測設備點位圖 168
圖 4.3.2-1 民族路/文化路 8 巷(X4)平日晨峰各分相秒數合理性秒數分析圖 170

圖 4.3.2-2　路口 X4 平日晨峰主線及支線時相總秒數穩定性圖.....170
圖 4.3.2-3　民族路/北上匝道(X5)平日晨峰各分相秒數合理性分析圖.....171
圖 4.3.2-4　路口 X5 平日晨峰主線及支線時相總秒數穩定性圖.....171
圖 4.3.2-5　民族路/南出匝道(X6)平日晨峰各分相秒數合理性分析圖.....171
圖 4.3.2-6　路口 X6 平日晨峰主線及支線時相總秒數穩定性圖.....172
圖 4.3.2-7　民族路/文化路 8 巷(X4)平日離峰各分相秒數合理性分析圖.....173
圖 4.3.2-8　路口 X4 平日離峰主線及支線時相總秒數穩定性圖.....173
圖 4.3.2-9　民族路/北上匝道(X5)平日離峰各分相秒數合理性分析圖.....173
圖 4.3.2-10 路口 X5 平日離峰主線及支線時相總秒數穩定性圖.....174
圖 4.3.2-11 民族路/南出匝道(X6)平日離峰各分相秒數合理性分析圖.....174
圖 4.3.2-12 路口 X6 平日離峰主線及支線時相總秒數穩定性圖.....174
圖 4.3.2-13 民族路/文化路 8 巷(X4)平日昏峰各分相秒數合理性分析圖.....175
圖 4.3.2-14 路口 X4 平日昏峰主線及支線時相總秒數穩定性圖.....175
圖 4.3.2-15 民族路/北上匝道(X5)平日昏峰各分相秒數合理性分析圖.....176
圖 4.3.2-16 路口 X5 平日昏峰主線及支線時相總秒數穩定性圖.....176
圖 4.3.2-17 民族路/南出匝道(X6)平日昏峰各分相秒數合理性分析圖.....176
圖 4.3.2-18 路口 X6 平日昏峰主線及支線時相總秒數穩定性圖.....177
圖 4.3.2-19 民族路/文化路 8 巷(X4)假日昏峰各分相秒數合理性分析圖.....178
圖 4.3.2-20 路口 X4 假日昏峰主線及支線時相總秒數穩定性圖.....178
圖 4.3.2-21 民族路/北上匝道(X5)假日昏峰各分相秒數合理性分析圖.....178
圖 4.3.2-22 路口 X5 假日昏峰主線及支線時相總秒數穩定性圖.....179
圖 4.3.2-23 民族路/南出匝道(X6)假日昏峰各分相秒數合理性分析圖.....179
圖 4.3.2-24 路口 X6 假日昏峰主線及支線時相總秒數穩定性圖.....179
圖 4.3.3-1　號誌控制核心運作模組架構.....180
圖 4.3.3-2　AI 智慧號誌控制系統執行流程.....180
圖 4.3.3-3　資料串接架構.....181
圖 4.3.3-4　交流道實驗場域實測監控畫面.....182
圖 4.3.4.2-1 民族路二段昏峰現場車流狀況.....184
圖 4.3.5-1 11/24(日)桃園市實驗場域 3 處路口實測各分相綠燈秒數趨勢圖.....185
圖 4.3.5-2 11/25(一)桃園市實驗場域民族路/文化街 8 巷實測各分相綠燈秒數趨勢圖..185
圖 4.3.5-3 11/25(一)桃園市實驗場域民族路/北上匝道實測各分相綠燈秒數趨勢圖.....185
圖 4.3.5-4 11/25(一)桃園市實驗場域民族路/南出匝道實測各分相綠燈秒數趨勢圖.....185
圖 4.3.5-5 11/26(二)桃園市實驗場域民族路/文化街 8 巷實測各分相綠燈秒數趨勢圖..186
圖 4.3.5-6 11/26(二)桃園市實驗場域民族路/北上匝道實測各分相綠燈秒數趨勢圖.....186
圖 4.3.5-7 11/26(二)桃園市實驗場域民族路/南出匝道實測各分相綠燈秒數趨勢圖.....186
圖 4.3.5-8 11/25(一)桃園市實驗場域 AI 實測與 TOD 各分相綠燈秒數比較.....186
圖 4.3.5-9 11/26(二)桃園市實驗場域 AI 實測與 TOD 各分相綠燈秒數比較.....186
圖 4.3.5-10 11/24(日)桃園市實驗場域 AI 實測與 TOD 各分相綠燈秒數比較.....187
圖 4.3.5-11 11/24(日)桃園市實驗場域事前事後高速公路主線車流變化.....189
圖 4.3.5-12 11/25(一)桃園市實驗場域往北事前事後高速公路主線車流變化.....190

圖 4.3.5-13　11/25(一)桃園市實驗場域往南事前事後高速公路主線車流變化.....191
圖 4.3.5-14　11/26(二)桃園市實驗場域往北事前事後高速公路主線車流變化.....192
圖 4.3.5-15　11/26(二)桃園市實驗場域往南事前事後高速公路主線車流變化.....192
圖 4.3.5-16　平日 AI 號誌控制與 TOD 旅行時間績效示意圖 193
圖 4.3.5-17　假日 AI 號誌控制與 TOD 旅行時間績效示意圖 193

表目錄

表 1.2-1　進度甘梯圖(Gantt Chart)....3
表 2.1.1-1 觸動號誌與固定時制績效比較表....6
表 2.1.1-2 情境績效比較表....8
表 2.1.1-3 控制策略及情境績效比較表....9
表 2.1.1-4 ACTS-T 控制策略及情境優劣比較表....10
表 2.1.2-1 高速公路速率控制與匝道儀控最佳化協控之模擬系統參數設定表....13
表 2.1.2-2 上匝道與都市協控模型之目標式....15
表 2.2.2.1-1 英國 M6 高速公路 TTS 與 SD(TWT)於各策略的結果....22
表 2.2.3-1 臺北市實驗場域 AI 強化學習模型設計....30
表 2.3.4-1 強化學習演算法之比較....56
表 3.1.1-1 臺南市「台 86 線-台 19 甲線」路口道路幾何特性....59
表 3.1.1-2 臺南市「台 86 線-台 19 甲線」前期及本期路口交通量比較....60
表 3.1.1-3 臺南市「台 86 線-台 19 甲線」路口平日週一~週四號誌時制計畫....60
表 3.1.1-4 臺南市「台 86 線-台 19 甲線」路口平日週五號誌時制計畫....61
表 3.1.1-5 臺南市「台 86 線-台 19 甲線」路口假日號誌時制計畫....61
表 3.1.2-1 德行西路、195 巷及克強路路口道路幾何特性彙整表....62
表 3.1.2-2 臺北市「中山北路-德行東路」場域前期及本期路口交通量比較....63
表 3.1.2-3 德行西路、195 巷及克強路路口號誌時制計畫....64
表 3.2.1-1 國內外模擬校估績效指標及範圍....65
表 3.2.1-2 國內外模擬校估績效指標及範圍....66
表 3.2.1-3 GEH 和誤差百分比的比較分析....66
表 3.2.1-4 臺北市實驗場域平日晨峰 SUMO 流量 GEH 及 MAPE....67
表 3.2.1-5 臺北市實驗場域平日離峰 SUMO 流量 GEH 及 MAPE....68
表 3.2.1-6 臺北市實驗場域平日昏峰 SUMO 流量 GEH 及 MAPE....69
表 3.2.1-7 臺北市實驗場域假日昏峰 SUMO 流量 GEH 及 MAPE....70
表 3.2.2-1 臺南市實驗場域 AI 號誌控制模型獎勵計算公式表....72
表 3.2.2-2 臺南市實驗場域 AI 強化學習模型設計....72
表 3.2.2-3 臺北市實驗場域 AI 號誌控制模型獎勵計算公式表....73
表 3.2.2-4 臺北市實驗場域 AI 強化學習模式規劃表....73
表 3.2.3-1 AI 號誌控制模型訓練使用之軟硬體規格....78
表 3.2.4-1 臺南市實驗場域晨峰時段超參數之說明....80
表 3.2.4-2 臺南市實驗場域其餘時段超參數之說明....81
表 3.2.4-3 臺北市實驗場域超參數之說明....81
表 3.2.5.2-1 平日晨峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表....84
表 3.2.5.2-2 平日離峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表....85
表 3.2.5.2-3 平日昏峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表

.....87
表 3.2.5.2-4 假日昏峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表
.....89
表 3.2.5.3-1 平日晨峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表.....91
表 3.2.5.3-2 平日離峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表.....92
表 3.2.5.3-3 平日昏峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表.....93
表 3.2.5.3-4 假日昏峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表.....95
表 3.3.1-1 路口車流轉向辨識平日晨峰(07:45~08:00)準確度驗證.....98
表 3.3.1-2 路口車流轉向辨識平日昏峰(17:45~18:00)準確度驗證.....98
表 3.3.1-3 臺北市場域偵測設備準確度驗證.....99
表 3.3.4.1-1 實測例外事件一覽表.....118
表 3.3.4.2-1 臺北市場域實測控制器異常紀錄.....121
表 3.3.5.1-1 平日 11/14(四) AI 號誌控制路口延滯績效.....124
表 3.3.5.1-2 平日 11/21(四)動態 TOD 號誌控制路口延滯績效.....124
表 3.3.5.1-3 平日 11/15(五) AI 號誌控制路口延滯績效.....124
表 3.3.5.1-4 平日 11/22(五)動態 TOD 號誌控制路口延滯績效.....125
表 3.3.5.1-5 假日 11/17(日)AI 號誌控制路口延滯績效.....125
表 3.3.5.1-6 假日 11/24(日)動態 TOD 號誌控制路口延滯績效.....125
表 3.3.5.1-7 與前期 AI 號誌控制模型實測平日績效比較.....126
表 3.3.5.1-8 與前期 AI 號誌控制模型實測假日績效比較.....126
表 3.3.5.2-1 平日及假日 AI 號誌控制&TOD 路口延滯績效表.....130
表 3.3.5.2-2 與前期 AI 號誌控制模型實測平日績效比較.....133
表 4.1-1 中壢交流道實驗場域的平面道路路口列表.....136
表 4.1-2 中壢交流道實驗場域 8 處平面道路路口號誌時制計畫.....136
表 4.1.2.2-1 中壢交流道車流偵測設備.....141
表 4.1.2.2-2 中壢交流道周邊平面道路 AI 辨識 CCTV 偵測設備清單.....141
表 4.2.1.2-1 國內外模擬校估績效指標及範圍.....147
表 4.2.1.2-2 中壢交流道區域高速公路主線校估結果(平日晨峰).....149
表 4.2.1.2-3 SUMO 中壢交流道區域平面道路校估結果(平日晨峰).....149
表 4.2.1.2-4 SUMO 中壢交流道區域平面道路校估結果(平日昏峰).....150
表 4.2.1.2-5 SUMO 中壢交流道區域平面道路校估結果(假日晨峰).....151
表 4.2.1.2-6 SUMO 中壢交流道區域平面道路校估結果(假日昏峰).....152
表 4.2.1.2-7 VISSIM 中壢交流道區域平面道路校估結果(平日晨峰).....153
表 4.2.1.2-8 部分模擬模式參數(以 SUMO 為例).....155
表 4.2.2-1 交流道實驗場域 AI 號誌控制模型獎勵計算公式表.....156
表 4.2.2-2 交流道實驗場域 AI 強化學習模式規劃表.....156
表 4.2.3-1 AI 號誌控制模型訓練使用之軟硬體規格.....159
表 4.2.4-1 中壢交流道實驗場域超參數之說明.....161
表 4.3.1-1 偵測設備準確度驗證.....169
表 4.3.4-1 實測例外事件一覽表.....183

表 4.3.5-1 假日 11/24(日)AI 號誌控制&11/17(日)TOD 路口延滯績效 187
表 4.3.5-2 平日 11/25(一)AI 號誌控制&11/18(一)TOD 路口延滯績效 188
表 4.3.5-3 平日 11/26(二)AI 號誌控制&11/19(二)TOD 路口延滯績效 189

第一章　計畫概述

1.1 計畫背景與目的

近年來全球各領域無不利用人工智慧進行應用發展，以帶來技術上的突破。交通領域亦引入人工智慧，可預期未來運用人工智慧、影像辨識、資通訊(ICT)、車聯網(V2X)與 5G 等技術，將有效提升交通號誌控制之智慧化，緩解交通壅塞之痛點，帶給民眾更加順暢之行車體驗。本所於 104 年至 108 年進行一系列智慧交通服務效能與安全的車聯網研究計畫，針對我國都市交通號誌控制與車聯網整合進行探討，使各式車輛接收即時號誌動態資訊，以提供安全、優先通行與節能之道路交通環境。交通部「淡海新市鎮智慧交通場域試驗研究計畫」以本所車聯網系列研究成果為基礎，進一步針對號誌控制與電信車聯網(C-V2X)整合的通訊協定需求，參酌 SAE 標準研擬「號誌控制器與車聯網路側設施間資通訊標準」。

本所於 109 年「應用人工智慧技術進行交通數據蒐集暨號誌控制之研究」計畫發展以仿真學習(Imitation Learning, IL)與以號誌「週期」為基礎之人工智慧強化學習(Reinforcement Learning, RL)號誌控制，國內亦有相關學術研究以及桃園市與高雄市的實作案例。同時本所於 110 年「構建 5G 智慧交通數位神經中樞(1/2)－功能架構探討與系統規劃」研究中，探討車聯網與路口號誌控制運作課題。

在 111 年度中，本所發展我國人工智慧車聯網之號誌控制模式探討」研究計畫，除回顧彙整國內外應用車聯網，以及人工智慧強化學習於號誌控制之應用與演算法外，並發展車聯網與人工智慧強化學習之號誌控制模擬環境，藉由車聯網緊急車輛優先號誌、單一路口多時相號誌控制，及幹道連鎖號誌控制模擬之人工智慧號誌控制模式構建、學習與訓練、模擬與績效評估，為後續人工智慧號誌控制奠下研發基礎。該計畫模擬實驗場域包含臺南市「台 86 線-台 19 甲線」單一路口、臺北市「中山北路-德行東路」3 個路口幹道與高雄市「台 88 鳳山出口」(過埤路-鳳頂路)單一路口。112 年依據 111 年所發展人工智慧號誌控制模式，與臺北市、臺南市政府交通局合作進行現場實驗測試，計畫執行過程中導入多目標強化學習，持續優化人工智慧號誌控制模型；同時納入高速公路匝道儀控之人工智慧號誌控制課題，探討協控相關模擬發展模型。

本(113)年度延續 112 年在交流道區域匝道儀控與平面道路號誌導入人工智慧強化學習探討成果，發展人工智慧強化學習之號誌協控模型，並與高速公路局及桃園市政府協作，在高速公路匝道儀控與平面道路動態號誌控制範圍，進行號誌協控訓練與實測。於都會區幹道實作上，亦將依據 112 年於臺北市、臺南市實測場域之現場實驗測試結果，進行人工智慧號誌控制模型精進之調整與訓練，訓練完畢之模型再次於現場進行實測，以期能對人工智慧號誌控制之發展和維護機制帶來貢獻。

1.2 計畫工作流程

計畫執行分為期中與期末階段，執行流程如圖 1.2-1 所示，計畫甘特圖如表 1.2-1 所示。

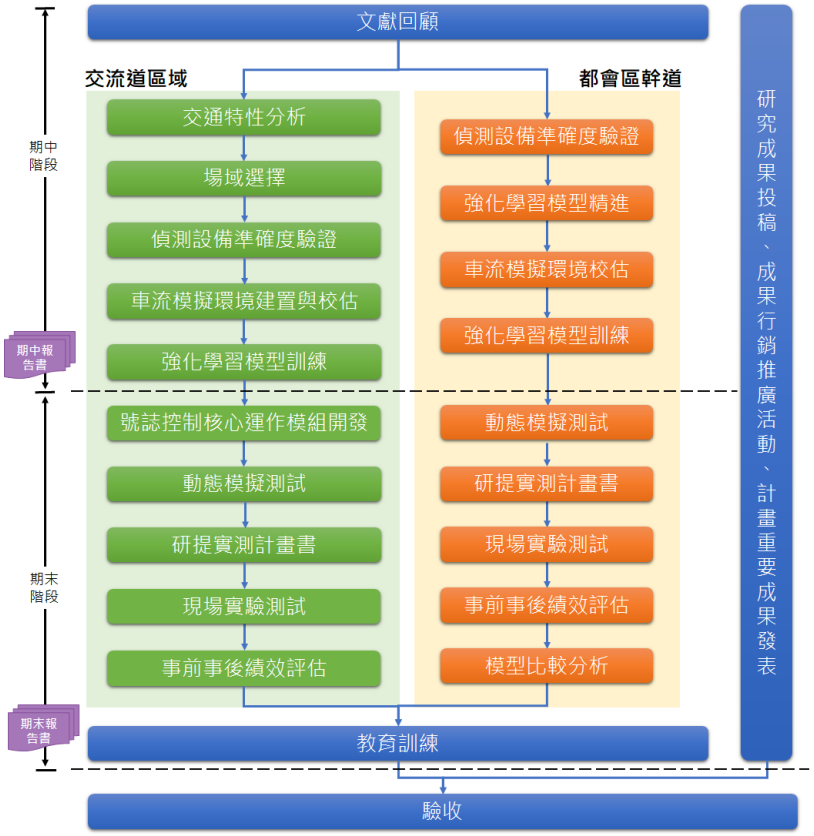

文獻回顧
交流道區域
都會區幹道
交通特性分析
場域選擇
偵測設備準確度驗證
車流模擬環境建置與校估
強化學習模型訓練
偵測設備準確度驗證
強化學習模型精進
車流模擬環境校估
強化學習模型訓練
期中階段
期中報告書
號誌控制核心運作模組開發
動態模擬測試
研提實測計畫書
現場實驗測試
事前事後績效評估
動態模擬測試
研提實測計畫書
現場實驗測試
事前事後績效評估
模型比較分析
期末階段
期末報告書
教育訓練
驗收
研究成果投稿、成果行銷推廣活動、計畫重要成果發表

圖 1.2-1 計畫執行流程

表 1.2-1 進度甘梯圖(Gantt Chart)

工作項目	第1月 (4月)	第2月 (5月)	第3月 (6月)	第4月 (7月)	第5月 (8月)	第6月 (9月)	第7月 (10月)	第8月 (11月)	第9月 (12月)	備　註
一、交流道區域號誌協控模式										
1. 文獻回顧	■									
2. 交通特性分析	■									
3. 場域選擇	■									
4. 偵測設備準確度驗證		■	■							
5. 車流模擬環境建置與校估			■	■						
6. 強化學習模型訓練				■	■					
7. 號誌控制核心運作模組開發					■	■				
8. 動態模擬測試						■	■			
9. 研提實測計畫書							■			
10. 現場實驗測試							■	■		
11. 事前事後績效評估							■	■		
二、都會區幹道號誌控制模型										
1. 文獻回顧	■									
2. 偵測設備準確度驗證		■	■							
3. 強化學習模型精進			■	■						
4. 車流模擬環境校估			■	■						
5. 強化學習模型訓練				■	■					
6. 動態模擬測試						■	■			
7. 研提實測計畫書							■			
8. 現場實驗測試							■	■		
9. 事前事後績效評估							■	■		
10. 模型比較分析								■		
三、其他相關工作										
(一)研究/計畫成果發表							■	■		
(二)成果展示說明會							■	■		
(三)教育訓練								■		
四、驗收									■	
工作進度估計百分比(累積數)	5	20	30	40	40	50	70	90	100	
預定查核點	第 1 季：113 年 8 月 12 日，期中階段：期中報告初稿提送									
	第 2 季：113 年 12 月 02 日，期末階段：期末報告初稿提送									

1.3 研究內容與工作項目

本計畫之各項工作項目如下：

一、人工智慧強化學習模式應用探討

持續盤點與彙整國內外應用車聯網與人工智慧強化學習(Reinforcement learning, RL)在號誌控制之應用與演算法，以及進行相較於現有動態號誌控制模式之優缺點研析。

二、都會區幹道人工智慧強化學習號誌控制實測

根據 112 年於臺南市與臺北市實測場域實測結果，進行必要之人工智慧強化學習號誌控制模型調整與再訓練，以及實測工作與事前事後量化績效評估。

三、交流道區域人工智慧強化學習協控模型開發訓練

進行高速公路交流道區域匝道儀控與平面道路路口動態號誌整合之模擬模式構建與人工智慧強化學習號誌協控模型探討。檢討前期(112 年)於高速公路國道 1 號桃園楊梅交流道所探討人工智慧強化學習號誌協控模型與所發展模擬模式；以及利用經校估後之實測場域最新版專業交通運輸模擬軟體(VISSIM)模擬模式與最新版開源交通運輸模擬軟體(SUMO)模擬模式，進行人工智慧強化學習號誌控制模型發展，以及訓練學習。

四、交流道區域人工智慧強化學習協控模型實測

依據前項工作在匝道儀控與平面道路路口號誌整合之人工智慧強化學習號誌控制模型訓練成果，與高速公路局及縣市政府合作進行現場實作測試與量化績效評估。

第二章　文獻回顧與關鍵課題

2.1 國內外號誌控制策略探討

2.1.1 平面道路號誌控制

號誌控制是道路交叉口的重要環節之一，分配不同來向的車流順暢且安全的通過路口是號誌控制的重要目的之一。而其中田永平(2006)提及獨立路口的時制設計可透過公式推導、數學規劃模型及模擬進行求解。幹道的號誌系統，除了獨立路口的參數，更需要考量時差及綠燈續進帶，幹道連鎖的延滯、通過量等績效指標，也是判斷號誌策略是否被妥善的運用。陳麗雯等人(2020)亦將兩套號誌最佳化軟體，TRANSYT-7F 與 Synchro，對於幹道場域進行最佳化求解，並比較兩者求解結果。

而根據江伊嵐等人(2020)提出動態控制是目前交通控制中常見的手段，其中包括觸動式及動態式等模式，這些控制策略在國際交通運輸界受到重視，尤其是在智慧交通系統(ITS)領域，在臺北市所建置的智慧號誌控制系統中，亦以觸動控制和適應性號誌策略為主，觸動號誌控制根據道路上偵測的車流資料調整綠燈時間，應用於主次要道路交通量懸殊的地點；適應性號誌控制策略旨在增強路口號誌時制的智慧化，以快速應對交通狀況的變化，同時改進動態查表等交通控制方法的不足，提高運作績效。而近期，許多都市透過人工智慧建立號誌控制策略以嘗試解決長期壅塞的區域，主要可分為時相決策或週期決策。

一、觸動號誌控制

(一)半觸動號誌控制模式之建構與驗證(張佑鴻，2012)

為探討半觸動號誌在改善延滯的情況，對於半觸動號誌進行情境分析及敏感度分析，分別在都會區具上下游路口處，以及郊區獨立路口處進行半觸動號誌設立的績效評估。其中考慮了幹道的 V/C ratio 以及幹支道流量比。

其結果顯示，在假設每車道 C 值為 1200 PCU，幹道為兩車道，速限 50KM/HR 的情境下，當幹支道流量比例懸殊，例如 10：1、10：2 時，觸動控制改善之延滯績效成效較佳。當兩者流量比例接近時，觸動邏輯容易感應車流而延長綠燈，造成另一方向車流總延滯增加幅度大。在實驗場域，亦觀察市區廊道道路，即使幹支道流量差異大，亦不太適合施行感應性號誌。由於號誌不連鎖，上下游車流仍為紅燈停等狀態，該感應性路口即使支道無車輛而開啟幹道綠燈，多數情形為無效綠燈，反而造成幹道延滯增加，與感應性號誌欲減少幹道延滯之目標相悖。

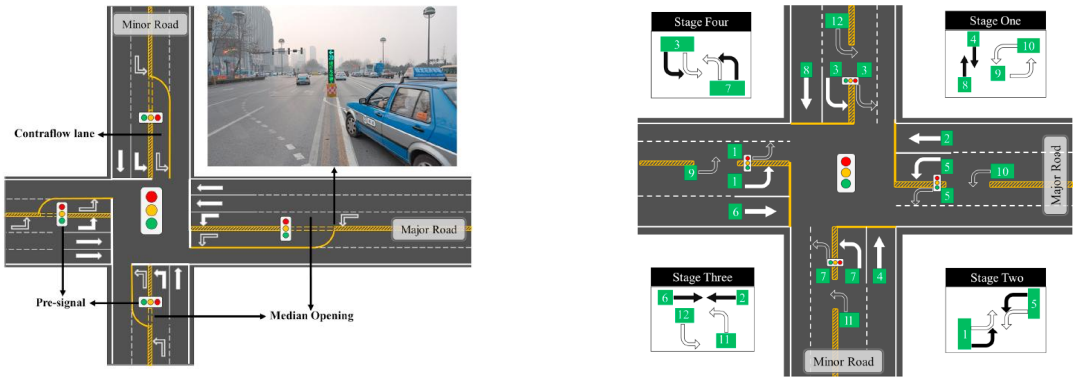
表 2.1.1-1 觸動號誌與固定時制績效比較表

V/C 值	幹支道流量比例	方向	定時號誌-平均延滯時間(秒/車)	半觸動號誌-平均延滯時間(秒/車)	績效值	定時號誌-路口平均延滯(秒/車)	半觸動號誌-路口平均延滯(秒/車)	績效值
0.8	10:1	幹道 1	5.37	3.31	38.31%	12.79	9.15	28.47%
		幹道 3	5.81	3.27	43.72%			
		支道 2	27.19	20.86	23.27%			
	9:1	幹道 1	5.13	3.56	30.54%	12.33	9.24	25.04%
		幹道 3	5.94	3.71	37.52%			
		支道 2	25.92	20.45	21.09%			
	8:1	幹道 1	5.31	4.38	17.65%	12.12	9.47	21.85%
		幹道 3	5.38	4.77	11.26%			
		支道 2	25.66	19.26	24.94%			
	10:2	幹道 1	5.79	4.53	22.06%	10.37	9.20	11.22%
		幹道 3	5.15	4.74	7.60%			
		支道 2	20.16	18.34	9.03%			
	10:3	幹道 1	5.11	5.01	2.19%	11.01	9.38	14.83%
		幹道 3	4.39	4.91	12.36%			
		支道 2	23.54	18.22	22.61%			

資料來源：張佑鴻(2012)

(二)Developing an actuated signal control strategy to improve the operations of contraflow left-turn lane design at signalized intersections (Wu 等人，2019)

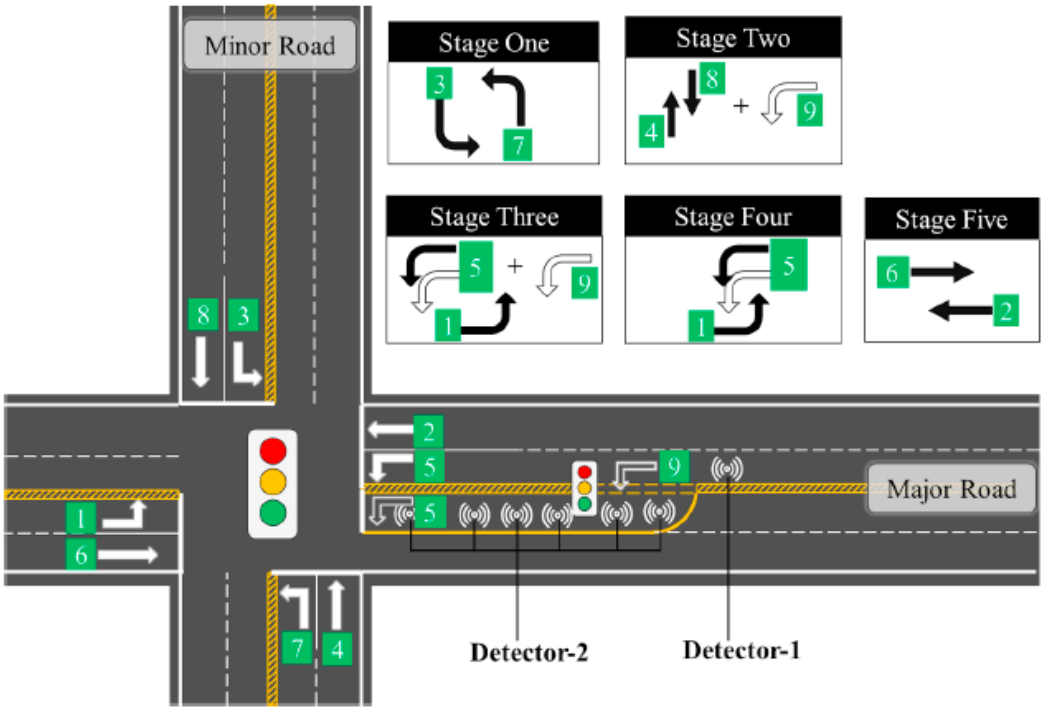
半觸動號誌除了適用於幹支道交通量差異較大之場域外，提出可以改善逆向左轉車道(Contraflow Left-Turn Lane, CLL)車輛延滯時間。在中國大陸，為了緩解號誌化十字路口左轉車輛引起的交通擁堵，越來越多地採用了 CLL 設計。CLL 設計即為在分隔帶的對向直行車道上，設置一個或多個左轉車道，如圖 2.1.1-1 所示。其中，該車道設計由於會駛入對向車道，故路口近端將設置預先號誌(pre-signal)設備，此號誌讓車輛除了被允許的等待左轉時間外，禁止進入對向車道，以免發生逆向的車輛衝突。而釋放停等車流進入對象等候左轉，亦能夠疏解原線道左轉車隊長度。



資料來源：Wu 等人(2019)

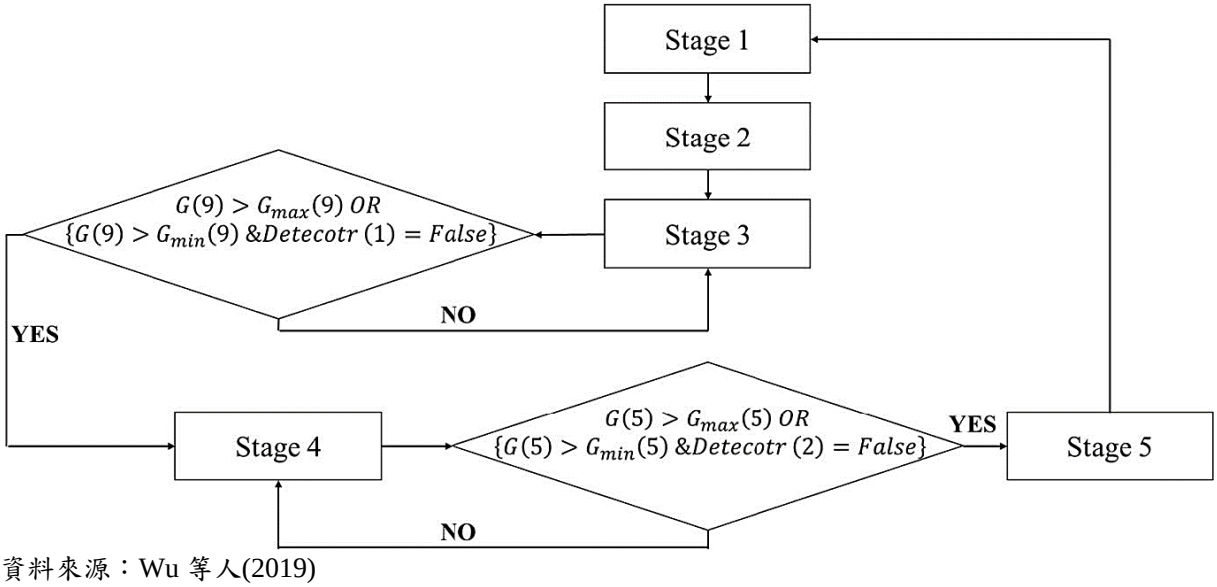
圖 2.1.1-1 設置逆向左轉車道路口以及路口時相示意圖

但 CLL 的預先號誌設計運作，亦產生問題。由於左轉車輛只能於特定時相進入 CLL，故設計的 CLL 長度可能有無法完全有效利用的問題；另一方面，如果在左轉時相結束時 CLL 中左轉車隊無法完整紓解，亦即在後續的時相，該停等車隊將全數變成逆向車流，存在交通安全上的問題(如圖 2.1.1-2 所示)。故以簡單一方向設置 CLL 的道路幾何條件下，提出半觸動控制邏輯策略，最大綠最小綠、時制重整，以及偵測器設置位置，以期改善左轉車輛延滯的情況。圖 2.1.1-3 為觸動號誌邏輯。



資料來源：Wu 等人(2019)

圖 2.1.1-2 單方向設置逆向左轉車道路口圖以及路口時相示意圖



資料來源：Wu 等人(2019)

圖 2.1.1-3 半觸動號誌邏輯

後續以固定時制(Fixed CLL)、無 CLL 的傳統左轉車道、以及觸動版本的 CLL 做比較。結論可得知觸動版本之 CLL 較使用固定時制之 CLL 佳，但績效略小於傳統的雙左轉專用車道之幾何配置。表 2.1.1-2 為情境績效比較。

表 2.1.1-2 情境績效比較表

Characteristics of different design concepts.

Design concepts	Control strategy	L (m)	n_{con}	n_{CLL}	Cycle length(s)
Actuated CLL	Actuated	50	1	1	–
Fixed CLL	Fixed Time	56	1	1	150
Fixed Conventional	Fixed Time	–	2	0	150

Comparison of the throughput volume associated with different design concepts.

Design Concept	Throughput Volume (veh/h)	Demand (veh/h)						
		300	350	400	450	500	550	600
Fixed-CLL	Mean	303.8	340.6	405.6	448.8	499.2	531.4	531.8
	Std. Deviations	74.6	62.7	60.2	69.9	56.2	15.9	15.4
Actuated-CLL	Mean	303.8	352.3	403.7	451.2	499.2	546.2	593.8
	Std. Deviations	81.8	93.5	83.1	98.7	109.7	87.1	67.2
Fixed-Conventional	Mean	303.8	351.4	405.1	449.3	501.6	549.6	601.0
	Std. Deviations	74.0	75.1	77.0	85.2	93.6	87.4	76.6

Comparison of delay performance associated with different design concepts.

Design Concept	Delay (s)	Demand (veh/h)						
		300	350	400	450	500	550	600
Fixed-CLL	Mean	62.1	60.7	63.1	68.9	88.6	208.1	223.3
	Std. Deviations	11.1	11.5	12.3	12.9	20.9	40.5	28.6
Actuated-CLL	Mean	60.3	56.8	57.6	55.7	61.0	68.7	130.1
	Std. Deviations	12.1	11.9	10.6	10.4	12.0	20.4	34.9
Fixed-Conventional	Mean	52.0	52.3	53.1	55.9	56.7	57.6	65.1
	Std. Deviations	12.1	12.2	10.0	9.8	8.6	11.4	11.6
P-value of t-Test[a]		0.46	0.10	0.01	< 0.01	< 0.01	< 0.01	< 0.01

資料來源：Wu 等人(2019)

二、適應性號誌控制

(一)都市適應性號誌控制原理與發展(胡守任等人，2020)

適應性號誌(Adaptive Traffic Control System, ATCS) 透過偵測車流高低來調整綠燈時比或延長綠燈，而運作方式可透過群組共同考量及控制，來加強其控制彈性及績效表現。適應性控制邏輯依演算差異可區分為二大類，在當前週期或一固定時間內，計算下一階段之號誌週期與時比的週期性號誌控制邏輯(Cyclic Control Logic)；以及以即時蒐集所得的車流資訊，在每一個步階中比較各種競爭方案的績效值，此為週期內號誌控制邏輯(Time-Step Control Logic)。

國外週期適應性號誌控制有少量多次頻繁微調參數之 SCOOT；以均衡鄰近衝突路段的飽和度為目標制定時制計畫，整體作法似進階動態查表的 SCATS；經由車流預測模式推估車流需求選擇最適宜之週期時間，再經由基因演算法求解群組最佳的時比與

時差之 BALANCE。

而國外週期內適應性號誌控制有藉過去數個週期之交通流量資料，透過水平推移法，預測未來數個週期之流量型態的 OPAC；藉由路口間的 P2P 串連分享即時車流資訊，並透過 PREDICT 模式推估上游車輛或車隊到達路口之時間，藉由演算法預測下一分鐘之隨機車流到達型態之 RHODES。

國內早期於 1988 年發表適用國內道路情境之適應性號誌控制邏輯 COMDYCS 系列，可適用於小型路網、雙時相、純車流情境。後續有版本納入轉向比估計模式，有的版本進一步發展混合車流 CTM 車流預測模式。COMDYCS-III 則是以 SAST 架構開發，屬於週期內號誌控制邏輯，其透過上下游偵測器蒐集車流資料，計算路口各路段之停等長度與總延滯時間，再判斷是否延長或結束綠燈。亦於單一路口進行實證，比較各號誌控制策略在到達率固定及變動的情境下的績效。表 2.1.1-3 為各控制策略及情境績效比較。

表 2.1.1-3 控制策略及情境績效比較表

	適應性號誌控制			定時號誌控制			觸動式號誌控制		
績效指標	固定到達	變動到達	增幅(%)	固定到達	變動到達	增幅(%)	固定到達	變動到達	增幅(%)
每車延滯	32.22	33.33	3.09	32.14	83.54	159.93	35.54	38.79	9.14
停等次數	1.27	1.38	8.66	1.37	4.54	231.39	1.48	1.78	20.27
最大等候線長度	91.10	92.19	1.20	78.81	316.45	301.54	109.15	138.83	27.19

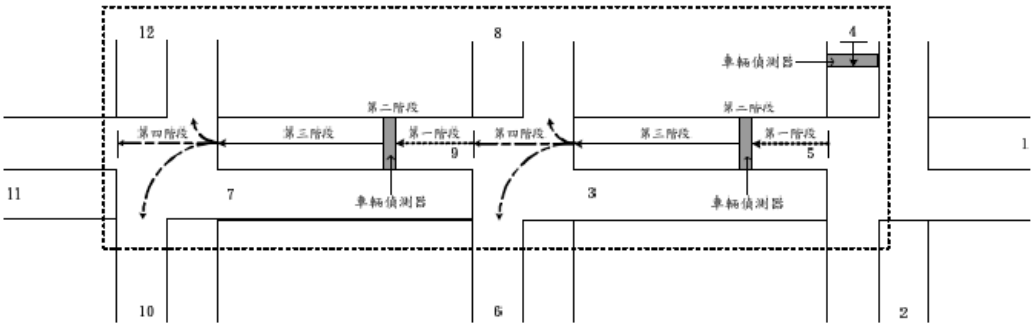
資料來源：胡守任等人(2020)

(二)幹道群組適應性號誌控制模式之開發研究(吳悅慈，2011)

針對適應性號誌控制策略以系統整體旅行延滯最小化為目標，提出都市幹道號誌群組之適應性號誌控制模式，並結合路段上游之先期車流資訊，提出四階段之車流推進與預測模式，以「幹道系統整體實施連鎖控制，並以一個完整週期時制作為實施適應性控制決策之基本控制單位」為決策基本概念，考量群組內路口之週期、時比與時差等因素。而適應性啟動之運作流程每個時相皆會更新當前車隊資訊，藉以判斷該時相可完全紓解該方向車隊的綠燈時間。

針對幹道群組車流發展一幹道車流推進與預測模式，其中包含多路口車流推進模組，以及車流預測模組。多路口車流推進模組每秒進行交通量資料蒐集與車流推移，提供號誌控制模型在決策進行時即時的幹道群組交通資訊。車流預測模組則在號誌模型決策時，提供未來的流量推移預測資訊，作為預估不同決策方案下的比較依據(如圖 2.1.1-4 所示)。實測場域選擇於中華東路廊道，其實測模組分為幹道群組內適應性控制模式(ACTS-T)及幹道群組週期性適應性模組(ACTS-C)，並與 SYNCHRO 計算出之最佳化應時時制比較。結果以 ACTS-T 為例，如表 2.1.1-4 所示。Case 1 為低流量，Case 10

為高流量，各流量再細分為低曾、遞減及持平穩定流量狀態。



資料來源：吳悅慈(2011)

圖 2.1.1-4 適應性號誌控制於多路口車流推進之分段示意圖

表 2.1.1-4 ACTS-T 控制策略及情境優劣比較表

實驗案例	ACTS-T 控制策略(較佳：ˇ；無差異：-：較差：╳)	
	較幹道群組最佳化定時	較 ACTS-C
Case1	ˇ	╳
Case2	ˇ	╳
Case3	ˇ	╳
Case4	ˇ	ˇ
Case5	ˇ	ˇ
Case6	ˇ	ˇ
Case7	ˇ	ˇ
Case8	ˇ	ˇ
Case9	ˇ	ˇ
Case10	ˇ	ˇ
Case11	ˇ	ˇ
Case12	ˇ	ˇ
總計	10(100.0%)	7(70%)

資料來源：吳悅慈(2011)

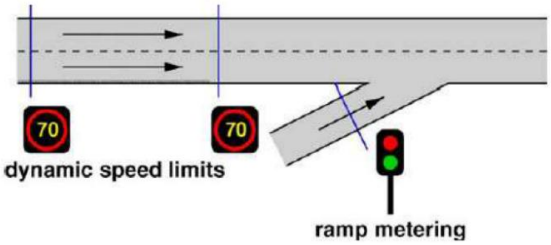
2.1.2 平面道路與交流道匝道號誌協控

交流道系統與一般市區號誌控制的不同，是高速公路、匝道、平面道路三個目標的相互關係，高速公路主線是否壅塞及上匝道的衝擊影響，是多數研究長年致力改善的目標之一。協控即為不同系統或不同單位，為了達成地區的交通控制而進行共同控制。而匝道儀控為目前國內最常使用的高速公路交通控制手段，依據高速公路主線的壅塞情況，可以降低匝道儀控率，來避免主線車流密度超過臨界值，雖能減少匯入主線的車流造成的衝擊，但實施低儀控率之時段過長亦會影響平面道路的車流情況，因此可在主線不壅塞時盡量放大儀控率，以保持平面道路車流順暢。

一、高速公路匝道儀控與主線速率控制間的協控

(一) 高速公路匝道儀控與速率控制協控模式之研究(黃崇宇，2009)

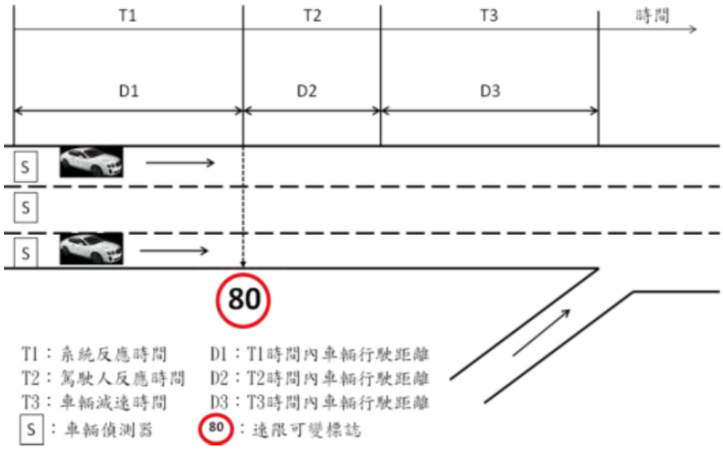
雖匝道儀控為常用手段，但當主線車輛密度過高時，匝道儀控為了避免匯入車流衝擊而不斷縮減儀控率；惟避免匝道等候車隊長度過長，到達匝道設置的最小儀控率時，在此情況下，匝道儀控即無法避免壅塞情形發生。在考量高速公路主線以及匝道的壅塞情況，為提升兩者的績效，透過調整匝道儀控率，亦在高速公路上游佈設偵測器，調整主線的車輛速率，可降低車間速率變異，使車流在高密度的情況下，維持較高的速率及流量。而降低上游車輛進入瓶頸的速率，也可以延緩衝擊波向上游蔓延的情況。藉由調整匝道匯入處上游的主線速率及匝道儀控率，兩者協控以降低車輛交會時受影響的程度，幾何示意如圖 2.1.2-1 所示。



資料來源：黃崇宇(2009)

圖 2.1.2-1 匝道儀控與速率控制協控系統

因偵測器是以每隔一固定時距方式收集交通特性資料給速率控制決策模式，故匝道匯入處上游車輛在此時距中已行駛 D1 的距離，因此上游偵測器位置應至少距速限可變標誌 D1 之距離，此時駕駛人發覺速限可變之速限內容，經過判斷開始採取減速措施，這段時間內，車輛保持原速率行駛了 D2 的反應距離；反應結束後車輛開始減速，在速率降至速率控制之目標值時，車輛又行駛了 D3 的減速距離。圖 2.1.2-2 為主線速率控制系統設施設置說明。



資料來源：黃崇宇(2009)

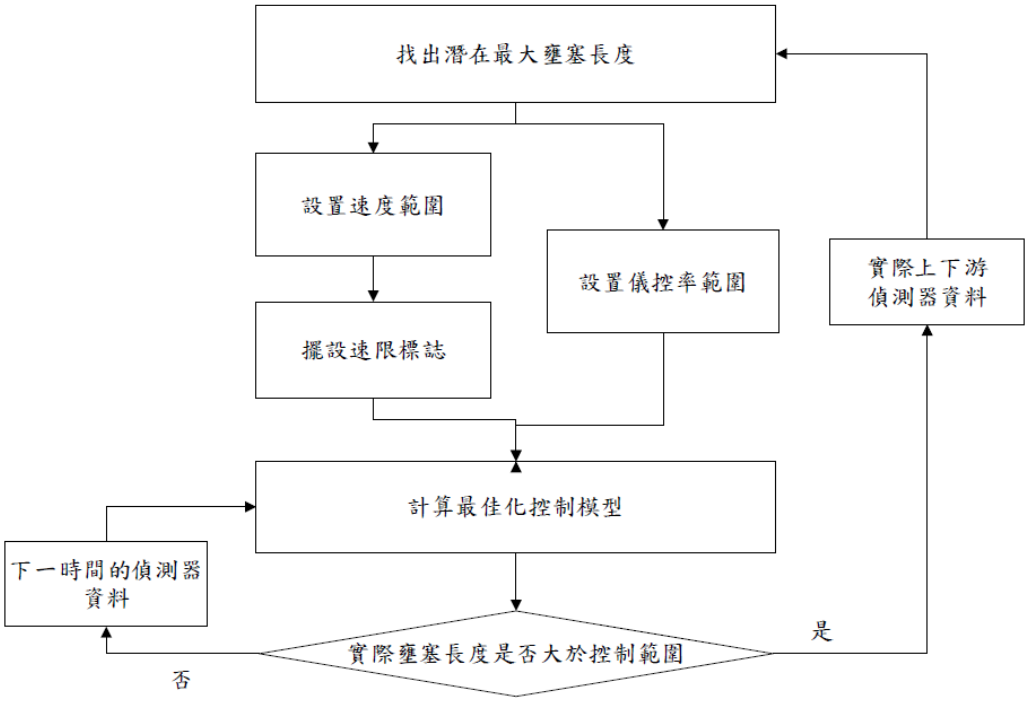
圖 2.1.2-2 主線速率控制系統設施設置說明圖

總結來說，此篇文獻提出，欲考量匝道儀控與主線速率控制的協控，除了匝道儀控外，主線道需取一段交會瓶頸區的上游距離作為主線協控距離。而此距離則透過反應

距離、安全減速度以及目標車輛速度幾個參數決定。

(二) 高速公路速率控制與匝道儀控最佳化協控模式之研究(薛博元，2011)

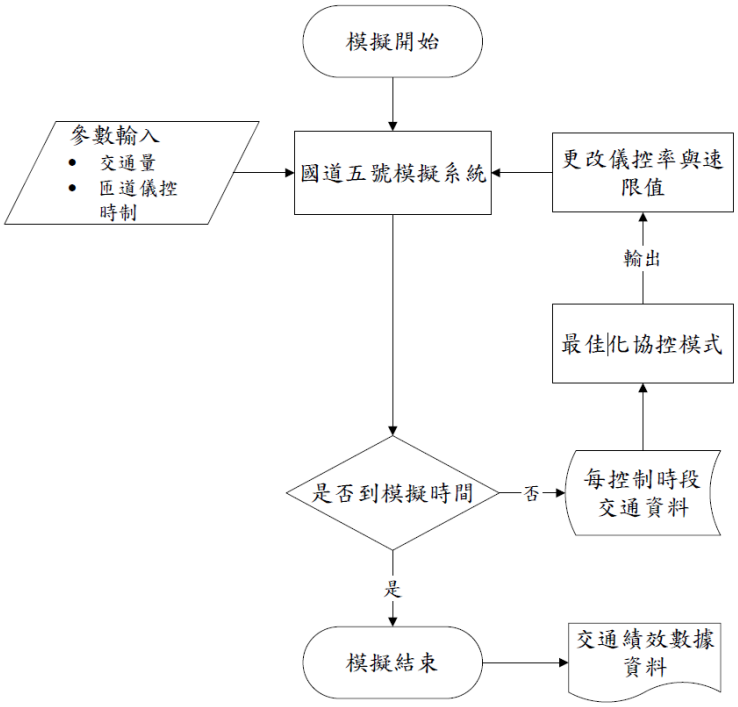
提出透過觀測高速公路主線的可能壅塞車隊長度，設定一最佳化協控模型，該研究控制邏輯架構圖如圖 2.1.2-3 所示。考量儀控率上限使得高速公路主線的流量密度不超過臨界值，下限需避免匝道等候車隊長度溢出至市區道路。同時計算瓶頸路段的上游速率上下限，此速率上下限是藉由宏觀車流理論計算自由流速率，以及考量駕駛安全加減速後透過牛頓運動定律而得。再經由觀測該次速限位置區間、速限上下限及儀控率上下限調整後，是否壅塞仍超出設定的範圍。如超出設定範圍，則需重新調整上述設定值區間；如壅塞情況仍在設定區間中，則持續觀測直到壅塞結束。



資料來源：薛博元(2011)

圖 2.1.2-3 高速公路速率控制與匝道儀控最佳化協控之控制邏輯架構圖

該控制策略以國道五號為分析案例，並透過 VISSIM 模擬軟體建模進行績效分析，模擬流程如圖 2.1.2-4 所示。其中，該模擬模型的基本參數設定，如表 2.1.2-1 所示，而動態輸入參數為交通量及匝道儀控時制；而該模擬每個 step 所產出的輸出，例如：匝道等候車隊長度、上游主線流量、上游主線密度及速率等，則為最佳化模型的輸入參數。



資料來源：薛博元(2011)

圖 2.1.2-4 高速公路速率控制與匝道儀控最佳化協控模擬之求解流程圖

表 2.1.2-1 高速公路速率控制與匝道儀控最佳化協控之模擬系統參數設定表

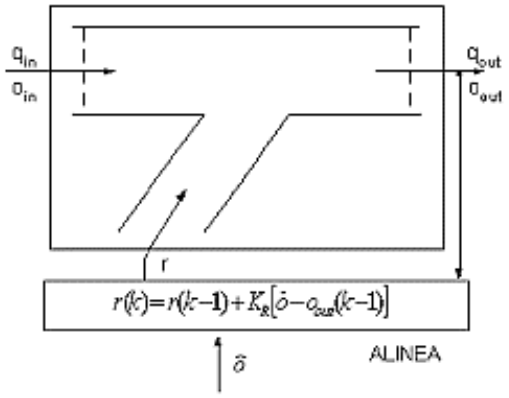
	高速公路主線	初入隧道	隧道中段
車道數	2 車道	2 車道	2 車道
最高速限	90 公里/小時	80 公里/小時	80 公里/小時
變換車道最小車頭距	1 公尺	1 公尺	1 公尺
最小停等車距	2.82 公尺	2.82 公尺	2.82 公尺
安全間距參數	0.23 秒	4.06 秒	3.07 秒
進入跟車門檻	6 公尺	6 公尺	6 公尺

資料來源：薛博元(2011)

(三) ALINEA: A Local Feedback Control Law for On-Ramp Metering (M. Papageorgiou 等人，1991)

ALINEA 是一個後回饋式(Feedback)控制手段，非前回饋式(Feedforward)架構。前饋式架構即為制定一控制門檻值後，僅考慮實時觀測之車流與門檻值差異，不論是考慮道路容量或佔有率做為門檻，皆因每個時隔的車流彼此離散，故儀控率可能有變動過大的問題。圖 2.1.2-5 為 ALINEA 邏輯架構。

提出一公式表示儀控率為上個時階之儀控率，加上模式參數乘目標佔有率與前時階佔有率的差值，即 $R_t = R_{t-1} + K(O - O_{out,(k-1)})$。以該公式為基礎，由於兩時階之儀控率具有關係，故儀控率之變動情況會較小，但公式本身不具匝道車流數值，故都會區車流情況並不會被考量。又公式中具有佔有率，故適合具備偵測設備的環境使用。



資料來源：Papageorgiou 等人(1991)

圖 2.1.2-5 ALINEA 邏輯架構圖

(四) 小結

過往協控邏輯中，區分為前回饋式(Feedforward)和後回饋式(FeedBack)，前回饋式在初始時，即根據現場車流情況，由專家判斷或經驗法則設定一控制門檻，當車流情形到達控制門檻時即調整儀控率。另一方面，後回饋式為接收到現場偵測資料後，進行儀控率的決策，且儀控率之間具有關係，使得儀控率的變動情況不會像前回饋式這麼劇烈。

在另外兩篇較為近代的文獻中如黃崇宇(2009)、薛博元(2011)，皆評估在模擬環境中，實施控制策略所帶來的績效。兩則文獻以主線通過量及主線平均旅行時間做為績效評估指標。具體來說，當控制策略介入時，普遍的情境可在主線得到比未介入時好的行車績效，例如比較少的總車輛旅行時間，亦或在模擬時間區間中有比較大的總通過量。而在薛博元(2011)中，亦將匝道的停等狀況及延滯納入績效考量，避免過往文獻只注重主線通順。

由績效評估得知，兩篇文獻之協控策略，皆可讓控制範圍內之績效指標有不等的提升。總通過量增加，意指可讓更多車輛通過瓶頸路段區域；總旅行時間和總延遲時間下降，意為藉由此速限控制可以使得車輛塞在瓶頸路段的時間縮小；匝道等候車隊長度縮短則為上匝道的需求更能被滿足，且對平面道路的影響也降低。

二、高速公路匝道與平面道路號誌控制的協控

匝道與平面道路的協控則主要回顧本所於 2010 年「標準化都市交通管理之通訊協定研發(二)」研究報告，於該報告 4.2.1 節及 4.2.2 節中各別探討上下匝道與及都市平面道路間的號誌協控模式。

(一)上匝道與平面道路號誌協控模式

上匝道與都市間的交通問題，主因為匝道儀控為高速公路局控管，而平面道路號誌

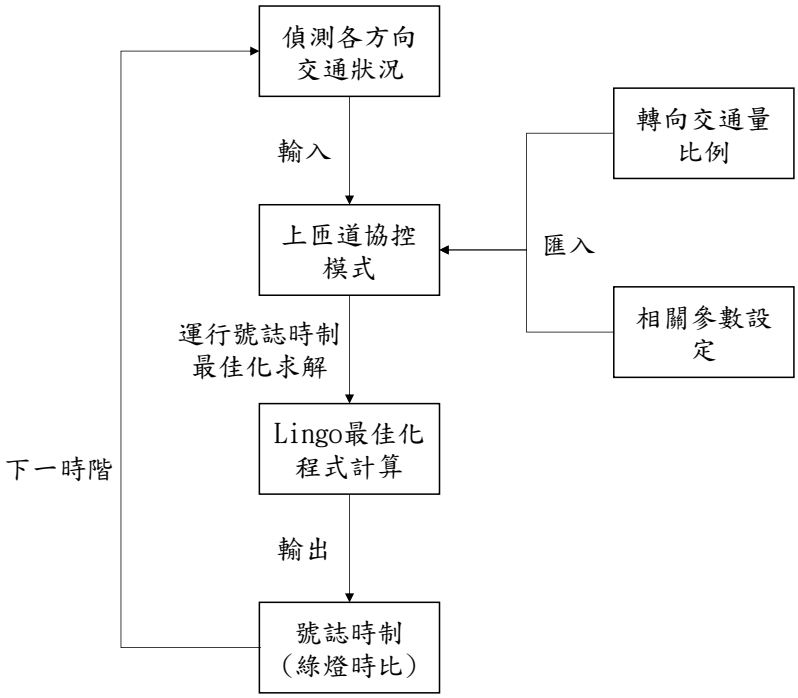
為縣市政府交控中心控管，如兩者分別考量，則可能發生高速公路壅塞時降低儀控率，惟地方號誌仍允許車輛進入匝道導致回堵；亦或地方號誌綠燈無法搭配儀控時相等。

此文獻以最佳化模型求解號誌協控模式，主要目標為匝道壅塞長度，以壅塞程度不同作為控制目標的門檻值。其目標式考量兩種狀況：匝道已壅塞，以及匝道未壅塞。若上匝道處已壅塞，則為避免回堵至平面道路，目標式為最小化匝道等候車輛數，其意義為原排隊車輛數加上市區進入匝道車輛數減去進入主線車輛數須求解最小值。若匝道處於非壅塞情況，為提高匝道使用效率，而採取匝道通過量最大為控制目標，其意義為匝道排隊數量加上進入主線車輛數必須為最大值。並考量求解效率及時間，該文獻透過權重將多目標模型轉為單目標式之模型，整理如表 2.1.2-2。而該模式於限制式中，亦考量平面道路的車輛數及時相、匝道儀控率的上下限值、主線壅塞程度及主線壅塞臨界值等，模式求解後得到路口各時相的綠燈時比，以及匝道儀控率。主要模式運作流程圖如圖 2.1.2-6 所示。

表 2.1.2-2 上匝道與都市協控模型之目標式

情境	目標式
匝道已壅塞	$J = \min\left(x - rcA + \sum_{i=1}^{n} g_i c q_i\right) \quad R_{ramp} > \beta$
匝道未壅塞	$J = \max\left(\sum_{i=1}^{n} g_i c Q_i + rcA\right) \quad R_{ramp} \leq \beta$
合併目標式	$J = \min\left[\left(x - rcA + \sum_{i=1}^{n} g_i c q_i\right) \times \alpha - \left(\sum_{i=1}^{n} g_i c q_i + rcA\right) \times (1-\alpha)\right]$

資料來源：交通部運輸研究所(2010)

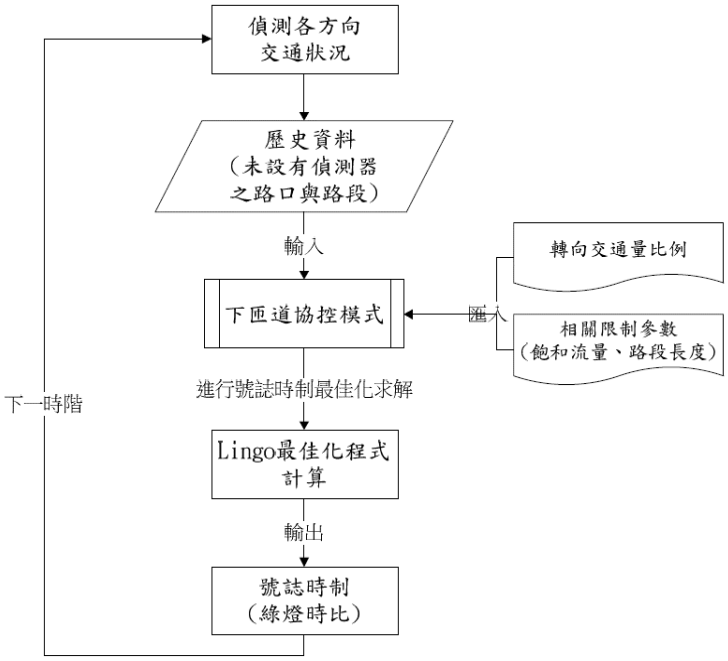


資料來源：交通部運輸研究所(2010)

圖 2.1.2-6 上匝道與都市間號誌協控模式流程圖

(二)下匝道與都市間的號誌協控模式

下匝道的文獻較少，現存亦無下匝道儀控設備，故多以最小延滯時間以及路段最大通過量進行設計。此文獻以最小總車輛停等時間為目標式進行號誌設計，考量了每一週期進入及離開的車輛數。其中設定路段流量守恆及容量限制、各方向之車道容量及流動限制、防止下匝道車隊溢流回主線道限制以及車輛紓解率等限制式。求解將得路口各方向之綠燈時間，其主要模式運作流程圖如圖 2.1.2-7 所示。



資料來源：交通部運輸研究所(2010)

圖 2.1.2-7 下匝道與都市間協作模式流程圖

(三)小結

該報告主要基於匝道的壅塞車隊長度，建構上下匝道與都市間的平面道路協控的最佳化模型。其中上匝道口因為現存高速公路局的匝道儀控設備，故模型中考量了儀控率、匝道車隊長度以及平面道路的綠燈時長，目標式為以權重混和考量最小化車隊長度以及最大化疏解流量。而下匝道口並無現存儀控設備，故以最小總車輛停等時間做為目標式求解，並考量路段流量及車道流量限制、匝道車隊長度限制以及車輛於平面道路匝道出口的疏解率。

2.2 強化學習於號誌控制之應用

本計畫中透過即時號誌動態資訊給各式車輛，以提供安全、優先通行、節能的道路交通環境，根據路口各方向即時交通變化作動態彈性調整號誌；然過往傳統適應性號誌控制仍存在限制，因演算法本身須給定適當假設條件，並對號誌控制問題進行一定程度簡化後建立控制模型，甚至是納入預測模式的結果後，再以最佳化方法來求解號誌控制策略。此舉很大程

度上取決於對交通流、道路環境之理解程度，無法學習並適應突發狀況外；當面臨規模較大之路網範圍時，其簡化問題難度、最佳化難度亦隨之急遽提升。

如 2.1 小節所述，若欲在複雜環境、難以透過模型建構關係的情況下求解，則強化學習(Reinforcement Learning, RL)適用於此問題；以號誌控制為例，當欲進行號誌控制時，可根據控制路口範圍內所能獲取到之車流環境狀態資訊，進行下一時相長度的決策，並透過具序列性的馬可夫決策過程，使整體控制路口範圍內的車輛在這決策周期內有著最佳的通行效率。然而市區路口環境複雜，使得狀態(State)空間與動作(Action)空間存在高維度問題，使用基本 RL 方法則可能不容易找出有用特徵，故目前研究與應用大多以深度強化學習方法(Deep Reinforcement Learning, DRL)以處理高維度與複雜之控制問題，本小節以下分別回顧國外文獻與國內過去相關研究計畫成果。

2.2.1 強化學習於平面道路號誌控制

一、單一路口號誌控制

過往應用強化學習方法於號誌控制問題時，Noaeen 等人(2022)主要分為兩種類別，第一類為單一代理人(Agent)的 DRL 應用，主要適用於單一路口或路口數較少的環境中的號誌控制問題；第二類為多個代理人(Agent)的多代理人深度強化學習(Multi-Agent Deep Reinforcement Learning, MADRL)應用，此方法則適用於範圍較大的路網環境。此外，目前研究如 Qadri 等人(2020)多以交通模擬軟體作為績效驗證。

關於應用單一代理人(Agent)之 DRL 方法至單一路口號誌控制問題，基於 DQN 方法為最常見的方法之一，其限制在於 Agent 所需之狀態空間與動作空間皆為離散分佈；而常見離散動作可分為兩類，其一為在特定時間點決定是否切換至下一時相，可區分為固定時相順序如 Abdulhai 等人(2020)、Brys 等人(2014)、Mannion 等人(2016)、Li 等人(2016)以及區分無順序性時相 Houli 等人(2010)、Wan 等人(2019)、Genders 等人(2016)；Zheng 等人(2019)為在每時相週期結束時針對下一週期特定時相長度進行調整。

Gender 等人(2016)使用 CNN 將 SUMO 車流模擬影像轉換為狀態輸入以估算 Q 函數值，證實使用 DRL 方法於號誌控制比傳統方法來的更有效。Wan 等人(2018)[48]提出動態計算折扣因子的方法，並應用於 DQN 方法中以設計可變的綠燈時間，證實其績效優於定時時制計畫。Shabestary 等人(2018)則在 DQN 方法中將累積延滯值差作為獎勵，動作空間中則使用 8 種不同時相。相較於前者，Wan 等人(2019)則將各方向車道之車隊長度總和、停等時間總和、號誌狀態、前次動作路口通過車輛數、旅行時間總和等加權為獎勵函數的計算。

相較於基於 DQN 之方法，號誌控制問題應用基於 Actor-Critic 的 DRL 方法之研究則相對較少。Mousavi 等人(2017)應用 Actor-Critic 方法於單一路口的號誌控制問題，其中狀態輸入係根據 SUMO 之車流模擬影像，以 CNN 方式進行轉換以檢測各車道的車隊長度、車速、以及車輛位置，動作則設定為東西向或南北向之時相，獎勵則累積延滯差；該研究發現，相較

於 DQN 方法，Actor-Critic 方法可找出更穩定的策略。Gender 等人(2016)則採取 A3C 方法應用於單一路口模擬。值得一提，該研究針對 3 種狀態輸入進行比較，分別是(1)各車道佔有率與平均車速、(2)各車道密度與停等車隊長度、以及(3)車輛位置與車速，結果發現僅藉由傳統方式及路側偵測器蒐集之數據所訓練之模型績效，並未不如使用複雜偵測器作為狀態輸入的模型。

過往應用車流模擬軟體於國內場域實作時，其中面臨最大的困難點之一為國內特有混合車流型態難以描述，故亦須進行應用 DRL 方法之國內文獻回顧。許添本等人(2020)在單一路口情況下，採用 DQN 結合 Double Q-learning、競爭網路架構(Dueling Network Architecture)及優先經驗回放之技術方法，每 5 秒決定是否切換時相；該研究透過 CNN 將路口各方向進行格位轉換來建立 Q 網路作為環境狀態輸入，動作考量固定時相順序下時相是否切換，獎勵則考量車輛停等時間及路口通過量所組成之加權指標，最終發現基於 DQN 方法可運用於國內混合車流環境，並即時因應各種車流變化。許添本等人(2021)則為克服 DRL 需大量訓練時間及有時會有訓練效率不佳的問題，採用了示範式 DQN 方法來處理單一路口號誌控制問題。該篇研究將狀態資訊以格位方式輸入，以便包含汽車與機車之位置與速度及當前時相；動作選擇係延長當前時相或切換至下一時相；獎勵函數由通過路口車輛數、停等時間與時相切換懲罰加權組成，並以最大化回合累積獎勵為目標。最終發現績效優於現有定時時制與觸動式號誌控制邏輯。

胡大瀛等人(2021)則針對 DRL 應用於單一路口之號誌控制，以不同獎勵機制對號誌 Agent 的學習過程與訓練成果進行分析，該研究先設計三種環境回饋號誌 Agent 決策的獎勵機制，分別如下：

(一)第一種為車隊等候長度，即車行方向停止線前車輛數，將綠燈方向停止線前車輛數減去紅燈方向停止線前車輛數，若綠燈方向停止線前的車輛數大於紅燈方向的車輛數，則環境獎勵號誌代理一個正值，表示此動作策略能夠提供給更多用路人通行此路口，提升整體效率。

(二)第二種為路口通行量，即於號誌代理執行動作開啟設置的直右綠燈 15 秒或延長直右綠燈 5 秒內，統計進入路口的車輛數，並與最後一秒紅燈方向停止於停止線前的車輛數相減，若路口通行量大於紅燈方向停止的車輛數，則環境獎勵號誌代理一個正值，表示此動作策略能提供更多的用路人通行路口，提升整體效益。

(三)第三種為計算每一輛車於路口停止等待的時間並做加總，利用路口全部車輛累積停等時間做為設計，將上一回合動作策略所導致的車輛總累積停等時間減去此回合動作策略所導致的車輛總累積停等時間，而每輛車於該路口的累積停等時間會持續存在或增加，直到離開路口，故此回合的累積停等時間會較上一回合大而形成負的獎勵值，透過持續持續縮小兩回合間的累積停等時間，使獎勵值能夠負的愈少，提升效益。

再針對獎勵機制做出相關研究，常用的獎勵為停等車輛數(停等車隊)、通過量、以及延滯等，此研究亦考量時相轉換懲罰，以及單一績效與多績效(或稱單一目標及多目標)在 RL 應用於號誌控制的差異。在該研究的個案研究中，時相轉換懲罰以及車道延遲懲罰對於最後的績效影響較大，且該研究得到兩個重要的結論：如獎勵設計良好的情況，多數情形多目標模型之在整體的績效表現會優於單目標；另一個結論則為在多目標的情形下，移除影響較小的 Reward 指標，對於績效影響不大卻能夠有效減少訓練所需收斂時間。

二、多路口號誌控制

應用 DRL 於多路口號誌控制問題時，除訓練出較好的控制策略的 Agent 外，其中一個相當關鍵的議題為如何使多個 Agent 相互合作以進行決策，以最佳化大範圍路網總體績效，此類型問題即為多代理人深度強化學習(Multi-Agent Deep Reinforcement Learning, MADRL)。在處理這類型問題時，主要會面臨 2 個挑戰：第一為在多個 Agent 情況中，對某一 Agent 而言，因其主要互動環境包含其餘 Agent，故執行動作時所需觀察的環境變化不僅是該路口之狀態，亦包括其餘 Agent 的動作變化，導致該 Agent 更新策略參數時所欲考慮的複雜度更高；第二為多路口號誌控制環境下狀態空間與動作空間的高維度與複雜度，將隨著路口數量呈指數性成長，係因該問題目標為整體路網之績效最大化，故須考慮每一路口 Agent 之聯合狀態空間與聯合動作空間。為解決上述問題，過往文獻通常透過資訊溝通、協調機制、或調整價值網路及策略網路架構以克服。

過往文獻中對於應用 MADRL 至多路口號誌控制問題上時，其中一個常見的概念為將每一路口分別以獨立之 DRL 方法訓練一個 Agent，Agent 間相互溝通資訊，使各 Agent 得以利用鄰近 Agent 之訊息進行協調控制。而常見應用於路口下游狀態如 Arel 等人(2010)、Chu 等人(2019)、Da Silva 等人(2006)、Dresner 等人(2006)、El-Tantawy 等人(2013)，應用於鄰近路口所有狀態如 Arel 等人(2010)、Nishi 等人(2018)，Tan 等人(2019)則應用於鄰近路口隱藏狀態。

考量將各路口分別視為獨立 Agent 以進行訓練之 MADRL 方法較不容易收斂，Chu 等人(2019)[8]提出多代理人 A2C 方法(Multi-Agent A2C)，該篇研究引入兩種技術以改善前述之問題，第一為在 Agent 狀態輸入加入鄰近 Agent 的策略資訊，使之能了解鄰近 Agent 之車流狀態及協調策略的概念；第二為在目標函數中加入空間折扣因子，按照路口間距離遠近加權鄰近 Agent 之獎勵與狀態。

另外常見的概念為調整價值網路及策略網路架構，Tan 等人(2019)將大範圍路網將大範圍路網分割成數個小範圍路網後，用一個類似於 DQN 的 Per-Action DQN 來估算集中化的 Q 函數值，用 Wolpertinger-DDPG 去最佳化每個小範圍路網的策略函數。Li 等人(2021)則是在此架構下設計了一個知識分享機制，將所有 Agent 從環境中得到的資訊存入一個知識容器(Knowledge Container)中，進而讓每個 Agent 能夠從中獲得環境資訊，並透過自己的方式去分析重組，得到一組自己特有的知識資訊，再加入本身觀測到的狀態資料一起去進行決策。

在實作之多路口控制案例中，張淑娟等人(2023)即探討在高雄市的應用，分別在固定周期以及變動週期皆有實作案例。在鄰近高雄港之場域中，該研究將處路口依據交通特性及地理位置切分為 6 個群組，每個群組皆由一個代理人各自決策 policy network 之訓練情況，而群組間決策不互相影響。而在九如一路，都會區幹道的區域，共有九個路口，其中兩個為高速公路上下匝道之平面道路號誌路口。該研究以其中三個路口作為路廊主控路口，其餘六處受限於路側設備限制無法作為主控路口，故依據主控路口時比產生及路段旅行時間等資訊，同步產出最佳化幹道續進時制，路廊之週期相同，但各自調整幅度各異。

2.2.2 強化學習於平面道路號誌與交流道匝道協控

2.2.2.1 強化學習於交流道協控之應用

目前所了解之文獻中，大部分將強化學習應用在匝道協控皆為考量高速公路主線以及匝道情況，幾乎無專門考量都會區平面道路及匝道進行強化學習控制協控的文獻。

而其中提及兩個常見的應用方式，單一代理人應用於單一或少量路口，並使其間隔固定時段決策路口時相，亦或透過上一個時相判斷下一個時相的配置；多代理人大多應用於較大的路網配置，其概念為各路口配置單一代理人，再透過獎勵各代理人彼此考量績效的方式，達到路口間的連鎖關係，而常見的獎勵函數包括通過路口車輛數、車隊排隊長度(亦或停等延滯)等。並且在文獻回顧中亦發現，目前主流的協控演算法仍是以 DQN 進行學習。

Liu 等人(2021)以分析的影像畫素坐標轉換為主線及匯入區域的流量作為狀態，決策為紅燈或綠燈為動作，並以交會區速率以及匝道排隊長度為模式獎勵。Yang 等人(2019)考量主線上游，如主線上游車流密度、匯流區車流密度、匝道車流密度以及儀控燈態；動作為紅燈或綠燈兩者；獎勵為系統總旅行時間。

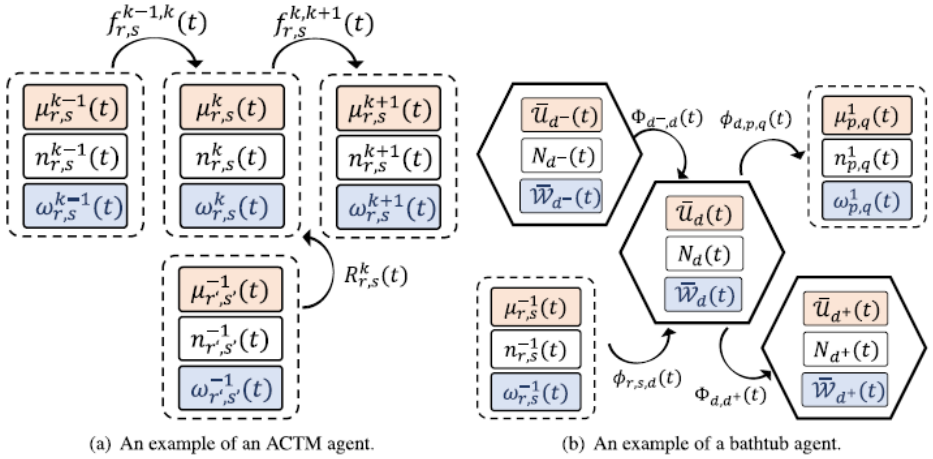
多代理人的運算複雜程度，隨時間及空間的增長而成非線性增加，故多代理人的實際應用仍多應用於模擬軟體階段，跨單位及跨不同公路系統的協控，具有更複雜的求解程度，其文獻數量亦不多。Hu 等人(2024)將高速公路環境視為一細胞傳遞模型，高速公路及都會區為兩個 Agent，輸入模型狀態為主線車流、上匝道車流、下匝道車流及平面道路之車流；動作為增加/持平/減少儀控率；而獎勵目標為降低系統平均旅行時間。Lu 等人(2017)所使用 Q-learning 演算法，考量的狀態為主線車流量及匝道車流量，動作為離散儀控率，獎勵目標為最小化路網車輛數。陳又均(2022)使用多代理學習獨立 Q 網路，考量狀態為主線儀控上下游的速率及佔有率、匝道儀控率，動作為離散儀控率，而由於該文獻選定地點為國道五號雪山隧道口，考量地緣關係，獎勵設為最大化雪隧口流量。

一、Demonstration-guided deep reinforcement learning for coordinated ramp metering and perimeter control in large scale networks (Hu 等人，2024)

提出將高速公路主線與上下匝道視為一個非對稱細胞傳遞模型 (Asymmetric Cell Transportation Model, ACTM)，並且以宏觀車流理論為基礎，William Vickrey 提出之浴

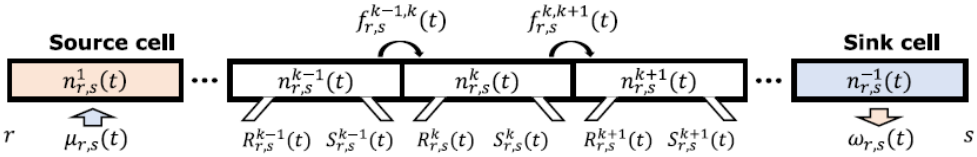
缸模型(bathtub model) 作為都會區交通模型的樣板。這兩者模型皆有輸入量，輸出量的概念，故皆適用於分析壅塞情形之交通情況。圖 2.2.2.1-1 至圖 2.2.2.1-3 為 ACTM 或浴缸模型之 Agen 與模型示意。

模型部分，文獻使用 DQN 架構，周邊平面道路及匝道主線分為兩個 Agent。狀態(State)部分，匝道主線包含主線車流、上匝道車流及下匝道車流，共 15 維度；平面道路則包含平面道路車流，維度視都會區本身的上下游，以及主線 ACTM 的 source 及 sink cell 決定維度。動作(Action)則為儀控率控制，共有增加儀控率、減少儀控率以及持平儀控率三種動作輸出。獎勵(Reward)則為最小化路網中的平均旅行時間(ATT)。在訓練部分，該研究中提及在訓練 DQN 的過程中，ACTM 的 Agent 會有 ALINEA 做為決策 Action 中的導師，ALINEA 為既有協控之理論。其概念近似於 pre-train 或是 action space shaping，讓神經網路在摸索求解時，會先從模仿 ALINEA 的相似行為開始。



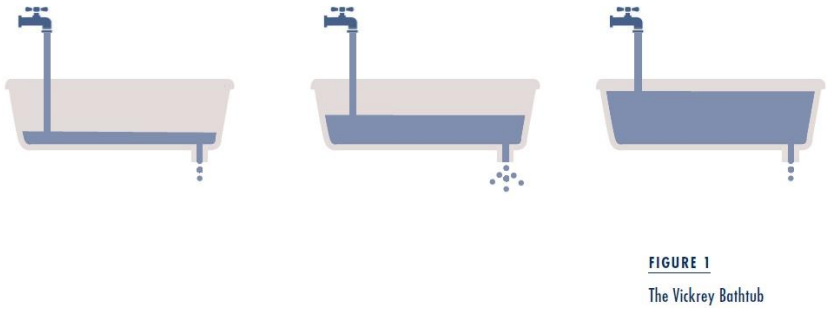
資料來源：Hu 等人(2024) [57]

圖 2.2.2.1-1 ACTM 或浴缸模型之 Agent 示意圖



資料來源：Hu 等人(2024) [57]

圖 2.2.2.1-2 非對稱細胞傳遞模型示意圖(ATCM)

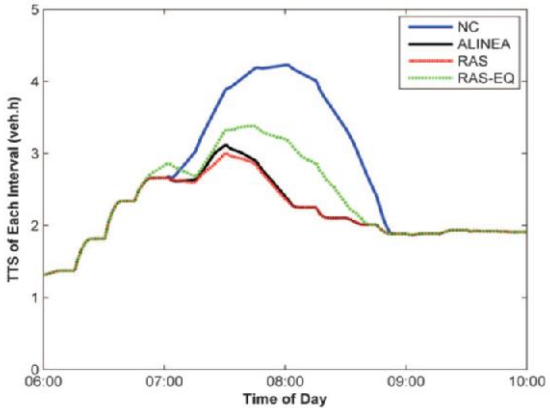


資料來源：https://reurl.cc/kyVr7K

圖 2.2.2.1-3 浴缸模型示意圖(bathtub)

二、Coordinated Ramp Metering with Equity Consideration Using Reinforcement Learning (Chao Lu 等人，2017)

提及過往的匝道儀控，大多犧牲儀控率以換取高速公路主線暢通。當主線近於壅塞時，儀控策略大多為縮減儀控率，避免主線密度超過宏觀車流理論中的密度臨界值。而該篇文獻中，透過設定強化學習的 Reward 為最小化主線的旅行時間，以達成主線優化的目的。其特點為考量車輛數時，主線道及匝道車輛數皆考量進去，且在目標式中設定權重相等，代表著犧牲匝道儀控率的情況會降低。該篇文獻中所論述 equity，目的是不論尖峰或離峰，車輛停等的時間標準差不應太大。該文獻之強化學習模型應用場域為英國 M6 高速公路的某一區段，最後得出之改善結論如表 2.2.2.1-1 所示，主線旅行時間下降約 18%。且加入 equity 因子後，各匝道停等車輛的等候時間變得相近，匝道上的車隊長度亦有減少，且過往尖峰等候時間峰值情況亦有改善，如圖 2.2.2.1-4~2.2.2.1-5 所示。



資料來源：Chao Lu 等人(2017)

圖 2.2.2.1-4 TTS result

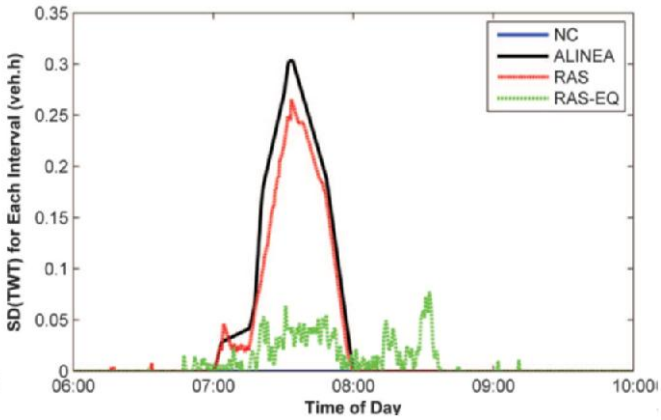


圖 2.2.2.1-5 SD(TWT) result

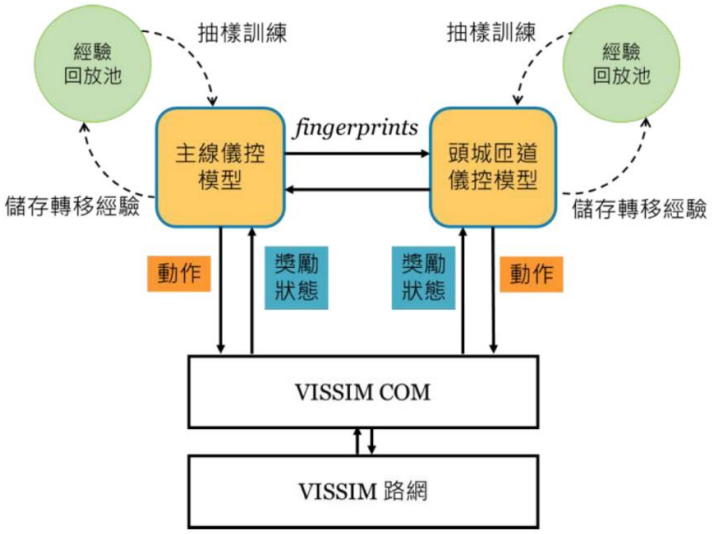
表 2.2.2.1-1 英國 M6 高速公路 TTS 與 SD(TWT)於各策略的結果

Different situations	NC	ALINEA	RAS	RAS-EQ
TTS (veh.h)	2,561.0	2,103.3	2,088.3	2,254.3
TTS reduction (%)	—	17.9	18.5	12.0
SD (TWT) (veh.h)	0.0	35.1	28.5	0.1

資料來源：Chao Lu 等人(2017)

三、應用多代理深度強化學習於高速公路主線及匝道聯合儀控策略—以國道五號為例(陳又均，2022)

應用強化學習建立於國道五號主線與匝道協控模型。其中考量的狀態有主線的速率及車流量數以及匝道儀控率，為避免 Q learning 可能因多目標發生維度爆炸的問題，而採用獨立 Q 學習(Independent Q learning)，一種分散式強化學習法，藉由將其他 Agent 行為考量進狀態的一部份，避免因維度而使模型運作不穩定，該文獻之模型運作模型如圖 2.2.2.1-6 所示。



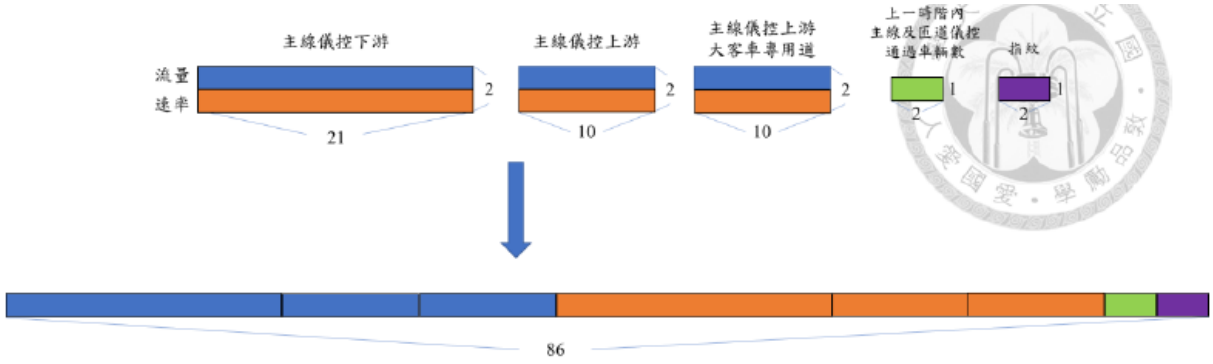
資料來源：陳又均(2022)

圖 2.2.2.1-6 高速公路主線與匝道協控策略模型示意圖

在強化學習所需要設定的狀態、動作及獎勵中，該文獻分別做以下考量：

(一)狀態

由於協控為多目標模型，故採用獨立 Q 學習來放寬維度上的限制。該文獻以流量及速率作為環境狀態，狀態範圍分為三個部分考量，分別為主線儀控上游、主線儀控下游以及上游之大客車專用道，並將上一時階內主線及匝道的通過車輛數作為狀態的一部份，如圖 2.2.2.1-7 所示。



資料來源：陳又均(2022)

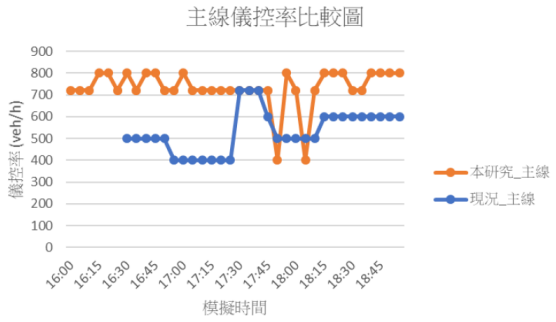
圖 2.2.2.1-7 狀態輸入示意圖

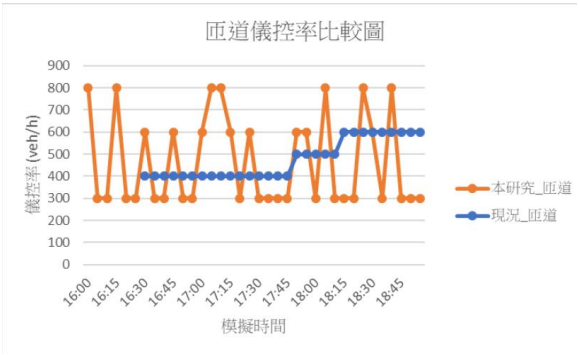
(二)動作：參考過往匝道儀控策略為離散儀控，故設定為每五分鐘一次的定時動作，調整儀控率與現行的國道五號匝道儀控率一致。

(三)獎勵：強化學習的獎勵針對不同應用個案，獎勵設定也會不同。過往小範圍控制策略多採用最小化旅行時間亦或最小化壅塞車輛數。該文獻針對國道五號，設定的獎勵為每一時階最大通過瓶頸流量，並以現行流量作為獎勵比較基準。該瓶頸點為國五

26.705K，雪隧北上處。

最後輸出績效可發現雖將匝道儀控率列為狀態的一部份作為考量，主體仍是高速公路主線道的疏解情形，故在主線的旅行速率及流量皆有提升，主線儀控率偏高；而匝道儀控率上下跳動，但整體平均儀控率仍偏低，故匝道的等候車隊長度較現況長，其輸出結果如圖 2.2.2.1-8~2.2.2.1-10 所示。

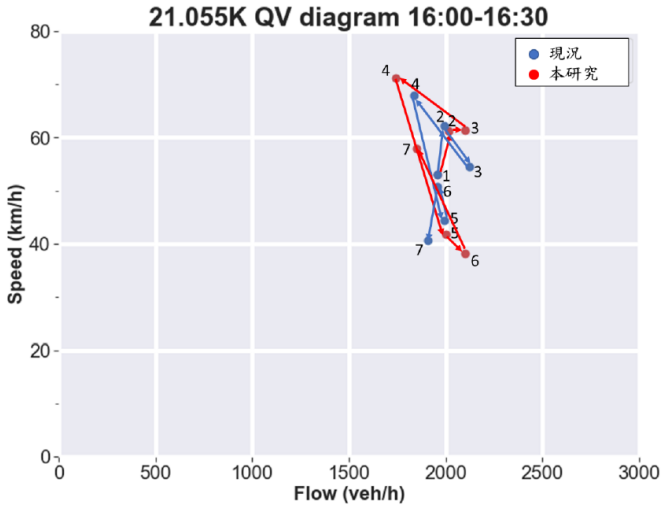




資料來源：陳又均(2022)

圖 2.2.2.1-8 主線儀控率

圖 2.2.2.1-9 匝道儀控率



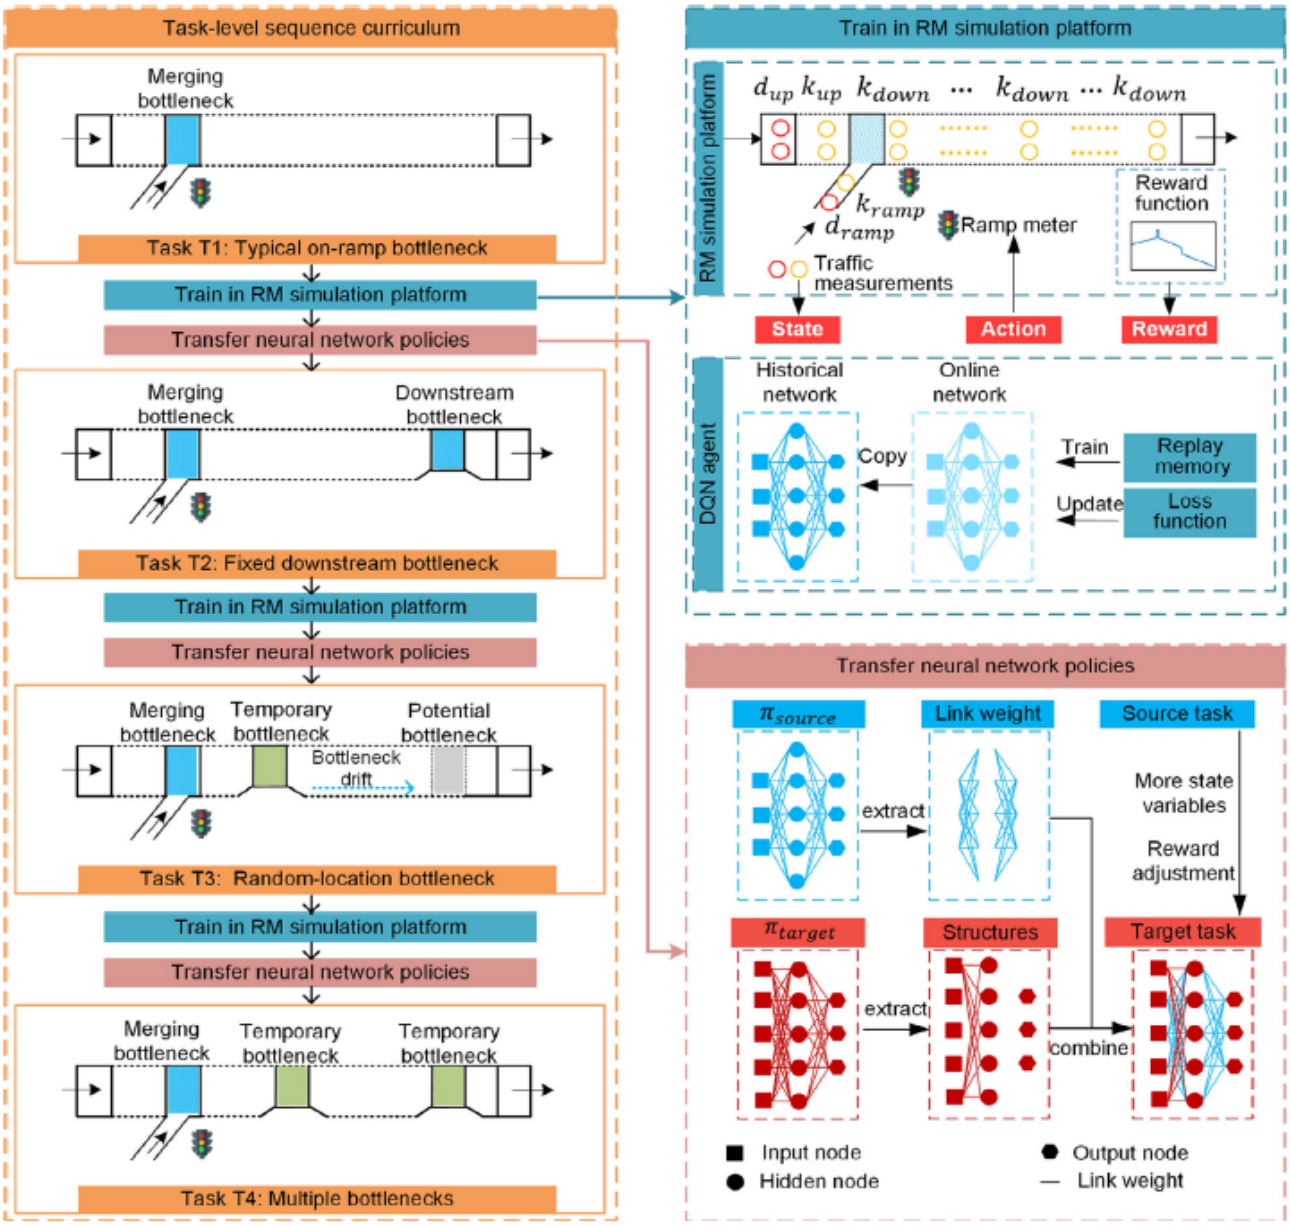
資料來源：陳又均(2022)

圖 2.2.2.1-10 主線速率流量關係圖

四、Enhancing reinforcement learning-based ramp metering performance at freeway at freeway uncertain bottlenecks using curriculum learning (Si Zheng 等人，2024)

應用強化學習建立於高速公路主線與匝道儀控模型。其中結合了深度強化學習(DRL)與課程學習(Curriculum Learning)之應用，其中 DQN 作為深度強化學習之演算法可以通過了解匝道流量與控制邏輯找出適應交通狀況之決策系統。而由於現實交通情境大多都會發生各種情況，且大多都無法預測，因而開發課程學習與強化學習互動，涉及將交通瓶頸作為任務按難度排列，從簡單的任務開始如紅燈延滯，並在模型在此情境逐漸收斂後，逐漸增加難度，這

種方法可以提高模型處理複雜的交通流量與不確定之交通情境，該文獻之模型運作如圖 2.2.2.1-11 所示。



資料來源：Si Zheng(2024)

圖 2.2.2.1-11 高速公路匝道與交通瓶頸之訓練模型架構圖

在強化學習所需要設定的狀態、動作及獎勵中，該文獻分別做以下考量：

(一)狀態：狀態範圍分為五個部分考量，分別為主線儀控上游、主線儀控下游、匝道通過量、停等長度與並匝道的號誌輸出作為狀態的一部份。

(二)動作：動作會以匝道秒數作為輸出並以匝道之通過量與停等長度適時調整。

(三)獎勵：強化學習的獎勵針對不同應用個案，獎勵設定也會不同。過往小範圍控制策略

多採用最小化旅行時間亦或最小化壅塞車輛數。該文獻針對國道五號，設定的獎勵為最大化減少旅行時間。

最後績效可發現通過量逐漸增加，交通瓶頸可及時適應實時狀況，並減少高速公路旅行時間、匝道停等長度，如圖 2.2.2.1-12 與 2.2.2.1-13。

Control strategy	No-RM	Feedback	DRLCL (ours)
TTS (veh·h)	407.84	384.28	**337.17**
Reduction	None	−5.77%	**−17.33%**
Average queue length (veh)	0	41	**15**
Maximum queue length (veh)	0	123	**48**

圖 2.2.2.1-12 主線儀控率

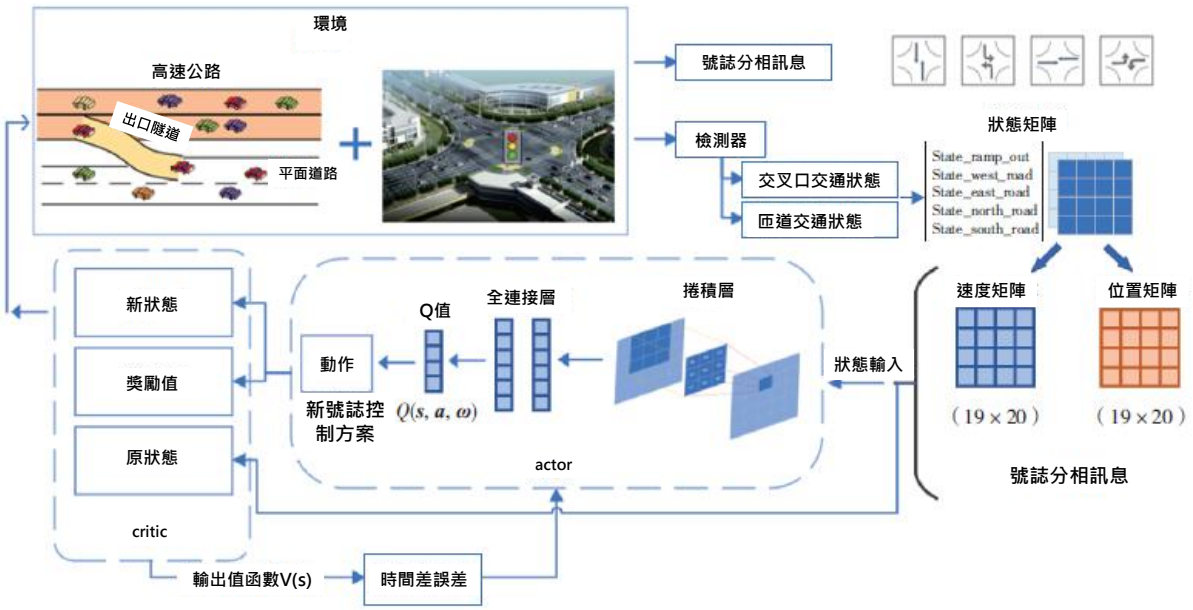
Control strategy	No-RM	Feedback	DRLCL (ours)
TTS (veh·h)	588.30	495.18	**445.85**
Reduction	None	−15.83%	**−24.21%**
Average queue length (veh)	0	66	**34**
Maximum queue length (veh)	0	192	**138**

圖 2.2.2.1-13 匝道儀控率

資料來源：Si Zheng(2024)

五、基於 A2C 的匝道相連交叉訊號誌控制制優化 (宋太龍等人，2024)

匝道與平面道路之連接路口大多受限於車道容量，導致高速公路與平面道路較大之車流無法在匝道之容量較小路段順利駛入目標路段，導致過大之停等延滯，嚴重時更會導致回堵至平面道路或高速路段。而該文獻中，透過設定使用 A2C 之深度強化學習，與其獎勵之設定為匝道排隊車輛數，以及平均停等延滯，以達成減少匝道回堵，並增加使入目標車道之通過量。而模型運作如圖 2.2.2.14 所示。



資料來源：宋太龍(2024)

圖 2.2.2.1-14 匝道與高速公路之號誌控制訓練模型

在強化學習所需要設定的狀態、動作及獎勵中，該文獻分別做以下考量：

(一)狀態：狀態範圍通過利用車子對於路網中之車速與位置化為矩陣，使其將 2D 範圍之交通狀況降維減少模型訓練的複雜程度，並也會引用號誌狀態作為輸入使其將號誌之運行狀態也納入考量。

(二)動作：為模型之動作空間能更佳控制號誌狀態，會有以下考量：

1.針對各時相含有最小綠之考量。

2.保留原有之時相轉向設定。

3.針對時相是否轉換為下一時相，如決策要轉換為下一時相，會輸出其下一時相之秒數，而如保留當前時相，則會輸出延長綠燈之秒數。

(三)獎勵：該文獻獎勵為匝道排隊車輛數與平均停等延滯作為評價模型控制之好壞，而其中考量之參數含有匝道內之車輛數，匝道之通過量，匝道內之停等長度與匝道之容納密度。

相較於現場之時制計劃與 DQN 演算法發現通過使用 A2C 演算法能使停等車輛數降低 34.17%與 12.63%，平均停等時間減少 33.94%與 12.92%，並且回堵之發生次數與持續時間減少 51.19%與 45.06%。如圖 2.2.2.1-15 與 2.2.2.1-16。

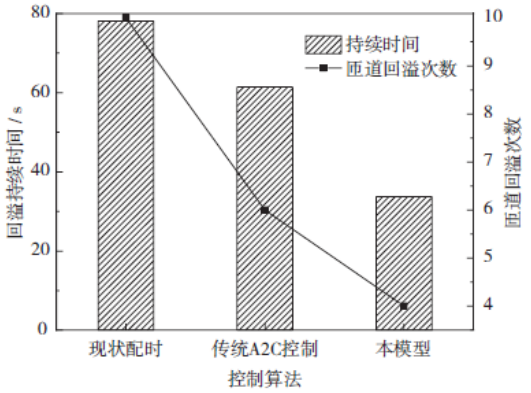


圖 2.2.2.1-15 不同控制方法針對匝道回堵次數與持續時間之統計圖

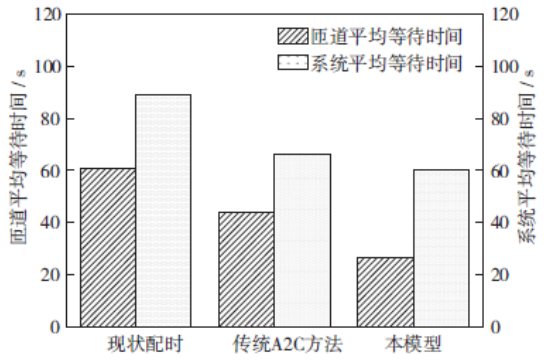


圖 2.2.2.1-16 不同控制方法針對停等時間之統計圖

資料來源：宋太龍(2024)

2.2.3 國內近期動態號誌控制研究計畫成果

一、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，2021)

過往傳統適應性號誌控制策略常面臨 3 種困境，以致難以推廣應用，包括：

(一)若欲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。

(二)控制邏輯設計大多以數學模式計算處理適應性控制問題，但目前仍無通用之數學模式。

(三)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。

為解決上述困境，該研究藉由模仿學習(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。該研究選定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作為實驗場域，並架設 AI 影像偵測設備、e-Tag 讀取器、號誌控制器及 AI IPC，並以 4G 無線通訊方式進行資料傳輸及號誌控制指令下傳。

該研究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，故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。該研究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。

二、構建5G智慧交通數位神經中樞(1/2)－功能架構探討與系統規劃(交通部運輸研究所，2022)

該研究基於國內對運用 5G 結合 AIoT 等創新科技之需求日益茁壯，期望透過 5G 高速傳輸加速跨域即時交通資料蒐集，降低資訊傳遞落差，並針對交通管理及服務進行技術盤點，開發人工智慧(AI)及大數據管理決策核心技術，迅速掌握城市人流、車流、公共運輸、交通號誌等系統即時狀況，提供即時精確的交通管理決策。為此，該研究旨在進行我國「智慧交通數位神經中樞」之都市交通控制通訊協定檢討，並遴選實作示範場域之縣市、進行整體場域之設備佈建規劃，以及進行緊急車輛之智慧號誌控制系統規劃，並整合 C-V2X 進行路口號誌控制之概念性驗證。

該研究最後建議「智慧交通數位神經中樞系統」未來必須建立端、網、霧、雲的標準平台，在這平台下須透過介面標準進行傳輸，而這樣的選用是開放的並且兼顧資安，雲平台是共享可擴充的網路且必須是安全的。未來將可透過 5G 網路，有效處理邊緣運算，無縫接軌各式各項的運輸系統雲端系統(公有雲)及營運公司雲(私有雲)，做好各類系統混和雲服務，亦可將所有整合、預測、分析、自主反應後的所有資訊傳輸到雲平台，將各項資訊整合及訊息展示，在通訊協定，或者在端設備的整合，則應同步考量相容性和整合性，進而做出「智慧交通數位神經中樞系統」的智慧決策。

除針對都市交通控制通訊協定提出檢討成果外，該研究亦在緊急車輛之智慧號誌控制系統發展之規劃與概念性驗證中提出建議，因場域以單一路口進行測試，未來將擴展至連續兩

個路口，表示 C-V2X 範圍可能涵蓋兩路口，在車輛端接受資訊需透過 GPS 確認自身位置後進行資訊過濾，確保接收正確資訊；此外，車輛端針對預估抵達路口時間需要導入較多評估與計算，例如透過 SPAT 資訊計算路口尚未紓解車輛所需秒數，此外若是採取在一時間點同時進行兩路口預估抵達時間的方式便須導入通過第一路口的時制計畫進行計算，確保 A 路口紅綠燈停等時間不會影響 B 路口的預估抵達時間。因此，整體的觸動機制與預估抵達時間息息相關，需要通盤考量設計。

三、我國人工智慧車聯網之號誌控制模式探討(交通部運輸研究所，2023)

根據上述兩案累積之研究基礎，該研究探討符合我國交通運行環境之人工智慧號誌控制模型，藉由與道路管理單位整合實作，支援其號誌控制與管理需求，期望能產生實際成效，提升車流運作效率及交通安全；此外，該研究以六都場域為目標，與管理單位交流並進行實地訪查評估，選擇於適當情境進行以下三類型場域模擬人工智慧導入號誌控制之實驗測試，包括：(1)單一路口多時相、(2)連鎖幹道、(3)車聯網環境之單一路口，地點包含臺南市「台 86-19 甲」單一路口、臺北市「中山北路-德行東路」3 個路口幹道、高雄市「台 88 鳳山出口」(過埤路-鳳頂路) 單一路口。除在上述三處場域進行交通調查，蒐集場域交通特性資料以及本計畫人工智慧號誌控制設計所需之資料項目，例如：交通量、停等延滯等，並同時採用交通模擬軟體 VISSIM 與開源模擬軟體 SUMO 分別依所蒐集場域資料建模與校估參數，作為後續人工智慧決策模型參數訓練與績效模擬測試的軟體環境。

該研究同時著重聯網車所能提供的即時資料，探討如何將該資料應用於 RL 的動態號誌控制層面。該研究所提出之人工智慧號誌控制方法將能依據各路口各方向交通變化即時演算號誌時制，而非在未知即時交通狀態下，以事先產生方式來給定號誌時制，因此號誌計畫之週期長度、續進寬帶應可動態彈性調整，以因應交通車流狀況的即時變異。

在強化學習演算法的選擇上，針對號誌控制議題應具備處理連續性決策(scalar action)的能力。該研究中所提到的兩種強化學習演算法，DDPG 與 PPO 皆為能夠應用連續性決策的演算方法，改進了過去國內強化學習號誌控制常用 DQN 離散型決策。並且在此基礎之上，能將演算法採用多代理人作法，應用至多路口場域當中。測試結果顯示不論是 DDPG 或是 PPO 在號誌問題上皆可取得良好的績效改善表現，代表該研究中對於強化學習的狀態、決策、獎勵設定合理，兩者都具備持續發展研究的價值。

四、我國人工智慧車聯網之號誌控制(1/2)-都會區幹道實作與交流道區域模式發展探討(交通部運輸研究所，2024)

根據前一年之研究，持續發展人工智慧號誌控制模式，進而與縣市政府合作進行現場實驗測試。選擇場域包含(1)單一路口多時相之臺南市「台 86-台 19 甲」(2)幹道連鎖之臺北市「中山北路 3 個路口」之幹道。除研究場域特性，亦對於實驗場域進行交通調查。

根據欲實驗場域之特性，該研究亦優化決策號誌控制策略，提到以 Q-pensive 之 RL 演算

法進行計算。過往研究提出，DDPG 可解決號誌常用的 DQN 演算法面臨的無法處理連續決策的問題，惟 DDPG 會因參數的敏感問題造成每次評論家(critic)訓練的精準度有很大的差異。PPO 則以隨機、只考慮 policy-network 的作法，減少演算法的複雜性而能夠處理高維狀態的問題，但僅考慮近期的經驗，而容易落在區域最佳解。

而該研究之 Q-Pensieve 繼承 SAC 的模型及優點，不只增加策略的探索性與隨機性，亦發展多目標的學習方法，使 Agent 能進行經驗共享。使用方法為利用 off-policy 學習並取得另外一個目標的偏好(preferences)與環境(States)和動作(Actions)，並且同時利用不同目標的 Q 值函數進行知識共享並更新同一個的策略學習。但缺點也因其龐大的 Q 值函數，導致演算法本身與神經網路架構皆較為複雜。

而在建構模擬路網時，為考量號誌產生的延滯、通過量的績效的數據變化，該研究建構微觀車流模擬模型，並考量調查之交通參數作為輸入，以觀察細部路口之影響。亦進行模擬模型調校，以模擬模型及實際調查之通過量作為校估基準。除了欲考量路口及路廊，在都會區幹道場域，亦建構幹道路網鄰近的支道，考量主幹道控制策略對於周遭可能帶來的影響。

以該研究之臺北市實驗場域為例，其 AI 號誌控制模型由一個代理人(Agent)控制三個路口，分別為中山北六段/克強路口、中山北六段/195 巷、中山北六段/德行西路口，因三個路口由一個代理人(Agent)決策，決策時間點三個路口必須相同。因此，決策頻率為此三個路口週期結束時決策，此三個路口週期會一致，輸入為上個週期路口週期秒數、各分相之比例及 AI 控制路口分車道分車種的總車輛數及停等車輛數，輸出則為下個週期此三個路口的週期秒數及各個分相的比例。

表 2.2.3-1 臺北市實驗場域 AI 強化學習模型設計

代理人數量(Agent)	狀態(State)	決策(Action)	獎勵(Reward)
1	1. 上個週期路口週期秒數及時向比例 2. AI 控制路口各分項結束時，各車道分車種之停等車輛數及總車輛數	下個週期 AI 控制路口之週期秒數及時相比例	1. 幹道延滯時間與固定時制的變化量 2. 支道延滯時間與固定時制的變化量 3. 幹道通過量與固定時制的變化量 4. 支道通過量與固定時制的變化量

資料來源：交通部運輸研究所(2024)

該研究之策略模型於模擬環境測試過後，亦於實驗場域進行實地測試，於臺南市(單一路口實驗場域)及臺北市(幹道實驗場域)進行平日各兩日、上下午尖峰及離峰及假日昏峰共四個時段，兩場域共計 4 日之現地實測。

(一) 臺南市實驗場域

平日時段，晨昏峰路口整體延滯減少 5.4 秒~7.3 秒，服務水準自 C 級升到 B 級，離峰時段，路口整體延滯略微增加 0.7 秒，但服務水準仍然維持 B 級水準。假日昏峰

11 月 4 日(六)較 11 月 11 日(六)路口整體延滯增加 16.1 秒，服務水準自 B 級降到 C 級；11 月 5 日(日)較 11 月 12 日(日)路口整體延滯增加 8.3 秒，服務水準自 B 級降到 C 級，兩天假日 AI 號誌控制模型表現較 TOD 表現略差。平日 11 月 7 日(二)AI 號誌控制模型於晨峰及昏峰表現都略優於 11 月 14 日，隔天 11 月 8 日(三)AI 號誌控制模型於晨峰出現兩處峰期，且昏峰表現較 11 月 15 日略差；假日 AI 號誌控制模型旅行時間表現皆略較 TOD 表現為差。此情形亦對應在延滯表現上，唯路口服務水準尚維持在 C 級以上，車流運行尚算通順。

(二) 臺北市實驗場域

平日 11 月 16 日(四)AI 號誌控制服務水準皆與 11 月 23 日維持一樣的水準，惟平日 11 月 20 日(一)195 巷及德行西路晨峰服務水準分別自 A 級降至 B 級，B 級降至 C 級，但昏峰德行西路服務水準自 D 級提升至 C 級，路口延滯減少 9.5 秒。假日昏峰 AI 號誌控制平均延滯皆較 TOD 略差，但服務水準大多維持不變，僅 11 月 19 日(日)195 巷及德行西路服務水準分別從 A 降到 B、C 降到 D。平日 11 月 16 日(四)AI 號誌控制模型除於晨峰因系統與設備多次斷線，導致旅行時間較 TOD 為高外，離峰及昏峰的表現雖略差，但都大致符合 TOD 走勢。假日兩天旅行時間績效 AI 號誌控制模型皆略差於 TOD。

(三) 實測後建議

該研究依據實測結果彙整出建議如下：

1. 加強 AI 號誌控制模型演算法、輸入狀態、輸出決策之探討，可考慮增加時制計畫改變的因應方式，並納入調整時相順序、與鄰近群組連鎖、時差續進之因素，以使人工智慧強化學習在號誌控制應用上更具彈性與全面性。

2. 目前模型控制仍受限於時段切分，各自開發，係受不同時段使用之時制計畫或時相組態差異所致，雖目前多任務強化學習模式尚無法比分開訓練的模型績效好，後續建議持續進行跨時段多任務 AI 號誌控制模型(Task Aware)整合建構與優化精進，減少因時段切分或時制計畫改變而增加 AI 號誌控制模型訓練次數，希望透過加強訓練，以獲得泛用型(全時段)AI 號誌控制模型。

3. 於 AI 號誌控制模型訓練中納入行人資訊，以探討行人安全之影響，並將常見之行人專用時相、行人影響右轉車輛納入模擬考量。

2.3 人工智慧強化學習(Reinforcement learning, RL)模式

2.3.1 強化學習架構與演算法

強化學習是一種機器學習方法，目的在訓練學習者 (learner) 從未知且具有隨機性的動態環境 (dynamical environment) 中，學習最佳順序性策略以達成特定目標，該方法通過讓學習者在環境中不斷地進行試驗和錯誤，從而學習什麼是正確的動作，進而將其與環境相關聯以實現目標。具體來說，強化學習是能讓學習者透過對環境進行一系列的動作，以使得獲得的累積獎勵 (cumulative reward) 最大化的學習方式。學習的目標為以迭代方式持續改善目前的策略 (policy)，透過不斷的訓練，期望能夠獲得最佳策略 (optimal policy)。學習方式是透過學習者對環境執行動作 (Action) 後，環境會回傳獎勵 (Reward) 和新的狀態 (State)，不斷進行此程序以逐漸優化策略，如圖 2.3.1-1 所示。在交通號誌控制問題場景，強化學習可以透過訓練來適應不同的交通情況，例如調整紅綠燈的時間，以達到最優化的交通流暢度和效率。

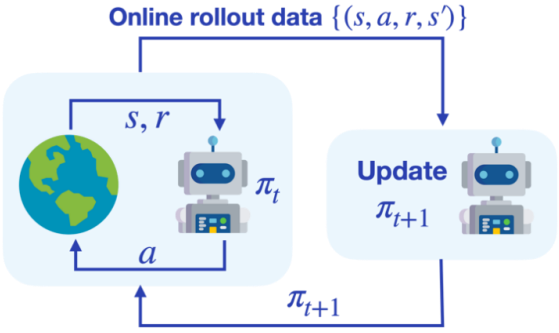


圖 2.3.1-1 強化學習概念示意圖

強化學習最常使用之動態環境模型為馬可夫決策過程 (Markov Decision Process，簡稱 MDP)，而標準的 MDP 包含以下要素(Bellman, 1957)：

一、環境狀態集合S，在每個時刻t 環境的狀態表示為$S_t \in S$。

二、動作集合A，為學習者能採取之動作，在觀察到當前狀態S_t後，學習者會選擇一個行動$A_t \in A$。

三、獎勵函數 $R(\cdot,\cdot): S \times A \to R$其定義為 $R(s,a) = E[R_{t+1}|S_t = s, A_t = a]$，描述在狀態$s$採取行動$a$後預期獲得的立即獎勵期望值，此外使用$R_{t+1}$來描述在每個時刻$t$下，觀察狀態$S_t$後採取$A_t$所得到之獎勵。

四、狀態轉移函數$P(\cdot,\cdot,\cdot): S \times A \times S \to [0,1]$，其定義為$P(s,a,s') = P[S_{t+1} = s'|S_t = s, A_t = a]$，滿足馬可夫性質 (Markov property)，亦即當下狀態的轉移機率僅與當下狀態與動作有關而與其他歷史資訊無關。

五、初始狀態分佈ρ。

六、$\gamma \in [0,1]$ 為獎勵折扣因子，旨在反映未來獎勵的「現在」價值。

為評估學得策略，強化學習常使用以下狀態價值函數 (state-value function) 與動作價值函數 (action-value function) 於演算法設計：

$$V^{\pi}(s) \coloneqq E_{\pi}[\sum_{k=0}^{\infty} \gamma^{k} R_{k+1} | S_0 = s]$$

$$Q^{\pi}(s,a) \coloneqq E_{\pi}[\sum_{k=0}^{\infty} \gamma^{k} R_{k+1} | S_0 = s, A_0 = a]$$

以上兩個價值函數皆在反映在某狀態下採取該策略之長期累積獎勵。從價值函數的角度出發，強化學習的目標也可描述為尋找能使價值函數最大化之策略，亦即尋找$Q^{*}(s,a) = \underset{\sim}{max}\, Q(s,a)$或$V^{*}(s) = \underset{\sim}{max}\, V(s)$。或以隨機梯度下降法(stochastic gradient descent)，使系統總停等延滯期望值最小化的方向更新類神經網路參數 θ。

以上是基於強化學習(Reinforcement Learning，後簡稱 RL)方法論之應用，而在本計畫中所採用之演算法在 RL 領域中的歸類屬於類似 Actor-Critic 的學習架構，因此需要明確定義狀態(State)、決策(Action)、 獎勵(Reward)，方能使整套方法合理運作。上述 AI 號誌控制訓練演算基本模型如圖 2.3.1-2 所示，而相關強化學習演算法的詳細說明如 2.3.3 節說明。

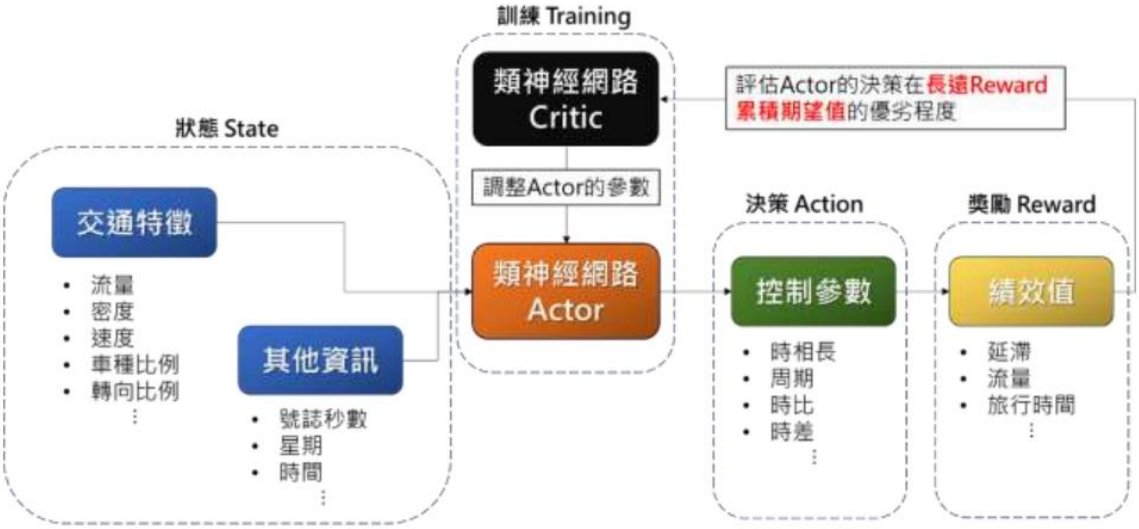


圖 2.3.1-2 號誌控制架構基本模型

強化學習方法可根據切入角度大致可分為以下幾個主要類別：

一、基於動態模型之強化學習(model-based RL)：

強化學習其中一個基礎且直觀的切入角度為對於 MDP 進行「基於學習之最佳控制」(learning-based control)。在標準的最佳化控制問題設定，控制器演算法的主要目標為在給定環境的動態模型資訊的情形下，透過迭代式的演算法進行規劃 (planning) 以逐步找出最佳決策，其中最常見的方式包含策略迭代法 (policy iteration) 與價值迭代法 (value iteration)，這類迭代方法皆基於前一章節介紹之 Bellman equations 之原理來設計。由於強化學習需在未知環境中做決策，基於動態模型之強化學習會透過以下兩個主要程序之交替運作來改善決策：

(一)學習與估計環境之動態模型

Janner et al(2019) [23]先基於與環境互動所得到之軌跡資料，來估計環境之狀態轉移機率以及獎勵函數，此項任務可透過監督式學習方法來達成，比如最大似然估計(maximum likelihood estimation)。具體來說，若將估計之動態模型以$\mathcal{M}_\theta$做參數化表示，則於t 時間下之動態模型可估計為

$$\theta_t^{\text{MLE}} \coloneqq \arg\max_\theta \prod_{i=1}^{t} p(s_i, s_{i+1}, a_i; \theta),$$

在實際應用中，此動態模型$\mathcal{M}_\theta$會使用深度神經網路來表現與參數化，而上式之最大值可透過常用的隨機梯度下降法來取得。

(二)基於估計之動態模型進行規劃

基於目前得到之$\mathcal{M}_\theta$，學習者可使用任一最佳控制之規劃方法(比如價值迭代) 來取得此模型對應之最佳決策。

儘管此類方法相當直觀，但基於動態模型之學習往往需要克服以下幾點挑戰。首先是「探索」問題，為了使動態模型的估計準確，必須確保學習者與環境互動取得之軌跡是足夠多元且包含環境之大部分區域，此一問題常透過使用強調探索之策略來收集軌跡或是引進樂觀估計 (optimism) 來解決，比如常使用的 Upper-Confidence RL 方法。再者，由於環境本身的隨機性，要足夠準確地估計動態模型往往相當困難，如何著重估計與最佳策略直接相關的環境部分是一大挑戰。

二、無動態模型之強化學習(model-free RL)-價值型方法(value-based methods)：

與基於模型的強化學習不同，價值型的強化學習並不仰賴動態模型估計，而是通過學習來逼近最佳之價值函數。比如，著名的 Q-learning 方法即為透過維持對最佳動作價值的估計來學習，具體作法為每個時刻基於所觀察得到之環境狀態與獎勵，進行以下迭代更新：

$$\mathrm{Q}(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha_t(s_t, a_t)\left(r_{t+1} + \gamma \max_{a'} Q\left(s_{t+1}, a'\right) - Q(s_t, a_t)\right)$$

其中$\alpha_t(s_t, a_t)$為 learning rate。值得一提的是，Q-learning 方法有兩大特色：(1) 此方法不需使用動態模型，因此為 model-free，(2) 此方法可支援 off-policy 學習，亦即與環境互動之策略可與學習得到的策略不同，此特色可使強化學習在資料取得上更有彈性。在實際應用上，Q-learning 往往需配合深度神經網路來實現，此方法稱為深度 Q 網路 (Deep Q network, 或簡稱 DQN)，其具體作法為將原始的 Q-learning 更新轉換為最小化以下損失函數(Mnih et al., 2013) [35]：

$$\mathrm{L}_{\mathrm{DQN}}(\phi) \coloneqq E_{(s,a,s',r)}\left[\left(\left(r + \gamma \max_{\mathrm{a}' \in \mathrm{A}} Q(s', a'; \phi^-)\right) - Q(s, a; \phi)\right)^2\right]$$

三、無動態模型之強化學習(model-free RL)–策略最佳化方法(policy optimization methods)：

與價值型方法不同，策略最佳化是將強化學習視為一個最佳化問題，亦即對總預期獎勵 $V^{\pi}(\rho) := E_{s\sim\rho}[V^{\pi}(s)]$進行最佳化。首先，策略最佳化方法從參數化策略開始，即$\pi(a|s) \equiv \pi_{\varphi}(a|s)$，其中$\varphi$為策略參數，在實際應用中目前最常用的策略參數化方式是使用深度神經網路 (Lillicrap, et al., 2016) [29]，常見的形式為

$$\pi_{\varphi}(a|s) = \frac{\exp\left(f_{\varphi}(s,a)\right)}{\sum_{a'\in A}\exp\left(f_{\varphi}(s,a')\right)}$$

其中f_{φ}代表深度神經網路之輸出值。至於更新策略的方式可舉一個例子來說明，目前廣泛使用的策略最佳化方法之一是隨機策略梯度演算法 (stochastic gradient ascent)，策略梯度方法的基本理論結果是策略梯度定理 (policy gradient theorem)，$\nabla_{\varphi}V_{\varphi}^{\pi}(\rho)$ 具有封閉形式的表達如下：

$$\nabla_{\varphi}V^{\pi_{\varphi}}(\rho) = E_{\pi_{\varphi}}\left[\nabla_{\varphi}\log\pi_{\varphi}(s,a)Q^{\pi_{\varphi}}(s,a)\right]$$

為了取得或估計以上之策略梯度，我們還需要估計動作價值函數，例如可透過蒙特卡羅方法 (Monte Carlo methods) 或時間差分方法 (temporal difference methods) 來估計 (Mnih, et al., 2016)。

相較於價值型方法，策略最佳化的主要優點有兩個：(1) 策略最佳化可以學習非確定性策略 (non-deterministic policy)，這是價值型方法 (如 Q-learning) 無法實現的；(2) 策略最佳化較容易處理連續動作控制 (continuous control) 問題，相較之下價值型方法之決策流程由於包含對動作價值函數取最大值而較不易處理連續動作，往往需要仰賴額外的離散化或是以抽樣方式來近似最大值。

考量本計畫交通號誌調控為連續動作控制，後續說明將著重介紹與本計畫執行相關之策略最佳化演算法。

四、DDPG (Deep Deterministic Policy Gradient, 深度確定性策略梯度法)

所謂 RL 訓練演算法，在此定義為從代理人(Actor)類神經網路初始化狀態，逐步更新其類神經網路中權重(weight)與偏差(bias)，使其達到最終能夠處理任務的一系列過程中所採用的計算方法，例如於 2.3.2 節中所介紹各種方法。是基於深度確定性策略梯度法(Deep Deterministic Policy Gradient) (以下簡稱 DDPG)訓練演算法，在 off-policy 的 Actor-Critic 架構下所加以修改成多代理人版本，並且亦加入了許多諸如目標網路、經驗回放等訓練技術，集結合成的獨特訓練演算法。在本節將會以既有文獻中最為接近之方法 DDPG，來做演算法的概念說明。

DDPG 是屬於 Actor-Critic 類的一種方法分支，其重點特徵在於「確定性(Deterministic)」的特性，該特性能更有效的提升傳統 Stochastic Policy Gradient 類的訓練效率。要了解這項特殊的作法之前，必須先了解原始 Actor-Critic 的基本背景架構。

$Ep\,(X)\ =\ \int\ PiXi$ 式(1)

Actor 的目標是最大化累計獎勵的期望值，在機率分布 P 當中，某個隨機變數 X 的期望值可以用式(1)表示。其中Xi是所有 X 的可能性，而Pi則是對應該Xi的機率密度函數。而 Actor 的期望回報，就可用下式定義：

$V(s)\ =\ E\pi(s)\,[r\ +\ \gamma V(s')]$ 式(2)

其中s為當前狀態；s'為下一個狀態；r為這個轉移過程中所產生的立即獎勵；γ為折減比例，介於 0~1 間；π為當下 Actor 的 policy。式(2)即為著名的 Bellman equation 的估值函數。這時候可以將式(2)改定義一個 Q 值的函數：

$Q(s,a)\ =\ r\ +\ \gamma V(s')$ 式(3)

式(3)中本質與式(2)是相同的概念，僅是將原本 policy π 的部分視為變數的一部分。為了衡量目前這個 policy π 的優劣程度，因此定義一個 $J(\pi)$的函數，來表示這個策略從起始狀態 $s0$ 開始到任務結束所能獲得的累積獎勵期望值。

$J(\pi)\ =\ E(V(s0\,))$ 式(4)

梯度函數可以被表示為

$$\begin{aligned}\nabla_\theta J(\pi_\theta) &= \int_S \rho^\pi(s) \int_A \nabla_\theta \pi_\theta(a|s) Q^\pi(s,a)\mathrm{d}a\mathrm{d}s \\ &= \mathbb{E}_{s\sim\rho^\pi, a\sim\pi_\theta}\left[\nabla_\theta \log \pi_\theta(a|s) Q^\pi(s,a)\right]\end{aligned} \quad \text{式(5)}$$

式(5)中， S 為狀態的集合空間；

$\rho^\pi(s)$為狀態在策略π下的機率分佈函數； A 為決策的集合空間； θ為策略參數。

式(5)的梯度函數，是基於未來決策仍是隨機，或是說仍無法確定決策為何的狀態下，所推導出之梯度近似值。然而很直覺的，由於 Actor 的目標即是去獲取最大利益的一種策略，因此在式(5)中其實對於未來的策略未必是隨機的，而可以直接用 policy 去產出未來的決策。在此概念之下，梯度函數可以被改寫為：

$$\begin{aligned}\nabla_\theta J\,(\mu_\theta) &= \int_S \rho^\mu(s) \nabla_\theta \mu_\theta(s) \nabla_a Q^\mu(s,a)\Big|_{a=\mu_\theta(s)} ds \\ &= \mathbb{E}_{s\sim\rho^\mu}\left[\nabla_\theta \mu_\theta(s) \nabla_a Q^\mu(s,a)|_{a=\mu_\theta(s)}\right],\end{aligned} \quad \text{式(6)}$$

至此，便可以以 Actor-Critic 的架構來進行梯度下降的策略更新：

$$\delta_t = r_t + \gamma Q^\omega(s_{t+1}, \mu_\theta(s_{t+1})) - Q^\omega(s_t, a_t), \quad \text{式(7)}$$

$$\omega_{t+1} = \omega_t + \alpha_\omega \delta_t \nabla_\omega Q^\omega(s_t, a_t), \quad \text{式(8)}$$

$$\theta_{t+1} = \theta_t + \alpha_\theta \nabla_\theta \mu_\theta(s_t) \nabla_a Q^\omega(s_t, a_t)|_{a=\mu_\theta(s_t)}, \quad \text{式(9)}$$

DDPG 的運作架構可參考圖 2.3.1-3。值得注意的是，輸入 Critic 與輸入 Actor 的 State 變數，兩者是相同的。此舉是為了確保 Actor 與 Critic 獲得的資訊量是相同的。若兩者所獲得

的資訊程度不相同，例如 Critic 有額外的資訊輸入，則可能會造成 Critic 能夠判斷更新方向，但 Actor 卻無法判斷 State 情境的差異，致使 Actor 更新方向不明確的狀況發生。所以採用 Actor-Critic 訓練方法時，即使 Actor 與 Critic 的網路結構可能有巨大的差異，但輸入資訊則會盡可能的保持一致。在上述作法下，完整 DDPG 演算法運作架構可以圖 2.3.1-4 表示。

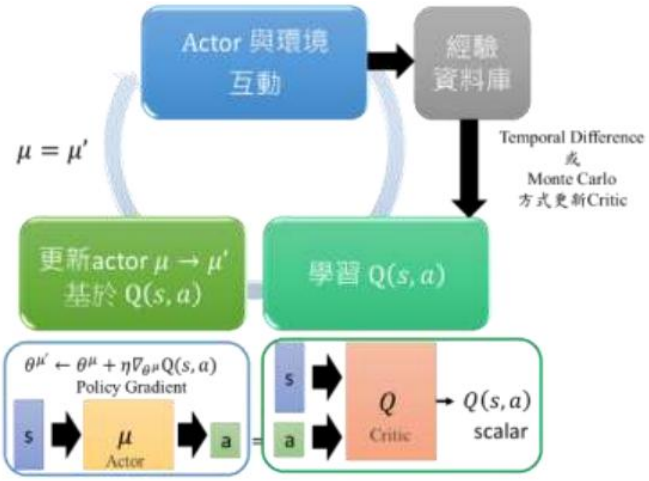


圖 2.3.1-3 DDPG 運作架構

Algorithm DDPG algorithm

Randomly initialize critic network $Q(s, a|\theta^Q)$ and actor $\mu(s|\theta^\mu)$ with weights θ^Q and θ^μ.
Initialize target network Q' and μ' with weights $\theta^{Q'} \leftarrow \theta^Q$, $\theta^{\mu'} \leftarrow \theta^\mu$
Initialize replay buffer R
for episode = 1, M **do**
  Initialize a random process $\mathcal{N}$ for action exploration
  Receive initial observation state s_1
  for t = 1, T **do**
    Select action $a_t = \mu(s_t|\theta^\mu) + \mathcal{N}_t$ according to the current policy and exploration noise
    Execute action a_t and observe reward r_t and observe new state s_{t+1}
    Store transition (s_t, a_t, r_t, s_{t+1}) in R
    Sample a random minibatch of N transitions (s_i, a_i, r_i, s_{i+1}) from R
    Set $y_i = r_i + \gamma Q'(s_{i+1}, \mu'(s_{i+1}|\theta^{\mu'})|\theta^{Q'})$
    Update critic by minimizing the loss: $L = \frac{1}{N}\sum_i (y_i - Q(s_i, a_i|\theta^Q))^2$
    Update the actor policy using the sampled policy gradient:

$$\nabla_{\theta^\mu} J \approx \frac{1}{N} \sum_i \nabla_a Q(s, a|\theta^Q)|_{s=s_i, a=\mu(s_i)} \nabla_{\theta^\mu} \mu(s|\theta^\mu)|_{s_i}$$

    Update the target networks:

$$\theta^{Q'} \leftarrow \tau\theta^Q + (1-\tau)\theta^{Q'}$$
$$\theta^{\mu'} \leftarrow \tau\theta^\mu + (1-\tau)\theta^{\mu'}$$

  end for
end for

圖 2.3.1-4 DDPG 演算法

以下說明部分訓練技巧，技巧並非僅限於 DDPG 訓練演算法中適用，更像是一些通用的實用方法。

(一)目標網路(Target Network)

在更新 Critic 的過程中，需要納入 s′的 Q 估值，然而若 Critic 處於一個高頻率更新參數的狀態下，也會使 s′的估值非常不穩定，從而導致 Critic 的訓練過程中無法收斂。

目標網路(Target Network) 的概念即是產生另一個與 Critic 結構完全相同的類神經網路，稱為 Target Critic。在參數更新的時候僅針對 Critic 進行梯度更新，而 Target Critic 則完全不改動，使 s′的 Q 估值保持穩定。而每隔一段時間再將 Target Critic 更新成最新狀態的 Critic，重複此步驟。除了一段時間更新 Target Critic，另有一種常見的作法稱為 soft update，即每次更新時 Critic 與 Target Critic 都接受梯度更新，但 Target Critic 更新的幅度僅為 Critic 的千分之 1 (該數值可由訓練者自訂)，限制 Target Critic 每次變動的幅度，從而達到穩定 s′的 Q 估值的目的。

(二)經驗回放(Experience Replay)

是 off policy 中常用的一種提升樣本效率的做法，其方法即為記錄所有代理人與環境互動過程中的(s,a,r,s′)轉移樣本，集結成一個巨大的經驗資料庫。在訓練過程中則從中隨機抽取一定數量的樣本訓練 Critic 或 Actor。經驗回放法能夠有效地重複多次使用同一筆樣本，因此能有更有效的應用蒐集來的資料。

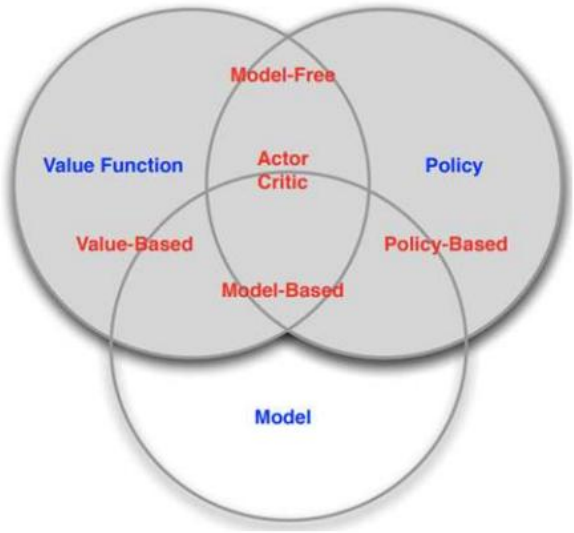
(三)優先經驗回放(Prioritization Experience Replay)

是經驗回放法的改良作法，原始方法中是從資料庫中以隨機的方式抽取一定數量的樣本來做梯度更新。然而當訓練進入後期，資料庫中大多數的樣本都已經非常好的配適當前的估值函數，僅少部分的樣本仍未能有效的配適。

若以隨機的方式抽取則較難抽到這些配適度較低的樣本，因此優先經驗回放方法即是去計算所有樣本的配適程度(loss 值)，並且賦予配適程度較差的樣本有較高的機率被 抽中的一種機制，使訓練過程可以更快速的配適所有資料庫中的樣本。

五、PPO (Proximal Policy Optimization, 近端策略優化)

所採用的第二種 RL 演算法為 OpenAI 於 2017 所提出的近端策略優化(Proximal Policy Optimization, 以下簡稱 PPO)。PPO 同樣是 Actor-Critic 架構的演算法，其結合價值函數(Value function)與策略函數(Policy)的技巧，如圖 2.3.1-5 所示，二函數均以類神經網路表示。訓練過程是藉由與環境 互動過程產生的軌跡，進行二函數的參數更新。價值函數路網的參數是朝向和估計值的均方差變小的方向更新，策略函數的參數則是朝向系統期望獎勵最大化的方向進行更新。



資料來源：Silver, D., Lectures on Reinforcement Learning https://www.davidsilver.uk/teaching/, 2015

圖 2.3.1-5 RL 代理人類型

更新 Actor 的策略梯度(policy gradient)通常使用隨機梯度上升法(stochastic gradient ascent)，常見的梯度估計值為：

$$\hat{g} = \hat{E}_t[\nabla_\theta log\pi_\theta(a_t|s_t)\hat{A}_t] \quad \text{式(10)}$$

其中$\pi\theta$ $(at\ |st\ )$為隨機策略(stochastic policy)，亦即在st的狀態下產出決策at 的機率，θ是此策略函數的參數。$\hat{A}\,t$則是步階t的優勢函數(advantage function)估計值。實際應用時，透過建構目標函數，軟體可自動計算出式(10)的梯度方向$\hat{g}$。目標函數形式如下：

$$L^{PG}(\theta) = \hat{E}_t[log\pi_\theta(a_t|s_t)\hat{A}_t] \quad \text{式(11)}$$

實務上用同個軌跡(trajectory)對此目標式進行數次最佳化時，常導致破壞性的大幅度策略更新(destructively large policy updates)。為解決此問題，TRPO 提出在目標式下加入 KL-divergence 的限制式，以限縮策略更新的幅度，其數學規劃式如下。

$$\max_\theta \hat{E}_t\left[\frac{\pi_\theta(a_t|s_t)}{\pi_{\theta_k}(a_t|s_t)}\hat{A}_t\right] \quad \text{式(12)}$$

$$s.t.\,\hat{E}_t\left[KL\left[\pi_{\theta_k}(\cdot|s_t),\pi_\theta(\cdot|s_t)\right]\right] \le \delta \quad \text{式(13)}$$

此處θk是更新前的策略參數。此數學規劃式可透過對目標式的線性估計及限制式的二次估計，以共軛梯度法(conjugate gradient algorithm)求取近似解。而在同樣的背景動機下，PPO 則是應用其他技巧使新舊策略不至於差異過大，且相較於 TRPO，PPO 顯著地較易應用，其績效表現至少和 TRPO 一樣好。

PPO 使用的目標式$LClip$如下：

$$\frac{1}{|D_k|T}\sum_{\tau\in D_k}\sum_{t=0}^{T} min\left(r_t(\theta)\mathrm{A}^{\pi_{\theta_k}}(s_t,a_t), clip(r_t(\theta),1-\varepsilon,1+\varepsilon)\mathrm{A}^{\pi_{\theta_k}}(s_t,a_t)\right) \quad (14)$$

$$\text{其中，} r_t(\theta)=\frac{\pi_\theta(a_t|s_t)}{\pi_{\theta_k}(a_t|s_t)} \quad (15)$$

$r_t(\theta)$是新舊策略在給定s_t時產生a_t的機率的比率。從目標式L^{Clip}可看出，首項$r_t(\theta)\mathrm{A}\ \pi\theta k(s_t, a_t)$與(12)相同，第二項則是將$r_t(\theta)$限制在$[1-\varepsilon,1+\varepsilon]$的區間，最後取此二項的最小值。圖 2.3.1-6 分別對優勢函數大於零及小於零的情況，繪製L^{Clip}和r值的關係圖，紅點是r值的初始位置(初始時新舊策略相同，所以r值為 1)。PPO 目標式L^{Clip}的設計可讓$r_t(\theta)$值在超出$[1-\varepsilon,1+\varepsilon]$時，目標式對$r(\theta)$的梯度為 0，藉此產生使新舊策略差異不至於過大的效果。圖 2.3.1-6 之左圖為當$A>0$時，$r(\theta)$往右側移動至$1+\varepsilon$後便無法再增加L^{Clip}，避免$r(\theta)$過大。圖 2.3.2-4 之右圖為當$A<0$時，$r(\theta)$往左側移動至$1-\varepsilon$後便無法再減少L^{Clip}，避免$r(\theta)$過小。

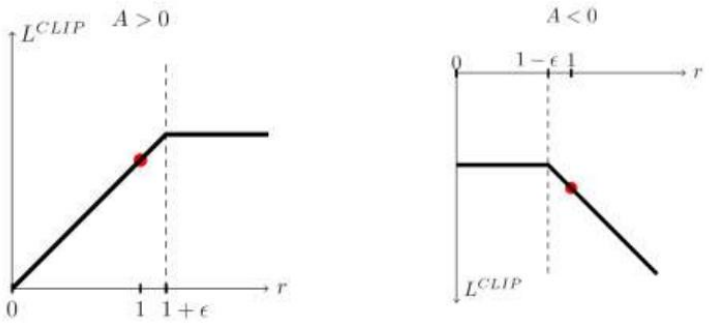


圖 2.3.1-6 PPO 的目標式L^{Clip}與$r(\theta)$的關係圖

PPO 也是使用 Actor-Critic 架構的方法，運作架構如圖 2.3.1-7 所示，演算法說明如圖 2.3.1-8 所示。先以隨機策略$\pi_{\theta k}$跟環境互動取得軌跡τi後，計算軌跡中各時階t的未來獎勵總值$R\hat{}t$以及優勢函數$A\hat{}t$。接著便可針對式(14)使用梯度上升法更新θ，再以梯度下降法更新 Critic 的參數ϕ。

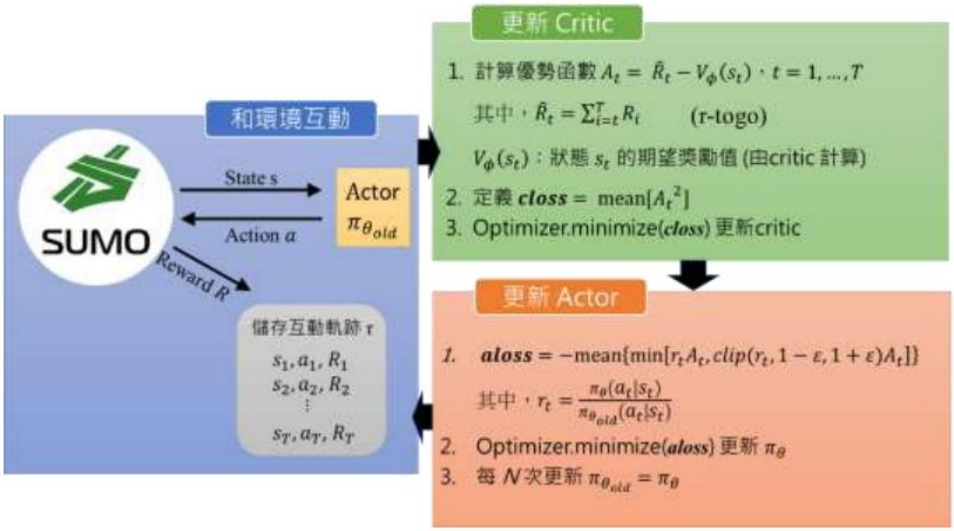


圖 2.3.1-7 PPO 運作架構圖

Algorithm 1 PPO-Clip

Input: initial policy parameters θ_0, initial value function parameters ϕ_0
for $k = 0, 1, 2, \ldots$ **do**
  Collect set of trajectories $\mathcal{D}_k = \{\tau_i\}$ by running policy $\pi_k = \pi(\theta_k)$ in the environment.
  Compute rewards-to-go $\hat{R}_t$.
  Compute advantage estimates, $\hat{A}_t$ (using any method of advantage estimation) based on the current value function V_{ϕ_k}.
  Update the policy by maximizing the PPO-Clip objective:

$$\theta_{k+1} = \arg\max_{\theta} \frac{1}{|\mathcal{D}_k|T} \sum_{\tau \in \mathcal{D}_k} \sum_{t=0}^{T} \min\left(\frac{\pi_\theta(a_t|s_t)}{\pi_{\theta_k}(a_t|s_t)} A^{\pi_{\theta_k}}(s_t, a_t),\ \ g(\epsilon, A^{\pi_{\theta_k}}(s_t, a_t)) \right),$$

  typically via stochastic gradient ascent with Adam.
  Fit value function by regression on mean-squared error:

$$\phi_{k+1} = \arg\min_{\phi} \frac{1}{|\mathcal{D}_k|T} \sum_{\tau \in \mathcal{D}_k} \sum_{t=0}^{T} \left(V_\phi(s_t) - \hat{R}_t \right)^2,$$

  typically via some gradient descent algorithm.
end for

圖 2.3.1-8 PPO 演算法

DDPG 與 PPO 算法分別由著名的 Google DeepMind 與 OpenAI 提出，詳細比較如後續章節說明。DDPG 能輸出確定性決策，並改善 DQN 難以應用在連續型決策空間的缺點，且其沿用 DQN 的經驗回放等技巧，大幅提升樣本使用率。而 PPO 的 Actor 則是輸出隨機策略，透過目標式加入上下界的技巧避免策略更新變化太大，並藉 importance sampling 提升樣本使用率。

OpenAI 將 PPO 當作 baseline 算法，並且著名的 OpenAI 亦使用 PPO 作為核心算法。因此該研究除應用類似 DDPG 的訓練演算法外，亦嘗試使用 PPO 訓練 AI 號誌代理人。

六、SAC (Soft-Actor Critic,軟性動作-評論演算法)

軟性動作-評論演算法(Soft-Actor Critic，以下簡稱 SAC)，SAC 也是屬於 Actor-Critic 類的一種方法分支架構的演算法，而此演算法的重點在於其納入了熵度量(Entropy)進回報函數(Reward)以提高探索率，並希望能學習到一種盡可能隨機行動的策略，也同時能夠完成任務目標。

相比於 PPO 與 DDPG，其目標的學習目標很直接，就是利用策略(policy)並以式(16)使回報期望值得到最大。而最大熵則是利用式(16)並以其為基礎進行更新使式(17)要求策略的動作(Action)的熵與回報期望值為最大。

$$\sum_t \mathbb{E}_{(\mathbf{s}_t, \mathbf{a}_t) \sim \rho_\pi} \left[r(\mathbf{s}_t, \mathbf{a}_t) \right] \qquad \text{式(16)}$$

$$\pi^* = \arg\max_{\pi} \sum_t \mathbb{E}_{(\mathbf{s}_t, \mathbf{a}_t) \sim \rho_\pi} \left[r(\mathbf{s}_t, \mathbf{a}_t) + \alpha \mathcal{H}(\pi(\cdot|\mathbf{s}_t)) \right], \qquad \text{式(17)}$$

至此，便能以此掌控每次動作與策略更新時的隨機性，由於此原因，策略的決策與執行方

程式與演算法也會造成改變，詳細會在以下進行說明。

策略 Action 與執行都是以 Bellman equation 為基礎，而加入熵並承上 α 係數會計算新的 Q 值函數(式[18])。

$$Q_{soft}(s_t, a_t) = r(s_t, a_t) + \gamma \mathbb{E}_{s_{t+1}, a_{t+1}} [Q_{soft}(s_{t+1}, a_{t+1}) - \alpha \log(\pi(a_{t+1}|s_{t+1}))] \quad \text{式(18)}$$

但要記住此算式是以舊回報值為基礎而計算的。而如果把熵回報加入係數裡，就能得出此策略的 Q 值函數更新法(式[19、20])。

$$\mathcal{T}^{\pi} Q(\mathbf{s}_t, \mathbf{a}_t) \triangleq r(\mathbf{s}_t, \mathbf{a}_t) + \gamma \, \mathbb{E}_{\mathbf{s}_{t+1} \sim p} [V(\mathbf{s}_{t+1})], \quad \text{式(19)}$$

$$V(\mathbf{s}_t) = \mathbb{E}_{\mathbf{a}_t \sim \pi} [Q(\mathbf{s}_t, \mathbf{a}_t) - \alpha \log \pi(\mathbf{a}_t|\mathbf{s}_t)] \quad \text{式(20)}$$

推導過程可參考式[18]。

而能使其策略能收斂，Haarnoja 等人利用了目標數值的最小化(KL Divergence)來趨近最佳的 Q 值函數 $\exp(Q^{\pi}_{soft}(s_t, \cdot))$ 並取得式(21)的策略更新方程式。

$$\pi_{\text{new}} = \arg\min_{\pi' \in \Pi} \mathrm{D}_{\mathrm{KL}} \left(\pi'(\cdot|\mathbf{s}_t) \,\middle\|\, \frac{\exp\left(\frac{1}{\alpha} Q^{\pi_{\text{old}}}(\mathbf{s}_t, \cdot)\right)}{Z^{\pi_{\text{old}}}(\mathbf{s}_t)} \right) \quad \text{式(21)}$$

Algorithm 1 Soft Actor-Critic

Input: θ_1, θ_2, ϕ ▷ Initial parameters
$\bar{\theta}_1 \leftarrow \theta_1, \bar{\theta}_2 \leftarrow \theta_2$ ▷ Initialize target network weights
$\mathcal{D} \leftarrow \emptyset$ ▷ Initialize an empty replay pool
for each iteration **do**
  for each environment step **do**
    $\mathbf{a}_t \sim \pi_\phi(\mathbf{a}_t|\mathbf{s}_t)$ ▷ Sample action from the policy
    $\mathbf{s}_{t+1} \sim p(\mathbf{s}_{t+1}|\mathbf{s}_t, \mathbf{a}_t)$ ▷ Sample transition from the environment
    $\mathcal{D} \leftarrow \mathcal{D} \cup \{(\mathbf{s}_t, \mathbf{a}_t, r(\mathbf{s}_t, \mathbf{a}_t), \mathbf{s}_{t+1})\}$ ▷ Store the transition in the replay pool
  end for
  for each gradient step **do**
    $\theta_i \leftarrow \theta_i - \lambda_Q \hat{\nabla}_{\theta_i} J_Q(\theta_i)$ for $i \in \{1, 2\}$ ▷ Update the Q-function parameters
    $\phi \leftarrow \phi - \lambda_\pi \hat{\nabla}_\phi J_\pi(\phi)$ ▷ Update policy weights
    $\alpha \leftarrow \alpha - \lambda \hat{\nabla}_\alpha J(\alpha)$ ▷ Adjust temperature
    $\bar{\theta}_i \leftarrow \tau \theta_i + (1 - \tau) \bar{\theta}_i$ for $i \in \{1, 2\}$ ▷ Update target network weights
  end for
end for
Output: θ_1, θ_2, ϕ ▷ Optimized parameters

圖 2.3.1-9 SAC 演算法

在上述作法下，完整 SAC 演算法可以圖 2.3.1-9 表示。要注意的是，關於 Q 值的神經網絡(目標網絡)。雖然與 DDPG 相同，都是帶 target soft Q 網絡與參數θ，使 s′的 Q 估值保持穩定，但 DDPG 的 Target Critic 會完全不改動。而 SAC 則會在每一次利用式(21)自動更新參數。而且為了更快速穩定的訓練，Haarnoja 等人引入了兩個 Q 網路，然後每次選擇 Q 值小的一個作為 target Q 值並利用其上述的算式更新 Q 值與其策略。

雖然上述所有演算法如 PPO、DDPG 與 SAC 都有在先前計畫中產出不錯的訓練成果，但其都是以單目標為基礎，而在交通運輸領域裡，單目標會使 AI 的訓練時間拉長而且多路口與

時相的持續控制問題也會陷入問題,所以本計畫引用多目標強化學習模式 Q-Pensieve 演算法。詳細內容會於後續章節說明。

七、多目標強化學習(MORL)模式

(一)多目標馬可夫決策過程

強化學習亦可用於學習具有多個最佳化目標之問題場景,可將標準單目標 MDP 擴展為多目標之 MDP(multi-objective MDP,或稱 MOMDP)。與標準 MDP 類似,MOMDP 依然具有狀態集合、動作集合、獎勵函數、狀態轉移函數、折扣因子等要素。另一方面,MOMDP 與一般 MDP 主要的差異在於獎勵函數,MOMDP 的獎勵函數可輸出一個多維度的向量$\boldsymbol{R}(s,a)=\left(R^{(1)}(s,a),\cdots,R^{(d)}(s,a)\right)$,以粗體表示。以交通運輸場景為例,獎勵訊號可以包含多種績效指標,例如:車輛排隊長度(queue length)、車輛延遲(delay)、路口等待時間 (waiting time)、號誌切換延遲(switching delay)等。在多目標問題中,我們依然可定義價值函數如下,而唯一的差別僅在於價值函數皆為向量函數。

$$\boldsymbol{V}^{\pi}(s) \coloneqq E_{\pi}[\sum_{k=0}^{\infty}\gamma^{k}\,\boldsymbol{R}_{k+1}|S_0=s]$$

$$\mathbf{Q}^{\pi}(s,a) \coloneqq E_{\pi}[\sum_{k=0}^{\infty}\gamma^{k}\,\boldsymbol{R}_{k+1}|S_0=s,A_0=a]$$

相對應的總獎勵也可表示為$\boldsymbol{V}^{\pi}(\rho) \coloneqq E_{s\sim\rho}[\boldsymbol{V}^{\pi}(s)]$,其亦為一個$d$維度之向量。在多目標問題,我們可對於各種策略π所對應之總獎勵$\boldsymbol{V}^{\pi}(\rho)$進行探討:以兩個目標為例$(d=2)$,$\boldsymbol{V}^{\pi}(\rho)$可表示在二維平面上(如下圖 2.3.1-10 之各個圓點),而從這些總獎勵向量我們可找出相對好之向量集合稱為 Pareto frontier,定義如下:首先我們用$\pi \geq \pi'$來表示$\boldsymbol{V}^{\pi}(\rho) \geq \boldsymbol{V}^{\pi'}(\rho)$,亦即$\pi$在各個目標都能勝過$\pi'$,則我們可定義 Pareto frontier 為

$$\text{PF} \coloneqq \{\boldsymbol{V}^{\pi}(\rho)|\nexists\pi'\,s.t.\;\pi' \geq \pi\}$$

以圖 2.3.1-10 為例,點 A 至 K 皆屬於 Pareto frontier。廣義來說,多目標問題的主要目標為找到 Pareto frontier 中所有點其對應之策略,這也是與單目標問題,僅需找到一個最佳策略之本質差異。

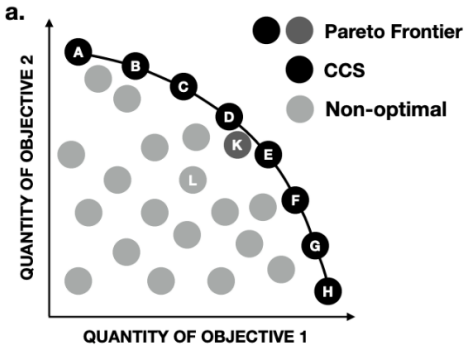


圖 2.3.1-10 兩目標馬可夫決策過程之 Pareto front 與 CCS 示意圖

(二)目標偏好與線性純量方法

在多目標問題中，如上述定義 Pareto front，我們可看出最佳策略會隨著對於各目標之偏好(preference)而改變。目前最常使用的描述偏好方式為線性純量(linear scalarization)方法，亦即透過一組權重$\boldsymbol{\lambda} = (\lambda_1, \cdots, \lambda_d)$來描述偏好並可將獎勵向量轉成純量$\boldsymbol{\lambda}^{\top}\boldsymbol{R}(s,a) = \sum_{i=1}^{d} \lambda_i R^{(i)}(s,a)$，在給定一種偏好下多目標問題即可簡化為一個單目標問題。在不失一般性下，我們可專注在$\boldsymbol{\lambda} = (\lambda_1, \cdots, \lambda_d)$滿足為機率分佈的情況下。基於此概念，找尋 Pareto frontier 可轉換為解決一群單目標問題：

對於各種非負偏好$\boldsymbol{\lambda} = (\lambda_1, \cdots, \lambda_d)$滿足$\sum_{i=1}^{d} \lambda_i = 1$，學習者的目標是輸出對應於各種偏好之最佳策略，即透過與環境互動同時解決一整群單目標問題。

(三)常用多目標強化學習模式介紹

基於以上的線性純量方法，現有的多目標強化學習演算法大致可分為兩類：

1.顯性搜尋(explicit search)

許多以多目標強化學習(MORL)為主題的先前研究，都是透過明確地搜尋獎勵空間的 Pareto frontier 來更新一個或多個策略。以近期被提出的 PGMORL 演算法為例，此篇提出了一種演化方法來搜索 Pareto frontier，並借助預測模型來確定搜索方向，主要概念可簡要呈現如圖 2.3.1-11 所示。此方法主要有三個步驟：首先在 warm-up 階段此方法會初始化多個 worker，在每次迭代時各個 worker 會從目前相對較好的策略出發並使用策略梯度的來估計來搜索更接近 Pareto frontier 策略，最後會將迭代過程中的策略做適當的分群並拼湊出 Pareto frontier。

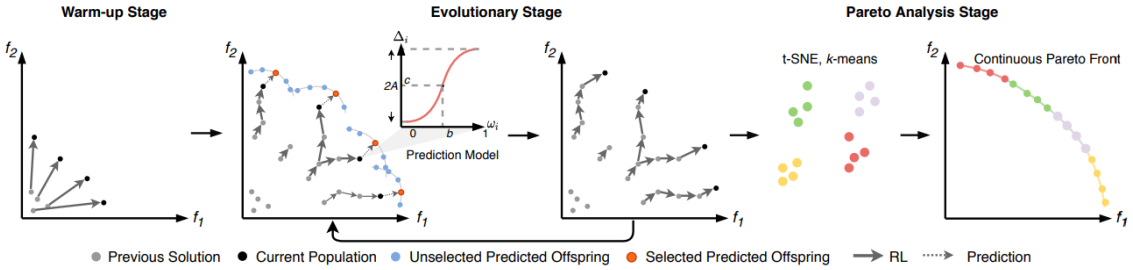


圖 2.3.1-11 PGMORL 之搜索概念示意圖

目前還有其他既有的類似顯性搜索策略，比如(Van Moffaert et al, 2014)提出了 Pareto 的 Q-learning 方法，是將即時獎勵和未來收益向量分別儲存並利用 Pareto 優勢來選擇 Q 學習中的動作。另外，(Mossalam et al., 2016)則是通過基於角落權重的優先順序選擇方法，使用 scalarized Q-learning 解決 MORL 問題。此外，近期的研究(Kyriakis et al., 2022)則是通過逼近 Pareto frontie 的一階必要條件來提出一種策略梯度方法。

儘管有前述許多顯性搜索方法，但上述明確搜索算法的一大缺點是因每次搜索過程之間的知識共享非常少，而使得樣本效率較低。

2.隱性搜尋(implicit search)

另一類演算法旨在通過隱式搜索改進多個偏好的策略。以近期的研究 (Abels et al., 2019)為例，此篇提出了一種名為「條件網路」(Conditioned Network,或簡稱 CN)的方法，將標準的單目標 DQN 擴展到學習偏好相關的多目標 Q 函數，具體方法為將偏好向量作為 DQN 的輸入，而期望透過訓練使 DQN 能對於各種偏好輸出相對應之最佳 Q 函數。條件網路之架構圖如圖 2.3.1-12 所示。

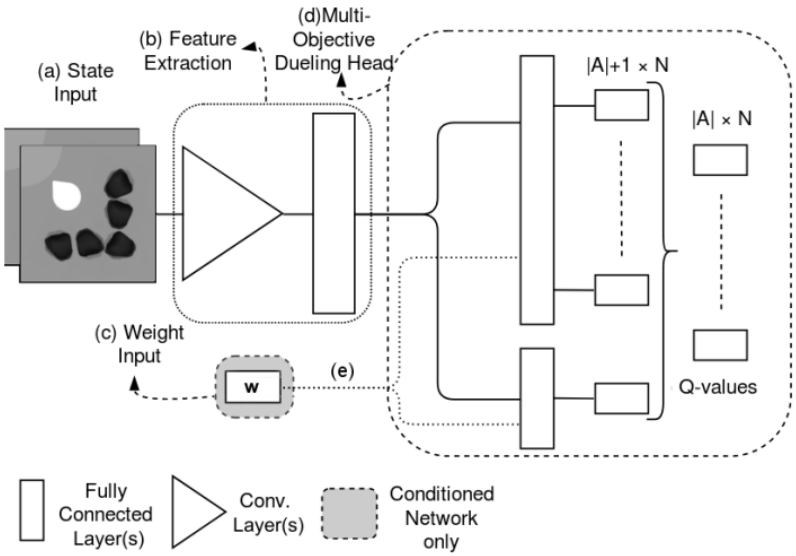


圖 2.3.1-12 Conditioned Network 架構示意圖

另一近期的研究為 Yang 等人(2019)，此篇提出包絡 Q 函數 (envelope Q function)的概念，以促進不同偏好下的 Q 函數之間的知識共享，使任何策略都可以從其他偏好的經驗中受益，從而使訓練更有效率。基於此概念，包絡 Q 函數提出基於動態模型的包絡值迭代，並給予多目標 Q 學習之收斂保證。

八、Q-Pensieve

Q-Pensieve(Hung 等人，2022)也是屬於 Actor-Critic 類的演算法，可以視為 SAC 算法的衍生，與 SAC 演算法相同都納入熵量(Entropy)為 Q 值函數裡的一種參數。但有所不同的是 Q-Pensieve 納入了多目標強化學習，使其不用多次尋找 Pareto 前線也能在共同確定政策更新方向時進行數據分享也能提高樣本效率。Q-Pensieve 的環境狀態與動作集 Q(S,A)是利用多目標馬可夫決策過程為多維度的向量(vector: S, A,P, r, γ, D, Sλ, Λ, d)。此演算法重要的變數為 d, Sλ, 和 Λ。d 代表的是多目標的數量，Λ 代表的是參數(preference)向量的系列組合，而 Sλ 代表的是 preference 參數的存量化算式。

總而言之，在單目標訓練裡的 SAC 裡，在訓練的每一步 AI 會收到狀態(State)、動作(Action)與獎勵的向量 r，而策略更新會用 SAC 小節裡的算式[18:21]來取得新的 Q 值函數。而 Q-Pensieve 延展其算式，使新的算式[1,2]融入了上述的重要變數。

$$\boldsymbol{Q}^{\pi}(s,a) = \boldsymbol{r}(s,a) + \gamma \mathbb{E}_{s' \sim \mathcal{P}(\cdot|s,a)}[\boldsymbol{V}^{\pi}(s')], \quad \text{式(1)}$$

$$\boldsymbol{V}^{\pi}(s) = \mathbb{E}_{a \sim \pi(\cdot|s)}[\boldsymbol{Q}^{\pi}(s,a) - \alpha \log \pi(a|s)\mathbf{1}_d], \quad \text{式(2)}$$

1_d 代表所以目標的向量。而 π(·|·;λ)是用於調整並取得參數的偏好及對於 Q 值函數的好壞。而關於其演算法的更新，Hung 等人也是引用了 SAC 的策略更新方程式(SAC 小節之算式(21))。但記得此方程式為應用於單目標的，而在多目標的情況下，因資料無法共享導致其抽取的樣本效率不佳。為了處理這個問題，Hung 等人開發了新的回放資料庫與其方程式(3)，而此資料庫是為了存取此目標的 Q 值以及參數，之所以選擇這方式是因其 Q 值與參數已經存在於 Action 裡了，並不需要在進行更新，只需存取於資料庫(與 replay buffer 相似)，並不會利用到多餘的資源。

$$\pi_{k+1}(\cdot|\cdot;\boldsymbol{\lambda}) = \arg\min_{\pi' \in \tilde{\Pi}} \mathrm{D}_{\mathrm{KL}}\left(\pi'(\cdot \mid s;\boldsymbol{\lambda}) \,\middle\|\, \frac{\exp\left(\sup_{\boldsymbol{\lambda}' \in W_k(\boldsymbol{\lambda}), \boldsymbol{Q}' \in \mathcal{Q}_k} \frac{1}{\alpha}\boldsymbol{\lambda}^{\top}\boldsymbol{Q}'(s,\cdot;\boldsymbol{\lambda}')\right)}{Z_{\mathcal{Q}_k}(s)}\right), \quad \text{式(3)}$$

Z_{Qk} 為 Q_k 的正量化值，Q_k 則為每一個 k 值的 Q 系列組合。而 W_k 則為每一個 k 值的參數系列組合。

而以下將說明此訓練的三種重要更新點：

(一)Policy-Evaluation

在策略選定的過程中，Bellman Equation 會以參數(preference)為基準，並用多目標歸一化指數函數(算式(4))而計算新的 Q 值函數。

$$(\mathcal{T}^{\pi}_{\mathrm{MO}}\boldsymbol{Q})(s,a;\boldsymbol{\lambda}) = \boldsymbol{r}(s,a) + \gamma \mathbb{E}_{s' \sim \mathcal{P}(\cdot|s,a), a' \sim \pi(\cdot|s';\boldsymbol{\lambda})}[\boldsymbol{Q}(s',a';\boldsymbol{\lambda}) - \alpha \log \pi(a'|s';\boldsymbol{\lambda})\mathbf{1}_d]. \quad \text{式(4)}$$

(二)Q Replay Buffer

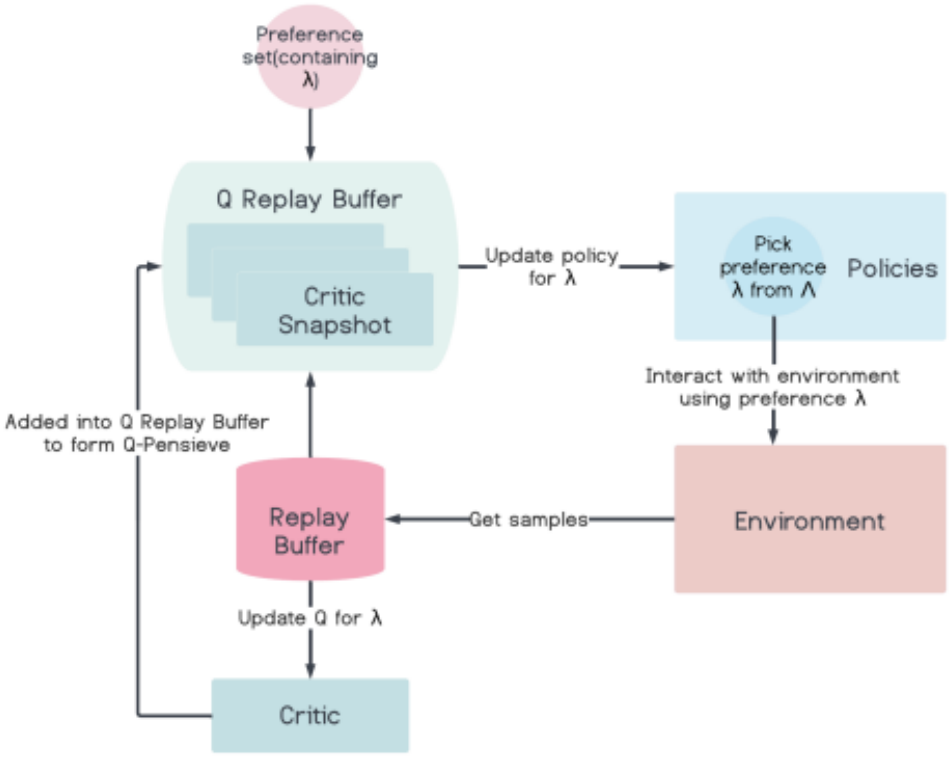
由此可見，Q-Pensieve 會用現在的 Q 與前面存取的 Q 進行策略更新，Q replay buffer 的用途就是用於儲存前面所有動作造成的 Q 值，並隨機抽取 Q 進行對比和 Policy Iteration。

(三)Soft-Policy Iteration

Policy Iteration 會利用 SAC 並以脫離策略學習多目標的梯度方向與計算出其目標函數(算式(5))。

$$\mathcal{L}_{\pi}(\theta;\boldsymbol{\lambda}) = \mathbb{E}_{s \sim \mu}\left[\mathbb{E}_{a \sim \pi_{\theta}}\left[\sup_{\boldsymbol{\lambda}' \in W(\boldsymbol{\lambda}), \boldsymbol{Q}' \in \mathcal{Q}} \left\{\alpha \log\left(\pi_{\theta}(a \mid s;\boldsymbol{\lambda})\right) - \boldsymbol{\lambda}^{\intercal}\boldsymbol{Q}'(s,a;\boldsymbol{\lambda}')\right\}\right]\right]. \quad \text{式(5)}$$

而其運作架構如圖 2.3.1-13，與演算法如圖 2.3.1-14。



資料來源：Hung 等人(2022)

圖 2.3.1-13 Q-Pensieve 運作架構圖

Algorithm 1: Q-Pensieve

Input : ϕ_1, ϕ_2, θ, preference sampling distribution $\mathcal{P}_{\boldsymbol{\lambda}}$, number of preference vectors $N_{\boldsymbol{\lambda}}$, the soft update coefficient τ, actor learning rates η_π, critic learning rates η_Q

Output : ϕ_1, ϕ_2, θ

$\bar{\phi}_1 \leftarrow \phi_1, \bar{\phi}_2 \leftarrow \phi_2$;
$\mathcal{M} \leftarrow \emptyset$ ▷ Initialize replay buffer;
$\mathcal{B} \leftarrow \emptyset$;
for *each iteration* **do**
  sample weight $\boldsymbol{\lambda}$ *from* Λ *according* $\mathcal{P}_{\boldsymbol{\lambda}}$;
  for *each environment step* **do**
    $a_t \sim \pi_\theta(\cdot|s_t; \boldsymbol{\lambda})$;
    $s_{t+1} \sim P(\cdot|s_t, a_t)$;
    $\mathcal{M} \leftarrow \mathcal{M} \bigcup \{(s_t, a_t, r(s_t, a_t), s_{t+1})\}$;
  for *each gradient step* **do**
    sample $N_{\boldsymbol{\lambda}} - 1$ *preferences and add them to set* W;
    $W \leftarrow W \bigcup \{\boldsymbol{\lambda}\}$;
    $\phi_i \leftarrow \phi_i - \eta_Q \hat{\nabla}_{\phi_i} \mathcal{L}_Q(\phi_i; \boldsymbol{\lambda}), \mathcal{B} \leftarrow \mathcal{B} \bigcup \{\phi_i; \boldsymbol{\lambda}\}$ for $i \in \{1, 2\}$;
    compute $\hat{\nabla}_\theta$ *with eq. 11 with* W;
    $\theta \leftarrow \theta - \eta_\pi \hat{\nabla}_\theta \mathcal{L}_\pi(\theta; \boldsymbol{\lambda})$;
    $\bar{\phi}_i \leftarrow \tau\phi_i + (1 - \tau)\bar{\phi}_i$ for $i \in \{1, 2\}$;

資料來源：Hung 等人(2022)

圖 2.3.1-14 Q-Pensieve 演算法

2.3.2 多模態強化學習演算法

一、Task-Aware(多任務強化學習模式)

(一)Multimodal Model-Agnostic Meta-Learning via Task-Aware Modulation (MMAML)

現有的大多數模型無關元學習器都是單模態(Unimodal)用於單一初始化(single initialization/reward)。從複雜的任務分布中隨機抽樣的不同任務可能需要截然不同的一參數(parameter θ)，這使得很難找到任單一獎勵能涵蓋所有的任務目標，使其接近所有目標參數，如圖 2.3.2-1 所示。

而如果任務分布是多模態的，其中模態之間是不相交且相距較遠的，可以想像使用一組獨立的元學習器(Meta-Learning)，每一個元學習器涵蓋一個模態，可能更好地掌握整個分布，如圖 2.3.2-2 所示。然而，任何任務與元學習器中的一個關聯不僅需要額外的任務身份信息，而這些信息通常並不可用或在模式不明確時可能存在分歧，而且這樣做也會阻止在任務分布的不同模式之間進行知識轉移。簡而言之，如果任務分布是多模態的且模式之間相距較遠，單一初始化的模型無法很好地處理所有任務。嘗試使用多個獨立的元學習器來涵蓋每一個模式可能更為有效，但這樣做會引入額外的挑戰，並可能限制跨模式的知識轉移。

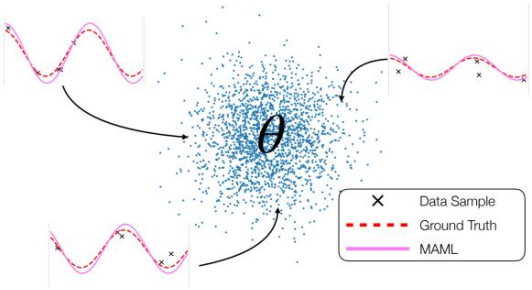


圖 2.3.2-1 單模態任務目標參數示意圖

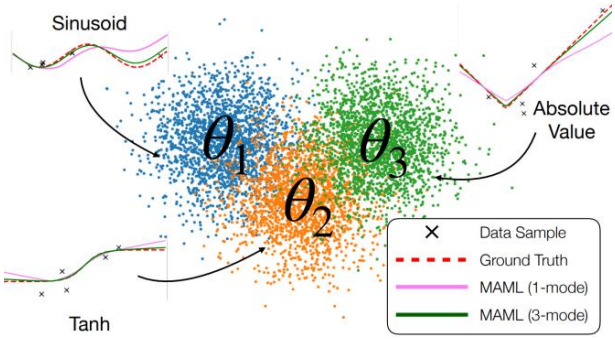


圖 2.3.2-2 多模態任務目標參數示意圖

為了處理這個問題，MMAML 運用了 Model-Based 與 Model-agnostic Meta-Learning(MAML)的優點，Chelsea Finn 等人(2017)演算法旨在使用過去的經驗中學習，

提高在此任務上的學習能力訓練一個模型(unimodal)，使得它能夠在新的任務上以最少的訓練數據快速適應(與 SAC 跟 Q-Pensieve 相同，詳情如後 AI 模式比較分析所述)。而用法旨在利用以上多種不同的 unimodal 來處理多種數據模態的任務，使各模型能夠在不同類型數據的任務中進行學習，並進行整合與泛化，使其更加多樣化和適應各種現實場景。而在號誌控制等跨模態檢任務中(multi-task)，因號誌的週期與秒數不同，模型需在不同模態之間找到相關信息，使其原因使 MMAML 特別有用。

(二)MMAML 用法(Method)

具體來說，MMAML 希望能增強跨多模態任務分布泛化能力的方法。與學習參數空間中的單一初始化點不同，會有兩個 neural Network(Modular network 與 Task network)。Modular network 會先進行關於任務相關的數據檢查(datapoints)來偵測一個任務身份(task identity)並估計其參數(parameterτ)。在得到估計後，其估計會作為輸入(input)對目標任務(task network)進行初始化調節，並以後續不同的任務模式進行推斷與參數設定(parameter T)。並以這些調節的參數對目標任務進行梯度適應，逐步改善其性能，如圖 2.3.2-3 所示。

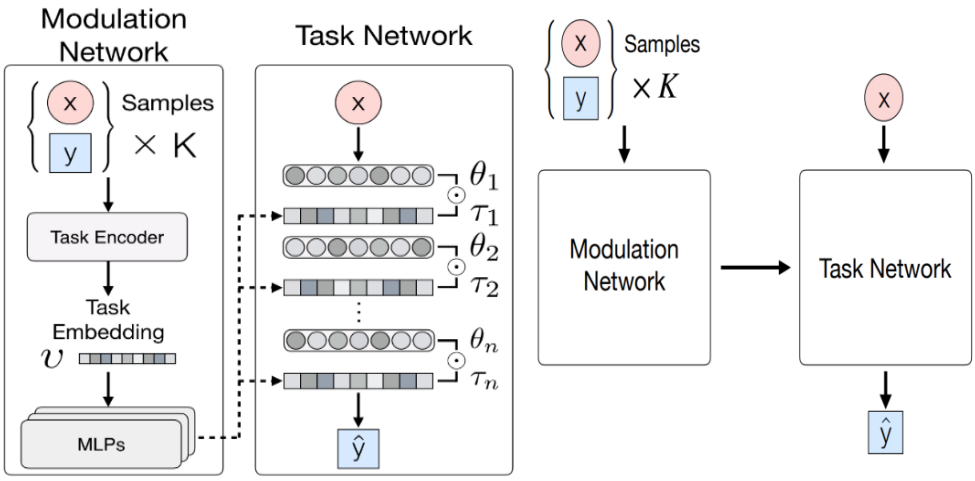


圖 2.3.2-3 MMAML 架構示意圖

1.Modulation Network

要產出與任務有關的參數，Modulation Network(LSTM)會先從{xk, yk}k=1,…,K 為輸入並由 Task Encoder 產出 list of 任務向量 υ(以 0,1 為表示)。

$$\upsilon = h\left(\{(x_k, y_k) \mid k = 1, \cdots, K\}; w_k\right) \quad \text{式(1)}$$

$$\tau_i = g_i\left(\upsilon; \omega_g\right), where\ i = 1, \ldots, N; \text{ N 為 task network 的任務數量} \quad \text{式(2)}$$

利用算式 1 計算出參數τ(task-related parameter，請看算式二)，並用於 task network。而因 task network 具有多個任務，Modulation Network 會產出多個方塊，對應的則是每一個任務的 Input(state and parameter)而且會進行位移和縮放為了能與其他 Output

有對應(knowledge transfer)。而有良好的任務初始值。

2.Task Network

Task network 具有多個任務，全部會用單一 Agent (neural-network)但會有多個 weights。而每一任務都會進行梯度適應(step action/gradient descent)，逐步改善其性能並覆蓋之前的 weights 與參數T。但要注意的是只有參數T會進行更新。因為參數τ代表 Task network 的初始化，只有在全部任務跑完並產出 data points(y_k)，才會進行更新，如圖 2.3.2-4 所示。

Algorithm 1 MMAML META-TRAINING PROCEDURE.

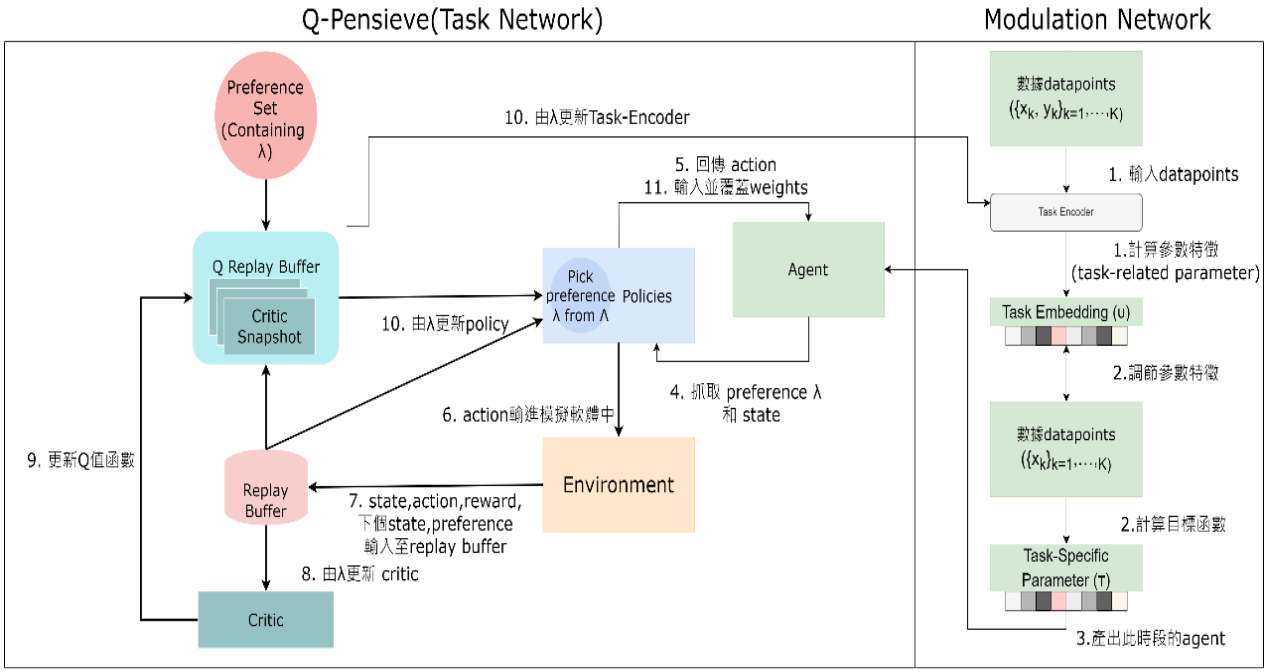
Input: Task distribution $P(\mathcal{T})$, Hyper-parameters α and β
Randomly initialize θ and ω.
while not DONE **do**
  Sample batches of tasks $\mathcal{T}_j \sim P(\mathcal{T})$
  for all j **do**
    Infer $v = h(\{x, y\}_K; \omega_h)$ with K samples from $\mathcal{D}^{\text{train}}_{\mathcal{T}_j}$.
    Generate parameters $\tau = \{g_i(v; \omega_g) \mid i = 1, \cdots, N\}$ to modulate each block of the task network f.
    Evaluate $\nabla_\theta \mathcal{L}_{\mathcal{T}_j}(f(x; \theta, \tau); \mathcal{D}^{\text{train}}_{\mathcal{T}_j})$ w.r.t the K samples
    Compute adapted parameter with gradient descent: $\theta'_{\mathcal{T}_j} = \theta - \alpha \nabla_\theta \mathcal{L}_{\mathcal{T}_j}(f(x; \theta, \tau); \mathcal{D}^{\text{train}}_{\mathcal{T}_j})$
  end for
  Update θ with $\beta \nabla_\theta \sum_{\mathcal{T}_j \sim P(\mathcal{T})} \mathcal{L}_{\mathcal{T}_j}(f(x; \theta', \tau); \mathcal{D}^{\text{val}}_{\mathcal{T}_j})$
  Update ω_g with $\beta \nabla_{\omega_g} \sum_{\mathcal{T}_j \sim P(\mathcal{T})} \mathcal{L}_{\mathcal{T}_j}(f(x; \theta', \tau); \mathcal{D}^{\text{val}}_{\mathcal{T}_j})$
  Update ω_h with $\beta \nabla_{\omega_h} \sum_{\mathcal{T}_j \sim P(\mathcal{T})} \mathcal{L}_{\mathcal{T}_j}(f(x; \theta', \tau); \mathcal{D}^{\text{val}}_{\mathcal{T}_j})$
end while

圖 2.3.2-4 Task Network 訓練虛擬碼

(三)多路口號誌控制的應用

而在多路口的號誌控制，Modulation Network(LSTM)會以每一個路口的號誌周期與紅綠燈秒數為 data points，並產出對應的任務目標與參數(θ, ω)，得以當作輸入給 Task Network。

Task Network(Q-Pensieve)則會以每一個路口號誌(任務)進行梯度適應並逐步改善其性能，直到跑完所有路口並更新任務目標與參數(θ, ω)，如圖 2.3.2-5 所示。



資料來源：本計畫整理

圖 2.3.2-5 多任務強化學習訓練架構

二、PEARL (Probability Embedding for Actor-Critic RL, 概率嵌入式強化學習)

(一)PEARL 簡介

PEARL 是一種元學習(Meta Learning, ML)強化學習演算架構，旨在透過利用先前學習任務的經驗來快速適應新任務。使用機率潛在上下文變數來編碼特定任務的訊息，並將此潛在上下文用於訓練與調節 RL 演算法，而其上下文計算的策略和價值函數則能夠學會區分不同任務使其遇見新任務時能快速辨別其特性無需重新訓練。PEARL 採用離線策略訓練以提高樣本效率，並使用演員-評論員(actor-critic)架構來實現穩定學習，該演算法的主要創新在於能夠透過從少量經驗中推斷任務上下文來快速適應新任務，這使其特別適用於需要在相關任務分佈中進行泛化的元學習場景。

其主要變動為新增了推理架構(task network)，其主要是通過模型參數將輸入資料映射到潛在上下文之向量分佈，而此向量不是固定的，而是通過高斯後驗將各輸入編碼之因數進行乘積，計算出潛在上下文變數的後驗變數(context z)，如圖 2.3.2-6 所示。

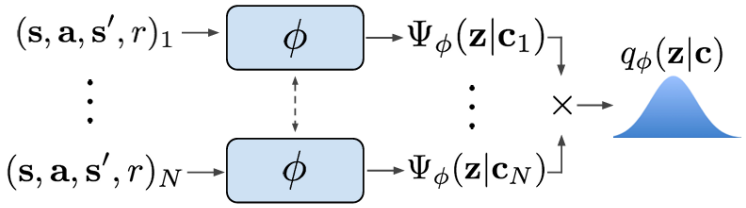


圖 2.3.2-6 推理網絡架構

(二)元學習與離線策略結合

因目前文獻中關於元學習含有一種必須遵守之法則，即用於適應的數據分佈將在元訓練和元測試之間匹配，代表元學習在訓練時需隨時根據新的數據進行更新才能產出下一個數據。但這會導致訓練資料不足使其訓練緩慢，無法馬上"適應"不同數據。而 Pearl 這個做法是將這個責任交付至推理網路來釋放這種約束，讓 Pearl 演算法不用隨時微調模型參數，而是讓每一次決策重新計算一次 context_z，使其約束改為編碼中的變數並且可以在元學習中應用在線策略學習使其含有離線學習之優點，其運作架構圖及訓練架構圖如圖 2.3.2-7 及圖 2.3.2-8 所示。

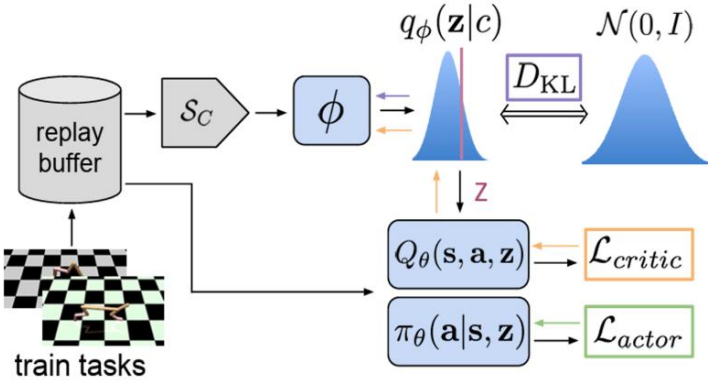
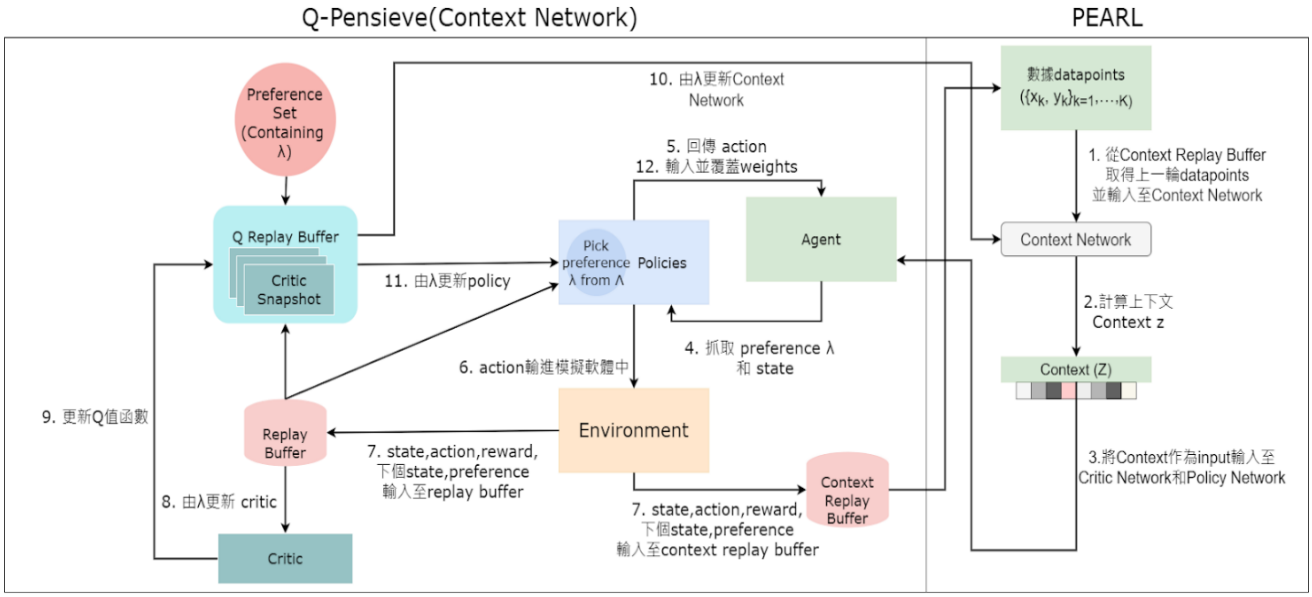


圖 2.3.2-7 Pearl 離線策略運作架構圖



資料來源:本計畫整理

圖 2.3.2-8 Pearl 訓練架構圖

2.3.3 多代理人集中訓練分散執行架構

一、人工智慧強化學習號誌協控模型發展構想

本計畫針對交流道區域提出高速公路交流道區域匝道儀控與平面道路路口號誌整合之人工智慧強化學習號誌協控模型發展構想與設計，模型發展與設計過程評估導入多號誌代理人機制，並於績效評估上額外考量駕駛人感受等相關指標。基於對單一平面道路號誌的學習模式，本計畫考慮將此模式推廣至平面道路號誌與匝道儀控的協控應用場景，對於多個環境中進行學習，其整體訓練主要有以下兩種方法：

(一)集中式控制(centralized control)

採用集中式控制方式進行匝道與平面道路號誌協控，此模式僅有單一代理人者，而學習者可同時取得匝道與平面道路路口之狀態且能同時決定兩地之號誌計畫內容。此模式透過增加狀態描述的維度與動作即可運用 SAC 與 Q-Pensieve 方法來訓練。值得一提的是，多目標方法如 Q-Pensieve 在此設定提供相當多彈性，比如若想考慮多種匝道與平面道路路口的偏好權衡，可設計多目標獎勵函數，並同時包含匝道與平面道路之獎勵目標。

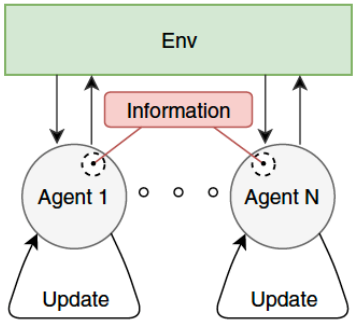
(二)分散式控制(decentralized control)

透過多代理人強化學習(multi-agent RL)達成分散式控制 (decentralized control) 之匝道與平面道路號誌協控，場景有兩個代理人，分別可控制匝道儀控與平面道路號誌，在測試階段各學習者僅能取得局部之狀態資訊，而無法得知全局之狀態。

在深度強化學習領域目前最主流的作法為集中訓練並分散執行(Centralized Training and Decentralized Execution, CTDE)架構，其架構如圖 2.3.3-1，每個「智能體」會各自產生策略與環境互動，因此稱為分散式執行(decentralized execution)，而每個「智能體」在訓練期間更新其策略時會共享狀態資訊，因此稱為集中式訓練(centralized training)。

當前已有許多在強化學習領域使用 CTDE 架構的研究工作，根據不同的訓練架構可分為多個類別，首先，第一個類別是參數共享，例如：Ahilan 等人(2019)、Sunehag 等人(2018)主要是通過訓練多個代理人策略，透過不同獨立「智能體」之間的參數共享，以提高訓練效率。另一種則為基於價值的方法，如 Foerster 等人(2016)、Foerster 等人(2017)提出將 deep Q-learning 透過 CTDE 的方式推廣至多「智能體」強化學習，並且通過 Lowe 等人將標準的 DDPG 透過 CTDE 的方式推廣為 Multi-Agent DDPG (MADDPG)，藉由訊息共享，Q 網路能學習到全局的預期獎勵，通過此 Q 函數，每個獨立的策略網路都能學到全局的最佳解。最後則是 Master-slave 架構，Kong 等人(2017)、Kumar 等人(2017)於強化學習中導入 Master-slave 架構，中央的訓練員負責為每個從屬的「智能體」提供 Action。每個從屬「智能體」則通過其局部觀察狀態來微調中央指導的行動，以實現合作訓練的目標。

Gronauer 等人(2022)則提出更詳細的 CTDE 文獻介紹，如圖 2.3.3-1 所示，說明如下。



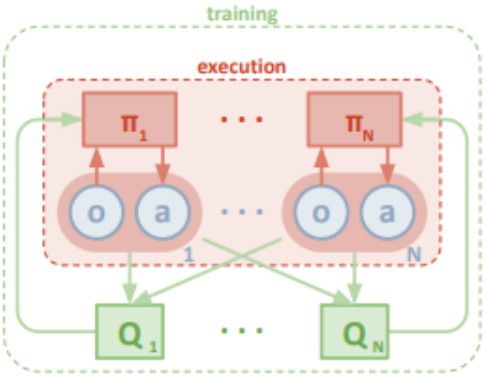
資料來源：Gronauer 等人(2022)

圖 2.3.3-1 CTDE 多智能體強化學習架構圖

更具體說明 CTDE 之特點，以下進一步用 MADDPG 為例並配合圖 2.3.3-2 描述 CTDE 架構：

(一)在策略網路部分，每個學習者有各自的 policy network，而此網路僅使用局部狀態作為輸入並輸出該號誌之動作(以 π(1)(s(1)),π(2)(s(2))表示)。

(二)在 Q 網路部分，將使用全局的狀態與兩個學習者的動作作為輸入，即可表示為 Q(s(1),s(2),π(1)(s(1)),π(2)(s(2)))。



資料來源：Gronauer 等人(2022)

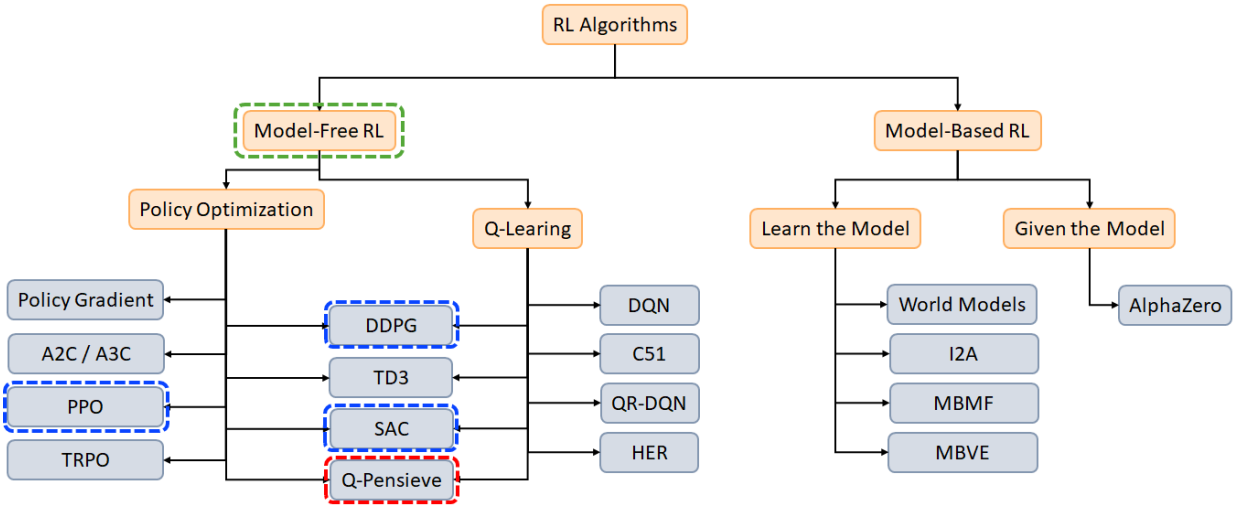
圖 2.3.3-2 MADDPG 之 CTDE 架構示意圖

二、小結

於高速公路交流道區域匝道儀控與平面道路號誌路口的整合協控中，需要中央 critic 針對匝道和平面道路號誌協控來訓練達到最佳目標，因此本計畫導入 CTDE 訓練架構。由於 Q 網路僅在訓練階段會使用而不會參與局部測試階段，故此設計並不違背前述之設計，因此 CTDE 模式可與 SAC 和 Q-Pensieve 都相容，並能順利發展單目標與多目標強化學習演算法。

2.3.4 強化學習演算法應用比較分析

目前強化學習演算法有非常多，圖 2.3.4-1 為目前常出現之強化學習演算法，以下就目前常用於交通號誌控制之演算法，如 DDPG、PPO、SAC 及 Q-Pensieve 進行介紹及比較。



資料來源: Kinds of RL Algorithms, 「Q-Pensieve」為本案外加.
https://spinningup.openai.com/en/latest/spinningup/rl_intro2.html

圖 2.3.4-1 強化學習演算法之歸納與衍生

一、DDPG

DDPG 啟用脫離策略學習(off-policy learning)與確定性策略(Deterministic Policy)。優點為因確定性策略(Deterministic Policy)減少了訓練的複雜性而能更快速與有效的優化連續動作的問題應用，而 DDPG 使用了目標網路，經驗回放技巧而穩定了脫離策略學習(off-policy learning)探索的多維狀態空間與其策略的更新過程，並大幅提升樣本使用率。缺點為 DDPG 會因參數的敏感問題造成每次 critic 訓練的精準度有很大的差異，例如：學習率(learning rate)與車輛或向量的多寡，與確定性策略(Deterministic Policy)無法對於潛在較佳的 Action 進行有效率的探索。

二、PPO

PPO 啟用同策略學習(on-policy learning)與隨機策略(Stochastic Policy) ，優點為因隨機策略(Stochastic Policy)解決了大規模和高維狀態空間的問題而能有效優化策略函數，並因 PPO 只使用策略函數來進行優化使其減少算法的複雜性，而 on-policy 通過限制策略更新的幅度確保了訓練過程的穩定性，而 PPO 使用的 Clipping Reward 充分利用了過去的經驗數據(importance sampling)而提高樣本使用率。主要缺點為其訓練結果會受限於近期的經驗，容易陷入一個局部區域最佳性能的策略，另外一個缺點為 Policy 的模型只能表單一波峰的動作概率分佈，無法對於全局的其他次佳策略進行有效率的探索。

三、SAC

SAC 啟用策略學習(off-policy learning)與隨機策略(Stochastic Policy)，優點為因同時使用策略學習(off-policy learning)跟隨機策略(Stochastic Policy)使 SAC 繼承了 DDPG 與 PPO 的優點，SAC 也利用了熵正則化的概念(Entropy-regularized RL)來增加策略的探索性與隨機性，使

其能有效地對於全域空間進行探索，並通過使用兩個 Q 值函數 Q(s,a)來減少錯誤估計。

最終使用策略函數來取得最大化的獎勵(Reward)並找到對應的動作概率分佈，使模型可以去找到其他全域最佳解，而不僅僅陷入局部最優解，這件事是 DDPG 與 PPO 所無法達成的，而 SAC 的缺點也因其增加了熵係數導致參數計算資源和訓練時間花費極大，而更新參數方面需借重專家經驗或需透過相當多次反覆的超參數搜尋才能達成，這導致需利用多個神經網絡來進行優化使其訓練過程也相對較為複雜，最後也因無法實行知識共享，透過共享不同訓練週期的 Q 值函數參數與不同獎勵偏好(Preference)對應的 Q 值函數，導致 SAC 難以在多種目標中確保資料的是使用效率以達成最適權衡。

四、Q-Pensieve

Q-Pensieve 啟用與 SAC 一樣的模型，因其原因 Q-Pensieve 繼承了 SAC 的優點不只增加了策略的探索性與隨機性而也增加多目標的學習方法使 Agent 能進行知識共享盡管目標不同。使用方法為利用 off-policy 學習並取得另外一個目標的偏好(preferences)與環境(States)和動作(Actions)，並且同時利用不同目標的 Q 值函數 Q(s,a)進行 knowledge sharing 與更新原來的 Policy network，但缺點也因其龐大的 Q 值函數導致演算法本身與神經網路架構皆較為複雜。

上述說明相關之強化學習演算法，表 2.3.4-1 就各演算法之樣本效率、離線策略學習及多目標進行比較。

表 2.3.4-1 強化學習演算法之比較

	DDPG	PPO	SAC	Q-Pensieve
策略 (Policy)	確定性策略 (Deterministic)	隨機策略 (Stochastic)	隨機策略 (Stochastic)	隨機策略 (Stochastic)
樣本效率 (Sample Efficiency)	高	低	高	高
離線策略學習 (Off-Policy Learning)	有	否	有	有
多目標 (Multi-Objective)	否	否	否	有

資料來源：本計畫整理

2.3.5 總結

強化學習(RL)演算法，無論是單目標還是多目標，都建立在馬爾可夫決策過程框架之上。通過與環境互動、與觀察到的獎勵、狀態、動作更新策略來學習最佳策略。而演算法會利用神經網絡或各種函數，與時序差分(TD)等等的學習策略優化技術。其中也包含經驗重播之類的策略，其中過去的轉換被存儲會被有效地利用，以及促進探索的熵(Entropy)正則化，在訓練期間增強了穩定性和探索性。

而任務感知元學習(Task-Aware)允許在不同任務模式下調節策略網絡初始化，從而實現更

好地泛化多模態任務分佈。將這與 Q-Pensieve 的偏好參數策略整合起來，即通過知識共享學習跨多個獎勵偏好參數的策略，可能提供一個強大的框架，用於優化多個交叉口的交通信號。將交叉口視為具有不同週期定時作為任務模式，並將優化目標，如延遲、通過量或旅行時間，視為偏好參數，這種結合了元學習和多目標方法的方法對於開發高度適應性和高效率的 AI 交通信號誌控制制器具有巨大潛力。

但因 Task-Aware 還保有元學習之限制(在線學習)使其隨機取樣之模型輸入資訊與在線模型之決策結果不匹配導致訓練緩慢，並有機率導致模型容易陷入區域最佳解。而 Pearl 演算法則是將在線策略之壓力推於額外開發的推理神經網絡讓其每次需更新模型參數時會將其變為更新推理網絡參數重新預測模型輸入為哪個時段之模型已其保有離線策略之優勢與加速 Pearl 的訓練時長。

如先前計畫所使用的 DDPG 與 Q-Pensieve 演算法，此模型控制仍受限於時段與時相維度切分，導致在全時段或較為複雜的場域時段切分需訓練各種不同的時相組態差異且會有較為複雜的模型訓練，而 task-aware 會利用元學習的概念學習各種不同的時相組態差異並整理成一種模型進行跨時段的訓練與優化精進。

總結強化學習(RL)演算法 Pearl、Task-Aware 及 Q-Pensieve 對於欲解決之交通課題及適應情境如下：

一、多時段控制

(一) 針對不同行為特徵的交通流量模式，Task-Aware 元學習框架能動態適應時段變化，將尖峰提高通行效率與離峰降低延滯時間的需求整合至同一模型中，避免傳統方法需單獨訓練每個時段的問題。

(二) Pearl 演算法透過推理神經網絡快速預測當前交通模式，進一步提升策略適應性與決策效率。

二、路域協控：Q-Pensieve 的多目標優化框架，能同時考量延滯與通過量，實現不同路口間的流量平衡與動態優化。

(一) 在中壢交流道場域，平面道路與匝道的交通特性存在互相影響，模型通過學習(如匝道車流控制對平面道路路口延滯的影響)，實現場域最佳控制。

(二) 透過經驗重播技術，模型能有效利用歷史數據，強化對多場域協控的適應能力。

2.4 人工智慧強化學習在號誌控制應用之關鍵課題

在前期計畫中，遭遇許多關鍵課題如資料介接格式不同、設備連線不穩造成 AI 時制無法下達、實測時應盡量避免人為手操燈或義交交警引導車流等情事。本計畫執行過程，亦在訓練模型時遭遇課題，希冀作為後續推動強化學習號誌控制的助力。

一、時制計畫及交通工程

由於模型為離線訓練之模型，故輸入之交通量資料，交通模擬環境設定以及相關參數調整皆會敏感的影響訓練結果。近年來，由於政府亦積極推動交通環境改革，故時有調整路口時制計畫以及道路工程改善的情況發生。這樣的改動都會直接影響在模擬環境中訓練的模型。當模型訓練與調整為其幾週亦或若干月，惟機關與此同時調整號誌亦或進行道路施工，則訓練成效將會大打折扣。

在前期計畫中，亦有一項課題指出，如該場域之全日時制計畫切分較密，時相組態過多，將造成需訓練的模型數量增加。故本期計畫調整原模型架構，增加推理架構使模型能適應跨時段之任務差異。

二、實驗場域大小

實驗場域大小除影響建立模擬環境模型之難易，亦對於模型設計有很大的影響。由於場域變大，模型須考量的狀態(State)，例如路口車流情況，的維度就會增加，如同時須考慮不同車種，則維度會進一步上升，決策之動作(Action)維度也會上升。模型難以取得較佳表現時，模型收斂將更困難，最直接的影響為訓練時長，難以收斂時更可能需調整模型架構設計。

三、實驗場域偵測器

在實測階段，偵測器回傳的資料是獲取模型輸入的主要手段。在訓練過程中，模擬環境能夠精確地回傳偵測值，但在實際的實驗場域中，可能會因為遮蔽物、偵測失敗、設備異常等眾多因素，造成設備所呈現的數值與訓練數值截然不同，進一步造成模型的成效不彰。故在初始建立模擬環境時，即需將設備的狀態與模擬環境中的偵測器對照，讓模擬與真實情況盡量維持一致。

第三章　強化學習號誌控制模型實測成果

3.1 實驗場域特性分析與模擬環境建置

於去年執行之「我國人工智慧車聯網之號誌控制(1/2)-都會區幹道實作與交流道區域模式發展探討」研究計畫(簡稱前期計畫)，發展車聯網與人工智慧強化學習之號誌控制模擬環境，前期計畫以臺南市實驗場域「台 86 線-台 19 甲線」做為單一路口、臺北市實驗場域「中山北路-德行東路」作為都會區幹道之實驗場域。本計畫都會區實驗場域與前期計畫相同，以下分別進行道路幾何與號誌控制等資訊說明。

3.1.1 單一路口場域(臺南市「台 86 線-台 19 甲線」路口)

本計畫對場域路口及周邊道路進行幾何及時制計畫調查，道路幾何情況與前期計畫調查內容大致相同；時制計畫則有部分更動，平日週五時制計畫與其他平日不同，各分相秒數亦有所調整，如下所述。



圖 3.1.1-1 臺南市「台 86 線-台 19 甲線」路口位置示意圖

一、道路特性

調查範圍道路包含台 86 線、台 19 甲線、關廟交流道。其道路幾何特性資料彙整如表 3.1.1-1，包含車道數、車道寬、分隔方式等。

表 3.1.1-1 臺南市「台 86 線-台 19 甲線」路口道路幾何特性

路名	道路類型	車道數	車道寬	分隔方式	車種管制
19 甲北向	一般道路	2+左轉袋+右轉槽化	4.0(直外)、3.5(直內)、3.3(左)、5.5(右)	實體分隔	內側禁行機車
19 甲南向	一般道路	2+左轉袋+右轉槽化	4.4(直外)、3.5(直內)、3.3(左)、5.5(右)	實體分隔	內側禁行機車
台 86	一般道路	2+2 左轉袋+右轉槽化	3.3(直外)、3.3(直內)、3.3(左外)、5.5(右)	實體分隔	內側禁行機車
關廟交流道	快速道路	2+2 左轉袋+右轉槽化	3.0(直外)、3.0(直內)、3.1(左外)、3.1(左內)、5.0(右)	實體分隔	內側禁行機車

資料來源：交通部運輸研究所(2023)[73]

二、交通量量調查

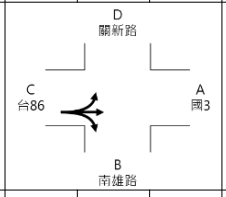
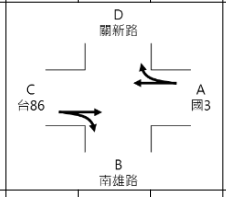
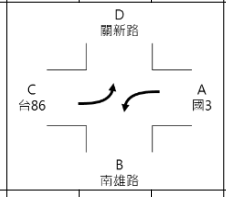
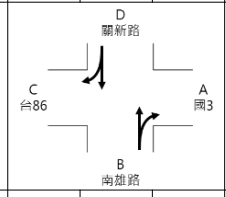
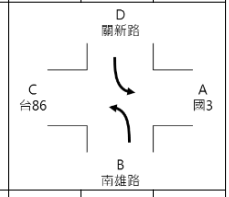
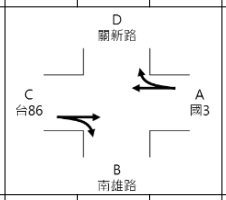
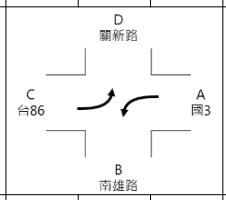
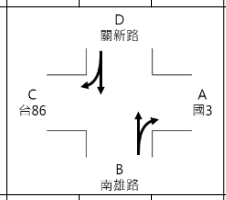
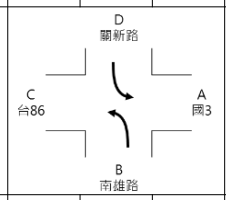
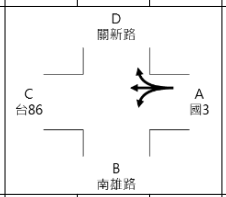
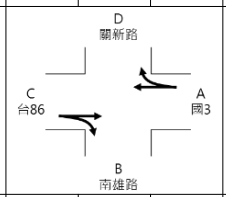
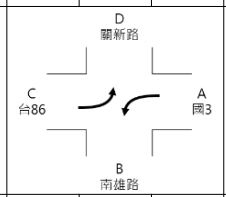
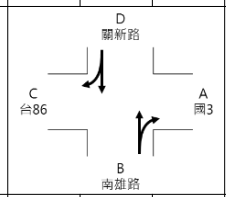
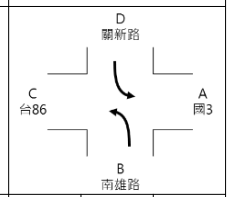
表 3.1.1-2 臺南市「台 86 線-台 19 甲線」前期及本期路口交通量比較

路口名稱	時段	時間	2023/11/7(二)、11/11(六)				時間	2024/11/5(二)、11/9(六)				各時段交通量差異	路口整體交通量差異
			A	B	C	D		A	B	C	D		
台86/台19甲	平日晨峰	07:45-08:45	989	898	1556	920	07:45-08:45	636	1208	1794	788	1.46%	-2.83%
	平日離峰	12:30-13:30	672	546	693	619	12:30-13:30	604	489	788	506	-5.60%	
	平日昏峰	17:00-18:00	1289	882	851	966	17:15-18:15	1022	839	1003	920	-5.09%	
	假日昏峰	17:00-18:00	1117	816	946	894	17:00-18:00	929	733	1202	831	-2.08%	

三、號誌時制計畫

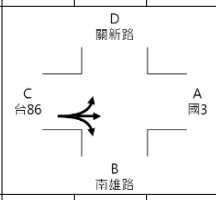
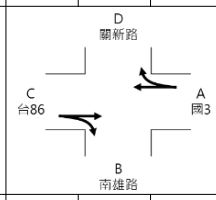
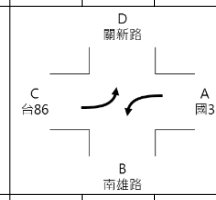
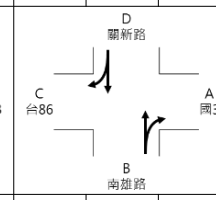
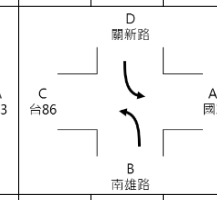
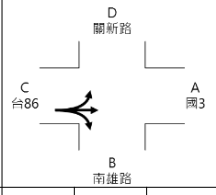
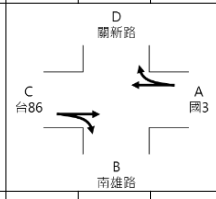
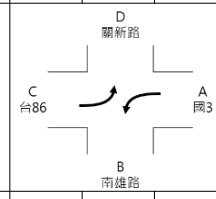
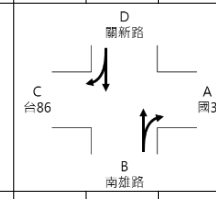
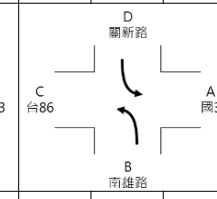
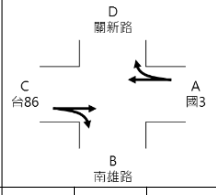
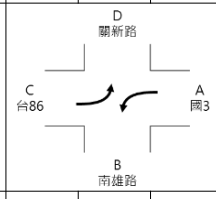
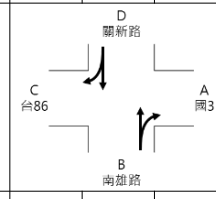
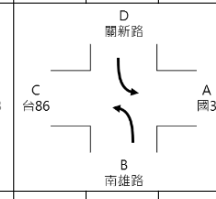
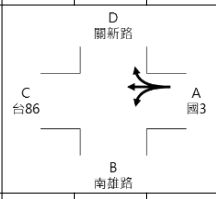
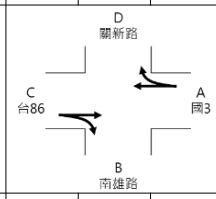
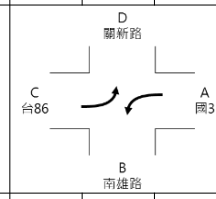
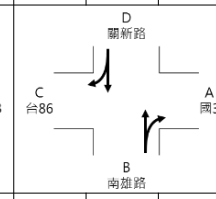
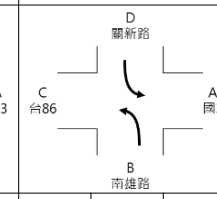
台 86 線-台 19 甲線路口時相組態與時制計畫內容，詳表 3.1.1-3~3.1.1-5 所示。

表 3.1.1-3 臺南市「台 86 線-台 19 甲線」路口平日週一~週四號誌時制計畫

時制	週期	時相1			時相2			時相3			時相4			時相5		
		G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
07:10 ~ 09:30																
21	230	11	6	0	99	5	3	15	5	3	28	5	3	39	5	3
09:30 ~ 16:00																
01	160	66	5	3	20	5	3	19	5	3	23	5	3			
16:00 ~ 18:50																
06	240	10	6	0	100	5	3	24	5	3	30	5	3	38	5	3

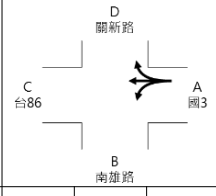
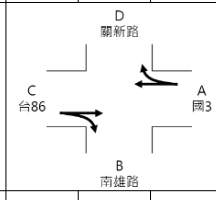
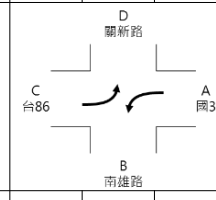
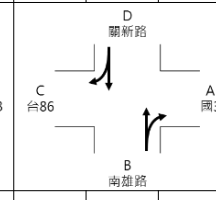
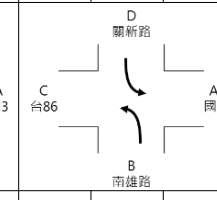
資料來源：本計畫整理

表 3.1.1-4 臺南市「台 86 線-台 19 甲線」路口平日週五號誌時制計畫

時制	週期	時相1			時相2			時相3			時相4			時相5		
		G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
07:10 ~ 08:00																
21	230	11	6	0	99	5	3	15	5	3	28	5	3	39	5	3
08:00 ~ 09:30																
02	200	16	6	0	79	5	3	15	5	3	26	5	3	26	5	3
09:30 ~ 15:30																
01	160	66	5	3	20	5	3	19	5	3	23	5	3			
15:30 ~ 20:00																
06	240	10	6	0	100	5	3	24	5	3	30	5	3	38	5	3

資料來源：本計畫整理

表 3.1.1-5 臺南市「台 86 線-台 19 甲線」路口假日號誌時制計畫

時制	週期	時相1			時相2			時相3			時相4			時相5		
		G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
15:30 ~ 20:00																
06	240	10	6	0	100	5	3	24	5	3	30	5	3	38	5	3

資料來源：本計畫整理

3.1.2 多路口幹道場域(臺北市「中山北路-德行東路」)

本計畫對場域主要路口及相關道路進行道路幾何及時制計畫調查，道路幾何情況與前期計畫調查內容大致相同；設備相較去年有所減少，中山北路/克強路及中山北路/195 巷兩處路口車流偵測設備已移除；時制計畫則有部分更動，各分相秒數亦有所調整，如下所述。

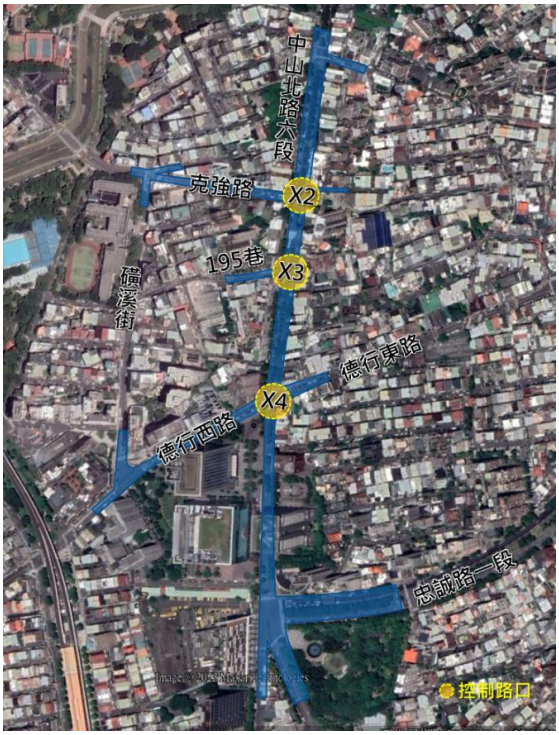


圖 3.1.2-1 臺北市「中山北路-德行東路」幹道位置示意圖

一、道路特性

調查範圍道路包含中山北路、德行東西路、195 巷及克強路，道路幾何特性資料彙整如表 3.1.2-1，包含了車道數、車道寬、分隔方式等，另本計畫於 113 年 6 月 22 月及 6 月 24 日重新進行路口轉向交通量調查，其調查結果整理如附錄三所示。

表 3.1.2-1 德行西路、195 巷及克強路路口道路幾何特性彙整表

路名	道路類型	車道數	車道寬	分隔方式	車種管制
路口 2 中山北路北向	一般道路	2	5.0(直外)、2.8(直內)	實體分隔	混合車道
路口 2 中山北路南向	一般道路	2	4.0(直外)、2.8(直內)	實體分隔	混合車道
路口 2 克強路	一般道路	1	3.2	雙黃線	混合車道
路口 3 中山北路北向	一般道路	2	5.4(直外)、2.8(直內)	實體分隔	混合車道
路口 3 中山北路南向	一般道路	2	4.2(直外)、2.8(直內)	實體分隔	混合車道
路口 4 中山北路北向	一般道路	3	3.0(直右)、3.0(直)、3.0(直左)	實體分隔	混合車道
路口 4 中山北路南向	一般道路	3	3.0(直右)、3.0(直)、3.0(直左)	實體分隔	混合車道
路口 4 德行東路	一般道路	1	4.5	雙黃線	混合車道
路口 4 德行西路	一般道路	2	3.0(直左)、3.5(直右)	雙黃線	混合車道

資料來源：交通部運輸研究所(2023)[73]

二、交通量量調查

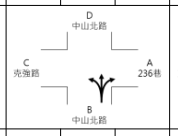
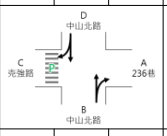
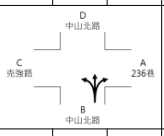
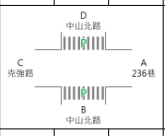
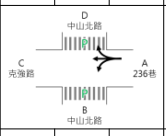
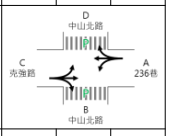
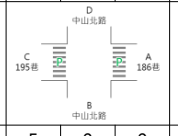
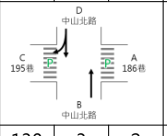
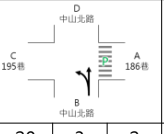
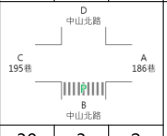
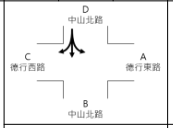
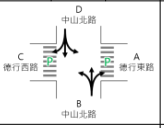
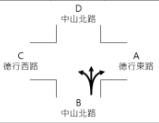
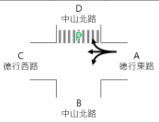
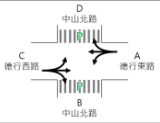
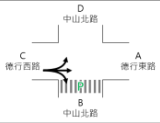
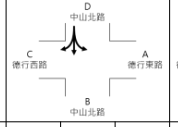
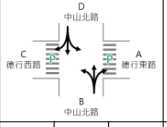
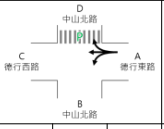
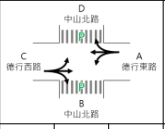
表 3.1.2-2 臺北市「中山北路-德行東路」場域前期及本期路口交通量比較

路口名稱	時段	時間	2023/7/13(四)、7/15(六)				時間	2024/06/20(四)、6/22(六)				各時段交通量差異	路口整體交通量差異
			A	B	C	D		A	B	C	D		
中山北路/290巷	平日晨峰	08:30-09:30	53	1159	-	1310	07:30-08:30	72	1018	-	1302	-5.15%	-6.46%
	平日離峰	14:00-15:00	36	973	-	1136	13:45-14:45	34	941	-	1069	-4.71%	
	平日昏峰	16:30-17:30	45	1096	-	1240	17:00-18:00	68	1067	-	1089	-6.59%	
	假日昏峰	17:00-18:00	41	1025	-	1213	16:45-17:45	39	921	-	1105	-9.39%	
中山北路/克強路	平日晨峰	08:30-09:30	40	1095	357	1344	07:30-08:30	48	1011	342	1394	-1.45%	-1.38%
	平日離峰	13:45-14:45	34	996	351	1100	13:45-14:45	33	966	280	1107	-3.83%	
	平日昏峰	16:30-17:30	44	1000	348	1168	17:00-18:00	36	1056	381	1168	3.16%	
	假日昏峰	16:45-17:45	33	886	378	1221	16:45-17:45	33	906	339	1154	-3.42%	
中山北路/195巷	平日晨峰	08:30-09:30	-	1173	-	1390	07:30-08:30	-	1109	-	1491	1.44%	-1.66%
	平日離峰	13:45-14:45	-	1051	-	1164	13:15-14:15	-	1003	-	1069	-6.46%	
	平日昏峰	07:15-08:15	-	921	-	1352	16:45-17:45	-	1093	-	1197	0.75%	
	假日昏峰	17:00-18:00	-	977	-	1223	16:00-17:00	-	1050	-	1098	-2.36%	
中山北路/德行西路	平日晨峰	08:00-09:00	659	1206	734	1553	07:30-08:30	614	1076	727	1614	-2.91%	-3.34%
	平日離峰	13:45-14:45	487	1190	623	1273	14:00-15:00	527	1094	616	1217	-3.33%	
	平日昏峰	17:15-18:15	705	1320	840	1275	17:15-18:15	696	1272	873	1223	-1.84%	
	假日昏峰	17:00-18:00	576	1085	736	1386	16:45-17:45	539	1032	714	1299	-5.26%	
中山北路/忠誠路一段	平日晨峰	08:00-09:00	1314	1970	-	1756	07:30-08:30	1322	1986	-	1669	-1.25%	0.28%
	平日離峰	14:00-15:00	1051	1742	-	1409	13:45-14:45	1018	1850	-	1374	0.95%	
	平日昏峰	17:00-18:00	1000	1967	-	1492	16:45-17:45	1124	2019	-	1472	3.50%	
	假日昏峰	17:00-18:00	1006	1919	-	1486	16:45-17:45	1070	1854	-	1395	-2.09%	
磺溪街/克強路	平日晨峰	08:15-09:15	230	177	542	21	07:30-08:30	298	183	622	31	16.91%	2.40%
	平日離峰	12:00-13:00	192	164	388	8	13:45-14:45	234	118	321	7	-9.57%	
	平日昏峰	17:15-18:15	286	191	466	7	17:30-18:30	288	208	493	14	5.58%	
	假日昏峰	16:45-17:45	234	148	397	9	17:00-18:00	246	136	371	9	-3.30%	
磺溪街/德行西路	平日晨峰	08:00-09:00	653	-	894	218	07:30-08:30	667	-	790	338	1.70%	-2.66%
	平日離峰	13:15-14:15	604	-	600	198	13:00-14:00	498	-	570	202	-9.42%	
	平日昏峰	17:15-18:15	708	-	736	284	17:30-18:30	675	-	822	294	3.65%	
	假日昏峰	16:30-17:30	565	-	692	237	17:00-18:00	524	-	679	193	-6.56%	

三、號誌時制計畫

整理臺北市中山北路六段/克強路、中山北路六段/195 巷、中山北路六段/德行西路等路口時制計畫與時相組態，如表 3.1.2-3 所示。

表 3.1.2-3 德行西路、195 巷及克強路路口號誌時制計畫

時段	時制	週期	時差	時相1			時相2			時相3			時相4			時相5			時相6		
				G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
中山北路/克強路																					
平日晨峰	09	200	70	9	0	0	102	3	2	6	3	3	9	0	0	14	0	0	44	3	2
平日離峰	04	150	70	9	0	0	64	3	2	6	3	3	9	0	0	14	0	0	32	3	2
平日離峰	02	200	68	9	0	0	101	3	2	6	3	3	9	0	0	14	0	0	45	3	2
平日昏峰	10	200	70	8	0	0	94	3	2	10	3	3	9	0	0	14	0	0	49	3	2
假日昏峰	03	200	69	9	0	0	102	3	2	6	3	3	9	0	0	14	0	0	44	3	2
中山北路/195巷																					
平日晨峰	09	200	65	5	0	0	130	3	2	20	3	2	30	3	2						
平日離峰	04	150	60	5	0	0	90	3	2	10	3	2	30	3	2						
平日離峰	02	200	60	5	0	0	110	3	2	20	3	2	50	3	2						
平日昏峰	10	200	60	5	0	0	110	3	2	20	3	2	50	3	2						
假日昏峰	03	200	70	5	0	0	130	3	2	20	3	2	30	3	2						
中山北路/德行西路																					
																					
平日晨峰	09	200	70	10	0	0	84	3	2	5	3	2	23	0	0	40	3	2	18	3	2
平日離峰	04	150	65	15	0	0	56	3	2	5	3	2	14	0	0	29	3	2	11	3	2
平日離峰	02	200	60	13	0	0	85	3	2	8	3	2	15	0	0	46	3	2	13	3	2
平日昏峰	10	200	65	10	0	0	83	3	2	19	0	0	50	3	2	23	3	2			
假日昏峰	03	200	70	10	0	0	86	3	2	5	3	2	15	0	0	45	3	2	19	3	2

資料來源：本計畫整理

3.2 都會區人工智慧號誌控制模型優化與精進

3.2.1 臺北市實驗場域模擬模式校估與驗證

為確保評估方案與現實交通環境能有相同的表現行為，模擬環境的校準過程相當重要，而由於本期臺北市實驗場域時制計畫與前期略有不同，並於 6/20(四)及 6/22(日)進行轉向交通量調查，因此於 SUMO 模擬模式的時制計畫、流量及轉向量進行調整後，亦須重新校估。校估指標參考國內外建議手冊與案例，說明如下：

一、校估指標選取

AI 的訓練過程是透過大量與環境互動的經驗累積所得出的決策優化過程。而此一與環境

的互動在實務上不宜直接讓 AI 在真實的交通環境下進行訓練，因此創建一個與真實交通狀態近似的互動環境，透過設定模擬軟體中甚多參數，使模擬績效指標值與現場調查績效指標值誤差能在接受範圍內。

驗證的項目主要指標為轉向交通量(流量)，計算方式為計算各方向、各轉向於 2 小時內的通過 PCU 數量與實際調查值以平均絕對百分比誤差(MAPE)做為量化誤差指標。而由於文獻回顧中較少採用此項指標進行驗證工作，因此在本案中將平均每車延滯做為輔助驗證指標。

為了確保模擬結果能夠反應實際交通行為，參考國內外相關案例後整理如表 3.2.1-1 所示，設定本計畫參數組必須滿足以下門檻：

(一) 轉向交通量之 MAPE≤10%

(二) 總停等延滯 MAPE≤20%

(三) 旅行時間 MAPE≤15%

從模擬校估相關文獻回顧當中可以發現到，絕大部分的微觀模擬仍是以交通流量作為主要的校估指標，在延滯部分則是受到實務上調查困難，調查自身數據存在一定程度誤差，故較少文獻使用。

表 3.2.1-1 國內外模擬校估績效指標及範圍

國內外案例	採用校估績效指標		
	平均流量	平均旅行時間 (or 平均速率)	平均停等延滯
107 年，交通改善措施微觀車流模擬成效評估案	< 10%	--	--
102 年，交通技術研發與人才培育規劃研究(4/4)	< 20%	--	< 30%
96 年，公路工程設計輔助工具引進與應用之研究	< 10%	< 15%	--
105 年，台 9 線蘇花改通車後對蘇澳地區交通衝擊影響評估分析	< 20%	< 20%	--
107 年，大新竹運輸走廊整合道路交通與電信資訊應用	< 20%	--	--
Calibration of VISSIM for Indian Heterogeneous Traffic Conditions, 2013	< 10%	--	--
Core of Rosslyn Transportation Study Existing Conditions Report, 2018	< 15%	< 15%	--
Calibration of VISSIM and QuickZone programs for work zone traffic impact analysis, 2015	--	< 15%	< 15%

資料來源：本計畫整理

而採用 MAPE 作為驗證統計量經常受到的批評為當部分轉向或路段的調查值本身數值較低時，容易很大程度的影響 MAPE 的數值，導致其評估結果有失客觀；反之，當調查數值極大時，MAPE 也容易低估，造成配適良好的假象。在文獻回顧中，為避免此種狀況，亦常見到以 GEH 統計量(Geoffrey E. Havers)來做為衡量模型是否為良好適配的指標。GEH 的計算方式如下：

$$GEH = \sqrt{\frac{2(M-C)^2}{M+C}}$$

其中，M 為模型輸出數值；C 為實際觀測數值。

由於 GEH 並非如 MAPE 可對於不同項目直接進行平均得到單一衡量數值，因此參考美國內華達州運輸部門所建議的作法，至少 75%的轉向交通量之 GEH 需小於 5。

表 3.2.1-2 國內外模擬校估績效指標及範圍

GEH 接受門檻(兩項皆需滿足)
GEH<5，對於至少 85%的路段
GEH<10，對於至少 100%的路段
GEH<5，對於至少 75%的轉向量
GEH<10，對於至少 95%的轉向量

而 GEH 統計量則可以一定程度的避免由於數值偏小造成的偏誤狀況。GEH 統計量在極大數值與極小數值的狀況下，可以有效的避免偏誤的狀況發生，表 3.2.1-3 中說明即使誤差百分比都在 10%的狀況，絕對誤差量仍可能非常高；反之在誤差量低的情況則也可能有百分比極高的狀況發生。而表中 GEH 統計量相較於誤差百分比則顯得更為客觀評估模擬與實際的誤差狀況。

表 3.2.1-3 GEH 和誤差百分比的比較分析

M	C	GEH	%Difference
10000	9000	10.3	10%
100	900	3.2	10%
100	90	1.0	10%
10000	9520	4.9	5%
100	850	4.9	18%
100	57	4.9	75%

本期已完成臺北市實驗場域 4 個時段資料校估之模擬路網比對交通調查數值，其各路口模擬誤差驗證如表 3.2.1-4~3.2.1-7 所示。

表 3.2.1-4 臺北市實驗場域平日晨峰 SUMO 流量 GEH 及 MAPE

路口	路口調查方向	方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE 指標 %	GEH 指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
中山北路 / 290 巷	290 巷往西	←	33	20	-39.4%	2.53
	中山北路往北	↑	706	759	+7.5%	1.96
	-	→	-	-	-	-
	中山北路往南	↓	925	963	+4.1%	1.24
中山北路 / 克強路	-	←	-	-	-	-
	中山北路往北	↑	728	720	-1.1%	0.30
	克強路往東	→	222	217	-2.3%	0.34
	中山北路往南	↓	975	981	+0.6%	0.19
中山北路 / 195 巷	-	←	-	-	-	-
	中山北路往北	↑	810	776	-4.2%	1.21
	-	→	-	-	-	-
	中山北路往南	↓	1,074	999	-7.0%	2.33
中山北路 / 德行西路	德行東路往西	←	320	412	+28.8%	4.81
	中山北路往北	↑	758	839	+10.7%	2.87
	德行西路往東	→	459	398	-13.3%	2.95
	中山北路往南	↓	1,123	1,187	+5.7%	1.88
中山北路 / 忠誠路一段	忠誠路一段往西	←	1,026	1,277	+24.5%	7.40
	中山北路往北	↑	1,348	1,348	+0.0%	0.00
	-	→	-	-	-	-
	中山北路往南	↓	1,036	1,249	+20.6%	6.30
平均					+2.3%	2.42

表 3.2.1-5 臺北市實驗場域平日離峰 SUMO 流量 GEH 及 MAPE

路口	路口調查方向	方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE 指標 %	GEH 指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
中山北路 / 290 巷	290 巷往西	←	15	17	+13.3%	0.50
	中山北路往北	↑	677	708	+4.6%	1.18
	-	→	-	-	-	-
	中山北路往南	↓	834	665	-20.3%	6.17
中山北路 / 克強路	-	←	-	-	-	-
	中山北路往北	↑	753	690	-8.4%	2.35
	克強路往東	→	168	201	+19.6%	2.43
	中山北路往南	↓	846	681	-19.5%	5.97
中山北路 / 195 巷	-	←	-	-	-	-
	中山北路往北	↑	815	720	-11.7%	3.43
	-	→	-	-	-	-
	中山北路往南	↓	861	707	-17.9%	5.50
中山北路 / 德行西路	德行東路往西	←	285	258	-9.6%	1.67
	中山北路往北	↑	804	798	-0.7%	0.21
	德行西路往東	→	425	391	-8.0%	1.68
	中山北路往南	↓	941	708	-24.8%	8.11
中山北路 / 忠誠路一段	忠誠路一段往西	←	735	655	-10.9%	3.03
	中山北路往北	↑	1,361	1,350	-0.8%	0.30
	-	→	-	-	-	-
	中山北路往南	↓	1,011	1,517	+50.0%	14.23
平均					-3.0%	3.78

表 3.2.1-6 臺北市實驗場域平日昏峰 SUMO 流量 GEH 及 MAPE

路口	路口調查方向	方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE 指標 %	GEH 指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
中山北路 / 290 巷	290 巷往西	←	36	28	-22.2%	1.41
	中山北路往北	↑	793	852	+7.4%	2.06
	-	→	-	-	-	-
	中山北路往南	↓	759	648	-14.6%	4.18
中山北路 / 克強路	-	←	-	-	-	-
	中山北路往北	↑	793	766	-3.4%	0.97
	克強路往東	→	232	240	+3.4%	0.52
	中山北路往南	↓	796	655	-17.7%	5.23
中山北路 / 195 巷	-	←	-	-	-	-
	中山北路往北	↑	848	839	-1.1%	0.31
	-	→	-	-	-	-
	中山北路往南	↓	815	636	-22.0%	6.65
中山北路 / 德行西路	德行東路往西	←	339	357	+5.2%	0.94
	中山北路往北	↑	872	872	+0.0%	0.00
	德行西路往東	→	571	493	-13.7%	3.38
	中山北路往南	↓	892	876	-1.7%	0.52
中山北路 / 忠誠路一段	忠誠路一段往西	←	762	774	+1.5%	0.42
	中山北路往北	↑	1,498	1,505	+0.5%	0.18
	-	→	-	-	-	-
	中山北路往南	↓	871	858	-1.5%	0.44
平均					-5.3%	1.81

表 3.2.1-7 臺北市實驗場域假日昏峰 SUMO 流量 GEH 及 MAPE

路口	路口調查方向	方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE 指標 %	GEH 指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
中山北路 / 290 巷	290 巷往西	←	23	22	-4.3%	0.21
	中山北路往北	↑	665	744	+11.9%	2.98
	-	→	-	-	-	-
	中山北路往南	↓	838	626	-25.3%	7.84
中山北路 / 克強路	-	←	-	-	-	-
	中山北路往北	↑	652	742	+13.8%	3.41
	克強路往東	→	226	213	-5.8%	0.88
	中山北路往南	↓	868	645	-25.7%	8.11
中山北路 / 195 巷	-	←	-	-	-	-
	中山北路往北	↑	676	764	+13.0%	3.28
	-	→	-	-	-	-
	中山北路往南	↓	923	833	-9.8%	3.04
中山北路 / 德行西路	德行東路往西	←	276	174	-37.0%	6.80
	中山北路往北	↑	729	823	+12.8%	3.36
	德行西路往東	→	535	470	-12.1%	2.90
	中山北路往南	↓	1,018	1,107	+8.8%	2.74
中山北路 / 忠誠路一段	忠誠路一段往西	←	798	793	-0.6%	0.18
	中山北路往北	↑	1,392	1,413	+1.5%	0.56
	-	→	-	-	-	-
	中山北路往南	↓	997	1,030	+3.3%	1.03
平均					-3.7%	3.15

二、參數調校

本計畫強化學習號誌控制都會區模型以臺南市「台 86-19 甲」和臺北市「中山北路-德行東路」兩種不同場域進行驗證。選擇這些場域的原因在於其交通結構的代表性，前者為單一路口，後者為多路口幹道。

模擬模型的初始設定可能與現場交通條件不完全吻合，透過參數微調與校正，驗證模擬環境指標和參數，讓模擬結果更接近真實交通情境。調校過程並無一定程序，但應一次調整單一參數，藉以了解各參數之影響力，應對模型誤差的來源進行細緻分析如靜態與動態參數的影響，以科學方法釐清問題，並在多次調整與驗證中確保結果的準確性。驗證過程中，採用數個關鍵效能指標及參數說明如下：

(一)驗證目標與指標

1. 路口延滯時間：衡量平均等待時間，期望減少 3%以上。

2. 紓解率：以 SUMO 進行微觀交通模擬觀測車流是否更順暢，或擁堵現象是否減少。

3. 通行效率：每小時通過路口的車輛數提升。

4. 車輛排隊長度：觀察車輛的排隊情況。

(二)靜態及動態參數

1. 靜態參數：運具平均車長、加減速度等，路網如道路線寬、路口優先性等。

2. 動態參數：跟車模式、駕駛行為等。

調校過程揭示模擬模型中不同參數對模擬結果的影響，為釐清可能的問題來源，並針對問題進行有針對性的優化提供了理論支持。若以單一參數調整後問題仍無法解決，再以組合方式調整兩項以上之參數，但須確定參數間相互作用所產生之影響符合實際車流情況，並反覆校正以上程序，直到誤差符合模型校估門檻。透過模型校估，提升模擬結果的準確性與可信度，並確保模擬過程的科學性，此過程對於最終績效指標(如旅行時間與延滯)的數據可信度至關重要。

三、路網微調

此步驟可於參數調校後仍無法令模擬車流與實際車流的誤差小於所設定門檻時進行。例如普遍性的違規(如跨越雙白線)等，雖於交通規則並不允許，然為忠實反映實際狀況，仍應將此一情形透過路網微調步驟修正。

3.2.2 都會區 AI 號誌控制模型精進

一、都會區 AI 號誌控制模規劃

(一)臺南市實驗場域

臺南市實驗場域 AI 號誌控制模型由一個代理人(Agent)控制該路口，於每週期結束時進行決策，將輸入各時相結束時之道路資訊與號誌資訊，輸出下個週期秒數與各時相秒數。設定 4 個獎勵目標(Reward)，分別為幹支道通過量與延滯車輛數，為加快 AI 號誌控制模型訓練速度與避免過大或過小秒數探索，使用固定時制(TOD)的平均績效進行獎勵計算方式的正規化，詳細績效計算公式列如表 3.2.2-1。

本計畫為發展 AI 號誌控制模型於實務上之便利性，探討如何使用單一模型處理各時段不同之時制計畫編號與其時相型態，因此除延續前期計畫 AI 號誌控制模型設計外，新增 Pearl 網路架構，利用模型參數自行判別時段與其時制型態，以適應不同之時

制計畫編號下的時相型態。其 AI 號誌控制模型學習設計如表 3.2.2-2 說明以供參考。

表 3.2.2-1 臺南市實驗場域 AI 號誌控制模型獎勵計算公式表

定義	計算方式
台 86 線延滯時間與固定時制的變化量	$\frac{\text{台 86 線總延滯時間} - \text{固定時制台 86 線總延滯時間}}{\text{固定時制台 86 線總延滯時間}}$
支道延滯時間與固定時制的變化量	$\frac{\text{台 19 甲線總延滯時間} - \text{固定時制台 19 甲線總延滯時間}}{\text{固定時制台 19 甲線總延滯時間}}$
台 86 線通過量與固定時制的變化量	$\frac{\text{台 86 線通過量} - \text{固定時制台 86 線通過量}}{\text{固定時制台 86 線通過量}}$
支道通過量與固定時制的變化量	$\frac{\text{台 19 甲線通過量} - \text{固定時制台 19 甲線通過量}}{\text{固定時制台 19 甲線通過量}}$

表 3.2.2-2 臺南市實驗場域 AI 強化學習模型設計

	Context Network (Q-Pensieve)	Task Network (PEARL)
定義	該時段每個週期之內容	週期結束時存取 Context Replay Buffer 與 Q-Pensieve Replay Buffer 中各時段資訊
代理人數量	1	1
輸入	號誌資訊：上個週期之路口週期秒數及各時相秒數	號誌資訊：隨機取樣出各時段兩小時每週期之路口週期秒數及各時相秒數
	道路資訊：各分相結束時分車道分車種(大/小/機車)停等車輛數及總車輛數	道路資訊：隨機取樣出各時段兩小時每週期各分相結束時分車道分車種(大/小/機車)停等車輛數及總車輛數
輸出	下個週期 AI 控制路口之週期秒數及時相比例	判別之時段模型參數(context_z)
決策頻率	週期結束時決策	週期結束時決策
獎勵目標	台 86 線延滯數量與固定時制之變化值	台 86 線延滯數量與固定時制之變化值
	台 19 甲線延滯數量與固定時制之變化值	台 19 甲線延滯數量與固定時制之變化值
	台 86 線通過量與固定時制之變化值	台 86 線通過量與固定時制之變化值
	台 19 甲線通過量與固定時制之變化值	台 19 甲線通過量與固定時制之變化值
權重設定	向量組合：[幹道延滯，支道延滯，幹道通過量，支道通過量] 1.偏重幹道：[0.4, 0.1, 0.4, 0.1]　2.偏重通過量：[0.1, 0.1, 0.4, 0.4,] 3.偏重支道：[0.1, 0.4, 0.1, 0.4]　4.偏重延滯：[0.4, 0.4, 0.1, 0.1]	

(二)臺北市實驗場域

臺北市實驗場域 AI 號誌控制模型規劃由一個代理人(Agent)蒐集中山北路六段/克強路口、中山北路六段/195 巷、中山北路六段/德行西路口等 3 個路口之道路與號誌資訊。今年度因現場車流偵測設備位置更動，僅中山北路六段/德行西路具車流偵測設備，故計畫嘗試於都會區幹道採用 AI 號誌控制模型進行協控。以中山北路六段/德行西路口作為主控路口，提供 AI 號誌控制模型道路車流資訊，以及輸入 3 個路口號誌資訊進

行運算，AI 號誌控制模型輸出主控路口(中山北路六段/德行西路口)之週期秒數與各時相秒數，以此調配其餘兩個路口之時相秒數，確保週期一致且車流可續進至下游路口。模型學習設計詳如表 3.2.2-3 與表 3.2.2-4 說明。

表 3.2.2-3 臺北市實驗場域 AI 號誌控制模型獎勵計算公式表

定義	計算方式
幹道延滯時間與固定時制的變化量	$\frac{\text{幹道總延滯時間} - \text{固定時制幹道總延滯時間}}{\text{固定時制幹道總延滯時間}}$
支道延滯時間與固定時制的變化量	$\frac{\text{支道總延滯時間} - \text{固定時制支道總延滯時間}}{\text{固定時制支道總延滯時間}}$
幹道通過量與固定時制的變化量	$\frac{\text{幹道通過量} - \text{固定時制幹道通過量}}{\text{固定時制幹道通過量}}$
支道通過量與固定時制的變化量	$\frac{\text{支道通過量} - \text{固定時制支道通過量}}{\text{固定時制支道通過量}}$

表 3.2.2-4 臺北市實驗場域 AI 強化學習模式規劃表

定義	內容
代理人數量	1
輸入	號誌資訊：上個週期路口週期秒數與各時相秒數
	道路資訊：各分相結束時分車道分車種(大/小/機車)之停等數與總車輛數
輸出	下個週期秒數與各時相秒數
決策頻率	週期結束時決策
獎勵目標	德行西路延滯數量與固定時制之變化值
	中山北路延滯數量與固定時制之變化值
	德行西路通過量與固定時制之變化值
	中山北路通過量與固定時制之變化值
權重設定	向量組合：[幹道延滯，支道延滯，幹道通過量，支道通過量] 1.偏重幹道：[0.4, 0.1, 0.4, 0.1]　2.偏重通過量：[0.1, 0.1, 0.4, 0.4,] 3.偏重支道：[0.1, 0.4, 0.1, 0.4]　4.偏重延滯：[0.4, 0.4, 0.1, 0.1]

二、都會區 AI 號誌控制強化學習模型訓練規劃

(一)臺南市實驗場域

1. 晨峰時段

臺南市晨峰時段使用之演算法與前期相同為 Q-Pensieve，其訓練架構如圖 3.2.2-1。

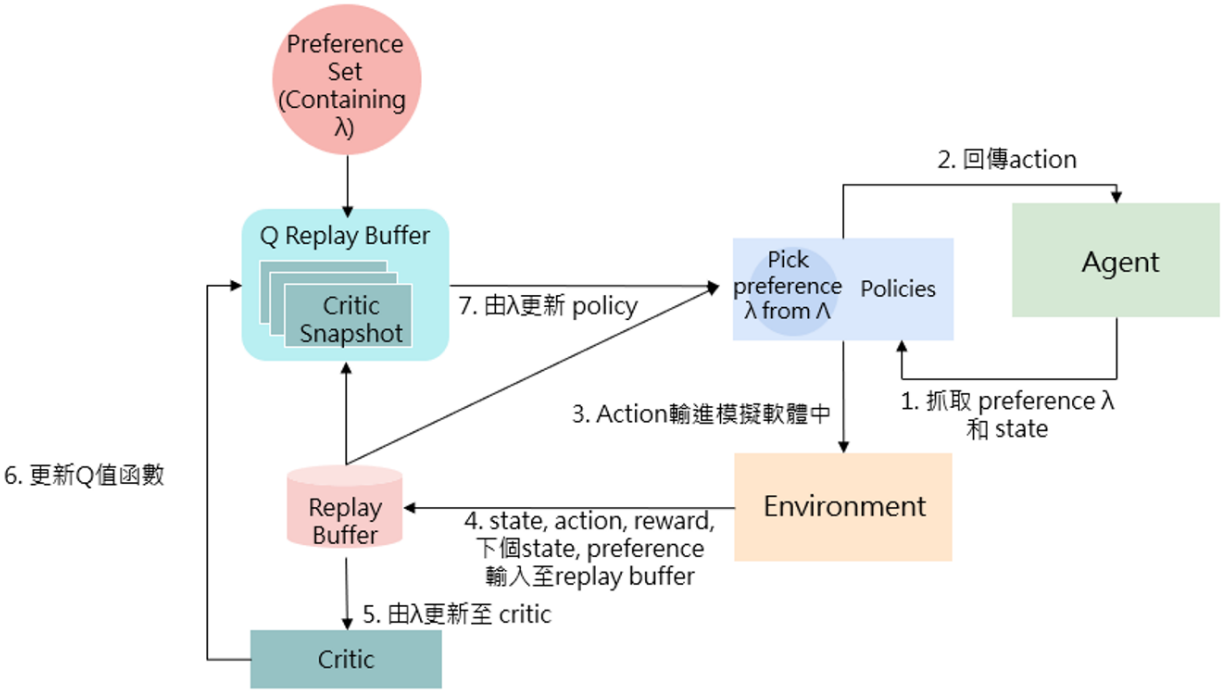


圖 3.2.2-1 臺南市晨峰時段之模型訓練架構圖

(1) 代理人(Agent)從模擬環境抓取狀態(State)，並從本身選取一個策略函數的獎勵偏好(preferenceλ)給予 Policy Network。Policy Network 負責於確定狀態(State)和獎勵偏好(preference)時進行採取動作(Action)決策的函數，該函數目標為最大化從環境獲得的累積獎勵，並持續更新與優化以提高在不同狀態下選擇動作的能力。

(2) 將模型決策回傳至代理人(Agent)。

(3) 將時相秒數之結果(Action)輸入進模擬環境裡產出下個環境變化(State)和獎勵(Reward)。

(4) 將這次的環境(State)、動作(Action)、獎勵(Reward)和下個環境(State)，並梳理成一筆數據存進 replay buffer(資料庫)。

上述步驟會重複直至資料庫含有一定數量才會進行下一步。

(5) 從資料庫裡隨機抽樣一定數量的環境(State)、動作(Action)、獎勵(Reward)和下個環境(State)給予 Critic Network 並由它評估產出此環境(State)的策略預期價值(會有好有壞)。而後續將會持續更新和改進以更準確地估計此策略的預期價值。

(6) 預期價值以 Q 值函數 Q(s,a)為輸出(output)，並儲存到另外一種資料庫(Q replay buffer)。Q replay buffer 會存取 Critic Network 所產出的 Q 值函數並以兩種資料：preference set(λ)、資料庫(replay buffer)的各種過去資料作為輸入。

(7) 從資料庫(replay buffer)裡隨機選擇一定數量的 experience，Q-replay buffer

會利用這些動作(Action)使用的 λ 和 preference set 抽取出不同 λ 產出不同的 Q 值函數來更新 Policy Network。

重複上述步驟直至模型收斂。

2. 其餘時段(離峰、昏峰、假日昏峰)

臺南市其餘時段如(離峰、昏峰、假日昏峰)使用之演算法為 Q-Pensieve 並且銜接了 Pearl 架構中的 Context Network，而 Context Network 主要是將輸入後的各時段之號誌與流量資料，通過資料前處理成同維度資料以讓模型學習各時段時制型態特性，使 AI 號誌控制模型得以自行決定資料符合之時段週期秒數與各時相秒數。其訓練架構如圖 3.2.2-2。

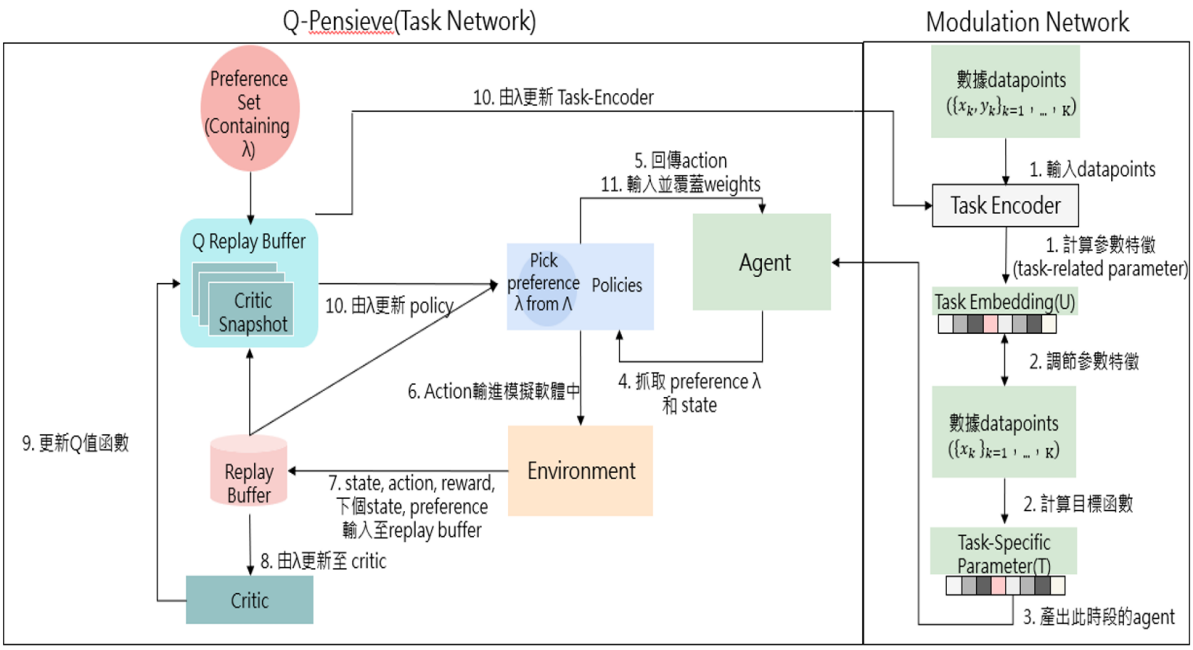


圖 3.2.2-2 臺南市實驗場域離峰/昏峰/假日昏峰模型訓練架構圖

Context Network 輸入各時段之號誌與流量資料，透過資料前處理成同維度資料，以讓模型學習各時段時制型態特性，使 AI 號誌控制模型得以自行決定資料符合之時段週期秒數與各時相秒數。

(1) 從 Context Replay Buffer 中取出歷史訓練資訊進 Context Network 中的 Task Encoder。

(2)通過 Task Encoder 裡的神經網絡將各時段資料之狀態(State)、動作(Action)、獎勵(Reward)轉換並映射至隨機向量(latent vector)使其計算出不同任務(時段)中的隱藏信息，如：時段特性、獎勵結構或動態分佈。所計算出之潛在變量為根據輸入資訊所推測出的時段向量(context_z)，該向量捕捉了當前任務的關鍵特徵。

(3) 關鍵特徵則會在 Context Network 裡轉換，準備與代理人(Agent)的狀態

(State)進行互動產出其時段中的週期與各時相秒數(Action)。

(4) Policy Network 從模擬環境抓取狀態(State)與獎勵偏好(preference)並與時段向量(context_z)計算出其週期秒數與各時相秒數。

(5) 將模型決策回傳至代理人(Agent)。

(6) 將模型輸出輸入進模擬軟體產出下個環境(State)和獎勵(Reward)。

(7) 將這次的環境(State)、動作(Action)、獎勵(Reward)和下個環境(State)梳理成一個數據資料(data transition)存進資料庫(replay buffer 與 context replay buffer)。

上述步驟會重複直至資料庫含有一定數量才會進行下一步。

(8) 從資料庫裡隨機選擇一定數量的環境(State)、動作(Action)、獎勵(Reward)和下個環境(State)給予 Critic Network 並由它評估產出此環境(State)的策略預期價值(會有好有壞)。而後續將會持續更新和改進以更準確地估計此策略的預期價值。

(9) 而這價值會以 Q 值函數 Q(s,a)為輸出(output)，並儲存到另外一種資料庫(Q replay buffer)。Q replay buffer 會存取 Critic Network 所產出的 Q 值函數並以兩種資料：preference set(λ)、資料庫(replay buffer)的各種過去資料作為輸入。

(10) 從資料庫(replay buffer)裡隨機選擇一定數量的 experience，Q-replay buffer 會利用這些 Action 使用的 λ 和 preference set 抽取出不同 λ 產出不同的 Q 值函數來更新 Modulation Network 中的神經網並同時也會用於更新代理人中的 Policy Network。

(11) 步驟十中的 Q 值函數也會用於更新 Context Network 中的 Task Encoder。

重複上述所有步驟直至模型收斂。

(二)臺北市實驗場域

臺北市實驗場域使用之演算法為 Q-Pensieve，並且利用主協控設計其餘控制路口之時相秒數。其訓練架構圖如圖 3.2.2-3。

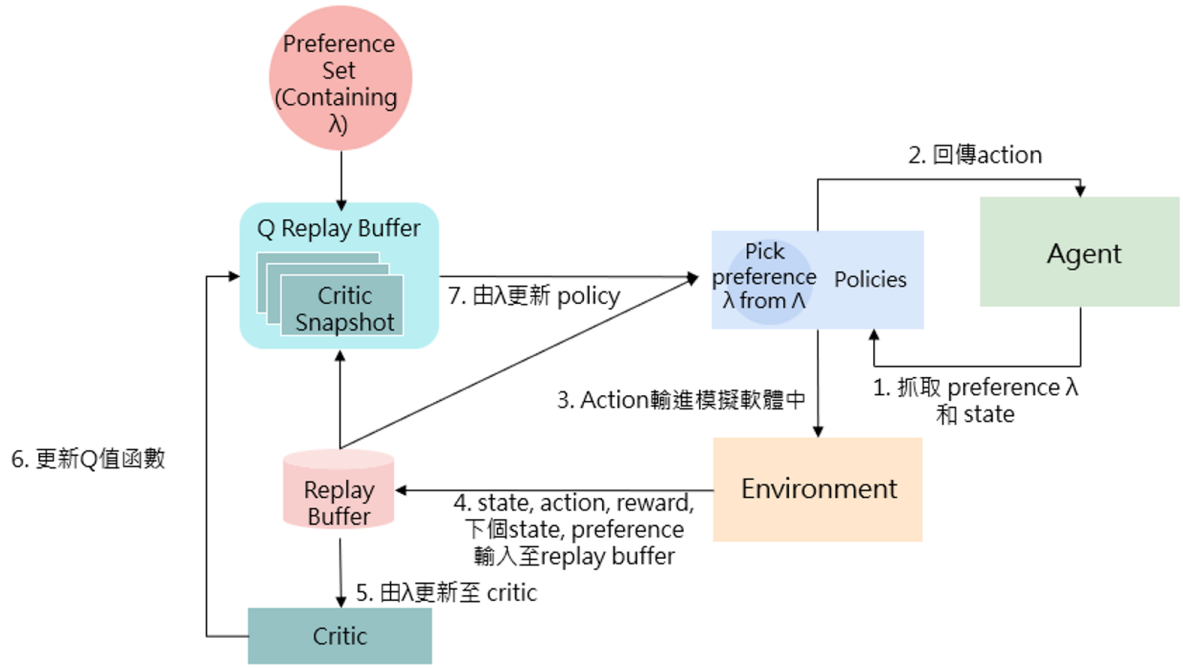


圖 3.2.2-3 臺北市實驗場域模型訓練架構圖

1.代理人(Agent)從模擬環境抓取狀態(State)，並從本身選取一個策略函數的獎勵偏好(preferenceλ)給予 Policy Network。Policy Network 負責於確定狀態(State)和獎勵偏好(preference)時進行採取動作(Action)決策的函數，該函數目標為最大化從環境獲得的累積獎勵，並持續更新與優化以提高在不同狀態下選擇動作的能力。

2.Policy Network 從策略函數中計算主控路口之週期與各時相秒數(Action)準備與環境互動。

3.通過主控路口之週期與時相秒數，調配出其餘路口之相關時相秒數確保週期一致並含有續進邏輯回傳至 policy network。

4.將主控路口與協控秒數之結果(Action)輸入進模擬環境裡產出下個環境變化(State)和獎勵(Reward)。

5.將這次的環境(State)、動作(Action)、獎勵(Reward)和下個環境(State)梳理成一筆數據存進 replay buffer(資料庫)。

6.上述步驟會重複直至資料庫含有一定數量才會進行下一步。

7.從資料庫裡隨機抽樣一定數量的環境(State)、動作(Action)、獎勵(Reward)和下個環境(State)給予 Critic Network 並由它評估產出此環境(State)的策略預期價值(會有好有壞)。而後續將會持續更新和改進以更準確地估計此策略的預期價值。

8.預期價值以 Q 值函數 Q(s,a)為輸出(output)，並儲存到另外一種資料庫(Q replay buffer)。Q replay buffer 會存取 Critic Network 所產出的 Q 值函數並以兩種資料：

preference set(λ)、資料庫(replay buffer)的各種過去資料作為輸入。

9.從資料庫(replay buffer)裡隨機選擇一定數量的 experience，Q-replay buffer 會利用這些動作(Action)使用的 λ 和 preference set 抽取出不同 λ 產出不同的 Q 值函數來更新 Policy Network。

10.重複上述步驟直至模型收斂

3.2.3 訓練環境程式與軟硬體說明

VISSIM 以 COM API 指令動態調整並取得模擬環境中資訊，SUMO 則是以 TraCI API 指令動態調整並取得模擬環境中資訊。在模擬中，兩者都是用 Python 程式介接取得環境中的狀態或是號誌燈號與其秒數。在訓練開始前取得模擬資料，如：轉向、流量與路網等資料，在模擬開始後初始化所需紀錄之參數，於暖機時間後開始紀錄狀態(State)，獎勵(Reward)，動作(Action)等模型所需資訊。待代理人(Agent)需做決策時(週期結束)，將收集的狀態(State)、動作(Action)、獎勵(Reward)給予模型並由模型參數產出下次動作秒數(Action)。如上述動作持續執行模擬與收集績效，從收集資訊提供給代理人(Agent)至代理人(Agent)產出動作(Action)為一個訓練步數(step)，重複執行訓練步數(step)，直到兩小時模擬時間結束再進行模型更新，並儲存為一個訓練回合(episode)。

另外，本研究所使用的軟硬體如表 3.2.3-1，AI 號誌控制模型訓練以 Pytorch 構建神經網絡與強化學習架構，並以 VISSIM，SUMO 作為模擬環境，其中 VISSIM 版本為 2022 SP09、SUMO 為 1.16.0、Pytorch 為 2.0.1、Python 為 3.9。

表 3.2.3-1 AI 號誌控制模型訓練使用之軟硬體規格

項目	規格
CPU	AMD Ryzen 9 7950x 16-Core Processor
GPU	NVIDIA GeForce RTX 4090
Python	3.9
Pytorch	2.0.1
VISSIM	2022 SP 09
SUMO	1.16.0

3.2.4 訓練結果

臺南市與臺北市實驗場域各時段之 AI 號誌控制模型訓練結果如圖 3.2.4-1 至圖 3.2.4-6，其中 X 軸為訓練步數，Y 軸為 AI 號誌控制模型收斂值，收斂值用於衡量 AI 號誌控制模型預測結果與實際結果之誤差，收斂值越高代表誤差越大，收斂值越低則代表誤差越小，而其中之收斂值只要低於 0 代表模型對於決策動作帶來更好的獎勵績效。表 3.2.4-1 與表 3.2.4-2 為臺南市實驗場域各時段使用之超參數，表 3.2.4-3 為臺北市實驗場域使用之超參數。

而收斂值源於演算法中的計算公式(loss function)而得，Q-Pensieve 演算法主要計算方式主要來源於時間差分誤差(TD error)與回歸損失(regression loss)，公式如下：

$$\delta = \mathbb{E}[\left(R + \gamma \overset{max}{a'} Q_{\theta'}(s', w_a) - Q_\theta(s, w_a)\right)] \sim \text{(TD error)}$$

$$Loss(\mathcal{L}_\pi) = -\mathbb{E}_{s\sim D, a\sim\pi}(\delta) \sim \text{(regression loss)}$$

其中 R 是實際獎勵值，γ 為折扣因子，$Q_\theta(s, w_a)$為當前狀態 S 與動作 a 所預測之 Q 值，$Q_{\theta'}(s', w_a')$則為針對新狀態與動作 a 的預測值。其主要是通過時間差分誤差來學習過去狀態與新狀態的 Q 值變化，並在通過回歸損失找出能 Q 值最大化之動作使其收斂值為最小。

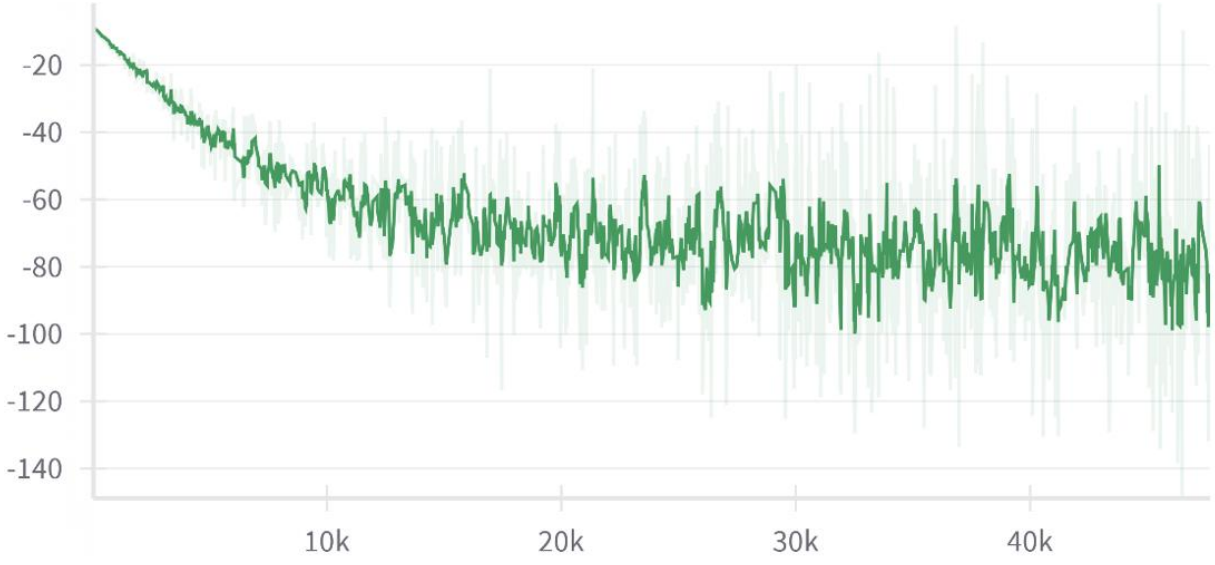


圖 3.2.4-1 臺南市實驗場域晨峰時段 Q-Pensieve 收斂

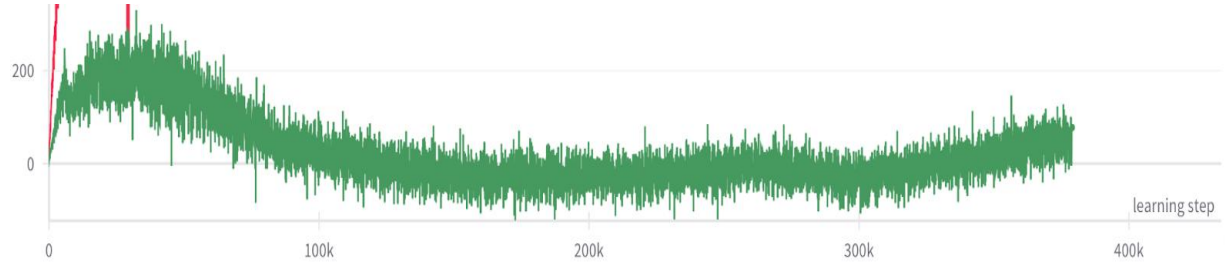


圖 3.2.4-2 臺南市實驗場域(離峰、昏峰、假日昏峰)時段之 Pearl 演算法收斂圖

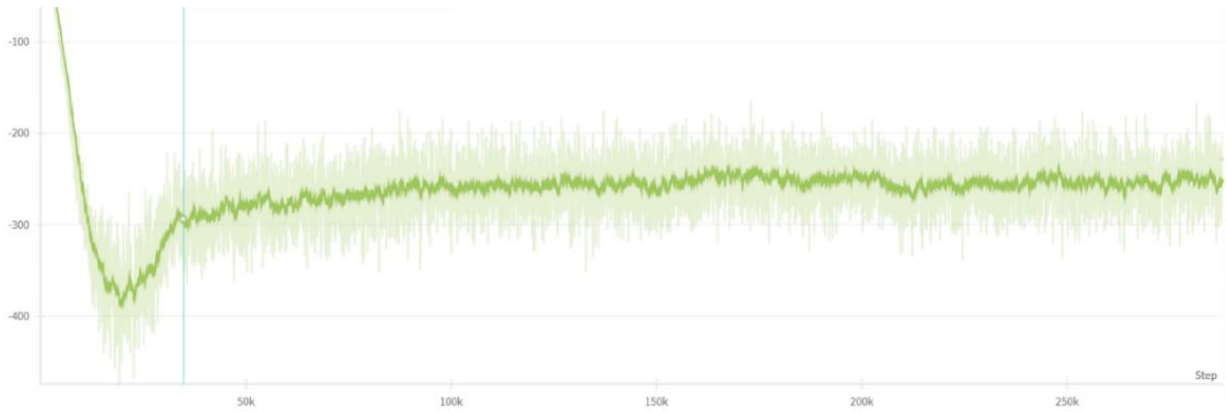


圖 3.2.4-3 臺北市實驗場域晨峰時段收斂圖

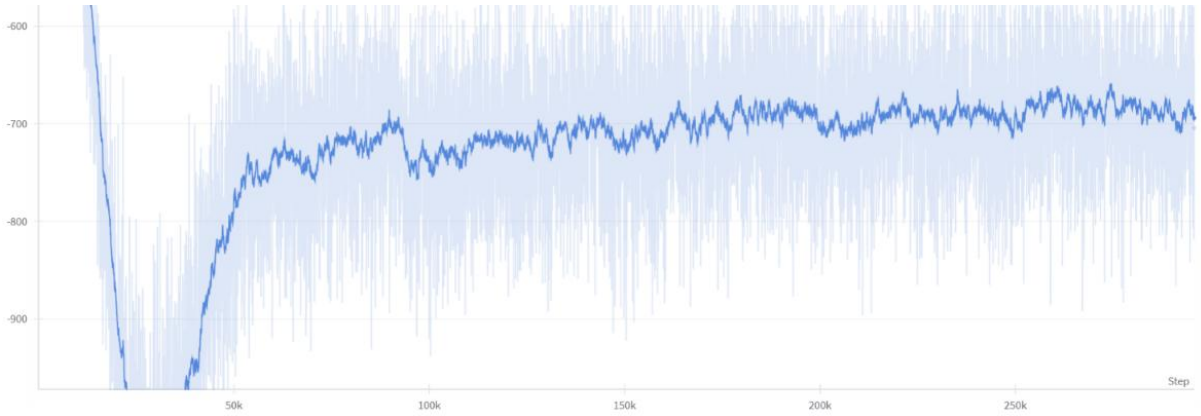


圖 3.2.4-4 臺北市實驗場域離峰時段收斂圖

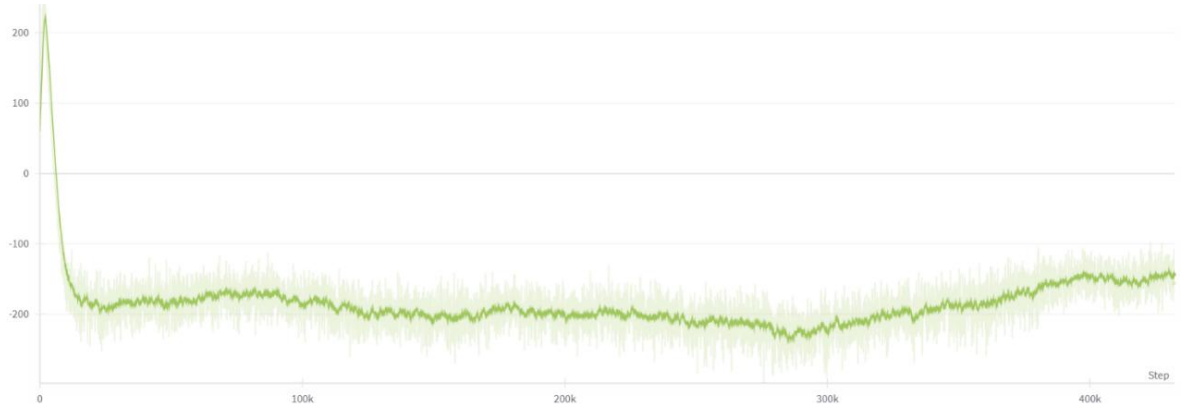


圖 3.2.4-5 臺北市實驗場域昏峰時段收斂圖

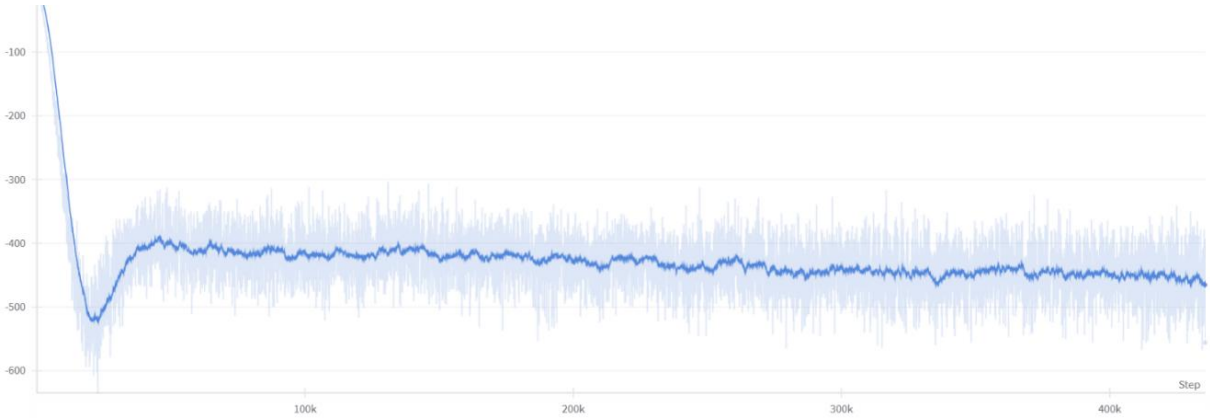


圖 3.2.4-6 臺北市實驗場域假日昏峰時段收斂圖

表 3.2.4-1 臺南市實驗場域晨峰時段超參數之說明

參數	說明
隱藏層數	2
神經元數量	[256,256]
隱藏向量數量	17
激活函數	Relu

學習率	0.0003
折和因子	0.99
熵係數	0.01
抽樣數	256
更新頻率	1000
資料庫大小	1000000

表 3.2.4-2 臺南市實驗場域其餘時段超參數之說明

參數	說明
Pearl (Context Network)	
隱藏層數	2
神經元數量	[256,256]
隱藏向量數量	17
資料庫大小	1000000
抽樣數	256
Q-Pensieve (Task Network)	
隱藏層數	2
神經元數量	[256,256]
激活函數	Mish
學習率	0.0003
折和因子	0.99
熵係數	0.01
抽樣數	256
更新頻率	1000
資料庫大小	1000000

臺南市實驗場域訓練時將觀察模型損失值以調整模型參數，確保模型可穩定收斂。若模型無法收斂，將進一步分析原因，判斷是於模型初期即存在不收斂情況，亦或後期因資料變化或參數設置問題導致，並相應修改模型設計或調整超參數。此外，由於臺南市實驗場域採用 Pearl 演算法，其中之嵌入式向量(embedding vector)負責將各時段的資訊整合為固定的向量。若向量設定不當，亦可能導致模型無法正常訓練。

表 3.2.4-3 臺北市實驗場域超參數之說明

參數	說明
隱藏層數	2
神經元數量	[512,256]
激活函數	Mish
學習率	0.0005
折和因子	0.95
熵係數	0.01
抽樣數	256
更新頻率	1000
資料庫大小	1000000

臺北市實驗場域訓練時，觀察模型損失值以調整模型參數，確保模型可穩定收斂。若模

型無法收斂，將進一步分析原因，判斷是於模型初期即存在不收斂情況，亦或後期因資料變化或參數設置問題導致，並相應修改模型設計或調整超參數。此外，訓練過程中採用網格搜索方法，用於尋找模型設計中最佳的超參數組合，以提升模型性能。

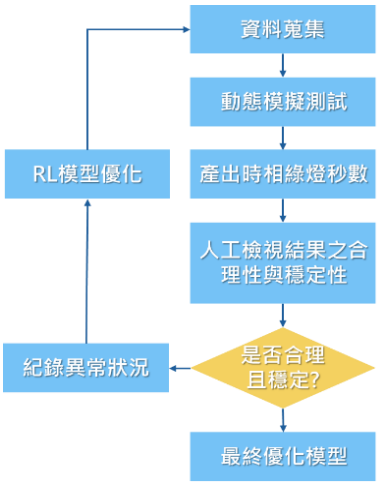
網格搜索是一種超參數調整技術，用來系統性的將所有可能的參數組使用並測試使其搜索一組超參數的最佳組合，而本場域調整之超參數如下：學習率(learning rate)、折和因子(discount factor)、抽樣數(batch size)、隱藏層數(hidden layer size)與神經元數(neuron size)，而其運作步驟說明如下。

1. 定義各種超參數範圍與數量，如：學習率~ $\alpha \in \{0.0001, 0.001, 0.01, 0.1\}$等、折扣因子~ $\gamma \in \{0.90, 0.95, 0.99\}$等。
2. 通過程式建立各種組合，如：$(\alpha=0.001, \gamma=0.90), (\alpha=0.001, \gamma=0.95), (\alpha=0.001, \gamma=0.99)$等。
3. 針對每一種組合訓練模型並計算績效。
4. 選擇出最佳組合
   (1) 找出收斂值最小、獎勵最大、收斂最快的參數組合作為最終選擇。
   (2) 而其中指標為收斂值最小與收斂最快之組合為重。

而通過使用網格搜索找出目前最佳之超參數組合如表 3.2.4-3 說明。

3.2.5 模擬績效分析

3.2.5.1 模擬評估流程及結果



透過 AI 號誌控制模型與車流模擬環境 SUMO 互動，模擬運算時相綠燈秒數，再透過人工檢視模型運算結果的合理性以及穩定度，以此循環過程優化模型，流程詳圖 3.2.5.1-1 所示。並依此合理性及穩定性概念，分別檢視臺南市實驗場域及臺北市實驗場域以現場偵測設備收集之資料，輸入模型後針對現場偵測資料所產出之模擬分相綠燈秒數、週期及模擬績效(如通過量及延滯等)。力求其於實測前，AI 號誌控制模型判定綠燈時長具一定效度，多方確保其可行性。

一、合理性

為維護行車安全及促進道路使用效率，號誌設計須符合交通流向、流量及路況，亦即某行駛方向交通量多，其分相綠燈秒數運算結果應足夠安全通過且延滯最小，不合理之情況如某轉向交通量很多，但其分相綠燈秒數運算結果很短；反之同樣非為合理狀況。

判定標準以 TOD 為參考基準，單位時間(秒)通過車流差異比應為正值且介於 1~4 之間，

亦即分相配置之秒數至少能通過適當比例車流,並符合 TOD 最大週期及最小綠 10 秒之限制。其公式計算如下：V 為流量、T 為分相秒數、χ 為單位時間(秒)通過車流差異比、χ 為 V/T。

二、穩定度

同天同時段內之穩定度與不同天同時段之穩定度確認，當出現各時相綠燈秒數差異很大之情況，就需特別注意該天是否有突發狀況，選擇無突發狀況之其他天的交通調查資料進行運算確認穩定度。判定標準以 AI 號誌控制模型產出之分相秒數及該分相通過之流量皆應介於 μ±2σ，亦即 95%信賴區間內，其公式計算如下：

μv：AI 號誌控制模型分相秒數通過流量平均值

σv：AI 號誌控制模型分相秒數通過流量標準差

μT：AI 號誌控制模型分相秒數平均值

σT：AI 號誌控制模型分相秒數標準差

χV,T：AI 號誌控制模型產出之該分相通過之流量或分相秒數

$\mu_{(V,T)}-2\sigma_{(V,T)} \leqq \chi \leqq \mu_{(V,T)}+2\sigma_{(V,T)}$

3.2.5.2 單一路口場域(臺南市「台 86-19 甲線」路口)模擬績效

透過 AI 號誌控制模型與車流模擬環境 SUMO 互動，分析其進行 10 次不同亂數種子的 training episode,藉此產出對應之平日晨峰、平日離峰、平日昏峰及假日昏峰時段之績效結果，以下說明各時段之本期 AI 號誌控制模型產出秒數分布與績效總結。表 3.2.5.2-1 至表 3.2.5.2-4 分別為各時段之 TOD、前期 AI 號誌控制模型、本期 AI 號誌控模型的績效彙整，其中 A 方向為國道 3 號下台 86，B 方向為南雄路二段，C 方向為台 86 往國道 3 號，D 方向為關新路一段。圖 3.2.5.2-1 至圖 3.2.5.3-8 為本期 AI 號誌控模型各時段輸出各分相秒數之合理性與穩定性分析。

一、平日晨峰(07：00~09：00)

本期 AI 號誌控制模型模擬產出之通過量約 5,105PCU，略優於 TOD 之 5,041PCU，亦高於前期 AI 之 5,099PCU，平均停等延滯為 64.1 秒，亦優於 TOD 及前期 AI 延滯表現。

各分相秒數之單位時間(秒)通過車流差異比皆為正值，各分相均值分別為分相一的 1.01、分相二的 0.86、分相三的 0.15、分相四的 1.78 及分相五的 0.12；週期及各分相趨勢圖顯示其週期秒數約呈現 245 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 26 秒、分相二的 102 秒、分相三的 28 秒、分相四的 40 秒及分相五的 49 秒，整體皆較 TOD 的 210 秒週期高。

表 3.2.5.2-1 平日晨峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表

	A			B			C			D			通過量 (PCU)	平均停等延滯 (秒)
	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉		
TOD	305	650	338	207	480	487	287	1161	142	262	281	441	5041	65.6
前期 AI	435	623	341	248	406	497	357	1024	130	379	242	419	5099	74.6
本期 AI	374	602	326	253	410	501	358	1103	139	383	240	418	5105	64.1

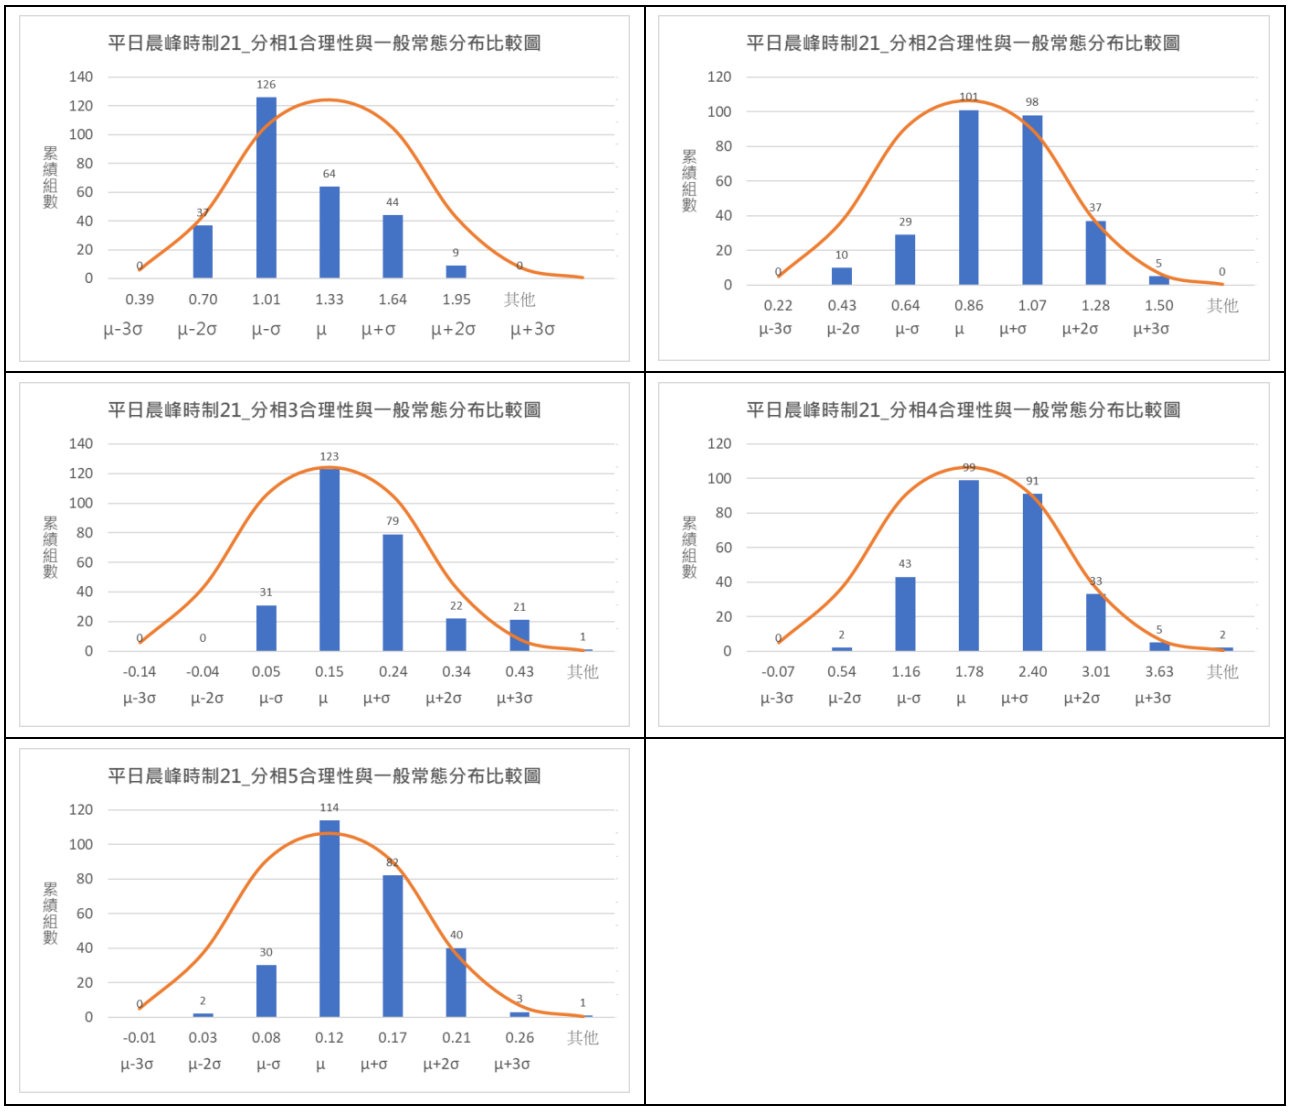


圖 3.2.5.2-1 本期 AI 號誌控制模型平日晨峰模擬各分相秒數合理性分析圖

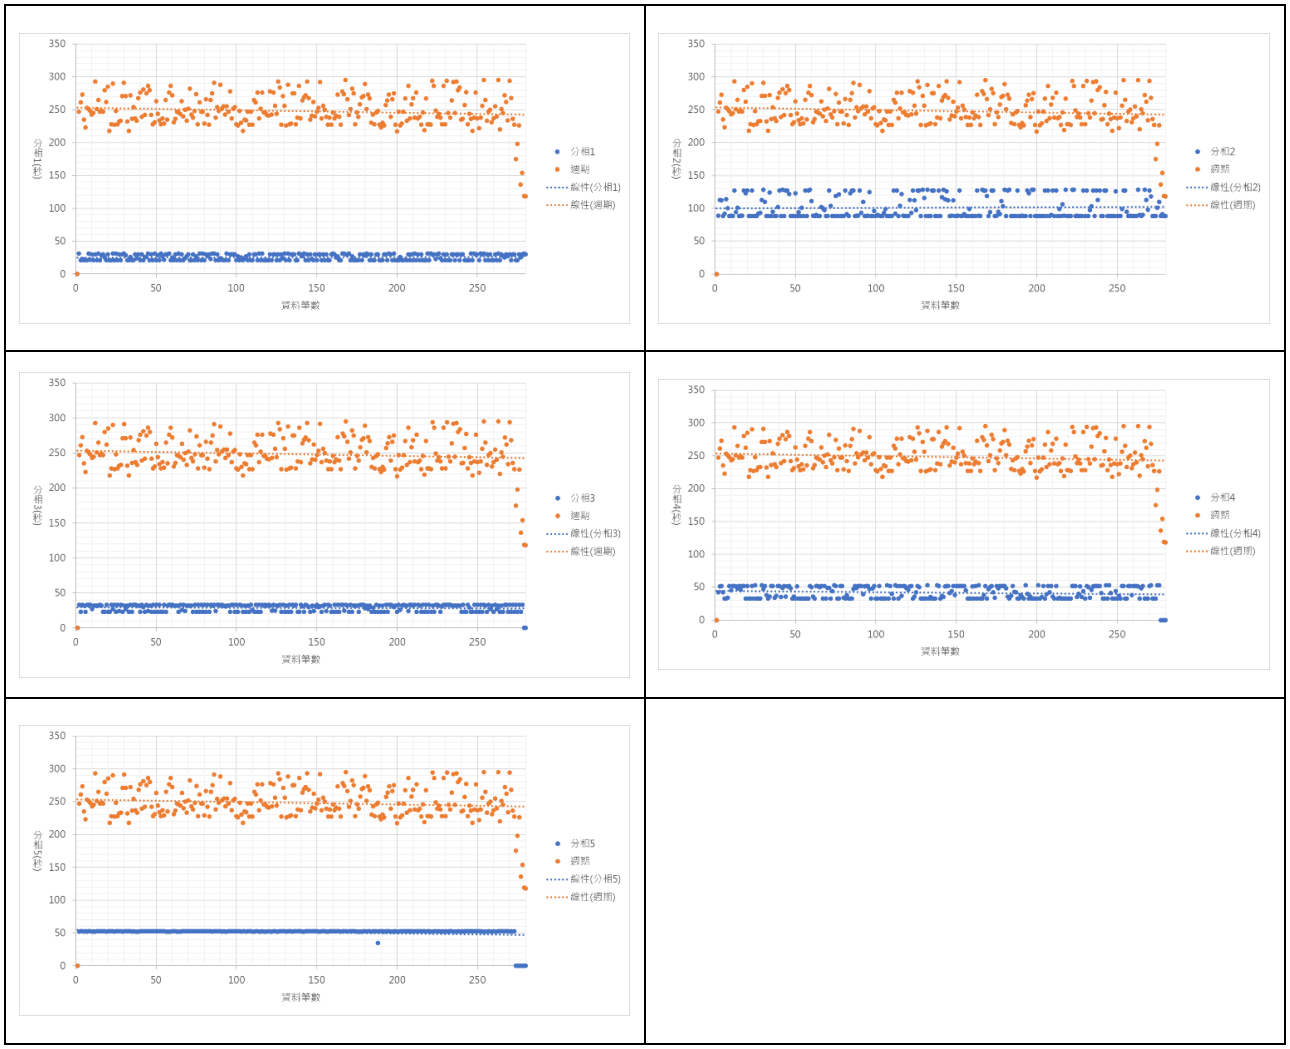


圖 3.2.5.2-2 本期 AI 號誌控制模型平日晨峰模擬各分相秒數穩定性分析圖

二、平日離峰(12：30~14：30)

本期 AI 號誌控制模型模擬產出之通過量約 3,443PCU，略高於 TOD 之 3,436PCU，平均停等延滯為 36.0 秒，略低於 TOD 之 38.3 秒。本期 AI 號誌控制模型模擬產出之通過量約 6,882PCU，平均停等延滯為 44.5 秒；其各分相秒數之單位時間(秒)通過車流差異比皆為正值，各分相均值分別為分相一的 0.13、分相二的 0.13、分相三的 0.22 及分相四的 0.14；週期及各分相趨勢圖顯示其週期秒數約呈現 231 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 102 秒、分相二的 43 秒、分相三的 45 秒及分相四的 41 秒，整體皆較 TOD 的 160 秒周期高。

表 3.2.5.2-2 平日離峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表

	A			B			C			D			通過量(PCU)	平均停等延滯(秒)
	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉		
TOD	237	550	278	168	199	230	273	637	119	266	208	273	3436	38.3
前期 AI	256	543	277	168	197	230	272	629	118	275	208	274	3444	39.3
本期 AI	256	545	278	168	197	230	267	632	119	272	208	274	3443	36.0

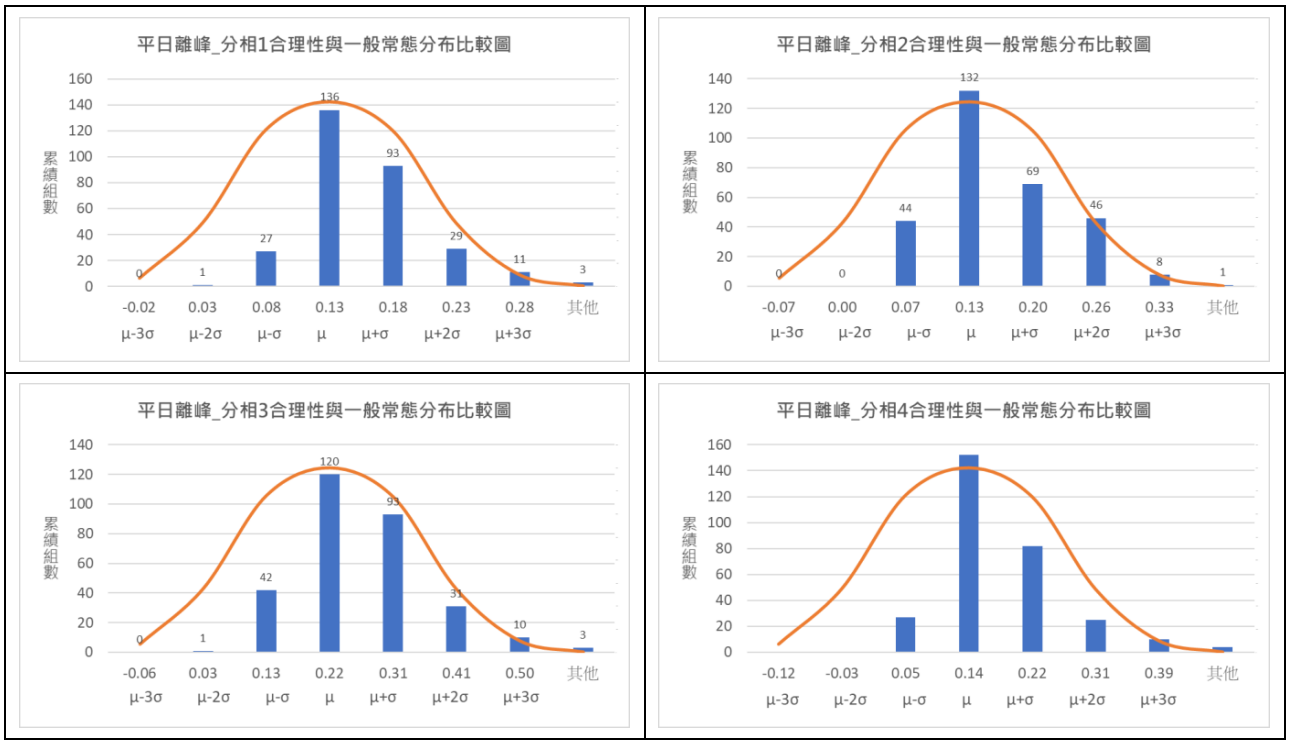


圖 3.2.5.2-3 本期 AI 平日離峰模型模擬各分相秒數合理性分析圖

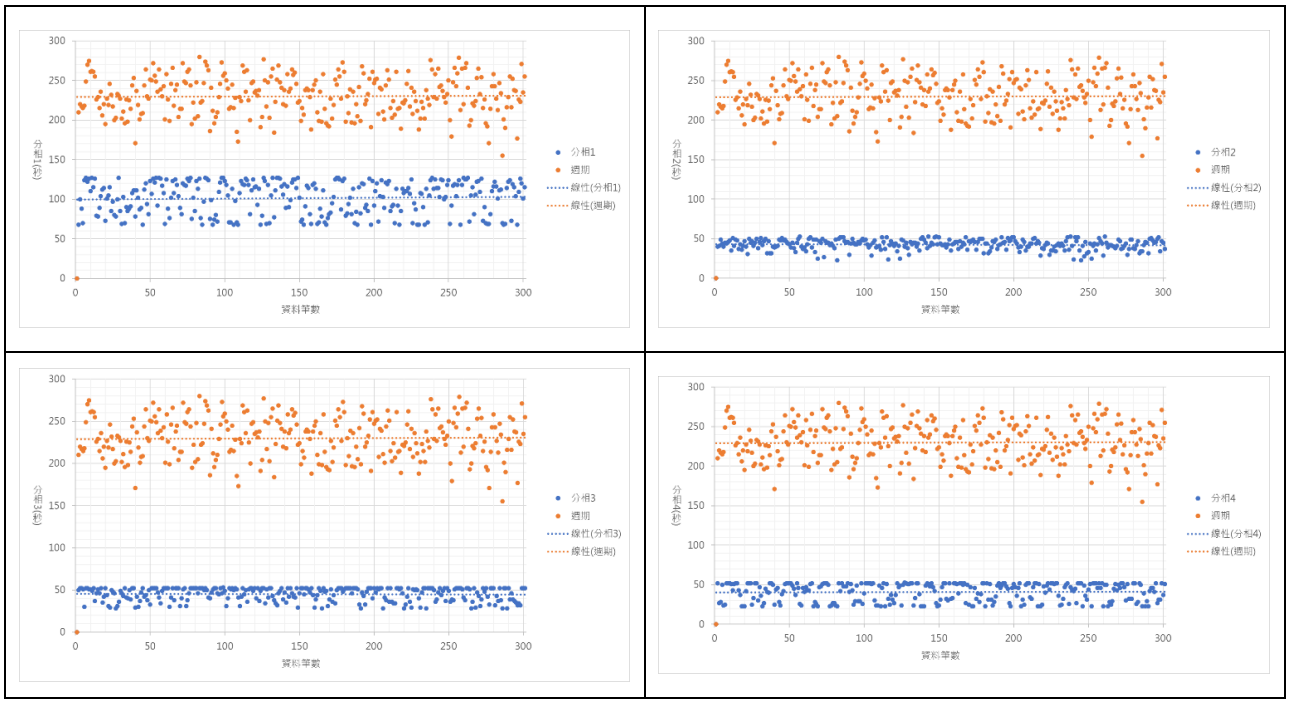


圖 3.2.5.2-4 本期 AI 號誌控制模型平日離峰模擬各分相秒數穩定性分析圖

三、平日昏峰(16：30~18：30)

本期 AI 號誌控制模型模擬產出之通過量約 4,717PCU，明顯優於 TOD 之 4,579PCU，平均停等延滯為 54.4 秒，亦優於 TOD 之 62.4 秒。

本期 AI 號誌控制模型模擬產出之通過量約 6,563PCU，平均停等延滯為 37.9 秒；其各分相秒數之單位時間(秒)通過車流差異比皆為正值，各分相均值分別為分相一的 1.27、分相二的 1.05、分相三的 0.14、分相四的 1.38 及分相五的 0.10；週期及各分相趨勢圖顯示其週期秒數約呈現 170 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 20 秒、分相二的 76 秒、分相三的 21 秒、分相四的 28 秒及分相五的 4226 秒，整體皆較 TOD 的 240 秒週期低。

表 3.2.5.2-3 平日昏峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表

	A			B			C			D			通過量 (PCU)	平均停等延滯 (秒)
	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉		
TOD	355	1074	312	169	300	277	232	792	128	253	350	337	4579	62.4
前期 AI	487	1021	311	202	241	265	419	734	123	317	280	323	4719	56.2
本期 AI	491	1033	317	207	243	270	371	744	126	309	283	326	4717	54.4

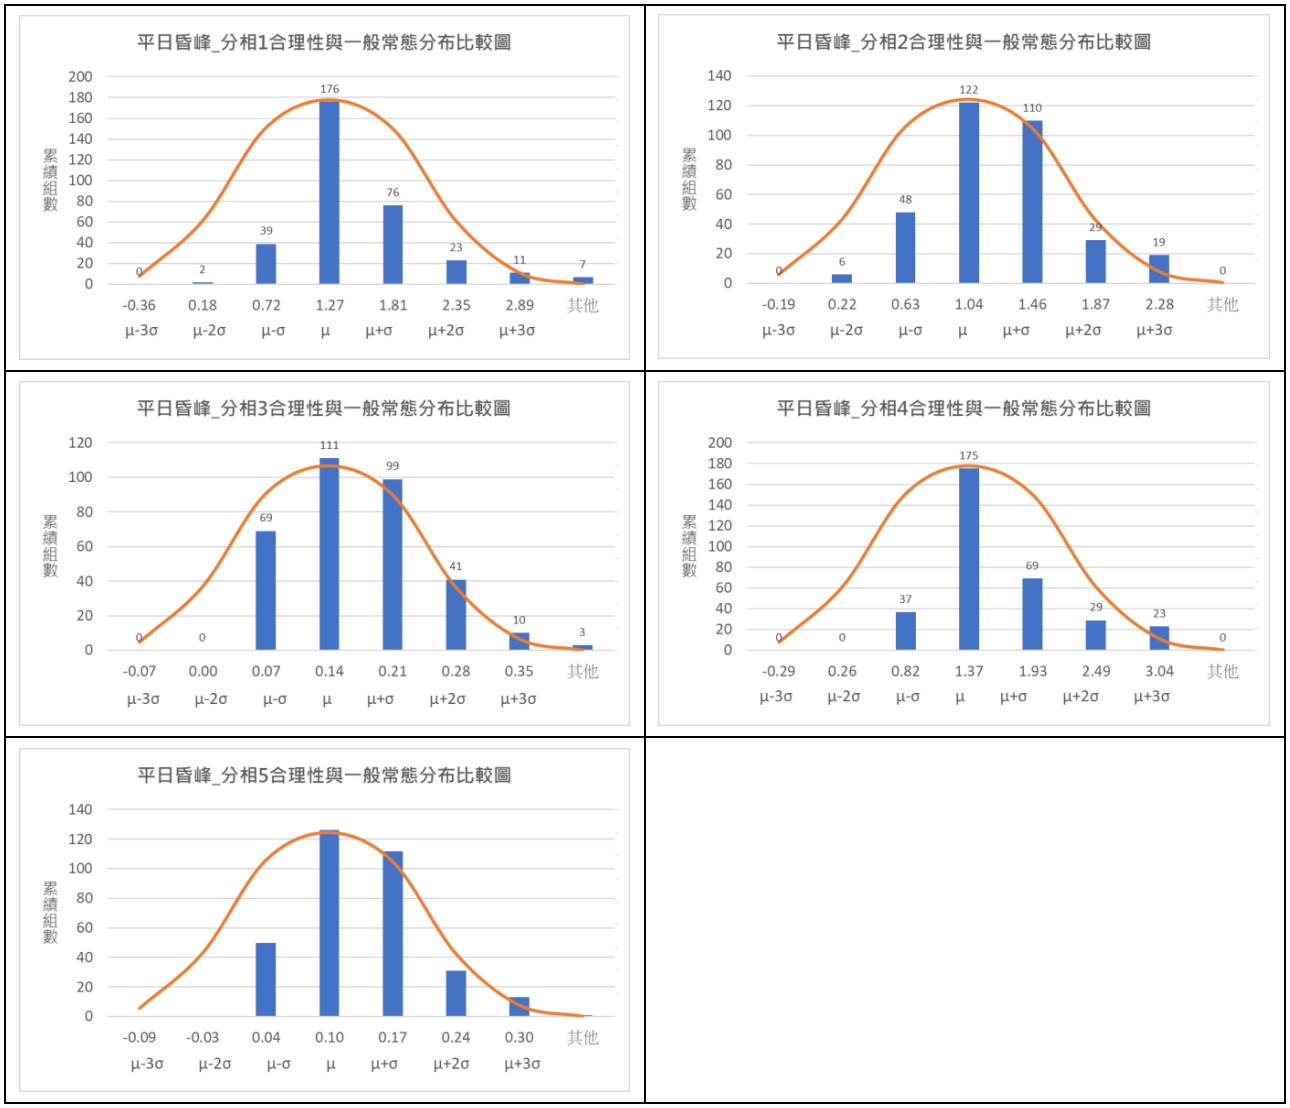
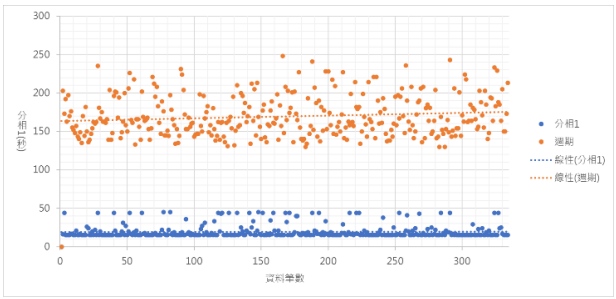
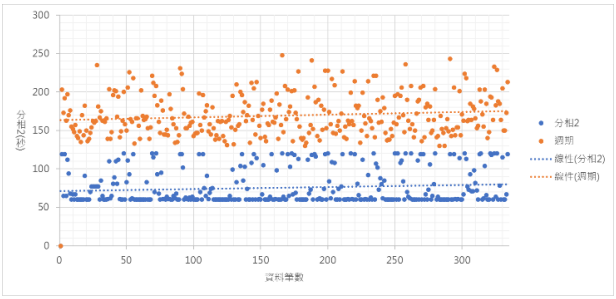


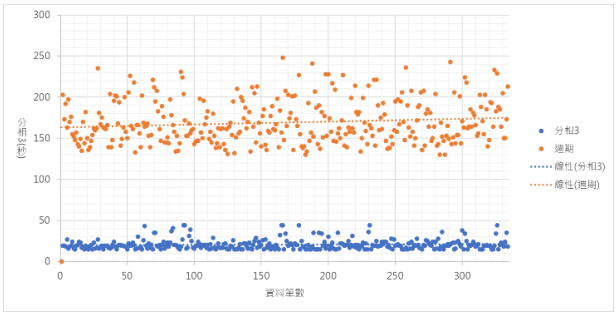
圖 3.2.5.2-5 本期 AI 平日昏峰模型模擬各分相秒數合理性分析圖



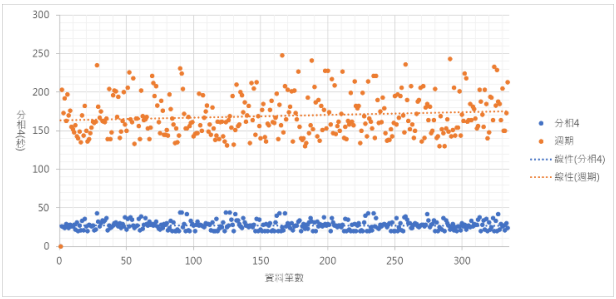
分相 1



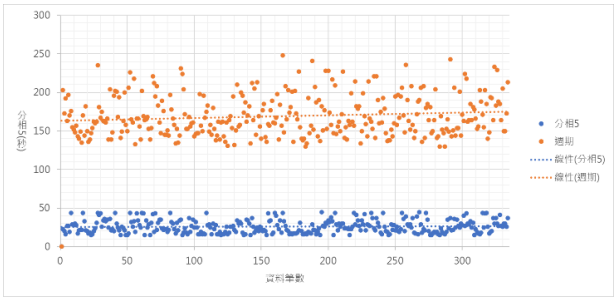
分相 2



分相 3



分相 4



分相 5

圖 3.2.5.2-6 本期 AI 號誌控制模型平日昏峰模擬各分相秒數穩定性分析圖

四、假日昏峰(16：30~18：30)

本期 AI 號誌控制模型模擬產出之通過量約 4,341PCU，優於 TOD 之 4,317，平均停等延滯為 51.9 秒，優於 TOD 之 53.7 秒及前期 AI 之 68.5 秒。本期 AI 號誌控制模型模擬產出之通過量約 9,521PCU，平均停等延滯為 51.8 秒；其各分相秒數之單位時間(秒)通過車流差異比皆為正值，各分相均值分別為分相一的 1.31、分相二的 1.07、分相三的 0.07、分相四的 1.18 及分相五的 0.08；週期及各分相趨勢圖顯示其週期秒數約呈現 190 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 19 秒、分相二的 76 秒、分相三的 27 秒、分相四的 31 秒及分相五的 37 秒，平均週期較 TOD 週期的 240 秒低。

表 3.2.5.2-4 假日昏峰 TOD、前期 AI 號誌控制模型、本期 AI 號誌控制模型績效彙整表

	A			B			C			D			通過量 (PCU)	平均停等延滯 (秒)
	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉	左轉	直行	右轉		
TOD	360	912	334	200	285	263	219	798	137	256	263	293	4317	53.7
前期 AI	484	860	354	244	239	262	273	692	123	317	213	291	4350	68.5
本期 AI	479	856	349	245	230	256	271	732	123	313	204	285	4341	51.9

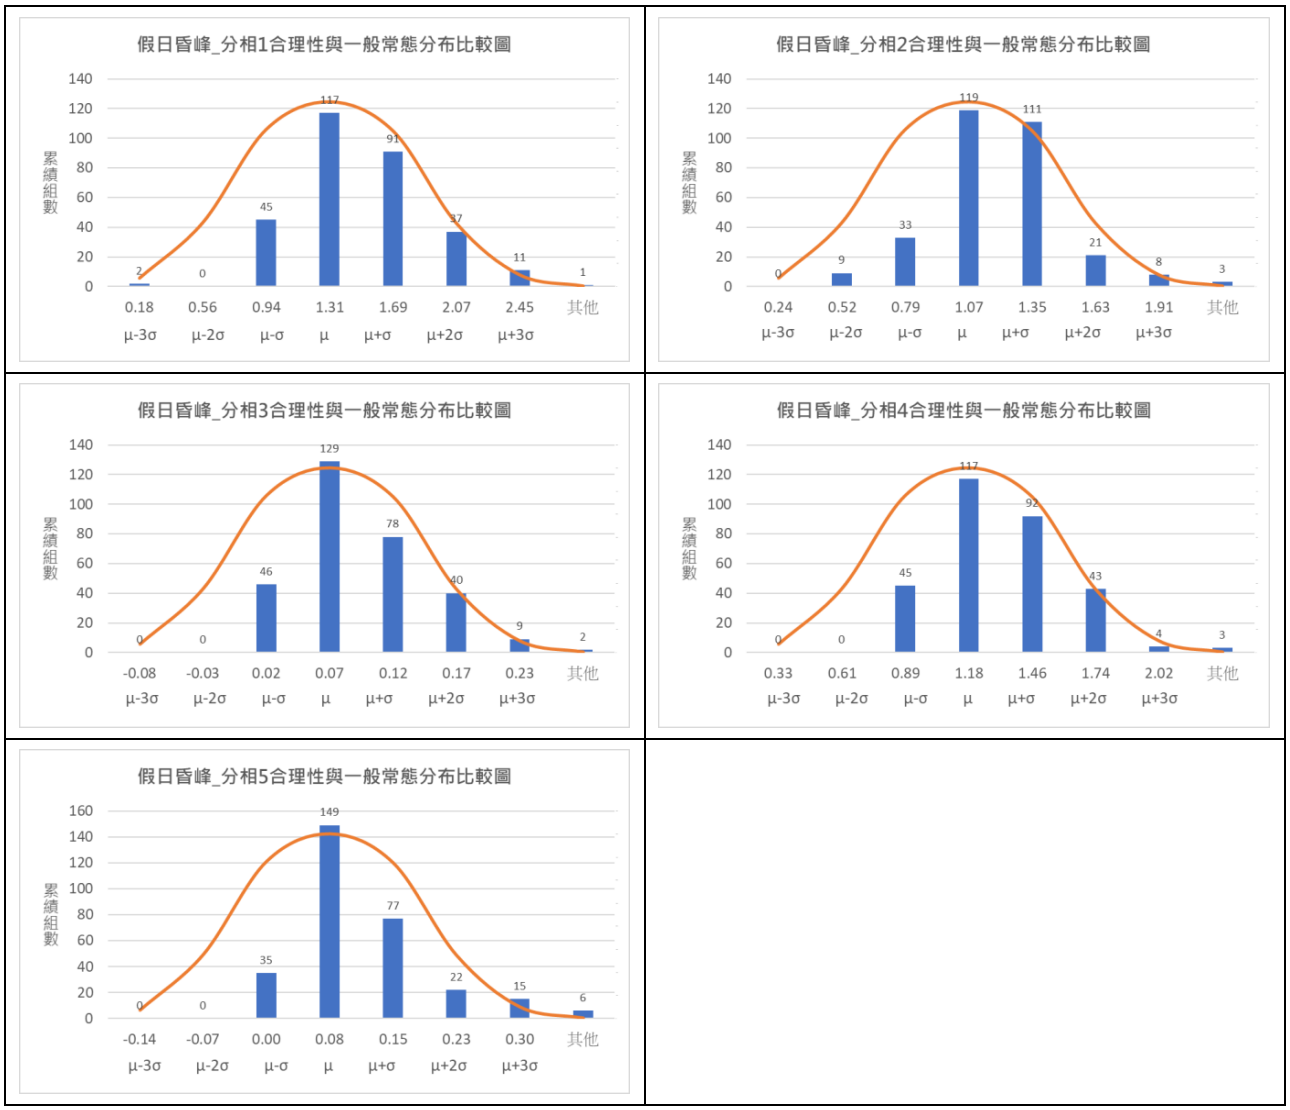


圖 3.2.5.2-7 本期 AI 號誌控制模型假日昏峰模擬各分相秒數合理性分析圖

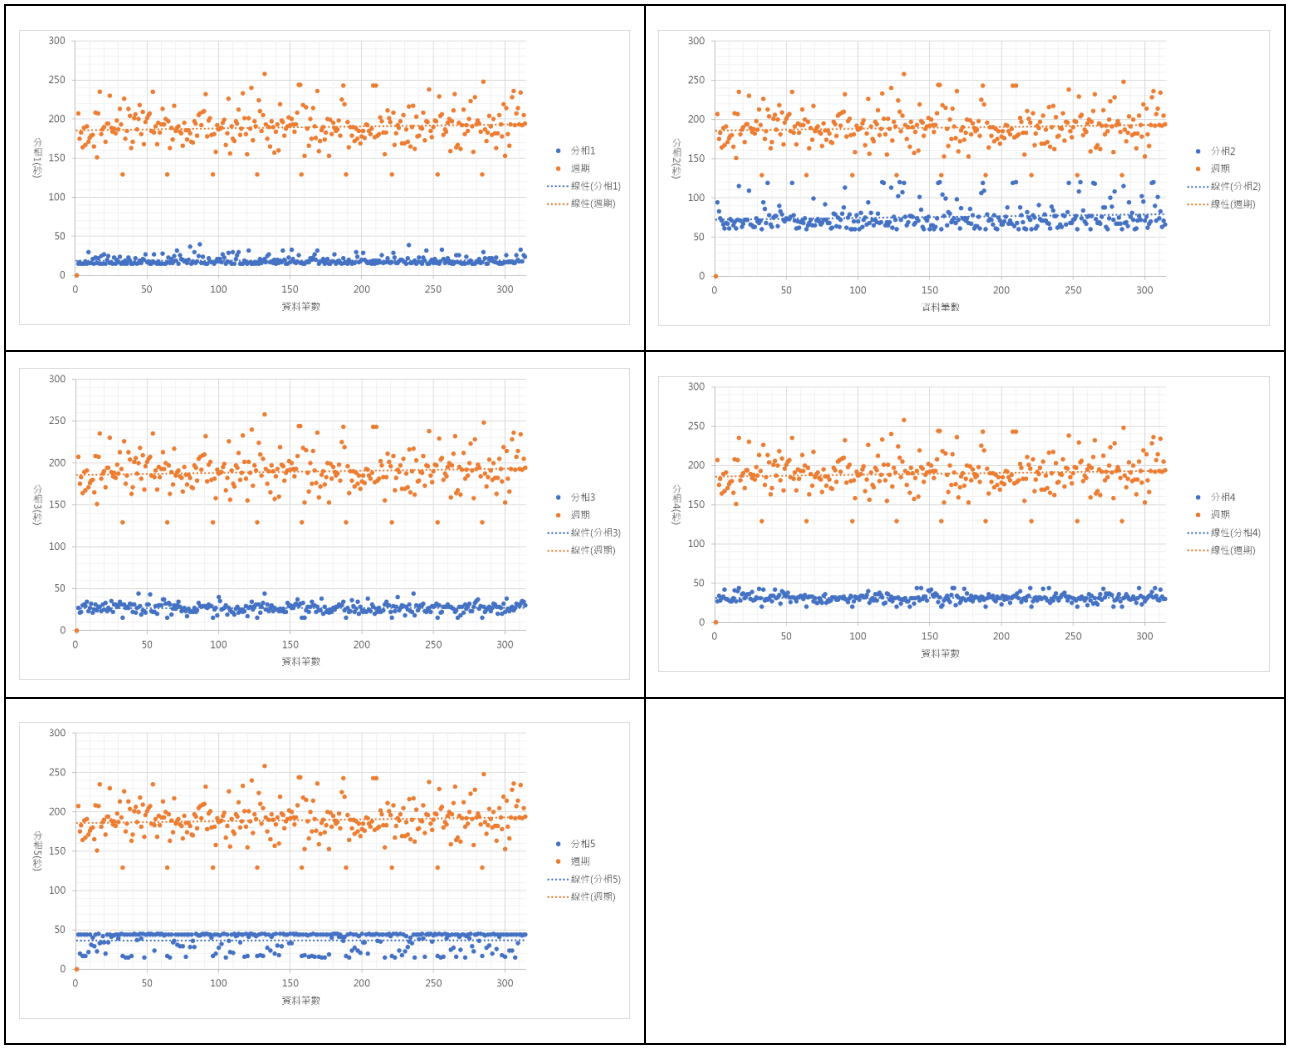


圖 3.2.5.2-8 本期 AI 號誌控制模型假日昏峰模擬各分相秒數穩定性分析圖

3.2.5.3 多路口幹道場域(臺北市「中山北路-德行東路」)模擬績效

透過 AI 號誌控制模型與車流模擬環境 SUMO 互動，分析其進行 10 次不同亂數種子的 training episode，藉此產出對應之平日晨峰、平日離峰、平日昏峰及假日昏峰時段之績效結果，以下說明各時段之本期 AI 號誌控制模型產出秒數分布與績效總結。表 3.2.5.3-1 至表 3.2.5.3-4 分別為各時段之 TOD、本期 AI 號誌控模型的績效彙整，圖 3.2.5.3-1 至圖 3.2.5.3-4 為本期 AI 號誌控模型各時段輸出各分相秒數之合理性與穩定性分析。

一、平日晨峰(07：00~09：00)

平日晨峰以注重平均表現之偏好績效結果較佳，其單一方向平均每車停等延滯增加 5.1 秒，每小時整體路口減少 678 PCU。中山北路/德行西路路口(X4)各分相秒數平均趨勢分別為分相一的 47 秒、分相二的 65 秒、分相三的 37 秒、分相四的 14 秒、分相五的 30 秒及分相六的 28 秒。其週期秒數約呈現 221 秒集中趨勢，略高於 TOD 的 200 秒。

表 3.2.5.3-1 平日晨峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表

次數	TOD						AI 號誌控制模型					
	單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道		單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道	
			停等延滯	通過量	停等延滯	通過量			停等延滯	通過量	停等延滯	通過量
1	75.4	33630	15190	660	34931	421	72.3	32927	13495	683	37798	354
2	53.6	33067	14783	652	29174	426	70.8	32945	12673	664	33850	382
3	71.2	33437	14773	673	34796	410	73.3	32994	13221	686	36951	364
4	72.4	33872	14282	697	36895	407	59.5	34051	12909	705	38476	389
5	63.7	34650	14421	691	37874	404	76.4	33076	13037	688	42628	355
6	81.1	32980	15134	663	38077	406	73.7	32127	14743	648	42728	367
7	60.0	34143	13819	689	35902	407	68.8	33591	12439	692	39846	370
8	70.4	34132	14928	671	33579	417	80.9	32785	13193	677	40611	353
9	60.9	33433	14582	655	40084	409	78.4	33321	13007	691	41977	365
10	65.4	33457	14364	668	41097	395	70.7	32199	13144	673	45675	352
μ	67.4	33680	14628	672	36241	410	72.5	33002	13186	681	40054	365

註 1：停等延滯單位為秒，通過量單位為 PCU/hr，每一行為該時段兩小時模擬平均值。

註 2：本表為各 episode 之績效平均值

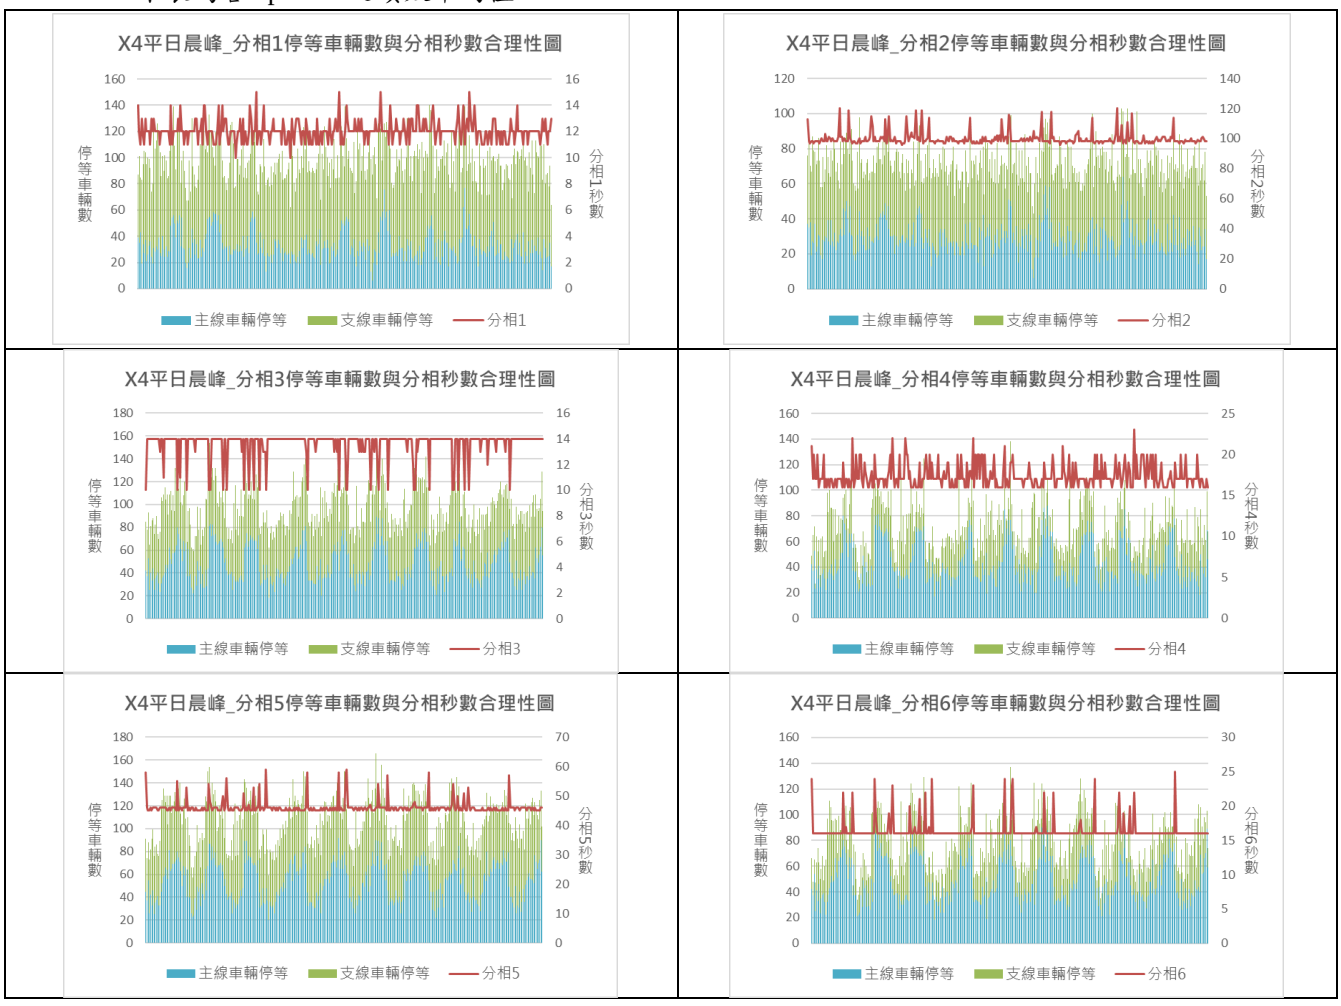


圖 3.2.5.3-1 平日晨峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖

二、平日離峰(12：30~14：30)

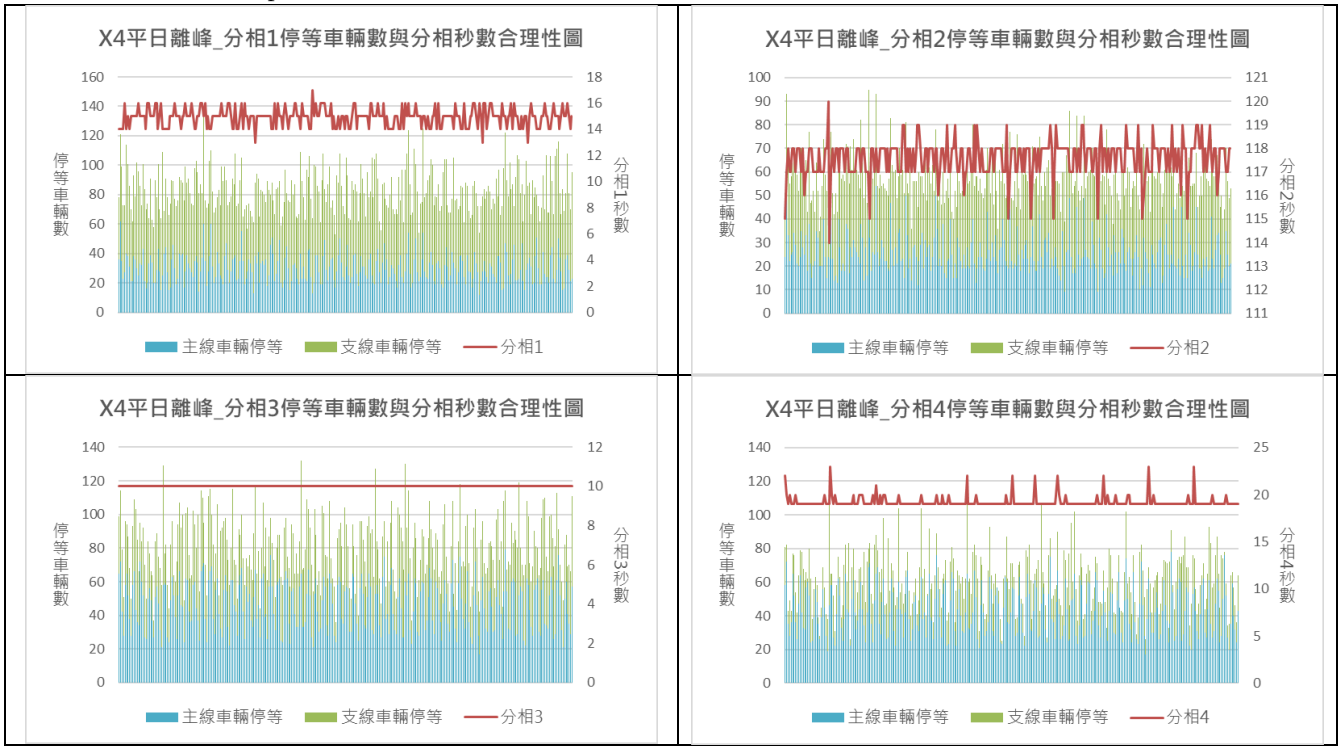
單一方向平均每車停等延滯減少 1.9 秒，每小時整體路口減少 75PCU，其週期秒數約呈現 199 秒集中趨勢，皆高於 09：00~13：00 運行時制計畫 4 週期 150 秒及 13：00~16：30 運行時制計畫 2 週期 200 秒。中山北路/德行西路路口(X4)各分相秒數平均趨勢分別為分相一的 36 秒、分相二的 64 秒、分相三的 18 秒、分相四的 11 秒、分相五的 30 秒及分相六的 44 秒。

表 3.2.5.3-2 平日離峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表

次數	TOD						AI 號誌控制模型					
	單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道		單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道	
			停等延滯	通過量	停等延滯	通過量			停等延滯	通過量	停等延滯	通過量
1	39.3	29960	11914	546	22927	302	37.3	30553	13183	550	30937	313
2	32.6	31854	10868	578	19870	307	34.1	31486	12686	559	26901	318
3	41.1	29569	11583	535	26636	281	33.9	29638	12603	547	27616	297
4	37.1	30981	10933	581	20903	292	32.2	30813	12827	559	23728	307
5	37.6	31238	10652	573	28790	298	34.4	30410	12650	556	30387	287
6	31.7	31585	10394	582	19029	315	30.1	31552	11798	576	28768	309
7	33.4	30738	10777	579	22310	310	34.6	30783	12344	554	33045	303
8	34.2	30187	11279	526	21760	299	33.0	30066	12351	536	28550	301
9	30.5	31457	10817	574	19102	312	33.5	31470	12181	558	27170	308
10	44.4	29695	11651	534	30118	290	39.6	29736	12666	534	32171	288
μ	36.2	30726	11087	561	23145	301	34.3	30651	12529	553	28927	303

註 1：停等延滯單位為秒，通過量單位為 PCU/hr，每一行為該時段兩小時模擬平均值。

註 2：本表為各 episode 之績效平均值



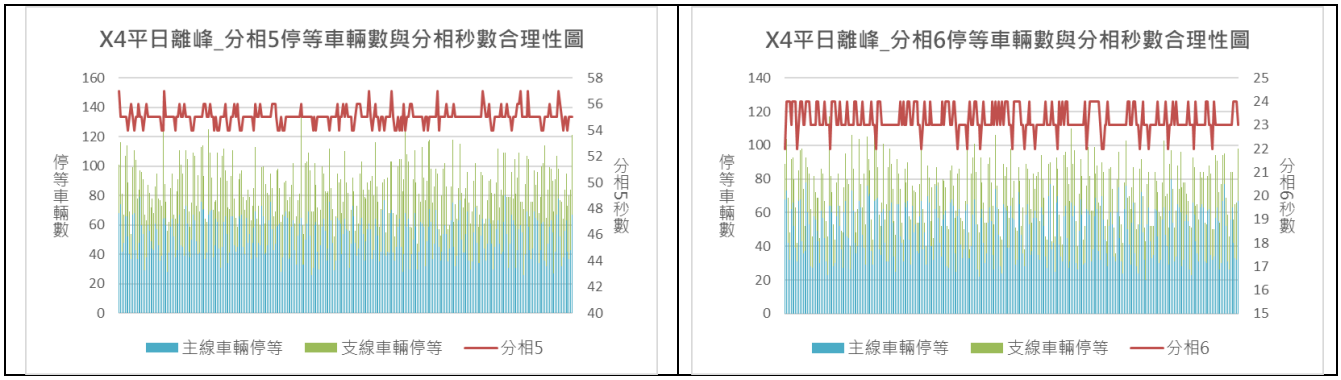


圖 3.2.5.3-2 平日離峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖

三、平日昏峰(16：30~18：30)

單一方向平均每車停等延滯減少 4.9 秒，每小時整體路口增加 250 PCU，其週期秒數約呈現 238 秒集中趨勢，中山北路/德行西路路口(X4)各分相秒數平均趨勢分別為分相一的 26 秒、分相二的 76 秒、分相三的 44 秒、分相四的 43 秒及分相五的 49 秒。

表 3.2.5.3-3 平日昏峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表

次數	TOD						AI 號誌控制模型					
	單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道		單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道	
			停等延滯	通過量	停等延滯	通過量			停等延滯	通過量	停等延滯	通過量
1	38.5	36613	16182	824	24136	474	43.1	36258	15439	835	32301	445
2	45.4	36107	17264	805	30146	465	46.8	36154	16482	813	34123	437
3	42.6	36593	17606	785	24469	458	37.4	36279	15526	827	26841	426
4	65.3	35922	17290	758	26773	455	47.1	36423	17205	819	35184	427
5	51.5	35606	17577	780	31167	454	48.3	35659	16411	812	33008	428
6	52.1	36356	17056	780	26945	454	48.0	36684	16425	817	34350	433
7	83.0	33076	20612	690	42153	436	65.2	35240	17413	776	41197	437
8	43.6	35880	16926	777	23888	463	38.7	36024	16155	812	28479	446
9	42.9	36932	17914	811	24388	460	41.0	37056	16877	832	27750	462
10	39.8	36490	17121	825	23004	470	40.3	36295	16327	846	29719	437
μ	50.5	35957	17555	784	27707	459	45.6	36207	16426	819	32295	438

註 1：停等延滯單位為秒，通過量單位為 PCU/hr，每一行為該時段兩小時模擬平均值。

註 2：本表為各 episode 之績效平均值



圖 3.2.5.3-3 平日昏峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖

四、假日昏峰(16：30~18：30)

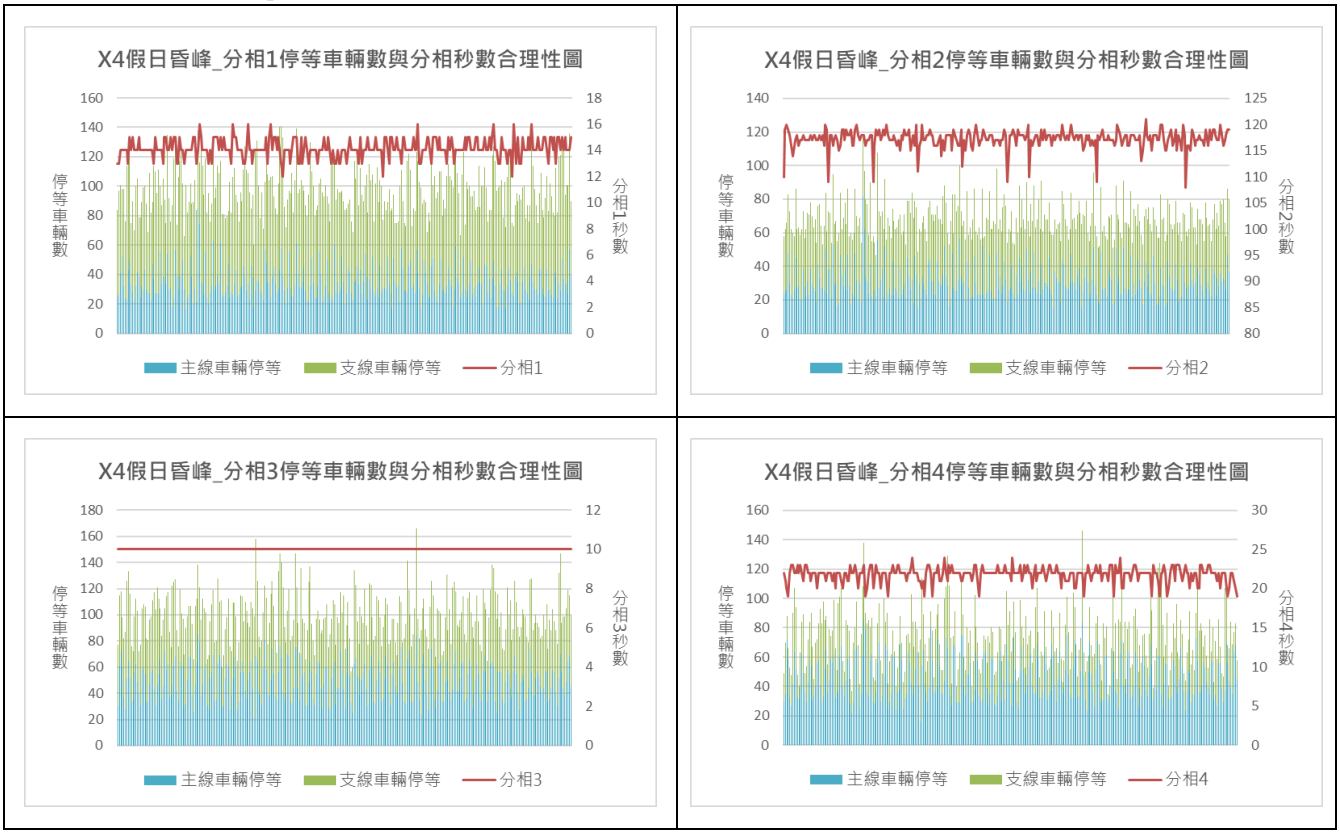
單一方向平均每車停等延滯略減少 0.5 秒，每小時整體路口增加 437 PCU，其週期秒數約呈現 199 秒集中趨勢，中山北路/德行西路路口(X4)各分相秒數趨勢分別為分相一的 26 秒、分相二的 68 秒、分相三的 28 秒、分相四的 17 秒、分相五的 32 秒及分相六的 32 秒。

表 3.2.5.3-4 假日昏峰 TOD 及本期 AI 號誌控制模型模擬績效彙整表

次數	TOD						AI 號誌控制模型					
	單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道		單一方向平均每車停等延滯	每小時整體路口 PCU	幹道每小時單一車道		支道每小時單一車道	
			停等延滯	通過量	停等延滯	通過量			停等延滯	通過量	停等延滯	通過量
1	36.0	30827	11291	583	21925	365	38.5	29932	11800	585	23449	353
2	46.6	29783	12417	532	26811	369	42.7	30889	12084	547	26003	374
3	47.4	29614	11761	548	22950	332	49.1	29551	12074	567	23055	329
4	46.2	30884	11871	578	26193	369	49.0	31019	11335	599	26101	364
5	41.7	29814	11725	547	23813	358	40.2	30855	11367	546	22597	379
6	42.4	28650	12470	531	23962	355	43.2	28839	12372	556	22705	379
7	41.6	30450	11576	579	23544	357	42.1	30640	11164	584	23538	348
8	37.9	30022	11374	564	19171	363	36.8	30289	12263	564	18697	389
9	38.6	30617	11205	583	19921	365	38.1	31998	11953	591	19356	376
10	39.0	31616	11675	584	21918	384	33.1	32640	11369	594	20483	393
μ	41.7	30228	11736	563	23021	362	41.3	30665	11778	573	22599	368

註 1：停等延滯單位為秒，通過量單位為 PCU/hr，為該時段兩小時模擬平均值。

註 2：本表為各 episode 之績效平均值



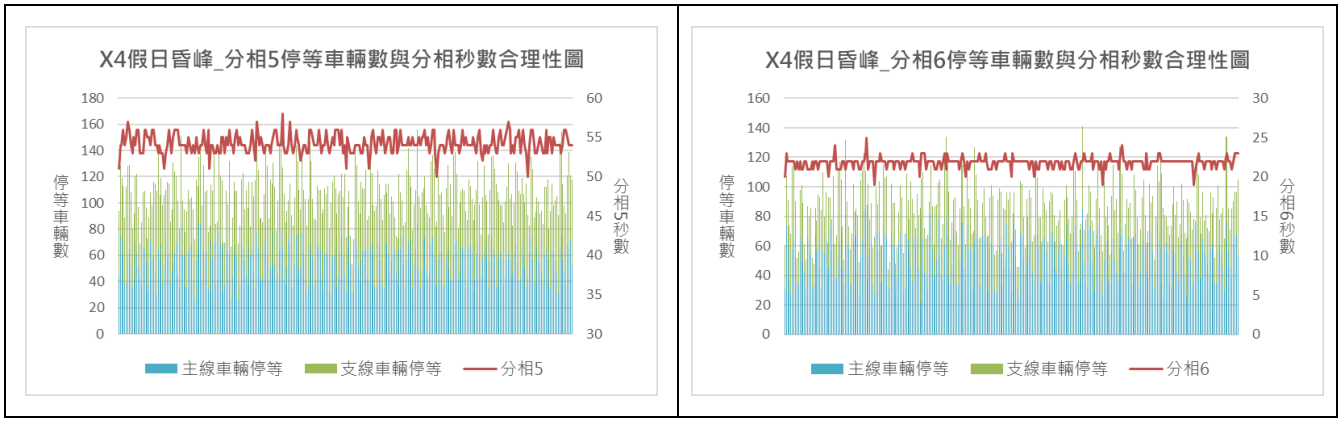


圖 3.2.5.3-4 平日昏峰 AI 號誌控制模型模擬各分相秒數合理性及穩定性圖

3.3 實測績效分析

前期計畫於去年 11 月分別與臺南市政府交通局及臺北市政府交通局合作進行現場實測，本期根據前期實測結果進行模型精進後再次實測以進一步探討 AI 號誌控制模型於都會區之實作。實測前將利用現場車流偵測設備之道路資訊、號誌資訊提供 AI 號誌控制模型進行動態模擬測試，觀察 AI 號誌控制模型輸出結果進行秒數之穩定性與合理性分析。將實測計畫連同前述動態模擬測試結果交付機關，待與臺南市政府交通局及臺北市政府交通局同意後，方得將 AI 號誌控制模型實際運用於實驗場域進行正式的實測工作，將運算結果下載至路口號誌控制器進行事前事後量化績效評估。

3.3.1 實驗場域偵測設備

考量本計畫所建置之 AI 號誌控制系統係依據於各路口或各車道所佈建之智慧型偵測器即時偵測資料，經由 AI 運算決策即時調整與控制現場號誌運作，因此偵測設備是否可有效辨識物件並提供精確之偵測值極為重要。關於臺南市實驗場域及臺北市實驗場域使用之偵測項目準確度驗證規劃說明如下：

一、單一路口場域(臺南市「台 86 線-台 19 甲線」路口)

臺南市「台 86 線-台 19 甲線」路口偵測設備如圖 3.3.1-1 所示，路口共架設 6 台即時影像車輛偵測設備，經由 AI 影像辨識取得路口轉向量資料，經執行團隊確認，設備位置與偵測範圍皆符合本計畫需求。

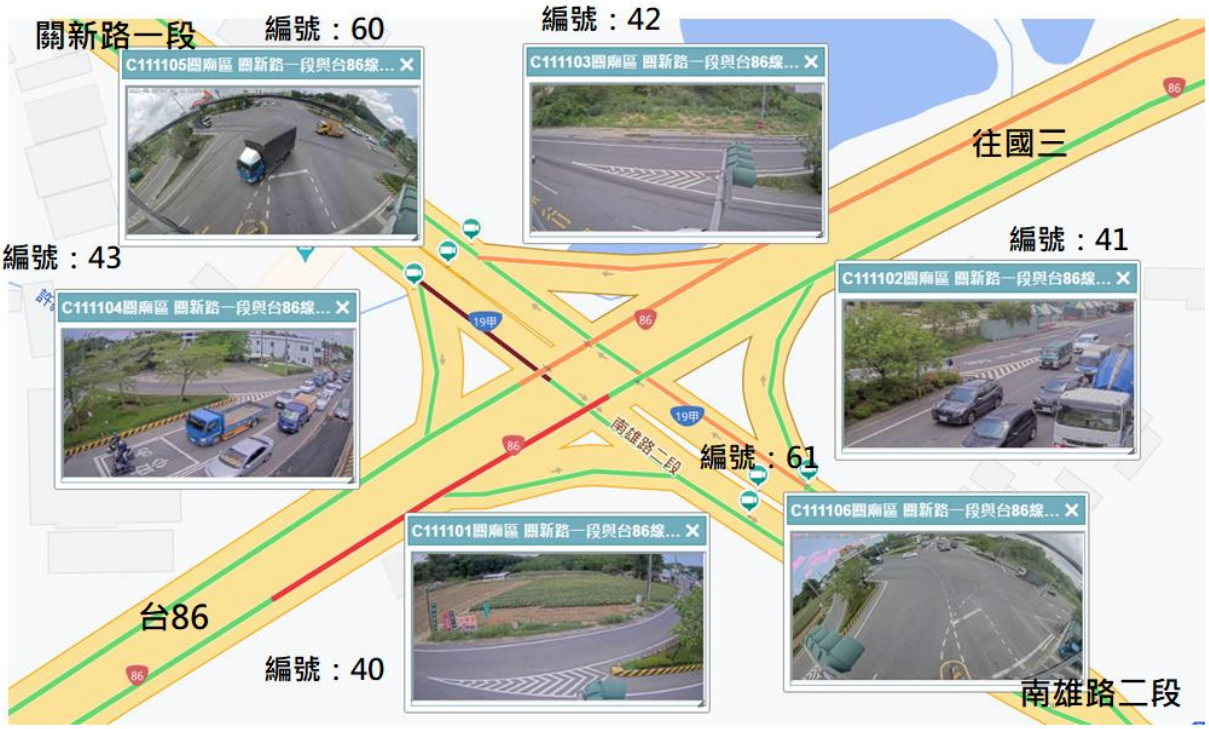


圖 3.3.1-1 臺南市「台 86 線-台 19 甲線」偵測設備位置

(一)路口車流轉向辨識

1.驗證說明：以各路口為一計算單位，於平日晨峰(07:00~09:00)與昏峰(16:30~19:30)共 2 時段各錄製 15 分鐘影像(二時段共 30 分鐘)，計算影片時間內車流轉向辨識之準確率。

2.計算方式：(1-|((各物件人工計數-各物件 AI 計數))/各物件人工計數|)*100%

3.準確率門檻：90%

4.測試方式：

(1)現場車況利用本計畫偵測路口之攝影機擷取影像，錄影收集車況數據，需提供各路段車流於路口轉向之數據。錄放影系統需具有時間紀錄，至少以秒為單位，且於播放時可單張播放。

(2)每路段皆可由以上記錄人工計算求得總路口轉向量與各路段轉向量等測試值，並與後端影像辨識系統(iTraView)之實際偵測結果進行準確度驗證。

A.各路段轉向量：利用放影機可步階控制單張播放的特性，以目視觀察物件之轉向量，以判斷為左轉、右轉與直行之轉向。

B.總路口轉向量：上項的加總，並依車流轉向進行分類。

5.應用方式：作為 AI 號誌控制模型輸入參數，以及後續監控畫面使用。

(二)準確率驗證

依上述驗證方法，取平日晨峰(07:45~08:00)與昏峰(17:45~18:00)2 時段，驗證其 15 分鐘內各車種轉向辨識準確率，整理如表 3.3.1-1、3.3.1-2 所示。晨峰準確率達 96.4%，昏峰準確率達 93.9%，符合準確率門檻。

表 3.3.1-1 路口車流轉向辨識平日晨峰(07:45~08:00)準確度驗證

平日晨峰			人工計算					AI辨識					準確率				
測試時間			大車	小車	機車	大車+小車	大車+小車+機車	大車	小車	機車	大車+小車	大車+小車+機車	大車	小車	機車	大車+小車	大車+小車+機車
每5分鐘統計																	
07:45:00	~	07:50:00	45	388	158	433	591	43	372	149	415	564	95.6%	95.9%	94.3%	95.8%	95.4%
07:50:00	~	07:55:00	49	332	123	381	504	47	320	122	367	489	95.9%	96.4%	99.2%	96.3%	97.0%
07:55:00	~	08:00:00	43	321	97	364	461	42	315	96	357	453	97.7%	98.1%	99.0%	98.1%	98.3%
每15分鐘統計																	
07:45:00	~	08:00:00	137	1,041	378	1,178	1,556	132	1,007	367	1,139	1,506	96.4%	96.7%	97.1%	96.7%	96.8%

表 3.3.1-2 路口車流轉向辨識平日昏峰(17:45~18:00)準確度驗證

平日昏峰			人工計算					AI辨識					準確率				
測試時間			大車	小車	機車	大車+小車	大車+小車+機車	大車	小車	機車	大車+小車	大車+小車+機車	大車	小車	機車	大車+小車	大車+小車+機車
每5分鐘統計																	
17:45:00	~	17:50:00	27	372	82	399	481	25	368	78	393	471	92.6%	98.9%	95.1%	98.5%	97.9%
17:50:00	~	17:55:00	22	341	98	363	461	21	337	94	358	452	95.5%	98.8%	95.9%	98.6%	98.0%
17:55:00	~	18:00:00	17	292	67	309	376	16	288	63	304	367	94.1%	98.6%	94.0%	98.4%	97.6%
每15分鐘統計																	
17:45:00	~	18:00:00	66	1,005	247	1,071	1,318	62	993	235	1,055	1,290	93.9%	98.8%	95.1%	98.5%	97.9%

二、幹道多路口場域(臺北市「中山北路-德行東路」)

臺北市「中山北路-德行東路」偵測設備位置如圖 3.3.1-2 所示，於路段號誌桿上架設車輛偵測器，共計架設 4 台，經執行團隊確認，設備位置與偵測範圍皆符合本計畫需求。



圖 3.3.1-2 臺北市「中山北路-德行東路」偵測設備位置

(一)物件雷達辨識

1.驗證說明：以各路口為一計算單位，於平日晨峰(07:00~09:00)與昏峰(16:30~19:30)時段各錄製 15 分鐘影像，計算影片時間內之大車、小車及機車人工計數與物件雷達辨識量之準確率。

2.計算方式：(1-|((各物件人工計數-各物件雷達偵測量))/各物件人工計數|)*100%

3.準確率門檻：90%

4.測試方式：

(1)現場車況利用人工錄影收集偵測路段之車況數據，需提供大車、小車、機車等物件之數據。錄放影系統需具有時間紀錄，至少以秒為單位，且於播放時可單張播放。

(2)每部車皆可由以上記錄求分車種數量測試值，並與 VD 實際偵測結果進行準確度驗證。

A.分車種數量：利用放影機可步階控制單張播放的特性，以目視計算呈現在螢幕上的車輛長度，以判定為大車、小車或機車。

5.應用方式：作為 AI 號誌控制模型輸入參數，以及作為號誌控制績效運算與監控畫面使用。

(二)準確率驗證

依上述驗證方法，取平日晨峰(07:45~08:00)與昏峰(17:45~18:00)2 時段，驗證其 15 分鐘內各車種雷達辨識準確率，整理如表 3.3.1-3 所示。晨峰準確率達 92%，昏峰準確率達 91%，符合準確率門檻。

表 3.3.1-3 臺北市場域偵測設備準確度驗證

平日晨峰									
路口	設備編號	方向	計數時段	VD_變化量	人工計數流量	人工_小	人工_中	人工_大	準確度
中山北路六段/德行西路口	VYSIB20	東向	0700~0705	67	70	31	33	6	96%
	VYSIB40	南向	0840~0845	145	157	37	113	7	92%
	VYSIB60	西向	0950~0955	60	62	38	23	1	97%
	VYSIB00	北向	0715~0720	232	218	68	145	5	94%
平日昏峰									
路口	設備編號	方向	計數時段	VD_變化量	人工計數流量	人工_小	人工_中	人工_大	準確度
中山北路六段/德行西路口	VYSIB20	東向	1015~1020	53	58	36	21	1	91%
	VYSIB40	南向	1035~1040	110	116	63	49	4	95%
	VYSIB60	西向	0940~0945	98	102	66	35	1	96%
	VYSIB00	北向	0957~1002	197	182	89	91	2	92%

3.3.2 動態模擬測試

3.3.2.1 車流模擬軟體

本計畫預計蒐集長時間的交通調查資料，以 3.2 節之 AI 號誌控制模型進行動態模擬，號誌代理人透過與環境的互動，從經驗中學習出最優化的控制策略，惟因現實上不可能允許代理人直接在實際場域探索各種可能的控制策略，因此仍必須建置一套在不影響現實車流下，讓代理人嘗試下控制策略取得績效的環境，而 SUMO 及 VISSIM 交通模擬軟體恰為符合需求的最佳選項。車流模擬軟體操作簡單說明如下：

一、SUMO

SUMO(Simulation of Urban MObility)是一個微觀、多運具、空間連續和時間離散的車流模擬平台。其應用最早始於 2001 年，2002 年首次發布開源版本。主要部分的開發工作由德國航空航天中心(Deutsches Zentrumfür Luft- und Raumfahrt, DLR)的交通系統研究所承擔。並透過外部團隊支持不同模擬套件的擴展。在過去的十年中，SUMO 已經發展成為一套功能齊全的車流模型套件。其路網導入工具能夠讀取不同來源的道路資料，可支援 VISUM、VISSIM、Shapefiles、OSM、RoboCup、MATsim、OpenDRIVE 和 XML 等格式。需求產生工具可支援不同方式作輸入，如起訖矩陣、路徑需求、流量計數、動態指派等。另外其高效的運算可用於整個城市的車流模擬，以 1GHz 的主機運算一秒可更新 10 萬台車的狀態。自 2001 年以來，SUMO 已在多個國家和國際研究項目中使用，包括交通號誌評估、路徑指引評估、交通調查方法評估、車輛通訊模擬、交通預測等領域的應用。圖 3.3.2.1-1 為 SUMO 路網編輯介面。

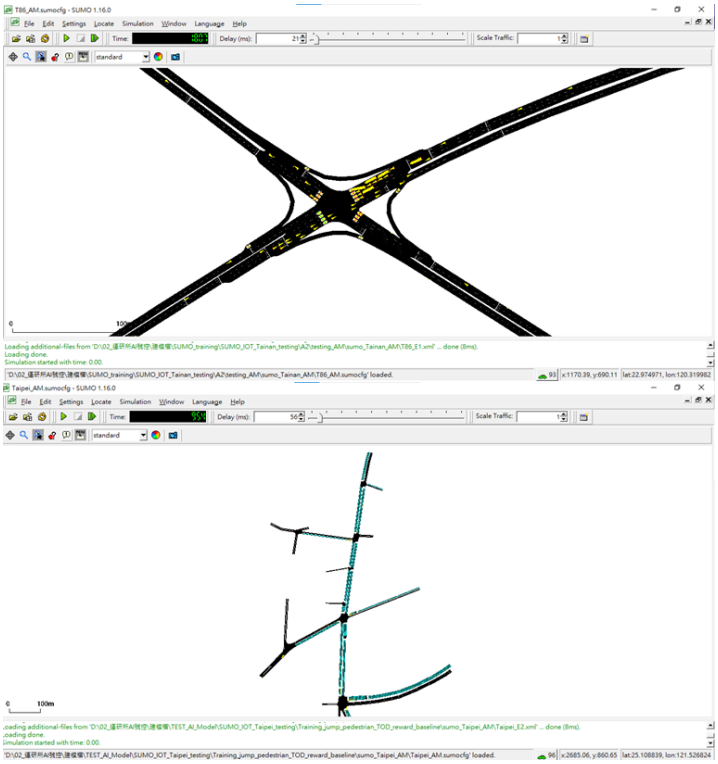


圖 3.3.2.1-1 SUMO 路網編輯介面示意圖

SUMO 提供 TraCI(Traffic Control Interface)工具包，這個套件可以實現訪問者(例如 Python script)對正在運作的模擬即時的存取操作其中的各項設定與行為。因此可用於取得號誌、車輛狀態、偵測器數值等，亦可使用在動態控制號誌燈號，或是改變特定車輛的參數或行駛路徑等。在 SUMO 模擬過程中，可以透過 TraCI 套件即時動態改動或取得資訊。

二、VISSIM

為德國 PTV 公司所開發之 VISSIM 專業交通車流模擬器。其特點在於大量可依據不同情

境調整之客制化參數，足以相當程度的模擬出各式不同地區的駕駛行為特性。其中也包含我國機車駕駛行為模擬，例如同車道超車(鑽行)、兩段式左轉、停等區等等。模擬畫面參考圖 3.3.2.1-2 所示。

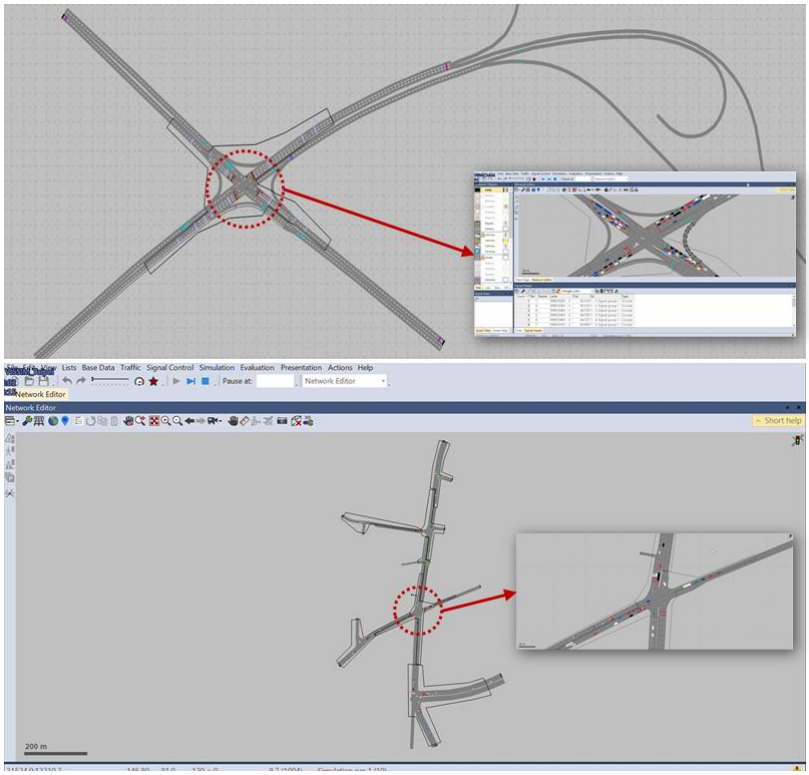


圖 3.3.2.1-2 VISSIM 模擬路網示意圖

VISSIM 車流模擬軟體是目前廣受國際交通業界好評與應用的交通模擬器，除前述豐富的軟體功能與客制化能力之外，對於本案的強化學習號誌控制而言相當重要的一點在於微觀車流軟體相較於定性(Deterministic)的巨觀車流模擬，能夠提供一個隨機性(Stochastic)的交通環境給代理人去做學習。這點將影響代理人的績效表現，因為實際的交通環境必然存在一定程度的隨機性，因此其必須要在類似的環境下探索，才能學到最佳化績效期望值的策略。倘若使用定性的巨觀車流模型讓代理人進行學習，則學出的結果將會是服從定性巨觀車流下的解析最佳解，與實際狀況就會有所差距，可能導致代理人失去原本能因應各種不同車流狀態並即時調整的最大強項。

VISSIM 作為一款微觀車流模擬器，一般的使用情境為所謂「靜態分析」，意即當模擬模型相關參數設定完畢之後，模型便會根據該組參數搭配選定之亂數種子進行模擬分析，在整套模擬過程當中將不再會有任何外部的影響因素干擾模擬過程。然而在動態控制的架構下，靜態分析並無法滿足動態控制的需求。因此 VISSIM 提供了一套能訪問或控制模擬器內所有物件的外部接口，可將數據與指令透過程式語言的指令集實現各式動態控制的模擬，稱為 VISSIM-COM。VISSIM-COM 接口定義了一個階層式物件模型，其中最初由 GUI 提供的模擬器的功能和參數可以通過編譯程式來訪問或操作各項物件，例如可以透過程式自由的控制

紅綠燈的秒數，或是讀取任何定義車道的車輛數等資訊。VISSIM-COM 能夠支援大多數主流的程式語言(例如 C++、Visual Basic、Java 等)。通過 VISSIM-COM，使用者能夠動態地操作大多數內部對象的屬性。

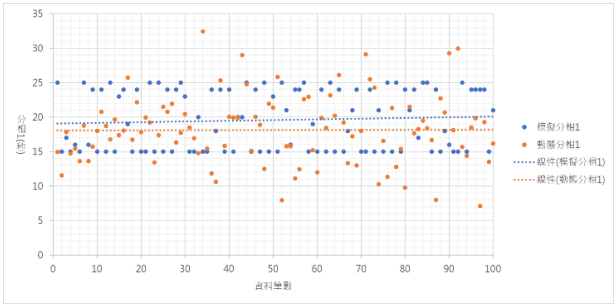
本研究透過 Python script 在 VISSIM API 環境，作為強化學習代理人訓練模組以及 VISSIM 模擬環境間的接口，可在 VISSIM 模擬過程中讀取各樣交通車流狀態以及號誌狀態，並以代理人計算出的時制/相秒數來動態地控制 VISSIM 號誌控制內容。其中亦將常用功能參數化，如最大最小綠燈長度、黃燈秒數、全紅秒數、時相順序等等，以利在擴充路網或調整參數時能夠順利調整。同時，API 環境亦預先定義了數種常用的 KPI 指標，如停等延滯、通過量、旅行時間等等，方便 AI 訓練時有不同的績效可供參考，而在計畫執行的過程，亦可視業主需求新增更多種類的 KPI。

3.3.2.2 單一路口場域(臺南市「台 86-19 甲線」路口)動態模擬績效

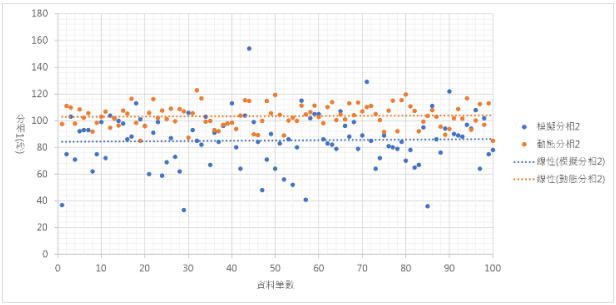
依偏好停等延滯為最低之獎勵目標，實際蒐集 10/26(六)、10/27(日)、11/5(二)及 11/6(三)交通轉向量資料，進行 AI 號誌控制模型動態模擬測試，產出對應之平日晨峰(07：00~09：00)、平日離峰(12：30~14：30)、平日昏峰(16：30~18：30)及假日昏峰(16：30~18：30)時段之分相秒數與績效結果，並須符合前述之合理性及穩定性，整理如下。~~表 3.2.5.3-1 至表 3.2.5.3-4 分別為各時段之 TOD、本期 AI 號誌控模型的績效彙整，~~圖 3.3.2.2.1 至圖 3.3.2.2-4 為本期 AI 號誌控模型各時段動態模擬各分相秒數之合理性與穩定性分析。

一、平日晨峰(07：00~09：00)

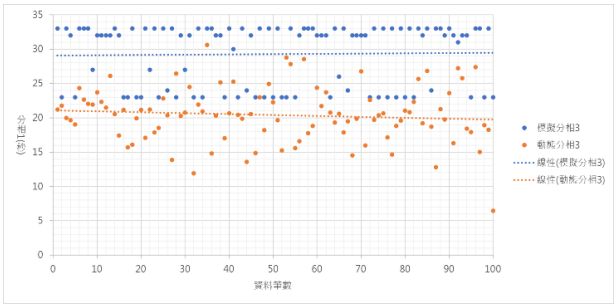
週期及各分相趨勢圖顯示其週期秒數約呈現 221 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 18 秒、分相二的 103 秒、分相三的 20 秒、分相四的 33 秒及分相五的 46 秒，較模擬環境 AI 號誌控制模型產出之 230 秒週期減少 9 秒，動態模擬週期平均較 TOD 之 220 秒週期多 1 秒。且動態模擬秒數各分相集中趨勢與模擬秒數趨近一致，具穩定及合理性，唯動態模擬會依據實際獲取之交通流狀態輸出對應之分相秒數，所以其秒數偶有離散情形。



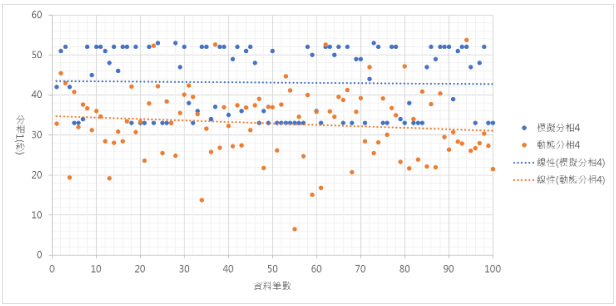
分相 1



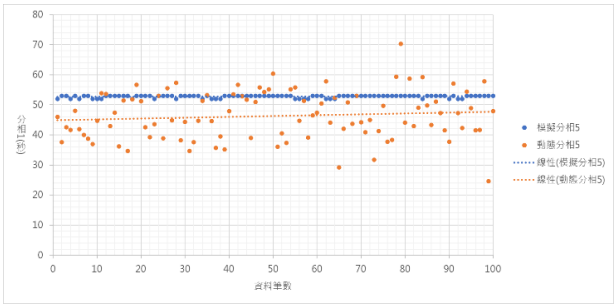
分相 2



分相 3



分相 4

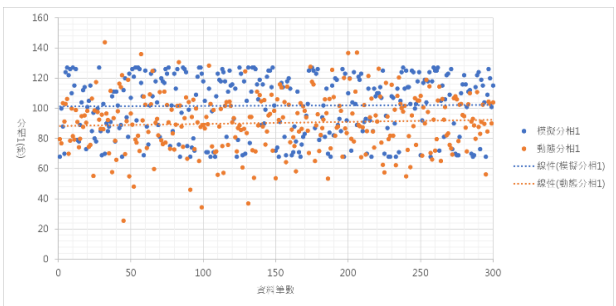


分相 5

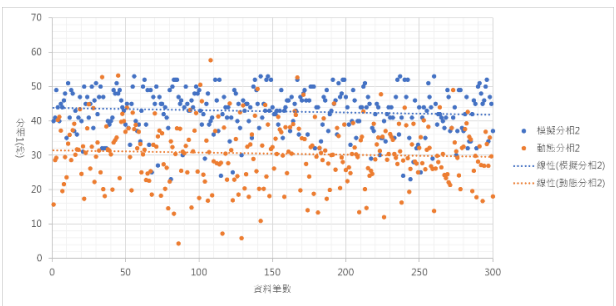
圖 3.3.2.2-1 平日晨峰動態模擬各分相秒數合理性及穩定性分析圖

二、平日離峰(12：30~14：30)

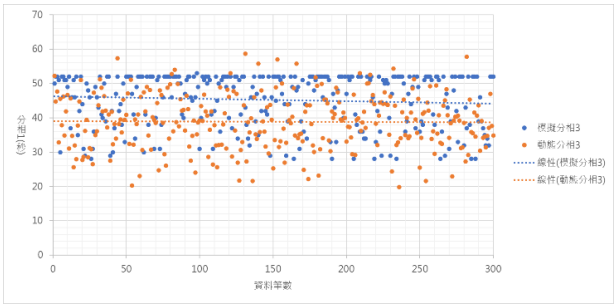
週期及各分相趨勢圖顯示其週期秒數約呈現 193 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 90 秒、分相二的 30 秒、分相三的 39 秒及分相四的 33 秒，較模擬環境 AI 號誌控制模型產出之 231 秒週期減少 38 秒，並高於 TOD 之 160 秒週期。且動態模擬秒數各分相集中趨勢與模擬秒數趨近一致，具穩定及合理性，唯動態模擬會依據實際獲取之交通流狀態輸出對應之分相秒數，所以其秒數偶有離散情形。



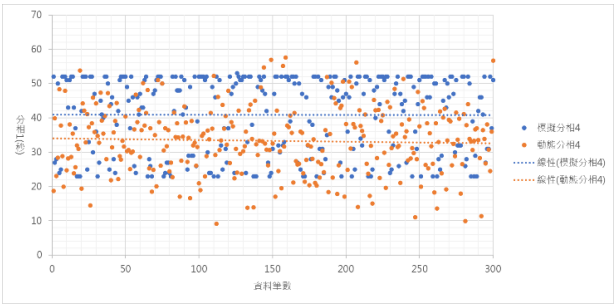
分相 1



分相 2



分相 3

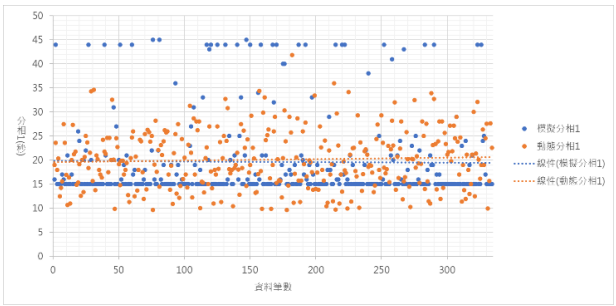


分相 4

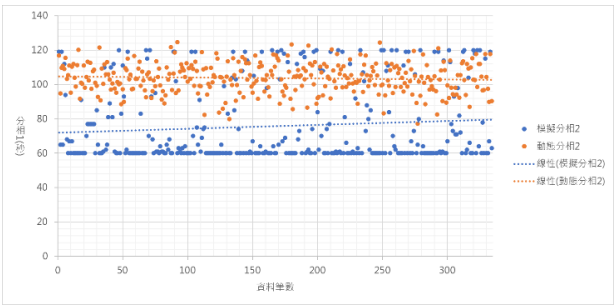
圖 3.3.2.2-2 平日離峰動態模擬各分相秒數合理性及穩定性分析圖

三、平日昏峰(16：30~18：30)

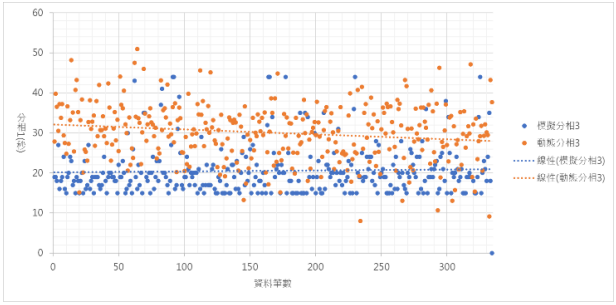
週期及各分相趨勢圖顯示其週期秒數約呈現 221 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 20 秒、分相二的 104 秒、分相三的 30 秒、分相四的 35 秒及分相五的 31 秒，較模擬環境 AI 號誌控制模型產出之 169 秒週期增加 52 秒，但略低於 TOD 之 240 秒週期。且動態模擬秒數各分相集中趨勢與模擬秒數趨近一致，具穩定及合理性，唯動態模擬會依據實際獲取之交通流狀態輸出對應之分相秒數，所以其秒數偶有離散情形。



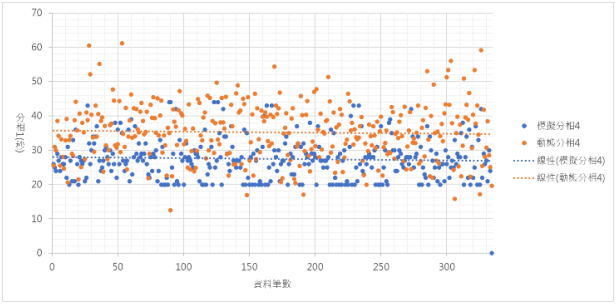
分相 1



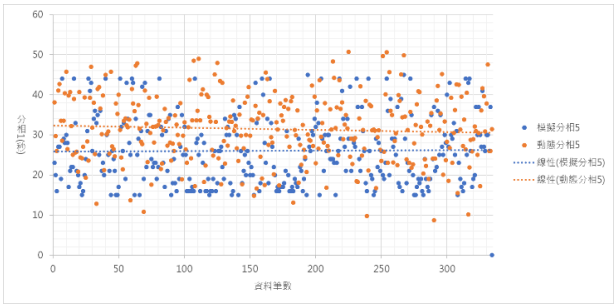
分相 2



分相 3



分相 4

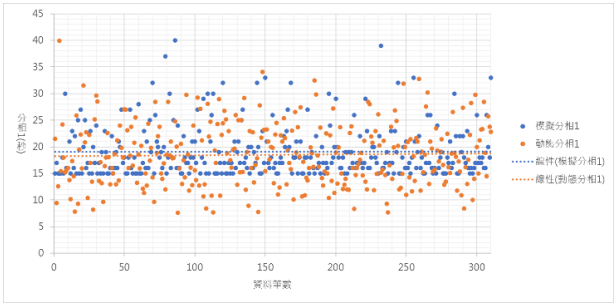


分相 5

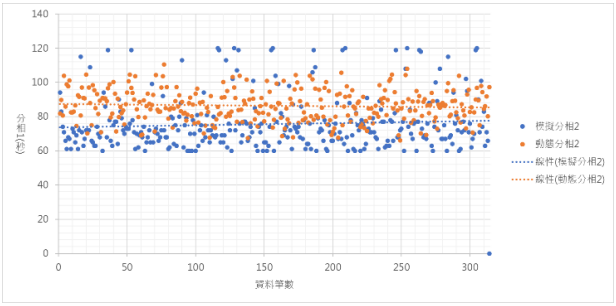
圖 3.3.2.2-3 平日昏峰動態模擬各分相秒數合理性及穩定性分析圖

四、假日昏峰(16：30~18：30)

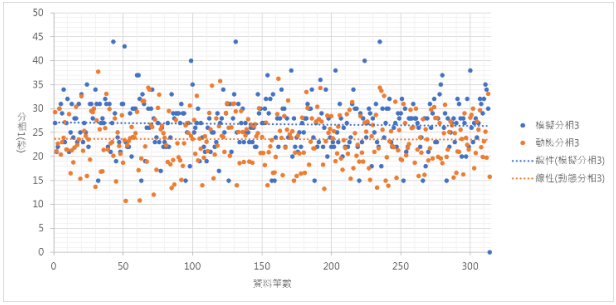
週期及各分相趨勢圖顯示其週期秒數約呈現 196 秒上下集中趨勢，各分相秒數趨勢分別為分相一的 18 秒、分相二的 86 秒、分相三的 24 秒、分相四的 31 秒及分相五的 36 秒，較模擬環境 AI 號誌控制模型產出之 190 秒週期增加 6 秒，但略低於 TOD 之 240 秒週期。且動態模擬秒數各分相集中趨勢與模擬秒數趨近一致，具穩定及合理性，唯動態模擬會依據實際獲取之交通流狀態輸出對應之分相秒數，所以其秒數偶有離散情形。



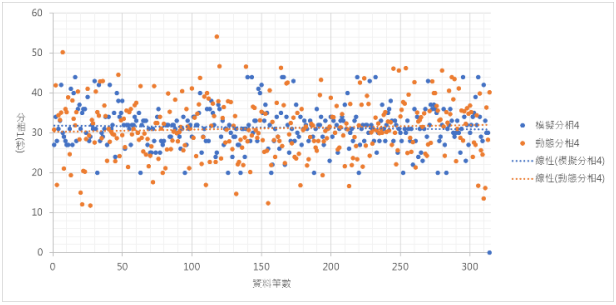
分相 1



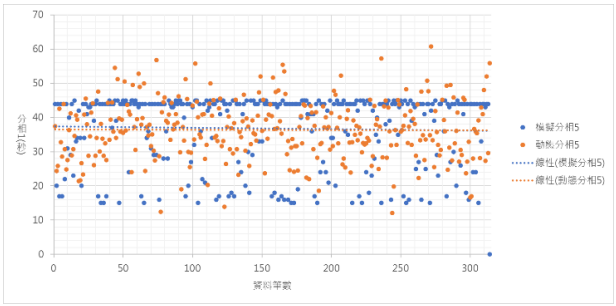
分相 2



分相 3



分相 4



分相 5

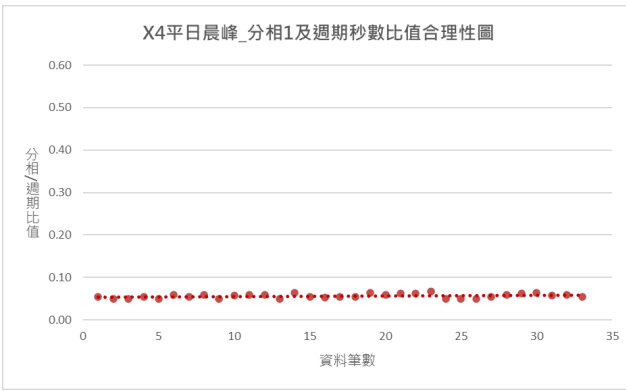
圖 3.3.2.2-4 假日昏峰動態模擬各分相秒數合理性及穩定性分析圖

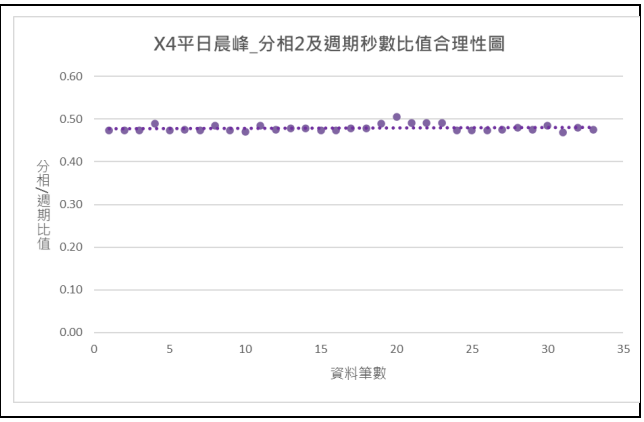
3.3.2.3 幹道多路口場域(臺北市「中山北路-德行東路」)動態模擬績效

延續車流模擬環境及測試，實際蒐集雷達辨識資料，進行 AI 號誌控制模型動態模擬測試，將 AI 號誌控制模型產出之中山北路/德行西路路口(X4)對應之平日晨峰(07：00~09：00)、平日離峰(中午 12:30-14:30)及平日昏峰(16：30~19：00)，共 4 個時段之分相秒數與偵測停等車輛數，並須符合前述之合理性及穩定性，說明如下。

一、平日晨峰(07：00~09：00)

中山北路/德行西路路口(X4)TOD 各分相秒數與週期之比值分別為：分相一的 0.06、分相二的 0.48、分相三的 0.05、分相四的 0.10、分相五的 0.22 及分相六的 0.08。圖 3.3.2.3-1 為平日晨峰本期 AI 號誌控制模型各分相秒數合理性分析，圖 3.3.2.3-2 為平日晨峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性，其斜率分別為-0.0086 及 0.014，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定。





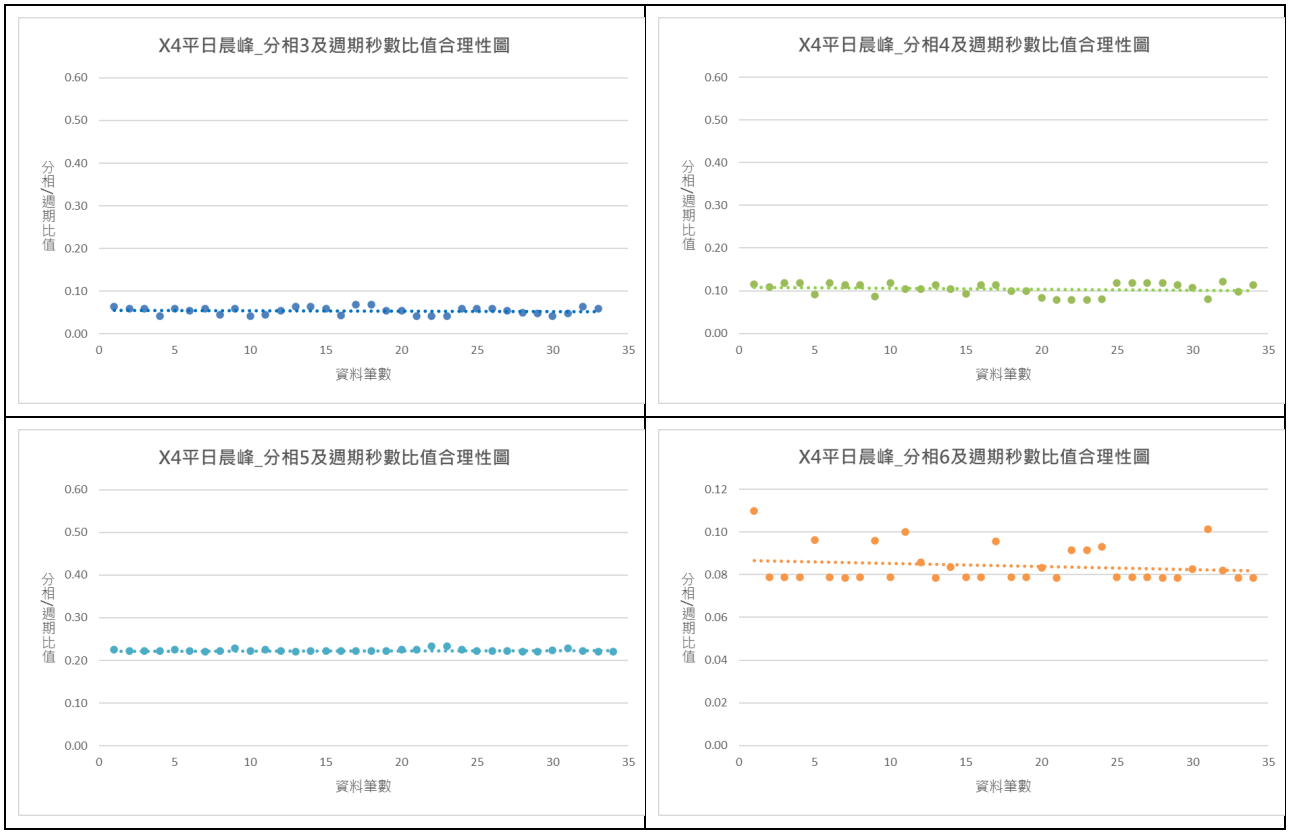


圖 3.3.2.3-1 平日晨峰本期 AI 號誌控制模型各分相秒數合理性分析圖

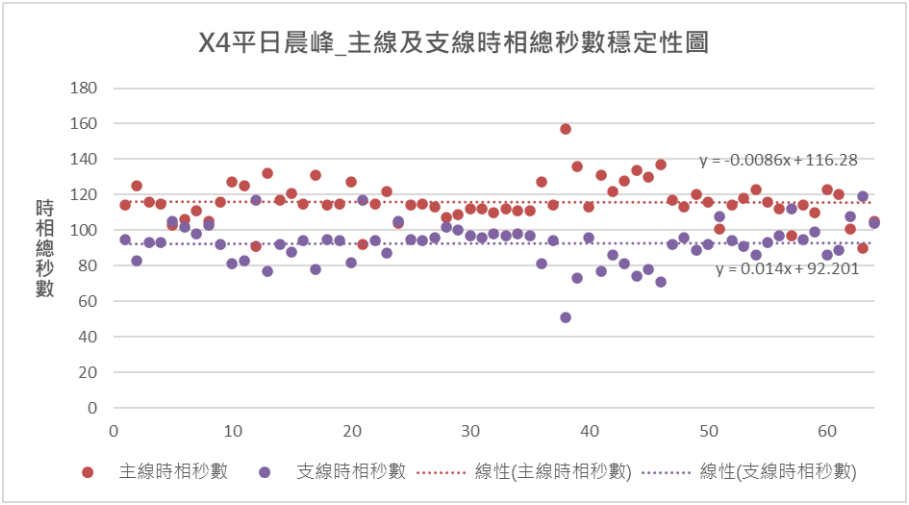


圖 3.3.2.3-2 平日晨峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖

二、平日離峰(12：30~14：30)

中山北路/德行西路路口(X4)TOD 各分相秒數與週期之比值分別為：分相一的 0.06、分相二的 0.49、分相三的 0.04、分相四的 0.08、分相五的 0.23 及分相六的 0.10。圖 3.3.2.3-3 為平日離峰本期 AI 號誌控制模型各分相秒數合理性分析，圖 3.3.2.3-4 為平日離峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性，其斜率分別為 0.0608 及-0.0274，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定。

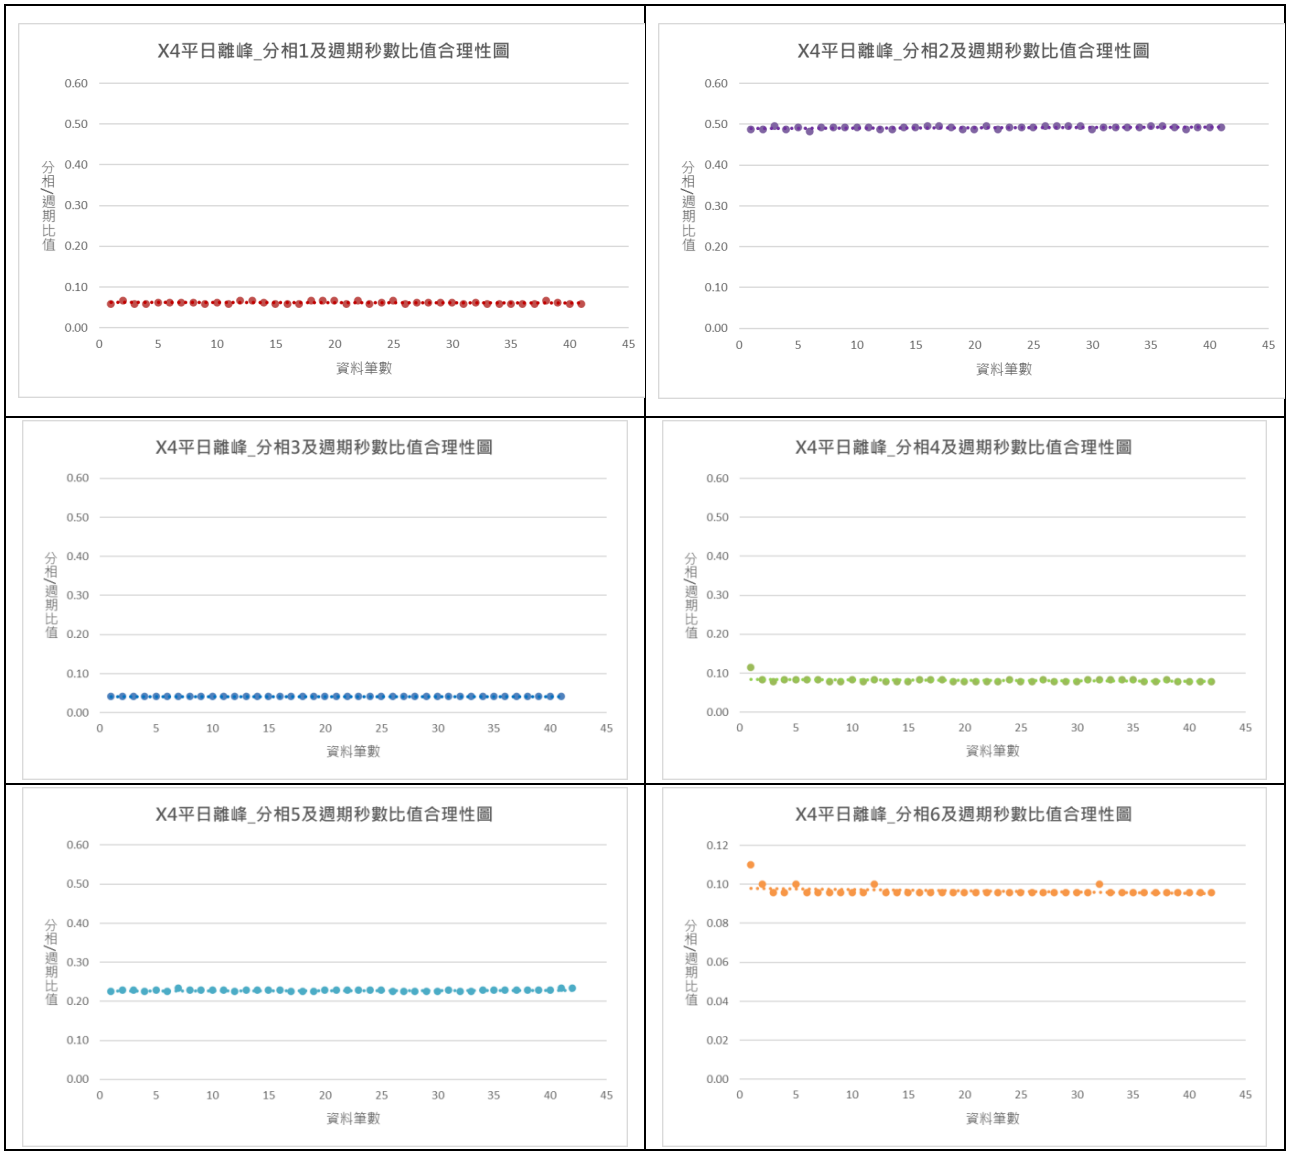


圖 3.3.2.3-3 平日離峰本期 AI 號誌控制模型各分相秒數合理性分析圖

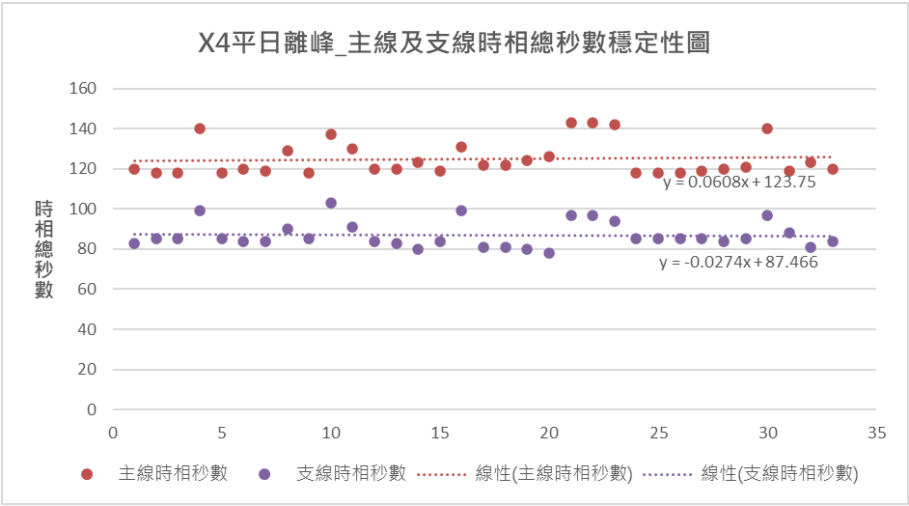


圖 3.3.2.3-4 平日離峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖

三、平日昏峰(16：30~18：30)

中山北路/德行西路路口(X4)TOD 各分相秒數與週期之比值分別為：分相一的 0.05、分相二的 0.44、分相三的 0.09、分相四的 0.28 及分相五的 0.14。圖 3.3.2.3-5 為平日昏峰本期 AI 號誌控制模型各分相秒數合理性分析，圖 3.3.2.3-6 為平日昏峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性，其斜率分別為 0.0092 及-0.0092，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定。

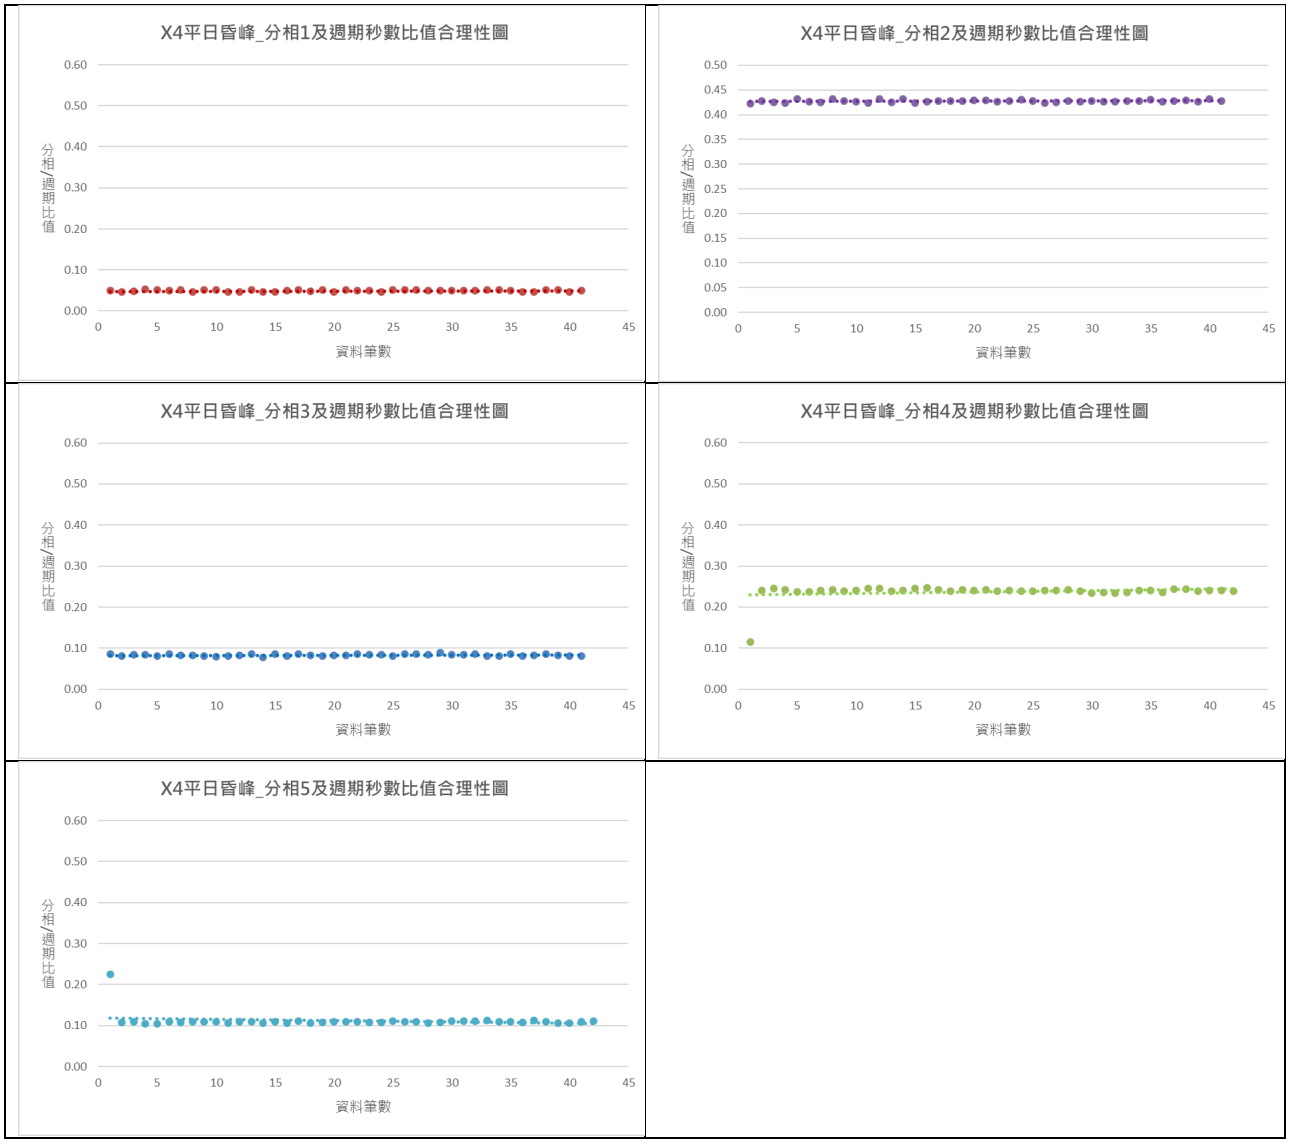


圖 3.3.2.3-5 平日昏峰本期 AI 號誌控制模型各分相秒數合理性分析圖

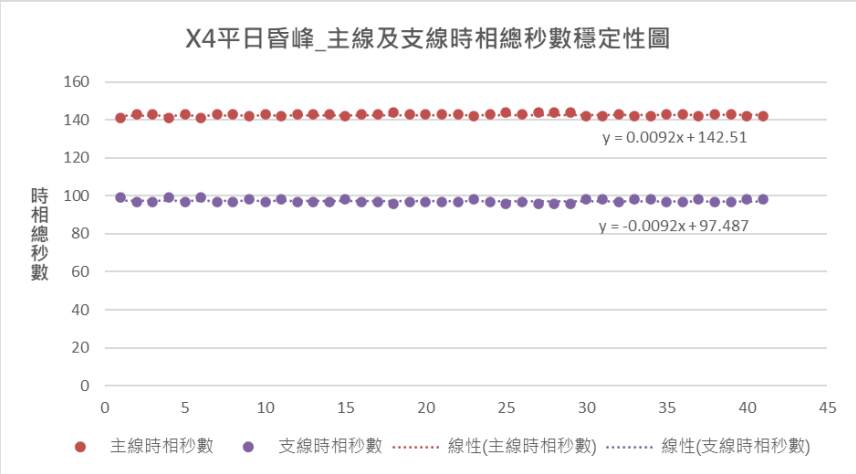
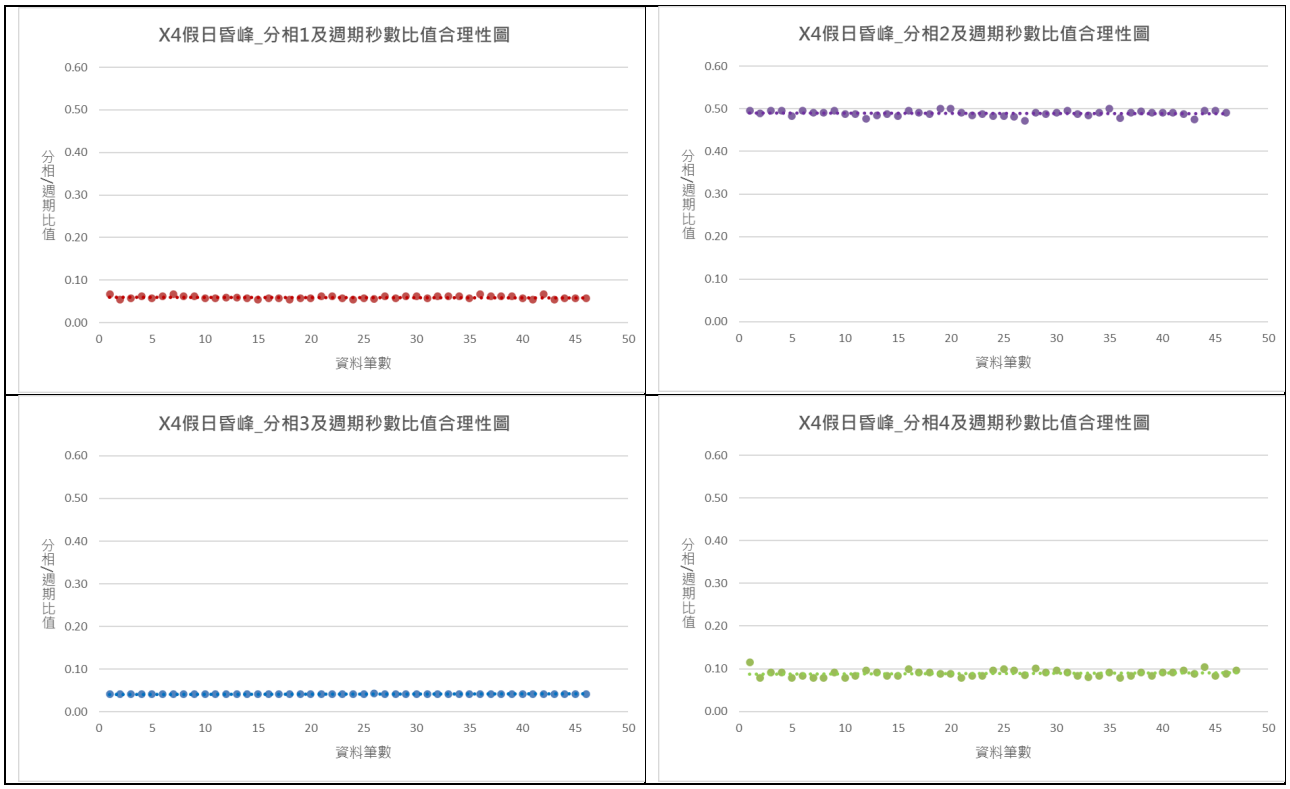


圖 3.3.2.3-6 平日昏峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖

四、假日昏峰(16：30~18：30)

中山北路/德行西路路口(X4)TOD 各分相秒數與週期之比值分別為：分相一的 0.06、分相二的 0.49、分相三的 0.04、分相四的 0.09、分相五的 0.22 及分相六的 0.10。圖 3.3.2.3-7 為假日昏峰本期 AI 號誌控制模型各分相秒數合理性分析，圖 3.3.2.3-8 為假日昏峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性，其斜率分別為-0.0104 及 0.0059，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定。



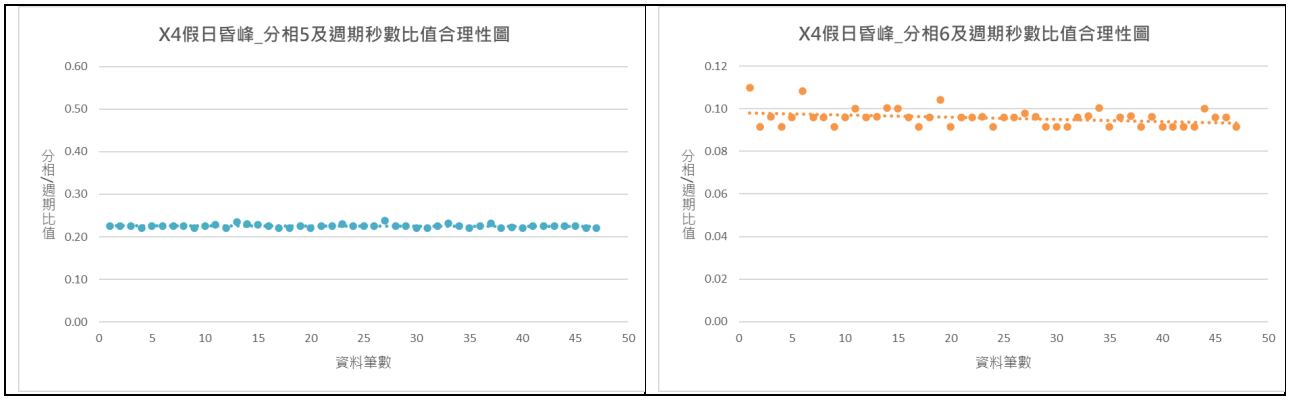


圖 3.3.2.3-7 假日昏峰本期 AI 號誌控制模型各分相秒數合理性分析圖

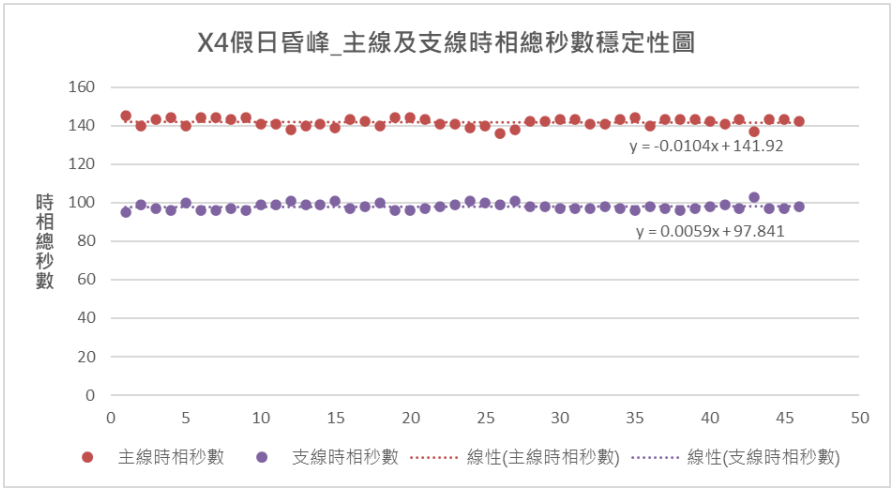


圖 3.3.2.3-8 假日昏峰本期 AI 號誌控制模型主線及支線時相總秒數穩定性圖

3.3.3 號誌控制核心運作模組與監控介面

本計畫開發人工智慧強化學習號誌控制核心運作模組，連結整合現場設備、縣市交通控制中心與 AI 號誌控制模型，將運作績效儲存於資料庫中，提供運作狀態監控畫面，呈現即時路口績效。

一、整體架構

人工智慧強化學習號誌控制系統整體架構如圖 3.3.3-1 所示，首先取得路口相關設備(如 TC、VD)運作數據，將收集到的資料傳送給 AI 號誌控制模型做運算，AI 號誌控制模型會即時將計算結果回傳，然後再依照結果調整時制計畫，最後傳送給號誌控制器，即時運作狀態與路口績效可透過實測監控畫面掌握。線下 AI 號誌控制模組則會定時做訓練，將最新的訓練結果傳送給線上 AI 號誌決策模組使用。

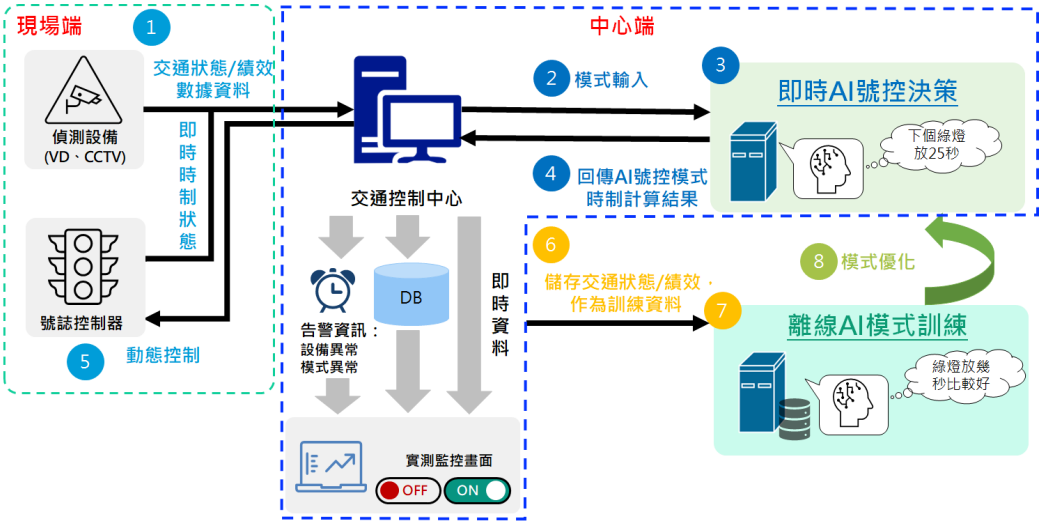


圖 3.3.3-1 號誌控制核心運作模組架構

系統的執行流程如圖 3.3.3-2 所示，首先會定時取得設備資料，如車輛偵測器分車道、車種與每秒之車輛數等，或是號誌控制器目前執行的時制計畫、時相及剩餘秒數。下一步驗證資料有無缺漏，當資料有所缺漏時會自動帶入原時制計畫秒數，避免現場因降階運轉之補償機制導致交通壅塞。若資料無缺漏，系統將再確認群組內控制器是否正常連線，緊接查看目前號制分相是否進入清道時間，若進入清道時間則呼叫線上 AI 決策模組，計算下個週期或分相秒數，最後將秒數傳送至控制器執行。

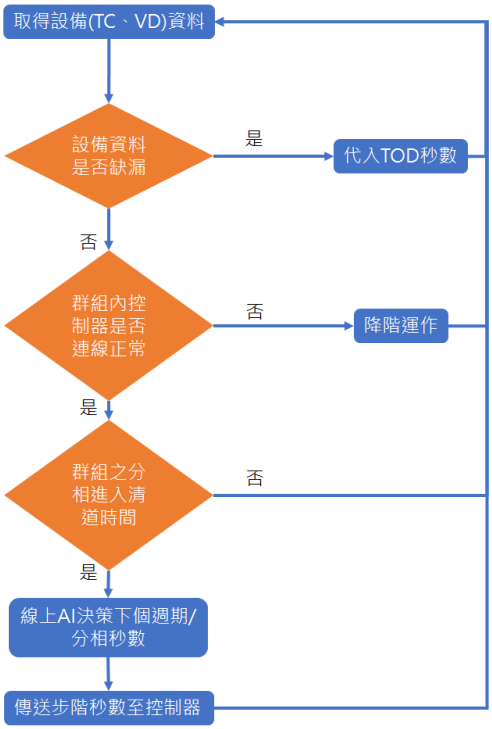


圖 3.3.3-2 AI 智慧號誌控制系統執行流程

二、軟體功能

設備透過即時串流服務，將資料依照頻率傳送至中心號誌控制系統，而號誌控制系統依照功能將資料傳送至 AI 號誌控制模型、資料庫及監控畫面，AI 號誌控制模型計算之最適結果則下達現場號誌控制器，進行動態人工智慧強化學習號誌控制，並可查詢即時燈態與步階資訊，其資料串接架構規劃如圖 3.3.3-3 所示。

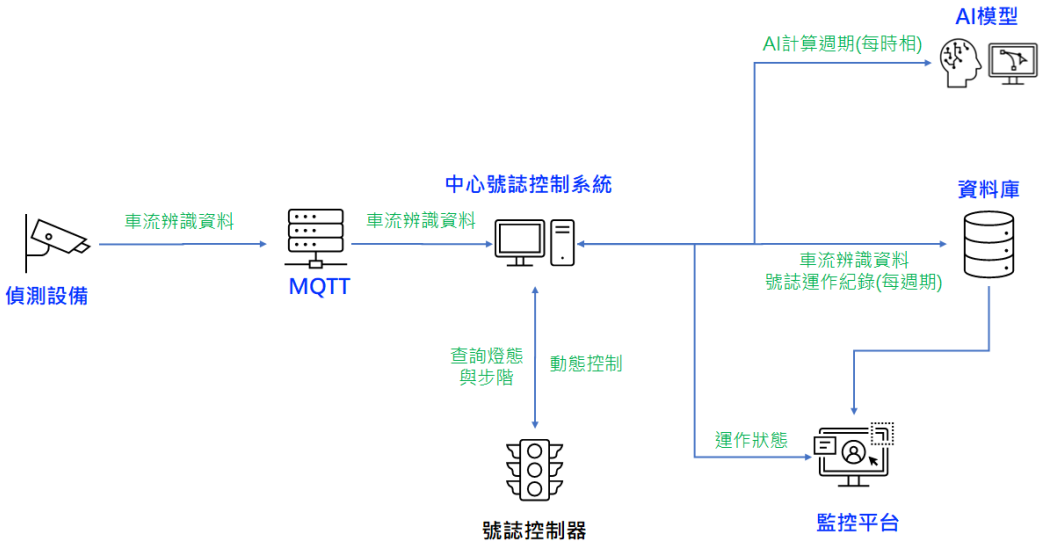


圖 3.3.3-3 資料串接架構規劃

三、實測監控畫面

實測監控畫面提供 GIS 監控圖台、系統管理、運作績效三大功能，協助使用者掌握實測情形。

(一)GIS 監控圖台

監控圖台分為畫面左側路口運作績效、路口狀態與畫面右側之 GIS 地圖，系統畫面如圖 3.3.3-4 所示。路口運作績效、路口狀態依車流偵測設備可提供之資訊不同，呈現即時路口延滯、各分相綠燈秒數比較表、綠燈續進帶、近 1 小時路口流量趨勢、轉向量交通量圖資料，使用者可藉由即時資料即時路口流量，並了解 AI 號誌控制模型運算之秒數與 TOD 之差異。

GIS 地圖呈現實測路口周邊之號誌控制器、車流偵測設備、CCTV 即時影像點位與路口即時燈號，右下角則顯示設備運作狀態，可一覽有無設備斷線。點選號誌控制器圖示可知路口當下時制計畫、分相圖與現場綠燈秒數，實測中可由現場綠燈秒數得知 AI 計算秒數是否有下達號誌控制器；點選臺北市實驗場域之車流偵測設備圖示可知即時停等車輛數，臺南市實驗場域由於使用即時影像 AI 辨識技術，故呈現 CCTV 即時影像畫面。

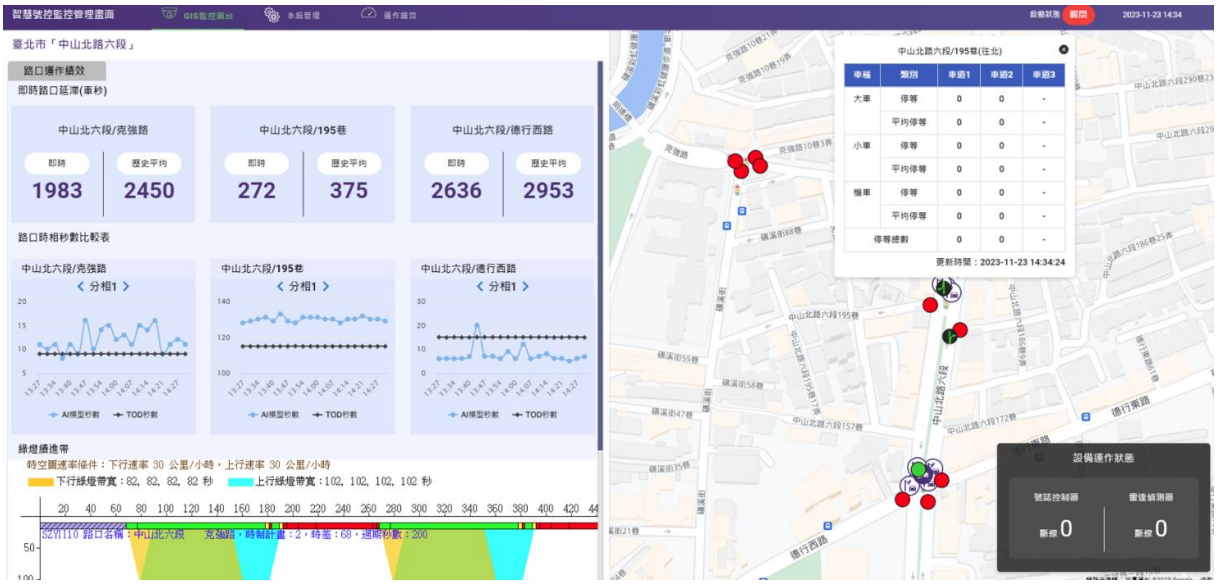


圖 3.3.3-4 實測監控畫面-GIS 監控圖台

(二)系統管理

使用者可於系統管理頁面進行 AI 號誌控制之排程設定，可依需求單日或每日、每週之循環排程，不須於每次實測安排人員手動開啟、關閉 AI 號誌控制。若實測過程發生意外事件，系統無自動回復 TOD 控制時，亦可於此頁面手動操作。圖 3.3.3-5 為實測監控的系統管理畫面。



圖 3.3.3-5 實測監控畫面-系統管理

(三)運作績效

提供智慧號誌控制運行時制計畫、車流偵測資料(停等車流量/影像辨識車流量)、系統運作異常紀錄之資料查詢、下載功能。智慧號誌控制運行時制計畫可查詢號誌控制器現場之週期、分相開始時間、時相編號、分相編號與號誌秒數；車流偵測資料可查詢路口各方向之車流量；系統運作異常紀錄可查詢號誌控制器暫停原因與暫停之起始、

結束時間。圖 3.3.3-6 至圖 3.3.3-8 為實測監控的運行時制計畫、車流偵測資料、系統運作異常紀錄等查詢畫面。

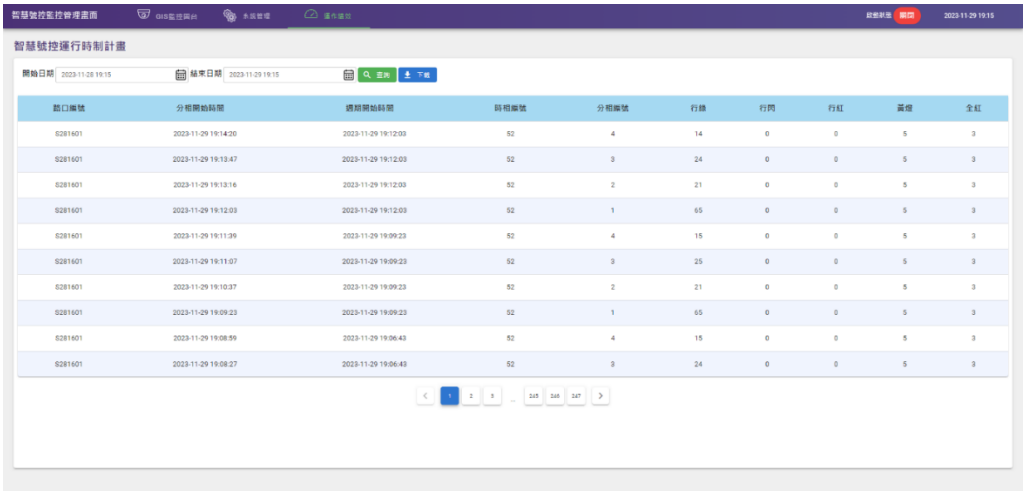


圖 3.3.3-6 實測監控畫面-「智慧號誌控制運行時制計畫」查詢畫面

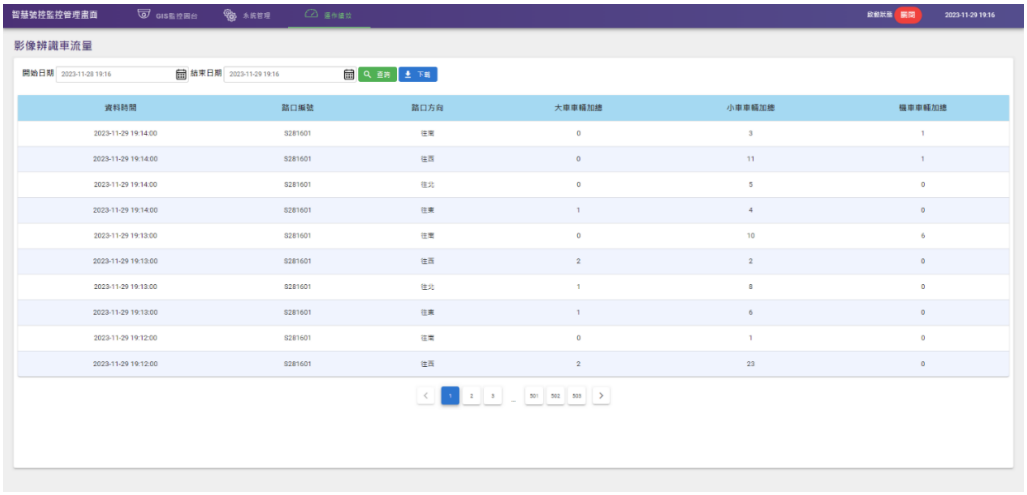


圖 3.3.3-7 實測監控畫面-「車流偵測資料」查詢畫面

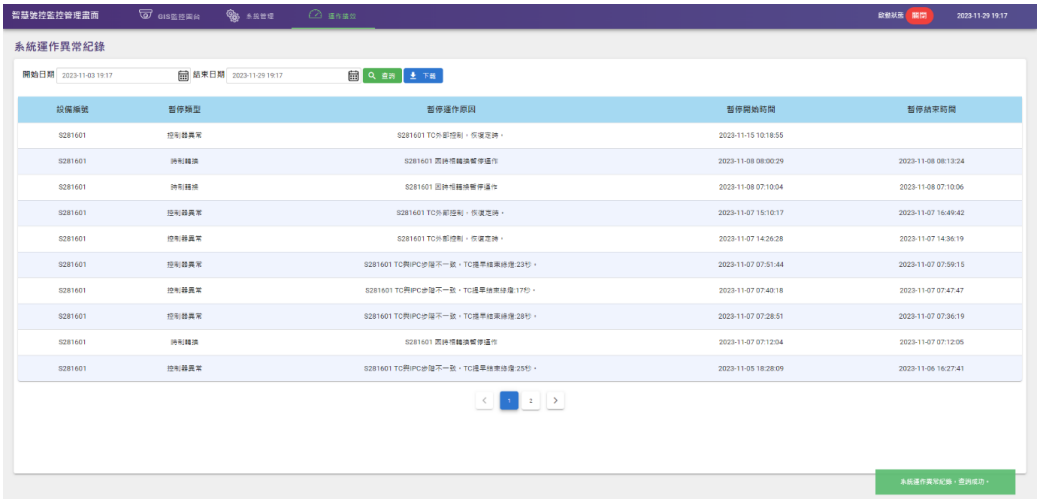


圖 3.3.3-8 實測監控畫面-「系統運作異常紀錄」查詢畫面

3.3.4 實測計畫與歷程

3.3.4.1 實測計畫

一、臺南市實驗場域計畫

(一)實測日期：平日 11 月 14 日(四)、11 月 15 日(五)及假日 11 月 17 日(日)。

(二)實測時段

1.平日上午尖峰：07：30 至 09：30。

2.平日下午離峰：12：30 至 14：30。

3.平日下午尖峰：16：30 至 18：30。

4.假日尖峰：16：30 至 18：30。

(三)實測地點：臺南市關廟區「台 86 線-台 19 甲線」路口。

(四)實測指標

1.通過量：使用 AI 影像辨識取得通過量資料。

2.停等延滯：使用 GVP 資料進行推估。

二、臺北市實驗場域計畫

(一)實測日期

平日 11 月 20 日(三)、11 月 21 日(四)及假日 11 月 23 日(六)。

(二)實測時段

1.平日上午尖峰：07：00 至 09：00。

2.平日下午離峰：12：30 至 14：30。

3.平日下午尖峰：16：30 至 18：30。

4.假日尖峰：16：30 至 18：30。

(三)實測地點：臺北市「中山北路/克強路」、「中山北路/195 巷」、「中山北路/德行東路」3 個路口幹道。

(四)實測指標

1.通過量：使用車輛偵測器蒐集資料。

2.停等延滯：使用車輛偵測器蒐集資料。

3.旅行時間：使用 GVP 資料進行推估。

三、實測流程操作方式如以下設定內容：

(一)設定人工智慧號誌控制排程

1.進入智慧號誌控制監控管理畫面，點選系統管理。

2.設定排程開始與結束之日期、時間、週期後點選確認。

3.於排程預覽確認欲設定之排程，確認無誤點選儲存。

(二)手動開啟/關閉

1.進入智慧號誌控制監控管理畫面，點選系統管理。

2.於號誌控制即時運作狀態點選「是否手動開關」，即可開啟、關閉人工智慧號誌控制。

四、監控方式

為掌握掌握系統運作狀況，實測初期將安排人力於現場觀察，確保號誌運作正常且不造成路況異常或惡化，同時安排人員監控管理畫面，監控內容如下：

(一)監看現場設備運作狀態，確認是否有設備斷線。

(二)確認系統是否正常運作，若人工智慧號誌控制運作異常則回復原 TOD 控制。

(三)確認人工智慧號誌控制指令是否有下達至現場號誌。

(四)監看現場路況是否發生異常惡化或壅塞，若符合以下門檻，則將人工關閉 AI 號誌控制，回復原 TOD 控制。

1.臺南市實驗場域

參考臺南市交通局提供之建議與前期實測經驗，當車隊長度超過網狀線時(如圖 3.3.4-1 所示)，將判斷為 AI 號誌控制導致之壅塞，觀測停等車輛經 3 週期仍未通過路口時，將人工關閉 AI 號誌控制，避免造成現場進一步壅塞。



圖 3.3.4-1 臺南市實驗場域觀測重點

2.臺北市實驗場域

參考前期實測經驗，當車隊長度超過箭頭標示位置時(如圖 3.3.4-2 所示)，將判斷為 AI 號誌控制導致之壅塞，觀測停等車輛經 3 週期仍未通過路口時，將人工關閉 AI 號誌控制，避免造成現場進一步壅塞。

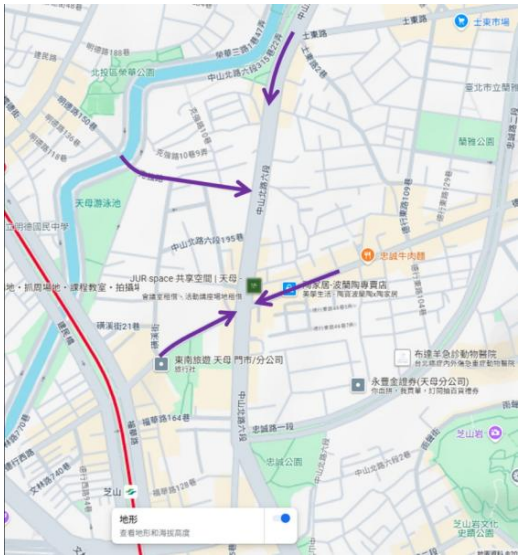


圖 3.3.4-2 臺北市實驗場域觀測重點

五、例外事件

號誌控制模組於實測期間持續偵測表 3.3.4.1-1 所列例外事件，當例外事件發生時將自動降階恢復原固定時制計畫，避免因號誌控制導致現場交通狀況混亂之情形。

表 3.3.4.1-1 實測例外事件一覽表

事件類型	狀態描述	因應方式
現場號誌閃光	現場號誌為綠衝突或時制閃光。	恢復原固定時制計畫，待號誌恢復，由人工智慧號誌控制重新取得控制權。
現場控燈	現場有人員直接手動進行號誌控	恢復原固定時制計畫，待現場控燈結束

	制。	後，人工智慧號誌控制重新取得控制權。
號誌控制器斷線	號誌控制器斷線，導致人工智慧號誌控制指令無法下達。	恢復原固定時制計畫，待號誌控制器恢復連線，再由人工智慧號誌控制取得控制權。
號誌控制器異常	號誌控制器異常，無法正常執行步階秒數。	恢復原固定時制計畫，待異常排除，再由人工智慧號誌控制取得控制權。

(一) 自動降階執行流程

1.暫停人工智慧號誌控制系統。

2.恢復原固定時制計畫。

3.2 個週期後轉換至原固定時制計畫，轉換期間由號誌控制器依當下狀況自行運算進行秒數補償。

(二)人工智慧號誌控制重新取得控制權流程

1.系統偵測例外事件結束。

2.恢復人工智慧號誌控制。

3.轉換需 2 個週期，期間現場號誌依固定時制計畫運作。

3.3.4.2 實測歷程

一、臺南市實驗場域

(一)平日

1.11 月 14 日(四)

晨峰車多但未回堵到悠然山莊門口，車流皆可於一週期順利紓解；昏峰時段台 19 甲線車輛較多，綠燈時可順暢通行，轉換紅燈後路口剩餘 1、2 台車未通過。圖 3.3.4.2-1 為台 86 線晨峰東向車流。



圖 3.3.4.2-1 台 86 線晨峰東向車流現況

2.11 月 15 日(五)

昏峰 17 點開始車輛陸續增加，幹支道車流皆可於一週期順利紓解，17：15 開始往關廟方向出現直行紓解不完狀況，右轉車輛無法順利匯入台 86 西向車流，造成停等。17：40 開始支道南向排隊至悠然山莊左右，各早開、左轉秒數大致符合需求。18：30 後車流紓解，支道有剩餘秒數出現，19：00 後幹道易出現剩餘秒數。圖 3.3.4.2-2 為台 86 線昏峰西向車流。



圖 3.3.4.2-2 台 86 線昏峰西向車流現況

(二)假日(11 月 17 日)：觀察現場車流狀況順暢，皆可於一週期紓解完成，無特殊情形。

二、臺北市實驗場域

(一)平日

1.11 月 20 日(三)

離峰、昏峰時受通訊不穩影響指令傳輸導致降階，離峰降階 7 次、昏峰降階 1 次。昏峰時中山北路六段/德行西路口車多高峰期約於 17：00 至 17：40，主要以南向往士林為主，有時候開綠燈會受前方忠誠路口停等回堵稍微影響起步順暢，17：40 後車流量變少且較順暢。

2.11 月 21 日(四)

晨、昏峰皆因通訊不穩各發生 5 次降階。晨峰車流高峰期約於 8 點前，主要以南向往士林為主，8 點後車流量變少轉為順暢；昏峰中山北路雙向整體車多但順暢。

(二)假日

1.11 月 23 日(六)

因通訊不穩造成 5 次降階(如表 3.3.4.2-1 所示)。車流於 5 點後增加，6 點後逐漸變少。德行西路西向車多，紅燈時車隊多排至上游路口磺溪街，但可於一個週期紓

解完畢。中山北路六段/克強路口南向車流較多，紅燈時多排至上游路口 290 巷，但可於綠燈連鎖時相順行至德行西路口。圖 3.3.4.2-3 為德行西路西向車流。

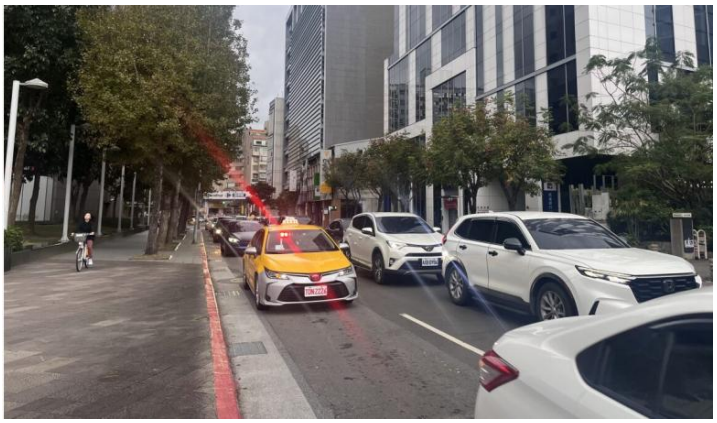


圖 3.3.4.2-3 德行西路西向車流現況

表 3.3.4.2-1 臺北市場域實測時號誌控制器異常紀錄

日期	設備編號	設備類型	暫停運作原因	暫停開始時間	暫停結束時間
2024/11/20	SYSIB10	控制器異常	SYSIB10 步階下載失敗次數太多(通訊異常)。	2024-11-20 12:40:31	2024-11-20 12:46:07
2024/11/20	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:230秒。	2024-11-20 12:50:11	2024-11-20 12:56:08
2024/11/20	SYSIB10	控制器異常	SYSIB10 步階下載失敗次數太多(通訊異常)。	2024-11-20 12:57:28	2024-11-20 13:04:22
2024/11/20	SYSIB10	控制器異常	SYSIB10 步階下載失敗次數太多(通訊異常)。	2024-11-20 13:31:09	2024-11-20 13:37:42
2024/11/20	SYSIB10	控制器異常	SYSIB10 步階下載失敗次數太多(通訊異常)。	2024-11-20 13:39:21	2024-11-20 13:47:44
2024/11/20	SYSIB10	控制器異常	SZYII10 TC與IPC步階不一致。TC提早結束綠燈:5秒。	2024-11-20 13:49:59	2024-11-20 13:57:43
2024/11/20	SYSIB10	控制器異常	SYSIB10 步階下載失敗次數太多(通訊異常)。	2024-11-20 14:02:51	2024-11-20 14:11:03
2024/11/20	SYSIB10	控制器異常	SYSIB10 步階下載失敗次數太多(通訊異常)。	2024-11-20 14:19:38	2024-11-20 14:27:42
2024/11/20	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:187秒。	2024-11-20 17:50:22	2024-11-20 17:57:47
2024/11/20	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:186秒。	2024-11-20 18:09:00	2024-11-20 18:17:50
2024/11/21	SYSIB10	時制轉換	SZYII10 因時相轉換暫停運作	2024-11-21 07:00:50	2024-11-21 07:11:15
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:5秒。	2024-11-21 07:23:21	2024-11-21 07:31:34
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:13秒。	2024-11-21 07:36:34	2024-11-21 07:47:53
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:10秒。	2024-11-21 08:00:44	2024-11-21 08:06:36
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:191秒。	2024-11-21 08:14:02	2024-11-21 08:21:14
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:6秒。	2024-11-21 08:26:23	2024-11-21 08:34:32
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:6秒。	2024-11-21 08:51:02	2024-11-21 12:31:18
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:7秒。	2024-11-21 12:34:58	2024-11-21 12:41:14
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:143秒。	2024-11-21 13:01:12	2024-11-21 13:07:42
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:144秒。	2024-11-21 13:16:14	2024-11-21 13:24:28
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:5秒。	2024-11-21 13:26:00	2024-11-21 13:34:49
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:5秒。	2024-11-21 13:36:00	2024-11-21 13:44:22
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:7秒。	2024-11-21 13:54:20	2024-11-21 14:01:14
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:10秒。	2024-11-21 14:08:44	2024-11-21 14:14:16
2024/11/21	SYSIB10	控制器異常	SZYII10 TC與IPC步階不一致。TC提早結束綠燈:5秒。	2024-11-21 14:20:39	2024-11-21 14:27:44
2024/11/21	SYSIB10	時制轉換	SYSIB10 因時相轉換暫停運作	2024-11-21 16:31:01	2024-11-21 16:31:03
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:190秒。	2024-11-21 17:34:33	2024-11-21 17:41:50
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:6秒。	2024-11-21 17:44:52	2024-11-21 17:51:35
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:6秒。	2024-11-21 17:53:03	2024-11-21 18:01:10
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:192秒。	2024-11-21 18:04:29	2024-11-21 18:11:09
2024/11/21	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:193秒。	2024-11-21 18:25:34	2024-11-23 16:35:25
2024/11/23	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:9秒。	2024-11-23 16:36:08	2024-11-23 16:41:14
2024/11/23	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:9秒。	2024-11-23 17:08:14	2024-11-23 17:17:36
2024/11/23	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC延遲結束綠燈:9秒。	2024-11-23 17:49:52	2024-11-23 17:57:52
2024/11/23	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:7秒。	2024-11-23 18:03:09	2024-11-23 18:11:19
2024/11/23	SYSIB10	控制器異常	SYSIB10 TC與IPC步階不一致。TC提早結束綠燈:226秒。	2024-11-23 18:26:04	

3.3.5 事前事後量化績效評估

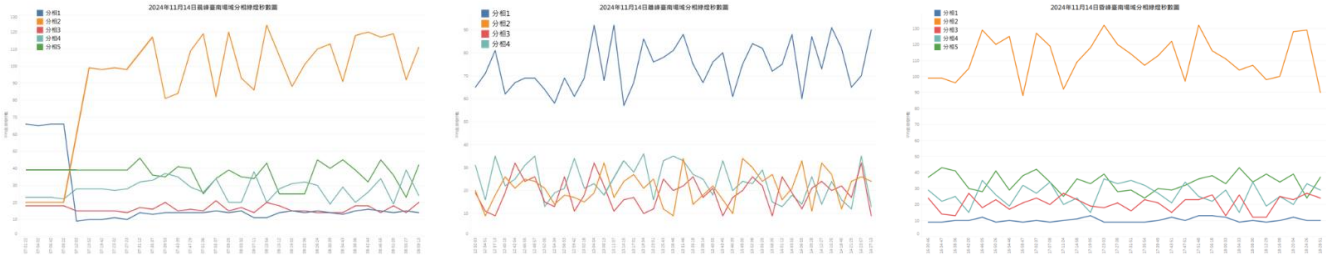
除透過實驗場域目前已建置之偵測設備蒐集來的資料外，本計畫預計增加道路 GVP 資料，作為量化之績效評估指標。GVP 資料蒐集情況，皆以實測所需而定。如實測為期 2 日，則設定當日欲實測時間段，以及未實測日同時段，蒐集 5 分鐘為一筆之事前及事後對照組資

料。比較事前及事後資料，評估模型應用於實際路口的成效。

3.3.5.1 臺南市實驗場域實測結果

一、實測路口分相秒數變化

為逐時相決策分相綠燈秒數，考量當下運行時相編號與該時相剩餘秒數，以及各分相結束時各車種轉向量，判斷下一個分相 AI 控制路口之綠燈秒數。圖 3.3.5.1-1 至圖 3.3.5.1-3 分別為 11/14、11/15、11/17 等日臺南市場域實測各分相綠燈秒數趨勢圖，圖 3.3.5.1-4 至圖 3.3.5.1-6 分別為 11/14、11/15、11/17 等日的臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較。



晨峰　　離峰　　昏峰

圖 3.3.5.1-1 11/14(四)臺南市場域實測各分相綠燈秒數趨勢圖



晨峰　　離峰　　昏峰

圖 3.3.5.1-2 11/15(五)臺南市場域實測各分相綠燈秒數趨勢圖

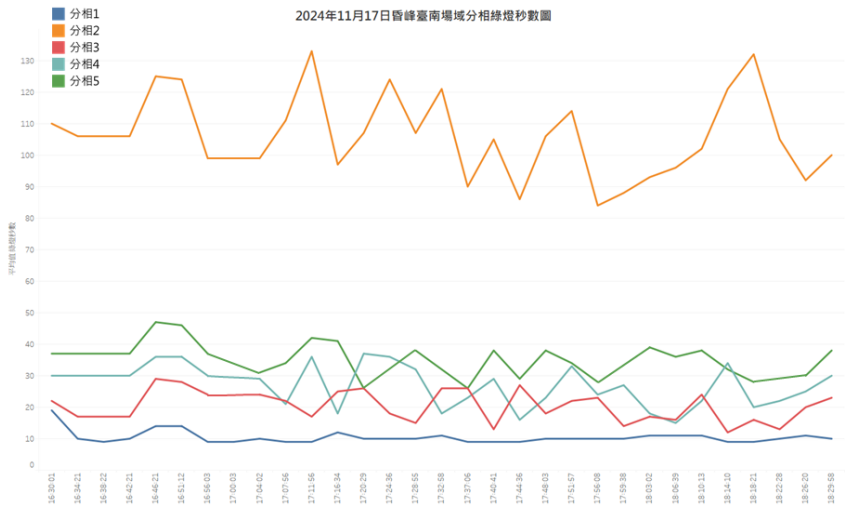
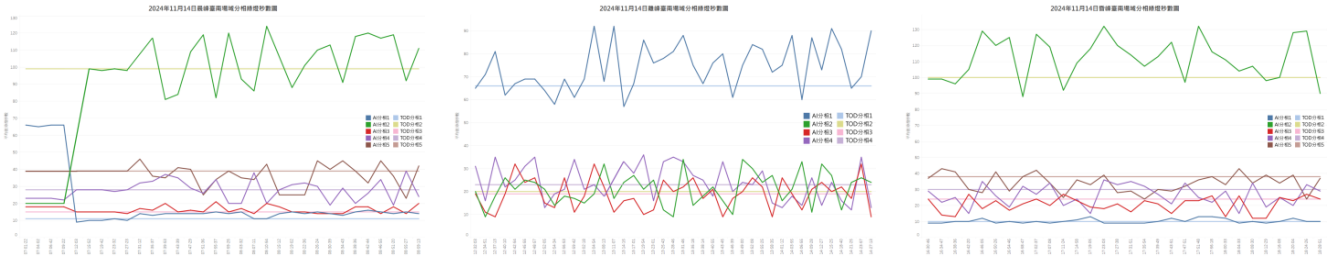
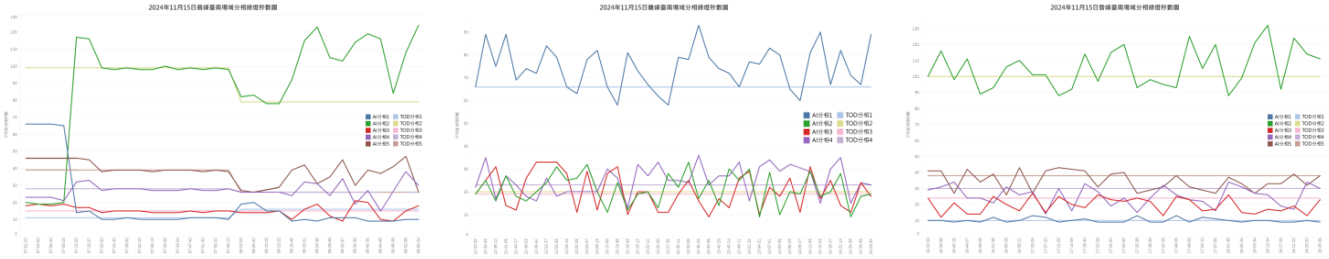


圖 3.3.5.1-3 11/17(日)昏峰臺南市場域實測各分相綠燈秒數趨勢圖



晨峰　　離峰　　昏峰

圖 3.3.5.1-4 11/14(四)臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較



晨峰　　離峰　　昏峰

圖 3.3.5.1-5 11/15(五)臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較

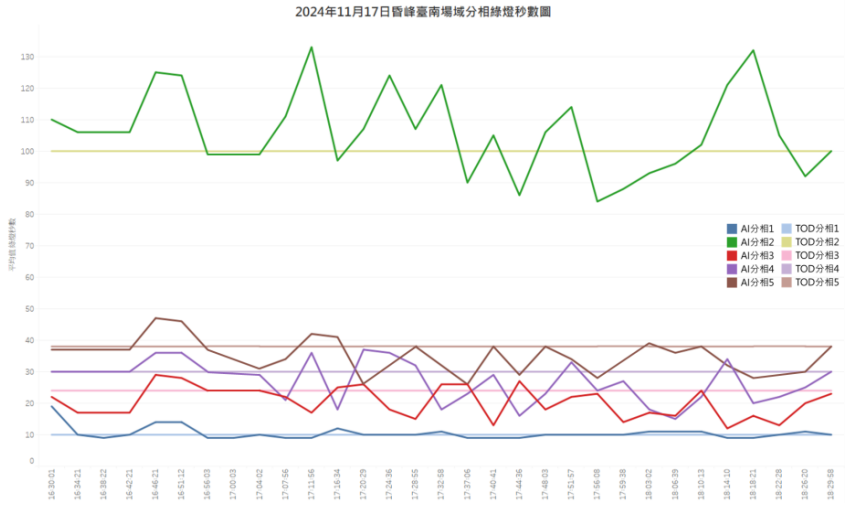


圖 3.3.5.1-6 11/17(日)昏峰臺南市場域 AI 實測與 TOD 各分相綠燈秒數比較

二、路口平均延滯績效

本場域蒐集各臨近路口各方向路段之 GVP 資料，進而推估各臨近路口之路段於 AI 號誌控制前後之延滯表現，具體作法為當車輛駛離上游路口進入目標路段時，其行駛速率會有一段距離不受路口號誌及停等車隊影響，僅受車流影響，且若維持此速率將可順利通過停止線；而實際受號誌影響後通過停止線的時間落差即為號誌帶給車流的整體影響(包含減速、停等、再啟動加速之延滯等)。

又本場域為單一號誌路口，且各方向距上、下游號誌路口達至少 500m 以上，不受號誌及停等車隊影響之車流速率資料取樣較具參考價值，因此採用此法。實測路口延滯績效表現說明如下。

(一) 11 月 14 日 AI 實測與 11 月 21 日動態 TOD 績效表現(如表 3.3.5.1-1 與 3.3.5.1-2 所示)

1. 晨峰：路口整體延滯減少 1.1 秒，改善 3.2%，服務水準維持 C 級。

2. 離峰：路口整體延滯減少 0.5 秒，改善 1.8%，服務水準維持 B 級。

3. 昏峰：路口整體延滯減少 0.6 秒，改善 2.5%，服務水準維持 B 級。

表 3.3.5.1-1 平日 11/14(四) AI 號誌控制路口延滯績效

本期AI	路口	時間	鄰近路口方向	方向	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體	較事前改善程度(%)
11/14	台86/台19甲	平日晨峰 0700~0930	關廟交流道往台86	↙	799	896	37.3	C	53.1	-2.5%
			南雄路二段往關新路一段	↖	705	1213	50.6	D		
			台86往關廟交流道	↗	1566	1587	66.1	E		
			關新路一段往南雄路二段	↘	626	1465	61.1	C	D	
	台86/台19甲	平日離峰 1230~1430	關廟交流道往台86	↙	645	483	20.1	B	27.1	2.6%
			南雄路二段往關新路一段	↖	599	761	31.7	C		
			台86往關廟交流道	↗	796	702	29.3	B		
			關新路一段往南雄路二段	↘	455	775	32.3	C	B	
	台86/台19甲	平日昏峰 1630~2030	關廟交流道往台86	↙	1931	973	40.5	C	57.4	-1.1%
			南雄路二段往關新路一段	↖	1128	1625	67.7	E		
			台86往關廟交流道	↗	1507	1574	65.6	E		
			關新路一段往南雄路二段	↘	1192	1548	64.5	E	D	

表 3.3.5.1-2 平日 11/21(四) 動態 TOD 號誌控制路口延滯績效

TOD	路口	時間	鄰近路口方向	方向	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/21	台86/台19甲	平日晨峰 0700~0930	關廟交流道往台86	↙	754	822	34.3	C	34.6
			南雄路二段往關新路一段	↖	768	1316	54.9	D	
			台86往關廟交流道	↗	1608	1716	71.5	E	
			關新路一段往南雄路二段	↘	543	1446	60.3	C	C
	台86/台19甲	平日離峰 1230~1430	關廟交流道往台86	↙	672	464	19.3	B	26.7
			南雄路二段往關新路一段	↖	527	769	32.0	C	
			台86往關廟交流道	↗	772	674	28.1	B	
			關新路一段往南雄路二段	↘	430	762	31.8	C	B
	台86/台19甲	平日昏峰 1630~2030	關廟交流道往台86	↙	2014	983	40.9	C	24.5
			南雄路二段往關新路一段	↖	1148	1658	69.1	E	
			台86往關廟交流道	↗	1478	1563	65.1	E	
			關新路一段往南雄路二段	↘	1070	1615	67.3	E	B

(二) 11 月 15 日 AI 實測與 11 月 22 日動態 TOD 績效表現(如表 3.3.5.1-3 與 3.3.5.1-4 所示)

1. 晨峰：路口整體延滯減少 1.1 秒，改善 3.0%，服務水準維持 C 級。

2. 離峰：路口整體延滯增加 0.9 秒，改善劣化 2.3%，服務水準維持 C 級。

3. 昏峰：路口整體延滯減少 0.9 秒，改善 3.3%，服務水準維持 B 級。

表 3.3.5.1-3 平日 11/15(五) AI 號誌控制路口延滯績效

本期AI	路口	時間	鄰近路口方向	方向	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體	較事前改善程度(%)
11/15	台86/台19甲	平日晨峰 0700~0930	關廟交流道往台86	↙	746	915	38.1	C	57.4	-1.9%
			南雄路二段往關新路一段	↖	744	1059	44.1	C		
			台86往關廟交流道	↗	1490	1943	81.0	F		
			關新路一段往南雄路二段	↘	604	1492	62.2	E	D	
	台86/台19甲	平日離峰 1230~1430	關廟交流道往台86	↙	652	1662	69.3	E	43.3	-5.1%
			南雄路二段往關新路一段	↖	471	740	30.8	C		
			台86往關廟交流道	↗	894	693	28.9	B		
			關新路一段往南雄路二段	↘	481	786	32.8	C	C	
	台86/台19甲	平日昏峰 1630~2030	關廟交流道往台86	↙	2219	1158	48.2	D	72.7	-11.5%
			南雄路二段往關新路一段	↖	1138	1628	67.8	E		
			台86往關廟交流道	↗	1944	2203	91.8	F		
			關新路一段往南雄路二段	↘	1239	2124	88.5	F	E	

表 3.3.5.1-4 平日 11/22(五) 動態 TOD 號誌控制路口延滯績效

TOD	路口	時間	鄰近路口方向	方向	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/22	台86/台19甲	平日晨峰 0700~0930	關廟交流道往台86	↙	707	828	34.5	C	37.3
			南雄路二段往關新路一段	↖	734	1216	50.7	D	
			台86往關廟交流道	↗	1580	2041	85.1	F	
			關新路一段往南雄路二段	↘	552	1470	61.2	E	C
	台86/台19甲	平日離峰 1230~1430	關廟交流道往台86	↙	762	1748	72.8	E	36.4
			南雄路二段往關新路一段	↖	550	730	30.4	C	
			台86往關廟交流道	↗	927	693	28.9	B	
			關新路一段往南雄路二段	↘	480	957	39.9	C	C
	台86/台19甲	平日昏峰 1630~2030	關廟交流道往台86	↙	2256	1263	52.6	D	27.0
			南雄路二段往關新路一段	↖	1244	1739	72.4	E	
			台86往關廟交流道	↗	2161	2794	116.4	F	
			關新路一段往南雄路二段	↘	1254	1978	82.4	F	B

(三) 11 月 17 日 AI 實測與 11 月 24 日動態 TOD 昏峰績效表現，路口整體延滯減少 2.7 秒，改善 6.3%，服務水準維持 C 級(如表 3.3.5.1-5 與 3.3.5.1-6 所示)。

表 3.3.5.1-5 假日 11/17(日)AI 號誌控制路口延滯績效

本期AI	路口	時間	鄰近路口方向	方向	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體	較事前改善程度(%)
11/17	台86/台19甲	假日昏峰 1630~2000	關廟交流道往台86	↙	1215	1346	56.1	D	64.8	-13.5%
			南雄路二段往關新路一段	↖	716	1584	66.0	E		
			台86往關廟交流道	↗	1124	1704	71.0	E		
			關新路一段往南雄路二段	↘	709	1645	68.5	E	E	

表 3.3.5.1-6 假日 11/24(日)動態 TOD 號誌控制路口延滯績效

TOD	路口	時間	鄰近路口方向	方向	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/24	台86/台19甲	假日昏峰 1630~2000	關廟交流道往台86	↙	1304	1418	59.1	D	42.7
			南雄路二段往關新路一段	↖	766	1621	67.5	E	
			台86往關廟交流道	↗	1184	2313	96.4	F	
			關新路一段往南雄路二段	↘	707	1703	71.0	E	C

(四) 與前期 AI 號誌控制模型實測績效比較

本期 11 月 14 日(四)及 11 月 15 日(五)平日 AI 實測與前期 11 月 7 日(二)及 11 月 8 日(三)平日 AI 實測；本期 11 月 17 日(日)假日 AI 實測與前期 11 月 4 日(六)及 11 月 5 日(日)假日 AI 實測績效表現說明如下(如表 3.3.5.1-7 與表 3.3.5.1-8 所示)。

1. 平日晨峰：路口整體延滯減少 3.0 秒，通過車輛數減少 10.8%，總旅行時間延滯減少 5.4%，平均延滯減少 23.4%。

2. 平日離峰：路口整體延滯增加 13.2 秒，通過車輛數減少 2.7%，總旅行時間延滯增加 99.5%，平均延滯減少 36.7%。

3. 平日昏峰：路口整體延滯減少 16.9 秒，通過車輛數增加 38.8%，總旅行時間延滯減少 4.4%，平均延滯減少 4.4%。

4. 假日昏峰：路口整體延滯減少 12.2 秒，通過車輛數增加 23.7%，總旅行時間延滯增加 1.9%，平均延滯減少 18.9%。

表 3.3.5.1-7 與前期 AI 號誌控制模型實測平日績效比較

本期AI	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/14	799	896	37.3	C	33.5
	705	1213	50.6	D	
	1566	1587	66.1	E	
	626	1465	61.1	E	C
	645	483	20.1	B	26.2
	599	761	31.7	C	
	796	702	29.3	B	
	455	775	32.3	C	B
	1931	973	40.5	C	23.8
	1128	1625	67.7	E	
	1507	1574	65.6	E	
	1192	1548	64.5	E	B

前期AI	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/7	863	603	35.4	C	28.3
	787	1023	60.2	E	
	1362	1090	64.1	E	
	806	1793	105.5	F	B
	627	252	36.0	C	19.8
	501	544	77.7	E	
	651	396	56.6	D	
	559	739	105.5	F	B
	1362	932	38.8	C	40.8
	948	1745	72.7	E	
	961	1676	69.8	E	
	1022	2936	122.3	F	C

本期AI	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/15	746	915	38.1	C	36.2
	744	1059	44.1	C	
	1490	1943	81.0	F	
	604	1492	62.2	E	C
	652	1662	69.3	E	37.3
	471	740	30.8	C	
	894	693	28.9	B	
	481	786	32.8	C	C
	2219	1158	48.2	D	26.1
	1138	1628	67.8	E	
	1944	2203	91.8	F	
	1239	2124	88.5	F	B

前期AI	通過車輛數(輛/小時)	總旅行時間延滯(秒)	平均延滯(秒)	服務水準	路口整體
11/8	827	1311	54.6	D	47.4
	831	1853	77.2	E	
	1541	2467	102.8	F	
	976	2621	109.2	F	D
	770	288	36.0	C	17.4
	576	478	59.8	D	
	805	462	57.8	D	
	636	788	98.5	F	B
	1441	883	36.8	C	39.0
	952	1678	69.9	E	
	991	1797	74.9	E	
	1161	3023	126.0	F	C

表 3.3.5.1-8 與前期 AI 號誌控制模型實測假日績效比較

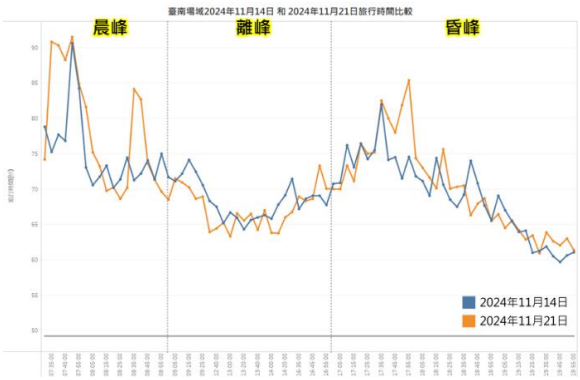
本期AI	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/17	1215	1346	56.1	D	40.0
	716	1584	66.0	E	
	1124	1704	71.0	E	
	709	1645	68.5	E	C

前期AI	通過車輛數(輛/小時)	總旅行時間延滯(小時/秒)	平均延滯(秒)	服務水準	路口整體
11/4 & 11/5	767	909	48	D	52.2
	642	1521	81	F	
	875	2241	112	F	
	736	2073	109	F	C

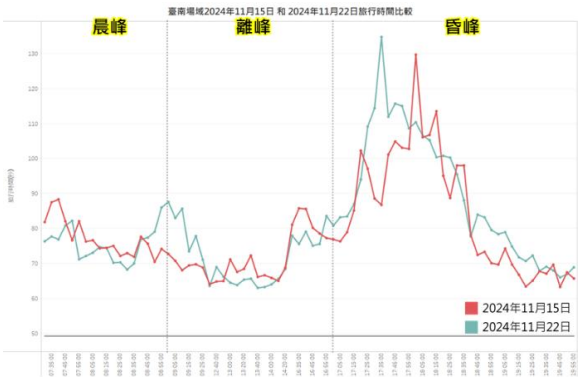
三、旅行時間績效

傳統之旅行速率調查係採用浮動車法，調查車輛於車隊中保持車隊之均速行駛。然在號誌化幹道中車輛不同的出發時間點其可續進的路口數不同，即使依交通工程手冊至少蒐集 6 趟資料，亦可能無法真正反應整體車流績效。因此本計畫透過蒐集 GVP 資料瞭解事前事後路段平均旅行時間，預計事前及事後將各至少蒐集 1 週之資料。由於短時間內車流隨號誌而有週期性變化，為能全面掌握路況 GVP 資料蒐集之頻率將避開號誌週期，如：號誌週期為 150 秒則不能每 150 秒或每 300 秒蒐集一次資料。

平日 11 月 14 日(四)AI 號誌控制晨峰及昏峰表現都略優於 11 月 21 日，隔一天 11 月 15 日(五)AI 號誌控制晨峰及離峰旅行時間呈緩降情形，15 日與 22 日皆有出現一次峰期又 15 日峰期較 22 日晚，且旅行時間表現較 22 日略好；假日 AI 號誌控制旅行時間表現整體皆較 TOD 表現為佳。由於現行臺南市場域實行動態 TOD 號誌控制策略，顯示平日動態 TOD 與 AI 號誌控制之旅行時間趨勢差不多，而假日 AI 號誌控制則明顯優於動態 TOD 控制，推測因動態號誌控制為固定週期或為達門檻啟動控制，其流量又不如平日集中，因此動態號誌控制效果較不如 AI 號誌控制。圖 3.3.5.1-7 與圖 3.3.5.1-8 分別為平日與假日的 AI 號誌控制與 TOD 旅行時間績效比較。



平日 11/14 AI 實測&11/21 動態 TOD



平日 11/15 AI 實測&11/22 動態 TOD

圖 3.3.5.1-7 平日 AI 號誌控制與 TOD 旅行時間績效圖

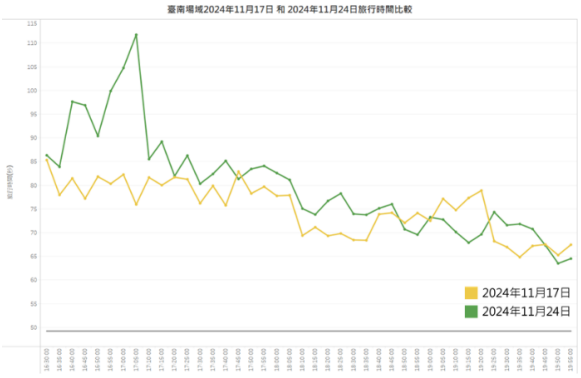
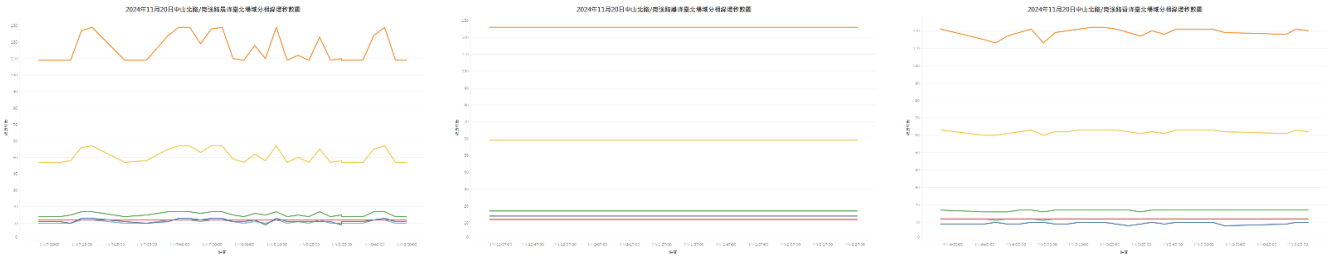


圖 3.3.5.1-8 假日 AI 號誌控制與 TOD 旅行時間績效圖

3.3.5.2 臺北市實驗場域實測結果

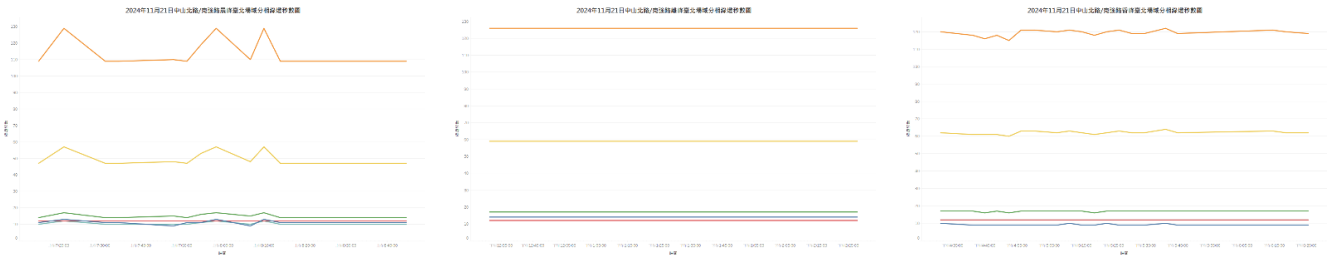
一、實測路口分相秒數變化

臺北市實驗場域為當周期該分相停等車輛數決策後續分相綠燈秒數，本期主要控制路口為中山北路/德行西路，協控中山北路/195 巷及中山北路/克強路，此三處路口各分相綠燈秒數趨勢如圖 3.3.5.2-1 至圖 3.3.5.2-7 所示，圖 3.3.5.2-8 至圖 3.3.5.2-10 為臺北市場域各時段的 AI 實測與 TOD 各分相綠燈秒數比較。



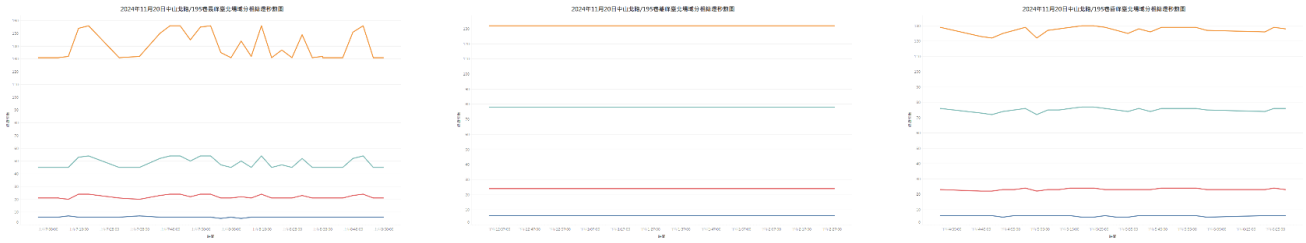
晨峰　　離峰　　昏峰

圖 3.3.5.2-1 11/20(三)中山北路/克強路實測各分相綠燈秒數趨勢圖



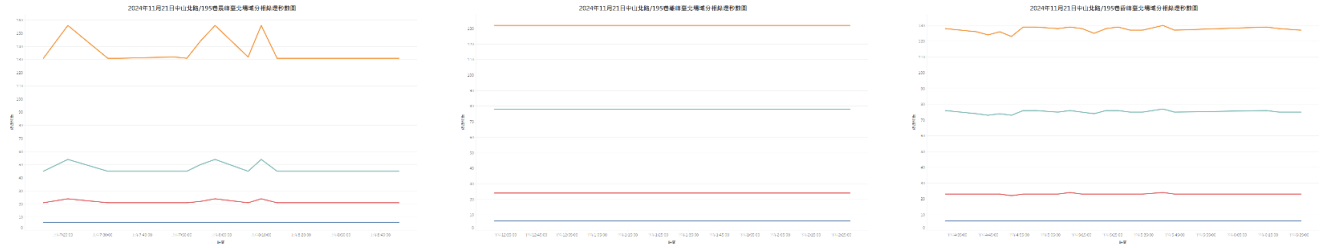
晨峰　　離峰　　昏峰

圖 3.3.5.2-2 11/21(四)中山北路/克強路實測各分相綠燈秒數趨勢圖



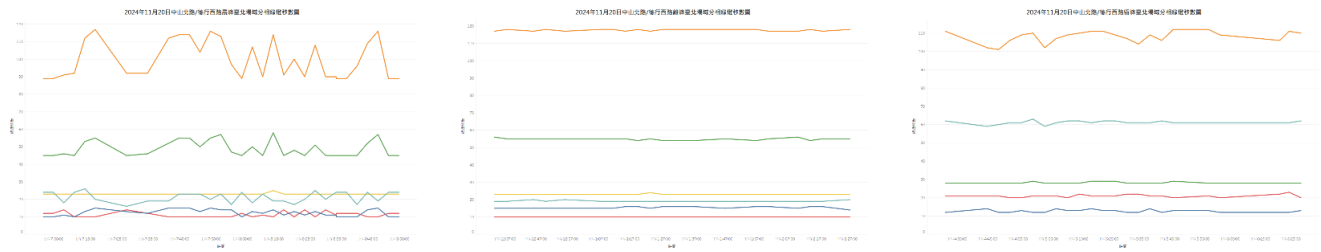
晨峰　　離峰　　昏峰

圖 3.3.5.2-3 11/20(三)中山北路/195 巷實測各分相綠燈秒數趨勢圖



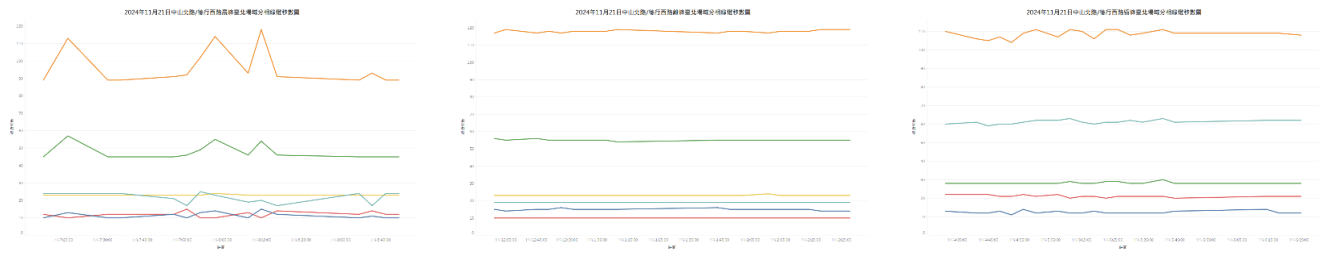
晨峰　　離峰　　昏峰

圖 3.3.5.2-4 11/21(四)中山北路/195 巷實測各分相綠燈秒數趨勢圖



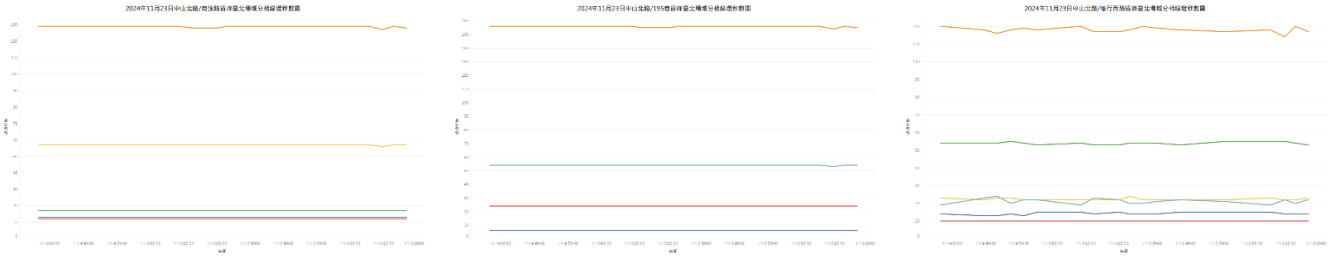
晨峰　　離峰　　昏峰

圖 3.3.5.2-5 11/20(三)中山北路/德行西路實測各分相綠燈秒數趨勢圖



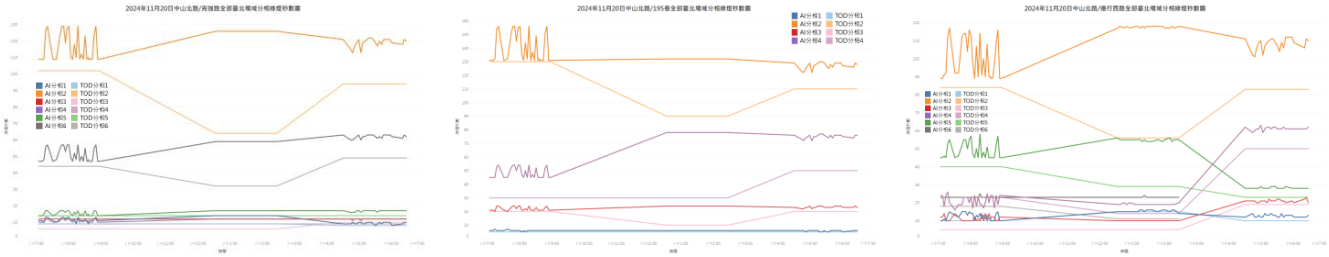
晨峰　　離峰　　昏峰

圖 3.3.5.2-6 11/21(四)中山北路/德行西路實測各分相綠燈秒數趨勢圖



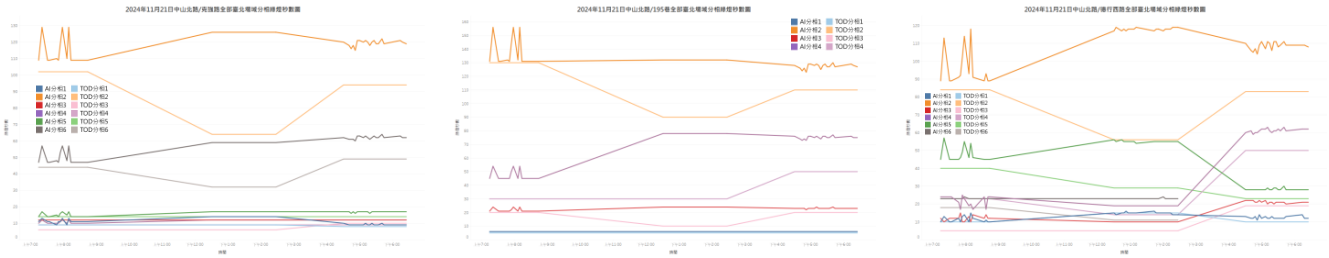
中山北路/克強路　　中山北路/195 巷　　中山北路/德行西路

圖 3.3.5.2-7 11/23(六)假日 3 處路口實測各分相綠燈秒數趨勢圖



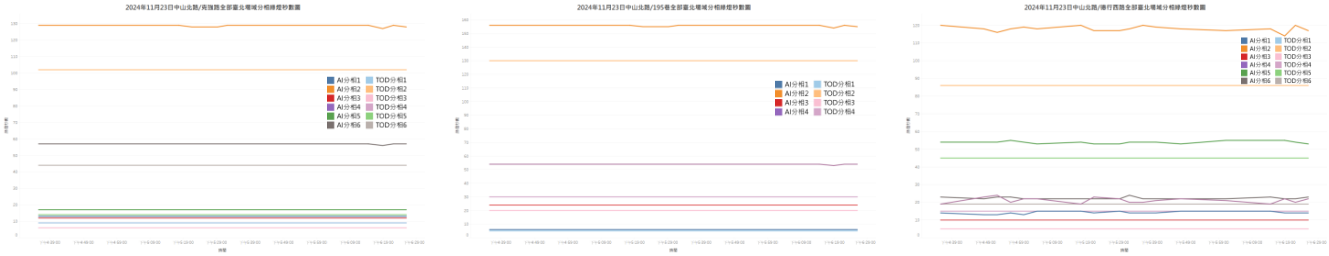
中山北路/克強路　　中山北路/195 巷　　中山北路/德行西路

圖 3.3.5.2-8 11/20(三)臺北市場域 AI 實測與 TOD 各分相綠燈秒數比較



中山北路/克強路　　中山北路/195 巷　　中山北路/德行西路

圖 3.3.5.2-9 11/21(四)臺北市場域 AI 實測與 TOD 各分相綠燈秒數比較



中山北路/克強路　　中山北路/195 巷　　中山北路/德行西路

圖 3.3.5.2-10 11/23(六)昏峰臺北市場域 AI 實測與 TOD 各分相綠燈秒數比較

二、路口平均延滯績效

傳統停等延滯調查係人員站在停止線附近，每 15 秒計數停等車輛數，本場域融合現代科技，採架設之路口偵測各車道停等車輛數之雷達設備資料，依路口方向分類，整理時間序列，加總同一方向全部車道之停等車輛，每 15 秒計數一次停等車輛數，偵測距離可達 100 公尺，惟可能受限於道路兩側行道樹遮蔽或現場網路不穩或斷線問題，造成事後資料蒐集分析績效

誤差。此法改善傳統人工判讀問題及人力耗費，實測路口延滯績效表現說明如下(如 3.3.5.2-1 所示)。

(一) 平日 11 月 20 日(三)及 11 月 21(四)上、下午尖峰 AI 號誌控制服務水準皆略低於 11 月 27 日(三)及 11 月 28 日(四)TOD，僅離峰路口平均延滯改善減少約 11 秒，因係受號誌控制器通訊異常，導致降階影響。

(二) 假日昏峰 11 月 23 日(六)AI 號誌控制路口平均延滯較 11 月 16 日(六)TOD 佳，服務水準從 C 及升至 B 級，且路口平均延滯改善減少約 4.9 秒。

表 3.3.5.2-1 平日及假日 AI 與 TOD 號誌控制路口延滯績效表

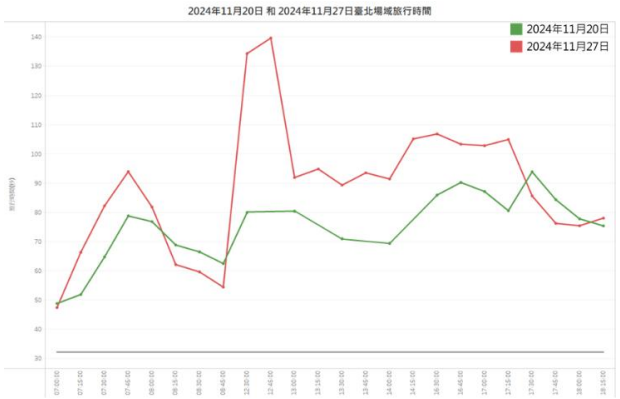
路口	時段	AI實測 2024/11/20(三)					TOD 2024/11/27(三)			
		總延滯	通過量	路口平均延滯	LOS	較事前改善程度(%)	總延滯	通過量	路口平均延滯	LOS
中山北路/德行西路	上午尖峰	16728	5354	46.9	D	25.7%	14032	5644	37.3	C
	下午離峰	11684	5614	31.2	C	-26.1%	16136	5730	42.2	C
	下午尖峰	19808	5932	50.1	D	16.2%	15772	5490	43.1	C

路口	時段	AI實測 2024/11/21(四)					TOD 2024/11/28(四)			
		總延滯	通過量	路口平均延滯	LOS	較事前改善程度(%)	總延滯	通過量	路口平均延滯	LOS
中山北路/德行西路	上午尖峰	19304	5734	50.5	D	23.4%	15020	5505	40.9	C
	下午離峰	10246	5093	30.2	C	-11.2%	12068	5325	34.0	C
	下午尖峰	24284	6136	59.4	D	1.2%	22196	5677	58.6	D

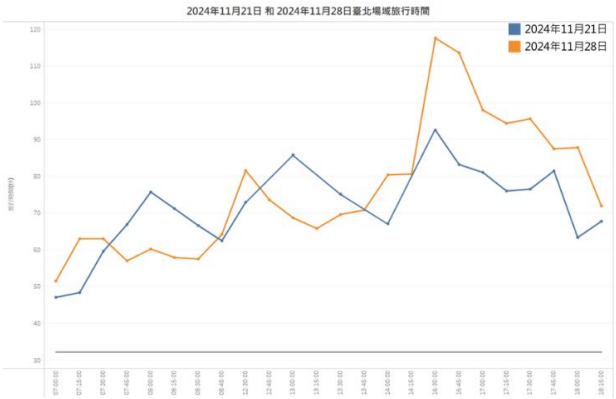
路口	時段	AI實測 2024/11/23(六)					TOD 2024/11/16(六)			
		總延滯	通過量	路口平均延滯	LOS	較事前改善程度(%)	總延滯	通過量	路口平均延滯	LOS
中山北路/德行西路	下午尖峰	11032	5844	28.3	B	-14.7%	12684	5729	33.2	C

三、旅行時間及平日續進績效

本計畫透過蒐集 GVP 資料瞭解事前事後路段平均旅行時間，平日因系統、設備多次斷線導致旅行時間較 TOD 高，惟假日昏峰表現明顯優於 TOD 表現。圖 3.3.5.2-11 與圖 3.3.5.2-12 分別為平日與假日的 AI 號誌控制與 TOD 旅行時間績效比較



平日 11/20 AI 實測&11/27 動態 TOD



平日 11/21 AI 實測&11/28 動態 TOD

圖 3.3.5.2-11 平日 AI 號誌控制與 TOD 旅行時間績效比較圖

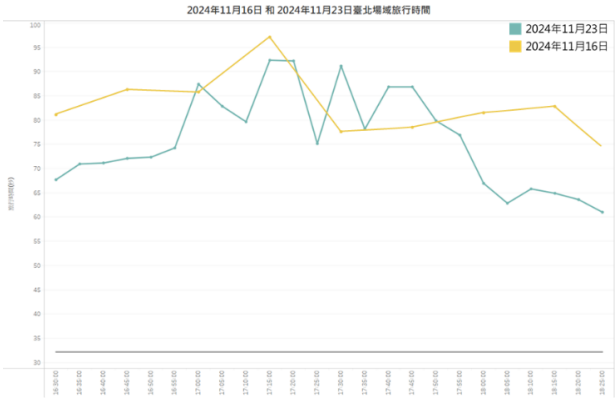
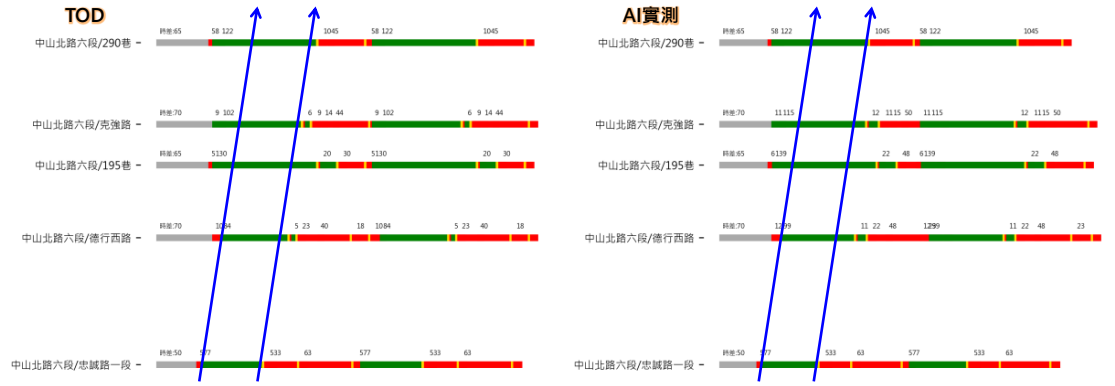
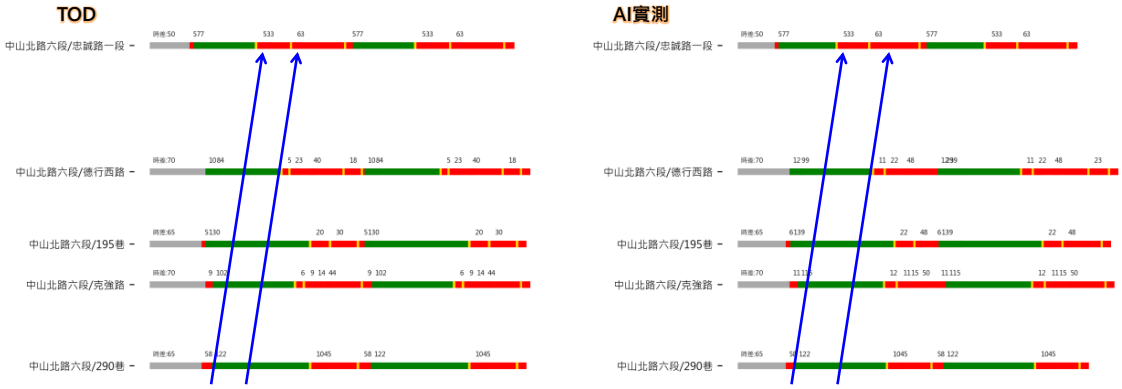


圖 3.3.5.2-12 假日 AI 號誌控制與 TOD 旅行時間績效比較圖

由於實測階段 AI 每次產出秒數不盡相同，以下以實測時段平日晨峰、離峰、昏峰之 AI 產出平均秒數繪製幹道續進績效圖，如圖 3.3.5.2-13 至圖 3.3.5.2-15 所示。透過 TOD 與 AI 實測續進績效圖比較顯示平日晨峰往北 TOD 續進效果與 AI 實測差不多，往南則 AI 實測續進帶寬優於 TOD，於現實層面紓解效率亦應較 TOD 佳；平日離峰往南 TOD 續進效果與 AI 實測差不多，忠誠路一段往北 TOD 續進至 290 巷會遭遇停等，需待 290 巷綠燈時將上一週期累積的車流先行紓解，因此容易出現無效綠燈情形，而 AI 實測續進至 290 巷時，290 巷已先行開啟北向綠燈，待車輛忠誠路末端車流抵達時有機率紓解；平日昏峰往北 TOD 續進效果與 AI 實測差不多，往南則 AI 實測續進帶寬優於 TOD，於現實層面紓解效率亦應較 TOD 佳。

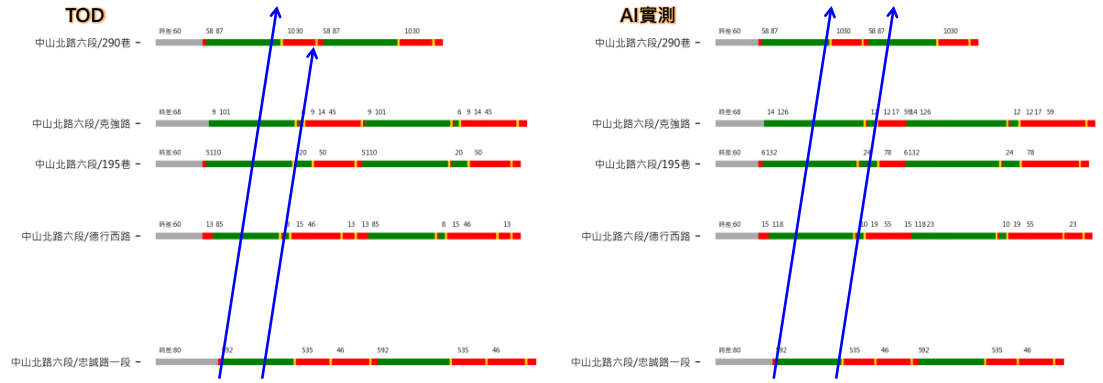


平日晨峰 TOD 及 AI 實測往北續進績效圖

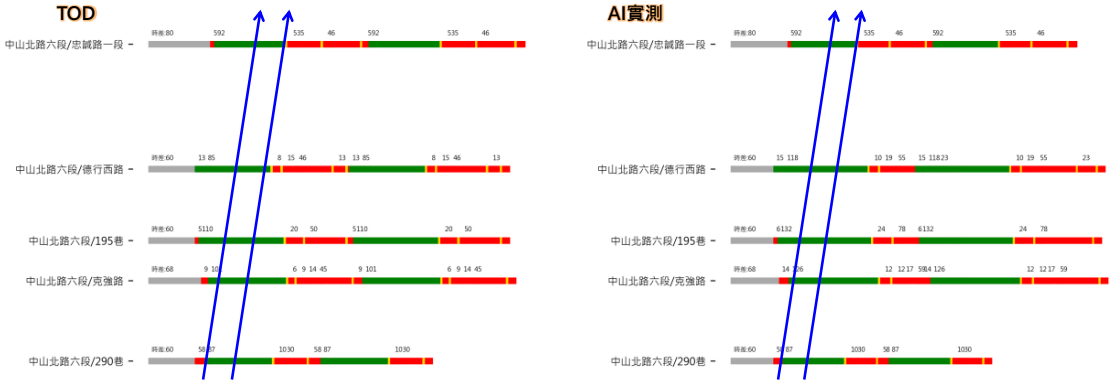


平日晨峰 TOD 及 AI 實測往南續進績效圖

圖 3.3.5.2-13 平日晨峰 AI 號誌控制與 TOD 續進績效比較示意圖

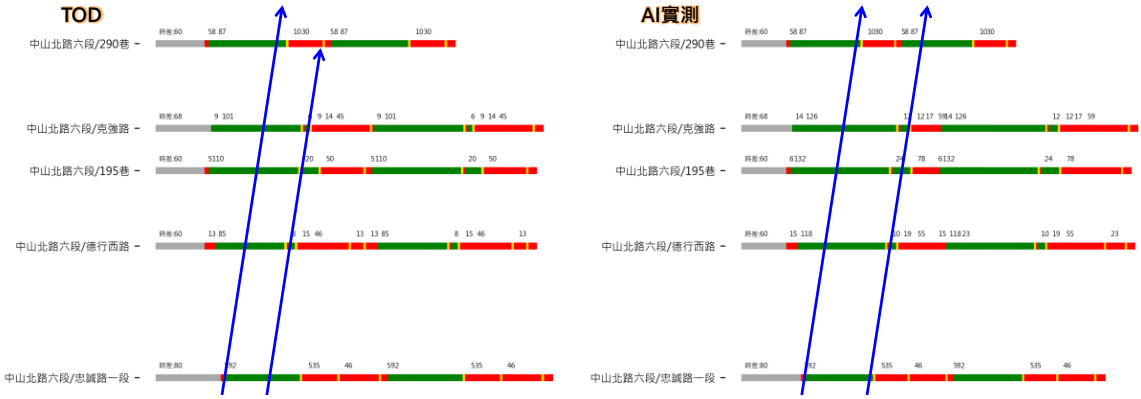


平日離峰 TOD 及 AI 實測往北續進績效圖

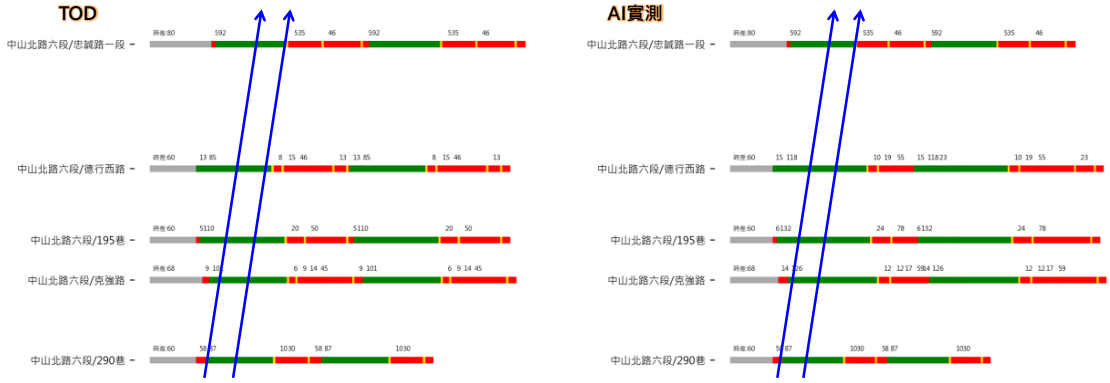


平日離峰 TOD 及 AI 實測往南續進績效圖

圖 3.3.5.2-14 平日離峰 AI 號誌控制與 TOD 續進績效比較示意圖



平日昏峰 TOD 及 AI 實測往北續進績效圖



平日昏峰 TOD 及 AI 實測往南續進績效圖

圖 3.3.5.2-15 平日昏峰 AI 號誌控制與 TOD 續進績效比較示意圖

四、與前期 AI 號誌控制模型實測績效比較

本期 11 月 20 日(三)及 11 月 21 日(三)平日 AI 實測與前期 11 月 16 日(四)及 11 月 20 日(一)平日 AI 實測；本期 11 月 23 日(六)假日 AI 實測與前期 11 月 18 日(六)及 11 月 19 日(日)假日 AI 實測績效表現說明如下(如表 3.3.5.2-2 所示)。

(一) 平日晨峰：路口整體延滯增加 17.8 秒，通過車輛數增加 2.6%。

(二) 平日離峰：路口整體延滯減少 12.4 秒，通過車輛數增加 8.4%。

(三) 平日昏峰：路口整體延滯增加 8.9 秒，通過車輛數增加 35.7%。

(四) 假日昏峰：路口整體延滯減少 26.3 秒，通過車輛數增加 36.6%。

表 3.3.5.2-2 與前期 AI 號誌控制模型實測平日績效比較

路口	時段	本期平日AI實測				前期平日AI實測			
		總延滯	通過量	路口平均延滯	LOS	總延滯	通過量	路口平均延滯	LOS
中山北路/德行西路	上午尖峰	18016	5544	48.7	D	11118	5405	30.9	C
	下午離峰	10965	5354	30.7	C	14188	4939.5	43.1	C
	下午尖峰	22046	6034	54.7	D	13498	4448	45.8	D

路口	時段	本期假日AI實測				前期假日AI實測			
		總延滯	通過量	路口平均延滯	LOS	總延滯	通過量	路口平均延滯	LOS
中山北路/德行西路	下午尖峰	11032	5844	28.3	B	15591	4279	54.6	D

五、網路不穩偵測設備與號誌控制器斷線紀錄

於 11/20(三)離峰斷線 8 次，昏峰斷線 2 次；11/21(四)：晨峰 7 次，離峰 8 次，昏峰 6 次，以及 11/23(六)昏峰 5 次。觀察結果顯示，異常情況於晨峰尤為明顯，其與網路通訊壅塞或偵測設備與號誌控制器間的數據延遲有關，而非 AI 號誌控制模型本身的問題。為應對此問題，我們於異常期間啟動降階運作模式，改為 TOD 控制，以維持系統穩定性。

3.3.6 小結

本期都會區臺南市場域實施 AI 號誌控制後之事後平、假日績效表現整體優於事前，尤以假日績效改善最為明顯。顯見現行臺南市場域實施動態 TOD 控制以具提升該路口運轉效率，但本計畫測試之 AI 號誌控制為藉由上個週期收集到的場域路口資訊，產出下一週期分相時比，其控制效果能更貼合時時的車流變化。

本期都會區臺北市場域延續前期 AI 號誌控制模型訓練，其各分相綠燈秒數變化趨勢變化較前期不明顯，可能原因為 1.車流抵達路口、分佈於車道之狀況較分散均勻，2.現場偵測設備不足，導致判斷環境依據較不足，3.模型訓練漸趨收斂穩定。且由於臺北市場域通訊較不穩定，斷線次數較高，時常降階運轉，導致實測事後績效較差。

第四章　強化學習號誌協控模型設計、訓練與實測成果

為利發展我國於人工智慧強化學習號誌控制模擬環境，本計畫持續強化人工智慧應用於號誌控制的課題，除與縣市政府合作，進行現地場域的號誌控制實驗測試，亦尋找適合的高速公路匝道，進行人工智慧號誌控制模型應用在跨機關的號誌協控應用以及相關模擬模式發展探討，以期逐步精進我國在號誌控制之經驗及實力。

4.1 號誌協控實驗場域特性分析與模擬環境建置

4.1.1 實驗場域特性分析

根據發展人工智慧號誌控制模式需求，自六都與高速公路介接的交流道中遴選一處上匝道與平面道路作為區域號誌協控實驗場域，藉由以交通運輸模型為基礎之智慧號誌控制系統，改善交流道周邊區域的交通。實驗場域之選擇須考量模擬模式與模型構建所需資料，以及後續實測現場資通訊軟硬體可配合因素。本計畫係從都會區角度進行探討，因此考量平常日與高速公路獨立式匝道儀控，暫未納入連續假期期間的號誌協控課題。本計畫依據前期計畫之場域選擇標準評估，調整實驗場域至桃園市中壢交流道，選擇標準與說明如下：

一、路側設備因素

經查前期計畫所遴選楊梅交流道周邊關鍵路側設備因故遷移，為能於後期動態模擬測試以及實測時能有效接收路側設備交通資料以達即時運算之目的，因此根據前期(112 年)選址標準，更改至更符合實測需求之中壢交流道為實驗場域。

二、實驗場域交通特性

桃園市民族路二段連接中壢、平鎮市區及中壢交流道，不只上下班尖峰時段車流量大，平日進出匝道車流交通量也非常大，又因為該處交流道除進入國道 1 號，亦為進出五楊高架中壢轉接道之路徑，尖峰時段平面道路路口車流量較鄰近之楊梅交流道高出約 15%，車流經常性回堵到民族路二段及周邊地方路網，造成區域性壅塞。經觀察，該處亦無地方替代道路或其他明顯旅次吸引處，故都會區壅塞可視與高速公路主線情況關聯性高，有利於評估該處對於高速公路匝道儀控以及周邊平面道路號誌控制之實驗測試效益評估。

三、實驗場域車輛偵測範圍

中壢交流道實驗場域除平面道路號誌化路口 1 至路口 8 車流資料蒐集外，亦納入高速公路資料(車輛偵測器與匝道儀控)的蒐集，範圍如圖 4.1-1 所示。表 4.1-1 為中壢交流道實驗場域的平面道路路口。

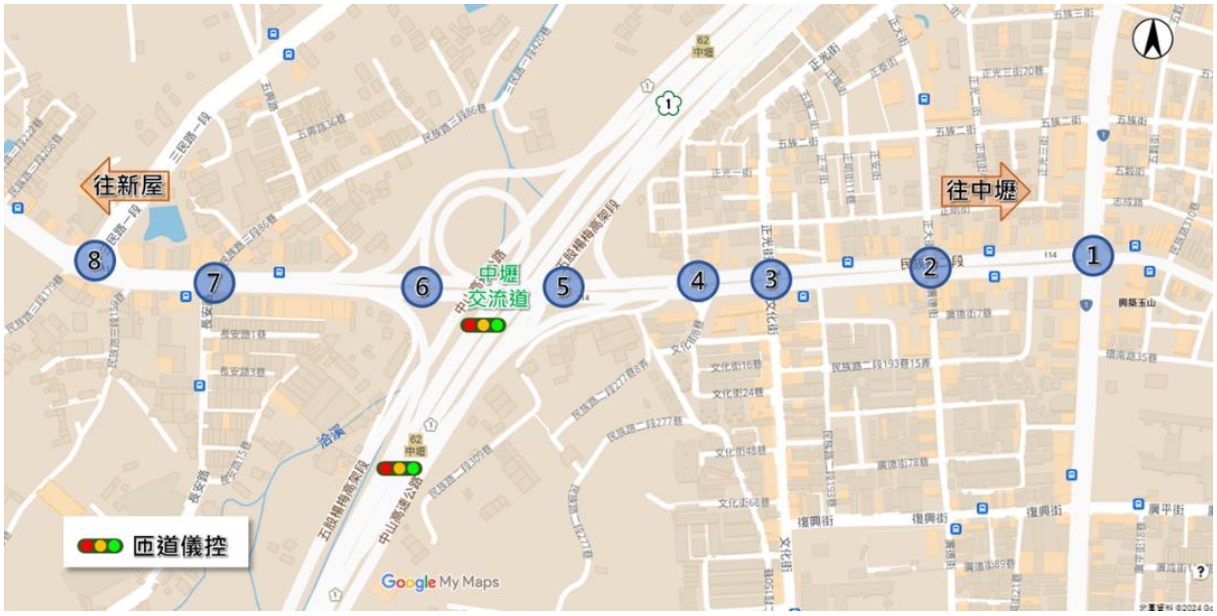


圖 4.1-1 高速公路匝道與平面道路中壢交流道實驗場域示意圖

表 4.1-1 中壢交流道實驗場域的平面道路路口列表

	路口名稱
路口 1	民族路/民族路二段/環南路/環西路
路口 2	民族路二段/廣德街/正大街
路口 3	民族路/文化街/正光街
路口 4	民族路二段/民族路二段 232 巷/文化街 8 巷
路口 5	民族路二段/北上匝道出口
路口 6	民族路三段/南下匝道出口
路口 7	民族路三段/長安路/民族路三段 86 巷
路口 8	民族路三段/三民路一段/民族路三段 179 巷

四、平面道路號誌時制計畫

中壢交流道場域平面道路號誌化路口 1 至路口 8 的時相組態與時制計畫內容，如表 4.1-2 所示。

表 4.1-2 中壢交流道實驗場域 8 處平面道路路口號誌時制計畫

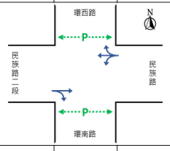
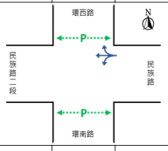
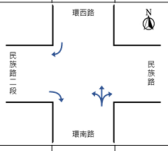
時段	時制	週期	時差	時相1			時相2			時相3			時相4			時相5		
				G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
民族路/環西路																		
平日晨峰	33	180	0	33	4	3	35	3	2	10	4	3	35	3	2	36	4	3
平日離峰	34	150	0	28	4	3	30	3	2	5	3	2	25	3	2	33	4	3
平日昏峰	35	180	0	43	4	3	30	3	2	10	3	2	30	3	2	38	4	3
假日昏峰	39	180	0	38	4	3	35	3	2	10	3	2	30	3	2	38	4	3

表 4.1-2 中壢交流道實驗場域 8 處平面道路路口號誌時制計畫(續 1)

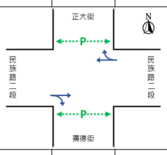
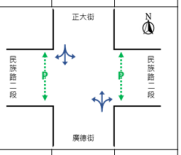
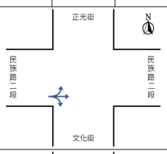
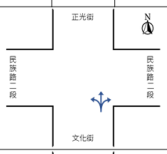
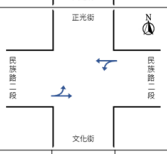
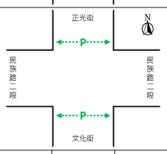
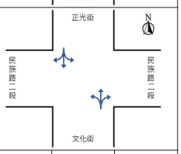
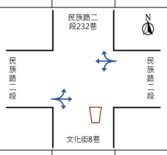
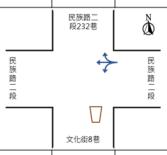
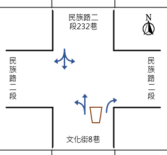
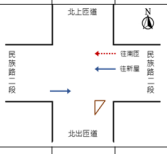
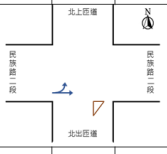
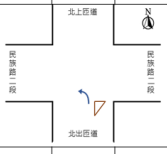
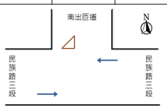
時段	時制	週期	時差	時相1			時相2			時相3			時相4			時相5		
				G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
民族路/正大街																		
平日晨峰	02	180	0	20	3	2	80	3	2	20	3	2	1	2	2	**35**	**3**	**2**
平日離峰	01	150	0	15	3	2	70	3	2	10	3	2	1	2	2	30	3	2
平日昏峰	03	180	0	20	3	2	85	3	2	15	3	2	1	2	2	35	3	2
假日昏峰	03	180	0	20	3	2	85	3	2	15	3	2	1	2	2	35	3	2
民族路/正光街			其他時段															
			平日離峰															
平日晨峰	02	180	0	15	3	2	76	3	2	13	3	3	15	3	2	35	3	2
平日離峰	05	150	0	15	3	2	64	3	2	10	3	3	5	0	0	35	3	2
平日昏峰	03	180	0	15	3	2	82	3	2	13	3	3	10	2	2	35	3	2
假日昏峰	03	180	0	15	3	2	82	3	2	13	3	3	10	2	2	35	3	2
民族路/文化路8巷																		
平日晨峰	02	180	0	98	4	3	18	4	3	43	4	3						
平日離峰	04	150	0	90	4	3	14	4	3	25	4	3						
平日昏峰	05	180	0	105	4	3	24	4	3	30	4	3						
假日昏峰	02	180	0	98	4	3	18	4	3	43	4	3						
民族路/北上匝道																		
平日晨峰	22	180	0	84	4	3	38	4	3	10	0	0	28	4	2			
平日離峰	24	150	0	64	4	3	33	4	3	10	0	0	23	4	2			
平日昏峰	25	180	0	78	4	3	43	4	3	10	0	0	28	4	2			
假日昏峰	22	180	0	84	4	3	38	4	3	10	0	0	28	4	2			
民族路/南出匝道																		
平日晨峰	02	180	0	106	4	3	60	4	3									
平日離峰	01	150	0	86	4	3	50	4	3									
平日昏峰	05	180	0	96	4	3	70	4	3									
假日昏峰	05	180	0	96	4	3	70	4	3									

表 4.1-2 中壢交流道場域平面道路路口號誌時制計畫(續 2)

時段	時制	週期	時差	時相1			時相2			時相3			時相4		
				G	Y	AR	G	Y	AR	G	Y	AR	G	Y	AR
民族路/長安路															
平日晨峰	22	180	0	80	4	3	25	4	3	5	0	0	45	4	3
平日離峰	21	150	0	60	4	3	25	4	3	5	0	0	35	4	3
平日昏峰	23	180	0	80	4	3	25	4	3	5	0	0	45	4	3
假日昏峰	23	180	0	80	4	3	25	4	3	5	0	0	45	4	3
民族路/三民路															
平日晨峰	22	180	0	103	4	3	18	4	3	38	4	3			
平日離峰	21	150	0	78	4	3	18	4	3	33	4	3			
平日昏峰	23	180	0	103	4	3	18	4	3	38	4	3			
假日昏峰	23	180	0	103	4	3	18	4	3	38	4	3			

4.1.2 實驗場域模擬環境建置

本計畫分別使用專業交通運輸模擬軟體 VISSIM 與開源交通運輸模擬軟體 SUMO，構建實驗場域的模擬模式。並以交通調查資料進行模擬環境參數校估，使模擬器的行為儘量符合實際車流的運作狀況，以供強化學習號誌控制代理人作為探索與學習最佳控制策略的環境。

4.1.2.1 交通參數與績效指標設計

進行實驗場域模擬模式所需各式交通參數與績效指標設計時，應考量強化學習號誌控制模型常見之「狀態(State)」與「獎勵(Reward)」參數，並在模型訓練後，推至現場實測後，所需要評估實測效果之「績效(performance)」，針對上面幾個重要元素，需評估何種參數為必要蒐集。以下分別說明暫定之設計交通參數與績效指標，目前依照此設計號誌控制模擬模型，如有需要後續將依人工智慧模型訓練結果作模擬模型調整。

一、交通參數

(一)流量：道路或區域中的交通量，通常以小客車當量數(PCU)表示，亦可體現車道通行能力。

(二)速度：交通流中的車輛行駛速度，通常以平均速度或速度分佈表示道路通行狀態。

(三)排隊長度：在路口判斷某方向的車道停等狀況，此數值可與時間一同作為後續與延滯相關的績效計算之基礎。

二、績效指標

(一)通過量：評估交通流的流動量，主要評估的參數。

(二)旅行時間：評估交通流在某路段的通行效率，此指標與速率有相關性。

(三)延滯：因交通擁堵而停滯，用於評估交通流的流動性，此指標與排隊長度相關性。

(四)排隊長度：排隊的車輛數，用於評估交通擁塞及疏導狀況，此指標與延滯時間有相關性。

4.1.2.2 交通參數資料蒐集規劃

針對實驗場域的現況道路特性及時制計畫外，所需進行交通資料蒐集項目說明如下。

一、路口轉向交通量

分車種(大型車、小型車、機踏車)、流向(左轉、直進、右轉)統計調查路口所有通過停止線之車輛數，並以每 5 分鐘紀錄 1 次，通常調查平假日中具代表性之時段，如平日上午下午尖峰、假日下午尖峰等。而高速公路的部分，由於路側調查難度較高，故運用高速公路局的 VD 偵測器資料，頻率為五分鐘一次的開放資料作為交通參數參考依據；亦蒐集 eTag 門架通過量(M03A)做為模擬校估所需資訊，以及驗證 VD 資料之參考數值。圖 4.1.2.2-1 為路口轉向交通量調查示意，圖 4.1.2.2-2 至圖 4.1.2.2-4 分別為中壢交流道實驗場域 VD 設備點位、eTag 設備點位、平面道路車流偵測設備點位，表 4.1.2.2-1 與表 4.1.2.2-2 為中壢交流道車流偵測設備以及周邊平面道路 AI 辨識 CCTV 偵測設備清單。

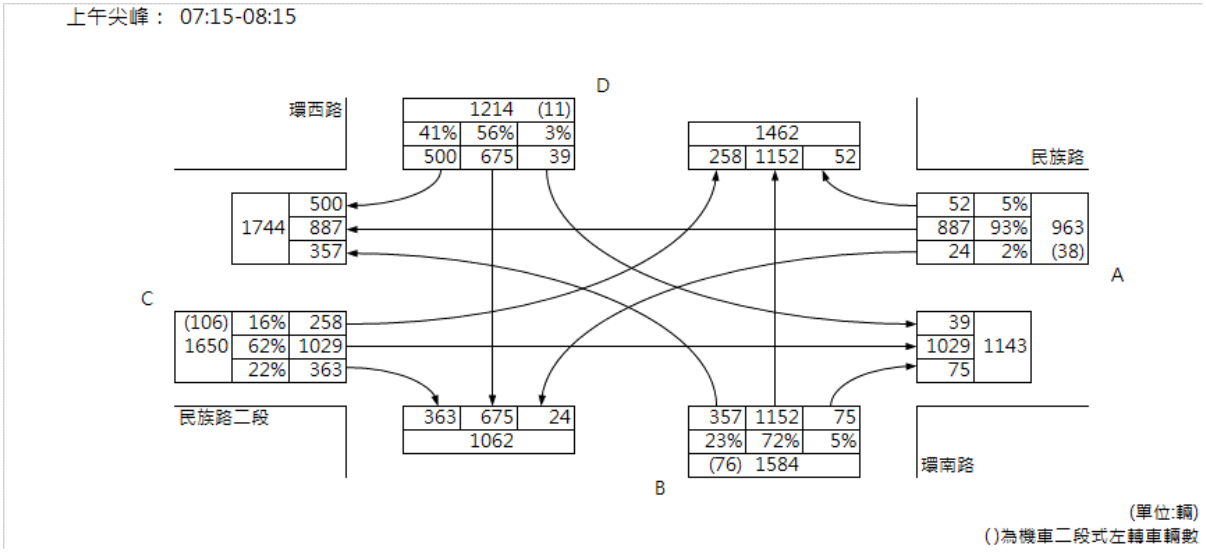


圖 4.1.2.2-1 路口轉向交通量調查示意圖



圖 4.1.2.2-2 中壢交流道實驗場域 VD 設備點位圖

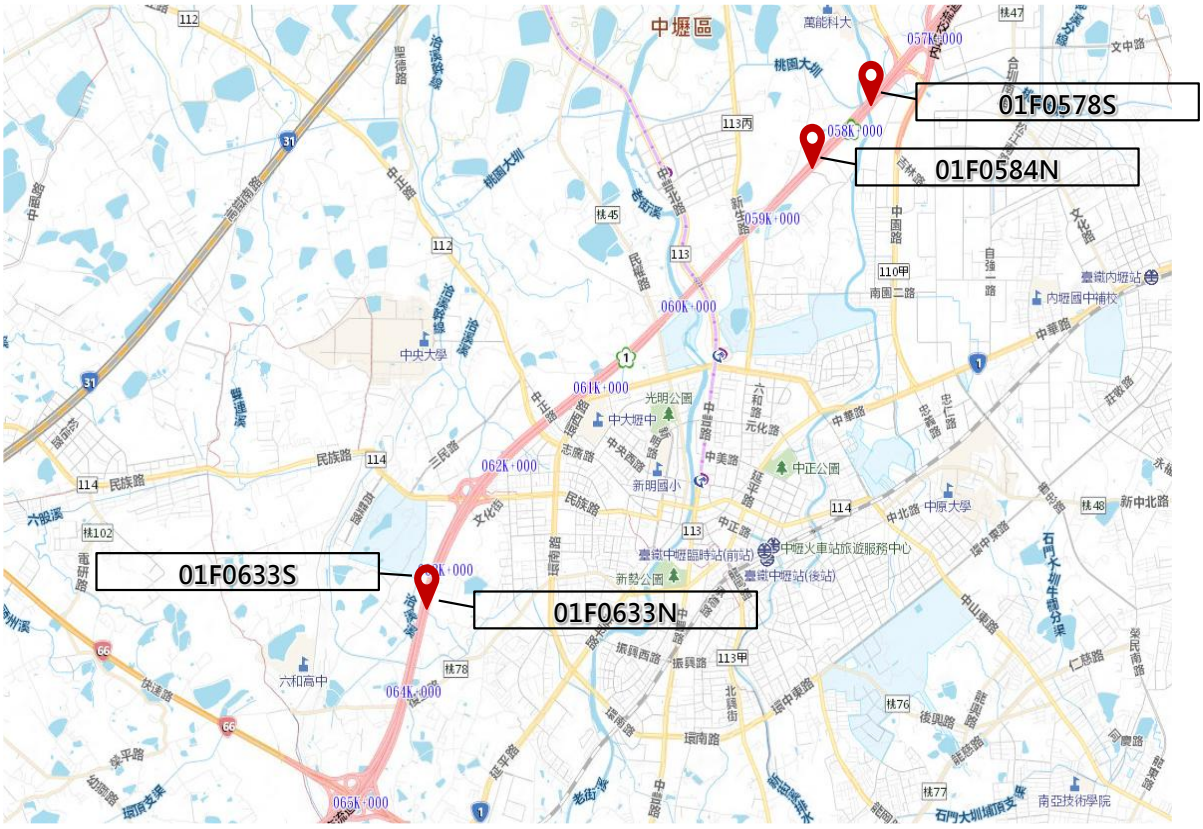


圖 4.1.2.2-3 中壢交流道實驗場域 eTag 設備點位圖

表 4.1.2.2-1 中壢交流道車流偵測設備

設備類別	設備資訊		
eTag	01F0578S, 01F0633S	01F0578S-01F0633S	5.31km
	01F0584N, 01F0633N	01F0633N-01F0584N	4.74km
VD	主線	VD-N1-N-61.580-M-LOOP	
	主線	VD-N1-S-62.200-N-LOOP	
	主線	VD-N1-N-62.360-N-LOOP	
	主線	VD-N1-N-62.900-M-LOOP	
	主線	VD-N1-N-62.900-M-LOOP	
	匝道	VD-N1-S-62-O-NW-1-中壢	
	匝道	VD-N1-S-62-I-ES-1A-中壢-環道	
	匝道	VD-N1-S-62-O-NW-21-中壢	
	匝道	VD-N1-S-62-I-WS-1B-中壢-匝道	
	匝道	VD-N1-N-62-I-WN-22-中壢	
	匝道	VD-N1-N-62-I-EN-21-中壢	
	匝道	VD-N1-N-62-O-SE-21-中壢	
	匝道	VD-N1-N-62-O-SE-1-中壢	

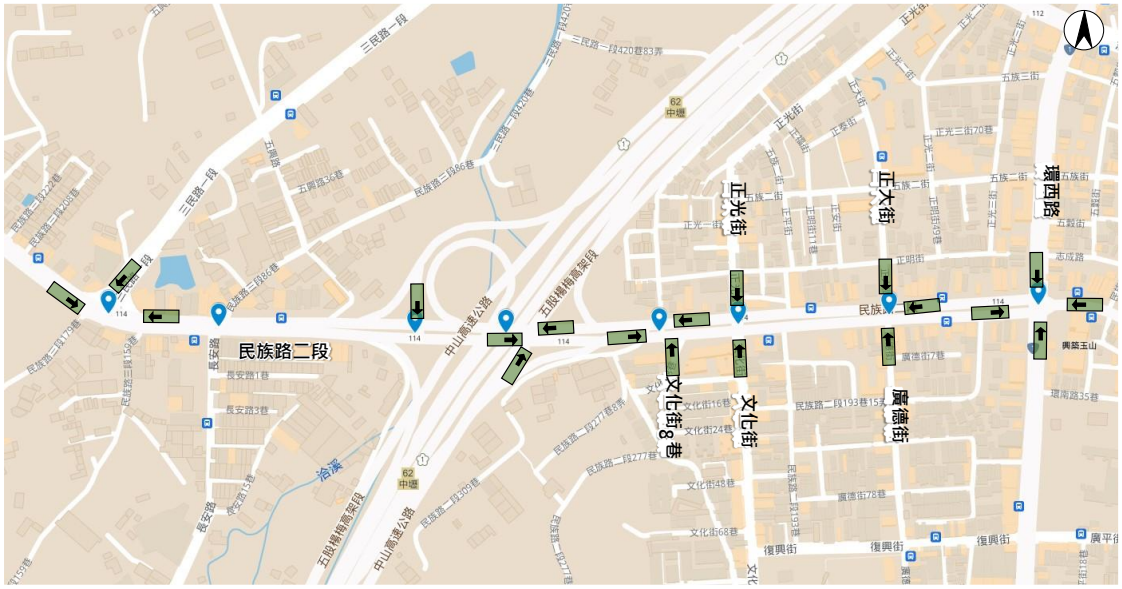


圖 4.1.2.2-4 中壢交流道平面道路車流偵測設備點位圖

表 4.1.2.2-2 中壢交流道周邊平面道路 AI 辨識 CCTV 偵測設備清單

設備資訊	
民族路/環西路/環南路	S214100-2, S214100-4, S214100-6, S214100-0
民族路二段/正大街/廣德街	S214000-0, S214000-4, S214000-2
民族路二段/正光街/文化街	S213900-4, S213900-0
民族路二段/文化街 8 巷	S320800-6, S320800-2, S320800-4
民族路二段/國 1 北上入口匝道	S213700-0, S213700-4, S213700-6
民族路二段/國 1 南下出口匝道	S213600-0
民族路三段/三民路一段	S255300-2, S255300-6, S255300-0

二、旅行時間

傳統之旅行速率調查係採用浮動車法，調查車輛於車隊中保持車隊之均速行駛。然在號誌化幹道中車輛不同的出發時間點其可續進的路口數不同，即使依交通工程手冊至少蒐集 6 趟資料，亦可能無法真正反應整體車流績效。因此本計畫透過蒐集 GVP 資料瞭解事前事後路段平均旅行時間，預計事前及事後將各至少蒐集 1 週之資料。選擇蒐集之路段除平面道路外，亦蒐集影響路口之匝道及高速公路主線部分。由於短時間內車流隨號誌而有週期性變化，為能全面掌握路況 GVP 資料蒐集之頻率將避開號誌週期，如：號誌週期為 150 秒則不能每 150 秒或每 300 秒蒐集一次資料。圖 4.1.2.2-5 為以中壢交流道範圍為例的 GVP 旅行時間蒐集路段示意。

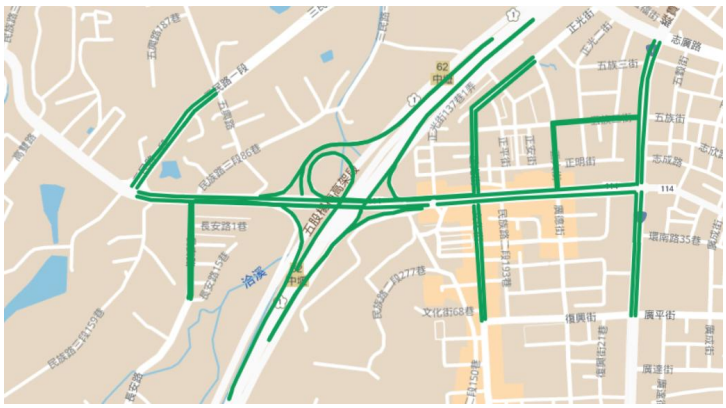


圖 4.1.2.2-5 GVP 旅行時間蒐集路段示意圖-以中壢交流道範圍為例

4.2 號誌協控模型訓練

4.2.1 協控實驗場域模擬環境構建

4.2.1.1 模擬模式設計與環境建置

為建置一套能夠讓強化學習代理人任意探索各種策略組合可能性的環境，本計畫使用 VISSIM 及 SUMO 兩種交通模擬軟體來建置此學習環境。以中壢交流道為例的 SUMO 路網編輯介面，如圖 4.2.1.1-1 所示，依照人工交通調查數據輸入相關交通需求、轉向比例、車種比例及運行之號誌時制計畫，並進行校估工作。



圖 4.2.1.1-1 SUMO 路網編輯介面示意圖-以中壢交流道為例

在號誌控制運作方面，根據號誌時制計畫設定各號誌時相動線與秒數，以及分時段執行不同號誌時制計畫(TOD)。號誌時制動線設定在 SUMO 中可以圖像化方式設定路口節點中各時相動線的連接方式，也可以採用文字矩陣方式設定各燈頭的燈號、秒數等等，如圖 4.2.1.1-2 所示。而在 VISSIM 中則是類似燈頭設定的方式，以圖像化的方式設定號誌控制器中所有號誌燈頭在號誌週期中的燈號與秒數，如圖 4.2.1.1-3 所示。

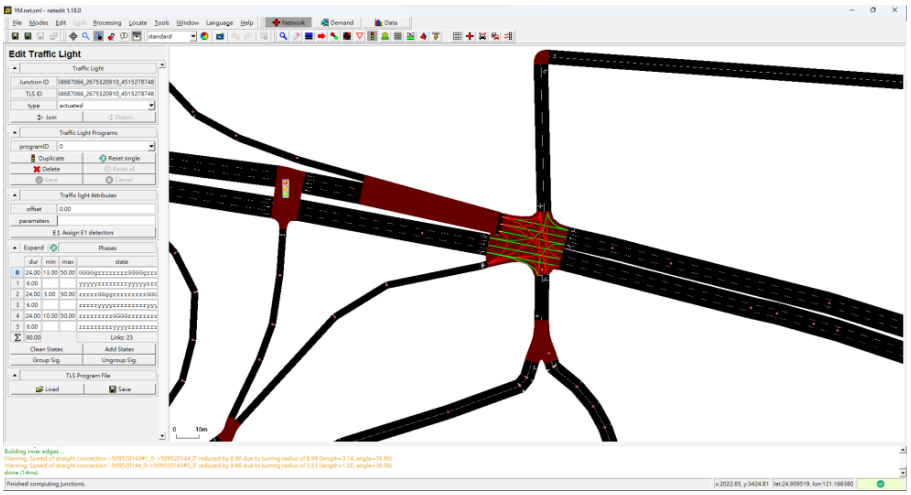


圖 4.2.1.1-2 SUMO 圖像化時相動線設定及文字矩陣時相動線設定

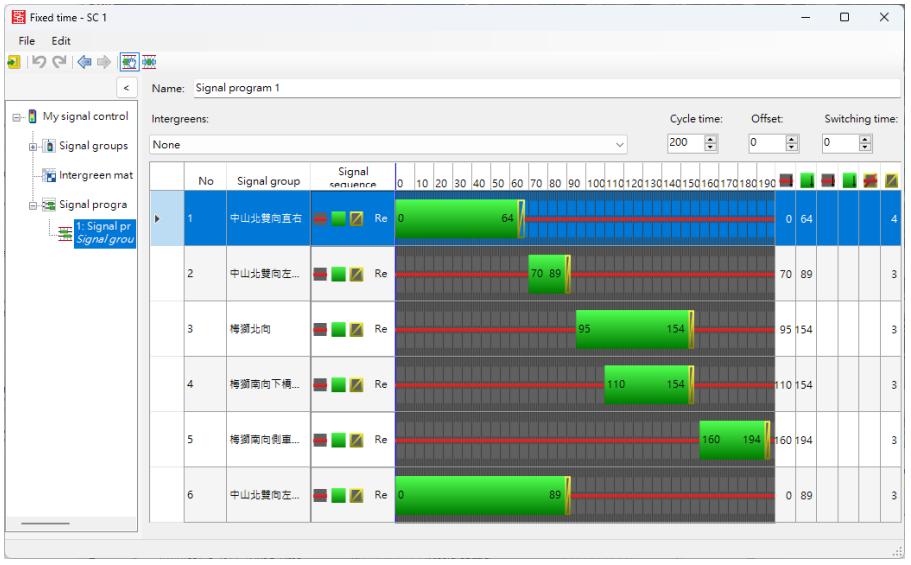


圖 4.2.1.1-3 VISSIM 中號誌時制設定範例

在完成基本的模擬模型結構與號誌運作設定後，接著須設定交通需求相關的設定。在 SUMO 中須透過計算車輛在發車點出現的機率值完成交通需求量的設定，而該機率值則是通過交通調查資料換算所得。而在 VISSIM 中則較為直觀，僅需設定在時段內預期出現的車輛數量，軟體即會以 Poisson 分配轉換發車機率值讓車輛到達。圖 4.2.1.1-4 與圖 4.2.1.1-5 分別為 SUMO 與 VISSIM 的交通需求設定範例。



圖 4.2.1.1-4 SUMO 交通需求設定範例

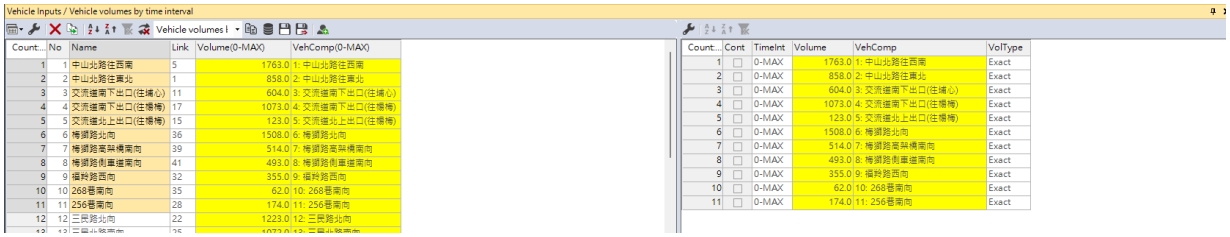


圖 4.2.1.1-5 VISSIM 交通需求設定範例

完成車輛需求設定後，最後需要設定各路口的轉向比例，在這方面兩套模擬軟體作法基本相同，皆為設定各轉向的機率數值，而在模擬過程中車輛即會隨機的決定在通過路口時的轉向動線，轉向比例同樣是從交通調查資料得到。至此，模擬模型基本的結構與運作方式大致底定。接下來須通過誤差模擬驗證的過程微調駕駛人行為參數，以確保最終的模擬行為與現況場域交通表現一致。

4.2.1.2 模擬模型校估與驗證

交通模擬方法是評估交通影響衝擊與改善方案的有效做法，在有限的資源下盡可能的獲得量化的方案評估結果。然而為了確保評估方案與現實交通環境能有相同的表現行為，模擬器的校準過程相當重要。以下參考國內外採用模擬方法之建議手冊與案例，將校估流程按步驟說明。

一、 模擬場域資料蒐集

路網建置需蒐集相關交通資料，一般可分為靜態資料與動態資料，說明如下。

(一)靜態資料

路網構建階段輸入之資料多為靜態道路設施資料，不隨模擬過程變動，可由道路幾何配置調查、道路工程圖面獲得，項目如下：

1.道路寬度、車道數、車道寬度。

2.轉向、車道縮減、或車道增加。

3.大眾運輸場站位置與長度。

4.停止線、號誌燈頭的位置。

5.以及與號誌控制時相之關聯。

6.「停」、「讓」標誌之位置。

7.機車停等區和機車待轉區尺寸和位置。

(二)動態資料

完成路網建構後，須進行車流特性等相關動態資料設定，動態資料會隨模擬執行過程變化，主要為輸入交通組成與交通量。交通組成係定義輸入交通量中，各類型運具所佔比例；交通量則依賴路網端點之上游路口轉向交通量，模擬系統根據兩項資料產生路網中相對應之各車種車輛數。相關動態資料可能包括：

1.路徑決策點的位置，以及時間與車種之決策情形。

2.非號誌化路口或路口允許左轉之優先控制。

3.大眾運輸之路徑、班次、班距與停靠站時間。

4.進入路網之交通量與車種組成。

二、模擬路網建置

調查、蒐集道路靜態及動態資料後，連同號誌化路口之時制計畫、抑或牌面標誌之交通管制以及相關基本參數，設置入模擬模型中。

(一)道路構建與路口管制方式設定

1.構建道路路網基本幾何線型：以背景圖為底，於圖上構建專案所需範圍之道路線型及車道數。

2.輸入車道寬度與各車道之行駛車輛限制。

3.設定各路段之連結路徑。

4.設定路口控制方式(號誌時制計畫)。

5.設定績效指標偵測器(通過車輛數、停等車隊長度)。

在號誌運作方面，根據號誌時制計畫設定各號誌時相動線與秒數以及分時段執行不同號誌時制計畫(TOD)。號誌時制動線設定在 SUMO 中可以圖像化方式設定路口節點中各時相動線的連接方式，也可以採用文字矩陣方式設定各燈頭的燈號、秒數等等。而在 VISSIM 中則是類似燈頭設定的方式，以圖像化的方式設定號誌控制器中所有號誌燈頭在號誌週期中的燈號與秒數。

設定績效偵測器部分，為了蒐集通過量，而在模擬環境中的路口每個近端車道設置感應線圈，模擬車輛偵測器；停等車隊長度的部分，則設置模擬車道偵測，以模擬利用 CCTV 偵測車輛的辨識情況。

(二)交通量輸入

1.設定車種組成。

2.輸入路網各路段之端點交通量。

3.設定路口轉向流量比例。

4.路徑產生方式。

在交通量相關的運作中，須透過計算車輛在發車點出現的機率值完成交通需求量的設定，而該機率值則是通過交通調查資料換算所得。例如，該路口某行駛方向紀錄每小時流量為 1,800 輛，以 SUMO 為例，該參數設定為 0.5，意即每秒出現該種車輛的機率為 0.5。

而各路口的轉向比例亦須設置，此為各轉向的機率數值。而在模擬過程中，車輛即會隨機的決定在通過路口時的轉向動線，轉向比例同樣是從交通調查資料得到。至此，模擬模型基本的結構與運作方式大致底定。接下來須通過誤差模擬驗證的過程，微調各類型參數，以確保最終的模擬行為與現況場域交通表現一致。

(三)參數設定

1.車輛幾何(車長、車寬、車重)。

2.車輛性能(最大加/減速率、期望加/減速率、期望速率分配)。

3.車輛種類(小汽車、公車、大貨車、機車、腳踏車)。

4.駕駛行為參數(跟車參數、變換車道參數、側向參數)。

三、參數校估

(一)校估指標選取

AI 號誌控制的訓練過程是透過大量與環境互動的經驗累積所得出的決策優化，而此一與環境的互動在實務上不宜直接讓 AI 在真實的交通環境下進行訓練，因此如何創建一個與真實交通狀態近似的互動環境對於 AI 的訓練可謂至關重要的。透過設定模擬軟體(VISSIM 與 SUMO)中甚多參數可供使用者根據經驗或校估結果輸入，如車流期望速度、車輛最大加減速度、接受間距等。各項參數皆有軟體提供之預設值，然而為了使模擬更貼近實際狀況，如何正確的輸入這些參數方能反映真實車流情況，使模擬績

效指標值與現場調查績效指標值誤差能在接受範圍內就極為重要。

本計畫亦參考近年來國內使用 VISSIM 的相關經驗做為初始參數設定，以加速模擬校估的工作進度。為了確保模擬結果能夠反應實際交通行為，參考國內外相關案例後整理如表 4.2.1.2-1 所示。從模擬校估相關文獻回顧當中可以發現到，絕大部分的微觀模擬仍是以交通流量作為主要的校估指標，在延滯部分則是受到實務上調查困難，調查自身數據存在一定程度誤差，故較少文獻使用。

表 4.2.1.2-1 國內外模擬校估績效指標及範圍

國內外案例	採用校估績效指標		
	平均流量	平均旅行時間 (or 平均速率)	平均停等延滯
107 年，交通改善措施微觀車流模擬成效評估案	< 10%	--	--
102 年，交通技術研發與人才培育規劃研究(4/4)	< 20%	--	< 30%
96 年，公路工程設計輔助工具引進與應用之研究	< 10%	< 15%	--
105 年，台 9 線蘇花改通車後對蘇澳地區交通衝擊影響評估分析	< 20%	< 20%	--
107 年，大新竹運輸走廊整合道路交通與電信資訊應用	< 20%	--	--
Calibration of VISSIM for Indian Heterogeneous Traffic Conditions, 2013	< 10%	--	--
Core of Rosslyn Transportation Study Existing Conditions Report, 2018	< 15%	< 15%	--
Calibration of VISSIM and QuickZone programs for work zone traffic impact analysis, 2015	--	< 15%	< 15%

資料來源：本計畫整理

但採用 MAPE 作為驗證統計量，當部分轉向或路段的調查值本身數值較低時，容易很大程度的影響 MAPE 的數值，導致其評估結果有失客觀而受到挑戰。反之，當調查數值極大時，MAPE 也容易低估，造成配適良好的假象。為避免此種狀況，亦常見到以 GEH 統計量(Geoffrey E. Havers, 1970)來做為衡量模型是否為良好適配的指標。GEH 統計量設計以用來校估模型及現實之每小時流量誤差情況，相關文獻回顧詳第二章。

本案中壢交流道實驗場域中，表 4.2.1.2-2~4.2.1.2-6 為 SUMO 模擬環境與現實交通量調查的誤差比較結果，表 4.2.1.2-7 為 VISSIM 模擬環境與現實交通量調查的誤差比較結果。在高速公路主線區域，北上路段受平面道路路網誤差之影響可能較大，準確率不如南下方向，惟兩者仍符合 GEH 準確率要求。在平面道路部分，於 MAPE 欄位中可見 MAPE 值與 GEH 值仍有正相關性，但相較起來較為和緩。以文化街/正光街路口為例，往南車輛 MAPE 差異超過 40%，但實際車輛差異約 50 台，雖後續可持續進行模型校估，惟整體以 GEH 指標作為校估手段。

在本研究中，所使用的模擬環境校估方法與倫敦及內華達州的建模規範作法一致。

倫敦及內華達州的建模規範都強調了微觀交通模擬中的校估指標，特別是在流量、旅行時間和停等延滯方面的準確度要求。例如：根據倫敦的相關交通模擬研究，VISSIM 的校估誤差通常要求交通流量的 MAPE 值不超過 10%，而旅行時間的 MAPE 值則需控制在 15%以內。此外，在美國內華達州，交通模型校準也採用類似的標準。例如：在內華達州南部地區交通委員會(RTC)的動態交通分配模型開發中，使用 TransCAD 和 TransModeler 雙平台模型，其模擬研究也強調使用 GEH 統計量來補充 MAPE 指標，特別是當部分交通量較小或較大時，MAPE 指標的偏差可能會影響結果的客觀性，而 GEH 則能提供一個更為穩定的衡量方式。

綜上所述，於交通模型調校中，MAPE 和 GEH 統計量是常用的指標，MAPE 用於衡量預測值與實際值之間的百分比誤差，適用於交通流量較大的情況，然而當交通流量較小時，MAPE 可能會放大誤差，導致評估結果失真。為此，GEH 統計量被引入作為補充指標。GEH 結合了絕對和相對誤差的特點，能夠更有效地評估模型在不同交通流量下的適配性。因此，在交通模型校準過程中，結合使用 MAPE 和 GEH 統計量，可以更全面地評估模型的適配性，確保其在不同交通流量條件下的準確性。

表 4.2.1.2-2 中壢交流道區域高速公路主線校估結果(平日晨峰)

路口	路口調查方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE %	GEH 指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
高速公路主線	往北	7,020	6,523	7.1%	6.04
	往南	7,919	7,898	0.3%	0.24
平均				3.7%	3.14

表 4.2.1.2-3 SUMO 中壢交流道區域平面道路校估結果(平日晨峰)

路口	路口調查方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE %	GEH指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
民族路/民族路二段/環西路/環南路	往西	569	615	8.1%	1.89
	往北	1,036	1,028	0.8%	0.25
	往東	1,077	1,110	3.1%	1.00
	往南	862	896	3.9%	1.15
民族路二段/廣德街/正大街	往西	1,364	1,174	13.9%	5.33
	往北	209	240	14.8%	2.07
	往東	1,218	1,257	3.2%	1.11
	往南	194	236	21.6%	2.86
民族路二段/文化街/正光街	往西	1,577	1,310	16.9%	7.03
	往北	348	376	8.0%	1.47
	往東	1,544	1,621	5.0%	1.94
	往南	109	159	45.9%	4.32
民族路二段/文化街8巷	往西	1,898	1,582	16.6%	7.58
	往北	450	445	1.1%	0.24
	往東	1,598	1,651	3.3%	1.31
	往南	91	96	5.5%	0.52
民族路二段/中壢北匝	往西	1,337	1,227	8.2%	3.07
	往北	277	406	46.6%	6.98
	往東	1,062	1,339	26.1%	7.99
	往南	–	–	–	–
民族路二段/中壢南匝	往西	710	703	1.0%	0.26
	往北	–	–	–	–
	往東	1,130	1,111	1.7%	0.57
	往南	474	433	8.6%	1.93
民族路三段/長安路	往西	1,387	1,315	5.2%	1.96
	往北	188	202	7.4%	1.00
	往東	1,424	1,357	4.7%	1.80
	往南	340	345	1.5%	0.27
民族路三段/三民路一段/民族路一段179巷	往西	1,342	1,315	2.0%	0.74
	往北	4	2	50.0%	1.15
	往東	1,249	1,213	2.9%	1.03
	往南	531	513	3.4%	0.79
平均				11.4%	2.32

表 4.2.1.2-4 SUMO 中壢交流道區域平面道路校估結果(平日昏峰)

路口	路口調查方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE %	GEH指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
民族路/民族路二段/環西路/環南路	往西	645	671	4.0%	1.01
	往北	730	734	0.5%	0.15
	往東	1,642	1,644	0.1%	0.05
	往南	881	849	3.6%	1.09
民族路二段/廣德街/正大街	往西	1,051	1,073	2.1%	0.68
	往北	162	207	27.8%	3.31
	往東	1,842	1,780	3.4%	1.46
	往南	163	238	46.0%	5.30
民族路二段/文化街/正光街	往西	1,186	1,168	1.5%	0.52
	往北	243	259	6.6%	1.01
	往東	2,110	2,060	2.4%	1.10
	往南	202	211	4.5%	0.63
民族路二段/文化街8巷	往西	1,419	1,326	6.6%	2.51
	往北	95	75	21.1%	2.17
	往東	2,456	2,371	3.5%	1.73
	往南	102	105	2.9%	0.29
民族路二段/中壢北匝	往西	1,599	881	44.9%	20.39
	往北	1,188	380	68.0%	28.86
	往東	2,175	2,055	5.5%	2.61
	往南	–	–	–	–
民族路二段/中壢南匝	往西	1,225	858	30.0%	11.37
	往北	–	–	–	–
	往東	1,497	1,237	17.4%	7.03
	往南	1,591	823	48.3%	22.11
民族路三段/長安路	往西	1,320	1,524	15.5%	5.41
	往北	204	220	7.8%	1.10
	往東	1,273	1,356	6.5%	2.29
	往南	179	157	12.3%	1.70
民族路三段/三民路一段/民族路一段179巷	往西	1,251	1,424	13.8%	4.73
	往北	9	11	22.2%	0.63
	往東	1,299	1,329	2.3%	0.83
	往南	391	358	8.4%	1.71
平均				14.6%	4.46

表 4.2.1.2-5 SUMO 中壢交流道區域平面道路校估結果(假日晨峰)

路口	路口調查方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE %	GEH指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
民族路/民族路二段/環西路/環南路	往西	747	705	5.6%	1.56
	往北	828	796	3.9%	1.12
	往東	1,501	1,460	2.7%	1.07
	往南	842	884	5.0%	1.43
民族路二段/廣德街/正大街	往西	1,268	1,199	5.4%	1.96
	往北	172	183	6.4%	0.83
	往東	1,605	1,560	2.8%	1.13
	往南	144	196	36.1%	3.99
民族路二段/文化街/正光街	往西	1,420	1,327	6.5%	2.51
	往北	278	229	17.6%	3.08
	往東	1,929	1,828	5.2%	2.33
	往南	260	234	10.0%	1.65
民族路二段/文化街8巷	往西	1,635	1,532	6.3%	2.59
	往北	159	151	5.0%	0.64
	往東	2,078	1,978	4.8%	2.22
	往南	97	106	9.3%	0.89
民族路二段/中壢北匝	往西	1,863	1,077	42.2%	20.50
	往北	943	300	68.2%	25.79
	往東	1,779	1,689	5.1%	2.16
	往南	–	–	–	–
民族路二段/中壢南匝	往西	1,394	854	38.7%	16.11
	往北	–	–	–	–
	往東	1,291	1,005	22.2%	8.44
	往南	1,357	689	49.2%	20.89
民族路三段/長安路	往西	1,310	1,497	14.3%	4.99
	往北	124	126	1.6%	0.18
	往東	1,129	1,208	7.0%	2.31
	往南	109	116	6.4%	0.66
民族路三段/三民路一段/民族路一段179巷	往西	1,108	1,402	26.5%	8.30
	往北	7	7	0.0%	0.00
	往東	1,133	1,150	1.5%	0.50
	往南	360	334	7.2%	1.40
平均				14.1%	4.71

表 4.2.1.2-6 SUMO 中壢交流道區域平面道路校估結果(假日昏峰)

路口	路口調查方向	調查輸入 通過車輛數 (輛/小時)	模擬輸出 通過車輛數 (輛/小時)	MAPE %	GEH指標 $GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
民族路/民族路二段/環西路/環南路	往西	666	698	4.8%	1.23
	往北	851	873	2.6%	0.75
	往東	1,515	1,467	3.2%	1.24
	往南	864	924	6.9%	2.01
民族路二段/廣德街/正大街	往西	1,190	1,270	6.7%	2.28
	往北	193	211	9.3%	1.27
	往東	1,807	1,706	5.6%	2.41
	往南	114	159	39.5%	3.85
民族路二段/文化街/正光街	往西	1,292	1,353	4.7%	1.68
	往北	274	246	10.2%	1.74
	往東	2,155	1,967	8.7%	4.14
	往南	233	218	6.4%	1.00
民族路二段/文化街8巷	往西	1,599	1,544	3.4%	1.39
	往北	98	104	6.1%	0.60
	往東	2,380	2,191	7.9%	3.95
	往南	66	65	1.5%	0.12
民族路二段/中壢北匝	往西	1,001	1,003	0.2%	0.06
	往北	294	296	0.7%	0.12
	往東	2,175	1,872	13.9%	6.74
	往南	–	–	–	–
民族路二段/中壢南匝	往西	721	832	15.4%	3.98
	往北	–	–	–	–
	往東	1,277	1,159	9.2%	3.38
	往南	618	584	5.5%	1.39
民族路三段/長安路	往西	1,449	1,610	11.1%	4.12
	往北	188	215	14.4%	1.90
	往東	1,251	1,313	5.0%	1.73
	往南	78	77	1.3%	0.11
民族路三段/三民路一段/民族路一段179巷	往西	1,301	1,494	14.8%	5.16
	往北	10	12	20.0%	0.60
	往東	1,272	1,288	1.3%	0.45
	往南	353	328	7.1%	1.35
平均				8.3%	2.02

表 4.2.1.2-7 VISSIM 中壢交流道區域平面道路校估結果(平日晨峰)

路口	臨近路口方向	方向	調查輸入	模擬輸出	MAPE	GEH 指標
			通過車輛數(輛/小時)	通過車輛數(輛/小時)	%	$GEH=\sqrt{\frac{2(m-c)^2}{m+c}}$
民族路/民族路二段/環南路/環西路	民族路往西	←	1,355	1,322	-2%	0.90
	環南路往北	↑	2,362	2,128	-10%	4.94
	民族路往東	→	1,934	1,610	-17%	7.70
	環西路往南	↓	1,510	1,534	2%	0.62
民族路二段/廣德街/正大街	民族路往西	←	2,142	2,049	-4%	2.03
	廣德街往北	↑	539	557	3%	0.77
	民族路往東	→	1,966	1,748	-11%	5.06
	正大街往南	↓	502	523	4%	0.93
民族路二段/文化街/正光街	民族路往西	←	2,397	2,181	-9%	4.51
	廣德街往北	↑	884	874	-1%	0.34
	民族路往東	→	2,390	2,040	-15%	7.44
	正光街往南	↓	413	390	-6%	1.15
民族路二段/文化街 8 巷	民族路往西	←	2,796	2,585	-8%	4.07
	文化街 8 巷往北	↑	743	641	-14%	3.88
	民族路往東	→	2,366	2,187	-8%	3.75
	232 巷往南	↓	110	107	-3%	0.29
民族路二段/中壢交流道北上匝道	民族路往西	←	3,637	3,206	-12%	7.37
	中壢交流道北上出口匝道	↑	844	703	-17%	5.07
	民族路往東	→	2,321	2,137	-8%	3.90
	-	-	0	-	-	-
民族路二段/中壢交流道南下匝道	民族路往西	←	2,861	2,134	-25%	14.55
	-	-	0	-	-	-
	民族路往東	→	2,503	2,419	-3%	1.69
	中壢交流道南下出口匝道	↓	1,134	1,128	-1%	0.18
民族路三段/長安路	民族路往西	←	2,693	2,177	-19%	10.46
	長安路往北	↑	411	388	-6%	1.15
	民族路往東	→	2,116	2,113	0%	0.07
	86 巷往南	↓	546	531	-3%	0.65
民族路三段/三民路一段/民族路三段 179 巷	民族路往西	←	2,510	2,131	-15%	7.87
	179 巷往北	↑	177	193	9%	1.18
	民族路往東	→	2,266	2,136	-6%	2.77
	三民路往南	↓	862	1,175	36%	9.81
平均					-5.5%	3.84

(二)參數調校

本計畫強化學習號誌控制交流道模型，以高速公路匝道與平面道路之中壢交流道區域為實驗場域進行驗證。其場域特性為高速公路主線及平面道路車流之匯入匯出彼此影響，且匝道出入口易成瓶頸，又跨層級結構及多路口連動，控制需要更精細的控制。

模擬模型的初始設定可能與現場交通條件不完全吻合，透過參數微調與校正，驗證模擬環境指標和參數，讓模擬結果更接近真實交通情境。調校過程並無一定程序，但應一次調整單一參數，藉以了解各參數之影響力，應對模型誤差的來源進行細緻分析如靜態與動態參數的影響，以科學方法釐清問題，並在多次調整與驗證中確保結果的準確性。驗證過程中，採用數個關鍵效能指標及參數說明如下：

1. 驗證目標與指標

(1)匯流效率：分析平面道路與匝道、高速公路主線與匝道間的車流交互情況，評估匯流區的通行能力。

(2) 延滯時間：測量在匯流與出口區域的平均等待時間。

(3) 紓解率：以 SUMO 進行微觀交通模擬觀測車流是否更順暢，或擁堵現象是否減少。

(4) 平均車速：確保車輛在主幹道和匝道的平均車速符合過往歷史表現。

(5) 排隊長度：觀察匯入匝道車輛的排隊情況是否降低。

2. 靜態及動態參數：部分參數使用模擬模型建議之預設值，整理如表 4.2.1.2-8 所示。

(1) 靜態參數

A.交流道幾何結構：匝道長度、彎道半徑、坡度等。

B.設施參數：匝道儀控率。

C.道路規劃：車道數量與寬度，匝道進出口間距。

(2) 動態參數

A.車流特性：高速公路匯入匯出流量狀態。

B.駕駛行為模式：匯流處加速/減速、跟車間距、變道行為。

C.高峰與非高峰動態流量：模擬不同時段的交通情境。

調校過程揭示了模擬模型中不同參數對模擬結果的影響，為團隊釐清可能的問題來源，並針對問題進行有針對性的優化提供了理論支持。若以單一參數調整後問題仍無法解決，再以組合方式調整兩項以上之參數，但須確定參數間相互作用所產生之影響符合實際車流情況，並反覆校正以上程序，直到誤差符合模型校估門檻。

透過模型校估提升模擬結果的準確性與可信度，並確保模擬過程的科學性，此過程對於最終績效指標(如旅行時間與延滯)的數據可信度至關重要。

表 4.2.1.2-8 部分模擬模式參數(以 SUMO 為例)

項目	模擬參數	
車輛相關	車長(m)	大車：12, 小車：5.5, 機車：1.6
	加減速(m/s2)	大車：3.2/1.0, 小車：3.5/3.0, 機車：3.6/3.0
車道相關	車道寬(m)	3.2 (default)
	優先順序	依道路等級
	道路速限(m/s)	依照道路規範
跟車模式相關	最小跟車距(m)	大車：1, 小車：0.5, 機車：0.2
	駕駛習慣	(bad) 0~1 (good)
	駕駛耐性	(bad) 0~1 (good)

(三)路網微調

此步驟可於參數調校後仍無法令模擬車流與實際車流的誤差小於所設定門檻時進行。例如普遍性的違規(如跨越雙白線)、左轉車不會禮讓直行車等，雖於交通規則並不允許，然為忠實反映實際狀況，仍應將此一情形透過路網微調步驟修正。

4.2.2 AI 號誌協控模型架構說明

一、AI 號誌協控模型規劃

號誌協控模型以 Q-Pensieve 作為模型演算法，並引用集中訓練並分散執行(Centralized Training and Decentralized Execution, CTDE)框架作為匝道與平面道路之號誌控制與訓練架構(architectures)。

交流道實驗場域分為平面道路號誌控制與匝道儀控兩個群組，為使策略網絡(Policy Network)能蒐集到平面道路與匝道的資訊，模型輸入分為匝道儀控率、平面道路路口號誌之時相資訊，以及高速公路主線道路、平面道路與匝道路口之道路資訊。而因匝道與平面道路週期不一致，且匝道之儀控秒數大多小於平面道路週期，因此當各群組自身週期結束時，決策其群組下一個週期秒數與分相比例。設定五個獎勵目標，包含幹支道通過量與延滯車輛數、匝道通過量作為平面道路與匝道之共同優化目標。為了加快 AI 號誌控制模型訓練速度與避免過大或過小秒數探索，使用固定時制(TOD)的平均績效進行獎勵計算方式的正規化，詳細績效計算公式列於表 4.2.2-1。

決策結果因匝道、平面道路有所區分，如匝道決策時將提供下個匝道綠、黃、紅燈秒數；平面道路號誌決策時則提供下一週期秒數及各分相比例，使其可以確保各自群組輸出時不會影響到另外一個群組的決策時間點，可以分別運作。當現場平面道路號誌週期結束時，AI 號誌控制模型會以平面道路結束時間點，收集平面道路號誌與道路資訊與上週期之匝道資訊，此資訊會輸入進平面道路模型並根據模型參數輸出平面道路群組之號誌；反之當匝道儀控結束時，AI 號誌控制模型會以匝道結束時間點收集匝道號誌與道路資訊，此資訊則會輸入進匝道模型並根據模型參數輸出匝道儀控率。至此模型可在各種不同時間點決策並不會影響其他

群組決策點，AI 號誌協控模型相關設計內容詳表 4.2.2-2。

表 4.2.2-1 交流道實驗場域 AI 號誌控制模型獎勵計算公式表

定義	計算方式
幹道延滯時間與固定時制的變化量	$\frac{\text{幹道總延滯時間} - \text{固定時制幹道總延滯時間}}{\text{固定時制幹道總延滯時間}}$
支道延滯時間與固定時制的變化量	$\frac{\text{支道總延滯時間} - \text{固定時制支道總延滯時間}}{\text{固定時制支道總延滯時間}}$
幹道通過量與固定時制的變化量	$\frac{\text{幹道通過量} - \text{固定時制幹道通過量}}{\text{固定時制幹道通過量}}$
支道通過量與固定時制的變化量	$\frac{\text{支道通過量} - \text{固定時制支道通過量}}{\text{固定時制支道通過量}}$
匝道通過量與固定時制的變化量	$\frac{\text{匝道通過量} - \text{固定時制匝道通過量}}{\text{固定時制匝道通過量}}$

表 4.2.2-2 交流道實驗場域 AI 強化學習模式規劃表

定義	內容	
代理人數量	2	
	平面道路	匝道
輸入 (兩個代理人共用)	平面道路號誌資訊：週期平面道路號誌結果。如:週期秒數及各時相比例	匝道號誌資訊：週期匝道綠、黃、紅燈秒數
	平面道路資訊：各路口各分相結束時，分車道分車種停等車輛數及總車輛數	高速公路道路資訊：匝道通過輛、高速公路各 eTag 偵測的通過量
輸出	平面道路號誌週期秒數及各分相比例	週期匝道移控率
決策頻率	平面道路週期結束時決策	匝道綠、黃、紅燈秒數結束時
獎勵目標 (兩個代理人共用)	延滯： (一)平面幹道延滯數量與固定時制的優化量 (二)平面支道延滯數量與固定時制的優化量 通過量： (一)上匝道 VD 通過量與固定時制的優化量 (二)平面幹道通過量與固定時制的優化量 (三)平面支道通過量與固定時制的優化量	
權重設定	向量組合：[平面幹道延滯，平面支道延滯，匝道通過量，平面幹道通過量，平面支道通過量] 1.偏重平面道路延滯：[0.425, 0.425, 0.05, 0.05, 0.05] 2.偏重平面道路通過量：[0.05, 0.05, 0.05, 0.425, 0.425] 3.偏重匝道通過量：[0.025, 0.025, 0.9, 0.025, 0.025] 4.偏重平面幹道：[0.425, 0.05, 0.05, 0.425, 0.05] 5.偏重平面支道：[0.05, 0.425, 0.05, 0.05, 0.425]	

資料來源：本計畫整理

二、交流道實驗場域 AI 強化學習模式訓練規劃

為增加訓練的效率，平面道路與匝道會以兩個決策網絡(policy network)各自收集與決策該群組之資訊，分別為平面道路與匝道的週期秒數及時相比例。為了達成分散化執行之目的，訓練週期以秒為單位，並根據當下平面道路與匝道的決策剩餘秒數是否為零，決定是否再提供下一輪的時相控制，並輸入對應的模型決策結果至環境(SUMO/VISSIM environment)；在當下群組週期結束時會存取收集整體場域之車流情況、號誌情況與模型決策結果進 replay buffer，並根據模型參數同時決策新週期秒數與各分相比例。在訓練回合(episode)結束時，評論者網絡(Critic Network)則會將全部資料隨機取樣並整合為各週期各群組整個場域的號誌、車流狀況，動作之向量資料用於計算 Q 值。其 Q 值會再以群組本身的狀態(State)重新計算並更新 Q 值予以更新模型與其參數。

三、Centralized Training Decentralized Execution(CTDE)運作機制

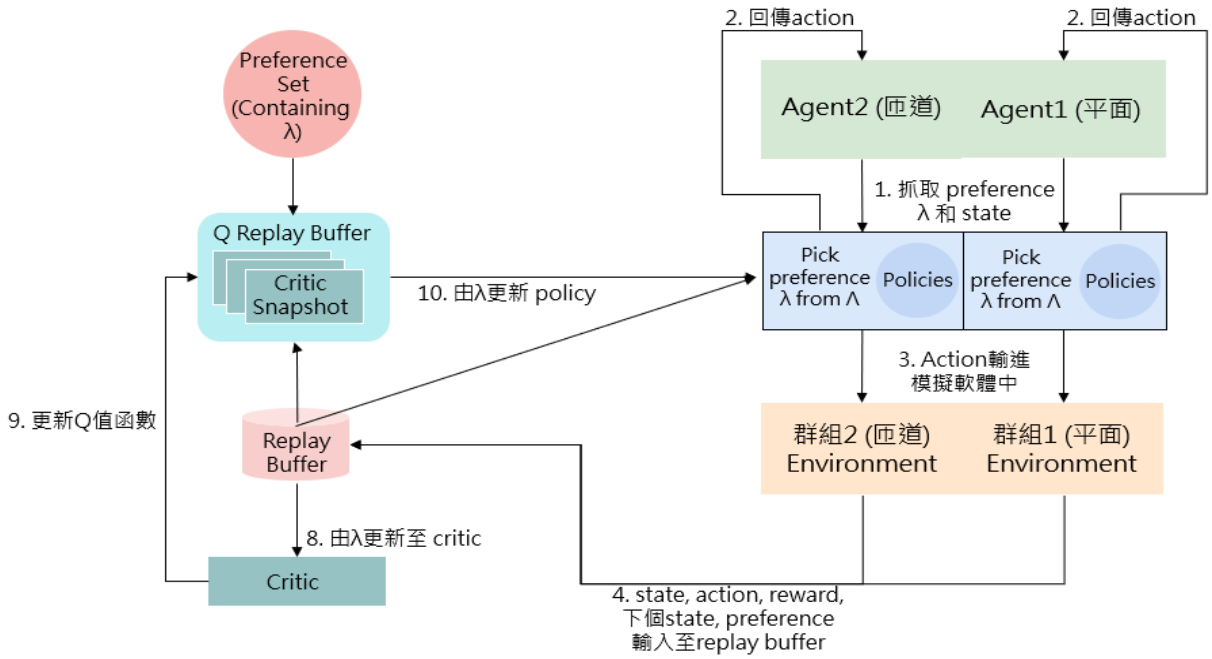
由於需要針對匝道和平面道路訓練不同的策略，在此實驗場域本計畫 AI 號誌控制模型使用 CTDE 訓練架構，該架構通常應用於大規模機器學習系統，特別是涉及同時訓練多個代理人用於各種策略。圖 4.2.2-1 為 CTDE 號誌協控模式訓練架構圖，架構主要分為兩個階段：

(一)集中式訓練(Centralized Training):

在訓練階段會有一個中央控制器收集所有代理人(Agents)於週期結束時各自決策之動作(Action)、狀態(States)與獎勵(Rewards)資訊，將其存取並計算策略參數值用於更新各代理人(Agents)的策略網絡。在訓練結束後並不再利用直至下一次更新時。可以想像成一個教室，學生(代理人)負責把筆記(模型輸入)分享給其他學生進行資訊共享一並討論(計算參數值)並從中學習更新策略網路。

(二)分散化執行(Decentralized Execution):

經過訓練後代理人(Agents)有各自的策略網絡(policy networks)，每個代理人(Agents)皆可針對自身群組收集資訊(匝道與平面道路)，並根據訓練後之策略網路決定該群組之動作(Action)，將其輸出至模擬環境中直到訓練回合(episode)結束並重新開啟中央化訓練，直至代理人(Agents)策略網路達到最佳解(收斂)。而這可以想像成中央化訓練結束後(學生討論完)，現在回到各自的考場(群組 environment)，而在這期間無法共享資訊但可以通過訓練後的更新參數(討論完獲得的知識)來取得更好的結果並進行下一次更新。



資料來源：本計畫整理

圖 4.2.2-1 號誌協控模式訓練架構圖

1.模型中各自代理人(Agent)根據其群組之上一週期號誌、道路資訊，以及模型參數決策其控制動作(Action)，意即平面道路週期秒數與各時相秒數與匝道之綠、黃、紅燈秒數，將其輸進模擬軟體與其互動產出下個週期該群組之環境(State)與獎勵(Reward)。

2.該群組週期或綠燈結束時，會將這週期的狀態(State)與獎勵(Reward)與模型決策結果(Action)整合並梳理為一筆數據資料(data transition)存進資料庫(replay buffer)。

3.上述兩步驟屬於分散化執行，意即執行途中兩個代理人(Agent)不會進行知識共享，直至該訓練回合(episode)結束。

4.訓練回合(episode)結束後，會從資料庫隨機取樣一定數量之數據資料(data transition)給予 Critic Network，由其評估該訓練回合(episode)的環境資料並計算出其動作(Action)之預期價值(好壞不定)，而這價值會以 Q 值函數作為輸出，同時儲存到另外一個資料庫(Q replay buffer)。

5.重複上述步驟直至資料庫中含有一定資料數量。

6.號誌協控模型設有兩位代理人，故須計算另一位代理人之 Q 值並同時儲存於(Q replay buffer)。

7.中央化訓練目的為知識共享，當模型更新時，模型會將各自模型之 Q 值重新計算出整合 Q 值用於更新各自代理人。

8.步驟三至五為集中式訓練，執行途中會將各自代理人的資訊與計算結果重新整合為

各代理人都能訓練之參數，而其代表為用於更新之 Q 值函數。結束後將用於更新模型並跳回步驟一、二之分散化執行。

9.上述所有步驟會重複執行直至模型收斂。

4.2.3 訓練環境程式與軟硬體說明

VISSIM 以 COM API 指令動態調整並取得模擬環境中資訊，SUMO 則是以 TraCI API 指令動態調整並取得模擬環境中資訊。在模擬中，兩者都是用 Python 程式介接取得環境中的狀態或是號誌燈號與其秒數。在訓練開始前取得模擬資料，如：轉向、流量與路網等資料，在模擬開始後初始化所需紀錄之參數，於暖機時間後開始紀錄狀態(State)，獎勵(Reward)，動作(Action)等模型所需資訊。待代理人(Agent)需做決策時(週期結束)，將收集的狀態(State)、動作(Action)、獎勵(Reward)給予模型並由模型參數產出下次動作秒數(Action)。如上述動作持續執行模擬與收集績效，從收集資訊提供給代理人(Agent)至代理人(Agent)產出動作(Action)為一個訓練步數(step)，重複執行訓練步數(step)，直到兩小時模擬時間結束再進行模型更新，並儲存為一個訓練回合(episode)。

另外，本研究所使用的軟硬體如表 4.2.3-1，AI 號誌控制模型訓練以 Pytorch 構建神經網絡與強化學習架構，並以 VISSIM，SUMO 作為模擬環境，其中 VISSIM 版本為 2022 SP09、SUMO 為 1.16.0、Pytorch 為 2.0.1、Python 為 3.9。

表 4.2.3-1 AI 號誌控制模型訓練使用之軟硬體規格

項目	規格
CPU	AMD Ryzen 9 7950x 16-Core Processor
GPU	NVIDIA GeForce RTX 4090
Python	3.9
Pytorch	2.0.1
VISSIM	2022 SP 09
SUMO	1.16.0

4.2.4 訓練結果

交流道實驗場域各時段之 AI 號誌控制模型訓練收斂情形如圖 4.2.4-1 至圖 4.2.4-4，其中 X 軸為訓練步數，Y 軸為 AI 號誌控制模型收斂值，收斂值用於衡量 AI 預測結果與實際結果之誤差，Loss 越高代表誤差越大，Loss 越低則代表誤差越小，而其中之收斂值只要低於 0 代表模型對於決策動作帶來更好的獎勵績效。表 4.2.4-1 為中壢交流道實驗場域的 AI 號誌控制模型超參數內容。

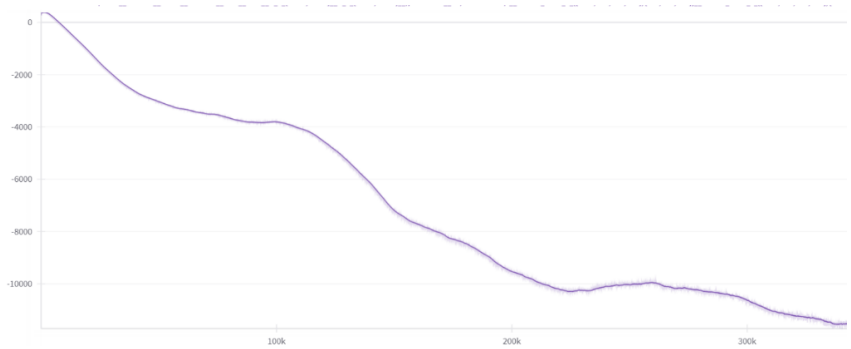


圖 4.2.4-1 中壢交流道晨峰時段 AI 號誌控制模型收斂圖



圖 4.2.4-2 中壢交流道離峰時段 AI 號誌控制模型收斂圖

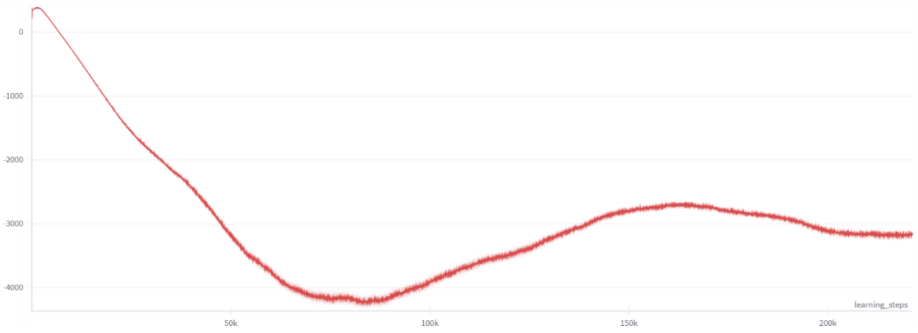


圖 4.2.4-3 中壢交流道昏峰時段 AI 號誌控制模型收斂圖

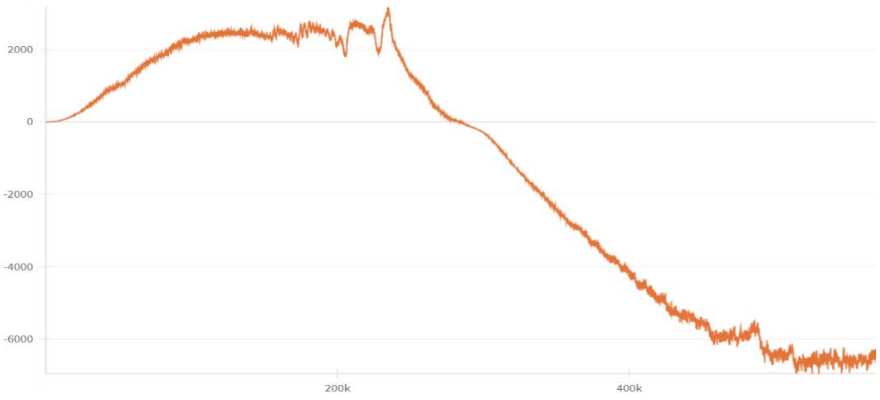


圖 4.2.4-4 中壢交流道假日昏峰時段 AI 號誌控制模型收斂圖

表 4.2.4-1 中壢交流道實驗場域 AI 號誌控制模型超參數

參數	說明
隱藏層數	4
神經元數量	[1024, 512,256, 128]
激活函數	Mish
學習率	0.00003
折和因子	0.99
熵係數	0.01
抽樣數	64
更新頻率	1000
資料庫大小	1000000

交流道區域訓練時將觀察模型損失值以調整模型參數，確保模型能穩定收斂。若模型無法收斂，將進一步分析原因，判斷是否為模型初期即存在不收斂情況，或是因後期資料變化或參數設置問題所致，並相應修改模型設計或調整超參數。由於交流道區域採用 CTDE 架構協同控制匝道與平面道路兩種不同之控制邏輯，因此在控制邏輯差異的情況下出現資料不平衡的問題，使模型決策過於偏向特定群組。因此針對模型資料存取架構進行調整，並結合網格搜索方法以尋找訓練過程中最有效的超參數設定，從而改善模型性能。

4.2.5 模擬績效分析

以 4.2 節訓練完成之 AI 號誌控制模型，透過車流模擬環境、實驗場域現場即時偵測資料兩種輸入資料運算時相綠燈秒數，經由人工檢視模型運算結果之合理性以及穩定度。可使用兩種角度進行觀察檢視：同天同時段內之穩定度、不同天同時段之穩定度。

同天同時段之穩定度為，在一般情況下，該天內上午晨峰時段內的車流狀況變化小，因此該天上午晨峰時段的時制計畫中，各時相之綠燈時間的變動程度理應同車流狀況一樣變化不大；不同天同時段之穩定度為，在一般情況下，同樣為平日的上午晨峰時段，不同天上午晨峰之車流狀況變化小，因此不同天的上午晨峰時段的時制計畫中，各時相之綠燈時間的變動程度理應同車流狀況一樣變化不大，所以當出現各時相綠燈秒數差異很大之情況，就需特別注意該天是否有突發狀況,選擇無突發狀況之其他天的交通調查資料進行運算確認穩定度。

相關合理性及穩定性檢視方式如下：

一、合理性

為維護行車安全及促進道路使用效率，號誌設計須符合交通流向、流量及路況，亦即某行駛方向交通量多，其分相綠燈秒數運算結果應足夠安全通過且延滯最小，不合理之情況如某轉向交通量很多，但其分相綠燈秒數運算結果很短；反之同樣非為合理狀況。

又本場域於路段號誌桿上架設車輛偵測器，辨識大車、小車及機車停等車量數，在不調整分相配置之情況下，各分相 AI 產出之秒數，應因應該分相主線及支線停等車輛數變化而波

動。

二、穩定度

同天同時段內之穩定度與不同天同時段之穩定度確認，當出現各時相綠燈秒數差異很大之情況，就需特別注意該天是否有突發狀況，選擇無突發狀況之其他天的交通調查資料進行運算確認穩定度判定標準除前述 AI 產出之各分相秒數與週期之比值合理性判定能同時判定週期產出穩定度外，另依據回歸方程式中依變數及自變數之關係說明其變化穩定程度，其公式計算如下：

Y：時段週期變化

a：截距

b：斜率

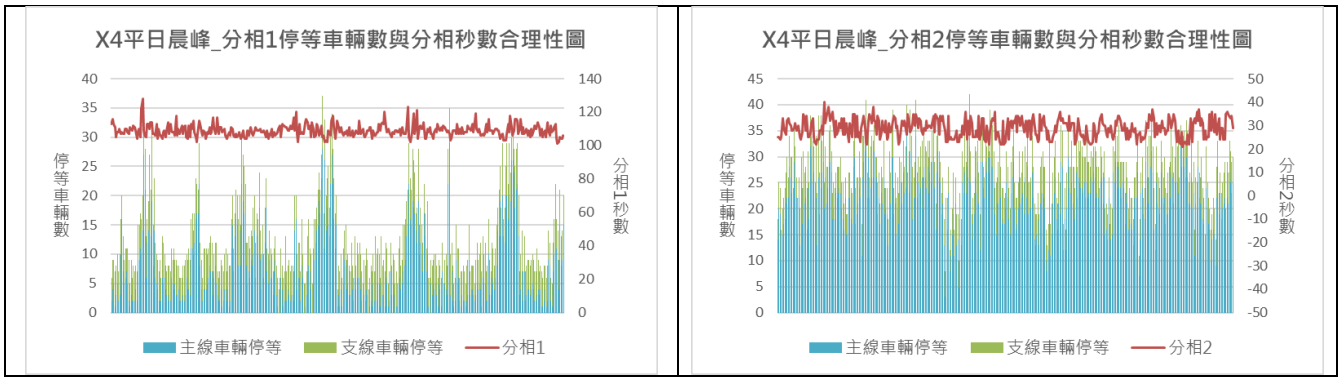
e：誤差或殘差

公式：$Y = a + bX + e$

模擬環境測試以平日晨峰(07：00~09：00)、平日離峰(中午 12:30~14:30)、平日昏峰(16：30~18：30)及假日昏峰(16：30~18：30)4 個時段為主，桃園市中壢交流道平面道路共計 8 個路口，執行團隊以靠近交流道周邊之三處重點路口進行分析，說明如下。

一、平日晨峰(07：00~09：00)

週期秒數約呈現 181 秒集中趨勢，略高於 TOD 的 180 秒，各分相停等車輛數與 AI 產出秒數之變化趨勢圖整理如圖 4.2.5-1 至圖 4.2.5-3 所示。



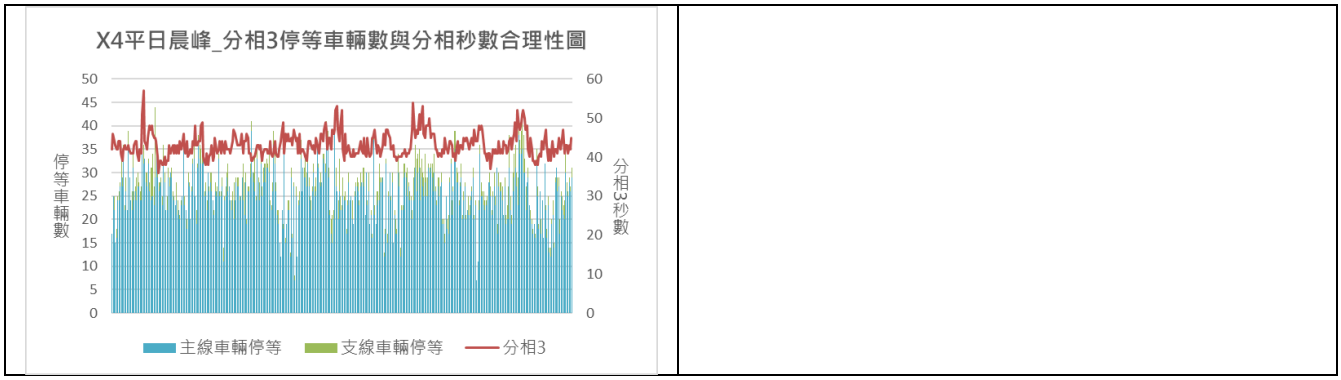


圖 4.2.5-1 民族路/文化路 8 巷(X4)平日晨峰模擬分相秒數合理性圖

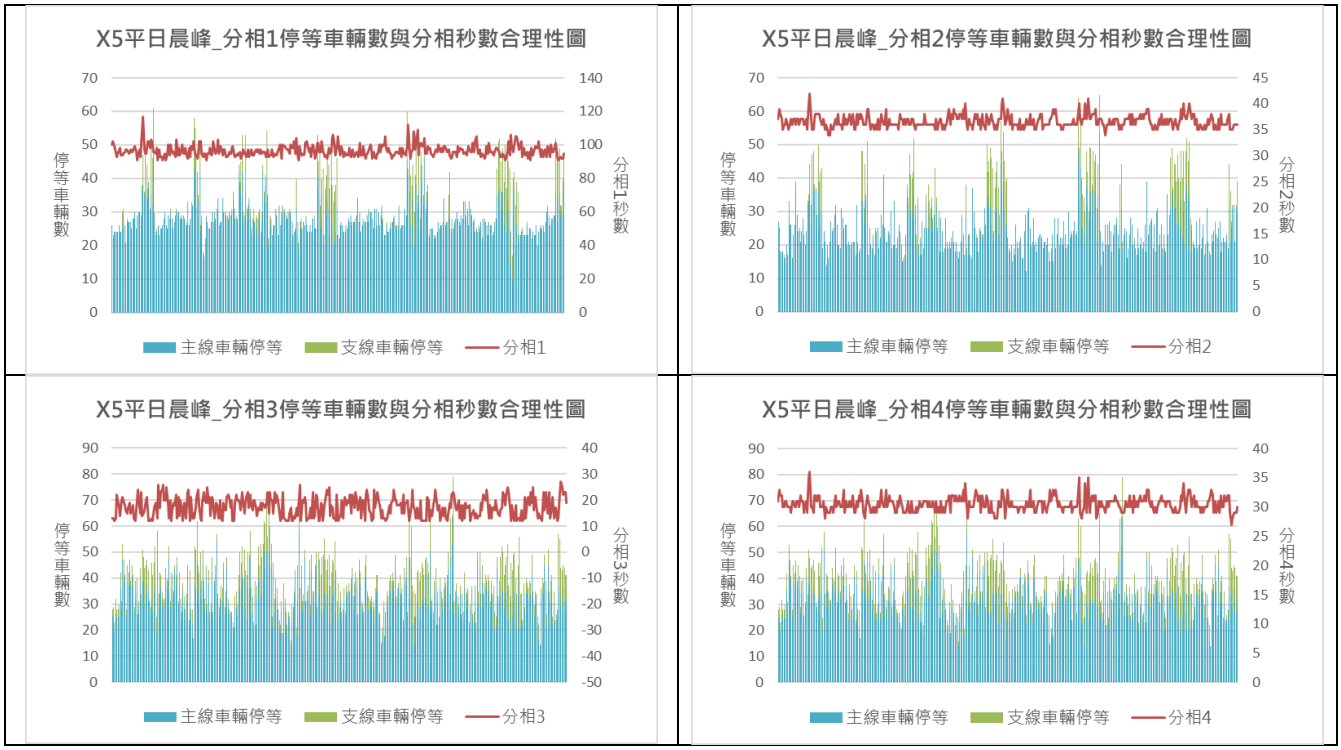


圖 4.2.5-2 民族路/北上匝道(X5)平日晨峰模擬分相秒數合理性圖

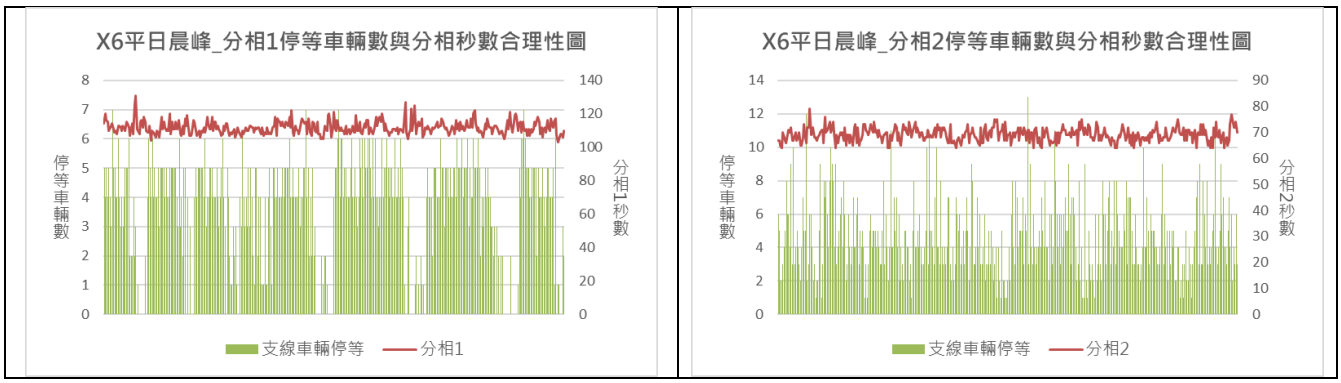


圖 4.2.5-3 民族路/南出匝道(X6)平日晨峰模擬分相秒數合理性圖

二、平日離峰(12：30~14：30)

週期秒數約呈現 179 秒集中趨勢，高於 TOD 的 180 秒，各分相停等車輛數與 AI 產出秒

數之變化趨勢圖整理如圖 4.2.5-4 至圖 4.2.5-6 所示。

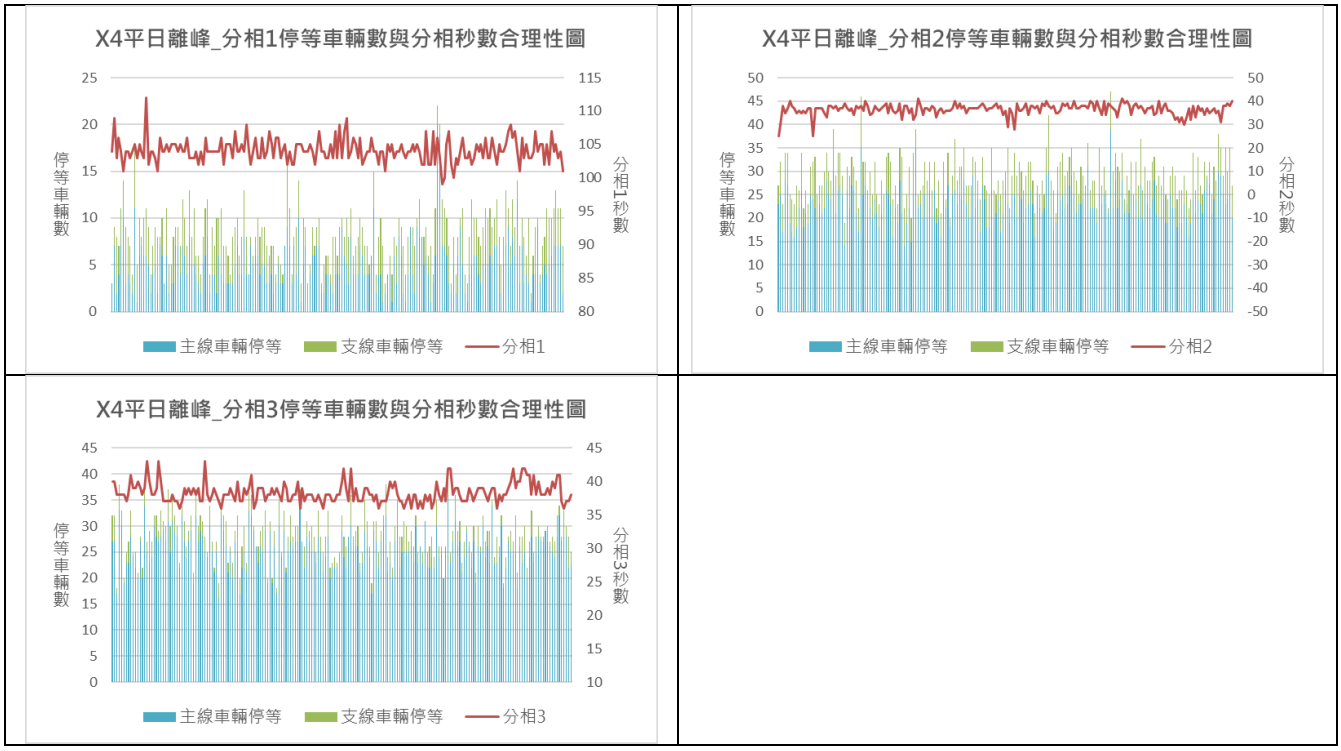


圖 4.2.5-4 民族路/文化路 8 巷(X4)平日離峰模擬分相秒數合理性圖

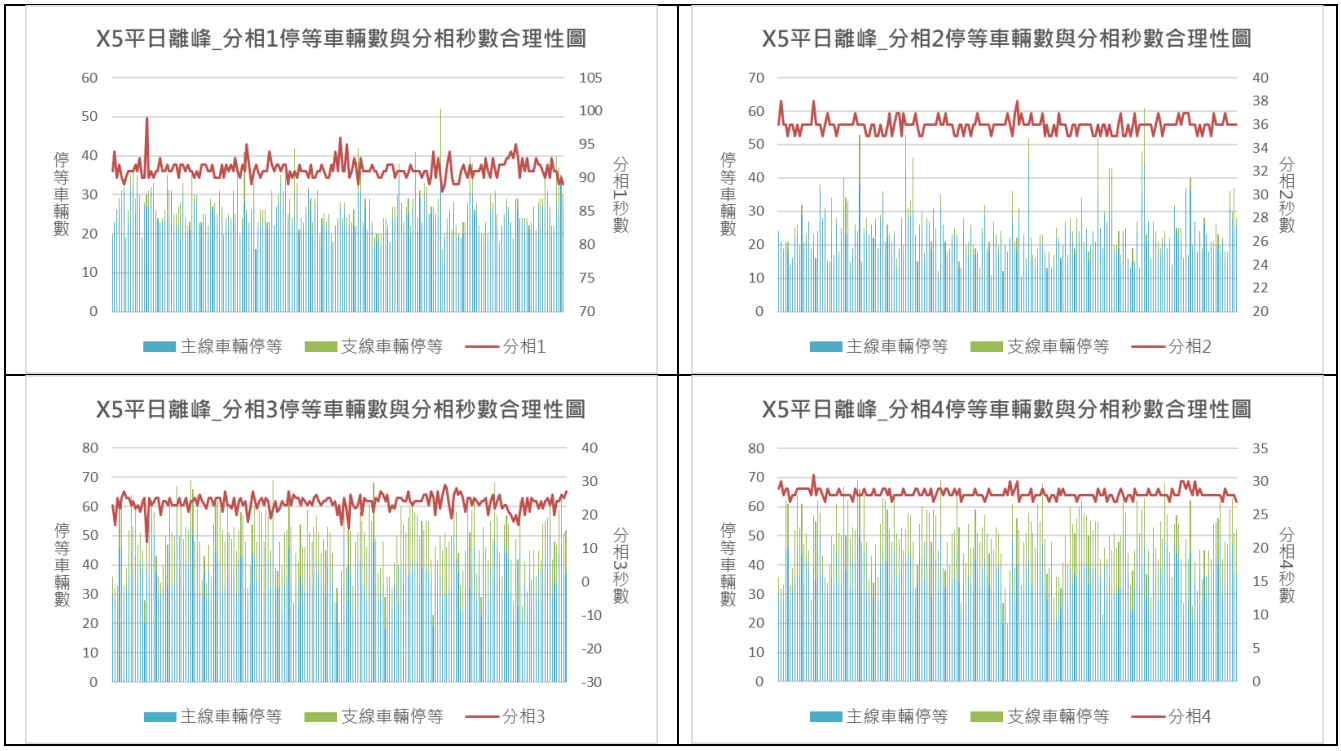


圖 4.2.5-5 民族路/北上匝道(X5)平日離峰模擬分相秒數合理性圖

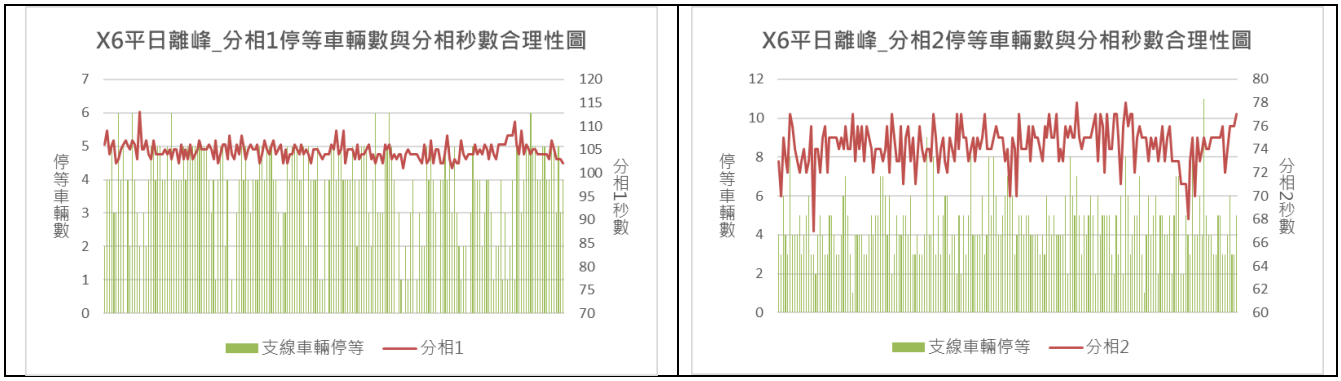


圖 4.2.5-6 民族路/南出匝道(X6)平日離峰模擬分相秒數合理性圖

三、平日昏峰(16：30~18：30)

週期秒數約呈現 180 秒集中趨勢，各分相停等車輛數與 AI 產出秒數之變化趨勢圖整理如圖 4.2.5-7 至圖 4.2.5-9 所示。

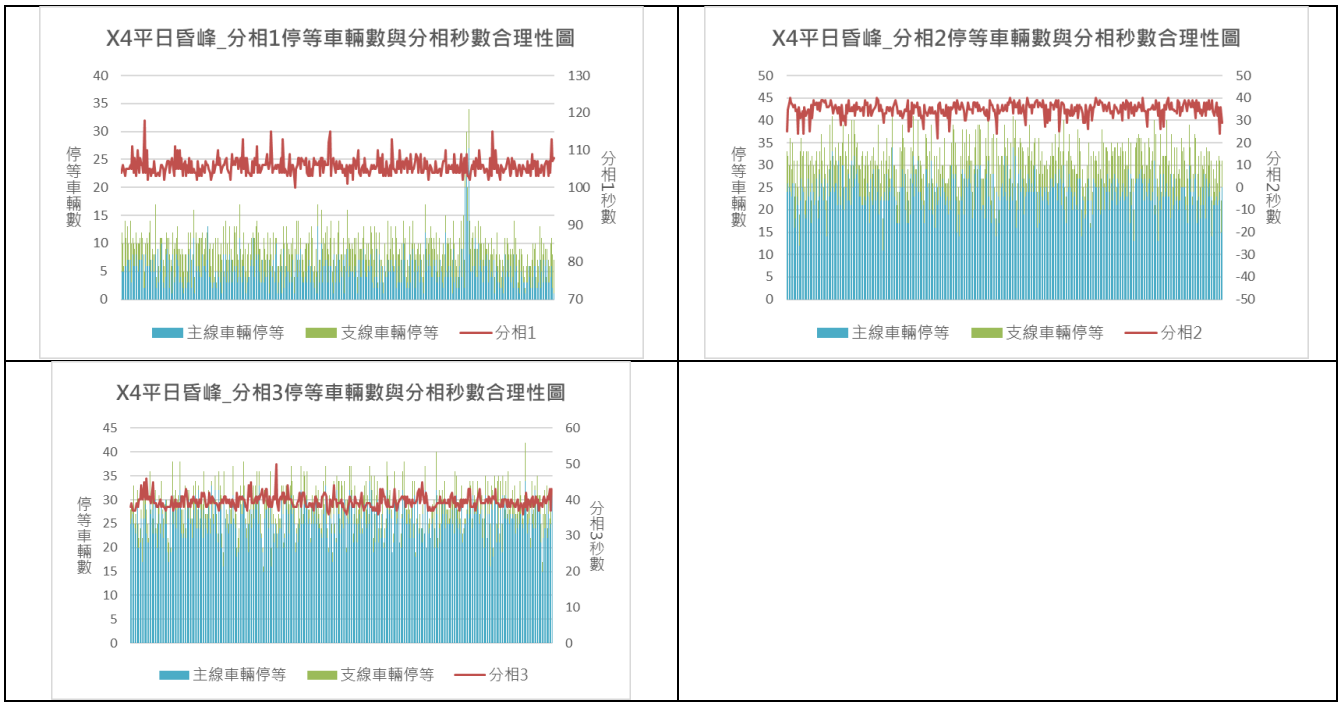
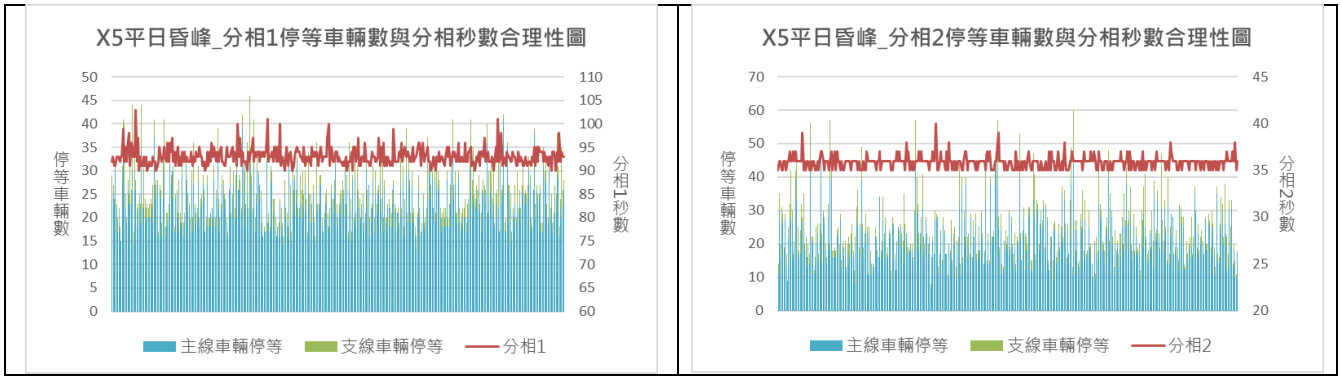


圖 4.2.5-7 民族路/文化路 8 巷(X4)平日昏峰模擬分相秒數合理性圖



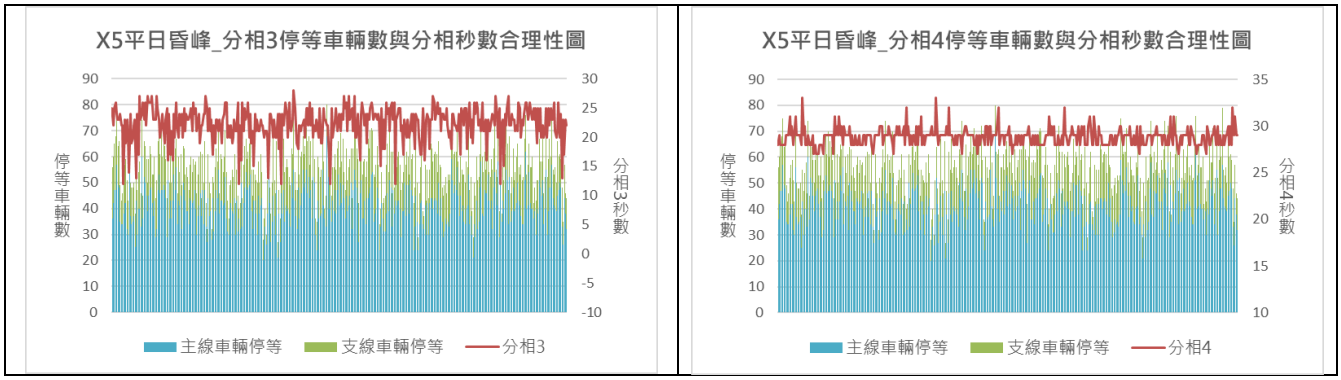


圖 4.2.5-8 民族路/北上匝道(X5)平日昏峰模擬分相秒數合理性圖

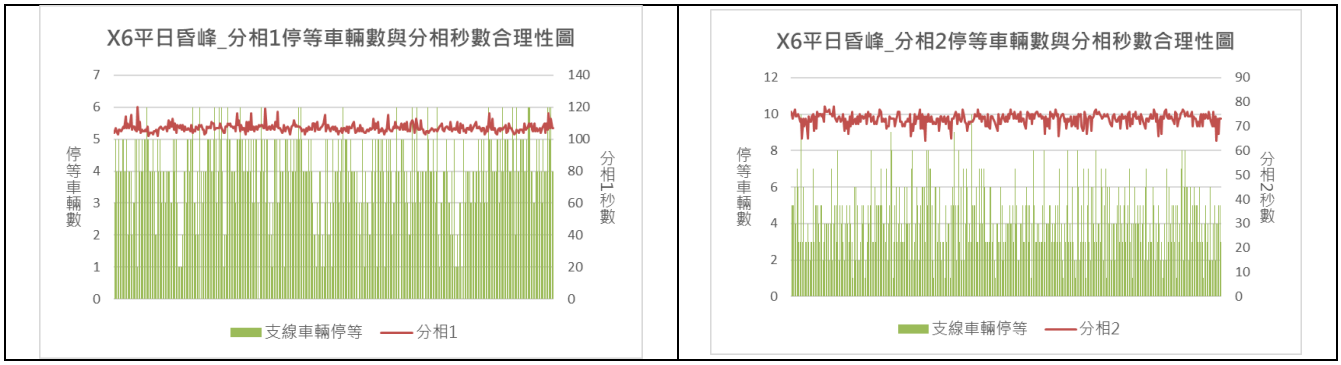


圖 4.2.5-9 民族路/南出匝道(X6)平日昏峰模擬分相秒數合理性圖

四、假日昏峰(16：30~18：30)

週期秒數約呈現 180 秒集中趨勢，各分相停等車輛數與 AI 產出秒數之變化趨勢圖整理如圖 4.2.5-10 至圖 4.2.5-12 所示。

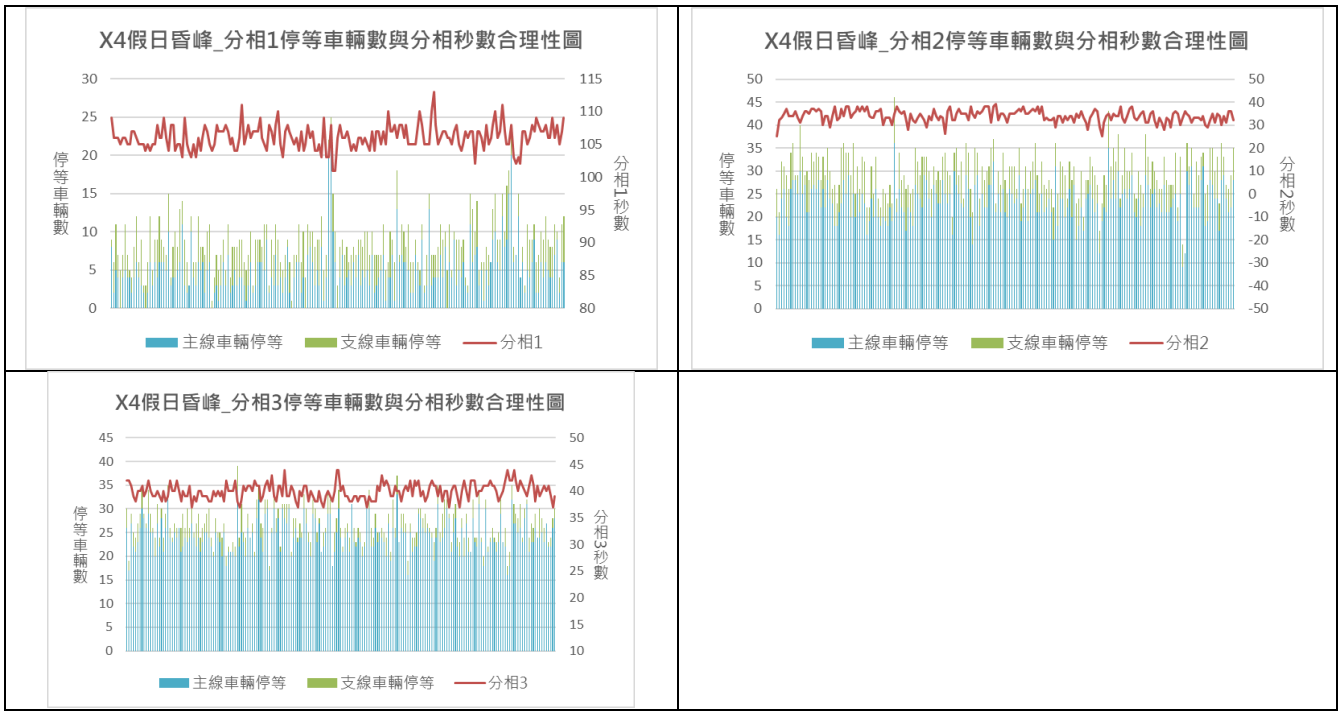


圖 4.2.5-10 民族路/文化路 8 巷(X4)假日昏峰模擬分相秒數合理性圖

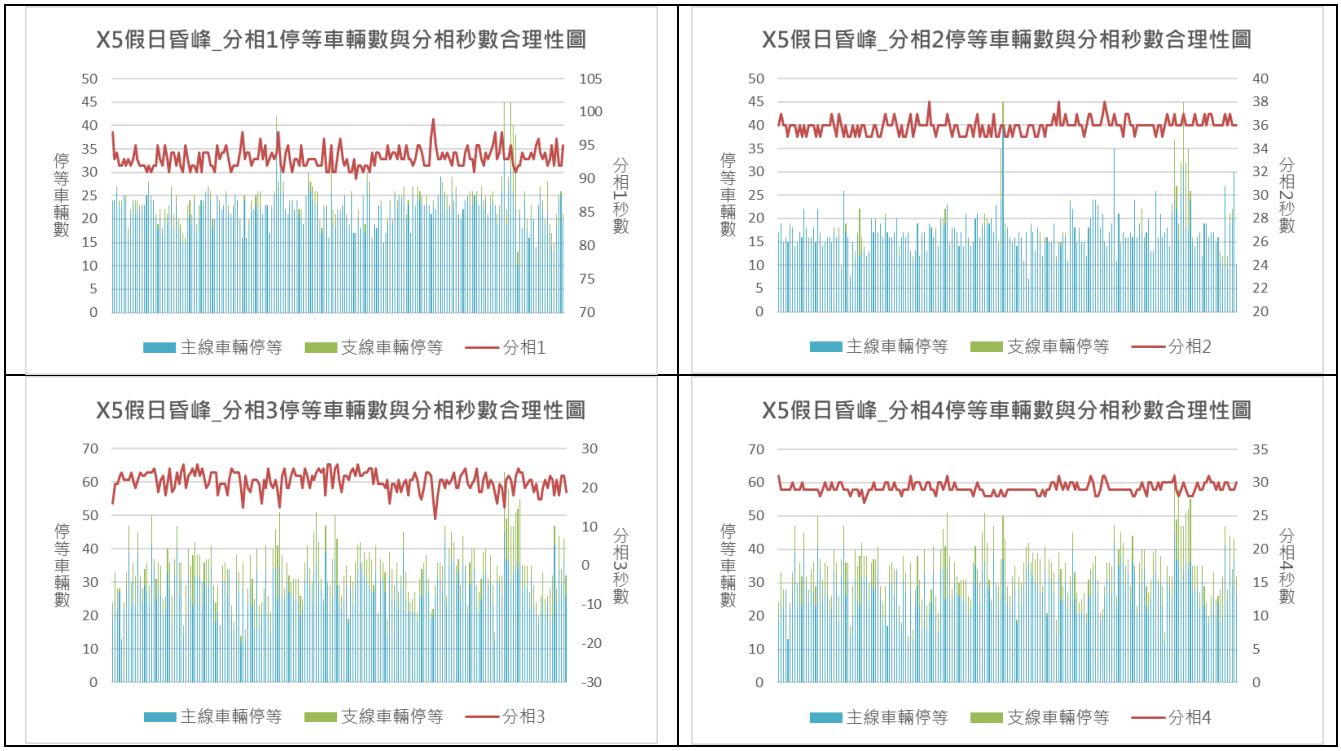


圖 4.2.5-11 民族路/北上匝道(X5)假日昏峰模擬分相秒數合理性圖

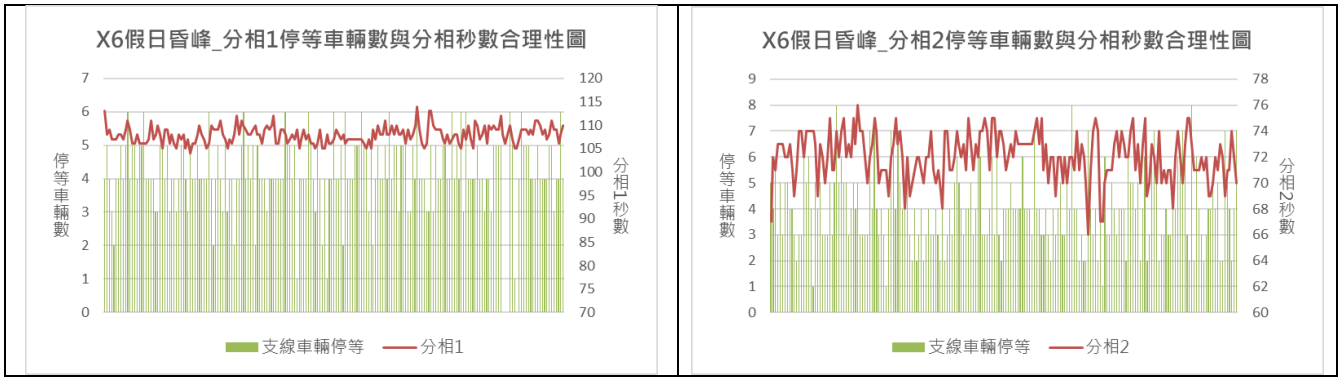


圖 4.2.5-12 民族路/南出匝道(X6)假日昏峰模擬分相秒數合理性圖

4.3 實測績效分析

4.3.1 實驗場域偵測設備

考量本計畫所建置之 AI 號誌控制系統係依據於各路口或各車道所佈建之智慧型偵測器即時偵測資料，經由 AI 運算決策即時調整與控制現場號誌運作，因此偵測設備是否可有效辨識物件並提供精確之偵測值極為重要。桃園市「中壢交流道」平面道路路口偵測設備如圖 4.3.1-1 所示，路口共架設 19 台即時影像車輛偵測設備，經由 AI 影像辨識取得車流量資料，經執行團隊確認，設備位置與偵測範圍皆符合本計畫需求。

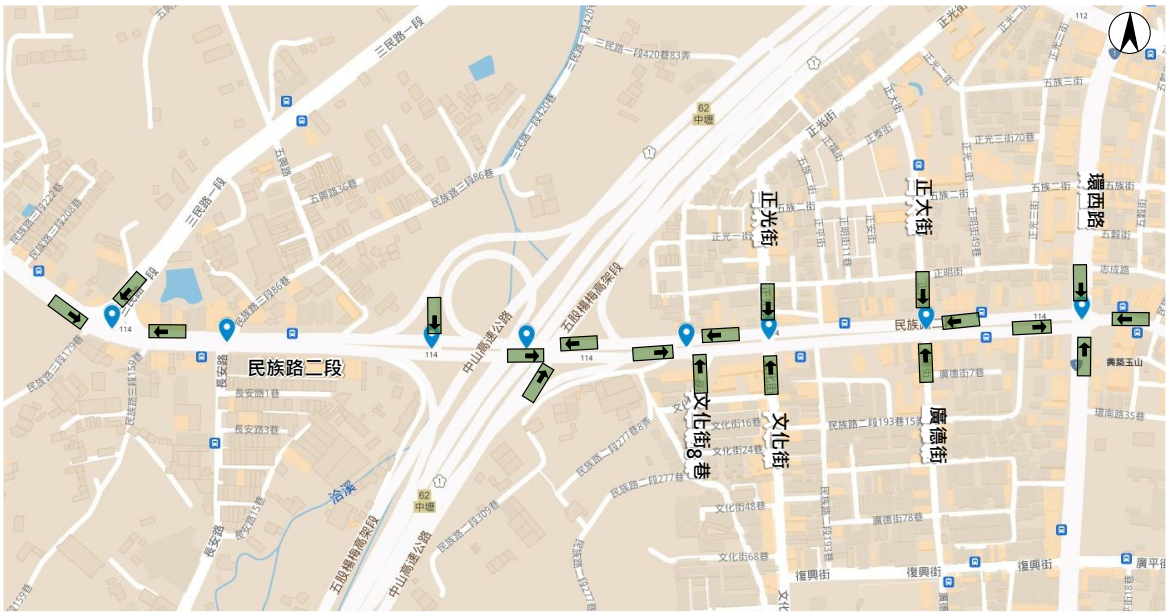


圖 4.3.1-1 中壢交流道平面道路車流偵測設備點位圖

一、驗證計畫

考量本計畫所建置之 AI 號誌控制系統係依據於重要路口車流方向或特定車道(如左轉車道)所佈建之智慧型偵測器即時偵測資料，經由 AI 運算決策即時調整與控制現場號誌運作，因此偵測設備是否可有效辨識物件並提供精確之偵測值極為重要。以各路口為一計算單位，於日夜間共 2 時段錄製 5 分鐘影像，計算車流辨識正確率。表 4.3.1-1 為偵測設備準確度驗證統計。

(一)計算方式

(1-|((各物件人工計數-各物件 AI 計數))/各物件人工計數|)*100%

(二)準確率：小車準確率達 99.19%，大車準確率達 95.43%，不分車種準確率達 97.31%，符合準確率門檻。

表 4.3.1-1 偵測設備準確度驗證

設備編號	日期	日間/夜間	晴天/雨天	小車人工資料	小車AI資料	小車誤差值	大車人工資料	大車AI資料	大車誤差值
S214100-2	113/10/24	日間	雨天	107	107	0.00%	6	4	-50.00%
S214100-2	113/10/24	夜間	雨天	85	85	0.00%	5	5	0.00%
S214100-4	113/10/24	日間	雨天	98	98	0.00%	1	1	0.00%
S214100-4	113/10/24	夜間	雨天	67	66	-1.52%	0	0	0.00%
S214100-6	113/10/24	日間	雨天	109	109	0.00%	6	6	0.00%
S214100-6	113/10/24	夜間	雨天	79	78	-1.28%	4	4	0.00%
S214100-0	113/10/24	日間	雨天	126	124	-1.61%	8	8	0.00%
S214100-0	113/10/24	夜間	雨天	95	95	0.00%	4	4	0.00%
S214000-0	113/10/24	日間	雨天	103	103	0.00%	6	6	0.00%
S214000-0	113/10/24	夜間	雨天	88	86	-2.33%	3	3	0.00%
S214000-4	113/10/24	日間	雨天	96	96	0.00%	0	0	0.00%
S214000-4	113/10/24	夜間	雨天	74	73	-1.37%	1	1	0.00%
S214000-2	113/10/24	日間	雨天	94	94	0.00%	0	0	0.00%
S214000-2	113/10/24	夜間	雨天	65	66	1.52%	0	0	0.00%
S213900-4	113/09/30	日間	晴天	98	98	0.00%	0	0	0.00%
S213900-4	113/09/30	夜間	晴天	73	71	-2.82%	0	0	0.00%
S213900-0	113/09/30	日間	晴天	108	107	-0.93%	6	6	0.00%
S213900-0	113/09/30	夜間	晴天	85	84	-1.19%	3	3	0.00%
S320800-6	113/09/30	日間	晴天	92	92	0.00%	0	0	0.00%
S320800-6	113/09/30	夜間	晴天	89	88	-1.14%	0	0	#DIV/0!
S320800-2	113/09/30	日間	晴天	124	123	-0.81%	8	8	0.00%
S320800-2	113/09/30	夜間	晴天	103	101	-1.98%	4	4	0.00%
S320800-4	113/09/30	日間	晴天	101	100	-1.00%	6	6	0.00%
S320800-4	113/09/30	夜間	晴天	78	78	0.00%	3	3	0.00%
S213700-0	113/10/24	日間	雨天	111	109	-1.83%	3	3	0.00%
S213700-0	113/10/24	夜間	雨天	91	90	-1.11%	2	2	0.00%
S213700-4	113/10/24	日間	雨天	132	131	-0.76%	11	11	0.00%
S213700-4	113/10/24	夜間	雨天	97	99	2.02%	7	7	0.00%
S213700-6	113/10/24	日間	雨天	124	122	-1.64%	13	12	-8.33%
S213700-6	113/10/24	夜間	雨天	98	97	-1.03%	6	6	0.00%
S213600-0	113/10/07	日間	晴天	121	120	-0.83%	6	6	0.00%
S213600-0	113/10/07	夜間	晴天	90	89	-1.12%	3	3	0.00%
S255300-2	113/10/24	日間	雨天	98	98	0.00%	10	8	-25.00%
S255300-2	113/10/24	夜間	雨天	67	66	-1.52%	5	4	-25.00%
S255300-6	113/10/24	日間	雨天	94	94	0.00%	8	8	0.00%
S255300-6	113/10/24	夜間	雨天	73	73	0.00%	5	5	0.00%
S255300-0	113/10/24	日間	雨天	96	96	0.00%	0	0	0.00%
S255300-0	113/10/24	夜間	雨天	67	66	-1.52%	0	0	0.00%

4.3.2 動態模擬測試

延續車流模擬環境及測試，進行 AI 號誌控制模型動態模擬測試，將 AI 號誌控制模型產出之民族路/文化路 8 巷(X4)、民族路/北上匝道(X5)及民族路/南出匝道(X6)對應之平日晨峰(07：00~09：00)、平日離峰(中午 12:30-14:30)及平日昏峰(16：30~19：00)，共 4 個時段之分相秒數與偵測停等車輛數，並須符合前述之合理性及穩定性，說明如下：

一、平日晨峰(07：00~09：00)

(一) 民族路/文化路 8 巷(X4)

各分相秒數與週期之比值分別為：分相一的 0.6、分相二的 0.16 及分相三的 0.24，其斜率分別為-0.001 及 0.0007，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-1 與圖 4.3.2-2 所示。

(二) 民族路/北上匝道(X5)

各分相秒數與週期之比值分別為：分相一的 0.53、分相二的 0.2、分相三的 0.1 及分相四的 0.17，其斜率分別為 0.0032 及 0.0011，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-3 與圖 4.3.2-4 所示。

(三) 民族路/南出匝道(X6)

各分相秒數與週期之比值分別為：分相一的 0.62、分相二的 0.38，其斜率分別為-0.0004 及 0.0013，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-5 與圖 4.3.2-6 所示。

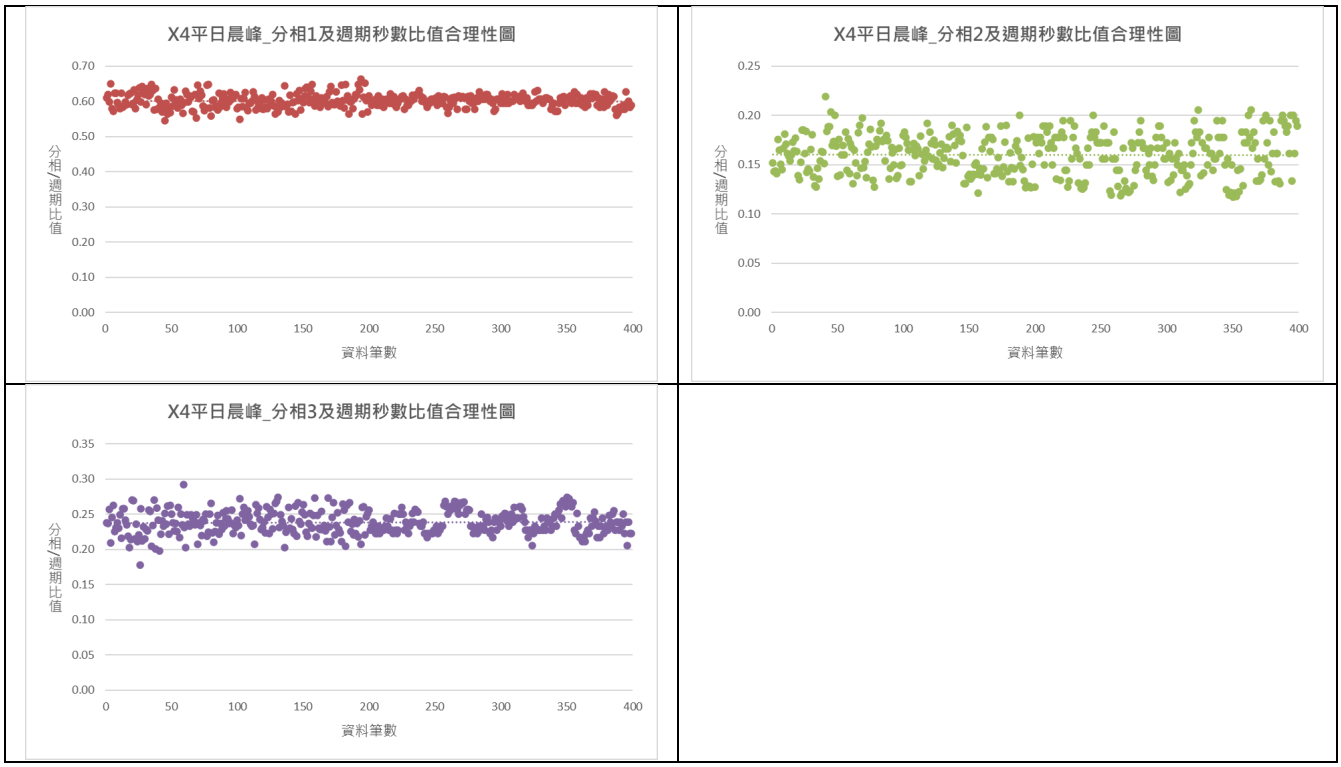


圖 4.3.2-1 民族路/文化路 8 巷(X4)平日晨峰各分相秒數合理性分析圖

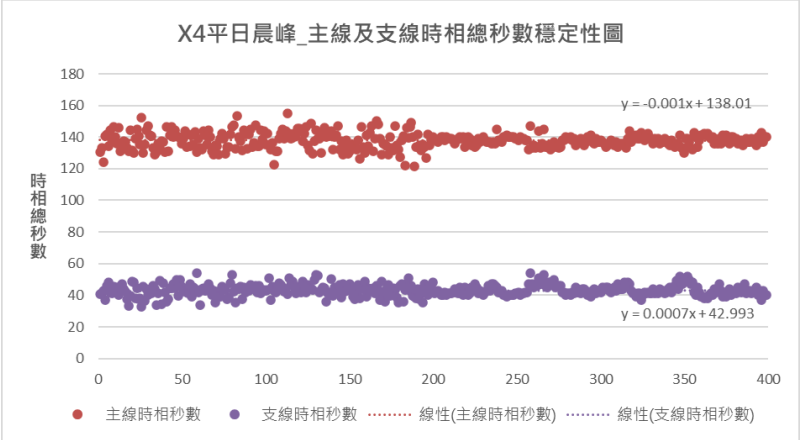


圖 4.3.2-2 路口 X4 平日晨峰主線及支線時相總秒數穩定性圖

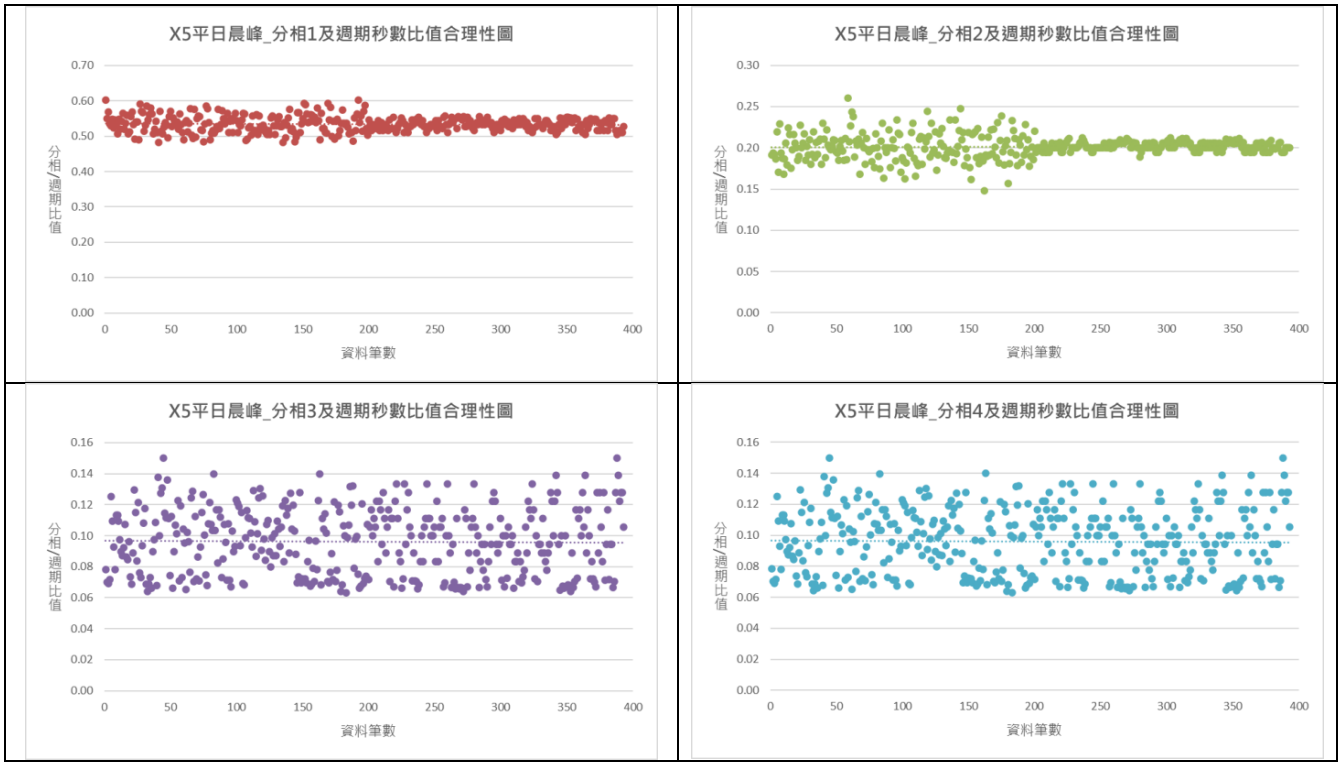


圖 4.3.2-3 民族路/北上匝道(X5)平日晨峰各分相秒數合理性分析圖

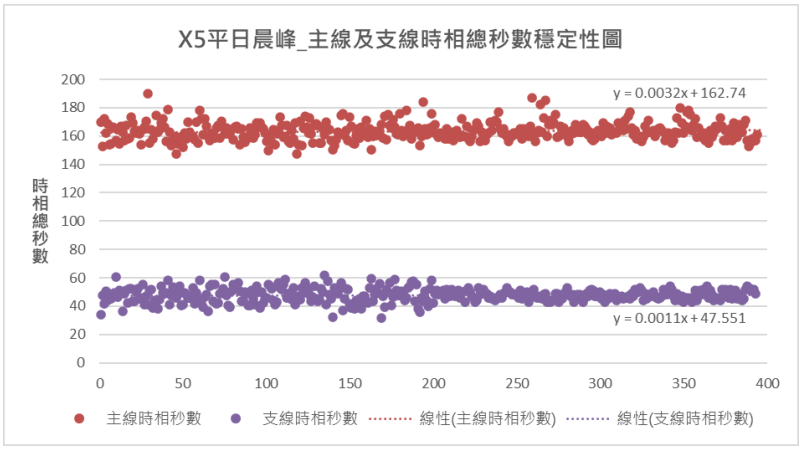


圖 4.3.2-4 路口 X5 平日晨峰主線及支線時相總秒數穩定性圖

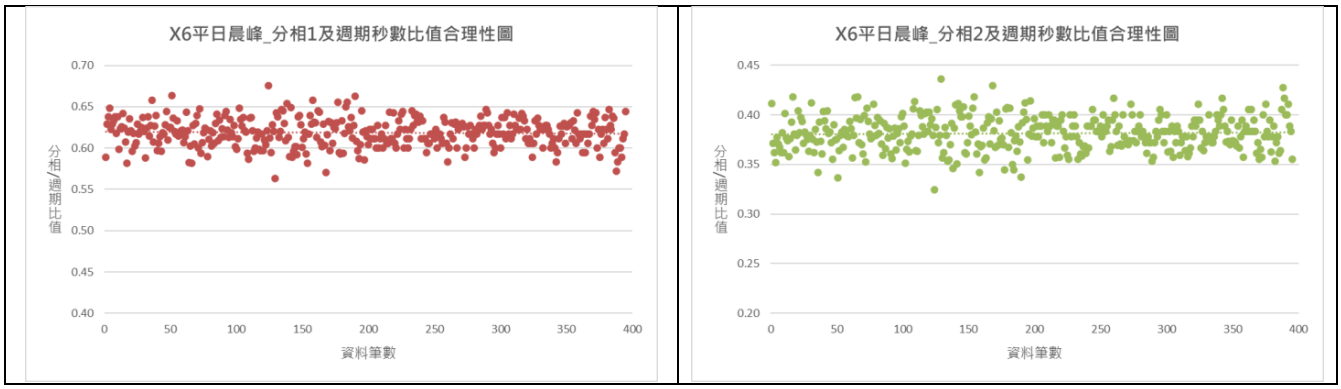


圖 4.3.2-5 民族路/南出匝道(X6)平日晨峰各分相秒數合理性分析圖

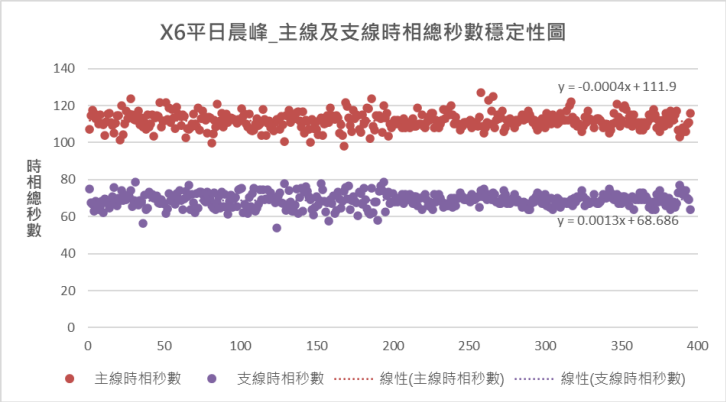


圖 4.3.2-6 路口 X6 平日晨峰主線及支線時相總秒數穩定性圖

二、平日離峰(12：30~14：30)

(一) 民族路/文化路 8 巷(X4)

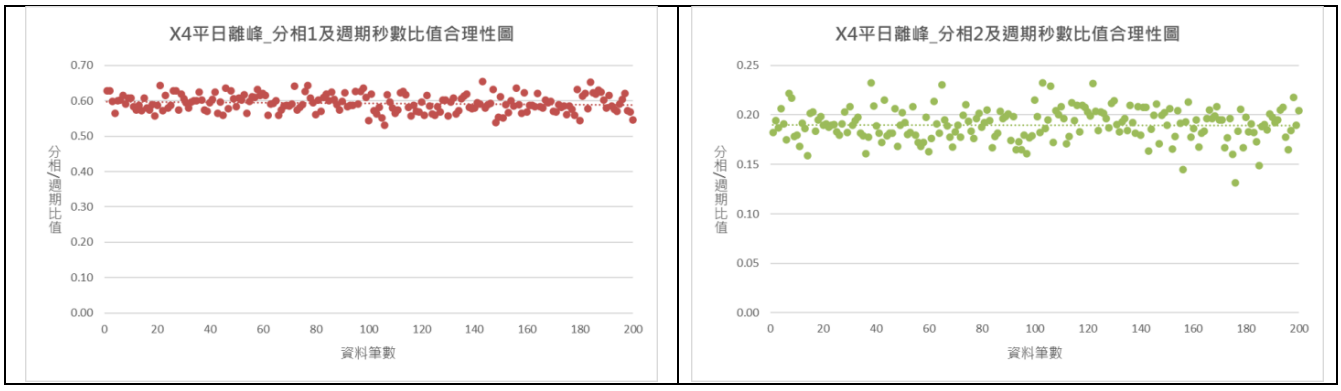
各分相秒數與週期之比值分別為：分相一的 0.59、分相二的 0.19 及分相三的 0.22，其斜率分別為-0.0332 及 0.0014，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-7 與圖 4.3.2-8 所示。

(二) 民族路/北上匝道(X5)

各分相秒數與週期之比值分別為：分相一的 0.51、分相二的 0.2、分相三的 0.13 及分相四的 0.16，其斜率分別為-0.0042 及 0.0019，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-9 與圖 4.3.2-10 所示。

(三) 民族路/南出匝道(X6)

各分相秒數與週期之比值分別為：分相一的 0.58、分相二的 0.42，其斜率分別為-0.0083 及 0.0085，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-11 與圖 4.3.2-12 所示。



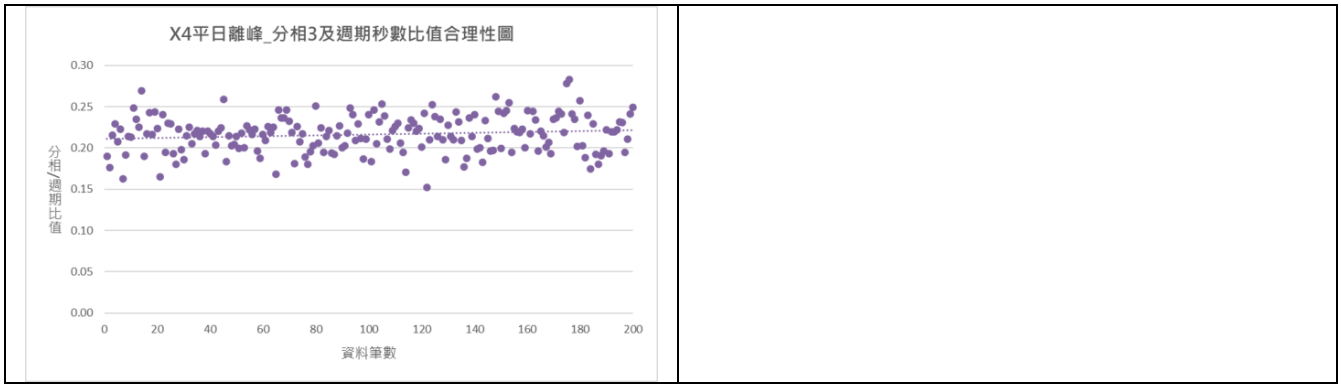


圖 4.3.2-7 民族路/文化路 8 巷(X4)平日離峰各分相秒數合理性分析圖

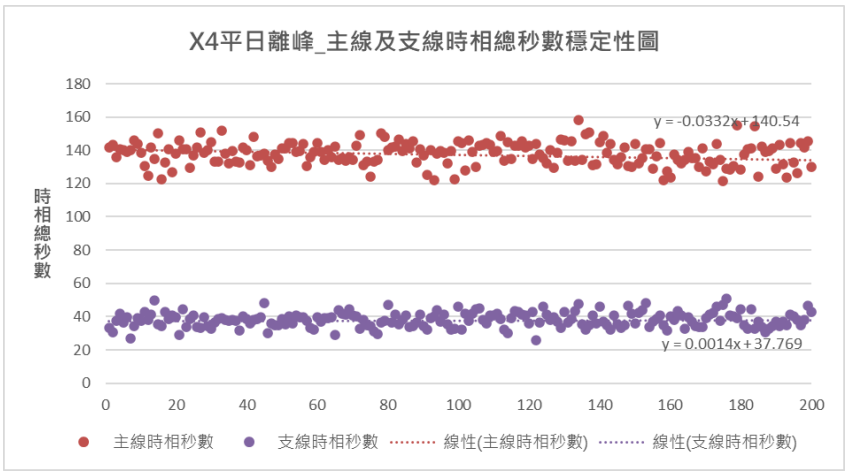


圖 4.3.2-8 路口 X4 平日離峰主線及支線時相總秒數穩定性圖

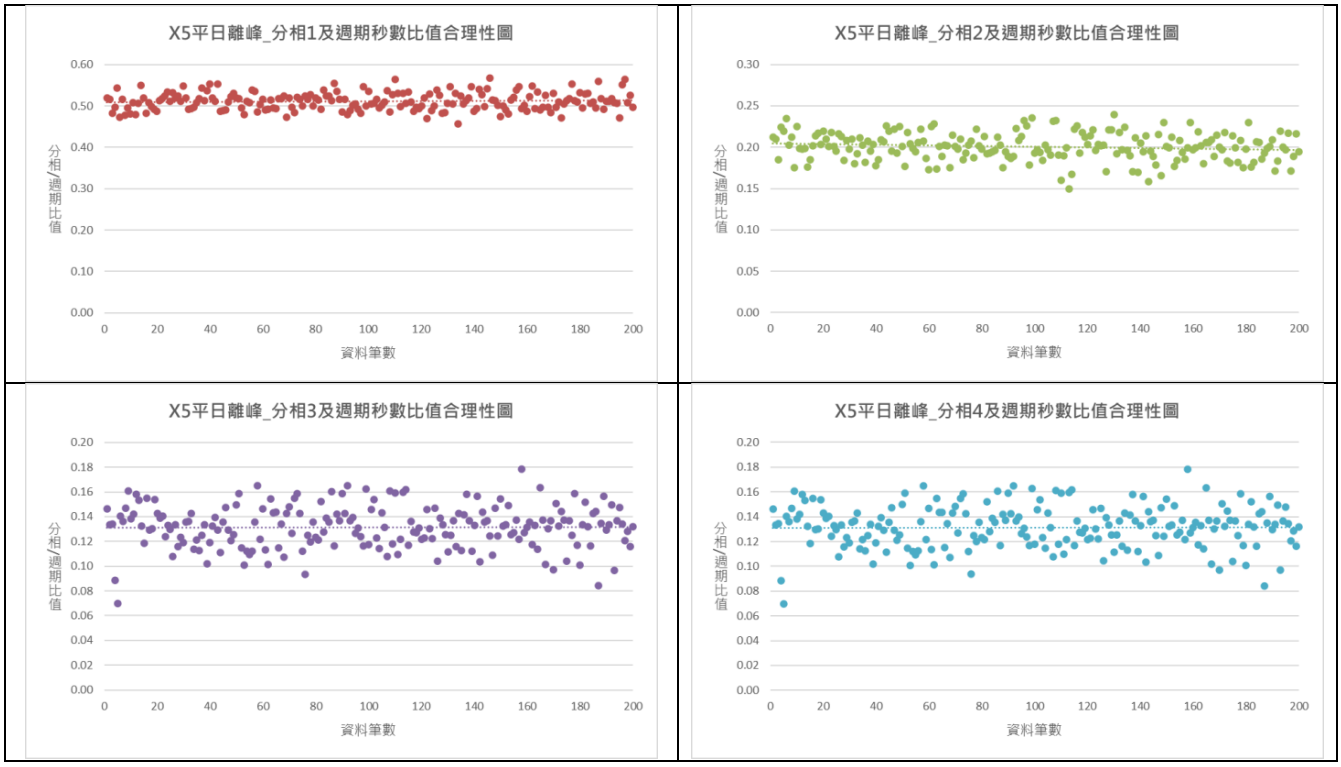


圖 4.3.2-9 民族路/北上匝道(X5)平日離峰各分相秒數合理性分析圖

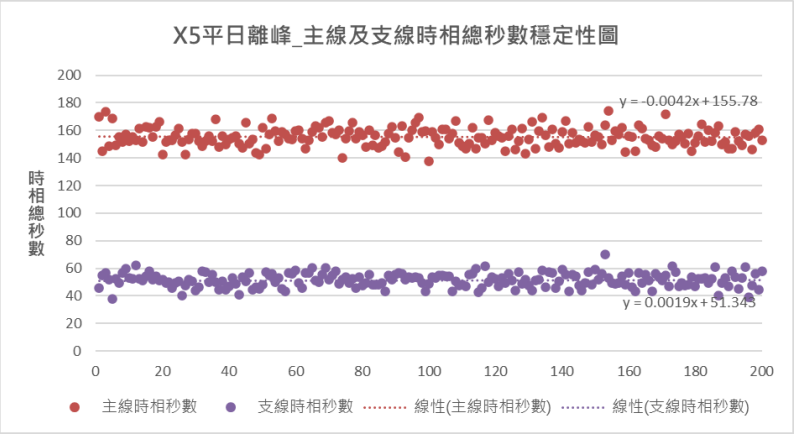


圖 4.3.2-10 路口 X5 平日離峰主線及支線時相總秒數穩定性圖

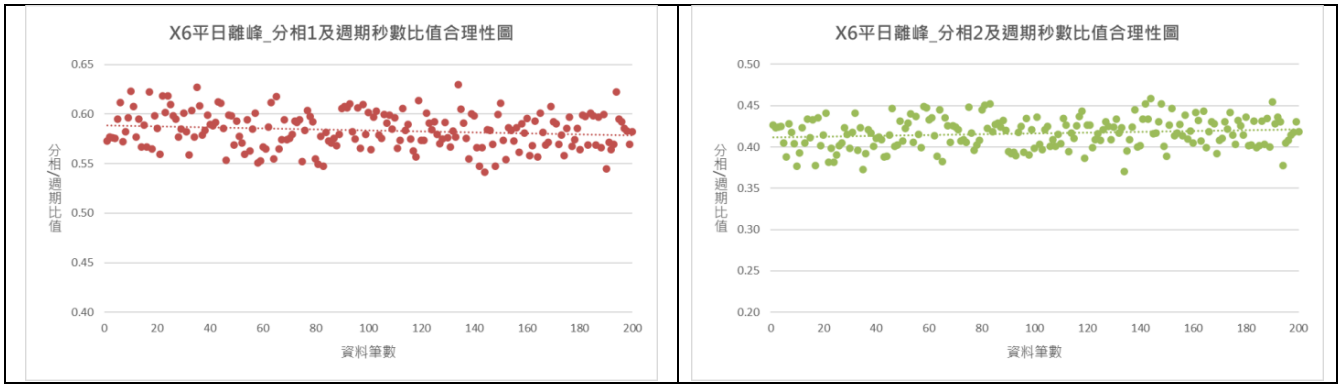


圖 4.3.2-11 民族路/南出匝道(X6)平日離峰各分相秒數合理性分析圖

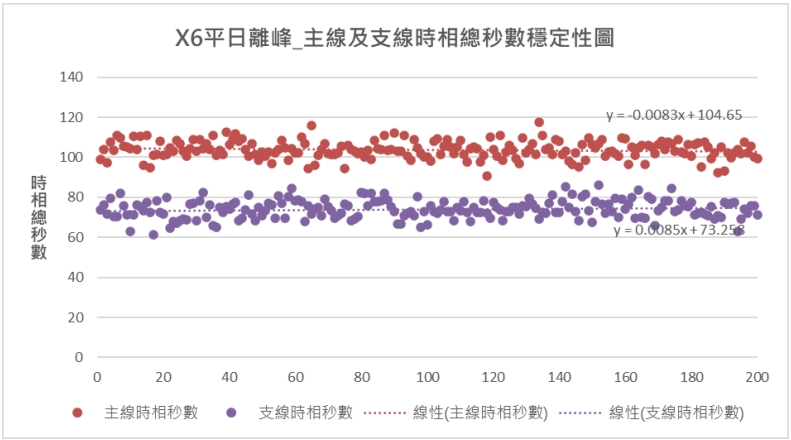


圖 4.3.2-12 路口 X6 平日離峰主線及支線時相總秒數穩定性圖

三、平日昏峰(16：30~18：30)

(一) 民族路/文化路 8 巷(X4)

各分相秒數與週期之比值分別為：分相一的 0.59、分相二的 0.19 及分相三的 0.22，其斜率分別為-0.0002 及 0.00007，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-13 與圖 4.3.2-14 所示。

(二) 民族路/北上匝道(X5)

各分相秒數與週期之比值分別為：分相一的 0.52、分相二的 0.2、分相三的 0.12 及分相四的 0.16，其斜率分別為-0.0025 及 0.0043，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-15 與圖 4.3.2-16 所示。

(三) 民族路/南出匝道(X6)

各分相秒數與週期之比值分別為：分相一的 0.6、分相二的 0.4，其斜率分別為 0.0006 及 0.00 案，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-17 與圖 4.3.2-18 所示。

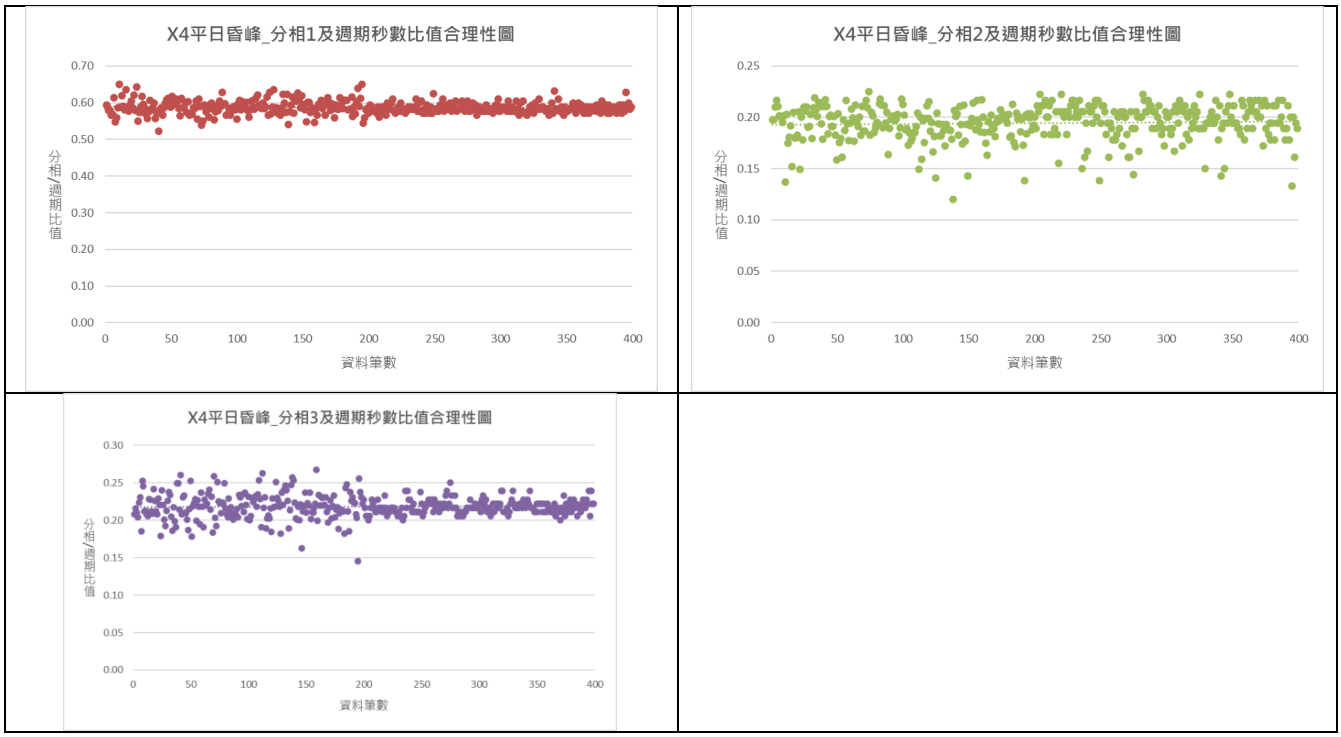


圖 4.3.2-13 民族路/文化路 8 巷(X4)平日昏峰各分相秒數合理性分析圖

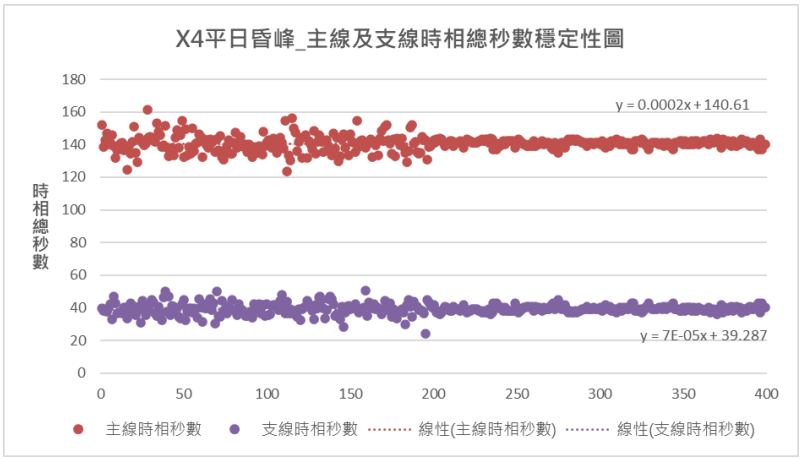


圖 4.3.2-14 路口 X4 平日昏峰主線及支線時相總秒數穩定性圖

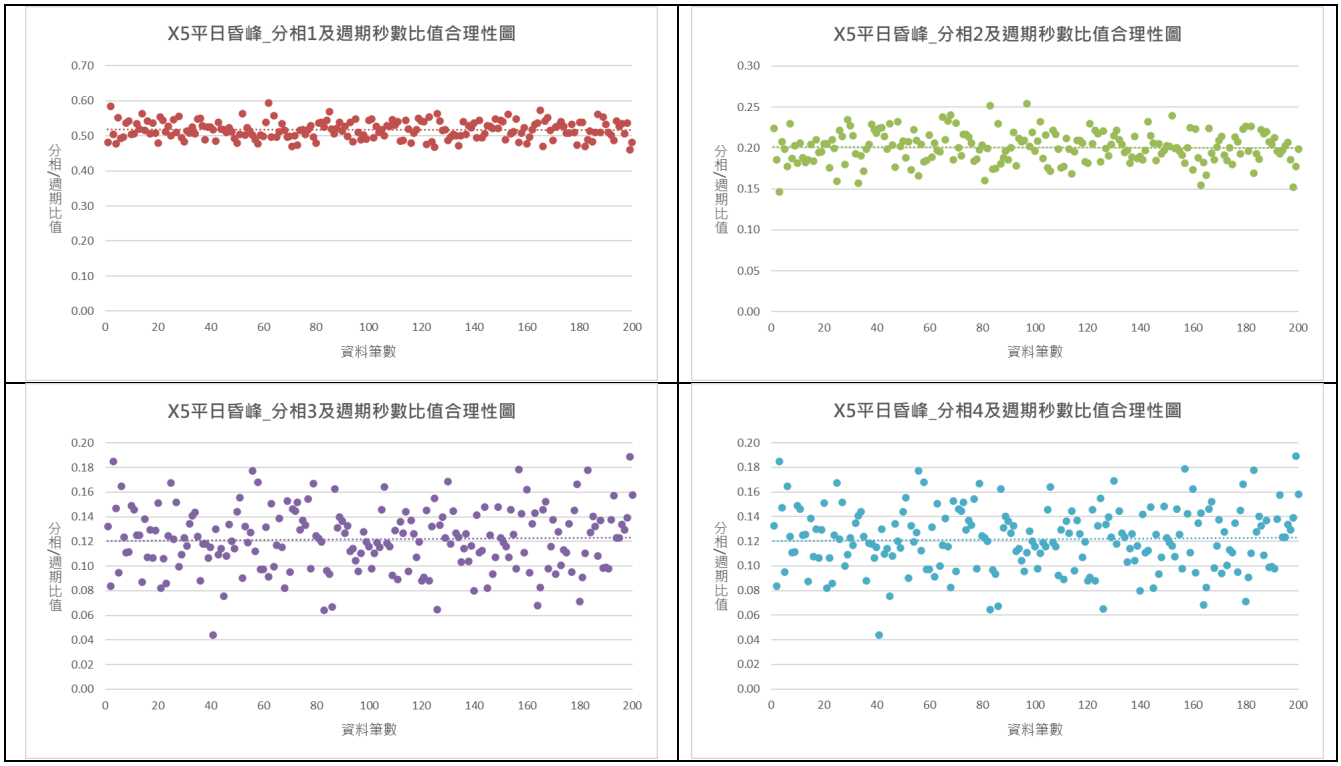


圖 4.3.2-15 民族路/北上匝道(X5)平日昏峰各分相秒數合理性分析圖

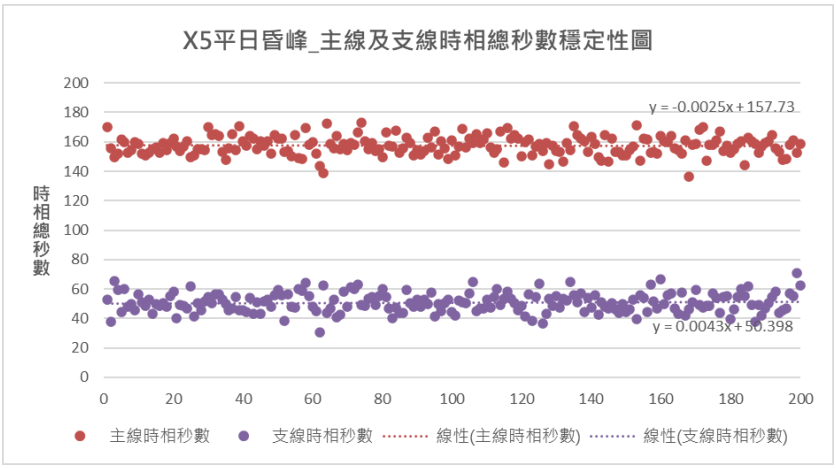


圖 4.3.2-16 路口 X5 平日昏峰主線及支線時相總秒數穩定性圖

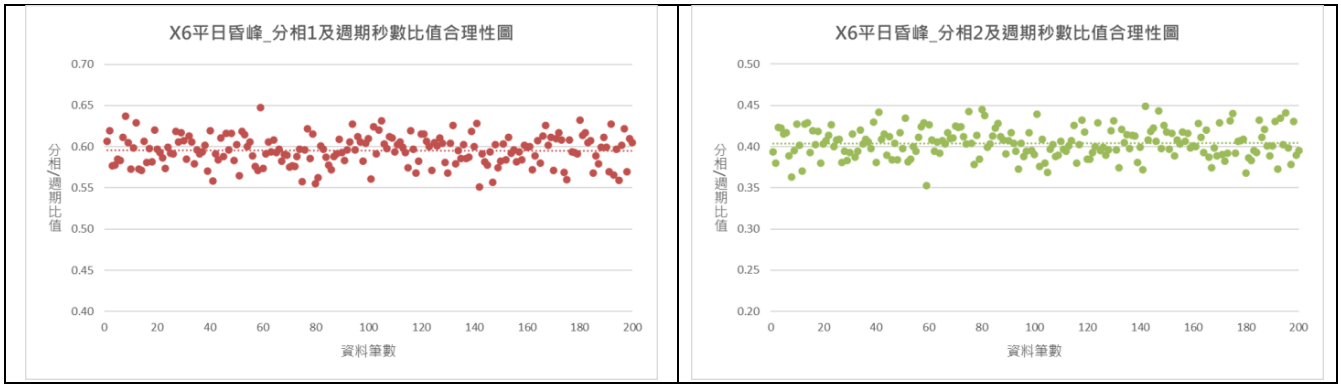


圖 4.3.2-17 民族路/南出匝道(X6)平日昏峰各分相秒數合理性分析圖

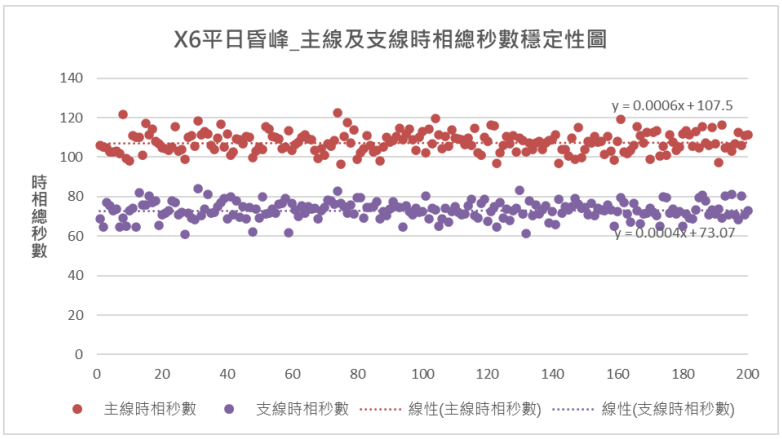


圖 4.3.2-18 路口 X6 平日昏峰主線及支線時相總秒數穩定性圖

四、假日昏峰(16：30~18：30)

(一) 民族路/文化路 8 巷(X4)

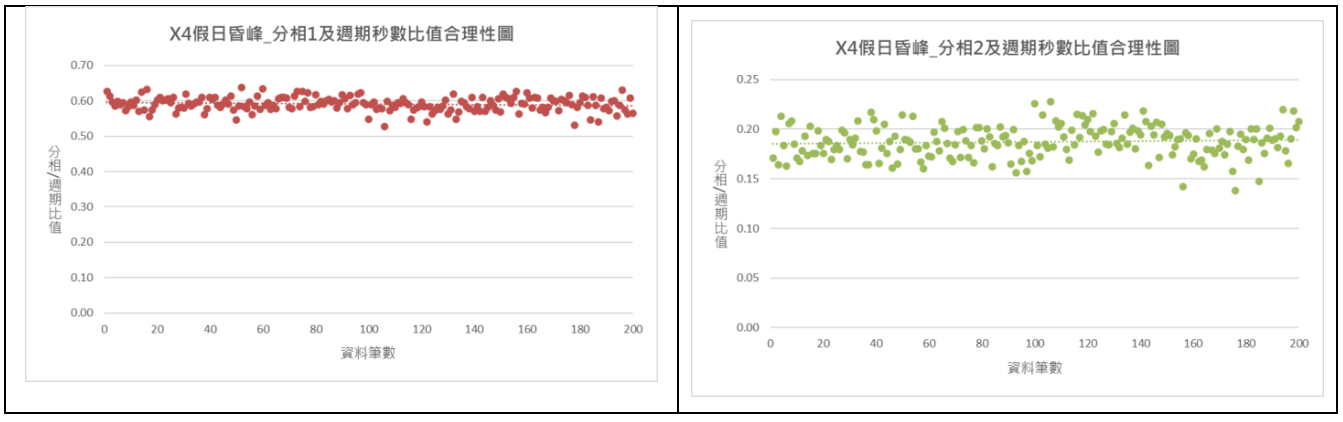
各分相秒數與週期之比值分別為：分相一的 0.59、分相二的 0.19 及分相三的 0.22 其斜率分別為-0.0446 及-0.0071，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-19 與圖 4.3.2-20 所示。

(二) 民族路/北上匝道(X5)

各分相秒數與週期之比值分別為：分相一的 0.55、分相二的 0.19、分相三的 0.11 及分相四的 0.15，其斜率分別為-0.029 及-0.0149，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-21 與圖 4.3.2-22 所示。

(三) 民族路/南出匝道(X6)

各分相秒數與週期之比值分別為:分相一的 0.6、分相二的 0.4，其斜率分別為-0.0026 及 0.0044，顯見每筆動態模擬資料對 Y 的影響極小，趨於穩定，如圖 4.3.2-23 與圖 4.3.2-24 所示。



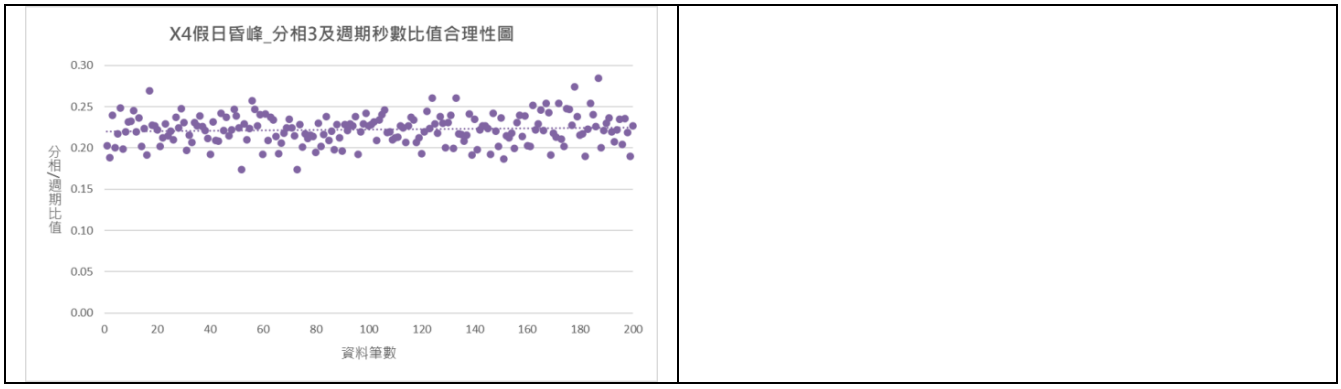


圖 4.3.2-19 民族路/文化路 8 巷(X4)假日昏峰各分相秒數合理性分析圖

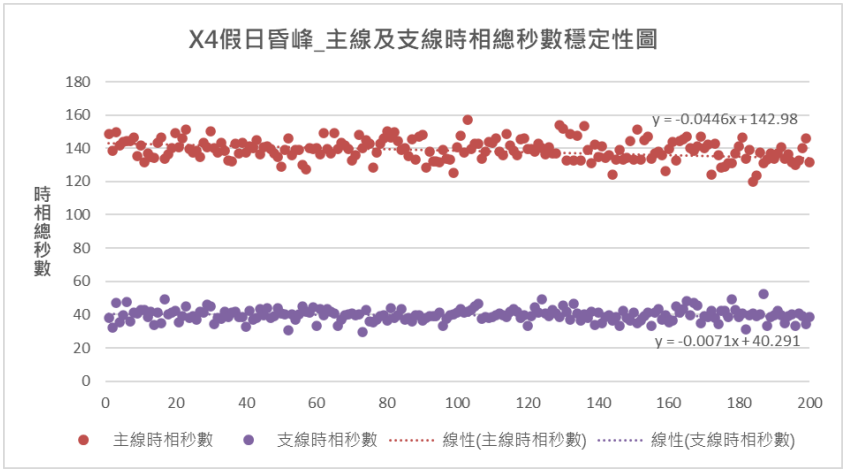


圖 4.3.2-20 路口 X4 假日昏峰主線及支線時相總秒數穩定性圖

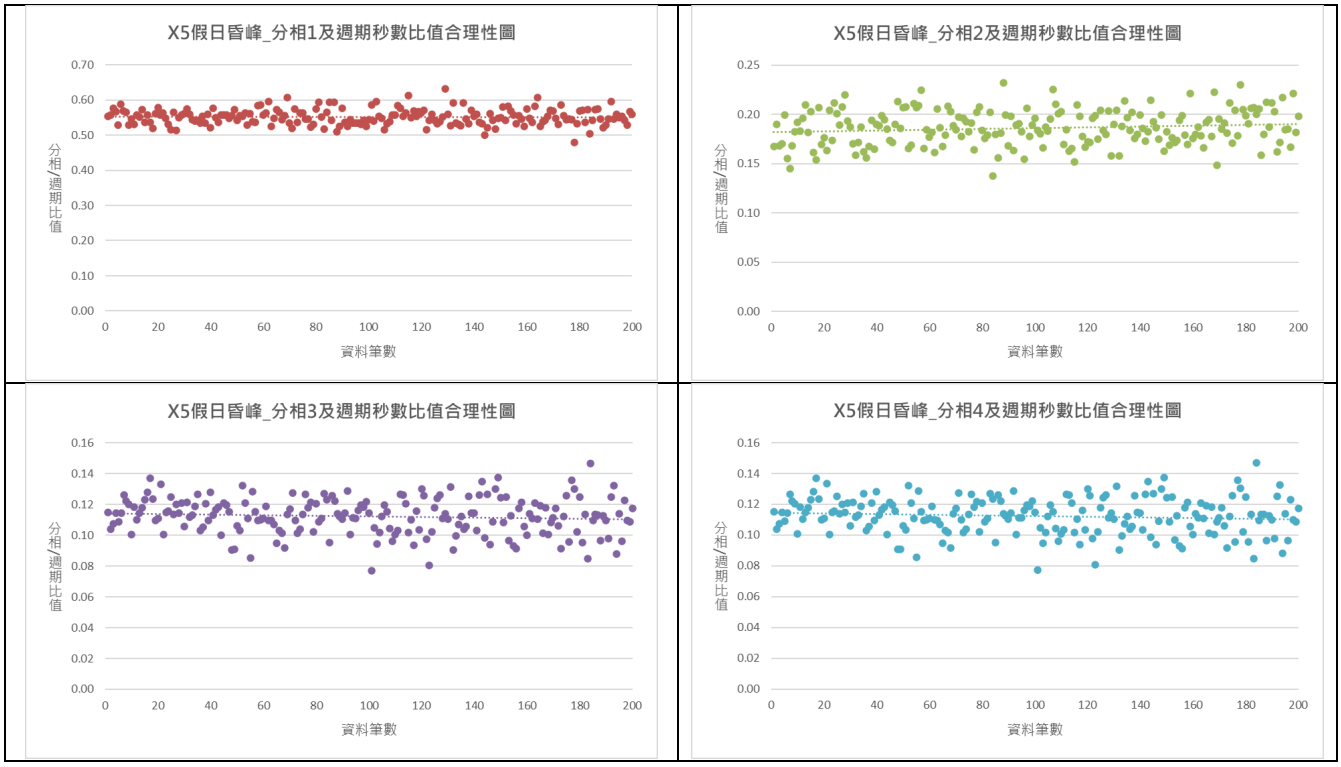


圖 4.3.2-21 民族路/北上匝道(X5)假日昏峰各分相秒數合理性分析圖

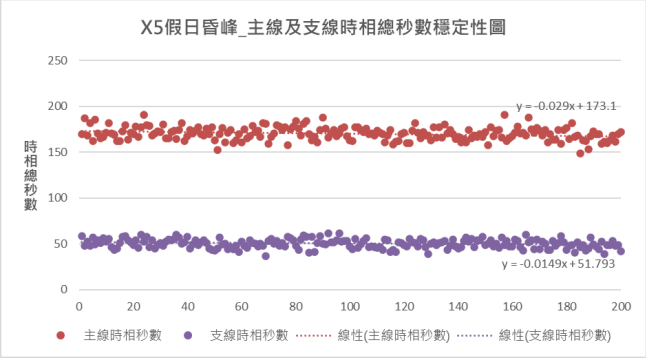


圖 4.3.2-22 路口 X5 假日昏峰主線及支線時相總秒數穩定性圖

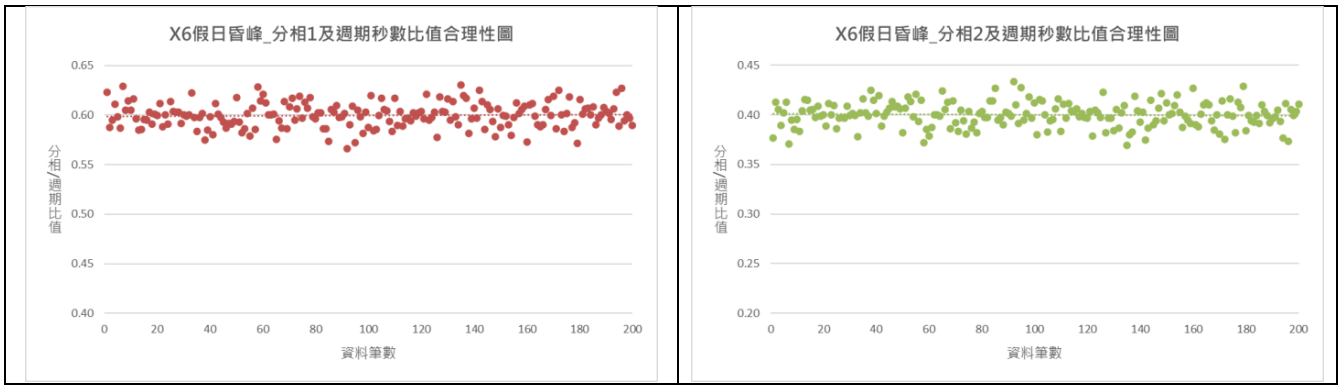


圖 4.3.2-23 民族路/南出匝道(X6)假日昏峰各分相秒數合理性分析圖

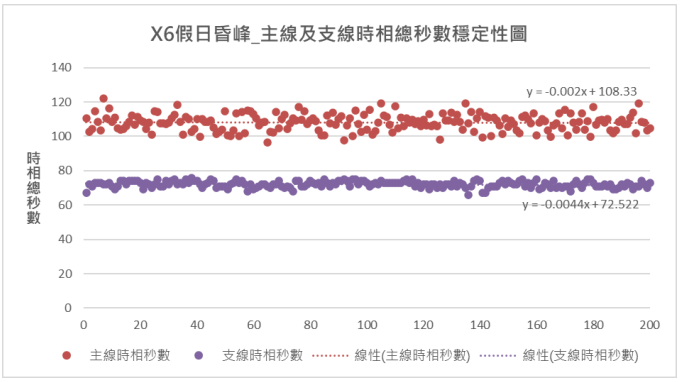


圖 4.3.2-24 路口 X6 假日昏峰主線及支線時相總秒數穩定性圖

4.3.3 號誌控制核心運作模組與監控介面

透過人工智慧強化學習號誌控制核心運作模組，連結整合現場設備、縣市交通控制中心、高速公路局 Open data 與 AI 號誌控制模型，將運作績效儲存於資料庫中，提供運作狀態監控畫面，呈現即時路口狀況。

一、整體架構

人工智慧強化學習號誌控制系統整體架構如圖 4.3.3-1 所示，首先取得路口相關設備(如 TC、VD)運作數據，將收集到的資料傳送給 AI 號誌控制模型做運算，AI 號誌控制模型會即時將計算結果回傳，平面道路路口將依照結果調整時制計畫並傳送給號誌控制器，匝道儀控

計算結果將於監控畫面呈現，由高速公路局值班台人員定時檢視並手動下達指令，即時運作狀態與路口績效可透過實測監控畫面掌握。線下 AI 號誌控制模組則會定時做訓練，將最新的訓練結果傳送給線上 AI 號誌決策模組使用。

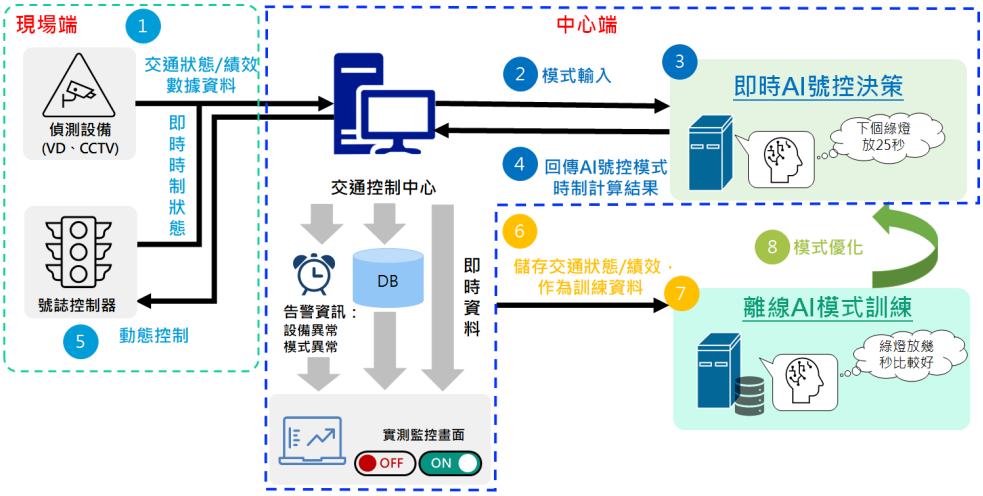


圖 4.3.3-1 號誌控制核心運作模組架構

平面道路之智慧號誌控制系統的執行流程如圖 4.3.3-2 所示，首先會定時取得設備資料，如車輛偵測器分車道、車種與每秒之車輛數等，或是號誌控制器目前執行的時制計畫、時相及剩餘秒數。下一步驗證資料有無缺漏，當資料有所缺漏時會自動帶入原時制計畫秒數，避免現場因降階運轉之補償機制導致交通壅塞。若資料無缺漏，系統將再確認群組內控制器是否正常連線，緊接查看目前號制分相是否進入清道時間，若進入清道時間則呼叫線上 AI 決策模組，計算下個週期或分相秒數，最後將秒數傳送至控制器執行。

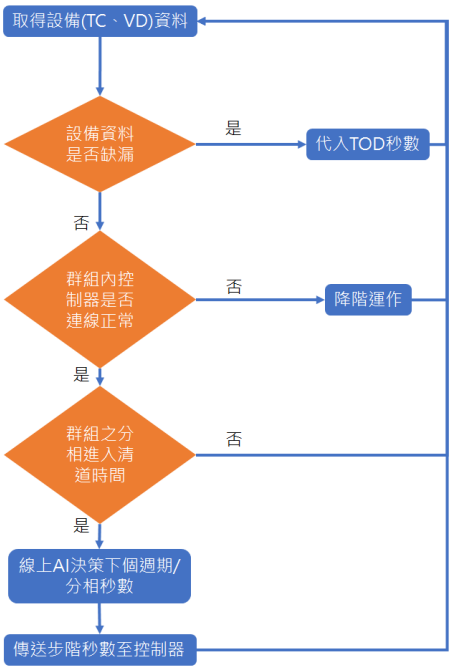


圖 4.3.3-2 AI 智慧號誌控制系統執行流程

二、資料串接架構

AI 號誌控制模型核心控制模組透過即時串流與 Internet 取得所需之平面道路、高速公路道路與號誌資料，將其儲存於資料庫中並進行運算，平面道路路口之運算結果經由交控系統直接下達號誌控制器，匝道秒數則經由監控畫面提供高速公路局值班台人員查詢並人工進行儀控。其資料串接架構規劃如圖 4.3.3-3 所示。

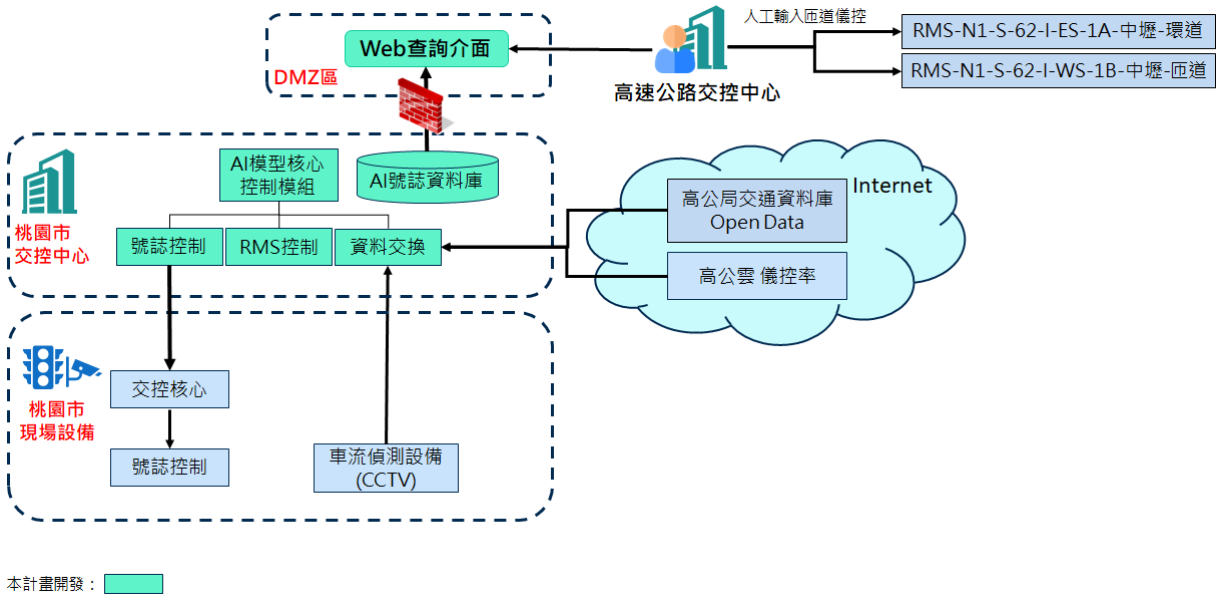


圖 4.3.3-3 資料串接架構

三、實測監控畫面

實測監控畫面左下角顯示設備運作狀態，可一覽有無設備斷線，左上角呈現 AI 影像辨識 CCTV 偵測之即時路口流量與停等秒數，右下角提供高速公路局匝道儀控建議，高速公路交控中心值班台人員查詢後可依實際需求決定是否下達指令，並於畫面點選確認、取消供執行團隊後續分析使用，系統畫面如圖 4.3.3-4 所示。

GIS 地圖為主，使用圖層呈現實測路口之號誌控制器、匝道儀控、高速公路 eTag、高速公路車流偵測設備、平面道路 CCTV 即時影像，各圖層說明如下。

(一)平面道路號誌控制器：呈現路口即時燈態與當下之時制計畫，實測中可由現場綠燈秒數得知 AI 號誌控制模型計算秒數是否下達號誌控制器。

(二)匝道儀控：呈現當下執行之儀控率與秒數。

(三)高速公路 eTag：呈現不分車道、車種之通過量以及高速公路即時路況。

(四)高速公路車流偵測設備：呈現不分車道、車種之速度。

(五)平面道路 CCTV 即時影像：點選可查看路口即時影像。



圖 4.3.3-4 中壢交流道實驗場域實測監控畫面

4.3.4 實測計畫與歷程

4.3.4.1 實測計畫

一、實測日期

由於現行中壢交流道僅有週六及連續假日進行南下匝道儀控，考量不影響既有高速公路局實務情況下，排除連續假日情形，以週六假日昏峰進行至少一次實測，實測日期定為平日 11 月 25 日(一)、11 月 26 日(二)及假日 11 月 24 日(日)。

二、實測時段

(一)平日上午尖峰：07：00 至 09：00。

(二)平日下午離峰：12：30 至 14：30。

(三)平日下午尖峰：16：30 至 18：30。

(四)假日尖峰：16：30 至 18：30。

三、實測地點

桃園市中壢交流道周邊八處路口與南下匝道儀控。

四、實測指標

(一)停等延滯：使用 GVP 資料進行推估。

(二)旅行時間：使用 GVP 資料進行推估。

五、實測流程操作方式如以下設定內容：

(一)設定人工智慧號誌控制排程

1.進入智慧號誌控制監控管理畫面，點選系統管理。

2.設定排程開始與結束之日期、時間、週期後點選確認。

3.於排程預覽確認欲設定之排程，確認無誤點選儲存。

(二)手動開啟/關閉

1.進入智慧號誌控制監控管理畫面，點選系統管理。

2.於號誌控制即時運作狀態點選「是否手動開關」，即可開啟、關閉人工智慧號誌控制。

六、監控方式

為掌握掌握系統運作狀況，實測初期將安排人力於現場觀察，確保號誌運作正常且不造成路況異常或惡化，同時安排人員監控管理畫面，監控內容與時程安排如下：

(一) 監看現場設備運作狀態，確認是否有設備斷線。

(二) 確認系統是否正常運作，若人工智慧號誌控制運作異常則回復原 TOD 控制。

(三) 確認人工智慧號誌控制指令是否有下達至現場號誌。

七、例外事件

號誌控制模組於實測期間持續偵測表 4.3.4-1 之例外事件，當例外事件發生時將自動降階恢復原固定時制計畫，避免因號誌控制導致現場交通狀況混亂之情形。

表 4.3.4-1 實測例外事件一覽表

事件類型	狀態描述	因應方式
現場號誌閃光	現場號誌為綠衝突或時制閃光。	恢復原固定時制計畫，待號誌恢復，由人工智慧號誌控制重新取得控制權。
現場控燈	現場有人員直接手動進行號誌控制。	恢復原固定時制計畫，待現場控燈結束後，人工智慧號誌控制重新取得控制權。
號誌控制器斷線	號誌控制器斷線，導致人工智慧號誌控制指令無法下達。	恢復原固定時制計畫，待號誌控制器恢復連線，再由人工智慧號誌控制取得控制權。
號誌控制器異常	號誌控制器異常，無法正常執行步階秒數。	恢復原固定時制計畫，待異常排除，再由人工智慧號誌控制取得控制權。

(一) 自動降階執行流程

1.暫停人工智慧號誌控制系統。

2.恢復原固定時制計畫。

3.2 個週期後轉換至原固定時制計畫，轉換期間由號誌控制器依當下狀況自行運算進行秒數補償。

(二)人工智慧號誌控制重新取得控制權流程

1.系統偵測例外事件結束。

2 恢復人工智慧號誌控制。

3.轉換需 2 個週期，期間現場號誌依固定時制計畫運作。

4.3.4.2 實測歷程

一、平日

(一)11 月 25 日(一)：觀察現場車流狀況順暢，皆可於一週期紓解完成，無特殊情形。

(二)11 月 26 日(二)：晨峰約七點開始進入車流量高峰，各方向皆須兩週期紓解，民族路二段路口不淨空導致環南路車輛無法左轉，八點後車流量漸緩，除民族路二段及環南路左轉車流仍需兩週期紓解外，其餘方向車輛可於一個週期順利通過。

二、假日

(一)11 月 24 日(日)：觀察民族路二段東向車多但可於一週期內紓解完成，民族路二段左轉環西路車陣會到廣德街(如圖 4.3.4.2-1)；環南路車隊約排隊到環南路 35 巷前後；民族路車隊最多到民族路 310 巷；環西路車隊終點最多不超過五族街。

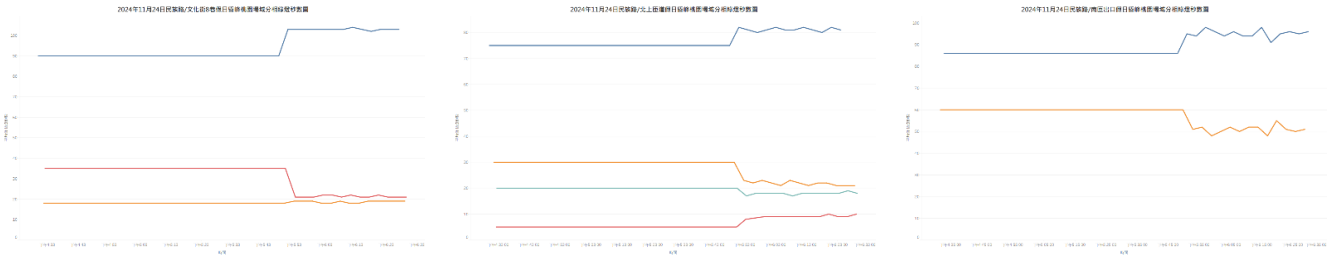


圖 4.3.4.2-1 民族路二段昏峰現場車流狀況

4.3.5 事前事後量化績效評估

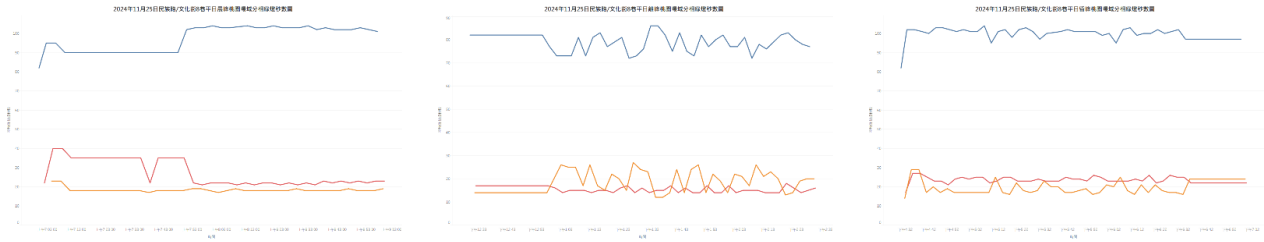
一、實測路口分相秒數變化

為逐時相決策分相綠燈秒數，考量當下運行時相編號與該時相剩餘秒數，以及各分相結束時各車種轉向量，判斷下一個分相 AI 控制路口之綠燈秒數。圖 4.3.5-1 至圖 4.3.5-10 為民族路/文化街 8 巷、民族路/北上匝道、民族路/南出匝道在不同實測日期與時段之各分相綠燈秒數趨勢圖。



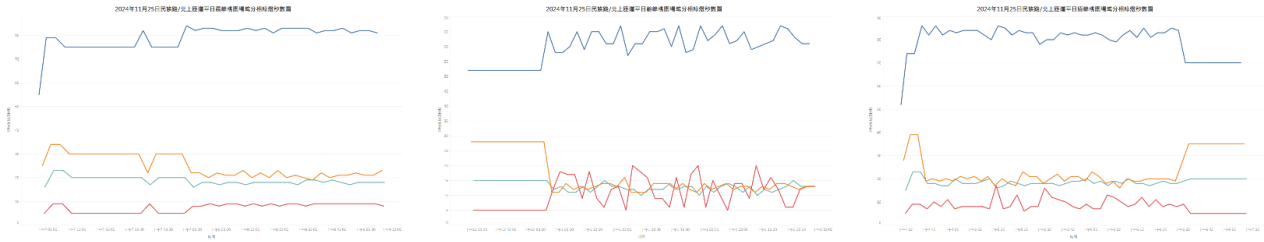
民族路/文化街 8 巷　　民族路/北上匝道　　民族路/南出匝道

圖 4.3.5-1 11/24(日)桃園市實驗場域 3 處路口實測各分相綠燈秒數趨勢圖



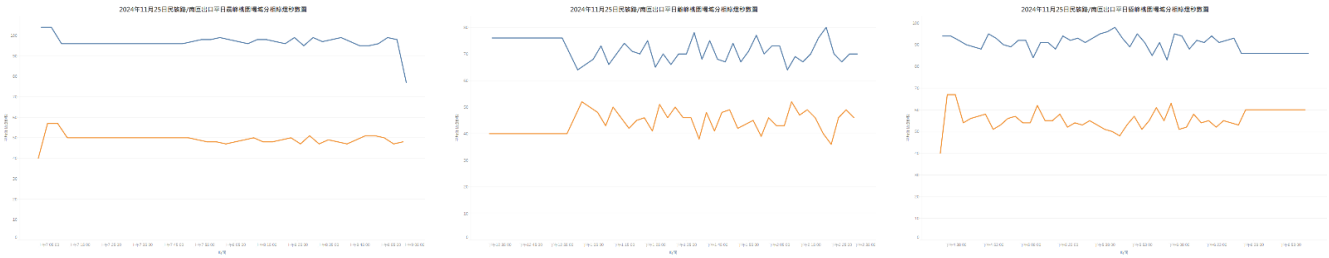
晨峰　　離峰　　昏峰

圖 4.3.5-2 11/25(一)桃園市實驗場域民族路/文化街 8 巷實測各分相綠燈秒數趨勢圖



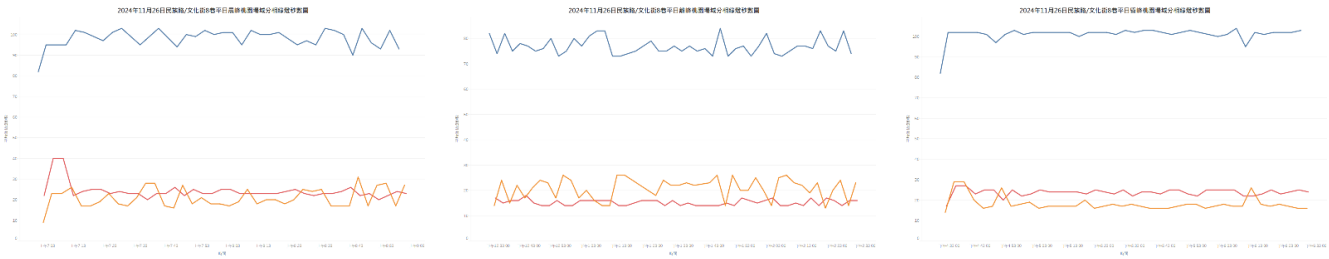
晨峰　　離峰　　昏峰

圖 4.3.5-3 11/25(一)桃園市實驗場域民族路/北上匝道實測各分相綠燈秒數趨勢圖



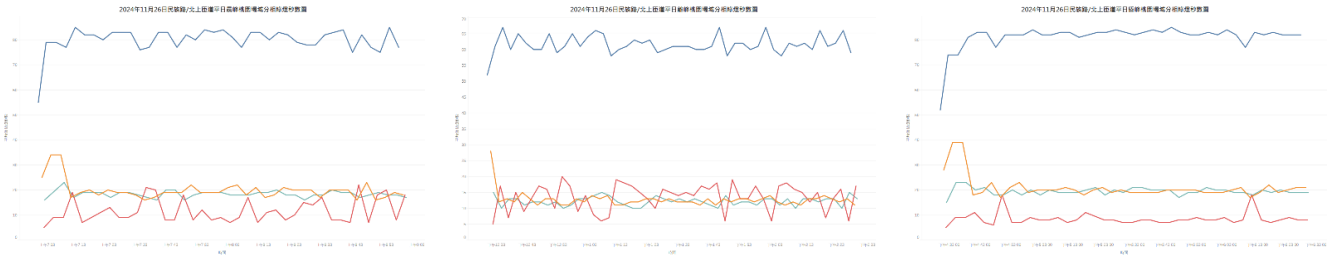
晨峰　　離峰　　昏峰

圖 4.3.5-4 11/25(一)桃園市實驗場域民族路/南出匝道實測各分相綠燈秒數趨勢圖



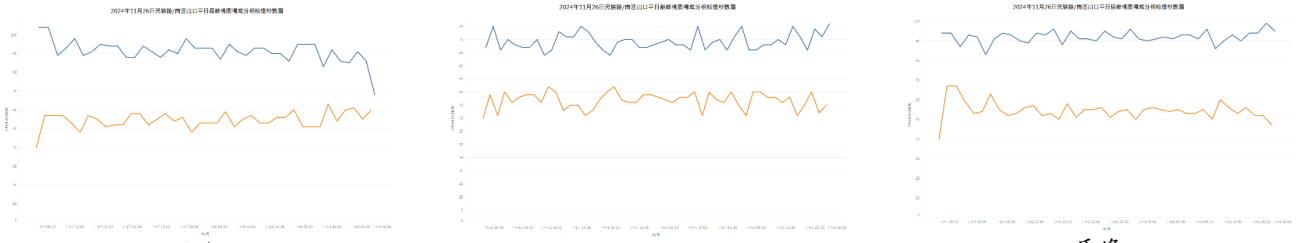
晨峰　　離峰　　昏峰

圖 4.3.5-5 11/26(二)桃園市實驗場域民族路/文化街 8 巷實測各分相綠燈秒數趨勢圖



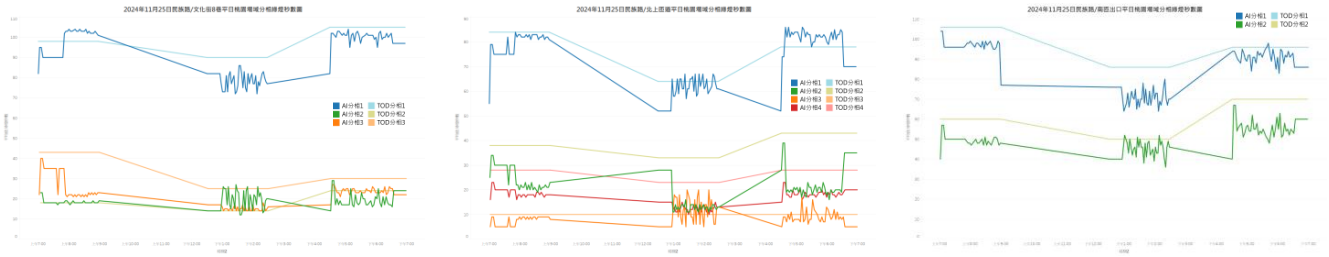
晨峰　　離峰　　昏峰

圖 4.3.5-6 11/26(二)桃園市實驗場域民族路/北上匝道實測各分相綠燈秒數趨勢圖



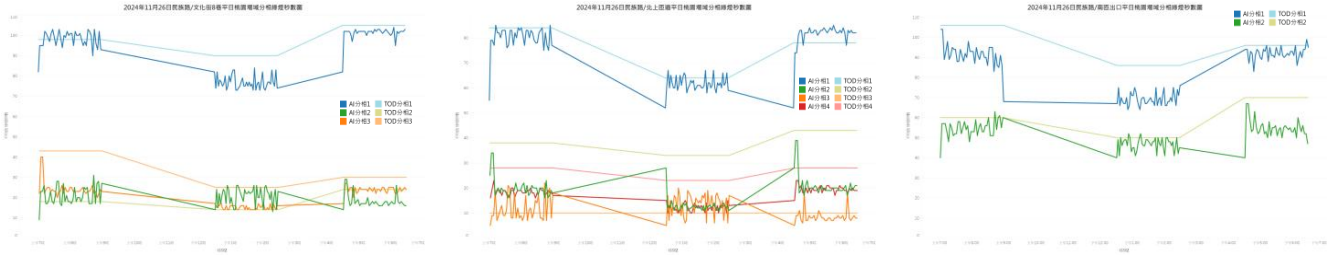
晨峰　　離峰　　昏峰

圖 4.3.5-7 11/26(二)桃園市實驗場域民族路/南出匝道實測各分相綠燈秒數趨勢圖



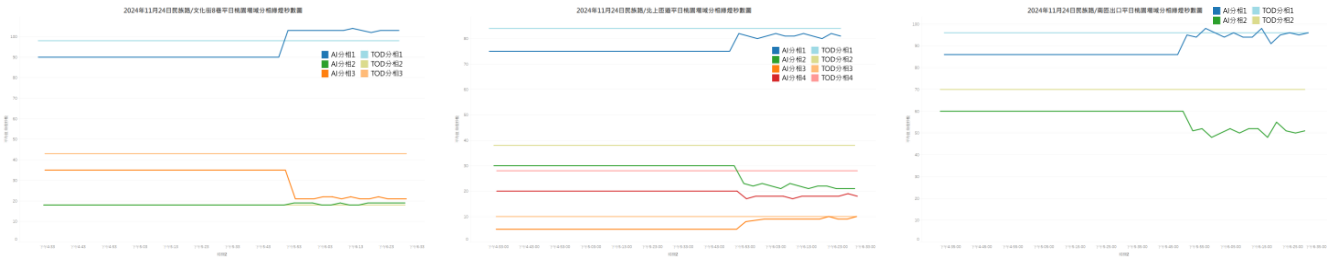
民族路/文化街 8 巷　　民族路/北上匝道　　民族路/南出匝道

圖 4.3.5-8 11/25(一)桃園市實驗場域 AI 實測與 TOD 各分相綠燈秒數比較



民族路/文化街 8 巷　　民族路/北上匝道　　民族路/南出匝道

圖 4.3.5-9 11/26(二)桃園市實驗場域 AI 實測與 TOD 各分相綠燈秒數比較



民族路/文化街 8 巷　　民族路/北上匝道　　民族路/南出匝道

圖 4.3.5-10 11/24(日)桃園市實驗場域 AI 實測與 TOD 各分相綠燈秒數比較

二、路口平均延滯績效

本場域蒐集各臨近路口各方向路段之 GVP 資料，進而推估各臨近路口之路段於 AI 號誌控制前後之延滯表現，具體作法為當車輛駛離上游路口進入目標路段時，其行駛速率會有一段距離不受路口號誌及停等車隊影響，僅受車流影響，且若維持此速率將可順利通過停止線；而實際受號誌影響後通過停止線的時間落差即為號誌帶給車流的整體影響(包含減速、停等、再啟動加速之延滯等)，實測路口延滯績效表現說明如下。

(一) 11 月 24 日(日)AI 實測與 11 月 17 日(日)TOD 績效表現(如表 4.3.5-1 所示)

1. 民族路/文化街 8 巷假日昏峰路口整體延滯略增加 2.1 秒，服務水準皆維持 C 級。

2. 民族路/北上匝道假日昏峰路口整體延滯略增加 6.0 秒，服務水準維持 B 級。

3. 民族路/南出匝道假日昏峰路口整體延滯略減少 1.5 秒，改善約 24.7%。

表 4.3.5-1 假日 11/24(日)AI 號誌控制與 11/17(日)TOD 路口延滯績效

	路口	時間	方向	平均延滯(秒)	服務水準	路口整體延滯	較事前改善程度(%)
11/24 (日) AI實測	民族路/文化街8巷	假日下午尖峰 1630~1830	←	44.0	C	40.4	-5.7%
			↑	35.1	C		
			→	34.9	C		
			↓	66.7	E	C	
	民族路/北上匝道		←	17.2	B	21.4	3.3%
			↑	53.1	D		
			→	10.8	A		
			↓	-	-	B	
	民族路/南出匝道		←	10.3	A	11.8	-22.8%
			↑	-	-		
			→	12.3	A		
			↓	12.9	A	A	

	路口	時間	方向	平均延滯(秒)	服務水準	路口整體延滯
11/17 (一) TOD	民族路/文化街8巷	假日下午尖峰 1630~1830	←	47.4	D	42.8
			↑	33.6	C	
			→	36.3	C	
			↓	77.4	E	C
	民族路/北上匝道		←	17.5	B	20.7
			↑	45.1	D	
			→	12.6	A	
			↓	-	-	B
	民族路/南出匝道		←	13.3	A	15.3
			↑	-	-	
			→	16.8	B	
			↓	15.1	B	B

(二) 11 月 25 日(一)、11 月 26 日(二)AI 實測與 11 月 18 日(一)、11 月 19 日(二) TOD 績效表現(如表表 4.3.5-2 與表 4.3.5-3 所示)

1. 民族路/文化街 8 巷兩天實測平日晨峰路口整體延滯略減少 7.7 秒，改善約 14.8%，服務水準從 D 級提升至 C 級；平日離峰路口整體延滯減少 5.5 秒，改善約 11.9%，服務水準從 D 級提升至 C 級；平日昏峰路口整體延滯略減少 7.9 秒，改善約 14.3%，服務水準維持 D 級。

2. 民族路/北上匝道兩天實測平日晨峰路口整體延滯略減少 6.0 秒，改善約 14.6%，

服務水準維持 C 級；平日離峰路口整體延滯減少 6.6 秒，改善約 15.1%，服務水準維持 C 級；平日昏峰路口整體延滯略減少 9.8 秒，改善約 16.4%，服務水準從 E 級提升至 D 級。

3. 民族路/南出匝道兩天實測平日晨峰路口整體延滯略減少 6.2 秒，改善約 15.8%；平日離峰路口整體延滯減少 6.4 秒，改善約 16.9%；平日昏峰路口整體延滯略減少 7.9 秒，改善約 19.3%，服務水準皆維持 C 級。

表 4.3.5-2 平日 11/25(一)AI 號誌控制與 11/18(一)TOD 路口延滯績效

	路口	時間	方向	平均延滯(秒)	服務水準	路口整體延滯	較事前改善程度(%)
11/25 (一) AI實測	民族路/文化街8巷	平日晨峰 0700~0900	←	33.2	C	38.4	-16.4%
			↑	34.1	C		
			→	38.8	C		
			↓	69.8	E	C	
		平日離峰 1230~1430	←	57.3	D	41.4	-11.3%
			↑	28.3	B		
			→	31.6	C		
			↓	46.8	D	C	
		平日昏峰 1630~1830	←	61.1	E	43.4	-15.0%
			↑	46.2	D		
			→	25.5	B		
			↓	57.0	D	C	
	民族路/北上匝道	平日晨峰 0700~0900	←	29.4	B	31.2	-15.9%
			↑	49.6	D		
			→	24.4	B		
			↓	-	-	C	
		平日離峰 1230~1430	←	18.9	B	31.1	-14.5%
			↑	66.4	E		
			→	28.7	B		
			↓	-	-	C	
		平日昏峰 1630~1830	←	45.8	D	50.0	-20.0%
			↑	42.2	C		
			→	59.1	D		
			↓	-	-	D	
	民族路/南出匝道	平日晨峰 0700~0900	←	16.7	B	34.6	-16.4%
			↑	-	-		
			→	49.1	D		
			↓	32.5	C	C	
		平日離峰 1230~1430	←	34.4	C	32.6	-18.9%
			↑	-	-		
			→	35.7	C		
			↓	23.8	B	C	
		平日昏峰 1630~1830	←	33.1	C	32.3	-19.8%
			↑	-	-		
			→	30.1	C		
			↓	35.6	C	C	

	路口	時間	方向	平均延滯(秒)	服務水準	路口整體延滯
11/18 (一) TOD	民族路/文化街8巷	平日晨峰 0700~0900	←	35.9	C	45.9
			↑	42.9	C	
			→	48.8	D	
			↓	84.8	F	D
		平日離峰 1230~1430	←	64.1	E	46.7
			↑	31.3	C	
			→	35.5	C	
			↓	57.1	D	D
		平日昏峰 1630~1830	←	69.3	E	51.1
			↑	55.5	D	
			→	31.7	C	
			↓	67.7	E	D
	民族路/北上匝道	平日晨峰 0700~0900	←	33.3	C	37.2
			↑	60.0	E	
			→	30.5	C	
			↓	-	-	C
		平日離峰 1230~1430	←	24.1	B	36.4
			↑	78.1	E	
			→	30.8	C	
			↓	-	-	C
		平日昏峰 1630~1830	←	59.4	D	62.6
			↑	48.5	D	
			→	73.5	E	
			↓	-	-	E
	民族路/南出匝道	平日晨峰 0700~0900	←	18.0	B	41.4
			↑	-	-	
			→	59.4	D	
			↓	40.6	C	C
		平日離峰 1230~1430	←	42.3	C	40.2
			↑	-	-	
			→	44.1	C	
			↓	29.5	B	C
		平日昏峰 1630~1830	←	41.1	C	40.3
			↑	-	-	
			→	37.2	C	
			↓	45.5	D	C

表 4.3.5-3 平日 11/26(二)AI 號誌控制與 11/19(二)TOD 路口延滯績效

	路口	時間	方向	平均延滯(秒)	服務水準	路口整體延滯	較事前改善程度(%)
11/26(二)AI實測	民族路/文化街8巷	平日晨峰 0700~0900	←	30.6	C	38.1	-13.4%
			↑	35.1	C		
			→	39.7	C		
			↓	72.7	E	C	
		平日離峰 1230~1430	←	53.4	D	40.6	-10.9%
			↑	26.4	B		
			→	33.0	C		
			↓	50.3	D	C	
		平日昏峰 1630~1830	←	58.2	D	43.6	-12.5%
			↑	44.8	C		
			→	28.7	B		
			↓	57.6	D	C	
	民族路/北上匝道	平日晨峰 0700~0900	←	28.8	B	31.5	-13.0%
			↑	51.4	D		
			→	24.8	B		
			↓	-	-	C	
		平日離峰 1230~1430	←	19.1	B	29.9	-16.1%
			↑	64.4	E		
			→	26.2	B		
			↓	-	-	B	
		平日昏峰 1630~1830	←	48.5	D	51.3	-15.0%
			↑	44.1	C		
			→	58.4	D		
			↓	-	-	D	
	民族路/南出匝道	平日晨峰 0700~0900	←	16.2	B	34.3	-15.6%
			↑	-	-		
			→	48.1	D		
			↓	33.7	C	C	
		平日離峰 1230~1430	←	35.2	C	33.3	-14.2%
			↑	-	-		
			→	37.1	C		
			↓	22.6	B	C	
		平日昏峰 1630~1830	←	31.6	C	33.4	-15.5%
			↑	-	-		
			→	33.0	C		
			↓	36.9	C	C	

	路口	時間	方向	平均延滯(秒)	服務水準	路口整體延滯
11/19(二)TOD	民族路/文化街8巷	平日晨峰 0700~0900	←	35.0	C	44.0
			↑	40.9	C	
			→	46.5	D	
			↓	80.8	F	C
		平日離峰 1230~1430	←	62.4	E	45.6
			↑	30.4	C	
			→	34.9	C	
			↓	55.7	D	D
		平日昏峰 1630~1830	←	67.5	E	49.9
			↑	53.6	D	
			→	31.2	C	
			↓	66.0	E	D
	民族路/北上匝道	平日晨峰 0700~0900	←	32.8	C	36.2
			↑	57.8	D	
			→	29.6	B	
			↓	-	-	C
		平日離峰 1230~1430	←	23.8	B	35.7
			↑	76.6	E	
			→	30.1	C	
			↓	-	-	C
		平日昏峰 1630~1830	←	57.5	D	60.4
			↑	47.6	D	
			→	70.4	E	
			↓	-	-	E
	民族路/南出匝道	平日晨峰 0700~0900	←	17.7	B	40.6
			↑	-	-	
			→	58.4	D	
			↓	39.2	C	C
		平日離峰 1230~1430	←	40.2	C	38.7
			↑	-	-	
			→	42.8	C	
			↓	28.5	B	C
		平日昏峰 1630~1830	←	40.2	C	39.5
			↑	-	-	
			→	36.5	C	
			↓	44.4	C	C

三、高速公路主線車流變化

圖 4.3.5-11 至圖 4.3.5-15 為實測期間高速公路主線車流事前與事後變化情形。

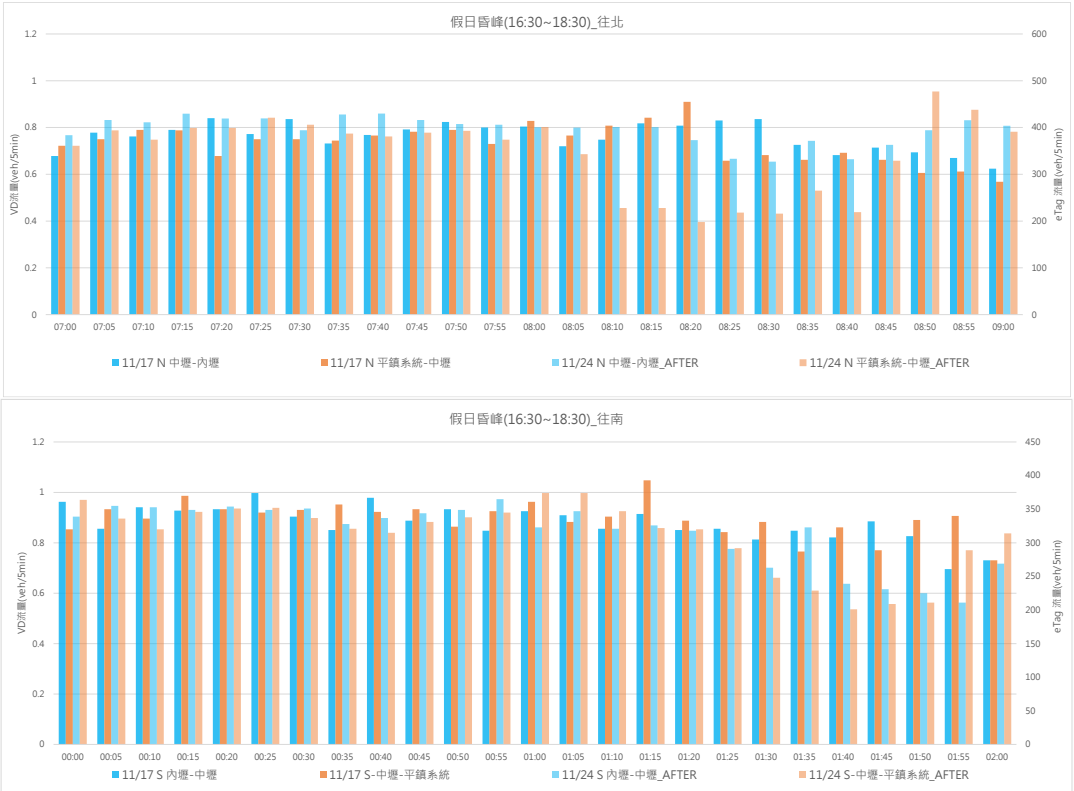


圖 4.3.5-11 11/24(日)桃園市實驗場域事前事後高速公路主線車流變化

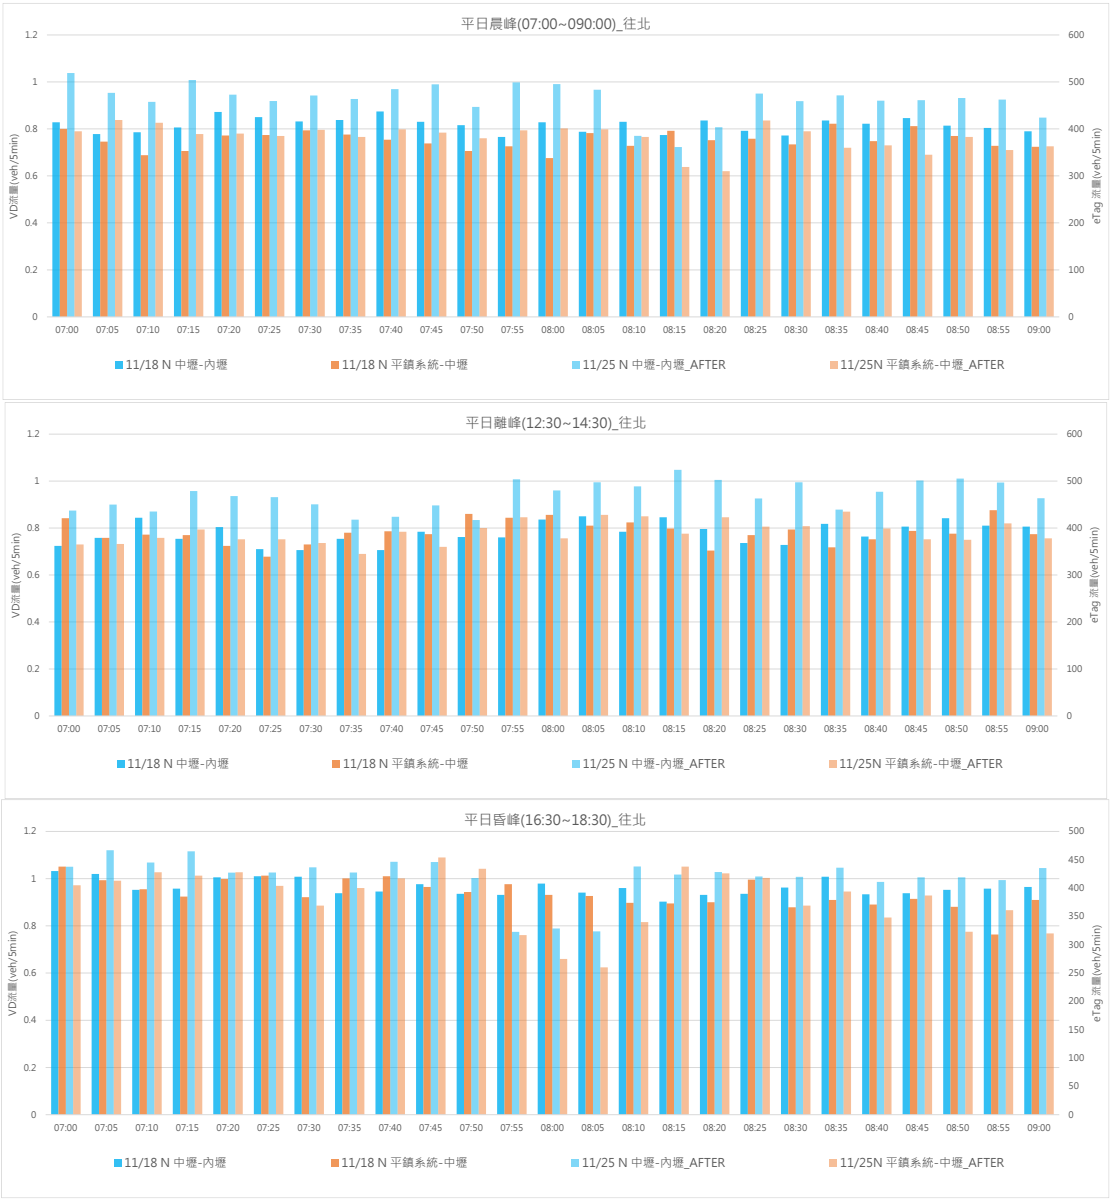
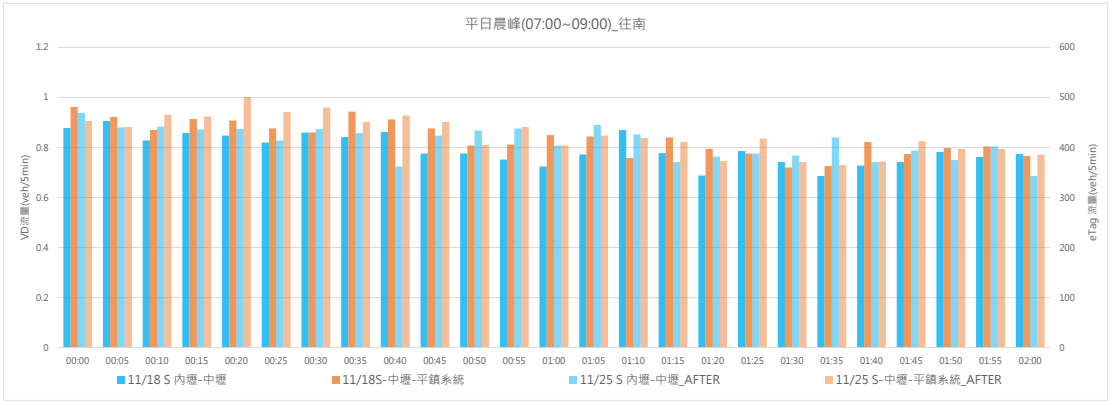
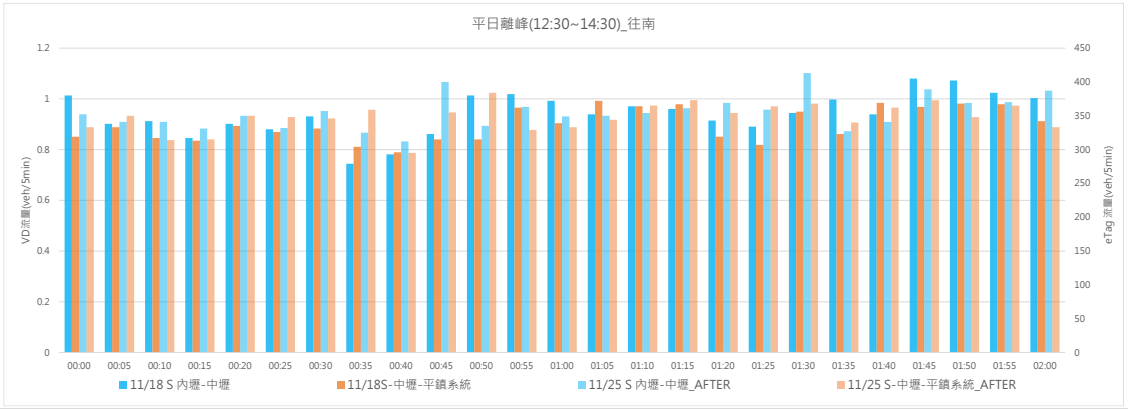


圖 4.3.5-12 11/25(一)桃園市實驗場域往北事前事後高速公路主線車流變化





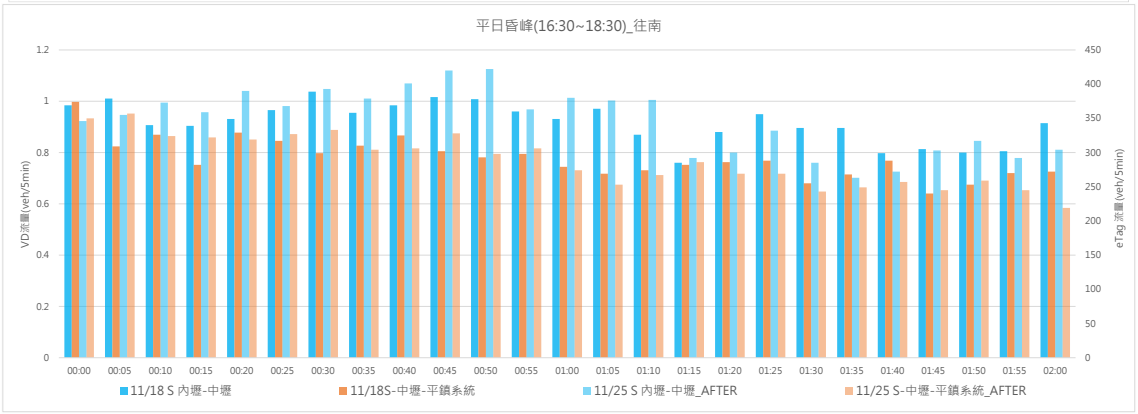
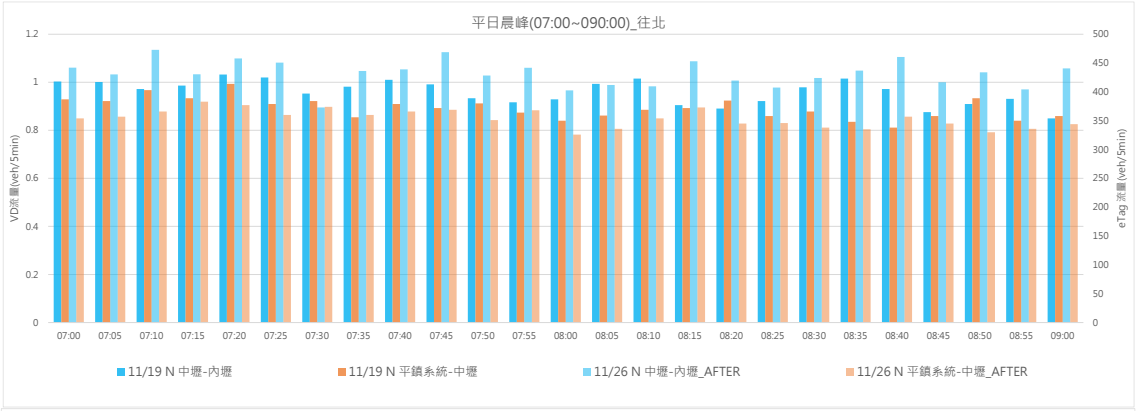
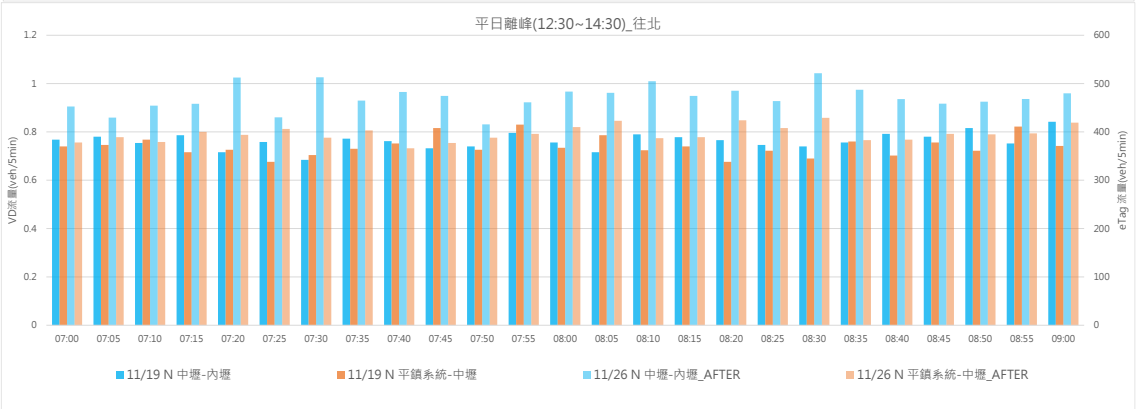


圖 4.3.5-13 11/25(一)桃園市實驗場域往南事前事後高速公路主線車流變化





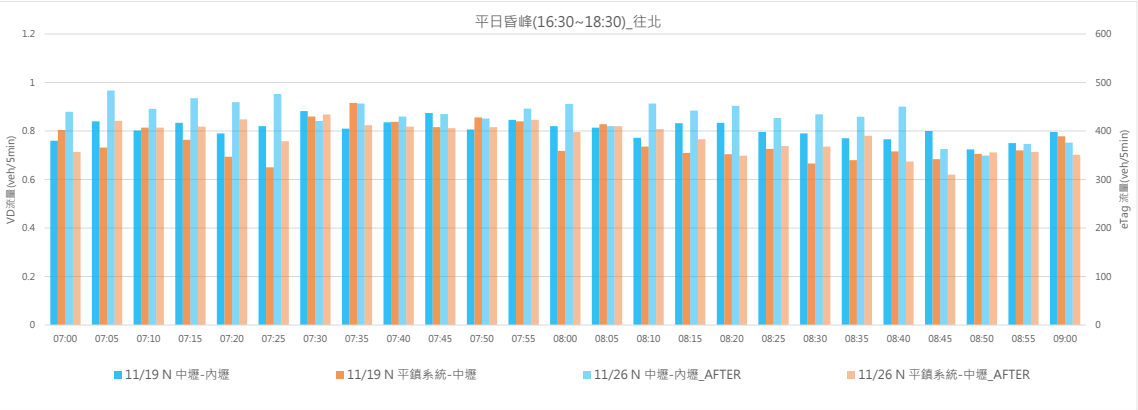
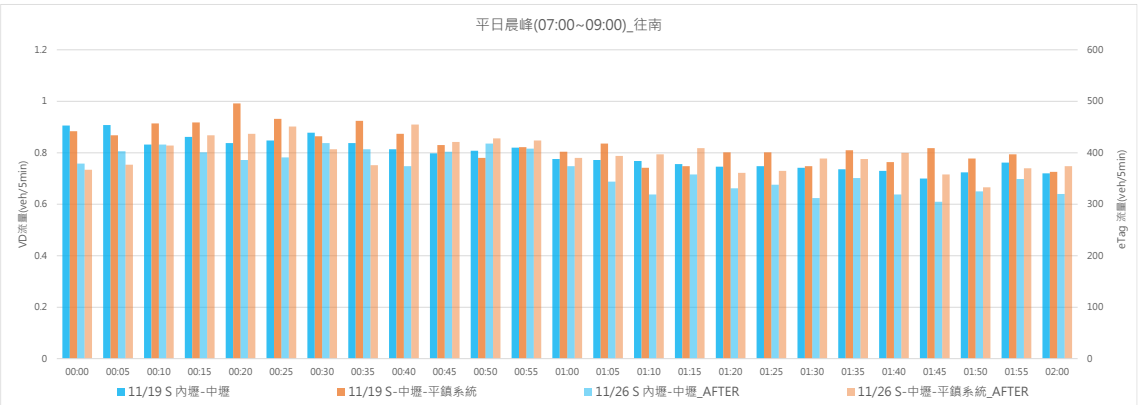
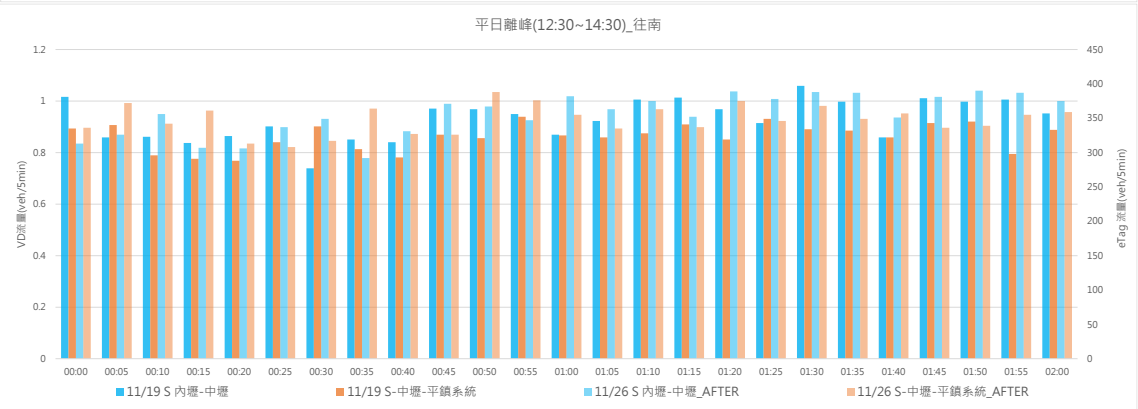


圖 4.3.5-14 11/26(二)桃園市實驗場域往北事前事後高速公路主線車流變化





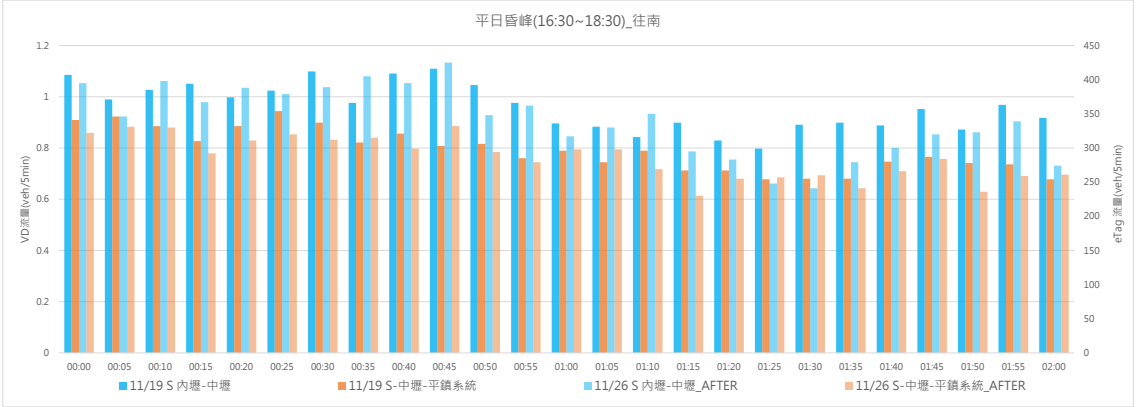
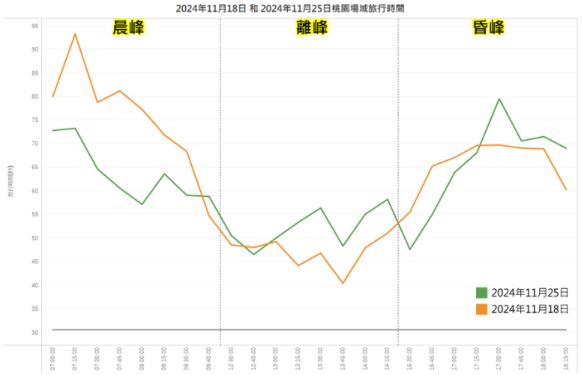


圖 4.3.5-15 11/26(二) 桃園市實驗場域往南事前事後高速公路主線車流變化

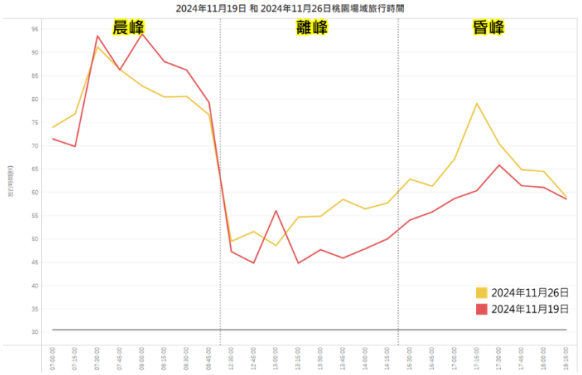
四、旅行時間績效

傳統之旅行速率調查係採用浮動車法，調查車輛於車隊中保持車隊之均速行駛。然在號誌化幹道中車輛不同的出發時間點其可續進的路口數不同，即使依交通工程手冊至少蒐集 6 趟資料，亦可能無法真正反應整體車流績效。因此本計畫透過蒐集 GVP 資料瞭解事前事後路段平均旅行時間，預計事前及事後將各至少蒐集 1 週之資料。由於短時間內車流隨號誌而有週期性變化，為能全面掌握路況 GVP 資料蒐集之頻率將避開號誌週期，如：號誌週期為 150 秒則不能每 150 秒或每 300 秒蒐集一次資料。

平日 11 月 25 日(一)及 11 月 26 日(二)AI 號誌控制晨峰表現明顯略優於 11 月 18 日(一)及 11 月 19 日(二)TOD，兩天平日離峰實測 AI 號誌控制旅行時間表現皆略差於 TOD，而昏峰實測表現 11 月 25 日(一)優於 11 月 26 日(二)。假日 AI 號誌控制旅行時間表現較為平穩，顯示 11 月 24 日(日)場域平面道路及高速公路主線交通壅塞狀況應較 11 月 17 日(日)嚴重。圖 4.3.5-16 與圖 4.3.5-17 分別為平日與假日 AI 模型與 TOD 號誌控制的旅行時間績效比較。



平日 11/25 AI 實測&11/18 動態 TOD



平日 11/26 AI 實測&11/19 動態 TOD

圖 4.3.5-16 平日 AI 號誌控制與 TOD 旅行時間績效示意圖

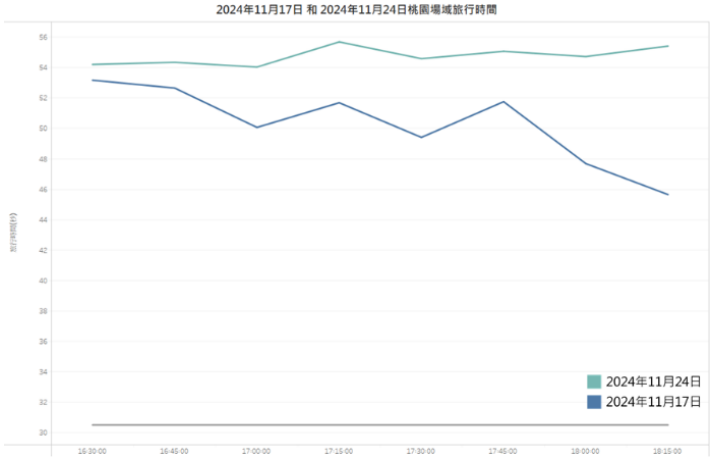


圖 4.3.5-17 假日 AI 號誌控制與 TOD 旅行時間績效示意圖

4.3.6 小結

本期交流道協控之桃園市實驗場域整體路口延滯平日晨峰、平日離峰、平日昏峰及假日昏峰 AI 號誌控制多優於 TOD 控制，唯旅行時間部分時段改善較不明顯或略差，經檢視各路口支道延滯狀況並無惡化情形，推測雖提升了路段行駛效率及路口淨空，但由於增加之週期、分相秒數導致匯入之車流亦增加，行駛速率雖降低但無阻滯，導致長路徑旅行時間增加。

而關於與匝道協控部分，每週期皆有依據平面道路及高速公路主線車流參數，產出對應之匝道儀控率，然其啟動與否取決於機關對主線車流狀態之判斷考量，且 AI 號誌控制模型匝道儀控僅依據交流道周邊平面道路號誌化路口，其適應彈性仍有限，不同事件情境考量作為參數依據建議可納入後續研究。

第五章　結論與建議

本計畫延續前期(112 年)研究成果，發展符合我國主要交通環境下之人工智慧號誌控制模型，藉由與實務單位合作進行不同型態場域(包含都會區幹道號誌控制與交流道區域號誌協控)實測，探討號誌控制與管理需求導入人工智慧，以及後續人工智慧模型的維護機制，以提升都會區交通運作效率及交通安全提升。在「都會區幹道強化學習號誌控制」部分，透過導入多任務強化學習演算法，以及通用環境之探討與建置，規劃以實測探討各時段與車流情境之泛用性，期望能提升人工智慧號誌控制模式之運作效率。在「交流道區域強化學習號誌協控」部分，以集中訓練與分散執行(CTDE)機制訓練多代理人，同時協調控制平面道路號誌與匝道儀控率，完成高速公路交流道匝道儀控與平面道路路口號誌協控之人工智慧強化學習號誌控制模型的發展與實作，及其運作量化效益分析，以期逐步發展我國在人工智慧號誌控制與實力構建。

5.1 結論

一、在人工智慧強化學習號誌控制應用的文獻回顧與模型發展部分：

1. 本計畫盤點與彙整國內外應用人工智慧強化學習於號誌控制案例，包括交流道區域匝道儀控與平面道路號誌協控，以及演算法應用。本計畫採用在連續動作控制領域的多目標強化學習方法 Q-Pensieve，Q-Pensieve 可視為多目標 SAC 演算法強化版，並針對 Q 值估算進行加強，啟用與 SAC 一樣的模型，並繼承了 SAC 的優點，除增加策略的探索性與隨機性，確保策略成長性和支持離線策略學習，也通過知識共享，有效率解決多目標強化學習效能議題。

2. 本計畫延續前期研究成果，並針對前期都會區人工智慧強化學習號誌控制模型進行多時段模型整合，透過模型架構分析，導入 Pearl 方式擴充既有人工智慧強化學習號誌控制模型訓練架構，並完成場域實測驗證，以確保跨時段型態模型運作可行性與各時段績效表現。

3. 針對交流道與鄰近平面道路區域，導入多號誌代理人(Multi Agent)機制，分別控制匝道儀控與平面道路號誌，透過中央化訓練、分散式控制(CTDE)的方式，可使多代理人各自人工智慧強化學習號誌控制模型可同時考量兩大系統之獎勵目標，據以產出適當之決策，同時亦透過場域實測，驗證人工智慧強化學習協控模型可各自分別控制匝道儀控與平面道路號誌並可達成既定之績效目標。

4. 本計畫人工智慧強化學習號誌控制模型與過往或傳統號誌控制方式主要差異在於並非事前研訂規則或流程，係透過多目標人工智慧強化學習號誌控制模型架構設計、權重偏好設定與訓練可於各種車流情境產出最佳決策，研訂相關人工智慧強化學習號誌控制模型流程，用於推廣與移植至其他場域

二、在都會區(臺北市與臺南市)實驗場域之人工智慧強化學習號誌控制模型精進部分，

1. 本計畫探討如何使用單一模型處理各時段不同之時制計畫編號與其時相型態，因此除延續前期計畫人工智慧強化學習號誌控制模型設計外，於臺南市實驗場域的平日離峰、昏峰、假日昏峰等時段，透過新增 Pearl 網路架構，利用模型參數自行判別時段與其時制型態，以適應不同之時制計畫編號下的時相型態；平日晨峰時段則維持原人工智慧強化學習號誌控制模型。

2. 臺北市實驗場域則受到車輛偵測器數量減少，改採以有車輛偵測器的「中山北路-德行東路」路口為主控路口，其餘 2 個路口為協控路口架構進行 AI 號誌控制模型設計與訓練工作，來設計其時相秒數。在人工智慧強化學習號誌控制模型訓練過程中採用網格搜索方法，系統性的將所有可能的參數組使用並測試使其搜索一組超參數的最佳組合，以提升模型性能。超參數內容包括:學習率、折和因子、抽樣數、隱藏層數與神經元數。

三、在桃園市中壢交流道實驗場域之人工智慧強化學習號誌協控與模擬環境建置部分，

1. 中壢交流道實驗場域中的車流模擬環境與現實交通量調查的誤差比較結果顯示，在高速公路主線區域，北上路段受平面道路路網誤差之影響可能較大，準確率不如南下路段方向，惟兩者仍符合 GEH 準確率要求。在中壢交流道周邊平面道路部分，MAPE 值與 GEH 值存有正相關性，但相較起來 MAPE 較為和緩，以文化街/正光街路口為例，往南車輛 MAPE 值差異超過 40%，但實際車輛差異約 50 台，雖後續可持續進行模型校估，惟整體以 GEH 指標作為校估手段。

2. 人工智慧強化學習號誌控制模型的訓練架構採用 CTDE (Centralized Training Decentralized Execution)方式，訓練過程中，直接將所有路口的相關資訊作為輸入數據，用來訓練 AI 強化學習模型(Du. et al, Zang. et al)，此設計方式使人工智慧強化學習號誌控制模型通過學習來捕捉全局路口之間的時空相關性，進一步幫助模型收斂到最佳權重分配。

四、在實測績效部分，

1. 本計畫與高速公路局、臺北市政府、臺南市政府及桃園市政府合作，進行實測與量化績效分析。實測績效顯示：(1)桃園中壢交流道周邊道路 8 個路口的整體路口停等延滯平均降低 15%，均優於現況定時號誌控制；(2)臺南市「台 86 與台 19 甲」路口的整體路口延滯多優於現況動態號誌控制約 2.5%；(3)臺北市「中山北路與德行西路」周邊 3 個路口，平日離峰與假日昏峰時段的路口平均停等延滯相較現況定時號誌控制平均改善 15%。

2. 桃園市中壢交流道協控於平日晨峰、平日離峰、平日昏峰及假日昏峰的整體路口延滯

方面，AI 號誌控制多優於現況 TOD 控制，惟旅行時間部分的改善較不明顯或略差；經檢視各路口支道延滯狀況並無惡化情形，推測 AI 號誌控制雖提升路段行駛效率及路口淨空，但由於增加之週期、分相秒數導致匯入之車流亦增加，行駛速率雖降低但無阻滯，導致長路徑旅行時間增加。

五、在計畫成果與外界分享部分，分別透過(1)投稿 2024 運輸年會暨學術論文國際研討會，於 113 年 12 月 6 日研討會時進行口頭發表、(2)於 2024 運輸年會暨學術論文國際研討會會場逢甲大學育樂館設攤位，以海報與多媒體方式呈現計畫成果、(3)於 114 年 11 月 29 日辦理計畫成果分享會、(4)於 114 年 12 月 2 日辦理計畫教育訓練。

5.2 建議

一、在都會區強化學習號誌控制部分，

1. 建議進一步探討人工智慧強化學習號誌控制模型的演算法、輸入狀態、輸出決策，並納入時相順序調整、與鄰近群組連鎖、時差續進等之因素，以使人工智慧強化學習在號誌控制應用上更具彈性與全面性。

2. 目前跨時段多任務人工智慧強化學習號誌控制模型仍有部分時段績效表現不如固定時制，建議持續進行此課題的模型整合建構與優化，以減少因時段切分或時制計畫改變而增加 AI 號誌控制模型訓練次數，嘗試獲得泛用型(全時段)的人工智慧號誌控制模型。

3. 目前國內在號誌控制導入人工智慧強化學習號誌控制模型時尚未納入行人資訊，在路口行人安全受到重視與行人偵測器技術逐漸成熟下，建議後續可探討將行人因素(例如：行人專用時相、行人影響右轉車輛)納入人工智慧強化學習號誌控制模型設計與訓練，以探討行人安全與行車效率提升課題。

二、在桃園市中壢交流道人工智慧強化學習號誌協控部分，

1. 在人工智慧強化學習號誌模型的 CTDE 的訓練過程中，由於匝道與平面道路的號誌時間週期不一致，匝道的時間週期通常較短，導致觀測數據存在收集時間不一致和資料量不平衡的問題。這種情況可能使模型在訓練時過度偏向匝道的最佳解，從而影響整體的訓練準確性。為了解決這一問題，在將數據存入資料庫之前，對匝道和平面道路的數據進行篩選和處理，僅保留匝道與平面道路最接近的決策時間作為訓練資料。此方法有效地減少訓練偏差，避免模型過度關注匝道特徵。然而，此策略也犧牲部分匝道的數據資訊。建議後續如何有效利用所有匝道和平面道路數據，平衡數據稀疏性與訓練精度，將是在 CTDE 架構下值得進一步探討的重要課題。

2. 每個號誌週期皆依據平面道路及高速公路主線車流參數，產出對應之匝道儀控率，然其啟動與否取決於高速公路局對主線車流狀態之判斷考量，且人工智慧強化學習號誌

控制模型的匝道儀控僅依據交流道周邊平面道路號誌化路口，其適應彈性仍有限，因此可進一步將不同事件(或情境)因素的參數化課題建議納入後續研究。

三、根據實測經驗，現場端各式路側設備的整合與調校為重要課題，例如：為滿足人工智慧強化學習號誌控制所需之偵測參數，須確保車流偵測器準確度，路口號誌控制器須能支援逐秒控制，同時應確保通訊系統的正常運作等，建議納入後續研究課題。

四、人工智慧強化學習號誌控制模型維護機制上，模型設計上多屬於微觀偵測與時相調控，因此模型內容與訓練對於現場車流偵測與號誌時相內容關聯性高，對於偵測設備的準確度、位置異動、號誌時制組態(時相術改變或增減行人時相)變動等，均會對人工智慧強化學習號誌控制模型造成影響，進而導致微調模型與重新訓練課題。建議後續可針對此課題進行探討，以強化人工智慧強化學習號誌控制模型在不同環境下的適用性。

參考文獻

1. Abdulhai, B., Pringle, R., Karakoulas, G. J. (2003). Reinforcement learning for true adaptive traffic signal control. Journal of Transportation Engineering,129(3), 278-285.
2. Abels, B., Roijers, D. M., Lenaerts, T., Nowe, A., Steckelmacher, D. (2019). Analyzing the impact of opponent models in zero-sum games. Proceedings of the 18th International Conference on Autonomous Agents and Multiagent Systems, 1773-1775.
3. Ahilan S, Dayan P (2019) Feudal multi-agent hierarchies for cooperative reinforcement learning.
4. Arel, I., Liu, C., Urbanik, T., Kohls, A. G. (2010). Reinforcement learningbased multi-agent system for network traffic signal control. IET Intelligent Transport Systems, 4(2), 128-135.
5. BELLMAN, R. (1957). A Markovian Decision Process. Journal of Mathematics and Mechanics, 6(5), 679–684. http://www.jstor.org/stable/24900506
6. Brys, T., Pham, T. T., Taylor, M. E. (2014). Distributed learning and multiobjectivity in traffic light control. Connection Science, 26(1), 65-83.
7. Chelsea Finn, Pieter Abbeel, and Sergey Levine. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. In International Conference on Machine Learning, 2017. 1, 2, 3, 5, 6, 8, 9.
8. Chu, T., Wang, J., Codecà, L., Li, Z. (2019). Multi-agent deep reinforcement learning for large-scale traffic signal control. IEEE Transactions on Intelligent Transportation Systems, 21(3), 1086-1095.
9. Da Silva, B. C., Basso, E. W., Perotto, F. S., C. Bazzan, A. L., Engel, P. M. (2006). Improving reinforcement learning with context detection. In Proceedings of the fifth international joint conference on Autonomous agents and multiagent systems (pp. 810-812).
10. David Silver, Guy Lever, Nicolas Heess, Thomas Degris, Daan Wierstra, and Martin Riedmiller. Deterministic policy gradient algorithms. In International Conference on Machine Learning, 2014.
11. Dresner, K., Stone, P. (2006). Multiagent traffic management: Opportunities for multiagent learning. In International Workshop on Learning and Adaption in Multi-Agent Systems (pp. 129-138). Springer, Berlin, Heidelberg.
12. El-Tantawy, S., Abdulhai, B., Abdelgawad, H. (2013). Multiagent reinforcement learning for integrated network of adaptive traffic signal controllers (MARLIN-ATSC): methodology and large-scale application on downtown Toronto. IEEE Transactions on Intelligent Transportation Systems, 14(3), 1140-1150.
13. Foerster, J., Assael, I. A., De Freitas, N., Whiteson, S. (2016). Learning to communicate with deep multi-agent reinforcement learning. Advances in Neural Information Processing Systems, 29.

14. Foerster, J., Nardelli, N., Farquhar, G., Afouras, T., Torr, P. H., Kohli, P., Whiteson, S. (2017, July). Stabilising experience replay for deep multi-agent reinforcement learning. In International Conference on Machine Learning (pp. 1146-1155). PMLR.
15. Genders, W., Razavi, S. (2016). Using a deep reinforcement learning agent for traffic signal control. arXiv preprint arXiv:1611.01142.
16. Gronauer, S., Diepold, K. (2022). Multi-agent deep reinforcement learning: a survey. Artificial Intelligence Review, 55(2), 895-943.
17. Haarnoja, T., Zhou, A., Hartikainen, K., Tucker, G., Ha, S., Tan, J., Levine, S. (2018). Soft actor-critic algorithms and applications. arXiv preprint arXiv:1812.05905.
18. Haarnoja, T., Zhou, A., Abbeel, P., Levine, S. (2018, July). Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor. In International conference on machine learning (pp. 1861-1870). PMLR.
19. He, W., Gao, H., Zhou, C., Yang, C., Li, Z. (2020). Reinforcement learning control of a flexible two-link manipulator: An experimental investigation. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 51(12), 7326-7336
20. Houli, D., Zhiheng, L., Yi, Z. (2010). Multiobjective reinforcement learning for traffic signal control using vehicular ad hoc network. EURASIP journal on advances in signal processing, 2010, 1-7.
21. Hung, W., Huang, B. K., Hsieh, P. C., Liu, X. (2022). Q-Pensieve: Boosting Sample Efficiency of Multi-Objective RL Through Memory Sharing of Q-Snapshots. arXiv preprint arXiv:2212.03117.
22. https://spinningup.openai.com/en/latest/algorithms/ppo.html
23. Janner, M., Fu, J., Zhang, M., Levine, S. (2019). When to trust your model: Model-based policy optimization. Proceedings of the 36th International Conference on Machine Learning, 3158-3167.
24. Kong X, Xin B, Liu F, Wang Y (2017) Revisiting the master-slave architecture in multi-agent deep reinforcement learning.
25. Kumar S, Shah P, Hakkani-Tür D, Heck LP (2017) Federated control with hierarchical multi-agent deep reinforcement learning.
26. Kyriakis, P., Deshmukh, J., Bogdan, P. (2022;). Pareto policy adaptation. In International Conference on Learning Representations(ICLR).
27. Li, L., Lv, Y., Wang, F. Y. (2016). Traffic signal timing via deep reinforcement learning. IEEE/CAA Journal of Automatica Sinica, 3(3), 247-254.
28. Li, Z., Yu, H., Zhang, G., Dong, S., Xu, C. Z. (2021). Network-wide traffic signal control optimization using a multi-agent deep reinforcement learning. Transportation Research Part C: Emerging Technologies, 125, 103059.
29. Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., Wierstra, D. (2016).

Continuous control with deep reinforcement learning. Proceedings of the 4th International Conference on Learning Representations (ICLR).

30. Lowe, R., Wu, Y. I., Tamar, A., Harb, J., Pieter Abbeel, O., Mordatch, I. (2017). Multi-agent actor-critic for mixed cooperative-competitive environments. Advances in neural information processing systems, 30.
31. Lu, C., Huang, J., Deng, L., Gong, J. (2017). Coordinated ramp metering with equity consideration using reinforcement learning. Journal of Transportation Engineering, Part A: Systems, 143(7), 04017028.
32. Ma, X., Li, J., Kochenderfer, M. J., Isele, D., Fujimura, K. (2021, May). Reinforcement learning for autonomous driving with latent state inference and spatial-temporal relationships. In 2021 IEEE International Conference on Robotics and Automation (ICRA) (pp. 6064-6071). IEEE.
33. Mannion, P., Duggan, J., Howley, E. (2016). An experimental review of reinforcement learning algorithms for adaptive traffic signal control. Autonomic road transport support systems, 47-66.
34. Mohammad Noaeen, Atharva Naik, Liana Goodman, Jared Crebo, Taimoor Abrar, Zahra Shakeri Hossein Abad, Ana L.C. Bazzan, Behrouz Far (2022). Reinforcement learning in urban network traffic signal control: A systematic literature review. Expert Systems with Applications.
35. Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., Riedmiller, M. (2013). Playing atari with deep reinforcement learning. arXiv preprint arXiv:1312.5602.
36. Mossalam, S., Assael, Y. M., Roijers, D. M., Whiteson, S. (2016). Multi-agent common knowledge reinforcement learning. Proceedings of the 2016 Conference on Advances in Neural Information Processing Systems, 3849-3857.
37. Mousavi, S. S., Schukat, M., Howley, E. (2017). Traffic light control using deep policy-gradient and value-function-based reinforcement learning. IET Intelligent Transport Systems, 11(7), 417-423.
38. Nishi, T., Otaki, K., Hayakawa, K., Yoshimura, T. (2018). Traffic signal control based on reinforcement learning with graph convolutional neural nets. In 2018 21st International conference on intelligent transportation systems (ITSC) (pp. 877-883). IEEE.
39. Shabestary, S. M. A., Abdulhai, B. (2018). Deep learning vs. discrete reinforcement learning for adaptive traffic signal control. In 2018 21st International Conference on Intelligent Transportation Systems (ITSC) (pp.286-293). IEEE.
40. Schulman, J., Levine, S., Abbeel, P., Jordan, M., and Moritz, P. (2015). Trust region policy optimization. In International conference on machine learning, pages 1889–1897.
41. Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O. (2017). Proximal policy optimization algorithms. arXiv preprint arXiv:1707.06347
42. Sutton, R.S. and Barto, A.G. (1998) Reinforcement Learning: An Introduction, Vol. 1. MIT Press, Cambridge.

43. Sunehag P, Lever G, Gruslys A, Czarnecki WM, Zambaldi V, Jaderberg M, Lanctot M, Sonnerat N, Leibo JZ, Tuyls K, Graepel T (2018) Value-decomposition networks for cooperative multi-agent learning based on team reward.
44. Syed Shah Sultan Mohiuddin Qadri, Mahmut Ali Gökçe, Erdinç Öner (2020). State-of-art review of traffic signal control methods: challenges and opportunities. European Transport Research Review.
45. Tan, T., Bao, F., Deng, Y., Jin, A., Dai, Q., Wang, J. (2019). Cooperative deep reinforcement learning for large-scale traffic grid signal control. IEEE transactions on cybernetics, 50(6), 2687-2700.
46. Van Moffaert, K., Nowé, A. (2014). Decentralized partially observable Markov decision processes with Monte Carlo tree search. Proceedings of the 2014 IEEE Conference on Computational Intelligence and Games, 1-8.
47. Vuorio, R., Sun, S. H., Hu, H., Lim, J. J. (2019). Multimodal model-agnostic meta-learning via task-aware modulation. Advances in neural information processing systems, 32.
48. Wan, C. H., Hwang, M. C. (2018). Value-based deep reinforcement learning for adaptive isolated intersection signal control. IET Intelligent Transport Systems, 12(9), 1005-1010.
49. Wan, C. H., Hwang, M. C. (2019). Adaptive traffic signal control methods based on deep reinforcement learning. In Intelligent Transport Systems for Everyone's Mobility (pp. 195-209). Springer, Singapore.
50. Wu, J., Liu, P., Qin, X., Zhou, H., Yang, Z. (2019). Developing an actuated signal control strategy to improve the operations of contraflow left-turn lane design at signalized intersections. Transportation research part C: emerging technologies, 104, 53-65.
51. Xu, L., Zhang, Y., Liu, Z., Wu, J., Zha, H. (2020). Meta reinforcement learning with adaptive hyperparameters. Proceedings of the 37th International Conference on Machine Learning, 10391-10402.
52. Yang, G., Sun, Y., Narasimhan, S. G. (2019). Critic-Aware Multi-Modal Planning for Heterogeneous Multi-Robot Systems. Proceedings of the IEEE International Conference on Robotics and Automation (ICRA), 5837-5843.
53. Zheng, G., Xiong, Y., Zang, X., Feng, J., Wei, H., Zhang, H., Li, Z. (2019). Learning phase competition for traffic signal control. In Proceedings of the 28th ACM International Conference on Information and Knowledge Management (pp. 1963-1972).
54. Zheng, S., Li, Z., Li, M., Ke, Z. (2024). Enhancing reinforcement learning-based ramp metering performance at freeway uncertain bottlenecks using curriculum learning. IET Intelligent Transport Systems.
55. 宋太龙、郭明洋、陈一凡、贺玉龙 (2024). 基于 A2C 的匝道相联交叉口信号控制优化. Journal of Shenzhen University Science & Engineering, 41(2).

56. 陳又均(2022). 應用多代理深度強化學習於高速公路主線及匝道聯合儀控策略—以國道5 號為例.
57. 胡大瀛、李卓育 (2021). 深度強化學習下號誌控制設計獎勵機制之探討，2021 年中華民國運輸學會學術論文研討會.
58. 許添本、蔡沐軒 (2021). 示範式深度強化學習應用於號誌時制最佳化之研究，2021 年中華民國運輸學會學術論文研討會.
59. 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，2020 年中華民國運輸學會學術論文研討會.
60. 江伊嵐、陳奕廷、葉梓銓 (2020).智慧型動態交通號誌控制系統-應用於台北市重點壅塞區域. 土木水利, 47(4), 20-27.
61. 陳麗雯、胡大瀛 (2020).都市幹道連鎖時制設計之研究與實例分析. 土木水利, 47(4), 40-50.
62. 胡守任、葉志韋、林定憲、劉瀚聰 (2020).都市適應性號誌控制原理與發展. 土木水利, 47(4), 28-39.
63. 張佑鴻、林良泰 (2012). 半觸動號誌控制模式之建構與驗證
64. 吳悅慈 (2011). 幹道群組適應性號誌控制模式之開發研究.
65. 薛博元 (2011). 高速公路速率控制與匝道儀控最佳化協控模式之研究.
66. 黃崇宇 (2009). 高速公路匝道儀控與速率控制協控模式之研究.
67. 田永平、卓訓榮、林貴璽(2005).號誌路口時制轉換時段長度之模擬研究.

附錄一 期中審查意見回覆表

項次	審查意見	審查意見回覆內容	主辦單位意見
一、陶治中委員			
1	P.50，建議將強化學習(RL)依四種類別：(1)Model-based (RL)、 (2) Value-based RL、(3) Policy-based (RL)、(4) Value + Policy-based RL，並在各類別彙整各演算法及其特性，以及與深度RL之差異。另請補充說明本計畫使用Q-Pensieve演算法之原因。	1. 謝謝委員意見，針對 RL 分類方式，將參酌委員意見於期末報告書進行適當的分類調整。 2. Q-Pensieve 為 RL 中可用於多目標學習之演算法，除具備多目標獎勵函數特性外，因採樣效率較高及隨機策略等特性，交通號誌控制應用上，會考量多目標獎勵如延滯、路口通過量等，因此該演算法適合應用於都會區幹道號誌控制進行 AI 號誌控制模型構建。	同意
2	2023年與2024年已有專為高速公路或快速道路匝道與平面道路RL的文獻發表，請於期末報告加以補充；該文獻中採用Value + Policy-based的A2C方法，並驗證優於DQN。	謝謝委員意見，已補充於期末報告書 2.2.2.1 節。	同意
3	由於高速公路及平面道路特性及週期設計完全不同，請補充兩者在獎勵值設計上之差異。	目前採用 CTDE 方式訓練 AI 號誌控制模型，故可以適應高速公路與平面道路週期不一樣之議題，且在獎勵目標設計上採用一致性的獎勵函數值，同時考量高速公路及平面道路的特性，獎勵目標設計包含：幹道延滯、平面支道延滯、平面幹道通過量、平面支道通過量及匝道通過量。	同意
4	請補充說明P.81表4.2-1，Q-Pensieve演算法之出口匝道及平面道路交叉路口的綜合加權獎勵值。	匝道及平面道路交叉路口非採用綜合加權獎勵值，在獎勵目標上是同時產出平面幹道延滯、平面支道延滯、平面幹道通過量、平面支道通過量及匝道通過量，採用多目標一起考量獎勵值。	同意
5	車流偵測數據種類是否將影響Policy或Value-based RL的選擇？	車流數據確實會影響選擇強化學習之方法，但其影響並非由數據種類決定，而是由數據之特性如複雜性、穩定性與動作是否離散，以影響模型學習過程。	同意
6	遷移學習可能更有效率，另	遷移學習也是一種可以將訓練好的模型應用	同意

	MARL 或 MADRL 的 Model-based等是否值得探討？	於其他場域的一種方式，但並非代表一定會更有效率，因為其中需要考量各種問題如轉移場域中的環境、車流是否相似、需要解決的問題與決策方式是否類似等。	
二、范俊海委員			
1	本計畫目標設定為何？是要驗證不同 AI 號誌控制模型在號誌控制應用成效，還是驗證流程是可行的，請加以說明。	本計畫目標主要驗證流程可行，其流程包括利用模擬環境供模型進行訓練、動態模擬測試、現場實驗等相關流程，並探討不同號誌控制與協控情境下可行之 AI 號誌控制模型。	同意
2	AI 號誌控制模型會利用模擬軟體資料作為訓練使用，請補充模擬資料處理與驗證方式，例如：模擬環境的車流輸入資料與輸出資料的準確性，又如部分資料取樣時段不同，計畫如何處理。	本計畫交流道建置模型選用 MAPE 及 GEH 指標，進行實際流量及模擬環境流量的擬真程度校估，而 MAPE 為 11.4%，GEH 指標為 2.32。針對不同時段資料，會依據不同時段建置不同之模擬環境，以供 AI 號誌控制模型進行訓練。	同意
3	若現場車流偵測設備無法提供資料時，請補充 AI 號誌控制模型的處理方式	當資料有所缺漏將導致 AI 號誌控制模型無法運算產出秒數，系統將自動使用原時制計畫，以避免現場因降階運轉之補償機制導致交通壅塞。	同意
4	P.64，表 3.2.1-2 僅有臺南實驗場域號誌資訊採隨機樣本的好處為何？而臺北市實驗場域並無此設計，請補充臺南及臺北市實驗場域在此部分設計上的差異。	本計畫之臺南市實驗場域模型以跨時段整合與構建，模型訓練時會隨機抽樣不同時段資料進行訓練，而臺北市實驗場域之模型則沿用前期計畫作法，依不同時段切分，並個別訓練，因此無需針對不同時段進行隨機抽樣。	同意
5	P.67，圖 3.2.3-2 訓練結果是否每個方案都比定時控制(TOD)好，如何進行優劣解讀，另 P.71 表 3.2.3-2 是評估最終結果嗎？	非每次訓練時，其結果皆會比 TOD 好，而優劣考量主要依據延滯及通過量判斷，延滯小於 TOD 則較 TOD 為佳，通過量大於 TOD 也較 TOD 為佳，期中報告書表 3.2.3-2 則為臺南實驗場域訓練最終結果。	同意
6	P.77、P.78，提及各實驗場域路口績效指標，請補充說明如何評估績效指標的效能、權重比例設計原因，績效指標在相對量或絕對量或全時段等，會有顯著差異嗎？	將補充各實驗場域評估績效指標的效能、權重比例設計考量，並分析績效指標差異性。	同意
7	計畫所發展 AI 號誌控制模型，是否能與觸動號誌方式進行比較，請補充說明。	經了解目前臺北市實驗場域、交流道區域實驗場域於日常執行 TOD，臺南市實驗場域執行動態 TOD，因此本計畫臺南市實驗場域將	同意

		取得動態 TOD 作為事前績效進行比較。	
8	依據計畫所使用 AI 號誌控制模型之現場車流偵測設備數量，可於期末階段提出相關之建議，以供後續計畫參考。	謝謝委員意見，針對都會區幹道車流偵測設備之說明於 3.3.1 節；交流道區域車流偵測設備之說明於 4.3.1 節，本計畫之相關建議詳 6.2 節。	
三、李明聰委員			
1	請補充說明本計畫在AI號誌控制模型設計之考量與原因。	本計畫共區分三個實驗場域，其 AI 號誌控制模型設計考量如下 1. 交流道區域為進行跨域協控，需同時考量匝道及平面道路狀態、並在不同時間點分別進行決策性，因此採用可集中式訓練、分散式執行之 CTDE 架構，於既有 Q-Pensive 演算法整合 CTDE 進行 AI 號誌控制模型設計構建。 2. 臺北市實驗場域考量幹道續進，以單一路口控制，並連鎖另兩個路口，演算法則沿用去年之演算法 Q-Pensieve，依不同時段切分，並個別訓練。 3. 本計畫於臺南市實驗場域嘗試整合使用一個 AI 號誌控制模型應用於多時段，由於 PEARL 可收集多模態資料並依資料特徵進行分類，適用於交通之多時段資料型態，因此於既有之 Q-Pensive 演算法新增 PEARL 架構。	同意
2	臺北市實驗場域控制路口為 X4，請補充說明 X2~X4 路口間建立之關係。	鑒於本期計畫僅 X4 路口具備車流偵測設備，AI 號誌控制模型僅可取得 X4 路口之即時道路資料，為進行 X2~X4 路口控制，X2 及 X3 路口將根據 X4 路口經由 AI 計算出的時比，連鎖分配各方向的時相長度，以避免幹道方向之號誌無法續進。	同意
3	請補充說明臺北市實驗場域多路口中，若車流偵測設備僅於 X4 路口，其設計與臺南市實驗場域之差異為何。	臺南實驗場域為單一路口控制，並且根據場域特性，該路口與上下游路口無關聯，可視為獨立路口；臺北市實驗場域為多路口廊道型控制，一次控制會影響 X2~X4 三個路口，需考量幹道續進。	同意
4	請補充說明高速公路局之匝道儀控表，已設定為固定儀控率之紅燈、黃燈、綠燈秒數，其秒數是否能夠變更。	匝道儀控表乃高速公路局多年經驗累積，共區分編號 0-31，依不同編號則定義不同之儀控率、紅燈秒數、黃燈秒數、綠燈秒數，另由於紅燈、黃燈、綠燈秒數受限於高速公路現	同意

		場之號誌設備限制，秒數不宜變更。	
5	協控模型之績效指標設計若考量最大路口通過量，高速公路之主線通過量勢必遠大於平面道路，在模型設計上需避免此問題影響整體模型訓練。	謝謝委員意見，本計畫在模型設計上在高速公路是考量匝道通過量，非高速公路主線通過量。	
四、許佳興委員			
1	報告書章節描述內容較為分散，而簡報易讀性較高，期末報告書可參考簡報架構進行撰寫。	謝謝委員意見，後續於期末報告書調整章節架構。	同意
2	報告書第二章提出許多 RL 演算法說明，請補充本計畫選用 Pearl 及 CTDE 作法之原因。	1. 考量交通號誌控制資料輸入面相是多模態的情形，在不同時段下會具備不同方向的交通流量以及不同的時制計畫，PEAR 則能處理多模態資料輸入的情形，可在不同時制計畫中能夠應對不同的分相數或轉向需求。 2. 由於需要針對匝道和平面道路訓練不同的策略，在交流道實驗場域本計畫規劃使用 CTDE 的架構，這種架構通常應用於大規模機器學習系統，特別是涉及同時訓練多個代理人。	同意
3	報告書第五章及第六章標題類似，標題描述應有所區別。	謝謝委員意見，後續於期末報告書一併修正。	同意
4	報告書有些圖過於模糊(如圖 2.1.2-6)，請檢視整份報告書內容，並予以修正。	謝謝委員意見，後續於期末報告書一併修正。	同意
5	簡報 P.6 甘特圖，請補充目前期中階段執行狀況。	謝謝委員意見，有關期中階段各實驗場域進度如下 1. 交流道實驗場域則選定中壢交流道及平面道路作為實驗場域，並於期中階段完成模擬環境建置及 AI 號誌控制模型規劃。 2. 都會區場域如臺南市實驗場域則已訓練出初步之成果，後續將進行動態模擬訓練及現場實測等項目。 3. 都會區場域如臺北市實驗場域則因 7 月底有新的時制計畫及本計畫於 6 月底重新路口調查，本計畫後續將依新資料重新進行訓練。	同意

6	簡報 P.20、P.31、P.49 Q-Pensieve 演算法流程箭頭方向有點差異，應統一 Q-Pensieve 演算法方向流程。	謝謝委員意見，後續於期末報告書重新整理 Q-Pensieve 演算法方向流程。	同意
7	針對 AI 號誌控制模型之前處理、資料處理、模型設計輸入輸出等，請於期末報告書中補充說明。	謝謝委員意見，後續於期末報告書補充相關內容。	同意
五、劉瑞麟委員			
1	報告書用詞多以貴所尊稱，用詞方面請整體修正。	謝謝委員意見，後續於期末報告書一併修正。	同意
2	報告書第二章多為有前一期計畫之文獻，請補充新的文獻回顧內容。	謝謝委員意見，已補充有關 GEH 及強化學習應用於號誌協控等新的文獻內容，如第二章所示。	同意
3	為求計畫前後期的延續性，前期計畫的結論與建議，應於報告書中補充詳實之說明處理情形。	前期計畫之簡要說明整理如期中報告書 P.33~P.34 所示。	同意
4	Peral 是考量不同時段，並將不同時段之交通量混合訓練，請補充說明交通量之演算處理方式。	PEARL 在訓練前進行前處理，將不同時段資料整合為擁有同一維度之分相數，並輸入於同一個模型。	同意
5	P.67，圖 3.2.3-2 提及 EPISDOE，請補充該用詞定義。	EPISODE 一般用於強化學習，在中文上可以訓練回合表示，以遊戲或下圍棋為例，如一場遊戲於開始到結束則可表示為一個 EPISODE，一局圍棋於開始到結束也可表示為一個 EPISODE，而在強化學習上 AI 號誌控制模型跑完一輪則也表示為一個 EPISODE。	同意
6	P.67、P.68，如平日昏峰所表現 TOD 有不同之資料樣態，請補充不同資料樣態之原因。	本計畫在臺南實驗場域模型設計上為多目標任務，其獎勵目標規劃為延滯及通過量兩種不同資料樣態。	同意
7	P.94，請補充說明模擬績效指標與前期計畫間的關聯性。	前期計畫並無挑選交流道場域，交流道實驗場域之模擬績效為本計畫重新規劃。	同意
8	建議計畫資料蒐集及現場實測，應盡量避免於非常態行為(如寒暑假、連假前後、大型活動前後)區間進行。	謝謝委員意見，本計畫之路口調查也避免非常態行為之區間，於暑假前 6 月底完成調查，如附錄一所示。	同意
六、李霞委員			

1	簡報 P.6 交流道區域及都會區幹道流程不同，部分流程設計乃考量前一年計畫，請於報告書中補充計畫關聯性。	謝謝委員意見，都會區幹道主要延續前期計畫持續選擇臺南實驗場域及臺北市實驗場域，因此在場域選擇上無需重新選擇，而交流道區域為本期計畫新增之實驗場域。	同意
2	簡報 P.8 提出之關鍵課題，請於期末報告書中補充能改善程度。	謝謝委員指教，本計畫與關鍵課題之處理方式，將於期末報告書補充。	同意
3	簡報 P.38 交流道協控部分，應考量設計不同應用情境。	謝謝委員指教，本計畫交流道 AI 號誌控制模型設計，可同時考量平面道路及匝道儀控，屆時因應實測狀況，AI 號誌控制模型可因應不同車流情境下紓解車流。	同意
4	簡報 P.57 不同實驗場域之績效指標設計不同，請補充各實驗場域績效指標設計不同之原因。	績效指標設計主要考量既有實驗場域特性而設計，臺南實驗場域為單一獨立路口，績效指標規劃為路口平均延滯、平均旅行時間及系統通過車輛數，臺北市實驗場域則為多路口廊道型控制，並考量幹道續進，績效指標除納入路口平均延滯、平均旅行時間及系統通過車輛數外，另增加幹道平均停車百分比及綠燈續進。	同意
5	本案需求說明書提及使用開源軟體，並外掛於相關人工智慧模型，請補充實際作法。	本計畫在模擬軟體主要採用開源軟體 SUMO，利用其模擬環境建構相關環境資料，以供本計畫之 AI 人工智慧模型進行訓練。	同意
6	本計畫完成後，能否提出建議之 AI 號誌控制模型導引手冊，以供縣市政府參考。	謝謝委員意見，相關 AI 號誌控制模型維護機制與建議將於期末報告書補充。	同意
7	報告書中用詞不一致，如等候長度、排隊長度等，請檢視整份報告書內容，並統一用詞。	謝謝委員意見，將一併修正為等候長度，並於期末報告書一併修正。	同意
8	P.87，請補充使用停等車輛採用雷達方式之原因。	謝謝委員意見，此為報告書誤植，該場域停等車輛應為透過 CCTV 畫面辨識等候長度。	同意
七、交通部高速公路局(書面審查意見)			
1	報告書 P.6 建議本段可修正成：做為人工智慧號誌控制「參考」使用。	謝謝意見，已於期末報告書進行調整。	同意
2	報告書 P.77 有關本段所述 Google 或 TomTom 之 GVP 資料，建議可補述其資料規模。	本段所述之 google 及 TomTom，抑或 GVP 資料，皆視實測長度而定，則以欲實測時段如平日晨峰 7-9 點、平日離峰 12 點 30 分-14 點 30 分、平日昏峰 16 點 30 分-18 點 30 分及假日昏峰 16 點 30 分-18 點 30 分，以 5 分鐘為一筆蒐集事前及事後資料。	同意

八、臺北市政府交通局(書面審查意見)			
1	附錄一 P.15、P.16 編號 X5 的中山北路六段/忠誠路一段，經檢視該路口並非為十字路口，且在中華電信公司臺北營業處旁設有機車待轉區，但在附錄當中並未提及。	附錄一 P15 該示意圖之 C 方向，是中山北路六段 35 巷，位在該路口傾斜往南向離開路口的單行道，與中山北路六段南向的道路相異，故調查示意圖中只有離開路口方向車流。	同意
2	附錄一 P.18、P.19 經檢視克強路向西的部分有分橋上與橋下的道路， 但附錄當中卻沒有細分此情況，試問附錄當中的數字為計算全部的情況總數，還是只有計算要過橋的情況數目而已。	該數值為全部總數，不分橋上與橋下。AI控制模型會影響中山北-克強向西方向的流量，磺溪-克強是實測場域的周邊道路，故調查流量除為了模擬建模外，僅做為評估周邊道路受影響的根據，故僅看總流量而不需區分是否上橋。	同意
九、新北市政府交通局(書面審查意見)			
1	有關實驗場域測試 AI 號誌控制模型與目前採用的動態號誌在號誌連鎖操作上的效果及差異為何。	在號誌控制上，動態控制與AI號誌控制的角色無異，原理皆為透過感測器偵測實際資料後，進行秒數決策。概略說明兩者最大的差別，動態號控的秒數計算邏輯，是基於歷史資料計算後得到model-based的決策；本計畫AI的強化學習，則是基於歷史資料自我訓練後，得出model-free的決策模型。	同意
十、 桃園市政府交通局(書面審查意見)			
1	在號誌控制週期上，平面道路是採用週期式，而匝道乃採用秒數，可能在 AI 模型設計上決策有時間差，請補充其設計概念。	本計畫於協控場域規劃兩個代理人，考量模型上決策有時間差，因此在兩個代理人資料抓取時間規劃為匝道代理人於平面道路週期結束時抓平面道路資料作為決策，平面道路代理人於民族路二段/文化街 8 巷分相結束時抓取匝道及平面道路資料作為決策。	同意
2	平面道路的交通量並非皆與上匝道有關，而在模型參數設計上，是否需要另外進行參數調教，請補充說明。	在模型參數設計上主要於模擬軟體建置時，於平面道路設定一定比例車流上匝道，其他比例則為行經平面道路之車流。	同意
3	臺北市實驗場域僅有一個代理人，請補充其設計之原因。	因臺北市實驗場域僅控制一個路口並連鎖另兩個路口，因此設計上僅需一個代理人即可。	同意
4	縣市政府如何在不需要新建車流偵測設備下，以既有車流偵測設備規劃 AI 號誌控制模型，能否於計畫中提出相關建議。	謝謝意見，將於期末報告書提出相關建議。	同意

十一、臺中市政府交通局			
1	有關本計畫所建置之 AI 號誌模型，請補充說明具體欲解決之問題。	AI 號誌模型之建立及訓練，主要因應於實測狀況下，AI 號誌控制模型可因應不同車流情境下紓解車流。	同意
十二、交通工程技師公會(書面審查意見)			
1	人工智慧的強化學習 RL 已經是號誌控制的演算法主流趨勢,且在 5G 及 V2X 的技術驅動下,將有機會實現市區大規模交通路網的即時適應性號誌控制。十分肯定運研所能投入預算資源在此方向上，且研究廠商能在短時間內投入強化學習 RL 演算法研發上，並且先在 Vissim 及 SUMO 兩類微觀模擬軟體實驗,再於台北及台南兩個真實環境下實測，亦實屬不易。	謝謝委員指教。	同意
2	因強化學習 RL 的模型品質，來自於學習成效的好壞，而學習成效的好壞則來自於偵測器資料的品質,所以建議在實測本案交流道區域人工智慧強化學習協控模型時,亦可以記錄資料的穩定度及可靠度狀況(如斷線、延遲與疏漏等)，據以分析資料品質好壞對於模型準確度的影響程度。	謝謝委員意見，本計畫於現場實測時，亦有系統記錄當下伺服器連斷線之情形，可作為實測後分析之依據。	同意
3	本案因是系列研究之第二年，可以延續之前的研究成果,進一步討論 AI 演算模型之輸入與輸出決策績效關聯,比對不同輸入與輸出決策對於績效(如 GVP 的旅行時間)之影響。並且增加輸出決策的多樣性，例如週期、時相增減、時相順序、連鎖或不連鎖、續進帶寬變化、自動分割時制計畫或無時制計畫等,才有機會產	謝謝委員意見，交通號誌策略所需考慮之因素非常多，將於期末報告書中建議後續計畫納入考量。	同意

	生更加之績效。		
4	目前世界主流趨勢是發展泛用型的 AI 演算模型，若套用在適應性號控的應用上，就是在時段上的泛用(全日 24 小時、平日假日尖離峰、全年 365 天)，及地域上的泛用(都市單一路口、路段、路網，郊區、偏遠地區，匝道、一般道路等)，這可以是未來運研所在持續投入相關研究之方向參考。	謝謝委員意見，將於期末報告書中建議後續計畫納入考量。	同意
5	因外在環境的變化會影響 AI 演算模型績效表現，建議可於實測計畫執行時， 若碰到外在環境變化時也要紀錄，如天候狀況(如雨量)、起霧影響視線、 施工交通維持、單位時間大型車輛高過一定門檻、單位時間行人穿越路口高過一定門檻時。	謝謝委員意見，相關建議將於實測計畫時進行記錄。	同意
6	事前事後績效評估資料來源有增加 Google 或 TomTom 等 GVP 資料，已可納入旅行時間變化。若經費許可，可以同時納入 Google 及 TomTom 兩種 GVP 資料比對。若經費不許可，則建議優先納入 Google 的 GVP 資料。	謝謝委員意見，本計畫將依經費許可下納入相關 GVP 資料，另於期末報告書中補充說明。	同意
7	因未來 AI 演算模型將有機會成為號控主流，本案如果可能的話，也可以提供一些建議，來修正並改善號誌控制器及相關協定等。	謝謝委員意見，將於期末報告書中建議後續計畫考量。	同意
8	本案目前無考慮行人與車輛之平衡演算，未來在運研所持續投入研發時， 可以將行人與車輛同時在 AI 演算模型中納入。透過偵測行人通過	謝謝委員意見，本計畫目前尚無考量行人資訊，將於期末報告書中建議後續計畫納入考量。	同意

	量、步行速度、通過方向等，控制行專用時相啟動時機、行人綠燈早開時間、行人綠燈早閉時間等。且同時平衡車流在路口之效率。		
9	本案預計辦理推廣活動，建議亦可廣邀地方政府、中華智慧運輸協會會員、號誌控制器廠商及交通工程技師公會會員等。	謝謝委員意見，本計畫期末階段將辦理相關宣導活動並邀請相關單位與會。	同意
十三、本所運輸資訊組(書面審查意見)			
1	請說明第二章所回顧國內外路口路段之號誌控制與號誌協控演算法或模擬系統，如何回饋於第三章及第四章 AI 強化學習在號誌控制模型設計與學習上，其關聯性為何？例如：P.25 所介紹 ACTM 或浴缸模型與 P.26 加入 equity 因子後之模型，與本案所設計 AI 號誌控制強化學習模型之異同；又如 P.27 所回顧陳又均之協控多代理人論文，與本案 CTDE 架構之差異為何？	1.補述內容於 2.2.2.1 引文中。如以關聯性來評估，文獻主要分為「模型設計」以及「模型架構」兩個方向說明。 2.模型設計如 ACTM 及浴缸模型，是說明該文獻以此兩種交通模型作為交通設計，故該文獻之 State, Action 及 Reward 會以此架構設計模型的輸入及輸出，equity 之文獻亦然。 3.模型架構如以陳又均該篇文獻為例，該文獻為多代理人，但為各自訓練，各自決策，故以定義上來說為 DTDE；本計畫預計嘗試之 CTDE，為共同訓練，各自決策。	同意
2	P.36~P.56 對於人工智慧強化學習模式內容似均摘錄自前期報告，請酌予濃縮與精簡，並就去年實測時之發現與經驗(2.4 節)，補充說明本案在模式設計與實測規劃精進之處。	謝謝意見，將於期末報告書補述及濃縮文獻內容。	同意
3	P.57 提出 PEARL (概率嵌入式強化學習)演算法，請補充說明新增與導入該演算法之考量，及其與前期類似演算法之差異，以及適用性與可能之限制等。	PEARL 能處理多模態資料輸入的情形，可在不同時制計畫中能夠應對不同的分相數或轉向需求，前期計畫之臺南市實驗場域採用 Q-Pensieve 演算法處理，是依不同時段切分，並個別訓練，本計畫因考量跨時段之處理，故採用 Q-Pensieve 整合 PEARL 構建。	同意
4	第三章部分		同意

	(1) 請補充說明臺南市與臺北市實驗場域之本期與前期在各式路側設備與號誌時制計畫限制之異同，及 AI 號誌控制模型之因應調整設計與內容。 (2) 請補充說明在考量 2.4 節所提關鍵課題與實務運作需求下，本期在臺南市與臺北市實驗場域 AI 號誌控制模型設計之精進作為。 (3) 請補充說明臺南市實驗場域所進行車流偵測資料檢核緣由與結果，及臺北市實驗場域補充交通量調查之目的與分析結果。 (4) 根據 P.73 表 3.2.3-2 臺南市實驗場域訓練結果表，請補充說明相較於前期成果之改善情形，若不如預期，後續之可能處理為何？ (5) 3.3.2 實測計畫節表 3.3.2-1 實測例外事件對於系統面異常事件處理進行說明，請補充說明如何掌握 AI 號誌控制模型運作時道路交通績效，以及如何設定異常門檻值與配套之交通管理或降級運轉工作。 (6) 請補充說明 3.3.3 節事前事後量化績效評估之具體資料來源與資料特性。	(1)本期臺南市與臺北市時制計畫詳述於 3.1 節，臺南市實驗場域與去年相異有二，其一為今年之晨峰時相皆為 5 時相，其二為臺 19 甲方向之秒數較去年減少。臺北市實驗場域相異點為 195 巷增加行人早開時相。 (2)臺北市實驗場域因車流偵測設備減少及時制計畫調整，演算法則沿用去年之演算法 Q-Pensieve 進行重新訓練，臺南市實驗場域前期計畫採用 Q-Pensieve 演算法處理，是依不同時段切分，並個別訓練，本期計畫因考量跨時段之處理，故採用 Q-Pensieve 整合 PEARL 構建。 (3)臺南市實驗場域之現場偵測設備因日前颱風造成現場設備故障，設備重新更換，後續須再重新進行準確度驗證，臺北市調查流量目的為建構事前模擬模型，並依此做為評估事後周邊道路受影響的根據之一，資料如附錄一，經與前期交通量調查比較結果，本次調查結果交通量較前期下降。 (4)期中報告書表 3.2.3-2 為目前訓練結果，後續將持續進行模型調整與再訓練，若模型持續無法改善優於固定時制計畫，將於工作會議上提出與機關進行討論。 (5)AI 號誌控制時期之績效，目前規劃透過事後 GVP 資料作為績效指標，詳 3.3.5 節。期中報告書表 3.3.2-1 為例外事件處理，其中現場控燈為交警或其他交通單位主動取回現場控制權之情況，而系統將於無法與號誌控制器連線下達指令時，自動降階回復固定時制計畫。 (6)臺南市實驗場域績效規劃為路口平均延滯、平均旅行時間、系統通過車輛數，其中路口平均延滯、平均旅行時間，資料來源為 TomTom 之 GVP 資料，系統通過車輛數資料來源為既有臺南市政府交通局之 CCTV 辨識	

		結果。	
5	第四章部分 (1) 請補充說明本案協控實驗場域桃園市中壢交流道範圍之高速公路與平面道路的車流偵測設備、號誌控制設備、控制策略內容等設備與資料現況。 (2) 請補充說明 4.3 節實驗場域模擬模式構建過程如何將現況平面道路號誌與匝道儀控同時納入模式進行運作，以進行同步道路績效資訊蒐集，以及績效評估與模式校估工作。 (3) 目前模擬模式校估以高速公路主線與平面道路之通過車輛數為依據，並未考量道路績效(例如：停等延滯、等候線長度、旅行時間等)，請補充說明此作法之參考文獻及其合理性。另此校估方式如何掌握各匝道之交通績效，以及因匝道儀控可能之平面道路衝擊與因平面道路號誌造成高速公路下匝道車流之回堵。	(1)已補充相關說明，如期末報告書 4.3.1 節。 (2)在模擬軟體中，於上匝道處設置號誌，並且給予平時控制之儀控率，即可在模型中實現儀控，而在匝道中設置偵測器，即可模擬匝道 VD 的偵測情況，輸出績效。 (3)目前模擬模式皆以 GEH 作為模型校估，並未考量其他道路績效，其原因有兩點，並後續將補述 GEH 文獻於本文中。 A. 本計畫亦有回顧文獻提及以延滯作為模擬模型校估指標，惟延滯調查本身即具有高度誤差，故過往文獻中，模型提及延滯校估者，其 MAPE 容忍值皆超過 30%，並且仍以流量校估作為模型是否可用之最終決斷。 B. 流量校估模型為建置模擬環境者最常使用的校估手段，而不似 MAPE 為泛用校估指標，GEH 基本設計用於以流量校估模擬模型，並且常見用於公共工程評估，頗具參考價值。	同意 同意 同意
6	請以圖形方式呈現 AI 號誌控制模型在訓練與測試過程之各種效能或績效變化，以及補充說明績效評估機制、模型參數調整與校估過程。	已補充臺南市訓練相關圖例，如期中報告書 P.69~P.70 所示。	同意
7	請補充說明後續在號誌協控的車流資料與控制策略及流程上，與高速公路局及桃園市	感謝委員意見，已補充於期末報告書 4.3.3 節。	同意

	政府交通控制系統間之運作需求與規劃。		
8	有關報告初稿中之錯漏字、語句不適當與資料來源修正部分，請於會後洽本所。	感謝委員意見，將配合於期末報告書進行修正。	同意
十四、主席結論			
1	簡報 P.8 提出之關鍵課題，可能有些能做到，也可能有些做不到，應於期末報告書中說明實際處理作法。	謝謝主席意見，後續將於期末報告書補充說明。	同意
2	審查會議各委員及與會單位研提之口頭及書面意見，請資拓宏宇國際股份有限公司整理「審查意見處理情形表」，且逐項說明回應辦理情形，並充分納入報告之修正。	遵照辦理。	同意
3	本計畫經徵詢審查委員意見，期中報告初稿審查通過，請資拓宏宇國際股份有限公司後續依本所出版品印製相關規定撰寫報告，並納入每月工作會議查核事項進行追蹤。	遵照辦理。	同意

附錄二 期末審查意見回覆表

項次	審查意見	回覆內容	主辦單位意見
一、李明聰委員			
1	報告書第三、四章， (1)請增加說明模擬環境的驗證參數，如：路口延滯時間、紓解率.....等。	有關模擬環境參數調校及驗證，詳報告書 3.2.1 節 P.78、4.2.1.2 節 P.62。	同意
	(2)補充說明實測過程各種情境的效果，以了解AI在各情境下的優勢與劣勢，並作為持續改善的資訊。	本計畫都會區(臺南及臺北市場域)以及交流道(中壢交流道場域)實測時段包含平日上午尖峰、離峰、下午尖峰及假日下午尖峰，各時段皆僅採用一種權重情境如幹支道延滯最低、幹支道通過量最高、幹道延滯及通過量最高、支道通過量及延滯最高或平均，因此，若需了解各 AI 權重情境優劣勢比較，各情境應要有較長的實測及績效蒐集。	同意
2	報告書第三章， (1)幹道控制情境建議補充說明AI控制後的續進績效。	有關幹道 AI 控制後的續進績效已補充，詳報告書 3.3.5.2 節 P.139~141 所示。	同意
	(2)高速公路與平面道路協控情境，建議補充說明2層路網可協控的情境與對應的績效。	RL 模型針對中壢交流道場域建構兩個控制 Agent：一個負責平面道路路口號誌控制，另一個負責匝道儀控。兩者通過共享即時車流資訊進行協同決策，特別是在平面道路與匝道匯流處理上，能有效提升整體交通效能。 關於委員提到的「2 層路網」情境，實際採用的是單一整合路網，並分平面道路號誌及匝道儀控兩群組，而非分層控制。兩者通過共享即時車流資訊進行協同決策，特別是在平面道路與匝道匯流處理上，能有效提升整體交通效能。 而績效指標設計為平面道路及匝道通過量、率行時間降低、平面道路路口延滯降低以及觀測排隊長度。	同意
3	報告書第六章，補充說明推廣或移植的可能性。	感謝委員意見，已補充於第六章。	同意
4	請於結論與建議章節針對本計畫之關鍵課題、計畫目的補充說	感謝委員意見，已補充於第六章。	同意

	明成果。		
5	建議於報告書中補充說明AI號誌控制模型訓練過程中所遭遇之困難與解決方式、後續精進空間。	在 CTDE 的訓練過程中，由於匝道與平面道路的號誌時間週期不一致，匝道的時間週期通常較短，這導致觀測數據存在收集時間不一致和資料量不平衡的問題。這種情況可能使模型在訓練時過度偏向匝道的最佳解，從而影響整體的訓練準確性。為了解決這一問題，在將數據存入資料庫之前，對匝道和平面道路的數據進行篩選和處理，僅保留匝道與平面道路最接近的決策時間作為訓練資料。此方法有效地減少訓練偏差，避免模型過度關注匝道特徵。然而，這一策略也帶來了一定的代價，即犧牲了部分匝道的數據信息。如何在未來的研究中有效利用所有匝道和平面道路數據，平衡數據稀疏性與訓練精度，將是 CTDE 框架下值得進一步探討的重要課題。	同意
二、陶治中委員			
1	報告書提出強化學習之類型分層圖，建議針對欲解決問題類型：(1)不精確的狀態資訊、(2)單一路口、(3)幹道、(4)區域路網、(5)區域協控彙整出相對應的強化學習演算法。	使用 Q-Penseive 演算法都可作為解決 5 種交通情況之基礎演算法，其主要因為其多目標之應用在交通領域下，能加速訓練並且能在單一目標中找出不同策略中的最優解，但在不同情況可引用不同之運作架構如 CTDE 與 Meta-Learning，其中 CTDE 較為適合解決區域協控等含有不同協控類型之場域。而 Meta-Learning 等相關演算法會較為適用於場域含有不精確之狀態資訊但也都適用，主要應用在整合狀態資訊使其能減少資料運用但也能涵蓋模型需訓練之資料型態。	同意
2	臺北市、臺南市、桃園市中壢交流道等實驗場域使用之各式 AI 演算法為何？	臺北市、臺南市、與桃園市等場域之演算法都是以 Q-Pensieve 為基礎，但其運作方式會因各場域之特性與今年考慮之優化方向額外新增訓練架構而非演算法。以此情況，臺北市為使用 Q-Pensieve 演算法配合協控架構，臺南市為使用 Q-Pensieve 架構配合 PEARL 架構，桃園市則使用 Q-Pensieve 配合 CTDE 架構。	同意

3	各路口時空相關性應可使用圖卷積神經網路(GRN)來界定路口(節點)與路段(邊)不同的權重。	在本期實作中，採用 CTDE(Centralized Training Decentralized Execution)的方式協助 RL 進行訓練。過程中，直接將所有路口的相關資訊作為輸入，用於訓練模型(Du. et al, Zang. et al)。這樣的設計使 RL 通過學習來捕捉全局路口之間的時空相關性，進一步幫助模型收斂到最佳的權重分配。 此外，認同圖卷積神經網路(Graph Convolutional Network, GCN)在交通號誌控制問題中的潛力。GCN 可以更精確地建模路口與路段之間的時空依賴關係，根據其結構和數據分佈來自動計算不同的權重。結合 RL 與 GCN，能提升對交通系統全局特性的理解，藉此來加速模型的收斂，從而實現更高效的交通號誌控制。	同意
4	獎勵函數由若干指標的加權和，權重大多依據經驗而定，熵權法應可納入未來研究方向。	在傳統的強化學習(Reinforcement Learning, RL)中，確實需要明確地定義一個獎勵函數，這個函數通常用來指導學習方向。然而，這樣的設計確實會面臨兩個問題： 1.需要依靠經驗法則來確定各指標的權重。 2.不同任務(ex:平日時段或假日時段)對權重的需求並不相同。 因此，在本次實作中，採用多目標強化學習 (Multi-Objective Reinforcement Learning, MORL)的協助，可以在不依賴人工設計權重的情況下，通過系統自動測試和模擬各種獎勵函數的組合，從而學習不同指標之間的最佳平衡關係。我們也相信，如果能結合熵權法的使用，將其應用於獎勵函數設計中，將進一步提升 MORL 在收斂到最優解時的效率。這種結合不僅能有效減少主觀性干預，還能更快地適應不同任務需求，是未來值得深入研究和嘗試的一個方向。	同意
5	狀態資訊使用的位置矩陣與速度矩陣是稀疏的，空間稀疏卷積網路可解決上述問題，降低	在本期實作中，由於環境中的 State 維度偏高且數值為轉向量或號誌資訊，我們在訓練過程中確實觀察到稀疏性問題對模	同意

	計算複雜度。	型帶來挑戰。為此，我們設計了一種將狀態(State)和偏好(preference)分開的網路模型： 1. 狀態(State)：通過更高層且較大的網路單獨提取狀態特徵，解決高維稀疏性問題。 2. 偏好(Preference)：在提取特徵後，再與偏好信息進行結合，避免直接處理高維數據導致的效率瓶頸。 這項改進有效降低高維稀疏問題的影響。同時，認同空間稀疏卷積網路(SCN) 作為未來值得探索的解決方案，以進一步提升特徵提取能力。	
6	事件對於狀態資訊蒐集產生不準確的狀況，如何確保狀態資訊蒐集不中斷，無人機偵測或可納入考慮。	感謝委員建議。本計畫已考量事件可能導致資訊蒐集中斷的情境，目前透過多源數據整合(如即時交通流資料與歷史模式補全)減少影響，並評估加入無人機偵測作為輔助，以強化關鍵區域的即時狀態資訊蒐集，確保 AI 運作穩定性與可靠性。	同意
7	建議未來導入聯網車(CV)、無人車(AV)之交控模式，如何持續研究 RL 之 AI 模式。	感謝委員建議。若未來聯網車(CV)或無人車(AV)普及後，個別駕駛行為影響道路車流情形將大幅減少，後續可以考慮強化學習為基礎，研究針對車輛協作與全局流量優化的交控模式，並整合 V2X 技術模擬，開發適應 CV/AV 場景的 AI 號誌控制模型。	同意
三、范俊海委員			
1	簡報 P.20，獎勵有延滯與通過車輛數，延滯的單位是秒，而通過車輛數為幾輛車，秒與車輛數是不同性質參數，如何整合為績效的判斷？即使使用增長率不見得具穩定或代表性，是否可能影響模型決策品質，建議執行團隊可探討是否應延續使用過往交通控制的績效標準。另績效之權重如何界定？請補充說明。	在 Q-Pensieve 模型設計過程中，針對延滯時間(秒)與通過車輛數(輛)之異質性，團隊採用標準化處理方式，延滯時間轉換為虛擬車輛損失數，即單位延滯時間內的平均車輛通過影響，使其與通過車輛數具備相同的量化單位。 增長率僅作為輔助分析工具而非主要獎勵設計，而為避免增長率指標的不穩定性，採用累積效益函數來整合多回合的績效，避免單次數據的波動對模型造成負面影響。並結合傳統交通控制指標進行模型驗證，例如延滯時間降低、通行效率提升及排隊長度減少等。	同意

		權重的設定基於場域特性與控制需求。例如在壅塞較嚴重的路段，延滯時間的權重會適當提高；在流量較高但壅塞較輕的路段，則會提高通過車輛數的權重。此方式確保模型決策符合實際交通需求，同時提升整體交通效能的可靠性與代表性。	
2	簡報頁 30 及 31，提到偵測的準確率為 96.4%、93.9%，做了準確度符合門檻。這樣的準確率是否對於整個系統模擬後有多少的誤差貢獻？我們並不清楚，或許對於績效影響微不足道，如果有明確的模擬結果，可能比較有說服力。	團隊於模擬設計中已採取數據濾波及動態校正措施，將設備誤差對績效指標的影響降至最低。為進一步評估準確率對模擬績效的貢獻，我們進行了敏感性分析，假設偵測設備準確率分別為 90%、95%和 96%，並觀察績效指標的變化幅度，結果顯示準確率從 96%降至 90%時，延滯時間僅增加 1.5%，通行效率減少亦不足 2%，表明設備準確率對模擬結果的影響甚小。 此外，由於訓練時輸入亦會輸入歷史流量與設備流量做交叉比對，因此當模擬系統在面對偵測數據的輕微偏差時，仍能維持較高的穩定性。	同意
3	簡報 P.47、48、49 有說明 AI 號誌控制模型決策與 TOD 的績效比較，每一項都有一些好壞，對於 AI 號誌控制模型績效不如 TOD 的原因，請補充檢討與可能的原因。	於部分實測時段，AI 號誌控制模型績效不如 TOD，原因可能有以下幾點： 1. 訓練數據的樣本覆蓋不足，導致模型無法充分適應某些高峰或特定情境。 2. 雖為多目標獎勵，但仍有偏重某些指標的可能性。 3. AI 號誌控制模型的超參數與學習策略可能未完全調校至最佳狀態。 4. TOD 控制基於歷史數據的設計對穩定場景具有天然優勢，AI 號誌控制模型在此類場景中的提升空間有限。 後續可改進優化的地方包括擴充訓練數據樣本、優化獎勵函數的權重配置、調整超參數及提升模型的適應性。這些調整也許能進一步提升 AI 號誌控制模型的整體績效，並增強其在多樣化交通場域的適應性及穩定性。	同意
4	簡報頁 50，請問服務水準是以延滯界定，還是有考慮通過量的因素？在假日昏峰中通過量	此服務水準係以延滯判斷，而假日昏峰中通過量增加但延滯顯著減少的情況，可能受到多重因素影響：	同意

	增加，延滯卻減少相當多，是否有甚麼因素造成？	1.假日以旅遊車流為主，駕駛行為更為穩定，且交通需求的分散性降低了主要幹道的壓力。 2.AI 號誌控制模型在假日場景中能更動態地適應交通流量變化，不似平日晨昏峰交通流易處於過飽和情形，導致效果不顯著。 假日實測當天天氣良好，促進交通流暢。	
5	簡報 P.54，請補充說明匝道儀控的決策頻率為 30 分鐘的原因，為何不是 15 分鐘、或 20 分鐘、或 45 分鐘，有何考慮。	考量交流道區域實測時，需由高速公路局值班台人員定時查看建議之匝道儀控秒數，依實務需求決定是否下達建議秒數，故擇定 30 分鐘決策頻率避免影響值班台人員日常庶務。	同意
6	簡報 P.55，為何 AI 號誌控制模型訓練步數越多，反而誤差卻放大？這是 Over fitting 過度適配的問題嗎？還是沒有太大的影響。	訓練步數上升反而誤差放大，此情況會有多種解釋，Overfitting 是部分原因，主要是模型對於部分數據過於專注，犧牲了其他數據的使用使其 Q-Pensieve 中的熵係數造成的探索策略使其上升，而之後可以發現模型誤差並非持續上升而是後續有在下降，使其可以認定為模型仍然收斂。	同意
7	簡報 P.73、74，AI 號誌控制模型決策結果與 TOD 比較，很顯然離峰的時候效果比較好，是否可以下一個結論，AI 號誌控制模型決策較適合於離峰時段決策協助。從這個觀點，我們可以發現 AI 號誌控制模型與傳統的適應性號誌控制系統(Adaptive Signal Control System)較為相近，在離峰時都有較佳的表現，而真正在尖峰壅擠時段，績效未必較佳的現象。	尖峰時段的表現雖然在部分場域不如 TOD，但這並非普遍現象或 AI 號誌控制模型不適用於尖峰時段的結論。以桃園市實驗場域來說，以下為可能影響尖峰時段表現的因素與分析： 1.實驗場域的交通特性(如高交通量、複雜路網結構)造成模型訓練與適應出現挑戰，但這些條件具有代表性，有助於測試 AI 號誌控制模型的極端性能。 2.實驗階段的模型可能因資料樣本量不足、部分參數調校尚有調整空間，導致模型在尖峰時段的表現略遜於 TOD。然而，這類問題可透過擴大訓練數據集、改善異常處理機制、增加模型泛化能力等方式逐步改善，降低實驗與實務應用的差異。 未來可考慮加入針對高流量情境的獎勵函數調整以及在更多場域測試模型的適應性，收集更多元廣泛的數據，驗證模型	同意

		在各種條件下的穩定性與績效。	
8	這樣的 AI 號誌控制模型發展流程系統，產生誤差的地方有哪些？哪些環節是關鍵節點？或者說是瓶頸在甚麼地方？請補充說明。	在 AI 發展流程中其關鍵節點為車流模擬環境建構與較估，程式介接 API，與強化學習演算法等三個環節。其中產生誤差大多為交通模擬軟體建構中之輸入值與交通模擬軟體對於車種之行為模式與現實中造成之偏差以及演算法優化造成之模型輸出與績效分析。瓶頸則為 API 介接程式，因介接程式需考慮模型使用之參數在現實是否可行，並且獎勵制度也須設定好否則訓練會沒有成效。	同意
9	行人的號誌時制的決策，其邏輯說明未見完整。	由於目前本計畫人工智慧強化學習號誌控制模型偵測設備均以車流為主，若實際現場設有行人早開、行人專用等時相，將會以固定秒數方式納入人工智慧強化學習號誌控制模型中。	同意
10	臺北市實驗場域績效是否真的受到通訊不穩影響，還是 AI 號誌控制模型本身的因素？請補充說明。	臺北市場域的績效主要受到通訊設備不穩定的影響，這可能導致部分狀態資訊的輸入不完整或延遲，進而影響 AI 號誌控制模型的即時判斷與輸出結果。AI 號誌控制模型本身經過嚴謹的訓練與驗證，具有穩定性與準確性，並在模擬環境中展現出良好的績效表現。然而，AI 號誌控制模型的運作依賴高品質的即時輸入數據，通訊中斷或數據延遲會對系統整體效能造成干擾。 為解決通訊不穩的問題，未來建議提升場域內通訊設備的穩定性與冗餘設計，例如引入多來源數據整合或使用備援機制以確保輸入數據的完整性。同時，亦可考慮優化 AI 號誌控制模型的抗噪能力，進一步減少因數據異常對模型輸出的影響，確保系統在實務運作中的可靠性。	同意
四、李霞委員			
1	第二章 2.3.5 總結僅有理論面之陳述，建議與本案欲解決課題加以連結(如多時段路口、路域協控不同時間點分別進行決策特性)，俾利後續演算法導入時之參考。	謝謝委員建議，有關強化學習(RL)演算法 Pearl、Task-Aware 及 Q-Pensieve 對於欲解決之交通課題及適應情境補充詳報告書 2.3.5 節 P.65 所示。	同意

2	期中審查階段曾建議團隊於期末時，針對 2.4 提出之關鍵課題檢視並提出後續建議，然期末未見相關說明，請提供本案成果適合導入路口及實驗場域大小等經驗。	感謝委員建議，已納入 6.2 節未來執行建議，於後續計畫深入探討 AI 號誌控制模型適用之路口與實驗場域，建置相關指引手冊。	同意
3	P.112 圖 3.3.3-2 AI 智慧號誌控執行流程之第一、二步驟為資料品質，資料異常時將降階處理，所謂缺漏或連線異常之定義為何？一筆異常即須降階？抑或連線幾筆始啟動異常作業程序？請補充說明。	資料缺漏指設備故障或連線異常導致 AI 號誌控制模型無法取得現場資料；控制器連線異常則表示通訊斷線無法下達號誌控制指令。 當設備資料導致 AI 號誌控制模型無法運算秒數時，為避免降階影響現場車流，因此將採用 TOD 秒數下達號誌控制指令；但若控制器連線異常則無法下達號誌控制指令，此時只能降階處理將控制權交還現場。	同意
4	P.119-120 臺北市實驗場域之異常比例？報告說明通訊不穩係發生於晨昏峰而須降階運作，另查臺北市、臺南市及交流道協控之實測數據觀察，亦顯示尖峰時段表現較 TOD 不佳，則是否意謂尖峰時段不適合導入 AI 號誌控制模型？或該實驗路口為特殊狀況或為實務上皆會發生現象？請補充說明。	臺北市實驗場域異常比例，詳報告書 3.3.4.2 節 P.129 及 P.141 所示。 而尖峰時段的表現雖然在部分場域不如 TOD，但這並非普遍現象或 AI 號誌控制模型不適用於尖峰時段的結論。以下為可能影響尖峰時段表現的因素與分析： 1. 尖峰時段的網路通訊不穩是影響模型表現的主要原因，導致偵測數據不完整，模型無法即時進行最佳決策。 2. 實驗場域的交通特性(如高交通量、複雜路網結構)造成模型訓練與適應出現挑戰，但這些條件具有代表性，有助於測試 AI 號誌控制模型的極端性能。 3. 實驗階段的模型可能因資料樣本量不足、部分參數調校尚有調整空間，導致模型在尖峰時段的表現略遜於 TOD。然而，這類問題可透過擴大訓練數據集、改善異常處理機制、增加模型泛化能力等方式逐步改善，降低實驗與實務應用的差異。 未來除加強實驗場域通訊穩定外，加入針對高流量情境的獎勵函數調整、數據缺失時模型仍能穩定運作之異常處理策略，以及在更多場域測試模型的適應性，收集更	同意

		多元廣泛的數據,驗證模型在各種條件下的穩定性與績效。	
5	匝道儀控與平面道路號誌控制：簡報 P.75-76，尖峰時段路口整體延滯增加,效果不佳,入口匝道車道及長度配置、車流量是否影響模式表現？請補充說明。	入口匝道車道與長度配置僅能容納有限的排隊車輛，當尖峰時段車流量過大時，匝道排隊會 queue 回平面幹道，導致延滯增加。 尖峰時段的車流量波動較大,尤其是突發性車流湧入，可能導致 AI 號誌控制模型短時間內無法完成有效調整,進一步加劇路口延滯。 又RL模型需兼顧平面道路上下游交通流以及高速公路主線車流的平衡,然而尖峰時段匝道車流量過大可能優先觸發匝道儀控,而平面道路路口因此延遲綠燈秒數開啟，進一步導致整體延滯增加。	同意
6	目前的運作模式為半小時決策一次輸出下個時段號誌週期建議，是否因須累積半小時之路況資料量？抑或無法即時運算？或有其它原因？請補充說明。	本計畫交流道RL模型本身可以於平面道路路口產出下一週期分相時比時輸出結果匝道儀控結果,但現實上匝道儀控除考慮交通流量變化外還有轉換控制的頻率,因此團隊在匝道部分設置了每半小時調整一次的條件,這樣的設計是為了避免過於頻繁的調整，並確保更穩定的控制效果，符合實際操作中的需求。	同意
7	本案研發成果是否可以因應臨時性的車流異常？請補充說明。	模擬環境是依據現場交通調查資料進行建置，AI 號誌控制模型於訓練時依據模擬環境亂數提供之各種車流型態進行決策，以求於各情況皆能提供最佳解，除非臨時性車流異常流量與模擬環境大相逕庭,否則本案研發成果於一定範圍下可因應臨時性之車流異常。	同意
8	一般車流下，**高速公路局**已透過大數據多年經驗建立 32 套匝道儀控率，本研究相較有何優勢？請補充說明。	高速公路局建立之匝道儀控率為多年大數據經驗累積，本計畫 AI 號誌控制模型參考其匝道儀控率,將計算結果經由換算套用**高速公路局**之匝道儀控率並提出實測建議秒數。	同意
9	本案成果具體產出為何？除報告外，建議提出模型建構指引(選點-道路條件、車流特性、設備品質等、模型建構、成效分析、維護)，另本案開發之系統	本計畫完成 3 個實驗場域之 AI 號誌控制模型訓練與實測,相關建構指引已補充於 6.1、6.2 節。本案開發之 AI 號誌控制模型受限場域路口特性、時制計畫與車流型態，無法直接移植供其他縣市使用。	同意

	程式是否亦屬成果可供其它縣市使用？請補充說明。		
10	結論中，請綜整會影響模式整體表現之可能因子，俾利後續選點或模型建構。	感謝委員意見，已補充於 6.1、6.2 節。	同意
五、莊國欽委員			
1	P.6 本計畫預期效益所列，「後續將可結合 5G 骨幹傳輸網路…發展…創新交通控制模式。」，惟後續章節並未再說明如何導入 5G 及相關效益，建議可再予以補充。	人工智慧號誌控制若結合 5G 高傳輸速度、低延遲、巨量接收之特性，於現場偵測資料部分，資料可全數回傳由中心主機進行判讀，提升判讀效能與準確度；於號誌控制部分，可大幅減少因網速、延遲導致中心與現場控制器指令不一致而發生之降階情形。	同意
2	P.142 本研究採用 MAPE 及 GEH 做為量化誤差指標驗證，建議補充文獻回顧之章節。另建議於本節簡要說明前述指標必須滿足之門檻，俾利進行績效比對。	謝謝委員建議。已於報告書 3.2.1 節及 4.2.1.2 節中詳細說明使用 MAPE 和 GEH 作為量化誤差指標的選擇原因及其門檻設定。由於 MAPE 和 GEH 這些指標在交通模擬領域中較為常見，基於相關文獻回顧選擇這些指標來驗證模型的效果。對於 MAPE 的使用，於文中指出其局限性，並對其可能出現的問題作出了補充解釋，同時引入 GEH 作為輔助指標以避免 MAPE 的偏差。 此外，關於文獻回顧的部分，團隊已於相應的段落中結合相關文獻的背景與分析，並強調本研究指標選取的合理性，因此不另設立獨立文獻回顧章節。若委員需進一步了解具體文獻資料，團隊樂於提供相關的補充資料。	同意
3	P.142 依據表 4.2.1.2-3，交通量過高路口如民族路二段/中壢北匝往北、民族路二段/中壢南匝往南，均產生 MAPE 差異超過 40%之情形，與本節所述「調查數值極大時，MAPE 也容易低估，造成配適良好的假象。」，論述內容及實際 MAPE 值，似乎有矛盾，建議再予以說明。	謝謝委員指正。如表 4.2.1.2-3 所示，出現 MAPE 差異超過 40%的情形。這一現象表明，當交通量極高時，MAPE 指標可能無法準確反映模擬結果的適配度，這是由於高交通量情況下，實際數據的波動性較大，MAPE 指標會因數據的高值而顯得過於敏感，可能會導致偏低的誤差評估。 為了解決這一問題，這正是為何於本計畫中同時引入了 GEH 指標來輔助評估模型的適配度。GEH 指標能夠避免 MAPE 可能帶來的偏差，特別是在高交通量的情況	同意

		下，因此提供更全面的績效評估方式。	
4	P.143 建議於本節簡要補充倫敦或內華達州之建模規範。	謝謝委員指教，已補充倫敦及內華達州建模規範詳報告書 4.2.1.2 節 P.156 所示。	同意
5	P.152AI 模型訓練結果圖之 X 軸為訓練步數，仍有下述疑義，建請提供說明： (1)是否有訂定收斂之標準或是限制訓練之步數或回合數。	在模型訓練中並沒有所謂的標準，其訓練指標會因演算法與獎勵目標而有所變化，但其中會引用其它措施如早停(Early Stopping)用於利用獎勵變化去停止訓練或更改參數而非只依賴損失值，Regularization 或 Dropout 來減緩訓練指標等。	
	(2)是否每步為1秒。	X 軸之訓練步數每一步為模型收集一定數量資料後的更新步數，其一步會因演算法與模型設計而有所變化，但在此案中約為 5-10 分鐘。	同意
	(3)X軸是否可對應晨、離及昏鋒相對時間。	收斂圖之 X 軸為對應訓練中的步數，主要是跑完模擬後之後的指標並非對應模擬中的時段。	同意
	(4)Y軸收斂值，有線性減少及趨於平緩2種，可否探討2者之差異及原因。	線性減少通常發生於早期訓練階段，主要為模型還未學習任何資料型態與行為模式使其訓練幅度成線性減少，而趨於平緩則為模型訓練到後期，模型以適應大多資料型態與行為模式，導致其訓練更新幅度較小，導致收斂逐漸平緩。	同意
6	P.177 考量實務運作上，匝道儀控現場設置有紅綠等倒數秒數，另考量下達匝道儀控時制需反應時間，因此本案經計算所建議之匝道儀控率秒數，是否考慮平滑機制或考量號誌時制轉換現況，以因應實務運作需求？請補充說明。	本案的匝道儀控率建議已考量到現場實際操作需求，包括倒數秒數顯示及儀控轉換反應時間。在輸出的匝道儀控率中加入平滑機制，有效避免儀控率的劇烈波動對現場操作及駕駛者造成的負面影響。同時，為確保匝道流量的有效管理，在模擬過程中針對不同交通流量條件進行多次實測與調校，以驗證該平滑機制的有效性及實務適用性。	同意
7	P.195 本計畫所建構之人工智慧強化學習號誌協控模型，建議探討不同之適用情境，並以實際交流道及平面道路，提出對應之交控設備布設原則(AI CCTV、eTag、RMS 等設備種類及設置間距)，提供場域單位未來設備建置之參考。	感謝委員意見，已補充於 6.2 節。	同意

8	本計畫採用之績效指標較難說服委員或讀者，建議執行團隊可再思考設計之嚴謹度與權重考量。	謝謝委員指教，本計畫採用之績效指標選取基於交通控制與管理的核心目標，採用衡量交通系統運作效能的通過量、直接反應通行效率和使用者成本的旅行時間、對於路段運行效能和號誌控制優化具衡量指標之路口延滯，以及提供交通壅塞空間視角之排隊長度觀測，與路口延滯互補，應已於選取與權重設計上充分考量其全面性與代表性，並透過文獻回顧與實驗結果加強其嚴謹性及說服力。	同意
9	當有特殊事故發生時，AI 號誌控制模型是否可配合現場設備進行事件反應，如：中壢交流道下游設有 CMS，可於 CMS 發布建議路徑；AI 號誌控制模型訓練時也可加入開放路肩之訓練考量。	AI 號誌控制為針對現場車流狀況進行號誌秒數決策，但可利用現場車流偵測設備搭配事件反應機制，如 AI 辨識 CCTV 偵測事故發生，可將資料回傳至中心事件反應系統進行改道訊息發布；若車流模擬軟體中具有路肩開放設定，則 AI 號誌控制模型於訓練時可將其納入決策考量。	同意
10	P.149 表 4.2.2-11(交流道實驗場域 AI 號誌控制模型獎勵計算公式表)設定 5 個獎勵目標，惟並未說明權重設定。因目標值訂定十分重要，獎勵值的權重的設定也會影響整體目標值績效，建議本研究對於權重之探討，再予以補充說明。	感謝委員指教，其權重設定將於在同一張表 4.2.2-2 進行補充說明。	同意
11	本研究以單一路口、幹道型多路口、單一交流道與平面道路之協控，循序建立 AI 號誌控制模型，並以 SUMO、VISSIM 建構交通車流狀態以及號誌狀態模擬，以實際場域交通資料進行參數校估，研究步驟及方法予以肯定。	謝謝委員給予研究的肯定，未來團隊將進一步探討多模態交通的協同控制問題。	同意
12	本研究採用 MAPE 及 GEH 做為量化誤差指標驗證，驗證調查輸入及模擬輸出之差異，AI 號誌控制模型績效驗證方式相當嚴謹，值得讚許。	謝謝委員肯定。	同意
13	建議未來可適度擴大研究範圍，能將高速公路路廊管理納	感謝委員意見，未來於交流道協控部分可嘗試納入高速公路路廊。	同意

	入研究範圍，可增加本研究之價值。		
六、許佳興委員(書面審查意見)			
1	請補正報告書中格式或圖片問題： (1)頁II→"錯誤!尚未定義書籤。"	感謝委員意見，已完成修正。	同意
	(2)圖說明跳頁，例如頁23-24，圖2.2.2.1-3；頁29-30，圖2.2.2.1-14。	感謝委員意見，已完成修正。	同意
	(3)圖2.2.2.1-14圖內簡體字。	謝謝指教，已修正圖 2.2.2.1-14。	同意
	(4)文獻回顧所使用之圖表是否有copyright的疑慮?可能需要重新繪製，請檢查。	謝謝委員指教，所引用之圖表均註明來源，且限於本計畫學術用途引用，應屬合理使用範疇。	同意
	(5)期末報告第三章和第四章為重要成果說明，很多分析的圖片很不清楚，無法明白呈現相關成效。	謝謝委員指教。由於本計畫第三章與第四章所呈現之圖表，旨在完整呈現分析結果，因此包含較多資訊，然考量黑白印刷之限制，部分圖表細節可能不易辨識，為能更清晰呈現研究成果，我們將於研究報告正式出版後，於運研所網站提供彩色電子檔供讀者下載，以利更深入探討。	同意
2	報告書第一章是否應該補充一節"進度與交付文件說明"? 其中實際交付日期應清楚說明且應備註是否符合本專案合約期程。	感謝委員意見，已補充於期末報告第一章。	同意
3	報告書第三章，請補充說明在台南市實驗場域有使用兩種模型 Pearl(平日離峰，平日昏峰，假日昏峰)和 Q-Pensieve(平日晨峰使用)；然而，在台北市實驗場域只使用一種模型 Q-Pensieve，是否在實作時曾經也有考慮在台北市也使用不同的模型來增加平日晨峰的效能？請補充說明。	本專案為探討多時段 AI 號誌控制模型可用性，以較單純之臺南市實驗場域單一路口進行實作，實作過程發現平日晨峰績效不符預期，故於平日晨峰採用前期之 AI 號誌控制模型架構處理並重新訓練，臺北市實驗場域則是以前期模型架構重新訓練深入探討。	同意
4	P.153 圖 4.2.4-3 中壢交流道昏峰時段收斂圖最後結果好像不是最佳值(最低值)？不曉得這樣是否是最好的結果？請補	其結果可以有兩種看法以因應訓練目標與現實考量，如果是以訓練考量(最小化損失值)確實不是最好結果，但如果以模型的泛化性與穩定性作為考量，其並非為	同意

	充說明。	最好結果因損失數為模型指標只為得到最好結果並未有現實之時相限制考量,所以模型收斂之最低值在模型中為最佳但並非代表在現實中可用。	
5	報告書第五章： (1)第五章標題建議改為”其他相關工作成果”。	感謝委員意見，已配合調整。	同意
	(2)5.2.1文宣與影片宣傳的執行方式與時間沒有說明清楚。	感謝委員意見，已於 5.2.1 節補充說明。	同意
	(3)圖5.2.1-1和圖5.2.1-2最後定稿為何？且圖片不清楚。	感謝委員意見,已補充定稿海報與影片截圖。	同意
6	請將簡報比較清晰且明確的比較效能如圖、表整合到期末報告內,並適當的輔以文字說明。	謝謝委員指教。本計畫報告書及簡報圖表旨在完整呈現分析結果,因此包含較多資訊,然考量黑白印刷之限制,部分圖表細節可能不易辨識,為能更清晰呈現研究成果,於研究報告正式出版後,提供彩色電子檔供讀者下載，以利更深入探討。	同意
7	簡報 20 頁”平日晨峰之通過量、平均停等延滯皆略低於TOD”是否有筆誤？請補充說明。	謝謝委員指教，此為筆誤，經修正後應為本期 AI 平日晨峰之通過量略低於 TOD、平均停等延滯亦略較 TOD 平均停等延滯差。	同意
七、劉瑞麟委員(書面審查意見)			
1	P.62-67 臺南市與臺北市實驗場域均為連續兩年場域，重新檢視道路環境、交通量及時制計畫相當不錯，交通量也有進行比較,惟 3.2.1 節僅進行臺北市實驗場域的模式校估(參數調校、路網調校),臺南市實驗場域之校估參數與前期結果為何？可否於報告附錄說明。	本次計畫延續前期校估的參數設定,詳報告書 3.3.2 節所示，唯一差別於臺南單一路口前期採用定時號誌控制,本期路口則導入動態號誌控制。然而，在建立 SUMO 模型時，仍以 TOD 時制計畫作為輸入基準，確保模擬過程的穩定性與一致性。 綜上,臺南市場域校估基於前期成果進行延續與調整，相關參數與指標無重大變動，因此報告內容未特別列入附錄補充。	同意
2	P.81-95 臺南市與臺北市實驗場域模式績效，臺北市實驗場域平日昏峰與假日昏峰並無說明 TOD 之資料。另請整理一下兩個場域個時段結果比較表，俾利閱讀。依結果來看,是否長周期為更佳解？請補充說明。	臺北市場域平日昏峰與假日昏峰 TOD 及本期 AI 模擬績效詳報告書 3.2.5.2 節 P.92~P.95 所示。 臺南市場域及臺北市場域各時段模擬結果比較詳表 3.2.5.2-1~表 3.2.5.2-4 以及表 3.2.5.3-1~表 3.2.5.2-4 所示。 另長週期號誌時制雖能減少切換損失、提升通行效率，但可能增加行人等待時間，	同意

		且在低流量路段可能產生無效綠燈。然而，AI 號誌控制模型產生的 220~240 秒週期並非一成不變，而是根據實時交通狀況動態調整。研究顯示，在特定條件下，適度延長週期能有效提升通行效率。然而，長週期是否為最佳解仍需視場域特性而定。建議未來應透過更多場域、時段的驗證，並結合行人需求與特殊事件，以期找到更優化的號誌控制策略。	
3	P.116-129 部分： (1)臺南市實驗場域P.118敘述為實測到19:00，而P.116實測時間僅到18:30，請補充說明18:30~19:00的號誌運作方式。	因應臺南市交通局意見，於 11 月 15 日實測延長實測時間至 20：00，故 18：30 至 20：00 現場仍執行 AI 人工智慧號誌控制。	同意
	(2)臺北市實驗場域的實測降階次數多，觀察敘述無法確定是降階運作或實測運作，建議以LOG來確認有實測運作的時段來監測車流。	為完整呈現系統在各種運作模式下的真實表現，本計畫保留了所有降階運轉的數據。此舉不僅確保了數據的連貫性，更能真實反映系統在面對不同交通狀況時的反應。 降階運轉作為系統運作中可能發生的正常事件，納入分析能更全面地評估系統績效，特別是對系統在異常情況下的穩定性與可靠性提供更深入的了解。透過保留所有數據，我們能夠更準確地評估系統的旅行時間、路口延滯等關鍵績效指標，進而為系統優化提供更可靠的數據基礎。	同意
	(3)臺南市實驗場域場域實測已進行AI號誌控制模型跟動態TOD比較，請補充說明臺南市實驗場域的動態TOD運作邏輯(另動態TOD之時比與AI號誌控制有差異？)。	關於臺南市實驗場域的動態 TOD 運作邏輯，由於本研究主要聚焦於 AI 號誌控制模型的效能評估，因此對於動態 TOD 的內部運作機制並無深入探討。 不過，根據我們對實驗數據的分析，可以初步推測臺南市現行的動態 TOD 系統可能具備以下特徵： 1. 固定週期或門檻觸發：動態 TOD 的號誌週期可能設定為固定值，或是在流量達到特定門檻時才會啟動調整。 2. 流量反應較慢：相較於 AI 號誌控制模型能即時響應交通流量變化，動態 TOD 的反應速度可能較慢，特別是在流量波動較大的時段。	同意

		3. 假日效能較差： 在假日等流量較分散的時段，動態 TOD 的控制效果可能不如 AI 號誌控制模型，這可能是由於動態 TOD 的控制策略較難適應假日流量的特性。 與 AI 號誌控制模型的比較，我們發現平日時段，動態 TOD 與 AI 號誌控制模型的旅行時間趨勢大致相似，這可能是由於平日流量較穩定，兩種控制方式都能達到較好的控制效果。在假日或流量波動較大的時段，AI 號誌控制模型的旅行時間表現明顯優於動態 TOD，顯示 AI 號誌控制模型在處理複雜交通狀況方面具有更強的適應性。 造成上述差異的原因可能包括： 1. AI 號誌控制模型能更精準地預測交通流量，並根據實時數據動態調整號誌時制，以達到最佳的控制效果。 2. 動態 TOD 的控制策略相對固定，可能無法靈活應對複雜多變的交通狀況。 總結來說，雖然我們無法提供臺南市動態 TOD 的詳細運作邏輯，但透過對實驗數據的分析，我們可以初步推測動態 TOD 與 AI 號誌控制模型在性能上的差異，以及造成這種差異的可能原因。	
	(4)臺南市實驗場域有本期AI號誌控制模型、前期AI號誌控制模型、動態TOD等實測資料，可否進行模型與實測數據比較？請補充說明。	臺南市場域本期 AI 與動態 TOD 及本期 AI 與前期 AI 號誌控制模型實測績效比較詳報告書 3.3.5.1 節所示。	同意
4	P.148，表 4.2.1.2-8 部分，該表內模擬參數(以 SUMO 為例)數值在與臺南市與臺北市實驗場域是否不同？建議可以於附件呈現各場域的參數比較表，另 VISSIM 模擬模式亦有類似現象，建議可以比照處理。	謝謝委員指教。 本計畫於臺北市與臺南市實驗場域的 SUMO 與 VISSIM 模擬參數設定，皆以表 4.2.1.2-8 所列參數為基準，採用一致且統一的配置。此設定考量到不同場域間的比較需求，確保模擬環境具可比性並減少因參數差異造成的影響。雖部分實驗場域可能存在道路特性差異，為維持模擬結果的公平性與科學性，模擬參數未另行調整。至於模擬結果差異，則反映場域交通量特	同意

		性與動態號誌控制策略的影響，非參數設定的因素所致。	
八、臺南市政府交通局			
1	P.121 之綠燈秒數趨勢圖為黑白，無法確認線段圖例，希望能有彩圖或相關說明補充以供了解臺南市實驗場域相關績效結果。	感謝委員的建議。本計畫報告書及簡報圖表旨在完整呈現分析結果，因此包含較多資訊。然考量黑白印刷的限制，部分圖表細節如綠燈秒數趨勢圖，可能因線段圖例不易辨識，影響讀者理解。為更清晰地呈現研究成果，我們將於研究報告正式出版後，於運研所網站提供彩色電子檔供讀者下載，讓相關趨勢與細節更為明確，並利於深入探討與參考。同時，未來簡報設計亦會考量以更直觀的方式標示圖例，進一步提升資料可讀性。	同意
2	P.124 表 3.3.1-7 表格欄位與臺北市實驗場域比較不一致，請執行團隊確認並進行補充。	因臺北市實驗場域與臺南市實驗場域之車流偵測設備類型不同，故可取得之相關績效亦有差別，導致表格欄為不一致。	同意
3	臺南市實驗場域之監控畫面是否可提供臺南市政府交通局作為參考。	畫面為提供現場執行 AI 號誌控制時監控現場執行狀況使用，因實測結束故畫面已無資料呈現，可提供過往截圖作為參考。	同意
4	P.185，AI 號誌控制模型匝道儀控率是否利用 AI 號誌控制模型計算出來的？還是實際上高速公路局當下使用的匝道儀控率？因過往臺南市交通局經由 Line notify 方式建議**高速公路局**南分局進行儀控，但實務上未必會被採用。	交流道區域實測過程 AI 號誌控制模型利用現場車流資訊計算建議之匝道儀控率，並經由 WEB 介面提供高速公路局值班台人員查看，由值班台人員依據現場車流與實務需求決定是否採用，系統將記錄匝道儀控率執行情形。	同意
5	P.189，後續維護機制對縣市政府相當重要，因過往開發動態 TOD，若因維護行人安全設置行人早開或增設左轉車道時，動態 TOD 需要暫停運作並進行修正，於實務上有許多困擾，請問 AI 號誌控制上是否有相關建議供縣市政府參考。	AI 號誌控制於實作上，亦會受到時相組態變更之影響需要重新訓練，後續建議可將時相組態變更納入 AI 號誌控制模型探討之項目。	同意
九、臺中市政府交通局(書面審查意見)			
1	AI 號誌控制應用是否讓縣市政府未來在號誌建置上，可以	AI 號誌控制仰賴偵測設備提供現場車流資料，以及號誌控制器穩定連線狀態以利	同意

	取代 TOD 基本時制計畫？如果不行有什麼樣的執行困難，建議補充說明。	指令傳輸執行，而 TOD 基本時制計畫多仰賴時制重整、維修員與值班台之現場經驗調校，並無偵測設備與連線狀態之要求，若以建置成本考量較難以全面取代 TOD 基本時制計畫，但可於縣市重點區域進行替代。	
2	本計畫 AI 號誌控制的成果，該模式是否可以直接複製到其他縣市路口？如縣市政府想採用 AI 號誌，就單一路口或路廊的成本大概是多少？請補充說明。	AI 號誌控制模型於車流模擬環境中針對路口幾何、時制計畫、車流型態等特性進行訓練，以學習最佳秒數決策，故 AI 號誌控制模型無法直接複製至其他縣市路口執行，但於相似之路口型態(如：單一路口、幹道多路口、交流道協控等)可採用相同之演算法架構進行訓練。 因 AI 號誌建置涉及車流偵測設備、號誌控制器版本、系統軟體等層面，建議未來可深入探討 AI 號誌控制於各類場域所需之成本。	同意
3	P.90，從實測績效來看，AI 號誌控制可以即時反應車流量的多寡，增加綠燈秒數提升路口的通過車流量，但也造成週期秒數有增加的趨勢，可能讓原本 5 個週期的時間 AI 號誌控制下僅分配有 4 個週期，亦可能造成上下游路口的號誌無法連鎖，又增加的紅燈時間也可能造成用路人誤以為紅燈時間過久號誌異常，故建議未來實作上可以觀察現場用路人感受，並裝設紅燈倒數的資訊，以提供用路人充分資訊。	謝謝謝委員提醒。對於週期秒數增加可能帶來的影響以及綜合考量用路人感受，將納入後續研究，並積極尋求解決方案。	同意
十、中華民國交通工程技師公會(書面審查意見)			
1	本計畫中以單一路口、幹道連鎖路口及高快速與地方匝道儀控等實際案例分析，以強化學習(Reinforcement Learning, RL)為基礎的適應性號誌控制演算，來改善車流績效，這是複雜且前瞻的研究，對於我國後續	感謝委員意見，已納入 6.2 節未來執行建議，可於後續計畫進行探討。	同意

	實務上推動具有指標性的意義。若能於本案報告書總結時，提供中央及縣市政府對於未來利用 RL 來做號誌控制方法時，給予一些軟體、硬體及偵測器等之採購方向建議，將更具實務意義。		
2	透過強化學習(Reinforcement Learning, RL)即時號誌動態資訊給各式車輛，以提供安全、優先通行、節能的道路交通環境，根據路口各方向即時交通變化作動態彈性調整號誌。此法需要學習過程與時間，很大程度上取決於對交通流、道路環境之理解程度；然實務上可能沒有太多的時間可以讓機器做學習，是否有相關的建議或折衷方式，縮短學習時間甚至無須學習？請補充說明。	關於實務上的模型應用與訓練建議如下幾種: 1. 使用預先訓練模型(Pre-Trained Model)與利用遷移學習(Transfer Learning)，其主要先用現場資料如流量，時制計劃進行離線學習，複製現場情況資料模型與各時相秒數型態。並且利用遷移學習之技術將模型之參數應用於現實並進行小幅度調整。 2. 並非使用無模型(Model-Free)，而是基於模型(Model-Based)模型，其主要可以先為模型提供場域之所需資料但會需要額外提供設計規則如固定周期調整規則或流量門檻)，模型則會以此作為基礎進行微調。 3. 使用模仿學習，將專家對於各種情況之應對方式與其控制策略，與 Model-Based 相似但不同之處為 model-based 是預測下一決策而非直接輸出秒數。 4. 使用元學習(Meta-Learning)，將一個場域各時段與時期之資料作為資料輸入使其在新數據來時，可以通過少量學習完成訓練。 上述都是可行之建議但需考量各種情況使用不同解法，瞄準準確性可以使用預訓練 (Pre-Trained) 或基於模型 (Model-Based)，適應性可以使用基於模型(Model-Based)或元學習(Meta-Learning)。	同意
3	能否簡單比較一下 SUMO 與 VISSIM 於本案中模擬優化硬體設備、軟體版本、操作過程及結果呈現之差異？請補充說明。	感謝委員的提問。SUMO 與 VISSIM 在本案中的應用主要差異如下： 1. 硬體設備：SUMO 為開源軟體，對硬體需求較低，適合高效能運算環境；VISSIM 則為商業軟體，對硬體效能有	同意

		更高要求，特別在多重場景模擬時更依賴顯示卡性能。 2.軟體版本：SUMO 使用最新開源版本，具備更多模擬參數設定的靈活性；VISSIM 採用穩定的商業版本，強調精確的視覺化呈現與參數校估工具。 3.操作過程：SUMO 的操作需透過程式化方式進行設定，適合大規模實驗場域；VISSIM 則以圖形介面操作為主，適合小型場域詳細調整。 4.結果呈現：SUMO 側重數據化分析輸出，便於後續統計處理；VISSIM 則提供豐富的視覺化模擬效果，便於展示場域特性與優化結果。 兩者結合的應用，確保了模擬結果的多樣性與完整性，以利於本案的研究與實務需求。	
4	由於行人議題的越來越被國人所重視，且很多平面道路亦開始廣為闢建自行車道，在多車種及人車競爭的道路環境下，勢必又更為複雜，基於本案執行經驗，或許可以提供後續研究之建議方向。	感謝委員意見，已納入 6.2 節未來執行建議，可於後續計畫進行探討。	同意
5	本案在實驗時，可能曾遭遇許多關鍵課題如資料介接格式不同、設備連線不穩造成，AI 時制無法下達、實測時應盡量避免人為手操燈或義交交警引導車流等情事，都有可能導致自動降階執行流程，以及自動降階執行後又再啟動ＡＩ智慧號誌控制。未來實務上如何自動偵測、設定固定或者浮動判準門檻等會是關鍵，建議若本案有些經驗亦可以回饋。	AI 號誌控制執行時可能因現場偵測設備異常、偵測器或控制器連線不穩、人為手操燈等因素導致系統自動進入降階，進入降階後，各廠牌號誌控制器依自身設定邏輯進行運算、調整週期秒數，使現場於 2 週期後恢復原固定時制計畫，期間可能造成現場車流異常。 當偵測設備因異常或連線不穩導致偵測資料缺漏，使 AI 號誌控制模型無法運算決策秒數時，為避免直接進入降階影響現場車流，將以固定時制計畫秒數下達指令，以維持 AI 號誌控制執行狀態，待偵測資料恢復正常時，便可直接進行運算並下達指令。 然控制器連線不穩情形無法藉由系統程式克服，當控制器無法正常接收 AI 決策	同意

		秒數指令時,只能交由控制器進入降階恢復原固定時制計畫,待連線正常時再重新進入 AI 號誌控制執行狀態。	
十一、交通部運輸研究所運輸科技及資訊組(書面審查意見)			
1	請補充說明臺北市、臺南市、桃園市中壢交流道等實驗場域的模擬模式校估驗證過程之參數調校與路網微調具體內容，對於桃園市中壢交流道實驗場域的模擬模式校估，請補充說明是否為一個模擬模式，同時模擬高速公路與平面道路運作績效。	臺北市、臺南市及桃園市中壢交流道實驗場域的模擬校估過程中,均採用一致的參數調校原則及路網微調策略，具體包含： 1. 參數調校：根據實地調查結果設定車輛車長、加減速度、跟車行為等動靜態參數，確保模擬結果能貼近真實交通狀況。 2. 路網微調：根據場域特性進行道路速限、優先性及幾何設計的校正，以提升模型準確度。 另桃園中壢交流道實驗場域的模擬模式校估，為一個模擬模型，同時模擬高速公路與平面道路運作績效。	同意
2	P.76 根據圖 3.2.2-1 內容臺南市實驗場域模型訓練架構圖似為 P.54 圖 2.3.2-5 之多任務強化學習訓練架構,而非 P.55 的 Pearl 訓練架構圖，請再確認臺南市實驗場域模型訓練架構；另本所初步了解，臺南市實驗場域模型訓練架構在平日晨峰採用單一多任務強化學習訓練架構，而平日離峰/昏峰與假日昏峰採用單一 Pearl 演算法訓練架構來代表 3 個時段，請加以確認與釐清實作內容與採用方式。	3.2.2-1 為誤植,應為圖 2.3.2-8 之 Pearl 訓練架構圖，將於修訂版修正。	同意
3	P.77 請補充說明臺北市實驗場域所採用主協控設計流程第 3 點「調配」出其餘路口之相關時相秒數,確保週期一致,並含有續進邏輯的具體作法，以及第 10 點「模型收斂」的定義與作法。	關於第 10 點模型收斂之作法為重複步驟 7-9 為模型收斂圖 X 軸之一步觀察模型之並且觀察其收斂值如收斂值是否有下降、其幅度是否過於快速或過慢、是否平穩於部分 X 軸、如果有上升情況是否過高或上升過快。而收斂定義為觀察收斂值是否有落入負值,如有達到負值以及平穩於部分 X 軸則會將其定為部分模型收斂並且持續觀察。	同意

4	P.79 的 3.2.4 節與 P.152 的 4.2.4 節訓練結果部分， (1)圖3.2.4-1顯示臺南市實驗場域僅有1個Pearl演算法收斂圖，請確認此收斂圖包括所有4個時段(平日晨峰/離峰/昏峰與假日昏峰/)。	是的，此為 Pearl 演算法包含四個時段的收斂圖。	同意
	(2)根據說明3個實驗場域「收斂值用於衡量AI號誌控制模型預測結果與實際結果之誤差」,請補充說明各收斂圖Y軸(誤差)定義及其在交通面向的意義。	Y 軸並無任何交通面向意義,僅代表策略與獎勵值的優化過程,其損失數下降代表正在改善(帶來更高的獎勵值)而趨於平穩代表策略逐漸穩定，所以 Y 軸(Loss Curve) 代表了模型策略的優化過程，有震盪但下降之趨勢代表模型在學習動態環境之同時也有其適應性。	同意
	(3)根據臺北市實驗場域的3個收斂圖，平日離峰的誤差在下降後又大幅上升，其他3個時段在一定時間(或Stop)後顯示誤差微幅上升，請補充說明是否產生過度訓練現象，甚或因而無法取得最佳解。	在初期快速下降為學習率之設定與模型有快速學習到數據中的資料型態導致大幅下降，而之後的上升則因因 SAC 與 Q-Pensieve 中熵係數造成的探索現象與模型在不同輸出下適應不同場景中的數據分佈導致的波動。 模型在訓練時大多不會達到最低解,因熵係數造成的探索與利用之平衡以及模擬軟體中的隨機性也會造成收斂服度變化。	同意
	(4)桃園市中壢交流道實驗場域等4個收斂圖各別意義的文字說明。	圖 4.2.4-1 代表損失函數有很好的收斂，模型有根據訓練步數不斷改進,其中沒有莫名明顯的尖端代表訓練過程穩定。 圖 4.2.4-2 代表模型在訓練過程中因資料行太太變化導致出現波動與不穩定之情況,而後續模型有逐漸收斂代表模型最終有找出更好之獎勵制度與其模型,但因模型並未達成平穩使其模型可能還有一點不穩定之輸出存在。 圖 4.2.4-3 代表模型在訓練中對於某些訓練數據過於專注犧牲了其他數據之使用，導致模型的探索讓其使用了不同數據造成了 Y 軸的升高，而最終的穩定代表不同數據中有使模型收斂有達到一個平衡點。 圖 4.2.4-4 代表模型在初期時還無法適應以及找出含有較高獎勵制度之策略導致	同意

		Y 軸升高，但後續模型逐漸下降，其中沒有其餘變化並且最後穩定代表收斂穩定。	
5	請確認 P.82~P.89 臺南市實驗場域之各時段模擬績效與模型穩定性與圖表數據內容，係對應所採用的 AI 多任務強化學習演算法與 Pearl 演算法作法。	P.88 中的晨峰時段為使用多任務強化學習演算法，P.90 中的離峰時段、P.92 中的昏峰時段、與 P.94 中的假日昏峰時段為使用 Pearl 演算法。	同意
6	P.99~P.102 的 3.3.2.1 節介紹 SUMO 與 VISSIM 車流模擬軟體，請說明本案在使用 SUMO 與 VISSIM 過程分別如何 TraCI 與 VISSIM API 進行模擬與各式 AI 號誌控制模型訓練，以及 KPI 內容。	本案於 SUMO 模擬中，透過 TraCI 實現即時數據交互與控制。TraCI 提供 API 用於讀取車輛位置、速度、延滯等即時狀態資訊。SUMO 具備高彈性的模擬架構，適合訓練需要多次互動的深度強化學習模型。 而在 VISSIM 模擬中，利用其 COM API 進行控制與數據交互。VISSIM API 允許讀取模擬中的詳細交通流特性，並向模型傳遞狀態數據，同時接受 AI 輸出指令進行號誌優化調整。由於 VISSIM 的精細模擬特性與視覺化優勢，特別適合用於驗證 AI 號誌控制模型在複雜路網條件下的適用性與穩定性。 績效指標(KPI)方面，兩套模擬均採用一致的標準進行評估，包括：(1)通過量評估交通流效率；(2)平均旅行時間與延滯反映路段通行效率與擁堵程度；(3)觀察車輛排隊長度評估號誌控制效果。透過模擬環境與即時數據交互，能有效驗證 AI 號誌控制模型在動態交通控制中的適用性與優化成效。	同意
7	P.102~P.106 臺南市實驗場域的圖 3.3.2.2-1 至圖 3.3.2.2-4 內容不具可讀性，請提高解析度，同時請詳細說明其號誌控制面向意義，例如：P.102 認為「動態模擬週期平均較 TOD 之 220 秒週期多 1 秒」，然平均值與 TOD 差異不大，可能波動大，不必然代表合理，除平均值請補充變異數與標準差。	已修正詳圖 3.3.2.2-1 至圖 3.3.2.2-4 所示。另有關報告書 P.108 所述「動態模擬週期平均較 TOD 之 220 秒週期多 1 秒」旨在呈現整體趨勢，然而僅以平均值來分析確實可能不足以反映波動情形。 為補充更完整的數據分析，已計算動態模擬週期的變異數與標準差，並發現其波動範圍相對有限(標準差約±5 秒)。此結果顯示，動態模擬的週期雖有些微波動，但大多數情況仍集中於 220 秒上下，且整體趨勢合理。	同意

		未來報告中，將強化此部分分析，提供完整的統計指標以佐證結論，進一步提升結果解讀的嚴謹性。	
8	P.106~P.111臺北市實驗場域與P.162~P.174中壢交流道實驗場域的動態模擬績效數據分析方式(分相秒數與週期長度比值)不同於臺南市實驗場域(分相秒數統計特性)，請補充說明其緣由與考量；另請說明為何P.108在平日昏峰之各分相比值加總為0.91，而不是1.0，同時請再確認所有計算數據之正確性。	臺北市場域與桃園市實驗場域動態模擬績效數據分析方式不同於臺南市場域之原因為偵測設備資料屬性不同所致，臺北及桃園市實驗場域動態模擬績效數據分析基準為停等車流量資料及分相秒數資料，而臺南市場域為流量資料及分相秒數資料。臺北市場域平日昏峰各分相比值加總為誤植，已修正，詳報告書 P.115	同意
9	P.117臺北市與臺南市實驗場域實測計畫的例外事件，請補充為避免AI號誌控制模型產生時制計畫不符現場車流需求，導致壅塞之各監控查核點設計內容。	感謝委員意見，已於 3.3.4 節補充說明。	同意
10	請補充說明臺北市、臺南市、桃園市中壢交流道等實驗場域所使用各式AI號誌控制模型的內容、類神經網路架構(含超參數)與輸出入參數請，以及模型參數調整與校估過程。	已於報告書 3.2.4 節 P.86 與 4.2.4 節 P.169 中補充說明。	同意
11	請補充臺北市、臺南市、桃園市中壢交流道等實驗場域，於實測時的AI號誌控制模型動態輸出時制計畫(含匝道儀控率)內容與TOD(臺南市為動態TOD或匝道儀控狀態)時制計畫對照。	已補充，詳報告書圖 3.3.5.1-4~圖 3.3.5.1-6、圖 3.3.5.2-8~圖 3.3.5.2-10 以及圖 4.3.5-8~圖 4.3.5-10 所示。	同意
12	桃園市中壢交流道實驗場域協控實測部分，除桃園市平面道路績效外，請補充同時段高速公路主線車流變化數據。	已補充，詳報告書圖圖 4.3.5-11~圖 4.3.5-15 所示。	同意

13	臺北市、臺南市、桃園市中壢交流道等實驗場域的實測績效部分， (1)請補充說明路口延滯、車輛通過數、旅行時間等績效數據來源，或其產生方式。	1. 路口延滯為搜集各臨近路口各方向路段之 GVP 資料，進而推估各臨近路口之路段於時制重整前後之延滯表現。 2. 車輛通過數來源為偵測設備 旅行時間來源為透過蒐集 TomTom GVP 資料瞭解事前事後路段平均旅行時間。	同意
	(2)各AI號誌控制模型運作績效表，請補充事前或現況績效，另除改善或降低的秒數外，請增加百分比數值。	遵照辦理，已修正詳表 3.3.5.1-1、3.3.5.1-3、3.3.5.1-5、表 3.3.5.2-1 及表 4.3.5-1~表 4.3.5-3 所示。	同意
	(3)桃園市中壢交流道協控實測時之高速公路主線車流數據。	已補充詳報告書圖圖 4.3.5-11~圖 4.3.5-15 所示。	同意
14	P.189 5.4節人工智慧強化學習號誌控制模型維護機制探討部分， (1)請納入本年度在臺北市實驗場域執行過程，所面臨實務上時相組態與時制計畫內容異於前期計畫，所導致或衍生AI號誌控制模型調整與訓練學習經驗。	關於時相組態與時制計劃內容變化對於模型調整並沒有相當大之影響，影響大多為重複性之 SUMO/VISSIM 之設定修正與 API 介接設定修正，確保 AI 輸出為正確時相與合理秒數。而關於模型調整與學習經驗大多為交通上的考量如模型輸入輸出設計，而此設計大多對於現場設備與優化的點關係較多而非時制計劃。	同意
	(2)目前內容尚無法回應李霞委員於期中審查時所提之AI號誌控制模型導引手冊需求，請再將兩期計畫執行過程與經驗整理為號誌控制導入AI強化學習的參考資訊。	感謝委員意見，已納入 6.2 節未來執行建議，可於後續計畫進行探討。	同意
15	結論中請補充2期計畫對於多任務與Pearl演算法強化學習，以及協控採用之多代理人集中訓練分散執行(Centralized Training and Decentralized Execution, CTDE)框架的應用與使用經驗、限制與心得。	感謝委員建議，已調整為 6.3 節各年度階段性成果。	同意
16	利用6.1節結論來呈現工作項目「綜整摘要說明112年至113年各年度階段性成果」內容並不合適，請以獨立章節來呈現。	感謝委員建議，已調整為 6.3 節各年度階段性成果。	同意

17	有關報告初稿中之錯漏字、語句不適當與資料來源修正部分，請於會後洽本所。	感謝委員意見，已配合完成修正。	同意
十二、主席結論			
1	請執行團隊於修訂版中補充以下內容： (1)本計畫之創新構想為何，並說明與該場域過往號誌控制方式之比較、差異，以呈現本計畫重點。	遵照辦理。	同意
	(2)請補充說明各時段之績效優劣之原因結論，說明人工智慧號誌控制之限制、條件。	遵照辦理。 1. 不同時段的交通特性直接影響人工智慧號誌控制的績效。於尖峰時段，車流量密集且變化快速，AI 號誌控制模型透過即時數據更新與預測能力，有效減少路口延滯與排隊長度，績效優於傳統定時控制。然而，於離峰時段，車流需求低且變化平穩，AI 號誌控制模型的動態調整頻率可能導致部分路段號誌切換頻繁，影響駕駛體驗，顯現出效率不及定時控制的情況。此外，異常交通事件(如事故或臨時道路封閉)可能導致數據偏差，使 AI 號誌控制模型無法即時應對，造成績效不穩定。 2. AI 號誌控制的應用需依賴高精度的即時數據蒐集與穩定的通訊設備，若數據有遺漏或延遲，將直接影響模型的判斷與輸出準確性。此外，AI 號誌控制模型對於場域的初始校估與訓練參數敏感，若模擬環境無法完全反映現場特性，可能影響控制效果。對於複雜路網，AI 號誌控制模型需要處理大量動態參數，計算成本高且需要時間進行深度訓練，限制了在資源有限場域的即時應用。 3. 未來應持續提升 AI 號誌控制模型的韌性與數據處理能力，並結合異常狀況的應對策略(如透過聯網車 CV、無人機輔助蒐集)，以克服限制，充分發揮人工智慧號誌控制的潛力。	同意

	(3)於結論與未來建議補充說明是否應退回傳統號誌控制方式？於本計畫中之學習、經驗為何？是否有發現潛在機會？	遵照辦理。	同意
2	審查會議各委員及與會單位研提之口頭及書面意見，請資拓宏宇國際股份有限公司整理「審查意見處理情形表」，且逐項說明回應辦理情形，並納入報告之修正。	遵照辦理。	同意
3	本計畫經徵詢審查委員意見，期末報告初稿審查通過，請資拓宏宇國際股份有限公司後續依本所出版品印製相關規定撰寫報告，於113年12月24日前提送期末報告修正定稿。	遵照辦理。	同意

附錄三 臺北市實驗場域路口轉向交通量

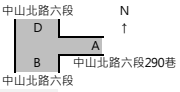
計畫範圍路口轉向量調查參考來源彙整表

編號	路口名稱	編號	路口名稱
X1	中山北六段/290 巷	X5	中山北六段/忠誠路一段
X2	中山北六段/克強路	X6	磺溪街/克強路
X3	中山北六段/195 巷	X7	磺溪街德行西路
X4	中山北六段/德行西路		

X1：中山北六段/290巷(6/20)平日交通量

站 號： X1
站 名： 中山北六段/290巷
時相數： 5

日 期： 2024/06/20 (四)
天 候： 晴
方 向： A B C D
車道數： 1 2 - 2



方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	合計 大型車比例	合計 小型車(輛)	合計 小型車比例	合計 機車(輛)	合計 機車比例	總和(輛)	PCU	PHF
A	06:30-07:30	-	27	22	38	0.88	-	-	-	-	-	-	-	3	5	5	0.12	-	-	30	0.53	27	0.47	57	43	
	07:30-08:30	-	30	67	60	0.83	-	-	-	-	-	-	-	3	19	12	0.17	-	-	33	0.28	86	0.72	119	72	
	08:30-09:30	-	44	53	69	0.82	-	-	-	-	-	-	-	11	6	15	0.18	-	-	55	0.48	59	0.52	114	84	
	12:00-13:00	-	13	27	25	0.78	-	-	-	-	-	-	-	2	10	7	0.22	-	-	15	0.29	37	0.71	52	32	
	13:00-14:00	-	12	21	22	0.79	-	-	-	-	-	-	-	3	7	6	0.21	-	-	15	0.35	28	0.65	43	28	
	14:00-15:00	-	14	26	26	0.70	-	-	-	-	-	-	-	5	12	11	0.30	-	-	19	0.33	38	0.67	57	37	
	16:00-17:00	-	15	45	35	0.74	-	-	-	-	-	-	-	7	10	12	0.26	-	-	22	0.29	55	0.71	77	47	
	17:00-18:00	-	30	58	56	0.82	-	-	-	-	-	-	-	6	12	12	0.18	-	-	36	0.34	70	0.66	106	68	
	18:00-19:00	-	20	45	40	0.75	-	-	-	-	-	-	-	6	15	13	0.25	-	-	26	0.30	60	0.70	86	53	
B	06:30-07:30	-	-	-	-	-	-	17	386	324	553	0.95	-	21	18	31	0.05	17	0.02	407	0.53	342	0.45	766	584	
	07:30-08:30	-	-	-	-	-	-	13	684	639	976	0.96	-	22	41	42	0.04	13	0.01	706	0.50	680	0.49	1399	1018	
	08:30-09:30	-	-	-	-	-	-	17	717	472	946	0.94	-	44	38	65	0.06	17	0.01	761	0.59	510	0.40	1288	1011	
	12:00-13:00	-	-	-	-	-	-	16	650	327	816	0.95	-	27	29	42	0.05	16	0.02	677	0.65	356	0.34	1049	858	
	13:00-14:00	-	-	-	-	-	-	16	724	368	907	0.97	-	15	23	27	0.03	16	0.01	739	0.64	391	0.34	1146	934	
	14:00-15:00	-	-	-	-	-	-	14	709	320	869	0.97	-	16	22	27	0.03	14	0.01	725	0.67	342	0.32	1081	896	
	16:00-17:00	-	-	-	-	-	-	17	700	409	902	0.93	-	44	43	67	0.07	17	0.01	744	0.61	452	0.37	1213	969	
	17:00-18:00	-	-	-	-	-	-	15	751	529	1000	0.94	-	42	47	67	0.06	15	0.01	793	0.57	576	0.42	1384	1067	
	18:00-19:00	-	-	-	-	-	-	15	741	755	1085	0.94	-	41	49	66	0.06	15	0.01	782	0.49	804	0.50	1601	1151	
C	06:30-07:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	08:30-09:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	12:00-13:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	13:00-14:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	14:00-15:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D	06:30-07:30	-	2	4	4	-	-	20	667	364	856	1.00	-	-	-	-	-	20	0.02	669	0.63	368	0.35	1057	860	
	07:30-08:30	-	7	5	10	0.01	-	19	918	810	1292	0.99	-	-	-	-	-	19	0.01	925	0.53	815	0.46	1759	1302	
	08:30-09:30	-	7	4	9	0.01	-	16	960	531	1212	0.99	-	-	-	-	-	16	0.01	967	0.64	535	0.35	1518	1221	
	12:00-13:00	-	3	8	7	0.01	-	11	831	434	1033	0.99	-	-	-	-	-	11	0.01	834	0.65	442	0.34	1287	1040	
	13:00-14:00	-	7	7	10	0.01	-	13	833	374	1013	0.99	-	-	-	-	-	13	0.01	840	0.68	381	0.31	1234	1023	
	14:00-15:00	-	6	6	9	0.01	-	13	860	379	1043	0.99	-	-	-	-	-	13	0.01	866	0.69	385	0.30	1264	1052	
	16:00-17:00	-	17	9	22	0.02	-	13	903	551	1158	0.98	-	-	-	-	-	13	0.01	920	0.62	560	0.38	1493	1180	
	17:00-18:00	-	7	9	11	0.01	-	13	752	720	1078	0.99	-	-	-	-	-	13	0.01	759	0.51	729	0.49	1501	1089	
	18:00-19:00	-	1	13	7	0.01	-	17	561	601	844	0.99	-	-	-	-	-	17	0.01	562	0.47	614	0.51	1193	851	
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**											
合計	06:30-07:30	-	29	26	42	0.03	-	37	1053	688	1409	0.95	-	24	23	36	0.02	37	0.02	1106	0.59	737	0.39	1880	1487	
	07:30-08:30	-	37	72	70	0.03	-	32	1602	1449	2268	0.95	-	25	60	54	0.02	32	0.01	1664	0.51	1581	0.48	3277	2392	
	08:30-09:30	-	51	57	78	0.03	-	33	1677	1003	2158	0.93	-	55	44	80	0.03	33	0.01	1783	0.61	1104	0.38	2920	2316	
	12:00-13:00	-	16	35	32	0.02	-	27	1481	761	1849	0.96	-	29	39	49	0.03	27	0.01	1526	0.64	835	0.35	2388	1930	
	13:00-14:00	-	19	28	32	0.02	-	29	1557	742	1920	0.97	-	18	30	33	0.02	29	0.01	1594	0.66	800	0.33	2423	1985	
	14:00-15:00	-	20	32	35	0.02	-	27	1569	699	1912	0.96	-	21	34	38	0.02	27	0.01	1610	0.67	765	0.32	2402	1985	
	16:00-17:00	-	32	54	57	0.03	-	30	1603	960	2060	0.94	-	51	53	79	0.04	30	0.01	1686	0.61	1067	0.38	2783	2196	
	17:00-18:00	-	37	67	67	0.03	-	28	1503	1249	2078	0.93	-	48	59	79	0.04	28	0.01	1588	0.53	1375	0.46	2991	2224	
	18:00-19:00	-	21	58	47	0.02	-	32	1302	1356	1929	0.94	-	47	64	79	0.04	32	0.01	1370	0.48	1478	0.51	2880	2055	

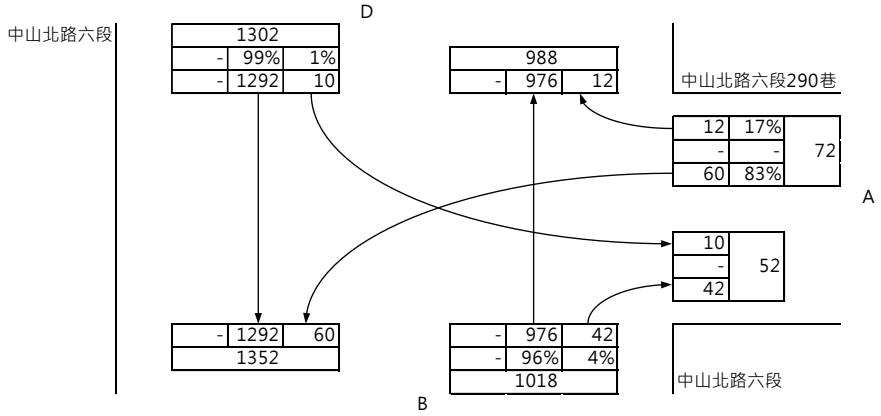
A	07:30-08:30	-	30	67	60	0.83	-	-	-	-	-	-	-	3	19	12	0.17	-	-	33	0.28	86	0.72	119	72	0.78
B		-	-	-	-	-	-	13	684	639	976	0.96	-	22	41	42	0.04	13	0.01	706	0.50	680	0.49	1399	1018	0.90
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
D		-	7	5	10	0.01	-	19	918	810	1292	0.99	-	-	-	-	-	19	0.01	925	0.53	815	0.46	1759	1302	0.90
A	13:45-14:45	-	13	26	25	0.74	-	-	-	-	-	-	-	4	10	9	0.26	-	-	17	0.32	36	0.68	53	34	0.69
B		-	-	-	-	-	-	10	749	343	911	0.97	-	19	20	30	0.03	10	0.01	768	0.67	363	0.32	1141	941	0.86
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
D		-	4	9	8	0.01	-	12	880	379	1061	0.99	-	-	-	-	-	12	0.01	884	0.69	388	0.30	1284	1069	0.94
A	17:00-18:00	-	30	58	56	0.82	-	-	-	-	-	-	-	6	12	12	0.18	-	-	36	0.34	70	0.66	106	68	0.73
B		-	-	-	-	-	-	15	751	529	1000	0.94	-	42	47	67	0.06	15	0.01	793	0.57	576	0.42	1384	1067	0.88
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
D		-	7	9	11	0.01	-	13	752	720	1078	0.99	-	-	-	-	-	13	0.01	759	0.51	729	0.49	1501	1089	0.90

X1：中山北六段/290巷(6/20)平日轉向交通量示意圖

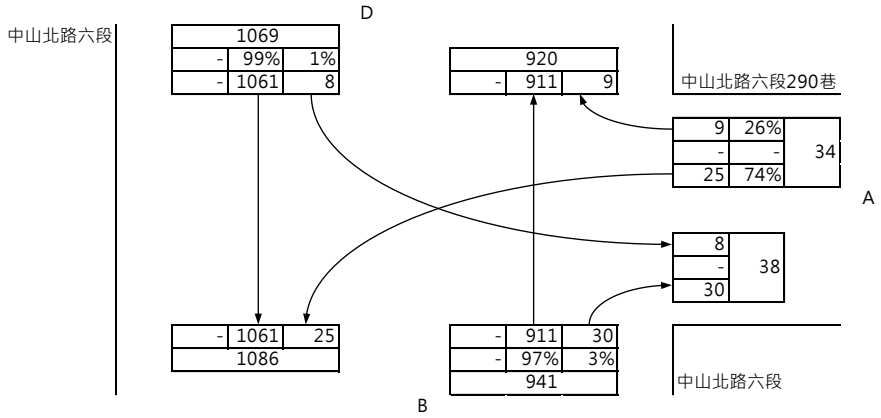
站　號：　X1
站　名：　中山北六段/290巷

單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

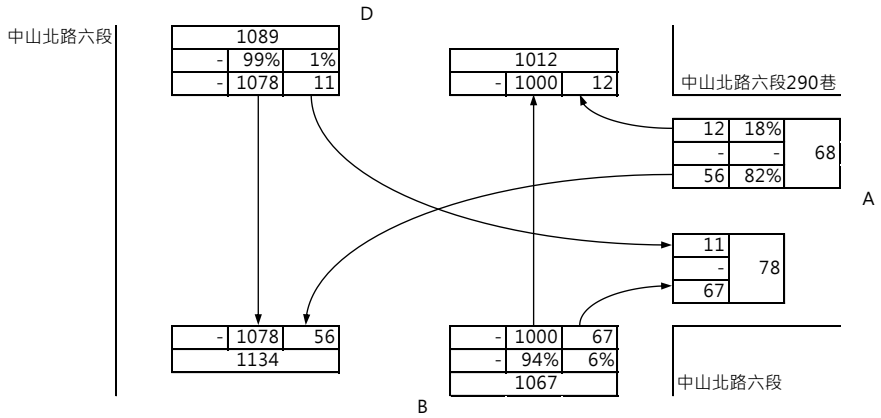
上午尖峰：　07:30-08:30



離峰：　13:45-14:45



下午尖峰：　17:00-18:00

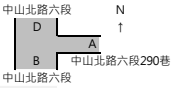


方　向：	A	B	C	D
總車道數：	1	2	-	2

X1：中山北六段/290巷(6/22)假日交通量

站　號：　X1
站　名：　中山北六段/290巷
時相數：　5

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　1　2　-　2



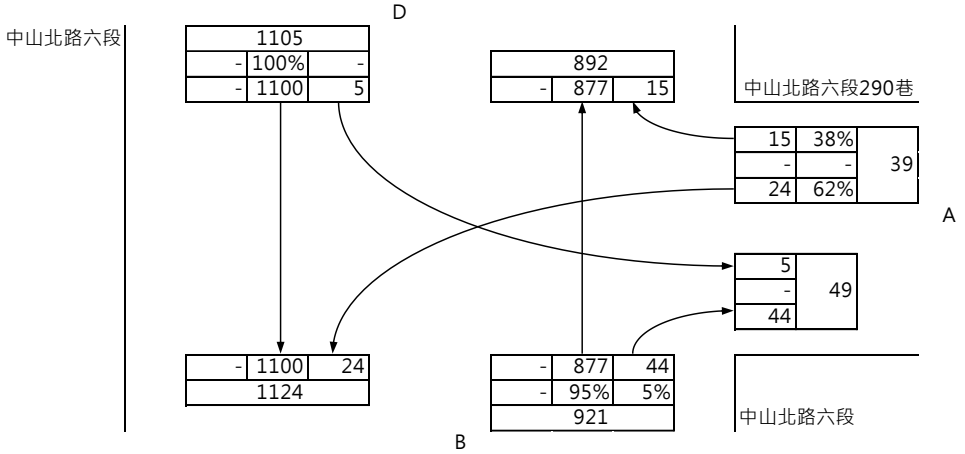
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	合計 大型車 比例	合計 小型車(輛)	合計 小型車 比例	合計 機車(輛)	合計 機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	-	13	23	24	0.69	-	-	-	-	-	-	-	7	8	11	0.31	-	-	20	0.39	31	0.61	51	35		
	17:00-18:00	-	14	23	25	0.68	-	-	-	-	-	-	-	9	6	12	0.32	-	-	23	0.44	29	0.56	52	37		
	18:00-19:00	-	10	18	18	0.60	-	-	-	-	-	-	-	9	4	12	0.40	-	-	19	0.46	22	0.54	41	30		
B	16:00-17:00	-	-	-	-	-	-	7	758	330	909	0.96	-	27	27	41	0.04	7	0.01	785	0.68	357	0.31	1149	950		
	17:00-18:00	-	-	-	-	-	-	9	639	418	831	0.95	-	26	29	41	0.05	9	0.01	665	0.59	447	0.40	1121	872		
	18:00-19:00	-	-	-	-	-	-	6	657	402	837	0.96	-	17	31	32	0.04	6	0.01	674	0.61	433	0.39	1113	869		
C	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
D	16:00-17:00	-	3	6	6	0.01	-	8	823	445	1024	0.99	-	-	-	-	-	8	0.01	826	0.64	451	0.35	1285	1030		
	17:00-18:00	-	3	6	6	0.01	-	10	835	553	1085	0.99	-	-	-	-	-	10	0.01	838	0.60	559	0.40	1407	1091		
	18:00-19:00	-	7	12	13	0.01	-	10	641	492	866	0.99	-	-	-	-	-	10	0.01	648	0.56	504	0.43	1162	879		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	16:00-17:00	-	16	29	30	0.01	-	15	1581	775	1933	0.96	-	34	35	52	0.03	15	0.01	1631	0.66	839	0.34	2485	2015		
	17:00-18:00	-	17	29	31	0.02	-	19	1474	971	1916	0.96	-	35	35	53	0.03	19	0.01	1526	0.59	1035	0.40	2580	2000		
	18:00-19:00	-	17	30	31	0.02	-	16	1298	894	1703	0.96	-	26	35	44	0.02	16	0.01	1341	0.58	959	0.41	2316	1778		
A	16:45-17:45	-	15	19	24	0.62	-	-	-	-	-	-	-	10	9	15	0.38	-	-	25	0.47	28	0.53	53	39	0.76	0.95
B		-	-	-	-	-	-	7	702	386	877	0.95	-	27	32	44	0.05	7	0.01	729	0.63	418	0.36	1154	921	0.91	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		-	3	4	5	-	-	9	846	567	1100	1.00	-	-	-	-	-	9	0.01	849	0.59	571	0.40	1429	1105	0.90	

X1：中山北六段/290巷(6/22)假日轉向交通量示意圖

站　號：　X1
站　名：　中山北六段/290巷

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　16:45-17:45

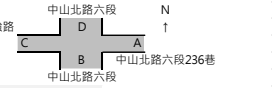


方向：	A	B	C	D
總車道數：	1	2	-	2

X2：中山北六段/克強路(6/20)平日交通量

站　號：　X2
站　名：　中山北六段/克強路
時相數：　6

日　期：　2024/06/20 (四)
天　候：　晴
方　向：　A　B　C　D
車道數：　1　2　1　2



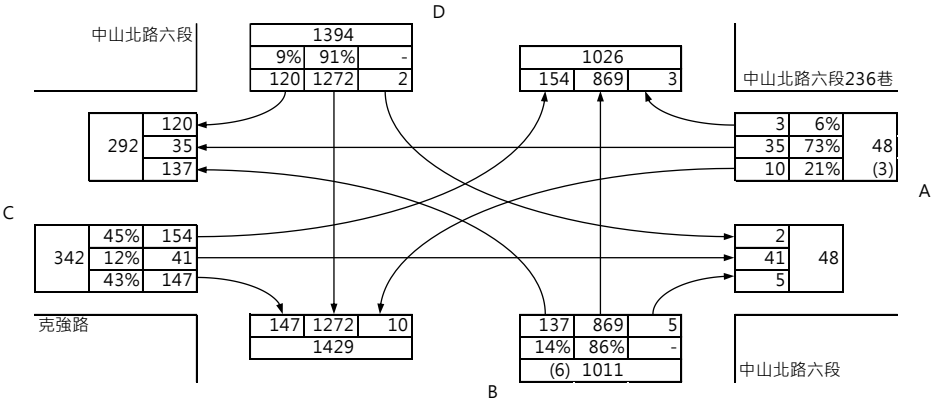
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	合計 大型車 比例	合計 小型車(輛)	合計 小型車 比例	合計 機車(輛)	合計 機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	06:30-07:30	-	-	12	5	0.22	-	-	1	31	14	0.61	-	2	3	4	0.17	-	-	3	0.06	46	0.94	49	23		
	07:30-08:30	-	2	19	10	0.21	3	-	3	76	35	0.73	-	1	5	3	0.06	-	-	6	0.06	100	0.94	106	48		
	08:30-09:30	-	1	14	7	0.18	-	-	2	56	26	0.69	-	2	7	5	0.13	-	-	5	0.06	77	0.94	82	38		
	12:00-13:00	-	-	4	2	0.06	2	-	3	45	22	0.71	-	4	6	7	0.23	-	-	7	0.11	55	0.89	62	31		
	13:00-14:00	-	-	4	2	0.09	-	-	2	37	18	0.82	-	-	5	2	0.09	-	-	2	0.04	46	0.96	48	22		
	14:00-15:00	-	2	4	4	0.13	1	-	4	29	16	0.54	-	5	11	10	0.33	-	-	11	0.20	44	0.80	55	30		
	16:00-17:00	-	1	7	4	0.11	2	-	1	60	26	0.72	-	2	9	6	0.17	-	-	4	0.05	76	0.95	80	36		
	17:00-18:00	-	-	9	4	0.11	1	-	-	65	27	0.75	-	2	6	5	0.14	-	-	2	0.02	80	0.98	82	36		
	18:00-19:00	-	1	9	5	0.11	2	-	3	73	34	0.74	-	3	9	7	0.15	-	-	7	0.07	91	0.93	98	46		
B	06:30-07:30	1	44	33	62	0.11	2	16	369	298	523	0.88	-	1	5	3	0.01	17	0.02	414	0.54	336	0.44	767	588		
	07:30-08:30	-	112	44	137	0.14	6	11	614	560	869	0.86	-	2	7	5	-	11	0.01	728	0.54	611	0.45	1350	1011		
	08:30-09:30	1	93	46	119	0.12	9	16	672	436	884	0.87	-	4	9	8	0.01	17	0.01	769	0.60	491	0.38	1277	1011		
	12:00-13:00	-	87	59	117	0.14	9	14	575	275	716	0.86	-	1	6	4	-	14	0.01	663	0.65	340	0.33	1017	837		
	13:00-14:00	-	93	46	117	0.12	5	14	659	318	818	0.87	-	1	15	8	0.01	14	0.01	753	0.66	379	0.33	1146	943		
	14:00-15:00	-	109	58	139	0.15	4	11	656	278	793	0.84	-	4	8	8	0.01	11	0.01	769	0.68	344	0.31	1124	940		
	16:00-17:00	-	105	59	136	0.15	5	14	622	344	792	0.84	-	3	13	9	0.01	14	0.01	730	0.63	416	0.36	1160	937		
	17:00-18:00	-	98	92	142	0.13	4	14	689	439	899	0.86	-	6	19	15	0.01	14	0.01	793	0.58	550	0.41	1357	1056		
	18:00-19:00	-	88	124	146	0.13	6	13	656	629	944	0.86	-	4	27	16	0.01	13	0.01	748	0.49	780	0.51	1541	1106		
C	06:30-07:30	2	37	53	66	0.38	-	-	1	37	17	0.10	2	70	20	90	0.52	4	0.02	108	0.49	110	0.50	222	173		
	07:30-08:30	3	92	120	154	0.45	-	-	6	83	41	0.12	-	124	29	147	0.43	3	0.01	222	0.49	232	0.51	457	342		
	08:30-09:30	2	111	108	167	0.48	-	-	-	85	36	0.10	1	113	45	145	0.42	3	0.01	224	0.48	238	0.51	465	348		
	12:00-13:00	3	105	91	155	0.46	-	-	3	87	40	0.12	-	115	35	140	0.42	3	0.01	223	0.51	213	0.49	439	335		
	13:00-14:00	1	83	80	124	0.49	-	-	2	56	26	0.10	-	83	32	104	0.41	1	0.00	168	0.50	168	0.50	337	254		
	14:00-15:00	3	73	65	111	0.40	-	-	10	54	33	0.12	-	103	44	131	0.48	3	0.01	186	0.53	163	0.46	352	275		
	16:00-17:00	3	118	104	175	0.51	-	-	6	88	43	0.13	-	102	34	125	0.36	3	0.01	226	0.50	226	0.50	455	343		
	17:00-18:00	1	131	142	201	0.53	-	-	8	110	54	0.14	-	93	56	126	0.33	1	0.00	232	0.43	308	0.57	541	381		
	18:00-19:00	2	135	197	230	0.59	-	-	4	120	54	0.14	-	82	41	107	0.27	2	0.00	221	0.38	358	0.62	581	391		
D	06:30-07:30	-	-	3	1	-	-	18	678	355	860	0.94	2	29	37	53	0.06	20	0.02	707	0.63	395	0.35	1122	914		
	07:30-08:30	-	-	4	2	-	-	16	902	812	1272	0.91	3	73	73	120	0.09	19	0.01	975	0.52	889	0.47	1883	1394		
	08:30-09:30	-	1	3	2	-	-	16	927	516	1173	0.92	2	67	68	108	0.08	18	0.01	995	0.62	587	0.37	1600	1283		
	12:00-13:00	-	-	1	-	-	-	11	800	400	988	0.92	1	57	59	91	0.08	12	0.01	857	0.64	460	0.35	1329	1079		
	13:00-14:00	-	1	2	2	-	-	11	792	361	963	0.92	2	53	45	83	0.08	13	0.01	846	0.67	408	0.32	1267	1048		
	14:00-15:00	-	2	3	3	-	-	12	834	364	1008	0.92	2	52	48	83	0.08	14	0.01	888	0.67	415	0.32	1317	1094		
	16:00-17:00	-	1	1	1	-	-	10	847	516	1082	0.90	3	68	76	116	0.10	13	0.01	916	0.60	593	0.39	1522	1199		
	17:00-18:00	-	1	1	1	-	-	12	700	691	1012	0.87	2	95	105	155	0.13	14	0.01	796	0.50	797	0.50	1607	1168		
	18:00-19:00	-	-	4	2	-	-	14	531	523	776	0.85	4	67	111	133	0.15	18	0.01	598	0.48	638	0.51	1254	911		
	PCE :	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	06:30-07:30	3	81	101	134	0.08	2	34	1049	721	1414	0.83	4	102	65	150	0.09	41	0.02	1232	0.57	887	0.41	2160	1698		
	07:30-08:30	3	206	187	303	0.11	9	27	1525	1531	2217	0.79	3	200	114	275	0.10	33	0.01	1931	0.51	1832	0.48	3796	2795		
	08:30-09:30	3	206	171	295	0.11	9	32	1601	1093	2119	0.79	3	186	129	266	0.10	38	0.01	1993	0.58	1393	0.41	3424	2680		
	12:00-13:00	3	192	155	274	0.12	11	25	1381	807	1766	0.77	1	177	106	242	0.11	29	0.01	1750	0.61	1068	0.38	2847	2282		
	13:00-14:00	1	177	132	245	0.11	5	25	1455	772	1825	0.81	2	137	97	197	0.09	28	0.01	1769	0.63	1001	0.36	2798	2267		
	14:00-15:00	3	186	130	257	0.11	5	23	1504	725	1850	0.79	2	164	111	232	0.10	28	0.01	1854	0.65	966	0.34	2848	2339		
	16:00-17:00	3	225	171	316	0.13	7	24	1476	1008	1943	0.77	3	175	132	256	0.10	30	0.01	1876	0.58	1311	0.41	3217	2515		
	17:00-18:00	1	230	244	348	0.13	5	26	1397	1305	1992	0.75	2	196	186	301	0.11	29	0.01	1823	0.51	1735	0.48	3587	2641		
	18:00-19:00	2	224	334	383	0.16	8	27	1194	1345	1808	0.74	4	156	188	263	0.11	33	0.01	1574	0.45	1867	0.54	3474	2454		
A	07:30-08:30	-	2	19	10	0.21	3	-	3	76	35	0.73	-	1	5	3	0.06	-	-	6	0.06	100	0.94	106	48	0.83	0.90
B		-	112	44	137	0.14	6	11	614	560	869	0.86	-	2	7	5	-	11	0.01	728	0.54	611	0.45	1350	1011	0.87	
C		3	92	120	154	0.45	-	-	6	83	41	0.12	-	124	29	147	0.43	3	0.01	222	0.49	232	0.51	457	342	0.88	
D		-	-	4	2	-	-	16	902	812	1272	0.91	3	73	73	120	0.09	19	0.01	975	0.52	889	0.47	1883	1394	0.88	
A	13:45-14:45	-	2	4	4	0.12	-	-	4	36	19	0.58	-	4	12	10	0.30	-	-	10	0.16	52	0.84	62	33	0.81	0.91
B		-	106	57	136	0.14	4	8	685	296	824	0.85	-	1	11	6	0.01	8	0.01	792	0.68	364	0.31	1164	966	0.88	
C		2	87	68	125	0.44	-	-	7	54	30	0.11	-	97	46	125	0.44	2	0.01	191	0.53	168	0.47	361	280	0.95	
D		-	3	3	4	-	-	12	845	361	1018	0.92	2	53	50	85	0.08	14	0.01	901	0.68	414	0.31	1329	1107	0.91	
A	17:00-18:00	-	-	9	4	0.11	1	-	-	65	27	0.75	-	2	6	5	0.14	-	-	2	0.02	80	0.98	82	36	0.71	0.94
B		-	98	92	142	0.13	4	14	689	439	899	0.86	-	6	19	15	0.01	14	0.01	793	0.58	550	0.41	1357	1056	0.90	
C		1	131	142	201	0.53	-	-	8	110	54	0.14	-	93	56	126	0.33	1	0.00	232	0.43	308	0.57	541	381	0.80	
D		-	1	1	1	-	-	12	700	691	1012	0.87	2	95	105	155	0.13	14	0.01	796	0.50	797	0.50	1607	1168	0.93	

X2：中山北六段/克強路(6/20)平日轉向交通量示意圖

站　號：　X2
站　名：　中山北六段/克強路

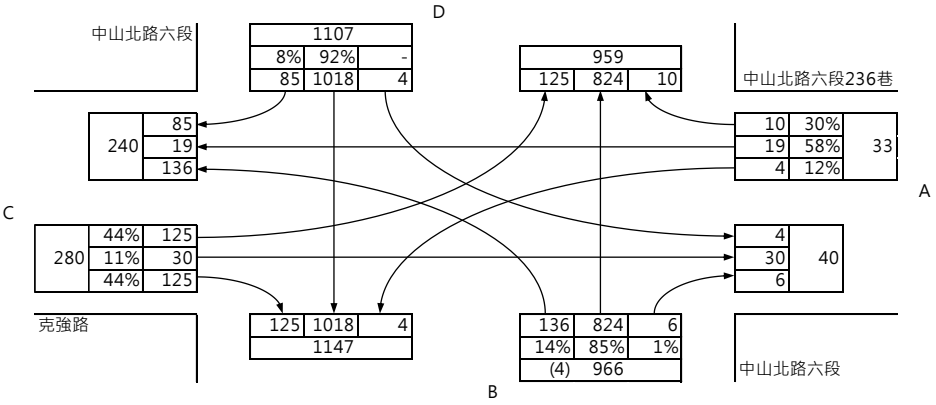
單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

上午尖峰：　07:30-08:30



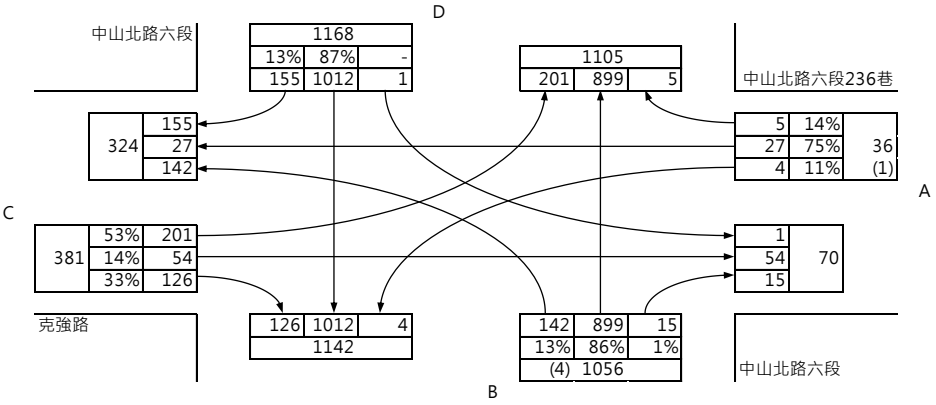
(單位:輛)
()為機車二段式左轉車輛數

離峰：　13:45-14:45



(單位:輛)
()為機車二段式左轉車輛數

下午尖峰：　17:00-18:00



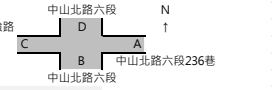
(單位:輛)
()為機車二段式左轉車輛數

方　向：	A	B	C	D
總車道數：	1	2	1	2

X2：中山北六段/克強路(6/22)假日交通量

站　號：　X2
站　名：　中山北六段/克強路
時相數：　6

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　1　2　1　2



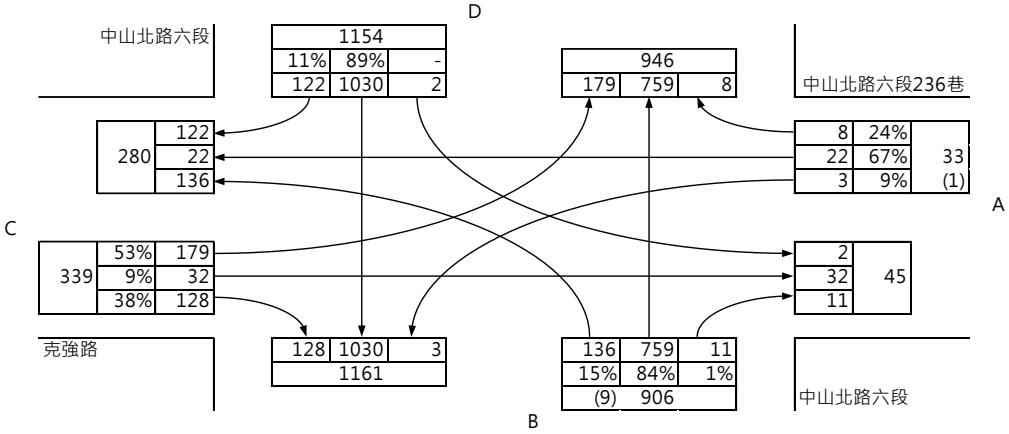
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	轉向比	合計 大型車(輛)	合計 大型車比例	合計 小型車(輛)	合計 小型車比例	合計 機車(輛)	合計 機車比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	-	-	7	3	0.11	1	-	-	36	15	0.53	-	4	12	10	0.36	-	-	4	0.07	55	0.93	59	28		
	17:00-18:00	-	-	8	3	0.10	1	-	-	52	22	0.71	-	1	10	6	0.19	-	-	1	0.01	70	0.99	71	31		
	18:00-19:00	-	-	6	3	0.17	2	-	-	25	11	0.61	-	1	7	4	0.22	-	-	1	0.03	38	0.97	39	18		
B	16:00-17:00	-	91	47	116	0.12	6	6	682	278	810	0.87	-	6	8	10	0.01	6	0.01	779	0.70	333	0.30	1118	936		
	17:00-18:00	-	90	75	127	0.15	7	7	555	336	709	0.84	-	7	4	9	0.01	7	0.01	652	0.61	415	0.39	1074	845		
	18:00-19:00	-	75	52	101	0.12	3	4	586	313	725	0.87	-	3	11	8	0.01	4	0.00	664	0.64	376	0.36	1044	834		
C	16:00-17:00	1	114	87	159	0.50	-	-	3	50	24	0.08	-	112	30	134	0.42	1	0.00	229	0.58	167	0.42	397	317		
	17:00-18:00	2	121	113	180	0.51	-	-	-	80	34	0.10	-	105	48	135	0.39	2	0.00	226	0.48	241	0.51	469	349		
	18:00-19:00	2	96	119	156	0.55	-	-	2	92	41	0.14	-	70	30	89	0.31	2	0.00	168	0.41	241	0.59	411	286		
D	16:00-17:00	-	1	1	1	-	-	7	790	415	977	0.91	2	59	65	98	0.09	9	0.01	850	0.63	481	0.36	1340	1076		
	17:00-18:00	-	-	4	2	-	-	8	806	495	1028	0.90	2	62	93	114	0.10	10	0.01	868	0.59	592	0.40	1470	1144		
	18:00-19:00	-	-	3	1	-	-	8	608	420	799	0.88	1	64	89	112	0.12	9	0.01	672	0.56	512	0.43	1193	912		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	16:00-17:00	1	206	142	279	0.12	7	13	1475	779	1826	0.77	2	181	115	252	0.11	16	0.01	1862	0.64	1036	0.36	2914	2357		
	17:00-18:00	2	211	200	312	0.13	8	15	1361	963	1793	0.76	2	175	155	264	0.11	19	0.01	1747	0.57	1318	0.43	3084	2369		
	18:00-19:00	2	171	180	261	0.13	5	12	1196	850	1576	0.77	1	138	137	213	0.10	15	0.01	1505	0.56	1167	0.43	2687	2050		
A	16:45-17:45	-	-	8	3	0.09	1	-	-	52	22	0.67	-	2	14	8	0.24	-	-	2	0.03	74	0.97	76	33	0.77	0.96
B		-	97	79	136	0.15	9	5	616	320	759	0.84	-	8	5	11	0.01	5	0.00	721	0.64	404	0.36	1130	906	0.87	
C		2	127	97	179	0.53	-	-	-	75	32	0.09	-	101	43	128	0.38	2	0.00	228	0.51	215	0.48	445	339	0.83	
D		-	-	4	2	-	-	7	805	505	1030	0.89	2	69	93	122	0.11	9	0.01	874	0.59	602	0.41	1485	1154	0.92	

X2：中山北六段/克強路(6/22)假日轉向交通量示意圖

站　號：　X2
站　名：　中山北六段/克強路

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　16:45-17:45



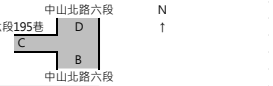
(單位:輛)
( )為機車二段式左轉車輛數

方　向：	A	B	C	D
總車道數：	1	2	1	2

X3：中山北六段/195巷(6/20)平日交通量

站　號：　X3
站　名：　中山北六段/195巷
時相數：　3

日　期：　2024/06/20 (四)
天　候：　晴
方　向：　A　B　C　D
車道數：　-　2　-　2



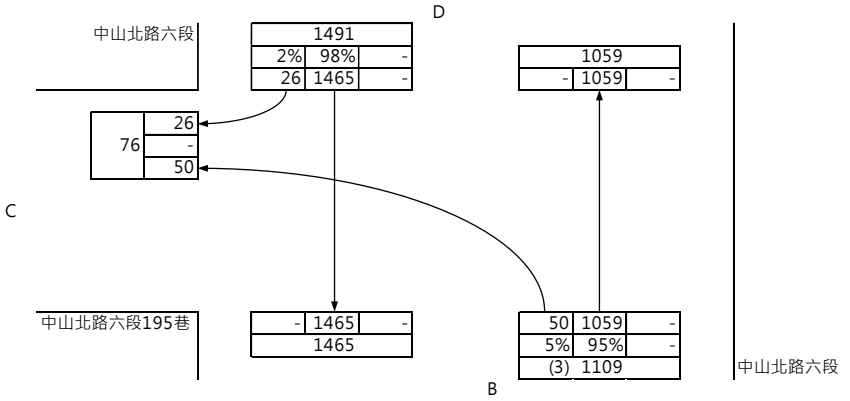
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車	比例	合計 小型車	比例	合計 機車	比例	總和(輛)	PCU	PHF	總流量 PHF
A	06:30-07:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	08:30-09:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	12:00-13:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	13:00-14:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	14:00-15:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
B	06:30-07:30	-	14	11	19	0.03	3	26	447	323	629	0.97	-	-	-	-	-	26	0.03	461	0.56	334	0.41	821	648		
	07:30-08:30	-	40	18	50	0.05	3	11	770	642	1059	0.95	-	-	-	-	-	11	0.01	810	0.55	660	0.45	1481	1109		
	08:30-09:30	1	35	13	44	0.04	7	14	754	449	968	0.96	-	-	-	-	-	15	0.01	789	0.62	462	0.36	1266	1012		
	12:00-13:00	-	17	27	29	0.03	3	15	643	340	813	0.97	-	-	-	-	-	15	0.01	660	0.63	367	0.35	1042	842		
	13:00-14:00	-	31	14	39	0.04	2	17	784	387	977	0.96	-	-	-	-	-	17	0.01	815	0.66	401	0.33	1233	1016		
	14:00-15:00	-	25	9	30	0.03	-	13	724	318	881	0.97	-	-	-	-	-	13	0.01	749	0.69	327	0.30	1089	911		
	16:00-17:00	-	42	12	49	0.05	2	12	807	429	1009	0.95	-	-	-	-	-	12	0.01	849	0.65	441	0.34	1302	1058		
	17:00-18:00	-	47	14	55	0.05	2	20	801	534	1061	0.95	-	-	-	-	-	20	0.01	848	0.60	548	0.39	1416	1116		
	18:00-19:00	-	49	23	61	0.06	5	14	725	683	1037	0.94	-	-	-	-	-	14	0.01	774	0.52	706	0.47	1494	1098		
C	06:30-07:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	08:30-09:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	12:00-13:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	13:00-14:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	14:00-15:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
D	06:30-07:30	-	-	-	-	-	-	23	811	383	1013	0.99	2	6	8	15	0.01	25	0.02	817	0.66	391	0.32	1233	1028		
	07:30-08:30	-	-	-	-	-	-	17	1057	899	1465	0.98	-	17	16	26	0.02	17	0.01	1074	0.54	915	0.46	2006	1491		
	08:30-09:30	-	-	-	-	-	-	27	1002	571	1290	0.99	-	8	20	18	0.01	27	0.02	1010	0.62	591	0.36	1628	1308		
	12:00-13:00	-	-	-	-	-	-	15	888	449	1104	0.98	1	10	14	20	0.02	16	0.01	898	0.65	463	0.34	1377	1124		
	13:00-14:00	-	-	-	-	-	-	16	857	369	1041	0.99	-	4	11	9	0.01	16	0.01	861	0.68	380	0.30	1257	1050		
	14:00-15:00	-	-	-	-	-	-	13	875	366	1052	0.99	1	2	14	11	0.01	14	0.01	877	0.69	380	0.30	1271	1063		
	16:00-17:00	-	-	-	-	-	-	11	925	520	1163	0.98	-	16	10	22	0.02	11	0.01	941	0.63	530	0.36	1482	1185		
	17:00-18:00	-	-	-	-	-	-	15	807	750	1149	0.98	1	8	15	18	0.02	16	0.01	815	0.51	765	0.48	1596	1167		
	18:00-19:00	-	-	-	-	-	-	13	587	560	846	0.98	-	12	8	17	0.02	13	0.01	599	0.51	568	0.48	1180	863		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	06:30-07:30	-	14	11	19	0.01	3	49	1258	706	1642	0.98	2	6	8	15	0.01	51	0.02	1278	0.62	725	0.35	2054	1676		
	07:30-08:30	-	40	18	50	0.02	3	28	1827	1541	2524	0.97	-	17	16	26	0.01	28	0.01	1884	0.54	1575	0.45	3487	2600		
	08:30-09:30	1	35	13	44	0.02	7	41	1756	1020	2258	0.97	-	8	20	18	0.01	42	0.01	1799	0.62	1053	0.36	2894	2320		
	12:00-13:00	-	17	27	29	0.01	3	30	1531	789	1917	0.98	1	10	14	20	0.01	31	0.01	1558	0.64	830	0.34	2419	1966		
	13:00-14:00	-	31	14	39	0.02	2	33	1641	756	2018	0.98	-	4	11	9	0.00	33	0.01	1676	0.67	781	0.31	2490	2066		
	14:00-15:00	-	25	9	30	0.02	-	26	1599	684	1933	0.98	1	2	14	11	0.01	27	0.01	1626	0.69	707	0.30	2360	1974		
	16:00-17:00	-	42	12	49	0.02	2	23	1732	949	2172	0.97	-	16	10	22	0.01	23	0.01	1790	0.64	971	0.35	2784	2243		
	17:00-18:00	-	47	14	55	0.02	2	35	1608	1284	2210	0.97	1	8	15	18	0.01	36	0.01	1663	0.55	1313	0.44	3012	2283		
	18:00-19:00	-	49	23	61	0.03	5	27	1312	1243	1883	0.96	-	12	8	17	0.01	27	0.01	1373	0.51	1274	0.48	2674	1961		
A	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0.90
B		-	40	18	50	0.05	3	11	770	642	1059	0.95	-	-	-	-	-	11	0.01	810	0.55	660	0.45	1481	1109	0.89	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		-	-	-	-	-	-	17	1057	899	1465	0.98	-	17	16	26	0.02	17	0.01	1074	0.54	915	0.46	2006	1491	0.91	
A	13:15-14:15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0.91
B		-	36	16	45	0.04	2	15	768	387	958	0.96	-	-	-	-	-	15	0.01	804	0.66	403	0.33	1222	1003	0.88	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		-	-	-	-	-	-	19	869	371	1059	0.99	-	3	14	10	0.01	19	0.01	872	0.68	385	0.30	1276	1069	0.93	
A	16:45-17:45	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0.96
B		-	47	12	55	0.05	2	17	805	483	1038	0.95	-	-	-	-	-	17	0.01	852	0.62	495	0.36	1364	1093	0.95	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		-	-	-	-	-	-	12	844	748	1180	0.99	1	7	15	17	0.01	13	0.01	851	0.52	763	0.47	1627	1197	0.95	

X3：中山北六段/195巷(6/20)平日轉向交通量示意圖

站　號：　X3
站　名：　中山北六段/195巷

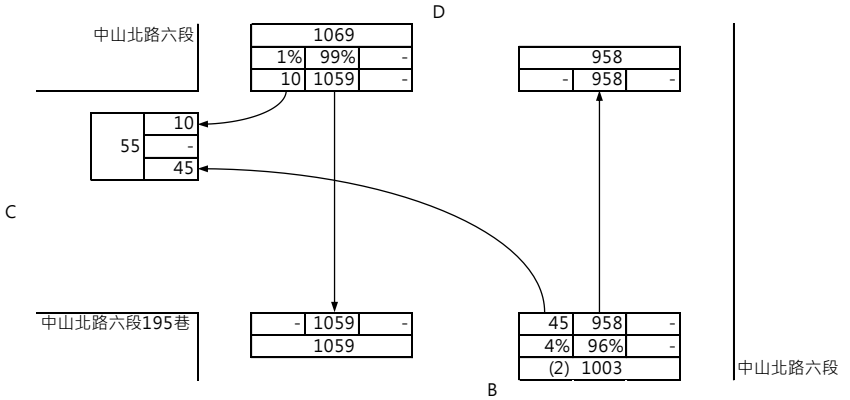
單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

上午尖峰：　07:30-08:30



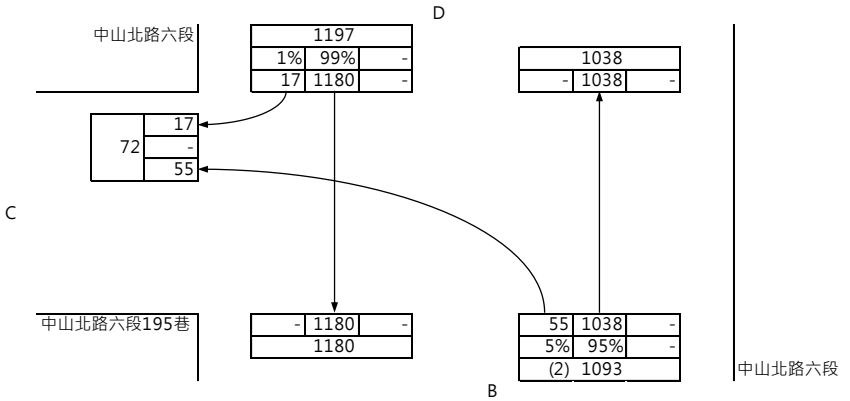
(單位:輛)
()為機車二段式左轉車輛數

離峰：　13:15-14:15



(單位:輛)
()為機車二段式左轉車輛數

下午尖峰：　16:45-17:45



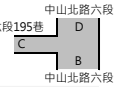
(單位:輛)
()為機車二段式左轉車輛數

方　向：	A	B	C	D
總車道數：	-	2	-	2

X3：中山北六段/195巷(6/22)假日交通量

站　號：　X3
站　名：　中山北六段/195巷
時相數：　4

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　-　2　-　2



方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	轉向比	合計 大型車(輛)	合計 大型車比例	合計 小型車(輛)	合計 小型車比例	合計 機車(輛)	合計 機車比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
B	16:00-17:00	-	37	15	45	0.04	4	12	853	311	1005	0.96	-	-	-	-	-	12	0.01	890	0.72	326	0.27	1228	1050		
	17:00-18:00	-	29	20	39	0.05	5	3	647	403	822	0.95	-	-	-	-	-	3	0.00	676	0.61	423	0.38	1102	861		
	18:00-19:00	-	30	15	38	0.05	4	8	646	346	806	0.95	-	-	-	-	-	8	0.01	676	0.65	361	0.35	1045	844		
C	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
D	16:00-17:00	-	-	-	-	-	-	6	891	429	1082	0.99	-	13	4	16	0.01	6	0.00	904	0.67	433	0.32	1343	1098		
	17:00-18:00	-	-	-	-	-	-	10	907	551	1156	0.98	-	16	9	21	0.02	10	0.01	923	0.62	560	0.38	1493	1177		
	18:00-19:00	-	-	-	-	-	-	8	658	455	864	0.98	-	13	13	20	0.02	8	0.01	671	0.59	468	0.41	1147	884		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	16:00-17:00	-	37	15	45	0.02	4	18	1744	740	2087	0.97	-	13	4	16	0.01	18	0.01	1794	0.70	759	0.30	2571	2148		
	17:00-18:00	-	29	20	39	0.02	5	13	1554	954	1978	0.97	-	16	9	21	0.01	13	0.01	1599	0.62	983	0.38	2595	2038		
	18:00-19:00	-	30	15	38	0.02	4	16	1304	801	1670	0.97	-	13	13	20	0.01	16	0.01	1347	0.61	829	0.38	2192	1728		

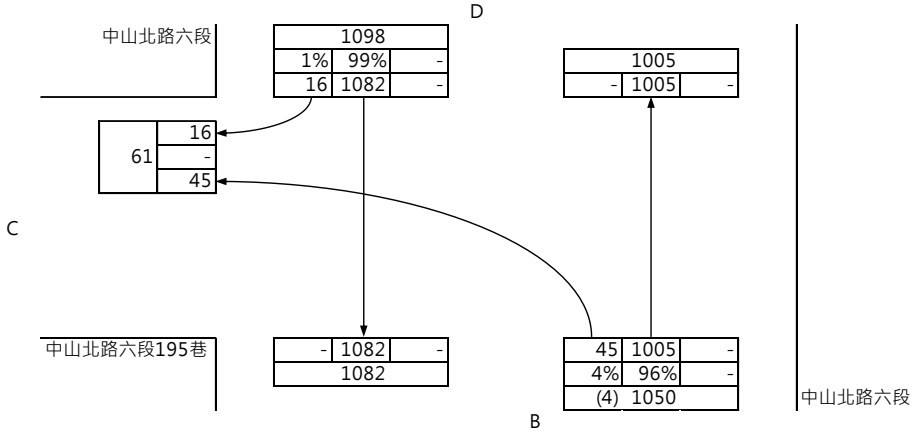
A	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0.97
B		-	37	15	45	0.04	4	12	853	311	1005	0.96	-	-	-	-	-	12	0.01	890	0.72	326	0.27	1228	1050	0.93	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		-	-	-	-	-	-	6	891	429	1082	0.99	-	13	4	16	0.01	6	0.00	904	0.67	433	0.32	1343	1098	0.97	

X3：中山北六段/195巷(6/22)假日轉向交通量示意圖

站　號：　X3
站　名：　中山北六段/195巷

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　16:00-17:00



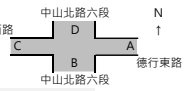
(單位:輛)
( )為機車二段式左轉車輛數

方向：	A	B	C	D
總車道數：	-	2	-	2

X4：中山北六段/德行西路(6/20)平日交通量

站　號：　X4
站　名：　中山北六段/德行西路
時相數：　6

日　期：　2024/06/20 (四)
天　候：　晴
方　向：　A　B　C　D
車道數：　1　3　2　3



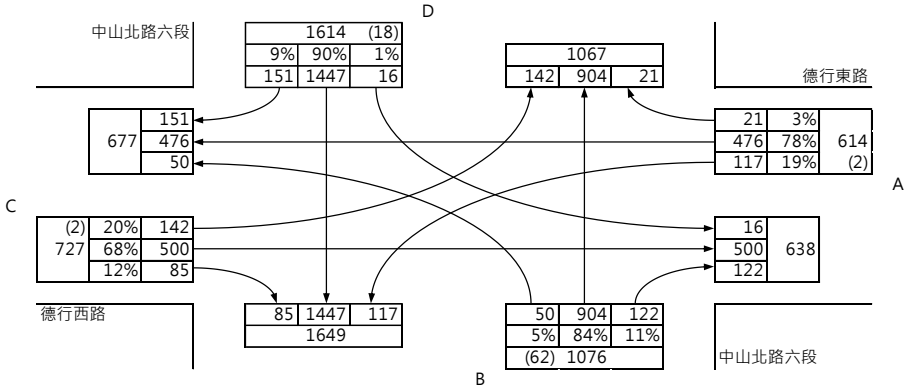
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	大型車 比例	合計 小型車(輛)	小型車 比例	合計 機車(輛)	機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	06:30-07:30	2	31	84	73	0.22	1	6	134	236	244	0.73	1	9	7	16	0.05	9	0.02	174	0.34	327	0.64	510	333		
	07:30-08:30	2	42	160	117	0.19	2	7	262	480	476	0.78	-	16	9	21	0.03	9	0.01	320	0.33	649	0.66	978	614		
	08:30-09:30	2	34	115	89	0.17	-	6	225	390	400	0.74	-	38	10	46	0.09	8	0.01	297	0.36	515	0.63	820	535		
	12:00-13:00	3	81	122	144	0.28	1	4	174	327	319	0.61	-	37	36	56	0.11	7	0.01	292	0.37	485	0.62	784	519		
	13:00-14:00	2	61	110	115	0.22	-	9	191	324	343	0.67	1	33	36	55	0.11	12	0.02	285	0.37	470	0.61	767	513		
	14:00-15:00	2	70	108	124	0.24	2	7	218	327	368	0.69	-	23	22	35	0.07	9	0.01	311	0.40	457	0.59	777	527		
	16:00-17:00	2	48	110	102	0.18	-	10	240	386	420	0.75	-	26	22	38	0.07	12	0.01	314	0.37	518	0.61	844	560		
	17:00-18:00	3	56	126	119	0.17	4	7	242	595	505	0.74	-	41	38	61	0.09	10	0.01	339	0.31	759	0.69	1108	685		
	18:00-19:00	1	44	146	111	0.17	2	6	201	617	471	0.74	-	37	38	57	0.09	7	0.01	282	0.26	801	0.73	1090	639		
B	06:30-07:30	-	15	-	16	0.03	16	13	369	291	515	0.86	2	36	48	66	0.11	15	0.02	420	0.54	339	0.44	774	597		
	07:30-08:30	-	47	1	50	0.05	62	10	650	563	904	0.84	1	61	118	122	0.11	11	0.01	758	0.52	682	0.47	1451	1076		
	08:30-09:30	-	45	1	48	0.04	78	15	682	517	926	0.85	1	66	113	125	0.11	16	0.01	793	0.55	631	0.44	1440	1099		
	12:00-13:00	-	41	1	43	0.05	60	12	571	330	731	0.77	3	96	118	165	0.18	15	0.01	708	0.60	449	0.38	1172	939		
	13:00-14:00	-	58	1	61	0.06	52	13	657	356	830	0.80	-	89	107	144	0.14	13	0.01	804	0.63	464	0.36	1281	1035		
	14:00-15:00	-	50	-	53	0.05	85	10	701	366	873	0.80	3	111	88	168	0.15	13	0.01	862	0.65	454	0.34	1329	1094		
	16:00-17:00	-	-	-	-	-	66	13	747	403	940	0.84	2	110	116	176	0.16	15	0.01	857	0.62	519	0.37	1391	1116		
	17:00-18:00	-	-	-	-	-	158	13	737	602	1013	0.82	2	135	153	220	0.18	15	0.01	872	0.53	755	0.46	1642	1233		
	18:00-19:00	-	3	-	3	-	154	11	720	758	1058	0.82	5	126	189	235	0.18	16	0.01	849	0.47	947	0.52	1812	1296		
C	06:30-07:30	2	55	38	78	0.17	-	5	199	231	305	0.69	-	52	15	63	0.14	7	0.01	306	0.51	284	0.48	597	446		
	07:30-08:30	1	101	79	142	0.20	2	10	293	450	500	0.68	1	65	27	85	0.12	12	0.01	459	0.45	556	0.54	1027	727		
	08:30-09:30	2	103	65	140	0.21	1	7	273	349	432	0.64	1	80	22	99	0.15	10	0.01	456	0.51	436	0.48	902	671		
	12:00-13:00	1	83	37	105	0.16	1	10	260	336	419	0.64	2	101	33	129	0.20	13	0.02	444	0.51	406	0.47	863	653		
	13:00-14:00	1	79	42	103	0.17	-	7	234	275	362	0.60	-	112	35	137	0.23	8	0.01	425	0.54	352	0.45	785	602		
	14:00-15:00	2	82	53	113	0.18	-	7	226	270	352	0.57	-	119	51	151	0.25	9	0.01	427	0.53	374	0.46	810	616		
	16:00-17:00	1	86	45	112	0.17	1	7	289	316	434	0.64	1	100	42	130	0.19	9	0.01	475	0.54	403	0.45	887	676		
	17:00-18:00	-	96	75	133	0.16	2	7	340	499	562	0.65	-	135	35	162	0.19	7	0.01	571	0.48	609	0.51	1187	857		
	18:00-19:00	1	85	98	133	0.15	1	8	371	546	615	0.70	-	99	66	137	0.15	9	0.01	555	0.44	710	0.56	1274	885		
D	06:30-07:30	1	6	-	8	0.01	10	9	709	453	915	0.92	-	55	32	74	0.07	10	0.01	770	0.61	485	0.38	1265	997		
	07:30-08:30	-	15	1	16	0.01	18	12	1007	997	1447	0.90	2	101	81	151	0.09	14	0.01	1123	0.51	1079	0.49	2216	1614		
	08:30-09:30	-	25	1	27	0.02	17	14	1009	656	1310	0.88	1	98	74	142	0.10	15	0.01	1132	0.60	731	0.39	1878	1479		
	12:00-13:00	-	46	-	48	0.04	41	9	851	439	1052	0.86	-	82	70	120	0.10	9	0.01	979	0.65	509	0.34	1497	1220		
	13:00-14:00	-	29	-	30	0.03	31	11	828	407	1019	0.87	-	84	52	114	0.10	11	0.01	941	0.67	459	0.33	1411	1163		
	14:00-15:00	-	44	-	46	0.04	42	10	870	391	1052	0.86	-	87	56	119	0.10	10	0.01	1001	0.69	447	0.31	1458	1217		
	16:00-17:00	-	29	1	31	0.02	34	9	876	527	1114	0.84	-	140	70	183	0.14	9	0.01	1045	0.63	598	0.36	1652	1328		
	17:00-18:00	-	20	-	21	0.02	41	9	768	735	1093	0.86	-	104	99	157	0.12	9	0.01	892	0.51	834	0.48	1735	1271		
	18:00-19:00	-	22	1	24	0.02	40	13	610	569	872	0.84	-	85	111	142	0.14	13	0.01	717	0.51	681	0.48	1411	1038		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	06:30-07:30	5	107	122	175	0.07	27	33	1411	1211	1979	0.83	3	152	102	219	0.09	41	0.01	1670	0.53	1435	0.46	3146	2373		
	07:30-08:30	3	205	241	325	0.08	84	39	2212	2490	3327	0.83	4	243	235	379	0.09	46	0.01	2660	0.47	2966	0.52	5672	4031		
	08:30-09:30	4	207	182	304	0.08	96	42	2189	1912	3068	0.81	3	282	219	412	0.11	49	0.01	2678	0.53	2313	0.46	5040	3784		
	12:00-13:00	4	251	160	340	0.10	103	35	1856	1432	2521	0.76	5	316	257	470	0.14	44	0.01	2423	0.56	1849	0.43	4316	3331		
	13:00-14:00	3	227	153	309	0.09	83	40	1910	1362	2554	0.77	1	318	230	450	0.14	44	0.01	2455	0.58	1745	0.41	4244	3313		
	14:00-15:00	4	246	161	336	0.10	129	34	2015	1354	2645	0.77	3	340	217	473	0.14	41	0.01	2601	0.59	1732	0.40	4374	3454		
	16:00-17:00	3	163	156	245	0.07	101	39	2152	1632	2908	0.79	3	376	250	527	0.14	45	0.01	2691	0.56	2038	0.43	4774	3680		
	17:00-18:00	3	172	201	273	0.07	205	36	2087	2431	3173	0.78	2	415	325	600	0.15	41	0.01	2674	0.47	2957	0.52	5672	4046		
	18:00-19:00	2	154	245	271	0.07	197	38	1902	2490	3016	0.78	5	347	404	571	0.15	45	0.01	2403	0.43	3139	0.56	5587	3858		
A	07:30-08:30	2	42	160	117	0.19	2	7	262	480	476	0.78	-	16	9	21	0.03	9	0.01	320	0.33	649	0.66	978	614	0.95	0.94
B		-	47	1	50	0.05	62	10	650	563	904	0.84	1	61	118	122	0.11	11	0.01	758	0.52	682	0.47	1451	1076	0.89	
C		1	101	79	142	0.20	2	10	293	450	500	0.68	1	65	27	85	0.12	12	0.01	459	0.45	556	0.54	1027	727	0.90	
D		-	15	1	16	0.01	18	12	1007	997	1447	0.90	2	101	81	151	0.09	14	0.01	1123	0.51	1079	0.49	2216	1614	0.93	
A	14:00-15:00	2	70	108	124	0.24	2	7	218	327	368	0.69	-	23	22	35	0.07	9	0.01	311	0.40	457	0.59	777	527	0.95	0.94
B		-	50	-	53	0.05	85	10	701	366	873	0.80	3	111	88	168	0.15	13	0.01	862	0.65	454	0.34	1329	1094	0.89	
C		2	82	53	113	0.18	-	7	226	270	352	0.57	-	119	51	151	0.25	9	0.01	427	0.53	374	0.46	810	616	0.93	
D		-	44	-	46	0.04	42	10	870	391	1052	0.86	-	87	56	119	0.10	10	0.01	1001	0.69	447	0.31	1458	1217	0.92	
A	17:15-18:15	2	54	131	117	0.17	4	5	238	626	510	0.73	-	48	38	69	0.10	7	0.01	340	0.30	795	0.70	1142	696	0.94	0.96
B		-	-	-	-	-	177	15	734	675	1045	0.82	1	136	171	227	0.18	16	0.01	870	0.50	846	0.49	1732	1272	0.86	
C		-	84	78	122	0.14	2	7	369	503	593	0.68	-	128	44	158	0.18	7	0.01	581	0.48	625	0.52	1213	873	0.91	
D		-	24	-	25	0.02	45	11	730	704	1045	0.85	-	103	92	153	0.13	11	0.01	857	0.52	796	0.48	1664	1223	0.89	

X4：中山北六段/德行西路(6/20)平日轉向交通量示意圖

站　號：　X4
站　名：　中山北六段/德行西路

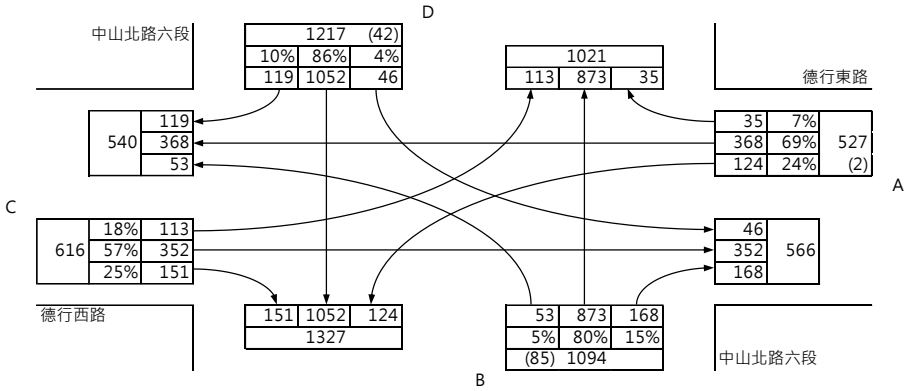
單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

上午尖峰：　07:30-08:30



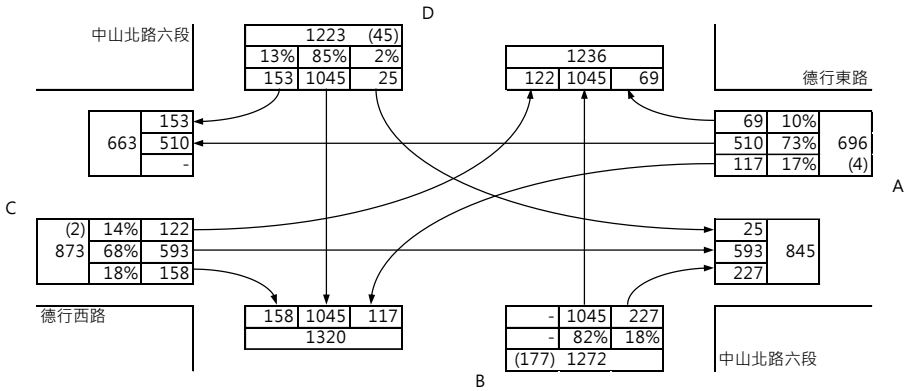
(單位:輛)
( )為機車二段式左轉車輛數

離峰：　14:00-15:00



(單位:輛)
( )為機車二段式左轉車輛數

下午尖峰：　17:15-18:15



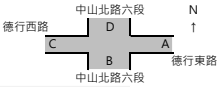
(單位:輛)
( )為機車二段式左轉車輛數

方　向：	A	B	C	D
總車道數：	1	3	2	3

X4：中山北六段/德行西路(6/22)假日交通量

站　號：　X4
站　名：　中山北六段/德行西路
時相數：　6

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　1　3　2　3



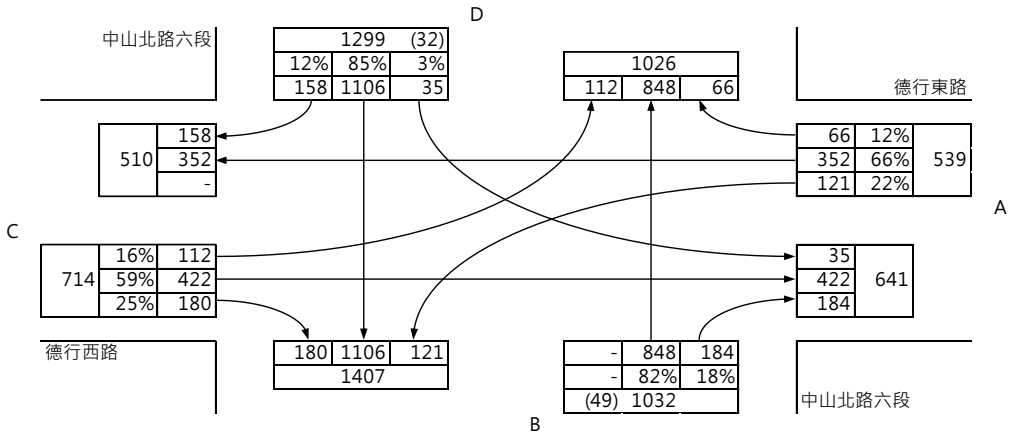
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	合計 大型車 比例	合計 小型車(輛)	合計 小型車 比例	合計 機車(輛)	合計 機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	1	75	104	125	0.25	-	4	200	292	330	0.65	1	36	25	53	0.10	6	0.01	311	0.42	421	0.57	738	508		
	17:00-18:00	1	66	117	122	0.23	-	2	174	424	356	0.67	-	36	32	53	0.10	3	0.00	276	0.32	573	0.67	852	531		
	18:00-19:00	3	48	139	116	0.23	-	5	169	393	343	0.67	-	31	34	49	0.10	8	0.01	248	0.30	566	0.69	822	508		
B	16:00-17:00	-	-	-	-	-	51	7	761	324	910	0.85	2	94	109	156	0.15	9	0.01	855	0.66	433	0.33	1297	1066		
	17:00-18:00	-	-	-	-	-	51	6	622	396	799	0.81	2	107	142	185	0.19	8	0.01	729	0.57	538	0.42	1275	984		
	18:00-19:00	-	1	-	1	-	70	4	639	338	788	0.82	3	95	132	170	0.18	7	0.01	735	0.61	470	0.39	1212	959		
C	16:00-17:00	1	95	43	120	0.18	-	4	265	274	387	0.58	-	136	37	164	0.24	5	0.01	496	0.58	354	0.41	855	671		
	17:00-18:00	-	79	50	104	0.14	-	3	301	316	439	0.61	-	155	38	185	0.25	3	0.00	535	0.57	404	0.43	942	728		
	18:00-19:00	1	82	67	117	0.16	-	5	277	390	450	0.60	1	140	52	177	0.24	7	0.01	499	0.49	509	0.50	1015	744		
D	16:00-17:00	-	31	-	33	0.03	26	6	865	408	1047	0.86	-	98	64	135	0.11	6	0.00	994	0.68	472	0.32	1472	1215		
	17:00-18:00	-	39	2	42	0.03	32	7	864	527	1098	0.85	-	115	75	158	0.12	7	0.00	1018	0.62	604	0.37	1629	1298		
	18:00-19:00	-	25	1	27	0.03	40	8	675	469	886	0.86	-	83	58	116	0.11	8	0.01	783	0.59	528	0.40	1319	1029		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	16:00-17:00	2	201	147	278	0.08	77	21	2091	1298	2674	0.77	3	364	235	508	0.15	26	0.01	2656	0.61	1680	0.39	4362	3460		
	17:00-18:00	1	184	169	268	0.08	83	18	1961	1663	2692	0.76	2	413	287	581	0.16	21	0.00	2558	0.54	2119	0.45	4698	3541		
	18:00-19:00	4	156	207	261	0.08	110	22	1760	1590	2467	0.76	4	349	276	512	0.16	30	0.01	2265	0.52	2073	0.47	4368	3240		
A	16:45-17:45	2	67	108	121	0.22	-	2	178	405	352	0.66	1	42	39	66	0.12	5	0.01	287	0.34	552	0.65	844	539	0.94	0.98
B		-	-	-	-	-	49	7	672	388	848	0.82	3	103	143	184	0.18	10	0.01	775	0.59	531	0.40	1316	1032	0.88	
C		-	88	46	112	0.16	-	3	281	323	422	0.59	-	149	42	180	0.25	3	0.00	518	0.56	411	0.44	932	714	0.92	
D		-	33	1	35	0.03	32	6	873	528	1106	0.85	-	113	81	158	0.12	6	0.00	1019	0.62	610	0.37	1635	1299	0.96	

X4：中山北六段/德行西路(6/22)假日轉向交通量示意圖

站　號：　X4
站　名：　中山北六段/德行西路

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　16:45-17:45



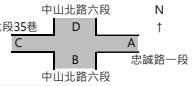
(單位:輛)
( )為機車二段式左轉車輛數

方　向：	A	B	C	D
總車道數：	1	3	2	3

X5：中山北六段/忠誠路一段(6/20)平日交通量

站　號：　X5
站　名：　中山北六段/忠誠路一段
時相數：　3

日　期：　2024/06/20 (四)
天　候：　晴
方　向：　A　B　C　D
車道數：　4　3　-　2



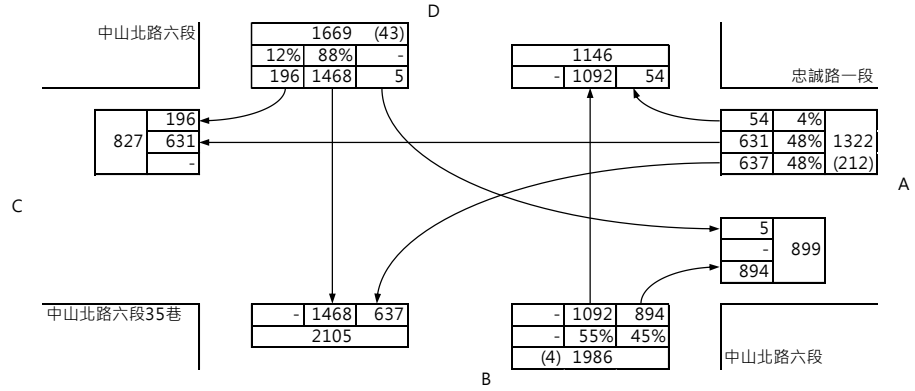
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	合計 大型車 比例	合計 小型車(輛)	合計 小型車 比例	合計 機車(輛)	合計 機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	06:30-07:30	19	405	6	466	0.55	97	11	250	228	366	0.42	-	23	12	30	0.03	30	0.03	678	0.71	246	0.26	954	862		
	07:30-08:30	26	555	6	637	0.48	212	15	432	410	631	0.48	-	39	26	54	0.04	41	0.03	1026	0.68	442	0.29	1509	1322		
	08:30-09:30	18	442	7	503	0.48	163	17	335	266	477	0.45	1	56	23	74	0.07	36	0.03	833	0.72	296	0.25	1165	1054		
	12:00-13:00	24	378	6	447	0.49	133	17	260	262	401	0.43	-	51	49	77	0.08	41	0.04	689	0.66	317	0.30	1047	925		
	13:00-14:00	21	393	4	456	0.50	84	14	281	171	378	0.41	-	61	43	85	0.09	35	0.04	735	0.74	218	0.22	988	919		
	14:00-15:00	22	440	10	510	0.51	121	11	277	200	381	0.38	-	79	52	109	0.11	33	0.03	796	0.73	262	0.24	1091	1000		
	16:00-17:00	32	421	18	514	0.46	218	14	349	383	535	0.47	-	52	39	74	0.07	46	0.04	822	0.63	440	0.34	1308	1123		
	17:00-18:00	20	404	9	468	0.44	282	9	307	486	527	0.49	-	51	47	76	0.07	29	0.02	762	0.57	542	0.41	1333	1071		
	18:00-19:00	22	291	10	354	0.41	232	14	240	425	444	0.51	1	47	46	74	0.08	37	0.03	578	0.53	481	0.44	1096	872		
B	06:30-07:30	-	-	-	-	-	2	16	411	365	593	0.52	26	370	196	558	0.48	42	0.03	781	0.56	561	0.41	1384	1151		
	07:30-08:30	-	-	-	-	-	4	11	768	724	1092	0.55	35	580	384	894	0.45	46	0.02	1348	0.54	1108	0.44	2502	1986		
	08:30-09:30	-	-	-	-	-	2	16	777	649	1078	0.56	25	597	315	854	0.44	41	0.02	1374	0.58	964	0.41	2379	1932		
	12:00-13:00	-	2	-	2	-	-	19	695	424	907	0.54	30	575	178	782	0.46	49	0.03	1272	0.66	602	0.31	1923	1691		
	13:00-14:00	-	-	-	-	-	1	12	782	429	984	0.55	32	579	186	795	0.45	44	0.02	1361	0.67	615	0.30	2020	1779		
	14:00-15:00	-	1	1	1	-	3	14	824	390	1013	0.55	37	597	211	840	0.45	51	0.02	1422	0.69	602	0.29	2075	1854		
	16:00-17:00	-	-	-	-	-	-	15	795	453	1012	0.52	29	677	256	925	0.48	44	0.02	1472	0.66	709	0.32	2225	1937		
	17:00-18:00	-	-	-	-	-	1	16	798	646	1098	0.52	31	700	347	996	0.48	47	0.02	1498	0.59	993	0.39	2538	2094		
	18:00-19:00	-	-	-	-	-	-	20	774	857	1170	0.53	33	710	383	1028	0.47	53	0.02	1484	0.53	1240	0.45	2777	2198		
C	06:30-07:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	08:30-09:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	12:00-13:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	13:00-14:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	14:00-15:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
D	06:30-07:30	1	2	-	4	-	11	20	638	592	923	0.87	3	99	48	137	0.13	24	0.02	739	0.53	640	0.46	1403	1064		
	07:30-08:30	2	1	-	5	-	43	15	896	1298	1468	0.88	3	139	84	196	0.12	20	0.01	1036	0.42	1382	0.57	2438	1669		
	08:30-09:30	4	10	-	19	0.01	24	17	942	869	1338	0.86	1	158	73	206	0.13	22	0.01	1110	0.54	942	0.45	2074	1563		
	12:00-13:00	2	32	1	38	0.03	36	12	803	609	1080	0.80	2	165	83	221	0.17	16	0.01	1000	0.59	693	0.41	1709	1339		
	13:00-14:00	1	29	1	33	0.02	33	13	799	564	1059	0.80	1	183	75	234	0.18	15	0.01	1011	0.61	640	0.38	1666	1326		
	14:00-15:00	1	31	1	35	0.03	29	13	825	563	1085	0.79	1	187	77	239	0.18	15	0.01	1043	0.61	641	0.38	1699	1359		
	16:00-17:00	1	-	-	2	-	35	14	785	776	1136	0.82	1	181	106	246	0.18	16	0.01	966	0.52	882	0.47	1864	1384		
	17:00-18:00	2	-	-	4	-	43	13	734	1071	1207	0.85	1	137	138	213	0.15	16	0.01	871	0.42	1209	0.58	2096	1424		
	18:00-19:00	3	-	-	6	0.01	44	15	575	851	959	0.82	-	124	134	194	0.17	18	0.01	699	0.41	985	0.58	1702	1159		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	06:30-07:30	20	407	6	470	0.15	110	47	1299	1185	1882	0.61	29	492	256	725	0.24	96	0.03	2198	0.59	1447	0.39	3741	3077		
	07:30-08:30	28	556	6	642	0.13	259	41	2096	2432	3191	0.64	38	758	494	1144	0.23	107	0.02	3410	0.53	2932	0.45	6449	4977		
	08:30-09:30	22	452	7	522	0.11	189	50	2054	1784	2893	0.64	27	811	411	1134	0.25	99	0.02	3317	0.59	2202	0.39	5618	4549		
	12:00-13:00	26	412	7	487	0.12	169	48	1758	1295	2388	0.60	32	791	310	1080	0.27	106	0.02	2961	0.63	1612	0.34	4679	3955		
	13:00-14:00	22	422	5	489	0.12	118	39	1862	1164	2421	0.60	33	823	304	1114	0.28	94	0.02	3107	0.66	1473	0.32	4674	4024		
	14:00-15:00	23	472	12	546	0.13	153	38	1926	1153	2479	0.59	38	863	340	1188	0.28	99	0.02	3261	0.67	1505	0.31	4865	4213		
	16:00-17:00	33	421	18	516	0.12	253	43	1929	1612	2683	0.60	30	910	401	1245	0.28	106	0.02	3260	0.60	2031	0.38	5397	4444		
	17:00-18:00	22	404	9	472	0.10	326	38	1839	2203	2832	0.62	32	888	532	1285	0.28	92	0.02	3131	0.52	2744	0.46	5967	4589		
	18:00-19:00	25	291	10	360	0.09	276	49	1589	2133	2573	0.61	34	881	563	1296	0.31	108	0.02	2761	0.50	2706	0.49	5575	4229		
A	07:30-08:30	26	555	6	637	0.48	212	15	432	410	631	0.48	-	39	26	54	0.04	41	0.03	1026	0.68	442	0.29	1509	1322	0.86	0.93
B		-	-	-	-	-	4	11	768	724	1092	0.55	35	580	384	894	0.45	46	0.02	1348	0.54	1108	0.44	2502	1986	0.96	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		2	1	-	5	-	43	15	896	1298	1468	0.88	3	139	84	196	0.12	20	0.01	1036	0.42	1382	0.57	2438	1669	0.94	
A	13:45-14:45	23	447	6	518	0.50	107	12	299	197	403	0.40	-	69	50	97	0.10	35	0.03	815	0.74	253	0.23	1103	1018	0.84	0.95
B		-	1	1	1	-	2	10	814	411	1005	0.54	35	611	200	844	0.46	45	0.02	1426	0.68	612	0.29	2083	1850	0.90	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		2	33	-	39	0.03	25	15	820	559	1082	0.79	2	197	78	253	0.18	19	0.01	1050	0.62	637	0.37	1706	1374	0.91	
A	16:45-17:45	25	420	15	497	0.44	285	9	319	499	545	0.49	-	55	51	82	0.07	34	0.02	794	0.57	565	0.41	1393	1124	0.86	0.97
B		-	-	-	-	-	1	14	792	565	1055	0.52	30	689	309	964	0.48	44	0.02	1481	0.62	874	0.36	2399	2019	0.97	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		1	-	-	2	-	40	14	756	1076	1233	0.84	1	158	141	237	0.16	16	0.01	914	0.43	1217	0.57	2147	1472	0.94	

X5：中山北六段/忠誠路一段(6/20)平日轉向交通量示意圖

站　號：　X5
站　名：　中山北六段/忠誠路一段

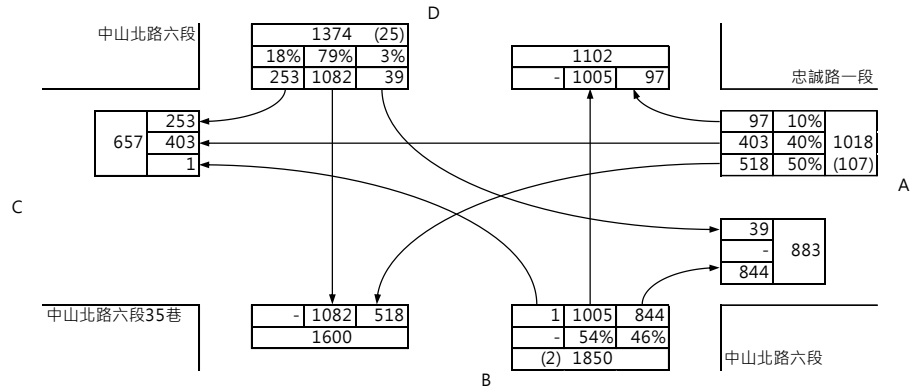
單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

上午尖峰：　07:30-08:30



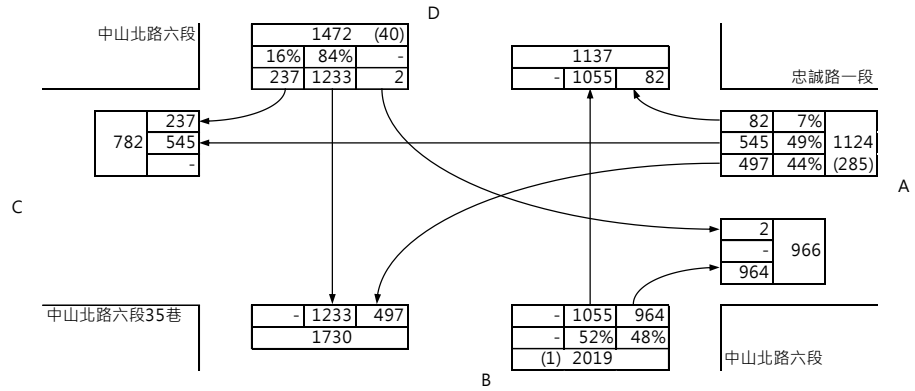
(單位:輛)
( )為機車二段式左轉車輛數

離峰：　13:45-14:45



(單位:輛)
( )為機車二段式左轉車輛數

下午尖峰：　16:45-17:45



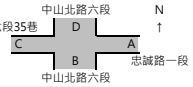
(單位:輛)
( )為機車二段式左轉車輛數

方　向：	A	B	C	D
總車道數：	4	3	-	2

X5：中山北六段/忠誠路一段(6/22)假日交通量

站　號：　X5
站　名：　中山北六段/忠誠路一段
時相數：　3

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　4　3　-　2



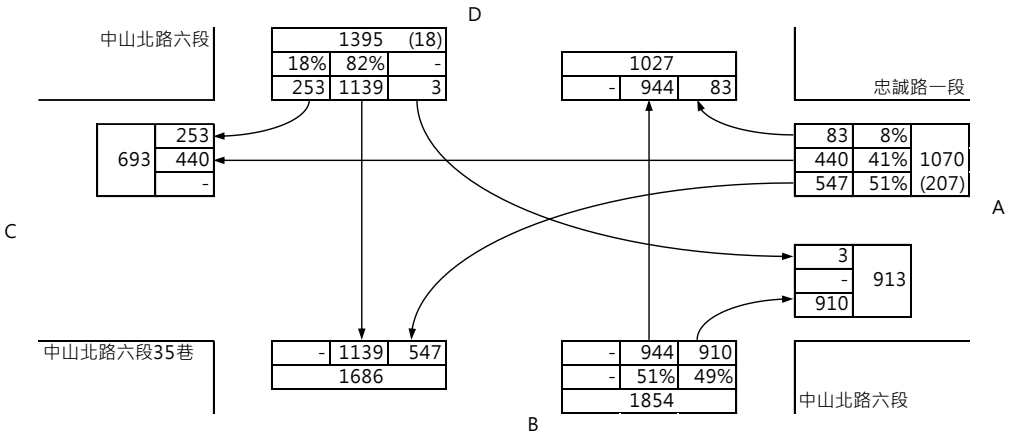
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	轉向比	合計 大型車(輛)	合計 大型車比例	合計 小型車(輛)	合計 小型車比例	合計 機車(輛)	合計 機車比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	11	420	20	472	0.47	163	6	323	259	443	0.45	-	64	25	80	0.08	17	0.02	807	0.72	304	0.27	1128	995		
	17:00-18:00	17	455	10	516	0.50	193	9	282	315	431	0.42	-	61	36	82	0.08	26	0.02	798	0.67	361	0.30	1185	1029		
	18:00-19:00	11	351	14	397	0.49	172	7	206	283	337	0.41	1	58	32	80	0.10	19	0.02	615	0.64	329	0.34	963	814		
B	16:00-17:00	-	-	-	-	-	-	9	780	391	960	0.54	18	646	135	807	0.46	27	0.01	1426	0.72	526	0.27	1979	1767		
	17:00-18:00	-	-	-	-	-	-	8	678	482	895	0.50	16	714	189	899	0.50	24	0.01	1392	0.67	671	0.32	2087	1794		
	18:00-19:00	-	-	-	-	-	1	6	695	421	883	0.52	21	612	181	799	0.48	27	0.01	1307	0.68	602	0.31	1936	1682		
C	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
D	16:00-17:00	1	3	-	5	-	15	8	813	577	1070	0.83	1	164	91	221	0.17	10	0.01	980	0.59	668	0.40	1658	1296		
	17:00-18:00	2	1	-	5	-	22	10	801	708	1116	0.81	-	195	126	267	0.19	12	0.01	997	0.54	834	0.45	1843	1388		
	18:00-19:00	3	1	-	7	0.01	25	11	647	671	949	0.78	-	184	109	248	0.21	14	0.01	832	0.51	780	0.48	1626	1204		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	16:00-17:00	12	423	20	477	0.12	178	23	1916	1227	2473	0.61	19	874	251	1108	0.27	54	0.01	3213	0.67	1498	0.31	4765	4058		
	17:00-18:00	19	456	10	521	0.12	215	27	1761	1505	2442	0.58	16	970	351	1248	0.30	62	0.01	3187	0.62	1866	0.36	5115	4211		
	18:00-19:00	14	352	14	404	0.11	198	24	1548	1375	2169	0.59	22	854	322	1127	0.30	60	0.01	2754	0.61	1711	0.38	4525	3700		
A	16:45-17:45	17	485	9	547	0.51	207	8	290	323	440	0.41	-	63	33	83	0.08	25	0.02	838	0.68	365	0.30	1228	1070	0.87	0.97
B		-	-	-	-	-	-	10	722	486	944	0.51	16	728	180	910	0.49	26	0.01	1450	0.68	666	0.31	2142	1854	0.93	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		1	1	-	3	-	18	10	825	705	1139	0.82	-	181	128	253	0.18	11	0.01	1007	0.54	833	0.45	1851	1395	0.96	

X5：中山北六段/忠誠路一段(6/22)假日轉向交通量示意圖

站　號：　X5
站　名：　中山北六段/忠誠路一段

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　16:45-17:45



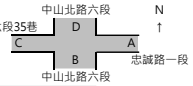
(單位:輛)
( )為機車二段式左轉車輛數

方向：	A	B	C	D
總車道數：	4	3	-	2

X6：磺溪街/克強路(6/20)平日交通量

站　號：　X5
站　名：　中山北六段/忠誠路一段
時相數：　3

日　期：　2024/06/20 (四)
天　候：　晴
方　向：　A　B　C　D
車道數：　4　3　-　2



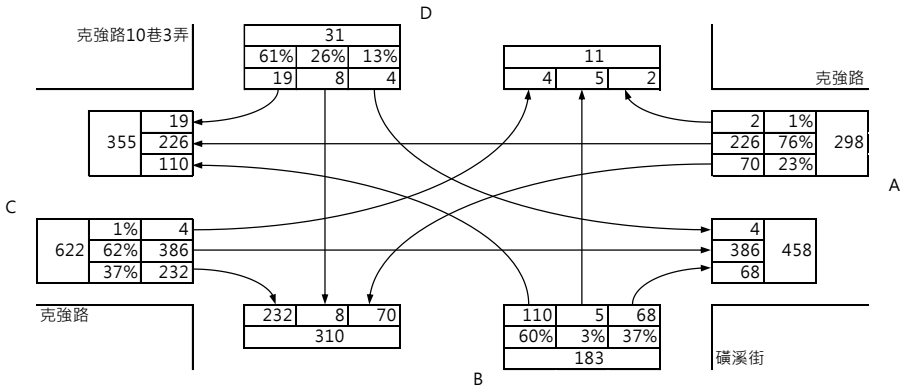
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	大型車 比例	合計 小型車(輛)	小型車 比例	合計 機車(輛)	機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	06:30-07:30	19	405	6	466	0.55	97	11	250	228	366	0.42	-	23	12	30	0.03	30	0.03	678	0.71	246	0.26	954	862		
	07:30-08:30	26	555	6	637	0.48	212	15	432	410	631	0.48	-	39	26	54	0.04	41	0.03	1026	0.68	442	0.29	1509	1322		
	08:30-09:30	18	442	7	503	0.48	163	17	335	266	477	0.45	1	56	23	74	0.07	36	0.03	833	0.72	296	0.25	1165	1054		
	12:00-13:00	24	378	6	447	0.49	133	17	260	262	401	0.43	-	51	49	77	0.08	41	0.04	689	0.66	317	0.30	1047	925		
	13:00-14:00	21	393	4	456	0.50	84	14	281	171	378	0.41	-	61	43	85	0.09	35	0.04	735	0.74	218	0.22	988	919		
	14:00-15:00	22	440	10	510	0.51	121	11	277	200	381	0.38	-	79	52	109	0.11	33	0.03	796	0.73	262	0.24	1091	1000		
	16:00-17:00	32	421	18	514	0.46	218	14	349	383	535	0.47	-	52	39	74	0.07	46	0.04	822	0.63	440	0.34	1308	1123		
	17:00-18:00	20	404	9	468	0.44	282	9	307	486	527	0.49	-	51	47	76	0.07	29	0.02	762	0.57	542	0.41	1333	1071		
	18:00-19:00	22	291	10	354	0.41	232	14	240	425	444	0.51	1	47	46	74	0.08	37	0.03	578	0.53	481	0.44	1096	872		
B	06:30-07:30	-	-	-	-	-	2	16	411	365	593	0.52	26	370	196	558	0.48	42	0.03	781	0.56	561	0.41	1384	1151		
	07:30-08:30	-	-	-	-	-	4	11	768	724	1092	0.55	35	580	384	894	0.45	46	0.02	1348	0.54	1108	0.44	2502	1986		
	08:30-09:30	-	-	-	-	-	2	16	777	649	1078	0.56	25	597	315	854	0.44	41	0.02	1374	0.58	964	0.41	2379	1932		
	12:00-13:00	-	2	-	2	-	-	19	695	424	907	0.54	30	575	178	782	0.46	49	0.03	1272	0.66	602	0.31	1923	1691		
	13:00-14:00	-	-	-	-	-	1	12	782	429	984	0.55	32	579	186	795	0.45	44	0.02	1361	0.67	615	0.30	2020	1779		
	14:00-15:00	-	1	1	1	-	3	14	824	390	1013	0.55	37	597	211	840	0.45	51	0.02	1422	0.69	602	0.29	2075	1854		
	16:00-17:00	-	-	-	-	-	-	15	795	453	1012	0.52	29	677	256	925	0.48	44	0.02	1472	0.66	709	0.32	2225	1937		
	17:00-18:00	-	-	-	-	-	1	16	798	646	1098	0.52	31	700	347	996	0.48	47	0.02	1498	0.59	993	0.39	2538	2094		
	18:00-19:00	-	-	-	-	-	-	20	774	857	1170	0.53	33	710	383	1028	0.47	53	0.02	1484	0.53	1240	0.45	2777	2198		
C	06:30-07:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	08:30-09:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	12:00-13:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	13:00-14:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	14:00-15:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
D	06:30-07:30	1	2	-	4	-	11	20	638	592	923	0.87	3	99	48	137	0.13	24	0.02	739	0.53	640	0.46	1403	1064		
	07:30-08:30	2	1	-	5	-	43	15	896	1298	1468	0.88	3	139	84	196	0.12	20	0.01	1036	0.42	1382	0.57	2438	1669		
	08:30-09:30	4	10	-	19	0.01	24	17	942	869	1338	0.86	1	158	73	206	0.13	22	0.01	1110	0.54	942	0.45	2074	1563		
	12:00-13:00	2	32	1	38	0.03	36	12	803	609	1080	0.80	2	165	83	221	0.17	16	0.01	1000	0.59	693	0.41	1709	1339		
	13:00-14:00	1	29	1	33	0.02	33	13	799	564	1059	0.80	1	183	75	234	0.18	15	0.01	1011	0.61	640	0.38	1666	1326		
	14:00-15:00	1	31	1	35	0.03	29	13	825	563	1085	0.79	1	187	77	239	0.18	15	0.01	1043	0.61	641	0.38	1699	1359		
	16:00-17:00	1	-	-	2	-	35	14	785	776	1136	0.82	1	181	106	246	0.18	16	0.01	966	0.52	882	0.47	1864	1384		
	17:00-18:00	2	-	-	4	-	43	13	734	1071	1207	0.85	1	137	138	213	0.15	16	0.01	871	0.42	1209	0.58	2096	1424		
	18:00-19:00	3	-	-	6	0.01	44	15	575	851	959	0.82	-	124	134	194	0.17	18	0.01	699	0.41	985	0.58	1702	1159		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	06:30-07:30	20	407	6	470	0.15	110	47	1299	1185	1882	0.61	29	492	256	725	0.24	96	0.03	2198	0.59	1447	0.39	3741	3077		
	07:30-08:30	28	556	6	642	0.13	259	41	2096	2432	3191	0.64	38	758	494	1144	0.23	107	0.02	3410	0.53	2932	0.45	6449	4977		
	08:30-09:30	22	452	7	522	0.11	189	50	2054	1784	2893	0.64	27	811	411	1134	0.25	99	0.02	3317	0.59	2202	0.39	5618	4549		
	12:00-13:00	26	412	7	487	0.12	169	48	1758	1295	2388	0.60	32	791	310	1080	0.27	106	0.02	2961	0.63	1612	0.34	4679	3955		
	13:00-14:00	22	422	5	489	0.12	118	39	1862	1164	2421	0.60	33	823	304	1114	0.28	94	0.02	3107	0.66	1473	0.32	4674	4024		
	14:00-15:00	23	472	12	546	0.13	153	38	1926	1153	2479	0.59	38	863	340	1188	0.28	99	0.02	3261	0.67	1505	0.31	4865	4213		
	16:00-17:00	33	421	18	516	0.12	253	43	1929	1612	2683	0.60	30	910	401	1245	0.28	106	0.02	3260	0.60	2031	0.38	5397	4444		
	17:00-18:00	22	404	9	472	0.10	326	38	1839	2203	2832	0.62	32	888	532	1285	0.28	92	0.02	3131	0.52	2744	0.46	5967	4589		
	18:00-19:00	25	291	10	360	0.09	276	49	1589	2133	2573	0.61	34	881	563	1296	0.31	108	0.02	2761	0.50	2706	0.49	5575	4229		
A	07:30-08:30	26	555	6	637	0.48	212	15	432	410	631	0.48	-	39	26	54	0.04	41	0.03	1026	0.68	442	0.29	1509	1322	0.86	0.93
B		-	-	-	-	-	4	11	768	724	1092	0.55	35	580	384	894	0.45	46	0.02	1348	0.54	1108	0.44	2502	1986	0.96	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		2	1	-	5	-	43	15	896	1298	1468	0.88	3	139	84	196	0.12	20	0.01	1036	0.42	1382	0.57	2438	1669	0.94	
A	13:45-14:45	23	447	6	518	0.50	107	12	299	197	403	0.40	-	69	50	97	0.10	35	0.03	815	0.74	253	0.23	1103	1018	0.84	0.95
B		-	1	1	1	-	2	10	814	411	1005	0.54	35	611	200	844	0.46	45	0.02	1426	0.68	612	0.29	2083	1850	0.90	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		2	33	-	39	0.03	25	15	820	559	1082	0.79	2	197	78	253	0.18	19	0.01	1050	0.62	637	0.37	1706	1374	0.91	
A	16:45-17:45	25	420	15	497	0.44	285	9	319	499	545	0.49	-	55	51	82	0.07	34	0.02	794	0.57	565	0.41	1393	1124	0.86	0.97
B		-	-	-	-	-	1	14	792	565	1055	0.52	30	689	309	964	0.48	44	0.02	1481	0.62	874	0.36	2399	2019	0.97	
C		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
D		1	-	-	2	-	40	14	756	1076	1233	0.84	1	158	141	237	0.16	16	0.01	914	0.43	1217	0.57	2147	1472	0.94	

X6：磺溪街/克強路(6/20)平日轉向交通量示意圖

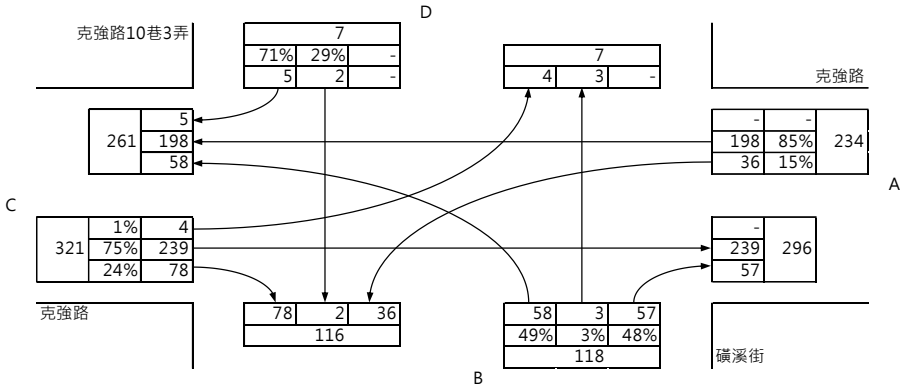
站　號：　X6
站　名：　礁溪街/克強路

單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

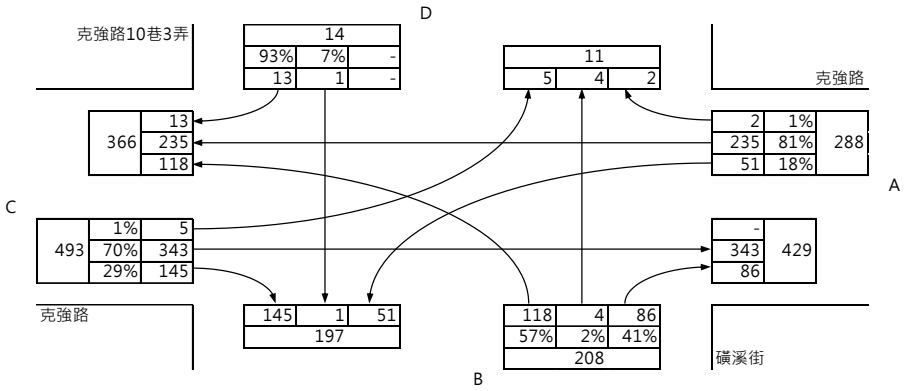
上午尖峰：　07:30-08:30



離峰：　13:45-14:45



下午尖峰：　17:30-18:30



方　向：	A	B	C	D
總車道數：	1	1	2	1

X6：磺溪街/克強路(6/22)假日交通量

站　號：　X6
站　名：　磺溪街/克強路
時相數：　4

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　1　1　2　1

克強路10巷3弄　N
克強路　D　↑
C　A
B
克強路
磺溪街

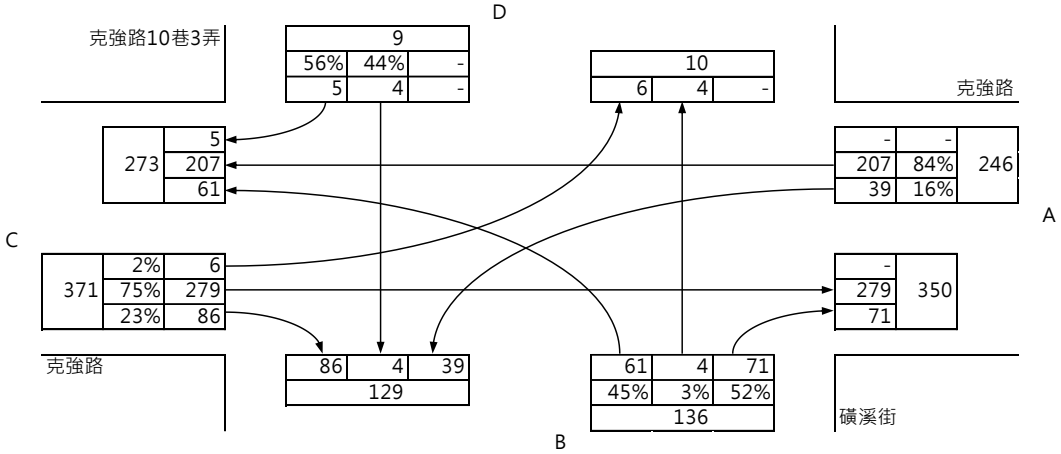
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	合計 大型車 比例	合計 小型車(輛)	合計 小型車 比例	合計 機車(輛)	合計 機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	2	28	24	44	0.20	-	121	132	176	0.80	-	-	1	-	-	2	0.01	149	0.48	157	0.51	308	220		
	17:00-18:00	2	24	23	39	0.16	-	127	190	207	0.84	-	-	1	-	-	2	0.01	151	0.41	214	0.58	367	246		
	18:00-19:00	1	23	19	34	0.17	-	101	156	167	0.83	-	-	-	-	-	1	0.00	124	0.41	175	0.58	300	201		
B	16:00-17:00	-	37	53	62	0.51	-	-	1	-	-	1	48	10	59	0.49	1	0.01	85	0.57	64	0.43	150	121		
	17:00-18:00	-	34	58	61	0.45	-	-	9	4	0.03	2	52	20	71	0.52	2	0.01	86	0.49	87	0.50	175	136		
	18:00-19:00	-	38	81	75	0.47	-	-	8	3	0.02	3	57	27	82	0.51	3	0.01	95	0.44	116	0.54	214	160		
C	16:00-17:00	-	1	3	2	0.01	-	192	139	250	0.76	-	52	47	77	0.23	-	-	245	0.56	189	0.44	434	329		
	17:00-18:00	-	1	12	6	0.02	-	183	229	279	0.75	-	50	72	86	0.23	-	-	234	0.43	313	0.57	547	371		
	18:00-19:00	-	-	5	2	0.01	-	129	224	223	0.73	-	48	60	79	0.26	-	-	177	0.38	289	0.62	466	304		
D	16:00-17:00	-	1	-	1	0.14	-	-	2	1	0.14	-	-	11	5	0.72	-	-	1	0.07	13	0.93	14	7		
	17:00-18:00	-	-	-	-	-	-	1	6	4	0.44	-	-	12	5	0.56	-	-	1	0.05	18	0.95	19	9		
	18:00-19:00	-	-	2	1	0.13	-	-	6	3	0.38	-	-	9	4	0.49	-	-	-	-	17	1.00	17	8		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**											
合計	16:00-17:00	2	67	80	109	0.16	-	313	274	427	0.63	1	100	69	141	0.21	3	0.00	480	0.53	423	0.47	906	677		
	17:00-18:00	2	59	93	106	0.14	-	311	434	494	0.65	2	102	105	162	0.21	4	0.00	472	0.43	632	0.57	1108	762		
	18:00-19:00	1	61	107	112	0.17	-	230	394	396	0.59	3	105	96	165	0.25	4	0.00	396	0.40	597	0.60	997	673		
A	17:00-18:00	2	24	23	39	0.16	-	127	190	207	0.84	-	-	1	-	-	2	0.01	151	0.41	214	0.58	367	246	0.86	0.93
B		-	34	58	61	0.45	-	-	9	4	0.03	2	52	20	71	0.52	2	0.01	86	0.49	87	0.50	175	136	0.97	
C		-	1	12	6	0.02	-	183	229	279	0.75	-	50	72	86	0.23	-	-	234	0.43	313	0.57	547	371	0.88	
D		-	-	-	-	-	-	1	6	4	0.44	-	-	12	5	0.56	-	-	1	0.05	18	0.95	19	9	0.45	

X6：磺溪街/克強路(6/22)假日轉向交通量示意圖

站　號：　X6
站　名：　礁溪街/克強路

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　17:00-18:00

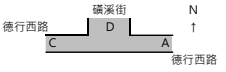


方向：	A	B	C	D
總車道數：	1	1	2	1

X7：磺溪街/德行西路(6/20)平日交通量

站　號：　X7
站　名：　磺溪街/德行西路
時相數：　4

日　期：　2024/06/20 (四)
天　候：　晴
方　向：　A　B　C　D
車道數：　2　-　2　1



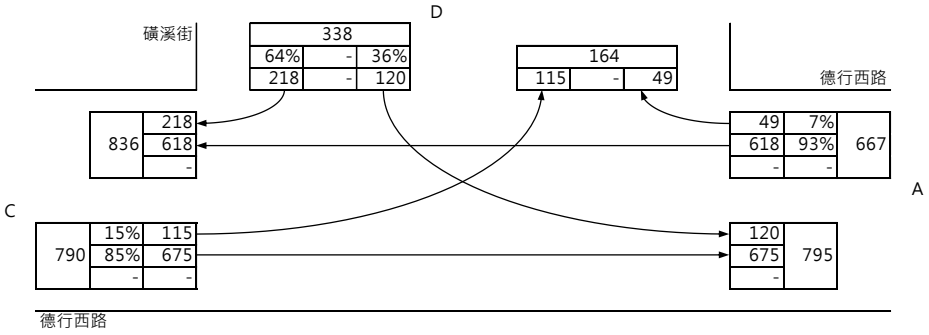
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	左轉 轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	直進 轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	右轉 轉向比	合計 大型車(輛)	大型車 比例	小型車(輛)	小型車 比例	機車(輛)	機車 比例	總和(輛)	PCU	PHF	總流量 PHF
A	06:30-07:30	-	-	-	-	-	-	6	188	237	298	0.96	-	6	17	14	0.04	6	0.01	194	0.43	254	0.56	454	312		
	07:30-08:30	-	-	-	-	-	-	7	390	513	618	0.93	1	30	30	49	0.07	8	0.01	420	0.43	543	0.56	971	667		
	08:30-09:30	-	-	-	-	-	-	9	344	430	541	0.89	-	39	49	64	0.11	9	0.01	383	0.44	479	0.55	871	605		
	12:00-13:00	-	-	-	-	-	-	10	281	362	451	0.90	-	24	50	48	0.10	10	0.01	305	0.42	412	0.57	727	499		
	13:00-14:00	-	-	-	-	-	-	9	293	352	457	0.92	-	26	28	41	0.08	9	0.01	319	0.45	380	0.54	708	498		
	14:00-15:00	-	-	-	-	-	-	11	320	361	491	0.91	-	31	34	49	0.09	11	0.01	351	0.46	395	0.52	757	540		
	16:00-17:00	-	-	-	-	-	-	12	327	451	538	0.91	-	30	39	50	0.09	12	0.01	357	0.42	490	0.57	859	588		
	17:00-18:00	-	-	-	-	-	-	11	335	714	655	0.93	-	25	47	48	0.07	11	0.01	360	0.32	761	0.67	1132	703		
	18:00-19:00	-	-	-	-	-	-	7	280	745	606	0.91	-	25	72	59	0.09	7	0.01	305	0.27	817	0.72	1129	665		
B	06:30-07:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	07:30-08:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	08:30-09:30	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	12:00-13:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	13:00-14:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	14:00-15:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
C	06:30-07:30	1	16	13	24	0.05	-	12	273	298	420	0.95	-	-	-	-	-	13	0.02	289	0.47	311	0.51	613	444		
	07:30-08:30	2	70	87	115	0.15	-	13	400	600	675	0.85	-	-	-	-	-	15	0.01	470	0.40	687	0.59	1172	790		
	08:30-09:30	2	47	86	90	0.13	-	21	401	412	612	0.87	-	-	-	-	-	23	0.02	448	0.46	498	0.51	969	702		
	12:00-13:00	3	41	50	71	0.11	-	18	392	321	559	0.89	-	-	-	-	-	21	0.03	433	0.52	371	0.45	825	630		
	13:00-14:00	2	43	42	67	0.12	-	14	342	324	503	0.88	-	-	-	-	-	16	0.02	385	0.50	366	0.48	767	570		
	14:00-15:00	3	41	30	62	0.12	-	11	335	271	469	0.88	-	-	-	-	-	14	0.02	376	0.54	301	0.44	691	531		
	16:00-17:00	3	46	53	77	0.13	-	10	377	318	529	0.87	-	-	-	-	-	13	0.02	423	0.52	371	0.46	807	606		
	17:00-18:00	-	44	52	69	0.09	-	14	451	475	676	0.91	-	-	-	-	-	14	0.01	495	0.48	527	0.51	1036	745		
	18:00-19:00	5	52	89	103	0.12	-	14	471	575	738	0.88	-	-	-	-	-	19	0.02	523	0.43	664	0.55	1206	841		
D	06:30-07:30	3	41	10	53	0.37	-	-	-	-	-	-	2	60	45	90	0.63	5	0.03	101	0.63	55	0.34	161	143		
	07:30-08:30	1	95	43	120	0.36	-	-	-	-	-	-	2	133	154	218	0.64	3	0.01	228	0.53	197	0.46	428	338		
	08:30-09:30	-	50	31	66	0.33	-	-	-	-	-	-	7	79	71	136	0.67	7	0.03	129	0.54	102	0.43	238	202		
	12:00-13:00	2	54	45	80	0.37	-	-	-	-	-	-	-	83	110	139	0.63	2	0.01	137	0.47	155	0.53	294	219		
	13:00-14:00	-	60	46	83	0.41	-	-	-	-	-	-	3	67	85	119	0.59	3	0.01	127	0.49	131	0.50	261	202		
	14:00-15:00	-	39	53	64	0.37	-	-	-	-	-	-	2	68	69	110	0.63	2	0.01	107	0.46	122	0.53	231	174		
	16:00-17:00	-	60	66	91	0.32	-	-	-	-	-	-	2	123	125	194	0.68	2	0.01	183	0.49	191	0.51	376	285		
	17:00-18:00	-	69	55	96	0.34	-	-	-	-	-	-	2	111	130	184	0.66	2	0.01	180	0.49	185	0.50	367	280		
	18:00-19:00	3	38	64	73	0.28	-	-	-	-	-	-	4	100	152	187	0.72	7	0.02	138	0.38	216	0.60	361	260		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	06:30-07:30	4	57	23	77	0.09	-	18	461	535	718	0.80	2	66	62	104	0.12	24	0.02	584	0.48	620	0.50	1228	899		
	07:30-08:30	3	165	130	235	0.13	-	20	790	1113	1293	0.72	3	163	184	267	0.15	26	0.01	1118	0.43	1427	0.56	2571	1795		
	08:30-09:30	2	97	117	156	0.10	-	30	745	842	1153	0.76	7	118	120	200	0.13	39	0.02	960	0.46	1079	0.52	2078	1509		
	12:00-13:00	5	95	95	151	0.11	-	28	673	683	1010	0.75	-	107	160	187	0.14	33	0.02	875	0.47	938	0.51	1846	1348		
	13:00-14:00	2	103	88	150	0.12	-	23	635	676	960	0.76	3	93	113	160	0.13	28	0.02	831	0.48	877	0.51	1736	1270		
	14:00-15:00	3	80	83	126	0.10	-	22	655	632	960	0.77	2	99	103	159	0.13	27	0.02	834	0.50	818	0.49	1679	1245		
	16:00-17:00	3	106	119	168	0.11	-	22	704	769	1067	0.72	2	153	164	244	0.16	27	0.01	963	0.47	1052	0.52	2042	1479		
	17:00-18:00	-	113	107	165	0.10	-	25	786	1189	1331	0.77	2	136	177	232	0.13	27	0.01	1035	0.41	1473	0.58	2535	1728		
	18:00-19:00	8	90	153	176	0.10	-	21	751	1320	1344	0.76	4	125	224	246	0.14	33	0.01	966	0.36	1697	0.63	2696	1766		
A	07:30-08:30	-	-	-	-	-	-	7	390	513	618	0.93	1	30	30	49	0.07	8	0.01	420	0.43	543	0.56	971	667	0.96	0.91
B		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
C		2	70	87	115	0.15	-	13	400	600	675	0.85	-	-	-	-	-	15	0.01	470	0.40	687	0.59	1172	790	0.84	
D		1	95	43	120	0.36	-	-	-	-	-	-	2	133	154	218	0.64	3	0.01	228	0.53	197	0.46	428	338	0.95	
A	13:00-14:00	-	-	-	-	-	-	9	293	352	457	0.92	-	26	28	41	0.08	9	0.01	319	0.45	380	0.54	708	498	0.95	0.97
B		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
C		2	43	42	67	0.12	-	14	342	324	503	0.88	-	-	-	-	-	16	0.02	385	0.50	366	0.48	767	570	0.93	
D		-	60	46	83	0.41	-	-	-	-	-	-	3	67	85	119	0.59	3	0.01	127	0.49	131	0.50	261	202	0.82	
A	17:30-18:30	-	-	-	-	-	-	6	297	736	617	0.91	-	26	66	58	0.09	6	0.01	323	0.29	802	0.71	1131	675	0.83	0.89
B		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
C		3	52	70	91	0.11	-	16	473	546	731	0.89	-	-	-	-	-	19	0.02	525	0.45	616	0.53	1160	822	0.90	
D		1	61	68	95	0.32	-	-	-	-	-	-	2	113	159	199	0.68	3	0.01	174	0.43	227	0.56	404	294	0.94	

X7：磺溪街/德行西路(6/20)平日轉向交通量示意圖

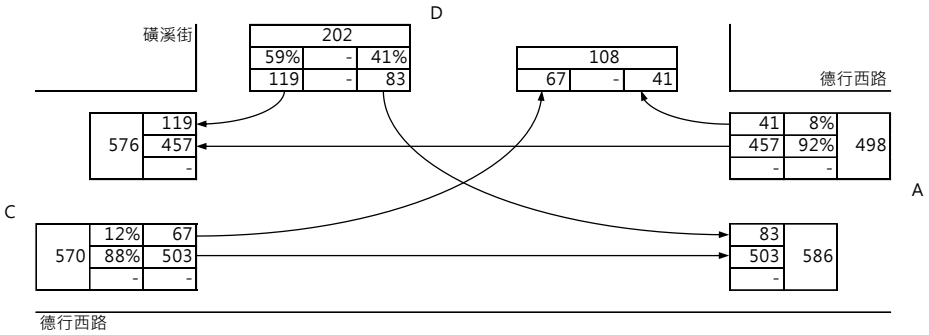
站　號：　X7
站　名：　磺溪街/德行西路

單　位：　PCU/HR
日　期：　2024/06/20 (四)
天　候：　晴

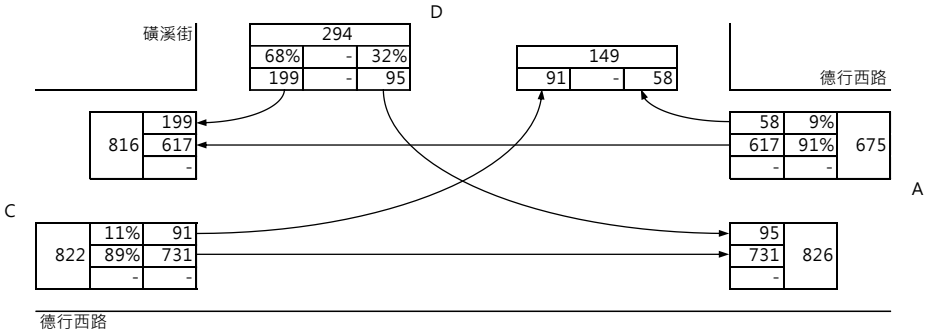
上午尖峰：　07:30-08:30



離峰：　13:00-14:00



下午尖峰：　17:30-18:30

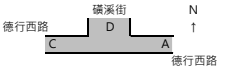


方　向：	A	B	C	D
總車道數：	2	-	2	1

X7：磺溪街/德行西路(6/22)假日交通量

站　號：　X7
站　名：　礁溪街/德行西路
時相數：　4

日　期：　2024/06/22 (六)
天　候：　晴
方　向：　A　B　C　D
車道數：　2　-　2　1



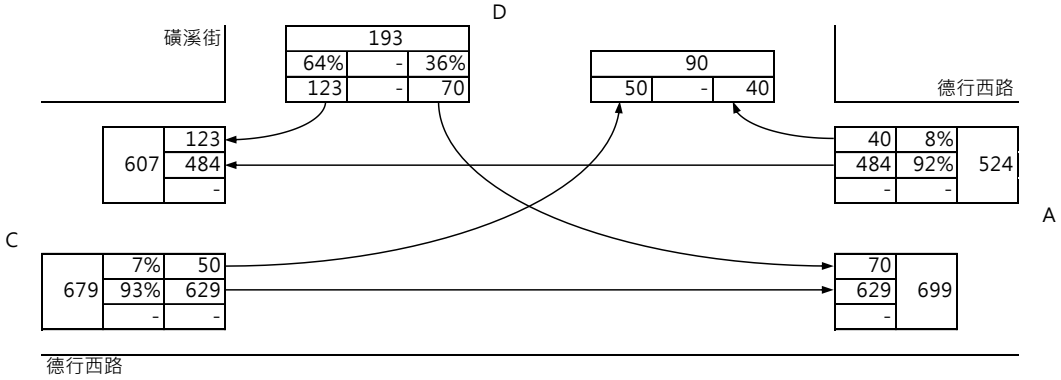
方向	時間	左轉 大型車(輛)	左轉 小型車(輛)	左轉 機車(輛)	左轉 PCU	轉向比	機車待轉	直進 大型車(輛)	直進 小型車(輛)	直進 機車(輛)	直進 PCU	轉向比	右轉 大型車(輛)	右轉 小型車(輛)	右轉 機車(輛)	右轉 PCU	轉向比	合計 大型車(輛)	合計 大型車比例	合計 小型車(輛)	合計 小型車比例	合計 機車(輛)	合計 機車比例	總和(輛)	PCU	PHF	總流量 PHF
A	16:00-17:00	-	-	-	-	-	-	3	267	336	414	0.90	-	25	37	44	0.10	3	0.00	292	0.44	373	0.56	668	458		
	17:00-18:00	-	-	-	-	-	-	5	284	454	484	0.92	-	19	44	40	0.08	5	0.01	303	0.38	498	0.62	806	524		
	18:00-19:00	-	-	-	-	-	-	9	235	464	446	0.91	-	23	48	46	0.09	9	0.01	258	0.33	512	0.66	779	492		
B	16:00-17:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	17:00-18:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
	18:00-19:00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-		
C	16:00-17:00	6	27	30	53	0.09	-	10	407	256	533	0.91	-	-	-	-	-	16	0.02	434	0.59	286	0.39	736	586		
	17:00-18:00	-	30	43	50	0.07	-	8	479	322	629	0.93	-	-	-	-	-	8	0.01	509	0.58	365	0.41	882	679		
	18:00-19:00	4	40	70	80	0.11	-	14	427	392	617	0.89	-	-	-	-	-	18	0.02	467	0.49	462	0.49	947	697		
D	16:00-17:00	2	44	37	66	0.33	-	-	-	-	-	-	2	87	76	134	0.67	4	0.02	131	0.53	113	0.46	248	200		
	17:00-18:00	-	48	46	70	0.36	-	-	-	-	-	-	2	61	115	123	0.64	2	0.01	109	0.40	161	0.59	272	193		
	18:00-19:00	-	43	62	72	0.37	-	-	-	-	-	-	3	64	104	124	0.63	3	0.01	107	0.39	166	0.60	276	196		
	PCE：	**2**	**1.05**	**0.43**				**1.8**	**1**	**0.42**			**2.7**	**1.08**	**0.45**												
合計	16:00-17:00	8	71	67	119	0.10	-	13	674	592	947	0.76	2	112	113	178	0.14	23	0.01	857	0.52	772	0.47	1652	1244		
	17:00-18:00	-	78	89	120	0.09	-	13	763	776	1113	0.80	2	80	159	163	0.12	15	0.01	921	0.47	1024	0.52	1960	1396		
	18:00-19:00	4	83	132	152	0.11	-	23	662	856	1063	0.77	3	87	152	170	0.12	30	0.01	832	0.42	1140	0.57	2002	1385		
A	17:00-18:00	-	-	-	-	-	-	5	284	454	484	0.92	-	19	44	40	0.08	5	0.01	303	0.38	498	0.62	806	524	0.87	0.98
B		-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
C		-	30	43	50	0.07	-	8	479	322	629	0.93	-	-	-	-	-	8	0.01	509	0.58	365	0.41	882	679	0.94	
D		-	48	46	70	0.36	-	-	-	-	-	-	2	61	115	123	0.64	2	0.01	109	0.40	161	0.59	272	193	0.96	

X7：磺溪街/德行西路(6/22)假日轉向交通量示意圖

站　號：　X7
站　名：　礁溪街/德行西路

單　位：　PCU/HR
日　期：　2024/06/22 (六)
天　候：　晴

下午尖峰：　17:00-18:00



方　向：	A	B	C	D
總車道數：	2	-	2	1