112-030-5509
IOT-111-ICB002

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

中華民國 112 年 5 月

112-030-5509
IOT-111-ICB002

我國人工智慧車聯網之號誌控制模式探討

著者：黃銘崇、萬家豪、黃友恆、徐嘉駿、胡鈞祥、
吳東凌、周家慶

交通部運輸研究所

中華民國 112 年 5 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模式探討/黃銘崇, 萬家豪, 黃友恆, 徐嘉駿, 胡鈞祥, 吳東凌, 周家慶等著. -- 初版. -- 臺北市 : 交通部運輸研究所, 民112.05
面 ; 公分
ISBN 978-986-531-509-2（平裝）

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

557.822 112007339

我國人工智慧車聯網之號誌控制模式探討

著　　者：黃銘崇、萬家豪、黃友恆、徐嘉駿、胡鈞祥、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 112 年 5 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：310 元
展 售 處：
交通部運輸研究所運輸資訊組・電話：(02)2349-6789
五南文化廣場：400002 臺中市中區中山路 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：1011200565　　ISBN：978-986-531-509-2（平裝）
著作財產權人：中華民國（代表機關：交通部運輸研究所）
本著作保留所有權利，欲利用本著作全部或部分內容者，須徵求交通部運輸研究所書面授權。

交通部運輸研究所合作研究計畫出版品摘要表

出版品名稱：我國人工智慧車聯網之號誌控制模式探討			
國際標準書號（或叢刊號） ISBN 978-986-531-509-2(平裝)	政府出版品統一編號 1011200565	運輸研究所出版品編號 112-030-5509	計畫編號 111-ICB002
本所主辦單位：運輸資訊組 主管：吳東凌 計畫主持人：吳東凌 研究人員：周家慶 聯絡電話：(02)23496756 傳真號碼：(02)25450426	合作研究單位：睿星科技股份有限公司 計畫主持人：黃銘崇 研究人員：萬家豪、黃友恆、徐嘉駿、胡鈞祥 地址：105007 臺北市松山區民生東路 3 段 107 巷 6 號 5 樓 聯絡電話：(02)25472965		研究期間 自 111 年 4 月 至 111 年 12 月
關鍵詞：AI 號誌控制；深度強化學習；車聯網技術應用；適應性號誌控制；微觀車流模擬			

摘要：

近年來人工智慧在軟硬體技術的突飛猛進與各領域應用的迅速發展，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，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。本計畫除回顧彙整國內外應用車聯網與人工智慧強化學習在號誌控制之應用與演算法，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與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，來為後續人工智慧號誌控制奠下研發基礎。計畫分別以臺北市「中山北路-德行東路」3 個路口幹道、臺南市「台 86-19 甲線」路口、高雄市台 88 線鳳山出口(過埤路-鳳頂路)路口)等 3 個縣市政府合作所發展交通模擬環境與人工智慧強化學習號誌控制模型及其訓練。

根據不同場域特色，以及強化學習探討的議題項目，總計提出 13 種不同的強化學習應用方案，訓練結果顯示 13 種強化學習方案皆能不同程度的改善現況交通績效，顯示 DDPG 強化學習號誌控制的潛力與可行性。計畫同時研提以 PPO 為核心演算法的做法，並於臺南市實驗場域進行模擬測試，結果顯示不同的強化學習演算法也同樣可以取得績效改善。車聯網資料應用上，研提採用卷積層網路(CNN)結構萃取資料特徵，進而做為強化學習的資料輸入，實驗結果顯示，以車聯網資料做為強化學習號誌控制資料來源的潛力。

出版日期	頁數	定價	本出版品取得方式
112 年 5 月	262	310	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 and Vehicle-to-Everything Traffic Signal Control Model in Taiwan

ISBN (OR ISSN)	GOVERNMENT PUBLICATIONS NUMBER	IOT SERIAL NUMBER	PROJECT NUMBER
ISBN 978-986-531-509-2(pbk.)	1011200565	112-030-5509	111-ICB002

DIVISION: Information Systems Division
DIVISION DIRECTOR: Tun-Ling Wu
PRINCIPAL INVESTIGATOR: Tun-Ling Wu
PROJECT STAFF: Ja-Ching Chou
PHONE:886-2-23496756
FAX:886-2-25450426

PROJECT PERIOD

FROM April 2022
TO December 2022

RESEARCH AGENCY: RisingStar Co., Ltd.
PRINCIPAL INVESTIGATOR: Ming-Chorng Hwang
PROJECT STAFF: Chia-Hao Wan, You-Heng Huang, Chia-Chun Hsu, Jing-Shyang Hwu
ADDRESS: 5F., No.6., Lane.107., Sec.3., Minsheng E. Rd., Taipei, Taiwan 105007, R.O.C.
PHONE: (02)25472965

KEY WORDS: Artificial intelligence traffic signal control；deep reinforcement learning；vehicle-to-everything applications；adaptive traffic signal control； microscopic traffic simulation

ABSTRACT:

In recent years, due to the rapid development of artificial intelligence in software and hardware technology and the rapid development of applications in various fields, technologies such as artificial intelligence, image recognition, information and communication technologies (ICT), vehicle-to-everything (V2X) and 5G can be expected to be used in the future as they especially alleviate pain points caused by the lack of intelligence in traffic control signals. In addition to reviewing and collecting the applications and algorithms of the Internet of Vehicles and artificial intelligence reinforcement learning in signal control both at home and abroad, this project also develops a simulated environment for signal control of the Internet of Vehicles and artificial intelligence reinforcement learning. Artificial intelligence signal control model construction, learning and training, simulation, and performance evaluation of multi-temporal signal control at a single intersection and arterial chain signal control simulation can lay the foundation for subsequent research and development of artificial intelligence signal control. The plan is to use three main roads at the intersection of "Zhongshan North Road-Dexing East Road" in Taipei City, the intersection of "Taiwan 86-19A" in Tainan City, and the intersection of Tai 88 Fengshan Exit (Guopi Road-Fengding Road) in Kaohsiung City) etc. where the collaboration between county and city governments led to the development of a traffic simulation environment, as well as artificial intelligence reinforcement learning signal control model and its training.

According to the characteristics of different scenarios and the topics discussed in reinforcement learning, a total of 13 different reinforcement learning application schemes are proposed. The training results show that all 13 reinforcement learning schemes can improve current traffic flow to varying degrees, this showcasing the potential and feasibility of control through DDPG reinforcement learning. At the same time, the plan is to develop the method of using PPO as the core algorithm and conduct a simulation with Tainan City as a testbed. The results showed that different reinforcement learning algorithms can also achieve improvements. In the application of Internet of Vehicles data, the research team uses a convolutional layer network (CNN) structure to extract data features, and then use it as data input for reinforcement learning. The experiment results show the potential of using Internet of Vehicles data as a source of reinforcement learning signal control data.

DATE OF PUBLICATION	NUMBER OF PAGES	PRICE
May 2023	262	310

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

目錄

目錄 III
圖目錄 VI
表目錄 XII
第一章 緒論 1
1.1 計畫背景與目的 1
1.2 計畫內容 1
1.3 關鍵課題與對策 3
第二章 文獻回顧 5
2.1 現有動態號誌控制 5
2.1.1 澳洲 SCATS 5
2.1.2 英國 SCOOT 7
2.1.3 德國 PTV GROUP 號誌控制方案 8
2.1.4 美國 RHODES 10
2.1.5 美國 OPAC 11
2.1.6 都市交通號誌全動態控制邏輯模式 11
2.1.7 路徑為基礎(Path based)的即時交通號誌控制方法 12
2.2 國內外人工智慧強化學習號誌控制 14
2.2.1 強化學習方法簡介 15
2.2.2 應用強化學習於號誌控制 21
2.3 國內人工智慧號誌實作案例 24
2.3.1 桃園市大園區 AI 智慧號誌控制試辦計畫 25
2.3.2 桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫 27
2.3.3 桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫第二期 28
2.3.4 高雄港聯外交通改善-區域性交控及大貨車行車安全提升計畫 29
2.3.5 應用人工智慧技術進行交通數據蒐集暨號誌控制之研究 30
2.4 車聯網號誌控制研究與案例 31
2.5 小結 36
第三章 研究方法 39
3.1 強化學習號誌控制方法 39
3.1.1 深度確定性策略梯度法 (Deep Deterministic Policy Gradient, DDPG) 42
3.1.2 近端策略優化(Proximal Policy Optimization, PPO) 46
3.2 模擬方法與建置流程 50

3.2.1 模擬軟體介紹 50
3.2.2 模擬器校估流程 54
第四章 實驗場域規劃與分析 57
4.1 實驗場域遴選過程 57
4.1.1 縣市訪談與候選場域 57
4.1.2 實驗場域遴選程序 58
4.1.3 實驗場域遴選結果 59
4.2 交通調查計畫 66
4.2.1 單一路口場域(臺南市) 66
4.2.2 幹道多路口場域(臺北市) 67
4.2.3 車聯網路口場域(高雄市) 70
4.3 交通現況分析 73
4.3.1 臺南場域交通現況分析 73
4.3.2 臺北市場域交通現況分析 78
4.3.3 高雄市場域交通現況分析 93
第五章 人工智慧強化學習方案規劃與模擬模式構建 101
5.1 本計畫人工智慧強化學習(RL)號誌控制適用條件 101
5.2 號誌控制模型方案設計 102
5.2.1 單一路口場域 AI RL 模型方案規劃 104
5.2.2 幹道多路口場域 AI RL 模型方案規劃 107
5.2.3 車聯網路口場域 AI RL 模型方案規劃 112
5.3 交通模擬模型建置成果 116
5.3.1 單一路口場域模擬驗證(臺南市) 121
5.3.2 幹道多路口場域模擬驗證(臺北市) 129
5.3.3 車聯網場域模擬驗證(高雄市) 143
5.3.4 模擬路網驗證小結 153
第六章 強化學習訓練成果與分析 157
6.1 強化學習訓練架構 157
6.2 單一路口場域(臺南市場域) 158
6.2.1 臺南場域模擬測試數值 160
6.2.2 臺南市場域績效分析與議題探討 167
6.2.3 PPO 演算法 170
6.3 幹道多路口場域(臺北市場域) 174

6.3.1 臺北市場域模擬測試數值 176
6.3.2 臺北市場域績效分析與議題探討 185
6.4 車聯網場域(高雄市場域) 189
6.4.1 高雄市場域模擬測試數值 192
6.4.2 高雄市場域績效分析與議題探討 202
6.5 訓練成果小結 205
第七章 結論與建議 207
7.1 結論 207
7.2 建議 210
參考文獻 213
附件一 期中報告審查意見處理情形表 223
附件二 期末報告審查意見處理情形表 235

圖目錄

圖 1.2.1 計畫流程圖 3
圖 2.1.1 REGIONAL COMPUTER CONTROL OF SYSTEMS AND SUBSYSTEMS 6
圖 2.1.2 KEY ELEMENTS OF THE SCOOT UTC SYSTEM 7
圖 2.1.3 VISUM, OPTIMA 與 BALANCE 運作架構示意 9
圖 2.1.4 車流模型描述週期內流量變化示意 9
圖 2.1.5 PTV BALANCE 運作架構示意 10
圖 2.1.6 THE RHODES HIERARCHICAL ARCHITECTURE 11
圖 2.1.7 平衡路徑紓解時間模式 12
圖 2.1.8 主要路徑停等車隊紓解時間預測方法 13
圖 2.2.1 強化學習架構圖 15
圖 2.2.2 ACTOR-CRITIC 演算架構圖 17
圖 2.3.1 桃園市大園區 AI 智慧號誌控制試辦計畫實證場域範圍 25
圖 2.3.2 桃園市大園區 AI 智慧號誌控制試辦計畫績效 26
圖 2.3.3 AI 號誌控制與現行時制幹道東向綠寬帶比較圖 26
圖 2.3.4 AI 幹道東西向綠寬帶 VS 流量圖 27
圖 2.3.5 桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫場域範圍 28
圖 2.3.6 事前事後週內日之平均停等延滯 28
圖 2.3.7 桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫第二期範圍 29
圖 2.3.8 高雄港洲際貨櫃中心聯外交通改善計畫場域範圍 30
圖 2.3.9 應用人工智慧技術進行交通數據蒐集暨號誌控制研究範圍 31
圖 2.4.1 車聯網之通訊類型 32
圖 2.4.3 彎道速限警示應用 33
圖 2.4.4 遠距診斷及時維修通知應用 33
圖 2.4.5 行人碰撞警示應用 34
圖 2.4.6 坦帕市 CVPD 計畫範圍與其應用項目 35
圖 3.1.1 強化學習號誌控制訓練架構 40
圖 3.1.2 RL 號誌控制架構基本模型 40
圖 3.1.3 CRITIC 產生過程 41
圖 3.1.4 AI 號誌方法整體架構圖 42
圖 3.2.1 DDPG 運作架構 44
圖 3.2.2 DDPG 演算法 45

圖 3.3.1 RL 代理人類型 46
圖 3.3.2 PPO 的目標式$LClip$與$r\theta$的關係圖 48
圖 3.3.3 PPO 運作架構圖 48
圖 3.3.4 PPO 演算法 49
圖 3.4.1 實際路況與模擬影片對比 51
圖 3.4.2 心理物理門檻示意圖 51
圖 3.4.3 SUMO 路網編輯介面(左)以及模擬畫面(右) 53
圖 4.1.1 臺南市「台 86-19 甲線」路口 59
圖 4.1.2 臺南市「中正北路-和平東路」路口 60
圖 4.1.3 臺北市「濱江街-大直橋」幹道 61
圖 4.1.4 臺北市「福林路-復興橋兩端」幹道 61
圖 4.1.5 臺北市「中山北路-德行東路」幹道 62
圖 4.1.6 臺北市「辛亥路-萬美街」幹道 62
圖 4.1.7 臺北市「木柵路一段」幹道 63
圖 4.1.8 臺北市「木柵路四段-萬芳交流道」幹道 63
圖 4.1.9 高雄市「台 88 線鳳山出口」車聯網路口 65
圖 4.1.10 緊急車輛優先號誌插入時相示意 65
圖 4.2.1 臺南市「台 86-19 甲線」路口 66
圖 4.2.2 臺北市「中山北路-德行東路」幹道 68
圖 4.2.3 高雄市「台 88 線鳳山出口」車聯網路口 70
圖 4.2.4 高雄市「台 88 線鳳山出口」路口南向車道配置 70
圖 4.2.5 高雄市「台 88 線鳳山出口」路口北向車道配置 71
圖 4.2.6 高雄市「台 88 線鳳山出口」路口東向車道配置 71
圖 4.2.7 高雄市「台 88 線鳳山出口」路口西向車道配置 71
圖 4.3.1 台 86-19 甲線路口號誌時制計畫(綠燈秒數-黃燈秒數-全紅秒數) 74
圖 4.3.2 台 86-19 甲線路口號誌 TOD 計畫 74
圖 4.3.3 台 86-19 甲線路口平日上下午尖峰交通總量(PCU/15MIN) 75
圖 4.3.4 台 86-19 甲線路口平日離峰交通總量(PCU/15MIN) 75
圖 4.3.5 台 86-19 甲線路口假日尖峰交通總量(PCU/15MIN) 75
圖 4.3.6 台 86-19 甲線路口平日上午尖峰小時轉向交通量 76
圖 4.3.7 台 86-19 甲線路口平日下午尖峰小時轉向交通量 76
圖 4.3.8 台 86-19 甲線路口平日離峰尖峰小時轉向交通量 77
圖 4.3.9 台 86-19 甲線路口假日尖峰小時轉向交通量 77

圖 4.3.10 路口 2(中山克強)號誌時制計畫 79
圖 4.3.11 路口 2(中山克強)號誌時相型態 79
圖 4.3.12 路口 2(中山克強)號誌時制計畫 80
圖 4.3.13 路口 3(中山 195 巷)號誌時制計畫 80
圖 4.3.14 路口 3(中山 195 巷)號誌時相型態 80
圖 4.3.15 路口 3(中山 195 巷)號誌時制計畫 81
圖 4.3.16 路口 4(中山德行)號誌時制計畫 81
圖 4.3.17 路口 4(中山德行)號誌時相型態 81
圖 4.3.18 路口 4(中山德行)號誌時制計畫 82
圖 4.3.19 路口 2(中山克強) 平日上下午尖峰交通總量(PCU/15MIN)..... 82
圖 4.3.20 路口 2(中山克強) 平日離峰交通總量(PCU/15MIN)..... 82
圖 4.3.21 路口 2(中山克強) 假日尖峰交通總量(PCU/15MIN)..... 83
圖 4.3.22 路口 3(中山 195 巷) 平日上下午尖峰交通總量(PCU/15MIN)..... 83
圖 4.3.23 路口 3(中山 195 巷) 平日離峰交通總量(PCU/15MIN)..... 83
圖 4.3.24 路口 3(中山 195 巷) 假日尖峰交通總量(PCU/15MIN)..... 83
圖 4.3.25 路口 4(中山德行) 平日上下午尖峰交通總量(PCU/15MIN)..... 84
圖 4.3.26 路口 4(中山德行) 平日離峰交通總量(PCU/15MIN)..... 84
圖 4.3.27 路口 4(中山德行) 假日尖峰交通總量(PCU/15MIN)..... 84
圖 4.3.28 路口 2(中山克強) 平日上午尖峰小時轉向交通量 85
圖 4.3.29 路口 2(中山克強) 平日下午尖峰小時轉向交通量 85
圖 4.3.30 路口 2(中山克強)平日離峰尖峰小時轉向交通量 86
圖 4.3.31 路口 2(中山克強) 假日尖峰小時轉向交通量 86
圖 4.3.32 路口 3(中山 195 巷) 平日上午尖峰小時轉向交通量 86
圖 4.3.33 路口 3(中山 195 巷) 平日下午尖峰小時轉向交通量 87
圖 4.3.34 路口 3(中山 195 巷) 平日離峰尖峰小時轉向交通量 87
圖 4.3.35 路口 3(中山 195 巷) 假日尖峰小時轉向交通量 87
圖 4.3.36 路口 4(中山德行) 平日上午尖峰小時轉向交通量 88
圖 4.3.37 路口 4(中山德行) 平日下午尖峰小時轉向交通量 88
圖 4.3.38 路口 4(中山德行) 平日離峰尖峰小時轉向交通量 88
圖 4.3.39 路口 4(中山德行) 假日尖峰小時轉向交通量 89
圖 4.3.40 臺北市場域旅行時間調查起訖位置..... 91
圖 4.3.41 臺北市場域平日上午旅行時間(扣除停等紅燈)..... 92
圖 4.3.42 臺北市場域平日下午旅行時間(扣除停等紅燈)..... 92

圖 4.3.43 臺北市場域平日離峰旅行時間(扣除停等紅燈) 93
圖 4.3.44 臺北市場域假日尖峰旅行時間(扣除停等紅燈) 93
圖 4.3.45 過埤鳳頂號誌時制計畫 94
圖 4.3.46 過埤鳳頂號誌時相型態 94
圖 4.3.47 過埤鳳頂號誌 TOD 計畫 95
圖 4.3.48 過埤鳳頂平日上下午尖峰交通總量(PCU/15MIN) 95
圖 4.3.49 過埤鳳頂平日離峰交通總量(PCU/15MIN) 95
圖 4.3.50 過埤鳳頂假日尖峰交通總量(PCU/15MIN) 95
圖 4.3.51 過埤鳳頂平日上午尖峰小時轉向交通量 96
圖 4.3.52 過埤鳳頂平日下午尖峰小時轉向交通量 96
圖 4.3.53 過埤鳳頂平日離峰小時轉向交通量 96
圖 4.3.54 過埤鳳頂假日尖峰小時轉向交通量 97
圖 4.3.55 過埤鳳頂平日上午尖峰停等車隊長度 99
圖 4.3.56 過埤鳳頂平日下午尖峰停等車隊長度 99
圖 4.3.57 過埤鳳頂平日離峰停等車隊長度 99
圖 4.3.58 過埤鳳頂假日尖峰停等車隊長度 100
圖 5.2.1 單一路口 AGENT 模型結構 106
圖 5.2.2 幹道多路口 AGENT 模型結構 109
圖 5.2.3 幹道多路口 AGENT 位置配置 110
圖 5.2.4 車聯網位置映射示意圖 114
圖 5.2.6 場域中範圍切割示意圖 115
圖 5.3.1 SUMO 建模搭配空拍底圖範例 116
圖 5.3.2 VISSIM 建模搭配空拍底圖範例 117
圖 5.3.3 VISSIM 中三處場域模擬路網 117
圖 5.3.4 SUMO 中三處場域模擬路網 117
圖 5.3.5 SUMO 中圖像化時相動線設定範例 118
圖 5.3.6 SUMO 中文字矩陣時相動線設定範例 118
圖 5.3.7 VISSIM 中號誌時制設定範例 119
圖 5.3.8 SUMO 交通需求設定範例 119
圖 5.3.9 VISSIM 交通需求設定範例 119
圖 5.3.10 臺北市「中山北路-德行東路」幹道 129
圖 6.1.1 訓練與測試架構圖 157
圖 6.2.1 台 86-19 甲線路口號誌時制計畫 158

圖 6.2.2 台 86-19 甲線路口號誌時制計畫 159
圖 6.2.3 臺南市場域訓練績效演進圖(以 A1 為例) 159
圖 6.2.4 A1 方案平均時相長度 161
圖 6.2.5 A2 方案平均時相長度 162
圖 6.2.6. A1 方案平均時相長度 164
圖 6.2.7 A4 方案平均時相長度 166
圖 6.2.9 PPO 應用於單一路口 ACTOR 模型結構 170
圖 6.2.10 PPO 應用於單一路口 CRITIC 模型結構 171
圖 6.2.11 連續型控制且有上下界的問題，決策值只能在某個區間 171
圖 6.2.12 PPO 訓練過程績效變化-平日下午尖峰 173
圖 6.2.13 PPO 訓練過程的常態分配參數變化-平日下午尖峰 173
圖 6.2.14 PPO 訓練過程績效變化-平日下午離峰 173
圖 6.2.15 PPO 訓練過程的常態分配參數變化-平日下午離峰 173
圖 6.3.1 臺北市場域模擬範圍圖 175
圖 6.3.2 臺北市場域時相組合設定 175
圖 6.3.3 臺北市場域訓練績效演進圖(以 B1 為例) 176
圖 6.3.4 B1 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內) 177
圖 6.3.5 B1 方案平日上午間峰平均時相長度 178
圖 6.3.6 B1 方案平日下午尖峰平均時相長度 178
圖 6.3.7 B1 方案平日下午離峰平均時相長度 178
圖 6.3.8 B1 方案假日下午尖峰平均時相長度 178
圖 6.3.9 B2 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內) 179
圖 6.3.10 B2 方案平日上午尖峰平均時相長度 180
圖 6.3.11 B2 方案平日下午尖峰平均時相長度 180
圖 6.3.12 B2 方案平日下午離峰平均時相長度 180
圖 6.3.13 B2 方案假日下午尖峰平均時相長度 180
圖 6.3.14 B3 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內) 181
圖 6.3.15 B3 方案平日上午尖峰平均時相長度 182
圖 6.3.16 B3 方案平日下午尖峰平均時相長度 182
圖 6.3.17 B3 方案平日下午離峰平均時相長度 182

圖 6.3.18 B3 方案假日下午尖峰平均時相長度 182
圖 6.3.19 B4 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內) 183
圖 6.3.20 B4 方案平日上午間峰平均時相長度 184
圖 6.3.21 B4 方案平日下午尖峰平均時相長度 184
圖 6.3.22 B4 方案平日下午離峰平均時相長度 184
圖 6.3.23 B4 方案假日下午尖峰平均時相長度 184
圖 6.3.24 平日上午尖峰綠寬帶圖(以 B1 為例)..... 186
圖 6.3.25 平日下午尖峰綠寬帶圖(以 B1 為例)..... 186
圖 6.4.1 高雄市場域偵測器佈設位置與範圍 190
圖 6.4.2 過埤鳳頂號誌時相型態 190
圖 6.4.3 高雄市場域訓練績效演進圖(以 C1 為例)..... 191
圖 6.4.4 C1 方案平均時相長度 192
圖 6.4.5 C1S 方案平均時相長度 195
圖 6.4.6 高雄市場域格位範圍分割 196
圖 6.4.7 格位轉換過程示意圖 197
圖 6.4.8 C2 方案平均時相長度 197
圖 6.4.9 C3 方案平均時相長度 199
圖 6.4.10 C4 方案平均時相長度 201

表目錄

表 3.3.1 DDPG 與 PPO 方法比較 50
表 3.4.1 VISSIM API 指令說明 53
表 3.4.2 TRACI 指令說明 54
表 4.1.1 臺北市、新北市、臺南市、高雄市的實驗場域候選名單 57
表 4.1.2 場域遴選考量準則 58
表 4.1.3 單一路口實驗場域遴選結果 61
表 4.1.4 幹道多路口實驗場域遴選結果 64
表 4.2.1 各場域調查項目一覽表 66
表 4.3.1 場域調查時段 73
表 4.3.2 臺南場域道路幾何特性 73
表 4.3.4 臺南場域平日上下午尖峰延滯與服務水準 77
表 4.3.4 臺南場域平日離峰延滯與服務水準 78
表 4.3.5 臺南場域假日尖峰延滯與服務水準 78
表 4.3.6 臺北市場域道路幾何特性 78
表 4.3.7 臺北市場域平日上下午尖峰延滯與服務水準 89
表 4.3.8 臺北市場域平日離峰延滯與服務水準 90
表 4.3.9 臺北市場域假日尖峰延滯與服務水準 90
表 4.3.10 臺北市場域平日上下午尖峰旅行時間調查 91
表 4.3.11 臺北市場域平日離峰旅行時間調查 92
表 4.3.12 臺北市場域假日尖峰旅行時間調查 92
表 4.3.13 高雄市場域道路幾何特性 93
表 4.3.14 高雄市場域平日上下午尖峰延滯與服務水準 97
表 4.3.15 高雄市場域平日離峰延滯與服務水準 97
表 4.3.16 高雄市場域假日尖峰延滯與服務水準 98
表 5.2.1 文獻回顧中各要素內容 103
表 5.2.2 單一路口情境實驗方案規劃 105
表 5.2.3 幹道多路口情境實驗訓練架構規劃 108
表 5.2.4 多路口號誌控制特性分類表 111
表 5.2.5 車聯網路口情境實驗訓練架構規劃 113
表 5.3.1 建議之 GEH 接受門檻 120
表 5.3.2 GEH 和誤差百分比的比較分析 121

表 5.3.3 VISSIM 臺南市場域平日上午尖峰調查與模擬流量 121
表 5.3.4 VISSIM 臺南市場域平日下午尖峰調查與模擬流量 122
表 5.3.5 VISSIM 臺南市場域平日下午離峰調查與模擬流量 122
表 5.3.6 VISSIM 臺南市場域假日下午尖峰調查與模擬流量 122
表 5.3.7 VISSIM 臺南市場域流量 MAPE 123
表 5.3.9 VISSIM 臺南市場域平日上午尖峰平均每車延滯 124
表 5.3.10 VISSIM 臺南市場域平日下午尖峰平均每車延滯 124
表 5.3.11 VISSIM 臺南市場域平日下午離峰平均每車延滯 124
表 5.3.12 VISSIM 臺南市場域假日下午尖峰平均每車延滯 124
表 5.3.13 VISSIM 臺南市場域平均每車延滯 MAPE 125
表 5.3.14 VISSIM 臺南市場域平均每車延滯 GEH 125
表 5.3.15 SUMO 臺南市場域平日上午尖峰調查與模擬流量 125
表 5.3.16 SUMO 臺南市場域平日下午尖峰調查與模擬流量 126
表 5.3.17 SUMO 臺南市場域平日下午離峰調查與模擬流量 126
表 5.3.18 SUMO 臺南市場域假日下午尖峰調查與模擬流量 126
表 5.3.19 SUMO 臺南市場域流量 MAPE 127
表 5.3.20 SUMO 臺南市場域流量 GEH 127
表 5.3.21 SUMO 臺南市場域平日上午尖峰平均每車延滯 128
表 5.3.22 SUMO 臺南市場域平日下午尖峰平均每車延滯 128
表 5.3.23 SUMO 臺南市場域平日下午離峰平均每車延滯 128
表 5.3.24 SUMO 臺南市場域假日下午尖峰平均每車延滯 128
表 5.3.25 SUMO 臺南市場域平均每車延滯 MAPE 129
表 5.3.26 SUMO 臺南市場域平均每車延滯 GEH 129
表 5.3.27 VISSIM 臺北市場域平日上午尖峰調查與模擬流量 130
表 5.3.28 VISSIM 臺北市場域平日下午尖峰調查與模擬流量 130
表 5.3.29 VISSIM 臺北市場域平日下午離峰調查與模擬流量 131
表 5.3.30 VISSIM 臺北市場域假日下午尖峰調查與模擬流量 132
表 5.3.31 VISSIM 臺北市場域流量 MAPE 與 MAE..... 132
表 5.3.32 VISSIM 臺北市場域流量 GEH 133
表 5.3.33 VISSIM 臺北市場域平日上午尖峰平均每車延滯 134
表 5.3.34 VISSIM 臺北市場域平日下午尖峰平均每車延滯 134
表 5.3.35 VISSIM 臺北市場域平日下午離峰平均每車延滯 135
表 5.3.36 VISSIM 臺北市場域假日下午尖峰平均每車延滯 135

表 5.3.37 VISSIM 臺北市場域平均每車延滯 MAPE 與 MAE 135
表 5.3.38 VISSIM 臺北市場域平均每車延滯 GEH 136
表 5.3.39 SUMO 臺北市場域平日上午尖峰調查與模擬流量 136
表 5.3.40 SUMO 臺北市場域平日下午尖峰調查與模擬流量 137
表 5.3.41 SUMO 臺北市場域平日下午離峰調查與模擬流量 138
表 5.3.42 SUMO 臺北市場域假日下午尖峰調查與模擬流量 138
表 5.3.43 SUMO 臺北市場域流量 MAPE 與 MAE 139
表 5.3.44 SUMO 臺北市場域流量 GEH 140
表 5.3.45 SUMO 臺北市場域平日上午尖峰平均每車延滯 141
表 5.3.46 SUMO 臺北市場域平日下午尖峰平均每車延滯 141
表 5.3.47 SUMO 臺北市場域平日下午離峰平均每車延滯 141
表 5.3.48 SUMO 臺北市場域假日下午尖峰平均每車延滯 142
表 5.3.49 SUMO 臺北市場域平均每車延滯 MAPE 與 MAE 142
表 5.3.50.79. SUMO 臺北市場域平均每車延滯 GEH 142
表 5.3.51 VISSIM 高雄市場域平日上午尖峰調查與模擬流量 143
表 5.3.52 VISSIM 高雄市場域平日下午尖峰調查與模擬流量 144
表 5.3.53 VISSIM 高雄市場域平日下午離峰調查與模擬流量 144
表 5.3.54 VISSIM 高雄市場域假日下午尖峰調查與模擬流量 145
表 5.3.55 VISSIM 高雄市場域流量 MAPE 145
表 5.3.56 VISSIM 高雄市場域流量 GEH 146
表 5.3.57 VISSIM 高雄市場域平日上午尖峰平均每車延滯 147
表 5.3.58 VISSIM 高雄市場域平日下午尖峰平均每車延滯 147
表 5.3.59 VISSIM 高雄市場域平日下午離峰平均每車延滯 147
表 5.3.60 VISSIM 高雄市場域假日下午尖峰平均每車延滯 147
表 5.3.61 VISSIM 高雄市場域平均每車延滯 MAPE 148
表 5.3.62 VISSIM 高雄市場域平均每車延滯 GEH 148
表 5.3.63 SUMO 高雄市場域平日上午尖峰調查與模擬流量 148
表 5.3.64 SUMO 高雄市場域平日下午尖峰調查與模擬流量 149
表 5.3.65 SUMO 高雄市場域平日下午離峰調查與模擬流量 149
表 5.3.66 SUMO 高雄市場域假日下午尖峰調查與模擬流量 150
表 5.3.67 SUMO 高雄市場域流量 MAPE 150
表 5.3.68 SUMO 高雄市場域流量 GEH 151
表 5.3.69 SUMO 高雄市場域平日上午尖峰平均每車延滯 152

表 5.3.70 SUMO 高雄市場域平日下午尖峰平均每車延滯 152
表 5.3.71 SUMO 高雄市場域平日下午離峰平均每車延滯 152
表 5.3.72 SUMO 高雄市場域假日下午尖峰平均每車延滯 152
表 5.3.73 SUMO 高雄市場域平均每車延滯 MAPE 153
表 5.3.74 SUMO 高雄市場域平均每車延滯 GEH 153
表 5.3.75 模擬驗證 MAPE 一覽 154
表 5.3.76 模擬驗證 GEH 一覽 154
表 6.1.1 軟硬體環境規格 157
表 6.2.1 臺南場域訓練過程與時間 160
表 6.2.2 A1 方案模擬測試績效 160
表 6.2.3 A1 方案模擬各方向績效變化 160
表 6.2.4 A1 方案模擬決策統計表 161
表 6.2.5 A2 方案模擬測試績效 162
表 6.2.6 A2 方案模擬各方向績效變化 162
表 6.2.7 A2 方案模擬決策統計表 163
表 6.2.8 A3 方案模擬測試績效 164
表 6.2.9 A3 方案模擬各方向績效變化 164
表 6.2.10 A3 方案模擬決策統計表 164
表 6.2.11 A4 方案模擬測試績效 165
表 6.2.12 A4 方案模擬各方向績效變化 166
表 6.2.13 A4 方案模擬決策統計表 166
表 6.2.14 臺南市場域各方案平均績效一覽 167
表 6.2.12 A1 vs A2 模擬績效比較 168
表 6.2.16 A1 vs A3 模擬績效比較 168
表 6.2.17 A1 vs A4 模擬績效比較 170
表 6.2.18 PPO 模擬績效比較 173
表 6.3.1 臺北市場域訓練過程時間 176
表 6.3.2 B1 方案模擬測試績效 177
表 6.3.3 B1 方案模擬測試旅行時間 177
表 6.3.4 B1 方案模擬週期統計表 178
表 6.3.5 B2 方案模擬測試績效 179
表 6.3.6 B2 方案模擬測試旅行時間 179
表 6.3.7 B2 方案模擬週期統計表 180

表 6.3.8 B3 方案模擬測試績效 181
表 6.3.9 B3 方案模擬測試旅行時間 182
表 6.3.10 B3 方案模擬週期統計表 182
表 6.3.11 B4 方案模擬測試績效 183
表 6.3.12 B4 方案模擬測試旅行時間 184
表 6.3.13 B4 方案模擬週期統計表 185
表 6.3.16 B1 方案所有路口平均每車延滯差異 187
表 6.3.17 B2 vs B3 方案績效差異 187
表 6.3.18 B2 vs B3 各方向平均延滯改善幅度 188
表 6.3.19 B1 vs B4 各方向平均延滯改善幅度 189
表 6.4.1 高雄市場域訓練過程所需時間 191
表 6.4.2 C1 方案模擬測試績效 192
表 6.4.3 C1 方案模擬各方向績效變化 192
表 6.4.4 C1 方案模擬決策統計表 193
表 6.4.5 C1S 方案模擬測試績效 194
表 6.4.6 C1S 方案模擬各方向績效變化 194
表 6.4.7 C1S 方案模擬決策統計表 195
表 6.4.8 C2 方案模擬測試績效 197
表 6.4.9 C2 方案模擬各方向績效變化 197
表 6.4.10 C2 方案模擬決策統計表 198
表 6.4.11 C3 方案模擬測試績效 199
表 6.4.12 C3 方案模擬各方向績效變化 199
表 6.4.13 C3 方案模擬決策統計表 199
表 6.4.14 C4 方案模擬測試績效 201
表 6.4.15 C4 方案模擬各方向績效變化(延滯) 201
表 6.4.16 C4 方案模擬各方向績效變化(停等車隊長) 201
表 6.4.17 C4 方案模擬決策統計表 202
表 6.4.18 高雄市場域各方案平均績效一覽 202
表 6.4.19 C1 vs C1S 績效比較 203
表 6.4.20 C2 vs C3 績效比較 204
表 6.5.1 所有模擬測試績效一覽表 205
表 7.1 本計畫強化學習要素設定列表 209
表 7.2 模擬測試績效一覽表 210

第一章 緒論

1.1 計畫背景與目的

近年來人工智慧在軟硬體技術的突飛猛進與各領域應用的迅速發展，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，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。

本所於 104 年至 108 年進行系列智慧交通服務效能與安全的車聯網研究計畫，優先探討我國都市交通號誌控制與車聯網整合，提供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。另運輸研究所於 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 」為基礎的人工智慧強化學習 (RL)號誌控制 ，而國內相關學術單位人員亦進行人工智慧強化學習 (RL)號誌控制之研究，另桃園市與高雄市分別於 108 年開始，先後進行人工智慧適應性號誌控制系統實作。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。

國內在這些先行的人工智慧/車聯網研究基礎之下，本計畫將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。

1.2 計畫內容

本計畫透過重點回顧國內外應用車聯網與人工智慧強化學習 (Reinforcement learning, RL)在號誌控制之研究文獻與實際建置案例，以進行相較於現有動態號誌控制模式之優缺點研析。此外，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：單一路口多時相、連鎖幹道、車聯網環境之單一路口。遴選上述實驗場域時，同時考量後續年度實作現場環境配合需求，並挑選既有設備能夠支援相關控制策略實施之場域。除了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，做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。

在人工智慧號誌控制模式探討中，針對狀態(State)、決策(Action)、獎勵(Reward)分別考量不同定義(參數)可能性，並評估場域特性設計適當之組合，研提模擬模式之學習與訓練及測試與績效評估之規劃，並依此規劃在期程內完成相關訓練與成效分析。另於訓練架構與過程中，導入多個號誌代理人協同控制機制，以利達到動態時差、綠寬等幹道連鎖成效。

車聯網技術泛指聯網車(Connected Vehicle) 對各種物體通訊，是車輛與外部環境的連結。在本計畫中將著重於聯網車所能提供的即時資料，探討如何將該資料應用於 AI RL 的動態號誌控制層面。而考量目前國內交通環境中尚無足夠高的聯網車滲透率，在本計畫中將以模擬環境中假設聯網車滲透比例的方法完成相關的 RL 號誌控制模式研究與發展。

本計畫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。意即，考量模式之後續擴充與實作彈性，模擬各路口控制單元(代理人)間在透過即時通訊下，進行強化學習架構之多路口協同運作的訓練。本計畫各項工作執行流程如圖 1.2.1 所示。

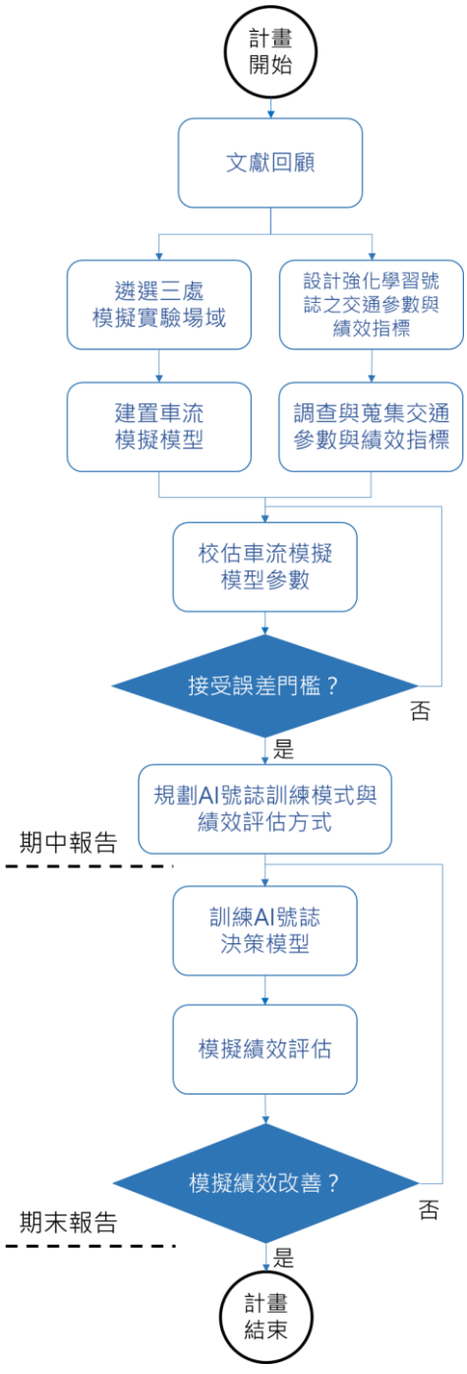

圖 1.2.1 計畫流程圖

1.3 關鍵課題與對策

美國運輸部(USDOT)在「Identifying Real-World Transportation Applications Using Artificial Intelligence (AI) - Plan for Artificial Intelligence for Intelligent Transportation Systems」(FHWA-JPO-20-813, August 2020)文件中針對 ITS 的 AI 定義為「Artificial Intelligence (AI) refers to processes that make it possible for systems to replace or augment routine human tasks or enable

new capabilities that humans cannot perform.」。這個定義揭櫫 AI 在 ITS 的應用除了可以取代及擴充人類既有的常態性工作之外，也包含了開拓人類目前未曾達到的新能力(“enable new capabilities that humans cannot perform”)。並且在 AI 技術選項中首要強調機器學習，並說明 AI 學習、認知與決策的過程不應有人為介入：「Machine learning (ML) is a broad subfield of AI in which computers learn from data, discover patterns and make decisions without human intervention. The ML field is broadly categorized into supervised, semi-supervised, unsupervised and reinforcement learning.」，而強化學習為其中的分支之一，也是目前廣受推崇的 AI 主流技術之一。該文件亦將適應性交通號誌(adaptive traffic signals)列在「Potential Categories of AI-Enabled Applications in ITS - Transportation Systems Management and Operations (TSMO)」的清單之中，顯現美國對於 AI 技術應用於適應性交通號誌的重視。

然而 AI 技術(強化學習)應用於適應性交通號誌，不應只是將其視為一個演算法(algorithm)，甚至只是一個解最佳化問題的工具(optimization tool)。其重點乃在於「適應性交通號誌問題本質的認知」，與「強化學習是否適合」以及「如何應用於求解這個問題」。因此，釐清這個問題的本質與分析既有方法的缺點，將有助於對比強化學習應用時所應著力的關鍵所在。因此，研究團隊在文獻回顧中，分析與評估既有適應性交通號誌控制方法與強化學習方法，做為強化學習應用於構建適應性交通號誌控制模型的重要依據，進而「突破既有方法論(methodology)的能力」，並可以「付諸於實務應用」。

第二章 文獻回顧

設置交通號誌的目的主要係透過時相設計與時相秒數設定，使得各方向車流能安全通過路口並且提升路口整體運行的效率。整體而言，號誌控制主要可分為固定時制號誌控制(fixed-timing plan traffic signal control)、反應式號誌控制(responsive traffic signal control)、觸動式號誌控制(actuated traffic signal control)，以及適應性號誌控制(adaptive traffic signal control)等四類，依據本計畫需求規範「須能依據各路口各方向交通變化即時(real time)演算號誌時制，動態彈性調整週期長度、續進寬帶，而不宜在未知即時交通狀態下，以事先產生方式來給定號誌時制」之說明，本章內容以「適應性號誌控制」文獻回顧為主，以確保符合計畫需求。

此外，本計畫以人工智慧號誌控制模型為主題，特別是強化學習在適應性號誌控制的應用，為利於其與現有號誌控制方法的比較與評估，本章將進行文獻回顧探討各方法的差異。這部分內容將依序區隔為「現有適應性號誌控制」與「強化學習號誌控制」等兩類文獻。同時，為因應車聯網技術快速發展，以及這些科技在實作案例的推行狀況，本章文獻回顧將再包含國內人工智慧號誌控制建置案例、車聯網號誌控制研究與案例等兩類文獻。最後，再經整合分析與綜合評估，歸納後續人工智慧號誌控制模型建立之重要依據。

2.1 現有動態號誌控制

適應性號誌控制以其能因應交通狀況即時計算或調整號誌時制而著稱，顧名思義其必須具備獲取交通狀況與即時計算或調整時制之能力，為聚焦於計畫主題，本節回顧內容著重在即時計算或調整號誌時制的模型、邏輯或機制為主，而且為國內外已經有應用於實際道路(多路口)號誌控制系統建置案例。

2.1.1 澳洲SCATS

SCATS(Sydney Coordinated Adaptive Traffic System)號誌控制方法/軟體[0~[4]]由澳洲新南威爾斯政府所開發，使用迄今已超過 40 年並且遍及全球 28 個國家。具備可以處理整體區域級(whole area-wide)大型路網號誌控制能力，整體區域可區分為多個地區(regions)，以其電腦網路系統架構的處理容量而言，整體區域可包含 64 個地區，每個地區最多可處理 250 個系統(systems)，系統內有多個子系統(subsystems)，每一子系統則由數個號誌化路口組成(grouping)。經由設置地區級電腦(regional computer)來管理

其所屬的系統，以利進行號誌控制，地區級電腦、系統與子系統控制關聯示意如圖 2.1.1。

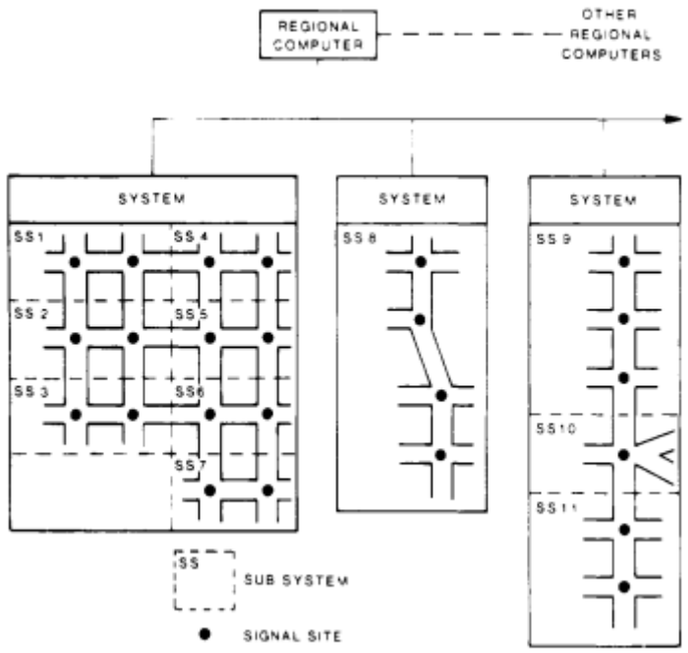

圖 2.1.1 Regional computer control of systems and subsystems

資料來源：[1]

以號誌控制邏輯而言，SCATS 的基本控制單元為子系統，其中只有一個路口為主控路口(a single critical intersection)，其餘路口則與主控路口週期相同，並且依循主控路口時制預設時比(phase split)、時差(offset)進行協同控制(coordinated together)，子系統間也可以依據交通狀況即時進行協同控制。子系統內(within a subsystem)或子系統間(intra subsystems)的協同控制時制計算方法類似，皆由地區級電腦根據各路口偵測資料(設置於停止線)計算共同週期長度、時比與時差，再由各子系統據以執行。週期計算主要係依據各主控路口的飽和度(degree of saturation)，並以維持飽和度 0.9 為調整原則，這種含括時空範圍較廣的控制邏輯屬於策略性控制層級(strategic control level)。此外，SCATS 經由路口偵測器偵知並判斷確認後，允許由路口控制器(local controller)執行減少時相時間或跳過一個時相(不可為主要時相 main road phase)，因此在這個週期節省的時間，必須在後續週期加入以維持共同週期長度之運作。這種控制邏輯則稱為戰術性控制層級(tactical control level)，其保留了個別路口號誌運作的靈活性，以因應局部時空範圍的交通狀況變異。

2.1.2 英國SCOOT

SCOOT(Split Cycle and Offset Optimization Technique)號誌控制方法/軟體[4]~[8]由英國政府成立的運輸研究實驗室(Transport and Road Research Laboratory)所開發，使用迄今已遍及全球 145 個國家。其前身為號誌控制軟體 TRANSYT，後續逐步發展成為可應用於場域的線上(on-line) 號誌控制系統產品。SCOOT 也將號誌路口進行群組劃分(grouping)而形成一個子區(sub area)，同一子區的號誌週期皆為相同，以利進行協同控制。

整個線上運作主要依賴車流模型(traffic model)與最佳化模組(optimizers)，車流模型依據設置於停止線上游偵測器傳來的資料，產生週期性流量剖面(cyclic flow profiles，CFP)型態的資料，車流模型依據這項資料進行各路口的停等車輛(queue)預測及其他績效指標(performance index，PI)計算，最佳化模組再據以進行各路口時差、時比與週期的優化調整，其組成架構示意如圖 2.1.2。

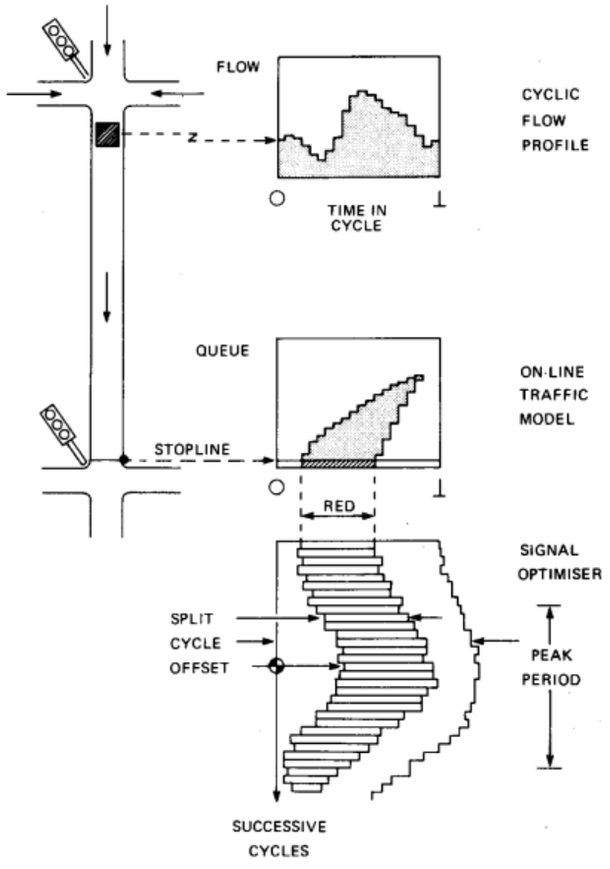

圖 2.1.2 Key elements of the SCOOT UTC system

資料來源：[5]

SCOOT 的最佳化模組正如其名，係分別對各路口現行時制的時比、

週期長度與時差，依據車流模型的分析與預測結果，進行微量優化(incremental optimization)，時比與時差在每週期內都會進行優化，週期則可設定在固定時間內(2-10 分鐘[4])進行優化，以決定是否微量調整現行時制參數。首先是時比優化模組(split optimizer)，其運作原則係使調整後(增/減一個微量或維持不變)的結果達到：最小化「所有鄰近路口方向中飽和度最大值」(minimizing the maximal degree of saturation on links approaching the node)，這將會使各鄰近方向的飽和度趨向相等，飽和度的計算則依據 CFP 資料。時差優化模組(offset optimizer)則依據車流模型預測路口各鄰近方向的停等車隊與停等延滯，依權重加總後所得績效指標(PI)最小化，以決定時差是否增/減一個微量或維持不變。最後是週期長度優化模組(cycle length optimizer)，其優化原則為：檢視子區內所有路口的鄰近方向飽和度，如果皆小於 0.9(系統預設值)則週期長度減少一個微量，若有一個達到 0.9 則週期長度增加一個微量，為利於一個子區內的號誌進行協同控制，同一子區的號誌週期皆為相同。

2.1.3 德國PTV GROUP號誌控制方案

德國 PTV GROUP 同提出的 OPTIMA 與 BALANCE 模組，以同為 PTV 旗下的 VISUM 產出結果為基礎，再整合即時多元交通資訊計算最佳化號誌時制方案[9]~[11]。意即這個方法係以 VISUM 模組的巨觀交通運輸指派(traffic assignment)模型，解得場域路網的供需平衡狀態，包括各道路的指派車流量、平均車速等交通參數。經彙集各種外部即時交通資訊，例如：偵測器、eTag、GVP 或 CVP 等，由 OPTIMA 模組以流量傳遞方法(flow propagation)適度調整原由 VISUM 求解的路網(包括沒有車輛偵測器的大部分路段)交通參數，以因應即時交通狀態的變化，並確保系統能夠每 5 分鐘更新路網參數，同時 OPTIMA 可以計算輸出交通管理所需之短期(60 分鐘以內)動態預測結果，輸入 PTV BALANCE 據以進行動態號誌優化，這三個模組的運作架構如圖 2.1.3 所示。

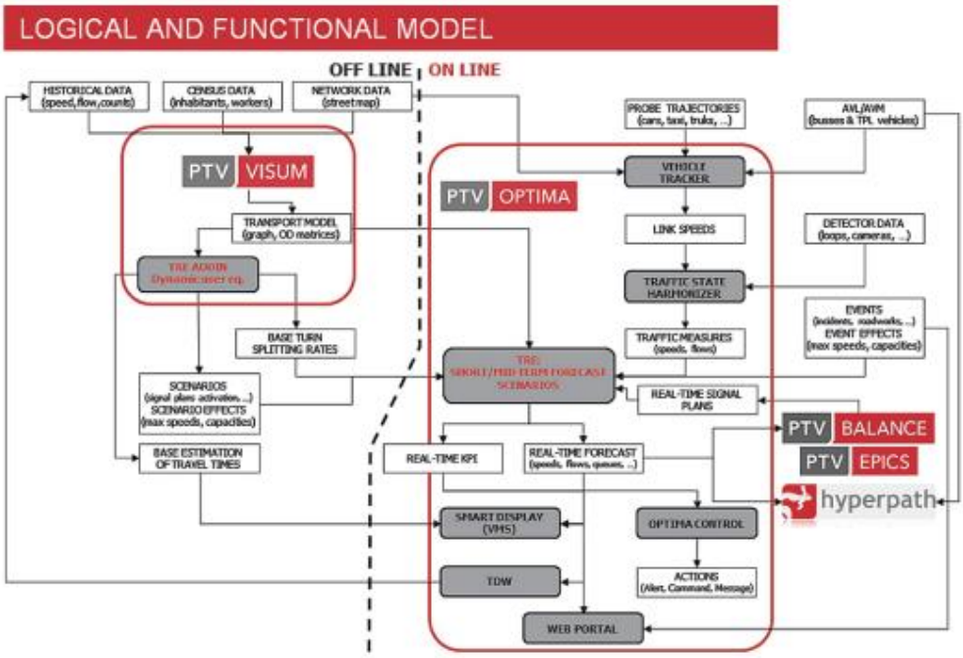

圖 2.1.3 VISUM, OPTIMA 與 BALANCE 運作架構示意

資料來源：[10][11]

在 BALANCE 模組中則以描述路口流量在號誌週期內的變化(如圖 2.1.4 所示，其中 tU 與 Ssg1 分別表示「週期長度」與「方向 1 的飽和流率」)，做為其中觀車流模型的核心，以這個車流模型為基礎，再由基因演算法優化號誌時制。並且配合系統每 5 分鐘更新路網交通參數(O/D、流量…等)後，由此控制模型計算新的優化時制，其運作架構如圖 2.1.5 所示。

這個 PTV GROUP 的動態號誌控制方案在臺中市[10]與臺北市[11]已經實際建置案例(國外亦有其他實作案例[9])，停等延滯改善約為 10-15%。

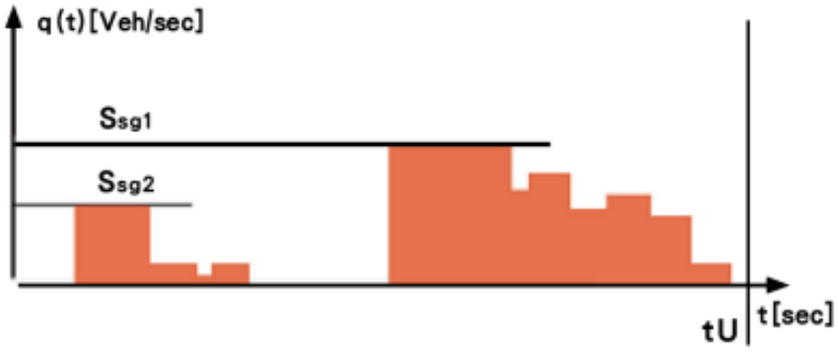

圖 2.1.4 車流模型描述週期內流量變化示意

資料來源： [10]

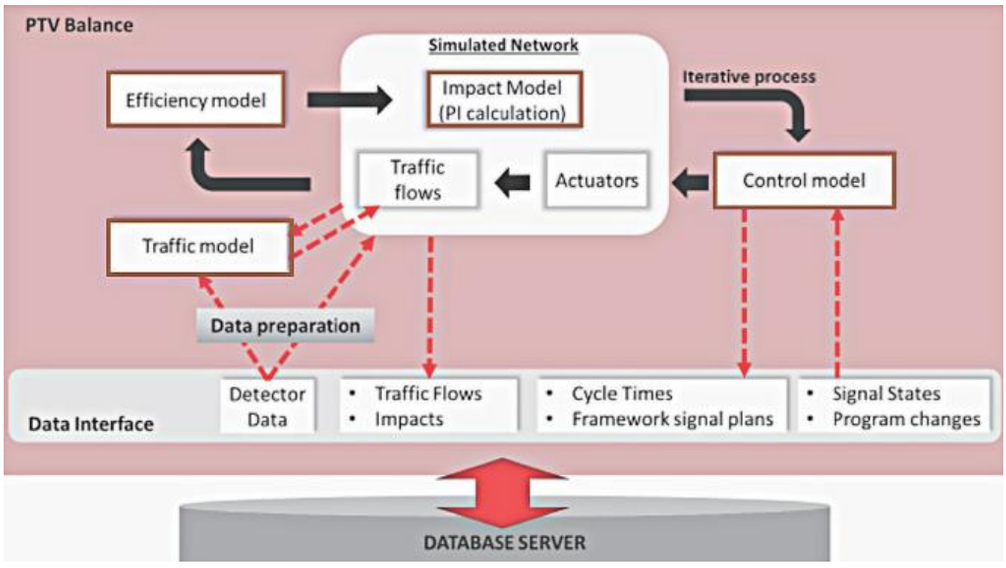

圖 2.1.5 PTV BALANCE 運作架構示意

資料來源：[11]

2.1.4 美國RHODES

Real-time Hierarchical Optimizing Distributed Effective System(RHODES)，由 University of Arizona 的研究團隊所提出的 RHODES[12][13]也有類似 PTV GROUP 動態號誌控制方案的系統架構，最上層為一個具有旅次起訖資料的預測路網，其係由一個類似交通指派的 dynamic network loading 模型所計算而得，稱為 networking loading control。第二層 network flow control，則進行分析預測路網車隊(platoon)續進行為，當車隊在路口產生衝突(conflict)，則以決策樹(decision tree)法則與績效函數決定優先權。第三層為路口控制(intersection control)，其包含一個預測路口到達車輛數的方法(prediction of intersection arrivals)，特別的是這個預測考量了具不確定性(uncertainty)的隨機因素，路口號誌時相秒數以動態規劃(dynamic programming)決定，其整體系統架構如圖 2.1.6 所示。惟這個方法仍以學術研究為主，產品化的程度相對較低，有關各項車流預測所需的參數推估功能模組，可參考文獻[12][13]。

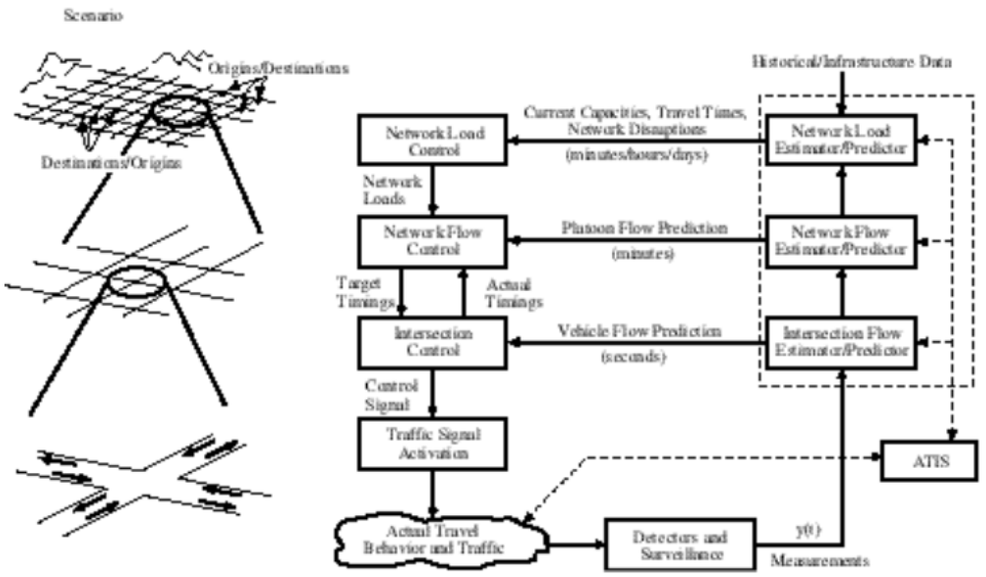

圖 2.1.6 The RHODES Hierarchical Architecture

資料來源：[12]

2.1.5 美國OPAC

這個研究型號誌控制方法由 University of Massachusetts 教授 Nathan H. Gartner 所提出[14]~[16]，其原創的概念(OPAC 1)在於應用偵測器資料，產生週期流量剖面型態資料，並預測數個週期流量，再以此預測為基礎應用動態規劃模型計算績效指標(延滯)最佳化的號誌控制方案(考量所有可能的方案組合)，因此這個方法所需計算資源較大且必須輸入很多資料，在實務應用上較為繁複，因此後續相繼有改良的方法出現，例如：OPAC 2(sequential optimization)、OPAC 3(rolling horizon)與 OPAC 4(virtual fixed-cycle network version)，並且進行了實驗性的實證測試[16]，惟同樣的類似 RHODES，這個方法以學術研究為主，產品化的程度相對仍低。國內也有研究提出兩階段水平推移法(two stages rolling horizon)改良 OPAC[17]，可供學術研究參考。

2.1.6 都市交通號誌全動態控制邏輯模式

何志宏團隊研發「都市交通號誌全動態控制邏輯模式」方法[18]~[21]在國內已完成階段性開發多年且有相當的實證測試。其係以 SAST(Stepwise Adjustment of Signal Timing，林豐博)為基礎架構，經該團隊簡化與重新設計所開發，稱為「第三代電腦化全動態交通控制系統 COMDYCS-III 模式」，可應用於單一路口、幹道與路網型態。SAST 為一種二元決策(Binary Choice)的程序，其核心精神為：以四個決策準則進行

判斷，由績效指標的推估與計算，決定下一個△T 時段結束時，是否要繼續延長現行綠燈時段或是中止現行綠燈時段。其中的前三個判斷準則是屬於門檻情境判斷，分別為(1)競爭時相無停等車輛、(2)現行時相最大停等車隊長度大於設定門檻、(3)現行時相最大停等車隊長度大於所有競爭時相最大停等車隊長度且現行時相總停等車輛數大於所有競爭時相總車輛數，第四個判斷準則為真正的號誌時制最佳化與運作核心之所在，優化目標為總停等延滯最小化，評估接續的 n 個△T 所有可能的時相轉換組合(以上係參考文獻[20][21])。可以據此推想，這 4 個判斷準則與停等車隊的預測極其相關，甚至會影響 SAST 演算法的成效，相關研究亦著力於預測方法的改善、車流模型的改善、偵測器的佈設位置等[18]~[23]。COMDYCS-III、COMDYCS-3e[18]~[21]亦陸續加入新設計的門檻情境判斷準則與號誌時制最佳化準則，詳細內容可參考[20][21].

2.1.7 路徑為基礎(Path based)的即時交通號誌控制方法

曾明德與卓訓榮等人提出[24]~[27] 路徑為基礎(Path based)的即時交通號誌控制方法，其概念為依據壅塞區域往上游擴散的程度(必須事先設定壅塞程度判斷門檻)分別採取壅塞區域紓流、壅塞區域上游截流與分流三種策略。壅塞區域紓流策略的作法如下：

1. 以「旅次起訖調查或相關推估方法，確認壅塞區域與上游區域之路徑關係，以便進行主要路徑設定」。
2. 以平衡路徑紓解時間模式(如圖 2.1.7)決定各主要路徑之平衡綠燈時間(G)，這個模式的主要作用在於目標式，且必須輸入各主要路徑停等車隊紓解時間的預測值(g)。
3. g 的預測方法：以偵測車輛停等時間(S)結合衝擊波分析，推導連續兩週期偵測車輛停等時間的增減值(△S)與停等車隊紓解時間增減值(△g)的關係(在連續兩週期內的到達流量相同的假設下)，如圖 2.1.8 所示。其中 n 為主要路徑數。

目標式 $\min \left| \frac{G_1}{\Sigma G} - \frac{g_1}{\Sigma g} \right| + \cdots + \left| \frac{G_n}{\Sigma G} - \frac{g_n}{\Sigma g} \right|$

限制式
$$\Sigma G = G_1 + \cdots + G_n$$
$$\Sigma G \le \text{MaxPathCycle}$$
$$\Sigma g \le g_1 + \cdots + g_n$$
$$\min G_i \le G_i \le \text{Max}\, G_i \; 1 \le i \le n$$

圖 2.1.7 平衡路徑紓解時間模式

資料來源：[27]

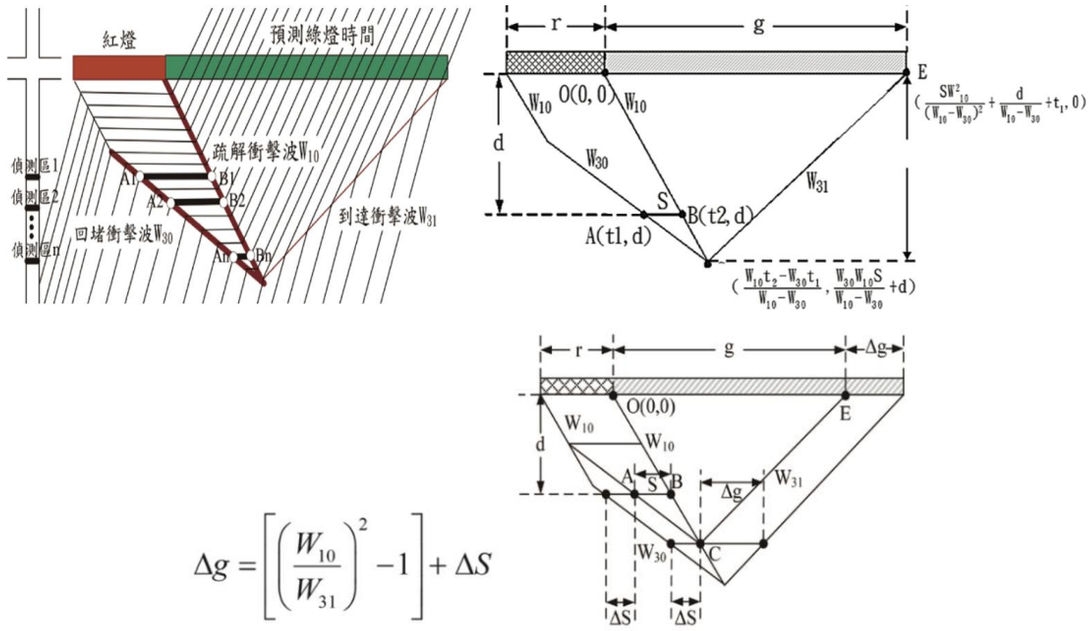

圖 2.1.8 主要路徑停等車隊紓解時間預測方法

資料來源：[27]

此外，上游截流策略可利用時差及縮短主要路徑的時相綠燈時間，用以減少車輛進入壅塞區域，上游分流策略則可於上游路口發布壅塞資訊並由員警協助導引車流於替代道路。此方法存在幾個課題如下說明。

1. 平衡路徑紓解時間模式與系統績效(例如：延滯)無關，以致所求得的解並無法確保系統績效的最佳化。雖然以數學方程式表達，但其意義並無科學理論支持(例如：常見的系統總成本最佳化)，僅能視為一種經驗法則(rule of thumb)。
2. 顯然的這個模式有多重解的情況(目標式＝0 的解有很多組，只要滿足 G 的佔比與 g 的佔比相同都會滿足目標式＝0)，但該模型並無法決定何組解的系統績效最好。
3. 而且僅考量路徑起點路口的某一方向的停等車隊紓解，且完全忽略下游各個路段、以及各個路口橫交道路的即時交通狀態，顯然過於簡化描述整體號誌路口系統的車流壅塞時空傳導特性，會與實際車流運作情形有顯著差異。
4. 圖 2.1.8 的衝擊波型態為理想情境下的理論值，在實務中多車道、多車種、異質駕駛者、非固定的上游到達率與下游紓解率的混合車流情境下，停等車隊紓解時間增減值(g 值)難以適用於實際狀況，致使實際成效難與模式計算相同。

5. 主要路徑之平衡綠燈時間(G)與該路徑下游路口的時相綠燈時間的關係難以建構，並且該模式並沒有考慮競爭路徑上的各個路口績效。另外各個路口、各個時相的綠燈時間如何產生亦沒有明確交代。在此種狀況下，時相綠燈時間與主要路徑之平衡綠燈時間(G)係依不同方式產生，並無法確保系統績效優化的方向。計算產生秒數的方式與系統績效的因果關係邏輯並不清楚，亦難以合理解釋。
6. 截流策略與紓流策略並未整合，無法確保系統優化的明確方向，最終容易落入人為決定的主觀認定，即截流造成上游績效變差下游績效變好，取捨難有明確標準。尤其在都會地區尖峰時段常態處於過飽和狀態，壅塞必然會造成在時間與空間上(特別是上游)的傳導，或沒有考量系統總成本的最佳化，截流將必然的陷於挖東牆補西牆的窘境。
7. 分流策略與截流策略同樣有分流路徑績效變差的取捨問題，同樣該模式並無法確保系統績效優化方向。並且分流策略非屬號誌控制措施，實不宜納入號誌控制模型，以免造成系統建模與分析更為複雜。

2.2 國內外人工智慧強化學習號誌控制

傳統適應性號誌控制方法大多需給定適當的假設條件，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。然現實生活中的號誌控制問題因涉及駕駛者的車流行為、型態多變的道路環境等因素，其複雜程度難以用簡化後的模型與過多的假設條件來詳加描述。又當遇到較有規模的路網範圍時，一旦控制路口數目增加，其問題複雜度與最佳化求解困難度皆急遽增加，如何在此狀況下提供一個最佳化的控制策略來最大化整體控制範圍的號誌運作績效，為實務上處理號誌控制問題的一大挑戰。

近年來受惠於巨量數據的產生與高速運算效能的提升，人工智慧領域的機器學習方法有了長足發展。而在此類以巨量資料來驅動的新形態方法中，強化學習(Reinforcement Learning, RL)方法常應用於處理控制類型問題。RL 乃是基於馬可夫決策過程的理論基礎下，透過獎勵或懲罰的機制，訓練機器從與環境互動過程的經驗中來學習如何做出一連串的決策動作，使得控制系統的績效最佳化。如果以適應性號誌控制問題來類比，即是希望透過 RL 來訓練機器，當要進行號誌控制時，其可以根據控制範圍內所能獲取到的車流狀態及交通資訊，來進行號誌秒數的決策，並透過此一隨時間進行的序列式決策過程，讓整體控制範圍內的車輛在這一段時間內有著最佳的通行效率。由此可見號誌控制問題性質與 RL 的

概念不謀而合，故如何應用 RL 來處理號誌控制問題，已成為智慧運輸領域中一項熱門的研究議題。

以下對 RL 方法進行簡介，並回顧該方法目前在號誌控制領域的相關研究成果。

2.2.1 強化學習方法簡介

RL 的學習架構主要是讓代理人(Agent)透過與環境(Environment)之間的互動，使其在不需任何先驗知識的情況下，自我學習該如何採取行動進而讓定義好的累積獎勵最大化(或累積懲罰最小化)。在此架構中，Agent 會根據環境狀態(State)採取某一動作(Action)，之後環境便會基於該動作變換至下一狀態並給予相對應的回饋獎勵(Reward)，而 Agent 便會利用所得到的獎勵來改善其目前採取動作的策略，如圖 2.2.1 所示。接著便是不斷地重複此一循環，讓 Agent 藉由跟環境互動的大量經驗來逐步學習最佳的動作策略，以達到長期下來累積獎勵最大化的目標。

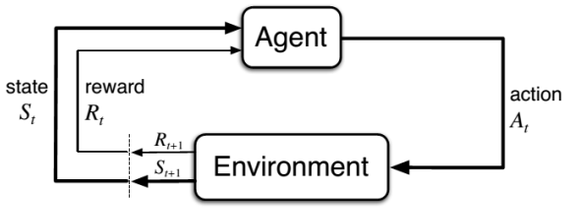

圖 2.2.1 強化學習架構圖

資料來源：[28]

由於 RL 可直接根據與環境互動的結果來進行學習，無需建立模型來對複雜的環境及其變化進行描述甚至是預測，此特性又被稱為"無模型"(Model-Free)方法。也因為 RL 具有此種特性，所以特別適合拿來求解系統環境複雜、高維度的控制類型問題，在應用上也更具有彈性及擴充性。此外，RL 訓練的目標是根據其所獲得的獎勵來決定，所以可針對求解的目標直接設計獎勵函數，讓 Agent 直接去學習出符合此目標的最佳動作決策，而無須透過其他間接的績效指標或模型去進行評估或求取近似的最佳結果。

但也因為 RL 需要盡可能地跟環境多做互動，累積足夠多的經驗後才能學習出最佳的動作策略，此類似於試誤法(Trial-and-error)的特性，勢必需要花費足夠多的時間與環境大量互動累績經驗才能達成。而在訓練 Agent 去優化策略的過程中，如何在探索(Exploration)新的動作與利用(Exploitation)既有有效動作上取得適當的平衡，也會是影響訓練效能的一

個重要因素。

2.2.1.1 基本強化學習方法

一般無模型的 RL 方法主要可分為三大類型，分別為：價值型(Value-based)方法、策略型(Policy-based)方法、混合價值與策略的 Actor-Critic 方法。以下將對這三種類型方法做一簡單概述。

1. 價值型(Value-based)方法

該類方法常用的概念是希望能找到一個價值函數，來預估當處在某一狀態 s 時，依據某個策略π去採取動作 a 的時候，能獲得多少期望的累積獎勵。這類型的價值函數又稱為 Q 函數或狀態-動作價值函數，其定義如下：

$$Q_\pi(s,a) = E_\pi\left[\sum_{k=0}^{\infty}\gamma^k r_{t+k+1}|s_t = s, a_t = a\right]$$

當中γ為折扣因子，通常介於 0 到 1 之間，而r_t代表時間點 t 所獲得的獎勵。

若 Agent 能精確估計出在每個狀態 s 下，採取各個動作 a 所能獲得的累積獎勵的話，那最佳的策略π即是根據不同的狀態 s，採取 Q 值最大那個動作 a，便可以獲得最大的累積獎勵，此即為最廣為應用的價值型 RL 方法：Q 學習(Q-learning)的演算概念[29]。而為了能精確的估計出 Q 函數，agent 需根據每次與環境互動後所得的經驗，也就是在不同狀態 s 下採取了某一動作 a 後所獲得的獎勵 r 及下一狀態 s’，來更新 Q 函數的估計值，其更新公式如下：

$$Q(s,a) = Q(s,a) + \alpha\left[r + \gamma\max_{a'}Q(s',a') - Q(s,a)\right]$$

其中α為學習率。

換個角度來看，Q 函數就是分別對應一組組狀態-動作配對(state-action pair)的值，故也常被稱為 Q 矩陣(Q-matrix)或 Q 表格(Q-table)。Q 學習方法常適用於狀態跟動作空間是離散且有限個集合的問題類型，該類型問題較易去對整體 Q 函數進行精確的估算。但相對地，該方法在連續型或是高維度的控制問題上，便會受到限制無法處理。

2. 策略型(Policy-based)方法

相較於價值型方法，策略型方法則是希望能找到一個最佳的策略函數，該函數會告訴 agent 在不同的狀態下該選取何種動作，便能使得長期

下來的累積獎勵最大化。若以π_θ代表策略函數，θ為函數內參數，此時要求取最佳策略函數最直接的方式，便是找到目標函數對θ的梯度，以此當作更新θ的方向，一步步去找到最佳的一組參數θ讓目標函數值最大化，意即有最高的累績獎勵值，該組參數θ所代表的策略函數便是最佳策略，而前述在更新θ所用到的梯度又稱為策略梯度(Policy Gradient)[30]。

由於策略型方法是去學習出一組較一般化的策略函數，而非像價值型方法要找到每一組狀態-動作對的函數值，因此較適合應用在高維度或連續型動作空間的控制問題上。在計算策略梯度上，常見方式會採用蒙地卡羅方式去進行疊代計算，但也衍伸出計算出的策略梯度變異度過高，以及要等系統進到終止狀態(Terminal State)或是回合(Episode)結束後才能真正獲得累積獎勵值，造成訓練效率較差等問題。

3. Actor-Critic 方法

由於價值型方法與策略型方法各有其應用上的局限性與訓練效率不佳等問題，為了克服這些限制，結合這兩種類型的 Actor-Critic 方法便因應而生[31]。在該方法中，Agent 需對 Actor 跟 Critic 這兩個函數進行訓練，當中 Actor 主要負責控制 Agent 如何進行動作的策略部分，Critic 函數則是負責估算及更新價值函數的部分。而當 Actor 策略函數參數要進行更新時，會透過 Critic 價值函數提供讓累積獎勵增加的更新方向；而 Critic 函數則是透過每次 Actor 跟環境互動所得到的獎勵值來更新對 Q 函數的估算。其演算架構流程如圖 2.2.2 所示。

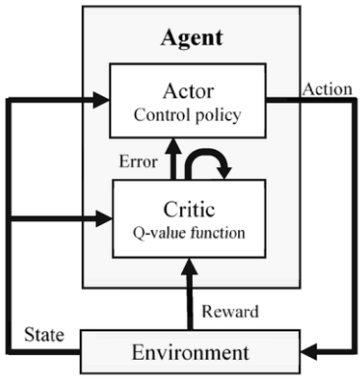

圖 2.2.2 Actor-Critic 演算架構圖

資料來源：[32]

2.2.1.2 深度強化學習方法

在基本 RL 方法中，通常用 Q 函數及線性近似函數去描述價值函數與策略函數。由於 Q 函數通常只適用在小量的狀態-動作空間上；而線性函

數在近似效果上還是有其極限存在，也無法有效學習出環境的特徵等資訊，所以在高維度及複雜的控制問題上，基本 RL 方法還是有其應用的限制。但在深度學習(Deep Learning, DL)方法出現後，可以結合深度神經網路(Deep Neural Network, DNN)、卷積神經網路(Convolutional Neural Network, CNN)、循環神經網路(Recurrent Neural Network, RNN)到基本的 RL 方法中，來對價值函數做更好的估計，或是讓策略函數從與環境的互動經驗資料中學習出有效特徵，進而能有效處理高維度及複雜的控制問題，此即為深度強化學習方法(Deep Reinforcement Learning, DRL)。以下將對常見的 DRL 方法進行簡單說明。

1. 深度 Q 網路

應用 DL 方法最直接的想法，便是將其用來取代 Q 函數，以改善其只能用在離散且小量的狀態-動作空間問題的限制，也就是深度 Q 網路方法(Deep Q-Network, DQN)[33]。DQN 方法使用了目標網路(Target Network)及經驗回放(Experience Replay)兩種技巧，讓 agent 的訓練更有效率及穩定。也由於 DQN 在 Atari 電視遊戲上的出色應用結果，使得 DRL 方法開始受到重視。

2. 雙層 DQN

為了改善 DQN 在更新 Q 網路時，總是選擇最大動作價值與目前狀態的動作價值的差值去進行更新，導致後續 DQN 所估計出的 Q 值常會因過度估計而發生高估的現象。對此，Van Hasselt 等人[34]提出雙層 DQN (Double DQN)方法，運用兩個 Q 函數各自獨立學習，讓一個 Q 函數選擇動作，另一個則用來評估動作，藉此避免前述問題發生。

3. 競爭架構 DQN

Wang 等人[35]為了能更有效率地去估計 Q 函數值，提出了競爭架構的 DQN (Dueling DQN)方法。在該方法中，Q 網路透過網路結構設計的方式，被拆解為只單純跟狀態相關的狀態價值函數 V(s)，與跟狀態及動作相關的優勢函數 A(s, a)兩部分，最後再合併成 Q 函數輸出。此方式可以強調出單純考慮狀態時，不同狀態所代表價值的高低，以及採取不同動作時對於價值函數的差異，這些特點使得其在估算 Q 函數值的效果上有顯著提升。

4. 示範式 DQN

而為了加速 DQN 方法的學習速度，Hester 等人[36]提出了示範式 DQN (Deep Q-learning from Demonstrations)方法，即是在訓練初期先讓 agent 以較少數量的專家示範資料進行監督式學習，使其能模仿專家行為並提升訓練速度。後續再逐步讓 agent 與環境互動，慢慢減少專家示範資料的數量，期望 agent 能再度藉由與環境互動的實際經驗與獎勵，學習到超越專家示範資料的策略。

5. DDPG

前述的 DRL 方法大多是基於 Q 學習之上，再加入深度學習技術後衍伸而來的方法。而後續將介紹的 DRL 方法，大多是屬於結合了 Actor-Critic 方法與深度學習的類別。

深度確定性策略梯度(Deep Deterministic Policy Gradient, DDPG)方法[37][38]，即是將 Actor-Critic 方法與深度學習進行結合，且適合處理連續型動作空間這類高維度控制問題的方法。DDPG 中的 Actor 跟 Critic 各自是一個神經網路，當中的 Critic 一樣會透過 Actor 與環境互動所得到的經驗，去對 Critic 的價值網路參數進行更新，使其能對 Q 值有更佳的估計；而 Actor 一樣也會從環境互動經驗中去計算策略梯度，以更新其策略網路參數值，只是此處所計算的策略梯度是確定性的，而非原本 Actor-Critic 方法中的隨機性策略梯度，以此來解決策略梯度方法中變異性過大的問題。此外，在 DDPG 中對於 Actor 及 Critic 也使用了目標網路及軟更新(Soft-update)的技巧，讓神經網路的更新較為緩和，也使得學習更為穩定易收斂。

6. A3C

為了讓 Actor-Critic 方法的學習效率更高，Mnih 等人提出了異步架構的優勢 Actor-Critic (Asynchronous Advantage Actor-Critic, A3C)方法[39]，使 RL 能透過類似平行計算的架構，去充分利用多 CPU 與多 GPU 的運算能力。在 A3C 的架構下只有一個 Critic 負責學習價值函數，但會有多個具有不同參數的 Actor 工作者，各自獨立地對環境去進行探索跟學習，並在不同的時間點將各自的策略梯度資訊回傳給主要的 Actor，讓其去對策略參數進行更新後，再將參數複製到該 Actor 工作者的策略網路中。由於主要的 Actor 可以藉由多個工作者去對環境進行探索與互動，同時匯集各工作者的策略梯度資訊整合成一個更佳的策略梯度來對本身的參數進行更

新，所以 A3C 方法有著更好的學習效率，收斂效果也更出色。

7. A2C

相較於 A3C 方法中各個 Actor 工作者有各自不同的參數，Minh 提出了各工作者都有著相同參數，並且每次都同步更新參數後才開始蒐集與環境互動經驗的優勢函數 Actor-Critic (Advantage Actor-Critic, A2C)方法[40]。又 A2C 通常被認為是 A3C 方法的同步且確定性的版本。

8. TRPO 與 PPO

一般策略梯度方法雖然可使新舊策略在參數空間中保持接近，但是，即使參數空間中看似很小的差異，卻可能在行為表現上產生非常大的差異。因此，一個不佳的參數更新可能會導致策略的績效崩潰。

TRPO[41]與一般的的策略梯度不同，透過加入 KL-Divergence 形式的限制式(KL-Divergence 類似於概率分佈之間距離的度量)改善了這個問題，訓練時能快速地提升績效表現。而 PPO[42]也沿襲 TRPO 的精神：如何才能使用當前的數據對策略採取最大可能的改進步驟，且不會走得太遠導致績效崩跌。TRPO 使用複雜的二階方法解決這個問題，而 PPO 則是透過在目標式作調整去達到此目標，使新舊策略不至於差距太大。PPO 的優勢在於實施起來比 TRPO 簡單，且其績效表現至少與 TRPO 一樣好。OpenAI 後續開發的演算法皆以 PPO 為指定比較對象，著名的 Dota2 人工智慧 OpenAI Five[43]也是以 PPO 為核心算法作訓練，足見此方法表現是受到肯定的。

2.2.1.3 多代理人深度強化學習方法

當要應用 DRL 到多路口號誌控制問題上的時候，除了前述提到如何應用 DRL 方法去訓練出一個做出好的控制策略的 Agent 外，另一個重點是如何讓多個 Agent 去互相合作做決策，使得大範圍路網的運作績效最佳，這類型問題又稱為多代理人深度強化學習(Multi-Agent Deep Reinforcement Learning, MADRL)問題。

在處理多路口號誌控制類型的 MADRL 問題時，主要考慮的困難點有下列兩項：首先是在多個 agent 的狀況下，對某一個 Agent 而言，它所要互動的環境還包含了除了它以外的所有 agent。所以當它執行動作時，它所要觀察的環境變化不單只有該路口的狀態，也包括了其他 agent 的行為變化。而且當它在進行學習更新策略參數時，其他路口 agent 的策略參

數也同時在學習並改變，這會使該 Agent 要學習的狀態變得更加複雜。第二項是由於多路口號誌控制問題的目標為整體路網的績效最大化，即此問題要考慮的狀態及動作空間，是所有路口 Agent 的聯合狀態空間與聯合動作空間。因此多路口號誌控制問題的維度及複雜程度，會隨著路口數量成指數性增長，也讓大範圍路網的號誌控制問題更難以處理。

而針對上述兩項多路口號誌控制問題主要的困難點，MADRL 通常會採取訊息溝通、協調機制或是調整價值網路及策略網路架構等方式來加以克服。

2.2.2 應用強化學習於號誌控制

在應用強化學習方法到號誌控制問題上時，大致上以該問題中所包含的 Agent 數量來分為兩類，一類是單一 Agent 的 DRL 應用，主要用在處理單一路口或是路口數極少的號誌控制問題上；另一類則是多個 Agent 的 MADRL 應用，即是多路口號誌控制問題，後續也將以此兩種分類進行整理介紹。此外，目前既有的文獻中，大多還是使用交通模擬軟體來驗證 DRL 的應用性與績效，鮮少在真實場域中實施與驗證績效的研究。

2.2.2.1 應用深度強化學習於單一路口號誌控制

在應用單一 Agent 的 DRL 方法至單一路口號誌控制問題上時，DQN 及其相關變形的方法最常被使用，但也由於其方法上的限制，所需要狀態及動作空間都要是離散的。而常用的離散動作可分為兩種，一是在特定時間點上決定是否切換時相，當中又可再分為固定時相順序[45]~[48]與時相無順序性[49]~[51]；另一是在週期結束時對於下一週期中之特定時相進行長度調整[52]。

Genders 等人[51]一開始將 DQN 方法應用在號誌控制問題時，使用了 CNN 做為深度網路來近似 Q 函數值，而狀態輸入則是用類似於圖片畫素的方式來表示交通狀態，在 SUMO 車流模擬環境中對單一路口進行控制。Choe 等人[21]則是以 RNN 為深度網路應用至 DQN 方法中，研究發現相對於使用 CNN 的 DQN 方法，RNN 在旅行時間的減少上表現較佳。Wan 等人[54]提出了動態計算折扣因子的方法，將其應用於 DQN 方法中，並在模擬軟體中針對單一路口問題與定時時制績效進行比較。Shabestary 等人[55]則是在 DQN 方法中把累積延滯的差值當作獎勵值，並採用了 8 種不同號誌時相做為動作空間。相對於[55]，Wei 等人[56]採用了另一種獎勵函數的變化，該獎勵函數將所有車道的車隊長度總和、停等時間總和、

號誌狀態、前次動作通過路口總車輛數與旅行時間總和等指標都納入獎勵函數中。

在 DQN 變形的 DRL 方法應用上，Liang 等人[52]採用了結合雙層 DQN 與競爭架構 DQN 的 double dueling DQN 方法，並應用了經驗回放(Experience Replay)的技巧來增加 agent 訓練效率。該研究中也將動作空間調整為決定下一週期的時相長度，動作為調整綠燈時間為延長 5 秒或減少 5 秒，最大不超過 60 秒。而在狀態空間的選擇上，則是採用了離散化後的車輛位置與車速做為輸入狀態。

相較於 DQN 類型的方法，在號誌控制問題上應用 Actor-Critic 類型 DRL 方法的研究則少了許多。Mousavi 等人[57]應用了 Actor-Critic 方法於單一路口的號誌控制問題上，其中狀態的部分是採用模擬軟體在連續時間點擷取到的圖片當作輸入，期望神經網路可以從中學習出車輛位置、車隊長度、車輛速度等特徵；而在動作的部分，則是採用離散的 2 時相做為切換動作的空間集合。透過在 SUMO 軟體上的測試發現，相較於 DQN 方法來說，Actor-Critic 方法的收斂過程較為平滑且穩定。

而 Genders 等人[58]則是採用了 A3C 方法處理此類號誌控制問題，其針對了三種不同類型的輸入狀態進行比較，分別為：各車道的佔有率與平均速度、各車道的密度與停等車隊長度、車輛位置與速度，當中車輛位置的狀態資訊也是透過圖片畫素的方式來取得。透過模擬軟體驗證後發現，低解析度的輸入狀態(佔有率與平均速度)與高解析度輸入狀態(個別車輛位置與速度)在控制績效表現上差異並不大。

國內也有數篇研究在探討如何應用 DRL 方法來處理號誌控制問題，許添本等人[59]以 CNN 來建立 DQN 中的 Q 函數網路，並採用了結合雙層 DQN 與競爭架構 DQN 的 double dueling DQN 方法，以及經驗回放技巧來訓練 Agent。其輸入狀態包含了車輛位置、速率以及當前號誌時相狀態；動作上則是在固定時相順序下時相切換與否做為離散動作空間集合；獎勵函數則採用了車輛停等時間及路口通過量所組成之加權指標。該研究以 VISSIM 模擬軟體做為 Agent 訓練及驗證的環境，結果顯示學習後的 Agent 在績效表現上皆優於定時時制，且經過不同情境之測試，該 Agent 確實具有應變車流變化之能力。

另許添本等人[60]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 方法來處理號誌控制問題。該研究以最

佳化的定時時制及全觸動的時制來當成示範，建構提升 Agent 訓練效率之示範式深度強化學習模型。該模型會依據當下的車輛狀態執行切換或延長時相的決定，其資訊包含位置及速度並以 5 公尺為單位長度分割，透過類圖像化之格位狀態方式做為輸入，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。結果顯示示範式 DQN 方法能有效縮短所需訓練回合數，且最後可訓練出較示範控制方法績效更佳的 Agent。

胡大瀛等人[61]則是針對 DRL 法中，不同獎勵機制對於 Agent 訓練過程與結果的影響進行探討。該研究利用常見的交通績效指標設計了三種不同的獎勵機制。

- 車隊等候長度

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；若綠燈方向停止線前的車輛數小於紅燈方向的車輛數，則環境懲罰號誌代理一個負值，表示此動作策略導致更多的用路人於紅燈方向等待，效益不彰。

- 路口通行量

於號誌代理執動作開啟設置的時相秒數內(包含基本最小綠與延長的秒數)，統計進入十字路口的車輛數，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，表示此動作策略能夠提供更多的用路人通行路口，提升整體效益；若路口通行量小於紅燈方向停止的車輛數，則環境懲罰號誌代理一個負值，表示此動作策略使更多的車輛停止等待，降低路口的效益。

- 車輛停等時間

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。

透過雙層 DQN 方法分別訓練三個不同獎勵目標的 Agent 模型。經模擬軟體驗證後，證實此 DRL 方法確實能夠有效提升路口效益，大幅降低車輛於路口的平均停等時間，且不同獎勵機制設計確實會影響 Agent 學習的方向，雖然各模型皆能提升路口整體的效益，但彼此間存在著明顯的差異。

2.2.2.2 應用多代理人深度強化學習於多路口號誌控制

如 2.2.1.3 節中所提到，在應用 MADRL 到多路口號誌控制上的研究，可應用訊息溝通、協調機制或是調整價值網路及策略網路架構等技巧來加以克服，以下將主要的相關研究整理如後。

最直接將 MADRL 應用到多路口號誌控制問題的想法，便是將每一個路口各自獨立用 DRL 訓練一個 Agent，並透過 Agent 間相互溝通訊息，讓各個 Agent 有辦法利用鄰近 Agent 傳來的訊息去做到協調控制。而常用來傳遞的資訊有以下幾種，如：路口下游的狀態資訊[62]~[66]、鄰近路口的所有狀態資訊[66][67]、鄰近路口的隱藏狀態資訊[68]等。

又由於將各路口視為獨立 Agent 去進行訓練的 MADRL 方法收斂較不穩定，[57]提出了多代理人的 A2C (Multi-Agent A2C)方法，並引入兩種技術來改善此缺點。第一種是在 Agent 輸入狀態中加入鄰近 Agent 的策略資訊，讓它能對鄰近 Agent 的車流狀態以及如何去進行協調策略有更多瞭解，此資訊又稱為指紋(fingerprint)。第二種是在目標函數中引入空間折扣因子，依距離遠近程度去弱化鄰近 Agent 的獎勵值及狀態值，當該鄰近 Agent 距離自己越近，其獎勵值與狀態值的權重相對較高，影響性也更大。

對於以調整價值網路及策略網路架構的方法中，Tan 等人[69]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[70]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。

2.3 國內人工智慧號誌實作案例

以下摘要說明國內在人工智慧應用於號誌控制實作案例。

2.3.1 桃園市大園區AI智慧號誌控制試辦計畫

桃園市於 108 年首先在大園區建置 AI 號誌控制系統實證場域，地點位於國道二號大園交流道周邊中正東路 5 處路口，詳細場域範圍如圖 2.3.1 所示。該路段相臨國家門戶桃園國際機場且鄰近大園工業區，為相連國道二號與大園工業區重要幹道，全日大型車、機車等各式車輛眾多且設有時段性調撥車道，交通環境相對複雜。

而在 AI 號誌控制系統建置前，該路段東側平安路、衡湳路、東向匝道 3 處路口因位置十分靠近，使得路口間幹道儲車空間相對不足，常有支道左轉車輛溢流導致幹道綠燈紓解效率不彰。另因路段邊界上游路口需求量變動幅度大，在原定時時制計畫下的固定續進綠寬無法針對變動的需求量做因應，造成綠寬帶尾端常常利用率不高，綠燈秒數白白浪費等情形。模擬測試結果顯示 AI 號誌控制可改善系統總停等延滯約 21%、減少幹道旅行時間約 15%。經過三週的事前事後實測(圖 2.3.2)，結果顯示 AI 號誌系統可減少用路人平均停等延滯 9 秒鐘(19%)、西向幹道旅行時間 16 秒(13%)、東向旅行時間 26 秒(13%)。

圖 2.3.1 桃園市大園區 AI 智慧號誌控制試辦計畫實證場域範圍

資料來源：「桃園市大園區 AI 智慧號誌控制試辦計畫」

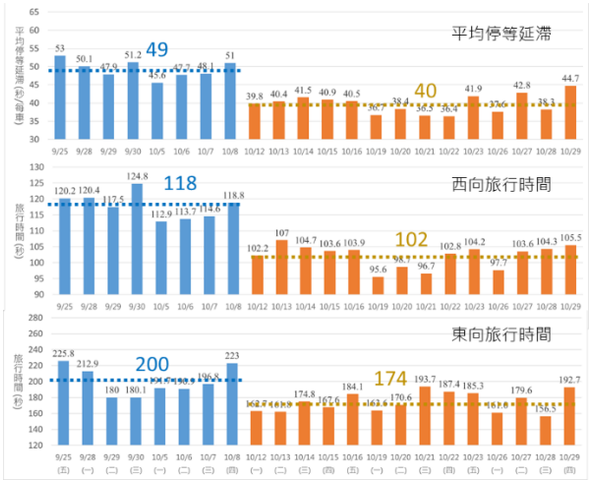

圖 2.3.2 桃園市大園區 AI 智慧號誌控制試辦計畫績效

資料來源：「桃園市大園區 AI 智慧號誌控制試辦計畫」

圖 2.3.3 可見到中正東路-東匝的週期隨幹道車流量增減而變化。除此之外，幹道綠寬帶隨車流而逐步增加(圖 2.3.4)，顯示鄰近路口間可協同控制產生動態綠寬帶的效果，確保幹道續進順暢，有效運用寬帶秒數。針對原本支道左轉產生的溢流問題上，由於 AI 號誌控制代理人在決定綠燈秒數時會將鄰近路口狀態納入考慮，因此能給定適當的支道綠燈秒數不致使溢流發生。此外， AI 號誌控制另一特點便是能根據不同車流狀況去提供變動的幹道續進寬帶，相較於原本定時時制固定的綠燈寬帶來說，動態綠寬帶可有效利用寬帶秒數，減少因車流量增減時綠寬帶不足或尾端無效率的狀況發生。

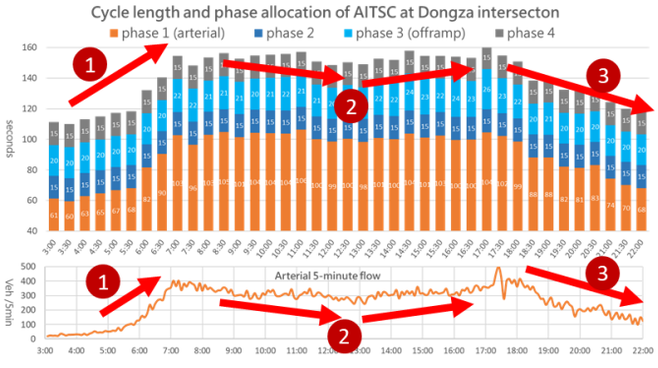

圖 2.3.3 AI 號誌控制與現行時制幹道東向綠寬帶比較圖

資料來源：「桃園市大園區 AI 智慧號誌控制試辦計畫」

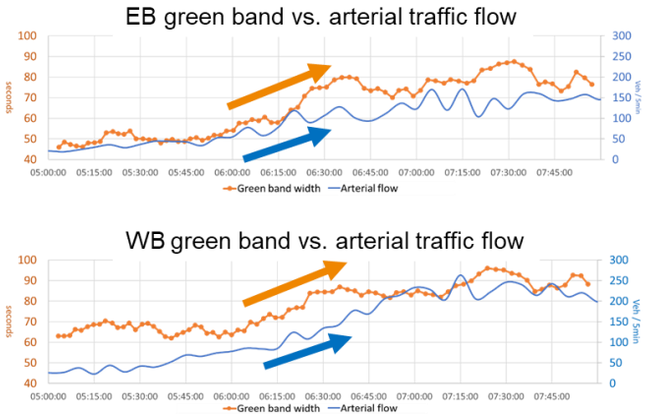

圖 2.3.4 AI 幹道東西向綠寬帶 vs 流量圖

資料來源：「桃園市大園區 AI 智慧號誌控制試辦計畫」

2.3.2 桃園高鐵聯絡道暨周邊路網AI號誌控制示範計畫

青埔地區為桃園市近年來發展最為快速的區域之一，並且由於高鐵所建立之北部一日生活圈，使得本區域人口快速成長，交通需求日益增加。國道 2 號大竹交流道為桃園青埔地區重要交通樞紐，大量的交通需求造成台 31 線嚴重壅塞，嚴重影響桃園高鐵站周邊交通水準。桃園市有鑑於 108 年度大園區 AI 號誌控制系統建置成效良好，故於 109 年辦理本案，期望在未來 4 年期內逐步將高鐵站周邊路網導入人工智慧 AI 號誌控制方法，而第一期計畫則實作於省道台 31 線鄰近國道 2 號大竹交流道至桃園高鐵站間的兩個重要號誌化路口。

本案場位於桃園大竹交流道南側的台 31-中正東路口及台 31-大竹南路 599 巷 2 處號誌化路口(圖 2.3.5)。在建置 AI 號誌控制系統前，該路段在台 31 線幹道北向車流需求量高，但受限於大竹交流道上匝道容量不足，故導致從匝道口一路往高鐵特區回堵壅塞。而幹道南向車流在中正東路二段路口易受到左轉車輛溢流之狀況，導致從高速公路往高鐵方向之主要車流需求受到阻礙。在 AI 號誌控制系統建置上線運作後，通過兩週的事前事後測試(圖 2.3.6)，平均停等延滯在平日減少 3.2 秒(11.6%)、假日減少 6.2 秒(20.1%)。南向幹道旅行時間在平日減少 17.5 秒(12.8%)、假日減少 15.1 秒(11.6%)；北向旅行時間平日減少 25.8 秒(13.1%)、假日減少 43.6(17.4%)。

圖 2.3.5 桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫場域範圍

資料來源：[28]

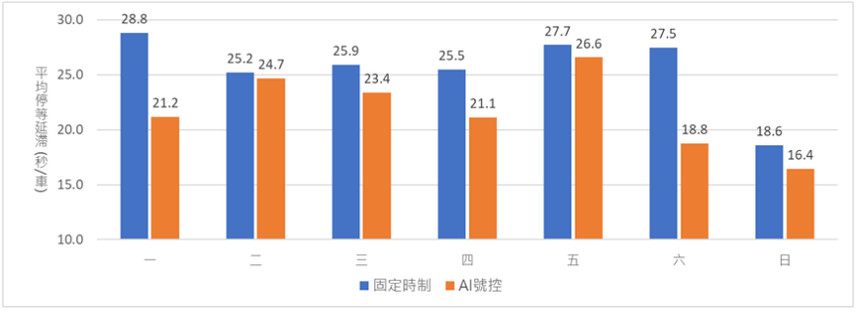

圖 2.3.6 事前事後週內日之平均停等延滯

資料來源：[28]

2.3.3 桃園高鐵聯絡道暨周邊路網AI 號誌控制示範計畫第二期

桃園市交通局於 109 年導入人工智慧 AI 號誌控制方法，實作於省道台 31 線鄰近國道 2 號大竹交流道至桃園高鐵站間的兩個重要號誌。前期計畫中，以影像式 AI 車輛偵測器蒐集路口即時交通狀態，並輸入 AI 號誌控制決策模型進行即時號誌時制運算來提升該區域路口運作效率。前期計畫完成建置後持續運作，該系統除每日自動記錄、監控 AI 適應性號誌控制運作狀態之外，並且提供每日號誌運作績效值(系統停等延滯)，有助於機關永續監管路口績效變化，提升管理功能。桃園市交通局將於 111 年延續前期計畫，於省道台 31 線大竹交流道至桃園高鐵站間號誌化路口擴充建置人工智慧 AI 號誌控制系統，並且整合前期計畫 2 處路口，形成準路網式 AI 號誌控制型態，實施範圍如圖 2.3.7 所示。

圖 2.3.7 桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫第二期範圍

資料來源：[87]

2.3.4 高雄港聯外交通改善-區域性交控及大貨車行車安全提升計畫

因應洲際貨櫃中心因二期啟用之移轉量及成長量，將造成台 17 線瓶頸路段尖峰小時交通量由現況大幅成長，加重台 17 線交通負荷，因此擬針對港區聯外道路交通量變異較大之路段，利用偵測設備蒐集即時交通資料，建置 AI 智慧化交通號誌系統。 藉由大數據資料訓練出的 AI 控制策略，將能因應不同交通型態去即時自動調整號誌時制，增加幹道續進綠寬帶，及提升號誌路口整體績效，降低路口停等延滯，以紓解因為交通量變異造成定時時制無法有效率紓解之情況。

「沿海二路中林路」及「沿海三路 南星路」此二處路口皆位於洲際貨櫃中心聯絡高雄市區道路必經 路口，同時轉向動線較為複雜，因此為重點改善路口。同時為配合台 17 線頭尾兩端瓶頸路口的智慧控制，將台 17 沿線及鄰近路口等共計 16 處號誌化路口皆納入 AI 智慧控制之範圍內，期望藉由 AI 控制的方案達到區域績效最優之目標。該計畫智慧化號誌控制範圍如圖 2.3.8 所示。

圖 2.3.8 高雄港洲際貨櫃中心聯外交通改善計畫場域範圍

資料來源：[88]

根據模擬測試成果，AI 號誌控制代理人在 6 個測試情境下的系統總延滯較原固定時制平均減少 23%，各情境之停等次數亦有改善，特別在尖峰時刻改善效果更為顯著。其結果顯示 AI 號誌系統可減少約 10%-11%的系統平均停等延滯，其中中林路口減少 6%-9%、南星路口減少 11%-13%的平均停等延滯。

2.3.5 應用人工智慧技術進行交通數據蒐集暨號誌控制之研究

本所於 109 年以透過 AI 技術蒐集交通數據的角度出發，探討如何將所蒐集到之資料進一步應用於 AI 號誌控制上，並挑選台中市太平區「樂業-十甲東」、「樂業-東英」2 處路口做為實驗場域，如圖 2.3.9 橢圓形匡列區域所示。而該路段在既有定時時制下，於尖峰時段的號誌週期秒數不

一致，以致於當往市區方向車流量較多時，便容易產生車流回堵情形。

圖 2.3.9 應用人工智慧技術進行交通數據蒐集暨號誌控制研究範圍

資料來源：[89]

該計畫為避免強化學習在訓練過程中需耗費大量試誤的探索時間才會收斂的問題，改以仿真學習方式來訓練代理人。該方法會先由時制最佳化分析軟體 PaSO 產生在不同的車流量及時段下的號誌時制計畫，以此當作代理人需模仿的號誌決策目標，期望訓練代理人能自行根據不同的車流量及時段下，做出與時制最佳化軟體相同的號誌時制結果。

後續將完成學習後之 AI 代理人，於現場進行實際運作，並針對事前及事後各進行為期兩週的績效蒐集與分析。其結果顯示，在星期一晨峰部分，主要路徑旅行時間改善 30%；星期五昏峰部分，主要路徑旅行時間改善 7%；一般日晨峰部分，主要路徑旅行時間改善 16%；一般日昏峰部分，主要路徑旅行時間改善 10%；星期六離峰部分，主要路徑旅行時間改善 4%；星期日離峰部分，主要路徑旅行時間改善 4%。

2.4 車聯網號誌控制研究與案例

車聯網應用泛指汽車對各種物體通訊，是車輛與外部環境的連結，各個交通實體，包括車輛、交通基礎設施及任何道路使用者，都可以經由周遭的其他交通實體所提供之訊息而受益；進而延伸出 Vehicle-to-Vehicle (V2V)車間通訊、Vehicle-to-Infrastructure (V2I)車與交通基礎設施通訊、Vehicle-to-Pedestrian (V2P)車與行人通訊以及 Vehicle-to-Network (V2N)車與核心網路通訊等多種形式，如圖 2.4.1 所示。

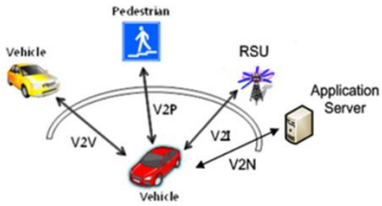

圖 2.4.1 車聯網之通訊類型

車聯網的 V2X 通訊應用包含以下四種形式：

1. Vehicle-to-Vehicle (V2V)車間通訊:

以廣播為主要傳送方式，在不同使用者裝置(UE, User Equipment)間交換 V2V 相關應用資訊。讓車輛之間能即時互傳訊息，了解彼此動態以避免碰撞發生。車輛間可以直接通訊；或者受限於通訊距離也可以透過支援 V2V 服務的基礎設施，如路側裝置(RSU, Roadside Unit)或是應用伺服器等來轉送訊息。以圖 2.4.2 前方碰撞預警應用為例，該應用警示駕駛即將發生與同車道及相同行駛方向的前車發生追撞。使用車間通訊可以減少甚至避免碰撞造成的傷害。前車週期性的廣播自己的位置、速度、加速度、行車方向等資訊。前車經計算周遭車輛行車資訊後發覺同車道後方即將發生碰撞，將此結果反應在廣播訊息中，後車接收到前車廣播出來的警示訊息後提醒駕駛採取相對應的措施來避免可能發生的追撞。

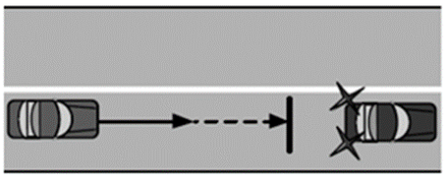

圖 2.4.2 前方碰撞預警應用

2. Vehicle-to-Infrastructure (V2I)車與交通基礎設施通訊

支援 V2I 應用的使用者裝置與路側裝置互相傳送應用層資訊。V2I 使車輛及路側裝置做為點對點網路中之通訊節點，互相傳遞有用訊息，特別是與交通壅塞及危險事故有關之訊息，大幅提升了行車安全與效能。以圖 2.4.3 彎道速限警示應用為例，一個支援 V2I 服務的路側裝置架設於彎道之前，週期性的廣播包括位置、彎道速限、坡度、路況等資訊的訊息。裝設支援 V2I 服務裝置之車輛進入該路側裝置的通訊範圍內，便開始接收到其所廣播的訊息；經計算車輛速度、加速度等資訊後警示駕駛採取對應措施，以達提醒駕駛以合適的速度過彎之綜效。

圖 2.4.3 彎道速限警示應用

3. Vehicle-to-Network (V2N)車與核心網路通訊

此通訊形式是指使用者裝置與服務實體彼此透過長期演進技術 LTE (Long Term Evolution)網路互相溝通，V2N 應用將相關資料傳輸至核心網路之後台應用伺服器進行資料儲存、使用與交換。由於路側裝置具有連網能力，以遠距診斷車況並提供及時維修通知為例，如圖 2.4.4 所示，當一輛已註冊該服務的汽車在進入支援 V2N 服務之路側裝置的通訊範圍後，開始回報目前功能狀態給遠端診斷中心並接收及時維修通知。車輛維修中心位於車輛服務中心內，需要週期性的獲得並分析車輛資訊，依據分析結果提供車主相關維修保養建議，此舉可優化車輛檢測並降低車輛功能失效的風險。支援 V2N 服務的車輛內建診斷裝置蒐集車內相關感測器的資料，包括引擎、傳動系統、穩定控制系統、安全氣囊、噴射系統、防鎖死煞車系統、胎壓等資訊，當車輛經過支援 V2N 服務的路側裝置時會將所蒐集之資料傳送給該路側裝置，路側裝置將資料傳送給汽車維修中心進行分析及診斷。若檢測到有零件需要維修或更換，汽車維修中心會將檢測資料、最接近的維修地點、維修的急迫性等資訊透過電子郵件或是支援 V2N 服務的裝置通知車主，車主可依此通知及時進行維修，並可要求車輛診斷中心刪除所儲存的車輛資料。

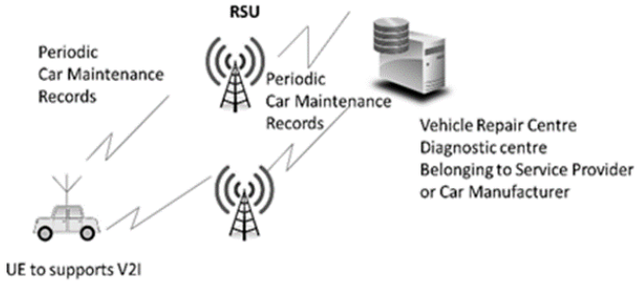

圖 2.4.4 遠距診斷及時維修通知應用

4. Vehicle-to-Pedestrian (V2P)車與行人通訊

支援 V2P 應用的使用者裝置傳送應用層資訊，此資訊可被支援 V2X

服務的車輛廣播以對行人提供警示，或是由行人端支援 V2X 服務的使用者裝置向路過車輛廣播。車輛與行人間可直接交換 V2P 相關應用資訊；或者受到傳輸距離的限制，透過支援 V2X 服務的基礎設施來互傳資訊。如圖 2.4.5 所示，在行人附近，當一輛支援 V2X 服務的汽車即將穿越人行道或交叉路口，車上的使用者裝置週期性的傳送 V2P 通訊訊息，訊息中提供了該車輛的速度及方向等行車資訊。行人的裝置接收到附近車輛所傳送的 V2X 訊息後，得知周遭車輛的存在情況，計算碰撞風險並以視覺、聽覺、震動等方式提供必要的警示，使穿越路口的行人可以採取預防措施，以提前避開造成行人的傷害。

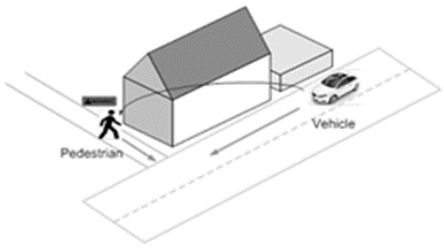

圖 2.4.5 行人碰撞警示應用

在本計畫針對號誌控制應用的相關研究，著重於 V2I 的相關技術應用與 RL 號誌模式探討。而關於其他車聯網的技術應用則不在本計畫的研究範圍內。以下整理關於 V2I 技術應用於號誌控制的相關研究文獻與案例。

交通號誌控制技術發展超過 100 年以上的歷史，而隨著各式科技的進步，在號誌控制方法上的應用也推陳出新，其中聯網車技術即是以 vehicle ad hoc network 為基礎架構所形成的一個 ITS 應用領域，這些通訊技術進展幫助聯網車顯著增強車輛、基礎設施和移動設備之間的數據交換能力。經由 V2V 與 V2I 的通訊技術，將可提供較傳統偵測器更微觀且即時的車輛資訊，例如：車輛位置、車輛速度、行車方向、加減速度、車種等資訊，多數文獻將這些資訊經過處理後成為各種號誌控制方法計算時制的輸入資料[72]~[73] [74]。

Guler 等人於 2014 年提出一種用於兩條單向街道的演算法[75]，其假設 CV 在環境中的使用率，藉以分析使用 CV 資料進行號誌化路口控制的量化價值（在延滯節省方面）。Feng 等人在 2015 年應用 CV 資料，最佳化號誌時制順序與時相秒數，成為一套車聯網應用適應性號誌控制方法[76]。而後又在 2016 年使用軌跡數據開發了一個適應性號誌控制框架，該框架考慮了猶豫區間(dilemma zone)、多時相號誌優先級別和號誌續進[77]。

Talukder 等人則於 2021 年探討裝機率對於號誌控制應用的影響程度，並發展了將車輛軌跡數據與傳統交通號誌控制器結合使用的方法，即使 V2I 資料的有限或不存在，亦能夠改進號誌化路口的績效[78]。

儘管使用車聯網資料在提高交通號誌效率方面具有巨大潛力，但受限於裝機率與環境建置的進度，全面應用車聯網資料進行號誌控制的進程仍有困難[79]。因此更多關於車聯網技術的應用是將號誌資料送回 CV，由車輛自主判斷適當的加減速行為以達到更節能的交通運作情境。如 Yan 等人及 Lin 等人皆在 2017 年提出基於軌跡的行駛速度最佳化策略，可以大幅度地減少車輛旅行時間並避免壅塞[80][81]。惟本計畫研究範疇有限，將不探討由 CV 資料回饋給駕駛者，進而影響駕駛決策行為的研究議題。

美國 ITS 業界看好自駕車與車聯網在未來的發展性，同時鑒於車間通訊技術的逐步成熟，美國交通部於 2015 年至 2020 年進行兩階段的 CVPD (Connected Vehicles Pilot Deployment)實驗場域建置計畫，其中第一階段的建置計畫包括紐約市、坦帕市以及懷俄明州。其中與號誌控制相關的應用屬坦帕市所實施的公車優先號誌系統[82]，其實施範圍包括市中心 20 處號誌化路口，其位置可參考圖 2.4.6。

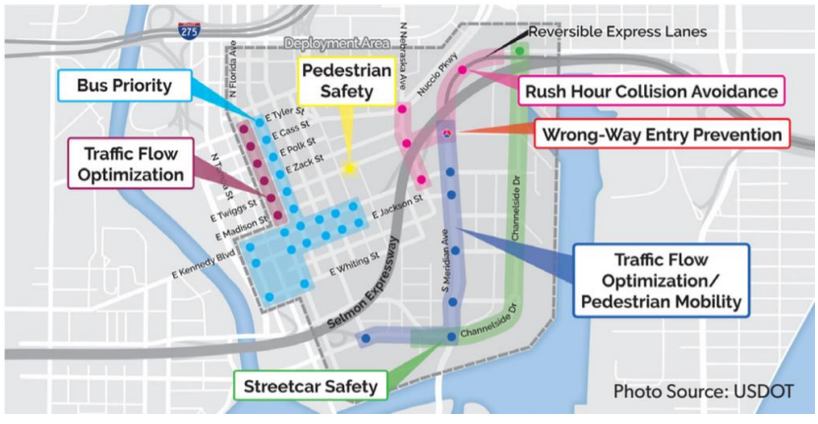

圖 2.4.6 坦帕市 CVPD 計畫範圍與其應用項目

資料來源：[82]

市中心的交通壅塞經常會導致市區公車延誤到達停靠點時刻。在此計畫中，營運單位為 10 輛市區公車配備了能夠與既定路線上所有交通號誌設備通信的車載系統。當公車落後於當班次的時刻表時，即會發送信號給予交通號誌控制器，並且給予適當的號誌優先秒數，以利公車優先通過路口，追上原定時刻表。此外，整個計畫的車聯網交通數據，用以評估既有號誌時制績效，並可以進一步離線分析改進號誌時制秒數，持續讓城市交通號誌運作績效精進。這部分國內亦有類似的緊急車輛、公

車結合號誌化路口優先通行的研發計畫，例如高雄市[83]、臺南市[84]等。

綜觀而論，研究團隊認為這類研究不應僅只是將 CV 資料轉化成與車輛偵測器資料同質後，再做為既有號誌控制方法的輸入資料。若從號誌控制方法論的角度出發，則應用 CV 技術所得到車流資訊是否能更為直觀的做為號誌控制方法計算時制的輸入資料，進而得到更優化的號誌控制績效，應該是比較具有原創性的做法，例如 Wang 等人[85]結合 RL 與 CV 技術所得到的直觀性微觀車流資料，應用於號誌控制與駕駛行為決策的研究，本計畫在車聯網場域所構建的 AI 號誌控制方案將考量此類似的作法，分析探討 CV 微觀車流資訊對 RL 訓練時制決策函數與運作績效的影響。

2.5 小結

適應性交通控制方法就是要改善固定號誌時制無法因應「交通狀況變異」，以致系統績效不佳的缺點而發展出來的，交通狀況的變異反映兩個適應性號誌控制問題的重要本質：系統狀態的不確定性(system state with uncertainty)與複雜的車流動態性(complex traffic dynamics)。

例如：多數的號誌控制方法都致力於構建描述交通狀態或運作的車流模型，並據以預測系統狀態的演變，進而在時間與空間的維度上執行系統績效微量優化(incremental optimization or near-hood optimization)的演算機制，獲得新的時制決策。然而，這些模型與解法都是確定性的(deterministic)，意即這樣的做法必須是在「未來情境(by prediction)已知且固定不變」的假設下，方能據以求解問題(計算在「給定的」未來情境下的時制)。而顯然的，因系統狀態演變具不確定性，實際與預測情境必然不一致，則此優化的決策效果必然不佳。如果以機率模型描述系統不確定性，則適應性號誌決策問題面臨的是一個系統演變具備機率分配的型態，面對這樣的問題不宜以單一樣本值或預測值，逕自假設為已知且固定不變之情境，再據以優化績效而產生決策值，而應構建具有不確定性的系統，並在這樣的運作情境下構建決策模型、求解決策模型，使所產出的決策模型具備優化「系統績效期望值」的能力。

又例如：多數的號誌控制方法中所構建描述交通狀態或運作的車流模型，以巨觀(macroscopic)車流模型、CFP(cyclic flow profile)分析、甚或理想化的衝擊波(shockwave)分析等，同樣的這些車流模型除了無法反應駕駛行為的不確定性(uncertain driving behavior)以及異質駕駛者

(heterogeneous drivers)外，對於實務上較複雜交通運作情境的車流動態性(complex traffic dynamics)，例如；多車道、多車種、異質駕駛者等運作情境、車道溢流(spillback)、路口溢流、公車停靠、路邊停車、壅擠傳導(congestion propagation)等，其描述能力都相當侷限。然而，這些系統運作特性會因為路網的連結，而產生在時/空間上互動後的因果關聯，對於控制模型的優化影響甚深。

因此，如果回歸到適應性號誌控制問題這兩個重要本質，意即uncertainty and complex traffic dynamics，一個適應性號誌控制方法必須有能力描述這樣系統特性，並在這樣的運作情境下構建適應性號誌控制模型以及求解，以及該理論模型方法須要能夠具備實作在場域的可行性，進而協助交通管理單位改善交通壅擠問題，具體實現計畫目標。

接續章節將說明在選定的三個實際場域，構建具有 uncertainty and complex traffic dynamics 的微觀(microscopic)車流模擬環境，並據以設計人工智慧適應性號誌控制模型，再進行時制決策模型參數訓練與績效模擬測試，進行新適應性號誌控制方法論探討。

第三章 研究方法

強化學習(Reinforcement Learning, RL)架構的本質是處理序列決策最佳化問題，是一個符合馬可夫轉移鏈的過程，同時交通號誌控制也同樣是一個符合馬可夫轉移鏈的動態機率系統。從文獻回顧中可以發現到，傳統號誌控制方法都致力於構建描述交通狀態或運作的車流模型，並依據該車流模型去預測系統狀態的演變，進而由預測的結果去進行各種最佳化的演算機制。然而絕大多數的車流模型，都是屬於確定性的(deterministic)，並且對於未來交通演變過程的預測，都是靜態的分析結果，並沒有考慮到控制過程對交通演變的動態影響。因此過往的號誌控制方法論，對於時間與交通情境的因果關聯描述能力是相當缺乏的。而 RL 方法能夠完整的描述一個動態機率系統的演變過程，因此當應用在號誌控制問題上，相較於傳統方法更能夠去考量一個複雜交通環境在序列決策過程中的隨機性與不確定性，因此能夠更精準、更有效地去解決交通壅塞問題。

3.1 強化學習號誌控制方法

強化學習號誌之訓練方法，是讓號誌代理人(Agent)在模擬環境中進行經驗的蒐集，並從經驗中調整代理人的類神經網路參數，使得決策過程的期望獎勵可以最大化。每筆經驗是由代理人經由輸入車流與號誌的即時狀態(State)所計算出的決策(Action)，以及在決策後產生的獎勵(Reward)所組成。而代理人的訓練演算法將透過經驗資料庫以及所設定之系統最佳化目標，調整代理人類神經網路中的相關參數。大量模擬並重複以上步驟後，號誌代理人的類神經網路參數(即狀態與即時控制變數間的數學關係)將在此迭代最佳化過程中逐步被訓練出來。圖 3.1.1 為上述之訓練架構示意圖。從以上過程訓練出的號誌代理人能面對極多樣的車流狀態，並且以系統績效期望值最大化為目標進行即時控制。而傳統適應性控制方法，多由專家設計控制之邏輯或流程、或用車流預測模型計算分配綠燈時比、甚或使用動態查表的方式，都與強化學習號誌的方法論有著本質上的區別。

藉由讓 AI 號誌控制代理人(以深度類神經網路π_θ表示之)在模擬環境中進行大量模擬，當在步階t進行決策時會儲存$s_{t-1}, a_{t-1}, r_{t-1}, s_t$，將所產生的樣本儲存於$R$。在$R$夠大後開始從中抽取$B$個樣本，以隨機梯度下降法(stochastic gradient descent)，朝著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。重複上述步驟，即可訓練出考量系統總停等延

滯期望值最小化之 AI 號誌控制代理人。

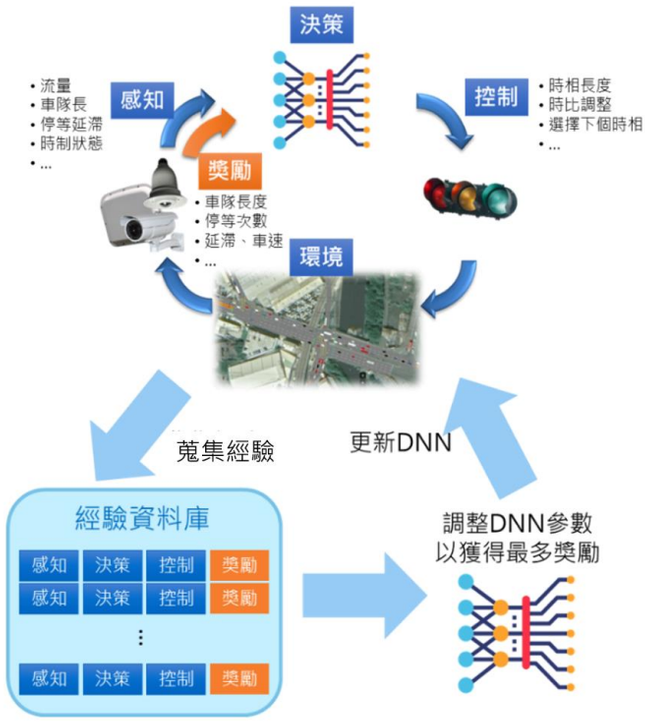

圖 3.1.1 強化學習號誌控制訓練架構

此方法乃是基於強化學習(Reinforcement Learning，後簡稱 RL)方法論之應用，而在本案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 RL 號誌控制訓練演算基本模型如圖 3.1.2 所示，而本案所採用演算法的詳細說明如 3.2 節說明。

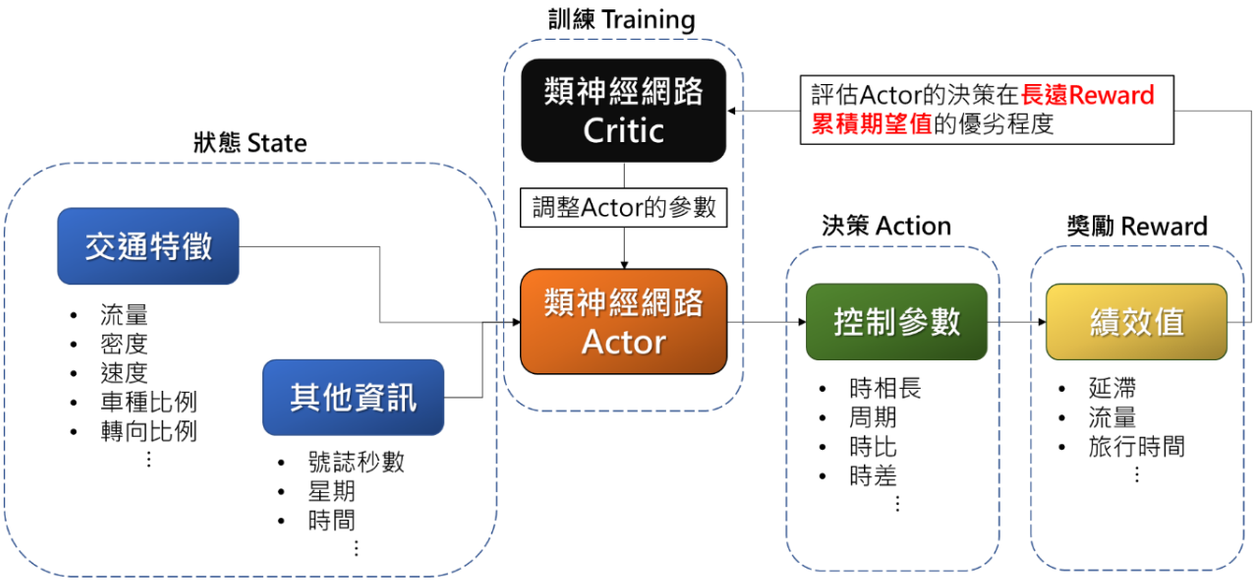

圖 3.1.2 RL 號誌控制架構基本模型

在圖 3.1.2 中的左側是所謂的狀態做為資料的輸入。狀態都是能夠描述當前交通情況的一些特徵，諸如傳統車流模型中的流量、密度、速度等。而另一方面，狀態資料中亦可以有一些比較特殊但也會影響判斷的重要資訊，比方說號誌的秒數、日期、時間等等。上述所有針對號誌控制的關鍵資料，將輸入一個稱之為 Actor 的類神經網路當中，期望透過 Actor 做為計算機制，通過上述 State 的關鍵資訊，考量當前交通狀態下，輸出控制決策 Action。針對決策的輸出格式也有著不同的設計可能，較為彈性的如每個分相的秒數；又或者是較為傳統的週期、時比、時差等。

不論前述的狀態和決策如何設計，對於整個交通系統必然會產生一項或多項績效值，諸如延滯、流量、旅行時間等等。而 AI 的目標即是希望透過變動決策數值，獲得長遠獎勵累積期望值的最大化。為了達到這個目標，會透過另一個稱之為 Critic 的類神經網路，去評估決策在長遠累積獎勵期望值的優劣程度。因此便可以逐步讓 Actor 減少壞決策出現的機率，提高好決策出現的機率，達到 Actor 最佳化的目標。這個架構也能夠適用於多代理人架構，實際做法即是多增加數個 Actor，各別產生各自的決策。而所有 Actor 最佳化的過程則與前述的方法相同。

在上述文字中，可以發現到 Actor 的最終結果是一個能夠根據環境狀態資訊計算決策數值的一套計算機制。然而如何使 Actor 從初始參數逐漸改變至最終結果，即需要透過 Critic 協助評估決策對於長遠績效的好壞程度，逐步更新參數，這一過程即稱為訓練。因此 Critic 的評估對於 RL 的訓練至關重要。Critic 類神經網路的功能在於能夠評判當前狀態與決策的聯合函數，輸出估計的長遠的累積獎勵期望值。為了達到此一目的，需要透過巨量的資料讓 Critic 去擬合出狀態與決策對於長遠的累積獎勵期望值的函數關係如圖 3.1.3。因此透過模擬過程能夠滿足巨量資料的要求，同時能夠快速取得長遠的累積獎勵值之目標。

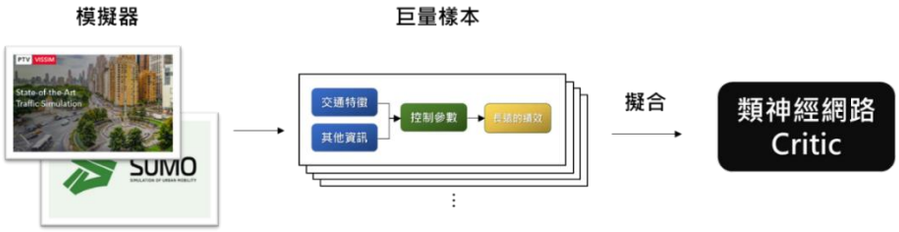

圖 3.1.3 Critic 產生過程

前述圖 3.1.1 至圖 3.1.3 之各項敘述，可以圖 3.1.4 來整合展現，並且透過 AI 號誌方法整體架構圖可以更理解各個項目在過程中的角色定位與

資料流動的過程。

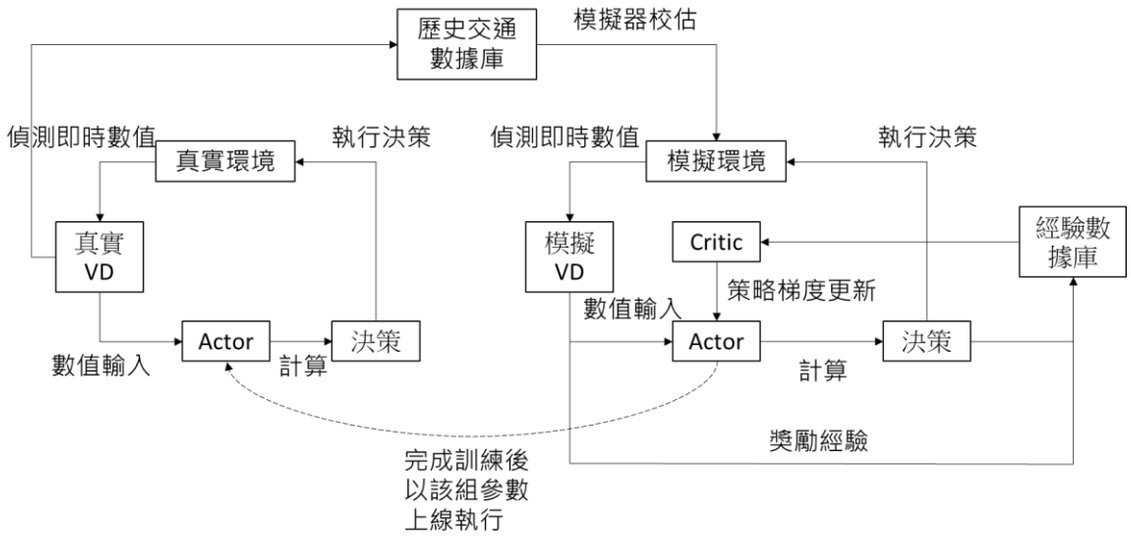

圖 3.1.4 AI 號誌方法整體架構圖

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

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 2.2.1 節中所介紹各種方法。在本案中所採用的訓練演算法，是基於深度確定性策略梯度法(Deep Deterministic Policy Gradient) [38](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。

$$E_p(X) = \int P_i X_i \tag{1}$$

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(1)表示。其中X_i是所有 X 的可能性，而P_i則是對應該X_i的機率密度函數。而 Actor 的期望回報，就可用下式定義：

$$V(s) = E_{\pi(s)}[r + \gamma V(s')] \tag{2}$$

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(2)改定義一個 Q 值的函數：

$$Q(s,a) = r + \gamma V(s') \tag{3}$$

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s_0開始到任務結束所能獲得的累積獎勵期望值。

$$J(\pi) = E(V(s_0)) \tag{4}$$

因此梯度函數可以被表示為

$$\begin{aligned}\nabla_\theta J(\pi_\theta) &= \int_{\mathcal{S}} \rho^\pi(s) \int_{\mathcal{A}} \nabla_\theta \pi_\theta(a|s) Q^\pi(s,a) \mathrm{d}a\mathrm{d}s \\ &= \mathbb{E}_{s\sim\rho^\pi, a\sim\pi_\theta}\left[\nabla_\theta \log \pi_\theta(a|s) Q^\pi(s,a)\right]\end{aligned} \tag{5}$$

援引自[38]，推導過程可參考[90]

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：

$$\begin{aligned}\nabla_\theta J(\mu_\theta) &= \int_{\mathcal{S}} \rho^\mu(s) \nabla_\theta \mu_\theta(s)\ \nabla_a Q^\mu(s,a)|_{a=\mu_\theta(s)}\, \mathrm{d}s \\ &= \mathbb{E}_{s\sim\rho^\mu}\left[\nabla_\theta \mu_\theta(s)\ \nabla_a Q^\mu(s,a)|_{a=\mu_\theta(s)}\right]\end{aligned} \tag{6}$$

推導過程可參考[38]

至此，便可以以 Actor-Critic 的架構來進行梯度下降的策略更新：

$$\delta_t = r_t + \gamma Q^w(s_{t+1}, \mu_\theta(s_{t+1})) - Q^w(s_t, a_t) \tag{7}$$

$$w_{t+1} = w_t + \alpha_w \delta_t \nabla_w Q^w(s_t, a_t) \tag{8}$$

$$\theta_{t+1} = \theta_t + \alpha_\theta \nabla_\theta \mu_\theta(s_t)\ \nabla_a Q^w(s_t, a_t)|_{a=\mu_\theta(s)} \tag{9}$$

DDPG 的運作架構可參考圖 3.2.1。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 演算法可以圖 3.2.2 表示。

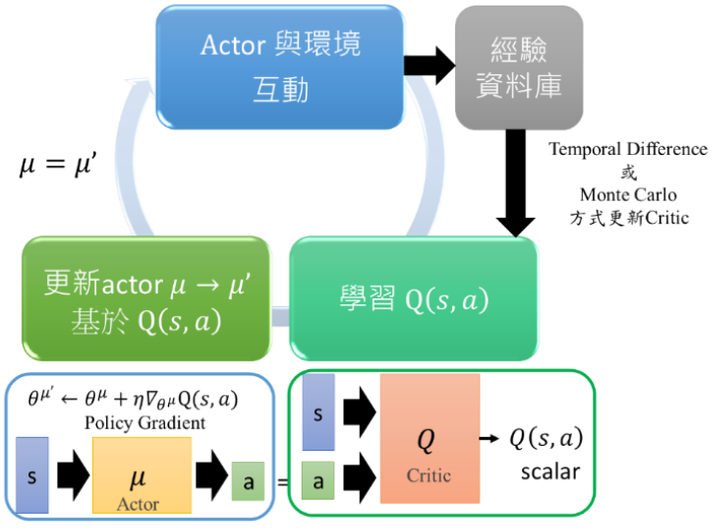

圖 3.2.1 DDPG 運作架構

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 3.2.2 DDPG 演算法

資料來源：[38]

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

1. Target Network (目標網路)

在更新 Critic 的過程中，Bellman equation 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。

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 做梯度更新，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，也有另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。

2. Experience Replay (經驗回放)

經驗回放技巧是 off policy 中常用的一種提升樣本效率的做法，其

方法即為記錄下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。

3. Prioritization Experience Replay (優先經驗回放)

優先經驗回放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。

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

本計畫中所採用的第二種 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 3.3.1)，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作更新。

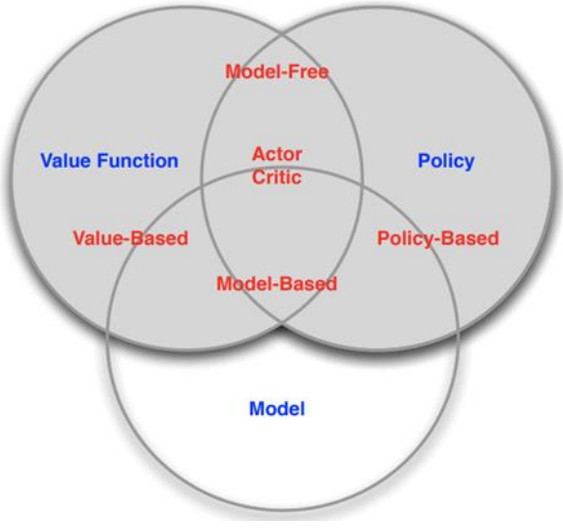

圖 3.3.1 RL 代理人類型

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

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：

$$\hat{g} = \hat{E}_t\left[\nabla_\theta log\pi_\theta(a_t|s_t)\hat{A}_t\right] \tag{10}$$

其中$\pi_\theta(a_t|s_t)$為隨機策略(stochastic policy)，亦即在s_t的狀態下產出決策a_t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：

$$L^{PG}(\theta) = \hat{E}_t\left[log\pi_\theta(a_t|s_t)\hat{A}_t\right] \tag{11}$$

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[41]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。

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

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

此處θ_k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[42]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L^{Clip}如下：

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

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

$r_t(\theta)$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 3.3.2 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。

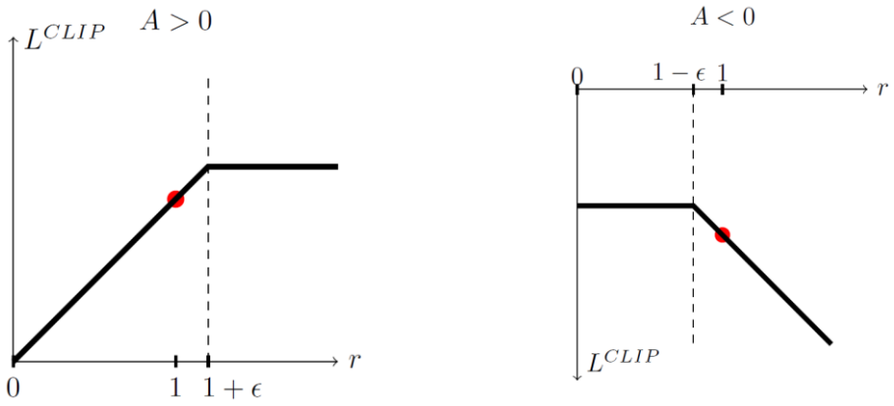

圖 3.3.2 PPO 的目標式L^{Clip}與$r(\theta)$的關係圖

圖 3.3.2 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 3.3.2 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

PPO 也是使用 Actor-Critic 架構的方法，運作架構如圖 3.3.3；演算法如圖 3.3.4。先以隨機策略π_{θ_k}跟環境互動取得軌跡τ_i後，計算軌跡中各時階t的未來獎勵總值$\hat{R}_t$以及優勢函數$\hat{A}_t$。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。

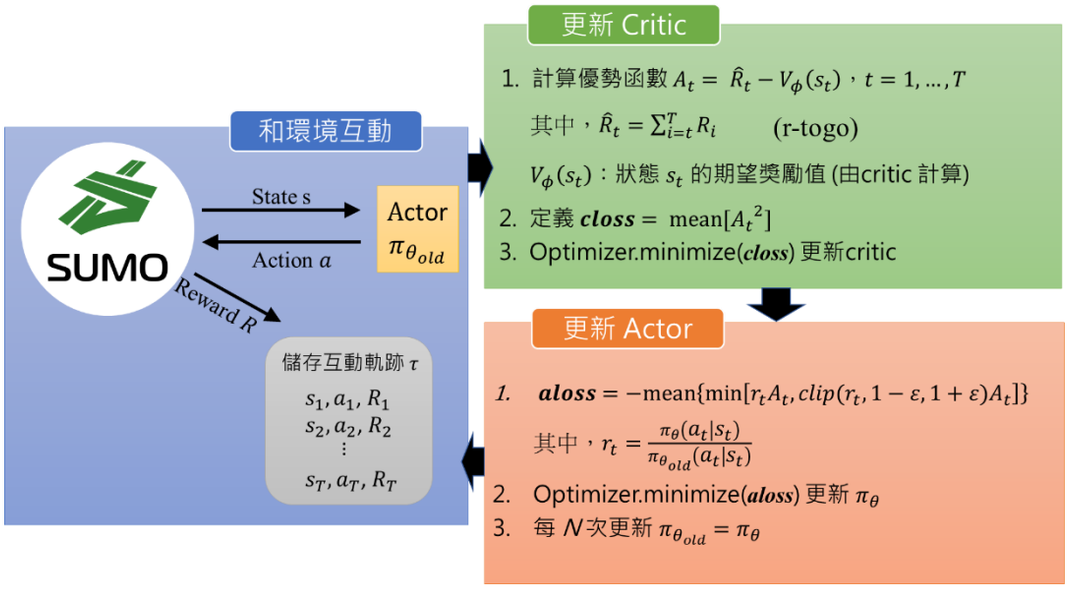

圖 3.3.3 PPO 運作架構圖

Algorithm 1 PPO-Clip

Input: initial policy parameters θ_0, initial value function parameters ϕ_0
for $k = 0, 1, 2, ...$ **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 3.3.4 PPO 演算法

資料來源：[44]

DDPG 與 PPO 算法分別由著名的 Google DeepMind 與 OpenAI 提出，表 3.3.1 為二者的特色比較。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 five[43]亦使用 PPO 做為核心算法。因此本計畫除應用類似 DDPG 的訓練演算法外，亦嘗試使用 PPO 訓練 AI 號誌代理人。

表 3.3.1 DDPG 與 PPO 方法比較

	DDPG	PPO
發表團隊/年份	Google DeepMind / 2016	OpenAI / 2017
方法框架	Actor-Critic	
Actor 決策類型	1. 確定性(deterministic)決策 2. 連續型決策	1. 隨機性(stochastic)決策 2. 連續型決策
方法特色	1. Off-policy 2. 應用目標網路、經驗回放、優先經驗回放等技巧，提升樣本使用率與訓練穩定度 3. 應用 soft update 避免參數更新變化太大	1. On-policy 2. 應用 importance sampling 提高樣本使用率 3. 在目標式加入上下界，避免策略更新變化太大
選擇原因	1. 承襲 DQN 的經驗回放技巧，大幅提升樣本使用率 2. 確定性的決策可有效提升訓練效率	1. OpenAI 把 PPO 做為目前的 baseline 算法 2. 參考資源豐富，且實作容易上手

資料來源：本研究整理

3.2 模擬方法與建置流程

強化學習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，雖然方法本身具備無模型(model free)的特色，然而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能夠讓代理人任意探索各種策略組合可能性的環境，而交通模擬器正是符合這樣需求的最佳選項。

本案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 3 個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，以供強化學習號誌代理人做為探索與學習最佳控制策略的環境。

3.2.1 模擬軟體介紹

3.2.1.1 VISSIM

本計畫選擇模擬軟體為德國 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。模擬與實際畫面對比可參考圖 3.4.1。VISSIM 為一款基於駕駛人心理物理門檻跟車理論(Wiedemann,1974，如圖 3.4.2 所示)所建構之微觀、定時掃描車流模擬器。心物門檻模式的基本概念是以車輛之間的相對速度(dv)與相對距離(dx)做為決策的輸入變數，在由相對速度與相對距離所構成的二維座標系中，各門檻方程將平面切割成數個區塊，而在不同的區塊之間則代表著不同的駕駛人反應行為。心物門檻將駕駛人分為數個反應區：

- 感知反應區：車輛由於前方車輛速度較快或較慢而有意識的影響。
- 無意識反應區：車輛在跟車過程中無法察覺到前車與自身的相對變化量，因此無任何因前車而產生的反應。
- 無反應區：由於前車距離自身過遠或是前車較自身速度高出許多的情況下，被駕駛人認為沒有前車，可自由行駛的情況。
- 緊急煞車區：相對距離小於駕駛人所能接受的下限情況。

除了考量前車的跟車模式之外，VISSIM 的車道變換模式考量周遭車輛對於自身的感知影響所建立而成。

圖 3.4.1 實際路況與模擬影片對比

資料來源：[86]

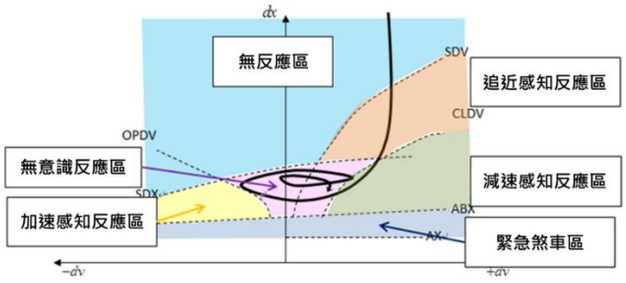

圖 3.4.2 心理物理門檻示意圖

資料來源：[93]

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 做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。

本計畫透過 Python script 在 VISSIM API 環境，做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。在本計畫中將使用到以下 VISSIM COM API 指令動態調整或取得資訊整理於表 3.4.1。

表 3.4.1 VISSIM API 指令說明

API	功能說明
Vissim.LoadNet	載入模擬路網
Vissim.Simulation.SetAttValue	設定模擬進行設定
Vissim.Evaluation.SetAttValue	偵測器設定值
Vissim.Net.SignalControllers	號誌燈號組態設定
Vissim.Simulation.RunContinuous()	執行模擬(直到設定之停止時間點)
Vissim.Net.Vehicles	取得當前所有存在於路網之車輛資訊
Vissim.Net.VehicleInputs	變更路網端點發車點需求量
Vissim.Net.VehicleRoutingDecisionsStatic	變更路徑靜態分派比例

3.2.1.2 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 Zentrum für 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 3.4.3 為 SUMO 路網編輯介面與模擬畫面。

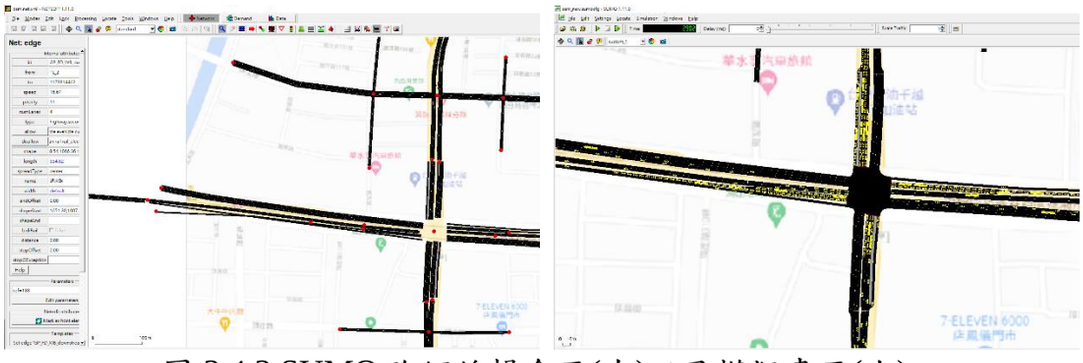

圖 3.4.3 SUMO 路網編輯介面(左)以及模擬畫面(右)

SUMO 提供 TraCI (Traffic Control Interface)工具包，允許在 SUMO 模擬中動態取得物件的狀態，或是操作其行為。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。Traci 是 Traffic Control Interface 的簡稱，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。表 3.4.2 列出在本計畫中所使用到的 traci 指令。

表 3.4.2 Traci 指令說明

API	功能說明
traci.start()	SUMO 模擬啟動
traci.simulationStep()	進行一個時間單位的模擬
traci.inductionloop	Loop 偵測器的資料存取
traci.lanearea	車道範圍的資料存取
traci.vehicle	取得當前所有存在於路網之車輛資訊
traci.trafficlight	號誌燈號的資訊存取與設定

3.2.2 模擬器校估流程

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[91][92]，將校估流程按步驟說明。

3.2.2.1 模擬場域資料蒐集

路網建置需先蒐集相關交通資料，一般可分為靜態資料與動態資料，說明如下。

1. 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。
   - 道路寬度、車道數、車道寬度
   - 轉向、車道縮減、或車道增加
   - 大眾運輸場站位置與長度
   - 停止線、號誌燈頭的位置
   - 以及與號誌控制時相之關聯
   - 「停」、「讓」標誌之位置
   - 機車停等區和機車待轉區尺寸和位置

2. 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：

- 路徑決策點的位置，以及時間與車種之決策情形
- 非號誌化路口或路口允許左轉之優先控制
- 大眾運輸之路徑、班次、班距與停靠站時間
- 進入路網之交通量與車種組成

3.2.2.2 模擬路網建置

路網之構建除道路幾何之劃設之外，還包括路口管制設定、交通量之輸入及基本參數之設定。

1. 道路構建與路口管制方式設定：構建道路基本路網主要包括下列程序。
   - 構建道路路網基本幾何線型：以背景圖為底，於圖上構建研究所需範圍之道路線型及車道數。
   - 輸入車道寬度與各車道之行駛車輛限制
   - 設定各路段之連結路徑
   - 設定路口控制方式(號誌時制計畫)
   - 設定績效指標偵測器
2. 交通量輸入主要包括下列內容：
   - 設定車種組成
   - 輸入路網各路段之端點交通量
   - 設定路口轉向流量比例
3. 參數設定：微觀模擬之參數相當多種類，主要參數設定包括下列四類：
   - 車輛幾何(車長、車寬、車重)
   - 車輛性能(最大加/減速率、期望加/減速率、期望速率分配)
   - 車輛種類(小汽車、公車、大貨車、機車、腳踏車)
   - 駕駛行為參數(跟車參數、變換車道參數、側向參數)

3.3.2.3 參數校估

完成路網構建的模擬環境雖幾何條件與現況相同，但因車輛性能與駕駛行為參數不盡相同，因此需進行參數校估後，方能反映真實車流情況。透過設定模擬軟體(VISSIM 與 SUMO)產出所需之績效指標，並調校

相關參數，確認實驗場域模擬模式之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。參數校估方式說明如下：

1. 校估指標選取

   本案中擬採用(a)路口轉向交通量做為主要驗證指標； (b)路口各方向平均每車延滯做為輔助的校估指標。

   一般在大多案例中[92]~[98]，轉向交通量(或路段流量)為主流的參數校估項目。而本案中由於AI是一種以資料驅動的學習方式，因此特別針對延滯項目一併做為校估評估項目。然而實務上由於延滯之調查在判讀上，本身存在一定程度的困難與誤差，較少文獻與案例採用延滯做為校估項目，也因此本案在此將延滯做為輔助之校估指標而非主要校估項目。

2. 參數調校

   參數調整時並無一定程序，但應一次調整單一參數，藉以了解各參數之影響力，調整後若問題還是無法解決，再以組合方式調整兩項以上之參數，但原則須確定其相互作用所產生之影響必須是要對符合實際車流情況有所貢獻。重複以上程序直到誤差小於門檻為止。

3. 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。

第四章 實驗場域規劃與分析

4.1 實驗場域遴選過程

本案依據計畫要求，以單一路口多時相、多路口幹道連鎖、車聯網環境，做為人工智慧強化學習的號誌控制模式研發實驗場域，並且考量後續與高速公路交流道上匝道儀控整合等議題，使本計畫具備後續年期延續性可能。實驗場域遴選在考量 112 年實作之建置財務實施可行性，以六都為主要考量對象。而其中桃園市、臺中市、高雄市已分別執行過人工智慧動態號誌控制實作，因此本案在單一路口與幹道多路口兩項情境的實驗場域遴選上先排除此桃園市、臺中市、高雄市。而在已實施車聯網運行計畫之縣市，目前國內僅有臺南市與高雄市。

4.1.1 縣市訪談與候選場域

在確立目標縣市後，透過會議訪談，除向縣市政府說明本案內容、介紹人工智慧強化學習動態號誌控制方法外，亦徵詢縣市政府適合場域名單(如表 4.1.1)、動態號誌控制實務上之考量，以及就 112 年實作相關規劃等議題交換意見。訪談會議分別於 4 月 21 日拜訪新北市政府交通局、4 月 22 日與臺北市交通管制工程處進行線上會議、4 月 29 日拜訪臺南市政府交通局、5 月 3 日拜訪高雄市政府智慧運輸中心。

表 4.1.1 臺北市、新北市、臺南市、高雄市的實驗場域候選名單

縣市	場域	情境分類/路口數
臺北市	濱江街-大直橋	幹道型/2
	至善路-善路71巷	單一路口/1
	福林路-復興橋兩端	幹道型/4
	中山北路-德行東路	幹道型/3
	辛亥路-萬美街	幹道型/3
	木柵路一段	幹道型/7
	木柵路四段-萬芳交流道	幹道型/6
	師大路-水源快速道路	單一路口/1
新北市	新台五路-新興路	幹道型/4
	(淡水區)中正東路-淡金公路	單一路口/1
	(鶯歌區)國慶街-重慶街	單一路口/1
臺南市	台86-19甲線	單一路口/1
	(永康區)中正北路-和平東路	單一路口/1
	(永康區)中正北路-永安路	幹道型/3

	(北區)中華北路-和緯路	幹道型/4
高雄市	過埤路-鳳頂路	車聯網情境/1

根據訪談會議意見交流與討論，以及本案計畫時程與經費考量後，由於新北市政府交通局所建議之場域皆期望於今年度即可進入建置階段，本案無法配合其時程；而臺南市則表達希望先從郊區單一路口嘗試 AI 號誌控制方法。因此遴選於臺南市進行單一路口實驗場域模式構建，以及於臺北市進行幹道多路口實驗場域模式構建；至於車聯網實驗場域部分，考量本案情境設定上必須挑選已有車聯網實際運行之場域，以及在車聯網通訊技術上，相較於臺南市所採用的專用短距通訊(DSRC)技術，高雄市車聯網場域採用較新的 C-V2X 車聯網通訊技術，因此遴選高雄市的過埤路-鳳頂路路口(台 88 線鳳山出口)做為實驗場域來進行模式構建。

4.1.2 實驗場域遴選程序

參考國內場域遴選相關案例[99][100]，本案從「經濟考量」、「施作環境」、「交通效用」與「主管機關考量」等四項層面進行臺北市與臺南市實驗場域的評估與遴選。表 4.1.2 為本案實驗場域遴選考量準則。

表 4.1.2 場域遴選考量準則

考量層面	經濟考量		
定義	本層面考量建置人工智慧號誌控制系統需要支付的成本		
評估要素	● 是否已經有偵測設備運行 ● 現行號誌系統是否支援動態控制 ● 場域是否已經執行過 AI 號誌控制專案	說明	● 在調查或偵測設備建置上可以有效節省經費需求 ● 現場號誌系統設備若可支援則可以有效節省經費需求 ● 避免造成疊床架屋情況
考量層面	施作環境		
定義	本層面考量場域外在環境適合程度		
評估要素	● 本案情境要求 ● 網路傳輸 ● 設備安裝可行性 ● 場域模擬適用性	說明	● 是否符合本案所設定之情境 ● 場址是否具有網路傳輸 ● 場址是否適合安裝相關設備；是否有電力 ● 場址是否有過多模擬難以重現狀況，如違停、攤販等
考量層面	交通效用		
定義	本層面考量場域實施號誌控制改善所能帶來之效益		
評估要素	● 現行號誌控制是否有改善	說	● 場域交通壅塞問題原因是否由號誌

	空間 ● 是否為區域瓶頸位置	明	控制所致 ● 場域績效提升對於區域的效益程度
考量層面	主管機關考量		
定義	本層面考量道路主管機關之偏好程度		
評估要素	● 施政方向考量 ● 建置與維護成本	說明	● 主管機關是否有意願嘗試新型態的交通控制模式 ● 設備定期的維護與耗損品的替換，涉及到維護的難度、人力的調度、時間與金錢的花費

4.1.3 實驗場域遴選結果

根據系列訪談會議結果，臺南市政府交通局傾向單一路口實驗場域，因此實驗場域遴選對象為臺南市政府交通局所建議之「台 86-19 甲線」與「中正北路-和平東路」兩個路口，臺北市則針對交通管制工程處所提「濱江街-大直橋」、「福林路-復興橋兩端」、「中山北路-德行東路」、「辛亥路-萬美街」、「木柵路一段」、「木柵路四段-萬芳交流道」等六個幹道。

4.1.3.1 單一路口情境實驗場域

1. 臺南市「台 86-19 甲線」路口

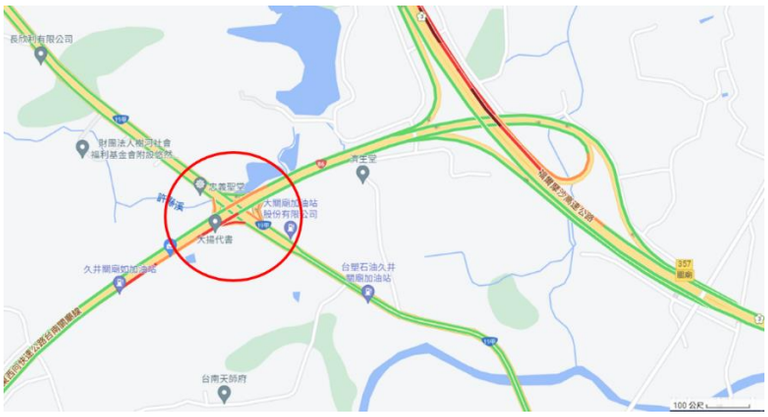

圖 4.1.1 臺南市「台 86-19 甲線」路口

(1) 路口概述：該路口位於國道 3 號關廟交流道旁，平面正交具有右轉槽化之路口。

(2) 優勢：

- 各方向距離上游號誌化路口皆有 1 公里以上之距離，非常符合獨立單一路口之情境設定。
- 周邊無住宅商業活動，路側干擾因素極少。
- 於 111 年執行『AI 影像辨識之智慧交通管理系統』計畫，

已安裝部分偵測器可供建模或 AI 號誌控制使用。

- 符合本案規劃未來年期匝道儀控議題探討。
- 臺南市政府交通局傾向以此路口做為後續年度實作對象。

(3) 挑戰：

- 上國道 3 號具有匝道儀控措施，恐怕影響 AI 績效之極限。
- 模擬測試時可能考量不同儀控率情境下的績效分析。

2. 臺南市「中正北路-和平東路」路口

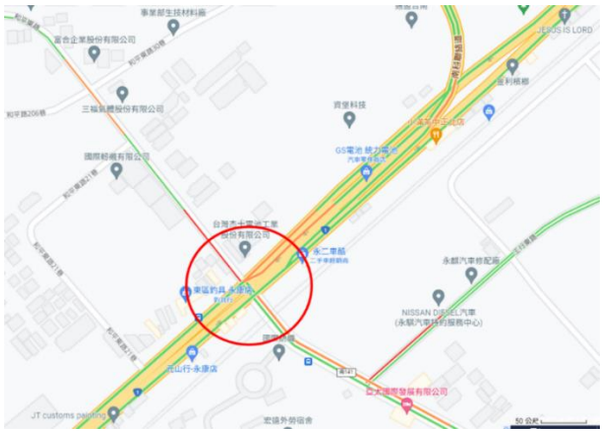

圖 4.1.2 臺南市「中正北路-和平東路」路口

(1) 路口概述：路口位於永康區工業區，南科聯絡道出口處，多車道幹道與支道平面正交路口。

(2) 優勢：此處尚未執行過任何動態號誌控制計畫，改善幅度將較為顯著。

(3) 挑戰：

- 位於工業區，大貨車多，偵測上較多干擾。
- 南方號誌化路口距離約 400 公尺，稍微需要考量幹道連鎖。

經與臺南市政府交通局討論，並以序位法針對各項考量項目評分(分數高為優)，其中若無法客觀區分優劣程度，則以同分方式處理。綜合以上考量，建議本案單一路口實驗場域以臺南市「台 86-19 甲線」路口做為目標場域。表 4.1.3 為本案單一路口實驗場域遴選結果。

表 4.1.3 單一路口實驗場域遴選結果

編號	場域	經濟考量	施作環境	交通效用	主管機關考量	總分
1	台 86-19 甲線	2	2	1	2	7
2	中正北路-和平東路	1	1	2	1	5

4.1.3.2 幹道多路口情境實驗場域

1. 臺北市「濱江街-大直橋」幹道

圖 4.1.3 臺北市「濱江街-大直橋」幹道

(1) 概述：位於汐五高架段下方，北接大直橋、南接復興北路地下道、西臨圓山交流道出口匝道。

(2) 優勢：各轉向皆有專用車道，轉向需求預估明確。

(3) 挑戰：位於高架道路下方與地下道出口，偵測器架設與偵測範圍將受限。

2. 臺北市「福林路-復興橋兩端」幹道

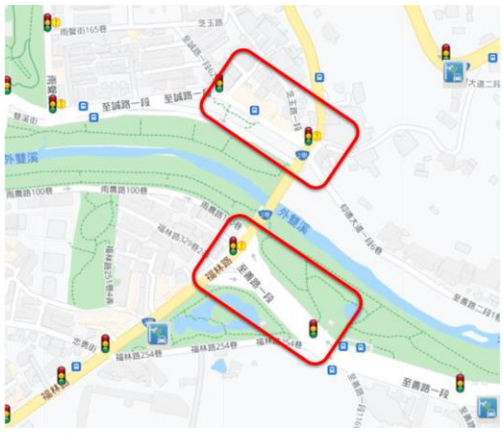

圖 4.1.4 臺北市「福林路-復興橋兩端」幹道

(1) 概述：福林路復興橋兩端路口與相鄰路口組成之雙 T 字型路網。

(2) 優勢：南端具備既有偵測器。

(3) 挑戰：雙 T 字型路網較不符合本案所設定之幹道型多路口情境。

3. 臺北市「中山北路-德行東路」幹道

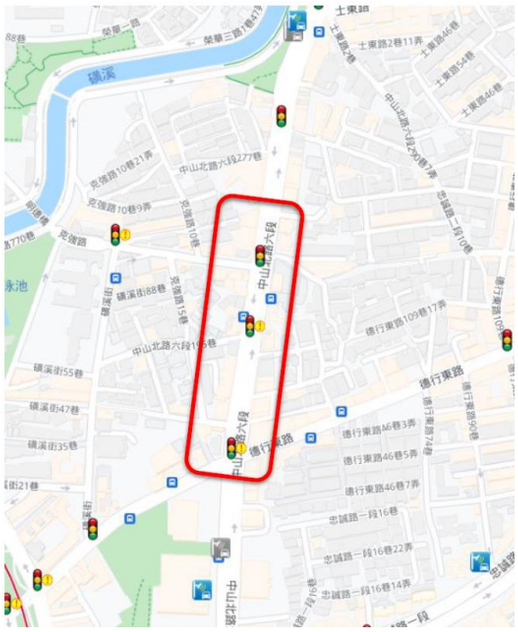

圖 4.1.5 臺北市「中山北路-德行東路」幹道

(1) 概述：中山北路六段連續三處號誌化路口，市區中心。

(2) 優勢：

- 非常符合幹道型多路口情境。
- 幹道南北端皆有既有偵測器。

(3) 挑戰：典型市區中幹道與其他號誌群組配合議題。

4. 臺北市「辛亥路-萬美街」幹道

圖 4.1.6 臺北市「辛亥路-萬美街」幹道

(1) 概述：辛亥路四段連續 3 處號誌化路口，捷運辛亥站旁、北接辛亥隧道。

(2) 優勢：幹道南北端皆有既有偵測器。

(3) 挑戰：此處主要交通問題恐受限於公車停靠站之設計問題，號誌控制所能改善幅度有限。

5. 臺北市「木柵路一段」幹道

圖 4.1.7 臺北市「木柵路一段」幹道

(1) 概述：木柵路一段上連續 7 處號誌化路口，鄰近考試院。

(2) 優勢：符合本案幹道多路口情境設定。

(3) 挑戰：

- 路側干擾因素較多，模擬重現困難。
- 路口數較多，規模較大。

6. 臺北市「木柵路四段-萬芳交流道」幹道

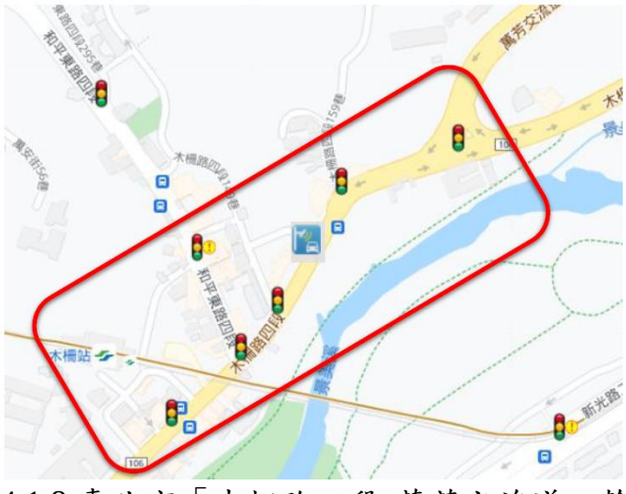

圖 4.1.8 臺北市「木柵路四段-萬芳交流道」幹道

(1) 概述：木柵路四段上連續 6 處號誌化路口，鄰近捷運木柵站，北接萬芳交流道。

(2) 優勢：符合本案幹道多路口情境設定。

(3) 挑戰：

- 此處恐受限於公車停靠站之設計問題，號誌控制所能改善幅度有限。

- 路側干擾因素較多，模擬重現困難。
- 路口數較多，規模較大。

評選方式以序位法針對各項考量項目評分(分數高為優)，其中若無法客觀區分優劣程度，則以同分方式處理。經與臺北市交通局確認，交通局針對候選名單中並無明顯優先偏好，因此主管機關考量項目中各選項皆為同分處理。表 4.1.4 為本案單一路口實驗場域遴選結果。

表 4.1.4 幹道多路口實驗場域遴選結果

編號	場域	經濟考量	施作環境	交通效用	主管機關考量	總分
1	濱江街-大直橋	2	5.5	5	3.5	16
2	福林路-復興橋兩端	4	1	5	3.5	13.5
3	中山北路-德行東路	5.5	5.5	5	3.5	19.5
4	辛亥路-萬美街	5.5	3.5	1.5	3.5	14
5	木柵路一段	2	3.5	1.5	3.5	10.5
6	木柵路四段-萬芳交流道	2	2	3	3.5	10.5

綜合以上考量，建議本案幹道多路口情境以臺北市「中山北路-德行東路」幹道做為目標場域。

4.1.3.3 車聯網運行路口情境之實驗場域

由於目前我國各縣市中已經有在運行車聯網的開放道路場域並不多，經研析後原先鎖定在臺南市公車優先號誌或高雄市緊急車輛優先號誌兩案例中擇一。而經過與臺南市交通局訪談後，了解到臺南市在實務執行上尚有許多困難與考量，因此不建議以公車優先號誌做為 AI 動態號誌控制的實驗對象，因此就本案車聯網場域即選取高雄市場域：台 88 線鳳山出口(過埤路-鳳頂路)。

鳳頂路為高雄市鳳山區南北向重要道路，全線屬市道 183 甲線。為連結鳳山區過埤、小港區、台 88 線鳳山交流道及高雄國際機場的主要道路，車流量甚大。鳳頂路採中央實體分隔型式，車道配置部分，南北向皆採用二快車道與一慢車道設計，各車道之間採標線分隔型式。南北側鳳頂路最內快車道皆採禁行機車。鳳頂路皆採快車道速限 60kph、慢車道速限 40kph。

過埤路為高雄市鳳山區東西向道路，西起於溪濱路、溪濱一街口銜接南華一路，東止於過埤路 2 巷口銜接大寮區六和路。屬於台 88 線東西

向快速公路高雄潮州線的橋下平面道路，也是頂新特區的主要道路之一，車流量甚大。過埤路採中央實體分隔設計，車道配置部分，東西向皆採用二快車道與一慢車道設計，而快慢車道之間設有一匝道出口，不同屬性車道之間採用實體分隔型式。轉向管制上，西側過埤路最外車道為右轉專用道，東西向過埤路全面禁止左轉。東西向過埤路快車道禁行機車。東西向過埤路皆採快車道速限 60kph、慢車道速限 40kph。圖 4.1.9 為高雄市「台 88 線鳳山出口」車聯網路口示意。

圖 4.1.9 高雄市「台 88 線鳳山出口」車聯網路口

109 年初鳳祥分隊消防車行經鳳頂路/過埤路，因曳引車未及時禮讓而造成嚴重交通事故。遂於 110 年辦理「緊急車輛優先通行號誌及路口防碰撞系統試辦計畫委託專業服務案」[83]，透過緊急車輛車機裝置，經由車聯網技術推播通行位置資訊，使路口號誌緊急切換至該方向綠燈，以阻斷衝突車流，並且增進緊急車輛運行效率。其運作方式乃是採用插入所需時相之方式實現，其方法如圖 4.1.10 示意。

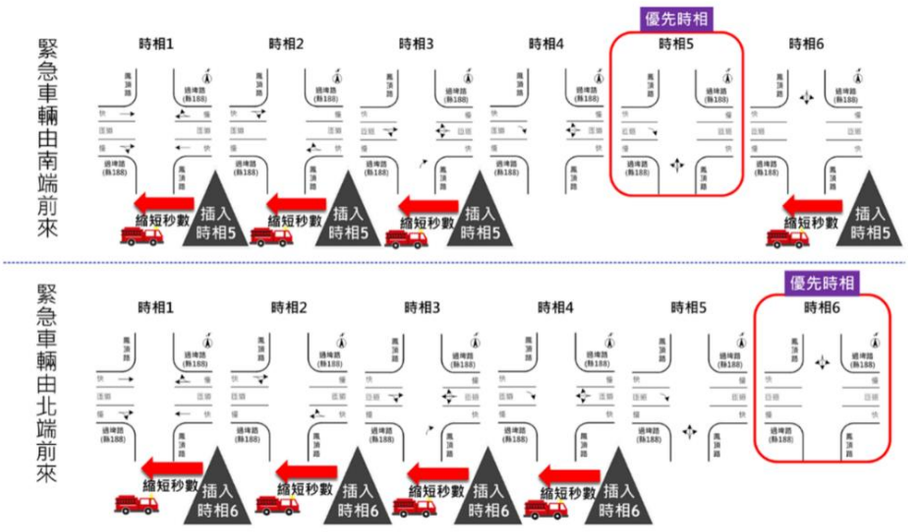

圖 4.1.10 緊急車輛優先號誌插入時相示意

資料來源：[83]

經與高雄市交通局溝通，此路口符合本案我國已建置與實施車聯網計畫之要求，並且本處交通量甚大，時相配置複雜，適合適應控制改善交通壅塞問題。綜合上述條件，本案建議以此路口做為車聯網情境實驗場域。

4.2 交通調查計畫

依據場域遴選結果所挑選出之三處位置，以下將分別制定交通調查計畫。為了方便閱讀，各場域所做之調查項目統整列於表 4.2.1。以下依各場域分別獨立說明調查項目與場域細節。

表 4.2.1 各場域調查項目一覽表

	臺南		臺北							高雄		
路口編號	1	2	1	2	3	4	5	6	7	1	2	3
現況道路特性	V	V	V	V	V	V	V	V	V	V	V	V
現行時制計畫	V	V	V	V	V	V	V	V	V	V	V	V
轉向交通量	V	V		V	V	V	V			V	V	V
停等延滯	V			V	V	V					V	
停等車隊長度											V	
旅行時間			V	V	V	V	V					

4.2.1 單一路口場域(臺南市)

i. 調查範圍：台 86-19 甲線(圖 4.2.1 路口 1)

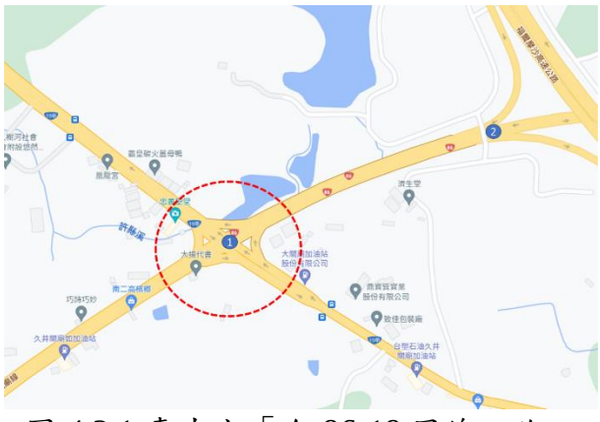

圖 4.2.1 臺南市「台 86-19 甲線」路口

1. 座標：22.97513440127898, 120.3188158521996
2. 幾何佈設(以 19 甲為南北向)：
   (1) 路口 1 南向：1 右轉槽化車道+1 混合車道+1 汽車直行+1 左轉專用道。

(2) 路口 1 北向：1 右轉槽化車道+1 混合車道+1 汽車直行+1 左轉專用道。
(3) 路口 1 東向：1 右轉槽化車道+ 2 汽車直行+2 左轉專用道。
(4) 路口 1 西向：1 右轉槽化車道+ 2 汽車直行+2 左轉專用道。
(5) 路口 2 各方向皆為 1 車道。

3. 調查項目：
(1) 現況道路特性：包括車道數、分隔型式、車道寬度、車道配置、相關道路管制(如禁左或單行道)等。
(2) 現行時制計畫：時制計畫包括週期、時相、綠燈、紅燈、全紅、以及各路口間之時差等資料，協請交通局提供相關資料。
(3) 轉向交通量：分車種(大型車、小型車、機車)統計所有路口各動線通過之通過車輛數(含兩段式左轉)，並以每 5 分鐘紀錄 1 次。調查方式採用定點錄影方式，錄製後以人工方式判讀記錄之。上述路口 1、2 皆應包含在內。
(4) 停等延滯：針對各來向車流中，就一般小汽車與大型車輛，以人工方式判讀推算路口停等延滯時間，就影像範圍內所偵測到停等線後方受到任何因素(含紅燈停等)而受阻無法前進之車輛數量進行統計，每 15 秒記錄一次。最後以每 15 分鐘彙整各方向停等延滯表。延滯調查需提供各方向具體調查範圍(即至停止線起算上游多少公尺範圍內計入停等延滯計算)考量本案號誌控制對象為路口 1，因此停等延滯僅需調查路口 1 各方向即可；路口 2 無須調查。

所有調查項目須為同一日，不同時段不可分日調查。(除非遭遇不可抗力因素，如車禍、臨時天氣驟變、天災等，則可擇日補上缺漏時段)

4. 調查時段：
- 111 年 5 月 31 日(二) 06:30~09:30
- 111 年 5 月 31 日(二) 16:00~19:00
- 111 年 6 月 23 日(四) 12:00~15:00
- 111 年 6 月 25 日(六) 16:00~19:00

4.2.2 幹道多路口場域(臺北市)

1. 調查範圍：中山北路六段上 4 處號誌化路口(中山北路，德行東路至克強路，圖 4.2.2 中路口 2、3、4、5)，紅色方框為計劃 AI 動態控制路口。

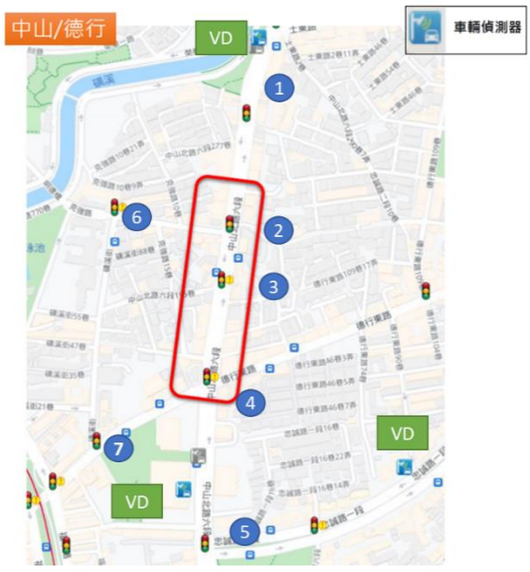

圖 4.2.2 臺北市「中山北路-德行東路」幹道

2. 坐標：25.106526018783594, 121.52498893549726

3. 幾何佈設(以中山北路為南北向)：

(1) 路口 2 南向：2 混合車道，禁止左轉。
(2) 路口 2 北向：2 混和車道，內側直左共用。
(3) 路口 2 東向：1 混合車道。機車免兩段式左轉。
(4) 路口 2 西向：消防通道，禁止左轉。交通量甚小，無須調查。
(5) 路口 3 南向：2 混合車道。
(6) 路口 3 北向：2 混和車道，內側直左共用。
(7) 路口 3 東向：單行進入，無須調查。
(8) 路口 4 南向：2 混合車道+1 左轉專用車道。
(9) 路口 4 北向：3 混合車道，最內側直左共用。
(10) 路口 4 東向：2 混合車道。機車免兩段式左轉。
(11) 路口 4 西向：1 混合車道。機車免兩段式左轉。
(12) 路口 5 南向：2 混合車道，內側直左共用，尖峰時段禁止左轉。
(13) 路口 5 北向：3 混合車道，最外側右轉專用道。
(14) 路口 5 西向：2 混合車道+2 左轉專用車道。最外側右轉專用道；機車免兩段式左轉 。

4. 調查項目：

(1) 現況道路特性：包括車道數、分隔型式、車道寬度、車道配置、相關道路管制(如禁左或單行道)等。

(2) 現行時制計畫：時制計畫包括週期、時相、綠燈、紅燈、全紅、以及各路口間之時差等資料，協請交通局提供相關資料。

(3) 轉向交通量：上述路口 2、3、4、5，分車種(大型車、小型車、機車)統計所有路口各動線通過之通過車輛數(含兩段式左轉)，並以每 5 分鐘紀錄 1 次。調查方式採用定點錄影方式，錄製後以人工方式判讀記錄之。路口 5 南向車流中分為至中山北路與 35 巷兩種流動，需分別記錄之，對於忠誠路左轉車流採相同處理方式。

(4) 停等延滯：上述路口 2、3、4，針對各來向車流中，就一般小汽車與大型車輛，以人工方式判讀推算路口停等延滯時間，就影像範圍內所偵測到停等線後方受到任何因素(含紅燈停等)而受阻無法前進之車輛數量進行統計，每 15 秒記錄一次。最後以每 15 分鐘彙整各方向停等延滯表。延滯調查需提供各方向具體調查範圍(即至停止線起算上游多少公尺範圍內計入停等延滯計算)除路口 2 西向與路口 3 東向無須調查，以及路口 1、5、6、7 非本次控制範圍無須調查之外，其餘各方向皆應包含在調查當中。

(5) 旅行時間：路段旅行時間調查以實際開車行駛調查路段進行相關資料蒐集，即配置一駕駛員駕駛車輛以道路整體車流之平均速率行經調查路段，調查員於通過所有號誌化路口時紀錄通過時間，若有延滯則紀錄延滯時間及原因。行駛速率資料整理係利用旅行時間與路段行駛距離，並統計延滯時間與原因，求取各路段上之平均車輛行駛速率。調查方式為每 30 分鐘調查路段來回各 1 次。每趟次出發時間間隔應盡可能維持一致，即間隔 30 分鐘。本場域起迄點設定如下：北向以通過路口 5(忠誠路)停止線起算；以通過路口 2(克強路)停止線為止。南向以通過路口 1(290 巷)停止線起算；以通過路口 4(德行東路)停止線為止。

1. 調查時段：

- 111 年 6 月 14 日(二) 06:30~09:30
- 111 年 6 月 14 日(二) 16:00~19:00
- 111 年 6 月 28 日(二) 12:00~15:00
- 111 年 7 月 02 日(六) 16:00~19:00

4.2.3 車聯網路口場域(高雄市)

1. 調查範圍：台 88 線鳳山出口(過埤路-鳳頂路路口，圖 4.2.3 中路口 2)

圖 4.2.3 高雄市「台 88 線鳳山出口」車聯網路口

2. 座標：22.590245968414475, 120.35887672177826

3. 幾何佈設(以鳳頂路為南北向)：

(1) 路口 1 南向：1 機慢車道+2 混合車道，最內側直左共用。

(2) 路口 1 北向：1 機慢車道+2 混合車道，最內側直左共用。

(3) 路口 1 東向：2 混合車道，最內側直左共用。

(4) 路口 1 西向：2 混合車道，最內側直左共用。

(5) 路口 2 南向：1 右轉專用+1 機車優先+2 汽車直行+1 左轉專用。如圖 4.2.4 所示。

圖 4.2.4 高雄市「台 88 線鳳山出口」路口南向車道配置

(6) 路口 2 北向：1 右轉專用+1 機車優先+1 汽車直行+汽車直左共用+1 左轉專用。如圖 4.2.5 所示。

圖 4.2.5 高雄市「台 88 線鳳山出口」路口北向車道配置

(7) 路口 2 東向：1 慢車道+1 下匝道右轉專用+下匝道直行專用+1 平面直右共用+1 平面直行。如圖 4.2.6 所示。平面汽車禁止左轉、下匝道車輛禁止左轉。

圖 4.2.6 高雄市「台 88 線鳳山出口」路口東向車道配置

(8) 路口 2 西向：1 慢車道+1 下匝道專用車道+1 平面直右共用+1 平面直行。如圖 4.2.7 所示。下匝道任何方向皆可、平面汽車禁止左轉。

圖 4.2.7 高雄市「台 88 線鳳山出口」路口西向車道配置

(9) 路口 3 南向：1 機慢車道+1 混合車道+1 汽車車道，最內側直左共用。

(10) 路口 3 北向：1 機慢車道+1 混合車道+1 汽車車道，最內側直左共

用。

(11) 路口 3 東向：1 混合車道。

(12) 路口 3 西向：1 混合車道。

4. 調查項目：

(1) 現況道路特性：包括車道數、分隔型式、車道寬度、車道配置、相關道路管制(如禁左或單行道)等。

(2) 現行時制計畫：時制計畫包括週期、時相、綠燈、紅燈、全紅、以及各路口間之時差等資料，協請交通局提供相關資料。

(3) 轉向交通量：上述路口 1、2、3，分車種(大型車、小型車、機車)統計所有路口各動線通過之通過車輛數(含兩段式左轉)，並以每 5 分鐘紀錄 1 次。調查方式採用定點錄影方式，錄製後以人工方式判讀記錄之。路口 2 中，東西向皆分有慢車道、下匝道、平面汽車道。三者應各自獨立為一來向，並且其餘方向進入時也應區分三者，分別記錄之。

(4) 停等延滯：上述路口 2 中，針對各來向車流中，就一般小汽車與大型車輛，以人工方式判讀推算路口停等延滯時間，就影像範圍內所偵測到停等線後方受到任何因素(含紅燈停等)而受阻無法前進之車輛數量進行統計，每 15 秒記錄一次。最後以每 15 分鐘彙整各方向停等延滯表。

延滯調查需提供各方向具體調查範圍(即至停止線起算上游多少公尺範圍內計入停等延滯計算)路口 2 中，東西向皆分有慢車道、下匝道、平面汽車道。三者應各自獨立為一來向，分別記錄之。除路口 2 慢車道外，其餘各方向皆應包含在調查當中。路口 1、3 則因非屬本次控制範圍，因此無須調查。

(5) 停等車隊長度：上述路口 2 中，除慢車道外，紀錄每個號誌週期中各來向，最大停等車隊長度(公尺)。計算範圍以停止線起算至上游 200 公尺為界，惟下匝道動線受限於攝影機架設位置，可能無法完全滿足 200 公尺範圍，將視現場狀況盡可能符合。

5. 調查時段：

- 111 年 5 月 31 日(二) 06:30~09:30
- 111 年 5 月 31 日(二) 16:00~19:00
- 111 年 6 月 23 日(四) 12:00~15:00
- 111 年 6 月 25 日(六) 15:00~18:00

4.3 交通現況分析

針對前述小節所詳列之交通調查範圍及項目，經確認後，調查時間如表 4.3.1。

表 4.3.1 場域調查時段

場域 / 調查時段	臺南市	臺北市	高雄市
平日上午尖峰	05/31(二) 06:30-09:30	06/14(二) 06:30-09:30	05/31(二) 06:30-09:30
平日上午尖峰	05/31(二) 16:00-19:00	06/14(二) 16:00-19:00	05/31(二) 16:00-19:00
平日離峰	06/23(四) 12:00-15:00	06/28(二) 12:00-15:00	06/23(四) 12:00-15:00
假日尖峰	06/25(六) 16:00-19:00	07/02(六) 16:00-19:00	06/25(六) 15:00-18:00

以下依各場域來說明交通調查現況分析。

4.3.1 臺南場域交通現況分析

4.3.1.1 現況道路特性

調查範圍道路包含台 86、19 甲、關廟交流道。其道路幾何特性資料彙整如表 4.3.2，包含了車道數、車道寬、分隔方式等。

表 4.3.2 臺南場域道路幾何特性

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)、3.3(左內)、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	禁行機車

4.3.1.2 號誌時制計畫

圖 4.3.1 與圖 4.3.2 分別為臺南場域路口時相組態與時制計畫。

	時相1			時相2			時相3			時相4			時相5		
計畫															
2	17	6	0	85	5	3	17	5	3	21	5	3	22	5	3
	時相1			時相2			時相3			時相4			時相5		
計畫															
6	22	6	0	96	5	3	20	5	3	24	5	3	20	5	3
				時相2			時相3			時相4			時相5		
計畫															
1				102	5	3	20	5	3	23	5	3	23	5	3
4				32	5	3	10	5	3	16	5	3	10	5	3
8				73	5	3	20	5	3	25	5	3	20	5	3

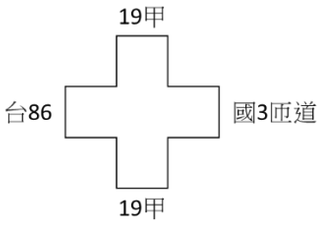

圖 4.3.1 台 86-19 甲線路口號誌時制計畫(綠燈秒數-黃燈秒數-全紅秒數)

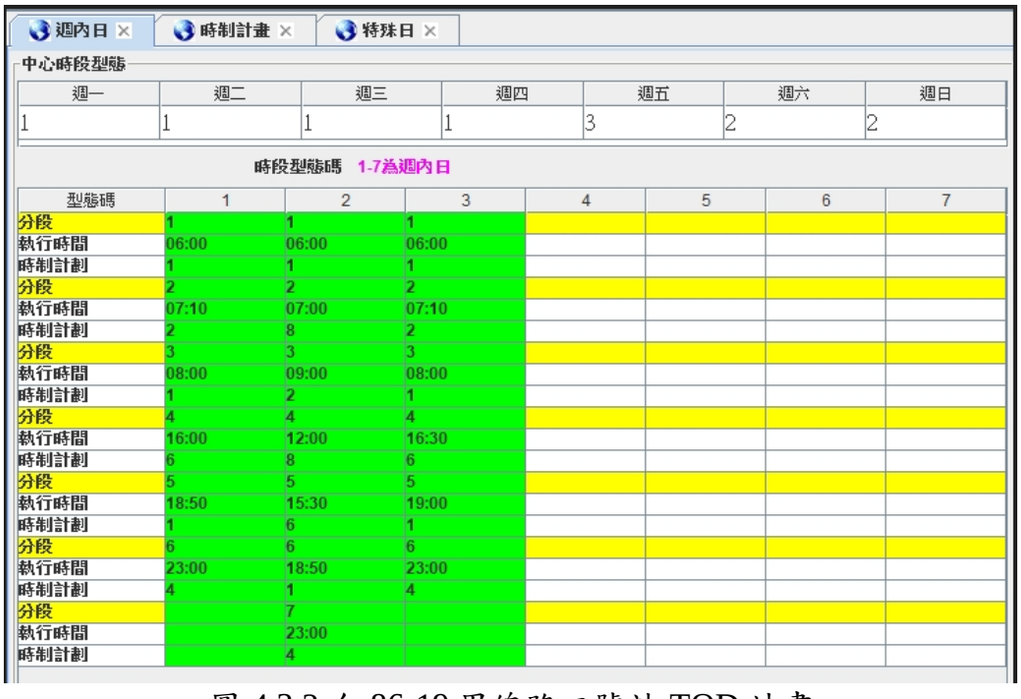
週內日 × 時制計畫 × 特殊日 ×

中心時段型態

週一	週二	週三	週四	週五	週六	週日
1	1	1	1	3	2	2

時段型態碼 1-7為週內日

型態碼	1	2	3	4	5	6	7
分段	1	1	1				
執行時間	06:00	06:00	06:00				
時制計劃	1	1	1				
分段	2	2	2				
執行時間	07:10	07:00	07:10				
時制計劃	2	8	2				
分段	3	3	3				
執行時間	08:00	09:00	08:00				
時制計劃	1	2	1				
分段	4	4	4				
執行時間	16:00	12:00	16:30				
時制計劃	6	8	6				
分段	5	5	5				
執行時間	18:50	15:30	19:00				
時制計劃	1	6	1				
分段	6	6	6				
執行時間	23:00	18:50	23:00				
時制計劃	4	1	4				
分段		7					
執行時間		23:00					
時制計劃		4					

圖 4.3.2 台 86-19 甲線路口號誌 TOD 計畫

4.3.1.3 尖峰小時轉向交通量

圖 4.3.3 至圖 4.3.5 中，僅顯示交通調查時段之流量資料，其餘時段因未調查而無資料，但不代表真實流量為 0。考量不同時段之調查未必為同一日調查，故仍依不同天各別製圖。

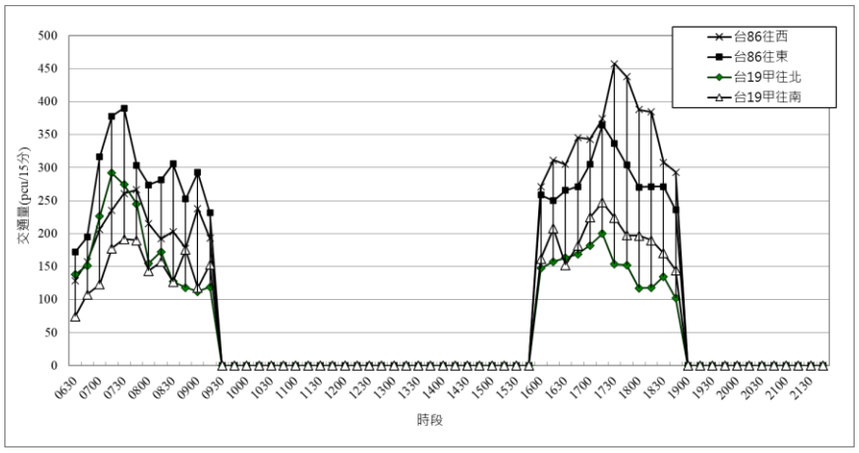

圖 4.3.3 台 86-19 甲線路口平日上下午尖峰交通總量(pcu/15min)

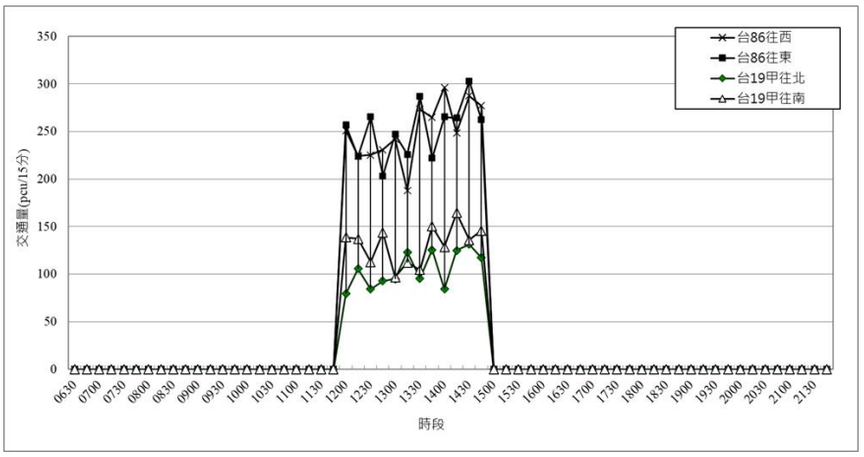

圖 4.3.4 台 86-19 甲線路口平日離峰交通總量(pcu/15min)

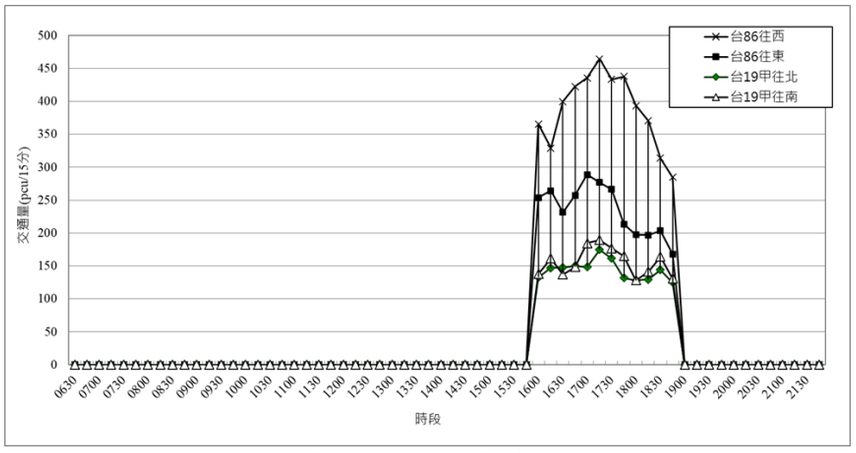

圖 4.3.5 台 86-19 甲線路口假日尖峰交通總量(pcu/15min)

從交通總量中可以發現，平日上午尖峰小時發生在 07:00~08:00；平

日下午尖峰小時則發生於 17:00~18:00；平日離峰的尖峰小時則發生於 14:00~15:00；假日尖峰小時則發生於 16:45~17:45。根據以上分析尖峰小時時段，分別製作轉向交通量圖。

圖 4.3.6 至圖 4.3.9 中，觀察平日上下午尖峰的轉向交通量數據，上午尖峰的主要流量為台 86 線往東，下午則是台 86 線往西，十分具有方向性。基於此特性，也可發現目前號誌時制計畫在上午尖峰時，針對台 86 線往東有設計一個左直右全開的時相 1；而在下午尖峰時，對台 86 線往西有設計一個左直右全開的時相 1。此外，針對台 86 線往西方向的流量，其在上下午尖峰的右轉流量皆佔了 60%以上，下午尖峰更達到 70%，算是該路口較為特別的一個轉向量。而從平日離峰跟假日尖峰的小時轉向量資料來看，幹道台 86 線的流量都明顯比支道台 19 甲線來得大，幹支道流量差異較平日上下午尖峰顯著。

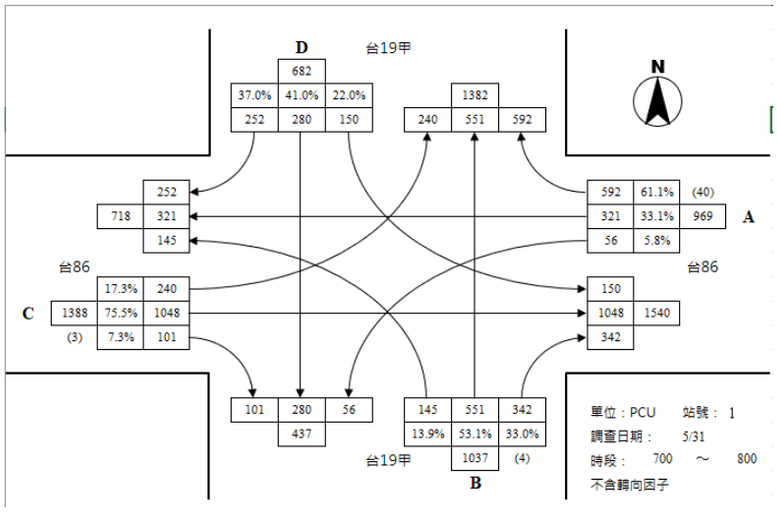

圖 4.3.6 台 86-19 甲線路口平日上午尖峰小時轉向交通量

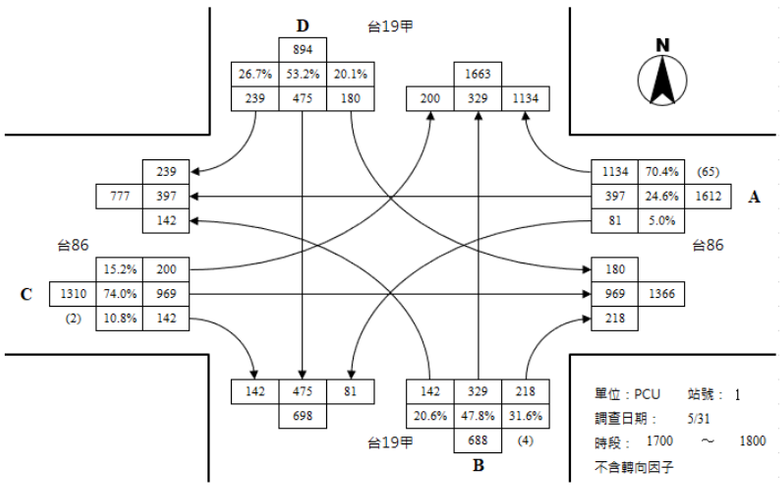

圖 4.3.7 台 86-19 甲線路口平日下午尖峰小時轉向交通量

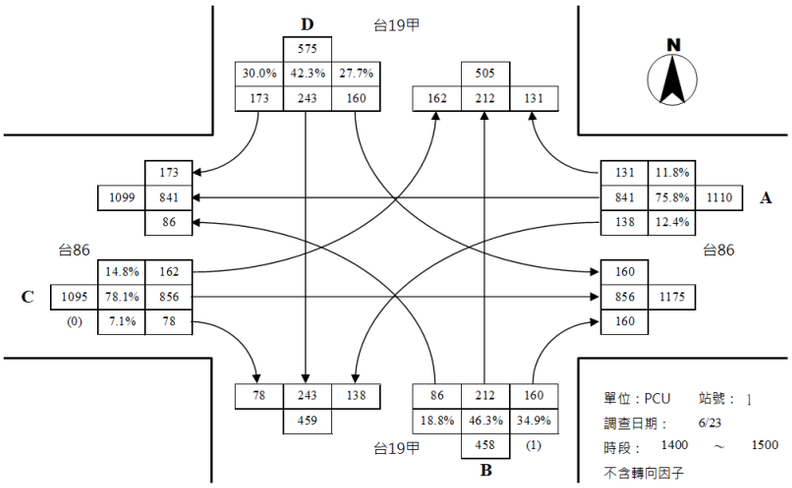

圖 4.3.8 台 86-19 甲線路口平日離峰尖峰小時轉向交通量

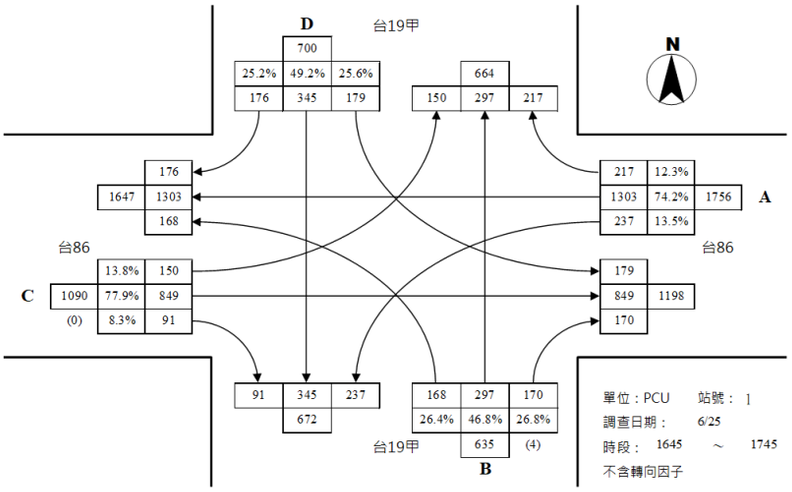

圖 4.3.9 台 86-19 甲線路口假日尖峰小時轉向交通量

4.3.1.4 尖峰小時延滯

表 4.3.3 至表 4.3.5 分別整理臺南場域路口各時段延滯與服務水準狀況。

表 4.3.4 臺南場域平日上下午尖峰延滯與服務水準

方向		平日晨峰			平日昏峰		
		各方向延滯	服務水準	平均延滯	各方向延滯	服務水準	平均延滯
A	台 86 線往西	40.3	C	44.7 服務水準 C	25.8	B	57.5 服務水準 D
B	台 19 甲線往北	80.4	F		84.5	F	
C	台 86 線	27.3	B		43.7	C	

	往東						
D	台 19 甲線往南	69.5	E		160.0	F	

表 4.3.4 臺南場域平日離峰延滯與服務水準

方向		平日離峰		
		各方向延滯	服務水準	平均延滯
A	台 86 線往西	37.5	C	45.7 服務水準 D
B	台 19 甲線往北	80.1	F	
C	台 86 線往東	30.9	C	
D	台 19 甲線往南	83.8	F	

表 4.3.5 臺南場域假日尖峰延滯與服務水準

方向		假日尖峰		
		各方向延滯	服務水準	平均延滯
A	台 86 線往西	23.4	B	47.4 服務水準 D
B	台 19 甲線往北	91.8	F	
C	台 86 線往東	43.3	C	
D	台 19 甲線往南	107.4	F	

觀察臺南場域的延滯與服務水準資料，發現幹道台 86 線的服務水準皆較台 19 甲線來得好，尤其在平日上下午尖峰與假日尖峰時段，幹道服務水準皆在 B~C 級左右，但支道的服務水準只有 E~F 級。

4.3.2 臺北市場域交通現況分析

4.3.2.1 現況道路特性

調查範圍道路包含中山北路、德行東西路、克強路。其道路幾何特性資料彙整如表 4.3.6，包含了車道數、車道寬、分隔方式等。

表 4.3.6 臺北市場域道路幾何特性

路名	道路類型	車道數	車道寬	分隔方式	車種管制
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
德行東路	一般道路	1	4.5	雙黃線	混合車道
德行西路	一般道路	2	3.0(直右)、 3.5(直左)	雙黃線	混合車道

4.3.2.2 號誌時制計畫

圖 4.3.10 至圖 4.3.18 表示臺北市場域各路口時制計畫與時相組態。

※參數順序為：黃、全紅、行人閃、行人停

時制	週期	時差	方向	時相	時相一	時相二	時相三	時相四	時相五	時相六
01	120	50	0	55	60	15	20	25		
					3,2,7,10	3,2,0,0	0,0,0,0	3,2,10,10		
02	150	68	0	F0	82	10	8	10	40	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,15	
03	200	69	0	F0	120	10	8	10	52	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,20	
04	150	70	0	F0	82	10	8	10	40	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,15	
05	120	50	0	55	60	15	20	25		
					3,2,7,10	3,2,0,0	0,0,0,0	3,2,10,10		
06	90	40	0	55	45	10	10	25		
					3,2,7,10	3,2,0,0	0,0,0,0	3,2,15,5		
08	150	60	0	F0	75	10	8	10	47	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,15	
09	200	70	0	F0	120	10	8	10	52	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,20	
10	200	70	0	F0	115	10	8	10	57	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,20	
11	150	60	0	F0	80	10	8	10	42	
					3,2,7,3	3,2,0,0	3,2,0,0	3,2,0,0	3,2,17,15	

圖 4.3.10 路口 2(中山克強)號誌時制計畫

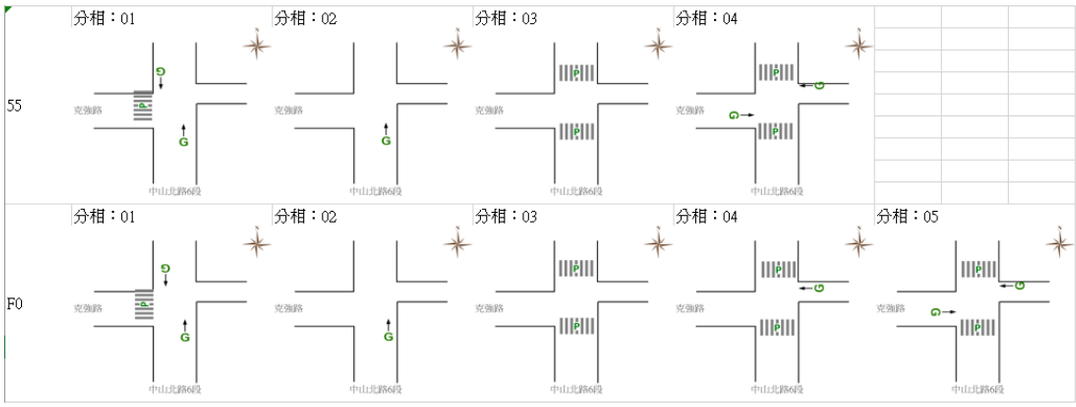

圖 4.3.11 路口 2(中山克強)號誌時相型態

	一	二	三	四	五	六	日
時間	00:00	00:00	00:00	00:00	00:00	00:00	00:00
時制	05	05	05	05	05	05	05
時間	01:00	01:00	01:00	01:00	01:00	01:00	01:00
時制	06	06	06	06	06	06	06
時間	05:00	05:00	05:00	05:00	05:00	05:00	05:00
時制	01	01	01	01	01	01	01
時間	07:00	07:00	07:00	07:00	07:00	07:00	07:00
時制	09	09	09	09	09	03	03
時間	09:00	09:00	09:00	09:00	09:00	09:00	09:00
時制	04	04	04	04	04	03	03
時間	13:00	13:00	13:00	13:00	13:00	13:30	13:30
時制	02	02	02	02	02	03	03
時間	16:30	16:30	16:30	16:30	16:30	16:30	16:30
時制	10	10	10	10	10	03	03
時間	19:00	19:00	19:00	19:00	19:00	19:00	19:00
時制	08	08	08	08	08	03	03
時間	22:00	22:00	22:00	22:00	22:00	22:00	22:00
時制	11	11	11	11	11	11	11
時間	23:00	23:00	23:00	23:00	23:00	23:00	23:00
時制	05	05	05	05	05	05	05

圖 4.3.12 路口 2(中山克強)號誌時制計畫

					※參數順序為：黃、全紅、行人閃、行人停					
時制	週期	時差	方向	時相	時相一	時相二	時相三	時相四	時相五	時相六
01	120	50	0	3C	75	15	30			
					3,2,7,3	3,2,7,3	3,2,7,3			
02	150	60	0	3C	100	15	35			
					3,2,7,3	3,2,7,3	3,2,7,3			
03	200	70	0	3C	140	25	35			
					3,2,7,3	3,2,7,3	3,2,7,3			
04	150	60	0	3C	100	15	35			
					3,2,7,3	3,2,7,3	3,2,7,3			
05	120	50	0	3C	75	15	30			
					3,3,7,3	3,2,7,3	3,3,7,3			
06	90	40	0	3C	45	15	30			
					3,3,7,3	3,2,7,3	3,3,7,3			
08	150	60	0	3C	100	15	35			
					3,2,7,3	3,2,7,3	3,2,7,3			
09	200	65	0	3C	140	25	35			
					3,2,7,3	3,2,7,3	3,2,7,3			
10	200	60	0	3C	120	25	55			
					3,2,7,3	3,2,7,3	3,2,7,3			
11	150	60	0	3C	100	15	35			
					3,2,7,3	3,2,7,3	3,2,7,3			

圖 4.3.13 路口 3(中山 195 巷)號誌時制計畫

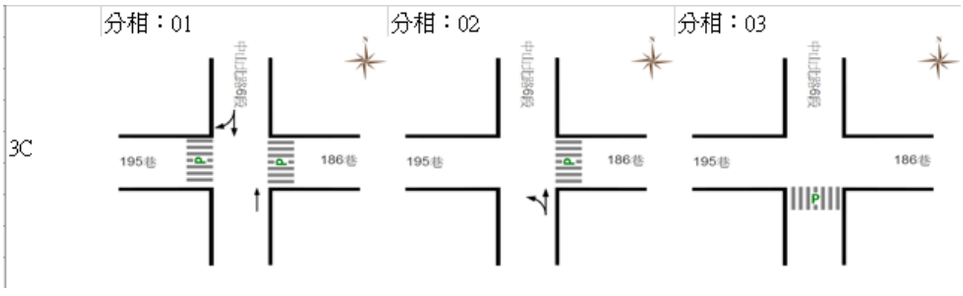

圖 4.3.14 路口 3(中山 195 巷)號誌時相型態

	一	二	三	四	五	六	日
時間	00:00	00:00	00:00	00:00	00:00	00:00	00:00
時制	05	05	05	05	05	05	05
時間	01:00	01:00	01:00	01:00	01:00	01:00	01:00
時制	06	06	06	06	06	06	06
時間	05:00	05:00	05:00	05:00	05:00	05:00	05:00
時制	01	01	01	01	01	01	01
時間	07:00	07:00	07:00	07:00	07:00	07:00	07:00
時制	09	09	09	09	09	03	03
時間	09:00	09:00	09:00	09:00	09:00	09:00	09:00
時制	04	04	04	04	04	03	03
時間	13:00	13:00	13:00	13:00	13:00	13:00	13:00
時制	02	02	02	02	02	03	03
時間	16:30	16:30	16:30	16:30	16:30	16:30	16:30
時制	10	10	10	10	10	03	03
時間	19:00	19:00	19:00	19:00	19:00	19:00	19:00
時制	08	08	08	08	08	03	03
時間	22:00	22:00	22:00	22:00	22:00	22:00	22:00
時制	11	11	11	11	11	11	11
時間	23:00	23:00	23:00	23:00	23:00	23:00	23:00
時制	05	05	05	05	05	05	05

圖 4.3.15 路口 3(中山 195 巷)號誌時制計畫

					※參數順序為：黃、全紅、行人閃、行人停					
時制	週期	時差	方向	時相	時相一	時相二	時相三	時相四	時相五	時相六
01	120	50	0	A9	10	45	10	10	30	15
					0,0,0,0	3,2,7,20	3,2,0,0	0,0,0,0	3,2,10,5	3,2,7,3
02	150	65	0	A9	14	58	14	14	35	15
					0,0,0,0	3,2,7,25	3,2,0,0	0,0,0,0	3,2,10,8	3,2,0,10
03	200	70	0	A9	10	95	10	15	50	20
					0,0,0,0	3,2,7,55	3,2,0,0	0,0,0,0	3,2,10,20	3,2,0,15
04	150	65	0	A9	15	60	10	15	35	15
					0,0,0,0	3,2,7,25	3,2,0,0	0,0,0,0	3,2,10,8	3,2,0,10
05	120	50	0	A9	10	45	10	10	30	15
					0,0,0,0	3,2,7,20	3,2,0,0	0,0,0,0	3,2,10,5	3,2,7,3
06	90	40	0	A9	5	29	6	10	25	15
					0,0,0,0	3,3,7,10	3,2,0,0	0,0,0,0	3,2,7,3	3,2,7,3
08	150	65	0	A9	10	57	10	15	43	15
					0,0,0,0	3,2,7,23	3,2,0,0	0,0,0,0	3,2,10,17	3,2,0,10
09	200	70	0	A9	10	90	10	23	45	22
					0,0,0,0	3,2,7,55	3,2,0,0	0,0,0,0	3,2,10,25	3,2,0,17
10	200	65	0	CF	10	89	15	7	55	24
					0,0,0,0	3,2,7,20	0,0,0,0	0,0,0,0	3,2,10,15	3,2,0,15
11	150	65	0	A9	10	57	10	15	43	15
					0,0,0,0	3,2,7,23	3,2,0,0	0,0,0,0	3,2,10,17	3,2,0,10

圖 4.3.16 路口 4(中山德行)號誌時制計畫

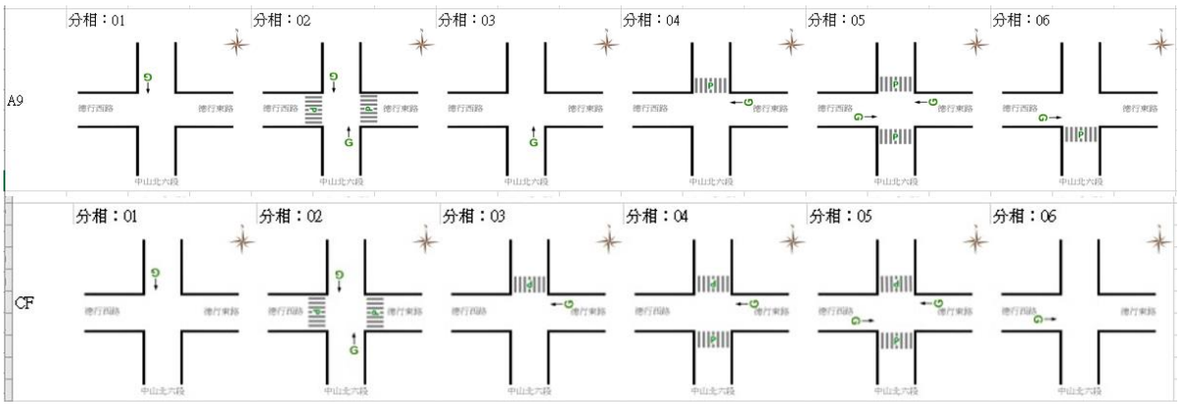

圖 4.3.17 路口 4(中山德行)號誌時相型態

	一	二	三	四	五	六	日
時間	00:00	00:00	00:00	00:00	00:00	00:00	00:00
時制	05	05	05	05	05	05	05
時間	01:00	01:00	01:00	01:00	01:00	01:00	01:00
時制	06	06	06	06	06	06	06
時間	05:00	05:00	05:00	05:00	05:00	05:00	05:00
時制	01	01	01	01	01	01	01
時間	07:00	07:00	07:00	07:00	07:00	07:00	07:00
時制	09	09	09	09	09	03	03
時間	09:00	09:00	09:00	09:00	09:00	09:00	09:00
時制	04	04	04	04	04	03	03
時間	13:00	13:00	13:00	13:00	13:00	13:00	13:00
時制	02	02	02	02	02	03	03
時間	16:30	16:30	16:30	16:30	16:30	16:30	16:30
時制	10	10	10	10	10	03	03
時間	19:00	19:00	19:00	19:00	19:00	19:00	19:00
時制	08	08	08	08	08	03	03
時間	22:00	22:00	22:00	22:00	22:00	22:00	22:00
時制	11	11	11	11	11	11	11
時間	23:00	23:00	23:00	23:00	23:00	23:00	23:00
時制	05	05	05	05	05	05	05

圖 4.3.18 路口 4(中山德行)號誌時制計畫

4.3.2.3 尖峰小時轉向交通量

圖 4.3.19 至圖 4.3.27 中，僅顯示交通調查時段之流量資料，其餘時段因未調查而無資料，但不代表真實流量為 0。考量不同時段之調查未必為同一日調查，故仍依不同天各別製圖。

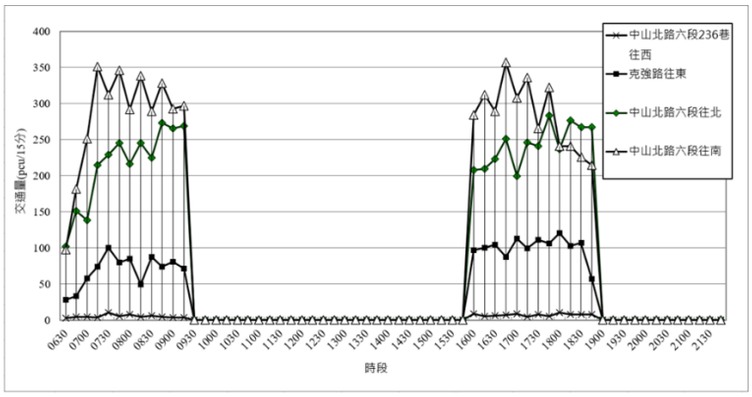

圖 4.3.19 路口 2(中山克強) 平日上下午尖峰交通總量(pcu/15min)

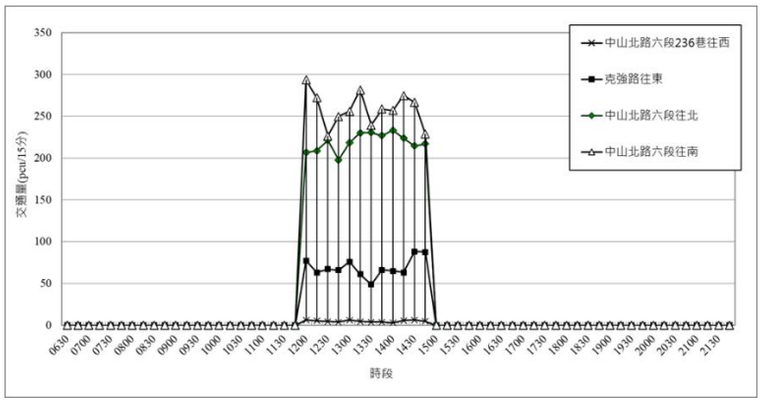

圖 4.3.20 路口 2(中山克強) 平日離峰交通總量(pcu/15min)

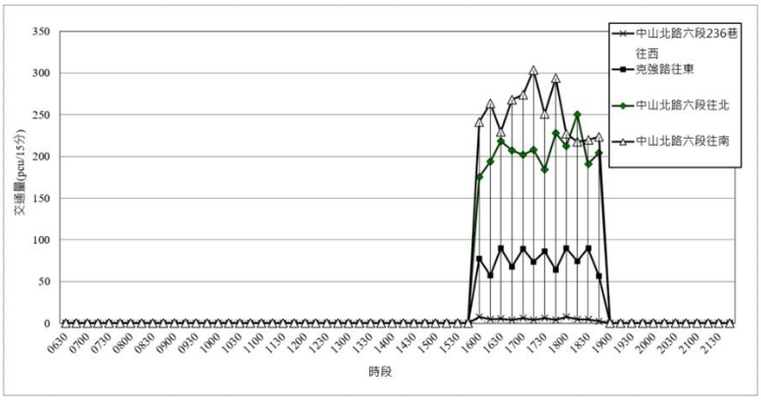

圖 4.3.21 路口 2(中山克強) 假日尖峰交通總量(pcu/15min)

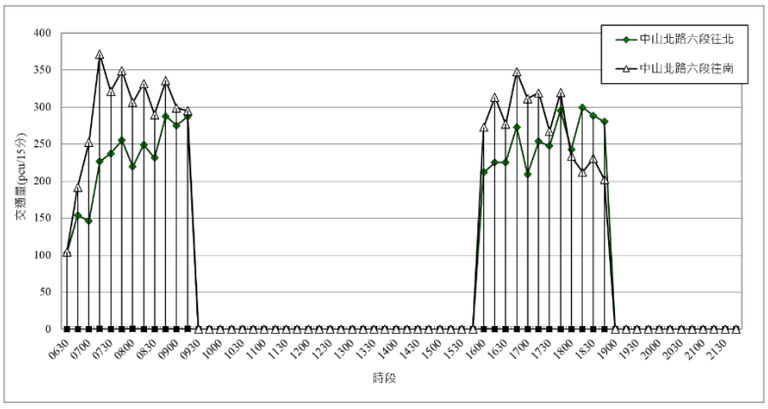

圖 4.3.22 路口 3(中山 195 巷) 平日上下午尖峰交通總量(pcu/15min)

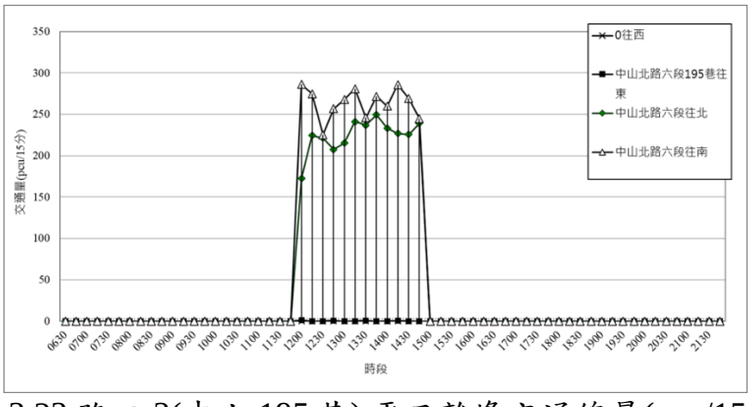

圖 4.3.23 路口 3(中山 195 巷) 平日離峰交通總量(pcu/15min)

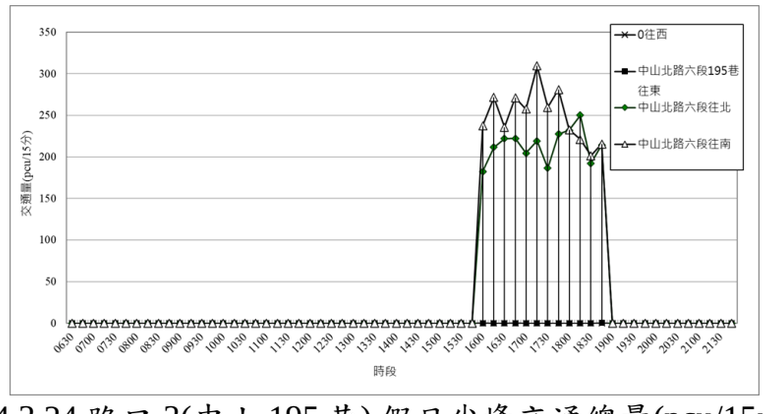

圖 4.3.24 路口 3(中山 195 巷) 假日尖峰交通總量(pcu/15min)

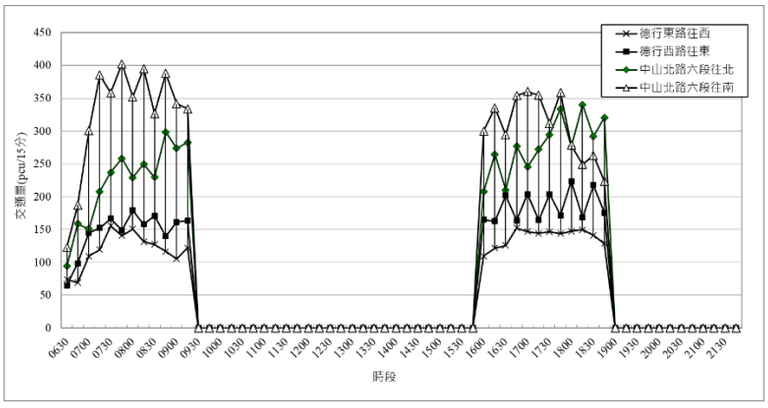

圖 4.3.25 路口 4(中山德行) 平日上下午尖峰交通總量(pcu/15min)

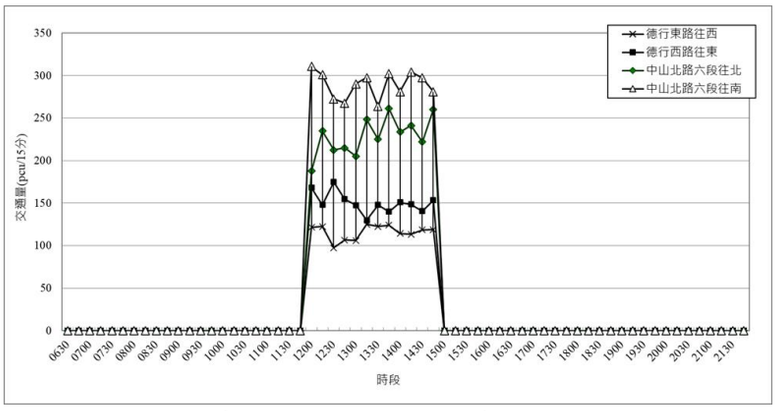

圖 4.3.26 路口 4(中山德行) 平日離峰交通總量(pcu/15min)

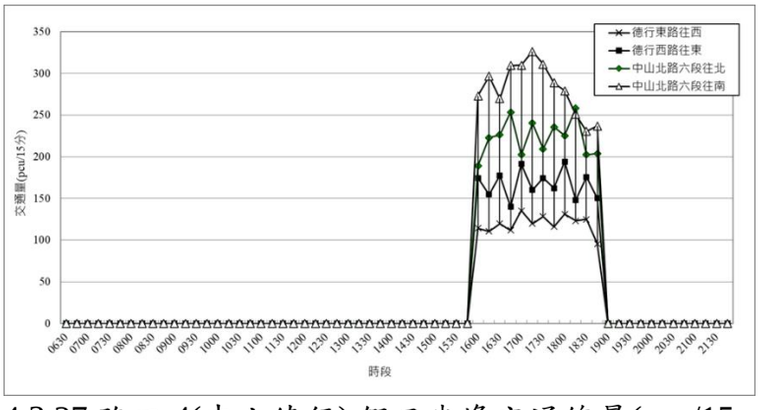

圖 4.3.27 路口 4(中山德行) 假日尖峰交通總量(pcu/15min)

從交通總量中可以發現，三處路口在平日尖峰小時發生時段略有不同。平日上午尖峰小時路口 2、3、4 分別發生在 07:15~08:15、08:30~9:30、07:30~08:30；平日下午尖峰小時則分別發生於 17:00~18:00、16:45~17:45、17:00~18:00。而在平日離峰跟假日尖峰時段，其尖峰小時的時段較為相近。平日離峰尖峰小時路口 2、3、4 皆發生在 13:45~14:45；假日尖峰則分別發生於 17:00~18:00、17:15~18:15、16:45~17:45。後續根據以上分析尖峰小時時段，分別製作轉向交通量圖。

圖 4.3.28 至圖 4.3.39 中，觀察各路口的轉向交通量可發現，臺北市場

域為一標準的幹道路段，不論平日尖峰、平日離峰或假日尖峰等時段，路口 2、3、4 的南北向幹道直行比例皆占了 80%以上。而在支道轉向上，路口 2、3 支道主要是左右轉向幹道方向；但路口 4 的支道則是直行比例有 60~75%上下，為其較特別之處。

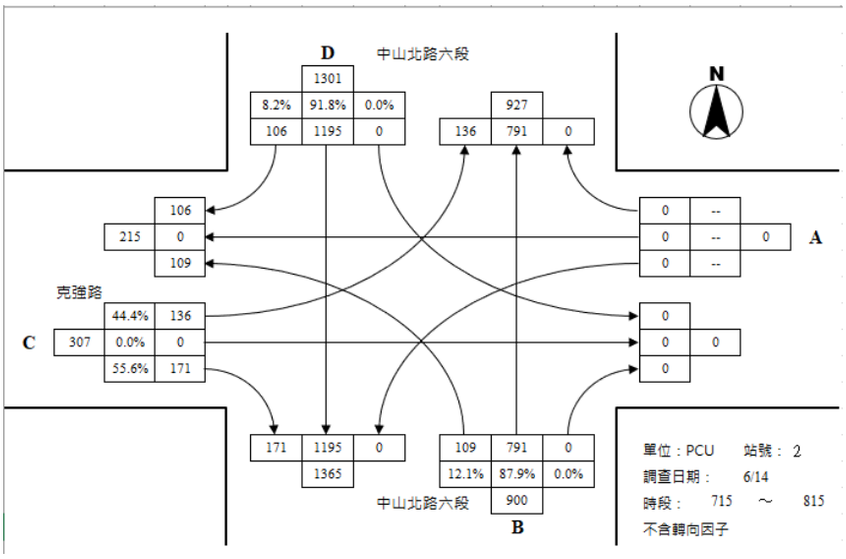

圖 4.3.28 路口 2(中山克強) 平日上午尖峰小時轉向交通量

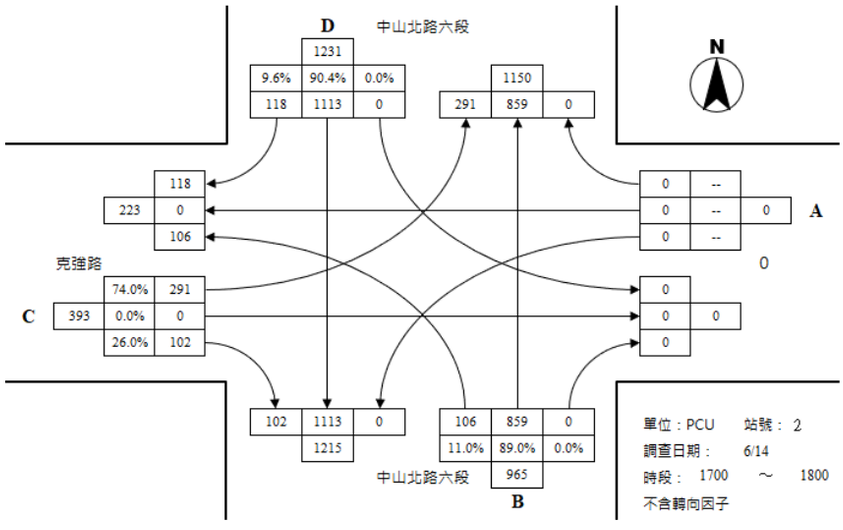

圖 4.3.29 路口 2(中山克強) 平日下午尖峰小時轉向交通量

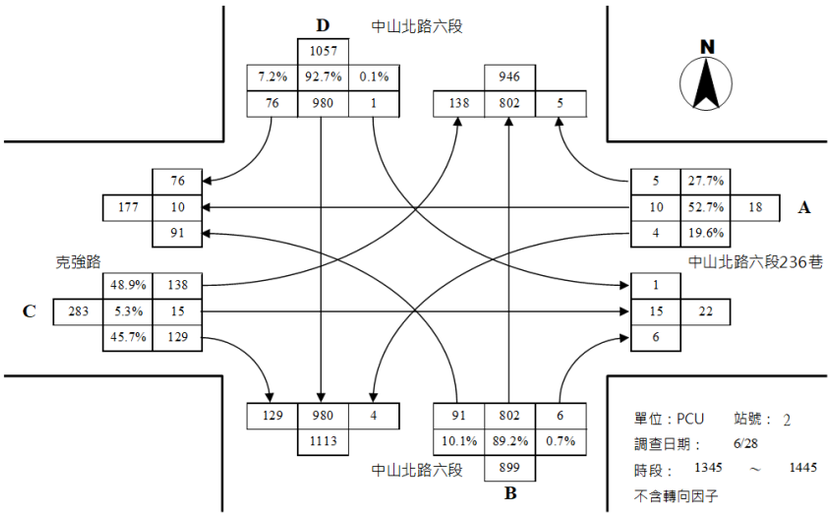

圖 4.3.30 路口 2(中山克強)平日離峰尖峰小時轉向交通量

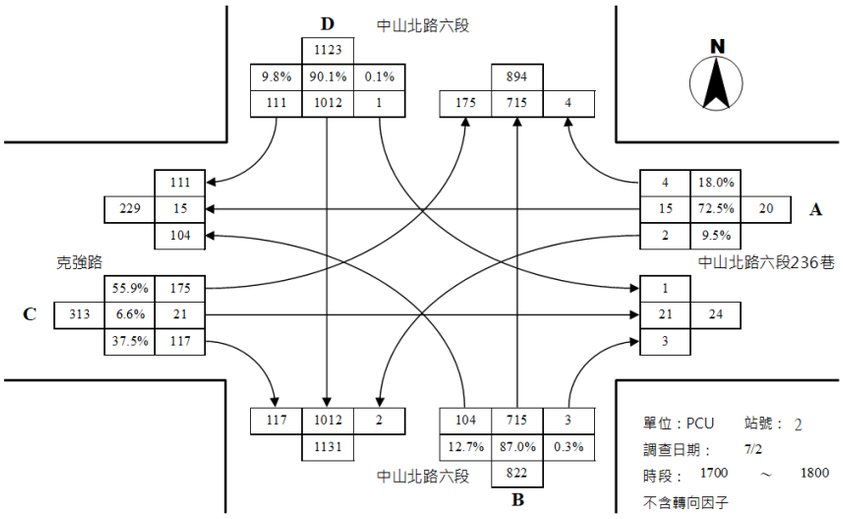

圖 4.3.31 路口 2(中山克強) 假日尖峰小時轉向交通量

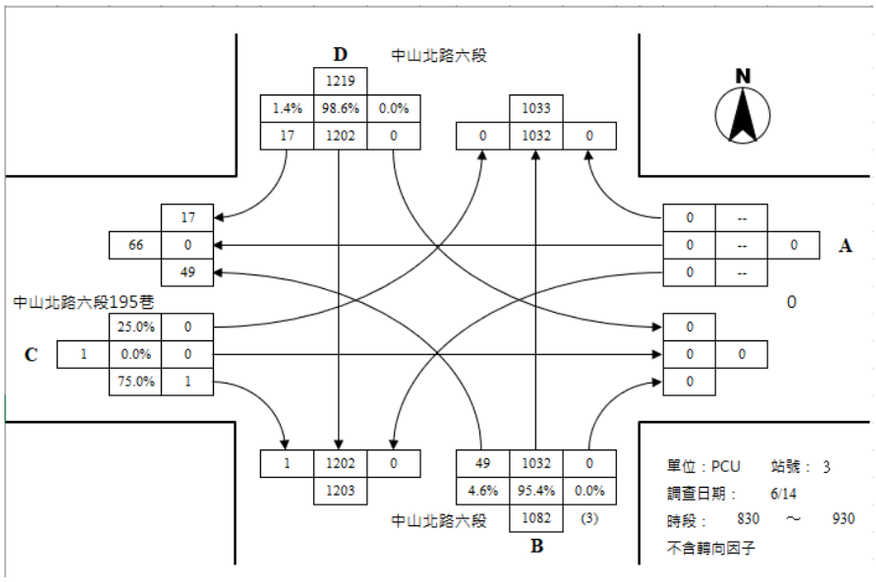

圖 4.3.32 路口 3(中山 195 巷) 平日上午尖峰小時轉向交通量

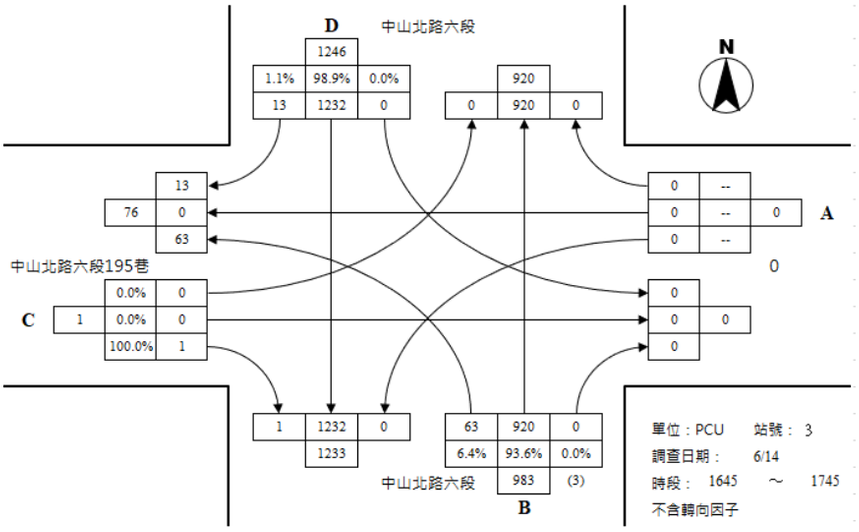

圖 4.3.33 路口 3(中山 195 巷) 平日下午尖峰小時轉向交通量

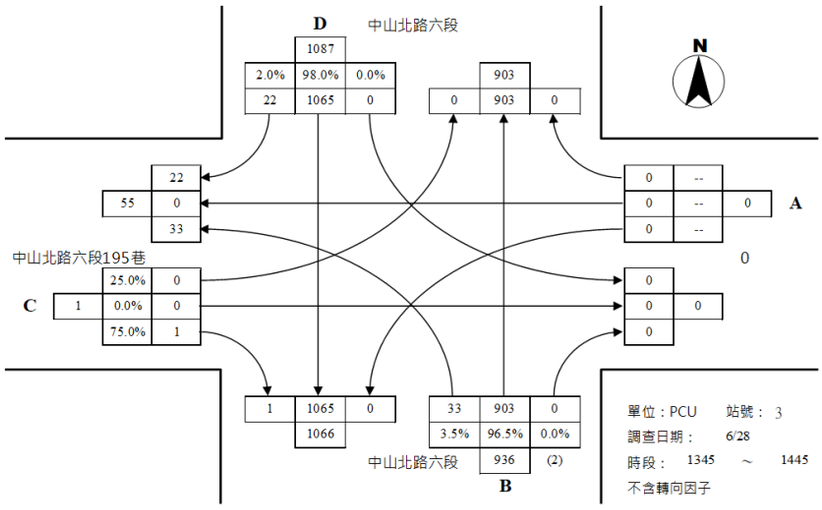

圖 4.3.34 路口 3(中山 195 巷) 平日離峰尖峰小時轉向交通量

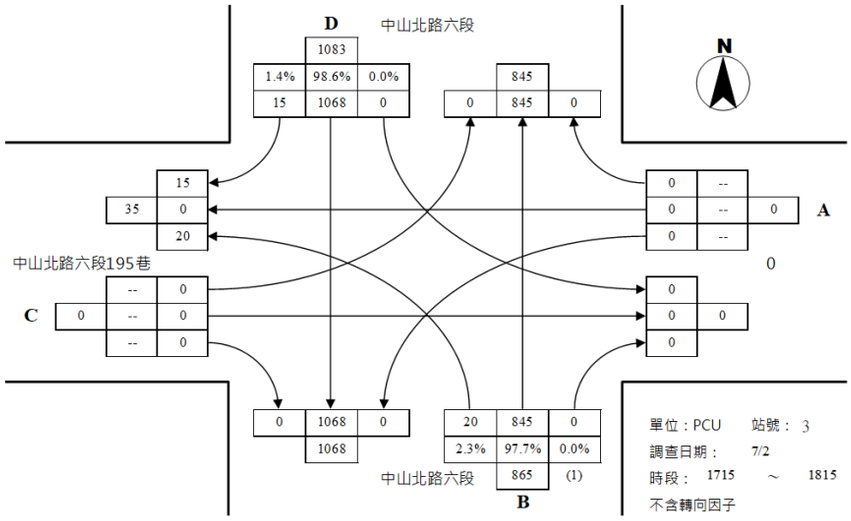

圖 4.3.35 路口 3(中山 195 巷) 假日尖峰小時轉向交通量

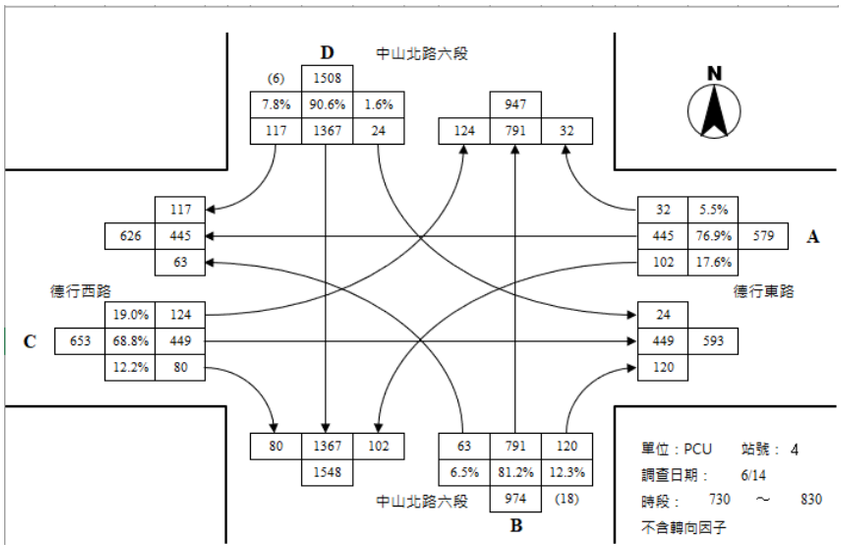

圖 4.3.36 路口 4(中山德行) 平日上午尖峰小時轉向交通量

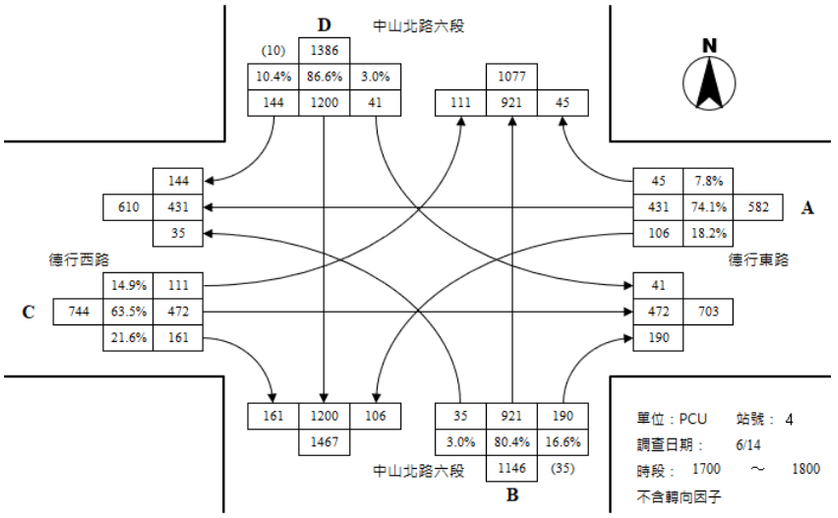

圖 4.3.37 路口 4(中山德行) 平日下午尖峰小時轉向交通量

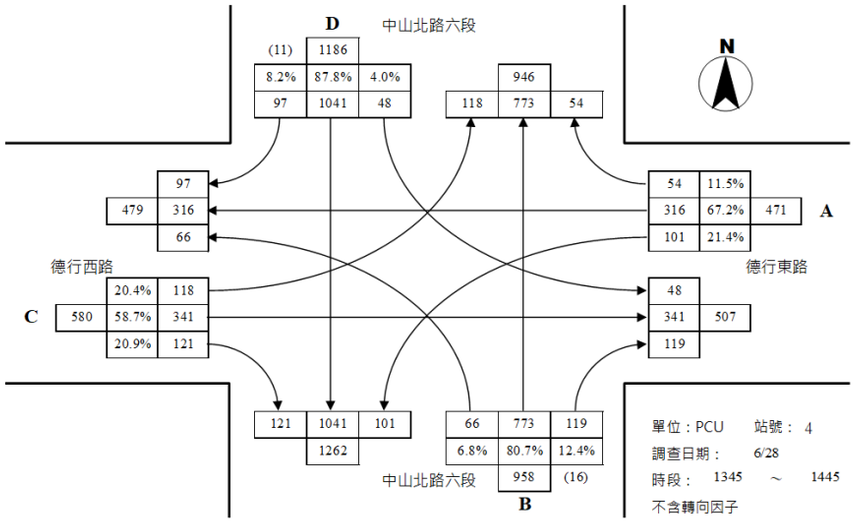

圖 4.3.38 路口 4(中山德行) 平日離峰尖峰小時轉向交通量

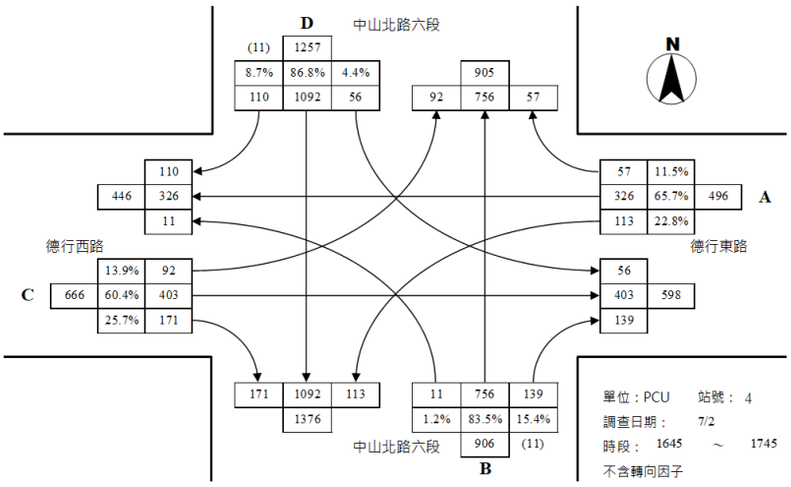

圖 4.3.39 路口 4(中山德行) 假日尖峰小時轉向交通量

4.3.2.4 尖峰小時延滯

表 4.3.7 至表 4.3.9 整理臺北市場域各路口延滯與服務水準狀況。

表 4.3.7 臺北市場域平日上下午尖峰延滯與服務水準

路口	方向		平日晨峰			平日昏峰		
			各方向延滯	服務水準	平均延滯	各方向延滯	服務水準	平均延滯
2	B	中山北路往北	9.6	A	14.5 服務水準 A	14.8	A	28.8 服務水準 B
2	C	克強路往東	73.0	F		110.5	F	
2	D	中山北路往南	4.1	A		11.7	A	
3	B	中山北路往北	2.4	A	2.3 服務水準 A	6.3	A	8.6 服務水準 A
3	D	中山北路往南	2.2	A		10.4	A	
4	A	德行東路往西	49.0	D	25.7 服務水準 B	69.7	E	37.0 服務水準 C
4	B	中山北路往北	7.1	A		14.2	B	
4	C	德行西路往東	39.2	C		66.9	E	
4	D	中山北路往南	23.4	B		29.1	B	

表 4.3.8 臺北市場域平日離峰延滯與服務水準

路口	方向		平日離峰		
			各方向延滯	服務水準	平均延滯
2	B	中山北路往北	12.5	A	15.1 服務水準 B
2	C	克強路往東	46.3	D	
2	D	中山北路往南	9.9	A	
3	B	中山北路往北	1.4	A	1.8 服務水準 A
3	D	中山北路往南	2.1	A	
4	A	德行東路往西	86.6	F	38.5 服務水準 C
4	B	中山北路往北	22.8	B	
4	C	德行西路往東	61.8	E	
4	D	中山北路往南	22.8	B	

表 4.3.9 臺北市場域假日尖峰延滯與服務水準

路口	方向		假日尖峰		
			各方向延滯	服務水準	平均延滯
2	B	中山北路往北	13.9	A	23.4 服務水準 B
2	C	克強路往東	78.5	E	
2	D	中山北路往南	15.6	B	
3	B	中山北路往北	3.9	A	3.0 服務水準 A
3	D	中山北路往南	2.2	A	
4	A	德行東路往西	99.1	F	41.0 服務水準 C
4	B	中山北路往北	8.9	A	
4	C	德行西路往東	98.4	F	
4	D	中山北路往南	15.0	B	

從臺北市場域的延滯與服務水準資料來看，在所有時段下，幹道中山北路南北雙向的服務水準皆有 A~B 級；但在支道方向則大部分只有 D~E 級，少數時段甚至只有 F 級。由此可知目前定時時制計畫內容，對於幹道續進的時差設計效果相當不錯。

4.3.2.5 旅行時間

旅行時間調查起訖點如圖 4.3.40 所示。調查方式為每 30 分鐘派遣一趟次探針車方式，紀錄通過各路口時間。圖中北向為綠色箭頭所示；南

向為藍色箭頭所示。起訖點設定如下：北向以通過路口 5(忠誠路)停止線起算；以通過路口 2(克強路)停止線為止。南向以通過路口 1(290 巷)停止線起算；以通過路口 4(德行東路)停止線為止。調查結果如所示。

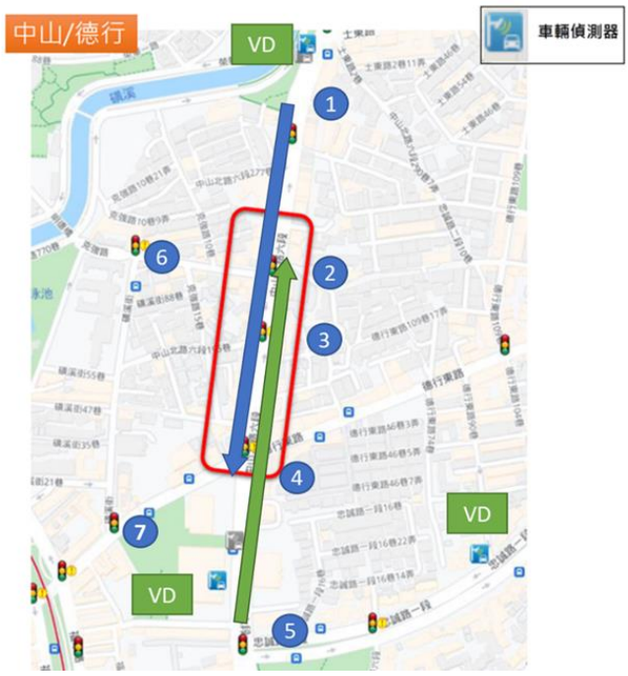

圖 4.3.40 臺北市場域旅行時間調查起訖位置

從表 4.3.10 中可以發現，由於本身旅次起迄距離較短(往南 440m、往北 550m)，加上受號誌化停等影響甚大，說明該旅行時間調查受號誌影響程度遠大於車流壅塞程度所造成的影響。下圖將總旅行時間扣除停等紅燈秒數後繪製旅行時間趨勢圖。

表 4.3.10 臺北市場域平日上下午尖峰旅行時間調查

發車時間點	南向		北向	
	總時間(秒)	停等紅燈(秒)	總時間(秒)	停等紅燈(秒)
06:30	80	27	98	39
07:00	119	73	48	0
07:30	45	0	69	0
08:00	40	0	76	0
08:30	41	0	58	0
09:00	130	76	70	0
16:00	131	79	204	91
16:30	52	0	66	0
17:00	139	62	64	0
17:30	51	0	78	0

18:00	49	0	169	73
18:30	174	97	199	68

表 4.3.11 臺北市場域平日離峰旅行時間調查

發車時間點	南向		北向	
	總時間(秒)	停等紅燈(秒)	總時間(秒)	停等紅燈(秒)
12:00	108	45	51	0
12:30	100	43	129	62
13:00	40	0	133	54
13:30	126	68	230	123
14:00	118	54	170	77
14:30	61	0	162	81

表 4.3.12 臺北市場域假日尖峰旅行時間調查

發車時間點	南向		北向	
	總時間(秒)	停等紅燈(秒)	總時間(秒)	停等紅燈(秒)
16:00	142	96	45	0
16:30	128	73	66	0
17:00	80	21	137	63
17:30	144	62	55	0
18:00	135	70	63	0
18:30	132	74	143	84

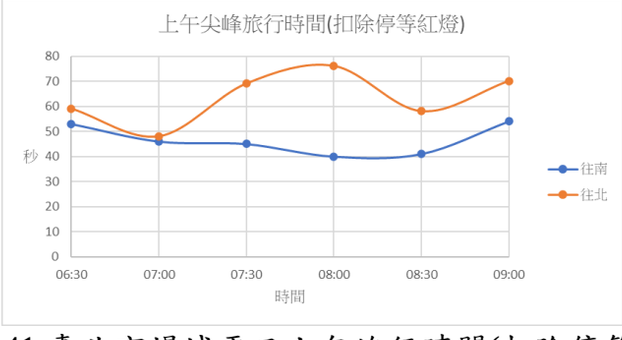

圖 4.3.41 臺北市場域平日上午旅行時間(扣除停等紅燈)

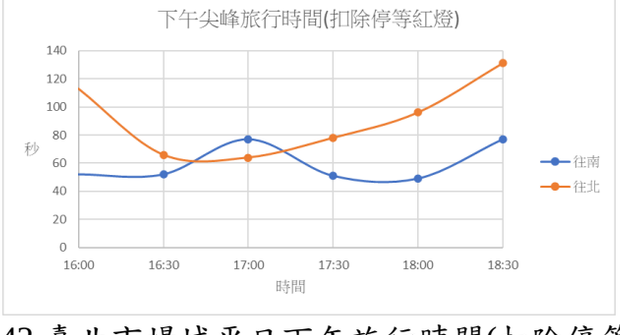

圖 4.3.42 臺北市場域平日下午旅行時間(扣除停等紅燈)

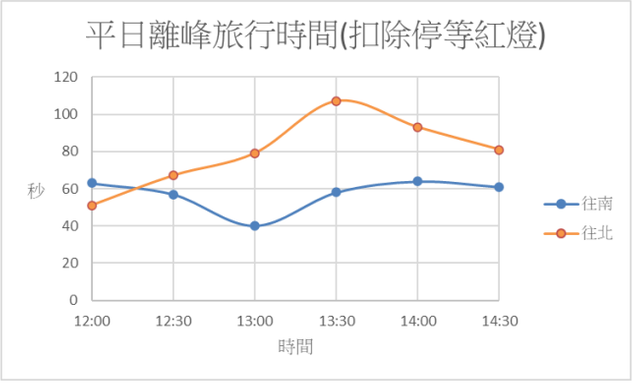

圖 4.3.43 臺北市場域平日離峰旅行時間(扣除停等紅燈)

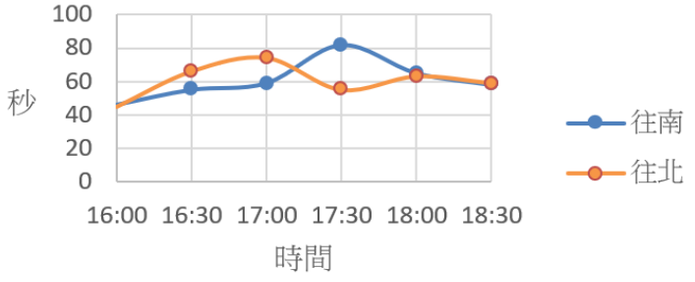

圖 4.3.44 臺北市場域假日尖峰旅行時間(扣除停等紅燈)

4.3.3 高雄市場域交通現況分析

4.3.3.1 現況道路特性

調查範圍道路包含台 88 線鳳山匝道、過埤路快車道、過埤路慢車道、鳳頂路、保生路、頂庄路。其道路幾何特性資料彙整如表 4.3.13，包含車道數、車道寬、分隔方式等。

表 4.3.13 高雄市場域道路幾何特性

路名	道路類型	車道數	車道寬	分隔方式	車種管制
保生路	一般道路	2	4.5(直外)、3.2(直內)	雙黃線	
頂庄路	一般道路	1	5	雙黃線	
過埤路西向快車道	一般道路	2	3.5(直外)、3.5(直內)	實體分隔	禁行機車
台 88 線鳳山西向出口	快速道路	1 (實際車流行為多為並排)	6.2	實體分隔	禁行機車
過埤路西向慢車道	一般道路	1	3.5	實體分隔	

過埤路 東向快車道	一般 道路	2	3.5(直外)、3.5(直內)	實體分隔	禁行機車
台 88 線鳳山 東向出口	快速 道路	2	3.5(直外)、3.5(直內)	實體分隔	禁行機車
過埤路 東向慢車道	一般 道路	1	3.5	實體分隔	
鳳頂路北向	一般 道路	5	4.0(右)、3.5(機優)、 3.3(直)、3.3(左外)、 3.5(左內)	實體分隔	內側 3 車 道禁行機 車
鳳頂路南向	一般 道路	5	4.2(右)、3.5(機優)、 3.5(直)、3.5(左外)、 3.5(左內)	實體分隔	內側 3 車 道禁行機 車

4.3.3.2 號誌時制計畫

圖 4.3.45 至圖 4.3.47 表示高雄市場域路口時制計畫與時相組態。

時制計畫編號	時相編號	時差	週期	時相一					時相二					時相三					時相四					時相五					時相六				
				1.縣道188東西向直行對開 2.慢車道直行右轉					1.縣道188東西向慢車道關 2.縣道188東往西快車道開直+右 3.縣道188西往東快車道開(圓頭綠)					1.縣道188東往西匝道下及西往東匝道下直行帶右轉 2.鳳頂路南往北紅燈右轉					1.縣道188東往西匝道下開 2.縣道188西往東匝道下紅燈右轉 3.南往北紅燈右轉					1.鳳頂路南往北開 2.縣道188西往東匝道下紅燈右轉					鳳頂路北往南 (往小港)				
				PH	G	PF	Y	R	PH	G	PF	Y	R	PH	G	PF	Y	R	PH	G	PF	Y	R	PH	G	PF	Y	R	PH	G	PF	Y	R
17	114 72H	0	220	42			4	4	33			4	4	50			4	4	25			4	4	38			4	4	32			4	5
18	114 72H	0	180	41			4	4	30			4	4	34			4	4	17			4	4	26			4	4	32			4	5
20	114 72H	0	200	42			4	4	24			4	4	46			4	4	20			4	4	36			4	4	32			4	5

圖 4.3.45 過埤鳳頂號誌時制計畫

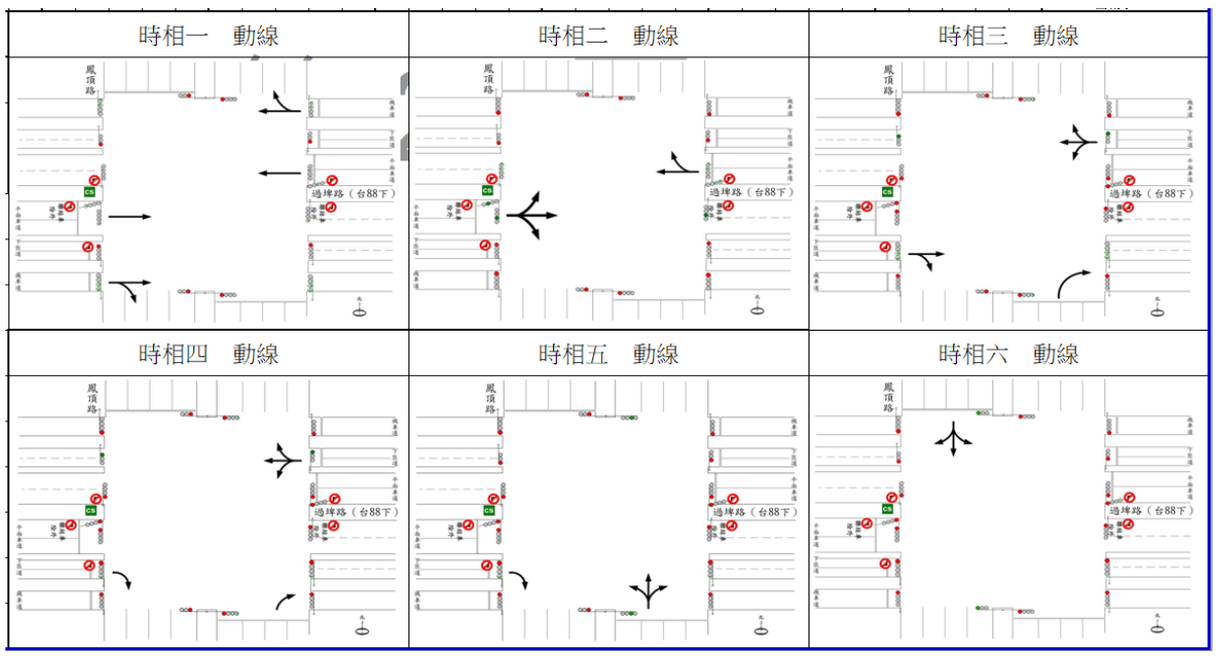

圖 4.3.46 過埤鳳頂號誌時相型態

區域	週內日		時制計畫編號	時相編號	時差	週期	時段型態					
鳳山區	星期	時段型態					8			9		
路口名稱	一	8					時	分	時制計畫	時	分	時制計畫
過埤路 鳳頂路	二	8										
	三	8	17	114 72H	0	220	7	0	17	7	0	17
	四	8	18	114 72H	0	180	9	0	20	19	0	18
良基	五	8	20	114 72H	0	200	19	0	18			
設備編號	六	9										
S341101	日	9										

圖 4.3.47 過埤鳳頂號誌 TOD 計畫

4.3.3.3 尖峰小時轉向交通量

圖 4.3.38 至圖 4.3.50 僅顯示交通調查時段之流量資料，其餘時段因未調查而無資料，但不代表真實流量為 0。考量不同時段之調查未必為同一日調查，故仍依不同天各別製圖。

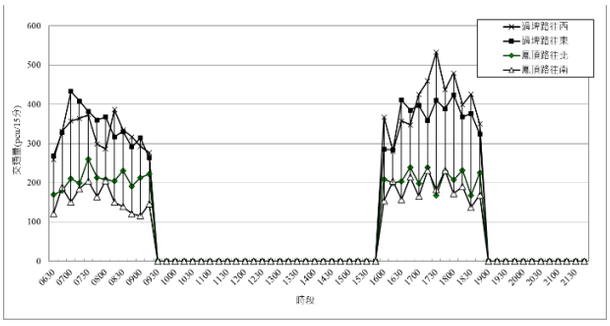

圖 4.3.48 過埤鳳頂平日上下午尖峰交通總量(pcu/15min)

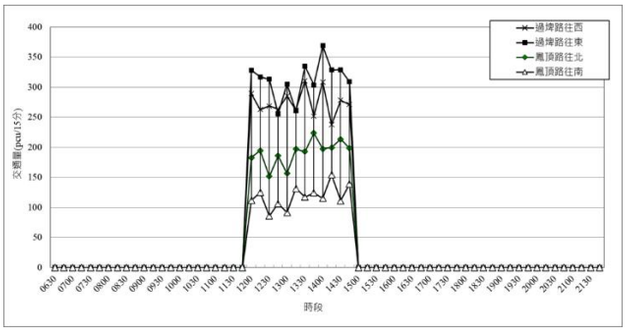

圖 4.3.49 過埤鳳頂平日離峰交通總量(pcu/15min)

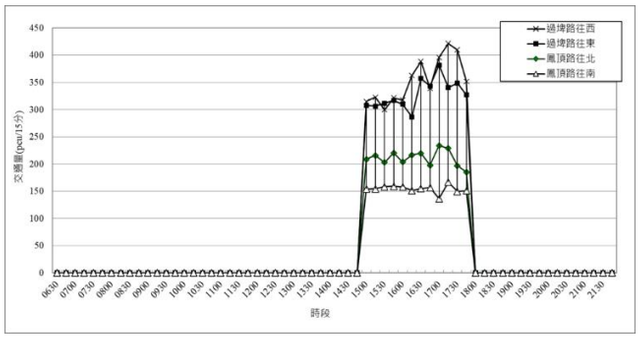

圖 4.3.50 過埤鳳頂假日尖峰交通總量(pcu/15min)

從交通總量中可以發現，平日上午尖峰小時發生在 07:00~08:00；平日下午尖峰小時則發生於 17:15~18:15；平日離峰尖峰小時發生在 13:30~14:30；假日尖峰小時則發生於 16:30~17:30。根據以上分析尖峰小時時段，分別製作轉向交通量圖。

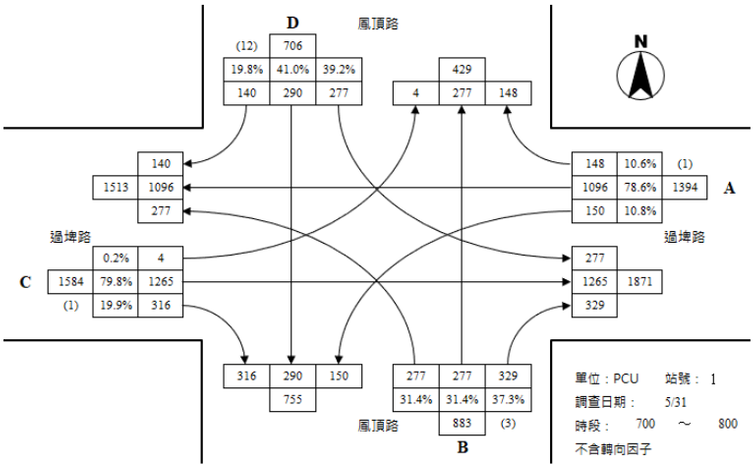

圖 4.3.51 過埤鳳頂平日上午尖峰小時轉向交通量

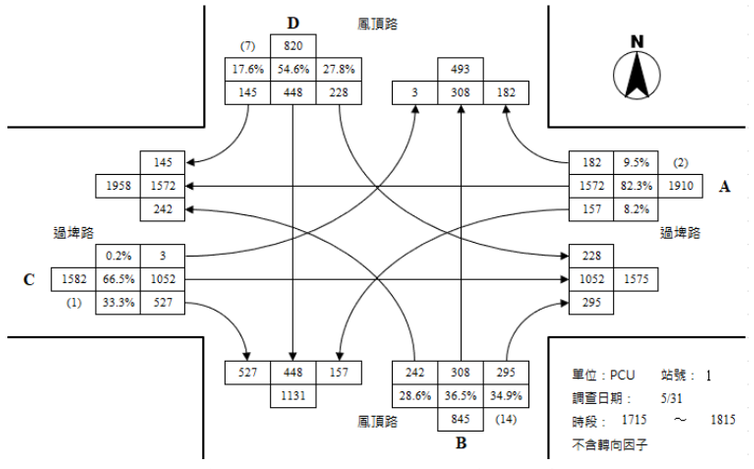

圖 4.3.52 過埤鳳頂平日下午尖峰小時轉向交通量

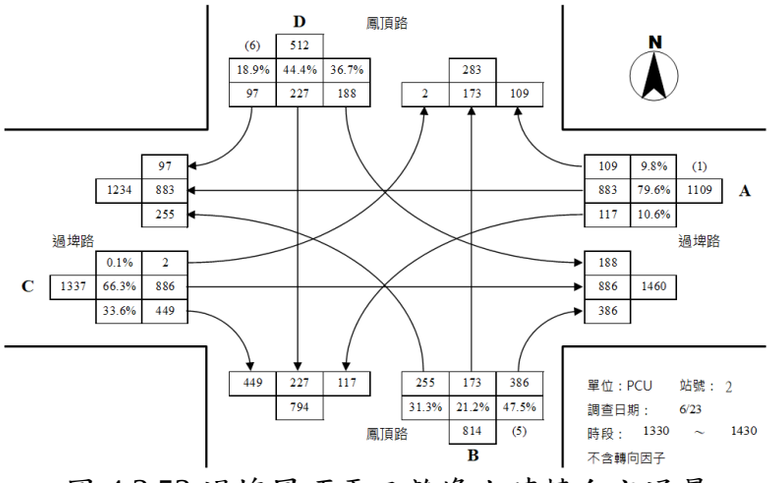

圖 4.3.53 過埤鳳頂平日離峰小時轉向交通量

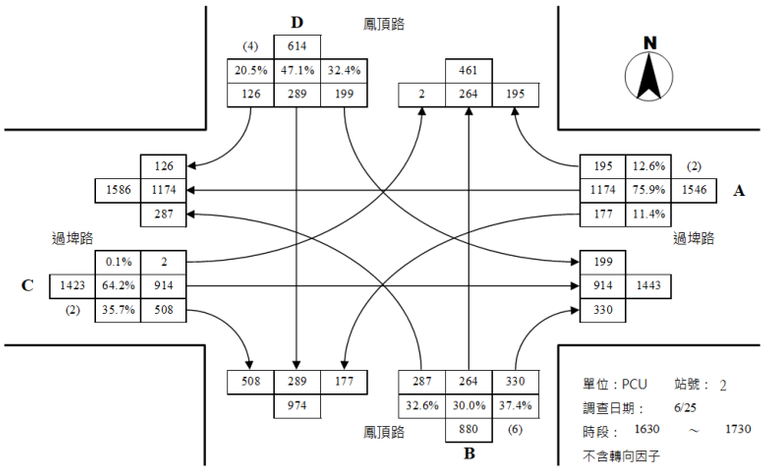

圖 4.3.54 過埤鳳頂假日尖峰小時轉向交通量

從轉向交通量數據來看，過埤路東西向車流以直行比例較高，約在60~80%之間；鳳頂路往北則是左直右各方向比例較平均，各佔 30%上下；鳳頂路往南則是以直行與左轉比例較高，右轉相對較小。

4.3.3.4 尖峰小時延滯

以下表 4.3.14 至表 4.3.16 表示高雄市場域路口延滯與服務水準狀況。

表 4.3.14 高雄市場域平日上下午尖峰延滯與服務水準

方向		平日晨峰			平日昏峰		
		各方向延滯	服務水準	平均延滯	各方向延滯	服務水準	平均延滯
A	過埤路往西快車道	48.1	D	68.6 服務水準 E	52.4	E	98.7 服務水準 F
A	台 88 線鳳山出口往西	93.2	F		196.3	F	
B	鳳頂路往北	70.9	E		56.5	E	
C	過埤路往東快車道	57.0	C		87.9	F	
C	台 88 線鳳山出口往東	42.7	C		60.9	E	
D	鳳頂路往南	99.6	F		155.1	F	

表 4.3.15 高雄市場域平日離峰延滯與服務水準

方向		平日離峰		
		各方向延滯	服務水準	平均延滯
A	過埤路往西快車道	45.3	D	76.7 服務水準 E
A	台 88 線鳳山出口往西	207.0	F	
B	鳳頂路往北	55.3	D	
C	過埤路往東快車道	52.3	D	

C	台 88 線鳳山出口往東	40.4	D	
D	鳳頂路往南	78.3	E	

表 4.3.16 高雄市場域假日尖峰延滯與服務水準

方向		假日尖峰		
		各方向延滯	服務水準	平均延滯
A	過埤路往西快車道	50.0	D	71.7 服務水準 E
A	台 88 線鳳山出口往西	114.3	F	
B	鳳頂路往北	63.5	E	
C	過埤路往東快車道	50.5	D	
C	台 88 線鳳山出口往東	43.6	C	
D	鳳頂路往南	102.6	F	

在延滯與服務水準調查數據上，該路口除了過埤路往東方向在某幾個時段服務水準有達到 C 級水準外，其他方向在各時段的服務水準皆在 D 級以下，整體路口的服務水準也都只有 E~F 級。

4.3.3.5 停等車隊長度

高雄市場域安排停等車隊長度調查的原因，主要是由於本場域已安裝停等車隊長度偵測設備。然該設備是透過 103 年適應性號誌控制建置計畫案[108]所安裝，年代較久，其準確度或校準維護工作於近年內未有公開報告可供確認。因此在本計畫中安排停等車隊長度之調查，用以確認該設備偵測效果與目前現況之配合程度，並於後續評估是否可做為 AI 號誌輸入資訊之一。調查結果如圖 4.3.55 至圖 4.3.58 所示。

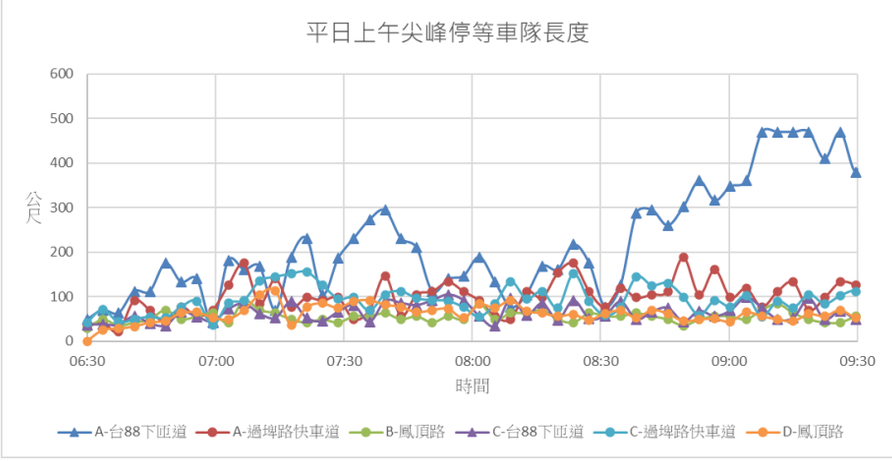

圖 4.3.55 過埤鳳頂平日上午尖峰停等車隊長度

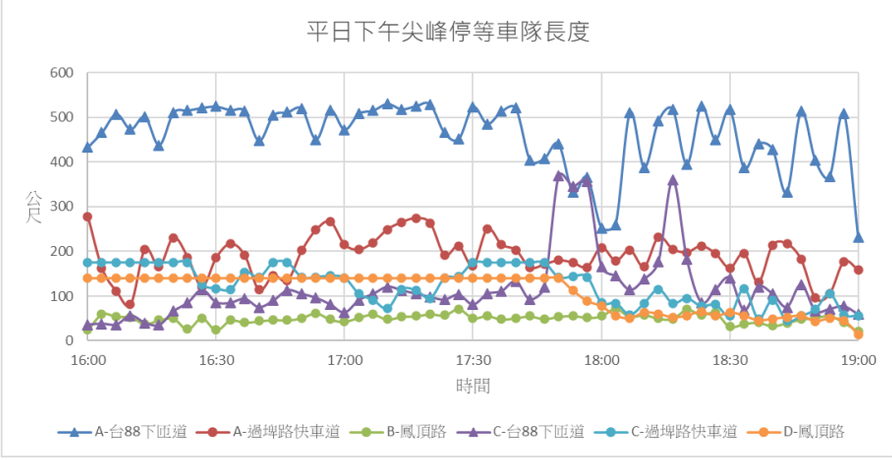

圖 4.3.56 過埤鳳頂平日下午尖峰停等車隊長度

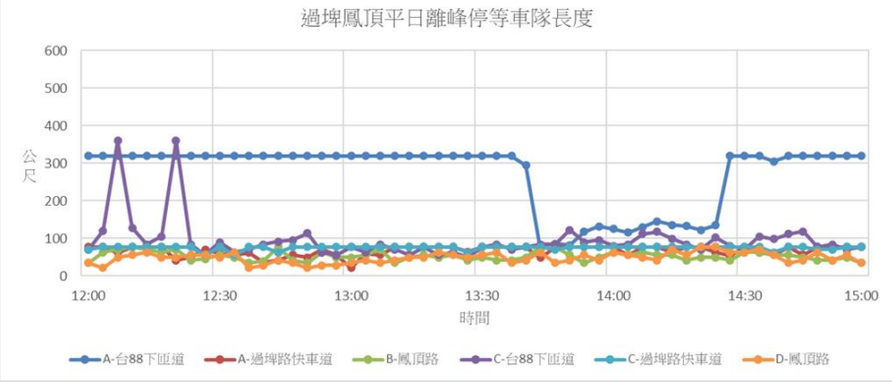

圖 4.3.57 過埤鳳頂平日離峰停等車隊長度

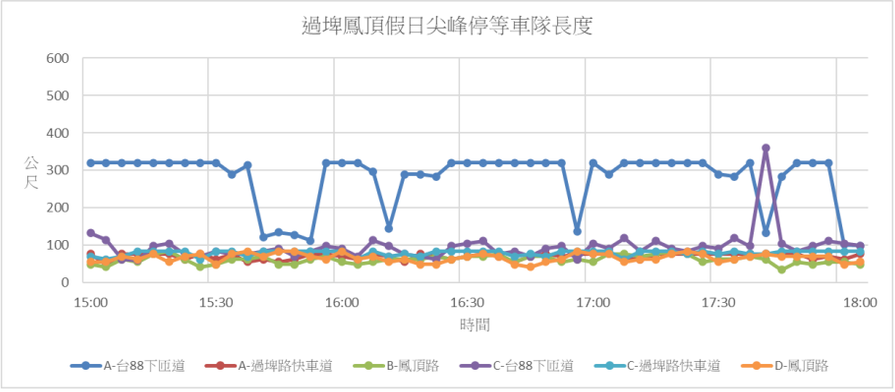

圖 4.3.58 過埤鳳頂假日尖峰停等車隊長度

其中特別需要說明的是平日離峰與假日尖峰的調查過程中，由於受到拍攝角度的限制與影響，導致僅能辨識到停止線上游 310 公尺，即真實停等車隊長度若超過 310 公尺即無法判讀。(註：平日上午尖峰與平日下午尖峰為同一天調查；平日離峰與假日尖峰則其他天調查，因此導致拍攝角度不相同的狀況)

從停等車隊長度折線圖來看，不論在任何時段，皆以 A 方向台 88 線線下匝道往西的停等車隊長度最顯著。在平日下午尖峰時段，有一半的時間以上皆達到 500 公尺長；在平日離峰與假日尖峰時段，也幾乎有 60% 以上的時間皆處在偵測器偵測長度上限 300 公尺左右。

第五章 人工智慧強化學習方案規劃與模擬模式構建

5.1 本計畫人工智慧強化學習(RL)號誌控制適用條件

RL 方法應用做法變化甚多，所能探討的可能性甚多，為讓讀者後續能夠聚焦於研究範圍中，因此在此界定本計畫中的 RL 應用作法與適用條件。首先，本計畫的 RL 應用聚焦於交通特徵輸入至類神經網路，再輸出控制項目的這一過程，以及如何使此類神經網路從初始化狀態逐步更新至完成最佳化目標的訓練過程。而為了套用此一格式，以下議題將假設為人為給定條件，不在本計畫討論範圍。

1. 時相順序與時相設計

在本計畫中所有場域的時相順序都是按照場域既有運作方式設定。在本計畫中，RL 並不涉及討論何種時相順序或是時相設計能夠提升場域績效。此種維持場域既有時相順序運作的做法，在考量駕駛人平時駕駛習慣上，對於實務單位通常也是較能接受的做法。

2. 時段切分

若場域存在不同時段採用不同時相順序或時相組合的情況，則在本計畫中將會依相場時段切分設定，執行不同的 RL 號誌控制模型。例如若上午尖峰為 5 時相號誌組合；而離峰則為 4 時相號誌組合，在此狀況下，本計畫將採用上午尖峰時段採用 5 時相 RL 號誌控制模型；離峰時段採用 4 時相 RL 號誌控制模型。

3. 最大最小綠燈秒數限制

為避免單一時相秒數過短或過長，在訓練前會先人為給定最大最小綠燈秒數的限制值。最小綠燈秒數通常是依照行人穿越所需的最小值做設定，或參考場域所有時制計畫中，最小綠燈秒數的數值。最大綠燈秒數的設定則是參考場域所有時制計畫中，最大綠燈秒數的數值，在增加 20~30 秒不等。最大最小綠燈秒數限制在實務上，應與實務管理單位討論適當數值。

4. 不同方向權重設定

在實務交通控制問題上，管理單位經常會有駕駛觀感的考量，而針對某些方向特別重視，例如幹道的績效重要程度高於支道；或某些路段的停等空間不足，需特別避免溢流狀況發生等。而在本計畫當中則暫不考慮實務上的一些偏好，所有路段的權重設定皆相同。值得一

提的是，在面對實務建置問題上，本計畫所提出的 RL 號誌控制模型保有調整不同方向不同權重設定的彈性，可視實務需求調整再加強訓練。

5. 單一獎勵目標

在 RL 方法論中的獎勵函數雖並未限制獎勵的項目，單在演算法中獎勵值本身為單一函數，而不能採用多項函數或階層式的獎勵目標。雖然許多研究中對於獎勵項目會以如不同權重的方式混合成一新的獎勵目標值，然而在權重數值設計上或最佳化目標的結果解釋上是相當困難的，因此在本計畫中是以單一的獎勵目標項目做為不同 RL 方案的設定，而不同的 RL 方案可能有不同得獎勵目標設定，例如總延滯最小、通過量最大、總停等車隊長度最小等等。

再者，本計畫中所完成訓練後的類神經網路參數(Actor)，僅適用於該場域。RL 方法在不同場域間的訓練資料應無法移轉應用，由於不同場域間之交通特性不同，因此 Actor 成果將僅適用於原設計之實驗場域。倘若欲轉移該組 Actor 至其他場域運作，則必須至少滿足：(1)車道數與路口幾何條件完全相同；(2)時相組態與順序完全相同。

由於 Actor 在設計之初便已經定義輸入資料中各維度的物理意義，因此必須要完全按照原定義的方式作輸入才至少能夠運作。然而由於各場域交通情境不可能完全相同，因此即使能夠順利將 Actor 轉移至其他場域運作，也未能確保能夠獲得良好的績效改善，因此並不建議將不同場域的 Actor 作轉移使用。唯一能夠確認的是整套 RL 訓練方法的流程是能夠適用於不同場域之間的，因此倘若是再轉移不同場域的 Actor 後仍有適當的再訓練過程，則可將轉移 Actor 做為一種起始解的作法。

5.2 號誌控制模型方案設計

透過第三章的文獻回顧可以發現到，AI 號誌控制的方法中，在架構面可以分為「輸入資料」、「輸出方式」、「最佳化目標」等三個要素，分別對應到 RL 方法論中的「狀態(State)」、「決策或動作(Action)」、「獎勵(Reward)」。而這三項要素可以有不同的組合方式，每種組合都為一種潛在的可能 AI 號誌控制方法。第二章回顧並整理了各要素可能的內容項目於表 5.2.1 中。

表 5.2.1 文獻回顧中各要素內容

輸入資料(狀態)	輸出方式(決策)	最佳化目標(獎勵)
● 分車道車輛數(密度) ● 路口轉向交通量(流量) ● 路段旅行時間(速率) ● 號誌時相指標 ● 號誌時相秒數	● 逐秒決策是否延長或切換時相 ● 逐秒決策是否延長或切換至任一時相 ● 逐時相決策該次時相秒數 ● 逐週期決策該次週期各時相秒數 ● 固定時段決策一次號誌時制	● 系統總停等延滯 ● 系統總通過車輛數 ● 平均每車停等延滯

另外在文獻回顧中也可以發現到，輸入資料中通常是可以互相替換、增減。意即資料之間即使單位或類型有所不同，透過深度學習優秀的資料融合能力[101]可使得資料之間的交互對比產生更多資訊。而在輸出方式以及最佳化目標這兩個要素當中，通常一種方案僅能對應一種輸出方式與一種最佳化目標。

在輸出方式可以理解為類神經網路的輸出格式，一組類神經網路的輸出格式必須被固定才能進行相關的訓練，因此上表中的輸出格式內容基本上屬於互斥的選項。而實務上更偏向硬體限制或執行便利性的考量，進而決定採用何種輸出方式。

最佳化目標則是受到 RL 方法論的限制，為單一獎勵函數的最佳化。雖然也有部分文獻中採用權重的方式融合不同的交通績效指標成為單一獎勵函數，例如平均每車停等延滯即類似於系統總延滯除以系統總通過車輛數，然而若權重的制定過於主觀，則容易陷入最佳化目標不明確的問題當中。

從上述的說明中可以理解到，三項要素的不同組合可以使 AI 號誌控制的做法有上百種可能性。在本案中受限於人力、時間自然不可能探討所有組合之成效，因此以下列出幾點在本計畫中欲探討的重點：

- 不同交通輸入資料(State)對於績效的影響程度
- 偵測器數量的敏感度分析
- 不同輸出格式的適用程度
- 不同最佳化目標下的績效表現
- 聯網車的資料如何應用於AI號誌控制方法

因此以下將針對三項場域分別規劃不同的訓練架構，並以上幾項欲探討的議題做為考量。

5.2.1 單一路口場域AI RL模型方案規劃

在單一路口號誌控制的研究工作當中，由於環境變化複雜程度相對單純，因此在本案中將會透過此一實驗場域多方嘗試不同的狀態資訊，試圖尋找對於號誌控制最為關鍵的交通特徵參數。而此一交通特徵參數必須同時考量到在實務建置時的限制，比方說現今市場上是否具備該項特徵偵測功能之偵測器、偵測範圍、傳輸延遲等等實務面的考量。另一方面，雖然一般對於深度類神經網路的認知為輸入變數應該盡可能的多，讓類神經網路自動去過濾重要與次要的資訊，然而在過去的 RL 訓練經驗，過多的特徵輸入將造成下列負面影響。

1. 訓練與收斂困難度增高
2. 過擬合(overfitting)狀況的發生
3. 實務資訊整合困難

因此仍會建議採用實驗不同交通特徵之方法，尋找對於號誌控制具有關鍵影響力的交通特徵，以達到降維又不失關鍵資訊的結果。有關的獎勵設計，由於獎勵的項目直接影響整個最佳化的方向，也代表著使用者最終期待的結果，因此獎勵的目標對於整個 RL 的訓練是至關重要的。常用的交通參數至少包括：車隊長度、停等次數、延滯、車速、通過量、...等。在 RL 的課題當中，由於優化方向必須是單一的，因此如何兼顧不同的交通參數皆能有一定水準的表現將會是一項重要的議題，例如：融合不同參數在同一獎勵函數當中。與狀態類似，選定的獎勵項目亦應該考量到實務上的限制，以避免實際建置後無法檢驗成效的情況發生。

在本案所選定的單一路口場域為臺南市台 86 與 19 甲路口，在不考慮關廟交流道匝道儀控回堵的特殊情況下，屬於單一獨立路口。有關場域介紹細節請參考 4.2 節與 4.3 節。由於單一路口型態較為單純，非常適合做為探討不同交通資料輸入、輸出格式、獎勵函數的實驗對象。在設計實驗方案時，雖在文獻回顧中有多種決策方式的可能性，但考量後續應用可能性，決策方式若採「非固定時相順序」的作法對駕駛人習慣衝擊過大，因此排除；另外也需考量偵測可行性與輸入參數與最佳化目標是否可共用同一偵測器，避免偵測器數量過多的狀況。綜合以上考量點，針對單一路口場域的 AI 方法實驗架構規劃如表 5.2.2。

表 5.2.2 單一路口情境實驗方案規劃

單一路口情境				
方案	輸入資料	輸出格式/頻率		最佳化目標
A-0	現況時制			
A-1	分車道分車種車輛數	逐時相決策該次時相長度	每次時相變更時決策	系統總停等延滯
A-2	路口轉向交通量	逐時相決策該次時相長度	每次時相變更時決策	系統總停等延滯
A-3	分車道分車種車輛數	逐週期決策該次週期時制	每次週期起始時決策	系統總停等延滯
A-4	分車道分車種車輛數	逐時相決策該次時相長度	每次時相變更時決策	系統總通過車輛數

表 5.2.2 中，分車道分車種車輛數定義為在該次決策瞬間，偵測範圍內所有車道上各別種類之車輛(如大車、小車、機車)分別有幾輛；路口轉向交通量定義為決策瞬間，前一次號誌週期中，各轉向實際通過車輛。各方案中盡可能維持控制變因，以利分析各項要素變動對績效的影響程度，以下列出各方案比較所要探討的議題：

1. 「A1-A2」：道路密度 vs 路口流量對於AI控制的重要程度
2. 「A1-A3」：逐時相 vs 逐週期輸出決策對於AI控制的影響程度
3. 「A1-A4」：系統總延滯 vs 系統總通過量對於AI控制的影響程度

在上述規劃中的輸入資料中，主要探討了傳統車流模型中最為重要的兩項觀測值「流量」、「密度」，而這兩項分別以「路口轉向交通量」與「分車道分車種車輛數」代表。在輸出格式的部分，主要分為兩種類型：逐時相與逐週期。逐時相做決策的優勢在於調整頻率較高，理論上較能夠快速反應即時交通需求；而缺點則是在實務上對於偵測與號誌控制器的傳輸要求較高，傳輸延遲的容忍程度較低。逐週期做決策則相較於更為穩定，並且一次輸出各時相的秒數長度，對於各轉向的平衡性或許有著較佳的效果，另外對於主管單位來說也是較為直觀的可以理解 AI 決策的結果。

而最後在最佳化目標的部分，過去很長一段時間交通號誌控制的目標都鎖定在如何最小化平均每車延滯這一目標[102]~ [104]。而由於傳統車流模型中在過飽和情況下(即路口車輛到達率大於路口飽和紓解率)延滯公式會出現難以正確估計的限制，因此也出現了當過飽和情況下改追求

最大通過量的控制策略目標[105]~ [107]。因此在最佳化目標的設定上採用此兩項指標，並且希望透過實驗方式確認最小化平均延滯與最大化通過量，此二者在獎勵函數的訓練過程是否為相同方向。

關於以上 A1~A4 的設計目的，主要是在探討 RL 三項要素的變動影響程度，用以評估建議後續有關研究可以朝向那些 RL 模型設計方向努力。由於三要素的可能性與組合眾多，因此特別挑選單一路口場域做為指標性的實驗，希望透過單一路口場域的實驗了解到 RL 應用在號誌控制上可能的模型設計議題。

而在評估方案的交通績效指標部分，各方案皆會檢視平均每車延滯、系統總通過量兩項指標，並且亦不限於偵測器偵測範圍內，而會檢視完整的模擬路網，以確保評估結果不會受到偵測器佈設的位置或範圍而有所影響。在確立狀態、決策、獎勵具體的物理意義之後，即可套用 RL 的演算方式來進行模型的訓練。具體來說，首先需要訂一個決策代理人稱為 Agent。此 Agent 為一類神經網路模型，其輸入即為前述狀態候選列表中之特徵值；而輸出即為決策候選列表中之產出。針對單一路口所設計之 agent 網路結構設計如圖 5.2.1 所示。

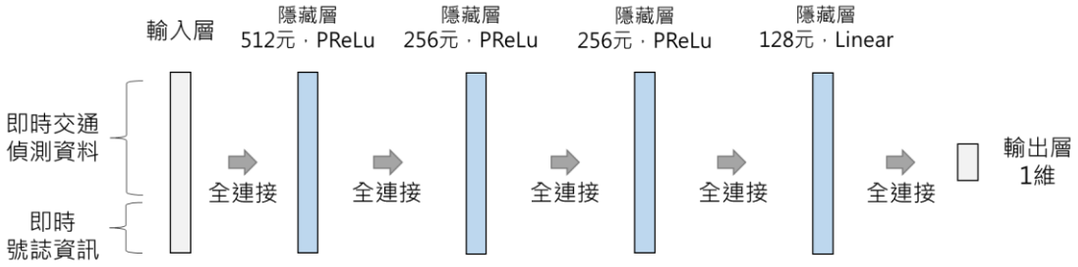

圖 5.2.1 單一路口 Agent 模型結構

在圖 5.2.1 中，輸入層可依照表 5.2.2 中不同方案做為資料輸入，而不同方案因資料類型不同，亦會使輸入層之維度大小有所差異，因此圖中並無標示輸入層之維度。另外在方案 A-1、A-2、A-4 須要逐時相決策綠燈秒數，因此會需要將當前即將執行何種時相的資訊一併輸入 Agent 當中，對應圖中「即時號誌資訊」；而 A-3 方案因為是逐週期決策，並不需要知道當前為何種時相，因此在而 A-3 方案當中「即時號誌資訊」可移除於模型之外。

在輸出層部分，方案 A-1、A-2、A-4 皆是採用逐時相決策秒數之作法，因此輸出層維度即為 1 維，輸出數值代表該次時相之綠燈秒數；而 A-3 方案則是逐週期決策該次週期內所有時相綠燈秒數，因此 A-3 輸出層維

度則為 5，每一維度代表該時相綠燈秒數。(因本場域時相設計為 5 時相，故輸出層為度為 5)

其中，Agent 類神經網路的參數即可視為對應問題的策略，稱之為π。因此此一 Agent 決策的過程可以表示為：

$$output = a^{\pi}(S)$$

而如何使這個輸出值，即號誌控制的秒數，能夠在狀態 S 下追求最佳化的結果，就需要引入期望值的概念。整個過程可以被敘述如下：

$$Q\big(S, a^{\pi}(S)\big) = E(R_t | S_t = S, a_t = a^{\pi}(S))$$

上式代表 Agent 在策略π的條件下，於特定狀態中執行特定動作的預期獎勵值，也就是這個決策在當下狀態的優良程度。而我們將$Q\big(S, a^{\pi}(S)\big)$稱為狀態-動作價值函數，或稱 Q 函數。在取得 Q 函數後，即可透過策略梯度(policy gradient)的方式去尋找 agent 策略π的更新方向，以獲取更大的 Q 值。其過程表示如下：

$$\nabla\theta = \frac{\partial Q\big(S, a^{\pi}(S)\big)}{a^{\pi}}$$

$$\theta_{\pi'} \leftarrow \theta_{\pi} + \nabla\theta$$

獲得新的策略參數$\theta_{\pi'}$後重新估算 Q 函數，不斷重複上述步驟，最終即可獲得使 Q 值最大化的策略π。也就是說，RL 的過程就是不斷更新 Agent 內的類神經網路參數，以使長期的獎勵總和期望值最大化。

5.2.2 幹道多路口場域AI RL模型方案規劃

本案所探討第二種類型的模擬實驗場域為 1 個幹道連鎖的號誌控制路口與路段模擬實驗場域。在此項工作當中，更進一步將控制範圍設定為多路口幹道連鎖人工智慧號誌控制，意即，人工智慧能夠同時控制幹道上的複數路口，達到諸如動態週期、動態時差、動態綠寬等系統最佳化成效。而在多路口的控制模式上，相較於單一路口的強化學習，將採用更進階的多代理人強化學習架構(Multi Agent Reinforcement Learning，後簡稱 MARL)，以實現不同路口或控制群組之間的協調，共同追尋系統最佳化。

本案所選定的幹道多路口場域為臺北市中山北路：德行東路至克強路連續 3 處號誌化路口之幹道路段，有關場域介紹細節請參考 4.2 節。在

幹道多路口情境的部分，由於多路口情況訓練較為複雜，因此對於單一路口已經實驗過的幾項議題在此便不再重複。針對幹道多路口場域的 AI 方法實驗架構規劃如表 5.2.3。

表 5.2.3 幹道多路口情境實驗訓練架構規劃

幹道多路口情境				
方案	輸入資料	輸出格式/頻率		最佳化目標
B-0	現況時制			
B-1	● 所有路口、所有方向、分車道分車種車輛數(9支) ● 範圍內號誌時相指標與秒數資訊 ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總停止延滯
B-2	● 部分路口、部分方向、分車道分車種車輛數 (6支VD配置於幹道) ● 範圍內號誌時相指標與秒數資訊 ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總停止延滯
B-2	● 部分路口、部分方向、分車道分車種車輛數 (4支VD配置於支道與幹道) ● 範圍內號誌時相指標與秒數資訊 ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總停止延滯
B-4	● 部分路口、部分方向、分車道分車種車輛數(9支) ● 範圍內號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總停止延滯

有關偵測器具體佈設位置，可參考第六章模擬結果的說明。表 5.2.3 中有關分車道分車種車輛數之定義請參考 5.2.1 節中之敘述。在幹道多路口情境下，本計畫最關切的議題為：

- 偵測器數量是否為關鍵因子
- 偵測器佈設位置是否為關鍵因子
- 控制範圍內的全動態控制如何與範圍外定時路口配合

在上述的議題考量之下，以下列出各方案比較所要探討到的議題：

1. 「B1-B2B3」：偵測器數量對於AI控制的敏感程度
2. 「B2-B3」：偵測器佈設位置對於AI控制的敏感程度

3.「B1-B4」：控制範圍外的號誌資訊對於AI控制的影響程度

在 B1~B4 的方案設計上，主要的目的在於將探討的議題從單一路口 RL 三要素的組合設計限縮到探討資料輸入上的差異比較。而在幹道多路口議題上，倘若採用如同在單一路口上各方向皆設有偵測器的作法，即 B1 方案，將會讓偵測器的數量需求大幅上升，此一作法對於大範圍路網的推動是一大劣勢條件，因此在此欲嘗試是否有替代方法能在有限的資料訊息中即可掌握路網交通狀態，進而完成原本動態號誌控制之目的。另外由於市區路網型的路口幾何佈設，對於續進的要求非常敏感，因此在此場域中亦嘗試探討與鄰近路口之間的協作能力，因此規劃了如 B4 的資訊落差，藉以了解 RL 在運作過程中不同路口之間的資訊重要程度。

另外多路口的一項重點在於多代理人(Multi Agent)的運作架構，因此設定上 B1~B4 都將會以一個路口為一代理人，即每一路口各自會擁有一組獨特之類神經網路進行決策的運算。逐時相決策之方法中，每個代理人將會在所負責之路口時相即將改變之時進行決策，其決策為下一時相之綠燈秒數。由於各路口之間之時相秒數皆可由代理人自由的變動，因此透過不同的時相長度即可創造出傳統號誌控制方法中的時差。也由於各路口各自負責其時相秒數的決策，因此其他路口的號誌秒數資訊是必要的輸入資訊。透過其他號誌秒數的即時資訊，代理人方能正確理解當下其他號誌的狀態，進而做出能夠配合上下游號誌連鎖的決策，以利得到區域的績效最佳化之共同目標。在評估方案的交通績效指標部分，基本上同單一路口情境之分析方法。另外由於幹道之特性，將會另外分析幹道之旅行時間以及綠寬帶比率兩項幹道續進指標。針對幹道多路口所設計之 Agent 網路結構設計如圖 5.2.2 所示。

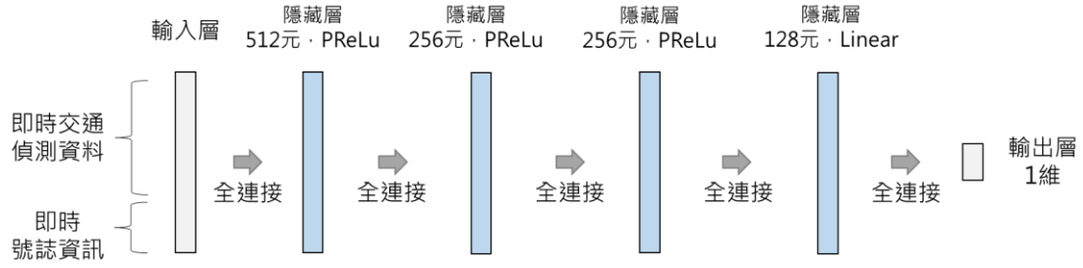

圖 5.2.2 幹道多路口 Agent 模型結構

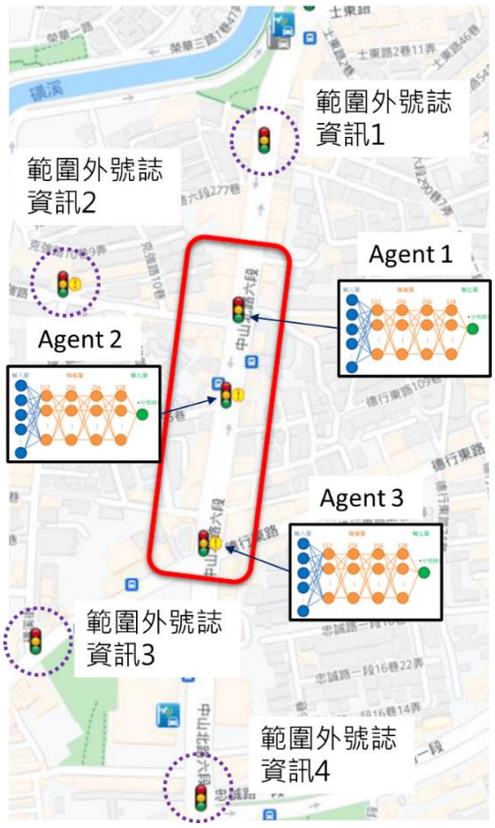

圖 5.2.3 幹道多路口 Agent 位置配置

為了符合多路口同時達到即時適應性的控制目標，本計畫在多路口控制上將採用多代理人強化學習架構(MARL)。多代理人的概念發展於賽局理論(或稱博弈理論)[109][110]，賽局理論考慮環境中的個體的預測行為和實際行為，並研究它們的最佳化策略。原始的 RL 所面對的問題可視為在環境中僅有一名控制者能使環境中的狀態做出改變，而當環境中若出現不只一名控制者時，即須面對賽局理論的議題。一般來說可視環境(常見於遊戲)的類型將賽局區分為幾種不同特性：

- 合作 vs 競爭： 控制者之間是否僅追求自身利益最大化
- 全域資訊 vs 部分資訊：控制者所獲得的資訊範圍
- 對稱 vs 非對稱：所有控制者的目標是否相同
- 即時 vs 回合：控制者做決策是即時的或輪流的
- 零和 vs 非零和：環境機制是否為當一控制者得利，另一控制者必定失利

MALR 即為在處理賽局理論上完美融合 RL 的一套機制。除了原先 RL 處理的探索未知隨機性之外，亦需要去假設預測對方的決策，並且需要去考量兩者的選擇組合起來對於後續環境的長期影響，對於自身或整體的有利程度，進而選擇最佳的決策行為。在多路口號誌控制上，也可

以發現到如同上述的一些特性。如不同路口間的控制結果彼此會相互影響；路口與路口間的交通、號誌資訊是否需要共享；所有路口的目標是否都相同等等。因此若以此角度歸納多路口控制架構，則可以統整幹道連鎖問題成表 5.2.4。

表 5.2.4 多路口號誌控制特性分類表

項目	幹道連鎖號誌控制
合作/競爭	合作型
全域/部分資訊	視實務條件決定(如網路延遲、處理器能力等等)，可為全域資訊，亦可為部分資訊
對稱/非對稱	通常為對稱(追求全域系統績效最佳)，但視需求亦可更動部份路口目標有所不同
即時/非即時	即時
零和/非零和	非零和

參考資料：[112]

相較於單路口，多路口面對最大的挑戰即在於如何去調和各路口之間的連鎖與各自的支道需求。更直接地闡述，MARL 即是在兼容賽局理論與 RL 架構的方法論。具體作法部分，首先須先將每個路口(或每個控制群組)定義為一個 Agent，也就是一套類神經網路模型。而這個 Agent 的輸入與輸出基本上與單路口大同小異，其中的關鍵在於資訊是否為全域。在單一路口部分，所有觀測資訊都會被輸入神經網路當中做為狀態的特徵。但在多路口控制問題當中，則可以考慮設計是否需要共享所有的觀測資訊。舉例來說，相隔超過 1 公里以上的路口資訊是否需要共享？亦或是受限於實務硬體效能無法即時彙整所有偵測資訊情況。因此在這裡 Agent 的輸入輸出可以被表示為：

$$output_i = a_i^{\pi_i}(S_{k(i)})$$

$$a_i^{\pi_i}(S_{k(i)})$$

其中，

i為 Agent 的編號；

a為 Agent，類神經網路；

π為當前 Agent 的策略，即類神經網路當中的參數組；

S_k為狀態特徵組；

k為依據i的函數，即代表不同 Agent 可能有不同的觀測狀態。

在定義好 Agent 對應的路口輸入輸出後，後續即可進入 RL 的演算方式當中，這個部分與單路口的作法相當類似，僅需修改單一 agent 成為多重 agent。其表示為：

$$Q\left(S, a_1^{\pi_1}\left(S_{k(1)}\right), \ldots, a_n^{\pi_n}\left(S_{k(n)}\right)\right) =$$
$$E(R_t|S_t = S, a_{1t} = a_1^{\pi_1}\left(S_{k(1)}\right), \ldots, a_{1t} = a_n^{\pi_n}\left(S_{k(n)}\right))$$

在取得聯合 Q 函數後，同樣可透過策略梯度(policy gradient)的方式去尋找每個 Agent 策略π_i的更新方向，以獲取更大的聯合 Q 值。其過程表示如下：

$$\nabla\theta_i = \frac{\partial Q(S, a_1, \ldots, a_n)}{a_i^{\pi_i}}$$

$$\theta_{\pi_i'} \leftarrow \theta_{\pi_i} + \nabla\theta_i$$

在這一過程中，由於 Q 值當中包含所有 Agent 的策略，因此所有策略在進行梯度更新的時候皆會考量到其他 Agent 在其中的影響程度，也就是說會考量到如何去配合其他 agent 以獲得最大的聯合 Q 值期望值。

5.2.3 車聯網路口場域AI RL模型方案規劃

從文獻回顧中可以發現到，聯網車所能夠提供的資訊種類，相較於不論是傳統的 VD，或是影像式 VD，在車輛軌跡方面都有明顯的優勢。另外車聯網的資料傳輸距離約為 300m，相較於 VD 的 100~150m 也更能涵蓋到各方向的交通需求資訊，進而反饋至號誌控制邏輯上。因此在本項工作中，將會試圖從聯網車所能提供之資訊當中，篩選適合的資料種類，融合成 AI 號誌控制的輸入資料型式，以取代原本 VD 做為偵測的輸入資訊，預期聯網車的傳輸範圍優勢與軌跡資訊能夠為 AI 號誌控制帶來新的可能性。為此，計畫中將會比較以聯網車資料做為輸入與 VD 資料做為輸入的 AI 號誌控制績效比較。

本案所選定的車聯網路口場域為高雄市台 88 線鳳山出口(過埤路-鳳頂路)，有關場域介紹細節請參考 4.2 節與 4.3 節。針對車聯網路口場域的 AI 方法實驗架構規劃如表 5.2.5。

表 5.2.5 車聯網路口情境實驗訓練架構規劃

車聯網路口情境				
方案	輸入資料	輸出格式/頻率		最佳化目標
C-0	定時時制			
C-1	● 分車道分車種車輛數 ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總延滯
C-1S	● 分車道分車種車輛數 ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總延滯(僅用部分情境樣本進行訓練)
C-2	● 聯網車資訊(70%) ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總延滯
C-3	● 聯網車資訊(30%) ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	系統總延滯
C-4	● 停等車隊長度 ● 範圍外號誌時相指標與秒數資訊	逐時相決策該次時相長度	每次時相變更時決策	總停等車隊長度

表 5.2.5 中，有關分車道分車種車輛數請參考 5.2.1 節中之敘述；聯網車資訊則包含以下資料類型：

- 即時車輛位置(坐標位置)
- 即時車輛速度

在車聯網路口情境下，本計畫最關切的議題為：

- 聯網車資料是否可以做為 AI 號誌控制資料輸入
- 聯網車在環境中所佔的比例影響 AI 號誌控制的程度

在上述的議題考量之下，以下列出各方案比較所要會探討到的議題：

1. 「C1-C2」：聯網車資訊做為AI號誌控制的輸入資料可行性
2. 「C2-C3」：聯網車在環境中所佔之比例對於AI號誌控制的影響程度
3. 「C1-C4」：採用停等車隊長度做為輸入與獎勵是否可行
4. 「C1-C1S」：訓練樣本僅來自於部分情境，其餘情境則靠隨機產生

聯網車即時車輛位置將先以網格化方式映射至場域平面當中，若在所劃分的格位中存在車輛，則以 1 表示；若無車則以 0 表示，如圖 5.2.4 所示意。

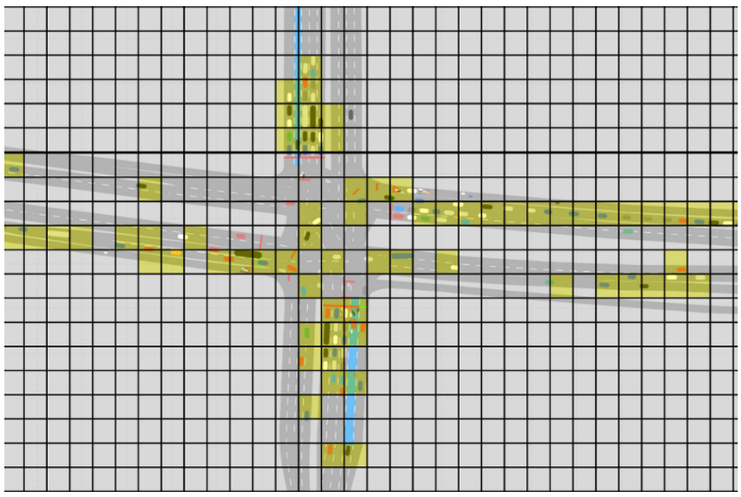

圖 5.2.4 車聯網位置映射示意圖

針對上述聯網車座標資料所設計之 Agent 網路結構設計，如圖 5.2.5 所示。

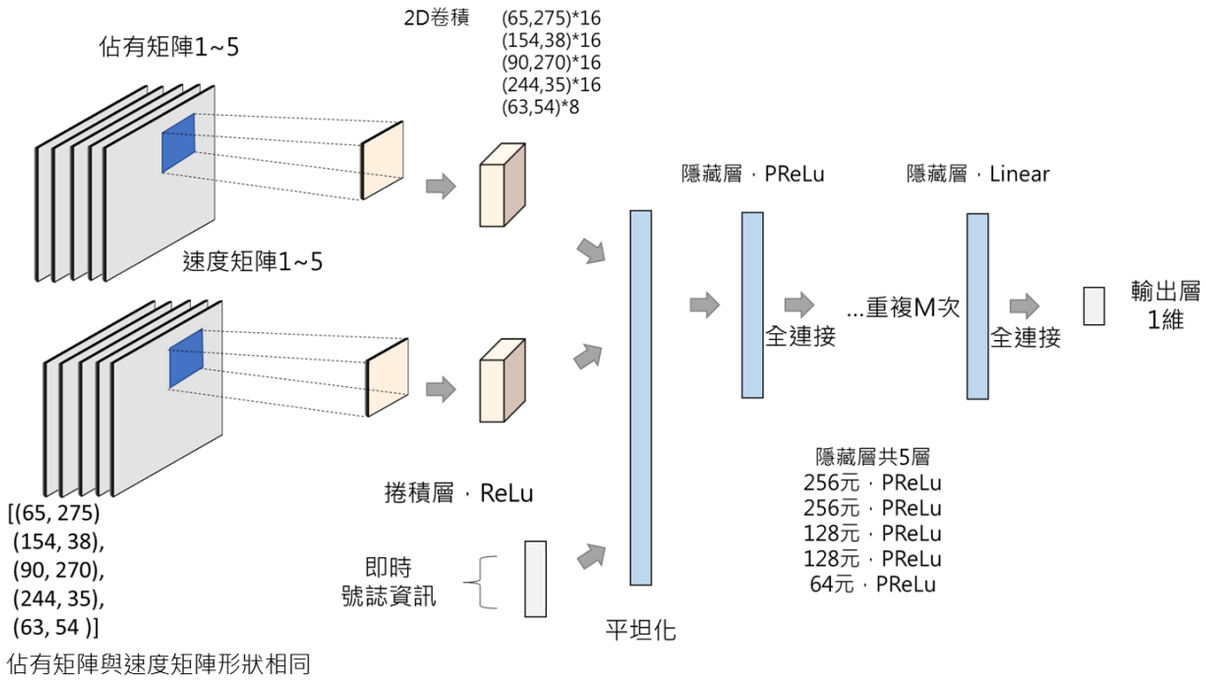

圖 5.2.5. 車聯網 Agent 網路結構設計

圖 5.2.5 中的平坦化(flatten operation)是在進行卷積層結構設計時常用的一種處理程序，其目的是在於將多維度的重整為 1 維的張量，才能順利的銜接上後續的全連接隱藏層。在圖 5.2.4 的示意圖中可以發現到，若是直接將以路口中心做為圓心，半徑 300 公尺範圍內的空間都做為格位轉換，

許多格位並未包含車道經過，亦不會有任何的車輛資訊進入，但卻對 RL 的運算與訓練會消耗大量的資訊，效率低落。為解決此一問題，本計畫中將場域再細切割成五個區域範圍，如圖 5.2.6 所示，有效的排除沒有車道的格位。不同的區域再以計算出的矩陣形狀輸入至如圖 5.2.5 的類神經網路結構，即可順利完成 RL 的輸入設定。

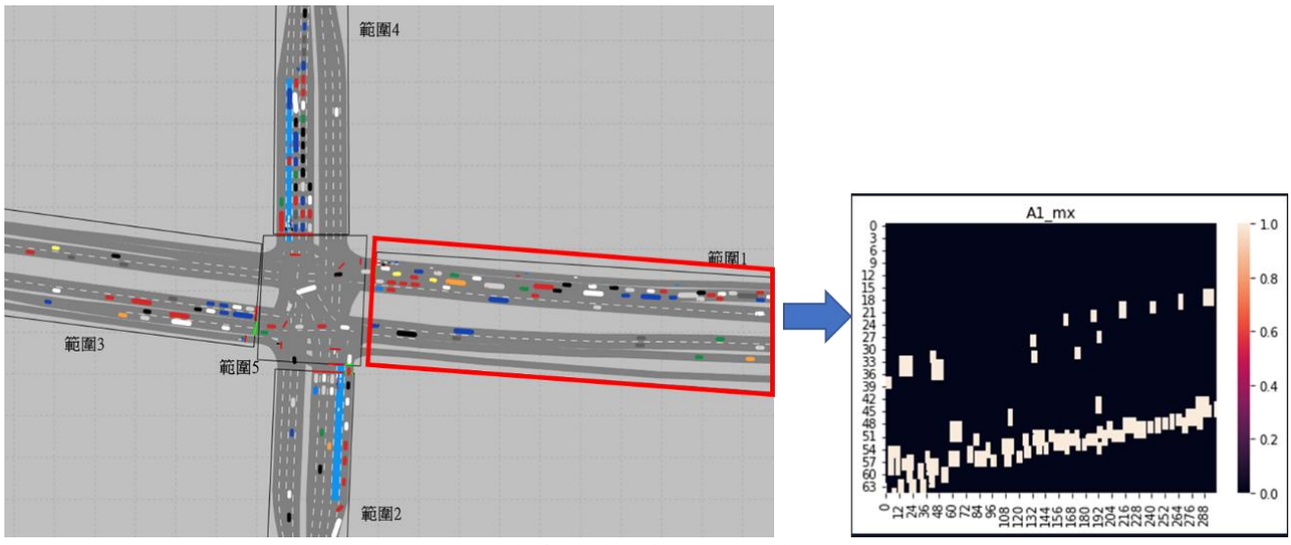

圖 5.2.6 場域中範圍切割示意圖

由於聯網車情境中並非所有車輛都具備聯網車功能，因此聯網車之位置分布與各別車輛速度的資訊非常重要，透過映射方式可將不同數量，不同分布的車輛資訊統整成統一結構的數據資訊，不同資訊就如同是一張張的影像資料。而捲積層擅長從平面的張量中萃取出特徵，因此此種車聯網資料映射成為平面資料的方式預期將能夠比傳統 VD 資料更能夠得到額外的交通資訊，並且也可以適用聯網車在環境的不同比例。而同樣由於是逐時相決策的緣故，因此需要輸入號誌當前的時相資訊供 agent 判斷。由於即時號誌資訊並無捲積特徵的特性，因此設計在聯網車資訊捲積處理完特徵後再加入號誌資訊即可。

本場域雖型態並非傳統定義上的獨立號誌化路口，但因為 RL 僅控制單一目標路口，在 Agent 訓練的過程基本上與 5.2.1 節中的敘述相同，皆是以策略梯度(policy gradient)的方式去尋找 agent 策略π的更新方向，以獲取更大的 Q 值，以使長期的獎勵總和期望值最大化。

在第四項探討議題中，即 C-1S 方案的做法中，希望僅透過部分情境樣本做為訓練資料，檢視 RL 是否可透過有限資料推論至其他情境的號誌控制。此處的實驗發想於模擬器在校估驗證上是非常耗費人力時間的一項工作，而 RL 號誌控制的本質是透過大量樣本歸納出控制策略，因此理

論上僅需針對場域幾個有代表性的情境，例如上下午尖峰，良好校估駕駛行為參數，該模擬模型便足以透過隨機改變交通設定產生出各種情境的交通樣本，而不需要針對所有可能的交通情境都進行模擬器參數校估，以節省計畫執行的人力時間成本。為了驗證此種作法的可行性，將安排 C-1S 方案中僅利用完成的參數校估的上下午尖峰交通模擬模型產出訓練樣本，並以隨機方式改變如交通需求量、轉向比例、車種組成等設定，創造不同交通情境，產生樣本供 RL 進行訓練。而最後在績效測試階段，除了檢驗平日上下午尖峰的績效數值外，同時也用經過完整參數校估的平日離峰與假日尖峰交通情境模擬模型進行績效的檢視，探討此種作法的可行性。

5.3 交通模擬模型建置成果

本案交通模擬模型分別以 VISSIM 與 SUMO 建立模型，並且除針對計畫範圍內欲控制之號誌化路口，亦將各目標路口上游一處號誌化路口納入模型當中，以考量上游號誌對目標範圍內的車流影響。模擬模型建置範圍請參考圖 5.3.1 與圖 5.3.2。三處場域皆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、當天號誌時制計畫，並依 3.4.2 節之敘述進行校估工作。模擬模型建置過程包含以場域衛星空照圖做為底圖做為背景，搭配比例尺確認路網距離與實際一致，如圖 5.3.3 與圖 5.3.4 所示。

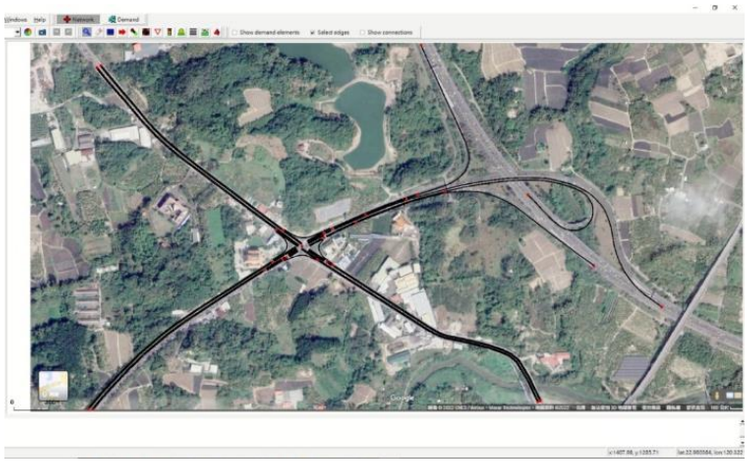

圖 5.3.1 SUMO 建模搭配空拍底圖範例

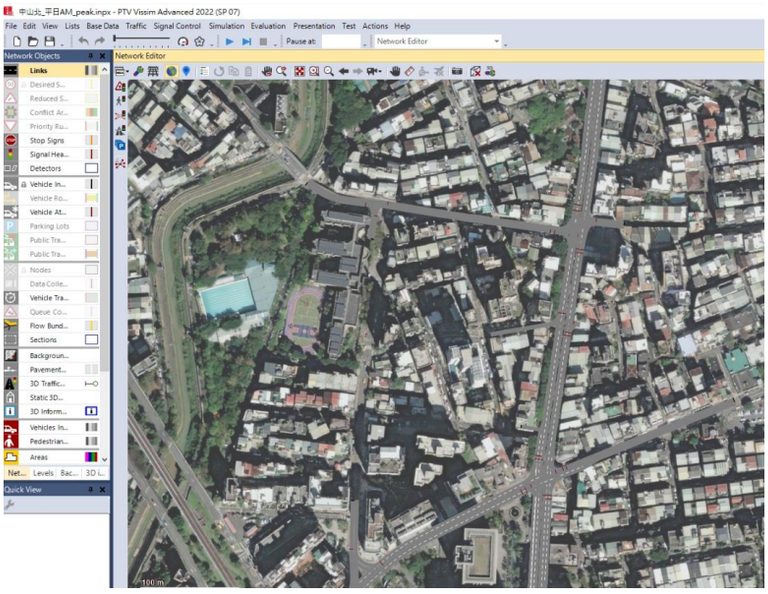

圖 5.3.2 VISSIM 建模搭配空拍底圖範例

透過空拍底圖可以清楚的看到道路連結的幾何線型，再搭配實地場勘、調查影片或是街景圖等方式可以更詳細的了解場域的車道佈設、號誌運作方式等等。通過以上資料可以將場域路網結構繪製建模，如圖 5.3.3 與圖 5.3.4 所示。

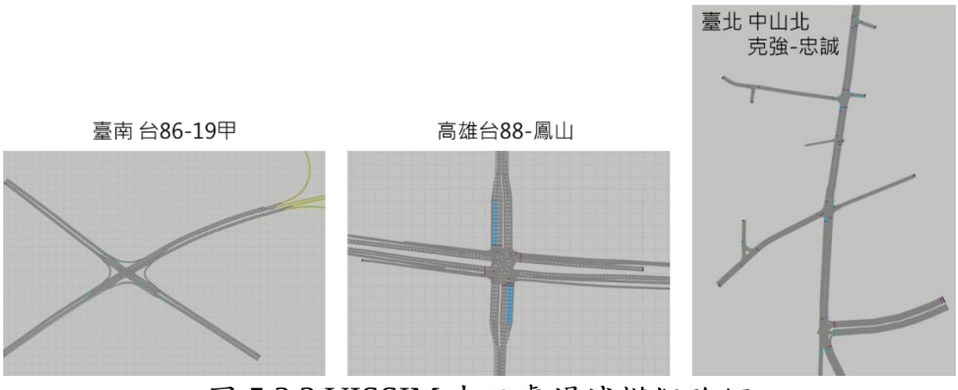

圖 5.3.3 VISSIM 中三處場域模擬路網

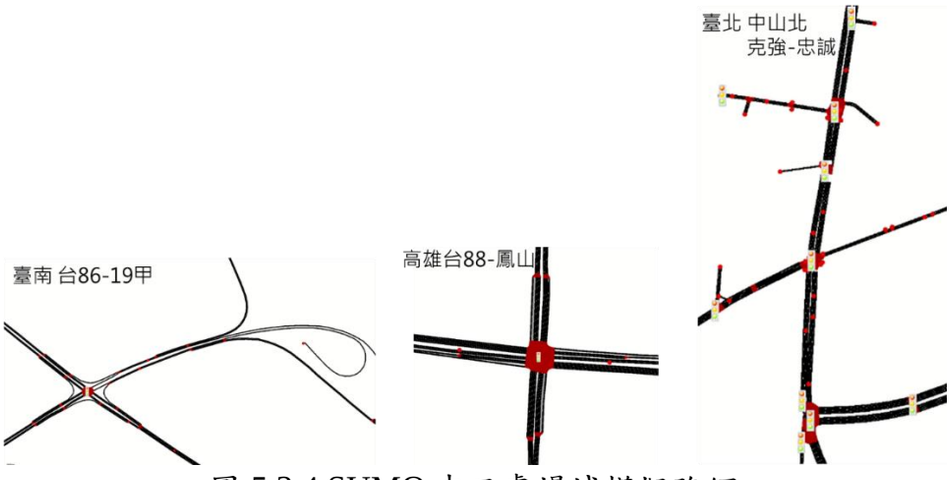

圖 5.3.4 SUMO 中三處場域模擬路網

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，如圖 5.3.5 所示。或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 5.3.6 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 5.3.7 所示。

圖 5.3.5 SUMO 中圖像化時相動線設定範例

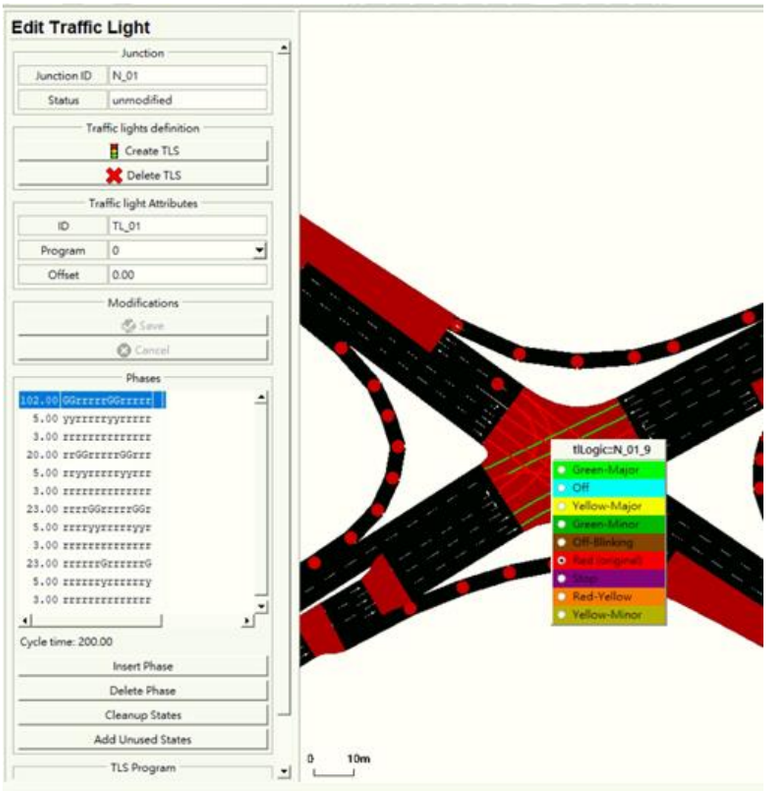

圖 5.3.6 SUMO 中文字矩陣時相動線設定範例

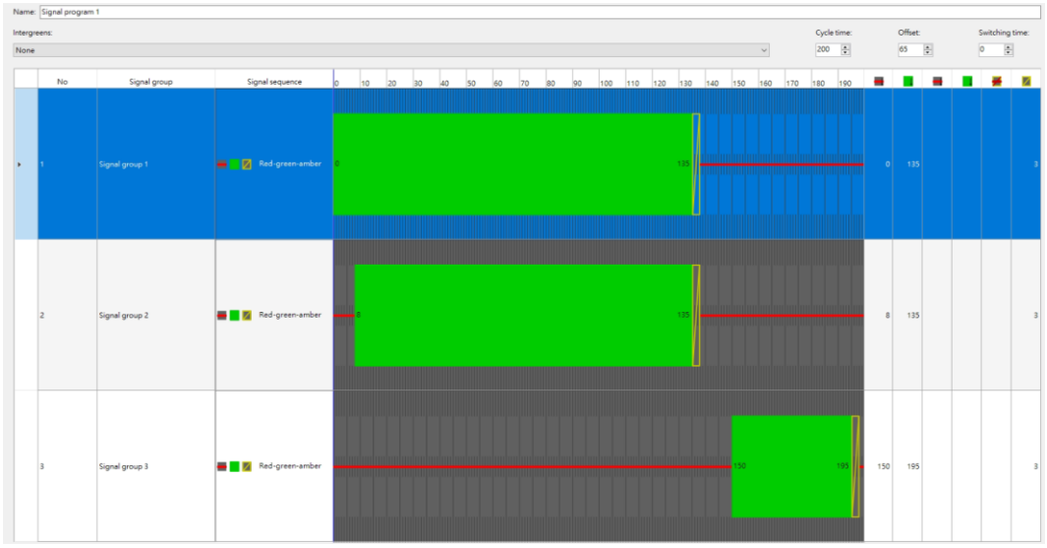

圖 5.3.7 VISSIM 中號誌時制設定範例

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 5.3.8 SUMO 交通需求設定範例

Vehicle Inputs / Vehicle volumes by time interval

Vehicle volumes by t

Count: 33	No	Name	Link	Volume(0-1800)	Volume(1800-3600)	Volume(3600-5400)	Volume(5400-7200)	Volume(7200-9000)	Volume(9000-MAX)	V
1	1	中山北北向_H	32	76.0	36.0	86.0	72.0	58.0	52.0	6
2	2	中山北北向_C	32	526.0	1086.0	1295.0	1208.0	1276.0	1136.0	5
3	3	中山北北向_S	32	466.0	844.0	1332.0	1072.0	1200.0	838.0	7
4	4	忠誠_H	37	32.0	50.0	30.0	46.0	32.0	44.0	6
5	5	忠誠_C	37	472.0	1126.0	1376.0	1058.0	958.0	814.0	5
6	6	忠誠_S	37	194.0	340.0	482.0	488.0	346.0	272.0	7
7	7	德行東_H	3	18.0	14.0	18.0	8.0	10.0	6.0	6
8	8	德行東_C	3	178.0	258.0	405.0	348.0	368.0	340.0	5
9	9	德行東_S	3	272.0	496.0	718.0	614.0	518.0	354.0	7
10	10	德行西_H	19	18.0	14.0	16.0	14.0	22.0	10.0	6

圖 5.3.9 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。本案期中階段將以平日上午尖峰與平日下午尖峰兩種調查情境進行誤差驗證。模擬誤差驗證採用 111 年 5 月 31 日上午 6:30~9:30 與 16:00~19:00 之人工調查資料做為上下午尖峰兩種不同情境的驗證資料來源。模擬中將前 30 分鐘資料做為暖機時間；最後 30 分鐘為冷卻時間，皆不計入績效，因此實際驗證之時間範圍為上午 7:00~9:00 與下午 16:30~18:30，兩小時時段。

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。此外本次亦調查平均每車停等延滯，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。

而採用 MAPE 做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做法[113]：至少 75%的轉向交通量之 GEH 需小於 5。

表 5.3.1 建議之 GEH 接受門檻

GEH 接受門檻(兩項皆須滿足)
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。在文獻中[114]也提出 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 5.3.2 為文中所舉的一個範例，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 5.3.2 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%

而平日離峰情境與假日尖峰情境則會於期中階段之後，以已完成校估之模擬路網比對人工調查數值，確認由平日尖峰資料校估之模擬器所產出的其他情境績效資料是否具代表性。以下小節將分別就各場域的模擬誤差驗證進行說明。

5.3.1 單一路口場域模擬驗證(臺南市)

5.3.1.1 臺南市 VISSIM 模擬數據

表 5.3.3 VISSIM 臺南市場域平日上午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	87.6	94.9
西向_直行	362.9	358.8
西向_右轉	86.0	83.6
北向_左轉	67.9	77.7
北向_直行	215.8	229.3
北向_右轉	135.0	134.9
東向_左轉	103.0	110.6
東向_直行	536.1	532.8
東向_右轉	48.6	48.0
南向_左轉	85.8	82.8
南向_直行	139.9	136.7
南向_右轉	116.5	118.1

表 5.3.4 VISSIM 臺南市場域平日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	130.0	133.9
西向_直行	620.0	633.0
西向_右轉	109.3	111.6
北向_左轉	65.0	75.1
北向_直行	153.6	179.3
北向_右轉	107.0	110.6
東向_左轉	102.5	105.3
東向_直行	467.0	465.8
東向_右轉	63.0	63.3
南向_左轉	95.3	93.9
南向_直行	203.7	198.5
南向_右轉	115.6	115.5

表 5.3.5 VISSIM 臺南市場域平日下午離峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	80.6	88.1
西向_直行	410.1	445.1
西向_右轉	64.3	63.1
北向_左轉	52.0	65.1
北向_直行	99.8	119.5
北向_右轉	69.0	70.4
東向_左轉	79.3	82.1
東向_直行	450.8	454.2
東向_右轉	42.4	43.1
南向_左轉	84.4	87.5
南向_直行	100.6	98.5
南向_右轉	84.7	82.0

表 5.3.6 VISSIM 臺南市場域假日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	123.4	113.1
西向_直行	620.3	596.8
西向_右轉	117.9	111.5
北向_左轉	74.0	78.1
北向_直行	142.8	142.8
北向_右轉	85.0	80.6

東向_左轉	72.2	75.6
東向_直行	382.9	382.1
東向_右轉	45.8	47.0
南向_左轉	82.8	88.3
南向_直行	155.5	152.2
南向_右轉	88.1	90.3

經過整理，可將各方向的模擬誤差整理成表 5.3.7。

表 5.3.7 VISSIM 臺南市場域流量 MAPE

轉向	平日上午尖峰 MAPE	平日下午尖峰 MAPE	平日下午離峰 MAPE	假日下午尖峰 MAPE
西向_左轉	8%	3%	9%	8%
西向_直行	1%	2%	9%	4%
西向_右轉	3%	2%	2%	5%
北向_左轉	14%	16%	25%	6%
北向_直行	6%	17%	20%	0%
北向_右轉	0%	3%	2%	5%
東向_左轉	7%	3%	4%	5%
東向_直行	1%	0%	1%	0%
東向_右轉	1%	0%	2%	3%
南向_左轉	3%	1%	4%	7%
南向_直行	2%	3%	2%	2%
南向_右轉	1%	0%	3%	2%
平均	4%	4%	7%	4%

臺南市場域轉向交通量 GEH 數值整理於表 5.3.8。

表 5.3.8 VISSIM 臺南市場域流量 GEH

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向_左轉	0.8	0.3	0.8	0.9
西向_直行	0.2	0.5	1.7	1.0
西向_右轉	0.3	0.2	0.1	0.6
北向_左轉	1.1	1.2	1.7	0.5
北向_直行	0.9	2.0	1.9	0.0
北向_右轉	0.0	0.3	0.2	0.5
東向_左轉	0.7	0.3	0.3	0.4
東向_直行	0.1	0.1	0.2	0.0
東向_右轉	0.1	0.0	0.1	0.2

南向_左轉	0.3	0.1	0.3	0.6
南向_直行	0.3	0.4	0.2	0.3
南向_右轉	0.2	0.0	0.3	0.2

從 GEH 表中可以發現，臺南市場域在 VISSIM 模擬中，所有轉向的 GEH 值皆低於 5，並且從 MAPE 數值皆在 10%以內。因此可以認為 VISSIM 臺南場域是一個合格的模擬模型。第二個部分將針對平均每車延滯進行分析。表 5.3.9 與表 5.3.10 表分別為上午尖峰與下午尖峰之平均每車延滯調查與模擬值。

表 5.3.9 VISSIM 臺南市場域平日上午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	40.3	37.9
北向	80.4	72.6
東向	27.3	23.3
南向	69.5	65.4

表 5.3.10 VISSIM 臺南市場域平日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	25.8	24.3
北向	84.5	87.1
東向	43.7	37.9
南向	160.0	145.8

表 5.3.11 VISSIM 臺南市場域平日下午離峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	37.5	31.3
北向	80.1	50.5
東向	30.9	26.6
南向	83.8	80.8

表 5.3.12 VISSIM 臺南市場域假日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	23.4	21.7
北向	91.8	93.4
東向	43.3	39.3
南向	107.4	92.1

經過整理，可將各方向的模擬誤差整理成表 5.3.13 與表 5.3.14。

表 5.3.13 VISSIM 臺南市場域平均每車延滯 MAPE

	平日上午尖峰平均每車延滯 MAPE	平日下午尖峰平均每車延滯 MAPE	平日下午離峰平均每車延滯 MAPE	假日下午尖峰平均每車延滯 MAPE
西向	6%	6%	17%	7%
北向	10%	3%	37%	2%
東向	15%	13%	14%	9%
南向	6%	9%	4%	14%
平均	9%	8%	18%	8%

表 5.3.14 VISSIM 臺南市場域平均每車延滯 GEH

來向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向	0.4	0.3	1.1	0.4
北向	0.9	0.3	3.7	0.2
東向	0.8	0.9	0.8	0.6
南向	0.5	1.1	0.3	1.5

從 GEH 表中可以發現，臺南市場域在 VISSIM 模擬中，所有來向平均每車延滯 GEH 值皆低於 5，並且從 MAPE 數值也 10%以內。因此從輔助指標平均每車延滯也可以說明 VISSIM 臺南市場域是一個合格的模擬模型。

5.3.1.2 臺南市 SUMO 模擬數據

表 5.3.15 SUMO 臺南市場域平日上午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	87.6	97.0
西向_直行	362.9	364.4
西向_右轉	86.0	76.3
北向_左轉	67.9	68.5
北向_直行	215.8	185.6
北向_右轉	135.0	150.4
東向_左轉	103.0	104.5
東向_直行	536.1	534.3
東向_右轉	48.6	46.2
南向_左轉	85.8	89.9
南向_直行	139.9	130.7
南向_右轉	116.5	122.1

表 5.3.16 SUMO 臺南市場域平日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	130.0	136.1
西向_直行	620.0	651.3
西向_右轉	109.3	118.5
北向_左轉	65.0	72.1
北向_直行	153.6	150.5
北向_右轉	107.0	110.3
東向_左轉	102.5	105.5
東向_直行	467.0	447.3
東向_右轉	63.0	64.9
南向_左轉	95.3	94.4
南向_直行	203.7	180.8
南向_右轉	115.6	115.2

表 5.3.17 SUMO 臺南市場域平日下午離峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	80.6	91.6
西向_直行	410.1	437.5
西向_右轉	64.3	57.5
北向_左轉	52.0	63.6
北向_直行	99.8	108.1
北向_右轉	69.0	70.4
東向_左轉	79.3	79.9
東向_直行	450.8	464.3
東向_右轉	42.4	38.5
南向_左轉	84.4	96.0
南向_直行	100.6	110.1
南向_右轉	84.7	78.4

表 5.3.18 SUMO 臺南市場域假日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向_左轉	123.4	124.1
西向_直行	620.3	621.9
西向_右轉	117.9	116.9
北向_左轉	74.0	81.4
北向_直行	142.8	146.0
北向_右轉	85.0	94.8

東向_左轉	72.2	80.0
東向_直行	382.9	384.1
東向_右轉	45.8	42.3
南向_左轉	82.8	85.3
南向_直行	155.5	143.2
南向_右轉	88.1	88.8

經過整理，可將各方向的模擬誤差整理成表 5.3.19。

表 5.3.19 SUMO 臺南市場域流量 MAPE

轉向	平日上午尖峰 MAPE	平日下午尖峰 MAPE	平日下午離峰 MAPE	假日下午尖峰 MAPE
西向_左轉	11%	5%	14%	1%
西向_直行	0%	5%	7%	0%
西向_右轉	11%	8%	11%	1%
北向_左轉	1%	11%	22%	10%
北向_直行	14%	2%	8%	2%
北向_右轉	11%	3%	2%	11%
東向_左轉	1%	3%	1%	11%
東向_直行	0%	4%	3%	0%
東向_右轉	5%	3%	9%	8%
南向_左轉	5%	1%	14%	3%
南向_直行	7%	11%	9%	8%
南向_右轉	5%	0%	7%	1%
平均	6%	5%	9%	5%

臺南市場域轉向交通量 GEH 數值整理於表 5.3.20。

表 5.3.20 SUMO 臺南市場域流量 GEH

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向_左轉	1.0	0.5	1.2	0.1
西向_直行	0.1	1.2	1.3	0.1
西向_右轉	1.1	0.9	0.9	0.1
北向_左轉	0.1	0.9	1.5	0.8
北向_直行	2.1	0.3	0.8	0.3
北向_右轉	1.3	0.3	0.2	1.0
東向_左轉	0.1	0.3	0.1	0.9
東向_直行	0.1	0.9	0.6	0.1
東向_右轉	0.4	0.2	0.6	0.5

南向_左轉	0.4	0.1	1.2	0.3
南向_直行	0.8	1.6	0.9	1.0
南向_右轉	0.5	0.0	0.7	0.1

從 GEH 表中可以發現，臺南市場域在 SUMO 模擬中，所有轉向交通量的 GEH 值皆低於 5，並且從 MAPE 數值也皆在 10%以內。因此可以認為 SUMO 臺南場域是一個合格的模擬模型。第二個部分將針對平均每車延滯進行分析。表 5.3.21 與表 5.3.22 分別為上午尖峰與下午尖峰之平均每車延滯調查與模擬值。

表 5.3.21 SUMO 臺南市場域平日上午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	40.3	34.9
北向	80.4	71.1
東向	27.3	29.1
南向	69.5	50.8

表 5.3.22 SUMO 臺南市場域平日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	25.8	23.1
北向	84.5	63.4
東向	43.7	46.8
南向	160.0	161.3

表 5.3.23 SUMO 臺南市場域平日下午離峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	37.5	30.4
北向	80.1	53.5
東向	30.9	29.7
南向	83.8	64.1

表 5.3.24 SUMO 臺南市場域假日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向	23.4	22.1
北向	91.8	81.1
東向	43.3	39.2
南向	107.4	98.2

經過整理，可將各方向的模擬誤差整理成表 5.3.25 與表 5.3.26。

表 5.3.25 SUMO 臺南市場域平均每車延滯 MAPE

來向	平日上午尖峰平均每車延滯 MAPE	平日下午尖峰平均每車延滯 MAPE	平日下午離峰平均每車延滯 MAPE	假日下午尖峰平均每車延滯 MAPE
東向	13%	11%	19%	6%
北向	12%	25%	33%	12%
西向	7%	7%	4%	9%
南向	27%	1%	24%	8%
平均	15%	11%	20%	9%

表 5.3.26 SUMO 臺南市場域平均每車延滯 GEH

來向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
東向	0.9	0.5	1.2	0.3
北向	1.1	2.4	3.3	1.2
西向	0.3	0.5	0.2	0.6
南向	2.4	0.1	2.3	0.9

臺南市場域在 SUMO 模擬中，雖然從延滯 MAPE 統計量部分方向仍有改善空間，但從 GEH 表中可以發現，所有來向中的平均每車延滯 GEH 值皆低於 5，因此從輔助指標平均每車延滯也可以說明 SUMO 臺南市場域可被視為是一個合格的模擬模型。

5.3.2 幹道多路口場域模擬驗證(臺北市)

5.3.2.1 臺北市 VISSIM 模擬數據

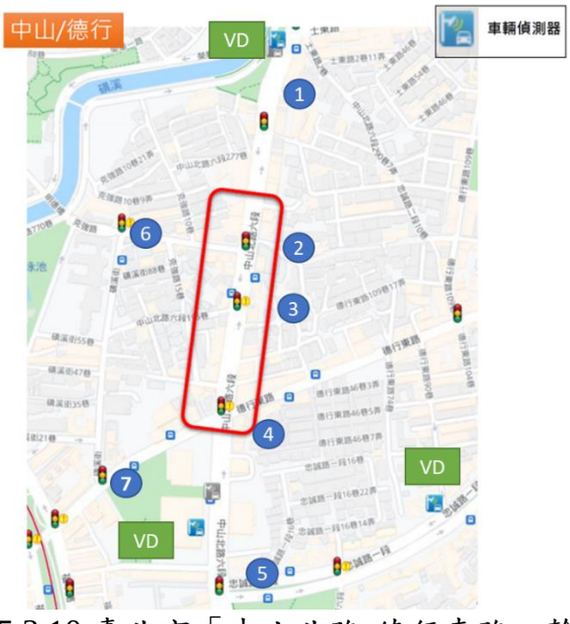

圖 5.3.10 臺北市「中山北路-德行東路」幹道

臺北市場域驗證作法與臺南市場域類似，表 5.3.27 與表 5.3.28 為模擬數值對照。

表 5.3.27 VISSIM 臺北市場域平日上午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	53.2	48.7
路口 2_往北_直行	399.4	405.1
路口 2_往東_左轉	69.4	59.9
路口 2_往東_右轉	70.0	56.3
路口 2_往南_直行	592.1	599.9
路口 2_往南_右轉	45.5	48.3
路口 3_往北_左轉	21.9	19.6
路口 3_往北_直行	449.6	458.9
路口 3_往南_直行	637.4	647.0
路口 3_往南_右轉	11.2	12.2
路口 4_往西_左轉	47.5	47.2
路口 4_往西_直行	204.0	211.1
路口 4_往西_右轉	17.8	17.8
路口 4_往北_左轉	30.1	30.3
路口 4_往北_直行	390.0	402.2
路口 4_往北_右轉	53.7	54.4
路口 4_往東_左轉	58.9	59.1
路口 4_往東_直行	221.7	228.9
路口 4_往東_右轉	40.5	40.2
路口 4_往南_左轉	13.9	20.2
路口 4_往南_直行	673.0	653.6
路口 4_往南_右轉	50.2	47.5

表 5.3.28 VISSIM 臺北市場域平日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	54.1	56.8
路口 2_往北_直行	440.9	462.9
路口 2_往東_左轉	145.2	137.5
路口 2_往東_右轉	51.1	57.8
路口 2_往南_直行	538.1	543.4
路口 2_往南_右轉	62.5	63.0
路口 3_往北_左轉	28.7	19.4

路口 3_往北_直行	490.2	525.2
路口 3_往南_直行	572.7	586.6
路口 3_往南_右轉	9.4	18.6
路口 4_往西_左轉	55.4	54.3
路口 4_往西_直行	213.1	200.9
路口 4_往西_右轉	27.1	24.5
路口 4_往北_左轉	15.8	13.6
路口 4_往北_直行	461.1	468.8
路口 4_往北_右轉	94.0	94.3
路口 4_往東_左轉	54.4	51.0
路口 4_往東_直行	246.6	255.1
路口 4_往東_右轉	79.7	74.3
路口 4_往南_左轉	24.1	30.8
路口 4_往南_直行	562.3	551.8
路口 4_往南_右轉	64.0	64.9

表 5.3.29 VISSIM 臺北市場域平日下午離峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	46.1	62.0
路口 2_往北_直行	402.8	389.1
路口 2_往東_左轉	58.6	61.2
路口 2_往東_右轉	60.6	63.8
路口 2_往南_直行	476.6	479.4
路口 2_往南_右轉	41.3	42.8
路口 3_往北_左轉	15.2	15.1
路口 3_往北_直行	448.2	453.5
路口 3_往南_直行	521.4	534.9
路口 3_往南_右轉	9.2	9.0
路口 4_往西_左轉	51.7	68.2
路口 4_往西_直行	151.2	143.1
路口 4_往西_右轉	28.9	29.2
路口 4_往北_左轉	27.0	29.6
路口 4_往北_直行	378.6	375.8
路口 4_往北_右轉	61.2	59.4
路口 4_往東_左轉	61.6	64.0
路口 4_往東_直行	179.0	180.3
路口 4_往東_右轉	62.5	62.9

路口 4_往南_左轉	24.0	18.8
路口 4_往南_直行	508.3	490.5
路口 4_往南_右轉	44.4	44.8

表 5.3.30 VISSIM 臺北市場域假日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	52.4	61.2
路口 2_往北_直行	377.1	405.5
路口 2_往東_左轉	91.4	92.3
路口 2_往東_右轉	56.2	53.8
路口 2_往南_直行	471.7	468.1
路口 2_往南_右轉	48.5	49.2
路口 3_往北_左轉	13.1	13.3
路口 3_往北_直行	431.5	473.7
路口 3_往南_直行	513.5	510.8
路口 3_往南_右轉	7.7	7.9
路口 4_往西_左轉	58.7	61.9
路口 4_往西_直行	159.1	167.2
路口 4_往西_右轉	31.8	32.8
路口 4_往北_左轉	6.0	5.7
路口 4_往北_直行	393.7	396.2
路口 4_往北_右轉	67.5	67.8
路口 4_往東_左轉	53.1	58.3
路口 4_往東_直行	200.7	220.9
路口 4_往東_右轉	86.2	91.7
路口 4_往南_左轉	24.5	21.8
路口 4_往南_直行	514.3	508.7
路口 4_往南_右轉	51.5	50.2

整理後之轉向交通量 MAPE 與 MAE 於表 5.3.31；轉向交通量之 GEH 則整理於表 5.3.32。

表 5.3.31 VISSIM 臺北市場域流量 MAPE 與 MAE

轉向	平日上午尖峰		平日下午尖峰		平日下午離峰		假日下午尖峰	
	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE
路口 2_往北_左轉	8%	4.5	5%	2.8	34%	15.9	17%	8.8
路口 2_往北_直行	1%	5.7	5%	22.0	3%	13.7	8%	28.4
路口 2_往東_左轉	14%	9.5	5%	7.7	5%	2.7	1%	0.9

路口 2_往東_右轉	20%	13.7	13%	6.7	5%	3.2	4%	2.4
路口 2_往南_直行	1%	7.8	1%	5.2	1%	2.8	1%	3.7
路口 2_往南_右轉	6%	2.8	1%	0.5	4%	1.5	1%	0.6
路口 3_往北_左轉	11%	2.4	32%	9.3	0%	0.1	2%	0.2
路口 3_往北_直行	2%	9.3	7%	35.0	1%	5.3	10%	42.2
路口 3_往南_直行	2%	9.7	2%	13.9	3%	13.6	1%	2.8
路口 3_往南_右轉	9%	1.0	98%	9.2	2%	0.2	4%	0.3
路口 4_往西_左轉	1%	0.3	2%	1.2	32%	16.5	5%	3.2
路口 4_往西_直行	3%	7.1	6%	12.2	5%	8.1	5%	8.1
路口 4_往西_右轉	0%	0.0	9%	2.5	1%	0.3	3%	1.1
路口 4_往北_左轉	1%	0.2	14%	2.2	10%	2.6	5%	0.3
路口 4_往北_直行	3%	12.3	2%	7.7	1%	2.9	1%	2.4
路口 4_往北_右轉	1%	0.7	0%	0.3	3%	1.8	0%	0.3
路口 4_往東_左轉	0%	0.2	6%	3.4	4%	2.4	10%	5.2
路口 4_往東_直行	3%	7.2	3%	8.5	1%	1.3	10%	20.2
路口 4_往東_右轉	1%	0.3	7%	5.4	1%	0.4	6%	5.5
路口 4_往南_左轉	45%	6.3	28%	6.8	22%	5.2	11%	2.8
路口 4_往南_直行	3%	19.4	2%	10.6	4%	17.8	1%	5.6
路口 4_往南_右轉	5%	2.7	1%	0.9	1%	0.4	3%	1.3
平均	6%	5.6	11%	7.9	6%	5.4	5%	6.6

表 5.3.32 VISSIM 臺北市場域流量 GEH

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
路口 2 往北左轉	0.6	0.4	2.2	1.2
路口 2 往北直行	0.3	1.0	0.7	1.4
路口 2 往東左轉	1.2	0.6	0.3	0.1
路口 2 往東右轉	1.7	0.9	0.4	0.3
路口 2 往南直行	0.3	0.2	0.1	0.2
路口 2 往南右轉	0.4	0.1	0.2	0.1
路口 3 往北左轉	0.5	1.9	0.0	0.1
路口 3 往北直行	0.4	1.6	0.2	2.0
路口 3 往南直行	0.4	0.6	0.6	0.1
路口 3 往南右轉	0.3	2.5	0.1	0.1
路口 4 往西左轉	0.0	0.2	2.1	0.4
路口 4 往西直行	0.5	0.8	0.7	0.6
路口 4 往西右轉	0.0	0.5	0.1	0.2
路口 4 往北左轉	0.0	0.6	0.5	0.1

路口 4 往北直行	0.6	0.4	0.1	0.1
路口 4 往北右轉	0.1	0.0	0.2	0.0
路口 4 往東左轉	0.0	0.5	0.3	0.7
路口 4 往東直行	0.5	0.5	0.1	1.4
路口 4 往東右轉	0.0	0.6	0.1	0.6
路口 4 往南左轉	1.5	1.3	1.1	0.6
路口 4 往南直行	0.8	0.4	0.8	0.2
路口 4 往南右轉	0.4	0.1	0.1	0.2

倘若從 MAPE 來看，平日上下午尖峰分別為 9%與 13%。另檢視臺北市場域的 GEH 統計量，則可以發現所有轉向的 GEH 值都 5 以下，符合表 5.3.31 中所定義的可接受之誤差門檻。另外臺北市場域的平均每車延滯模擬數值對照，整理於表 5.3.33 與表 5.3.34。

表 5.3.33 VISSIM 臺北市場域平日上午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	9.6	9.3
路口 2 往東	73.0	71.1
路口 2 往南	4.1	4.5
路口 3 往北	2.4	3.6
路口 3 往南	2.2	2.0
路口 4 往西	49.0	48.1
路口 4 往北	7.1	8.0
路口 4 往東	39.2	38.9
路口 4 往南	23.4	20.9

表 5.3.34 VISSIM 臺北市場域平日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	14.8	13.3
路口 2 往東	110.5	101.2
路口 2 往南	11.7	13.9
路口 3 往北	6.3	5.2
路口 3 往南	10.4	9.4
路口 4 往西	69.7	65.9
路口 4 往北	14.2	16.5
路口 4 往東	66.9	74.5
路口 4 往南	29.1	32.4

表 5.3.35 VISSIM 臺北市場域平日下午離峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	12.5	10.2
路口 2 往東	46.3	40.4
路口 2 往南	9.9	8.9
路口 3 往北	1.4	1.3
路口 3 往南	2.1	2.3
路口 4 往西	86.6	78.5
路口 4 往北	22.8	19.4
路口 4 往東	61.8	49.3
路口 4 往南	22.8	17.1

表 5.3.36 VISSIM 臺北市場域假日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	13.9	9.0
路口 2 往東	78.5	62.7
路口 2 往南	15.6	15.3
路口 3 往北	3.9	3.2
路口 3 往南	2.2	2.0
路口 4 往西	99.1	79.2
路口 4 往北	8.9	7.3
路口 4 往東	98.4	80.7
路口 4 往南	15.0	16.7

臺北市場域的平均每車延滯誤差，整理於 5.3.37。

表 5.3.37 VISSIM 臺北市場域平均每車延滯 MAPE 與 MAE

來向	平日上午尖峰		平日下午尖峰		平日下午離峰		假日下午尖峰	
	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE
路口 2 往北	3%	0.3	11%	1.6	19%	2.4	35%	4.9
路口 2 往東	3%	1.9	8%	9.3	13%	5.9	20%	15.8
路口 2 往南	11%	0.4	19%	2.2	11%	1.0	2%	0.4
路口 3 往北	47%	1.1	18%	1.1	5%	0.1	17%	0.6
路口 3 往南	11%	0.2	10%	1.0	6%	0.1	10%	0.2
路口 4 往西	2%	0.9	5%	3.8	9%	8.1	20%	19.8
路口 4 往北	13%	0.9	16%	2.3	15%	3.4	18%	1.6
路口 4 往東	1%	0.3	11%	7.6	20%	12.5	18%	17.7
路口 4 往南	11%	2.5	11%	3.3	25%	5.7	11%	1.7

平均	11%	1.0	12%	3.6	14%	4.4	17%	7.0

下上下午尖峰延滯 MAPE 分別為 11%與 12%。細看數據則可以發現誤差百分比較大的幾個方向都為南北向幹道，且南北向絕對誤差量平均每車大約是 1.4 秒，然而南北向誤差百分比卻有 15%，很明顯的，在此處平均每車延滯也受到數值過小造成誤差百分比被嚴重放大效應。因此進一步檢視 GEH 統計量，整理表 5.3.38。

表 5.3.38 VISSIM 臺北市場域平均每車延滯 GEH

來向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
路口 2 往北	0.1	0.4	0.7	1.5
路口 2 往東	0.2	0.9	0.9	1.9
路口 2 往南	0.2	0.6	0.3	0.1
路口 3 往北	0.7	0.5	0.1	0.3
路口 3 往南	0.2	0.3	0.1	0.2
路口 4 往西	0.1	0.5	0.9	2.1
路口 4 往北	0.3	0.6	0.7	0.6
路口 4 往東	0.1	0.9	1.7	1.9
路口 4 往南	0.5	0.6	1.3	0.4

從 GEH 統計量中可以發現到，所有路段的 GEH 皆小於 5，因此滿足表 5.3.1 中所建議的可被接受誤差門檻。因此綜合上述數據，雖然轉向交通量與平均每車延滯在 MAPE 上的表現略有偏高，然而經過數據的研析，並且以 GEH 統計量再次檢視，皆符合合理誤差範圍以內，因此可以認為 VISSIM 臺北市場域的建模是合格的模擬模型。

5.3.2.2 臺北市 SUMO 模擬數據

表 5.3.39 SUMO 臺北市場域平日上午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	53.2	35.3
路口 2_往北_直行	399.4	400.3
路口 2_往東_左轉	69.4	66.2
路口 2_往東_右轉	70.0	68.7
路口 2_往南_直行	592.1	546.0
路口 2_往南_右轉	45.5	41.3
路口 3_往北_左轉	21.9	19.5
路口 3_往北_直行	449.6	443.4
路口 3_往南_直行	637.4	620.9

路口 3_往南_右轉	11.2	10.5
路口 4_往西_左轉	47.5	36.0
路口 4_往西_直行	204.0	181.6
路口 4_往西_右轉	17.8	19.3
路口 4_往北_左轉	30.1	22.4
路口 4_往北_直行	390.0	381.3
路口 4_往北_右轉	53.7	57.3
路口 4_往東_左轉	58.9	52.3
路口 4_往東_直行	221.7	196.0
路口 4_往東_右轉	40.5	39.3
路口 4_往南_左轉	13.9	10.8
路口 4_往南_直行	673.0	590.0
路口 4_往南_右轉	50.2	40.2

表 5.3.40 SUMO 臺北市場域平日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	54.1	34.8
路口 2_往北_直行	440.9	463.4
路口 2_往東_左轉	145.2	136.2
路口 2_往東_右轉	51.1	54.2
路口 2_往南_直行	538.1	509.2
路口 2_往南_右轉	62.5	55.4
路口 3_往北_左轉	28.7	24.8
路口 3_往北_直行	490.2	500.7
路口 3_往南_直行	572.7	569.2
路口 3_往南_右轉	9.4	6.4
路口 4_往西_左轉	55.4	40.5
路口 4_往西_直行	213.1	173.1
路口 4_往西_右轉	27.1	23.1
路口 4_往北_左轉	15.8	10.5
路口 4_往北_直行	461.1	449.8
路口 4_往北_右轉	94.0	91.7
路口 4_往東_左轉	54.4	46.4
路口 4_往東_直行	246.6	214.1
路口 4_往東_右轉	79.7	76.9
路口 4_往南_左轉	24.1	17.3
路口 4_往南_直行	562.3	493.0

路口 4_往南_右轉	64.0	59.6

表 5.3.41 SUMO 臺北市場域平日下午離峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	46.1	41.7
路口 2_往北_直行	402.8	412.2
路口 2_往東_左轉	58.6	57.5
路口 2_往東_右轉	60.6	67.0
路口 2_往南_直行	476.6	454.0
路口 2_往南_右轉	41.3	36.9
路口 3_往北_左轉	15.2	12.5
路口 3_往北_直行	448.2	467.4
路口 3_往南_直行	521.4	527.6
路口 3_往南_右轉	9.2	7.8
路口 4_往西_左轉	51.7	49.2
路口 4_往西_直行	151.2	151.3
路口 4_往西_右轉	28.9	30.6
路口 4_往北_左轉	27.0	22.0
路口 4_往北_直行	378.6	373.6
路口 4_往北_右轉	61.2	59.4
路口 4_往東_左轉	61.6	62.6
路口 4_往東_直行	179.0	159.6
路口 4_往東_右轉	62.5	59.4
路口 4_往南_左轉	24.0	21.6
路口 4_往南_直行	508.3	469.6
路口 4_往南_右轉	44.4	37.6

表 5.3.42 SUMO 臺北市場域假日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
路口 2_往北_左轉	52.4	52.2
路口 2_往北_直行	377.1	395.4
路口 2_往東_左轉	91.4	86.5
路口 2_往東_右轉	56.2	56.7
路口 2_往南_直行	471.7	458.4
路口 2_往南_右轉	48.5	43.3
路口 3_往北_左轉	13.1	12.4
路口 3_往北_直行	431.5	458.8

路口 3_往南_直行	513.5	527.5
路口 3_往南_右轉	7.7	6.0
路口 4_往西_左轉	58.7	47.3
路口 4_往西_直行	159.1	141.7
路口 4_往西_右轉	31.8	27.8
路口 4_往北_左轉	6.0	4.5
路口 4_往北_直行	393.7	380.0
路口 4_往北_右轉	67.5	62.9
路口 4_往東_左轉	53.1	48.1
路口 4_往東_直行	200.7	166.4
路口 4_往東_右轉	86.2	88.2
路口 4_往南_左轉	24.5	21.8
路口 4_往南_直行	514.3	479.7
路口 4_往南_右轉	51.5	49.3

經過整理，將流量誤差整理於表 5.3.43 與表 5.3.44 。

表 5.3.43 SUMO 臺北市場域流量 MAPE 與 MAE

轉向	平日上午尖峰		平日下午尖峰		平日下午離峰		假日下午尖峰	
	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE
路口 2_往北_左轉	34%	17.9	36%	19.3	10%	4.5	0%	0.2
路口 2_往北_直行	0%	0.9	5%	22.5	2%	9.4	5%	18.3
路口 2_往東_左轉	5%	3.2	6%	9.0	2%	1.1	5%	4.9
路口 2_往東_右轉	2%	1.3	6%	3.1	10%	6.4	1%	0.5
路口 2_往南_直行	8%	46.1	5%	28.9	5%	22.6	3%	13.3
路口 2_往南_右轉	9%	4.2	11%	7.1	11%	4.4	11%	5.2
路口 3_往北_左轉	11%	2.4	14%	4.0	17%	2.7	5%	0.7
路口 3_往北_直行	1%	6.1	2%	10.6	4%	19.2	6%	27.3
路口 3_往南_直行	3%	16.5	1%	3.5	1%	6.2	3%	13.9
路口 3_往南_右轉	6%	0.6	32%	3.1	14%	1.3	22%	1.7
路口 4_往西_左轉	24%	11.5	27%	14.9	5%	2.5	19%	11.4
路口 4_往西_直行	11%	22.4	19%	40.1	0%	0.1	11%	17.4
路口 4_往西_右轉	9%	1.5	15%	4.0	6%	1.7	12%	3.9
路口 4_往北_左轉	26%	7.7	33%	5.3	18%	5.0	25%	1.5
路口 4_往北_直行	2%	8.6	2%	11.3	1%	5.0	3%	13.8
路口 4_往北_右轉	7%	3.6	2%	2.3	3%	1.8	7%	4.6
路口 4_往東_左轉	11%	6.6	15%	7.9	2%	1.0	10%	5.1
路口 4_往東_直行	12%	25.8	13%	32.4	11%	19.4	17%	34.3

路口 4_往東_右轉	3%	1.2	3%	2.8	5%	3.2	2%	2.0
路口 4_往南_左轉	23%	3.1	28%	6.8	10%	2.4	11%	2.8
路口 4_往南_直行	12%	82.9	12%	69.3	8%	38.7	7%	34.6
路口 4_往南_右轉	20%	10.0	7%	4.4	15%	6.9	4%	2.2
平均	11%	12.9	13%	14.2	7%	7.5	9%	10.0

表 5.3.44 SUMO 臺北市場域流量 GEH

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
路口 2 往北左轉	2.7	2.9	0.7	0.0
路口 2 往北直行	0.0	1.1	0.5	0.9
路口 2 往東左轉	0.4	0.8	0.1	0.5
路口 2 往東右轉	0.2	0.4	0.8	0.1
路口 2 往南直行	1.9	1.3	1.0	0.6
路口 2 往南右轉	0.6	0.9	0.7	0.8
路口 3 往北左轉	0.5	0.8	0.7	0.2
路口 3 往北直行	0.3	0.5	0.9	1.3
路口 3 往南直行	0.7	0.1	0.3	0.6
路口 3 往南右轉	0.2	1.1	0.5	0.6
路口 4 往西左轉	1.8	2.2	0.4	1.6
路口 4 往西直行	1.6	2.9	0.0	1.4
路口 4 往西右轉	0.4	0.8	0.3	0.7
路口 4 往北左轉	1.5	1.5	1.0	0.7
路口 4 往北直行	0.4	0.5	0.3	0.7
路口 4 往北右轉	0.5	0.2	0.2	0.6
路口 4 往東左轉	0.9	1.1	0.1	0.7
路口 4 往東直行	1.8	2.1	1.5	2.5
路口 4 往東右轉	0.2	0.3	0.4	0.2
路口 4 往南左轉	0.9	1.5	0.5	0.6
路口 4 往南直行	3.3	3.0	1.7	1.6
路口 4 往南右轉	1.5	0.6	1.1	0.3

倘若從 MAPE 來看，平日上下午尖峰分別為 11%與 13%。與在 VISSIM 驗證時有相同的問題，同樣是受到部分次要轉向的流量本身調查數值偏小，導致些微的誤差就造成百分比的高度敏感，而實際上這種程度的誤差量對模擬的結果影響其實幾乎可以忽略不計。若從此觀點出發，檢視臺北市場域的 GEH 統計量，則可以發現以所有轉向的 GEH 值都低於 5，符合表 5.3.1 中所定義的可接受之誤差門檻。臺北市場域的平均每車延

滯對照整理於表 5.3.45 與表 5.4.46，另外臺北市場域的平均每車延滯誤差，整理於表 5.3.49。

表 5.3.45 SUMO 臺北市場域平日上午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	9.6	10.0
路口 2 往東	73.0	95.1
路口 2 往南	4.1	10.1
路口 3 往北	2.4	4.0
路口 3 往南	2.2	2.0
路口 4 往西	49.0	52.5
路口 4 往北	7.1	8.7
路口 4 往東	39.2	54.8
路口 4 往南	23.4	16.6

表 5.3.46 SUMO 臺北市場域平日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	14.8	14.6
路口 2 往東	110.5	131.5
路口 2 往南	11.7	13.8
路口 3 往北	6.3	5.3
路口 3 往南	10.4	5.8
路口 4 往西	69.7	83.5
路口 4 往北	14.2	4.1
路口 4 往東	66.9	63.8
路口 4 往南	29.1	14.7

表 5.3.47 SUMO 臺北市場域平日下午離峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	12.5	13.0
路口 2 往東	46.3	59.0
路口 2 往南	9.9	11.9
路口 3 往北	1.4	1.9
路口 3 往南	2.1	1.3
路口 4 往西	86.6	65.1
路口 4 往北	22.8	29.1
路口 4 往東	61.8	49.9
路口 4 往南	22.8	18.0

表 5.3.48 SUMO 臺北市場域假日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
路口 2 往北	13.9	8.5
路口 2 往東	78.5	81.2
路口 2 往南	15.6	24.1
路口 3 往北	3.9	2.4
路口 3 往南	2.2	2.4
路口 4 往西	99.1	88.7
路口 4 往北	8.9	6.5
路口 4 往東	98.4	98.0
路口 4 往南	15.0	16.6

表 5.3.49 SUMO 臺北市場域平均每車延滯 MAPE 與 MAE

來向	平日上午尖峰		平日下午尖峰		平日下午離峰		假日下午尖峰	
	MAPE	MAE	MAPE	MAE	MAPE	MAE	MAPE	MAE
路口 2 往北	4%	0.4	2%	0.2	4%	0.5	38%	5.3
路口 2 往東	30%	22.1	19%	21.1	27%	12.7	3%	2.7
路口 2 往南	147%	6.0	19%	2.2	20%	2.0	54%	8.5
路口 3 往北	64%	1.5	16%	1.0	35%	0.5	38%	1.5
路口 3 往南	7%	0.2	45%	4.6	38%	0.8	7%	0.1
路口 4 往西	7%	3.5	20%	13.8	25%	21.6	10%	10.3
路口 4 往北	23%	1.6	71%	10.1	28%	6.3	27%	2.4
路口 4 往東	40%	15.6	5%	3.1	19%	11.9	0%	0.4
路口 4 往南	29%	6.8	50%	14.4	21%	4.8	10%	1.6
平均	39%	6.1	27%	7.8	24%	6.8	21%	3.6

與流量 MAPE 有同樣的問題，受到調查數值較低的影響使誤差百分比偏高。而細看數據則可以發現誤差百分比較大的幾個方向都為南北向幹道，且南北向絕對誤差量平均每車大約是 4.1 秒，然而南北向誤差百分比卻高達 40%，很明顯的，在此處平均每車停等延滯也受到數值過小造成誤差百分比被嚴重放大效應。因此進一步檢視 GEH 統計量，整理於表 5.3.50。

表 5.3.50.1. SUMO 臺北市場域平均每車延滯 GEH

來向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
路口 2 往北	0.1	0.1	0.1	1.6
路口 2 往東	2.4	1.9	1.7	0.3
路口 2 往南	2.3	0.6	0.6	1.9

路口 3 往北	0.9	0.4	0.4	0.8
路口 3 往南	0.1	1.6	0.6	0.1
路口 4 往西	0.5	1.6	2.5	1.1
路口 4 往北	0.6	3.3	1.2	0.9
路口 4 往東	2.3	0.4	1.6	0.0
路口 4 往南	1.5	3.1	1.1	0.4

從 GEH 統計量中可以發現到，所有的路段的 GEH 數值都小於 5，因此滿足表 5.3.1 中所建議的可被接受誤差門檻。因此綜合上述數據，雖然轉向交通量與平均每車延滯在 MAPE 上的表現略有偏高的狀況，然而經過數據的研析，並且以 GEH 統計量再次檢視，皆符合合理誤差範圍內，因此可以認為 SUMO 臺北市場域的建模是合格的模擬模型。

5.3.3 車聯網場域模擬驗證(高雄市)

5.3.3.1 高雄市 VISSIM 模擬數據

表 5.3.51 VISSIM 高雄市場域平日上午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	73.7	80.5
西向下匝道_直行	201.3	205.1
西向下匝道_右轉	56.4	57.6
西向快車道_直行	323.4	319.1
西向快車道_右轉	8.9	8.8
西向慢車道_直行	101.0	101.4
西向慢車道_右轉	3.4	3.4
北向_左轉	156.4	166.9
北向_直行	128.1	132.8
北向_右轉	193.9	198.4
東向下匝道_直行	93.0	110.5
東向下匝道_右轉	169.6	164.9
東向快車道_直行	346.2	350.8
東向慢車道_直行	154.6	160.5
東向慢車道_右轉	5.7	5.7
南向_左轉	137.4	129.5
南向_直行	140.6	143.9
南向_右轉	67.5	62.6

表 5.3.52 VISSIM 高雄市場域平日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	85.4	81.1
西向下匝道_直行	213.6	210.1
西向下匝道_右轉	74.3	72.8
西向快車道_直行	365.3	360.0
西向快車道_右轉	7.0	7.3
西向慢車道_直行	162.8	154.6
西向慢車道_右轉	7.6	6.4
北向_左轉	121.5	115.5
北向_直行	156.9	161.8
北向_右轉	185.3	187.1
東向下匝道_直行	147.6	151.4
東向下匝道_右轉	259.4	257.8
東向快車道_直行	341.3	338.1
東向慢車道_直行	83.7	84.7
東向慢車道_右轉	9.5	9.3
南向_左轉	127.9	127.6
南向_直行	213.5	215.3
南向_右轉	68.8	64.3

表 5.3.53 VISSIM 高雄市場域平日下午離峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	81.6	88.6
西向下匝道_直行	181.3	192.4
西向下匝道_右轉	54.2	61.3
西向快車道_直行	291.3	286.1
西向快車道_右轉	4.0	4.4
西向慢車道_直行	33.1	33.8
西向慢車道_右轉	4.3	4.4
北向_左轉	133.8	131.0
北向_直行	96.0	102.4
北向_右轉	217.7	217.5
東向下匝道_直行	125.6	126.5
東向下匝道_右轉	235.6	238.5
東向快車道_直行	323.9	326.7
東向慢車道_直行	31.3	31.9

東向慢車道_右轉	7.8	7.7
南向_左轉	90.0	89.5
南向_直行	109.4	109.3
南向_右轉	48.5	48.1

表 5.3.54 VISSIM 高雄市場域假日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	92.2	92.4
西向下匝道_直行	213.3	201.9
西向下匝道_右轉	83.9	81.6
西向快車道_直行	269.0	273.1
西向快車道_右轉	2.0	2.3
西向慢車道_直行	74.8	72.4
西向慢車道_右轉	6.3	6.6
北向_左轉	151.9	156.4
北向_直行	129.3	130.8
北向_右轉	174.3	165.9
東向下匝道_直行	112.4	114.8
東向下匝道_右轉	227.5	236.1
東向快車道_直行	300.8	299.4
東向慢車道_直行	53.9	58.4
東向慢車道_右轉	13.6	12.2
南向_左轉	115.1	111.6
南向_直行	149.2	148.1
南向_右轉	58.1	50.3

經過整理，可將各方向的模擬誤差整理成表 5.3.55 與表 5.3.56。

表 5.3.55 VISSIM 高雄市場域流量 MAPE

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向下匝道_左轉	9%	5%	9%	0%
西向下匝道_直行	2%	2%	6%	5%
西向下匝道_右轉	2%	2%	13%	3%
西向快車道_直行	1%	1%	2%	2%
西向快車道_右轉	1%	4%	9%	13%
西向慢車道_直行	0%	5%	2%	3%
西向慢車道_右轉	2%	16%	3%	5%
北向_左轉	7%	5%	2%	3%

北向_直行	4%	3%	7%	1%
北向_右轉	2%	1%	0%	5%
東向下匝道_直行	19%	3%	1%	2%
東向下匝道_右轉	3%	1%	1%	4%
東向快車道_直行	1%	1%	1%	0%
東向慢車道_直行	4%	1%	2%	8%
東向慢車道_右轉	1%	2%	2%	10%
南向_左轉	6%	0%	1%	3%
南向_直行	2%	1%	0%	1%
南向_右轉	7%	7%	1%	14%
平均	4%	3%	3%	5%

表 5.3.56 VISSIM 高雄市場域流量 GEH

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向下匝道_左轉	0.8	0.5	0.8	0.0
西向下匝道_直行	0.3	0.2	0.8	0.8
西向下匝道_右轉	0.2	0.2	0.9	0.3
西向快車道_直行	0.2	0.3	0.3	0.2
西向快車道_右轉	0.0	0.1	0.2	0.2
西向慢車道_直行	0.0	0.6	0.1	0.3
西向慢車道_右轉	0.0	0.5	0.1	0.1
北向_左轉	0.8	0.6	0.2	0.4
北向_直行	0.4	0.4	0.6	0.1
北向_右轉	0.3	0.1	0.0	0.6
東向下匝道_直行	1.7	0.3	0.1	0.2
東向下匝道_右轉	0.4	0.1	0.2	0.6
東向快車道_直行	0.2	0.2	0.2	0.1
東向慢車道_直行	0.5	0.1	0.1	0.6
東向慢車道_右轉	0.0	0.0	0.0	0.4
南向_左轉	0.7	0.0	0.1	0.3
南向_直行	0.3	0.1	0.0	0.1
南向_右轉	0.6	0.6	0.0	1.1

高雄市場域在 VISSIM 模擬中，MAPE 指標皆在 10%以內；而更進一步從 GEH 統計量檢核，所有轉向亦都能滿足 GEH 小於 5，符合表 5.3.1 誤差接受門檻。因此可以認為 VISSIM 高雄市場域是一個合格的模擬模型。第二個部分將針對平均每車延滯進行分析。表 5.3.57 與表 5.3.58 分別為上

午尖峰與下午尖峰之平均每車延滯調查與模擬值。

表 5.3.57 VISSIM 高雄市場域平日上午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	93.2	80.7
西向快車道	48.1	48.0
北向	70.9	60.0
東向下匝道	42.7	41.1
東向快車道	57.0	53.1
南向	99.6	96.5

表 5.3.58 VISSIM 高雄市場域平日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	196.3	183.0
西向快車道	52.4	47.3
北向	56.5	52.5
東向下匝道	60.9	62.2
東向快車道	87.9	84.6
南向	155.1	144.4

表 5.3.59 VISSIM 高雄市場域平日下午離峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	207.0	192.4
西向快車道	45.3	46.0
北向	55.3	49.9
東向下匝道	40.4	37.0
東向快車道	52.3	51.3
南向	78.3	72.0

表 5.3.60 VISSIM 高雄市場域假日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	114.3	104.0
西向快車道	50.0	45.5
北向	63.5	58.8
東向下匝道	43.6	39.7
東向快車道	50.5	49.1
南向	102.6	103.5

經過整理，可將各方向的模擬誤差整理成表 5.3.61 與表 5.3.62。

表 5.3.61 VISSIM 高雄市場域平均每車延滯 MAPE

來向	平日上午尖峰	平日下午尖峰	平日上午離峰	假日下午尖峰
西向下匝道	13%	7%	7%	9%
西向快車道	0%	10%	1%	9%
北向	15%	7%	10%	7%
東向下匝道	4%	2%	8%	9%
東向快車道	7%	4%	2%	3%
南向	3%	7%	8%	1%
平均	7%	6%	6%	6%

表 5.3.62 VISSIM 高雄市場域平均每車延滯 GEH

來向	平日上午尖峰	平日下午尖峰	平日上午離峰	假日下午尖峰
西向下匝道	1.3	1.0	1.0	1.0
西向快車道	0.0	0.7	0.1	0.7
北向	1.3	0.5	0.7	0.6
東向下匝道	0.2	0.2	0.5	0.6
東向快車道	0.5	0.3	0.1	0.2
南向	0.3	0.9	0.7	0.1

從 GEH 表中可以發現，高雄市場域在 VISSIM 模擬中，所有路段來向的平均每車延滯GEH值皆低於5，並且從MAPE數值也皆在10%以內。因此從輔助指標平均每車延滯也可以說明 VISSIM 高雄市場域是一個合格的模擬模型。

5.3.2.2 高雄市 SUMO 模擬數據

表 5.3.63 SUMO 高雄市場域平日上午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	73.7	68.0
西向下匝道_直行	201.3	207.8
西向下匝道_右轉	56.4	66.3
西向快車道_直行	323.4	306.9
西向快車道_右轉	8.9	8.0
西向慢車道_直行	101.0	95.2
西向慢車道_右轉	3.4	3.3
北向_左轉	156.4	159.9
北向_直行	128.1	129.2
北向_右轉	193.9	175.9

東向下匝道_直行	93.0	84.5
東向下匝道_右轉	169.6	162.6
東向快車道_直行	346.2	335.6
東向慢車道_直行	154.6	146.5
東向慢車道_右轉	5.7	3.0
南向_左轉	137.4	133.6
南向_直行	140.6	147.0
南向_右轉	67.5	68.4

表 5.3.64 SUMO 高雄市場域平日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	85.4	90.9
西向下匝道_直行	213.6	208.3
西向下匝道_右轉	74.3	81.9
西向快車道_直行	365.3	366.4
西向快車道_右轉	7.0	4.4
西向慢車道_直行	162.8	149.4
西向慢車道_右轉	7.6	2.3
北向_左轉	121.5	123.0
北向_直行	156.9	155.6
北向_右轉	185.3	175.5
東向下匝道_直行	147.6	126.9
東向下匝道_右轉	259.4	233.0
東向快車道_直行	341.3	333.4
東向慢車道_直行	83.7	87.7
東向慢車道_右轉	9.5	6.1
南向_左轉	127.9	129.8
南向_直行	213.5	219.2
南向_右轉	68.8	73.6

表 5.3.65 SUMO 高雄市場域平日下午離峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	81.6	84.5
西向下匝道_直行	181.3	189.1
西向下匝道_右轉	54.2	54.8
西向快車道_直行	291.3	300.6
西向快車道_右轉	4.0	4.0
西向慢車道_直行	33.1	33.3

西向慢車道_右轉	4.3	4.2
北向_左轉	133.8	124.6
北向_直行	96.0	92.1
北向_右轉	217.7	223.0
東向下匝道_直行	125.6	119.4
東向下匝道_右轉	235.6	231.0
東向快車道_直行	323.9	321.4
東向慢車道_直行	31.3	32.7
東向慢車道_右轉	7.8	8.1
南向_左轉	90.0	90.1
南向_直行	109.4	111.1
南向_右轉	48.5	49.5

表 5.3.66 SUMO 高雄市場域假日下午尖峰調查與模擬流量

轉向	調查值(pcu/30min)	模擬值(pcu/30min)
西向下匝道_左轉	92.2	91.0
西向下匝道_直行	213.3	207.8
西向下匝道_右轉	83.9	65.4
西向快車道_直行	269.0	248.0
西向快車道_右轉	2.0	2.8
西向慢車道_直行	74.8	70.7
西向慢車道_右轉	6.3	7.4
北向_左轉	151.9	135.5
北向_直行	129.3	126.5
北向_右轉	174.3	151.4
東向下匝道_直行	112.4	103.6
東向下匝道_右轉	227.5	202.4
東向快車道_直行	300.8	298.3
東向慢車道_直行	53.9	49.3
東向慢車道_右轉	13.6	12.7
南向_左轉	115.1	102.6
南向_直行	149.2	145.8
南向_右轉	58.1	59.7

經過整理，可將各方向的模擬誤差整理成表 5.3.67 與表 5.3.68。

表 5.3.67 SUMO 高雄市場域流量 MAPE

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰

西向下匝道_左轉	8%	6%	4%	1%
西向下匝道_直行	3%	2%	4%	3%
西向下匝道_右轉	17%	10%	1%	22%
西向快車道_直行	5%	0%	3%	8%
西向快車道_右轉	10%	38%	0%	38%
西向慢車道_直行	6%	8%	1%	6%
西向慢車道_右轉	4%	70%	2%	18%
北向_左轉	2%	1%	7%	11%
北向_直行	1%	1%	4%	2%
北向_右轉	9%	5%	2%	13%
東向下匝道_直行	9%	14%	5%	8%
東向下匝道_右轉	4%	10%	2%	11%
東向快車道_直行	3%	2%	1%	1%
東向慢車道_直行	5%	5%	5%	9%
東向慢車道_右轉	47%	36%	4%	6%
南向_左轉	3%	1%	0%	11%
南向_直行	5%	3%	2%	2%
南向_右轉	1%	7%	2%	3%
平均	8%	12%	3%	10%

表 5.3.68 SUMO 高雄市場域流量 GEH

轉向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向下匝道_左轉	0.7	0.6	0.3	0.1
西向下匝道_直行	0.5	0.4	0.6	0.4
西向下匝道_右轉	1.3	0.9	0.1	2.1
西向快車道_直行	0.9	0.1	0.5	1.3
西向快車道_右轉	0.3	1.1	0.0	0.5
西向慢車道_直行	0.6	1.1	0.0	0.5
西向慢車道_右轉	0.1	2.4	0.0	0.4
北向_左轉	0.3	0.1	0.8	1.4
北向_直行	0.1	0.1	0.4	0.3
北向_右轉	1.3	0.7	0.4	1.8
東向下匝道_直行	0.9	1.8	0.6	0.8
東向下匝道_右轉	0.5	1.7	0.3	1.7
東向快車道_直行	0.6	0.4	0.1	0.1
東向慢車道_直行	0.7	0.4	0.3	0.6
東向慢車道_右轉	1.3	1.2	0.1	0.2

南向_左轉	0.3	0.2	0.0	1.2
南向_直行	0.5	0.4	0.2	0.3
南向_右轉	0.1	0.6	0.2	0.2

高雄市場域在SUMO模擬中，延滯MAPE在上下午分別為8%與12%，並且所有轉向亦都能滿足 GEH 小於 5，符合表 5.3.1 的誤差接受門檻。因此可以認為 SUMO 高雄市場域是一個合格的模擬模型。第二個部分將針對平均每車延滯進行分析。表 5.3.69 與表 5.3.70 分別為上午尖峰與下午尖峰之平均每車延滯調查與模擬值。

表 5.3.69 SUMO 高雄市場域平日上午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	93.2	81.2
西向快車道	48.1	37.5
北向	70.9	66.4
東向下匝道	42.7	48.0
東向快車道	57.0	62.2
南向	99.6	103.4

表 5.3.70 SUMO 高雄市場域平日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	196.3	215.3
西向快車道	52.4	62.8
北向	56.5	67.6
東向下匝道	60.9	71.3
東向快車道	87.9	66.0
南向	155.1	158.4

表 5.3.71 SUMO 高雄市場域平日下午離峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)
西向下匝道	207.0	211.8
西向快車道	45.3	35.7
北向	55.3	60.9
東向下匝道	40.4	50.9
東向快車道	52.3	59.0
南向	78.3	91.5

表 5.3.72 SUMO 高雄市場域假日下午尖峰平均每車延滯

來向	調查值(s/veh)	模擬值(s/veh)

西向下匝道	114.3	119.7
西向快車道	50.0	60.0
北向	63.5	68.6
東向下匝道	43.6	49.9
東向快車道	50.5	57.2
南向	102.6	97.8

經過整理，可將各方向的模擬誤差整理成表 5.3.73 與表 5.3.74。

表 5.3.73 SUMO 高雄市場域平均每車延滯 MAPE

來向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向下匝道	13%	10%	2%	5%
西向快車道	22%	20%	21%	20%
北向	6%	20%	10%	8%
東向下匝道	12%	17%	26%	14%
東向快車道	9%	25%	13%	13%
南向	4%	2%	17%	5%
平均	11%	16%	15%	11%

表 5.3.74 SUMO 高雄市場域平均每車延滯 GEH

來向	平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
西向下匝道	1.3	1.3	0.3	0.5
西向快車道	1.6	1.4	1.5	1.3
北向	0.5	1.4	0.7	0.6
東向下匝道	0.8	1.3	1.6	0.9
東向快車道	0.7	2.5	0.9	0.9
南向	0.4	0.3	1.4	0.5

從 GEH 表中可以發現，高雄市場域在 SUMO 模擬中，所有來向的平均每車延滯 GEH 值皆低於 5。因此從輔助指標平均每車延滯也可以說明 SUMO 高雄市場域是一個合格的模擬模型。

5.3.4 模擬路網驗證小結

經上述說明，本案分別以 VISSIM 與 SUMO 兩套微觀車流模擬軟體完成臺南市、臺北市、高雄市等三處場域上下午尖峰之參數校估驗證。驗證指標分別以轉向交通量與平均每車延滯兩項指標做為驗證項目，而驗證統計量除採用傳統常見之平均絕對誤差百分比(MAPE)外，為避免極小值或極大值對百分比的劇烈影響導致有失客觀，另外也採用了 GEH 統

計量來確保模型配適程度的合理性。MAPE 驗證結果整理於表 5.3.75；GEH 統計驗證列於表 5.3.76。

表 5.3.75 模擬驗證 MAPE 一覽

	臺南市		臺北市		高雄市	
	流量	延滯	流量	延滯	流量	延滯
VISSIM						
平日上午尖峰	4%	9%	6%	11%	4%	7%
平日下午尖峰	4%	8%	11%	12%	3%	6%
平日下午離峰	7%	18%	6%	14%	3%	6%
假日下午尖峰	4%	8%	5%	17%	5%	6%
SUMO						
平日上午尖峰	6%	15%	11%	39%	8%	11%
平日下午尖峰	5%	11%	13%	27%	12%	16%
平日下午離峰	9%	20%	7%	24%	3%	15%
假日下午尖峰	5%	9%	9%	21%	10%	11%

表 5.3.76 模擬驗證 GEH 一覽

	臺南市		臺北市		高雄市	
	流量	延滯	流量	延滯	流量	延滯
VISSIM						
平日上午尖峰	100%	100%	100%	100%	100%	100%
平日下午尖峰	100%	100%	100%	100%	100%	100%
平日下午離峰	100%	100%	100%	100%	100%	100%
假日下午尖峰	100%	100%	100%	100%	100%	100%
SUMO						
平日上午尖峰	100%	100%	100%	100%	100%	100%
平日下午尖峰	100%	100%	100%	100%	100%	100%
平日下午離峰	100%	100%	100%	100%	100%	100%
假日下午尖峰	100%	100%	100%	100%	100%	100%

在表 5.3.75 中，有幾個情境場域的 MAPE 值雖然略微偏高，然而在細究數據分析後，大多皆是因為調查數值本身偏低，導致誤差百分比大幅受到影響所致，實際絕對誤差量甚小，對於模擬評估結果並無重大影響。為佐證此一說法，另採用 GEH 統計量說明模型合理性。GEH 統計量可以有效的避免調查數值在極小狀況下造成誤差百分比嚴重高估的狀況；亦可以避免調查數值在極大狀況下嚴重低估誤差百分比的狀況。GEH 驗證通過門檻可參考表 5.3.1，表 5.3.76 列出各情境 GEH 低於 5 的百分比。

從表 5.3.76 中可以發現到，兩款模擬器在所有情境，流量與延滯指標之所有 GEH 數值皆能低於 5，符合表 5.3.1 所建議的接受門檻(85%以上)。這也說明了，MAPE 的統計結果確實有受到調查數據本身數值大小的影響，進而造成無法維持在合理誤差範圍的的狀況。在本計畫中模擬模型誤差的分析當中，SUMO 誤差略高於 VISSIM 表現，然而這點並不代表 SUMO 能力不如 VISSIM，僅能說明在本案中 VISSIM 的建模校估相較於 SUMO 所建立之模型較為貼近現況交通表現。而在本案已盡可能的調整 SUMO 中各項參數設定與建模細節，並且也透過不同統計量的檢驗證實模型的合理性。

經過本節針對模擬器校估驗證數據的分析與探討，本案中的模擬器已可被視為完成校估，且足以合理反映現場交通狀況之車流模型。

第六章 強化學習訓練成果與分析

6.1 強化學習訓練架構

在本章中將依照 5.2 節的模型輸入、輸出、獎勵等 13 種方案規劃進行模擬中的訓練與績效測試。此 13 種方案的訓練方式將會採用 3.2 節所介紹的 DDPG 方法做為訓練演算法。另外在臺南市場域部分，本計畫嘗試另一種 RL 演算法 PPO，測試不同 RL 演算法是否亦可適用於號誌控制議題上。關於 PPO 方法的相關說明可參考 3.3 節。在本章中訓練/測試過程架構基本上可以對照 3.1 節中的圖 3.1.4，訓練過程基本上即為圖 3.1.4 之右半部分；而由於本計畫在今年度的規劃僅在模擬器上測試訓練成效，因此圖 3.1.4 的左半部分則是改由在模擬器上進行事前事後的績效評估。彙總後的架構如圖 6.1.1。

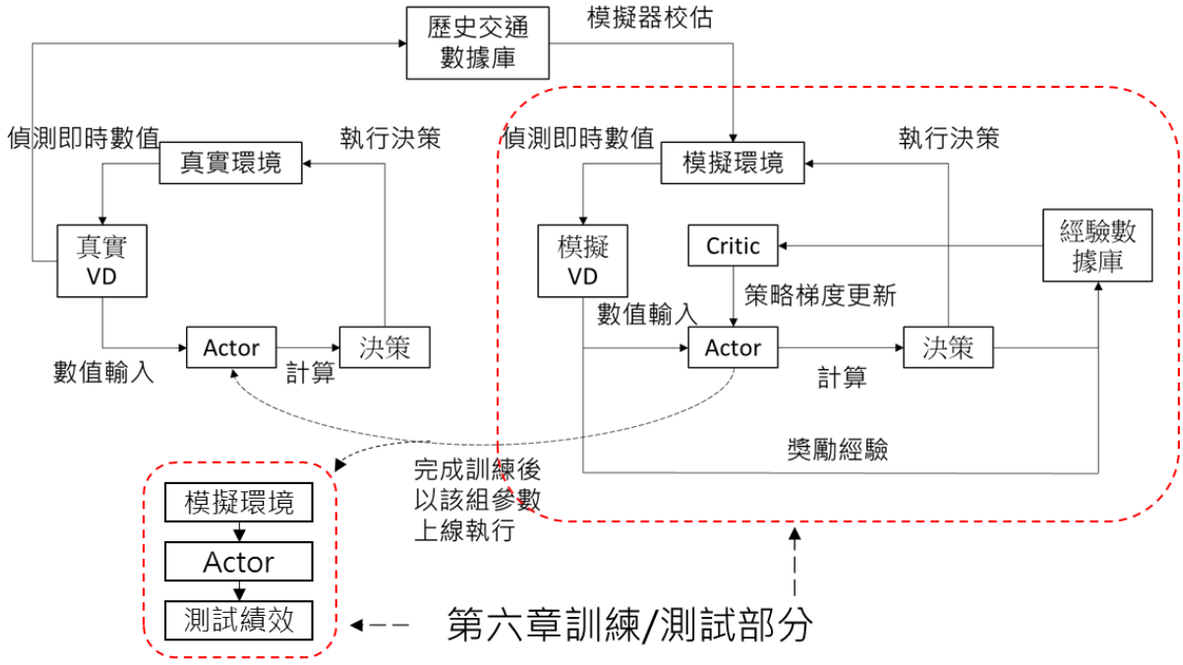

圖 6.1.1 訓練與測試架構圖

另外整理本計畫中所使用的軟硬體設備，以供做為訓練耗時的參考基準，VISSIM 為 2022 SP07 版，SUMO 為 1.14.1 版。

表 6.1.1 軟硬體環境規格

項目	規格	備註
CPU	I9 9900K	
GPU	RTX2080Ti	11GB
RAM	DDR4 2666	16GB * 2
SSD	M.2	2TB

Python	3.7.3	
TensorFlow	1.13.1	

6.2 單一路口場域(臺南市場域)

在臺南場域的實驗中，根據 5.2.1 節中的說明，共有 4 種不同的設定方案。而在探討這幾種方案的訓練結果前，需先說明套用於本場域的幾項共通設定。首先，由於臺南場域現況中，不同時段將採用不同的時相順序配置，如圖 6.2.1 與圖 6.2.2 所示。在本計畫中所設定的四種不同的交通情境，平日上午尖峰 06:30~09:30、平日下午尖峰 16:00~19:00、平日下午離峰 12:00~15:00、假日下午尖峰 16:00~19:00，分別對應到圖 6.2.1 的時制計畫 2、6、1、6。

由於在本計畫中並不探討時段切分與時相設計等議題，為了要配合套用 RL 的架構，Action set 需要固定，意即時相順序需要固定，因此在臺南市場域的所有方案都將分 3 套 RL 參數進行訓練，分別對應時制計畫 2、6、1。而實際訓練與模擬測驗時，將依時段運行對應的 RL 參數組。舉例來說，在運作上午尖峰交通情境的測試時，模擬的前 40 分鐘以第三套 RL 參數(對應時制計畫 1)運作；模擬的 40~90 分鐘以第一套 RL 參數(對應時制計畫 6)運作；模擬的 90~180 分鐘以第三套參數(對應時制計畫 1)運作。

	時相1			時相2			時相3			時相4			時相5		
計畫															
2	17	6	0	85	5	3	17	5	3	21	5	3	22	5	3

	時相1			時相2			時相3			時相4			時相5		
計畫															
6	22	6	0	96	5	3	20	5	3	24	5	3	20	5	3

		時相2			時相3			時相4			時相5		
計畫													
1		102	5	3	20	5	3	23	5	3	23	5	3
4		32	5	3	10	5	3	16	5	3	10	5	3
8		73	5	3	20	5	3	25	5	3	20	5	3

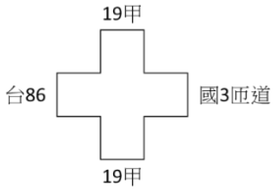

圖 6.2.1 台 86-19 甲線路口號誌時制計畫

週內日 × 時制計畫 × 特殊日 ×

中心時段型態

週一	週二	週三	週四	週五	週六	週日
1	1	1	1	3	2	2

時段型態碼 1-7為週內日

型態碼	1	2	3	4	5	6	7
分段	1	1	1				
執行時間	06:00	06:00	06:00				
時制計劃	1	1	1				
分段	2	2	2				
執行時間	07:10	07:00	07:10				
時制計劃	2	8	2				
分段	3	3	3				
執行時間	08:00	09:00	08:00				
時制計劃	1	2	1				
分段	4	4	4				
執行時間	16:00	12:00	16:30				
時制計劃	6	8	6				
分段	5	5	5				
執行時間	18:50	15:30	19:00				
時制計劃	1	6	1				
分段	6	6	6				
執行時間	23:00	18:50	23:00				
時制計劃	4	1	4				
分段		7					
執行時間		23:00					
時制計劃		4					

圖 6.2.2 台 86-19 甲線路口號誌時制計畫

有關模擬測試的設定上，共計 4 種不同交通情境 ，每種情境都以不同的亂數種子模擬 10 次，再計算平均的績效數值。比較對象為現場場域既有 TOD 時制計畫，定時時制計畫也以同樣的亂數種子模擬 10 次後計算績效數值。模擬總時長為 3 個小時，其中前 30 分鐘為暖機時間，後 30 分鐘為冷卻時間，即所有績效分析數值僅包含模擬過程中的中間 2 小時。

訓練過程中績效將隨著類神經網路逐漸收斂而逐漸的進步，以 A1 為例的訓練績效演進圖可參考圖 6.2.3。由於績效演進過程需要對訓練過程中各歷代 Actor 進行績效的數值模擬，耗費時間甚鉅，並且基本上各方案的績效演進過程皆類似，因此在臺南場域即以 A1 做為代表呈現。另外在表 6.2.1 中整理了臺南場域各方案訓練過程所需的時間。

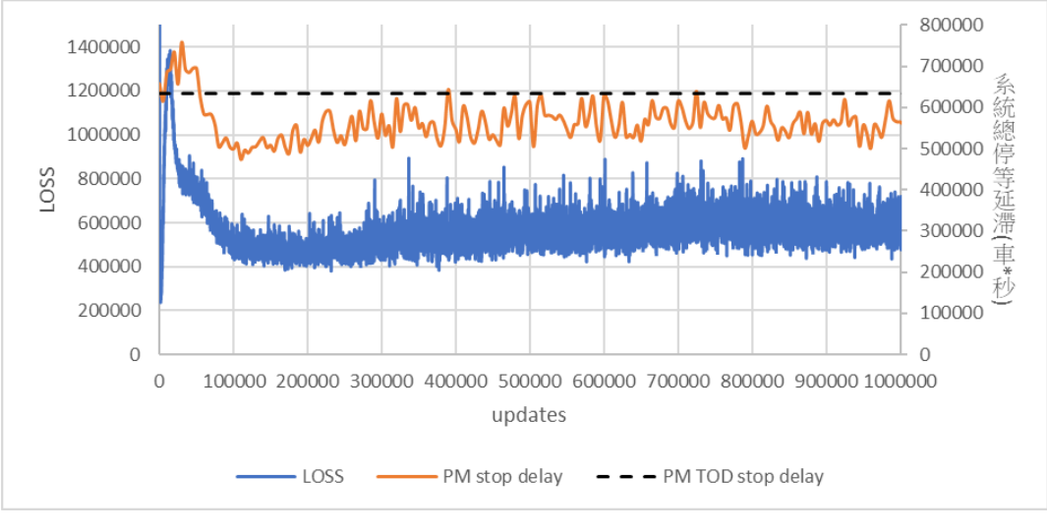

圖 6.2.3 臺南市場域訓練績效演進圖(以 A1 為例)

表 6.2.1 臺南場域訓練過程與時間

方案	更新次數	訓練時間
A1	150 萬次(單一 Agent)	21 小時(單一 Agent)
A2	150 萬次(單一 Agent)	20 小時(單一 Agent)
A3	150 萬次(單一 Agent)	20 小時(單一 Agent)
A4	150 萬次(單一 Agent)	21 小時(單一 Agent)
PPO	3 萬次(單一 Agent)(約 1000 episodes)	48 小時(單一 Agent)

6.2.1 臺南場域模擬測試數值

6.2.1.1 A1 方案(車輛數-逐時相-延滯)

方案設定如下：

1. 資料輸入：(1)決策瞬間，所有方向的分車道分車種車輛數；(2)時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

表 6.2.2 A1 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰(1)	52.4	41.3	-21%	7985	8022	0%
平日下午尖峰(2)	65.1	54.1	-17%	9099	9057	0%
平日下午離峰(3)	45.4	34.4	-24%	6831	6818	0%
假日下午尖峰(2)	52.8	39.1	-26%	7771	7763	0%

表 6.2.3 A1 方案模擬各方向績效變化

	往西方向 每車延滯	往東方向 每車延滯	往北方向 每車延滯	往南方向 每車延滯
情境	與 TOD 差異			
平日上午尖峰	+2.8	+5.1	-28.8	-26.1
平日下午尖峰	+5.5	+14.3	-18.9	-57.8
平日下午離峰	-2.6	-5.4	-19.1	-27.5
假日下午尖峰	+0.2	+0.4	-19.9	-53.0

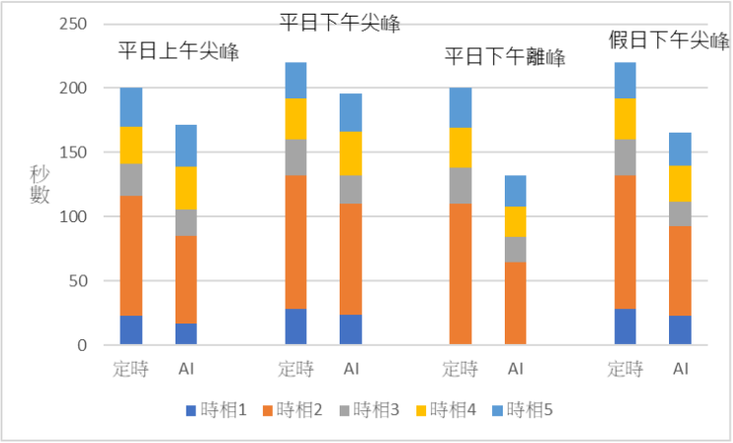

圖 6.2.4 A1 方案平均時相長度

表 6.2.4 A1 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	171.2	196	131.9	165.7
	最大值	256	299	248	289
	最小值	128	132	114	129
	標準差	32.7	34.4	20.4	29.1
時相 1	平均值	16.7	23.8	-	22.5
	最大值	31	39	-	39
	最小值	15	17	-	17
	標準差	3.6	7.8	-	7.4
時相 2	平均值	68.6	86.5	64.6	69.9
	最大值	135	152	150	147
	最小值	50	56	56	56
	標準差	23.8	27.5	15.6	19.9
時相 3	平均值	20.5	22.1	19.5	19.5
	最大值	33	38	38	38
	最小值	17	18	18	18
	標準差	4	5.7	2.6	3
時相 4	平均值	33.2	33.9	23.7	27.7
	最大值	39	44	43	44
	最小值	17	20	20	20
	標準差	5.3	9.1	4.6	7.6
時相 5	平均值	32.3	29.8	24.3	26.1
	最大值	41	38	43	38
	最小值	19	18	20	18
	標準差	7.4	6.5	5.6	6.1

6.2.1.2 A2 方案(轉向量-逐時相-延滯)

方案設定如下：

1. 資料輸入：(1)決策瞬間，前一週期該時相的轉向交通量(分車種)；(2)時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

表 6.2.5 A2 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰(1)	52.4	45.5	-13%	7985	8014	0%
平日下午尖峰(2)	65.1	61.9	-5%	9099	9032	-1%
平日下午離峰(3)	45.4	37.3	-18%	6831	6818	0%
假日下午尖峰(2)	52.8	47.3	-10%	7771	7773	0%

表 6.2.6 A2 方案模擬各方向績效變化

	往西方向 每車延滯	往東方向 每車延滯	往北方向 每車延滯	往南方向 每車延滯
情境	與 TOD 差異			
平日上午尖峰	+14.3	-0.3	-26.3	-12.7
平日下午尖峰	+14.1	+6.6	-12.5	-33.8
平日下午離峰	+4.5	-4.5	-17.6	-28.0
假日下午尖峰	+9.8	+3.5	-13.2	-40.1

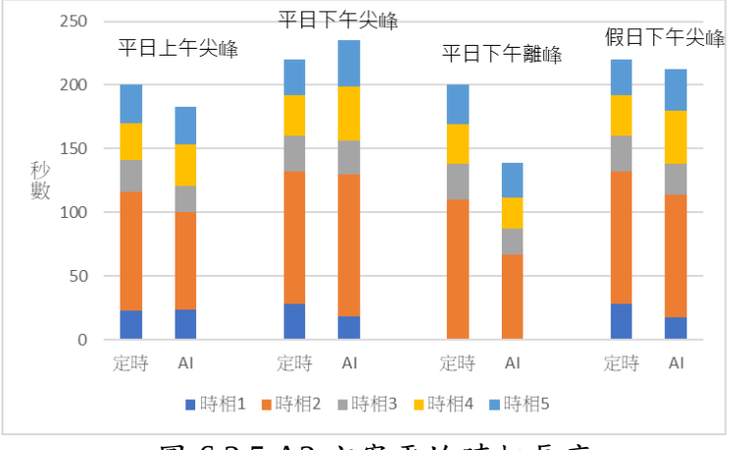

圖 6.2.5 A2 方案平均時相長度

表 6.2.7 A2 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	183.3	235	138.8	212.7
	最大值	248	283	180	274
	最小值	136	179	114	148
	標準差	22.4	22.4	11.6	32.5
時相 1	平均值	23.4	18.1	-	17.6
	最大值	31	29	-	26
	最小值	15	17	-	17
	標準差	4	1.7	-	1.2
時相 2	平均值	76.7	111.7	66.8	96.4
	最大值	138	152	105	150
	最小值	50	66	56	56
	標準差	20.7	18.4	9	25.5
時相 3	平均值	20.7	26.5	20.8	24.1
	最大值	32	38	37	38
	最小值	17	18	18	18
	標準差	3.1	4.5	3.3	4.2
時相 4	平均值	32.7	42.9	24.2	42.1
	最大值	39	44	43	44
	最小值	20	35	20	28
	標準差	4.6	1.4	4.8	2.8
時相 5	平均值	29.7	35.9	27	32.5
	最大值	41	38	43	38
	最小值	19	23	20	18
	標準差	5	3.1	4.4	5.4

6.2.1.3 A3 方案(車輛數-逐週期-延滯)

方案設定如下：

1. 資料輸入：(1)決策瞬間，所有方向的分車道分車種車輛數(以前一週期數據輸入)；(2)時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在週期即將結束時間點，決策下一週期中所有時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

表 6.2.8 A3 方案模擬測試績效

	系統 平均每車停等延滯(s/veh)			系統 通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰(1)	52.4	47.7	-9%	7985	7978	0%
平日下午尖峰(2)	65.1	63.1	-3%	9099	9099	0%
平日下午離峰(3)	45.4	37.0	-19%	6831	6819	0%
假日下午尖峰(2)	52.8	47.0	-11%	7771	7749	0%

表 6.2.9 A3 方案模擬各方向績效變化

	往西方向 每車延滯	往東方向 每車延滯	往北方向 每車延滯	往南方向 每車延滯
情境	與 TOD 差異			
平日上午尖峰	+13.5	-3.8	-30.7	+11.1
平日下午尖峰	-4.8	+22.3	-13.5	-14.5
平日下午離峰	-5.3	-9.4	-5.6	-15.0
假日下午尖峰	-6.2	-7.6	-4.3	-5.3

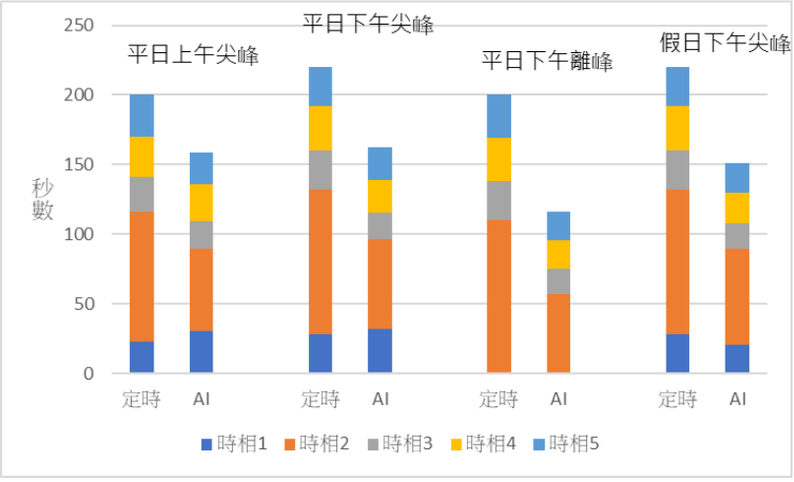

圖 6.2.6. A1 方案平均時相長度

表 6.2.10 A3 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	158.8	162.8	116.3	151.1
	最大值	211	197	139	200
	最小值	129	135	114	130
	標準差	20.4	12	4.3	11.9
時相 1	平均值	30.7	31.6	-	20.8
	最大值	31	39	-	39

	最小值	22	17	-	17
	標準差	1	8.2	-	3.8
時相 2	平均值	59.1	64.9	57.1	68.5
	最大值	83	95	81	98
	最小值	50	56	56	56
	標準差	6.9	6	3	7.6
時相 3	平均值	19.7	18.8	18	18.4
	最大值	33	26	21	28
	最小值	17	18	18	18
	標準差	3.1	1.4	0.2	1
時相 4	平均值	26.7	23.5	20.3	22.1
	最大值	39	41	29	37
	最小值	16	20	20	20
	標準差	8.9	3.4	0.9	2.9
時相 5	平均值	22.6	23.9	20.9	21.3
	最大值	33	35	28	33
	最小值	19	18	20	18
	標準差	3.1	3.5	1.7	3.1

6.2.1.4 A4 方案(車輛數-逐時相-通過量)

方案設定如下：

1. 資料輸入：(1)決策瞬間，所有方向的分車道分車種車輛數；(2)時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總通過量最大

表 6.2.11 A4 方案模擬測試績效

	系統 平均每車停等延滯(s/veh)			系統 通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰(1)	52.4	47.3	-10%	7985	7967	0%
平日下午尖峰(2)	65.1	56.4	-13%	9099	9114	0%
平日下午離峰(3)	45.4	37.4	-17%	6831	6819	0%
假日下午尖峰(2)	52.8	37.6	-29%	7771	7759	0%

表 6.2.12 A4 方案模擬各方向績效變化

	往西方向 每車延滯	往東方向 每車延滯	往北方向 每車延滯	往南方向 每車延滯
情境	與 TOD 差異			
平日上午尖峰	+14.2	-3.2	-28.5	+4.1
平日下午尖峰	-4.3	+24.3	-17.0	-44.8
平日下午離峰	-4.7	-9.1	-3.8	-15.4
假日下午尖峰	-6.1	-6.6	-15.5	-44.2

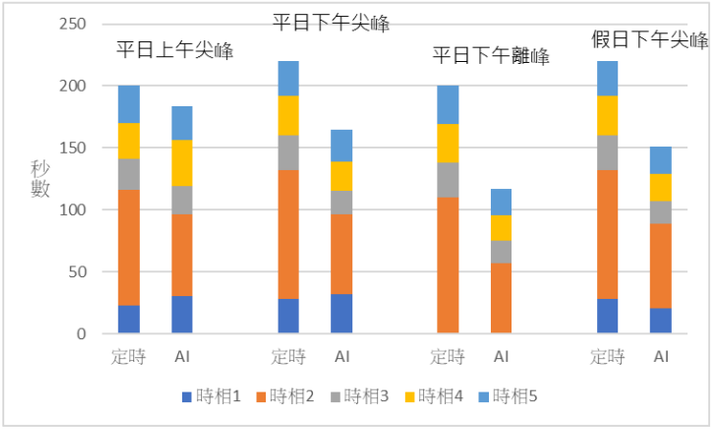

圖 6.2.7 A4 方案平均時相長度

表 6.2.13 A4 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	183.6	164.7	116.6	151.3
	最大值	222	197	146	197
	最小值	129	132	114	129
	標準差	14.2	13	4.8	13.7
時相 1	平均值	30.3	31.8	-	20.6
	最大值	31	39	-	39
	最小值	17	17	-	17
	標準差	2	8.4	-	4.4
時相 2	平均值	66.3	64.7	57.3	68.1
	最大值	83	93	88	104
	最小值	51	56	56	56
	標準差	5.8	5.6	3.4	8.1
時相 3	平均值	22.7	18.8	18	18.4
	最大值	33	30	20	24
	最小值	17	18	18	18
	標準差	3.1	1.3	0.2	0.9

時相 4	平均值	37.1	23.4	20.3	21.6
	最大值	39	42	27	33
	最小值	21	20	20	20
	標準差	3.6	3.4	0.9	2.2
時相 5	平均值	27.2	25.9	21.1	22.6
	最大值	41	38	28	36
	最小值	20	18	20	18
	標準差	3.7	4.1	1.9	4.4

6.2.2 臺南市場域績效分析與議題探討

綜整臺南市場域 4 種不同方案的績效表現於表 6.2.14。

表 6.2.14 臺南市場域各方案平均績效一覽

方案	平均系統停等延滯改善幅度
A1(車輛數-逐時相-延滯)	-22%
A2(轉向量-逐時相-延滯)	-12%
A3(車輛數-逐週期-延滯)	-11%
A4(車輛數-逐時相-通過量)	-18%

在臺南場域的訓練成果中，從各方向的績效變化中(表 6.2.3、表 6.2.6、表 6.2.9、表 6.2.12)可以發現到，目前現行的號誌時制對於台 86 東西向的綠燈秒數是較為寬裕的，這點從 4.2.1 節的交通調查中也顯示相同的現象。而在 RL 以全域績效最佳的目標下，所有方案都選擇略為犧牲東西向的績效，以換取大幅提升南北向的績效，而這樣的交換從全域的角度來看確實是績效有所改善。上述的訓練成果固然是在所有方向的重要性相等的狀況下，RL 客觀的計算結果，然而實務上管理單位很可能存在有特殊考量，例如盡可能減少發生國道下匝道回堵的機率，才因此刻意將現場時制調整為特別偏向東西向的績效優先。關於這點，RL 方法是可以透過設定不同方向、甚至是不同轉向的權重數值，以符合管理單位的實務期待，惟在本案中暫不討論權重值的設定議題。

在 A1 與 A2 方案的比較上，唯一的差異在於輸入交通資訊的部分，A1 為偵測範圍即時分車道與分車種車輛數；A2 為前一週期的分車種轉向交通量。因此在此議題上可以視為是「路段密度」與「路口流量」兩項傳統的交通參數中，何者對於 RL 訓練上更能夠掌握交通現況的比較。兩方案的績效比較整理於表 6.2.15。模擬結果顯示以即時分車道分車種車輛數做為交通資訊輸入 RL 的成效是比以轉向交通量做為交通資訊輸入 RL

的成效更為突出。

表 6.2.12 A1 vs A2 模擬績效比較

方案	A1(車輛數)		A2(轉向交通量)	
情境	系統平均每車停等延滯	系統通過 PCU	系統平均每車停等延滯	系統通過 PCU
	與 TOD 差異百分比		與 TOD 差異百分比	
平日上午尖峰	-21%	0%	-13%	0%
平日下午尖峰	-17%	0%	-5%	-1%
平日下午離峰	-24%	0%	-18%	0%
假日下午尖峰	-26%	0%	-10%	0%

在此有兩個觀點可以解釋兩者的差異。首先從交通工程的角度來思考，密度的概念在評估壅塞狀況時是具有單向遞增的特性，意即密度越高直接代表壅塞程度越高；而交通流量在評估壅塞狀況時，並不具有單向遞增的特性，高流量未必代表壅塞程度高。而雖然本場域情境中未有下游回堵的問題，但交通流量在下游回堵時可能會出現無法通過，流量低但壅塞程度高的狀況。這對於 RL 在掌握交通狀態上就會產生誤導，因此倘若僅以流量做為交通狀態的資訊來源，可能並非特別適用於 RL 號誌控制方法。建議可能需要搭配其他資訊讓 RL 能夠正確的評估即時交通狀態才能最大化發揮 RL 的能力。

其次是資料的即時性，車輛數是決策瞬間各方向的即時交通壅塞狀態體現；然而交通量卻是過去一段時間的交通結果，因此在反應決策當下交通狀態的能力上，密度仍然是較為直觀與即時的一項交通資訊。

同樣有關時效性的還有 A1 與 A3 的比較。這兩者的差異在於決策的頻率上，A1 是逐時相進行決策，也就是每當時相即將結束時，讀取即時車輛數資訊，決策下一時相的綠燈秒數；A3 則是每當週期即將結束時，讀取上一週期中各次時相即將開始時的車輛數資訊，在一次性決定下一週期中所有時相的綠燈秒數。兩者在交通資訊上的輸入項目都是車輛數，但時效性上有所差異。兩方案的模擬績效比較整理於表 6.2.16。

表 6.2.16 A1 vs A3 模擬績效比較

方案	A1(逐時相決策)		A3(逐週期決策)	
情境	系統平均每車停等延滯	系統通過 PCU	系統平均每車停等延滯	系統通過 PCU
	與 TOD 差異百分比		與 TOD 差異百分比	

平日上午尖峰	-21%	0%	-9%	0%
平日下午尖峰	-17%	0%	-3%	0%
平日下午離峰	-24%	0%	-19%	0%
假日下午尖峰	-26%	0%	-11%	0%

同樣是以 A1 的成效較 A3 更為突出，其原因如同前一個議題中資料時效性的討論相同，A1 的資料時效性較 A3 更為即時，因此預期也更能夠精準掌握即時交通狀態。另外是逐時相的決策也較逐週期的決策更為靈活，可以更快速的反應交通狀態的變化，因此在績效上也確實取得更好的成果。不過在實務應用上，逐時相的決策對於系統或是通訊的負擔較為沉重，因此若考量可能的實務限制下，逐週期的決策方式也可做為一種可行的替代方案。

最後一項要探討的議題是 A1 vs A4 的結果。兩者的差異在於最佳化的獎勵目標差異，前者為系統總停等延滯最小化；後者是系統總通過量最大化。兩方案的比較成果列於表 6.2.17。在模擬結果中，若是從延滯的角度來評估成效，仍是 A1 方案略佳；而若是以通過量來評估成效，則兩者無明顯差異。RL 方法理論上會針對所設定的獎勵目標方向進行策略的更新，因此結果上應預期 A4 的通過量效果較 A1 更佳，然而在此卻未能體現此一結果。推測可能的原因是在於本場域所選取的交通情境下幾乎沒有發生下游回堵的狀況，亦沒有長時間過飽和的狀況，因此將目標設定為總停等延滯最小化的更新方向基本上與最大化通過量的更新方向是重疊的，所以最後的結果也相當接近。

另外由於雖然模擬分析時段內(2 小時)車輛都能順利通過路口，但中間可能存在短時間的過飽和狀態，在過飽和狀態下兩方案可能會有所差異，因此特別分析了平均每秒通過量的差異分析。從累積通過車輛數來看，例如圖 6.2.8，A4 方案在某些時段是略高於 A1 方案的。而統整所有情境下平均每秒的通過量差異數值，平均每秒 A4 方案較 A1 方案多通過 0.001 輛車，約是每小時多通過 3.6 輛車。此差異甚是微小，較難視為 A4 方案號誌策略優先以通過量為重。建議若是要分析通過量是否適合做為獎勵目標，則應特別挑選過飽和情境或是下游回堵的狀況，兩方案的更新方向才會有更明顯的差異出現。

表 6.2.17 A1 vs A4 模擬績效比較

方案	A1(停等延滯最小)		A4(通過量最大)	
情境	系統平均每車停等延滯	系統通過 PCU	系統平均每車停等延滯	系統通過 PCU
	與 TOD 差異百分比		與 TOD 差異百分比	
平日上午尖峰	-21%	0%	-10%	0%
平日下午尖峰	-17%	0%	-13%	0%
平日下午離峰	-24%	0%	-17%	0%
假日下午尖峰	-26%	0%	-29%	0%

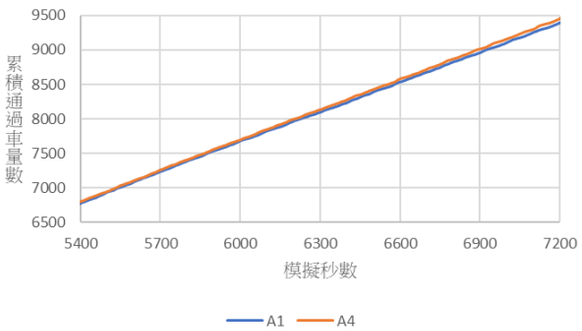

圖 6.2.8 累積通過車輛數(以平日下午尖峰為例)

6.2.3 PPO演算法

除了 DDPG 之外，本計畫嘗試使用 PPO 方法訓練臺南市單一路口的 AI 號誌代理人。PPO 演算法雖同樣使用 Actor-critic 架構，但與 DDPG 主要差異之一是其 Actor 使用隨機決策模型，其輸出為一機率分配的參數而非固定的決策值。本案在臺南市路口的 Actor 與 Critic 設計如圖 6.2.9 與圖 6.2.10，其輸出為一常態分配的平均值與標準差，再從此常態分配中取樣出決策值。代理人是逐分相執行決策，亦即在某分相即將結束時取得即時交通偵測資料與號誌資訊做為 Actor 的輸入值，透過圖 6.2.9 決策模型計算後會輸出一常態分配的平均數與變異數，並從分配中取樣一值做為下一分相的綠燈秒數。

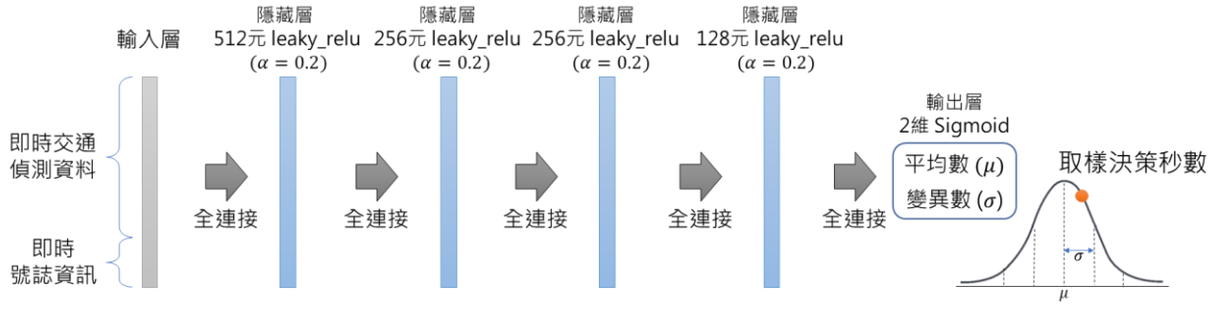

圖 6.2.9 PPO 應用於單一路口 Actor 模型結構

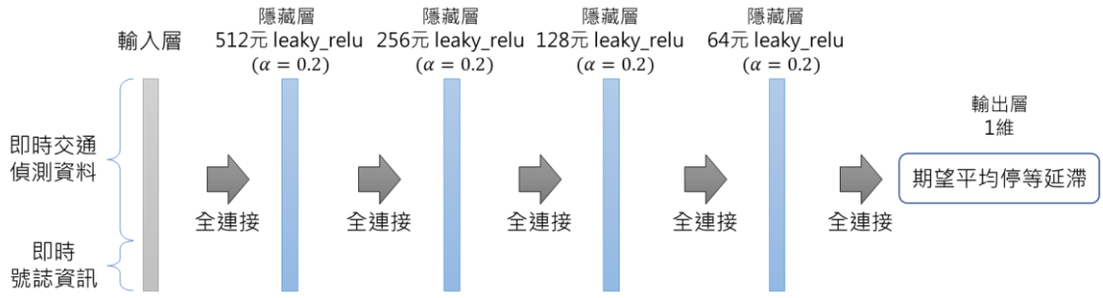

圖 6.2.10 PPO 應用於單一路口 Critic 模型結構

Open AI 團隊稱 PPO 演算法易於使用、好調校且效果優良，並將其做為預設(default)的 RL 演算法[115]。然本計畫在應用 PPO 於臺南單一路口實驗場域過程中仍經歷許多嘗試，茲將測試的幾個主要方向與結果簡要紀錄如下。

一、 隨機分配函數選擇

隨機型的 RL 演算法(如 TRPO、PPO)的 Actor 通常使用常態機率分配函數的形式。然而在適應性號誌問題中，不論是逐時相決策分相秒數，或是逐週期決策週期長度與時比，都有其最大最小值限制。而由於常態分配機率函數的定義域是正負無窮大的範圍，使決策值無法避免地會出現超出可行區間的狀況(如圖 6.2.11)。為此須進行剪裁(clipping)或其他特殊處理，可能會造成估計偏誤(Estimation bias)，進而降低訓練效率甚至使問題難以處理。相關研究[115]提出可改用貝他分配(Beta distribution)，其機率函數定義域是在[0,1]的區間，因此可避開上述的問題。本計畫曾測試使用 Beta、Uniform 等做為 Actor 的決策分配函數，然而並未取得較好的測試效果，且 Beta 分配的參數α、β在適應性號誌問題的意義不若常態分配易理解，因此最後仍使用常態分配做為 Actor 的決策分配函數，透過設定合理的初始值，讓決策值出現在可行範圍，以減少需要作特殊處理的次數。

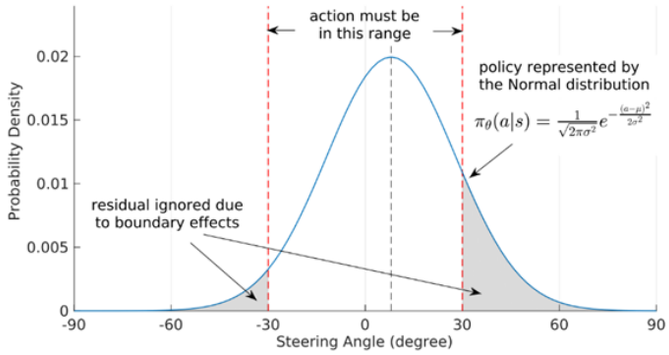

圖 6.2.11 連續型控制且有上下界的問題，決策值只能在某個區間

資料來源：[115]

二、 Actor 與 Critic 設計

本計畫嘗試不同的 DNN 設計方式，例如：減少隱藏層數至 3 層、縮減各層神經元數目至 128 或 64 等等，但並未觀察到對訓練結果有顯著影響，最後使用 512、256、256、128 的隱藏層設計(如圖 6.2.9)。另外也嘗試過不同的激活函數，如 Sigmoid、TanH、SoftPlus、ReLU 等，最後使用 Leaky Relu 作各隱藏層的激活函數，在輸出層則是使用 Sigmoid 函數，確保輸出值在[0,1]之間，最後將輸出值進行線性轉換，確保平均值與變異數產生在合理的區間內。

三、 狀態、決策、獎勵設計與正規化

三者的設計是應用 RL 方法能否成功的重要因素之一，PPO 在臺南市場域的設定如下：

1. 狀態：(1)決策瞬間，前一週期於該時相的轉向交通量(分車種)除以前一次該組時相之綠燈秒；數(2)時相指示，以獨熱編碼(One Hot Encoder)
2. 決策：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵：模擬路網平均停等延滯最小

上述為最終的設計方式，測試過程中曾嘗試過其它的設定，例如僅使用該時相轉向交通量(未除以上一次該時相的綠燈秒數)做為狀態。但此設計可能讓代理人在遇到低流量狀態時，無法辨別是需求量低、還是路口壅塞、亦或是綠燈秒數過短所造成的結果。而將轉向交通量除以綠燈秒數後，意義則為每秒綠燈通過的車輛數，此值的高低可對應到綠燈的使用效率，應能讓代理人感知到分相秒數的控制對於車流運作與整體路網績效的關聯。另外，本計畫曾測試過對狀態和獎勵值作一般化，但並未取得顯著的表現，因此最終並未對二者進行一般化處理。

PPO 在臺南市單一路口的測試績效如表 6.2.18，在平日下午的尖離峰都分別減少 23%與 32%的平均停等延滯，且提升約 2%系統通過量。圖 6.2.9 與圖 6.2.14 分別為代理人在尖離峰情境訓練過程中的績效變化，約莫 400 回合的訓練後，代理人的績效表現便超越固定時制。而從圖 6.2.13 與圖 6.2.15 中可看出代理人所決策的常態分配參數(平均值與標準差)的變化趨勢，最終趨向平坦收斂。此結果說明 RL 是一般化的最佳化算法框架，本質上很適用於求解適應性號誌的問題，即便替換不同的核心算法，仍可達到很好的表現效果。

表 6.2.18 PPO 模擬績效比較

	系統平均每車停等延滯(s/veh)			系統通過車輛數(veh)		
	定時	AI	百分比	定時	AI	百分比
平日下午尖峰	39.4	30.2	-23.4%	9339.1	9506.1	1.8%
平日下午離峰	30.2	20.7	-31.6%	6694.1	6813.8	1.8%

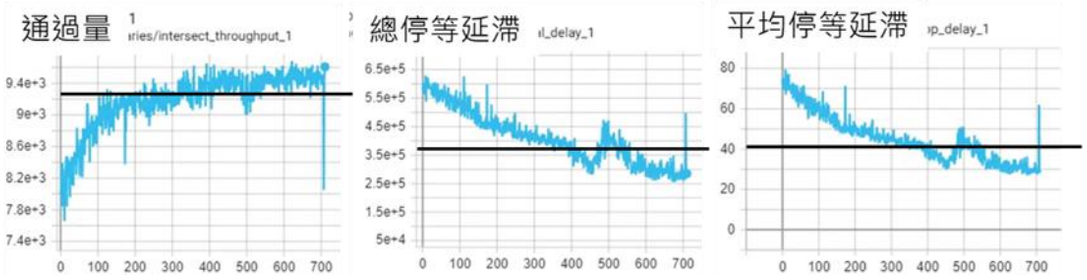

圖 6.2.12 PPO 訓練過程績效變化-平日下午尖峰

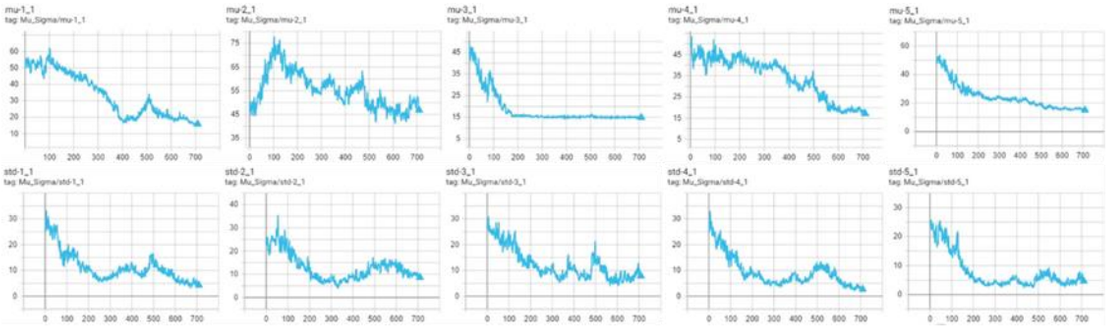

圖 6.2.13 PPO 訓練過程的常態分配參數變化-平日下午尖峰

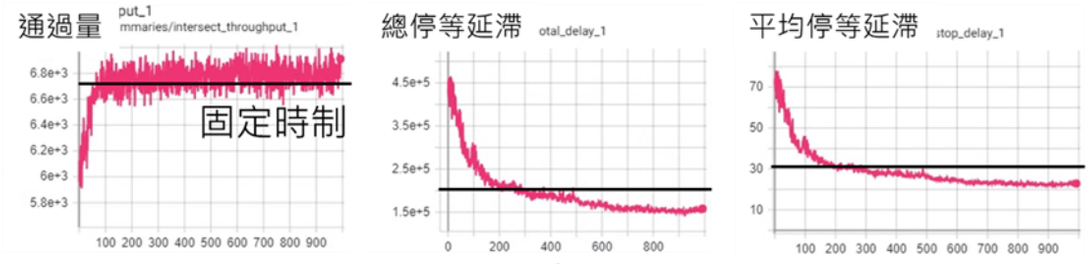

圖 6.2.14 PPO 訓練過程績效變化-平日下午離峰

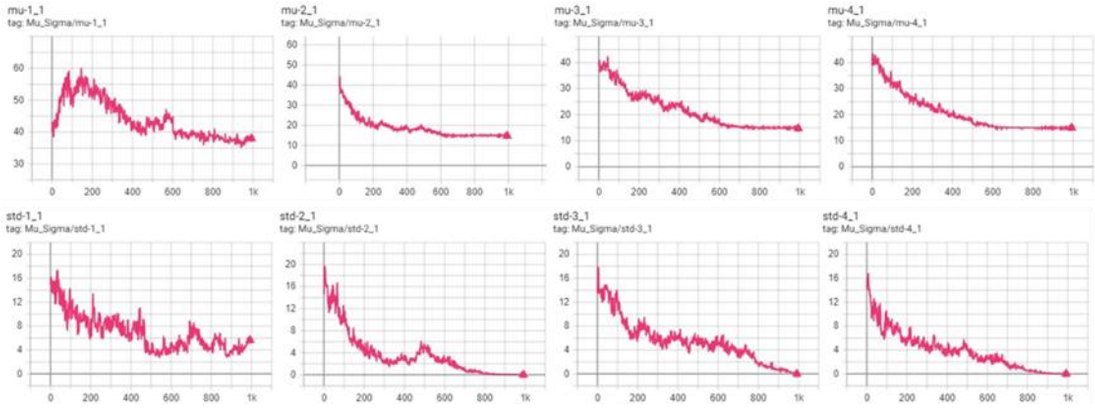

圖 6.2.15 PPO 訓練過程的常態分配參數變化-平日下午離峰

以上測試成果顯示 PPO 在臺南市場域單一路口的表現良好。PPO 是 OpenAI 的預設演算法，其透過調整目標式讓新舊策略不至於差異過大，並應用 importance sampling 技術提升樣本使用率。其隨機性的決策模型在未來發展上應較有一般性，而 DDPG 的確定性決策模型就實務單位而言較易理解與掌握。因此建議未來在場域建置上使用 DDPG，而研發或新方向探討上可嘗試使用 PPO。建議幾點後續 PPO 可延伸的研究方向如下：

一、 提升訓練速度

PPO 運作是透過和環境互動所蒐集到的軌跡資料去更新 Critic 和 Actor 的參數，更新過並不會儲存該回合的互動軌跡資料。雖使用 importance sampling 技術提升樣本利用率，但仍不如 DQN 或 DDPG 的經驗回放機制。建議未來可將 PPO 擴充為多執行序(Multi-thread)架構，亦即同時開啟多組 Actor 進行模擬作軌跡樣本蒐集，可提升樣本產生速度，有效減少訓練所需時間。

二、 多代理人架構

本案 PPO 僅使用一代理人控制單路口號誌，後續可擴充為多代理人架構，並以幹道型或網格型的路網作模擬場域進行開發與測試。

三、 其它決策機制

本案 PPO 的決策機制是逐時相決定下個分相的秒數，而實務上可能有不同偏好，例如：逐週期或數個週期作一次週期與時比的調整；或是週期固定，僅改變時比等等。建議後續可針對不同決策機制作 PPO 的開發訓練，以滿足實務單位需求。

6.3 幹道多路口場域(臺北市場域)

在臺北市場域的實驗中，根據 5.2.2 節中的說明共有 4 種不同的設定方案。而在探討這幾種方案的訓練結果前，需先說明套用於本場域的幾項共通設定。在臺北市場域中，控制路口為圖 6.3.1 中的路口 2、3、4 (X2、X3、X4)，同時為了模擬市區幹道連鎖與評估對於周遭交通的影響，控制範圍外相鄰路口亦納入模擬路網當中，而這些鄰近路口(X1、X5、X6、X7)則是依照現場場域既定 TOD 時制輸入模擬設定當中。

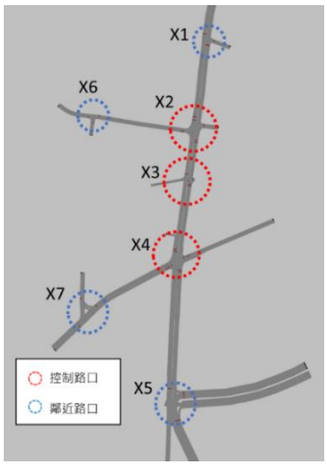

圖 6.3.1 臺北市場域模擬範圍圖

另外在控制路口的時相設定上，雖大部分時段的時相組合皆相同，惟德行路口(X4)在北向有少數時段取消遲閉時相。考量訓練上的通用性，以下所有訓練時相組合皆採如圖 6.3.2 的設定，訓練僅改變每次時相的秒數長度，時相順序並不會變化。

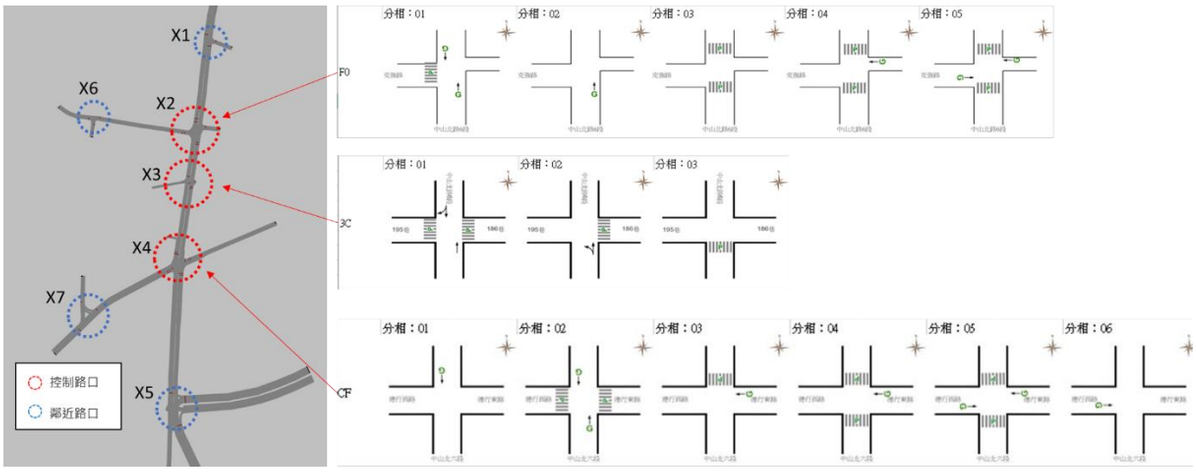

圖 6.3.2 臺北市場域時相組合設定

在本計畫中，將以平日上午尖峰 06:30~09:30、平日下午尖峰 16:00~19:00、平日下午離峰 12:00~15:00、假日下午尖峰 16:00~19:00 等四個不同的交通情境進行訓練與績效測試，每種情境都以不同的亂數種子模擬 10 次，再計算平均的績效數值。比較對象為現場場域既有 TOD 時制計畫，定時時制計畫也以同樣的亂數種子模擬 10 次後計算績效數值。模擬總時長為 3 個小時，其中前 30 分鐘為暖機時間，後 30 分鐘為冷卻時間，即所有績效分析數值僅包含模擬過程中的中間 2 小時。

特別需要說明的是在績效評估上，為了避免發生 RL 只顧及控制範圍內的績效，反而造成控制範圍外的負面衝擊，因此後續的延滯數值分析上都是以全域 7 處路口的平均每車延滯做為評估對象。另外在臺北市場域

考量為幹道特性，因此在數據分析上另外增加旅行時間的計算比較。往南旅行時間的起點設定為通過 X1 停止線起算、終點設定為通過 X5 停止線為止；往北旅行時間的起點設定為通過 X5 停止線起算、終點設定為通過 X1 停止線為止。南北雙向旅行距離皆約為 700 公尺。旅行時間的設定上也同樣考量了避免僅注重控制範圍的偏誤，因此設定上南向旅行時間會將停等路口 5 的效果納入；北向旅行時間會將停等路口 1 的效果納入。

訓練過程中績效將隨著類神經網路逐漸收斂而逐漸的進步，以 B1 為例的訓練績效演進可參考圖 6.3.3。由於績效演進過程需要對訓練過程中各歷代 Actor 進行績效的數值模擬，耗費時間甚鉅，並且基本上各方案的績效演進過程皆類似，因此在臺北市場域即以 B1 做為代表呈現。另外在表 6.3.1 中整理臺北市場域各方案訓練過程所需的時間。

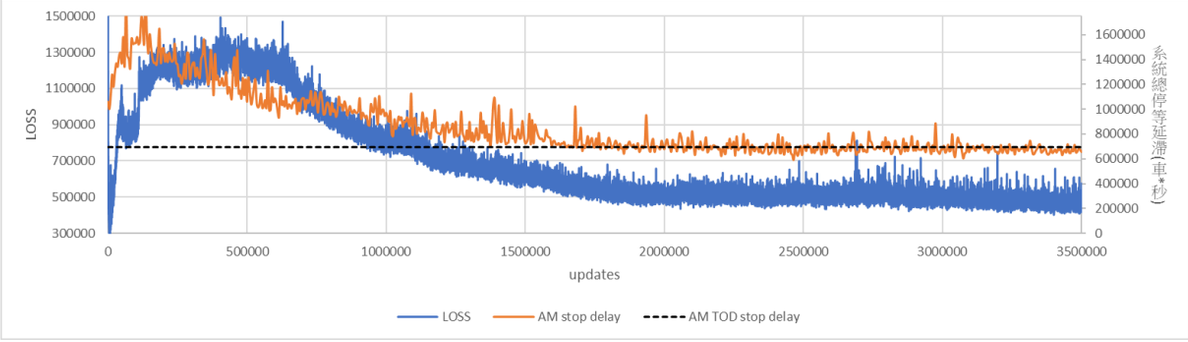

圖 6.3.3 臺北市場域訓練績效演進圖(以 B1 為例)

表 6.3.1 臺北市場域訓練過程時間

方案	更新次數	訓練需時
B1	380 萬次	103 小時
B2	310 萬次	88 小時
B3	305 萬次	85 小時
B4	350 萬次	95 小時

6.3.1 臺北市場域模擬測試數值

6.3.1.1 B1 方案(全資訊)

方案設定如下：

1. 資料輸入：
   - 決策瞬間，所有方向的分車道分車種車輛數(偵測範圍詳見圖 6.3.4)
   - 控制範圍內路口時相指示，以獨熱編碼(One Hot Encoder)
   - 控制範圍外路口時相指示，以獨熱編碼(One Hot Encoder)

- 控制範圍內路口剩餘時相秒數
- 控制範圍外鄰近路口剩餘時相秒數

2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

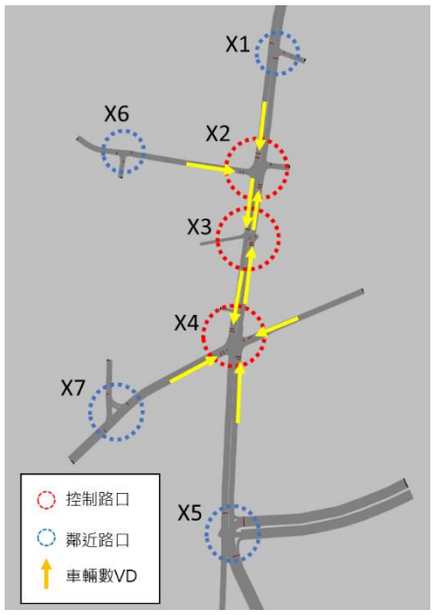

圖 6.3.4 B1 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內)

表 6.3.2 B1 方案模擬測試績效

	系統 平均每車停等延滯(s/veh)			系統 通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	19.4	18.8	-3%	13257	13263	0%
平日下午尖峰	25.0	23.1	-8%	13508	13550	0%
平日下午離峰	20.9	19.0	-9%	10936	11029	1%
假日下午尖峰	22.5	18.3	-19%	11560	11662	1%

表 6.3.3 B1 方案模擬測試旅行時間

	往南旅行時間(秒)			往北旅行時間(秒)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	173	164	-5%	97	86	-11%
平日下午尖峰	185	182	-2%	131	111	-15%
平日下午離峰	155	146	-6%	148	138	-7%
假日下午尖峰	133	138	4%	100	105	5%

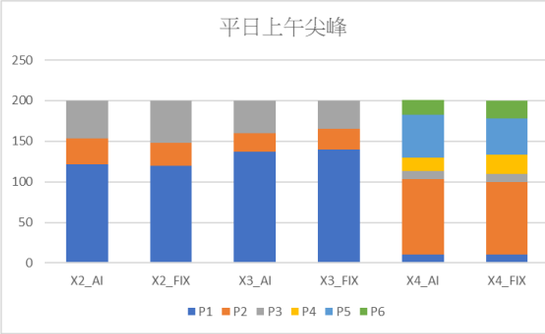

圖 6.3.5 B1 方案平日上午間峰平均時相長度

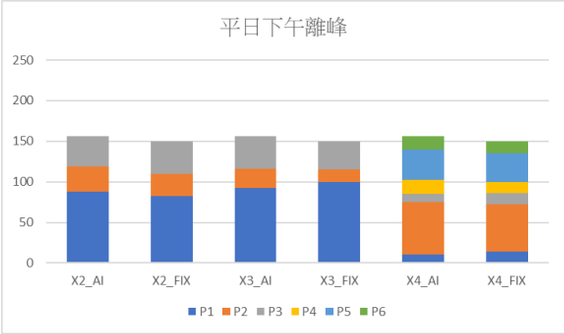

圖 6.3.7 B1 方案平日下午離峰平均時相長度

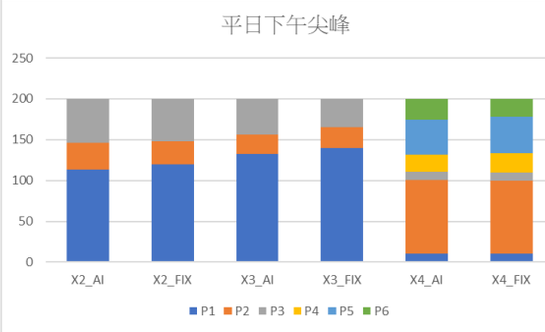

圖 6.3.6 B1 方案平日下午尖峰平均時相長度

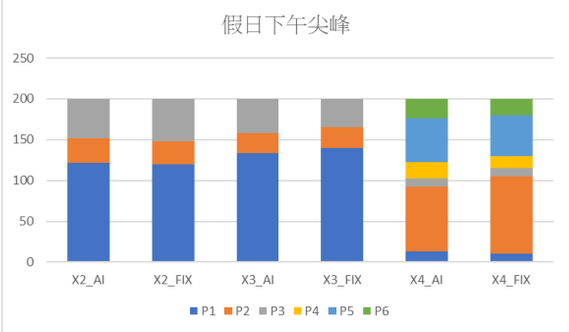

圖 6.3.8 B1 方案假日下午尖峰平均時相長度

表 6.3.4 B1 方案模擬週期統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
X2 週期	平均值	200.3	199.5	156.3	199.8
	最大值	245	246	231	230
	最小值	169	154	138	147
	標準差	11.4	13.3	17.3	13.9
X3 週期	平均值	200.3	199.5	156.5	199.5
	最大值	226	239	225	235
	最小值	172	154	130	159
	標準差	9.3	13	18.8	11.6
X4 週期	平均值	200.9	199.8	156.3	199.9
	最大值	244	233	230	236
	最小值	151	157	135	171
	標準差	13.3	12.3	17.6	16

6.3.1.2 B2 方案(VD 在幹道)

方案設定如下：

1. 資料輸入：
   - 決策瞬間，幹道方向的分車道分車種車輛數(偵測範圍詳見圖

6.3.9)

- 控制範圍內路口時相指示，以獨熱編碼(One Hot Encoder)
- 控制範圍外路口時相指示，以獨熱編碼(One Hot Encoder)
- 控制範圍內路口剩餘時相秒數
- 控制範圍外鄰近路口剩餘時相秒數

2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

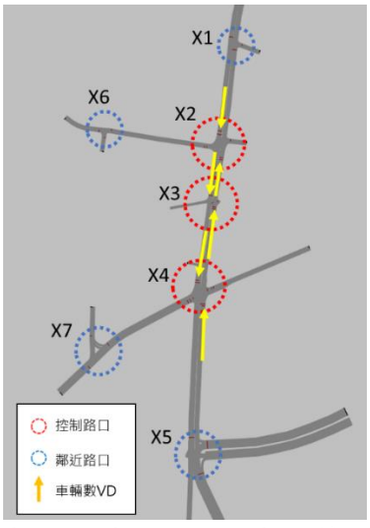

圖 6.3.9 B2 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內)

表 6.3.5 B2 方案模擬測試績效

	系統 平均每車停等延滯(s/veh)			系統 通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	19.4	20.0	3%	13257	13256	0%
平日下午尖峰	25.0	24.8	-1%	13508	13526	0%
平日下午離峰	20.9	20.6	-1%	10936	10912	0%
假日下午尖峰	22.5	20.3	-10%	11560	11407	-1%

表 6.3.6 B2 方案模擬測試旅行時間

	往南旅行時間(秒)			往北旅行時間(秒)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	173	163	-6%	97	88	-9%
平日下午尖峰	185	184	-1%	131	119	-9%
平日下午離峰	155	160	3%	148	118	-20%
假日下午尖峰	133	143	8%	100	104	4%

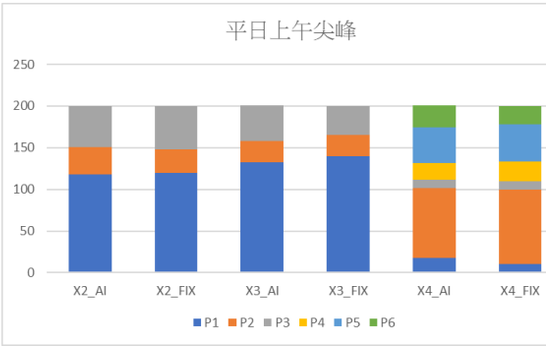

圖 6.3.10 B2 方案平日上午尖峰平均時相長度

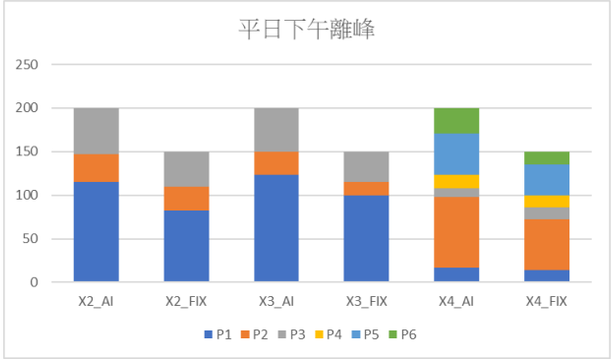

圖 6.3.12 B2 方案平日下午離峰平均時相長度

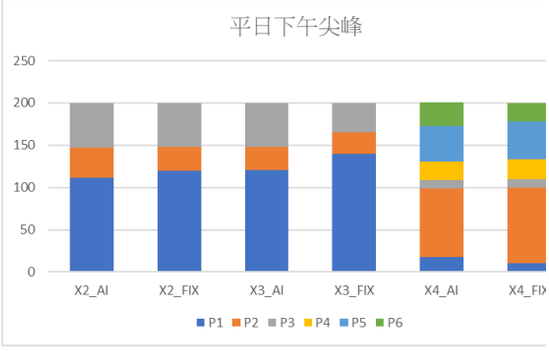

圖 6.3.11 B2 方案平日下午尖峰平均時相長度

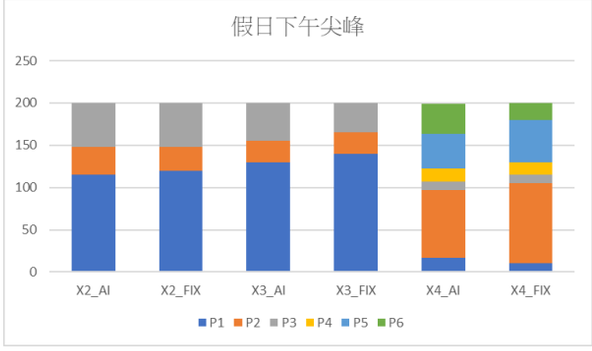

圖 6.3.13 B2 方案假日下午尖峰平均時相長度

表 6.3.7 B2 方案模擬週期統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
X2 週期	平均值	200.4	200.2	199.4	199.5
	最大值	229	231	248	250
	最小值	174	161	140	147
	標準差	10.3	12.4	21.9	21.1
X3 週期	平均值	200.4	200.1	199.7	199.6
	最大值	242	244	249	243
	最小值	146	153	135	135
	標準差	12.6	15.2	23.2	20.5
X4 週期	平均值	200.4	200.2	199.9	199.5
	最大值	238	238	248	249
	最小值	158	168	149	159
	標準差	12.6	13.2	20.2	17.2

6.3.1.3 B3 方案(VD 在支道與部分幹道)

方案設定如下：

1. 資料輸入：

- 決策瞬間，關鍵方向的分車道分車種車輛數(偵測範圍詳見圖 6.3.14)
- 控制範圍內路口時相指示，以獨熱編碼(One Hot Encoder)
- 控制範圍外路口時相指示，以獨熱編碼(One Hot Encoder)
- 控制範圍內路口剩餘時相秒數
- 控制範圍外鄰近路口剩餘時相秒數

2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

關於 B3 方案 VD 佈設位置，設計原因主是在進行 B2 方案訓練的過程當中，注意到本場域在配合上下游號誌幹道連鎖續進的過程中，除路口 4 往南方向以外，其餘各路口南北向路段皆較無車輛會因號誌而遭到攔阻、停等，絕大多數的車輛皆會順利一次性穿越路口 2、3、4，因此認為佈設 VD 在南北向幹道的資訊效益較差。這點也可以從交通調查的資料中再次確認，從 4.3.2 節中的表 4.3.7 中可以觀察到，幹道南北向的停等延滯相較於支道方向都明顯低上不少，說明 VD 佈設於南北向幹道所能夠提供給 RL 的資訊將難以反應真實的交通需求狀況。

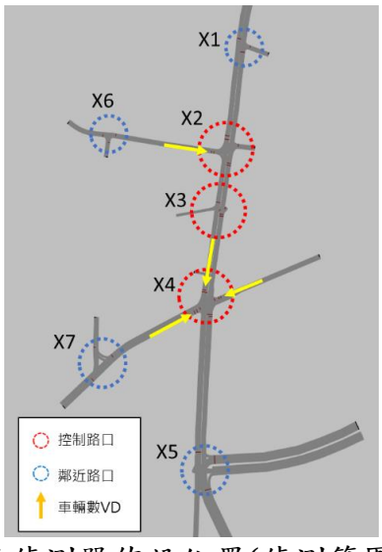

圖 6.3.14 B3 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內)

表 6.3.8 B3 方案模擬測試績效

	系統 平均每車停等延滯(s/veh)			系統 通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	19.4	19.3	-1%	13257	13259	0%

平日下午尖峰	25.0	23.6	-6%	13508	13578	1%
平日下午離峰	20.9	20.7	-1%	10936	11006	1%
假日下午尖峰	22.5	18.5	-18%	11560	11631	1%

表 6.3.9 B3 方案模擬測試旅行時間

	往南旅行時間(秒)			往北旅行時間(秒)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	173	172	-1%	97	95	-2%
平日下午尖峰	185	199	8%	131	154	18%
平日下午離峰	155	145	-6%	148	127	-14%
假日下午尖峰	133	151	14%	100	109	9%

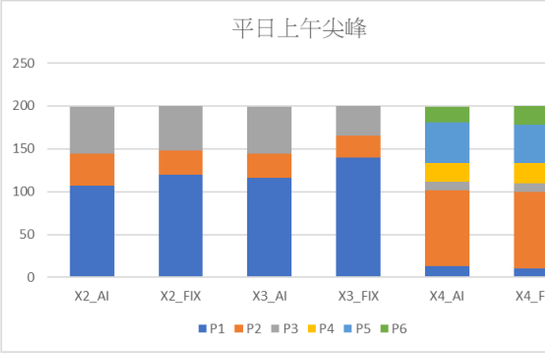

圖 6.3.15 B3 方案平日上午尖峰平均時相長度

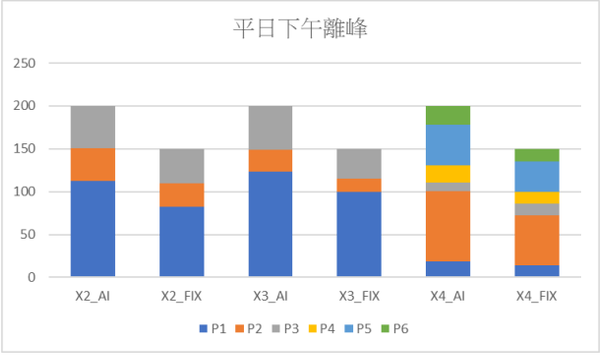

圖 6.3.17 B3 方案平日下午離峰平均時相長度

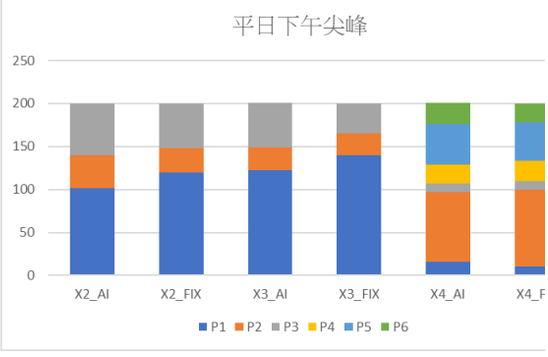

圖 6.3.16 B3 方案平日下午尖峰平均時相長度

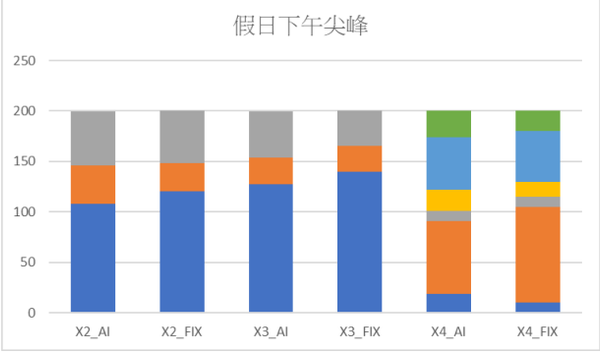

圖 6.3.18 B3 方案假日下午尖峰平均時相長度

表 6.3.10 B3 方案模擬週期統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
X2 週期	平均值	199.4	200.4	199.6	199.7
	最大值	243	256	248	242
	最小值	153	155	151	157
	標準差	12.4	16.6	19.3	17.9

X3 週期	平均值	199.2	200.5	199.5	199.9
	最大值	245	243	245	240
	最小值	158	167	152	158
	標準差	15.1	14.6	17.4	12.9
X4 週期	平均值	199.3	200.4	199.5	199.9
	最大值	227	250	257	231
	最小值	159	159	155	159
	標準差	12.4	15.4	18.1	11.3

6.3.1.4 B4 方案(缺乏鄰近路口資訊)

方案設定如下：

1. 資料輸入：
   - 決策瞬間，所有方向的分車道分車種車輛數(偵測範圍詳見圖 6.3.19)
   - 控制範圍內路口時相指示，以獨熱編碼(One Hot Encoder)
   - 控制範圍內路口剩餘時相秒數
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

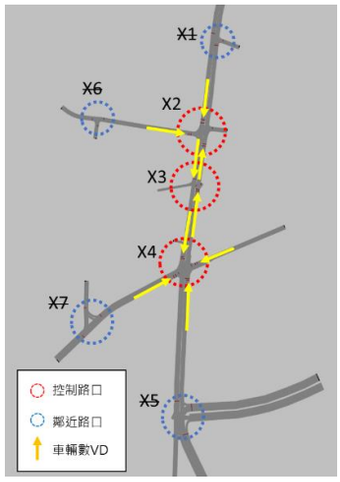

圖 6.3.19 B4 方案車輛數偵測器佈設位置(偵測範圍：停止線起算上游 150 公尺內)

表 6.3.11 B4 方案模擬測試績效

	系統 平均每車停等延滯(s/veh)			系統 通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	19.4	20.1	3%	13257	13233	0%
平日下午尖峰	25.0	24.1	-3%	13508	13554	0%

平日下午離峰	20.9	20.2	-3%	10936	11071	1%
假日下午尖峰	22.5	19.3	-14%	11560	11678	1%

表 6.3.12 B4 方案模擬測試旅行時間

	往南旅行時間(秒)			往北旅行時間(秒)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	173	178	3%	97	113	16%
平日下午尖峰	185	196	6%	131	134	2%
平日下午離峰	155	167	8%	148	125	-16%
假日下午尖峰	133	146	10%	100	123	23%

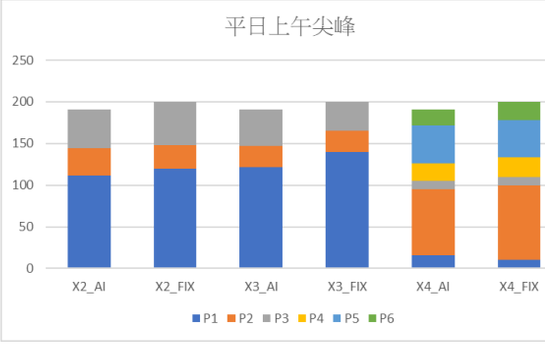

圖 6.3.20 B4 方案平日上午間峰平均時相長度

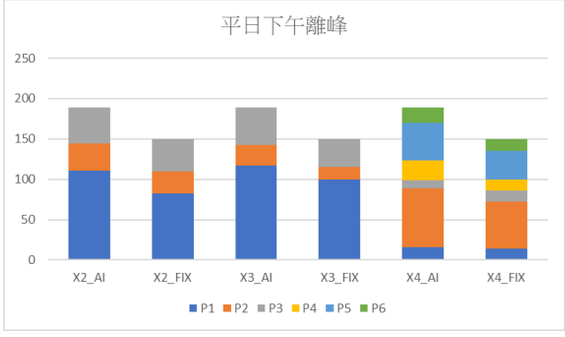

圖 6.3.22 B4 方案平日下午離峰平均時相長度

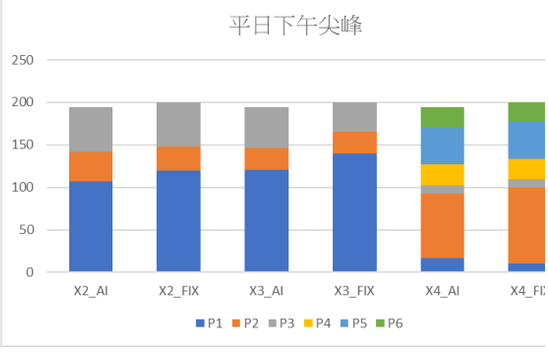

圖 6.3.21 B4 方案平日下午尖峰平均時相長度

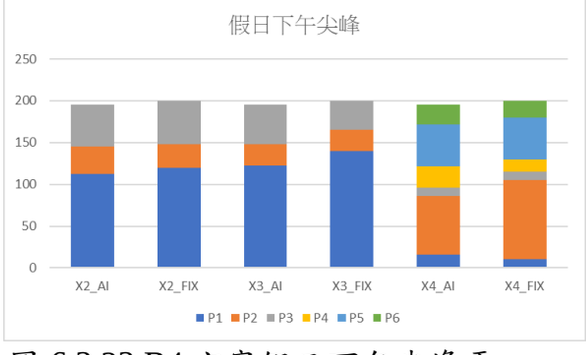

圖 6.3.23 B4 方案假日下午尖峰平均時相長度

表 6.3.13 B4 方案模擬週期統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
X2 週期	平均值	190.9	194.6	189	195
	最大值	242	256	242	245
	最小值	138	149	138	148
	標準差	19.6	21.7	18.4	18.2
X3 週期	平均值	190.8	194.3	189	195.2
	最大值	239	241	233	235
	最小值	132	138	138	134
	標準差	20.6	21.4	19.1	18
X4 週期	平均值	191.2	194.5	189.1	195.2
	最大值	229	249	227	235
	最小值	140	142	143	153
	標準差	15.7	19.3	15.1	14

6.3.2 臺北市場域績效分析與議題探討

綜整臺北市場域 4 種不同方案的績效表現於表 6.3.14。

表 6.3.14 臺北市場域各方案平均績效一覽

方案	平均系統停等延滯改善幅度
B1(全資訊)	-12%
B2(VD 在幹道)	-2%
B3(VD 在支道與部分幹道)	-8%
B4(缺乏鄰近路口資訊)	-4%

從表中可以明確的看出，在所有資訊都提供給 RL 的狀況下能夠最大程度的發揮出 RL 動態號誌控制的能力，B1 方案是嘗試的 4 種方案中績效表現最佳的方案。並且從表 6.3.2 中可以觀察到 4 種交通情境下績效皆能有所改善，代表 RL 確實能夠依照不同的交通需求動態調整控制策略，以獲取最好的區域績效。

不同情境的改善幅度有差距，其主要原因可能在於原先的定時時制對於該情境下的契合程度差異，例如平日上午尖峰的改善幅度明顯相較其他情境較小，其原因可能在於平日上午尖峰原本的定時時制已經趨近完美，即使以動態號誌控制方法亦難以取得大幅度的績效改善；而相比之下，假日下午尖峰明顯的在原本定時時制的控制之下，並非最佳的秒數配置，因此可以取得非常大幅度的績效改善。

而從表 6.3.3 的旅行時間分析中也可以觀察到，大部分情境下南北向的旅行時間都能有減少，或持平的表現。由於旅行時間的起訖點是從路口 1 到路口 5，意即需要配合鄰近路口的號誌，製造幹道連鎖的效果，才能獲得旅行時間改善。因此從旅行時間分析上可以說明 RL 號誌是具備有幹道連鎖、綠寬帶續進的能力。更進一步，將其中一次模擬過程中的綠燈秒數歷史紀錄繪製成綠寬帶圖如圖 6.24 與圖 6.25 所示。從圖中可以很明顯的看出 3 處控制路口之間能夠互相配合，製造適當時差，產生綠寬帶以獲取區域績效最佳。甚至可以發現每次綠帶的寬度並不一致，這便是動態控制下，根據不同交通狀態動態計算最佳化綠燈秒數的結果，並且在此動態過程中，仍可維持綠寬帶的續進效果。

另外若從圖 6.3.5 至圖 6.3.8 的時相平均長度中可以發現到，除下午離峰之外各情境的平均週期長度皆與原定時時制相當接近。這點也同樣可以做為幹道續進所帶來的一項結果展現。由於距離上下游邊界路口相當近，若未能正確配合鄰近路口的號誌週期，則較難穩定地製造續進綠寬帶，因此最終的 RL 策略顯示配合鄰近路口的週期將會是最佳的作法。

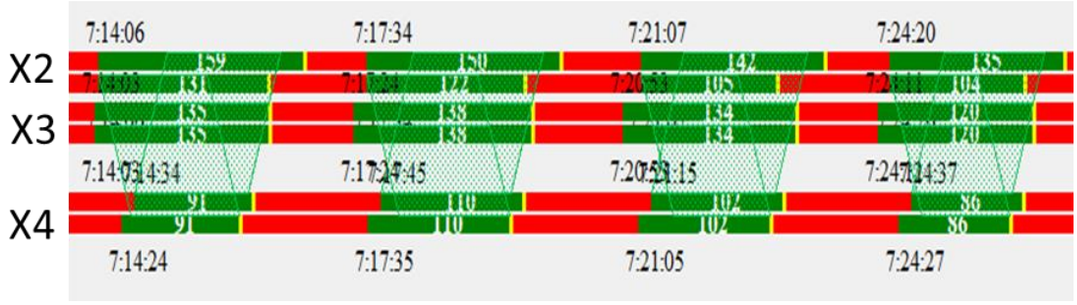

圖 6.3.24 平日上午尖峰綠寬帶圖(以 B1 為例)

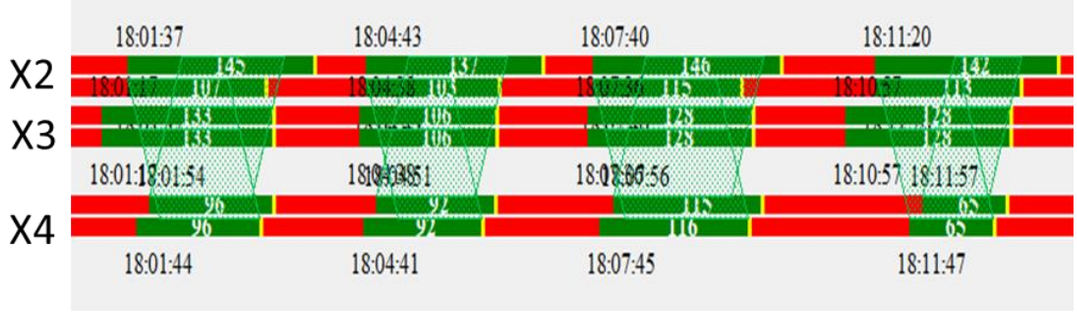

圖 6.3.25 平日下午尖峰綠寬帶圖(以 B1 為例)

更進一步，表 6.3.15 與表 6.3.16 中可以探討 B1 的一些表現特色。為了確保 RL 號誌控制所學出的策略，並非是故意犧牲某些方向的交通需求，將車輛都阻擋於控制範圍之外，因此特別分析整個模擬路網在績效分析範圍的 2 小時內的總通過車輛數，即有多少車輛抵達了目的地。可以發現

到相比定時時制，平日上下午尖峰所服務的車輛數幾乎一致；而在離峰與假日情境則由於號誌秒數的改善甚至服務了更多的車輛數，顯見 RL 號誌控制下並沒有出現故意將車輛阻絕於分析範圍以外的情況出現，因此也更加證實了 RL 號誌控制的合理性與可行性。同時在表 6.3.16 中整理所有路口的績效表現，由於路口 1、5、6、7 並非受到 RL 控制，因此 RL 必須要能夠去配合既有的 TOD 時制計畫，才能避免只有控制範圍內績效提升而控制範圍外嚴重惡化的情況發生。從各路口的表現可以發現 RL 在這點上也做得相當符合期待，只有在路口 1、5 帶來非常小幅度的負面影響，但全體區域是明顯有改善的。

表 6.3.15 B1 方案績效細節

B1(所有資訊)	系統平均每車停等延滯	系統總通過量	往南旅行時間	往北旅行時間
情境	與 TOD 差異百分比			
平日上午尖峰	-3%	0%	-5%	-11%
平日下午尖峰	-8%	0%	-2%	-15%
平日下午離峰	-9%	1%	-6%	-7%
假日下午尖峰	-19%	1%	4%	5%

表 6.3.16 B1 方案所有路口平均每車延滯差異

B1	平均每車停等延滯(秒)
路口	與 TOD 差異
X1	+0.3
X2	-1.2
X3	-0.3
X4	-8.0
X5	+0.2
X6	-2.2
X7	-2.0

而在方案 2 與方案 3 的比較上呈現許多有趣的現象，表 6.3.17 與表 6.3.18 整理出 B2 與 B3 在延滯、旅行時間與各方向的差異。

表 6.3.17 B2 vs B3 方案績效差異

	B2			B3		
項目	系統平均每車停等延滯	往南旅行時間	往北旅行時間	系統平均每車停等延滯	往南旅行時間	往北旅行時間

情境	與 TOD 差異百分比					
平日上午尖峰	3%	-6%	-9%	-1%	-1%	-2%
平日下午尖峰	-1%	-1%	-9%	-6%	8%	18%
平日下午離峰	-1%	3%	-20%	-1%	-6%	-14%
假日下午尖峰	-10%	8%	4%	-18%	14%	9%

表 6.3.18 B2 vs B3 各方向平均延滯改善幅度

	B2(幹道)	B3(支道)
方向	平均每車停等延滯與 TOD 差異(s/veh)	
X2_往北	-2.8	-0.7
X2_往東	+15.0	-10.0
X2_往南	+1.9	+7.3
X3_往北	-0.5	0.9
X3_往南	+2.9	+2.9
X3_往南	+2.9	+2.9
X4_往西	+11.9	-4.5
X4_往北	-2.4	2.0
X4_往東	-20.1	-25.1
X4_往南	-4.0	-3.9

經過整理後，B2 方案在延滯方面，幹道方向平均較 TOD 差異為約-0.8 秒/車；支道方向平均較 TOD 差異為約+2.3 秒/車。B3 方案在延滯方面，幹道方向平均較 TOD 差異為約+1.4 秒/車；支道方向平均較 TOD 差異為約-13.2 秒/車。

在此觀察到 B2 方案最終的策略比較傾向於改善幹道方向；而 B3 方案則傾向改善支道方向，正好與這兩個方案所佈設的 VD 位置相符。關於這項結果，推測是由於偵測器佈設所能觀測到的狀態差異所致。以 B2 來說，雖然在獎勵目標中支道的績效也會同等權重的被納入樣本當中，但以 B2 所能觀測到的狀態轉移過程中，會比較容易判斷因為綠燈秒數分配給幹道方向所帶來的狀態轉移過程與對應獎勵關係，較難判斷綠燈秒數分配給支道所帶來的效果；B3 也是同樣道理，在狀態轉移與獎勵對應關係上，較容易觀察到綠燈秒數分配給支道所帶來的獎勵函數。因此最終造成 B2、B3 對於號誌控制策略的分歧。而如同在 6.3.1.2 節設計 B2 的發想過程所述，認為在此場域中 B3 的 VD 佈設方式更能夠掌握到較多的交通狀態資訊。而最終的測試結果也顯示 B3 的績效在各情境下都較 B2 更為突出，從此結果也可算是間接證實 B3 的設計概念具有某種程度的合理

性。

在過去研究或是案例中對於偵測器的數量經常是非常重視的一項指標。然而從此模擬測試中，B2 使用了 6 支偵測器；B3 使用了 4 支偵測器，結果卻顯示 B3 的績效較 B2 更佳。這點說明了在 RL 控制的概念下，比起偵測器數量，或許佈設的位置反而更為關鍵。而 B3 的成效雖不如 B1 來的好，但所使用的偵測器數量卻僅不到 B1(9 支 VD)的一半，這點說明了在透過專家判斷適當佈設位置後，可以減少偵測器的數量需求同時又保留一定程度的改善成效。

最後一項要探討的議題即為控制範圍外的號誌資訊對於 AI 控制的影響程度。這點可以透過 B1 與 B4 之間的績效比較得出結論，尤其是在旅行時間的結果上更為明顯。以下整理兩方案在旅行時間上的差異對照。

表 6.3.19 B1 vs B4 各方向平均延滯改善幅度

方案	B1(所有資訊)		B4(缺鄰近路口)	
	往北 旅行時間	往南 旅行時間	往北 旅行時間	往南 旅行時間
情境	與 TOD 差異百分比			
平日上午尖峰	-5%	-11%	3%	16%
平日下午尖峰	-2%	-15%	6%	2%
平日下午離峰	-6%	-7%	8%	-16%
假日下午尖峰	4%	5%	10%	23%

可以很明顯的看出來，在幾乎所有情境下，B4 方案在南北雙向的旅行時間都是較原 TOD 時制更為惡化的結果。這點即是由於 B4 缺乏鄰近路口的號誌資訊，導致無法配合幹道連鎖續進所致。從圖 6.3.20 至圖 6.3.23 的平均時相長度堆疊中也可間接印證，若觀察 B1~B3 方案的時相堆疊圖，可以發現到大部分情況下平均的號誌週期都會與原 TOD 相近，即與鄰近路口的號誌週期相近。惟 B4 方案沒有呈現這樣的結果，這也造成 B4 方案在旅行時間的項目上是所有方案中最差的結果。因此透過 B4 方案的實驗可以說明在市區場域中，由於控制路口與鄰近邊界路口距離相當靠近，因此鄰近邊界路口的即時號誌資訊對於 RL 的控制是至關重要的。

6.4 車聯網場域(高雄市場域)

在高雄市場域的實驗中，根據 5.2.3 節中的說明共有 5 種不同的設定方案。而在探討這幾種方案的訓練結果前，需先說明套用於本場域的幾項共通設定。高雄市場域根據現況車輛偵測器佈設位置規劃 RL 輸入資料

的偵測範圍，現況偵測器位置可參考圖 6.4.1，路口端在東西向下匝道、東西向快車道、南北向各有一支偵測器；而在快速道路台 88 線高架段在出口分岔處亦各有一支偵測器，總計共有 8 支偵測器，各偵測器偵測範圍設定為 150 公尺。而場域偵測器輸出項目為各方向推估停等車隊長度，最大停等車隊長度設定為下匝道：400 公尺；東西向快車道：300 公尺；南北向鳳頂路：200 公尺。控制路口的時相配置可參考圖 6.4.2，共有 6 時相，時相配置在所有時段、所有週內日皆相同，訓練僅改變每次時相的秒數長度，時相順序並不會變化。

圖 6.4.1 高雄市場域偵測器佈設位置與範圍

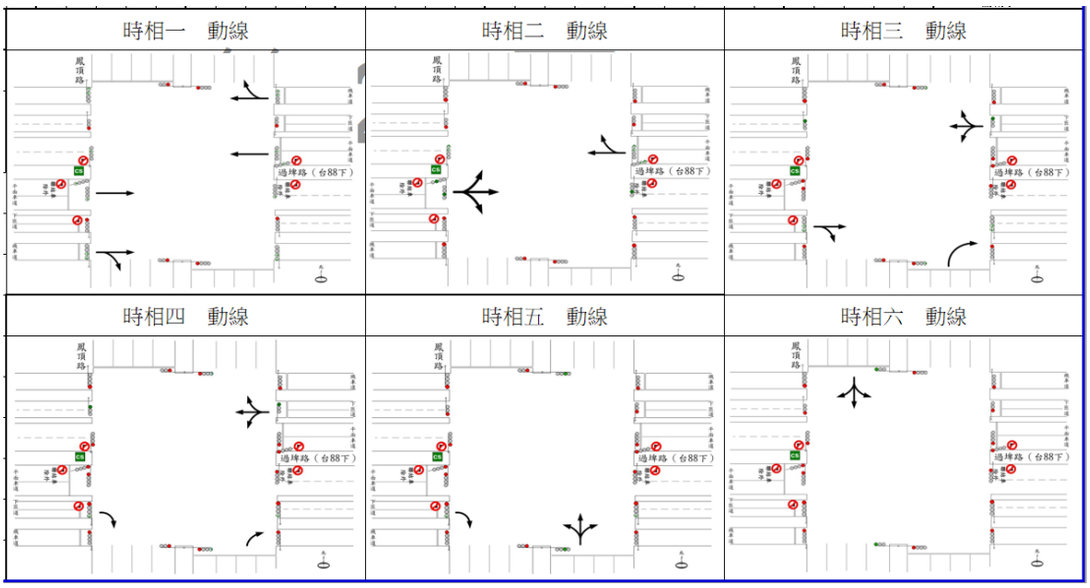

圖 6.4.2 過埤鳳頂號誌時相型態

在本計畫中，將以平日上午尖峰 06:30~09:30、平日下午尖峰 16:00~19:00、平日下午離峰 12:00~15:00、假日下午尖峰 15:00~18:00 等四個不同的交通情境進行訓練(除 C1S 外)與績效測試，每種情境都以不同的亂數種子模擬 10 次，再計算平均的績效數值。比較對象為現場場域既有 TOD 時制計畫，定時時制計畫也以同樣的亂數種子模擬 10 次後計算績效數值。模擬總時長為 3 個小時，其中前 30 分鐘為暖機時間，後 30 分鐘為冷卻時間，即所有績效分析數值僅包含模擬過程中的中間 2 小時。特別需要說明的是在績效評估上，與臺北市場域相同，為了避免發生 RL 只顧及控制範圍內的績效，反而造成控制範圍外的負面衝擊，因此後續的延滯數值分析上都包含鳳頂路南北向上游各延伸一路口，共計 3 處路口的平均每車停等延滯。

訓練過程中績效將隨著類神經網路逐漸收斂而逐漸進步，以 C1 為例的訓練績效演進可參考圖 6.4.3。由於績效演進過程需要對訓練過程中各歷代 Actor 進行績效的數值模擬，耗費時間甚鉅，並且基本上各方案的績效演進過程皆類似，因此在高雄市場域即以 C1 做為代表呈現。另外在表 6.4.1 中整理高雄市場域各方案訓練過程所需的時間。其中可以特別注意到 C2 與 C3 的訓練費時，由於採用了捲積層的類神經網路結構，計算複雜度遽增，導致更新次數與耗費時間的比例與其他方案明顯不同。

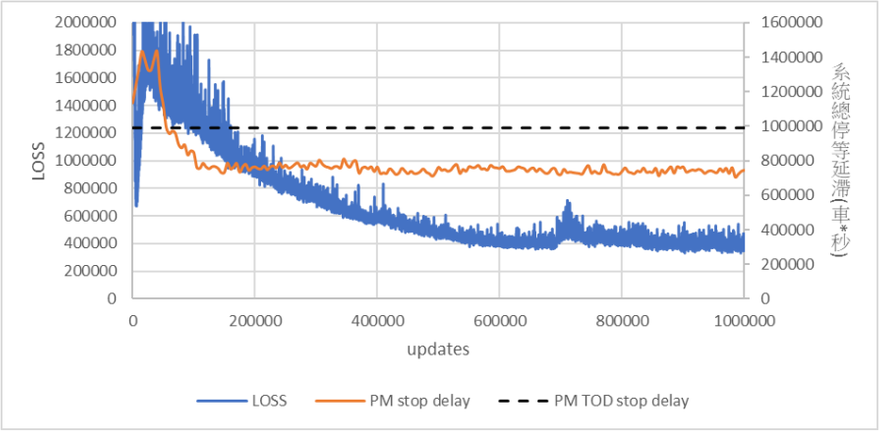

圖 6.4.3 高雄市場域訓練績效演進圖(以 C1 為例)

表 6.4.1 高雄市場域訓練過程所需時間

方案	更新次數	訓練費時
C1	115 萬次	18 小時
C1S	125 萬次	18 小時
C2	32 萬次	110 小時
C3	27 萬次	95 小時

C4	93 萬次	14 小時

6.4.1 高雄市場域模擬測試數值

6.4.1.3 C1 方案

方案設定如下：

1. 資料輸入：
   - 決策瞬間，所有方向的分車道分車種車輛數(高架段 VD 視為獨立方向)
   - 時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

表 6.4.2 C1 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	41.8	30.9	-26%	11904	11886	0%
平日下午尖峰	54.6	36.5	-33%	13051	13150	1%
平日下午離峰	42.1	27.8	-34%	9649	9662	0%
假日下午尖峰	40.7	27.7	-32%	10670	10703	0%

表 6.4.3 C1 方案模擬各方向績效變化

C1	往西慢車道	往西快車道	往西下匝道	往東慢車道	往東快車道	往東下匝道	往北	往南
情境	平均每車停等延滯 與 TOD 差異(秒/車)							
平日上午尖峰	-25	-13	-27	-24	-11	-17	-23	-24
平日下午尖峰	-11	-7	-92	-13	6	-23	-13	-96
平日下午離峰	-14	-9	-121	-13	-9	-17	-15	-16
假日下午尖峰	-24	-12	-66	-24	-11	-17	-22	-26

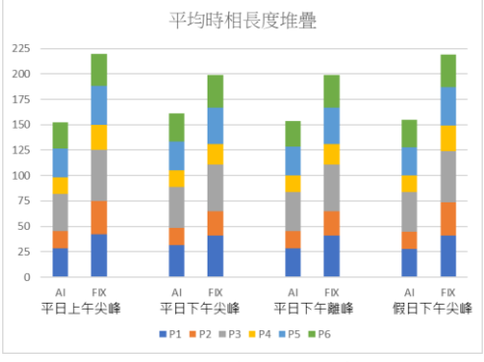

圖 6.4.4 C1 方案平均時相長度

表 6.4.4 C1 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	152.5	161.5	153.5	154.8
	最大值	171	202	175	179
	最小值	146	146	146	146
	標準差	5	8.6	6.6	6.6
時相 1	平均值	28.3	31.3	28.1	28
	最大值	35	44	33	32
	最小值	28	28	28	28
	標準差	1	3.8	0.4	0.3
時相 2	平均值	17.1	17.4	17.1	17
	最大值	21	30	24	18
	最小值	17	17	17	17
	標準差	0.3	1.4	0.5	0
時相 3	平均值	36.7	39.8	38.3	38.8
	最大值	53	55	58	56
	最小值	33	33	33	33
	標準差	4.2	5.3	5.3	5.4
時相 4	平均值	16.2	16.6	16.6	16.1
	最大值	22	24	24	21
	最小值	16	16	16	16
	標準差	0.8	1.2	1.2	0.5
時相 5	平均值	28	28.1	28.3	28
	最大值	32	33	43	30
	最小值	28	28	28	28
	標準差	0.2	0.5	1.1	0.1
時相 6	平均值	26.2	28.3	25.1	26.8
	最大值	38	74	33	38
	最小值	24	24	24	24
	標準差	2.6	4.5	1.7	3.2

6.4.1.2 C1S 方案

方案設定如下：

1. 資料輸入：
   - 決策瞬間，所有方向的分車道分車種車輛數(高架段 VD 視為獨立方向)

- 時相指示，以獨熱編碼(One Hot Encoder)

2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

C1S 方案在輸入資料部分與 C1 完全相同，兩者差異在於訓練過程中，C1 使用了 4 種不同的交通情境(4 套經過完整校估的模擬器參數)產生訓練樣本。而 C1S 則僅使用平日上午尖峰與平日下午尖峰兩套模擬器參數產生樣本。樣本產生的過程會加入隨機變數變動模擬中的設定，如需求量、轉向比例、車種比例等等，但不會變動駕駛行為參數。可以將 C1S 視為僅採用具有較強烈隨機變異的平日上下午尖峰情境樣本進行訓練。

而在績效測試時，除平日上下午尖峰情境外，同樣以經過完整參數校估過程的平日下午離峰與假日下午尖峰情境進行測驗。其目的在於探討僅用部份交通情境樣本訓練出的 RL 是否能夠適用於其他未用於訓練的交通情境當中。

表 6.4.5 C1S 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	41.8	31.7	-24%	11904	11857	0%
平日下午尖峰	54.6	43.9	-20%	13051	13160	1%
平日下午離峰	42.1	31.8	-25%	9649	9645	0%
假日下午尖峰	40.7	29.3	-28%	10670	10711	0%

表 6.4.6 C1S 方案模擬各方向績效變化

C1S	往西慢車道	往西快車道	往西下匝道	往東慢車道	往東快車道	往東下匝道	往北	往南
情境	平均每車停等延滯 與 TOD 差異(秒/車)							
平日上午尖峰	-25	-14	-11	-24	-11	-15	-23	-24
平日下午尖峰	-3	-5	-30	-8	9	-7	-8	-72
平日下午離峰	-14	-10	-69	-12	-12	-12	-13	-13
假日下午尖峰	-25	-14	-44	-24	-13	-15	-23	-21

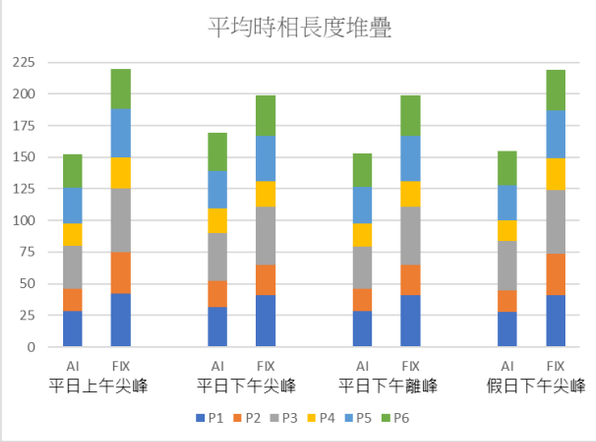

圖 6.4.5 C1S 方案平均時相長度

表 6.4.7 C1S 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	152.6	169.6	155.6	152.9
	最大值	182	266	191	219
	最小值	146	146	146	146
	標準差	6.2	20.8	8.4	7.8
時相 1	平均值	28.4	31.5	29.3	28.2
	最大值	38	51	45	41
	最小值	28	28	28	28
	標準差	1.3	5.9	2.7	1
時相 2	平均值	17.9	20.8	19.3	17.5
	最大值	35	66	42	34
	最小值	17	17	17	17
	標準差	2.1	6.6	3.6	1.7
時相 3	平均值	33.6	37.8	34.8	33.8
	最大值	57	91	54	61
	最小值	33	33	33	33
	標準差	2.2	8.2	3.8	3
時相 4	平均值	17.7	19.4	18.7	18.3
	最大值	34	38	31	33
	最小值	16	16	16	16
	標準差	2.6	4.6	3.2	3.3
時相 5	平均值	28.4	29.4	28.4	28.7
	最大值	40	61	47	47
	最小值	28	28	28	28
	標準差	1.4	3.5	1.6	2

時相 6	平均值	26.6	30.7	25.2	26.4
	最大值	46	75	46	42
	最小值	24	24	24	24
	標準差	3.7	9.6	2.6	3.6

6.4.1.3 C2 方案

方案設定如下：

1. 資料輸入：
   - 決策瞬間，場域內路口半徑 300 公尺範圍內所有聯網車的座標與速度
   - 時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

聯網車佔所有車輛的比例：70%。(此處所指 70%是指聯網車佔大車小車加總的比例數值。所有機車皆不具有聯網車功能) 。在聯網車(CV)資料的處理上，將依照 5.2.3 節中的格位轉換方式處理。而考量到若直接依照路口中心半徑 300 公尺的範圍去框列矩陣，則會有大量並非車道的區域也被框列入內。這些非屬車道的區域佔比甚高，且不會有任何資訊，但卻對訓練的計算、記憶體等等會造成巨大的負擔。因此在處理上會先將半徑範圍內再細切成五個區域，如圖 6.4.6 所示。在完成分割後，個別 CV 車輛會依所在的位置去換算其所在的區域，並且計算在該區域中佔有哪些格位，如圖 6.4.7 所示。而最後可以得到 5 個佔有格位矩陣與 5 個速度格位矩陣，共計 10 個矩陣的向量資料。依照圖 5.2.5 的 Agent 設計，分別將 10 個矩陣按照固定的順序與矩陣形狀輸入至類神經網路即可完成。

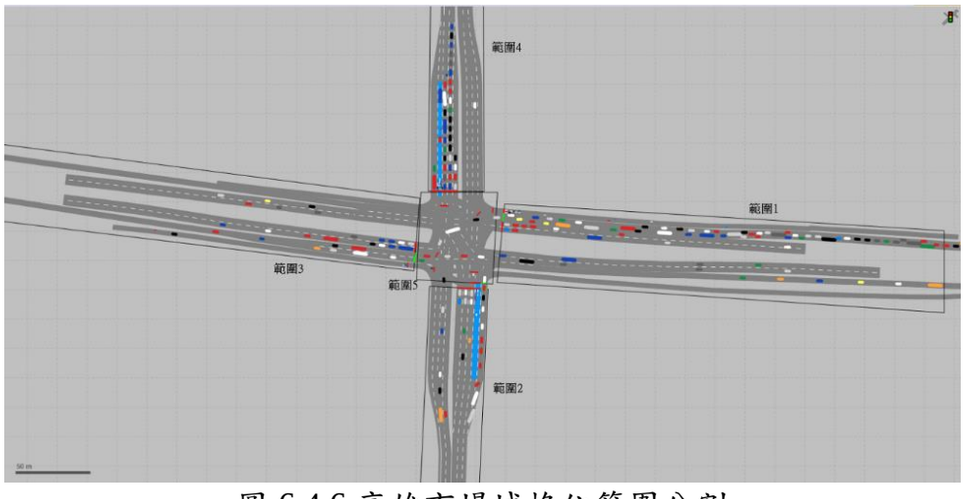

圖 6.4.6 高雄市場域格位範圍分割

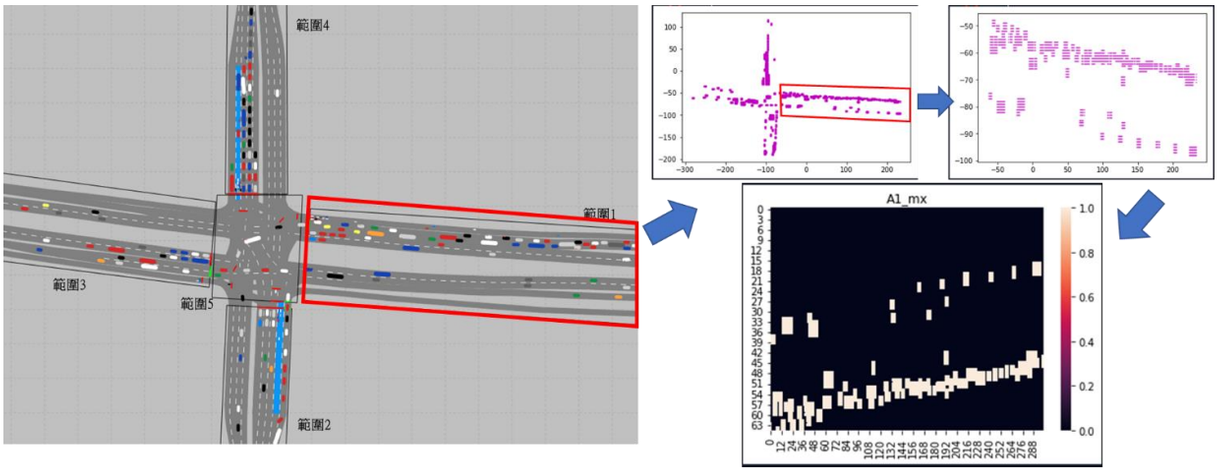

圖 6.4.7 格位轉換過程示意圖

表 6.4.8 C2 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	41.8	33.2	-21%	11904	11911	0%
平日下午尖峰	54.6	40.4	-26%	13051	13176	1%
平日下午離峰	42.1	28.7	-32%	9649	9652	0%
假日下午尖峰	40.7	28.9	-29%	10670	10712	0%

表 6.4.9 C2 方案模擬各方向績效變化

C2	往西慢車道	往西快車道	往西下匝道	往東慢車道	往東快車道	往東下匝道	往北	往南
情境	平均每車停等延滯 與 TOD 差異(秒/車)							
平日上午尖峰	-17	-5	-52	-14	-2	-15	-12	-20
平日下午尖峰	8	10	-169	2	70	-23	0	-92
平日下午離峰	-5	0	-165	-5	3	-17	-7	-1
假日下午尖峰	-18	-6	-82	-17	-5	-16	-14	-23

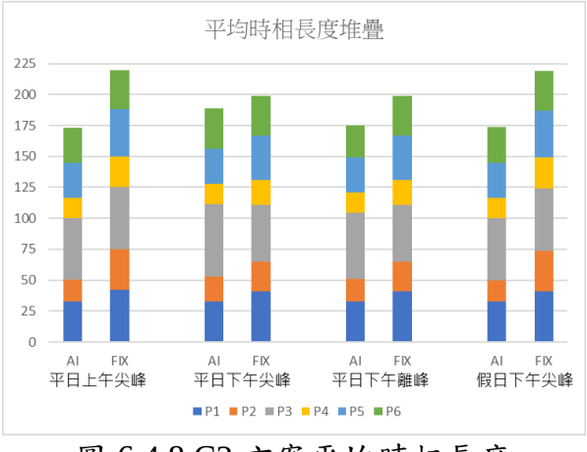

圖 6.4.8 C2 方案平均時相長度

表 6.4.10 C2 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	173.1	188.8	174.9	173.6
	最大值	243	267	278	237
	最小值	149	150	150	150
	標準差	17.9	23.7	23	17.8
時相 1	平均值	32.5	32.8	32.9	32.5
	最大值	34	43	51	35
	最小值	29	29	31	29
	標準差	0.8	1.2	1.5	0.7
時相 2	平均值	18.1	20	18	17.1
	最大值	32	39	64	22
	最小值	17	17	17	17
	標準差	2.7	4.4	3.7	0.5
時相 3	平均值	49.5	58.9	53.5	50.8
	最大值	101	101	101	101
	最小值	33	33	33	33
	標準差	16.3	19.3	19.9	15.3
時相 4	平均值	16.2	16.2	16.4	16.1
	最大值	34	42	34	32
	最小值	16	16	16	16
	標準差	1.4	1.7	2.2	0.8
時相 5	平均值	28.3	28.5	28.3	28.1
	最大值	33	33	41	32
	最小值	28	28	28	28
	標準差	0.8	1	0.9	0.5
時相 6	平均值	28.6	32.5	25.8	28.9
	最大值	47	67	42	43
	最小值	24	24	24	24
	標準差	5	6.4	3.5	5.1

6.4.1.4 C3 方案

方案設定如下：

1. 資料輸入：
   - 決策瞬間，場域內路口半徑 300 公尺範圍內所有聯網車的座標與速度

- 時相指示，以獨熱編碼(One Hot Encoder)

2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等延滯最小

聯網車佔所有車輛的比例：30%。(此處所指 30%是指聯網車佔大車小車加總的比例數值。所有機車皆不具有聯網車功能)。在聯網車資料的處理上，與 C2 方案完全相同。為模擬器中聯網車比例改變為 30%。

表 6.4.11 C3 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	41.8	32.0	-24%	11904	11876	0%
平日下午尖峰	54.6	41.9	-23%	13051	13130	1%
平日下午離峰	42.1	31.6	-25%	9649	9646	0%
假日下午尖峰	40.7	30.4	-25%	10670	10718	0%

表 6.4.12 C3 方案模擬各方向績效變化

C3	往西慢車道	往西快車道	往西下匝道	往東慢車道	往東快車道	往東下匝道	往北	往南
情境	平均每車停等延滯 與 TOD 差異(秒/車)							
平日上午尖峰	-27	-15	-9	-27	-14	-17	-25	-10
平日下午尖峰	-11	-9	14	-15	17	-18	-16	-95
平日下午離峰	-17	-11	-55	-17	-12	-16	-16	-14
假日下午尖峰	-28	-16	-33	-27	-16	-17	-25	-7

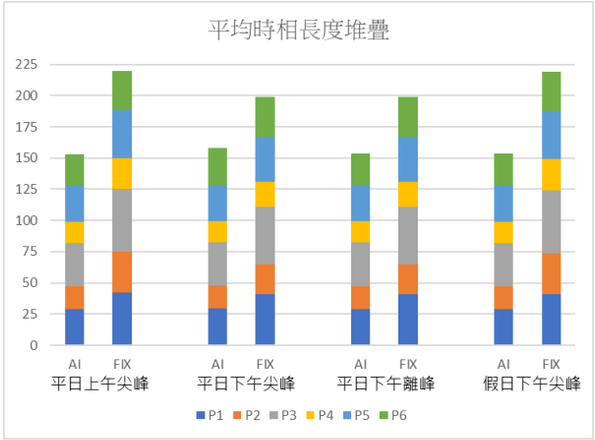

圖 6.4.9 C3 方案平均時相長度

表 6.4.13 C3 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	147.2	151.9	147.6	147.4

	最大值	189	219	179	175
	最小值	146	146	146	146
	標準差	4.2	11.2	4.2	3.9
時相 1	平均值	28	28.6	28	28.1
	最大值	37	51	32	37
	最小值	28	28	28	28
	標準差	0.5	2.8	0.3	0.6
時相 2	平均值	17.1	17.2	17.1	17.1
	最大值	28	30	27	30
	最小值	17	17	17	17
	標準差	0.7	1.1	0.7	0.8
時相 3	平均值	33.4	33.5	34.1	33.5
	最大值	60	57	66	57
	最小值	33	33	33	33
	標準差	1.9	2.5	3.9	2.3
時相 4	平均值	16.1	16.3	16.2	16.1
	最大值	25	30	32	33
	最小值	16	16	16	16
	標準差	0.6	1.5	1.1	0.8
時相 5	平均值	28	28.1	28	28
	最大值	29	52	35	48
	最小值	28	28	28	28
	標準差	0.1	1.1	0.3	0.9
時相 6	平均值	24.6	28.4	24.2	24.6
	最大值	67	85	36	53
	最小值	24	24	24	24
	標準差	3.7	10.2	0.9	2.8

6.6.4.3 C4 方案

方案設定如下：

1. 資料輸入：
   - 決策瞬間，所有方向停等車隊長度(定義為最後一輛停等車距離停止線長度)
   - 時相指示，以獨熱編碼(One Hot Encoder)
2. 輸出格式：在時相即將變換的時間點，決策下一時相的綠燈秒數
3. 獎勵目標：模擬路網系統總停等車隊加總最小

表 6.4.14 C4 方案模擬測試績效

	系統平均每車停等延滯(s/veh)			控制路口平均停等車隊長(m)			系統通過車輛數(pcu)		
	定時	AI	百分比	定時	AI	百分比	定時	AI	百分比
平日上午尖峰	41.8	32.0	-23%	44.7	32.9	-27%	11904	11912	0%
平日下午尖峰	54.6	43.7	-20%	93.6	67.4	-28%	13051	13155	1%
平日下午離峰	42.1	27.3	-35%	56.3	26.6	-56%	9649	9655	0%
假日下午尖峰	40.7	28.6	-30%	45.9	28.7	-37%	10670	10719	0%

(註：停等車隊僅顯示目標路口的原因在於研究關切的重點在於目標路口的停等長度結果，而其他上游路口不宜納入平均值中影響評估結果)

表 6.4.15 C4 方案模擬各方向績效變化(延滯)

C4	往西慢車道	往西快車道	往西下匝道	往東慢車道	往東快車道	往東下匝道	往北	往南
情境	平均每車停等延滯 與 TOD 差異(秒/車)							
平日上午尖峰	-21	-10	-36	-21	-10	-13	-19	-20
平日下午尖峰	11	-1	-92	5	-19	10	8	-73
平日下午離峰	-13	-7	-146	-12	-8	-14	-13	-9
假日下午尖峰	-24	-10	-62	-23	-12	-13	-18	-25

表 6.4.16 C4 方案模擬各方向績效變化(停等車隊長)

C4	往西慢車道	往西快車道	往西下匝道	往東慢車道	往東快車道	往東下匝道	往北	往南
情境	平均停等車隊長度 與 TOD 差異(公尺)							
平日上午尖峰	-3	-5	-52	-7	-5	-7	-12	-2
平日下午尖峰	3	-1	-152	26	1	-25	5	-67
平日下午離峰	-1	-4	-200	-21	-1	-5	-8	0
假日下午尖峰	-3	-27	-91	-13	-3	-7	-9	-6

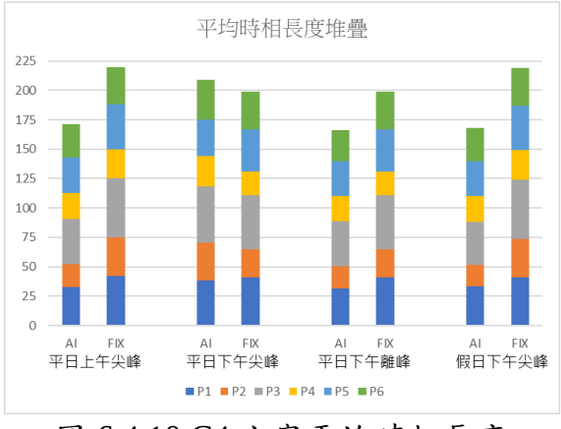

圖 6.4.10 C4 方案平均時相長度

表 6.4.17 C4 方案模擬決策統計表

		平日上午尖峰	平日下午尖峰	平日下午離峰	假日下午尖峰
週期	平均值	165.1	203.1	159.9	162.2
	最大值	228	341	206	198
	最小值	148	149	146	148
	標準差	12.7	34.5	12.2	9.3
時相 1	平均值	32	37.6	30.7	32.2
	最大值	48	51	42	45
	最小值	28	28	28	28
	標準差	3.7	7	2.8	4
時相 2	平均值	18.4	31.1	17.7	17.5
	最大值	47	76	41	25
	最小值	17	17	17	17
	標準差	3.3	13.7	1.4	1
時相 3	平均值	37	46.5	37.1	35.4
	最大值	53	89	58	54
	最小值	33	33	33	33
	標準差	3.4	8.8	4.5	2.7
時相 4	平均值	21.2	25.3	20.3	21
	最大值	38	57	39	36
	最小值	16	16	16	16
	標準差	6.4	7.1	6.5	4.1
時相 5	平均值	29.1	29.6	28.9	28.5
	最大值	33	55	33	36
	最小值	28	28	28	28
	標準差	1	2.2	1	1
時相 6	平均值	27.5	32.9	25.1	27.7
	最大值	40	64	38	51
	最小值	24	24	24	24
	標準差	3.6	7.3	1.8	4.2

6.4.2 高雄市場域績效分析與議題探討

整理高雄市場域 5 種不同方案的績效表現於表 6.4.18。

表 6.4.18 高雄市場域各方案平均績效一覽

方案	平均系統停等延滯改善幅度
C1(車輛數-逐時相-延滯)	-31%

C1S(僅用部份樣本訓練)	-24%
C2(70% CV 環境)	-27%
C3(30% CV 環境)	-24%
C4(車隊長-逐時相-車隊長)	-28%

在高雄市場域中第一個重要的議題即是 C1 與 C1S 之間的比較，即僅用部份交通情境(經過參數校估)的模擬器去產生其他交通情境的樣本做為訓練是否可行。此想法的源起是由於 RL 最終的目標是以一套參數 24 小時/一周 7 天穩定運作，因此必須具備不論遭遇何種交通情境都需要能有應對的能力。然而在人力與資源都有限的情況下，不可能將平日、假日 24 小時的交通情境都分別建模、校估、驗證，尤其是在離峰情境下，模擬器的校估與否似乎重要性就遠不如尖峰。另外 RL 的本質在於學習狀態、決策與獎勵之間的數學關係，在足夠多變異的樣本下，應可期待 RL 所學習的結果是可以被推論與泛用的。因此在本計畫中提出一種觀點是利用已經經過良好校估的駕駛行為參數模擬器，透過改變模擬中非屬駕駛參數的設定，如需求量、轉向比例、車種組成等，隨機的創造各種不同的交通情境，再將這些樣本都用來給 RL 學習使用。如此一來，不但可以節省不同情境的模擬器校估工作時間，也可以透過這種方法讓 RL 大量學習各種可能情境，已達到面對任何情況都有能力應對的效果。

從 C1 與 C1S 的對比(表 6.4.19)，可以發現到 C1S 方案的訓練過程中雖然並未提供平日下午離峰與假日下午尖峰的資料做為訓練資料庫來源，但在測試中 C1S 在平日下午離峰與假日下午尖峰兩項情境的表現仍然非常優秀，僅些微輸給 C1 方案而已。而在兩方案都有資料的平日上下午尖峰表現上，C1 略為優於 C1S 的原因可能在於 C1 的資料非常高度集中在這四種情境，因此對於這四種情境的應對都非常熟練；而 C1S 是透過大量隨機的方式產生不同情境樣本出來，因此在策略的擬定上可能無法像 C1 高度集中於平日上下午尖峰，因此表現不如 C1 方案。不過可以預期 C1S 在面對其他有別於這四種交通情境的狀況下，有可能表現比 C1 更優秀。

表 6.4.19 C1 vs C1S 績效比較

	C1		C1S	
	系統平均 每車停等延滯	系統通過 PCU	系統平均 每車停等延滯	系統通過 PCU
	與 TOD 差異百分比			
平日上午尖峰	-26%	0%	-24%	0%
平日下午尖峰	-33%	1%	-20%	1%

平日下午離峰	-34%	0%	-25%	0%
假日下午尖峰	-32%	0%	-28%	0%

在高雄市場域中第二個重要的議題就是如何使用聯網車的資料與其效果。在 C2 方案中已經非常好的證實個別 CV 離散的資料，經過切割區域、格位轉換、卷積層(CNN)萃取特徵、RL 演算法，這一過程是可行且效果顯著的。而在理論上越高的 CV 滲透率代表著對於交通資訊的掌握程度也越高，這點自然成為探討的議題之一：滲透率是否會影響 RL 的控制。在本計畫中探討了兩種不同的滲透率設定：70%與 30%，希望藉此觀察是否有明顯的績效影響。

從 C2 與 C3 的模擬結果比較來看(表 6.4.20)，可以說兩者的差異並不大，但仍符合滲透率較高的情境下績效也較好的直觀預期。這項結果可能說明在本場域中，滲透率在高於 30%的情況下，對於 RL 來說就足以掌握大部分的場域交通狀況，因此70%與30%雖然數字上差異巨大，但對於最終的績效影響卻並不關鍵。這項結果對於 CV 未來的進程展望是正向的，也就是說可以期待未來 CV 滲透率並不需要到特別高的一個情境，也許就可以達到採用 CV 資料的 RL 號誌控制實作條件。

表 6.4.20 C2 vs C3 績效比較

	C2		C3	
	系統平均每車停等延滯	系統通過 PCU	系統平均每車停等延滯	系統通過 PCU
	與 TOD 差異百分比			
平日上午尖峰	-21%	0%	-24%	0%
平日下午尖峰	-26%	1%	-23%	1%
平日下午離峰	-32%	0%	-25%	0%
假日下午尖峰	-29%	0%	-25%	0%

在高雄市場域中第三個議題是有關於後續年度的應用可能性。由於前述的 C1 方案到 C3 方案在現況的場域上軟硬體都無法直接支援。若是希望在後續計畫中能夠順利上線測試，則需要根據目前已有的軟硬體做規劃設計，因此產生 C4 方案：以停等車隊長度做為偵測輸入的方案。現況高雄市場域已有適應性號誌控制運行，其所採用的交通參數為即時的各方向停等車隊長度，進行動態的綠燈秒數延長策略。因此本計畫即採用相同的資料格式設計 RL 方案，而 C4 的結果顯示以停等車隊長度做為輸入與最佳化目標同樣是可行且有效的。並且與 C1 方案相比，C1 停等延

滯平均改善： -31%；C4 停等延滯平均改善： -28%，兩者的績效差距非常接近，因此可以將 C4 視為可行的 C1 替代實作方案。

6.5 訓練成果小結

整理所有 RL 模擬測試的停等延滯績效改善百分比於表 6.5.1。

表 6.5.1 所有模擬測試績效一覽表

臺南市		臺北市		高雄市	
方案	績效(延滯)	方案	績效(延滯)	方案	績效(延滯)
A1	平均 -26%	B1	平均 -12%	C1	-31%
A2	平均 -12%	B2	平均 -2%	C1S	-24%
A3	平均 -11%	B3	平均 -8%	C2	-27%
A4	平均 -18%	B4	平均 -4%	C3	-24%
PPO	平均 -27%			C4	-28%

透過方案之間的議題探討，概略整理出以下幾點結論。

1. 以車道車輛數(車道密度)做為交通特徵輸入的效果最佳。推論是由於密度概念屬於單向性反應壅塞程度的交通參數，相較於其他交通觀測參數來說更能夠直觀的回饋給與 RL 進行狀態、決策與獎勵之間的函數關係。
2. 決策頻率上的探討中，逐時相的效果較逐週期的效果更好。其原因推論是由於逐週期的資料即時性更佳，同時逐時相的變動應對交通變化的能力更為靈活彈性。
3. 最佳化獎勵目標的設定上，在本次的實驗場域中似乎並沒有明顯的差異，可以說明在臺南市場域中以延滯最小或以通過量最大的策略更新方向是高度重疊的。然而這項結果在其他場域未必適用，需要後續更多的研究探討。
4. 從臺北市場域的實驗中可以發現，比起偵測器數量，佈設的位置似乎更為關鍵。並且在透過專家判斷適當佈設位置後，可以減少偵測器的數量需求同時保留一定程度的改善成效。
5. 在臺北市場域的實驗中顯示，市區場域中由於控制路口與邊界路口距離相當接近，因此邊界路口的即時號誌資訊對於 RL 的控制是至關重要的。
6. 個別聯網車的離散資料，透過本計畫中所提出的格位方式轉化後可轉化為結構化的矩陣資料，再以卷積層方式萃取矩陣上的平面空間分布特徵，能順利地將 CV 資料應用至 RL 號誌控制上。考量到 CV

資料在資料特性上較傳統 VD 仍有不可取代性，以及在滲透率足夠高的情況下具有成本的優勢，因此可以將 CV 資料視為是一項具有潛力的 RL 號誌控制作法。

7. 從高雄市場域的實驗結果中，停等車隊長度做為輸入與獎勵目標的績效良好，並且與績效表現最好的 C1 方案績效相近，在考量現況場域軟硬體限制的情況下，可將 C1S 視為 C1 方案的可行替代方案。

第七章 結論與建議

本計畫回顧與彙整國內外應用車聯網與人工智慧強化學習在號誌控制之應用與演算法，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與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。計畫分別以臺北市「中山北路-德行東路」3個路口幹道、臺南市「台86-19 甲線」路口、高雄市台 88 線鳳山出口(過埤路-鳳頂路)路口)等 3 個縣市政府合作所發展交通模擬環境與人工智慧強化學習號誌控制模型及其訓練。根據不同場域特色，以及強化學習探討的議題項目，總計提出13 種不同的強化學習應用方案。

訓練結果顯示 13 種強化學習方案皆能不同程度的改善現況交通績效，顯示 DDPG 強化學習號誌控制的潛力與可行性。計畫同時研提以 PPO 為核心演算法的做法，並於臺南市實驗場域進行模擬測試，結果顯示不同的強化學習演算法也同樣可以取得績效改善。車聯網資料應用上，研提採用卷積層網路(CNN)結構萃取資料特徵，進而做為強化學習的資料輸入，實驗結果顯示，以車聯網資料做為強化學習號誌控制資料來源的潛力。以下為本計畫提出下列幾點結論與建議。

7.1結論

以下從文獻回顧與方法論、交通調查、交通模擬模型構建、人工智慧強化學習 DDPG 與 PPO 演算法號誌控制應用、訓練模型設計與績效測試等六個面向來說明本案結論。

一、文獻回顧與方法論

1. 本計畫回顧國內外既有的號誌控制方法，以及關於強化學習方法應用於號誌控制上的研究與實務案例，同時也探討目前車聯網技術所能提供資料型態與可能號誌控制應用。
2. 本計畫界定適應性號誌控制問題必須反應即時(real time)交通狀況的變異，此變異的問題本質主要在於「系統狀態的不確定性」與具有時空傳導作用的車流動態性」。多數既有號誌控制方法都致力於構建描述交通狀態的巨觀車流模型，並據以預測系統狀態的演變，進而求解號控模型或依控制邏輯計算而獲得時制決策。然而，這些方法都是確定性的，意即假設「未來情境已知且固定不變」，然而因系統狀態演變具不確定性，這樣的決策績效可能不佳。此外，若這

些方法沒有考量「系統績效」最適化，就可能會得到經驗法則式的局部劣解(inferior solution from rule of thumb)，績效在空間上的呈現有可能產生扭曲。

3. 強化學習結合隨機性(stochastic)微觀車流模擬模型，以機率模型描述車流系統狀態的不確定性，並在這樣的運作情境下構建決策模型、求解決策模型，使所產出的決策模型具備優化系統績效「期望值(expectation)」的能力，突破多數既有號控方法為「確定性」模型或計算方式的限制。

二、交通調查

傳統上在進行交通號誌改善，不論是交通影響評估或是號誌時制重整，皆會針對欲分析的各種交通情境進行完整的交通調查，以利在模擬模型中進行各方案的參數校估。而在本案中由於考量到強化學習是學習環境中的車流模型因果關係與其趨勢，因此嘗試僅以調查部分具有代表性的交通情境做為模擬器參數校估的資料來源。而其他不包含在交通調查時段內的交通情境，則可透過變動已完成校估的模擬器產出資料供強化學習進行訓練與測試。此一作法可以證實完成訓練的強化學習代理人具備面對各種交通情境的能力，同時也讓強化學習的作法更具有實務建置上的成本與時效競爭力。

三、交通模擬模型構建

強化學習方法論克服傳統號誌方法論上的隨機性問題。而為使該特色最大程度發揮與儘可能的貼近實際車流狀況，採用微觀車流模擬模型的作法是最佳的作法。在構建模擬模型的過程中，除按照流成進行相關參數的校估、確保模擬與實際誤差在一定程度之外，亦須確保動態號誌控制的燈號轉換指令是否可行、是否符合現況通訊協定所能滿足，例如：在模擬燈號控制過程中是否正確執行秒數與介間時間的轉換是否正確等；以及在存取即時交通資料上是否正確，例如讀取到的各車道上車輛數是否與模擬畫面中一致等。

模擬環境的正確建構對於強化學習的訓練是相當重要的，不論在重現環境的交通特色上，或燈號指令、資料存取上都需要仔細確認是否有任何錯誤的存在，以避免在花費大量時間完成訓練後才發現資料或指令有問題造成需要重新訓練的時間成本。

四、人工智慧強化學習 DDPG 與 PPO 演算法號誌控制應用

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。本計畫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，代表本計畫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。

五、訓練模型設計

本計畫強化學習方案所探討的狀態、決策、獎勵、演算法列於表 7.1。

表 7.1 本計畫強化學習要素設定列表

狀態	決策	獎勵	演算法
• 分車道分車種車輛數 • 轉向交通量 • 停等車隊長度 • 車輛數偵測器分布位置與數量 • 聯網車座標與速度 • 鄰近路口號誌資訊	• 逐時相決策下一時相長度 • 逐週期決策下一週期所有時相長度	• 系統總停等延滯 • 系統總通過車輛數	• DDPG • PPO

過去在探討適應性控制實作時，其中一項關切的議題即是偵測器數量。偵測器數量直接關係到建置與後續養護的成本。在本計畫中發現到對於強化學習方法來說，比起偵測器數量，佈設的位置似乎更為關鍵。在透過專家判斷適當佈設位置後，可以減少偵測器的數量需求同時保留一定程度的改善成效。並且在市區場域中由於控制路口與邊界路口距離相當接近，因此邊界路口的即時號誌資訊對於強化學習的控制是至關重要的。

六、績效測試

既有號誌控制邏輯、方法或模型常以假設交通系統為確定性方式提出，因此，在建置之前實應先以模擬方式測試其績效，以確保其在具有不確性的情境下是否能如預期的發揮改善的作用及其堅固性。模擬績效測試應以隨機性車流模擬情境為測試基礎，至少應包含平/例假日晨昏尖離峰等 8 種情境測試，且每一情境至少應包含高變異與低變異兩種呈現不確定性的子情境。

另外雖本計畫中尚未達到實測階段，但仍建議實測階段的事前事後實測績效應進行每日 24 小時實測，並持續至少一個月以上，採取動態控制與既有時制(已經時制重整後)隔日互換測試的方式進行，以確保事前事後測試的情境是相近的。本計畫中 13 項模型方案與 PPO 方案的改善績效整理於表 7.2。

表 7.2 模擬測試績效一覽表

臺南市		臺北市		高雄市	
方案	績效(延滯)	方案	績效(延滯)	方案	績效(延滯)
A1	平均 -22%	B1	平均 -12%	C1	-31%
A2	平均 -12%	B2	平均 -2%	C1S	-24%
A3	平均 -11%	B3	平均 -8%	C2	-27%
A4	平均 -18%	B4	平均 -4%	C3	-24%
PPO	平均 -27%			C4	-28%

在強化學習模型設計上，在 13 項強化學習方案的模擬測試結果中，仍是以車道車輛數(車道密度)做為交通特徵輸入的效果最佳。推論是由於密度概念屬於單向性反應壅塞程度的交通參數，相較於其他交通觀測參數來說更能夠直觀的回饋給與強化學習進行狀態、決策與獎勵之間的函數關係。在考量實務偵測器功能後，其他如轉向交通量、停等車隊長度亦可以做為強化學習號誌控制的輸入資料，惟可能需要更多的額外資訊進行輔助判斷才能再進一步提升強化學習控制的績效。

七、車聯網資料號誌控制應用部分，

本計畫透過格位轉化作法，將個別聯網車的離散資料轉化為結構化的強化學習輸入資料來源，並採用卷積層網路(CNN)結構萃取資料特徵，在模擬環境豬的實驗顯示此種作法之可行性。由於連網車資料具有某些偵測器資料較難提供的特徵，因此預期未來以連網車資料做為強化學習號誌控制資料來源仍是相當具有潛力的作法。

7.2 建議

本計畫中人工智慧強化學習號誌控制應用是在既有時段型態與時相組態下，產生多個尖離峰時段的號誌控制強化學習模型及其訓練成果，建議可以探討如何自動依車流情境，來動態產生時相組態及其對應之最適化號誌控制機與內容，以使人工智慧強化學習在號誌控制應用上更為全面。

1. 在號誌控制的最大最小綠燈限制上，最大綠燈秒數的限制主要是不希望支道方向駕駛人因幹道綠燈秒數過長而有不合理的紅燈停等時間，而最小綠燈秒數則是考量行人穿越路口所需最短通過時間而設定。其中最大綠燈秒數的限制，建議可透過將路口各方向的平均停等延滯或服務水準指標納入獎勵函數來放鬆限制，避免 AI RL 在只考慮系統總延滯下，因支道車輛數稀少而將該方向紅燈秒數設計超長，以此來達到減少系統總延滯的目的。而在最小綠燈秒數方面，則是可以透過在路口佈設行人偵測設備，提供欲通過路口的行人數量與類型等資訊，並將行人通過路口的績效納入獎勵函數中讓 AI RL 進行訓練，便有機會解決最小綠燈秒數的限制議題。

2. 針對臺南市場域的交通情境設定上，本計畫以平日與例假日做為目標。而在連接國道關廟交流道處經常實施匝道儀控，將可能發生本路口紓解率下降，致使強化學習效益打折扣。建議後續可以考量匝道儀控率的影響，並納入回堵情況的樣本供強化學習模型進行訓練。

3. 由於臺南市場域鄰近國道三號關廟交流道，在連續假期時可能因高速公路實施較嚴格的匝道儀控限制，導致車流自上匝道入口處回堵至該路口。因此建議可嘗試介接即時的匝道儀控率資訊，並納入模擬環境中讓 AI RL 進行訓練，便可將既有 AI RL 號誌控制邏輯與匝道儀控資訊進行整合，避免因匝道回堵讓該場域 AI RL 號誌控制模型做出台 86 往東方向發生無效綠燈秒數的決策。

4. 人工智慧強化學習在號誌控制領域應用尚屬萌芽期，涉及跨領域整合，且屬於政府單位引用的小眾市場，建議後續可整合既有產學研基礎資源，規劃人力養成、技術研發與示範實作等計畫，發揮人力、研發紮根與實務推廣的成效，創造國內號誌控制理論方法與實務建置有效進步的驅動力。

參考文獻

[1] Sims, A.G., and Dobinson, K.W. (1980). The Sydney Coordinated Adaptive Traffic (SCAT) System Philosophy and Benefits. IEEE Transactions on Vehicular Technology 29, 130-137.

[2] https://www.scats.nsw.gov.au/

[3] The New Generation SCATS 6 Functional Description, https://www.aldridgetrafficcontrollers.com.au/

[4] Stevanovic, A., Kergaye, C., Martin, P.T. (2009). SCOOT and SCATS: A Closer Look into Their Operations. Conference paper, 88th TRB Annual Meeting, Transportation Research Board, Washington D.C., USA.

[5] Robertson, D.I. and Bretherton, R.D. (1991). Optimizing Networks of Traffic Signals in Real Time – The SCOOT Method. IEEE Transactions on Vehicular Technology 40, 11-15.

[6] The SCOOT Urban Traffic Control System，https://ocw.nctu.edu.tw/upload/classbfs121112032755485.pdf

[7] Bretherton, R.D. (1989). SCOOT Urban Traffic Control System – Philosophy and Evaluation. IFAC Symposium on Control, Communications in Transportation, IFAC Proceedings Volume 23(2), 237-239.

[8] SCOOT® - TRL Software，https://trlsoftware.com/products/traffic-control/scoot/

[9] PTV GROUP，https://company.ptvgroup.com/en-us

[10] 葉昭甫、馮輝昇、林大鈞、許添本 (2020)，國一暨台 74 匝道及平面聯絡道號誌協控計畫，土木水利 47(4)，5-19.

[11] 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.

[12] Mirchandani, P. and Head, L., RHODES: A REAL-TIME TRAFFIC SIGNAL CONTROL SYSTEM: ARCHITECTURE, ALGORITHMS, AND ANALYSIS, https://neuro.bstu.by/ai/To-dom/My_research/Papers-0/Trafic-signal-control/TRISTANIII.pdf

[13] RHODES: a real-time traffic adaptive signal control system，https://ocw.nctu.edu.tw/upload/classbfs121111501263203.pdf

[14] Gartner, N. H., OPAC: A Demand-Responsive Strategy for Traffic Signal Control. In Transportation Research Record 906, TRB, National Research Council, Washington, D.C., 1983, pp. 75–81.

[15] Chen, H., S. L. Cohen, N. H. Gartner, and C. C. Liu., Simulation Study of OPAC: A Demand-Responsive Strategy for Traffic Signal Control. Transportation and

Traffic Theory (N. H. Gartner and N. H. M. Wilson, eds.), Elsevier Science, New York, 1987, pp. 233–249.

[16] Nathan H. Gartner, Farhad J. Pooran, and Christina M. Andrews, Optimized Policies for Adaptive Control Strategy in Real-Time Traffic Adaptive Control Systems. In Transportation Research Record 1811, TRB, National Research Council, Washington, D.C., 2002, pp. 148–156.

[17] 張堂賢、張智華(2004)，應用智慧型號誌控制器執行適應性交通控制之研究，運輸計劃季刊 33(1)，203-226.

[18] 林豐福、張開國、張仲杰、何志宏、丁國樑、黃泰林、顏應明、 徐國鈞、魏健宏、林佐鼎、石家豪、蔣封文、吳悅慈、莊捷媚 （2004），「都市交通號誌全動態控制邏輯模式之研究（I）」， MOTC-IOT-92-SBB03，交通部運輸研究所。

[19] 林豐福、張開國、張仲杰、何志宏、石家豪、蔣封文、吳悅慈、 莊捷媚（2005），「都市交通號誌全動態控制邏輯模式之研究 （II）— 單一路口實例研究」，MOTC-IOT-92-SBB03，交通部運 輸研究所。

[20] 陳一昌、張仲杰、何志宏、邱素文、顏應明、丁國樑、魏健宏、 林佐鼎、徐國鈞、石家豪、蔣封文、吳悅慈、莊捷媚（2006）， 「都市交通號誌全動態控制邏輯模式之研究（III）－幹道路口實 例研究」，MOTC-IOT-94-SDB001，交通部運輸研究所。

[21] 陳一昌、張開國、張仲杰、何志宏、邱素文、徐國鈞、石家豪、 蔣封文、吳悅慈、莊捷媚（2007），「都市交通號誌全動態控制 邏輯模式之研究（IV）— 網路路口實例研究」，MOTC-IOT-95- SDB001，交通部運輸研究所。

[22] 胡守任，蔡滌塵（2016），應用格位傳遞與轉向比估計模式於適應性號誌控制邏輯之構建，運輸學刊，第 28 卷第 1 期，第 35-81 頁。

[23] 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.

[24] 曾明德 (2012)，「雷達車輛偵測及衝擊波技術應用於緊鄰路口號誌控制之研究」(指導教授：卓訓榮)，交通大學博士論文。

[25] 曾明德 (2013)，「群組路口即時交通號誌控制方法及其疏解路口車流所需綠燈時間預測方法」，中華民國專利，證書號數：I416439。

[26] 卓訓榮、曾明德等 (2018)，「台灣號誌控制軟體(PaSO)示範驗證與推廣計畫案」，MOTC-STAO-107-01，交通部。

[27] 曾明德、卓訓榮、許哲瑋 (2020)，以路徑為基礎之匝道與幹道協控系統，土木水利 47(4)，51-65.

[28] Sutton, R. S., & Barto, A. G. (2018). Reinforcement learning: An introduction. MIT press.

[29] Watkins, C. J., & Dayan, P. (1992). Q-learning. Machine learning, 8(3), 279-292.

[30] Williams, R. J. (1992). Simple statistical gradient-following algorithms for connectionist reinforcement learning. Machine learning, 8(3), 229-256.

[31] Konda, V. R., and Tsitsiklis, J. N. (2000). Actor-critic algorithms. In Advances in neural information processing systems (pp. 1008-1014).

[32] Farazi, N. P., Zou, B., Ahamed, T., & Barua, L. (2021). Deep reinforcement learning in transportation research: A review. Transportation research interdisciplinary perspectives, 11, 100425.

[33] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. nature, 518(7540), 529-533.

[34] Van Hasselt, H., Guez, A., & Silver, D. (2016). Deep reinforcement learning with double q-learning. In Proceedings of the AAAI conference on artificial intelligence (Vol. 30, No. 1).

[35] Wang, Z., Schaul, T., Hessel, M., Hasselt, H., Lanctot, M., & Freitas, N. (2016). Dueling network architectures for deep reinforcement learning. In International conference on machine learning (pp. 1995-2003). PMLR.

[36] Hester, T., Vecerik, M., Pietquin, O., Lanctot, M., Schaul, T., Piot, B., & Gruslys, A. (2018). Deep q-learning from demonstrations. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 32, No. 1).

[37] Lillicrap, T. P., Hunt, J. J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., & Wierstra, D. (2015). Continuous control with deep reinforcement learning. arXiv preprint arXiv:1509.02971.

[38] David Silver, Guy Lever, Nicolas Heess, Thomas Degris, Daan Wierstra, and Martin Riedmiller. Deterministic policy gradient algorithms. In International Conference on Machine Learning, 2014.

[39] Mnih, V., Badia, A. P., Mirza, M., Graves, A., Lillicrap, T., Harley, T., & Kavukcuoglu, K. (2016). Asynchronous methods for deep reinforcement learning. In International conference on machine learning (pp. 1928-1937). PMLR.

[40] Wu, Y., Mansimov, E., Grosse, R. B., Liao, S., & Ba, J. (2017). Scalable trust-region method for deep reinforcement learning using kronecker-factored approximation. Advances in neural information processing systems, 30.

[41] 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.

[42] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O. (2017). Proximal policy optimization algorithms. arXiv preprint arXiv:1707.06347

[43] https://openai.com/blog/openai-five/

[44] https://spinningup.openai.com/en/latest/algorithms/ppo.html

[45] Abdulhai, B., Pringle, R., & Karakoulas, G. J. (2003). Reinforcement learning for true adaptive traffic signal control. Journal of Transportation Engineering, 129(3), 278-285.

[46] Brys, T., Pham, T. T., & Taylor, M. E. (2014). Distributed learning and multi-objectivity in traffic light control. Connection Science, 26(1), 65-83.

[47] 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.

[48] 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.

[49] 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.

[50] 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.

[51] Genders, W., & Razavi, S. (2016). Using a deep reinforcement learning agent for traffic signal control. arXiv preprint arXiv:1611.01142.

[52] 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).

[53] Choe, C. J., Baek, S., Woon, B., & Kong, S. H. (2018). Deep q learning with LSTM for traffic light control. In 2018 24th Asia-Pacific Conference on Communications (APCC) (pp. 331-336). IEEE.

[54] 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.

[55] 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.

[56] Wei, H., Zheng, G., Yao, H., & Li, Z. (2018). Intellilight: A reinforcement learning approach for intelligent traffic light control. In Proceedings of the 24th

ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (pp. 2496-2505).

[57] 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.

[58] Genders, W., & Razavi, S. (2018). Evaluating reinforcement learning state representations for adaptive traffic signal control. Procedia computer science, 130, 26-33.

[59] 許添本、程楷祐，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] 許添本、蔡沐軒，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。

[61] 胡大瀛、李卓育，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。

[62] 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.

[63] Dresner, K., & Stone, P. (2005). Multiagent traffic management: Opportunities for multiagent learning. In International Workshop on Learning and Adaption in Multi-Agent Systems (pp. 129-138). Springer, Berlin, Heidelberg.

[64] 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.

[65] 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).

[66] Arel, I., Liu, C., Urbanik, T., & Kohls, A. G. (2010). Reinforcement learning-based multi-agent system for network traffic signal control. IET Intelligent Transport Systems, 4(2), 128-135.

[67] 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.

[68] 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.

[69] 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.

[70] Guo, Q., L. Li, and X. Ban. 2019. "Urban traffic signal control with connected and automated vehicles: A survey." Transp. Res. Part C: Emerging Technol. 101: 313–334. https://doi.org/10.1016/j.trc.2019 .01.026.

[71] Lee, J., B. Park, and I. Yun. 2013. "Cumulative travel-time responsive real-time intersection control algorithm in the connected vehicle environment." J. Transp. Eng. 139 (10): 1020–1029. https://doi.org/10.1061 /(ASCE)TE.1943-5436.0000587.

[72] Guo Q., Li L., Ban X.J. "Urban traffic signal control with connected and automated vehicles: A survey." Transp. Res. C, 101 (2019), pp. 313-334.

[73] Eom, M., Kim, BI. The traffic signal control problem for intersections: a review. Eur. Transp. Res. Rev. 12, 50 (2020). https://doi.org/10.1186/s12544-020-00440-8

[74] Jindong Wang, Shengchuan Jiang, Yue Qiu, Yang Zhang, Jianguo Ying, Yuchuan Du, "Traffic Signal Optimization under Connected-Vehicle Environment: An Overview", Journal of Advanced Transportation, vol. 2021, Article ID 3584569, 16 pages, 2021. https://doi.org/10.1155/2021/3584569

[75] Guler, S. I., M. Menendez, and L. Meier. 2014. "Using connected vehicle technology to improve the efficiency of intersections." Transp. Res. Part C: Emerging Technol. 46: 121–131. https://doi.org/10.1016/j.trc .2014.05.008.

[76] Feng, Y., K. L. Head, S. Khoshmagham, and M. Zamanipour. 2015. "A real-time adaptive signal control in a connected vehicle environment." Transp. Res. Part C: Emerging Technol. 55 (Jun): 460–473. https://doi .org/10.1016/j.trc.2015.01.007.

[77] Feng, Y., M. Zamanipour, K. L. Head, and S. Khoshmagham. 2016. "Connected vehicle–based adaptive signal control and applications." Transp. Res. Rec. 2558 (1): 11–19. https://doi.org/10.3141/2558-02.

[78] Talukder, M.A.S., A.D. Lidbe, E.G. Tedla, A.M. Hainen, and T. Atkison. Trajectory-Based 11 Signal Control in Mixed Connected Vehicle Environments. Journal of Transportation 12 Engineering, Part A: Systems, 147(5), p.04021016, 2021.

[79] Charles, J. 2017. Readiness of the road network for connected and autonomous vehicles. London: RAC Foundation.

[80] Yan, L., and H. Shen. 2017. “TOP: Vehicle trajectory based driving speed optimization strategy for travel time minimization and road congestion avoidance.” In Proc., 2016 IEEE 13th Int. Conf. on Mobile Ad Hoc and Sensor Systems, MASS 2016, 281–289. New York: IEEE.

[81] Lin, P., J. Liu, P. J. Jin, and B. Ran. 2017. “Autonomous vehicleintersection coordination method in a connected vehicle environment.” IEEE Intell. Transp. Syst. Mag. 9 (4): 37–47. https://doi.org/10.1109 /MITS.2017.2743167.

[82] U.S. Department of Transportation, “Connected Vehicle Pilot Deployment Program Performance Measurement and Evaluation – Tampa (THEA)”, 2020.

[83] 高雄市政府交通局，”緊急車輛優先通行號誌及路口防碰撞系統試辦計畫委託專業服務案”期末報告，民國 110 年。

[84] 臺南市政府交通局，”109 年臺南市整合型公車優先號誌計畫”期末報告，民國 110 年。

[85] Z. Wang, H. Zhu, Y. Zhou and X. Luo, "Joint Traffic Signal and Connected Vehicle Control in IoV via Deep Reinforcement Learning," 2021 IEEE Wireless Communications and Networking Conference (WCNC), 2021, pp. 1-6, doi: 10.1109/WCNC49053.2021.9417262.

[86] 桃園市政府交通局，「桃園高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫」期末報告書，民國 110 年。

[87] 桃園市政府交通局，「桃園市高鐵聯絡道暨周邊路網 AI 號誌控制示範計畫第二期」期中報告書，民國 111 年。

[88] 高雄市政府交通局，「高雄港聯外交通改善-區域性交控及大貨車行車安全提升計畫」委託專業服務案期末報告書，民國 110 年。

[89] 交通部運輸研究所，「應用人工智慧技術進行交通數據蒐集暨號誌控制之研究」期末報告書，民國 109 年。

[90] Sutton, R. S., McAllester, D. A., Singh, S. P., and Mansour,Y. (1999). Policy gradient methods for reinforcement learning with function approximation. In Neural Information Processing Systems 12, pages 1057–1063.

[91] U.S. Department of Transportation Federal Highway Administration,” Traffic Analysis Toolbox Volume III: Guidelines for Applying Traffic Microsimulation Modeling Software”, 2019 Update to the 2004 Version,2019.

[92] 臺北市交通管制工程處，「107 年度交通改善措施微觀車流模擬成效評估案 」，民國 107 年。

[93] 中華民國運輸學會，交通技術研發與人才培育規劃研究(4/4)，民國 103 年。

[94] 交通部運輸研究所，公路工程設計輔助工具引進與應用之研究，民國 96 年。

[95] 交通部公路總局，台 9 線蘇花改通車後對蘇澳地區交通衝擊影響評估分析，民國 105 年。

[96] 新竹市政府，大新竹運輸走廊整合道路交通與電信資訊應用，民國 107 年。

[97] Siddharth, S. M. P., & Ramadurai, G. (2013). Calibration of VISSIM© for Indian Heterogeneous Traffic Conditions. Procedia - Social and Behavioral Sciences, 104(0), 380-389.

[98] Arlington County Department of Environmental Services Transportation Division, Transportation Engineering & Operations Bureau. “Core of Rosslyn Transportation Study Final Existing Conditions Report”, 2018.

[99] 黃祺芳，”緊急車輛優先通行號誌系統建置場域之研究-以高雄市為例”，國立成功大學交通管理科學系研究所學位論文，民國 109 年。

[100] 吳憲彬，”新型道路交通工程設施設置決策之探討”，國立成功大學交通管理科學系碩士論文，民國 91 年。

[101] Jing Gao, Peng Li, Zhikui Chen, Jianing Zhang; A Survey on Deep Learning for Multimodal Data Fusion. Neural Comput 2020; 32 (5): 829–864

[102] Webster, F.V. (1958),” Traffic Signal Settings”, The Transportation Research Board, No.39, London.

[103] Green D.H. (1967), “Control of oversaturated intersections”, Journal of the Operational Research Society, Vol. 18, Issue 2, pp. 161-173.

[104] D’Ans, G.C. and Gazis, D.C. (1976), “Optimal Control of Oversaturated Store-and-Forward Transportation Networks”, Transportation Science, Vol. 10, Issue 1, pp. 1-19.

[105] U.S Department of Transportation (2008), Federal Highway Administration, Signal 91 timing under saturated conditions,U.S.

[106] Yue Liu and Gang-Len Chang(2010),An arterial signal optimization model for intersections experiencing queue spillback and lane blockage, Transportation Research Part C,pp130-144.

[107] 吳育婷、張智華、劉宜傑(2011)，「多時相適應性號誌控制系統之發展」，中華 技術專題報導，第 93 期，PP71-79。

[108] 高雄市政府交通局，「103 年高屏區域交控整合計畫委託專業服務案」，民國 103 年。

[109] Singh, S. and Kearns, M. (2000) Nash Convergence of Gradient Dynamics in General-Sum Games. Conference on Uncertainty in Arti-ficial Intelligence, 541-548.

[110] Bowling, M. and Veloso, M. (2002) Multiagent Learning Using a Variable Learning Rate. Artificial Intelligence, 136, 215-250.

[111] https://doi.org/10.1016/S0004-3702(02)00121-2

[112] Lanctot, M. et al. A unified game-theoretic approach to multiagent reinforcement learning. Adv. Neural Information Process. Syst. 30, 4190–4203 (2017).

[113] Virginia Transportation Research Cooncil, Methodology for Calibration and Validation of Mesoscopic Traffic Simulation Models,2021.

[114] Transport for London (2021). Traffic Modelling Guidelines, Version 4.0.

[115] Chou, P.-W. et al. Improving Stochastic Policy Gradients in Continuous Control with Deep Reinforcement Learning using the Beta Distribution. Proceedings of the 34th International Conference on Machine Learning, PMLR 70:834-843, 2017.

附件一 期中報告審查意見處理情形表

審查委員	審查意見	審查意見回覆	主辦單位意見
胡大瀛委員	本研究的課題為我國人工智慧車聯網之號誌控制模式探討，期中報告的內容大多著重於深度學習於號誌控制最佳化的討論，針對車聯網的探討，建議於後續進行中強化。建議於第一章增加有關於車聯網的定義與相關的描述，車聯網的分類與應用與未來可能的發展。	遵照辦理，相關說明請參考期末報告書。	同意
	車聯網的發展，近年來有許多的討論，車聯網的技術亦有相關的突破，但是如何充分發揮其功能與應用，仍是 emerging issue，建議可以設定幾種可能情境，談討未來發展。如有些研究者建議，未來在全車聯網環境中，車輛在路口可以主動通訊協調通過的時空，不再仰賴號誌運作。	感謝委員建議，期末階段有關車聯網號誌應用上亦有規劃不同聯網車比例滲透率的情境探討。而由於考量全車輛都備有連網功能的情境在短期內較難實現，因此本案仍是著重於聯網車資訊如何應用於號誌秒數的研究上。此外，本計畫中針對車聯網號誌控制議題界定研究範圍，是藉由 CV 資料回饋給號誌控制邏輯的單向使用，並無再探討號誌控制資訊回饋給車輛的影響。而有關車與車之間的資料通訊及其影響，亦不在本計畫的研究範圍內。	同意
	如同期中報告指出在車聯網發展的過程中，並不是每輛車都具備車聯網的功能，因此討論中應該分成全部都是車聯網的情況與部分車輛為車聯網的情況。	感謝委員建議，期末階段將會探討不同滲透率的情境，相關說明請參考期末報告書。	同意
	AI/車聯網應用於號誌控制模式方法，必須與台灣的交通環境做一個整合，考慮台灣車流的特性才能發揮號誌控制的功能，建議針對台灣車流特性與 AI/車聯網的結合，進一步說明。	感謝委員建議，在模擬器校估階段皆是根據實際交通調查所得的車流資料進行校估車流模擬模型，以平日上午尖峰、平日下午尖峰、平日下午離峰、假日下午尖峰等四種情境校估之駕駛行為參數，其中並包括了大車、小車、機車等根據實際調查之車種組合，相關說明請參考期末報告書。因此可視為符合我國車流特性的模擬環境。另外在車聯網通訊上也參考了目前我國車聯網通訊協定上常見並且成熟的資料格式(車輛位置座標與車輛速度)。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	本研究採用的 DDPG 的訓練演算法為其中一個可能方法，但是深度學習仍有許多的方法，建議加強說明演算法的優缺點與選擇的原因。	感謝委員建議，期末報告中進一步回顧其他 RL 演算法應用於號誌控制的案例，並分析與目前採用之方法差異。相關說明請參考報告書。	同意
	在交通模擬的軟體的選擇，利用 VISSIM 與 SUMO 都是可行的方法，但是這兩套軟體如何應用於車聯網，未來要應用的環境應該要做如何的調整，請加強說明。過去的研究考慮是利用 SUMO 進行車流模擬，利用 NS2/NS3 進行通訊模擬，建議可以參考相關研究。	有關車聯網資料應用部分，本案預計採用常見的車輛座標位置與車輛即時速度做為 RL 輸入資料。此兩種資料在車聯網通訊技術中皆已確認成熟且可行，而在兩套模擬器中亦皆可即時取得所有車輛的座標與速率。 有關 NS2/NS3 等通訊模擬工具主要是用於通訊網路方法上的評估，例如封包遺失率等，並不在本計畫的研究範圍內。	同意
	在場域的規劃與分析中，可以看著規劃團隊花了很多時間與 effort，在台灣尋找適合的場域。針對場域選擇，建議可以依照規劃團隊的說明進行。針對高雄市車聯網，請加強說明 C-V2X 通訊的可能應用。	感謝委員肯定。有關車聯網可能應用說明補充於期末報告書。	同意
	期中報告書 P.101，表 18 所列，表示是有關於車聯網輸入資料，基本上大概是車輛的狀態，但是車聯網是否未來能夠有其他相關的輸入資料，仍應補充說明。	目前團隊所回顧較為主流且成熟的車聯網資料為座標與速度，因此採用此兩項資料做為輸入。	同意
莊東穎委員	可加強說明本案所設置的三處模擬實驗場域與模擬工作和軟體之間進行所謂的績效改善的實際交通資料的關係？	場域車流模擬模型是以實際交通調查車流資料經由校估程序驗證確認其模擬結果與實際運作有足夠的相似程度，因此可視為符合實際車流運作行為的模擬環境。由於無法在實際場域直接進行 MADRL 號誌的學習，因此採用模擬環境做為替代，同時進而實現在微觀車流的隨機性系統情境下(較傳統方法的車流模型更貼近真實車流運作情境)，求解多路口適應性號誌控制問題，突破傳統號控方法求解這個問題的限制。而由於模擬環境已經過誤差驗證，因此可以預期在模擬環境中取得改善的策略，複製到實際場域上亦可取得改善的成果，這也可由團隊在文獻回顧的實作案例中得到印證。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	可加強非監督學習方法的其他類型方法(如: GAN 和自我學習)說明和為何採用深度強化式學習的原因？	感謝委員建議，團隊目前評估對抗生成網路(GAN)主要用途在於生成人類難以分辨人工或是電腦所產生的結果，多應用於圖像、影像、聲音等方面。而 GAN 本質並非處理最佳化問題，因此較不適合應用於號誌控制問題。 深度強化學習(RL)相較於其機器學習方法，更強調「決策」對結果影響的評估以及如何使決策精進的過程，因此採用 RL 做為 AI 號誌控制的核心理論。 GAN 與 RL 除了在處理的問題類型不相同外，另外在訓練過程中亦有一項非常巨大的差異在於 GAN 的訓練必須提供真實的資料，例如人類繪畫的作品、人類創作的音樂等等；而 RL 則不需要真實的資料，僅需要環境提供的資料，例如本研究中的模擬資料。因此在號誌控制問題上，若是需要預先提供號誌控制的策略或結果，顯然不符合本研究中希望透過機器學習自我學習找出最佳化策略的初衷，因此在本研究中並未考慮使用 GAN 做為演算法。	同意
	建議研究團隊主要採用研究方法應該是使用[38]的 DDPG 演算法(2014 年)，建議可以針對為何採用該演算法的原因略作說明。另外近年有許多新強化式學習的演算法，為何不考慮採用，例如：GAN+DRL？	感謝委員建議，有關 GAN 的說明同前述。另有關其他 RL 演算法的回顧與分析與目前採用之方法差異，相關說明請參考期末報告書。	同意
	報告書第四章所提到使用兩個 VISSIM 和 SUMO 模擬器與真實場域獲得的相關實際資料的關係為何？	模擬場域是經過實際交通調查資料校估參數，因此可視為符合實際表現行為的模擬環境。	同意
	可加強提供和聚焦討論臺北市、新北市、臺南市、高雄市實驗場域的整體交通特質差異分析，如車道數量、交通尖峰時間和非交通尖鋒時間的流量差異和平均車速差異等性質分析，以提供 AI 方案做為條件差異的深度討論。	遵照辦理。相關說明請參考期末報告書。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	建議針對本研究僅使用單一獎勵函數的最佳化的正確性和合理性做詳實說明。	遵照辦理。相關說明請參考報告書。	同意
	建議本案針對 RL(強化式學習)中的 State space 宜做較明確的說明?似乎仍是以 VISSIM 和 SUMO 模擬器進行驗證，期待與臺北市、新北市、臺南市、高雄市實驗場域實驗場域資料即時或非即時整合，並有機會及時反饋到真實燈號誌控，進而改善交通之實際驗證工作。	誠如委員所述，本案期待透過模擬器的驗證，確認RL號誌的成效。有關State space的說明於期末報告中各訓練方案中補充說明。相關說明請參考報告書。	同意
吳健生委員	傳統適應性號制控誌在最佳化求解結果會得到一個最終的績效極限，而 AI 方法持續最佳化的過程，是否也有最終績效的極限？	RL 號誌控制本質上仍然屬於適應性號誌控制的定義範疇內，而號誌控制方法在解決壅塞問題上本身就必定存在極限，因此RL 號誌控制亦會有其績效的極限存在。	同意
	第三章所敘述的 AI 方法似乎是通用不同場域，在文獻回顧中實際應用到不同場域時，是否都可取得相同的績效改善程度？	不同交通場域所遇到的壅塞問題面相有所不同，飽和程度也有所不同，因此改善的程度亦會有所不同。	同意
	AI 號誌控制方法是否可以應變特殊事件(例如：車禍)下的即時反應？	目前團隊所提之訓練方法並未針對特殊事件進行訓練，這是由於考量到特殊事件的情況屬於相對稀少樣本，但卻可能嚴重影響訓練的方向，因此暫不考慮納入訓練樣本當中。 而在實務經驗中，程度較輕的車禍(例如僅占用 1 車道)RL 號誌仍可持續運作，並且其反應仍屬合理範圍，其原因推測是RL 號誌將車禍造成壅塞視為一般的壅塞車隊，因此仍會給予更多的綠燈時間。然而由於並未針對特殊事件的訓練，因此並不能保證所有種類的車禍 RL 都可以正確應對，建議實務上仍應在收到通報後轉換為定時時制，並儘速排除事件再切換為AI 號控模式運作，以利加快紓解因事件造成的突發性壅塞。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	在實務應用上，AI 號誌控制的動作(Action)為何？是否會去碰觸到時相順序或時相設計等議題？	經與實務單位討論溝通，考量駕駛人習慣與安全性的原因，採用維持案場既有固定時相順序的作法。因此在本案中將不會針對時相設計或跳過時相的作法進行相關的探討。	同意
	傳統適應性控制在處理幹道多路口時經常會有主控路口與協控路口的做法，在 AI 處理多路口的時候是否也會採用這樣的作法？	多代理人 RL 訓練過程並無主控協控的設定，完全依照資料驅動代理人間彼此協調控制。	同意
	在遴選場域的過程中，是否有評估過所選取的場域現況仍有改善空間？ 例如：避免場域現況已經過於壅塞，難以透過任何號誌方法改善，或是現況完全沒有壅塞議題，無須改善的狀況。	場預評選過程皆與地方政府密切討論，三處場域皆是有壅塞問題存在。而依照過去經驗，即使在過飽和狀態下，RL 號誌控制仍有機會再稍微提升些許的績效，因此預期此三處皆還有改善的空間。	同意
	請在期末階段補充聯網車資料如何應用的詳細說明。	遵照辦理。	同意
	建議本案在期末成果中應根據研究成果與實務經驗，提供若要執行 AI 號誌方法，在硬體端應有那些要求與配套，例如號誌控制器應有那些功能方能配合。	感謝委員建議，期末報告中依本案研究成果與過去實務經驗補充針對硬體套件的需求。相關說明請參考期末報告書第 7 章。	同意
李忠璋委員	本案所選取的臺南市台 86-19 甲線路口，其壅塞問題很大程度是由於國道 3 號關廟交流道上匝道的匝道儀控管制所致。在這種情況下，AI 號誌控制是否仍可適用？	經交通調查顯示，在一般平日尖峰與例假日尖峰時段尚未出現從國道 3 號回堵的狀況發生。本案在本年度將聚焦於一般情境(工作日與例假日)的分析與探討，而有關匝道儀控率對於本案場主要的影響應是在連續假日或是特殊活動情境下，本年度暫不探討儀控率對 RL 號誌的影響程度。	同意
	本案所選取的高雄市台 88 線鳳山出口，主要的壅塞問題在於東西向台 88 線高架車流下匝道需求極大，建議團隊在後續的研究過程需要考慮到主線上的績效。	感謝委員建議，團隊在後續訓練過程中會特別注意下匝道方向的績效表現情況，以避免回堵至主線的狀況發生。	同意
	另有關高雄市台 88 線鳳山出口(即鳳頂-過埤路口)，原已運行車聯網功能之緊急車輛的優先號誌通行。本案預期後續年度實際建置 AI 號誌控制時，在本場域其他車輛未有裝設車聯網車機(OBU)	由於在短年期內聯網車比例達到可供應用的門檻機率較低，因此有關本案場車聯網號誌控制的應用部分仍屬研究性質。而明年度預計實作於高雄案場的 RL 號誌，功能上仍會以整合既有緊急車輛通行優先號	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	的情況下預計如何執行？而原緊急車輛優先通行的功能預計如何整合至本案 AI 號誌控制運作？	誌為主要訴求，並在適當位置增設 VD 以利 RL 號誌運作。	
	文獻回顧中提到 AI 號誌控制的實際案例，這些案例能獲得不錯的績效改善應該在先天條件上有一些特性，即尚有改善空間，因此對於 AI 使用的時機或適用條件是否可能有所建議？	RL 號誌控制方法目前仍仰賴在模擬環境中進行訓練，因此團隊建議較為適用的先決條件為適合建立模擬環境的場域。部分場域由於一些路側活動，例如市場、攤商等，人因隨機性過高，難以在模擬器中還原車流行為，固不適合採用 RL 號誌方法。 此外，針對場域是否仍存在飽和度可供號誌控制方法進行改善，則須視各案場個案分析，較難提出一套通用的適用條件。	同意
	實際建置後偵測器所蒐集到的歷史交通資料，是否可能再做為 AI 訓練的資料來源？	實際上線運作之車輛偵測器所蒐集到的交通資料，可做為模擬器微調的資料來源，除可更進一步精進模擬器與現況的還原程度，亦可為 RL 提供更多不同情境的樣本，使 RL 號誌的績效有持續提升的可能。	同意
	報告書中第五章有關模擬模型驗證的部分，臺北市實驗場域有列出絕對誤差值(MAE)，而其他場域則沒有列出，請說明原因；另在臺北市實驗場域中某些車流方向出現MAE數值低，但MAPE值卻很高的情況，造成這種情況的原因為何？	臺北市場域特別列出 MAE 值的原因是為了說明雖MAPE數值較高但實際誤差是在可接受範圍。而其他場域由於MAPE數值已在合理範圍內，固不特別說明 MAE 數值。 而臺北市場域 MAPE 數值高但 MAE 數值低的原因即出在調查值本身數值較低，導致些微誤差在百分比上被嚴重放大。也因此緣故特別利用 MAE 與 GHE 的分析來說明其誤差實際上對於模擬的結果分析是在可接受的誤差範圍內。	同意
劉瑞麟委員	3.3.2.3 節參數校估部分，本案所用兩個模擬模式，參數使用有分尖離峰？5.2 節有驗證尖峰模式適用性，其參數上下午尖峰使用是否一致？第六章後續工作項目還要進行離峰、假日尖離峰情境校估，請說明未來模擬模式的參數使用方式？另結案後，參數資料	不同情境在模擬器中所使用的駕駛行為參數一致，惟號誌管制、交通需求、車種比例與轉向比例所有差異。在 AI 的訓練部分，所有情境的資料皆會回饋給予 AI 做為訓練樣本，而訓練過程中並不會刻意去區分情境，使 AI 能夠自然判別當下狀況最適合的決策。也因此在實際應用上無需特別劃分時段，一套 AI 參數即可 24 小時運作。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	應提供給甲方，以驗證本案的可操作性。	在後續工作有關離峰與假日情境的校估，主要是為了確認期中階段所校估之參數在平日離峰與假日尖峰亦有代表性。 有關本案所產出之路網成果，包含駕駛行為參數，皆會在驗收階段移交給甲方。	
	4.1.2 節實驗場域遴選程序部分，僅有考量準則並無說明遴選程序，請再補充說明場域遴選過程中序位法的評分方式。	本案場域遴選採用序位法方式，從四個不同的面相進行考慮。每個面向中皆依照團隊評估優劣順序加以排序，最終加總各面向總得分，最優方案即做為目標場域。相關說明請參考期末報告書。	同意
	5.1.1 節單一路口場域 AI 模型方案規劃部分，採固定時相順序，逐時相決策該次時相長度，其效益與適應性號誌決策模式之差異(或其優點)？未來有不固定時相順序(或分流動組合時相)的機會？	團隊經與各地方政府訪談中發現，實務單位皆考量駕駛人習慣與安全性的因素，傾向採用原固定時制之時相順序做為模式。在研究文獻中亦有出現非屬固定時相順序的作法，並且其績效亦相當良好，惟在本案中遵循地方政府的考量，暫以固定時相順序進行後續研究工作。	同意
	5.1.2 節幹道多路口場域 AI 模型方案規劃部分，表 16 輸入資料是指單一路口或全數路口，9 支與 4 支分別所指為何？；未來幹道多路口情境之可變動號誌時制項目彈性可多大？	有關臺北市場域方案 B-1 中所提之 9 支偵測器，其意義即代表所有路口所有來向的車輛數皆能被偵測到的情況。(該場域3路口共計 9 來向) 而 B-2 與 B-3 方案則將探討若減少偵測器數量與布設位置對於最終成效的影響程度，具體偵測器佈設位置則會於期末階段研議。 幹道多路口情境的號誌變動程度可能會受到鄰接路口定時時制的限制影響，關於這點將透過 B-4 方案探討。相關說明請參考期末報告書。	同意
	5.2 節交通模擬模型建置成果部分，目前以尖峰時段資料進行模式構建，未來離峰/假日模式構建後，各模式間的關係為何？VISSIM 或 SUMO 模擬模式顯示流量誤差較小，而每車延滯則有部分來向誤差大現象，未來在 AI 模式使用延滯參數為獎勵時，是否會造成特定來向車流，在實測過程發生結果不如預期現象？	所有模擬情境的建立僅為了樣本的蒐集與績效測試的確認，實際運作過程中並無須再切分時段或判別屬於何種情境。 模擬延滯誤差仍在可接受範圍當中，並且經不同情境的校估績效確認模擬模型足以反映交通績效趨勢，故即使在延滯有所誤差的情況下，將預期 AI 仍可學習到正確應對的趨勢。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	表 96，在臺北市實驗場域規劃有不同偵測器數量的方案，請在期末階段中補充說明偵測器預計設置的位置。另外在偵測器數量較少的方案中，若控制範圍中有發生事件，但偵測器沒有掌握到事件發生的情況，AI 是否亦可以應對？	偵測器佈設位置將在期末階段補充說明，請參考期末報告書。另本案將著重於 RL 號誌在一般狀況下的運作成效探討，有關特殊事件的處理與模式建構，在本案中暫不考慮。	同意
	AI 訓練目標設定上採用延滯最小化，但不論 VISSIM 或 SUMO 在延滯驗證上的誤差似乎都偏高，是否會影響 AI 訓練的成果？另外在 SUMO 的驗證成果上多數都較 VISSIM 為差，兩套模擬誤差程度不同是否會影響影訓練？	模擬延滯誤差仍在可接受範圍當中，並且經不同情境的校估績效確認模擬模型足以反映交通績效趨勢，故即使在延滯有所誤差的情況下，將預期 AI 仍可學習到正確應對的趨勢。 兩套模擬軟體雖然在重現場域交通狀況的程度有所不同，不過 RL 訓練過程將會在 VISSIM 中進行，而模擬測試階段則會在兩套軟體中各自測試，不會交互比對。	同意
臺北市政府交通局	本案所選定臺北市實驗場域，在模擬時是否有考慮到行人穿越對於左右轉車流的影響？	本案中並無調查行人穿越的需求，而在建模階段亦沒有建置行人，惟為盡可能還原場域調查數值，模擬模型在左右轉車皆有設定減速，因此預期在巨觀結果上應有呈現出左右轉車受行人之影響結果。	同意
	本案所選定臺北市實驗場域，附近常有百貨周年慶活動，進出停車場的車流可能會對計畫產生影響，建議實作前應考量是否將此情境納入訓練樣本。	感謝臺北市府交通局的建議，在本年度計畫中暫先以一般平日與例假日情境做為訓練環境，以避免稀少事件對於訓練的影響偏差。	同意
	臺北市的消防車輛目前皆無安裝 OBU，若欲透過 AI 號誌方式達到優先通行的效果，團隊的建議為何？	據了解目前緊急車輛回傳車輛資訊方式主要為 GPS 資料或車聯網方式回傳，都可屬於廣義上的 OBU。而不論傳輸方式為何，對於 AI 號誌控制最終仍是以收到的資料型態做為交通狀態的判斷依據，例如位置、旅行時間等。	同意
	是否考慮以旅行時間做為訓練目標參數？	感謝臺北市府交通局的建議，以旅行時間做為獎勵目標在模擬器中應屬可行，惟若僅針對幹道旅行時間做為訓練目標，則必然會造成犧牲橫交道路/支道績效的結果；而倘若欲考慮支道績效，又可能會陷入所有路徑皆需偵測旅行時間致而增加硬體成本的困境。在以「系統總績效最適化」為考量評估下，目前團隊對於市區道	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
		路的號誌控制並不建議以旅行時間做為獎勵目標，可列為重要績效觀察指標。	
中華交通號誌協會	有關報告書表 2，場域遴選考量準則，是否有考量路口有裝行人行車倒數計時器？如有考量，在人工智慧車聯網之號誌控制模式下是如何運作？	場域遴選過程並無考量行人倒數計時需求。團隊過去在桃園案例中有實做過行人綠燈倒數以及行車紅燈倒數，實務上可行。	同意
	有關報告書表 16，幹道多路口情境實驗訓練架構規劃，是否有評估各路口號誌控制器的廠牌、型號與版本？	團隊目前所提之方案所需之控制需求，應屬於目前市面通訊式控制器皆可支援的做法，因此在評選階段與方案規劃過程並無特別考量號誌控制器廠牌與版本，並且在桃園、高雄皆已有成功執行案例。	同意
運輸經營管理組	有關現有動態號誌控制之文獻回顧中係以澳、英、德、美等偏歐美國家環境為主，並未列入亞洲地區，例如：新加坡、日本、香港等氣候及地理環境與我國類似之國家(地區)，為顧慮偵測車流於相似環境模擬之實際狀況，建議應增加亞洲地區案例之文獻回顧。	本計畫文獻回顧引用之國際號誌控制方法/軟體:SCAT、SCOOT、PTV 等，雖發展國所在地為歐美偏多，但號誌控制方法的核心理論並不因實施場域不同而有所改變，僅需調整在地化參數。例如 SCOOT 的應用案例遍佈全球超過 140 以上的國家；PTV BALANCE 在臺灣、新加坡、中國等亞洲區域也都有實作案例。	同意
運輸資訊組	由於「人工智慧(Artificial Intelligence)」演算法甚多，而本案係導入人工智慧之「強化學習(Reinforcement Learning, RL)」於號誌控制，因此請於報告避免單純使用「人工智慧」用詞。	遵照辦理。	同意
	期中報告初稿對於臺南市「台 86-19 甲線」單一路口、臺北市「中山北路-德行東路」幹道、高雄市「台 88 線鳳山出口」(過埤路-鳳頂路) 等實驗場域之 VISSIM 與 SUMO 模擬模式構建內容之著墨較少，請再加強補充說明。	遵照辦理。	同意
	第二章文獻回顧部分， 1. 已進行國內外應用車聯網與人工智慧強化學習在號誌控制之應用與演算法之盤點與彙整，惟在車聯網號誌控制與優缺點研析與探討的著墨	遵照辦理。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	校少，請再加強補充說明。 2.請補充說明各研究之主要作法或重要內容，例如：P.21 胡大瀛等人研究中所探討之獎勵機制內容。		
	在 VISSIM 與 SUMO 模擬模式校估部分，SUMO 環境下之誤差值均大於 VISSIM 模擬環境，請再進一步探討可能精進之作法。	遵照辦理。	同意
	請再補充說明 P.33 最後一段「藉由讓 AI 號控代理人(以深度類神經網路$\boldsymbol{\pi_\theta}$表示之)在模擬環境中進行大量模擬」之「大量模擬」作法，以及訓練與測試資料的規劃與產生方式。	大量模擬意指讓 agent 以不同的決策去獲得樣本，進而正確估計不同決策對於未來所可能造成的影響程度。不同決策的產生過程可以稱為探索階段，探索階段通常以隨機方式去進行決策。	同意
	請再確認 P.39 之「s，」是否為 P.36 公式(2)之「s'」(下一個狀態)，以及進行修正。	確認兩者相同，已修正用字。	同意
	部分圖表內容不清晰(例如：P.43 之圖 30)，以及若非本案產生之圖表(例如：P.41 之圖 29)請加註資料來源。	遵照辦理。	同意
	中英文字體請統一採用標楷體與 Times New Roman。	遵照辦理。	同意
	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。	遵照辦理。	
主席	通偵測技術日新月異，未來在交通調查工作項目可考慮採用移動式 AI 影像偵測器進行長時段調查，以減少人力使用需求。	感謝主席建議。本案中交通調查工作已透過人工方式完成。未來後續計畫若有適合 AI 影像式偵測器之項目會再評估是否採用。	同意
	審查會議各委員及與會單位研提之口頭及書面意見，請睿星科技股份有限公司整理「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

審查委員	審查意見	審查意見回覆	主辦單位意見
	本計畫經徵詢審查委員意見，期中報告初稿審查通過，請睿星科技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

附件二 期末報告審查意見處理情形表

審查委員	審查意見	審查意見回覆	主辦單位意見
胡大瀛委員	請針對 DDPG 與 PPO 的應用與使用上的效率運行說明並請說明 PPO 的使用想法、未來可能的延伸。	遵照辦理，各場域方案訓練效率與關 PPO 想法與未來可能應用均已補充期末報告書修正版。	同意
	報告書中交通轉向量調查圖表呈現方式，例如：P.75，容易讓人誤以為未調查時段流量為 0，請再加檢視與調整。	感謝委員指正，已於各流量調查表前補充相關說明以避免誤會。	同意
	過去常見的適應性號誌控制方法中有時相跳躍(skip phase)的作法，請考慮其於本案應用之可能性。	感謝委員建議，後續年度計劃方向將評估 RL 套用時相跳躍的可行性。	同意
	最大最小綠燈秒數的限制主要的設計考量為何？請說明求解結果與此限制條件的關係。	有關最小綠燈秒數部分，基本上是考量行穿需求上的安全考量，與一般號誌時制設計原則相同。最大綠燈秒數部分，則是與管理單位依實務管理經驗，確認駕駛人對於其他競爭時相所能容忍的最大值做為考量。因此在最大最小綠燈秒數的限制上，主要皆是以實務運作做為考量，並無求解上績效考量的因素在內。	同意
	從本案眾多模型中，請說明單一獎勵函數是否即可適用？	就本案成果可說明本案所挑選之單一獎勵具有一定程度的通用性，可代提供 RL 往正確的方向進行學習更新。	同意
	報告書中單一代理人(Agent)與多代理人(Agent)的類神經網路結構相同(如圖 113 與圖 114)，請加強說明兩者是否有差異？	本案中單一路口場域與幹道多路口場域的類神經網路結構雖然相同，但在輸入端是有所差異的。多路口相較單路口來說，輸入端需要而外考慮控制範圍內、外所有路口的號誌資訊，以及不同路口的 VD 資訊輸入。因此雖然在類神經網路的結構上兩者相同，但在輸入端的資料種類有明顯差別。有關多路口的資料輸入種類說明可參考表 5.2.3。	同意
	研究中使用兩種模擬軟體(VISSIM 與 SUMO)。效果似乎差異不大，請加強未來應用的建議。	本研究的計畫內容主要是在探討 RL 應用於號誌控制上的模型探討，而採用兩種不同微觀模擬軟體的原因在於說明此方法能夠適用於不同的模擬軟體當中。以報告成果的角度僅能說明兩套模擬軟體皆具備可行性，但無法判斷說明何者更適用於 RL	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
		號誌控制的研究或訓練。建議其他研究單位仍應視自身研究需求或資源，個案考量適用哪一款模擬器。	
	請補充說明針對三處場域的模型方案的設計考慮與目的。	相關說明補充於期末報告書修正版。	同意
	以團隊的執行經驗，是否建議 AI RL 號誌控制後續持續往 PPO 方向研究發展？請補充說明。	PPO 具有隨機性的特色，在某些不確定性問題上具有合理的推估結果。因此PPO在RL 號誌控制議題上確實具有未來性，相關建議補充於 0。	同意
張新福委員	報告書中部分圖表與文字敘述不符合，如表 13-15、圖 99-112 等，無對應說明段。請再檢核。	感謝委員指正，已修正並補上相關說明。	同意
	部分內容是否誤植：P.117 應為圖 113，內文誤植如上圖 28；P.120、P.124 有關分車道分車種車輛數之定義請參考 5 中之敘述，何謂 5？請補充說明。	感謝委員指正，已修正。	同意
	許多內容參考前面的章節或圖表，建議附上頁數，方便翻閱，如 P.123 請參考 4.2 與 4.3 節；P.147 符合表 28 中所定義。	遵照辦理。	同意
	臺南市實驗場域(單一路口)建議搭配其他資訊讓 RL(強化學習)能正確評估即時交通狀態，請問這邊的其他資訊包含那些項目？本案高雄市實驗場域(車聯網)有用到停等長度作輸入或獎勵目標成效不錯，或許可納入後續研究。	1. 由於若僅採用流量做為交通狀態的評估，將有可能有誤判的情況發生，如 6.1.2 中所述。因此建議搭配其他資訊一併輸入，讓 RL 有判別差異的可能性。例如在 PPO 方法嘗試的部分(6.1.3)，輸入部分即為通過車輛數(流量)除以前一次該時相的秒數，成為類似飽和流率比值的概念做為RL狀態的判斷。而其他可搭配輸入的資料可能性繁多，在本研究中僅以前述作法做為一種示範案例。 2. 感謝委員肯定。	同意
	13 種模型績效比較中，延滯改善幅度皆略有不同，但通過量卻幾乎都沒有差異，原因為何？請補充說明。	在所有場域的各種交通情境中，在分析時段內所有到達的車輛皆能夠順利通過路口，因此在系統總通過量上便沒有顯著差異。而停等延滯上，即使所有車輛皆能順利通過路口，不同方案的停等時間亦會有所差異。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	臺北市實驗場域(幹道多路口)結果發現提供施作 AI 號誌路口及鄰近路口的完整交通資訊其成效最好，桃園目前AI號控系以施作AI號控的路口資訊為主，本項成果未來可做為本是精進參考。	感謝委員肯定。	同意
	另在臺南市實驗場域有提到通過量是否適合當作獎勵目標，要挑選過飽和情境或下游回堵的狀況(P.183)再行檢討，請問臺北市實驗場域多路口中，有此情形嗎？請補充說明。	從臺北市場域的分析結果來看，在支道部分稍有過飽和狀況出現，這點也反應在 B1、B3、B4 的方案中，系統總通過量略高於 TOD 的結果。	同意
	臺北市實驗場域(幹道多路口)結果發現比起偵測器數量，佈設建置的位置更為關鍵，且模擬結果發現建置部分偵測設備的成效也很好(延滯改善-8%)，略低於全部建置(延滯改善-12%)，囿於預算有限，用最少的設備得到最大的效益，這項成果對地方政府很有助益，有無佈設原則？請補充說明。	從本案中的經驗來說，建議是以能夠掌握到場域交通需求變化的位置為原則。臺北市場域 VD 佈設設計想法相關的說明可以參考 0 節。	同意
	高雄市實驗場域(車聯網)結果發現，聯網車量的比例(70%與 30%)成效無太大差異，推論這個比例不需要特別高，請問本案為何用 70%與 30%進行模擬研究？又是否有嘗試過 30%以下的比例是否可行？請補充說明。	在文獻回顧階段，參考國外研究中以滲透率 30%即可進行號誌控制相關研究，因此設定 30%；而 70%則為規劃階段欲探討更高的深透率是否能帶來更佳的績效，因此設定之。本案中在時間的限制下，並無探討到 30%以下的滲透率是否可行。	同意
	表 155 中所提的「控制路口」意指為何？請補充說明。	指鳳頂-過埤路口。此處停等車隊僅顯示控制路口的原因在於研究關切的重點在於控制路口的停等長度結果，而其他上游路口不宜納入平均值中影響評估結果。	
	第七章、實務建置建議，前面章捷有討論到 AI 分析需耗費運算資源，建議本章節納入伺服器的建議規格及資安防護內容。	本案中訓練過程的軟硬體環境說明補充於第六章。另外特別說明，實務管理單位在執行 RL 號誌控制時，並不需要訓練階段，因此對於硬體的要求並不嚴苛。有關資安部分則應視各管理單位的實際需求檢視相關內容，本案中較難有所建議。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
李忠璋委員	在模擬軟體驗證部分，雖然從 3 個實驗場域路口流量的 MAPE 多在 10%以下，但若從平均延滯來看，部分實驗場域的 MAPE 則有超過 20%的情形，還有部分路口轉向 MAPE 有超過 40%以上，不見得是報告書認為因數值過小造成誤差百分比被放大的情形，建議可以再做個別的原因檢視。	經檢視轉向交通量 MAPE 高於 40%以上的部分為 VISSIM 臺北市場域在路口 4 南向左轉的部分誤差特別高，經再檢查後發現數值有誤植的情況，已修正於表 5.3.27~表 5.3.31。 延滯部分 MAPE 高於 20%部分，經檢視主要仍是由於原調查數值較低的緣故所致。僅少部分再經過反覆調整仍有誤差較高的情況。	同意
	本研究採用 VISSIM 和 SUMO 來模擬驗證，看起來 VISSIM 的驗證能力略佳於 SUMO，但由於 SUMO 是免費軟體，所以大多交通管理單位比較會採用，是否在本研究可以再嘗試調整相關的參數值來提高準確率。	在實務建置計畫中，管理單位並不需要考慮模擬軟體是商用授權還是免費開源軟體，僅需評估最後績效是否符合管理單位需求。另外 VISSIM 在臺灣的應用案例眾多，甚至有專門的參數校估研究計畫，因此可供參考的經驗較多；相較來說，SUMO 在臺灣的經驗仍相對較少，因此也期待未來有更多 SUMO 應用計畫可供參考。	同意
	臺南市實驗場域的單一路口績效在連續假期受下游關廟交流道匝道儀控影響很大，因此在路口時制調整上會不會因為沒有考量匝道儀控，而相較於實際狀況有較大的差異。建議可以將匝道儀控的影響納入。	感謝委員建議，後續年度計劃方向將再評估如何納入考量。	同意
	以臺北市、臺南市、高雄市等實驗場域的路口時制計畫來看都，高達 5~6 個時相(可能包括早開或遲閉時相)，這種多時相路口因黃燈及全紅的影響，所造成的損失時間會嚴重干擾路口的整體績效，請問對於在 AI 模式驗證或訓練的過程中是否有考量這些損失時間的控制或調整。	在 VISSIM 與 SUMO 中，都有完整重現黃燈與全紅的秒數，因此若 RL 在決策過程中決定較小週期，自然會在獎勵部分承擔更多的損失時間績效犧牲，因此 RL 最終會由資料經驗中找出符合場域介間時間考量下的最佳解。	同意
	另外本研究所採用強化學習(RL)的訓練假設條件在時相數及其順序是按既有設計方式，在決策策略上是進行號誌時比及週期時間上做調整，這對於路口績效的改善可能有限，而且長週期下，有時候會有顧此失彼的情形發生，	感謝委員建議，後續年度計畫方向將再評估是否有可能放寬固定時相順序的限制。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
	所以除了在特殊的情境下，單一路口週期時間儘量避免超過 180 秒。		
	報告中部分實驗場域的時制計畫，在時相規劃明顯不是最佳化，其也是影響路口號誌運作績效因素之一，建議後續可以利用人工智慧相關作法，將某些特定時段的時相最佳化調整納入研究。	感謝委員建議，後續年度計畫方向將再評估是否有可能針對時相配制納入 RL 最佳化的過程中。	同意
劉瑞麟委員	請團隊再檢查第四章、第五章中交通調查值不一致的情況。(表 9、10、11 與表 36、37、38、39、48、49、50、51； 表 13、14、15 與表 60、61、62、63、72、73、74、75 等，高雄市實驗場域統計內容不一致，無法比較)	感謝委員指正，已修正於表 4.3.4~表 4.3.5；表 4.3.7~表 4.3.9；表 4.3.14~表 4.3.16。	同意
	圖 111 等候車隊長度驟變(1345~1430)，請再查核。圖 112 亦有部分，亦請查核。	造成停等車隊長度出現定值的原因在於離峰與假日的調查(第二次調查)過程中，由於拍攝角度問題無法拍攝到下匝道的高架段，即停等車隊長度若超過 300 公尺後即無法判斷真實的停等車隊長度，才會造成停等車隊長度驟降的誤解。已補充相關說明於報告中。	同意
	表 27 下方”請參考 5 中”應為”請參考第 5 章中；P126 第 3 段第 2 行中間亦有漏字。	感謝委員指正，已修正。	同意
	表 121、122 數值一樣，請查核。	感謝委員指正，已修正於表 6.3.3。	同意
	有關各實驗場域之模擬最佳化結果，可否提供各地方政府直接應用，以造福地方政府。	遵照辦理，後續將在與地方政府交流成果。	
	A4 模擬績效顯示，以最大通過量為目標，在通過量上並無明顯差異，是因為無過飽和狀態或上游路口溢流，請問如何產出此推論？請補充說明。	在模擬過程與交通調查影片中，皆未發現回堵狀況，並且經與高公局確認調查日之所有時段內皆沒有啟動匝道儀控，因此可以確認並沒有下游回堵溢流之情況。而從模擬測試結果中顯示各方案中所有達到車輛皆可在分析時段內順利通過路口，因此 AI 與 TOD 在通過車輛數這個項目上，在未回堵或未過飽和狀態下，並無顯著差異。而若在下游壅塞發生時，推論 AI 應	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
		有能力將綠燈時間改分配給其他方向，因此建議未來若要研究以通過車輛數做為最佳化目標則應以過飽和或下游回堵的情境做為研究對象較為適宜。	
臺北市政府交通局	臺北市中山北路四段、五段預期將於明年度實施動態號誌控制，請問團隊在未來實作階段在介面處是否須要特殊處理？請補充說明。	在本案中多路口控制的輸入資料中有納入鄰近路口的號誌時制相關資訊，預期 RL 將有能力配合範圍外的動態控制。另外若可將範圍外的動態控制邏輯寫入模擬環境當中，將可更進一步精進環境的還原程度，提升 RL 的績效。	同意
	在本計畫臺北市實驗場域模擬中，部分績效顯示出幹道旅行時間上升但整體延滯下降的情況，是否為 AI 權衡後的結果？是否可依機關需求調整權衡的方向？請補充說明。	幹道旅行時間上升但整體延滯下降的情況確實為 AI 權衡後的結果。可依照管理單位的實務需求改變各別方向的重要度(權重)，即可改變 AI 最佳化的方向。	同意
	臺北市實驗場域 B4 的實驗中幹道旅行時間明顯較原時制為差，是否可說明原因？請補充說明。	由於 B4 缺乏鄰近路口的號誌資訊，導致無法配合幹道連鎖續進所致。相關說明可參考 0 節。	同意
新北市政府交通局	本文內未說明聯網車占所有車輛數的占比，建議加以補充說明或其造成之影響。	本案中車聯網方案為 C2、C3 方案，其聯網車占比分別為 70%與 30%，相關說明請參考 0 節與 0 節。	同意
	本文 AI 自主學習上相較於目前採用的動態號誌效果又為如何？兩者在號誌秒數操作上的變化大概差異為何？請補充說明。	動態號誌控制方法眾多，又或因不同場域會有不同的績效成效，因此在本案中較難簡單比較 AI RL 方法與其他動態號誌控制之成效差異。AI RL 在控制設計上皆遵循既有都市號誌控制 V3 通訊協定，因此在實務操作上可與一般動態號誌控制整合至交通中心統一介面當中。	同意
	本案智慧號控訓練於 3 處實驗場域之模擬應用上，建議補充說明是否考慮倘遇緊急事故 AI 號控之應變處理機制，以及結合報警系統與 CMS 等之可行性。	本案主要研究目標設定於 AI RL 號誌模型的設計探討與方法論的可行性，有關緊急事故的處理機制建議在實務建置案中另依各場域管理單位所需各別設計。	同意
桃園市政府交	過去桃園 AI 號誌控制經驗中，出現模擬中績效良好，但上線運作後績效改善幅度卻不如模擬中顯著的情況，請問團隊對此有何看法？	桃園經驗中，導致模擬績效與實測績效有落差的主要原因為偵測器的準確度所致。建議可依偵測器實測準確度再回饋調整 AI RL 的訓練過程。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
通局			
臺中市政府交通局	針對本案單一路口場域(臺南市實驗場域)，實作成果未入匝道儀控之情境一事，因匝道儀控管制影響平面道路交通狀況，可能為多個縣市交通塞車之課題，建議本案後續可以考量納入匝道儀控情境下的 AI 號誌控制模式。	感謝建議，後續年度計劃方向將再評估如何納入考量。	同意
	在經驗上，執行幹道動態號誌後，易有民眾反映支道變塞車或不連貫情形，故關於報告書幹道多路口場域(臺北市實驗場域)第 206 頁表示，透過 VD 車輛偵測器架設於支道上，可改善整體路網績效，並且對於支道亦有明顯改善績效，惟幹道的績效未有明顯效果時，對於執行單位的投入成本恐會有遭到疑慮，對此如何平衡幹支道績效，並且達到幹支道皆有改善績效時，建議可納入後續計畫評估。	感謝建議，在實測階段將在與管理單位討論各方向的重要程度與訓練微調。	同意
高雄市政府交通局	高雄市實驗場域之偵測設備正常運作中，路口號誌控制器亦為高階控制器，後續實務建置上再請團隊協助，以達預期績效。	感謝建議，後續將在與地方政府交流成果。	同意
	有關人工智慧號誌控制模式運行之績效量化與計算，建議訂定統一計算標準與單位，以利後續長期成效追蹤及比較。	感謝建議，後續將在與地方政府交流討論採用何種量化指標評估成效。	同意
	建議針對智慧號誌控制模式運作事後環境改善、淨零績效衡量進行量化及貨幣化計算以供後續地方政府參考。	感謝建議，後續將在與地方政府交流討論採用何種量化指標評估成效。	同意
中華交通號	有關 P277 頁第 4 點：「若路口號誌控制器無法配合號控系統運作需求，則需進行號誌控制器更換或號誌控制器軟硬體更新。」協會已成立技術委員會，可針對上	感謝協會的協助與肯定。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
誌協會	述需求提供相關討論或進一步地探討。		
莊東穎委員	本計畫在文獻回顧、AI 強化學習 DDPG 和 PPO 演算法搭配 VISSIM 和 SUMO 的模擬/參數校估/訓練、後續實驗場域實作建議，以及成果推廣等工作的成果優良具參考性。	感謝委員的肯定。	同意
運輸資訊組	有關本案所使用演算法確定性策略梯度訓練演算法(DDPG)與策略近似演算法(PPO)兩種強化學習(Reinforcement Learning, RL)演算法進行號誌控制探討與實作，請補充說明或調整下列內容： 1. 第三章介紹 DDPG 與 PPO 演算法，請於第五章 RL 模式構建中針對本案 3 個實驗場域分別說明所使用 DDPG 與 PPO 之實作內容與訓練作法。 2. 在模擬環境下進行 DDPG 與 PPO 演算法實作過程所使用之 VISSIM API 與 SUMO TraCI 項目。 3. DDPG 與 PPO 演算法中之類神經網路架構及其結構。 4. 相較於期末報告初稿對於 DDPG 與 PPO 演算法說明，簡報呈現方式更具說明性，請參酌簡報內容來調整報告，並輔以適當文字說明。 5. 訓練環境之軟硬體規格。	遵照辦理。	同意
	請補充說明 P.125 圖 117 中的 CNN 網路結構、平坦化，以及所使用 RL 演算法。	平坦化的作法為將多維張量(tensor)重新改變形狀成 1 維的張量，例如原本是 4*3 的矩陣轉為 1*12 的矩陣。其目的是為了連接後續的隱藏層格式所需。已補充說明於 0 節中。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
		另外 CNN 網路結構與 RL 演算法並無關聯，所採用的 RL 演算法即為第三章中所介紹之 DDPG 與 PPO 演算法。	
	請於第六章訓練成果與分析中，補充各案例之訓練速度與收斂情形，以及訓練經驗彙整。	遵照辦理，已補充說明於第六章圖 6.2.3、圖 6.3.3、圖 6.4.3。	同意
	第七章在本計畫後續年度實作建議部分，除目前內容外，請針對臺北市、臺南市、高雄市等實驗場域之實作可能挑戰及課題進行探討，以及提出建議。	遵照辦理，已補充說明。	同意
	第九章在結論部分，請將各項內容再加以彙整，並提出本計畫在交通調查、模擬模式構建、DDPG 與 PPO 演算法導入於號誌控制、訓練環境設計之各面向成果或觀察；在建議部分，請針對本計畫後續年度實作、我國後續在此課題之發展等提出建議。	遵照辦理	同意
	P.122 本計畫對於「相隔 1 公里以上的路口資訊是否需要共享？」議題的處理方式為何？請補充說明。	所提到的「相隔 1 公里以上的路口」僅為舉例說明可能探討的方向，在本案多路口幹道場域中由於範圍僅 250 公尺，並無此議題。 而有關此一議題，從本案研究成果 B1 方案績效最好的結果來看，若在資訊上能共享仍是最佳的處理方式，惟不同場域仍有可能有不同的結果出現，在此只能將共享所有路口資訊視為一種建議的方式。	同意
	請補充說明將本案訓練成果複製至其它車流型態與路口/路段幾何類似場域之可行性與可能作法。	遵照辦理，已補充說明。	同意
	請補充 5.3.1 節中各資料表之尖離峰時時間段區間與車流參數單位。	遵照辦理。	同意
	中英文字體請統一採用標楷體與 Times New Roman。	遵照辦理。	同意
	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。	遵照辦理。	同意

審查委員	審查意見	審查意見回覆	主辦單位意見
主席	近年來科技執法範圍日漸擴大，對於駕駛行為產生明顯影響，AI號誌控制是否會考量到科技執法因素？請補充說明。	目前市面上的微觀交通模擬器沒有特別針對科技執法所帶來之影響作相關參數的功能設定。建議若是未來要考量科技執法對駕駛行為的影響，可採用實際於科技執法處進行相關的交通調查，再進行駕駛行為的參數校估。	同意
	本所過去所研發之 THCS 軟中也有包含交通模擬功能，是否亦能應用於 AI 強化學習的號誌控制訓練當中？請補充說明。	THCS 在動態號誌控制上尚無提供相關的 API 介接模組，無法滿足本研究中動態控制的作法，因此暫不考慮做為 AI RL 的模擬訓練、測試環境。	同意
	建議團隊將本計畫模擬測試績效彙整後納入結論當中，以利讀者快速了解本計畫成效。	遵照辦理，已補充於第 7 章。	同意
	審查會議各委員及與會單位研提之口頭及書面意見，請睿星科技股份有限公司整理「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
	本計畫經徵詢審查委員意見，期末報告初稿審查通過，請睿星科技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 12 月 22 日(四)前提送修訂版本。	遵照辦理。	同意

ISBN 978-986-531-509-2
00310
9 789865 315092

GPN：1011200565
定價 310 元