

113-051-3526
IOT-112-SCF001

應用人工智慧分析技術探勘高風險路段 (3/4)—行車異常事件及 高風險駕駛行為分析



交通部運輸研究所

中華民國 113 年 7 月

113-051-3526
IOT-112-SCF001

應用人工智慧分析技術探勘高風險路段 (3/4)—行車異常事件及 高風險駕駛行為分析

著者：鍾易詩、邱裕鈞、吳昆峯、余嘉萱、王佑星、
顏君潔、彭信瑋、劉曜峯、吳碩捷、朱浩瑄、
何玉鳳、葉祖宏、黃明正、黃士軒

交通部運輸研究所

中華民國 113 年 7 月

國家圖書館出版品預行編目(CIP)資料

應用人工智慧分析技術探勘高風險路段. (3/4) :
行車異常事件及高風險駕駛行為分析/鍾易詩,
邱裕鈞, 吳昆峯, 余嘉萱, 王佑星, 顏君潔, 彭
信瑋, 劉曜峯, 吳碩捷, 朱浩瑄, 何玉鳳, 葉祖
宏, 黃明正, 黃士軒著. -- 初版. -- 臺北市 :
交通部運輸研究所, 113.07

面 ; 公分

ISBN 978-986-531-612-9(平裝)

1. CST: 交通安全 2. CST: 交通管理 3. CST: 人
工智慧

557.16

113009538

應用人工智慧分析技術探勘高風險路段(3/4)
—行車異常事件及高風險駕駛行為分析

著 者：鍾易詩、邱裕鈞、吳昆峯、余嘉萱、王佑星、顏君潔、彭信瑋、
劉曜峯、吳碩捷、朱浩瑄、何玉鳳、葉祖宏、黃明正、黃士軒

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 113 年 7 月

印 刷 者：全凱數位資訊有限公司

版(刷)次冊數：初版一刷 70 冊

本書同時登載於交通部運輸研究所網站

定 價：550 元

展 售 處：

交通部運輸研究所運輸科技及資訊組•電話：(02)2349-6789

五南文化廣場：400002 臺中市區中山路 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：1011300847 ISBN：978-986-531-612-9 (平裝)

著作財產權人：中華民國（代表機關：交通部運輸研究所）

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

交通部運輸研究所合作研究計畫出版品摘要表

出版品名稱：應用人工智慧分析技術探勘高風險路段(3/4)－行車異常事件及高風險駕駛行為分析			
國際標準書號（或叢刊號） ISBN 978-986-531-612-9(平裝)	政府出版品統一編號 1011300847	運輸研究所出版品編號 113-051-3526	計畫編號 112-SCF001
主辦單位：運輸安全組 主管：葉祖宏 計畫主持人：葉祖宏 研究人員：黃明正、黃士軒 聯絡電話：02-2349-6859 傳真號碼：02-2545-0429	合作研究單位：國立陽明交通大學 計畫主持人：鍾易詩 研究人員：邱裕鈞、吳昆峯、余嘉萱、王佑星 顏君潔、彭信瑋、劉曜峯、吳碩捷 朱浩瑄、何玉鳳 地址：新竹市大學路 1001 號 聯絡電話：03-571-2121 #57652		研究期間 自 112 年 4 月 至 112 年 12 月
關鍵詞：人工智慧、影像辨識、高風險路段、高風險駕駛行為、行車異常事件			
<p>摘要：</p> <p>過去由於鮮少蒐集駕駛過程資料，在肇因判斷上多以事故發生當下近因為主，然近因並不一定為肇事主因，僅預防近因也未必能有效預防肇事。本計畫目標在將目前以事故資料為基礎的道路交通安全管理程序，提升為以事故資料、行車異常事件及駕駛行為等為基礎的道路交通安全管理程序。本計畫為 4 年期計畫之第 3 年計畫，以前期計畫為基礎，定義行車異常事件/高風險駕駛行為之風險指標，篩選出高風險駕駛行為事件，並融合車內外影像辨識技術篩選異常事件，透過增加樣本及引進新技術，優化影像辨識技術，探討影響異常事件/高風險駕駛行為發生之影響因素及好發情境，及進行巨觀、微觀之時空間特性分析，最終提供業者教育訓練及安全管理參考，也做為路權機關安全改善策略擬定之參考。</p> <p>本期計畫將業者分為四類管理系統類別進行分析：第一類僅使用車機系統和 GPS；第二類在此基礎上增加了 ADAS 資料；第三類再加入駕駛員監控系統；第四類整合前三類的管理手段，並加入外部環境資料進行分析。透過設計一混合計量經濟與機器學習方法之模式定義高風險駕駛行為，計算出相對風險值和各變數高風險比例辨識高風險情境。縱向警示中，本車變換車道和前車變換車道的高風險行為與車距、駕駛員年資、駕駛手部行為有關；橫向警示中，行駛於國道全線(含匝道)的高風險行為與車距、駕駛手部行為相關，而在國道主線的情境下，則與行駛於全線段相同、駕駛員年資有關。在模式驗證中，透過盒鬚圖資料分布，設定縱向警示的切分點為機率預測值 0.39，橫向警示的切分點為機率預測值 0.2，利用此切分點能將大部分警示事件正確分為異常和非異常事件。</p> <p>本期計畫時空分析著重在完整第一至四類管理系統類別巨觀到微觀的樣本，第一類管理系統類別以隨機單一趟次為樣本發現，大部分 OBD 資料在加速度有觸及的時間點前後幾分鐘內，幾乎都有警示事件發生；第二至四類管理系統類別透過路段、趟次、事件分析，發現車流量大、服務區、時段性差異（假日、方向等），可能因交織情形多駕駛員會更加注意而警示發生較少，業者排班若長時間派班越多，從趟次模式中發現發生警示事件的次數也較多。</p> <p>本期計畫針對現今運輸業者在車隊管理面臨的問題，提出以 AI 辨識和車載系統資料為基礎的管理平台雛型系統，此系統之介面分為四個部分，包含首頁呈現所有駕駛的行為報表、各駕駛表現的綜合報表、關注特定事件的異常事件報表以及進行行車影像風險分析，能識別異常事件並計算風險值，期望能節省大量處理資料的時間和人力成本，更能量化異常事件的風險值，協助運輸業者更有效率地執行車隊管理。</p>			
出版日期	頁數	定價	本出版品取得方式
113 年 7 月	364	550	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: Applying Artificial Intelligence Techniques to Identifying Accident-prone Road Sections (3/4): Analysis of Dangerous Events and High Risk Driving Behavior			
ISBN(OR ISSN) ISBN 978-986-531-612-9(pbk.)	GOVERNMENT PUBLICATIONS NUMBER 1011300847	IOT SERIAL NUMBER 113-051-3526	PROJECT NUMBER 112-SCF001
DIVISION: Safety Division DIVISION DIRECTOR: Tsu-Hurng Yeh PRINCIPAL INVESTIGATOR: Tsu-Hurng Yeh PROJECT STAFF: Ming-Cheng Huang; Shih-Hsuan Huang PHONE: 886-2-2349-6859 FAX: 886-2-2545-0429			PROJECT PERIOD FROM April 2023 TO December 2023
RESEARCH AGENCY: National Yang Ming Chiao Tung University PRINCIPAL INVESTIGATOR: Yi-Shih Chung PROJECT STAFF: Yu-Chiun Chiou; Kun-Feng Wu; Chia-Hsuan Yu; Yu-Hsing Wang; Chun-Chien Yen; Hsin-Wei Peng; Yao-Feng Liu; Shou-Chieh Wu; Amy Chu; Yu-Fong Ho ADDRESS: 1001 University Road, Hsinchu, Taiwan 300, R.O.C. PHONE: 886-3-571-2121# 57652			
KEY WORDS: Artificial Intelligence, Image Recognition, High-risk Road Segment, High-risk Driving Behavior, Dangerous Event			
ABSTRACT: <p>The executive summary presents an advanced project dedicated to enhancing road safety by broadening the scope of accident prevention strategies. Traditionally focused on proximal causes, this initiative advocates for a more inclusive analysis that encompasses not only accidents but also potential dangerous driving events and behaviors. Leveraging state-of-the-art in-vehicle and external image recognition technologies, this project—now in its third year of a four-year plan—builds upon prior research to pinpoint risk indicators for dangerous events and high-risk driving behaviors. By augmenting sample sizes, integrating cutting-edge technologies, refining image recognition methods, examining influential factors, and undertaking both broad and detailed spatiotemporal analysis, the project aims to furnish educational training materials and safety management guidelines for operators and inform safety improvement strategies for road authorities.</p> <p>The project develops a comprehensive model to identify high-risk driving behaviors, categorizing management systems based on data completeness and incorporating various data sources, including vehicle system and global satellite positioning data, Advanced Driver Assistance Systems (ADAS), and external environmental data. A novel hybrid model combines quantitative economics with machine learning techniques to assess high-risk driving behaviors, establishing risk values and identifying hazardous scenarios.</p> <p>Experimental results highlight the potential of image recognition technologies like YOLOv7 and YOLOv8, and ViTPose in accurately detecting internal and external risk factors, despite challenges such as overexposure and interference. Spatiotemporal analysis provides insights into warning event patterns across different management systems, revealing the impact of traffic volume, service areas, and scheduling on driver behavior.</p> <p>To address fleet management challenges, the project proposes an AI-powered system that streamlines data processing, risk evaluation, and reporting, promising significant efficiency gains for transportation operators. This system not only quantifies the risk of dangerous events but also offers detailed insights into driver behavior, enhancing overall fleet safety management.</p>			
DATE OF PUBLICATION July 2024		NUMBER OF PAGES 364	PRICE 550
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	VII
表目錄	XI
執行摘要	XVII
第一章緒論	1
1.1 計畫緣起	1
1.2 計畫目的	5
1.3 計畫範圍	6
1.3.1 四年期計畫關係	6
1.3.2 本期計畫架構與流程	10
第二章文獻回顧	13
2.1 前期計畫回顧	13
2.1.1 「駕駛行為分析工具開發及行為特性探討」案	13
2.1.2 「應用人工智慧分析技術探勘高風險路段 (1/4) - 駕駛 行為模式研析及車外行車異常事件影像辨識技術開發 」案	15
2.1.3 「應用人工智慧分析技術探勘高風險路段 (2/4) - 車內 行車異常事件影像辨識技術開發」案	19
2.2 高風險駕駛行為與行車異常事件研究	20
2.2.1 高風險駕駛行為樣態與好發情境	20
2.2.2 高風險駕駛行為與事故風險	36
2.2.3 行車異常事件研究	38
2.2.4 小結	40
2.3 行車影像辨識技術與影像資料整合應用	40
2.3.1 車外行車影像辨識技術	40
2.3.2 車內行車影像辨識技術	43
2.4 交通事故時空間分析	45
2.4.1 高風險駕駛行為時空間特性不同	45
2.4.2 交通事故時空間分析與預測模式	47
2.4.3 小結	56
2.5 高風險駕駛行為與行車異常事件之管理案例	57
2.5.1 歐美地區	57
2.5.2 亞洲地區	70
2.5.3 管理系統接受度與支持度	75
2.5.4 小結	77
2.6 小結	80

第三章高風險駕駛行為之分析與管理之構想.....	83
3.1 業者分類架構	83
3.2 高風險駕駛行為定義與分析架構	85
3.2.1 行車異常事件之定義	85
3.2.2 高風險駕駛行為定義與分析架構	86
3.3 高風險駕駛行為分析之資料結構	88
3.4 資料盤點與變數定義	90
3.4.1 資料盤點	90
3.4.2 變數定義	94
第四章高風險駕駛行為分析結果.....	103
4.1 ADAS 警示、行車異常事件與駕駛行為特性描述	103
4.2 高風險駕駛行為之操作型定義及歸納：混合計量經濟與機器學習方法之應用	106
4.2.1 縱向警示事件：本車變換車道	107
4.2.2 縱向警示事件：前車變換車道	113
4.2.3 橫向警示事件：本車行駛國道全線段 (含匝道)	118
4.2.4 橫向警示事件：本車行駛國道主線段	122
4.3 高風險駕駛行為之風險評估	127
4.3.1 縱向警示風險評估：本車變換車道	127
4.3.2 縱向警示風險評估：前車變換車道	131
4.3.3 橫向警示風險評估：國道全線段 (含匝道)	135
4.3.4 橫向警示風險評估：國道主線段	138
4.4 以機器學習方法預測行車異常事件	141
4.4.1 XGBoost	142
4.4.2 隨機森林	145
4.5 小結	151
4.5.1 高風險駕駛行為及風險評估	151
4.5.2 混合方法與機器學習之比較	156
第五章特定警示之高風險駕駛行為分析：前車碰撞與橫向偏移	159
5.1 資料與分析流程	159
5.1.1 風險評估模式及模式驗證資料	160
5.1.2 警示鏈分析資料	160
5.2 分析結果	161
5.2.1 警示事件風險評估模式驗證	161
5.2.2 警示鏈分析	163
5.3 小結	167
第六章行車影像辨識技術與解析	169
6.1 車外模型比較及改善	169

6.1.1 Scaled YOLOv4	169
6.1.2 YOLOv5	175
6.1.3 YOLOv7	176
6.1.4 YOLOv8	178
6.1.5 模式辨識效果及改善流程	179
6.1.6 針對車外偵測不穩定的事件情境分析和模型測試比較	182
6.1.7 新樣本影片觀察模型效果	201
6.1.8 車外物件偵測及計算相對速度和距離所需時間	206
6.2 車內模型比較及改善	206
6.2.1 影像相關前處理測試	208
6.2.2 關節點偵測穩定性的評估與比較	211
6.2.3 針對關節點偵測不穩定的事件整理並分類因素	214
6.2.4 造成車內關節點偵測不穩定的各因素說明與可能改善方式	217
6.2.5 新樣本影片觀察模型改善效果	220
6.2.6 車內駕駛分心行為偵測所需時間	221
6.3 影像辨識結果討論與建議	222
6.4 小結	223
第七章 高風險駕駛行為與行車異常事件之時空分析	225
7.1 時空分析架構與資料庫說明	225
7.2 時空變數應用說明與樣本數量統計	234
7.3 以 OBD 資料為基礎之高風險駕駛行為之時空分析	237
7.4 以 ADAS 資料為基礎之高風險駕駛行為之時空分析	240
7.4.1 以路段為基礎之分析	241
7.4.2 以趟次為基礎之分析	245
7.4.3 以事件為基礎之分析	250
7.5 時空分析結果之管理意涵	255
7.6 小結	257
第八章 行車異常事件管理雛型系統開發	259
8.1 雛型系統架構	259
8.1.1 概念說明	259
8.1.2 系統組成與業者管理之連結	259
8.1.3 系統軟硬體架構	267
8.2 資料輸入格式與報表輸出樣式	270
8.3 雛型系統操作使用說明	272
8.3.1 首頁頁面	272
8.3.2 新增行車影像分析頁面	273
8.3.3 駕駛綜合報表頁面	273

8.3.4 行車異常事件列表頁面	275
8.4 雛型系統資料前處理說明	276
第九章國道客運駕駛安全管理策略建議.....	277
9.1 駕駛管理	277
9.2 車隊管理	281
9.3 設備管理	284
第十章結論與建議.....	287
10.1 結論.....	287
10.2 建議.....	290
參考文獻	293
附錄一 期中報告審查意見回覆.....	303
附錄二 期末報告審查意見回覆.....	319
附錄三 雛型系統說明會討論事項.....	339

圖目錄

圖 1.1-1 以事故為基礎之道路交通安全管理程序	4
圖 1.1-2 以事故、行車異常事件與駕駛行為基礎之 道路交通安全管理程序	5
圖 1.3-1 整合模組架構	8
圖 1.3-2 本期計畫流程圖	11
圖 2.1-1 前期研究未保持安全距離之序列分類流程圖	17
圖 2.1-2 前期研究車道偏移之序列分類流程圖	18
圖 2.1-3 前期研究匝道車速過快之序列分類流程圖	18
圖 2.3-1 使用臉部特徵定位之間的距離關係判斷駕駛的眼睛和口部開闔	44
圖 2.3-2 使用正面、側面兩相機視角共同辨識駕駛疲勞狀態與分心行為	45
圖 2.4-1 旅行時間分割紀錄駕駛行為事件發生率	54
圖 2.4-2 GMR 模式的學習與驗證過程	56
圖 2.5-1 駕駛行為監測 App 操作介面示意圖	65
圖 2.5-2 分數變化趨勢比較 (黃為實驗組，藍為對照組)	66
圖 2.5-3 特定駕駛 2007 年 3 月旅次資料	67
圖 2.5-4 某駕駛與平均分數比較圖	67
圖 2.5-5 駕駛風險評估案例	68
圖 2.5-6 APP 操作畫面示意圖	69
圖 2.5-7 APP 警示畫面示意圖	69
圖 2.5-8 各等級平均危險事件發生件數	70
圖 2.5-9 駕駛風險評估案例	71
圖 2.5-10 車機數據使用流程	72
圖 2.5-11 駕駛評分系統示意圖	72
圖 2.5-12 駕駛行為分數計算方式	73
圖 2.5-13 千代田運輸急煞車事件趨勢圖	73
圖 2.5-14 適性診斷表	74
圖 2.5-15 即時監控系統畫面	74
圖 2.5-16 危險事件發生次數趨勢圖	75
圖 3.1-1 客運業者分類架構	83
圖 3.2-1 高風險駕駛情境分析架構	87
圖 3.3-1 車外 12 宮格之影像辨識示意	89
圖 3.3-2 影像辨識輸出資料範例	90
圖 3.4-1 本期各分析項目使用之資料說明	94
圖 4.2-1 高風險駕駛行為定義流程	107
圖 4.2-2 探討分心與人工辨識關聯之二元迴歸	110
圖 4.3-1 BRT 模式圖形 (縱向警示：本車變換車道)	128
圖 4.3-2 各風險值選取範圍 (縱向警示：本車變換車道)	130

圖 4.3-3 BRT 模式圖形 (縱向警示：前車變換車道).....	132
圖 4.3-4 各風險值選取範圍 (縱向警示：前車變換車道).....	134
圖 4.3-5 BRT 模式圖形 (橫向警示：本車行駛國道全線段).....	135
圖 4.3-6 各風險值選取範圍 (橫向警示：本車行駛國道全線段).....	137
圖 4.3-7 BRT 模式圖形 (橫向警示：本車行駛國道主線段).....	138
圖 4.3-8 各風險值選取範圍 (橫向警示：本車行駛國道主線段).....	140
圖 4.4-1 XGBoost 方法操作流程圖	143
圖 4.4-2 隨機森林資料層級與行車異常事件之關係示意圖	146
圖 4.4-3 SMOTE 方法示意圖	148
圖 4.4-4 Tomek Link 方法示意圖	150
圖 5.2-1 行車異常事件機率及真值盒鬚圖 (縱向警示).....	162
圖 5.2-2 行車異常事件機率及真值盒鬚圖 (橫向警示).....	163
圖 6.1-1 Scaled YOLOv4 架構圖	169
圖 6.1-2 YOLOv4 架構圖	170
圖 6.1-3 YOLOv5 架構圖	175
圖 6.1-4 YOLOv7 架構圖	176
圖 6.1-5 YOLOv8 架構圖	178
圖 6.1-6 強光影像過曝和雜訊，特徵細節丟失偵測效果比較	183
圖 6.1-7 強光影像過曝水珠或地面反光特徵細節模糊偵測效果比較	184
圖 6.1-8 低光照影像過暗和雜訊水珠或地面反光偵測效果比較	186
圖 6.1-9 低光照影像過暗和雜訊，輪廓和特徵細節丟失偵測效果比較	187
圖 6.1-10 低光照影像過曝和雜訊輪廓和特徵細節丟失偵測效果比較	188
圖 6.1-11 夜間其他燈光雜訊干擾偵測效果比較	189
圖 6.1-12 過曝影像對比過低，輪廓及陰影特徵模糊效果比較	190
圖 6.1-13 強光影像過曝水珠或地面反光特徵細節模糊偵測效果比較	191
圖 6.1-14 濃霧視野不清偵測距離有限偵測效果比較	192
圖 6.1-15 陰天影像對比過低，輪廓特徵模糊偵測效果比較	193
圖 6.1-16 雨滴大小和密度的遮蔽干擾偵測效果比較	195
圖 6.1-17 角度變換和紋理干擾偵測效果比較	196
圖 6.1-18 夜間部分影片出現煞車燈的炫光現象	202
圖 6.1-19 豪雨狀況物件偵測拖車出現 bounding box 範圍過大的異常	202
圖 6.1-20 豪雨狀況偵測大客車出現 bounding box 範圍過大的異常	203
圖 6.1-21 擋風玻璃雨滴附著出現偵測機車的異常	203
圖 6.1-22 擋風玻璃雨滴附著出現偵測卡車的異常	203
圖 6.1-23 地面反光出現偵測大客車的異常	204
圖 6.1-24 地面反光出現偵測卡車的異常	204
圖 6.2-1 車內駕駛行為分析架構	207
圖 6.2-2 車內模型偵測時遇到多物件狀況目標選擇方法改善	208

圖 6.2-3 車內影像強化前處理測試結果	209
圖 6.2-4 車內影像轉正測試結果	210
圖 6.2-5 駕駛關節點偵測不穩定的事件數量與重疊狀況	212
圖 6.2-6 駕駛關節點偵測不穩定的事件時間分布	212
圖 6.2-7 駕駛關節點偵測不穩定事件各車分布比較	213
圖 6.2-8 駕駛關節點偵測在夜間 IR 狀態下的改善	213
圖 6.2-9 副駕駛座有乘客且特徵較駕駛明顯問題說明	215
圖 6.2-10 車內關節點偵測不穩定影響因素之間的重疊關係	215
圖 6.2-11 車內關節點偵測不穩定影響因素分析-車輛 2 到 5	216
圖 6.2-12 車內關節點偵測網路 ViTPose 相較於 YOLOv7 Pose 不穩定事件 的原因數量比較.....	216
圖 6.2-13 夜間 IR 對車內關節點偵測影響	217
圖 6.2-14 車內光線不足對車內關節點偵測影響	218
圖 6.2-15 駕駛衣著對車內關節點偵測影響	218
圖 6.2-16 較難辨識駕駛動作對車內關節點偵測影響	219
圖 6.2-17 部分身體部位被遮蔽對車內關節點偵測影響	219
圖 6.2-18 車內新樣本影片中各車輛關節點偵測不穩定的數量	220
圖 6.2-19 車內 IR 或是濾光片自動切換功能沒有正確開啟的車輛成像	221
圖 7.1-1 時空分析架構圖	226
圖 7.1-2 資料庫架構設計示意圖	230
圖 7.1-3 資料庫建構流程示意圖	230
圖 7.2-1 ADAS 警示事件資料分級與後續分析方向示意圖	235
圖 7.3-1 OBD、GPS 資料逐秒串接國道幾何資訊示意圖	239
圖 7.3-2 透過 OBD 計算加速度後，趟次觸發條件次數	239
圖 7.3-3 對應趟次之警示事件表	240
圖 7.4-1 整合資料分析架構圖	241
圖 7.4-2 路段分析概念示意圖	242
圖 7.4-3 趟次分析概念示意圖	246
圖 7.4-4 單一事件分析概念示意圖	250
圖 7.5-1 前期分析路段風險管理象限圖	257
圖 7.6-1 各司機依月份分析概念示意圖	258
圖 8.1-1 雛型系統概念圖	259
圖 8.1-2 首頁報表介面	260
圖 8.1-3 駕駛風險象限圖	262
圖 8.1-4 隨時間演變之警示風險圖 (含縱向與橫向警示).....	263
圖 8.1-5 隨時間演變之警示風險圖 (橫向警示).....	263
圖 8.1-6 隨時間演變之右手離開方向盤次數	264
圖 8.1-7 隨時間演變之超速次數	264

圖 8.1-8 隨時間演變之警示次數	264
圖 8.1-9 駕駛綜合報表介面	265
圖 8.1-10 行車異常事件列表介面	266
圖 8.1-11 駕駛警示次數雷達圖	267
圖 8.1-12 雛型系統軟體架構圖	267
圖 8.1-13 雛型系統資料處理邏輯設計架構	268
圖 8.1-14 雛型系統軟體架構分部解說(1).....	268
圖 8.1-15 雛型系統軟體架構分部解說(2).....	269
圖 8.1-16 雛型系統軟體架構分部解說(3).....	269
圖 8.2-1 首頁介面	270
圖 8.2-2 駕駛綜合報表介面	271
圖 8.2-3 行車異常事件列表介面	271
圖 8.2-4 影片呈現方式	272
圖 8.3-1 雛型系統首頁頁面	273
圖 8.3-2 雛型系統新增行車影像分析頁面	274
圖 8.3-3 雛型系統駕駛綜合報表頁面	274
圖 8.3-4 雛型系統行車異常事件列表頁面	275
圖 8.3-5 雛型系統播放行車異常事件影片紀錄	275
圖 8.4-1 車內區域劃分範例說明	276
圖 9.1-1 趟次路線中好發交通事故、警示事件、行車異常事件之路段示意	277
圖 9.1-2 違規舉動—使用手機	278
圖 9.1-3 違規舉動—抽菸	278
圖 9.1-4 良好之個人習慣與駕駛習慣—擺頭、著正式制服	279
圖 9.1-5 駕駛管理之安全管理策略架構	279
圖 9.2-1 車內光線不足造成影像辨識困難	282
圖 9.2-2 車隊管理之安全管理策略架構	282
圖 9.3-1 駕駛員動作被遮蔽	284
圖 9.3-2 夜間 IR 功能過強.....	284
圖 9.3-3 設備管理之安全管理策略架構	285

表目錄

表 1.3-1 分年研究重點彙整	9
表 2.1-1 前期研究未保持安全距離之序列分類	16
表 2.1-2 前期研究車道偏移之序列分類	17
表 2.1-3 前期研究匝道車速過快之序列分類	18
表 2.2-1 ADAS 警告指標及警告系統條件	29
表 2.2-2 高風險與偏差駕駛行為樣態與影響因子	30
表 2.2-3 駕駛行為樣態與人、車、路之影響因子	34
表 2.2-4 SHRP2 之行車異常事件觸發門檻值	38
表 2.2-5 相關文獻危險駕駛行為之門檻值	39
表 2.4-1 事故空間分析與預測研究整理	51
表 2.5-1 FMCSA 評估項目表	58
表 2.5-2 使用率因子數值對照表	59
表 2.5-3 危險駕駛指標業者分組	59
表 2.5-4 危險駕駛指標業者分組	59
表 2.5-5 工作時數指標業者分組	60
表 2.5-6 工作時數指標門檻值	60
表 2.5-7 駕駛適性指標業者分組	60
表 2.5-8 駕駛適性指標門檻值	61
表 2.5-9 藥物或酒精使用指標業者分組	61
表 2.5-10 藥物或酒精使用指標門檻值	61
表 2.5-11 車輛維護指標業者分組	62
表 2.5-12 車輛維護指標門檻值	62
表 2.5-13 危險物品運送指標業者分組	63
表 2.5-14 危險物品運送指標門檻值	63
表 2.5-15 使用率因子數值對照表	64
表 2.5-16 事故指標業者分組	64
表 2.5-17 事故指標門檻值	64
表 2.5-18 文獻案例彙整表	78
表 3.1-1 各類型業者管理系統特徵彙整	84
表 3.4-1 3 期計畫分心事件中各動作類別統計	91
表 3.4-2 3 期計畫趟次資料之警示事件類別統計	91
表 3.4-3 本期新增資料之各車輛不同警示事件數	92
表 3.4-4 本期新增資料之平均每趟次、每車輛、每人發生之警示事件數	92
表 3.4-5 第 I 類管理方式之資料欄位	94
表 3.4-6 第 II 類管理方式新增之資料欄位表	97
表 3.4-7 第 III 類管理方式新增之資料欄位表	99

表 3.4-8 第 IV 類管理方式新增之資料欄位表	101
表 4.1-1 行車異常事件數量統計	103
表 4.1-2 駕駛行為數量統計 (影像辨識).....	104
表 4.1-3 駕駛行為數量統計 (人工辨識).....	105
表 4.2-1 第 I 類管理方式本車變換車道高風險駕駛模式	108
表 4.2-2 第 I 類管理方式本車變換車道高風險駕駛模式刪除變數	108
表 4.2-3 第 II 類管理方式本車變換車道高風險駕駛模式	109
表 4.2-4 第 II 類管理方式本車變換車道高風險駕駛模式刪除變數	109
表 4.2-5 第 III 類管理方式本車變換車道高風險駕駛模式	111
表 4.2-6 第 III 類管理方式本車變換車道高風險駕駛模式刪除變數	111
表 4.2-7 第 IV 類管理方式本車變換車道高風險駕駛模式	112
表 4.2-8 第 IV 類管理方式本車變換車道高風險駕駛模式刪除變數	113
表 4.2-9 第 I 類管理方式前車變換車道高風險駕駛模式	114
表 4.2-10 第 I 類管理方式前車變換車道高風險駕駛模式刪除變數	114
表 4.2-11 第 II 類管理方式前車變換車道高風險駕駛模式	115
表 4.2-12 第 II 類管理方式前車變換車道高風險駕駛模式刪除變數	115
表 4.2-13 第 III 類管理方式前車變換車道高風險駕駛模式	116
表 4.2-14 第 III 類管理方式前車變換車道高風險駕駛模式刪除變數	116
表 4.2-15 第 IV 類管理方式前車變換車道高風險駕駛模式	117
表 4.2-16 第 IV 類管理方式前車變換車道高風險駕駛模式刪除變數	117
表 4.2-17 第 I 類管理方式行駛國道全線段高風險駕駛模式	118
表 4.2-18 第 I 類管理方式行駛國道全線段高風險駕駛模式刪除變數	119
表 4.2-19 第 II 類管理方式行駛國道全線段高風險駕駛模式	119
表 4.2-20 第 II 類管理方式行駛國道全線段高風險駕駛模式刪除變數	119
表 4.2-21 第 III 類管理方式行駛國道全線段高風險駕駛模式	120
表 4.2-22 第 III 類管理方式行駛國道全線段高風險駕駛模式刪除變數 ..	121
表 4.2-23 第 IV 類管理方式行駛國道全線段高風險駕駛模式	122
表 4.2-24 第 IV 類管理方式行駛國道全線段高風險駕駛模式刪除變數 ..	122
表 4.2-25 第 I 類管理方式行駛國道主線段高風險駕駛模式	123
表 4.2-26 第 I 類管理方式行駛國道主線段高風險駕駛模式刪除變數	123
表 4.2-27 第 II 類管理方式行駛國道主線段高風險駕駛模式	124
表 4.2-28 第 II 類管理方式行駛國道主線段高風險駕駛模式刪除變數	124
表 4.2-29 第 III 類管理方式行駛國道主線段高風險駕駛模式	125
表 4.2-30 第 III 類管理方式行駛國道主線段高風險駕駛模式刪除變數 ..	125
表 4.2-31 第 IV 類管理方式行駛國道主線段高風險駕駛模式	126
表 4.2-32 第 IV 類管理方式行駛國道主線段高風險駕駛模式刪除變數 ..	126
表 4.3-1 類別化變數選取範圍 (縱向警示：本車變換車道)	128
表 4.3-2 類別化修正模式 (縱向警示：本車變換車道)	129

表 4.3-3 風險嚴重度劃分 (縱向警示：本車變換車道)	131
表 4.3-4 類別化變數選取範圍 (縱向警示：前車變換車道)	132
表 4.3-5 類別化修正模式 (縱向警示：前車變換車道)	133
表 4.3-6 風險嚴重度劃分 (縱向警示：前車變換車道)	135
表 4.3-7 類別化變數選取範圍 (橫向警示：本車行駛國道全線段)	136
表 4.3-8 類別化修正模式 (橫向警示：本車行駛國道全線段)	136
表 4.3-9 風險嚴重度劃分 (橫向警示：本車行駛國道全線段)	138
表 4.3-10 類別化變數選取範圍 (橫向警示：本車行駛國道主線段)	139
表 4.3-11 類別化修正模式 (橫向警示：本車行駛國道主線段)	139
表 4.3-12 風險嚴重度劃分 (橫向警示：本車行駛國道主線段)	141
表 4.4-1 決策樹與 XGBoost 之分析結果	143
表 4.4-2 混淆矩陣	144
表 4.4-3 XGBoost 績效指標	145
表 4.4-4 決策樹與隨機森林之分析結果	146
表 4.4-5 隨機森林績效指標	147
表 4.4-6 訓練樣本在 SMOTE 前後之異常與非異常數量	148
表 4.4-7 SMOTE 前後之 AUC 值比較	149
表 4.4-8 SMOTE 前後之 Recall 值比較	149
表 4.4-9 SMOTE 與 Tomek Link 之 AUC 值比較	150
表 4.5-1 不同情境下各類管理方式對應可管理項目	153
表 4.5-2 各情境下需關注項目	155
表 4.5-3 混合模型、隨機森林與 XGBoost 之平均 AUC 值	156
表 5.1-1 三期 FCWH、SLDW 警示事件類別統計	159
表 5.1-2 三期 FCWH、SLDW 警示當下之分心事件中各動作類別統計 ..	159
表 5.1-3 用以模式驗證之本期新增行車異常事件數量統計	160
表 5.1-4 用於警示鏈分析之各分心行為類別統計	160
表 5.2-1 警示當下分心行為、發生警示類別、警示後 10 秒分心行 為序列法則：前車變換車道 (本期)	164
表 5.2-2 警示當下分心行為、發生警示類別、警示後 10 秒分心行 為序列法則：前車變換車道 (前期)	164
表 5.2-3 警示當下分心行為、發生警示類別、警示後 10 秒分心行 為序列法則：本車變換車道 (本期)	165
表 5.2-4 警示當下分心行為、發生警示類別、警示後 10 秒分心行 為序列法則：本車變換車道 (前期)	165
表 5.2-5 警示當下分心行為、發生警示類別、警示後 10 秒分心行 為及導致事件異常程度序列法則：本車車道偏移 (本期)	165
表 5.2-6 警示當下分心行為、發生警示類別、警示後 10 秒分心行 為序列法則：本車車道偏移 (前期)	166

表 6.1-1 YOLOv4 iot 車外辨識不穩定統計	197
表 6.1-2 YOLOV7 ef-iot 車外辨識不穩定統計	198
表 6.1-3 YOLOV7 iot-ft50 車外辨識不穩定統計	199
表 6.1-4 YOLOV7 iot-ft600 車外辨識不穩定統計	200
表 6.1-5 日間情境偵測不穩定統計	205
表 6.1-6 夜間情境偵測不穩定統計	205
表 6.1-7 物件偵測及計算相對速度和距離所需時間	206
表 6.2-1 車內關節點偵測不穩定事件影響因素各車統計-白天	214
表 6.2-2 車內關節點偵測不穩定事件影響因素各車統計-夜晚	214
表 6.2-3 車內駕駛分心行為偵測所需要的時間	221
表 6.3-1 建議「行車視野輔助系統」規格	223
表 7.1-1 各類型業者管理系統特徵彙整	225
表 7.1-2 整合資料庫主要欄位定義說明	231
表 7.1-3 分析模式與整合資料庫變數關係	233
表 7.2-1 三年期間 ADAS 警示資料分析欄位	234
表 7.2-2 路段被解釋變數之敘述性統計	236
表 7.2-3 趟次被解釋變數之敘述性統計	237
表 7.2-4 單一事件異常程度-事件分析被解釋變數之敘述性統計	237
表 7.3-1 周遭車流資訊、OBD 加速度對警示事件之事件分析模式	238
表 7.4-1 解釋變數之敘述性統計 (連續變數)	243
表 7.4-2 解釋變數之敘述性統計 (類別變數)	243
表 7.4-3 路段分析模式-警示事件推估結果	244
表 7.4-4 解釋變數之敘述性統計 (連續變數)	246
表 7.4-5 解釋變數之敘述性統計 (類別變數)	247
表 7.4-6 駕駛人排班趟次統計分布	247
表 7.4-7 發車時間之時段區分統計	247
表 7.4-8 趟次分析模式-警示事件推估結果	249
表 7.4-9 解釋變數之敘述性統計 (連續變數)	251
表 7.4-10 解釋變數之敘述性統計 (類別變數)	251
表 7.4-11 駕駛人排班趟次統計分布	252
表 7.4-12 發車時間之時段區分統計	252
表 7.4-13 事件異常程度普羅比模式校估結果	253
表 8.1-1 離型系統功能列表	260
表 8.2-1 各類型業者管理系統特徵彙整	270
表 9.1-2 與駕駛管理有關之行車異常事件、時空分析、高風險駕駛 行為改善措施及管理策略	281
表 9.2-1 與車隊管理有關之影像辨識影響因素、精進策略及管理策略 ..	283
表 9.2-2 與車隊管理有關之行車異常事件、時空分析、高風險駕駛	

行為改善措施及管理策略.....	283
表 9.3-1 與設備管理有關之影像辨識影響因素、精進策略及管理策略 ..	285

執行摘要

本 4 年期計畫旨在運用人工智慧分析技術，透過整合車內外影像與車機資料，以及結合現代先進駕駛輔助系統 (Advanced Driver Assistance System, ADAS)，針對駕駛運行車輛的狀態和行車異常事件進行判別與訓練。本計畫使用 ADAS 系統生成的警示事件解析行車異常事件，並從整合的資料集合中進行與道路交通環境的時空環境分析、關聯，據以評估駕駛行為。主要目標為探索容易發生行車異常事件的條件與情境，並支援業者和政府在營運安全與車隊管理提出實務策略。

行車異常事件原為學理上狹義之事故前兆，為與事故關聯性高的特定型態安全相關事件之子集合。而本計畫所定義之行車異常事件係為人工判斷車內外環境而得，研究人員會依據 ADAS 警示事件發生前後之行車動態、周圍車流環境及天候狀況等座車外行車異常事件之判斷；車內異常行為則依據駕駛員於警示發生前後之潛在分心行為以及警示發生後之處理方式做綜合判斷，最後再依據前述車外環境、動態及駕駛人的車內行為定義個別警示事件是否為異常。

本計畫使用國道客運業者 A 的 ADAS 警示紀錄，包含 FCWH 高速前車碰撞、FCWL 低速前車碰撞、LDWL 向左車道偏移、LDWR 向右車道偏移、SLDW 嚴重車道偏移、SDW 0.4 未保安全距離 0.4、SDW 1.2 未保持安全距離 1.2 等 7 種警示。而車內異常行為定義為與行車異常事件異常程度具有關聯性之駕駛潛在分心，包含雙手離開方向盤、單手離開方向盤、軀幹移動 (身體前傾)、軀幹移動 (身體右傾)、擺頭、操作車內設備、拿東西、用手機 (手持)、手靠近嘴巴 (飲食或抽菸) 等 9 種。

前 2 期計畫著重於分析與整合車內外行車資料，以了解 ADAS 警示事件特性與確立車內外行車異常事件之判斷模組。第 1 年期計畫著重在影像辨識模組開發與訓練，使用客運環景錄影資料，比對車輛運行的動態資料與車機資訊，並透過人工辨識確立行車異常事件，再進行大量影像訓練以建立車外行車異常事件判斷模組。第 2 年期計畫擴展至車內影像應用，開發能辨識駕駛狀態並分析其行為的車內外行車異常事件判斷模組，擴展並完善行車異常事件資料集合。

本(第3年)期計畫成果包含車內外行車異常事件行車影像辨識工具之建立，藉由所建立之行車影像辨識工具分析車內外行車異常事件，且定義行車異常事件/高風險駕駛行為之風險指標，篩選出更具事故風險之高風險駕駛行為事件，同時藉由車內外行車影像資料分析篩選行車異常事件，並透過增加樣本及引進新技術，優化影像辨識技術，探討影響行車異常事件/高風險駕駛行為發生之影響因素及好發情境，及進行巨觀、微觀之時、空間特性分析，最終提供業者教育訓練、安全管理及路權機關安全改善策略擬定之參據。

本期計畫為完整建立高風險駕駛行為模式供客運業者參考，有鑒於各家業者之資料完整度有所不同，故針對客運業者導入之系統及對應所能得獲取之資料，將其分為四類管理系統類別進行分析。第1類僅使用車機系統 (On-Board Diagnostics, OBD) 和全球衛星定位系統 (Global Positioning System, GPS) 資料，主要分析 OBD 和 GPS 紀錄的欄位；第2類在此基礎上增加了 ADAS 資料，可進一步分析前方車距情況；第3類則加入駕駛員監控系統 (Driver Monitoring System, DMS)，透過車內攝影機針對駕駛員行為 (如使用手機、分心行為等) 進行更深入的管理與資料分析；第4類整合前3類管理手段，並加入對外部環境分析，如周圍車輛狀況、道路線型、天候等，進行更全面的高風險駕駛行為分析。

第1期計畫共篩選200趟次之資料，2,524個警示事件，其中有193個事件有駕駛分心行為；第2期再加入150趟次資料，篩選出1,704個警示事件，其中349個事件有駕駛分心行為，然而因部分動作數據不足以定義高風險駕駛行為，本期計畫進一步向業者索取15台車、383趟次資料，共計8,984個警示事件。

本期計畫為定義高風險駕駛行為，設計一套混合計量經濟與機器學習方法之模式，藉由將各類管理系統類別可獲取之變數運用計量模式篩選顯著變數，並對連續變數使用機器學習模式中的提升迴歸樹模式 (Boosted Regression Tree, BRT) 進行類別化，辨識其引起異常的門檻值；其後將類別化後的變數重新放入計量模式中，建立高風險駕駛行為的機率模式；最後，在不同情境下組合機率並進行風險程度標準化，計算相對風險值和各變數的高風險比例，據以辨識高風險情境。縱向警示部分，

本期計畫納入 SDW 0.4 前方車距警示和 FCWH 前方碰撞警示，涵蓋本車變換車道和前車變換車道兩種情境，而橫向警示則包括 LDW 車道偏離警示和 SLDW 嚴重車道偏離警示，分別針對本車行駛於國道全線（含匝道）和國道主線兩種情境。

分析結果顯示，不同情境會對應不同高風險駕駛行為組合。縱向警示中，本車變換車道和前車變換車道的高風險駕駛行為與車距、駕駛員年資、駕駛手部行為有關；橫向警示中，行駛於國道全線（含匝道）的高風險駕駛行為與車距、駕駛手部行為（潛在分心）相關，而在國道主線情境下，則與車距、駕駛員年資有關，此結果可提供客運業者做為及時介入進行駕駛員行為管理、建立風險管控或強化教育訓練等各項安全管理措施之參考，並依照 4 類不同管理系統類別尋找對應之管理項目。值得注意的是，各情境下需特別關注之項目皆至少需利用 ADAS 系統資料方能完成辨識，因此，若客運業者希望建立更完整的高風險駕駛行為管控機制與工具，至少須導入 ADAS 系統，及建立相關資料存取、處理及分析功能。另透過本期計畫可得到之變數項目得知，在大部分警示事件及行車異常事件下，第 3 類管理系統類別已足以辨識高風險駕駛行為並達到適當之成效水準。

本期計畫建立高風險駕駛行為評估模式，以驗證該模式是否能正確應用於預測警示事件是否會發展為行車異常事件。在模式驗證中，透過盒鬚圖資料分布將縱向警示的切分點設定為機率預測值 0.39，橫向警示的切分點為機率預測值 0.2，利用此切分點能將大部分警示事件分為行車異常事件和非行車異常事件。此外，警示鏈分析針對新增的 FCWH 和 SLDW 兩種警示進行，發現序列規則變化較前期計畫多，且各種情境下的行為組合更為複雜，縱向警示事件是否會發展為行車異常事件之關鍵在於警示後的行為，而橫向警示事件則與警示當下的動作有關，其中以「拿東西」的行為最為顯著。

本期計畫在影像辨識部分以深度學習技術為基礎，透過增加樣本及引進新技術，精進前期計畫發展之車內外影像辨識與駕駛行為分析工具。在車外影像辨識方面，針對偵測不穩定事件進行情境分析和模型測試，車外物件偵測不穩定的因素歸納包括日夜間影像過曝、水珠或地面反光、

濃霧視野不清、角度變換和紋理干擾等；在車內影像辨識方面，車內關節點偵測不穩定的因素包含夜間 IR 影響、車內光線不足、駕駛衣著色彩較單一難以區分、難辨識的駕駛動作、部分身體部位遮蔽，以及副駕駛座有乘客且特徵較駕駛明顯等；在車內外影像辨識技術方面，對新型物件偵測模型：YOLOv7、YOLOv8 和 ViTPose 進行實驗比較，結果顯示，YOLOv7 和 YOLOv8 的辨識正確度與辨識速度相近，而 ViTPose 則具備較準確的辨識結果，但需較長的辨識處理時間，建議可從「辨識正確度」或「辨識速度」的使用需求，選擇相對應的辨識方法。

本期計畫之時空分析探討在第 1 至 4 類管理系統可取得不同完整度等級資料的差異下，客運業者得以從巨觀至微觀分析的時空特性態樣，並納入高風險駕駛行為，以路段、趟次、事件等多個層面，探討行車異常事件與高風險駕駛行為之好發情境，可提供道路主管機關及客運業者更全面的行為資訊與相對應之管理意涵。資料樣本包含前 2 期計畫已蒐集 350 趟次國道客運行駛路線外，再增加本期計畫所取得同業含臺北（或板橋）往返臺南（或高雄）8 種路線組合近 400 趟次之警示事件資料。

第一類以 OBD 資料為基礎之高風險駕駛行為時空分析部分，以隨機單一趟次為樣本發現，大部分 OBD 資料在加速度有觸及門檻的時間點前後幾分鐘內，幾乎都有警示事件發生，但並無 OBD 一觸及門檻後，警示事件隨即發生的狀況，第一類資料主要係以無 ADAS 資料前提下可進行之高風險駕駛行為之條件分析與管理，後續應可透過既有的 ADAS 資料，再與此些 OBD 資料由觸發高風險門檻之紀錄，兩相比對是否有關連性，以分析此些高風險駕駛行為好發於何些時空環境；而第 2 至 4 類以 ADAS 資料為基礎之高風險駕駛行為時空分析部分，透過路段、趟次、事件分析，結果發現車流量大、服務區、時段性差異（假日、方向等），可能因交織情形多，駕駛員本身就會更加注意而發生較少警示事件，另業者排班時若再一定時間內派班越多，從趟次模式中發現發生警示事件的次數也較多，後續亦可藉由以「司機」為分析單位的新架構，更深入了解個別司機的駕駛特性和行為模式，為公司提供更具鑑別性的教育和管理方針。

本期計畫針對現今運輸業者在車隊管理中所面臨的問題，包括難以控制駕駛行為、處理龐大資料成本高昂、難以量化風險值等，提出以 AI

辨識和車載系統資料為基礎的管理平台雛型系統，此系統透過識別行車異常事件並計算風險值，期望能節省大量處理資料的時間和人力成本，更能量化行車異常事件的風險值，協助運輸業者更有效率地執行車隊管理。所設計之介面分為 4 個部分，包含首頁呈現所有駕駛的行為報表、各駕駛表現的綜合報表、關注特定事件的行車異常事件報表以及進行行車影像風險分析，這些介面提供不同層次的資訊，讓業者能快速找出高風險駕駛並優先處理，進一步做出管理策略。這套雛型系統不僅有助於業者節省資料處理成本，也提供了一套全面的駕駛風險分析工具，讓業者能更有針對性地改善高風險駕駛行為，提升整體車隊管理效率。

本期計畫最後統整本期與前 2 期計畫成果，分別由駕駛管理、車隊管理、設備管理 3 個面向，提出客運業者安全管理之影響因素及相關改善與管理策略建議，供客運業者參考。在駕駛管理方面，建議業者透過課程、評分機制和個人管理 3 個層面改善駕駛行為，包括教育訓練、定期評分、強化衣著與個人習慣等，相關教育訓練手冊和流程建議應融入安全設備操作、ADAS 警示提醒及應對作為、不可有之違規舉動，並針對不同駕駛員提供路線和交通環境相關的課程，強調良好的個人、駕駛習慣，並加入業者內部的評分獎懲制度，達到實際落實教育訓練成果之目的；在車隊管理方面，著重車內管理和後臺管理，車內管理包括車內設備、監控系統和座艙特性，而後臺管理則需建立有效的後臺電腦和資料庫系統，包含運用 ADAS 警示之風險門檻值、影像辨識之車內外行為指標與本期計畫開發之雛型系統，做為車隊管理中重要項目；在設備管理方面，分為購買和安裝兩個層面，購買時需注意攝影影像資料和車機系統的規格、整合程度和維修更新，安裝時需考慮設備位置、功能和防水，以確保設備正確運作且不影響駕駛員。

第一章 緒論

1.1 計畫緣起

依據統計，我國 111 年全年發生 375,844 件道路交通事故 (A1 及 A2)，共計造成 3,064 人死亡、498,887 人受傷 (以事故發生 30 天內死亡為計算基準) (道安資訊查詢網，2023)，近年道路交通事故件數與傷亡人數持續上升。為改善道路交通安全，交通部運輸研究所 (後簡稱本所) 歷年辦理易肇事路段改善，以及推動運輸業安全管理系統等計畫，然而受限於資料取得困難，此等計畫安全改善績效及相關分析往往以事故件數、死亡人數、受傷人數等呈現安全水準，並據以找出應強化改善的環節，惟因事故屬高度隨機的稀有事件 (rare event)，且此類型之落後指標 (lagged indicator) 難以有效分析評估駕駛之安全性。

事故的發生，往往肇因於人、車、路、環境等多重因素交互影響下造成之不幸結果，其中「人」必須擔負所有資訊接收、解讀、判斷、決策與執行，為行車安全最重要的關鍵環節；此外，歷年事故多以未注意車前方、未依規定讓車、未保持行車安全間隔、變換車道或方向不當等人為因素為主要肇因者，約占全國交通事故死亡人數之 70% 以上，顯見「駕駛人行為分析」在整體事故預防之重要性，而由運安會所調查之事故報告亦可看出，國內大型車發生重大事故肇因與駕駛年資、駕駛車內行為、天候情況、道路線型等有關，若能透過行車資料，了解不同路況可能導致的不安全駕駛行為，在行車前提供給駕駛相關注意，即有可能避免類似事件發生。甚至可透過相關資料的蒐集、整理與分析，做為職業駕駛人初訓或定期訓練的參考資料，亦可提供一般駕駛人參考，以預防同樣類型不安全駕駛行為的發生，進而降低交通事故發生的可能性。

近年來，隨著科技進展，各國陸續以自然駕駛 (naturalistic driving) 為題，透過在車輛上裝設各項偵測設備，長時間蒐集駕駛人在「自然」狀態下的駕駛行為，並透過其於行車過程中發生的失誤或偏差等領先指標 (leading indicator) 之監控，分析駕駛人的行為模式，以達到安全管理之目的。以美國運輸部公路安全署 (US National Highway Traffic Safety Administration of DOT, NHTSA) 與維吉尼亞理工學院運輸中心 (Virginia

Tech Transportation Institute, VTTI) 負責執行 100-car 計畫為例，該案募集於車輛上裝設各種儀器，蒐集大規模真實駕駛行為資料，期能透過對駕駛行為的深入探討，了解駕駛人在行車過程中的各項行為特性，做為研提事故預防策略的基礎。

本所於 107 年辦理「駕駛行為分析工具開發及行為特性探討」，透過在營業大客車之各項智慧車載系統 (包含 OBD II、ADAS 等) 蒐集車輛速度、警示事件等資料，並以所蒐集的 100 個旅次的自然駕駛行為資料為例，針對國道客運業者進行本土化指標與門檻值之建立、高風險駕駛行為過濾分析、駕駛人特性分析、計算駕駛人安全分數，並初步開發駕駛行為分析工具，供業者進行駕駛人安全診斷，並於 108 年「應用車聯網與先進駕駛輔助系統於我國公路公共運輸行車安全」計畫案，於基隆地區車聯網實驗場域建置結合先進駕駛輔助系統 (Advanced Driver Assistance System, ADAS)，以提升公路公共運輸車輛在行經高速公路與市區號誌化路口之行車與行人交通安全。

另交通部已將「臺灣地區易肇事路段改善計畫」列為長期性之任務，並委由本所負責規劃，此計畫目的在於降低都市及一般公路易肇事路段交通事故之傷亡人數與發生次數，並自 69 年開始辦理第 1 期計畫，迄今至 112 年底，已完成 40 期計畫，除此之外，各縣市政府針對轄管道路亦會自行規劃各項改善計畫。此類道安改善工作雖係以每件事故發生位置為基礎探討事故發生的集中性，並透過統計事故發生頻率及嚴重程度等篩選出易肇事路段/路口，然而因其所篩選出的熱區往往必須多起事故發生後方得進行各項資料分析、處理，無法在事故發生前預先篩選出潛在地點；再者，易肇事路段篩選過程中，僅能就事故本身紀錄之人、車、路、環境及各項碰撞型態等資料進行分析，及研判事故發生肇因，無法實際得知駕駛人於該地點的真實行為。

為達到事先防範、預先改善之目的，必須從日常車流、駕駛行為當中，預先定義出與事故發生具有高度相關的事故前兆 (precursor) 或高風險駕駛行為，並從行為層面篩選駕駛人出現高風險駕駛行為的好發熱區與情境，進而依據不同類型之高風險駕駛行為研提改善方案；日本國土交通省為改善沖繩地區外國觀光客自駕事故頻仍的狀況，透過與當地租車

公司合作蒐集車載 ETC2.0 及行車紀錄器，抽樣調查自駕觀光客緊急剎車、突然加速、突然轉動方向盤等動作的所在場所，再以此做為基準分析不同國籍之行為特性，掌握「某些特定國家或地區的人，容易在某些地方發生特定類型車禍」，然後用該國語言在該地進行宣導。

此外，分心與疲勞是發生事故的主要車內原因，國內 111 年 5 月發生一起大貨車追撞工程車事故，造成工程車駕駛與同車作業員死亡，經警方調查後發現駕駛係因低頭滑手機分心肇事。2016 年日本一輛觀光大客車在途經長野縣與群馬縣交界附近的國道 18 號時突然失控，衝向對面行車線，隨後撞斷護欄墜落懸崖，造成 15 個乘客死亡、26 人受傷，調查後發現大客車公司除了發車前沒檢查駕駛的健康狀態，亦忽視駕駛連續駕駛時數限制。此外，駕駛抄捷徑，違法行駛未經審查之路線，以致疲勞駕駛狀態下，在不熟悉路線的危險路段無煞車墜落懸崖。若能在駕駛有分心或疲勞的狀態發生時，提供駕駛或行車中心警示，有可能避免事故之發生。

鑑於各項行為特性對駕駛行為分析與安全管理之重要性，同時奠基於近年 ADAS 系統普及與影像辨識技術發展，本所於 110 年起辦理「應用人工智慧分析技術探勘高風險路段」4 年期計畫，旨在協助客運業者提升自主安全管理能量，善用各項資料與分析技術，有效找出安全管理之關鍵環節與提出適當之對應策略。本 4 年期計畫於 110 年與 111 年分別辦理「應用人工智慧分析技術探勘高風險路段 (1/4) -駕駛行為模式研析及車外行車異常事件影像辨識技術開發」、「應用人工智慧分析技術探勘高風險路段 (2/4) -車內行車異常事件影像辨識技術開發」計畫案（後稱前期計畫），就營業大客車在國道交通特性蒐集大量自然駕駛資料，初步發展本土化高風險駕駛行為指標，及應用行車影像開發車內、外行車異常行為/事件影像辨識技術。另前期計畫自 3,677 個警示事件當中，篩選出 5,273 件車內行車異常行為並分析好發情境，研究結果顯示，大客車駕駛人經常出現單手離開方向盤的動作，其中又以右手離開方向盤對安全影響較大；另在不同行車動態下，駕駛出現特定動作組合時，極有可能造成行車異常事件之發生，例如在本車車道偏移時，當駕駛有身體前傾、雙手離開方向盤、拿東西等無法即時適當控制車輛的動作，容易發生行車異常事件；在好發情境分析上，車內行車異常行為對警示事件、行車異常

事件的發生造成顯著正向之影響，而在特定時空環境下，例如大彎道、上坡等，亦會出現較多車內行車異常行為。前面兩期計畫已辨識與行車異常事件有關之車外環境與車內行為，然為協助業者進行車隊及駕駛管理，本期進一步優化高風險駕駛行為分析工具，研提不同等級高風險駕駛行為事件所對應之指標與門檻。

綜合言之，本計畫之目標在將目前以事故資料為基礎的道路交通安全管理程序（圖 1.1-1），提升為以事故資料、行車異常事件以及駕駛行為為基礎的道路交通安全管理程序（圖 1.1-2），以達事故預防與零死亡重傷之長期目標。

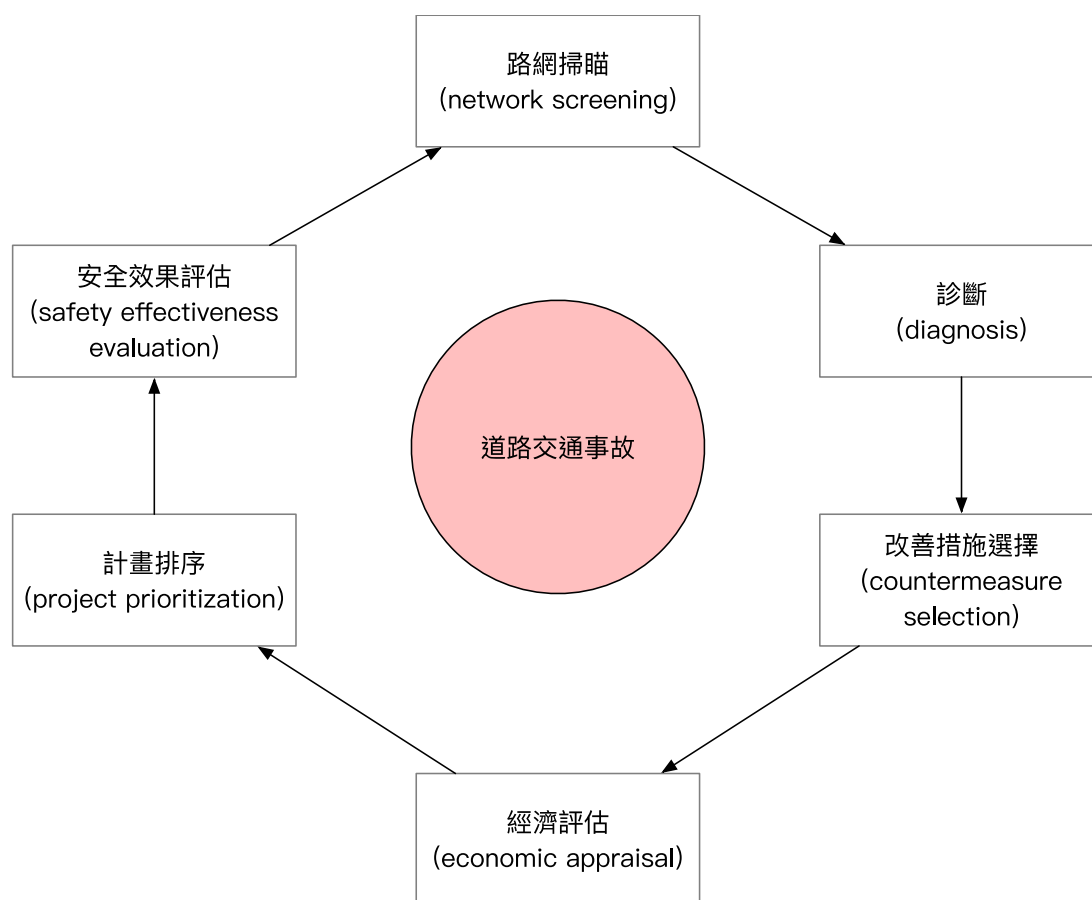


圖 1.1-1 以事故為基礎之道路交通安全管理程序

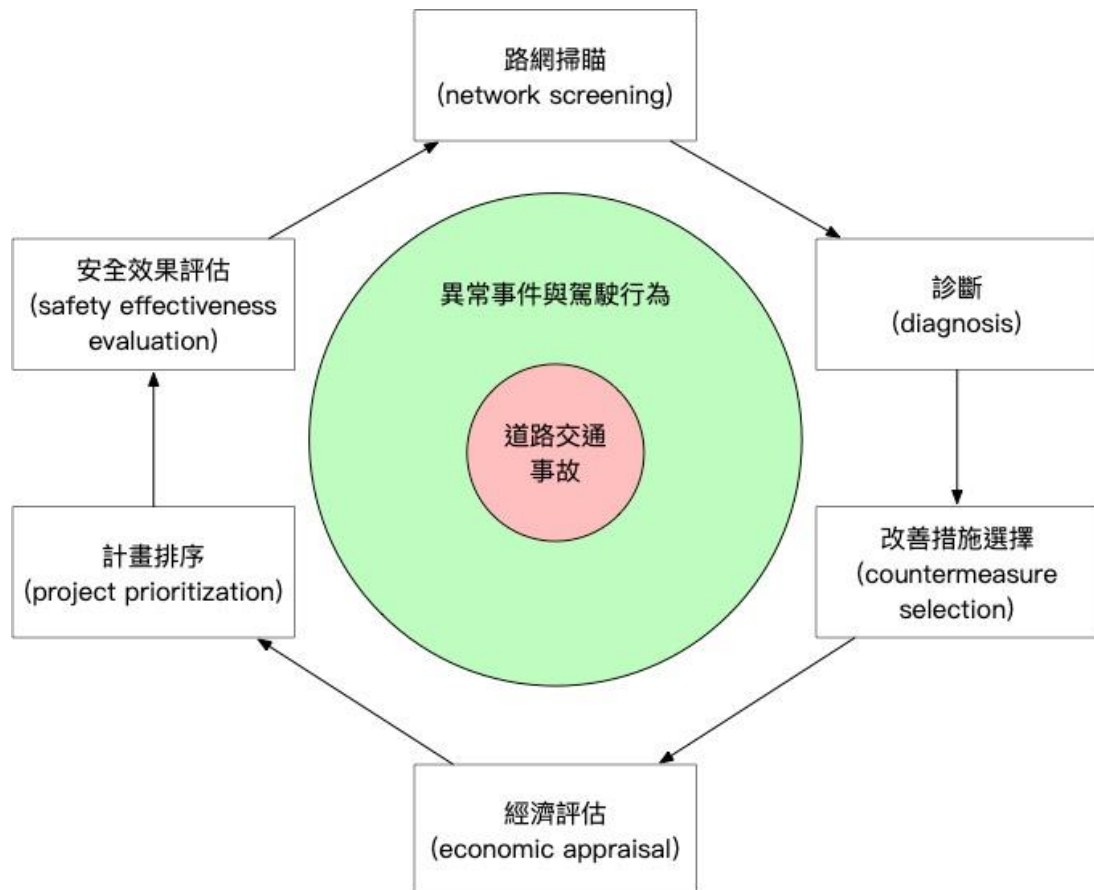


圖 1.1-2 以事故、行車異常事件與駕駛行為基礎之
道路交通安全管理程序

1.2 計畫目的

本計畫為 4 年期計畫，主要計畫目的如下：

- (一) 奠基於近年已逐漸發展成熟的各項智慧車載系統，以本所 107 年度「駕駛行為分析工具開發及行為特性探討」、110 年度「應用人工智慧分析技術探勘高風險路段 (1/4) — 駕駛行為模式研析及車外行車異常事件影像辨識技術開發」、111 年「應用人工智慧分析技術探勘高風險路段 (2/4) - 車內行車異常事件影像辨識技術開發」計畫案成果為基礎，持續蒐集自然駕駛資料，包含在既有車種、業別及營運環境(國道客運)下增加資料蒐集區間、樣態。
- (二) 應用影像辨識技術，藉由車內行車影像資料分析篩選行車異常事件，進而做為駕駛行為分析工具優化之基礎，據以篩選出可能造成事件及事故風險的高風險駕駛行為。

- (三)深化自然駕駛資料之應用，透過整合空間資訊，例如以 GPS 定位資料整合各路段坡度、車道數、速限、曲率及車流資料 (如各路段平均車速) 等，以大數據分析、資料探勘之技術探索高風險駕駛行為/事件之特性。
- (四)以自然駕駛行為資料及駕駛行為分析工具為基礎，探索各類高風險駕駛行為或行車異常事件的空間集中性，找出駕駛人高風險駕駛行為的好發路段、地點與情境，改善過去易肇事路段受限於道路交通事故稀少性、隨機性及事後改善之狀況，提升道路主管機關對易肇事路段事先防範能量之目的。
- (五)從事後預防角度，針對透過事故資料所篩選之易肇事路段，整合駕駛行為分析、空間、時間及各項環境狀態等資料，可由行為角度深入解析事故發生成因，並據以研提各項工程、教育、執法等不同層面的改善方案，做為主管機關改善道路交通安全及運輸業者強化駕駛人管理之基礎。

1.3 計畫範圍

本計畫以前期 (111 年) 計畫為基礎，回顧國內外文獻，針對國道環境，分析國道客運駕駛本身駕駛行為，同時結合空間資訊預測高風險路段。本期計畫主要為完成行車異常事件行車影像辨識以高風險駕駛行為分析工具，並藉由所建立之行為分析工具分析行車異常事件之好發特性。

1.3.1 四年期計畫關係

本 4 年期計畫：「應用人工智慧分析技術探勘高風險路段」，係透過車內外影像與車機資料，並結合現今科技發展之 ADAS 系統 (例如 Mobileye)，針對駕駛運行車輛時之狀態與行車異常事件進行判別與訓練。藉由前述各類資料，以 ADAS 系統產生之警示事件解析行車異常事件，再從綜整建立之資料集合中進行與道路交通環境資料之時空環境分析、關聯，以及駕駛行為之評估，探索容易發生行車異常事件之條件與情境，並供業者、政府在營運與管理上能有實務上之策略與幫助。

前期計畫著重於車內外行車資料之整合，以確立 ADAS 警示事件資料與駕駛實際有操作錯誤之行車異常事件之分辨能力，藉由客運環景錄影資料，獲得車輛外部周遭之影像。第 1 年側重於影像辨識模組開發訓練之產出，將車輛運行之動態資料偕同車機資訊，與 ADAS 警示事件資料進行比對。由於 107 年計畫車隊之 ADAS 主要透過 Mobileye 以 TTC 之時間大小做為警示標準，難以直接分辨是駕駛因素或外在因素觸發告警，因此本次四年期計畫透過人工辨識一定數量趟次，先確立行車異常事件，再供影像訓練進行大量驗證以建立可行之車外行車異常事件判斷模組。第二年期則增加車內影像之應用，開發能辨識駕駛狀態與分析其行為的車內、外行車異常事件判斷模組，最後擴展大量且完善之行車異常事件資料集合。

至此，以既有車輛行車異常事件資料基礎，結合道路幾何與天候資料獲得之特性，可針對行車異常事件及交通事故之時空與交通環境、駕駛行為進行初探分析，並針對計數模式 (count model) 進行細節之校估與定式之建立，確立行車異常事件以及交通事故資料，探索關鍵影響因素並兩相比對。同時，隨著駕駛人資料與行為加入，能針對駕駛行為探勘並分析，除可評估駕駛績效外，或可擷取適當時長，分析好發行車異常事件種類與時序組合。第 3、4 年找出行車異常事件及高風險駕駛行為，最後應用地理資訊系統等技術，探討高風險駕駛行為/行車異常事件的空間特性。

在各項模組成熟之餘，可從客運業者取得一定車輛發生事故的錄影與車機資料，以個案分析方式進行事故鏈分析模組化，與行車異常事件判斷模組進行比對，確認是否一定項目的行車異常事件，與發生事故之結果有關聯，能較行車異常事件與交通事故之關聯分析模組獲得更微觀的駕駛行為影響之資訊，並可驗證行車異常事件判斷模組確實可實際應用。最後，由行車異常事件、交通事故以及駕駛特性之關聯與模式模組所得結果，將可提供營運公司訓練要求員工、政府部門策略改善道安。

本計畫預期主要研究成果包含：ADAS 系統之組成與規格，除了攝影設備所需之規格標準外，擬著重於將行車異常事件判斷模組功能加入系統，結合道路幾何、天候、交通特性及設施特性等，找出高風險路段所

具備特徵；透過駕駛風險指跡研究，找出異常駕駛序列風格及風險等級，結合時空分析特性，得到異常駕駛行為之好發情境，可監督駕駛行為並供客運公司建構車隊安全管理系統。最終，結合地理資訊系統等相關技術，將可進行行車異常事件時空與交通環境之分析應用，探討高風險駕駛行為之特性。

本團隊針對此 4 年期計畫之整體構想繪如圖 1.3-1 所示，分年研究重點則整理如表 1.3-1 所示。

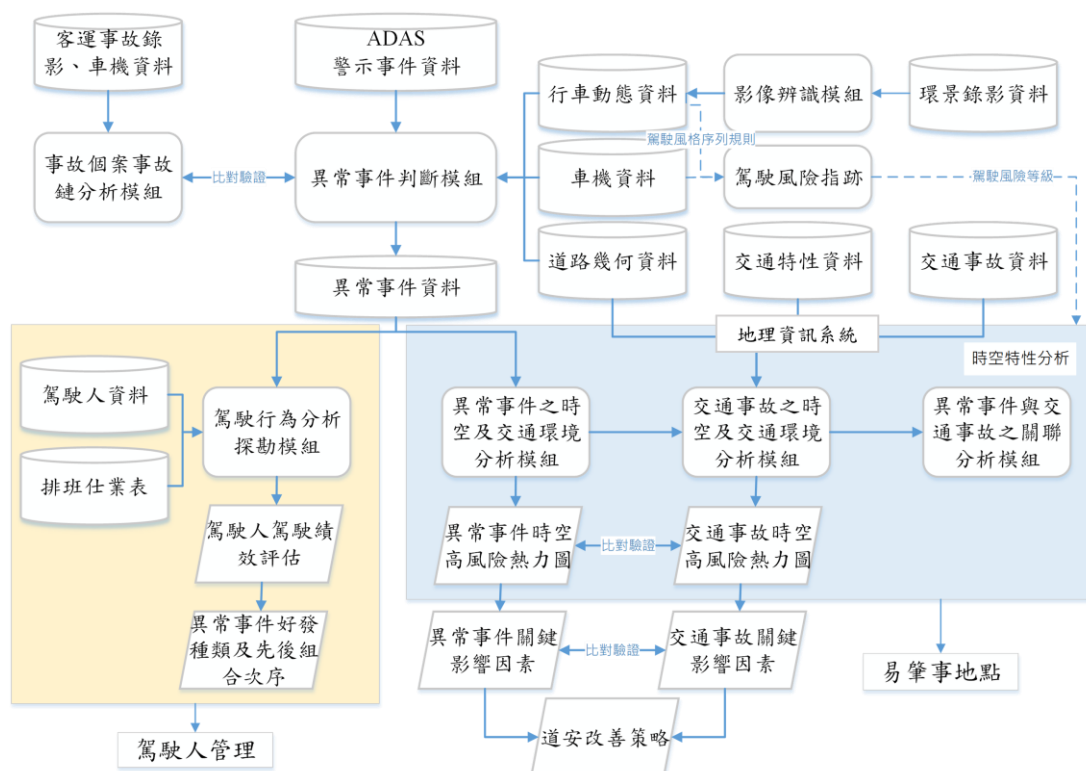


圖 1.3-1 整合模組架構

表 1.3-1 分年研究重點彙整

模組	第一年	第二年	第三年	第四年
行車異常事件判斷	1.國道客運 2.車外影像 3.車外行車異常事件	1.國道客運 2.車外 + 車內影像 3.車內分心事件	1.國道客運 2.車外 + 車內影像 3.各類型行車異常事件	1.國道客運 2.車外 + 車內影像 3.行車異常事件待定
影像辨識	1.車外影像 2.影像品質分析 3.車外攝影設備規格標準	1.車外 + 車內影像 2.影像品質分析 3.車內攝影設備規格標準	1.車外 + 車內影像 2.影像品質關鍵影響因素分析	1.車外 + 車內影像 2.攝影設備規格標準 3.操作手冊
事故個案事故鏈分析	1.國道客運 2.事故鏈定序	-	1.國道客運 2.事故鏈定序	-
行車異常事件之時空及交通環境分析	國道客運(初探)	國道客運(定式)	國道客運(定式) (含大型車計畫資料 ²⁾)	國道客運(定式)
駕駛行為探勘分析	國道客運(初探)	國道客運(定式)	國道客運(定式)	國道客運(定式)
交通事故之時空及交通環境分析	國道(初探)	國道(初探)	國道(定式)分析工具優化	國道(定式)分析工具完成
行車異常事件與交通事故之關聯分析	-	-	國道	國道

註 1：主要研究成果含 (1) ADAS 系統組成及規格 (含攝影設備規格標準、行車異常事件判斷模組功能)；(2) 駕駛及車隊安全管理系統 (含駕駛行為探勘模組功能)；以及，(3) 行車異常事件資料集合及大數據運算設備之組成及規格 (含行車異常事件時空及交通環境分析模組功能)

1.3.2 本期計畫架構與流程

本期計畫研究流程關係如圖 1.3-2 所示，工作項目包含：(1) 摘要說明前期(包含 107 年計畫)；(2) 文獻回顧及高風險駕駛行為分析架構之建立；(3) 高風險駕駛行為分析工具優化；(4) 行車異常事件及高風險駕駛行為特性分析以及(5) 管理應用策略研析。

高風險駕駛行為指標及其特性分析將於本年度完成，整合前期完成辨識且結果較佳之車外及車內影像、道路幾何及車流動態資料，討論外在環境對駕駛分心行為的影響，及導致行車異常事件發生之關聯性架構。亦針對前期辨識結果較差之樣本，考量新型影像辨識軟體之可行性；針對樣本數較少之警示事件，考量增加樣本之可能性。以期建立行車異常事件/高風險駕駛行為之指標與門檻，整合資料集合找出行車異常事件/高風險駕駛行為之樣態與其空間特性等，最後提供業者駕駛人管理及主管機關易肇事地點管理。

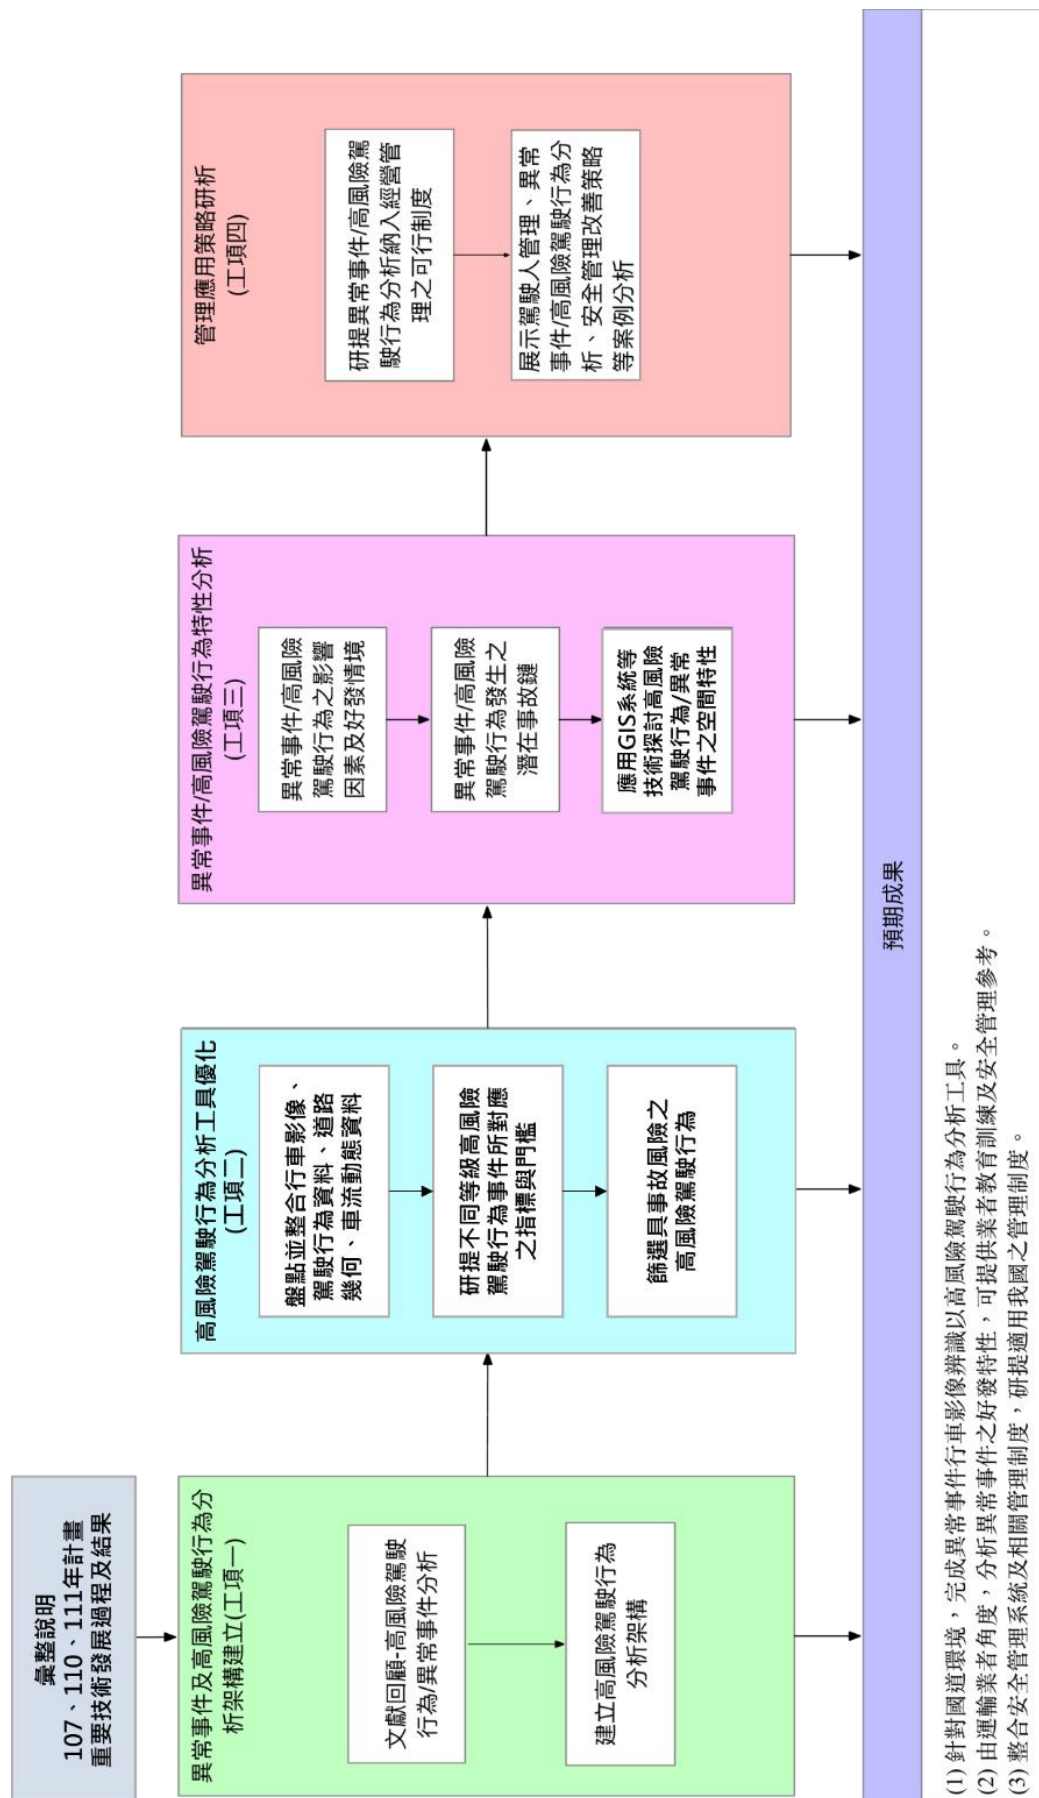


圖 1.3-2 本期計畫流程圖

第二章 文獻回顧

2.1 前期計畫回顧

透過前期計畫成果回顧，能夠讓本期計畫補足過往研究缺口，也能夠以前期計畫為基礎進行後續研究之延伸探討，以下將分別針對「駕駛行為分析工具開發及行為特性探討」案、「應用人工智慧分析技術探勘高風險路段 (1/4) - 駕駛行為模式研析及車外行車異常事件影像辨識技術開發」案、「應用人工智慧分析技術探勘高風險路段 (2/4) - 車內行車異常事件影像辨識技術開發」案來進行相關回顧。

2.1.1 「駕駛行為分析工具開發及行為特性探討」案

吳昆峯等 (2020) 首先透過相關文獻回顧，了解國內外現行安全駕駛行為管理之方法，以及常用指標之相關定義、門檻值與所需之設備；並透過與業者的訪談及問卷調查，進一步掌握車載資訊設備之應用成效與需求。最後以所蒐集 100 個旅次的自然駕駛行為資料為例，針對國道客運業者進行本土化指標與門檻值之建立、危險事件分析、駕駛行為特性分析、安全駕駛行為分數與班表變數相關分析、危險事件與班表變數相關分析，並初步開發駕駛行為分析工具，提供業者進行駕駛人安全診斷之便利，以協助業者在進行安全駕駛行為管理方面，達到預防事故發生之終極目標，亦可做為政府政策規劃以及業者裝載車機設備之參考依據。

在整理過去各類危險事件的指標型態、偵測設備中，發現若要偵測不同危險事件所需之偵測設備皆不盡相同，在業者資本與人力資源皆有限的情況下，無法同時偵測並驗證所有的危險事件，因此業者在挑選欲採用之駕駛人安全駕駛行為指標時，須從自家駕駛員常發生之事故類型、事故地點著手，並找出相關之指標。

為掌握車載資訊設備之應用成效與需求，此計畫進行了業者訪談及問卷調查，根據結果可以得知，目前國內客運業者普遍都裝設有 GPS 系統與數位影像紀錄器，然而僅有少數業者有裝設 ADAS 與 OBD II。且由於 GPS 系統與數位影像紀錄器可掌握之資訊有限，因此國內業者運用於

道路安全管理之指標仍停留於事故數、違規數、投訴件數等落後指標，造成管理成效相當有限。若有裝設 ADAS 系統，則可進一步偵測如：急加急減、車道偏移、未保持安全距離等指標，然而該設備之操作複雜且容易故障，維護成本過高，導致許多業者不願裝設 ADAS 系統；受限於目前客運業之收入及獲利成長有限，此高固定成本系統之導入仍需要相關誘因機制。

在本土化指標及門檻值部分，有裝設 ADAS 與沒有裝設 ADAS 的各種指標組合比較下，有裝設 ADAS 之指標其真陽性率與 ROC 值效力明顯優於沒有裝設 ADAS 之指標，顯見 ADAS 確實可提升危險事件偵測的準確度。

自然駕駛資料分析部分，目前國內業者雖已陸續裝設車載資訊系統，但仍缺少適用於國內的駕駛人評分標準與方法來衡量行車表現，以致無法發揮系統的最大功用。因此此計畫以 ADAS 系統為基礎，發展適合國內之本土化指標與門檻值，並考量各家業者裝設車載資訊系統之不同等級進行分類，探討各類管理方式所能應用之駕駛人安全駕駛行為考核方法。

駕駛行為分析工具之開發部分，此計畫所定義之危險事件包括：超速、彎道超速、車距過近及車道偏移等，因應駕駛行為資料完整等級 (Level 1~Level 4) 及事後驗證與否等情境，此計畫開發了一套駕駛行為分析工具，以利客運公司管理者及駕駛員透過圖形視覺化表達方式，掌握危險事件的人事時地物資訊 (人：駕駛員、事：好發的危險事件類型與件數、時：好發的時間及趟次、地：好發地點的道路類型與行向、物：好發的環境背景，如雨天及交通狀況)。管理者可將此系統做為駕駛人回訓作業規劃之用，亦可做為駕駛人獎懲之依據。同時，駕駛人也可以透過此系統了解自身危險駕駛件數 (或比率) 相對於其他駕駛的狀況，俾利行為之掌握與矯正。為便利運輸業者應用，此計畫以 Excel 介面開發駕駛行為特性分析及駕駛人之行車安全診斷工具。

2.1.2 「應用人工智慧分析技術探勘高風險路段 (1/4) -駕駛行為模式研析及車外行車異常事件影像辨識技術開發」案

107 年度「駕駛行為分析工具開發及行為特性探討」雖已成功透過駕駛行為資料優化高風險駕駛行為分析模式，然而其過程尚未建立駕駛行為及行車異常事件之關聯性，因此行車影像須經由人工進行檢核，並藉由專家意見來判別各項警示事件是否屬於可能造成事故風險之行車異常事件，過程耗日費時，且僅能納入小規模樣本進行分析，難以廣泛應用。

有鑑於此，本所於 110 年起辦理「應用人工智慧分析技術探勘高風險路段」4 年期計畫，旨在透過蒐集車內外之行車影像資料、駕駛行為資料及 ADAS 系統產生之警示事件等，應用影像辨識技術取代前期計畫之人工判讀程序，據以從大量警示事件中有效篩選出具事故風險的行車異常事件，並探討此等行車異常事件的空間特性，進一步從駕駛行為角度探討其好發熱區，可做為「行為基礎」易肇事路段分析之依據。

110 年度為 4 年期計畫之第 1 年(駕駛行為模式研析及車外行車異常事件影像辨識技術開發)，主要聚焦於應用車外行車影像，從 2,558 件警示事件當中透過車外行車影像辨識技術篩選出 102 件行車異常事件及 485 件可能行車異常事件，並進一步整合自車機蒐集之駕駛行為資料、外部道路幾何及環境等資料，探索車外行車異常事件及可能行車異常事件之好發特性。車外行車異常事件之定義沿用吳昆峯等 (2020) 整理、歸納出之駕駛序列與定義，並精進行車異常事件內容。「未保持安全距離」、「車道偏移」、「匝道車速過快」之行車異常事件序列說明如下表 2.1-1 至 2.1-3，流程圖如圖 2.1-1 至 2.1.3。

表 2.1-1 前期研究未保持安全距離之序列分類

序列 1L/1R 前車由左/右變換車道	
1-1 且前車剎車	目標車輛之駕駛來不及反應，易形成追撞事故。
1-2 且目標車輛正在加速	兩車間的距離會急速縮小，易造成追撞事故的發生。
同時滿足 1-1 及 1-2	
序列 2 目標車輛向左/右變換車道	
2-1 且前車剎車	目標車輛之駕駛來不及反應，易形成追撞事故。
2-2 且後車正在加速 (未減速)	目標車輛未注意前車而正在加速或沒有煞車的動作，易造成追撞。
2-12 同時滿足 2-1 及 2-2	
序列 3 前車突然減速	
3-1 且目標車輛未剎車	兩車間的距離會急速縮小，易造成追撞事故的發生。
3-2 且鄰近車道有車輛	目標車輛若有向外閃避的動作，易造成與鄰近車輛擦撞。
3-12 同時滿足 3-1 及 3-2	
序列 4 前車等速行駛 (慢速)	
4-1 且目標車輛未剎車	兩車間的距離會急速縮小，易造成追撞事故的發生。
4-2 且鄰近車道有車輛	目標車輛進行變換車道的動作，若未注意鄰近車輛，易造成擦撞。
4-12 同時滿足 4-1 及 4-2	
序列 5 未注意前車的前車 = 前車向左/右變換車道且目標車與前前車距離過近	
5-1 且目標車輛未剎車	兩車間的距離會急速縮小，易造成追撞事故的發生。
5-2 且前前車突然剎車	目標車輛與前前車的距離會急速縮小，易造成追撞事故的發生。
5-12 同時滿足 5-1 及 5-2	
序列 6 前車向左/右變換車道且目標車與前車距離過近	
6-1 且目標車輛未煞車	若前車未順利變換車道至相鄰車道，且目標車輛正在加速或無煞車行為，易造成目標車輛與前車追撞。

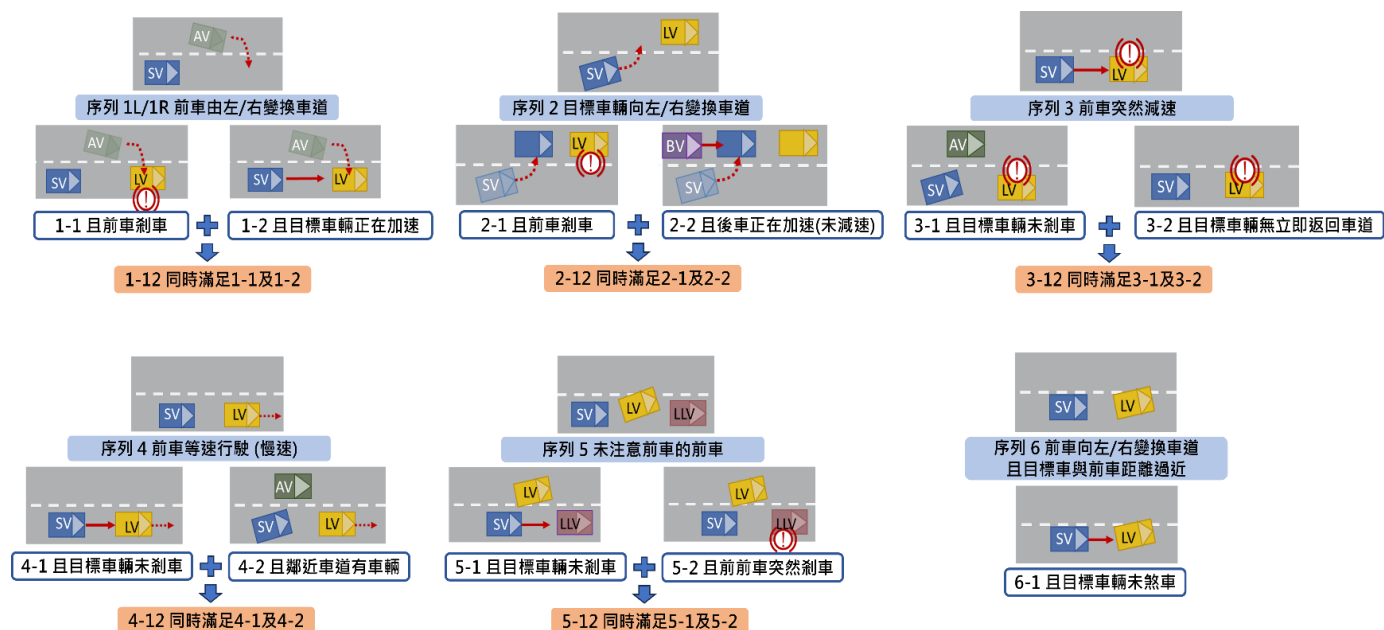


圖 2.1-1 前期研究未保持安全距離之序列分類流程圖

表 2.1-2 前期研究車道偏移之序列分類

序列 1 偏離車道	
1-1 且鄰近車道有車	鄰近車輛之駕駛來不及反應，易形成同向擦撞事故。
1-2 且目標車輛無立即返回車道	易形成同向擦撞事故或駕駛可能處於分心恍惚狀態。
1-12 同時滿足 1-1 及 1-2	
序列 2 因閃避動作而偏離車道	
2-1 且鄰近車道有車	鄰近車輛之駕駛來不及反應，易形成同向擦撞事故。
序列 3 匝道上偏移	
3-1 且鄰近車道有車	鄰近車輛之駕駛來不及反應，易形成同向擦撞事故。
3-2 且目標車輛無立即返回車道	易形成同向擦撞事故或駕駛可能處於分心恍惚狀態。
3-12 同時滿足 3-1 及 3-2	

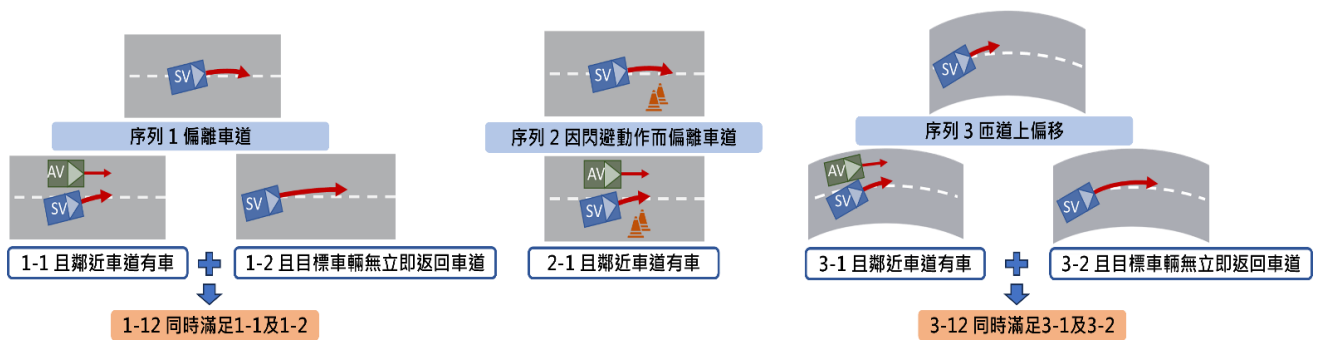


圖 2.1-2 前期研究車道偏移之序列分類流程圖

表 2.1-3 前期研究匝道車速過快之序列分類

序列 1 匝道未減速	
1-1 且鄰近車道有車	匝道未減速容易造成車道偏移與車輛失控，當鄰近車輛之駕駛來不及反應，易形成同向擦撞事故。
1-2 且正在下雨	天雨路滑更容易造成車道偏移與車輛失控
1-12 同時滿足 1-1 及 1-2	
序列 2 匝道超速	
2-1 且鄰近車道有車	匝道「超速」較「未減速」更容易造成車道偏移與車輛失控，當鄰近車輛之駕駛來不及反應，易形成同向擦撞事故。
2-2 且目標車輛未減速	匝道超速且未減速的情形下，其發生車道偏移與失控，甚至衝出路外或擦撞護欄的機率甚高。
2-12 同時滿足 2-1 及 2-2	

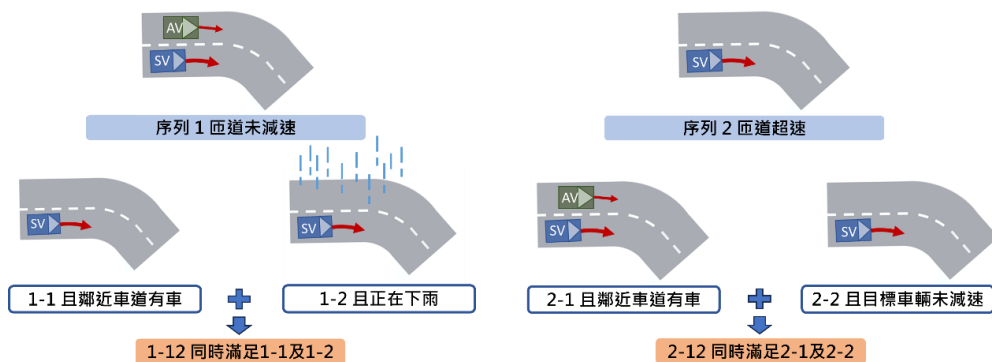


圖 2.1-3 前期研究匝道車速過快之序列分類流程圖

此計畫研究成果發現車速、爬坡段、天候、日夜、北上/南下、路肩寬、彎道、車種混合、交通量等因素會影響異常及可能行車異常事件發生的機率。此計畫成果可做為汽車運輸業者對轄下駕駛員進行安全管理之參考依據，在路權主管機關方面亦可做為評估道路安全改善之參考。

2.1.3 「應用人工智慧分析技術探勘高風險路段 (2/4) -車內行車異常事件影像辨識技術開發」案

以 110 年度對車外行車異常事件影像辨識技術開發成果為基礎，進行國內外相關文獻回顧，針對國道環境分析大客車駕駛本身之駕駛行為，同時結合空間資訊以預測高風險路段。此期計畫主要為完成車內行車異常事件行車影像辨識技術之開發，並藉由所建立之行車影像辨識工具進行車內行車異常事件分析。

透過蒐集國道客運車內行車影像，探討駕駛人於車內各種異常行為態樣，並開發車內異常行為影像辨識技術；此外，透過車內、外行車異常行為/事件整合，進一步探討車內異常行為 (潛在分心行為) 對行車安全之影響。

在車內異常行為影像辨識技術方面，此計畫主要透過車內駕駛人體關節點之影像辨識方式，進行車內事件辨識架構與流程，藉由車內事件影像之駕駛關節點、座艙內設備位置、方向盤辨識及手機物件辨識等技術，以頭部、手部與軀幹等關節點變化關係，完成辨識車內駕駛各項動作行為事件。

此計畫自 3,677 個警示事件當中，篩選出 5,273 件車內行車異常行為，並從中探討各項車內行車異常行為發生時序之關聯性，以及對行車異常事件嚴重度之影響與好發情境。

此計畫參考過往文獻，將分心分為認知分心、眼部分心以及手部分心。由於此計畫分心變數衡量方式是觀看駕駛艙內影片，並以人工進行判斷，所以此計畫僅探討手部分心及其他可由駕駛艙內影片辨識之肢體動作。在車內行為與行車異常事件關聯分析中，此計畫發現駕駛車內行為會依據當下的情境與危險性有所不同，如：在壅塞或慢速的情境下，駕駛的手部分心動作會偏多，但若是在高速接近前車或是與前車距離太過近的情境下，駕駛會減少手部分心動作。此外，駕駛若有手部分心之動作，通常會有補償的機制 (如：減速)，以避免發生危險。

在事件動作序列分析中，此計畫發現在不同行車動態的條件下，駕駛若出現特定動作或是動作組合，則容易發生行車異常事件。在前車變

換車道的情境下，駕駛只要高速接近前車 (FCWH)，就容易發生行車異常事件；在本車變換車道的情境下，本車離前車太近且駕駛有操作非撥桿的車內設備動作，容易發生行車異常事件；在本車車道偏移的情境下，當駕駛有身體前傾、雙手離開方向盤、拿東西等無法即時適當控制車輛的動作，容易發生行車異常事件。

在行車異常事件時空分析中，建構了分心行為好發情境之模型，針對警示事件與行車異常事件 (輕度異常、異常) 進行之時空分析結果指出，分心行為不論從巨觀至微觀的角度，都顯著對警示、行車異常事件造成顯著正向之結論。意即，時空環境有部分條件使分心事件較為好發，而分心事件又會顯著使警示與行車異常事件發生。

綜上所述，此計畫成果顯示國道客運駕駛經常出現單手離開方向盤之分心行為，其中又以右手離開方向盤對安全的影響較大，另在不同行車動態的條件下，駕駛出現特定動作或動作組合時，行車異常事件較容易之發生，例如在本車車道偏移時，當駕駛有身體前傾、雙手離開方向盤、拿東西等無法即時且適當控制車輛的動作，容易發生行車異常事件；在好發情境分析上，車內行車異常行為對警示事件、行車異常事件的發生造成顯著正向之影響，而在特定時空環境下，如大彎道、上坡等，亦出現較多車內行車異常行為。

2.2 高風險駕駛行為與行車異常事件研究

2.2.1 高風險駕駛行為樣態與好發情境

高風險駕駛行為 (risky driving behavior) 或偏差駕駛行為 (aberrant driving behavior) 在每個不同研究的選擇與定義皆不盡相同。通常偏差駕駛行為可以分為錯誤 (error) 及違規 (violation) (Reason, 1990)，錯誤指的是未能達到預期的結果，可以再分為三個類別，即疏忽 (slips)、失誤 (lapses) 及錯誤 (mistake)。其中，疏忽為因記憶錯誤或未注意而造成之輕微錯誤決策；失誤是指與個人認知相關，因缺乏正確知識而無法完成指定工作；違規是個人因故意而違反規定之政策，駕駛人可能對法律規範有其個人見解所致 (Reason, 1990)。然而，後者通常並不會發生在交通事故的範疇

內，也較少將其納入研究考量。事實上，引起研究興趣的是特定的違規，即存在某種意圖，但未企圖造成損害或造成受傷之情況 (Chen *et al.*, 2019)。

然而，Lawton *et al.* (1997) 將導致偏差駕駛行為的因素歸類成三種，分別是錯誤、違反高速公路法規、失誤。Mallia *et al.* (2015) 以這三種分類為基礎，進一步將不同事件進行分類，例如：錯誤包含切換車道時低估對向來車車速、變換車道錯誤使用方向燈號等；違反法規的部分包含無視住宅道路速限等；失誤則包含看錯標誌進而導致在圓環行駛時從錯誤的出口離開，以及倒車時撞到不在視線範圍內的東西。而此篇研究方法主要採用人格-態度模型(personality-attitudes model)，評估個性特質是否直接和間接(透過對交通安全的態度影響)預測公車駕駛員異常的自評駕駛行為(駕駛違規、疏忽和錯誤)，並在大量樣本中進行分析。

另外，Dula and Ballard (2006) 也透過文獻回顧，將侵略性的駕駛行為分為三項：動作、文字或手勢的刻意侵略行為、負面情緒以及冒險行為，其中針對高風險駕駛行為 (risky driving behaviors)，作者認為其成因為漠視他人 (disregard of others) 或具有敵意 (hostility)，作者使用 DDDI (Dula Dangerous Driving Index) 對 119 位受測者之問卷調查結果發現，高風險及侵略性駕駛行為與性別 (男性)、情緒化的個性有顯著相關。

高風險駕駛行為的定義更加廣泛，其通常與駕駛特性最為相關，如物理與心理疲勞、駕駛經驗的缺乏及工作壓力等 (Useche *et al.*, 2017)，或與人格特質與心理狀態有關，其長久以來被視為與高風險駕駛行為存在重要的關係 (Wang *et al.*, 2019)。

D'Souza and Maheshwari (2012) 在其研究中提到，美國運輸部定義分心駕駛為駕駛者執行任何非駕駛的活動，並提高事故發生的風險，分心可以分為視覺的 (visual) (例如將視線移開路上)、手動的 (manual) (例如將手移開方向盤) 以及認知的 (cognitive) (例如駕駛時不專心) 等。該研究針對公車駕駛者無法掌握的分心因素進行分析，如車內設備或乘客因素。D'Souza and Maheshwari (2012) 對駕駛員蒐集其社會經濟變數、駕駛型態、分心來源與程度、分心時長與其感知效果等，並將不同分心類型加以定義，並使用多項羅吉特模型，探討性別、年齡、駕駛經驗、每週工作時長等對於分心層級的影響 (沒有分心、些微分析、有分心及非常分心)。以

「乘客使用手機使駕駛者分心」為例，男性駕駛者比女性駕駛者更容易受此事件導致分心結果；而在年齡的部分，駕駛者年齡每增加一年，些微分心與沒有分心的差異為 1.65 倍，表示較年長的駕駛有些微分心的可能性更高，但有分心的層級則是相反。另外，出乎意料的是，駕駛經驗的變數之估計值皆大於 0 (些微分心、有分心及非常分心)，代表駕駛者的駕駛經驗越久，反而更容易出現分心的情形。最後，駕駛時長越長，則越有可能出現些微分心的狀況，但有分心的狀況則較少出現。

Stutts *et al.* (2005) 研究中提到，駕駛於駕車過程中食用食物與飲料是常見的駕駛行為，並且可能是分散注意力的常規來源。不論是何種車輛的駕駛，都常常出現此行為，雖然沒有比使用手機對駕駛的影響大，但在行車過程中仍是存在風險的行為。因此，Irwin *et al.* (2015) 進行了查看或寄送簡訊、飲食在自然駕駛場景中對模擬駕駛影響的相關實驗，研究結果發現查看或寄送簡訊以及飲食都會導致駕駛表現惡化，並且與非分心駕駛相比，無意的車道偏離顯著增加。從以上文獻可以得知駕駛過程中飲食，的確會提高行車風險。

職業駕駛者不同於私有運具或一般駕駛，其特性為長時間的駕駛、高專注的需求、疲勞及繁重的工作狀況。因此，Wang *et al.* (2019) 在其研究中探討公車駕駛者社會經濟特性、個人特質及心理狀況與交通違規之關係。其研究結果顯示，駕駛者年齡、駕駛經驗、年收入、飲酒狀態皆與交通違規有顯著關係；對於案例群組的駕駛者 (即交通違規群組) 而言，外向與神經質的人格特質分數皆比控制群組的駕駛者 (即非交通違規組) 更高，而其強迫症、人際關係敏感度、焦慮與敵意的分數也較高。除此之外，總體而言，駕駛年齡越高，發生交通違規的風險越低；而駕駛經驗少於 2 年的駕駛者，比高於 21 年駕駛經驗之駕駛者有三倍的可能性發生交通違規；年收入的勝算比則是隨著收入增加而降低，顯示較低收入之駕駛者，有更高的機會發生交通違規事件。

Han and Zhao (2020) 透過修訂後的《駕駛員行為問卷》(Driving Behavior Questionnaire, DBQ) 調查中國城市公車職業駕駛員的具體行為，問卷問項有幾點關於高風險駕駛行為的樣態，像是變換車道或併入其他車道時不看後照鏡、綠燈時間估算錯誤，以致不能安全停車、在超車或

左轉彎時低估超車或迎面而來的車輛速度、與前車車距過近，以致於在緊急情況下很難快速反應踩剎車、沒有注意到前方的車輛打算在嘗試超車時向左打方向盤、在行車隊伍中開車時幾乎要撞上前方的車輛、在潮濕的路面或條件惡劣的道路上突然剎車、在主幹道上排隊等待左轉時，過度關注對向直行車輛，而導致幾乎撞上前方的車輛。此研究採用相關性分析方法分析駕駛員行為及其影響因素，研究結果顯示都市職業駕駛者的年齡與錯誤 (errors) 呈負相關；駕駛年齡/經驗與違規行為 (violations) 呈負相關；都市公車駕駛員的駕駛年齡與異常駕駛行為傾向和情緒對駕駛行為的影響呈負相關；駕駛員的家庭人口數與錯誤行為、違規行為呈正相關，與積極駕駛行為顯著負相關；駕駛員的教育背景與違規行為呈負相關；都市公車駕駛員每日駕駛時間與錯誤、注意力錯誤 (inattention errors) 和違規行為呈正相關，而與積極駕駛行為呈負相關；駕駛員每天的睡眠時間與注意力錯誤和違規行為呈正相關，而與積極駕駛行為呈負相關；自我評估中情緒對駕駛行為的影響呈顯著負相關；駕駛員每天的睡眠時間與遵守交通規則呈正相關，並與異常駕駛行為傾向呈負相關；都市公車駕駛員的平均月收入與注意力錯誤呈負相關，而平均休息日與注意力錯誤的駕駛行為呈正相關；駕駛員的平均月收入與錯誤、違規行為呈負相關；每月平均休息日與積極駕駛行為呈負相關；都市公車駕駛員的月平均收入與自我評估中遵守交通規則呈顯著負相關，而與異常駕駛行為傾向呈顯著正相關；每月平均休息日與駕駛技能、駕駛安全以及遵守法律法規呈負相關，與異常駕駛行為傾向和情緒對駕駛行為呈正相關；駕駛員的異常駕駛行為傾向與錯誤、注意力錯誤和違規行為呈正相關；情緒對駕駛行為的影響與錯誤、注意力錯誤和違規行為呈正相關。

Reason (1990) 透過 520 位駕駛員完成之 DBQ，請駕駛員自述其開車過程中疏忽、錯誤及違規的次數，研究發現，錯誤與違規與事故的產生有直接相關，且與性別及年齡有高度相關：違規行為將隨年齡增加而減少，錯誤則相反；男性駕駛人的違規行為較女性駕駛人為多，女性駕駛人則相較於男性，較易產生疏忽行為。然作者也提到，問卷可能無法完全反映真實狀況，易受到社會預期而影響填答。

Chen *et al.* (2019) 使用結構方程式 (Structural Equation Model, SEM) 探討偏差駕駛行為與公車駕駛者壓力、不專心及公車業者安全氣候之關係。

因公車業者與公車駕駛員有巢式關係，因此該研究以階層線性模型 (Hierarchical Linear Model, HLM) 解釋研究資料的階層架構。而資料部分則主要分為四個項目，即為 DBQ 駕駛行為問卷、駕駛行為量表 (Driver Behavior Inventory, DBI)、注意力相關之駕駛錯誤規模 (Attention-related Driving Error Scale, ARDEC) 及駕駛者的安全氣候問卷 (Safety Climate Questionnaire-modified for Drivers, SCQ-MD)。其研究結果顯示 SEM 模型中變數的相關性，安全氣候與駕駛偏差行為、壓力及不專心呈負相關；而壓力與不專心呈正相關等。最後，根據模式校估結果，安全氣候的對偏差駕駛行為的總效果大於壓力與不專心，因此對於公車業者而言，其可能要對公司的營運方向、員工訓練、文化建立等投入更多的資源，使安全氣候成為最優先改變之因素，以降低公車駕駛員的偏差駕駛行為。然而，由於業者都是以追求最高利潤為導向，故在有限的資源中，業者通常會讓員工做最長的工時，而使得安全氣候的推動與改善相當不易，故該研究也指出政府對於公車業者的規範與立法，以及對工時的干預是需要且必須的。

Wang *et al.* (2022) 訪問了 331 位中國的公車司機，並使用結構方程模式探討組織管理、外部環境(塞車、交通管理及旅客行為)、駕駛對安全的態度等因素對高風險駕駛行為(闖紅燈、超速、疲勞、分心及強制變換車道)的關聯性，值得注意的是，所有參與研究的駕駛人在高風險駕駛行為中，以強制變換車道(93.05%)及分心(90.94%)為多，與本計畫之研究範圍相符。研究發現，上述各項因素中以塞車及薪資水準最明顯影響公車司機做出高風險駕駛行為，而高風險駕駛行為中又以分心及強制變換車道有最高的因素負荷量，其中，作者指出易塞車的路段易使駕駛人產生壓力，同時導致其作出較為躁進的違規行為，對行車安全造成負面影響。本計畫因暫不考慮組織管理，故將針對外部行車環境作探討，而此文獻也正好說明外部環境確實對高風險駕駛行為之形成相關。

Wang *et al.* (2022) 採用結構方程式評估企業管理和外部環境是否直接或間接地透過駕駛對交通安全態度的影響，與危險駕駛行為自評結果有關聯，樣本包括眾多公車駕駛員。疲勞駕駛、超速行駛、闖紅燈等危險駕駛行為在公車駕駛員駕車時屢見不鮮，給大眾運輸系統的營運帶來了一些隱患。此研究在公車駕駛自評表中關於危險駕駛行為的自評問題是

分成超速、疲勞駕駛、闖紅燈、分心駕駛、強制切換車道五種潛在變數去詢問駕駛，主要想了解這五種測量變數如何影響潛在變數-危險駕駛行為。經調查結果發現，各潛在變數與其對應測量變數之間的因數負荷量(絕對值)在 0.24-0.87 範圍內，均滿足 0.05 的顯著性水準，表明所選測量變數對其對應的潛在變數具有一定的解釋能力，而經研究統計也發現大約有 93%的公車駕駛員表示在駕駛過程中有強制切換車道的行為；90.94%的人在駕駛過程中有分心駕駛行為，包括與乘客聊天、聽收音機、接聽或打電話等。

許多研究已確認疲勞與高風險駕駛行為以及壓力與疲勞之間的關係。概念上而言，駕駛者的疲勞可以分為許多樣態，像是精神不濟、警惕狀態的下降等，而其原因為過長的駕駛時間、單調的道路狀態、天氣變化與個人特性等 (Useche *et al.*, 2017)。在實證研究上，Useche *et al.* (2017) 在其研究中探討疲勞是否會在工作相關的壓力與高風險駕駛行為的關係中成為中介效果。在資料部分，該研究以 DBQ 測量高風險駕駛行為，並以兩份問卷調查受訪者的工作壓力與評估社會心理風險因素，最後以兩份量表測量疲勞與工作上的恢復需要 (The Need for Recovery)。其研究結果顯示疲勞程度與高風險駕駛行為的發生率呈正相關，而努力與獎勵的失衡感知也與駕駛錯誤的行為呈正相關。此外，Useche *et al.* (2017) 將模型分為普通的疲勞與工作的恢復需求。模式一顯示普通的疲勞完全地調節工作壓力與高風險駕駛行為的關係，也調節社會支持與駕駛行為的關係。換言之，工作壓力與社會支持並不直接地與高風險駕駛行為有關係，他們僅有在普通疲勞做為調節效果時有影響。而標準化的路徑係數指出，工作壓力與疲勞間有正向關係，而疲勞與高風險駕駛行為亦是。另外，社會支持與疲勞則為負相關。因此，路徑分析顯示高工作壓力與低社會支持導致較高的疲勞，進而導致較高的風險駕駛。最後，模式二顯示與工作相關的恢復需求完全地調節工作壓力與高風險駕駛行為的關係，也調節工作相關的社會支持與高風險駕駛行為的關係。工作壓力與社會支持透過恢復的需求與高風險駕駛行為相關，並解釋高風險駕駛行為。標準化的路徑係數則顯示工作壓力與恢復需要呈正相關，而恢復需要與高風險駕駛亦是。同時，社會支持與恢復需要為負相關。

Salmon (2011) 應用一個新的人因工程方法 (novel framework of ergonomics methods) 框架，研究了一家澳洲大眾運輸公司駕駛員分心的本質，包括分心的來源以及它們對駕駛員表現的影響。駕駛分心是高風險駕駛行為樣態的一種，而此研究將駕駛分心的影響來源分成了七種，分別是：與科技相關的分心因素 (包括任何在駕駛公共汽車時與駕駛員互動的科技設備，包括手機、CD 播放器、廣播收音機和手持式設備以及售票機)、操作相關的分心因素 (包括任何可能分散注意力的公車運營方面，包括操作售票機、與客運運營控制中心聯絡、收聽一般和個人廣播以及閱讀和/或修改路線日誌)、與乘客相關的分心因素 (包括管理乘客任何可能會分散公車駕駛員注意力的方面，例如聆聽乘客對話、監控乘客行為、與乘客交談、發放車票、提供乘客協助、處理不守秩序的乘客以及聽取乘客在手機上大聲講話等)、與環境相關的分心因素 (駕駛員進行某些行為以減輕環境條件帶來的不適，例如調整氣候控制或遮陽板，則環境條件可能成為分心的因素)、與公車車內相關的分心因素 (包括擾人的震動聲 (例如車廂門、售票機)，調整遮陽板、座椅、控制和安全帶等)、與基礎設施相關的分心因素 (路邊廣告 (例如在公車站和車輛上))、個人分心因素 (例如疲勞、失能和藥物作用等)。在此研究確定的來源中，有 15 個被歸類為代表駕駛員從事違規活動 (即公司政策，規則和法規禁止的活動) 的情況，例如在駕駛時使用手機或與乘客交談。

Hickman (2012) 利用現有的自然駕駛數據，評估卡車和公車駕駛員的駕駛分心情況，接著計算了勝算比以評估某些第三級任務 (與駕駛無關的任務) 增加或減少參與重大安全事件 (safety-critical event) 的機率，並將研究結果與過往研究的結果進行比較。研究結果中有提到，雖然在駕駛時接聽手機的比率沒有顯著增加參與重大安全事件的可能性，但其他手機次要任務 (如發訊息、撥號、伸手拿取等) 被發現顯著增加了參與重大安全事件的可能性。

綜上所述，許多探討高風險駕駛行為或偏差駕駛行為的文獻，會將分心之樣態納入研究中，評估其與影響因子之關係 (D'Souza & Maheshwari, 2012; Hickman, 2012; Salmon, 2011; Wang *et al.*, 2022)。導致分心之因子非常多，包含駕駛本身行為的不專心，如使用手機或操作車內設備等；乘客影響駕駛，如乘客使用手機或向駕駛者談話，導致駕駛者

的分心。本研究使用之分心因子主要與駕駛者本身密切相關，包括操作車內設備、手持手機、拿東西、與吃東西等四項，與乘客有關之因子則是與乘客互動。此外，Wang *et al.* (2022) 將超速視為高風險駕駛行為，也與本研究欲探討之內容相符。然而，過去研究並未探討急加速或急減速之駕駛行為，但此行為對於交通事故的發生可能存在相當大的影響，故本研究選擇將急加減速視為高風險駕駛行為，探討其與行車異常事件之關係。另外，既有研究在探究高風險或偏差駕駛行為時，經常使用問卷之形式蒐集研究資料，例如 DBQ 駕駛行為問卷、駕駛員社經背景調查、業者基本特性等與偏差駕駛行為相關之內容，以更全面地分析高風險駕駛行為與行車異常事件之關係。此外，魏健宏等人更利用駕駛風險總值(各項風險值加總)藉以表示每位駕駛人的風險分數，雖本計畫暫不考慮人格特質之影響，但透過以上回顧可知，駕駛員若有認知上的錯誤及違規已足夠對其駕駛過程帶來及高風險。

車道偏離是道路交通事故的重要原因 (Navarro *et al.*, 2017)，而造成車道偏離情況的原因也有許多種，包含駕駛分心、駕駛打噴嚏、駕駛打瞌睡等，對於行車風險都有一定程度的增加，因此本研究也參考了與先進駕駛輔助系統 (ADAS) 中車道偏離警示 (LDWS) 的相關研究，其中有探討 LDWS 對駕駛的影響 (Navarro *et al.*, 2017)，以及為了改善駕駛員對 ADAS 的適應性，研究了駕駛員在 ADAS 下不當駕駛行為與車輛異常狀態 (車道偏離、急加減速、未保持安全車距等) 之間的相關性，且該研究也列出以上車輛異常狀態觸發 ADAS 警告系統的條件門檻值，如當車輛速度超過 55km/h 並偏離車道越過車道線時，將觸發預警系統 (Wang *et al.*, 2020)。

魏健宏等 (2018) 透過行車紀錄器發現可能造成事故風險之偏差駕駛行為，除分類駕駛風險外，並利用問卷調查訪問 62 位國道客運駕駛人，據以了解人格特質與駕駛風險之相關性，作者將偏差駕駛行為分為：左右偏移、未保持安全距離、引擎轉速過高、超速、急加速以及電磁煞車使用過久，使用極值正規化 (min-max normalization) 獲得每位駕駛人的個別偏差行為之風險值，此研究使用順序性羅吉斯迴歸及階層分析將駕駛人分為「有相對明顯偏差行為」的高風險駕駛人及「未有明顯偏差行為」的低風險駕駛人，其中，容易焦慮及易怒的駕駛員為易產生偏差行為的高風險族群。

Xian *et al.* (2023) 利用北京市近郊快速道路的 GPS 定位資料及事故資料，分析高風險駕駛行為在不同路段下的事故關聯。其中，作者將高風險駕駛行為定義為急加速、急減速以及超速，與魏健宏等人 (2018) 所使用之偏差駕駛行為項目相似，此研究結果發現，高風險駕駛行為與車禍的發生有高度相關，以急減速尤其顯著；而車禍最容易發生於交流道口及彎道兩種路段。

Moslem *et al.* (2022) 指出頻繁的變道會導致嚴重的交通安全問題，包括死亡和重傷。有一項在上海進行，收集了 60 名駕駛且為期 3 個月的駕駛研究顯示，中國駕駛員具有侵略性並頻繁地變換車道，在高速公路的平均車道變換頻率為每公里 0.317 次，具有高碰撞風險 (Wang & Xu, 2021)。

駕駛過程中的危險駕駛行為會產生道路交通安全隱患，甚至引發交通事故。常見的危險駕駛行為包括：進食、吸煙、取東西、使用手機和觸摸控制監視器。以上作者提及的危險駕駛行為都與手部動作有關，當駕駛進行手部相關行為，就會伴隨著手部離開方向盤，進而提高行車風險。另外，表 2.2-1 為 ADAS 警告指標與警告系統條件之過去文獻門檻值，細項則為急加減速、車道偏離、未保持安全車距等。

具體而言，車道偏離是道路交通事故的重要原因 (Navarro *et al.*, 2017)，而造成車道偏離情況的原因也有許多種，包含駕駛分心、駕駛打噴嚏、駕駛打瞌睡等，對於行車風險都有一定程度的增加，因此本研究也參考了與 ADAS 中車道偏離警示 (LDWS) 的相關研究，其中有探討 LDWS 對駕駛的影響 (Navarro *et al.*, 2017)，以及為了改善駕駛員對 ADAS 的適應性，研究了駕駛員在 ADAS 下不當駕駛行為與車輛異常狀態 (車道偏離、急加減速、未保持安全車距等) 之間的相關性，且該研究也列出以上車輛異常狀態觸發 ADAS 警告系統的條件門檻值，如當車輛速度超過 55km/h 並偏離車道越過車道線時，將觸發預警系統 (Wang *et al.*, 2020)。

上述文獻皆清楚定義何謂偏差駕駛行為及高風險駕駛行為，給予本計畫更明確之方向，並透過適切的變數選擇，探討高風險駕駛行為的成因及樣態，其中，駕駛人的認知錯誤以及違規為風險最高之行為，本計畫將針對此二項行為及後續所造成之事故風險更深入的文獻回顧；過去相關研究彙整如表 2.2-2、表 2.2-3。

表 2.2-1 ADAS 警告指標及警告系統條件

指標	觸發警告系統條件
急加減速	一旦縱向加速度變化值超過 SGS 安全標準規定的相應閾值，將觸發警告系統。
車道偏離	當車輛速度超過 55km/h 並偏離車道越過車道線時，將觸發預警系統，但車輛轉向燈亮起、在加速/減速狀態下發生變道、車輛快速切換車道、沒有線或車道線不清晰時除外。
未保持安全車距	當車速超過 55km/h 或車輛以超過 30km/h 的恆定速度行駛，同時相對速度快於前方車輛，相對時間距離(車輛頭部與前車尾部的距離/ (車速-前方車輛速度)) 在 3 s 以內時，將觸發預警系統。

資料來源：Wang et al. (2020)

表 2.2-2 高風險與偏差駕駛行為樣態與影響因子

作者及方法	駕駛行為樣態	駕駛行為樣態與因子定義	因子
D'Souza & Maheshwari (2012) MNL	分心(distraction)	分心：在該研究中，分心分為視覺的、手動的與認知的。其中，視覺的意指駕駛者的視線離開道路；手動的代表手離開方向盤的情況；而認知的則為將注意力移至其他方面，而忽略駕駛行為。	<ul style="list-style-type: none"> ● 乘客使用手機、乘客向駕駛者講話、售票機器影響
Wang <i>et al.</i> (2019) Statistics analysis	交通違規(violation)	交通違規：在研究期間過去兩年間，有在工作時間內，由於駕駛本身之因素導致交通違規行為，而受到警方的罰款(包含超速、闖紅燈、與他人發生碰撞或酒駕等)	<ul style="list-style-type: none"> ● 年齡、駕駛經驗 ● 年收入、飲酒狀態、外向、神經質等人格特質 ● 強迫症、人際關係敏感度、焦慮等
Chen <i>et al.</i> (2019) HLM	偏差駕駛行為	偏差駕駛行為：由疏忽/失誤、錯誤與違規等三大項目組成，其中共有 20 項問題，並利用李克特五量表供駕駛者填答 駕駛員壓力：採用駕駛員侵略 (driver aggression)、不喜歡駕駛及特定情況的緊張等三個問題，共 20 個問題供駕駛者填答。 不專心：使用 Ledesma <i>et al.</i> (2010) 發展之問卷，稱之為 ARDES，其中共有 10 個項目供駕駛者填答。 安全氣候：Wills <i>et al.</i> (2005) 的六個因素被採用，共分為溝通與程序、工作壓力、管理承諾、關係、駕駛訓練及安全規則，共有 30 個題目供駕駛者填答。	<ul style="list-style-type: none"> ● 公車業者駕駛文化 ● 駕駛員壓力 ● 駕駛員不專心駕駛
Wang <i>et al.</i> (2022) SEM	超速 疲勞駕駛 闖紅燈 分心駕駛 強制切換車道	疲勞駕駛：駕駛車輛時間過長，無足夠休息時間 分心駕駛：進行駕駛車輛以外的任務 強制切換車道：未打方向燈便直接變換車道或為閃避直行車道上等待左轉的車輛而向右駛離原車道，進而占用右手邊的車道	<ul style="list-style-type: none"> ● 與乘客聊天 ● 聽收音機 ● 接聽或打電話

表 2.2-2 高風險與偏差駕駛行為樣態與影響因子 (續 1)

作者及方法	駕駛行為樣態	駕駛行為樣態與因子定義	因子
Useche <i>et al.</i> (2017) SEM	高風險駕駛行為	<p>高風險駕駛行為：DBQ 問卷測量</p> <p>工作壓力：27 項工作內容問卷 (JCQ) 的量表，被使用來評估工作時的社會心理因素，其可能潛在地導致工作壓力，是由六個子量表組成：技能判斷力、決策權、社會心理需求、監督與管理支持、同儕或同事支持及工作不安全。工作控制是技能判斷力與決策權的加總。而社會支持則是同儕支持與監督者支持的加總。</p> <p>努力回報失衡 (effort-reward imbalance)：評估社會心理風險因素，在工作的壓力時，是根據努力回報失衡模型的實施：外在努力 (extrinsic effort) 與獎勵 (reward)。而外在努力與獎勵是透過每個子量表的項目加總而成，努力/獎勵失衡則是使用公式獲得：失衡 = $K/(E/R)$，K 等於 (獎勵的項目/努力的項目)。</p> <p>疲勞：藉由 CIS 量表的 8 個項目主觀判斷駕駛者的疲勞程度</p>	<ul style="list-style-type: none"> ● 疲勞程度 (駕駛時間長、道路改變及個人特性) ● 努力與獎勵之失衡程度 ● 工作壓力 ● 社會支持
Mallia <i>et al.</i> (2015) 人格-態度模型 (personality-attitudes model)、SEM	錯誤失誤違規	<p>錯誤：由於計劃動作失敗所導致 (判斷錯誤)</p> <p>失誤：由於注意力和記憶力衰竭所導致</p> <p>違規：違反駕駛相關規定</p>	<ul style="list-style-type: none"> ● 超車時低估對向來車車速 ● 變換車道錯誤使用方向燈號 ● 無視住宅道路速限 ● 看錯標誌進而導致在圓環行駛時從錯誤的出口離開 ● 倒車撞到不在視線範圍內的東西

表 2.2-2 高風險與偏差駕駛行為樣態與影響因子 (續 2)

作者及方法	駕駛行為樣態	駕駛行為樣態與因子定義	因子
Salmon (2011) 人因工程方法 (novel framework of ergonomics methods)	分心	分心：進行駕駛車輛以外的任務	<ul style="list-style-type: none"> ● 使用科技設備 (如：手機) ● 操作公車營運相關事項 ● 乘客分散駕駛員注意力 ● 駕駛員進行某些行為以減輕環境條件帶來的不適 ● 車廂內相關影響因素 (如：車廂門震動聲等) ● 路邊廣告 ● 個人因素 (疲勞、失能、藥物作用)
Hickman (2012) Statistics analysis	駕駛分心	駕駛分心：注意力不集中、進行開車以外的任務	<ul style="list-style-type: none"> ● 手機次要任務 (發訊息、撥號、伸手拿取)

表 2.2-2 高風險與偏差駕駛行為樣態與影響因子 (續 3)

作者及方法	駕駛行為樣態	駕駛行為樣態與因子定義	因子
Han & Zhao (2020) Statistics analysis	<p>錯誤 (綠燈時間估算錯誤, 以致不能安全停車、在超車或左轉彎時低估超車或迎面而來的車輛速度、在潮濕路面或條件惡劣道路上突然剎車、變換車道或併入其他車道時不看後照鏡)</p> <p>交通違規 (與前車車距過近, 以致於在緊急情況下很難快速反應踩剎車)</p> <p>注意力不集中錯誤 (分心、沒有注意到前方的車輛打算在嘗試超車時向左打方向盤、在行車隊伍中開車時幾乎要撞上前方車輛、在主幹道上的排隊等待左轉時, 過度關注對向直行車輛, 而導致幾乎撞上前方的車輛)</p>	<p>錯誤: 是指司機做出的錯誤決定, 但不違反交通法律法規</p> <p>交通違規: 司機違反交通法規</p> <p>注意力不集中錯誤: 司機駕駛時注意力分散</p>	<ul style="list-style-type: none"> ● 職業駕駛者的年齡 ● 駕駛經驗 ● 駕駛員的家庭人口數 ● 駕駛員的教育背景 ● 駕駛員每日駕駛時間 ● 駕駛員每天的睡眠時間 ● 駕駛員的情緒 ● 駕駛員的平月月收入 ● 駕駛員每月平均休息日

表 2.2-3 駕駛行為樣態與人、車、路之影響因子

駕駛行為樣態	因子		
	人	車	路
分心 (D'Souza and Maheshwari, 2012; Salmon, 2011; Han & Zhao, 2020; Wang <i>et al.</i> , 2022)	乘客使用手機影響駕駛者 乘客向駕駛者講話影響駕駛者 駕駛接聽或撥打電話、聽收音機 使用科技設備 (如：手機) 操作公車營運相關事項 駕駛員每日駕駛時間 駕駛員進行某些行為以減輕環境條件帶來的不適 個人因素 (疲勞、失能、藥物作用) 駕駛員每日駕駛時間 駕駛員的情緒	售票機器影響駕駛者 車廂內相關影響因素 (如：車廂門震動聲等)	天氣影響駕駛員 路邊廣告
交通違規 (Wang <i>et al.</i> , 2019; Mallia <i>et al.</i> , 2015; Han & Zhao, 2020)	飲酒狀態 個人特質 (外向、神經質) 人際關係敏感度高、焦慮 職業駕駛者的年齡 駕駛經驗 駕駛員的家庭人口數 駕駛員的教育背景 駕駛員每日駕駛時間、睡眠時間 駕駛員的情緒 駕駛員的平均月收入 駕駛員每月平均休息日 無視住宅道路速限	-	-

表 2.2-3 駕駛行為樣態與人、車、路之影響因子 (續)

駕駛行為樣態	因子		
	人	車	路
偏差駕駛行為 (Chen <i>et al.</i> , 2019; Han & Zhao, 2020)	公車業者安全氣候不佳 駕駛員壓力 駕駛員不專心駕駛	-	-
高風險駕駛行為 (Useche <i>et al.</i> , 2017)	駕駛員工作壓力 駕駛員所受之社會支持、同儕支持等	-	-
駕駛員疲勞 (Useche <i>et al.</i> , 2017)	駕駛時間過長 個人特性	-	道路景色單調且單一 天氣改變或天氣惡劣
錯誤 (Mallia <i>et al.</i> , 2015)	綠燈時間估算錯誤以致不能安全停車 職業駕駛者的年齡 駕駛員的家庭人口數 駕駛員每日駕駛時間 駕駛員的情緒 在超車或左轉彎時低估超車或迎面而來的車輛速度 看錯標誌進而導致在圓環行駛時從錯誤的出口離開 倒車時撞到不在視線範圍內的東西	-	潮濕的路面或條件惡劣 的道路上駕駛突然剎車
失誤 (Mallia <i>et al.</i> , 2015)		-	-

2.2.2 高風險駕駛行為與事故風險

在道路交通安全議題研究中，過去研究已找出眾多相關之議題，如與道路交通安全具有高相關性之事件 (safety-related events)、高風險駕駛行為或徵兆事件，期能在大量事故發生之前預先進行防範及改善。故本計畫除了解高風險駕駛行為之樣態及其成因外，本計畫將於此小節針對高風險駕駛行為與事故相關文獻做回顧，並討論交通事故與駕駛行為、外在環境及道路特性之間的關聯性。

Wang *et al.* (2022) 於其研究中更明確的定義高風險駕駛行為，其中，分心行為也被納入於研究中，說明分心對駕駛過程確實造成不可避免之風險，並且高達九成的駕駛自述曾有分心行為，Wundersitz (2019) 也曾利用 2014 至 2018 年澳洲阿德萊德的事故資料，分析駕駛人的分心 (distraction) 與注意力不集中 (inattention) 之行為與死亡或重傷事故的相關性。該研究將駕駛人注意力不集中的現象分為五類，分別是錯誤優先的注意力 (駕駛人無法在多種駕駛活動之間有效地分配注意力)、被忽視的注意力 (駕駛人對駕駛狀況的預期有誤，忽視了與安全最相關的事項)、草率的注意力 (駕駛人對安全的重視度不足)、轉移的注意力 (又稱分心，指駕駛人的注意力被轉移到與安全無關的事項) 及無法明確辨別的注意力。在與注意力不集中有關的事故中，最常見的注意力不集中類型為分心 (佔所有事故的 44%) 與錯誤優先的注意力 (佔所有事故的 26%)，其中分心之事故通常是由與乘客互動、在車內尋找物品、駕駛人自身情緒壓力及其他道路使用者所引起的，另外也有 2.5% 的事故是起因於駕駛人在開車中途使用手機，且駕駛人是有意識自己處於分心狀態。此研究發現，事故的道路型態皆集中在路口、大都會地區及低限速區。

Kaplan and Prato (2012) 利用順序性羅吉斯迴歸探討美國的公車事故嚴重性的關聯因素，Kaplan and Prato 將事故嚴重度分為死亡、重傷 (造成殘廢)、中傷 (未造成殘廢)、輕傷及財損。其研究結果發現，年輕 (25 歲以下) 與高齡駕駛 (55 歲以上)、道路型態、外部環境 (光線及鋪面型態) 及高風險駕駛行為 (疲勞、超速、分心等) 將會造成事故嚴重程度上升。高風險駕駛行為中以疲勞最為嚴重：相較非高風險駕駛行為事件分別提升死亡、

重傷、中傷及輕傷機率為 65.3%、8.8%、20.6%及 95.2%；本計畫關注的分心行為則是略低於疲勞駕駛及超速，將較於非高風險駕駛行為事件分別增加死亡及輕傷機率 39.1%及 27.9%。在道路型態方面，作者指出彎道相較於直線易增加事故嚴重度，值得注意的是，水平路段相較於有坡度的路段更加危險；針對外部環境，作者特別提到夜間是較有風險的，且相較於提供人工光源的路段提升 10.5%~18.5%的重傷機率，未安裝照明設施的路段將大幅躍升至 55.1%~66.7%。

Feng *et al.* (2016) 使用順序性羅吉斯迴歸及階層分析將公車駕駛人分為三群：1) 中年人且有發生過交通違規；2) 年輕人及老年人且有發生過交通違規；3) 未曾發生過交通違規。研究結果發現，第一類駕駛人為「最安全的族群」，因其曾發生過交通違規，且相較於年輕人有更豐富的駕駛經驗；第二類駕駛人為「最危險的族群」，因年輕人駕駛經驗不足、較容易低估事故風險及嚴重度，且易於開車時分心，老年人則因為年齡因素，易發生較嚴重事故，且認知能力相較於年輕人及中年人為差；第三類人則介於另兩群中間。另一方面，作者更指出，時間、碰撞型態、道路特性、行車狀態以及高風險駕駛行為也是造成嚴重事故的重要因素。以時間來說，雨天、傍晚及夜間、秋季及冬季為嚴重事故的好發時段；碰撞型態則以本車追撞前車、本車偏移較為嚴重；道路特性則以交岔路口、高限速路段以及曲線型道路對於第二 (28%) 及第三類 (25%) 駕駛較易發生嚴重事故；行車狀態以左右轉相較於直行易發生事故，值得注意的是，相較於直行及左轉，右轉有較高的事故風險；最後，高風險駕駛行為則包含疲勞、身體不適、酒/藥駕、疏忽、超速、分心及未繫安全帶，其中，以酒/藥駕、疏忽、超速以及分心等四型為最為嚴重，且又以第二類駕駛人有最高的事故風險。

透過上述文獻可發現，除了駕駛的個人特性及高風險駕駛行為外，外在道路環境與事故的發生擁有著極大的關聯性。其中，道路交岔口 (路口、交流道等)、彎道、速限及天色為事故發生的高風險因素。

2.2.3 行車異常事件研究

早期業者利用 GPS 偵測超速、急加速或急減速，做為行車異常事件之指標，惟此方式之指標可靠度過低，目前鮮少使用；爾後，導入 ADAS 之業者則採用跟車距離過近及車道偏離之警示事件，做為行車異常事件偵測指標。而在資本與人力資源皆有限的情況下，難以同時偵測並驗證所有行車異常事件，因此在挑選所欲採用之駕駛人安全駕駛行為指標時，應從目標駕駛員常發生之事故類型、事故地點著手，並設立對應之事件門檻值。

以美國為例，SHRP2 在 2010 至 2013 年期間蒐集了 6,559,367 個旅次檔案。研究學者透過這些自然駕駛研究計畫中所蒐集的數據，以及各自演算法推算出不同的行車異常事件，進而估算出不同駕駛人的行為、道路環境特徵所造成的風險。該計畫所訂定行車異常事件之觸發門檻值如表 2.2-4 所示。

表 2.2-4 SHRP2 之行車異常事件觸發門檻值

指標	事件門檻值
縱向減速度	縱向減速度大於等於 0.65g，且超過門檻值的持續時間至少 0.001 秒，而在 2 秒內發生將算成同一個事件
縱向加速度	縱向加速度大於等於 0.50g，且超過門檻值的持續時間至少 0.001 秒，而在 2 秒內發生將算成同一個事件
高速公路縱向減速度	當車輛行駛在高速公路上時，縱向減速度大於等於 0.3g，且超過門檻值的持續時間至少 0.001 秒，而在 2 秒內發生將算成同一個事件。
橫向加速度	橫向加(減)速度大於等於 0.75g，且超過門檻值的持續時間至少 0.2 秒，而在 2 秒內發生將算成同一個事件。
轉向	當車輛以 11mph 或更高的速度行駛時，偏航率 (yaw rate) 經微分後，其最大或最小正弦波在兩秒內變化超過 15 度時。
偏航率	當車輛以 30mph 或更高的速度行駛時，在 0.75 秒內，車頭的偏移角度大於等於 8 度者，而在 2 秒內發生將算成同一個事件。
縱向變加速度	當車輛以 11mph 或更高的速度行駛時，縱向加速度的導數小於 -1.0g/s，並持續 1 秒。
側向變加速度	當車輛以 11mph 或更高的速度行駛時，側向加速度的導數的絕對值大於 1.0g/s，並持續 0.8 秒。

Yu *et al.* (2021) 在其研究中提到，使用 0.3 g 做為急減速的門檻值，並將其視為應變數，探討道路線型、速限、分心駕駛等因素對急減速的影響。另外，Glaser (2017) 發現 119 個事故衝突中，有 74 起事件急減速高於 0.4 g，亦有嘗試 0.5 g 及 0.65 g 做為急減速之門檻值。Feng *et al.* (2017) 使用自然駕駛資料，探討衝度 (jerk) 是否可以精準地確認侵略性駕駛 (aggressive driving)，而研究結果指出若駕駛的衝度指標高於 12.7，則該駕駛會被分類至高事故風險的群組 (代表駕駛每 100 英里超過 12.7 次較大的負衝度)。此外，Bagdadi (2013) 在其自然駕駛研究中，將縱向加速度大於 0.65 g 標記為關鍵駕駛事件。更甚者，Bagdadi (2013) 也使用衝度做為參數，並將其門檻值設定為 1.0，使識別碰撞事件的成功率高達 86%。另外，有鑑於車輛加速度及衝度在辨識不同駕駛行為中的重要性，Bagdadi & Várhelyi (2011) 亦使用 -9.9 m/s^3 之衝度值，並將其用於識別安全關鍵的駕駛行為指標。

至於車道偏移的門檻值，Klauer *et al.* (2006) 在美國交通局所做的研究中，指出當駕駛使用車內設備如收音機、音樂裝置等，容易造成車道偏移之高風險駕駛行為，而提高事故風險。該研究更提供該駕駛行為之門檻值，為每秒 3.64 度，即為超過每秒 3.64 度之轉向角度，可視為高風險駕駛行為。表 2.2-5 為相關文獻危險駕駛行為之門檻值的總整理。最後，Wang *et al.* (2020) 在其研究中亦提及，當車輛速度超過 55km/h 並偏離車道越過車道線時，將觸發預警系統。

表 2.2-5 相關文獻危險駕駛行為之門檻值

危險駕駛行為	文獻	門檻值與內容
縱向急加速	Bagdadi (2013)	0.65 g
縱向急減速	Yu <i>et al.</i> (2021)	0.3 g
	Glaser (2017)	0.4 g、0.5 g、0.65 g
衝度 (jerk)	Bagdadi <i>et al.</i> (2013)	1.0 m/s^3
	Bagdadi & Várhelyi (2011)	-9.9 m/s^3
	Feng <i>et al.</i> (2017)	駕駛每 100 英里超過 12.7 次較大的負衝度
車道偏移	Wang <i>et al.</i> , (2020)	車速超過 55km/h 並偏離車道且越過車道線
	Klauer <i>et al.</i> (2006)	每秒 3.64 度之轉向角度

2.2.4 小結

本計畫於本節分別針對高風險駕駛行為之樣態與情境、高風險駕駛行為與交通事故之關聯性以及行車異常事件等主題回顧其相關文獻。

本計畫發現在討論高風險駕駛行為前，必須先定義偏差駕駛行為，而根據文獻上的定義，偏差駕駛行為分為疏忽、錯誤以及違規三項，而又以錯誤及違規更容易造成後續之事故。「錯誤」主要之成因與個人認知有關，根據回顧之文獻，認知錯誤包含分心、設備使用有誤以及對環境危險感知能力不足(如未保持車距、偏移車道等)；「違規」則更嚴重，因其代表著駕駛員對法律規定的不清楚或不重視。根據本計畫前期所蒐集之資料，駕駛員造成行車異常事件之主因為認知錯誤(未保持車距、對環境之危險感知不足等)，其次為使用手機(違規)。而行車異常事件則主要包含本車與前車之相對位置過近、強迫變換車道、行駛過程中有較大的車道偏移或駕駛員於車內放開雙手以及未專心於開車等等。另外，本計畫亦回顧多篇文獻定義之高風險駕駛行為之門檻值，做為本計畫之危險駕駛行為門檻值的參考。

因此，本計畫將於本期持續針對上述之行車異常事件找尋相關風險之所在，並納入道路幾何與環境之影響因素，藉以完整探討高風險駕駛行為，據以建立更完整之衡量指標。

2.3 行車影像辨識技術與影像資料整合應用

2.3.1 車外行車影像辨識技術

車外行車影像辨識技術是一種進階的汽車科技，它通過安裝在汽車上的一個或多個鏡頭，以收集周圍的影像訊息，再透過電腦視覺和機器學習等技術，對這些影像訊息進行分析和解讀。這種技術可以幫助汽車進行對環境的識別，如道路、行人、車輛、交通標誌等，進而提供輔助駕駛或自動駕駛的功能。

(一)對象辨識：這是最基本的功能，包括行人、轎車、卡車、公車、連結車、工程車等的識別。

(二)ROI 分割：這是依照本車車輛的附近區域，將畫面分為多個距離的區域，識別出每一區域的物體類型，例如行人、車輛等。

(三)距離識別：這是計算可偵測物體和車輛之間的距離。

(四)相對速度：這是用可偵測物體的距離變化和車輛的速度計算被識別出來的物體的相對速度，例如行人或其他車輛。

這些技術在自動駕駛、先進駕駛輔助系統等領域有廣泛的應用，可以幫助提高行車安全和效率。但同時也存在一些挑戰，例如在複雜的道路環境下，如何確保辨識的準確性，或在不同光照、天氣條件下，如何確保影像的清晰度等。

行車影像辨識技術在進一步的發展上，也存在許多研究與挑戰。例如：

(一)即時性：在汽車行駛中，對於周圍環境的辨識需要具有高度的即時性，才能確保行車安全。這需要高效能的處理器和優化的演算法才能達到。

(二)偽識別與遺漏識別的問題：在複雜的道路環境中，可能會出現將非目標對象誤認為目標對象(偽識別)，或是將目標對象誤認為非目標對象(遺漏識別)的問題。這需要透過更精確的模型訓練和優化來解決。

(三)光照與天氣條件變化：不同的光照與天氣條件可能會影響影像的清晰度和識別的準確性。研究人員需要開發能夠在各種條件下都能正常工作的模型。

(四)保護隱私：由於車輛鏡頭會收集大量的影像數據，如何保護這些數據中的個人隱私，也是一個重要的問題。

行車影像辨識技術的發展可以追溯到 20 世紀 80 年代，當時主要是研究用於輔助駕駛的系統，如車道保持系統 (Lane Keep Assistance; LKA) 和適應性巡航控制系統 (Adaptive Cruise Control; ACC)。但真正的突破發生在 21 世紀初，隨著深度學習技術的發展，行車影像辨識技術得到了飛躍性的進步。以下是一些具體的汽車品牌和他們的行車影像辨識技術：

(一) 特斯拉 (Tesla) Autopilot 自動駕駛系統：特斯拉是自駕車技術的先驅，其 Autopilot 系統利用多個雷達感應器和相機，收集周邊環境數據，然後透過深度學習算法進行處理，實現自動駕駛的功能。除此之外，特斯拉還在不斷更新和優化自己的自動駕駛系統，進一步提高其識別的準確性和實時性。

(二) Google Waymo：Waymo 是 Google 母公司 Alphabet 的子公司，專門從事自駕車技術的研究。Waymo 的自駕車採用 Lidar (Light Detection and Ranging, 光學遠程測量技術) 系統和攝像鏡頭，收集周邊環境的數據，然後通過深度學習算法進行處理。Waymo 的自駕車已經在美國的一些地方進行了公眾試駕。

(三) BMW：BMW 的輔助駕駛系統也具有影像辨識技術，例如其 Traffic Jam Assistant 系統可以識別車輛和行人，並進行適應性的巡航控制。

(四) Audi：Audi 的自駕車技術也採用了影像辨識技術，其 A8 車型的自駕車系統可以識別行人和其他車輛，並進行適應性的巡航控制。

深度學習是一種特殊類型的機器學習，它使用多層的神經網路來模擬人腦的思慮過程，通過訓練可以從大量數據中識別出有用的特徵和規律。在行車影像辨識技術的發展中，深度學習起到了關鍵的作用。

以下是深度學習在行車影像辨識技術中的一些重要應用：

(一) 卷積神經網路 (CNN)：CNN 是一種特殊類型的深度學習模型，特別適合處理影像數據。它可以自動萃取出影像中的特徵，並進行分類或識別。在行車影像辨識技術中，CNN 被廣泛用於行人和車輛的識別，交通標誌的識別等。

(二) 物件偵測 (Object Detection)：這是一種更進階的影像識別技術，不僅可以識別出影像中的物體，還可以定位其位置。常用的物體檢測算法包括 R-CNN、Fast R-CNN、Faster R-CNN、YOLO、SSD 等，它們在車道線識別、行人和車輛偵測等領域有著廣泛的應用。

(三)語義分割 (Semantic Segmentation)：這是一種將影像分割為多個區域，並識別出每個區域的物體類型的技術。例如識別出路面、行人、車輛、建築物等。這種技術可以讓自駕車更好地理解其周圍環境，進一步提高行車安全。

這些深度學習技術大大提高了行車影像辨識的準確性和即時性，並推動了自駕車技術的發展。然而，它們也面臨著一些挑戰，例如如何處理各種複雜的道路環境和不同的光照條件，如何保護收集到的影像數據的隱私等。在未來，這些技術可能會透過更深入的研究和改進，提供更高級的自駕車服務。

2.3.2 車內行車影像辨識技術

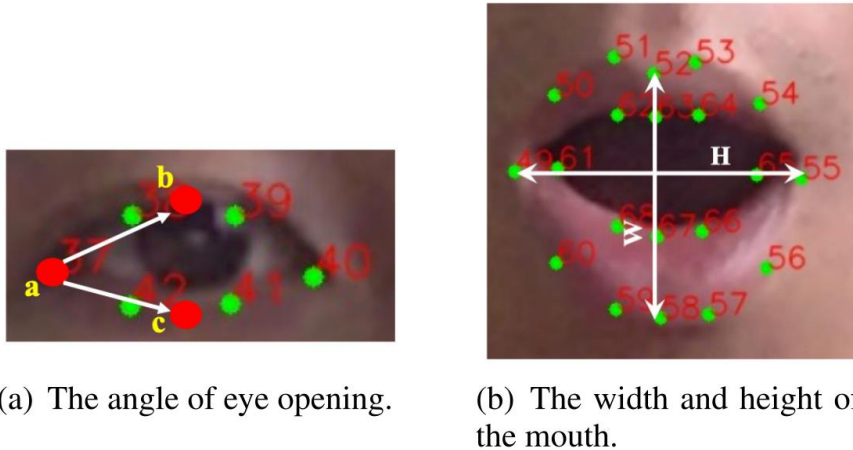
駕駛者分心與疲勞是造成車輛意外事故的重要原因，藉由駕駛者監控系統 (Driver Monitoring System; DMS) 可為行車安全多加一道防線。DMS 藉由安裝鏡頭並結合近紅外線技術來蒐集面部運動特徵如眨眼、注視方向、頭部運動等來監控和偵測駕駛人行為、生理狀態，以及車輛動態反應，透過偵測到異常數據時發出警示訊號和啟動輔助駕駛系統，提高行車安全，降低事故發生率。應用包含預防疲勞駕駛、分心偵測、不當駕駛，以及未授權駕駛等多樣功能。

目前已知的駕駛者監控相關演算法大致能分為兩類：根據五官特徵使用電腦視覺方法判斷與透過卷積神經網路 (CNN) 判斷。前者會先找出一些臉部特徵，例如臉部特徵定位，再透過這些特徵以電腦視覺方法判斷駕駛是否昏睡或未注意前方等分心行為；後者會將駕駛影像或是駕駛局部部位影像交由卷積神經網路進行分類以判斷是否有昏睡或分心行為。

Tsao (2008) 提出以 Eye candidate 進行眼睛偵測，並用支援向量機 (SVM) 確認是否是眼睛，最後確認眼睛是否左右成對。若眼睛偵測連續 3 個影格成功即開始追蹤，使用 Kalman filter 預測接下來位置，即可在預測位置附近小範圍偵測。有了眼睛部位的資訊可以用來計算：透過左右眼位置推測臉面向和臉範圍；透過兩眼眼球分別處於眼睛的左、中、右區域則可以判斷視線方向；透過眼睛上下緣高度，可以推測眼睛開闔，並

根據持續時間以 PERCLOS (PERcentage of eye CLOSure) 方法判斷是否昏睡。

Deng *et al.* (2019) 透過找出臉部特徵定位，並透過這些特徵點之間的位置與距離關係，計算可以用來判斷駕駛者的眼睛與口部是張開或閉合的指標，如圖 2.3-1 所示。透過這些指標可以知道駕駛是否有閉眼或打呵欠的狀況，即可進一步判斷駕駛的精神狀況。



(a) The angle of eye opening.

(b) The width and height of the mouth.

(資料來源："Real-time driver-drowsiness detection system using facial features.", IEEE Access (2019))

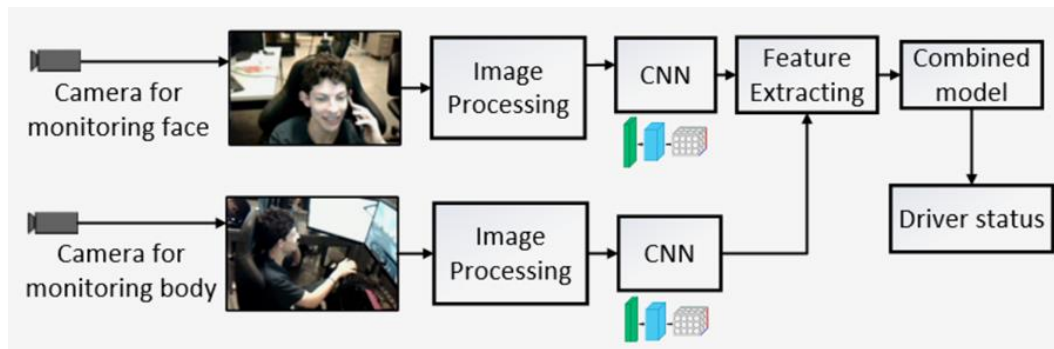
圖 2.3-1 使用臉部特徵定位之間的距離關係判斷駕駛的眼睛和口部開闔

Lollett *et al.* (2022) 針對戴口罩情境進行駕駛疲勞偵測，同樣先找出臉部特徵定位，再依據以下三個特徵判斷：眼睛開闔、臉部下緣是否有拉長、肩膀起伏狀況。其中臉部下緣的判斷是因為在打哈欠時即使戴著口罩，臉部的下緣也會拉長，另外在打哈欠時因為會有明顯吸吐氣，肩膀會隨著上下起伏。

Reddy *et al.* (2017) 先透過 MTCNN (Multi-task Cascaded Convolutional Networks) 進行人臉偵測，找出臉部位置和五官的大致位置後將部分臉部的影像，如眼睛部位或嘴部部位的截取影像丟入論文所提出的昏睡偵測網路 (DDDN)，得到三階段的昏睡程度輸出。

Tran *et al.* (2017) 使用正面、側面兩支相機，如圖 2.3-2 所示。將兩個視角的影像分別丟入卷積神經網路，最後再將輸出合併，以找出駕駛是否有以下分心行為：使用手機講電話、使用手機打字、調整收音機、飲食、伸手到後方、撥弄頭髮、和旁邊說話、疲勞。由於使用兩個相機視

角，相較於傳統只有拍攝正臉視角的駕駛者監控方法，可以找到較多需要看到整個身體才能看到的分心行為，但相對所需運算資源也相對較多。



資料來源："Real-time detection of distracted driving using dual cameras.", IEEE Access (2020)

圖 2.3-2 使用正面、側面兩相機視角共同辨識駕駛疲勞狀態與分心行為

2.4 交通事故時空間分析

在道路交通安全議題研究中，過去研究已找出眾多相關之議題。除對涉入事故之駕駛員或事故周遭環境特徵進行分析外，更可透過事故鏈之概念，針對一般駕駛時發生警示事件、行車異常事件之觸發，找尋與交通事故具有高相關性之事件、高風險駕駛行為或徵兆事件，期能在大量事故發生之前預先進行防範及改善。近年常透過車載資訊系統，獲得自然駕駛之駕駛行為，進行安全分析與管理，本節針對駕駛行為與時空特性，及交通事故時空分析與預測模式進行回顧。

2.4.1 高風險駕駛行為時空間特性不同

Ghasemzadeh and Ahmed (2018) 透過自然駕駛 (Naturalistic Driving Study, NDS) 將紐約 144 名駕駛，總計行駛 200 小時、19,200 公里的駕駛資料，將空間之道路環境與時間之日期時段進行編碼，整理出不同時空特徵的集群，包含：時段、平假日、速限、匝道、橋梁、彎道、天氣等。該研究目的在針對控制一定之時空環境下，雖每位駕駛有異質性，但嘗試建立出通用模式，透過整合駕駛資訊資料，包含駕駛速度變異、加減速與車道偏移，以及駕駛者變數，檢視時空特徵與駕駛行為之關係。該研究在考量時空特徵下，發現同組內之駕駛員在超速、加減速、車道偏

移之變異較小；而各個時空特徵，以羅吉斯迴歸檢視各變數的勝算比是否與該類時空環境有顯著高低差異。

Khan *et al.* (2018) 亦透過 SHRP2 蒐集 NDS 資料於各種霧況下的道路駕駛行為，並與天氣晴朗時做為對照組進行分析，發現駕駛人行駛於不同程度的霧況，減速機率比晴朗時高出約 1.2~1.3 倍不等，速度則降低 3~10%，並建議針對霧天時以可變速度限制進行管理。

Jiang *et al.* (2022) 則以中國廣東的大貨車，蒐集為期半年、車隊數 81 輛、駕駛員 5,396 位之 NDS 資料，透過觀察危險駕駛分心行為與車輛警示事件的關鍵因子。該研究先將危險駕駛行為之警示事件與道路等級進行組合，做為時空分析之分類特徵，並建立 Moran Index 衡量危險駕駛行為之分數。根據研究結果，其中有高達 50% 的大貨車駕駛常傾向以危險駕駛行為駕駛大貨車，主要危險駕駛行為類別為偏移、遮蔽監視鏡頭，以及吸菸動作；另外指出特定月份的警示事件數較高。

本計畫除了考量客運班次時間與國道幾何空間條件之不同，駕駛人的趟次、時數等曝光量之狀況亦可納入考量。回顧 Bell *et al.* (2017)，其記錄駕駛人於系統中的駕駛行為，並結合回饋機制之教育方式外，亦將駕駛人分組、分時段再進行觀察，此分類方式亦可供本研究後續可分析高風險駕駛行為與行車異常事件空間特性時之參考。

本計畫利用 ADAS 偵測之警示事件及依據車機及車內影像資料所判讀之車內行為，做為事故前兆，據以檢視高風險駕駛行為及時空間特性是否相關。

而 Jun *et al.* (2007) 為了驗證涉入事故駕駛的曝光量與績效是否因為旅次開始行駛時間而有顯著差異，根據全球定位系統 (GPS) 偵測之車輛資料，評估在 14 個月的研究期間內，有無涉入事故之駕駛員之間的曝光量與績效差異。研究結果顯示涉入事故之駕駛在累積里程、速度和變加速度，均與無涉入事故之駕駛有顯著差異，且其累積行駛里程較長、速度較快並較常急煞車。該研究表示透過對上述風險駕駛行為的識別及糾正，將可有效避免事故發生，並建議運輸業者將個別駕駛行為納入做為教育訓練或駕駛評估之參考，以減少高風險駕駛行為發生次數。

Gitelman *et al.* (2018) 納入交通事故資料，並採用負二項迴歸模式分析車載資訊設備 (IVDR) 產生之警示事件和交通事故間的關係，以檢驗駕駛事件對預測事故和識別道路中高風險位置的可能性。該研究在 9 條不同的道路中共蒐集到 62 位駕駛 2010 年之車載資訊設備資料，共計有 20 種不同的警示事件。其中事件種類以煞車事件與速度警報事件占多數，並將道路類型分為高速公路、雙車道道路及單車道道路 3 種，以煞車事件、速度警報事件和總警示事件做為自變數，根據 4 種事故嚴重程度分別建立了 36 個負二項迴歸模式，結果顯示煞車事件可用於預測雙車道道路及單車道道路上的事故。接著，同樣運用負二項迴歸模式，深入了解駕駛行為與道路特徵的關係，以 2 類事件數及總事件數做為應變數，自變數考慮車道寬度、路肩寬度、平均每日交通量 (ADT)、水平曲率、坡度、路口接近程度、車道數變化、車道寬變化等，分別建立負二項迴歸模式。研究結果顯示大多數道路設施特徵的變數均具有顯著影響，而最有影響力的道路特徵則包括道路類型、路口接近程度、路段長度和路肩寬度，且道路條件越好，煞車事件發生機率下降，速度警報事件則是越可能發生，反映道路設計一致性對駕駛行為的影響。

2.4.2 交通事故時空間分析與預測模式

針對交通事故時空間分析，受限於事故資料特性、數量與分析目的，本節先回顧事故發生相關計數模式之文獻，供後續應用時分析警示與行車異常事件發生與時空分布及車內行為之關聯性，以找出高風險路段。另外，考量車內外行車異常事件之結合具有時序關係，以及預測此些事故前兆之發生可能性，預測模式部分則回顧有關駕駛行為時序以及可能組合之資料規則探勘模式。

Miaou and Lum (1993) 分別建立傳統的線性迴歸模式以及卜瓦松迴歸模式，用以探索公路上的卡車事故和道路幾何設計之間的關係，其自變數包含年平均每日交通量 (AADT)、水平曲率、縱坡度及路肩寬度。事故和道路資料皆來自於 1985 年至 1987 年美國聯邦公路管理局 (FHWA) 的公路安全資訊系統 (HSIS)，分析路段具有均質的道路幾何特徵，且分析的時間段為一年，即是相同位置的道路會被視為 3 個獨立的路段，最終共有

4,983 個路段，長度介於 0.016 公里至 12.43 公里間。結果證明傳統的線性迴歸模式無法描述道路上擁有隨機、離散且非負特性的事故資料，而卜瓦松迴歸模式則具備分析車輛事故頻次時大部分所需的統計特性，因此卜瓦松迴歸模式近幾十年來被視為事故頻次分析的起點。

Shankar *et al.* (1995) 以道路幾何設計與天候因素，探討對事故發生頻次之影響，自變數包含水平曲率、坡度、降雨量、降雨天數以及降雪量。過往相關研究建議道路分段應採固定且相等長度，作者根據此將全長 61 公里的華盛頓州 90 號高速公路分為 10 個 6.1 公里的等長路段，從這 10 個路段 1988 年 1 月至 1993 年 5 月的事故頻次資料，觀察到有過度離散 (over-dispersion) 的情形，不符合卜瓦松迴歸模式對資料變異數等於平均數之要求，因此針對總事故頻次建立負二項迴歸模式。另外，根據不同的碰撞類型 (如追撞等) 也各自分別建立模式，其中除了翻車事故頻次是卜瓦松迴歸模式，其餘均為負二項迴歸模式，最終對顯著的自變數進行歸納分析。

Abdel Aty *et al.* (2000) 採用負二項迴歸模式分析事故頻次，針對連續 3 年 (1992~1994) 的佛羅里達 50 號國道共 1,606 筆事故資料進行模式校估，道路分割方式是以地理環境或道路幾何 (例如車道數及中央分隔寬度等) 的改變做為依據，共分割成 566 個事故分析路段。解釋變數包含年平均每日交通量 (AADT)、車道數、路肩寬度、道路鋪面、水平曲率、中央分隔型式、行車速度以及是否為城際道路等，研究結果顯示當年平均每日交通量增加、超速、道路寬度縮減、多車道以及是城際道路等變數對提高事故發生機率有顯著影響。

Anastasopoulos and Mannering (2009) 採用負二項迴歸模式建構事故頻次模式，分析美國印第安那州 1995 年至 1999 年 5 年期間之事故資料，欲找出顯著影響事故發生頻率之解釋因子。作者依據內外路肩寬度、中央分隔帶寬度、速限、車道數與鋪面性質等特性，將具有相同道路特徵之路段分類，共分割成 322 個研究路段，解釋變數包含日平均交通量、鋪面摩擦係數、路面水平曲率、路段長度、內側與外側路肩寬度、中央分隔帶寬度、每英里橋樑數以及是否有中央分隔護欄等。而研究結果顯示日平均交通量、日平均聯結車比例、路段長度、鋪面性質、中央分隔帶寬

度、內外側路肩寬度及每英里橋樑數等均對路段事故發生之頻率有顯著影響。

Wang *et al.* (2009) 欲探討交通壅塞對於道路交通事故頻次之影響，建立負二項迴歸和卜瓦松對數常態之非空間模式，以及依條件自迴歸 (CAR) 模式進行建構之空間模式。以英國 M25 環狀高速公路做為研究範圍，道路分段位置採高速公路之進出匝道，共劃分出 70 個分析路段，平均長度為 5.26 公里，且長度介於 0.76~15.39 公里之間。資料蒐集從 2004 年至 2006 年，包含事故資料和平均旅行速度、平均旅行時間及總車輛延滯等的交通特性資料，自變數則採道路擁擠指數、年平均每日交通量 (AADT)、路段長度、最小轉彎半徑、坡度、車道數、及車輛行駛方向等。研究結果顯示，英國 M25 環狀高速公路上交通壅塞對事故頻次之影響微乎其微。

黃珮芬 (2014) 首先採用基因演算法，以樣本間同質性最高為目標對樣本資料進行時空分割，再根據求得之樣本分割結果利用卜瓦松模式、負二項模式、零膨脹卜瓦松模式、零膨脹負二項模式建構事故頻次模式，並以績效指標針對時空最佳化分割下之事故頻次模式與傳統時空分割下之模式進行比較。該文獻採用我國 2004 年至 2008 年共 5 年，國道一號依南北向串連之事故資料進行模式建構與分析，解釋變數包含路段之最大上坡坡度、最大下坡坡度、對大坡度差、曲率半徑、克羅梭曲線參數、每日平均小車車流量、每日平均大車 (大型車+聯結車) 車流量與平均車道數共 8 項。研究結果顯示該研究所提最佳時空切割之負二項迴歸模式有最佳模式預測能力，且最大上坡坡度、最大下坡坡度、曲率半徑、克羅梭曲線參數與小型車車流量、大型車車流量、車道數等變數顯著影響事故之頻次。

盛郁淳 (2014) 分別建立單變量與多變量事故頻次模式，單變量事故頻次使用單變量之卜瓦松迴歸模式、負二項迴歸模式與廣義卜瓦松迴歸模式進行模式建構；分時段之多變量事故頻次模式則採用多變量卜瓦松迴歸模式與多變量廣義卜瓦松迴歸模式進行建構，用以推估及預測各路段下各時段之事故頻次。作者使用我國 2005 年國道 1 號之交通事故資料進行分析，解釋變數分為空間變數與時間變數兩部分，空間變數又可分為道路幾何特性、設施與環境特性以及交通特性等 3 類。時間變數則考量

日夜光線亮度、光線照射角度以及不同時段下之車流量對事故頻次在時間的分布上造成之影響，提出影響之相關假設。研究結果顯示多變量卜瓦松迴歸模式在平均預測事故件數上較接近平均實際事故件數，但其模式績效較差，整體表現以負二項迴歸與分群整合模式為最佳，事故發生件數與最大下坡度、克羅梭曲線參數、測速照相點數量以及重車比例呈反向影響，與曲率、鄰近都會區及小車車流量呈正向影響。並且各時段之事故數會特定集中於不同路段群，日間 (07~14) 之事故較易於鄰近系統交流道之路段發生，傍晚 (14~20) 之事故較易於非鄰近系統交流道之路段發生，而夜間 (20~23) 與清晨 (23~07) 之事故則較易於郊區路段發生。

邱裕鈞、傅強 (2015) 採用多變量廣義卜瓦松 (Multivariate Generalized Poisson) 模式分析不同事故類別 (嚴重程度、碰撞型態) 之高速公路事故頻次，此方法改善傳統單變量模式之分析限制，可計算事故類別間之關聯性及資料離散程度。研究資料以我國 2005 年國道 1 號高速公路的事故統計案例進行分析，並依照交流道所界定分析路段單元，解釋變數包含上下坡度、曲率、克羅梭曲線參數、車道數、總交通量、小車比例、大車比例、聯結車比例、平均年雨量、速限、收費站、休息站、固定式測速照相、路段設置戰備道、鄰近重要都會區與鄰近港口、機場及工業區等。研究結果顯示多變量模式精確度確較單變量模式佳，且 A1 與 A2 事故兩高嚴重性事故有高度正向關聯，而在碰撞型態的部分，則以同向擦撞、追撞及其它碰撞彼此之間有高度正相關。

以上研究提供合理且適切的變數分類與選取，包含道路環境、曝光量，以及時段路段 (時空分割)，如透過基因演算法尋找適當分類方式，事故頻次模式相關文獻彙整如表 2.4-1。

表 2.4-1 事故空間分析與預測研究整理

作者(年份)	使用模式	研究地點	資料期間	時空分段類型	解釋變數
Miaou and Lum (1993)	線性迴歸模式 卜瓦松迴歸模式	美國聯邦公路	1985~1987	以具有相同道路特徵之路段進行分段。	年平均每日交通量 (AADT)、水平曲率、縱坡度及路肩寬度。
Shankar <i>et al.</i> (1995)	卜瓦松迴歸模式 負二項迴歸模式	華盛頓州 90 號高速公路	1988~1993	以固定道路長分段。	水平曲率、坡度、降雨天數及降雨、降雪量。
Abdel Aty <i>et al.</i> (2000)	負二項迴歸模式	佛羅里達 50 號國道	1992~1994	以地理環境或道路幾何的改變進行分段。	年平均每日交通量 (AADT)、車道數、路肩寬度、道路鋪面、水平曲率、中央分隔型式、行車速度以及是否為城際道路。
Anastasopoulos and Mannering (2009)	負二項迴歸模式	美國印第安那州	1995~1999	以具有相同道路特徵之路段進行分類。	日平均交通量、鋪面摩擦係數、路面水平曲率、路段長度、內外側路肩寬度、中央分隔帶寬度、每英里橋樑數及是否有中央分隔護欄。
Wang <i>et al.</i> (2009)	負二項迴歸空間模式 卜瓦松對數常態空間模式	英國 M25 環狀高速公路	2004~2006	以具有相同道路特徵之路段進行分段。	道路擁擠指數、年平均每日交通量 (AADT)、路段長度、最小轉彎半徑、坡度、車道數、及車輛行駛方向等。
黃珮芬 (2014)	卜瓦松模式 負二項模式 零膨脹卜瓦松模式 零膨脹負二項模式	我國國道一號	2004~2008	採用基因演算法進行時空分割。	路段之最大上坡坡度、最大下坡坡度、對大坡度差、曲率半徑、克羅梭曲線參數、每日平均小車車流量、每日平均大車 (大型車+聯結車) 車流量與平均車道數。

表 2.4-1 事故空間分析與預測研究整理 (續 1)

作者(年份)	使用模式	研究地點	資料期間	時空分段類型	解釋變數
盛郁淳(2014)	卜瓦松迴歸模式 負二項迴歸模式 廣義卜瓦松迴歸 模式	我國國道一 號	2005	-	路段長、速度、曲率、曲率半徑、克羅梭曲線參數、坡度、車道數、左轉車道數、右轉車道數、車道寬、路肩寬、道路寬、分隔島寬、視距、縱坡度、最大上坡坡度、最大下坡坡度、最大坡度差、平曲線與豎曲線長度、路面摩擦力、總道路里程、國道與縣道分別佔總道路之比例、天候、光線、霧區路段、年雨量、降雨天數、年降雪量、路面狀態、路面缺陷、障礙物、左轉車道線、左轉車道緣石、右轉車道、地形、道路類型、行人數、城鄉區域、收費站、休息站、鄰近都會區、鄰近港口、機場或工業區、鄰近系統交流道、鄰近戰備道、交流道數、匝道數、橋梁數量、坡道數量、照明設備、測速照相、路旁特徵、環境特徵、年平均每日交通量(AADT)、平均每日交通量(ADT)、平均每日小車流量、平均每日大車流量、平均每日聯結車流量、小車比例、大車比例、聯結車比例、重車比例、平均每日車流量、尖峰小時係數(PHF)、駕駛人數、登記車輛數、人口數、家戶收入、駕駛特性、總車公里數、城鄉公路分別佔總車公里數之比例、各旅次產生與吸引數。

表 2.4-1 事故空間分析與預測研究整理 (續 3)

作者(年份)	使用模式	研究地點	資料期間	時空分段類型	解釋變數
邱裕鈞、傅強 (2015)	廣義卜瓦松模式 多變量廣義卜瓦 松模式	我國國道一 號	2005	以交流道做為道路切割依據。	上下坡度、曲率、克羅梭曲線參數、車道數、總交通量、小車比例、大車比例、聯結車比例、平均年雨量、速限、收費站、休息站、固定式測速照相、路段設置戰備道、鄰近重要都會區與鄰近港口、機場及工業區。

由於車載資訊系統能紀錄駕駛人駕駛行為，因此可將特殊、警示或行車異常事件種類與時間等資訊詳實記載並進行分析研究。Cai *et al.* (2021) 與美國 1 家大型商業貨車公司合作，蒐集到 2015 年 4 月至 2016 年 3 月 1 年間 31,828 名貨車司機的車載設備資料，該設備記錄了 4 種警示事件，包括未保持安全距離、急遽煞車、車身不穩與碰撞預警，自變數納入駕駛人特性，如年齡、性別、所屬部門以及駕駛風格，並使用貝葉斯 (Bayesian) 負二項迴歸模式進行分析。基於樣本量充足，不僅能探明此四種警示事件與貨車司機事故頻次間的關係，還能夠分析事件與受傷人數與死亡人數的關係。研究結果表示警示事件與事故頻次和受傷人數有顯著的正向關聯，每 1 萬英里任何類型的警示事件數量每增加 1 個單位，每英里碰撞事故將增加 8.4%，而每英里的受傷人數將增加 8.7%。雖然該研究中的自然駕駛資料不包含影像資料，但車載設備資料的警示事件已經明確的捕捉了重要的駕駛行為，包含駕駛車輛速度、激進駕駛以及潛在的分心行為，因此建議貨車業者參考該研究參數估計結果，應用於駕駛教育訓練中，或是制定調度和路線策略以減少司機駕駛警示事件發生次數。

而早期採用車內影像紀錄器 (In-Vehicle Data Recorders, IVDR) 蒐集之資料進行事件分類，如 Musicant *et al.* (2010) 在研究中蒐集：加減速、急轉彎、突然切換車道等，並利用旅次的旅行時間長度 (duration) 與事件發生率 (Event Frequency, EF) 進行探索性分析。同時，亦將時間以固定時段分割，再以負二項迴歸進行預測，並整理出在旅次起迄、夜晚時，事件發生的機率普遍較高。該研究雖未討論有無事件時序之議題，但透過駕駛行為資料與影像分析異常駕駛行為，已有將時間進行分割並加以解析之觀點，如圖 2.4-1 所示。

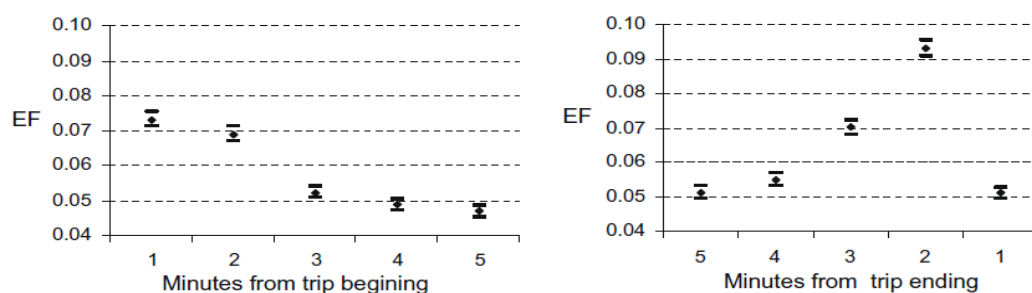


圖 2.4-1 旅行時間分割紀錄駕駛行為事件發生率

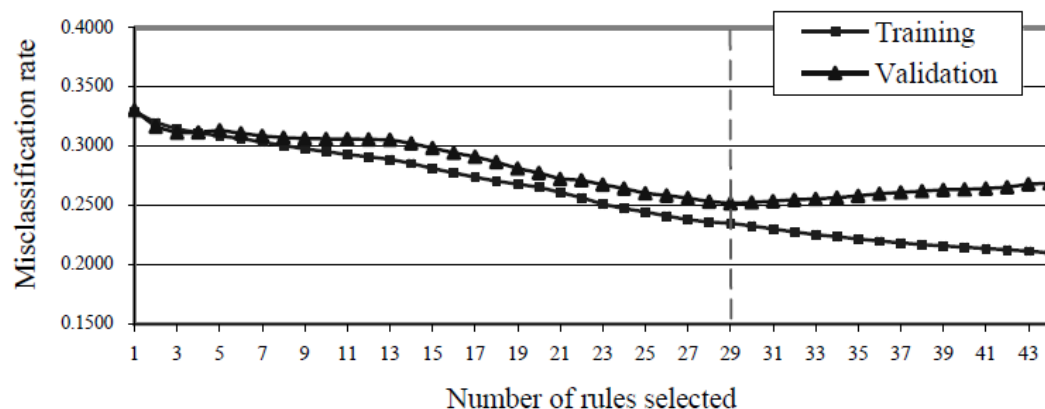
隨著 ADAS 發展逐漸成熟與更能說服駕駛安裝以獲得更多資料，並落實至管理意涵，現今已有更多研究針對職業駕駛蒐集資料，並將事件定義更細緻，而採用巨量資料的探勘方式。透過車載資訊系統能記載駕駛員開車時的操作任務，Li *et al.* (2013) 將車內操作導航、收音機等車內其他儀器做為駕駛的次要任務，針對 20 名選定駕駛進行分心測試並分析，並將一些操作特性定義與探索，以供區分為駕駛任務或次要任務之影響。若將主要與 7 個次要任務，僅以主次要之二分法分類，進行訓練並判斷，其模式準確度可達 77%；而若將次要任務各自獨立，共有 8 項主次要任務，該研究雖僅 41% 準確度，但仍已顯著反映車載系統之判讀解釋變數（如：眨眼頻率、視線離開道路頻率與時長等）進行建模分析已有一定成效；並且，透過後者之模式，能看出不同次要任務對分心之影響程度與重要度，即特定任務使駕駛更容易分心，該研究利用高斯混合模型 (Gaussian Mixture Models, GMMs) 量化駕駛員行為與預期之差距。

Lyu *et al.* (2021) 則設計讓駕駛員實地駕車，操作測試選定在中國大陸武漢之固定路線場域，捕捉遇到事件時駕駛反應的初象與最大風險等級之評定。該研究對 ADAS 系統包含前方碰撞預警、車道偏移警示與車距監控警示，具有時間車距與車輛加減速之門檻觸發警示機制與採取動作時點之標記，針對事件紀錄前後共 20 秒，對微觀資料所需的時段性進行切割，並以減速率與動能折損率兩指標進行集群分析，再以 k-means 分 3 群，訂為輕度、中度、高度風險（依照跟車距離與時間車距、反應時間計算的 Safety Margin, SM 值）。由於挑選之駕駛有經驗較資淺與經驗較豐富者，並透過事前事後 min SM 與 SM 於剎車當下之值分析出 ADAS 對輕中度風險與資淺駕駛有正效果、對高度風險與資深駕駛則偏負效果；然而，正向改善的程度比受影響程度大。

Higgs and Abbas (2013) 使用兩階段演算法之方式，先將車輛跟車時的時段定義與分割，說明時間之分布，再依照其相似度透過數個駕駛行為：縱向加速度、橫向加速度、偏向率、車速、車道偏移、偏向角、範圍與其比率，以 k-means 分群。此研究設立 3 個假說，是針對模擬方法提出探討，包含：所有駕駛的同質性假設、車隊跟車環境下駕駛有異質性，但每單一駕駛是否操作有同質性、以及一般跟車時單一駕駛是否能維持不變駕駛行為。但自然駕駛資料乃透過車載資訊系統向商用車駕駛蒐集資

料，再分別以駕駛特性集群、跟車環境時段集群，與駕駛行為維持時段進行分類。同時，駕駛人依照所被蒐集的資料，亦被分為高度風險、中度風險以及低度風險之駕駛。

Chiou *et al.* (2013) 亦使用兩階段資料探勘之演算法針對駕駛遭遇的危險情境分析，雖是以較巨觀之國道高速公路單車輛事故資料 (2003~2007 年)，然而透過事故資料登記欄位，道路因素與駕駛人於事故當下狀態變數之資料獲得完整記錄，針對重要危險情境的因子可進行組合，對事故嚴重度做為被解釋變數分析。該研究處理的失誤鏈 (error-chain) 之根據，即車輛事故可能歸因於不只 1 件，而為一連串的因素影響。是故，第 1 階段先以遺傳探勘方法 (Genetic mining rule, GMR) 將此些變數以規則之方式探勘，包含生成、覆蓋與關聯之建立。由於研究中有 21 個變數且不全然是二元變數，該研究以逐步探勘之方式提升效率，挑選適當訓練規則數，如圖 2.4-2，並將訓練結果與決策樹比較，確認該研究探勘方式較佳且易於解釋。基此，第二階段則以混合羅吉特模式 (Mixed logit model)，將各變數與嚴重度建模，分類安全與危險因子。此研究亦提及，當時條件無法包含微觀的駕駛人心智狀態、反應行為、疲勞度、事故當下車流交通狀況。



(資料來源：Chiou *et al.*, 2013)

圖 2.4-2 GMR 模式的學習與驗證過程

2.4.3 小結

本計畫目前車載資訊系統，包含車外 ADAS、車內影像與車機，已獨立進行駕駛人行為之資訊蒐集，可分析各類型車內分心行為，及對應車

外警示、行車異常事件之發生與頻率，亦能整合既有的巨觀環境資訊資訊等。考量各業者將有不同設備程度之條件，可將資料分為：僅有 OBD 資料、整合車外 ADAS、加入車內影像資料，以及加入外部環境資料等四級。

時空分析將基於計畫蒐集資料，結合本年度主軸行車異常事件及高風險駕駛行為，透過本計畫所定義之高風險駕駛行為、門檻，透過巨、微觀之分析，探勘高風險路段、時序發生之推估與比例，整合安全之計數模式進行分析。

2.5 高風險駕駛行為與行車異常事件之管理案例

本節蒐集國外透過車機系統實施車隊管理之文獻與案例並將監理與業者管理研究案例分為歐美地區與亞洲地區兩部分進行介紹。

2.5.1 歐美地區

(一) 監理

美國聯邦汽車運輸安全局 (Federal Motor Carrier Safety Administration, FMCSA) 為提升國內大型商用車輛的安全水準，自 2010 年起啟動 CSA 計畫 (Compliance, Safety, Accountability program)。FMCSA 於 2023 年 4 月發表之 Safety Measurement System (SMS) Methodology: Behavior Analysis and Safety Improvement Category (BASIC) Prioritization Status 中說明其對業者評比之方式與標準，該計畫將運輸業者分為客運、危險品運輸以及一般貨物運輸業者 3 類，並由 7 大指標 (表 2.5.1-1) 評估各個運輸業者的風險程度，根據 2 年內資料計算業者各項指標原始分數，分數越低代表風險程度越低，接著將原始分數與業者所在組別內其他業者進行比較並轉換為百分比表示，依各類別之門檻值評斷，一旦超出門檻值將會依不同風險程度對業者發出警告信、調查、罰款甚至勒令停業等處罰，詳細分數計算方式與分組方式將於後續段落分別介紹。根據成效評估報告指出在實施本計畫後，FMCSA 透過警示、調查等介入手段每年穩定減少

運輸業者事故發生率，其中在小規模 (10 台車以下) 業者中效果更加明顯。

表 2.5-1 FMCSA 評估項目表

指標	內容
危險駕駛	超速、分心、不當變換車道等
工作時數	超時工作、疲勞駕駛
駕駛適性	體檢合格、訓練、經驗
藥物或酒精使用	駕駛期間是否使用違禁品
車輛維護	是否適當維護營運車輛
危險物品運送	程序是否符合標準
事故	事故發生頻率及嚴重性

1. 危險駕駛指標

危險駕駛指標原始分數計算考慮事件時間、違規風險權重以及曝光量，公式如式 2.5-1 所示。事件時間權重分為 3 等級，近 6 個月發生之事件為 3，距計算時間 6 至 12 個月內發生之事件為 2，其餘事件則為 1。違規事件權重依 FMSCA 內部對各事件的風險程度定義為 1 至 10。平均車輛數為業者目前的車輛數、6 個月前的車輛數以及 18 個月前車輛數總和之平均。使用率因子為透過行駛里程調整曝光率的參數，行駛里程根據運輸業者填寫之 MCS-150 表格或是執法單位填寫之 MCS-151 表格取得，計算首先將業者分為聯結車為主 (聯結車占比超過車隊總車數 70%) 與一般貨車為主兩類，接著將最近紀錄之總里程除以上述之平均車輛數，使用率因子即依所求得之平均行駛里程選擇表 2.5-2 所對應之數值。

$$\text{危險駕駛指標原始分數} = \frac{\text{事件時間權重} \times \text{違規事件權重}}{\text{平均車輛數} \times \text{使用率因子}} \quad (2.5-1)$$

表 2.5-2 使用率因子數值對照表

聯結車為主		一般貨車為主	
平均行駛里程	使用率因子	平均行駛里程	使用率因子
<80,000	1	<20,000	1
80,000~160,000	$1 + \frac{\text{平均里程}-80,000}{133,333}$	20,000~60,000	平均里程/20,000
160,000~200,000	1.6	60,000~200,000	3
>200,000	1	>200,000	1
無資料	1	無資料	1

分組同樣將業者依車隊型態分為聯結車與一般貨車為主 2 類進行，首先排除針對業者危險駕駛之調查次數少於 3 次之業者，其餘業者根據被發現危險駕駛的次數分為 5 個組別如表 2.5-3 所示。每組別內皆進行業者排序，根據危險駕駛指標門檻值 (表 2.5-4) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-3 危險駕駛指標業者分組

聯結車為主		一般貨車為主	
組別	違規次數	組別	違規次數
1	3~8	1	3~4
2	9~21	2	5~8
3	22~57	3	9~18
4	58~149	4	19~49
5	150 以上	5	50 以上

表 2.5-4 危險駕駛指標業者分組

客運業者	危險品運輸業者	一般貨運業者
後 50%	後 40%	後 35%

2. 工作時數指標

工作時數指標原始分數計算考慮事件時間、違規風險以及調查時間權重，公式如式 (2.5-2) 所示。事件與調查時間權重分為 3 等級，近 6 個月發生之事件或調查作業為 3，距計算時間 6 至 12 個月內發生之事件或調查作業為 2，其餘時間之事件或調查作業則為 1。違規事件權重依 FMSCA 內部對各事件的風險程度定義為 1 至 10。

$$\text{工作時數指標原始分數} = \frac{\text{事件時間權重} \times \text{違規事件權重}}{\text{調查時間權重}} \quad (2.5-2)$$

分組首先排除針對業者工作時數之調查次數少於 3 次之業者，其餘業者根據違規次數分為 5 個組別如表 2.5-5 所示。每組別內皆進行業者排序，根據工作時數指標門檻值 (表 2.5-6) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-5 工作時數指標業者分組

組別	調查次數
1	3~10
2	11~20
3	21~100
4	101~500
5	501 以上

表 2.5-6 工作時數指標門檻值

客運業者	危險品運輸業者	一般貨運業者
後 50%	後 40%	後 35%

3. 駕駛適性指標

駕駛適性指標原始分數計算考慮事件時間、違規風險以及調查時間權重，公式如式 (2.5-3) 所示。事件與調查時間權重分為 3 等級，近 6 個月發生之事件或調查作業為 3，距計算時間 6 至 12 個月內發生之事件或調查作業為 2，其餘時間之事件或調查作業則為 1。違規事件權重依 FMSCA 內部對各事件的風險程度定義為 1 至 10。

$$\text{駕駛適性指標原始分數} = \frac{\text{事件時間權重} \times \text{違規事件權重}}{\text{調查時間權重}} \quad (2.5-3)$$

分組首先排除調查次數少於 5 次之業者，其餘業者根據違規次數分為 5 個組別如表 2.5-7 所示。每組別內皆進行業者排序，根據駕駛適性指標門檻值 (表 2.5-8) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-7 駕駛適性指標業者分組

別	調查次數
1	5~10
2	11~20
3	21~100
4	101~500
5	501 以上

表 2.5-8 駕駛適性指標門檻值

客運業者	危險品運輸業者	一般貨運業者
後 35%	後 25%	後 20%

4. 藥物或酒精使用指標

藥物或酒精使用指標原始分數計算考慮事件時間、違規風險以及調查時間權重，公式如式 (2.5-4) 所示。事件與調查時間權重分為 3 等級，近 6 個月發生之事件或調查作業為 3，距計算時間 6 至 12 個月內發生之事件或調查作業為 2，其餘時間之事件或調查作業則為 1。違規事件權重依 FMSCA 內部對各事件的風險程度定義為 1 至 10。

$$\text{藥物或酒精使用指標原始分數} = \frac{\text{事件時間權重} \times \text{違規事件權重}}{\text{調查時間權重}} \quad (2.5-4)$$

分組首先排除無違規受調查之業者，其餘業者根據違規次數分為 5 個組別如表 2.5-9 所示。每組別內皆進行業者排序，根據藥物或酒精使用指標門檻值 (表 2.5-10) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-9 藥物或酒精使用指標業者分組

組別	調查次數
1	1
2	2
3	3
4	4 以上

表 2.5-10 藥物或酒精使用指標門檻值

客運業者	危險品運輸業者	一般貨運業者
------	---------	--------

後 35%	後 25%	後 20%
-------	-------	-------

5. 車輛維護指標

車輛維護指標原始分數計算考慮事件時間、違規風險以及調查時間權重，公式如式 (2.5-5) 所示。事件與調查時間權重分為 3 等級，近 6 個月發生之事件或調查作業為 3，距計算時間 6 至 12 個月內發生之事件或調查作業為 2，其餘時間之事件或調查作業則為 1。違規事件權重依 FMSCA 內部對各事件的風險程度定義為 1 至 10。

$$\text{車輛維護指標原始分數} = \frac{\text{事件時間權重} \times \text{違規事件權重}}{\text{調查時間權重}} \quad (2.5-5)$$

分組首先排除調查次數少於 5 次之業者，其餘業者根據違規次數分為 5 個組別如表 2.5-11 所示。每組別內皆進行業者排序，根據車輛維護指標門檻值 (表 2.5-12) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-11 車輛維護指標業者分組

組別	調查次數
1	5~10
2	11~20
3	21~100
4	101~500
5	501 以上

表 2.5-12 車輛維護指標門檻值

客運業者	危險品運輸業者	一般貨運業者
後 35%	後 25%	後 20%

6. 危險物品運送指標

危險物品運送指標原始分數計算考慮事件時間、違規風險以及調查時間權重，公式如式 (2.5-6) 所示。事件與調查時間權重分為 3 等級，近 6 個月發生之事件或調查作業為 3，距計算時間 6 至 12 個月內發生之事件或調查作業為 2，其餘時間之事件或調查作

業則為 1。違規事件權重依 FMSCA 內部對各事件的風險程度定義為 1 至 10。

$$\text{危險物品運送指標原始分數} = \frac{\text{事件時間權重} \times \text{違規事件權重}}{\text{調查時間權重}} \quad (2.5-6)$$

分組首先排除調查次數少於 5 次之業者，其餘業者根據違規次數分為 5 個組別如表 2.5-13 所示。每組別內皆進行業者排序，根據危險物品運送指標門檻值 (表 2.5-14) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-13 危險物品運送指標業者分組

組別	調查次數
1	5~10
2	11~15
3	16~40
4	41~100
5	101 以上

表 2.5-14 危險物品運送指標門檻值

客運業者	危險品運輸業者	一般貨運業者
後 20%	後 20%	後 20%

7. 事故指標

事故指標原始分數計算考慮事件時間、事故權重以及曝光量，公式如式 (2.5-7) 所示。事件時間權重分為 3 等級，近 6 個月發生之事件為 3，距計算時間 6 至 12 個月內發生之事件為 2，其餘事件則為 1。事故權重部分未有人員受傷為 1，有傷亡為 2，若為危險物品運送車輛則前述事故權重再加 1。平均車輛數為業者目前的車輛數、6 個月前的車輛數以及 18 個月前車輛數總和之平均。使用率因子為透過行駛里程調整曝光率的參數，行駛里程根據運輸業者填寫之 MCS-150 表格或是執法單位填寫之 MCS-151 表格取得，計算首先將業者分為聯結車為主 (聯結車占比超過車隊總車數 70%) 與一般貨車為主 2 類，接著將最近紀錄之總里程除以

上述之平均車輛數，使用率因子即依所求得之平均行駛里程選擇表 2.5-15 所對應之數值。

$$\text{事故指標原始分數} = \frac{\text{事件時間權重} \times \text{事故權重}}{\text{平均車輛數} \times \text{使用率因子}} \quad (2.5-6)$$

表 2.5-15 使用率因子數值對照表

聯結車為主		一般貨車為主	
平均行駛里程	使用率因子	平均行駛里程	使用率因子
<80,000	1	<20,000	1
80,000~160,000	$1 + \frac{\text{平均里程} - 80,000}{133,333}$	20,000~60,000	平均里程/20,000
160,000~200,000	1.6	60,000~200,000	3
>200,000	1	>200,000	1
無資料	1	無資料	1

分組同樣將業者依車隊型態分為聯結車與一般貨車為主 2 類進行，首先排除事故件數少於 2 件之業者，其餘業者根據事故件數分為 5 個組別如表 2.5-16 所示。每組別內皆進行業者排序，根據事故指標門檻值 (表 2.5-17) 對超出門檻值之業者實施強制介入手段如警告或調查等。

表 2.5-16 事故指標業者分組

聯結車為主		一般貨車為主	
組別	事故件數	組別	事故件數
1	2~3	1	2
2	4~6	2	3~4
3	7~16	3	5~8
4	17~45	4	9~26
5	46 以上	5	27 以上

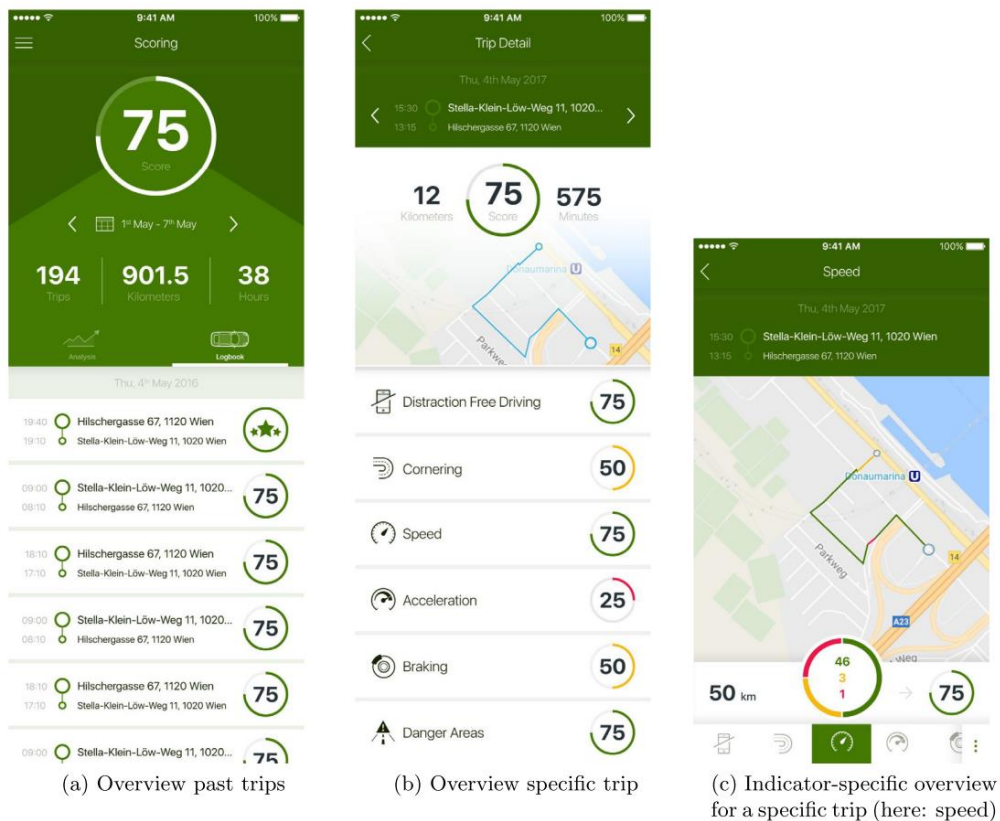
表 2.5-17 事故指標門檻值

客運業者	危險品運輸業者	一般貨運業者
後 50%	後 40%	後 35%

(二)管理文獻與案例

Peer *et al.* (2020) 透過 App 紀錄奧地利 130 名駕駛人的駕駛行為，其中包含超速、加減速、轉彎等行為，在紀錄的同時也能直接將駕駛數據呈現在 App 頁面上供駕駛人參照 (圖 2.5-1)。該研究分為 3 階

段，第 1 階段僅記錄駕駛人的駕駛數據做為分析基礎，第 2 階段則會將蒐集到的駕駛數據作分析並分別為駕駛行為評分以及提供改善建議給駕駛人參考，最後的第 3 階段為改善效果的追蹤，將不再為駕駛行為評分僅觀察駕駛人在接收改善建議後是否對其行為作出改善，降低風險程度。研究結果發現駕駛人在經過建議後對駕駛安全性有小幅正向效果，此外相對小心的駕駛使用 App 的頻率相對較高，App 使用率越高的駕駛人行為改善效果也更加明顯。



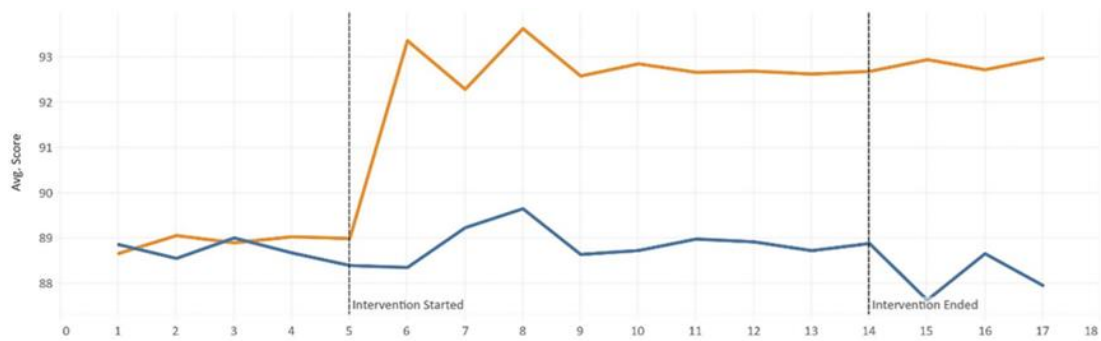
(資料來源：Peer *et al.*, 2020)

圖 2.5-1 駕駛行為監測 App 操作介面示意圖

Masello *et al.* (2023) 挑選 373 名輕型商用車駕駛共約 100 萬旅次的駕駛數據研究即時警示系統對駕駛帶來的影響效果。研究選擇每行駛一百公里超速、急加減速以及分心發生件數做為風險評估指標。研究結果顯示警示有助於減少駕駛分心事件的發生，另外若將主被動的監管系統結合獎勵機制更能有效降低急加減速等危險事件發生。

Ghamari *et al.* (2022) 將公車駕駛分為實驗組與對照組，利用車載系統紀錄駕駛人超速、急加減速、劇烈變換方向、長時駕駛次數及

夜間行駛比例。實驗組駕駛將會在每週收到根據其駕駛行為計算出的分數與等級，觀察駕駛人在得到這些資訊後是否會提高駕駛安全度。根據研究結果所繪製出的趨勢圖 (圖 2.5-2) 發現實驗組駕駛在獲得回饋後分數明顯上升，意味著駕駛行為變得更加安全。此外根據檢定結果，實驗組與對照組間的分數有顯著差異，即便在停止回饋後，實驗組駕駛也能維持良好的駕駛行為，顯示透過車載系統紀錄並針對個別駕駛給出改善建議對於駕駛人有正面影響。



(資料來源：Ghamari *et al.*, 2020)

圖 2.5-2 分數變化趨勢比較 (黃為實驗組，藍為對照組)

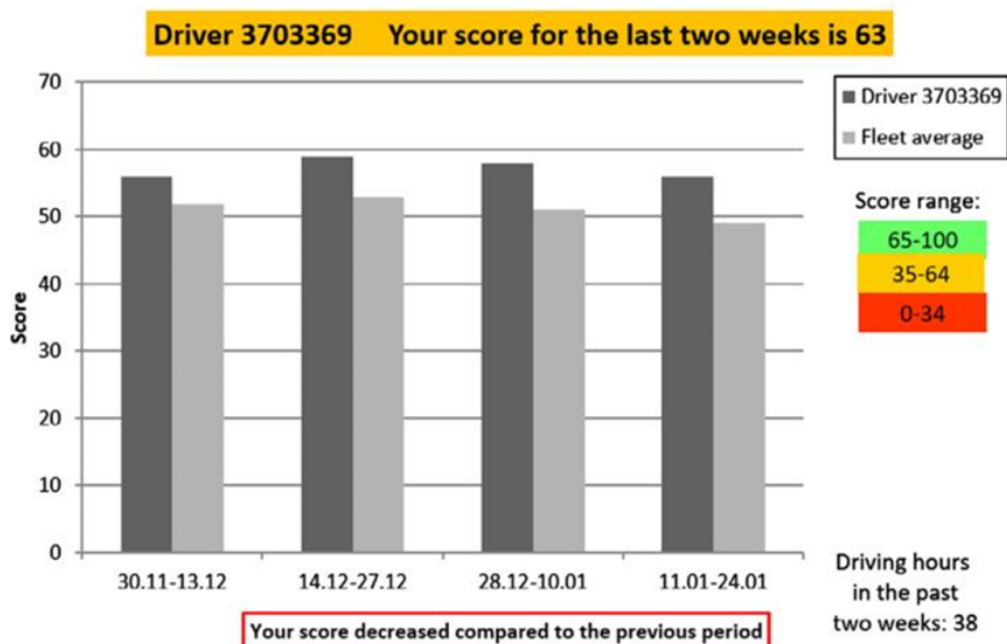
Farah *et al.* (2013) 透過車載設備紀錄超速、加減速、轉向、變換車道等狀況下的 g 力做為風險程度的評估媒介，並將駕駛人每趟次的駕駛行為依不同風險程度做為分為低風險 (綠)、中風險 (黃)、高風險 (紅) 3 等級 (圖 2.5-3)，根據研究結果可得知經由將分析車載系統紀錄的數據回饋給駕駛，能夠有效減少駕駛發生事故的比率。

Toledo & Shiftan (2016) 蒐集 155 台車輛的行車數據，根據紀錄到之剎車和側向 g 力以及車速判斷駕駛的風險高低並將風險程度轉換為百分位分數，分數越高則代表風險值越低。研究將駕駛依不同分數分為 3 等級 (圖 2.5-4)，結果顯示在駕駛接受第 1 階段的回饋後有效減少 20% 的事件比率，在經過第 2 階段的回饋後將能再減少 7% 的事件比率。



(資料來源：Farah *et al.*, 2013)

圖 2.5-3 特定駕駛 2007 年 3 月旅次資料

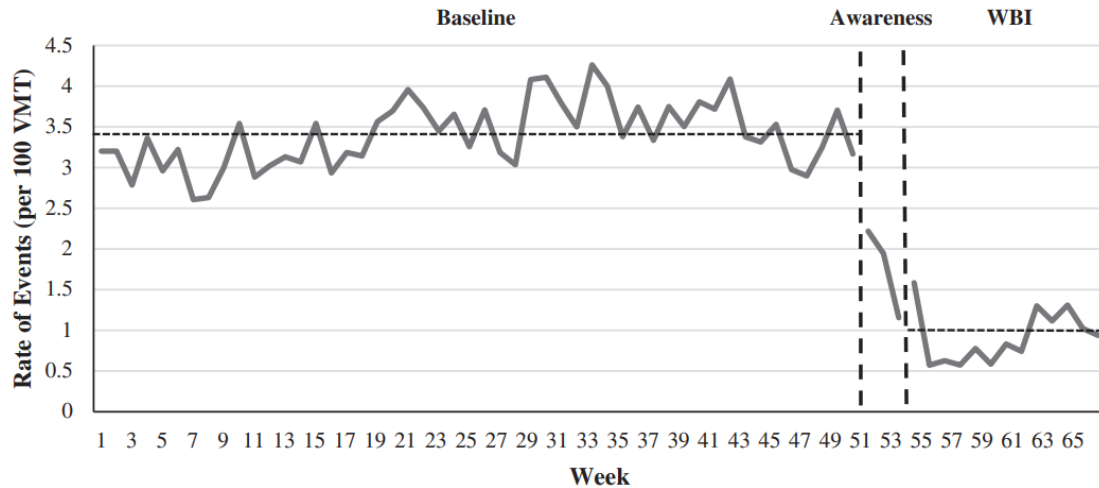


(資料來源：Toledo & Shiftan, 2016)

圖 2.5-4 某駕駛與平均分數比較圖

Camden *et al.* (2019) 蒐集超速、急加速、急減速及急轉彎等危險事件並以每行駛 100 公里做為駕駛行為的判斷指標。研究分為 3 階段，第一階段記錄駕駛原有的駕駛行為，第 2 階段提醒受測駕駛人未來將有駕駛行為改善計畫，第 3 階段則是要求在 1 天內發生超過 3 次危險

行為之駕駛人接受線上課程。研究結果顯示自第 2 階段起，危險事件發生頻率明顯降低，可以預期將線上教育課程應用到商用車隊能有效減少事故發生並減少死傷數，進而降低業者所需的保險費用。



(資料來源：Camden *et al.*, 2019)

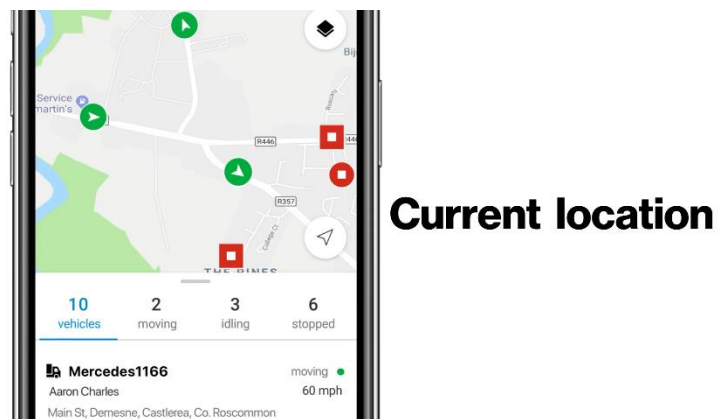
圖 2.5-5 駕駛風險評估案例

Ziakopoulos *et al.* (2022) 回顧過往分析車機數據對駕駛行為改善的相關研究探討車機資料應用對保險業的影響，文獻中有 7 項研究指出能減少 20%~43%的道路事故，3 項研究指出事故風險下降 37%~50%，7 項研究證實能減少 15~80%超速事件，6 項研究發現減少 10~52%危險事件發生。透過回顧結果驗證車機數據對於減少危險駕駛行為有正面效果，將能應用於目前新興的 UBI 保險，即保險費用會參考駕駛行為一併評估，鼓勵駕駛改善危險行為，進而減少事故發生。

Progressive Corporation 為一美國保險公司，透過小型車載設備監測駕駛人的駕駛行為並將數據回傳至總公司評斷該名駕駛的行為是否妥當。藉著該設備，保險公司將能更仔細審視個駕駛人的駕駛行為並依據不同駕駛人訂定適當的保費，不再以過去單純依年齡做為保費收取標準，保險公司與駕駛人也將能獲取更大的利益。

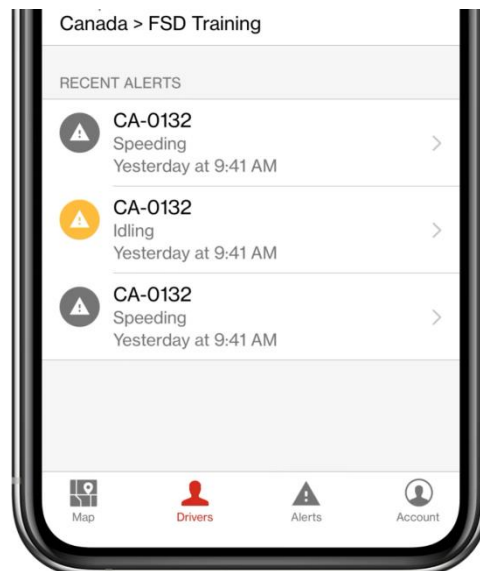
美國 Verizon Networkfleet 為一線上車隊管理系統，不管車隊規模大小皆適用，配備車機及後台管理系統可以看到駕駛人資訊、車輛位置、燃油使用等資料，搭配攝影機便能更清楚地掌握完整的駕駛

過程，車機記錄駕駛行為並定期產出報表為駕駛表現評分。除了透過電腦查看之外，該系統同時也支援 APP，供管理方可以在任何時間點以不同平台即時查看車隊所有狀況與資訊 (圖 2.5-6、圖 2.5-7)，進一步提升管理效果。美國運輸業者 Bill Howe 的公司標語為「照顧好員工，他們就會幫你照顧好客戶」，期望透過合適的教育降低員工駕駛過程中遭遇風險的機會故引進該系統。在裝設後駕駛平均得分明顯提高，事故數也顯著減少，燃油費以及保險花費也同時達到降低的效果。



(圖片來源：<https://www.verizonconnect.com/>)

圖 2.5-6 APP 操作畫面示意圖



(圖片來源：<https://www.verizonconnect.com/>)

圖 2.5-7 APP 警示畫面示意圖

2.5.2 亞洲地區

(一)管理文獻與案例

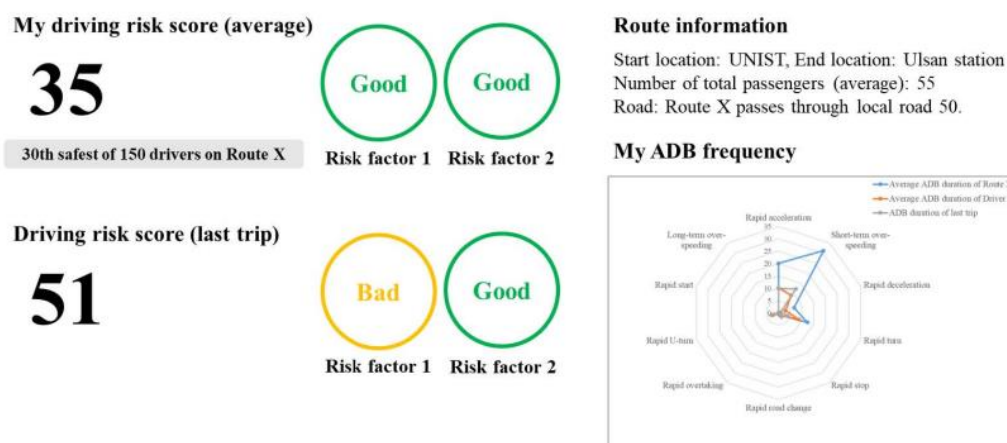
Kim *et al.* (2018) 蒐集 5 輛裝設車機系統行駛高速公路的客運車輛共 140 筆行車數據，內容包含行駛距離、車速、引擎轉速、方位角等資訊。研究以韓國政府所定義之危險駕駛行為（急加減速、急變換車道、不當超車、急轉彎）做為標準，將數據依照危險事件發生的次數分為高風險、中風險與低風險 3 個等級（圖 2.5-8）。研究結果顯示急加速與急減速以及急轉彎有相關性，又急加速是最常見之危險行為樣態，故推斷若能減少急加速行為將能同時改善急減速與急轉彎事件的發生。此外，透過行車數據將駕駛分制不同安全等級，可為管理階層提供改善優先順序並給予駕駛適當改善建議，藉由客觀數據也能提升駕駛的接受度與改善效果。

Group	Sample	Rapid acceleration	Rapid start	Rapid deceleration	Rapid stop	Rapid lane change	Rapid overtaking	Rapid turn	Rapid U-turn	Total
High risk	13	4.34	0.00	1.00	0.04	0.08	0.06	0.91	0.04	6.46
Middle risk	42	2.81	0.00	0.73	0.03	0.08	0.02	0.85	0.01	4.52
Low risk	58	1.50	0.00	0.35	0.01	0.09	0.01	0.64	0.00	2.59

（資料來源：Kim *et al.*, 2018）

圖 2.5-8 各等級平均危險事件發生件數

Seo *et al.* (2022) 透過車機數據蒐集韓國 20 條不同路線客運駕駛的行車數據，擷取其中的危險駕駛行為，包含超速、急加減速、急轉向、不當變換車道等，並將駕駛行為轉換為百分位分數以利後續分析，得分越高代表行為越危險。研究顯示能有效將駕駛分為高風險與低風險兩組（分別為得分在前 25% 及後 25% 的群體），也能根據分析結果掌握需要改善的項目（圖 2.5-9），提供一個更明確的駕駛安全教育方針。



(資料來源：Seo *et al.*, 2022)

圖 2.5-9 駕駛風險評估案例

Kim *et al.* (2016) 將公車駕駛分為一般組與危險組，使用車載設備紀錄超速、急加減速、劇烈轉向及不當變換車道等危險行為，評估每位駕駛的駕駛行為並針對各駕駛的日常行為實施交通安全教育，以正常行駛至發生事故的時間長度做為評估指標。研究結果證實安全教育對於改善危險駕駛行為有正面效果，並建議針對個別駕駛不足處實施安全教育訓練成效將更好。

近年國內保險業者陸續推出 UBI 車險，如同上節美國保險公司之案例，將紀錄駕駛數據並依照駕駛開車習慣、時段及行駛里程等面向訂定合適保險費用。其中駕駛數據將透過手機 App 或是車載設備取得，若是駕駛表現良好保費也可得到相應的折扣，如此可使保費彈性更高、促進駕駛人保有安全良好的駕駛行為。

日本國土交通省針對車機數據與影像之使用有提出建議使用方式希望業者妥善利用車機資訊避免駕駛發生事故，流程如圖 2.5-10 所示，透過車機紀錄駕駛行車數據，依據各業者自行訂定的危險行為及其門檻值調取危險事件做為後續駕駛安全教育的依據。教育環節分為個別安全教育以及團體安全教育兩類，個別安全教育經由開放式的問題確認駕駛是否理解自身問題點並了解事件發生的背景，從而擬定對策避免事件再次發生，後續再調取類似交通環境之數據追蹤改善效果。團體安全教育則是建議每年至少辦理 1 次，播放與主題相關的影像片段鼓勵駕駛針對問題點提出看法再由管理階層負責解

說並排除駕駛疑問，惟需注意在使用影像前須先與當事駕駛溝通並做匿名處理。

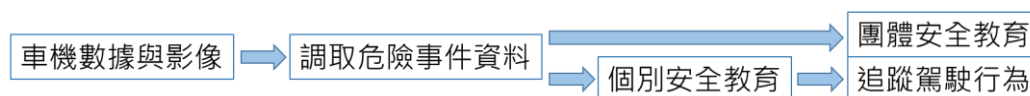
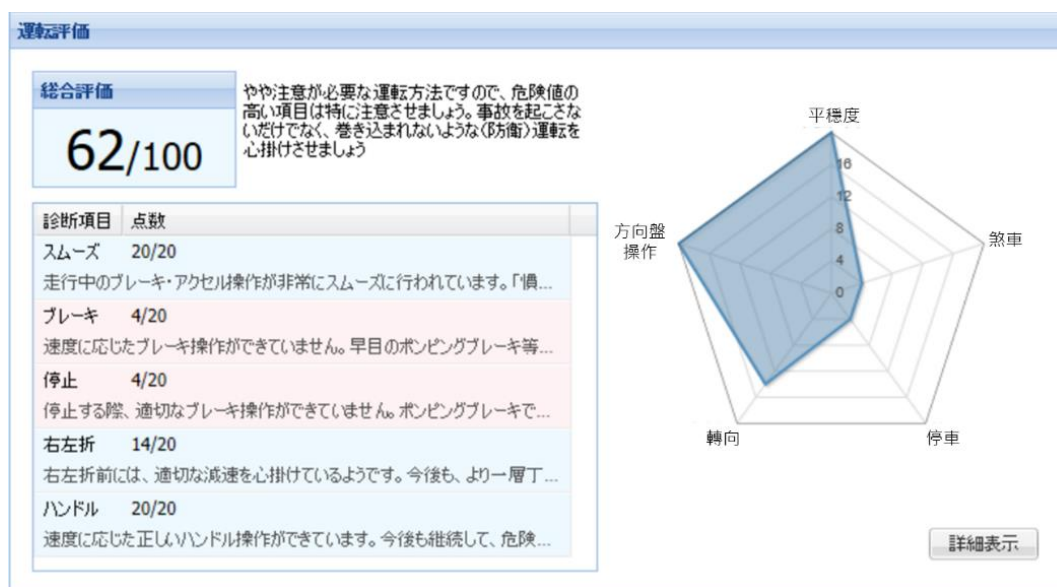


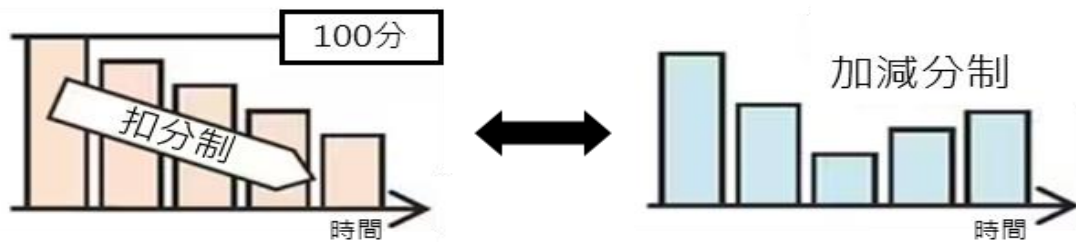
圖 2.5-10 車機數據使用流程

日本 docomo 公司開發的「doco です car safety」系統致力於降低事故發生率，希望可以透過紀錄日常駕駛習慣以及危險行為找出可能導致事故發生原因，並從根本改善駕駛行為，其使用方式大致符合日本國土交通省的使用手冊。後台可以直接查看所有危險行為發生的時間以及危險程度，並記錄發生次數檢視危險行為發生頻率。此外，導入安全等級的評分機制透過 5 個面向，方向盤、轉向、穩定度、剎車以及停車方式為所有駕駛評分 (圖 2.5-11)，評分方式採用加減分制而非扣分制 (圖 2.5-12)，目的在於較能看出駕駛改善的效果，根據數據所顯示的駕駛能力找出各個駕駛需要改善調整的部分，透過安全教育以及報表改善駕駛行為，提升車隊的安全性。每年導入該系統的數家業者所呈現的數據也顯示在使用後事故與危險行為件數顯著下降 (圖 2.5-13)，除了能減少車輛維修所需費用，保險所需的花費也有一定程度降低，對業者有明顯的正面效果。



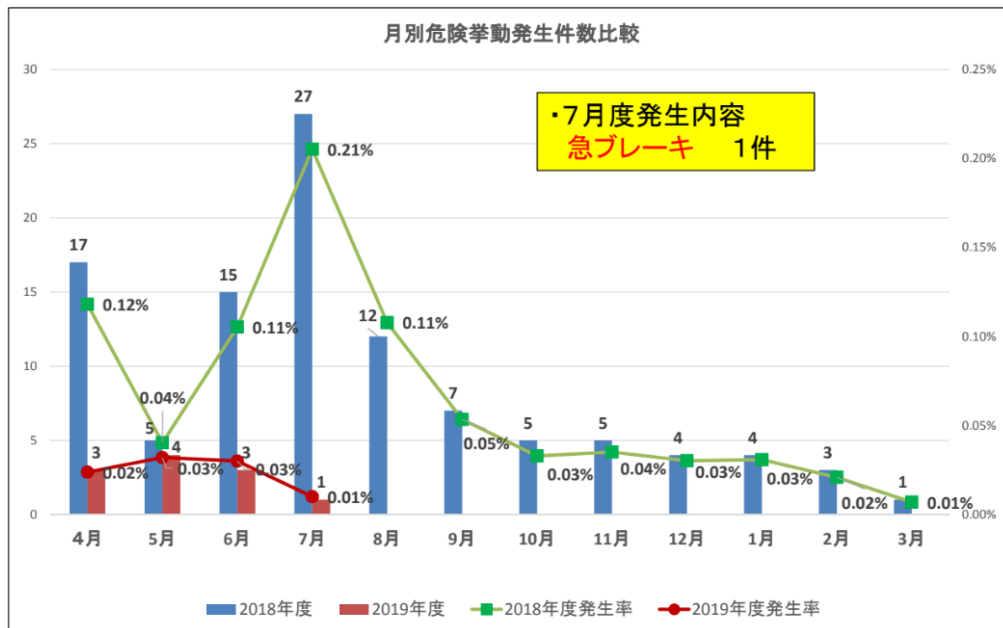
(圖片來源：<https://www.ntt.com>)

圖 2.5-11 駕駛評分系統示意圖



(圖片來源：<https://www.ntt.com/>)

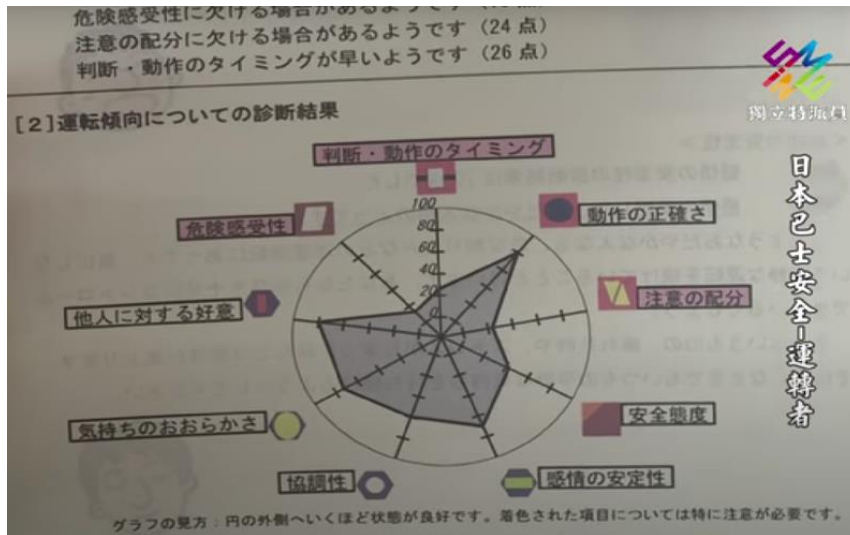
圖 2.5-12 駕駛行為分數計算方式



(圖片來源：千代田運輸案例介紹)

圖 2.5-13 千代田運輸急煞車事件趨勢圖

日本自 2002 年起強制要求客運駕駛在就職前須先進行適性診斷，首先透過模擬器模擬實際駕駛狀態，初步掌握駕駛行為、反應速度、生心理狀態等，除了確保駕駛有辦法勝任該職務之外，也幫助客運公司了解駕駛人的弱點，加強營運上的管理與訓練。為了更深入了解駕駛行為，另有安全駕駛訓練車，藉由車上設備，訓練人員能監測當下駕駛的視線、車速、與周遭車輛間的距離、車輛晃動程度等資訊(圖 2.5-14)。



(圖片來源：<https://www.youtube.com/watch?v=P8ty6IGgAKc>)

圖 2.5-14 適性診斷表

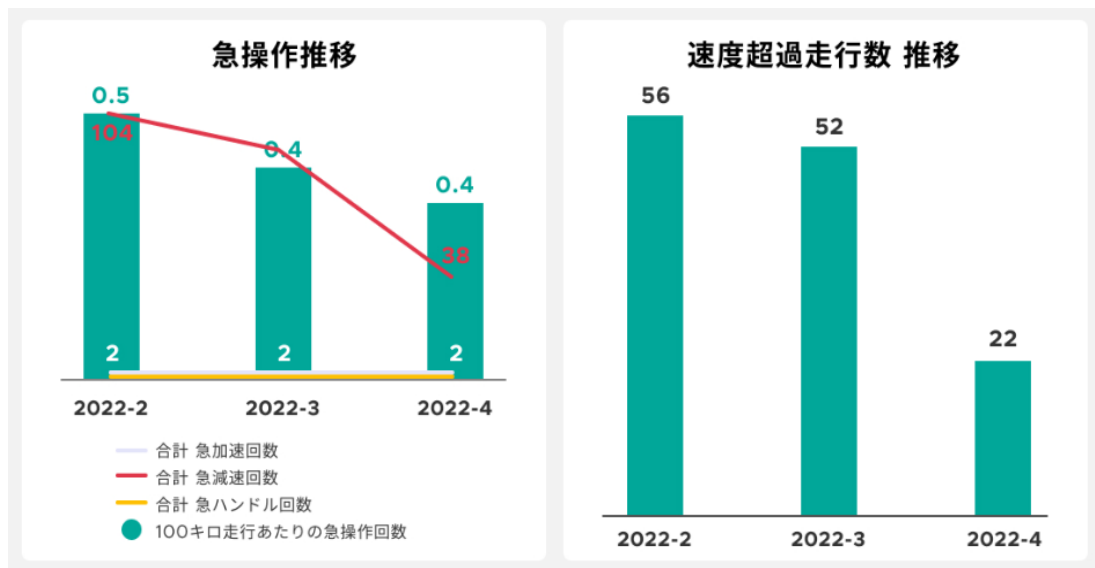


(圖片來源：<https://www.youtube.com/watch?v=P8ty6IGgAKc>)

圖 2.5-15 即時監控系統畫面

日本 SmartDrive 公司的車隊管理系統 SmartDrive Fleet 專案導入日本國內數家業者中，內容包括監控即時行車數據、調度管理車輛及將各個駕駛人的駕駛行為轉換為分數等，全面強化公司內部的管理系統。以沖繩某公司為例，該公司在導入系統後每月皆會為每名駕駛人製作行為報表，藉由檢視危險事件發生時的數據以及影像，找出事件發生的原因進而研擬一套合適的應對標準。實施後發現駕駛人劇烈加減速或轉動方向盤以及超速行駛等可能直接或間接導致事故發生的危險事件次數皆有下降的趨勢 (圖 2.5-16)，從圖中可以發

現在該系統投入後，急減速與超速事件再短短兩個月的時間減少超過一半的次數，顯見該系統對於車隊安全管理相當有效過。



(圖片來源：<https://smartdrive.co.jp/company/>)

圖 2.5-16 危險事件發生次數趨勢圖

2.5.3 管理系統接受度與支持度

Camden *et al.* (2022) 表示過去案例顯示車隊於車輛裝設攝影機後，對於車隊安全有明顯幫助，然而駕駛對於行駛過程中會被攝影機記錄駕駛行為多半抱持反感，主因在於隱私問題以及不願遭到過度管理，駕駛認為裝設管理設備代表業主不信任員工且被記錄的資料會在駕駛不知情的狀況下被觀看或使用，此外駕駛對於影像何時會記錄與觸發紀錄門檻大多不清楚；業者方則是面臨缺員的問題，縱使裝設設備可提升運行安全，但同時也可能加劇車隊缺員的狀況，因此是否裝設設備成為一大車隊管理難題。在與 24 名駕駛員進行訪談後，作者提出運輸業者應就管理系統機制如何運作、資料的使用與保存時間等細節與駕駛進行妥善說明，業者在管理上應聚焦於提倡良好的駕駛行為而非一味挑出錯誤或不良的行為懲處駕駛，另外作者也綜整可幫助減少業者與駕駛間矛盾的建議共 12 項如下所列：

- (一)建議於設備安裝前明確告知駕駛設備裝設原因、目的、功能與使用方式等資訊，提供雙方交流的機會並藉駕駛回饋調整觸發門檻及思考如何將資料應用於獎勵制度。
- (二)建議駕駛組建監督團體確認業者是否有符合規定使用資料，在出現爭議時可重新檢視當時影像片段，扮演業者與駕駛間的溝通橋樑。
- (三)應避免一味藉系統挑出駕駛的不良行為，此舉將導致駕駛認為裝設該系統目的僅僅是做為處罰的工具而無益於駕駛。建議透過擷取可有效預防事故發生之行為影像片段，做為嘉獎或未來駕駛教育之教材使用。
- (四)藉管理系統可將駕駛行為量化為分數，透過舉辦安全競賽有助於駕駛投入更多心力於好的駕駛行為，同時展現系統不僅具處罰功用而是對駕駛也有正向幫助。
- (五)據實使用資料並透明化整體流程將能使駕駛較不易質疑管理層的作為也有助於降低駕駛反彈聲浪。
- (六)嚴格遵守資料使用相關規定，未遵守相關規範可能導致駕駛難以信任管理階層與管理系統
- (七)透過第三方單位協助檢視影像被認為將能減少業者刻意針對特定駕駛的狀況。
- (八)於駕駛教育訓練時須確保駕駛理解哪些行為將觸發系統紀錄影像，另該事項應定期告知駕駛而非僅於雇傭時知會駕駛一次。
- (九)部分系統在被觸發狀況下並無燈光或聲響告知駕駛，使駕駛在不知情狀況下被記錄影像也無法得知其行為須進行改善，因此業者應於訓練時清楚告知駕駛並展示警示燈號。
- (十)建議提供駕駛在被召回教育訓練前自主改善的機會。
- (十一)由於駕駛多半不清楚該系統對其有何效益，業者應展示過去案例向駕駛說明，並強調紀錄影像同時能做為警示誤報時的證據。

(十二)大多數駕駛因隱私問題對影像紀錄持反對態度，故建議僅保存觸發事件後或駕駛按壓緊急開關後的影像。

2.5.4 小結

交通事故的發生多與人因有關，過去評斷風險程度多以事故等事後指標做為衡量依據故不易防患於未然。在近年車機系統逐漸普及的背景之下，透過駕駛數據及影像找出與事故相關聯之駕駛行為提前進行改善管理為未來車隊管理之趨勢。彙整過去文獻以及管理應用的實例(表 2.5-18)發現各方選擇做為判斷指標的事件主要有四項，超速、急加速、急減速以及急轉彎，其中研究指出急加速與急減速造成事故的風險最高，藉由上述各案例之結果可以發現由這四項高風險駕駛行為著手進行改善對於降低駕駛風險成效相當顯著，唯監理及業者對於數據的應用稍有差異。

本節車機管理實際應用案例涵蓋危險事件之定義至透過客觀數據教育改善駕駛之行為的成功範本，預期將能做為本計畫案未來雛型系統建置與後續操作應用的參考。

表 2.5-18 文獻案例彙整表

	適用對象	既有文獻	管理指標	資料蒐集	駕駛行為分數計算方式	警戒門檻	矯正機制
監理	全體業者	定義危險事件門檻透過車機系統偵測事件，採百分位分數或其他自訂尺度衡量駕駛行為表現，提供管理階層客觀資料做為督導的依據。	危險駕駛	道路攔查	考慮違規事件發生時間、違規風險程度及車輛曝光率	客運：後 50% 危險品：後 40% 普通貨物：後 35%	視業者風險程度以警告、現場或非現場調查、勒令停業等手段強制介入改善
			事故	書面文件	考慮事故發生時間、事故危險程度及車輛曝光率	客運：後 50% 危險品：後 40% 普通貨物：後 35%	
			藥物或酒精使用	道路攔查		客運：後 35% 危險品：後 25% 普通貨物：後 20%	
			駕駛工作時數	書面文件		客運：後 50% 危險品：後 40% 普通貨物：後 35%	
			駕駛適性	書面文件		客運：後 35% 危險品：後 25% 普通貨物：後 20%	
			車輛維護	書面文件	考慮違規事件發生時間、違規風險程度及受調查時間	客運：後 35% 危險品：後 25% 普通貨物：後 20%	
			危險品運送	書面文件		客運：後 20% 危險品：後 20% 普通貨物：後 20%	

表 2.5-18 文獻案例彙整表 (續)

適用對象	既有文獻	管理指標	資料蒐集	駕駛行為分數計算方式	警戒門檻	矯正機制
業者 該業者	定義危險事件門檻透過車機系統偵測事件，採百分位分數或其他自訂尺度衡量駕駛行為表現，提供管理階層客觀資料做為督導的依據。	超速	GPS、 OBD、 CANbus	業者選取其注重指標，各指標以百分位分數個別評分或將百分位分數平均分配給各指標	業者自行 訂定門檻值	業者教育訓練 輔獎懲制度
		急加速	OBD、 CANbus、 G-sensor			
		急減速	OBD、 CANbus、 G-sensor			
		急轉彎	GPS、 OBD、 CANbus、 G-sensor			
		車輛晃動\ 程度	G-sensor			
		分心	影像辨識設備			
		疲勞	影像辨識設備			
		事故	書面文件	定期事故件數報告		

2.6 小結

本計畫分別針對高風險駕駛行為之樣態與情境、高風險駕駛行為與交通事故之關聯性、行車異常事件、高風險駕駛行為相關管理案例、交通事故時空間分析與行車影像辨識技術等主題回顧其相關文獻。

在高風險駕駛行為與行車異常事件研究部分，在定義高風險駕駛行為前，必須先定義偏差駕駛行為，文獻中表示偏差駕駛行為分為疏忽、錯誤以及違規3項，其中「錯誤」與個人認知有關，認知錯誤包含分心、設備使用有誤以及對環境危險感知能力不足(如未保持車距、偏移車道等)。根據本計畫前期所蒐集之資料，駕駛員造成行車異常事件之主因為認知錯誤(未保持車距、對環境之危險感知不足等)，其次為使用手機(違規)。而行車異常事件主要包含與前車相對位置過近、強迫變換車道、車道偏移或駕駛員未雙手握方向盤以及未專心開車等等，本計畫亦回顧多篇文獻定義之高風險駕駛行為之門檻值，做為本計畫之高風險駕駛行為門檻值的參考。因此，本計畫將持續針對上述之行車異常事件尋找其風險，並加入道路幾何與環境之影響因素，藉以完整探討高風險駕駛行為，據以建立更完整之衡量指標。

在高風險駕駛行為與行車異常事件之管理案例部分，彙整過去文獻以及管理應用的實例發現各方選擇做為判斷指標的事件主要有4項：超速、急加速、急減速以及急轉彎，其中研究指出急加速與急減速造成事故的風險最高，藉由上述各案例之結果可以發現由這4項高風險駕駛行為著手進行改善對於降低駕駛風險成效相當顯著。本計畫蒐集之車機管理實際應用案例涵蓋危險事件之定義至透過客觀數據教育改善駕駛之行為的成功範本，預期將能做為未來離型系統建置與後續操作應用的參考。

在時空分析部分，本計畫目前車載資訊系統，包含車外ADAS、車內影像與車機，已獨立進行駕駛人行為之資訊蒐集，可分析各類型車內分心行為，及對應車外警示、行車異常事件之發生與頻率，亦能整合既有的巨觀環境資訊資訊等。考量各業者將有不同設備程度之條件，可將資料分為：僅有OBD資料、整合車外ADAS、加入車內影像資料，以及加入外部環境資料等4級。時空分析將基於計畫蒐集資料，結合本年度主軸行車異常事件及高風險駕駛行為，透過本計畫所定義之高風險駕駛行為、

門檻，透過巨、微觀之分析，探勘高風險路段、時序發生之推估與比例，整合安全之計數模式進行分析。

在影像辨識技術部分，從前述章節重點描述在行車影像辨識技術發展中，車外影像辨識與車內影像辨識所要辨識標的、技術手段與現行產業發展重點。從中整理可觀察到採用相機感測 (camera Sensing) 的視覺技術除了能保有偵測 (detection) 能力也同時能達到辨識 (recognition) 能力，這也說明技術發展從感測邁向感知之趨勢。由於在感知具有語意資訊，便能進一步針對物件類別、空間位置、移動軌跡行為、情境描述有更多資訊萃取與解析，這也是目前現行其他車用感測器資料 (如：毫米波雷達、光達等) 無法從中萃取豐富語意資訊之處。車用影像辨識技術也從計算機視覺特徵工程結合機器學習，乃至於 2012 年深度學習辨識技術浪潮掀起至目前邊緣 AI 運算晶片普及發展，不論在車輛端 (on-line/real-time) 發展從 Level 2 至 Level 4 之 AI-ADAS 至自動駕駛系統產品模組，乃至於雲端 (off-line) 分析風險駕駛行為等，深度學習技術成為現今在產學研界於影像辨識分析發展所採用主流技術核心。因此，本計畫將以深度學習技術為基礎進一步發展車內外影像辨識與風險行為分析研究。

第三章 高風險駕駛行為之分析與管理之構想

3.1 業者分類架構

為完整建立高風險駕駛行為模式供客運業者參考，有鑒於各家業者之資料完整度有所不同，故針對客運業者導入之系統及對應所能得獲取之資料，將不同業者分為 4 大類型。另外，依據交通部公路局車輛定期檢驗之規定，大客車應裝設視野輔助系統，故理論上所有業者皆有車外影像可使用，然而，本計畫將「使用車外影像進行分析」列為第 IV 類管理方式，也是使用最完整分析方式進行管理之業者，係認為雖所有大型車輛皆有車外影像，但實際會使用影像進行分析之業者並不多見，故有此一模式設定，詳細分級架構如下圖 3.1-1 所示。

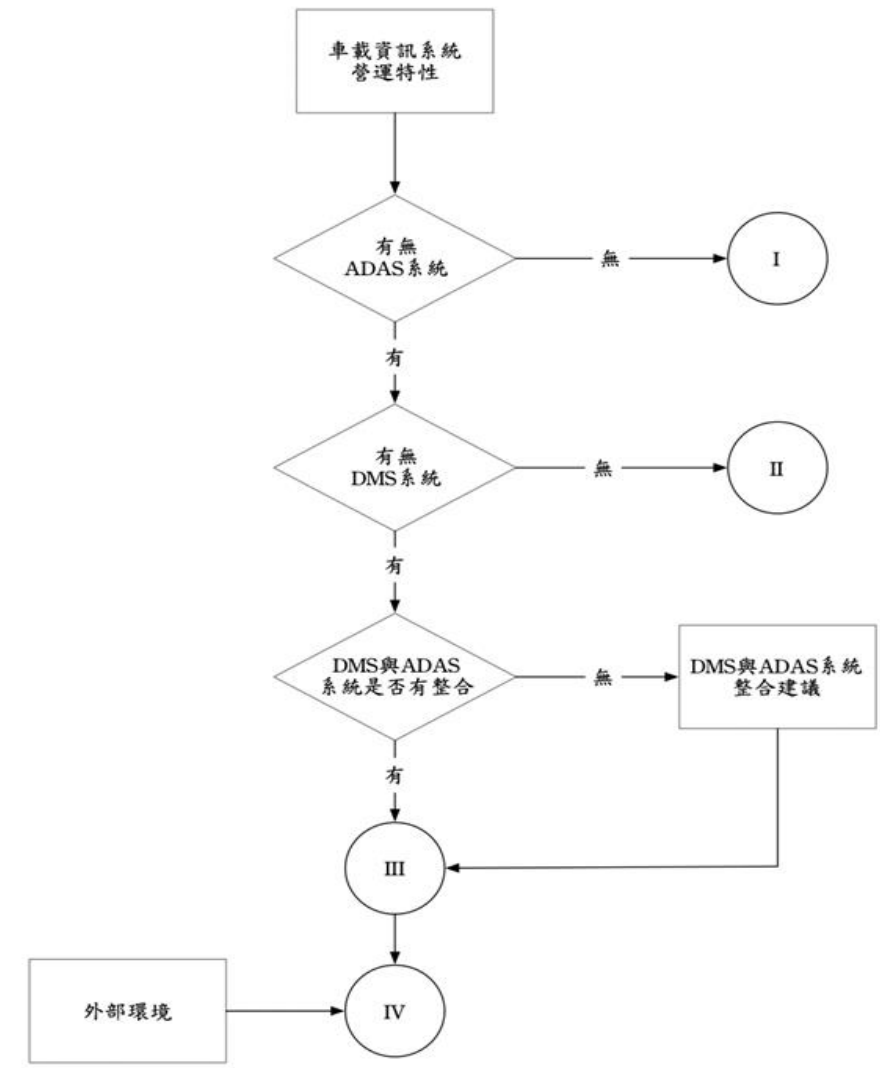


圖 3.1-1 客運業者分類架構

依據上圖之分析架構，本計畫將客運業者管理方式之資料完整度分為四類，分述如下：

- (一)第 I 類管理方式為僅使用車輛內建之車機 (OBD) 及車載衛星系統 (GPS) 資料，僅能就 OBD 及 GPS 有紀錄之欄位 (如時間、車速、方向角、車輛位置等) 進行分析；
- (二)第 II 類管理方式則加入 ADAS¹，可就前方車距狀況進行分析；
- (三)第 III 類管理方式則除了 OBD、GPS 及 ADAS 外再加入駕駛員管理系統 (Driver Management System, DMS)，可利用車內攝影機額外針對駕駛員之車內狀況，如使用手機、吃東西、未手握方向盤等分心行為進行更進一步管理與資料分析；
- (四)第 IV 類管理方式則整合前三類管理方式之管理手段，加上對外部環境之分析，如周圍車輛狀況、道路線型、天候情況等變數進行更完整的高風險駕駛行為分析。

本計畫使用之變數詳如 3.2 節所述，另針對上述各類型業者之管理系統類別，本計畫整理如表 3.1-1：

表 3.1-1 各類型業者管理系統特徵彙整

管理系統類別	特徵
I	有 OBD、GPS，無 ADAS 系統
II	有 OBD、GPS、ADAS，無 DMS
III	有車內影像系統，且與 ADAS 整合，無外部環境資料
IV	第 III 類管理方式，並整合外部環境資料，可以加入天候、道路狀況、車流狀況等資料

¹ 本計畫使用之 ADAS 系統係為 Mobileye 公司產品，警示項目包含前方碰撞警示 (FCW)、車距警示 (SDW) 及車道偏離警示 (LDW)。

3.2 高風險駕駛行為定義與分析架構

3.2.1 行車異常事件之定義

本計畫將參考相關研究中對於高風險駕駛行為之定義，並從本計畫前期建立之資料庫中，自各項駕駛行為及外在環境中篩選易造成事故風險之行為，並將其定義為高風險駕駛行為。

本計畫前期針對駕駛員之各項行為定義如下：

- (一)車內駕駛行為：泛指駕駛在車內的行為，含無分心行為與分心行為。
- (二)無分心行為（又稱專心駕駛）：駕駛有在注意路況，且手在方向盤上無特別肢體動作之行為。
- (三)分心行為：依文獻定義包含認知分心、眼部分心、手部分心。
 - 1. 認知分心：駕駛行車過程中，因為某些原因使注意力轉移至其他地方。
 - 2. 眼部分心：駕駛行車過程中視線離開道路。
 - 3. 手部分心：單手或雙手離開方向盤。
- (四)違規行為：法規不允許之行為或公司內部規定不允許之行為，如：用手機、抽菸、雙手離開方向盤等動作。
- (五)未違規行為：法規或公司內規雖無明文規定不允許，但駕駛員的分心行為動作仍可能導致行車異常事件。
- (六)行車異常事件：行車異常事件為學理上狹義之事故前兆，為與事故關聯性高的特定型態安全相關事件之子集合。事件之異常程度會依據事件發生當下之情境是否危險、與前車之相對距離、駕駛人之因應動作等不同情境組合判定。
- (七)車內異常行為：在分析手部分心行為與事件異常程度之關聯後，判定與事件異常程度相關之行為；該行為可能為單一動作，或多個動作的組合。

本計畫所定義之行車異常事件係為人工判斷而得，研究人員會依據警示發生前後之行車動態、周圍車流環境及天候狀況等座車外行車異常事件之判斷；車內則依據駕駛員於警示發生前後之行為 (如是否專心駕車或有分心行為等) 以及警示發生後之處理方式做綜合判斷，最後再依據前述車外環境、動態及駕駛人的車內行為得到最終異常程度分數自 0 (不是異常) 至 2 (異常)，因前期計畫結論係以二元模式進行分析，故本期計畫依循前期結果，使用前述判斷方式定義個別警示事件是否為異常 (0、1 變數)。

3.2.2 高風險駕駛行為定義與分析架構

長期以來，駕駛行為相關研究將駕駛員行為定義為偏差駕駛行為 (Reason, 1980；魏健宏等，2018)、侵略性駕駛行為 (Dula and Ballard, 2006) 及高風險駕駛行為 (Kaplan and Prato, 2012; Feng *et al.*, 2016; Wang *et al.*, 2022; Xian *et al.*, 2023)，透過文獻回顧，本計畫了解高風險駕駛行為將可歸類至偏差駕駛行為中，然偏差駕駛行為對於駕駛過程不一定會造成風險，外在條件與駕駛行為相互配合下，才有可能對後續的駕駛過程產生事故風險。

本計畫亦參考 Reason's Model (Reason, 1990)、人為因素分析與分類工具 (HFACS) 及澳洲運輸安全局之肇因分析模式 (ATSB, 2008)，根據此模式，本計畫由交通事故的發生 (即本計畫中為行車異常事件)，向前分析造成行車異常事件之警示事件，再向前探討高風險駕駛行為與周遭車輛互動等可能造成行車異常事件之因素，以及與情境 (如駕駛、環境) 有關之前置狀況，進行逐步分析。由於 HFACS 僅考慮人為因素所造成之行車異常事件，但實務上前置狀況也可能直接對行車異常事件的產生有關，故本計畫也將前置狀況與行車異常事件連接，以期更完整的將所有風險因素放入模式進行分析。綜合言之，本計畫對高風險駕駛行為的定義為「增加行車異常事件發生機率之行為，包括駕駛本身之車內動作、駕駛行為以及發生此事件之前置狀況，例如車流環境、道路幾何等。」

針對高風險駕駛行為之定義，本計畫使用事故鏈概念，將資料庫中能使用的變數，根據前述之分析架構定義逐一列入，詳如下圖 3.2-1。

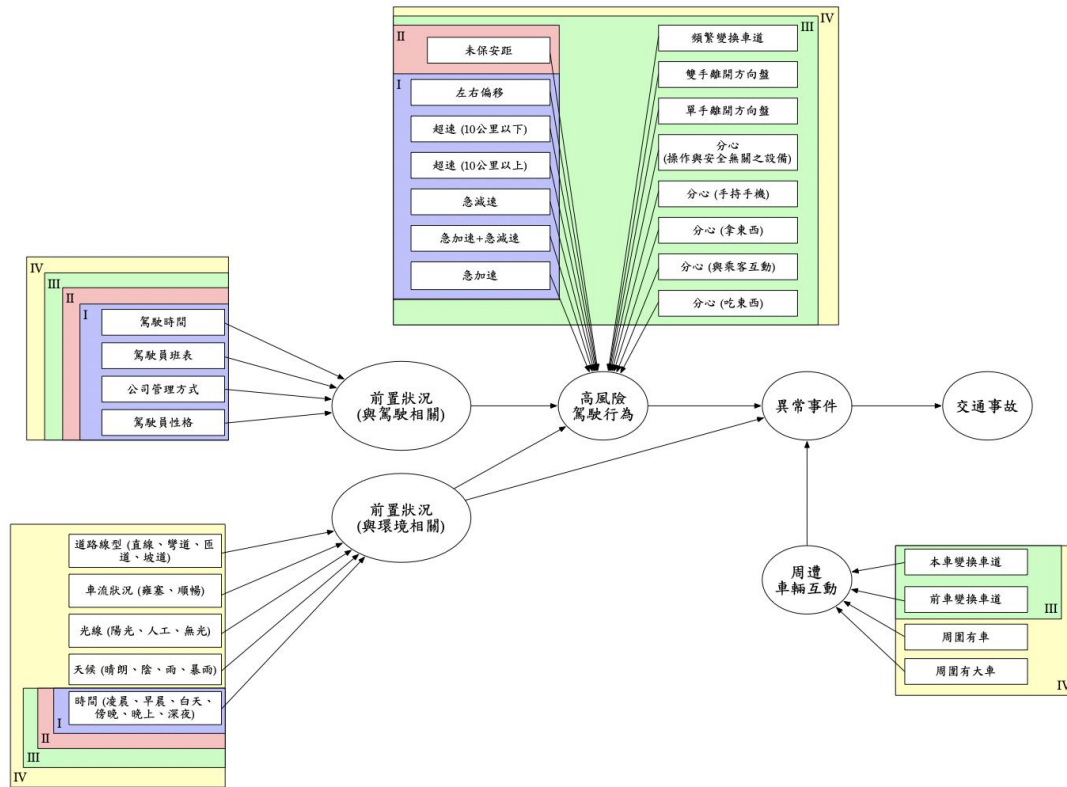


圖 3.2-1 高風險駕駛情境分析架構

針對高險駕駛行為之形成，需搭配對應之前置狀況，例如：新進駕駛員 (與駕駛相關之前置狀況) 在壅塞的下雨天晚上 (與環境相關的前置狀況)，與前車未保持安全距離 (高風險駕駛行為)，前述情況即為產生行車異常事件之高風險情境；然而，本計畫另外定義一條路徑為「前置狀況直接影響行車異常事件之形成」，換言之，造成行車異常事件行程之高風險情境不一定需搭配高險駕駛行為，如彎道、下雨、壅塞等情況交互作用下，可能直接造成行車異常事件之發生；若於模式中加入周遭車輛互動狀況則更可能形成高風險駕駛情境，進而導致行車異常事件之產生。

由於各家客運業者資料完整度不盡相同，本計畫依業者管理系統建置以及對應系統可得資料分為 4 種類型 (如本計畫 3.1 節所述)，於研究架構中亦依照各類管理方式能獲得之資料分別探討；總體而言，資料類型主要可以分為下列 3 類：

- (一)前置狀況：分為駕駛相關 (如駕駛時間、年資、個性等) 及環境相關變數 (如光線、時間、天候等)；

(二)高風險駕駛行為：為本期計畫重點項目，將包含前期計畫中得到之車內行為(如分心行為等)，以及車距狀況及車輛動態；

(三)周遭車輛動態：警示發生前後，本車周圍是否有(大)車或本車及前車是否正變換車道等。

本計畫透過文獻回顧得知駕駛風險的形成也與道路環境相關，因此，參考澳洲運輸安全局模式進一步整理出可於分析中使用架構及對應之事件型態，藉由前期所得之各項車內異常行為事件與道路幾何與環境等關聯性，建立高風險駕駛行為模式，藉由顯著之變數及以下準則，說明高風險駕駛情境。

(一)該行為是否為與行車異常事件高度相關之行為；

(二)該行為是否發生於高風險路段或高風險情境，如：大彎道、夜間或雨天等；

(三)綜合以上行為與相關情境，可判別該行為即為高風險駕駛行為。

3.3 高風險駕駛行為分析之資料結構

本期計畫結合第1期與第2期之研究成果，將車外行車異常事件與車內駕駛行為之分析結果綜合探討，欲找出高風險駕駛行為之定義，透過不同高風險駕駛情境及不同類型管理系統之資料，給定其風險等級與分數，做為後續業者管理手段或監管單位的監理依據。而不同資料完整度之管理系統類別之資料可分為以下4種，I：有OBD、GPS之資料；II：有OBD、GPS、ADAS之資料；III：有OBD、GPS之資料且有DMS之車內影像系統，並與ADAS整合；IV：有OBD、GPS、ADAS、車內影像資料，並有外部環境資料，可以加入天候、道路狀況、車流狀況等資料。

行車異常事件的判斷機制需藉由車輛周遭的環境、行車動態及駕駛因應來判斷，第一期計畫將原始影像數據藉由影像辨識技術萃取出車輛周遭環境、行車動態與駕駛反應，從而透過數據門檻值的設定與情境之搭配，判斷是否為行車異常事件，其中車外之影像辨識利用12宮格之概念架構，如圖3.3-1，橫向以車道、縱向以20公尺為單位，以本車為核心劃分出行車動態12宮格，主要採集車上三個鏡頭方位(車前、左後、右後

側方照後鏡視角) 之輸入影像與本車車身網路數據，對 12 宮格方位經運算後進行輸出之變數數據，除了大、小車的類別辨識、車流量 (該畫面時間內的車輛數)，包含前方車輛相對距離等幾何關係、左右兩側車輛的幾何關係等，這些數值將做為行車異常事件辨識的特徵。

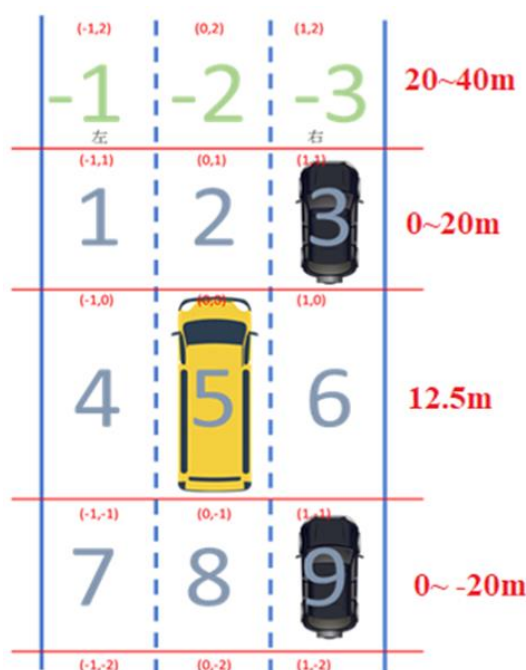


圖 3.3-1 車外 12 宮格之影像辨識示意

駕駛的車內行為可能會影響車輛的行車動態，進而演變成為行車異常事件，因此第二期計畫配合第一期計畫的資料結構，將車內影像辨識輸出資料設定為逐幀 (frame) 之格式，產生警示事件前 15 秒與後 5 秒的數據資料，以便將車內的駕駛行為資料結合車外 12 宮格的影像變數資料。此外，逐幀的格式在經過整理後，也可以產生以事件為基底的變數，如：事件中駕駛手離開方向盤之秒數、擺頭時間等，後續可彈性使用資料，分析車內行為與行車動態之關係、車內行為與行車異常事件之關係，其影像辨識輸出資料範例如圖 3.3-2。

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U
event	time	frame	頭部-偏 往左方	頭部-偏 往右方	頭部-低 低頭	頭部-抬 抬頭	頭部-無 法辨識	手在方 向盤上- 左手	手在方 向盤上- 右手	手-位置- 左手	手-位置- 右手	動作項目- 雙手離開 方向盤	動作項目- 單手離開 方向盤	動作項目- 軀幹移動 (身體前 傾)	動作項目- 軀幹移動 (身體右 傾)	動作項目- 擺頭(沒有 在看前方)	動作項目- 操作車內 設備	動作項目- 拿東西	動作項目- 用手機(手 持)	動作項目- 手靠近嘴 巴(飲食 抽菸)
52547557	09:54:59	1	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	2	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	3	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	4	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	5	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	6	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	7	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	8	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	9	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	10	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	11	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	12	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	13	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	14	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0
52547557	09:54:59	15	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0

圖 3.3-2 影像辨識輸出資料範例

本期繼續沿用前期使用的國道客運業者 A 的 ADAS 警示資料，包含 7 種警示的資料，分別為 FCWH 高速前車碰撞、FCWL 低速前車碰撞、LDWL 向左車道偏移、LDWR 向右車道偏移、SLDW 嚴重車道偏移、SDW_0.4 未保安全距離 0.4、SDW_1.2 未保持安全距離 1.2。各警示之定義說明如下：

- (一)FCWH：與前車可能發生碰撞時²且本車時速大於 30 公里。
- (二)FCWL：與前車可能發生碰撞時且本車時速低於 30 公里。
- (三)LDWL / LDWR：指未使用方向燈而向左/向右偏離車道，且時速高於 55 公里。
- (四)SLDW：指 300 秒內發生 2 次車道偏移。
- (五)SDW_0.4：代表距離前車之秒距小於 0.4 秒。
- (六)SDW_1.2：代表距離前車之秒距小於 1.2 秒。

3.4 資料盤點與變數定義

3.4.1 資料盤點

本期計畫延用前 2 年計畫之資料進行分析，第 1 期從 200 趟次中篩選出 2,558 個事件，2,558 個事件扣除無法辨識的事件共 2,524 個事件，2,524 個事件中僅 193 個事件有分心之行為；第 2 期新增 150 趟次資料，並從中篩選出 1,704 個事件，其中共有 349 個事件有 1 個或多個分心行為，動作

² 依據和欣客運使用之 Mobileye 系統原廠文件，碰撞警示之觸發門檻值為碰撞前 3 秒

類別統計如表 3.4-1 所示；另考量警示事件如高速前車碰撞 (FCWH)、嚴重車道偏移 (SLDW) 等之樣本偏低，本期另增加 15 台車、383 趟次資料，並從中篩選出 8,984 個事件，如表 3.4-2 所示，並特別關注在高速前車碰撞 (FCWH)、嚴重車道偏移 (SLDW) 這 2 種警示事件的分心行為，其中共有 63 個事件有分心之行為，期望藉由增加樣本數加強模式的精確度。

表 3.4-1 3 期計畫分心事件中各動作類別統計

動作類別	第 1 期次數	第 2 期次數	第 3 期 FCWH、 SLDW 次數
雙手離開方向盤	8	39	4
單手離開方向盤	83	232	36
軀幹移動	7	11	26
擺頭	13	37	5
操作車內設備	10	16	3
拿東西	26	67	14
用手機	22	6	8
手靠近嘴巴(飲食或抽菸)	64	45	5
總計	233	453	101

表 3.4-2 3 期計畫趟次資料之警示事件類別統計

警示事件種類	第一期樣本		第二期樣本		本期樣本	
	件數	百分比	件數	百分比	件數	百分比
高速前車碰撞(FCWH)	90	3.5%	65	3.8%	375	4.2%
低速前車碰撞(FCWL)	201	7.9%	94	5.5%	743	8.3%
向左車道偏移(LDWL)	202	7.9%	76	4.5%	471	5.2%
向右車道偏移(LDWR)	189	7.4%	121	7.1%	408	4.4%
嚴重車道偏移(SLDW)	61	2.4%	24	1.4%	113	1.3%
未保安全距離 0.4 (SDW_0.4)	1,315	51.4%	1,024	60.1%	4,874	54.3%
未保安全距離 1.2 (SDW_1.2)	500	19.5%	300	17.6%	2,000	22.3%
總計	2,558	100%	1,704	100%	8,984	100%

註：「SDW 1.2」因樣本數過多且多數為非行車異常事件，爰於本計畫於不同期分別以抽樣方式，抽出 500、300、2,000 件警示事件進行分析。

本期計畫所新增各車輛之 ADAS 警示事件資料如表 3.4-3 所示 (因前期已蒐集 5 台車輛之資料，故本期車輛從車輛 6 開始編號)，平均每趟次、每車輛、每人發生之警示事件數如表 3.4-4 所示，平均每趟發生 23.5 件警示事件，平均每車發生 598.9 件警示事件，平均每人發生 208.1 件警示事

件，其中可看出嚴重車道偏移 (SLDW) 發生次數最少，而未保安全距離 0.4 (SDW_0.4) 則發生次數最多。

表 3.4-3 本期新增資料之各車輛不同警示事件數

車輛/警示種類	FCWH	FCWL	LDWL	LDWR	SDW_0.4	SDW_1.2	SLDW	總計
車輛 6	21	42	16	27	287	120	3	516
車輛 7	9	12	98	25	180	76	16	416
車輛 8	36	215	26	60	429	170	12	948
車輛 9	8	15	53	26	127	89	11	329
車輛 10	25	45	38	69	437	150	31	795
車輛 11	12	18	23	11	212	100	2	378
車輛 12	23	32	13	12	257	180	3	520
車輛 13	11	4	21	12	121	55	3	227
車輛 14	13	83	30	35	264	140	7	572
車輛 15	44	43	51	41	366	130	11	686
車輛 16	72	40	14	8	637	170	0	941
車輛 17	46	38	15	8	582	170	1	860
車輛 18	24	24	38	27	261	170	3	547
車輛 19	7	67	20	26	246	100	7	473
車輛 20	24	65	15	21	468	180	3	776
總計	375	743	471	408	4,874	2,000	113	8,984

表 3.4-4 本期新增資料之平均每趟次、每車輛、每人發生之警示事件數

警示事件種類	各警示事件 件數	平均每趟 各警示件數	平均每車 各警示件數	平均每人 各警示件數
高速前車碰撞(FCWH)	375	1.0	25	8.7
低速前車碰撞(FCWL)	743	1.9	49.5	17.3
向左車道偏移(LDWL)	471	1.2	31.4	11.0
向右車道偏移(LDWR)	408	1.1	27.2	9.5
未保安全距離 0.4 (SDW_0.4)	4,874	12.7	324.9	113.3
未保安全距離 1.2 (SDW_1.2)	2,000	5.2	133.3	46.5
嚴重車道偏移(SLDW)	113	0.3	7.5	2.6
總計	8,984	23.5	598.9	208.1

事件樣本篩選流程與前 2 期相同，先人工檢視各趟次上下交流道與進出匝道之時間點，再篩選出發生於國道與匝道的事件。依據中央氣象署之日出日落之時間與離事件發生地點最近的氣象觀測站之雨量資料，判斷事件當下是否為夜間與晴雨狀況，再以事件發生的經緯度聯結國道幾何特性資料，最後依據警示事件種類、晴天/下雨、白天/夜晚、尖峰/離峰

等條件隨機篩選事件做為本期新增之樣本。

本期計畫主要有兩個部分的分析，分別為警示下的高風險駕駛行為分析、警示下高風險駕駛行為時空分析。圖 3.4-1 為本研究各分析項目使用之資料說明，警示下的行為分析係沿用第 1 期計畫國道客運業者 A 的警示事件資料與車外影像辨識資料，共 2,558 個警示事件，與第 2 期計畫的車內影像辨識資料，進行警示條件下的車內外高風險駕駛行為分析，並透過蒐集不同客運業者類別之管理資料，分析警示條件下高風險駕駛行為與行車動態、行車異常事件的關係，並找出高風險駕駛行為之定義，給定其風險等級與分數。

時空分析的部分亦沿用第 2、2 期的警示資料，共 200 趟次 (2,558 件) 加上 150 趟次的警示資料 (1,704 件)，由車內行車影像資料結合外部資料 (如：VD 資料、駕駛人特性、道路幾何資料) 進行時空分析，可以得到分心行為與行車異常事件的時空間特性，並利用已定義的高風險駕駛行為，透過前期與新增之 OBD 資料找出好發行車異常事件之高風險路段，後續也會再加入本期所新增之樣本 383 趟次的警示資料 (8,984 件) 強化分析，同時透過前期與新增之樣本進行微觀事件分析與巨觀趟次、路段、駕駛人分析，藉此探討高風險駕駛行為與行車異常事件之時空間特性。

本期計畫後續也會透過新增之資料強化車內外影像辨識模型，提升辨識之正確性，為高風險駕駛行為與行車異常事件分析帶來助益。

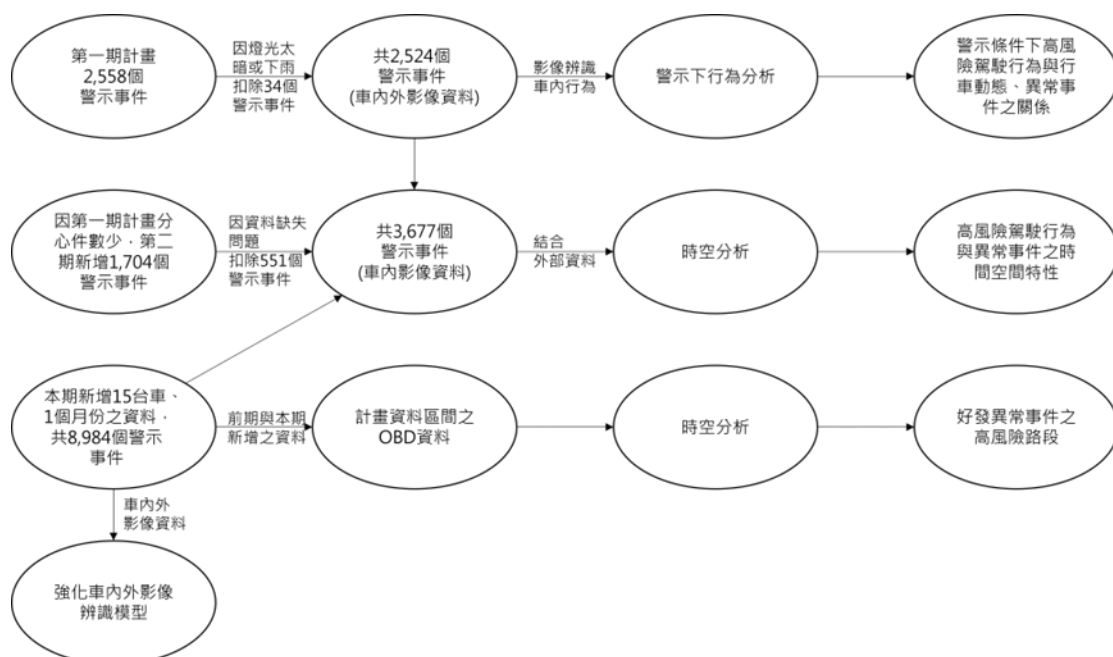


圖 3.4-1 本期各分析項目使用之資料說明

3.4.2 變數定義

在本期計畫中，不同資料完整度之客運業者類別資料欄位如下表中呈現。第 I 類管理方式使用車輛內建之車機 (OBD) 及車載衛星系統 (GPS) 資料，就 OBD 及 GPS 有紀錄之欄位 (如時間、車速、方向角、車輛位置等) 進行分析。其資料欄位如表 3.4-5。

表 3.4-5 第 I 類管理方式之資料欄位

變數名稱	變數定義說明	單位
id	event	-
employee_id	員工號碼	-
night	是否為夜晚	0/1
surrogate2	1: 不是異常、2: 可能異常、3: 異常	類別
dir_N	是否為向北行駛	0/1
location	是否在高速公路的主線段	0/1
Llight	左方向燈是否開啟	0/1
Rlight	右方向燈是否開啟	0/1
signal	方向燈是否開啟	0/1
bearing_range	方向盤轉向角度	度
v_ave	平均車速	km/hr
accel_ave	平均加速度	g

表 3.4-5 第 I 類管理方式之資料欄位 (續 1)

變數名稱	變數定義說明	單位
accel_max	最大加速度	g
bearing_max	最大方向盤轉動角度	度
bearing_min	最小方向盤轉動角度	度
v_ave_n3p3	前三秒至後三秒時平均車速	km/hr
accel_ave_n3p3	前三秒至後三秒時平均加速度	g
accel_max_n3p3	前三秒至後三秒時前三秒至後三秒時最大加速度	g
bearing_max_n3p3	前三秒至後三秒時最大方向盤轉動角度	度
bearing_min_n3p3	前三秒至後三秒時最小方向盤轉動角度	度
v_ave_n3	前三秒時平均車速	km/hr
accel_ave_n3	前三秒時平均加速度	g
accel_max_n3	前三秒時最大加速度	g
bearing_max_n3	前三秒時最大方向盤轉動角度	度

bearing_min_n3	前三秒時最小方向盤轉動角度	度
v_ave_p3	後三秒時平均車速	km/hr
accel_ave_p3	後三秒時平均加速度	g
accel_max_p3	後三秒時最大加速度	g
bearing_min_p3	後三秒時最小方向盤轉動角度	度
seniority	駕駛員年資	年
dang	是否為異常或可能異常狀態	0/1
NHkm_110.0	位於國道公里數哪一段	0/1
NHkm_125.0	位於國道公里數哪一段	0/1
NHkm_132.0	位於國道公里數哪一段	0/1
NHkm_140.0	位於國道公里數哪一段	0/1
NHkm_150.0	位於國道公里數哪一段	0/1
NHkm_159.0	位於國道公里數哪一段	0/1
NHkm_160.0	位於國道公里數哪一段	0/1
NHkm_165.0	位於國道公里數哪一段	0/1
NHkm_168.0	位於國道公里數哪一段	0/1
NHkm_174.0	位於國道公里數哪一段	0/1
NHkm_178.0	位於國道公里數哪一段	0/1
NHkm_181.0	位於國道公里數哪一段	0/1
NHkm_189.0	位於國道公里數哪一段	0/1
NHkm_192.0	位於國道公里數哪一段	0/1
NHkm_198.0	位於國道公里數哪一段	0/1
NHkm_207.0	位於國道公里數哪一段	0/1
NHkm_211.0	位於國道公里數哪一段	0/1
NHkm_220.0	位於國道公里數哪一段	0/1

表 3.4-5 第 I 類管理方式之資料欄位 (續 2)

變數名稱	變數定義說明	單位
NHkm_229.0	位於國道公里數哪一段	0/1
NHkm_230.0	位於國道公里數哪一段	0/1
NHkm_235.0	位於國道公里數哪一段	0/1
NHkm_240.0	位於國道公里數哪一段	0/1
NHkm_243.0	位於國道公里數哪一段	0/1
NHkm_250.0	位於國道公里數哪一段	0/1
NHkm_257.0	位於國道公里數哪一段	0/1
NHkm_264.0	位於國道公里數哪一段	0/1
NHkm_27.0	位於國道公里數哪一段	0/1
NHkm_270.0	位於國道公里數哪一段	0/1
NHkm_272.0	位於國道公里數哪一段	0/1
NHkm_284.0	位於國道公里數哪一段	0/1

NHkm_288.0	位於國道公里數哪一段	0/1
NHkm_299.0	位於國道公里數哪一段	0/1
NHkm_303.0	位於國道公里數哪一段	0/1
NHkm_311.0	位於國道公里數哪一段	0/1
NHkm_319.0	位於國道公里數哪一段	0/1
NHkm_32.0	位於國道公里數哪一段	0/1
NHkm_33.0	位於國道公里數哪一段	0/1
NHkm_35.0	位於國道公里數哪一段	0/1
NHkm_373.0	位於國道公里數哪一段	0/1
NHkm_41.0	位於國道公里數哪一段	0/1
NHkm_49.0	位於國道公里數哪一段	0/1
NHkm_52.0	位於國道公里數哪一段	0/1
NHkm_55.0	位於國道公里數哪一段	0/1
NHkm_57.0	位於國道公里數哪一段	0/1
NHkm_59.0	位於國道公里數哪一段	0/1
NHkm_62.0	位於國道公里數哪一段	0/1
NHkm_65.0	位於國道公里數哪一段	0/1
NHkm_67.0	位於國道公里數哪一段	0/1
NHkm_69.0	位於國道公里數哪一段	0/1
NHkm_71.0	位於國道公里數哪一段	0/1
NHkm_83.0	位於國道公里數哪一段	0/1
NHkm_86.0	位於國道公里數哪一段	0/1
NHkm_91.0	位於國道公里數哪一段	0/1
NHkm_95.0	位於國道公里數哪一段	0/1
NHkm_99.0	位於國道公里數哪一段	0/1

表 3.4-5 第 I 類管理方式之資料欄位 (續 3)

變數名稱	變數定義說明	單位
speed_limit	該路段速限	km/hr
speed_diff	車速與速限差異	km/hr
over_speed	是否超速	0/1
over_speed_5	超速 5 公里以上	0/1
over_speed_10	超速 10 公里以上	0/1
over_speed_15	超速 15 公里以上	0/1
over_speed_20	超速 20 公里以上	0/1
bearing_max_8	最大方向盤角度超過 8 度	0/1
bearing_max_10	最大方向盤角度超過 10 度	0/1

第 II 類管理方式再較第 I 類管理方式增加先進駕駛輔助系統 (ADAS)，可就前方車距狀況進行分析，其中，TITG (與前車車距之累積時間) 及

TETG (與前車之時距與時間積分) 係計算自車距資料，故須第 II 類管理方式方能辨識。其新增的資料欄位如表 3.4-6。

表 3.4-6 第 II 類管理方式新增之資料欄位表

變數名稱	變數定義說明	單位
seqtype	警示類別	類別
TETG_03	與前車車距之累積時間 (時距門檻為 0.3 秒)	秒
TETG_04	與前車車距之累積時間 (時距門檻為 0.4 秒)	秒
TETG_05	與前車車距之累積時間 (時距門檻為 0.5 秒)	秒
TETG_06	與前車車距之累積時間 (時距門檻為 0.6 秒)	秒
TETG_07	與前車車距之累積時間 (時距門檻為 0.7 秒)	秒
TETG_08	與前車車距之累積時間 (時距門檻為 0.8 秒)	秒
TETG_09	與前車車距之累積時間 (時距門檻為 0.9 秒)	秒
TETG_1	與前車車距之累積時間 (時距門檻為 1 秒)	秒
TERCRI	追撞風險指數	-
TITG_03	與前車之時距與時間積分 (時距門檻為 0.3 秒)	秒 ²
TITG_04	與前車之時距與時間積分 (時距門檻為 0.4 秒)	秒 ²
TITG_05	與前車之時距與時間積分 (時距門檻為 0.5 秒)	秒 ²
TITG_06	與前車之時距與時間積分 (時距門檻為 0.6 秒)	秒 ²
TITG_07	與前車之時距與時間積分 (時距門檻為 0.7 秒)	秒 ²
TITG_08	與前車之時距與時間積分 (時距門檻為 0.8 秒)	秒 ²
TITG_09	與前車之時距與時間積分 (時距門檻為 0.9 秒)	秒 ²
TITG_1	與前車之時距與時間積分 (時距門檻為 1 秒)	秒 ²
caspace_min	與前車最小車距	m
caspace_range	與前車車距範圍	m

表 3.4-6 第 II 類管理方式新增之資料欄位表 (續 1)

變數名稱	變數定義說明	單位
veh_expo	周圍是否有車	0/1
vehlarge_expo	周圍是否有大車	0/1
caspace_min_n3p3	前三秒至後三秒時與前車最小車距	m
caspace_range_n3p3	前三秒至後三秒時與前車車距範圍	m
veh_expo_n3p3	前三秒至後三秒時周圍是否有車	0/1
vehlarge_expo_n3p3	前三秒至後三秒時周圍是否有大車	0/1
TETG_03_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.3 秒)	秒
TETG_04_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.4 秒)	秒
TETG_05_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.5 秒)	秒
TETG_06_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.6 秒)	秒
TETG_07_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.7 秒)	秒
TETG_08_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.8 秒)	秒

TETG_09_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 0.9 秒)	秒
TETG_1_n3p3	前三秒至後三秒時與前車車距之累積時間 (門檻為 1 秒)	秒
TITG_03_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.3 秒)	秒^2
TITG_04_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.4 秒)	秒^2
TITG_05_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.5 秒)	秒^2
TITG_06_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.6 秒)	秒^2
TITG_07_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.7 秒)	秒^2
TITG_08_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.8 秒)	秒^2
TITG_09_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 0.9 秒)	秒^2
TITG_1_n3p3	前三秒至後三秒時與與前車之時距與時間積分 (時距門檻為 1 秒)	秒^2
caspace_min_n3	前三秒時與前車最小車距	m
caspace_range_n3	前三秒時與前車車距範圍	m
veh_expo_n3	前三秒時周圍是否有車 (0, 1 變數)	0/1
vehlarge_expo_n3	前三秒時周圍是否有大車 (0, 1 變數)	0/1
TETG_03_n3	前三秒時與前車車距之累積時間 (門檻為 0.3 秒)	秒
TETG_04_n3	前三秒時與前車車距之累積時間 (門檻為 0.4 秒)	秒
TETG_05_n3	前三秒時與前車車距之累積時間 (門檻為 0.5 秒)	秒
TETG_06_n3	前三秒時與前車車距之累積時間 (門檻為 0.6 秒)	秒

表 3.4-6 第 II 類管理方式新增之資料欄位表 (續 2)

變數名稱	變數定義說明	單位
TETG_07_n3	前三秒時與前車車距之累積時間 (門檻為 0.7 秒)	秒
TETG_08_n3	前三秒時與前車車距之累積時間 (門檻為 0.8 秒)	秒
TETG_09_n3	前三秒時與前車車距之累積時間 (門檻為 0.9 秒)	秒
TETG_1_n3	前三秒時與前車車距之累積時間 (門檻為 1 秒)	秒
TITG_03_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.3 秒)	秒^2
TITG_04_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.4 秒)	秒^2
TITG_05_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.5 秒)	秒^2
TITG_06_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.6 秒)	秒^2
TITG_07_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.7 秒)	秒^2
TITG_08_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.8 秒)	秒^2
TITG_09_n3	前三秒時與前車之時距與時間積分 (時距門檻為 0.9 秒)	秒^2
TITG_1_n3	前三秒時與前車之時距與時間積分 (時距門檻為 1 秒)	秒^2

caspace_min_p3	後三秒時與前車最小車距	m
caspace_range_p3	後三秒時與前車車距範圍	m
veh_expo_p3	後三秒時周圍是否有車	0/1
vehlarge_expo_p3	後三秒時周圍是否有大車	0/1
TETG_03_p3	後三秒時與前車車距之累積時間 (門檻為 0.3 秒)	秒
TETG_04_p3	後三秒時與前車車距之累積時間 (門檻為 0.4 秒)	秒
TETG_05_p3	後三秒時與前車車距之累積時間 (門檻為 0.5 秒)	秒
TETG_06_p3	後三秒時與前車車距之累積時間 (門檻為 0.6 秒)	秒
TETG_07_p3	後三秒時與前車車距之累積時間 (門檻為 0.7 秒)	秒
TETG_08_p3	後三秒時與前車車距之累積時間 (門檻為 0.8 秒)	秒
TETG_09_p3	後三秒時與前車車距之累積時間 (門檻為 0.9 秒)	秒
TETG_1_p3	後三秒時與前車車距之累積時間 (門檻為 1 秒)	秒
TITG_03_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.3 秒)	秒^2
TITG_04_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.4 秒)	秒^2
TITG_05_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.5 秒)	秒^2
TITG_06_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.6 秒)	秒^2
TITG_07_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.7 秒)	秒^2
TITG_08_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.8 秒)	秒^2
TITG_09_p3	後三秒時與前車之時距與時間積分 (時距門檻為 0.9 秒)	秒^2
TITG_1_p3	後三秒時與前車之時距與時間積分 (時距門檻為 1 秒)	秒^2
mileage	國道里程	km
caspace_min_n3_40	前三秒時最小車距為 40 公尺 (前方無車)	0/1
caspace_range_n3p3_0	前三秒至後三秒時車距範圍為 0 (前方無車)	0/1
caspace_range_n3_0	前三秒時車距範圍為 0 (前方無車)	0/1

第 III 類管理方式除了 OBD、GPS 及 ADAS 外再加入駕駛員管理系統 (DMS)，可利用車內攝影機額外針對駕駛員之車內狀況、分心行為進行更進一步管理與資料分析。其新增的資料欄位如表 3.4-7。

表 3.4-7 第 III 類管理方式新增之資料欄位表

變數名稱	變數定義說明	單位
distract	是否為分心	0/1
distract_n3p3	前三秒至後三秒時是否分心	0/1
distract_n3	前三秒時是否分心	0/1
distract_p3	後三秒時是否分心	0/1
head_l	向左擺頭	0/1
head_r	向右擺頭	0/1
head_low	低頭	0/1

head_high	抬頭	0/1
head	是否擺頭	0/1
l_hand_leave	左手離開方向盤	0/1
r_hand_leave	右手離開方向盤	0/1
both_hand_leave	雙手離開方向盤	0/1
single_hand_leave	單手離開方向盤	0/1
body_forward	身體前傾	0/1
body_right	身體右傾	0/1
no_look_forward	未注視前方	0/1
equipment	使用車內設備	0/1
taking_sth	拿東西	0/1
phone	用手機(手持)	0/1
mouth	手靠近嘴巴	0/1
head_l_mode	向左擺頭_眾數	0/1
head_r_mode	向右擺頭_眾數	0/1
head_low_mode	低頭_眾數	0/1
head_high_mode	抬頭_眾數	0/1
head_mode	是否擺頭_眾數	0/1
l_hand_leave_mode	左手離開方向盤_眾數	0/1
r_hand_leave_mode	右手離開方向盤_眾數	0/1
both_hand_leave_mode	雙手離開方向盤_眾數	0/1
single_hand_leave_mode	單手離開方向盤_眾數	0/1
body_forward_mode	身體前傾_眾數	0/1
body_right_mode	身體右傾_眾數	0/1
no_look_forward_mode	未注視前方_眾數	0/1
equipment_mode	使用車內設備_眾數	0/1

表 3.4-7 第 III 類管理方式新增之資料欄位表 (續)

變數名稱	變數定義說明	單位
taking_sth_mode	拿東西_眾數	0/1
phone_mode	用手機(手持)_眾數	0/1
mouth_mode	手靠近嘴巴_眾數	0/1
l_hand_leave_true	左手離開方向盤_人工	0/1
r_hand_leave_true	右手離開方向盤_人工	0/1
both_hand_leave_true	雙手離開方向盤_人工	0/1
single_hand_leave_true	單手離開方向盤_人工	0/1
head_true	擺頭_人工	0/1
body_forward_true	身體前傾_人工	0/1
body_right_true	身體右傾_人工	0/1
equipment_true	使用車內設備_人工	0/1

equipment_notlight_true	使用車內設備(與安全無關)_人工	0/1
taking_sth_true	拿東西_人工	0/1
phone_true	用手機(手持)_人工	0/1
mouth_true	手靠近嘴巴_人工	0/1
normal_true	正常駕駛_人工	0/1
move	移動情境	類別
self_change	本車變換車道	0/1
front_change	前車變換車道	0/1
self_change_head_true	本車變換車道且駕駛擺頭_人工	0/1
self_change_head	本車變換車道且駕駛擺頭	0/1
front_change_head_true	前車變換車道且駕駛擺頭_人工	0/1
front_change_head	前車變換車道且駕駛擺頭	0/1
other_head_true	未變換車道且擺頭_人工	0/1
other_head	未變換車道且擺頭	0/1

第 IV 類管理方式整合前三類管理方式之管理手段，加上對外部環境之分析進行更完整的高風險駕駛行為分析。其新增的資料欄位如表 3.4-8。

表 3.4-8 第 IV 類管理方式新增之資料欄位表

變數名稱	變數定義說明	單位
rain	是否有下雨	0/1
curve_radius	轉彎半徑	m
state_slope	道路線型：爬坡	0/1
state_RT	道路線型：右彎	0/1
state_LT	道路線型：左彎	0/1

第四章 高風險駕駛行為分析結果

4.1 ADAS 警示、行車異常事件與駕駛行為特性描述

本計畫警示資料經整理及合併後共 2,524 筆警示，各警示類別與定義分述如下：

(一)與縱向相關警示：

1. FCWH：高速前方碰撞警示，時速高於 30 公里/小時始作動。
2. FCWL：低速前方碰撞警示，時速低於 30 公里/小時始作動。
3. SDW0.4：未保持安全距離警示，與前方車輛秒距小於 0.4 秒。
4. SDW1.2：未保持安全距離警示，與前方車輛秒距小於 1.2 秒。

(二)與橫向相關警示：

1. LDW：車道偏移警示，未打方向燈情況下，偏離本車行駛車道。
2. SLDW：嚴重車道偏移警示，5 分鐘內發生兩次車道偏移即觸發。

本期計畫依前期資料庫建模，同時依據前期資料針對準確度不佳之 SDW1.2 予以刪除，另低速下之警示 FCWL 因不屬於本計畫研究範圍，也一併刪除。由於縱向及橫向警示之發生有根本上之差異，本小節會依據上述警示類別拆分為縱向及橫向警示兩組資料，使用行車異常事件做為應變數 (Y) 建模，詳細各類警示事件下之行車異常事件數量統計如表 4.1-1：

表 4.1-1 行車異常事件數量統計

行車異常事件				
	縱向警示		橫向警示	
	FCWH	SDW 0.4	LDW	SLDW
不是異常	45 (52.3%)	877 (66.9%)	329 (86.1%)	51 (86.4%)
異常	41 (47.7%)	434 (33.1%)	53 (13.9%)	8 (13.6%)
合計	1,397		441	

透過上表可知，在縱向警示的情況下，行車異常事件的比例較橫向警示高出許多，事件數量也以縱向警示為多，而本計畫比對相關影片後得知，研究對象客運公司的駕駛員在縱向警示的處理上不若橫向警示的反應及時，有時甚至可能放任警示作動而不處理，故在本計畫研究人員之判讀下，會將此行為視為是行車異常事件；橫向警示對駕駛員來說通常反應較為即時，且不易放任警示作動，故行車異常事件數量佔比較低。

表 4.1-2 及表 4.1-3 分別為影像辨識及人工辨識之各項駕駛行為對不同類別警示的統計表，由可知無論是哪種類型的警示，駕駛員行為皆以單手離開方向盤 (縱向：37.2%；橫向 56.5%) 及擺頭 (縱向：42.3%；橫向 46.9%) 為多，單手離開方向盤的行為中，以右手離開方向盤為多。透過車內影像回顧，可知駕駛員於駕車時通常習慣將單手至於扶手上休息並由單手駕駛車輛，右手離開方向盤可能與伸手拿取右方座位上物品或操作車內設備有關 (車內設備多設計於駕駛員右方)；擺頭動作則與駕駛行為 (注意前方、左右方車輛) 或操作車內其他設備有關，可能為安全駕駛狀態抑或是分心狀態，這也是本期計畫欲找出之高風險駕駛行為及情境是否與單手離開方向盤或擺頭有關聯。

表 4.1-2 駕駛行為數量統計 (影像辨識)

駕駛行為列表						
	縱向警示			橫向警示		
	FCWH	SDW 0.4	合計	LDW	SLDW	合計
警示事件總數	86	1311	1397	382	59	441
左手離開方向盤	4	58	62 (4.4%)	25	2	27 (6.1%)
右手離開方向盤	18	268	286 (20.5%)	78	20	118 (26.8%)
單手離開方向盤	41	478	519 (37.2%)	216	33	249 (56.5%)
雙手離開方向盤	6	65	71 (5.1%)	31	2	33 (7.5%)
擺頭	36	555	591 (42.3%)	177	30	207 (46.9%)
身體前傾	0	0	0 (0.0%)	2	0	2 (0.5%)
身體右傾	0	0	0 (0.0%)	1	0	1 (0.2%)
拿東西	4	44	48 (3.4%)	25	3	28 (6.3%)

表 4.1-2 駕駛行為數量統計 (影像辨識) (續)

駕駛行為列表						
	縱向警示			橫向警示		
	FCWH	SDW 0.4	合計	LDW	SLDW	合計
操作車內設備 (全)	2	21	23 (1.6%)	10	1	11 (2.5%)
使用手機	7	72	79 (5.7%)	13	1	14 (3.2%)
手靠近嘴巴	7	84	91 (6.5%)	46	4	50 (11.3%)

表 4.1-3 駕駛行為數量統計 (人工辨識)

駕駛行為列表						
	縱向警示			橫向警示		
	FCWH	SDW 0.4	合計	LDW	SLDW	合計
警示事件總數	86	1311	1397	382	59	441
左手離開方向盤	8	224	232 (16.6%)	100	13	113 (25.6%)
右手離開方向盤	23	255	278 (19.9%)	81	19	100 (22.7%)
單手離開方向盤	31	475	506 (36.2%)	181	32	213 (48.3%)
雙手離開方向盤	1	24	25 (1.8%)	38	8	46 (10.4%)
擺頭	3	180	183 (13.1%)	50	14	64 (14.5%)
身體前傾	6	66	72 (5.2%)	55	12	67 (15.2%)
身體右傾	0	2	2 (0.1%)	3	4	7 (1.6%)
拿東西	0	11	11 (0.8%)	20	8	28 (6.3%)
操作車內設備 (全)	4	60	64 (4.6%)	1	4	5 (1.1%)
操作車內設備 (與安全無關)	8	31	39 (1.6%)	3	2	5 (1.1%)
使用手機	7	72	79 (5.7%)	13	1	14 (3.2%)
手靠近嘴巴	7	84	91 (6.5%)	46	4	50 (11.3%)

4.2 高風險駕駛行為之操作型定義及歸納：混合計量經濟與機器學習方法之應用

高風險駕駛行為之定義流程如圖 4.2-1 所示，此流程共分為五個步驟，分述如下：

- (一) 根據各類管理方式，統整其能獲取之所有變數；
- (二) 本計畫使用計量模式 (logistic regression) 以篩選與各類行車異常事件顯著之相關變數；
- (三) 根據變數型態劃分，若為連續變數則使用機器學習模式中的提升迴歸樹模式 (Boosted Regression Tree, BRT) 將其類別化並辨識其造成異常之門檻值；
- (四) 將類別化後之變數重新放入計量模式中，以建立其高風險駕駛行為機率模式；
- (五) 最後，根據不同情境下之組合機率標準化其風險程度，並計算相對風險值與各變數高風險比例，藉以辨識高風險情境。
- (六) 本小節利用先前建立之最佳模式建立 GBM (Gradient Boosted Machine) 模式，並以此模式建立 BRT 模式。
- (七) 增長迴歸樹 (BRT) 模式，為組合迴歸樹 (regression Tree) 及提升方法 (boosted method) 而得，最早由 Elith *et al.* (2018) 提出，與隨機森林法 (random forest) 類似，此種方法主要為重複計算模式中的決策樹 (decision tree) 並將其逐一擬合，其中最大的差異為，BRT 模式利用提升方法將選定資料加權後放入決策樹，同時前一決策樹中配適度較差的資料會有較高的機率重新加權後放入新的樹中，換言之，模式中所有的決策樹皆會考慮到前一決策樹的誤差，並藉由多次計算以增進模式整體配適度。

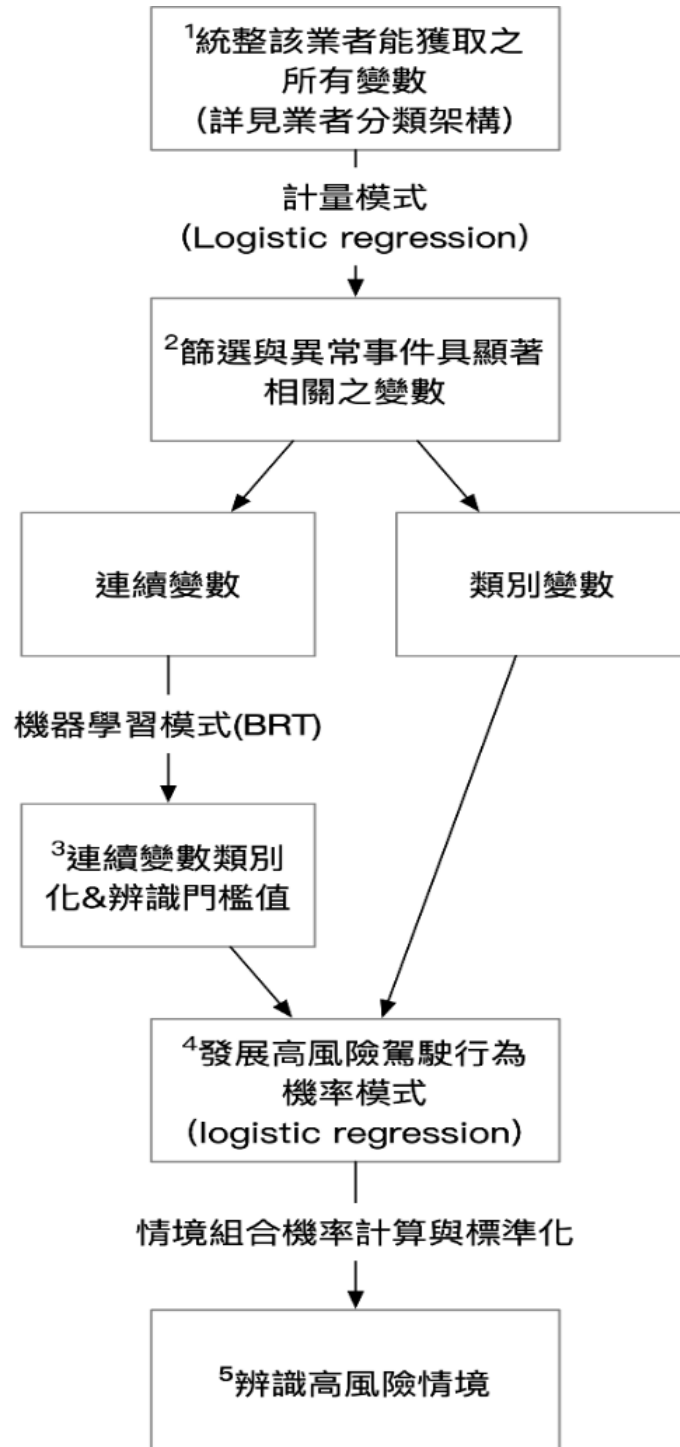


圖 4.2-1 高風險駕駛行為定義流程

4.2.1 縱向警示事件：本車變換車道

表 4.2-1 為第 I 類管理方式 (OBD+GPS) 所得之高風險駕駛模式，由下表可知，若警示前後 3 秒之最大加速度愈大，愈有可能是行車異常事件，

與本計畫之預期相符，因駕駛人須使用較大的加速度進行煞車或加速；若警示時間發生在晚上也可能會增加行車異常事件的機率，表 4.2-2 則為篩選時刪除之變數。

表 4.2-1 第 I 類管理方式本車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	1.543	1.042
平均速度 (n3p3)	-0.027 *	0.011
最大加速度絕對值 (n3p3)	1.730 ***	0.351
平均加速度絕對值 (p3)	-2.875 **	0.893
晚上	0.674 **	0.223
年資	-0.040 **	0.016
AIC	673.7	
平均 AUC	0.659	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-2 第 I 類管理方式本車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	左方向燈	-
2	右方向燈	-
3	國道里程	-
4	超速	-
5	平均速度	警示前 3 秒
6	平均速度	警示後 3 秒
7	最大加速度絕對值	警示前 3 秒
8	最大加速度絕對值	警示後 3 秒
9	平均加速度絕對值	警示前 3 秒
10	平均加速度絕對值	警示前後 3 秒

值得一提的是，本車之警示前後 3 秒平均速度以及警示後 3 秒平均加速度會將低行車異常事件發生之機率，本研究推測較高之平均車速表示行駛路段較為順暢；警示後平均加速度的提高也同樣表示駕駛員在變換車道後能以較高之速率行駛，道路環境應相對良好，本研究選用絕對值計算，係因加減速狀況將可能相互抵消加速度值，導致本車加減速行為無法分析，另經檢視影像本車變換車道後之加減速行為普遍一致，且多數為加速駛離，可說明變換車道後的平均加速度提高，即為道路狀況相對良好，使得警示事件較不易形成行車異常事件。駕駛年資愈高，愈不

易產生行車異常事件，此狀況與本研究之預期相符，年資愈高的駕駛員愈有經驗及時對警示事件進行反應，不會使之發展為行車異常事件。

表 4.2-3 為第 II 類管理方式 (OBD+GPS+ADAS) 所得之高風險駕駛模式，係基於第 I 類管理方式之模式中顯著之變數再加入 ADAS 資料，可判斷前車與本車之相對車距，表 4.2-4 為因不顯著而刪除之變數。

表 4.2-3 第 II 類管理方式本車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	1.796	1.123
平均速度 (n3p3)	-0.036 **	0.013
最大加速度絕對值 (n3p3)	1.664 ***	0.353
平均加速度絕對值 (p3)	-2.828 **	0.904
晚上	0.724 **	0.227
年資	-0.041 **	0.016
TITG_03 (n3p3)	1.082 *	0.522
車距範圍 (n3)	0.039 ***	0.012
AIC	660.72	
平均 AUC	0.683	

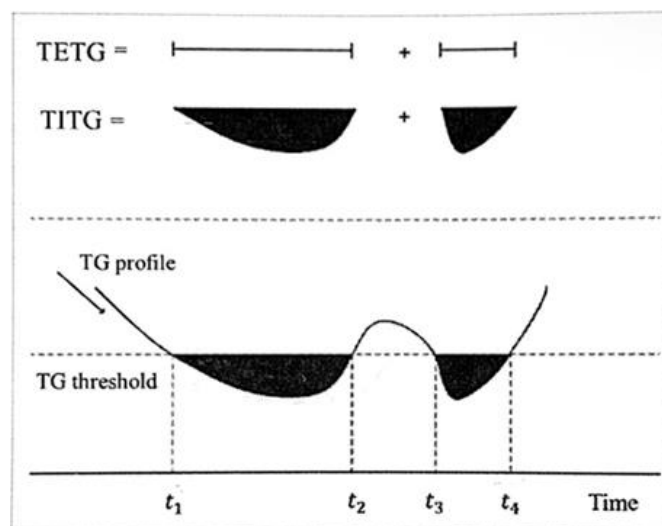
* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-4 第 II 類管理方式本車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	本車與前車秒距之累積時間 (TETG)	0.3~1 秒
2	本車與前車之秒距與時間積分 (TITG)	0.4~1 秒 ²
3	最小車距	警示前 3 秒
4	最小車距	警示前後 3 秒
5	最小車距	警示後 3 秒
6	前方無車	警示前 3 秒
7	車距範圍	警示前後 3 秒
8	車距範圍	警示後 3 秒

本計畫亦針對安全中介指標項目，增加 TETG 與 TITG 兩變數，其中，TETG (Time Exposed Time Gap) 為計算本車與前車之時距小於門檻值之時間間隔，依據文獻回顧及 ADAS 使用現況，本計畫將門檻值設定為 0.3~1.0 秒，TETG 愈大表本車風險愈大；TITG (Time Integrated Time Gap) 則表示為本車與前車之時距與設定門檻值之差異積分，若本車與前車時

距越小，則累積之總時距將越大，此項指標同樣設定門檻值為 0.3~1.0 秒，TITG 愈大則本車風險愈大，示意圖如下圖 4.2-2 所示，計算方式則如式 (4.2-1) 及 (4.2-2) 所示：



資料來源：Dey and Chandra (2009)

圖 4.2-2 探討分心與人工辨識關聯之二元迴歸

$$TETG_i = \sum_{t=0}^T [TG^* - TG_i(t)] \cdot \tau_{SC},$$

$$\begin{cases} [TG^* - TG_i(t)] = 1, if > 0 \\ [TG^* - TG_i(t)] = 0, otherwise \end{cases} \quad (4.2-1)$$

$$TITG_i = \int_0^T [TG^* - TG_i(t)] dt \quad (4.2-2)$$

其中， TG^* 為設定門檻值，本計畫為 0.3~1.0 秒； $TG_i(t)$ 為本車與前車之時距； τ_{SC} 為時間間隔，本計畫為 1 秒，TITG 為秒距對時間積分，本計畫選用時距為 1 秒。

本計畫發現在本車變換車道之情境下，警示前後本車與前車之秒距小於 0.3 秒之秒距對時間積分 (TITG)，其積分值愈大 (持續時間愈久且距離愈近)，則有愈高機率形成行車異常事件；警示前車距範圍愈大，表示本車與前車之相對行駛狀態較不穩定，如本車變換車道使得車距突然減少或前方突發雍塞等，導致警示事件有較高機率發展為行車異常事件，皆與本計畫之預期相符。

表 4.2-5 為第 III 類管理方式 (OBD+GPS+ADAS+DMS) 所得之高風險駕駛模式，係基於第 II 類管理方式之模式中顯著的變數再加入車內影像資料 (DMS) 以判斷駕駛員的分心狀況。值得注意的是，本計畫除使用人工觀看影片紀錄分心行為外，也利用影像辨識軟體進行分心行為辨識作業，為求精準，本計畫將人工及影像辨識之變數一併放入，表 4.2-6 為因不顯著而刪除之變數。若加入車內影像，可得知駕駛員的分心行為對行車異常事件的產生有極大的關聯。本計畫發現「雙手離開方向盤」、「操作與安全無關之設備 (如冷氣、窗戶等)」以及「手靠近嘴巴 (如飲食等)」皆會使警示事件有較高機率變為行車異常事件，顯示駕駛員若將手放開方向盤、或有其他可能造成視線離開前方的行為，會使駕駛員無法及時針對前方車輛動態進行反應，提高駕駛風險。

表 4.2-5 第 III 類管理方式本車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	1.752	1.133
平均速度 (n3p3)	-0.037 **	0.013
最大加速度絕對值 (n3p3)	1.762 ***	0.365
平均加速度絕對值 (p3)	-3.168 ***	0.937
晚上	0.696 **	0.230
年資	-0.043 **	0.016
TITG_03_n3p3	1.059 *	0.530
車距範圍 (n3)	0.040 ***	0.012
雙手離開方向盤	0.840 *	0.423
操作與安全無關之設備_真值	1.600 *	0.647
手靠近嘴巴_真值	1.175 *	0.590
AIC	652.36	
平均 AUC	0.695	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-6 第 III 類管理方式本車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	擺頭	人工/影像
2	左手離開方向盤	人工/影像
3	右手離開方向盤	人工/影像
4	單手離開方向盤	人工/影像
5	雙手離開方向盤	人工
6	身體前傾	人工/影像
7	身體右傾	人工/影像

表 4.2-6 第 III 類管理方式本車變換車道高風險駕駛模式刪除變數(續)

項次	刪除變數	範圍
8	操作車內設備	人工/影像
9	拿東西	人工/影像
10	用手機	人工/影像
11	手靠近嘴巴	影像
12	本車變換車道	-
13	前車變換車道	-
14	本車變換車道且擺頭	人工/影像
15	前車變換車道且擺頭	人工/影像
16	未變換車道但擺頭	人工/影像

表 4.2-7 為第 IV 類管理方式 (OBD+GPS+ADAS+DMS+車外環境) 所得之高風險駕駛模式，係基於第 III 類管理方式之模式中顯著之變數再加入車外環境資料，如道路線型、天候狀況、周圍車輛狀況等變數，可更清楚本車與周圍車輛環境互動關係對行車異常事件產生的影響，表 4.2-8 為篩選時因不顯著而刪除之變數。若加入車外環境變數，「警示前後 3 秒周圍有大車」會增加行車異常事件產生之機率，可能係因若本車駕駛員發現前方有狀況時會優先採變換車道方式避讓，但換車道當下若剛好有大型車輛併行，可能導致駕駛無法安全避讓前車，迫使本車與前車過於接近進而造成行車異常事件發生。

表 4.2-7 第 IV 類管理方式本車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	1.493	1.153
平均速度 (n3p3)	-0.036 **	0.013
最大加速度絕對值 (n3p3)	1.812 ***	0.368
平均加速度絕對值 (p3)	-3.251 ***	0.942
晚上	0.784 ***	0.235
年資	-0.045 **	0.017
TITG_03_n3p3	1.205 *	0.537
車距範圍 (n3)	0.041 ***	0.012
雙手離開方向盤	0.949 *	0.431
操作與安全無關之設備_真值	1.473 *	0.655
手靠近嘴巴_真值	1.168 *	0.592
周圍有大車 (n3p3)	0.121 *	0.059
AIC	650.22	
平均 AUC	0.700	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-8 第 IV 類管理方式本車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	彎道半徑	-
2	坡度	-
3	左彎	-
4	右彎	-
5	下雨	-
6	周圍有車	警示前 3 秒
7	周圍有車	警示前後 3 秒
8	周圍有車	警示後 3 秒
9	周圍有大車	警示前 3 秒
10	周圍有大車	警示後 3 秒

上述模式為縱向警示發生下，本車變換車道的最佳模式，說明當本車變換車道時，有以下行為，可能導致行車異常事件產生之機率提高：

- (一) 警示前後 3 秒最大加速度愈大。
- (二) 車趟時間為夜間。
- (三) 警示前後三秒，與前車之秒距小於 0.3 秒時，秒距與持續時間之積分。
- (四) 警示前 3 秒車距範圍變動幅度愈大。
- (五) 駕駛員雙手離開方向盤。
- (六) 駕駛員操作與安全無關之設備。
- (七) 駕駛員將手靠近嘴巴。
- (八) 警示前後 3 秒，周圍有大型車時。

4.2.2 縱向警示事件：前車變換車道

表 4.2-9 為第 I 類管理方式 (OBD+GPS) 所得之高風險駕駛模式，由下表可知，若警示後 3 秒之最大加速度愈大，愈有機會造成行車異常事件，與本計畫之預期相符，若駕駛人面對警示事件須使用較大的加速度進行加減速，則愈有可能由警示事件轉變為行車異常事件，表 4.2-10 則為篩選時刪除之變數。另外，駕駛年資愈高，愈不易產生行車異常事件，與本車變換車道之情境相同。

表 4.2-9 第 I 類管理方式前車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	-1.079 ***	0.202
年資	-0.031 ~	0.016
最大加速度絕對值 (p3)	0.940 ***	0.172
AIC	549.72	
平均 AUC	0.692	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-10 第 I 類管理方式前車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	左方向燈	-
2	右方向燈	-
3	國道里程	-
4	晚上	-
5	超速	-
6	平均速度	警示前 3 秒
7	平均速度	警示前後 3 秒
8	平均速度	警示後 3 秒
9	最大加速度絕對值	警示前 3 秒
10	最大加速度絕對值	警示前後 3 秒
11	平均加速度絕對值	警示前 3 秒
12	平均加速度絕對值	警示前後 3 秒
13	平均加速度絕對值	警示後 3 秒

表 4.2-11 為第 II 類管理方式 (OBD+GPS+ADAS) 所得之高風險駕駛模式，係基於第 I 類管理方式之模式中顯著之變數再加入 ADAS 資料，可加以判斷前車與本車之相對車距，表 4.2-12 為因不顯著而刪除之變數。本計畫發現在前車變換車道之情境下，「警示前後本車與前車之秒距小於 0.6 秒之累積時間 (TETG)」，其累積時間愈長將有愈高機率形成行車異常事件；警示前後 3 秒之最小車愈大，越不易形成行車異常事件；警示前 3 秒之車距範圍愈大，表示本車與前車之相對行駛狀態較不穩定，如前車突然變換車道至本車前方，或前方有擁塞的情況等，導致警示事件有較高機率發展為行車異常事件，皆與本計畫之預期相符。

表 4.2-11 第 II 類管理方式前車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	-1.251 *	0.493
年資	-0.039 *	0.017
最大加速度絕對值 (p3)	0.708 ***	0.172
TETG_06_n3p3	0.294 ***	0.074
最小車距 (n3p3)	-0.209 *	0.086
車距範圍 (n3)	0.038 *	0.015
AIC	526.88	
平均 AUC	0.749	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-12 第 II 類管理方式前車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	本車與前車秒距之累積時間 (TETG)	0.3~0.5, 0.7~1 秒
2	本車與前車之秒距與時間積分 (TITG)	0.3~1 秒平方
3	最小車距	警示前 3 秒
4	最小車距	警示後 3 秒
5	前方無車	警示前 3 秒
6	車距範圍	警示前後 3 秒
7	車距範圍	警示後 3 秒

表 4.2-13 為第 III 類管理方式 (OBD+GPS+ADAS+DMS) 所得之高風險駕駛模式，係基於第 II 類管理方式之模式中顯著之變數再加入車內影像資料 (DMS)，可使用車內影像判斷駕駛員的分心狀況，除使用人工觀看影片紀錄分心行為外，也利用影像辨識軟體進行分心行為之辨識作業，為求精準，本計畫將人工及影像辨識之變數一併放入，表 4.2-14 為因不顯著而刪除之變數。透過下表模式可發現加入車內影像後，「右手離開方向盤」及「雙手離開方向盤」等行為會使警示事件有較高機率變為行車異常事件，說明駕駛員若有手離開方向盤的狀況，可能代表其正在從事其他分心行為，尤以車內設備大部分位於駕駛員右側，與本計畫預期相符，分心行為將使駕駛員無法針對前方車輛動態及時反應，將大幅提高駕駛風險。

表 4.2-13 第 III 類管理方式前車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	-1.267 *	0.505
年資	-0.034 *	0.017
最大加速度絕對值 (p3)	0.743 ***	0.180
TETG_06_n3p3	0.292 ***	0.075
最小車距 (n3p3)	-0.258 **	0.089
車距範圍 (n3)	0.037 *	0.016
右手離開方向盤_真值	0.804 **	0.269
雙手離開方向盤	0.937 *	0.460
前車變換車道且擺頭_真值	-1.250 *	0.539
AIC	515.59	
平均 AUC	0.765	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-14 第 III 類管理方式前車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	擺頭	人工/影像
2	左手離開方向盤	人工/影像
3	右手離開方向盤	影像
4	單手離開方向盤	人工/影像
5	雙手離開方向盤	人工
6	身體前傾	人工/影像
7	身體右傾	人工/影像
8	操作車內設備	人工/影像
9	拿東西	人工/影像
10	用手機	人工/影像
11	手靠近嘴巴	人工/影像
12	本車變換車道	-
13	前車變換車道	-
14	本車變換車道且擺頭	人工/影像
15	前車變換車道且擺頭	影像
16	未變換車道但擺頭	人工/影像

值得注意的是，「前車變換車道且擺頭」變數為負向顯著，而本模式剛好為前車變換車道的情境，推測當前車變換車道時，駕駛員之擺頭動通常為注意前車動向，如此雖造成警示，但卻能降低行車異常事件發生機率。

表 4.2-15 為第 IV 類管理方式 (OBD+GPS+ADAS+DMS+車外環境) 所得之高風險駕駛模式，係基於第 III 類管理方式之模式中顯著之變數再加入車外環境資料，如道路線型、天候狀況、周圍車輛狀況等變數，可更清楚本車與周圍車輛環境互動關係對行車異常事件產生造成之影響，表 4.2-16 為因不顯著而刪除之變數。本計畫發現車外環境變數皆不顯著 (模式保留「警示後 3 秒周圍有車」變數)，本計畫推測，縱向警示發生當下前車變換車道之情境，與車外環境或週遭互動關係之關聯度較低，推測為此警示的發生主要肇因於本車駕駛員的應變反應，可著重於駕駛員的跟車距離及車內分心行為之管理，以降低行車異常事件的發生機率。

表 4.2-15 第 IV 類管理方式前車變換車道高風險駕駛模式

項目	係數	標準誤
(截距)	-1.281 *	0.518
年資	-0.034 *	0.017
最大加速度絕對值 (p3)	0.743 ***	0.180
TETG_06_n3p3	0.292 ***	0.075
最小車距 (n3p3)	-0.259 **	0.090
車距範圍 (n3)	0.037 *	0.016
右手離開方向盤_真值	0.805 **	0.269
雙手離開方向盤	0.938 *	0.460
前車變換車道且擺頭_真值	-1.252 *	0.539
周圍有車 (p3)	0.007	0.061
AIC	517.58	
平均 AUC	0.765	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-16 第 IV 類管理方式前車變換車道高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	彎道半徑	-
2	坡度	-
3	左彎	-
4	右彎	-
5	下雨	-
6	周圍有車	警示前 3 秒
7	周圍有車	警示前後 3 秒
8	周圍有大車	警示前 3 秒
9	周圍有大車	警示前後 3 秒
10	周圍有大車	警示後 3 秒

上述模式為縱向警示發生下，前車變換車道的最佳模式，說明當前車變換車道時，有以下行為，可能導致行車異常事件產生之機率提高：

- (一) 警示後 3 秒最大加速度愈大。
- (二) 警示前後 3 秒，本車與前車之秒距小於 0.6 秒之累積時間。
- (三) 警示前 3 秒車距範圍變動幅度愈大。
- (四) 駕駛員右手離開方向盤。
- (五) 駕駛員雙手離開方向盤。

4.2.3 橫向警示事件：本車行駛國道全線段(含匝道)

表 4.2-17 為第 I 類管理方式 (OBD+GPS) 管理方式所得之高風險駕駛模式，由下表可知，此模式顯著變數為「超速」、「夜晚」及「年資」三變數，皆為負向顯著，推測夜晚道路狀況較為順暢之故，本研究未考慮警示發生當下時的車速狀況，因此在深夜、道路車輛密度不高的狀況下，可能出現超速但未發展為行車異常事件的情況，然超速本身即為風險行為，建議業者仍可就駕駛員的超速情形進行管理。針對橫向警示事件(車道偏移警示)，本車行駛於國道全線段時將不易使警示事件發展為行車異常事件；針對駕駛年資的提高，也代表駕駛對於警示事件的處理也較為成熟，可降低形成行車異常事件的機率，表 4.2-18 則為篩選時刪除之變數。

表 4.2-17 第 I 類管理方式行駛國道全線段高風險駕駛模式

項目	係數	標準誤
(截距)	-0.803 **	0.282
超速	-1.742 *	0.737
晚上	-0.916 **	0.285
年資	-0.051 ~	0.027
AIC	338.75	
平均 AUC	0.689	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-18 第 I 類管理方式行駛國道全線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	左方向燈	-
2	右方向燈	-
3	國道里程	-
4	平均速度	警示前 3 秒
5	平均速度	警示前後 3 秒
6	平均速度	警示後 3 秒
7	最大加速度絕對值	警示前 3 秒
8	最大加速度絕對值	警示前後 3 秒
9	最大加速度絕對值	警示後 3 秒
10	平均加速度絕對值	警示前 3 秒
11	平均加速度絕對值	警示前後 3 秒
12	平均加速度絕對值	警示後 3 秒

表 4.2-19 為第 II 類管理方式 (OBD+GPS+ADAS) 所得之高風險駕駛模式，係基於第 I 類管理方式之模式中顯著之變數再加入 ADAS 資料，可判斷前車與本車之相對車距，本計畫發現行駛於國道全線段時，車距與行車異常事件的行程較無關聯，值得注意的是，若放入車距變數，將會使國道里程的變數變為不顯著，表 4.2-20 為因不顯著而刪除之變數。

表 4.2-19 第 II 類管理方式行駛國道全線段高風險駕駛模式

項目	係數	標準誤
(截距)	-0.991 **	0.306
超速	-1.836 *	0.743
晚上	-0.856 **	0.287
年資	-0.049 ~	0.028
TITG_09_n3p3	0.198 ~	0.111
AIC	337.81	
平均 AUC	0.690	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-20 第 II 類管理方式行駛國道全線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	本車與前車秒距之累積時間 (TETG)	0.3~1 秒
2	本車與前車之秒距與時間積分 (TITG)	0.3~0.8, 1 秒平方
3	最小車距	警示前 3 秒
4	最小車距	警示前後 3 秒

表 4.2-20 第 II 類管理方式行駛國道全線段高風險駕駛模式刪除變數 (續)

項次	刪除變數	範圍
5	最小車距	警示後 3 秒
6	前方無車	警示前 3 秒
7	車距範圍	警示前 3 秒
8	車距範圍	警示前後 3 秒
9	車距範圍	警示後 3 秒

表 4.2-21 為第 III 類管理方式 (OBD+GPS+ADAS+DMS) 所得之高風險駕駛模式，係基於第 II 類管理方式之模式中顯著之變數再加入車內影像資料 (DMS)，可使用車內影像判斷駕駛員的分心狀況。值得注意的是，本計畫除使用人工觀看影片紀錄分心行為外，也利用影像辨識軟體進行分心行為之辨識作業，為求精準，本計畫將人工及影像辨識之變數一併放入，表 4.2-22 為因不顯著而刪除之變數。當車輛行駛於國道全線段且橫向警示作動下，駕駛員的分心行為對行車異常事件的產生有極大的關聯，本計畫發現「雙手離開方向盤」、「拿東西」以及「使用手機」等分心行為皆有較高機率造成行車異常事件的發生，顯示駕駛員若將手放開方向盤、拿東西、使用手機或其他可能造成視線離開前方的行為，會使駕駛員將手離開方向盤，進而影響車輛的穩定操作，導致警示事件的發生而若無法及時修正警示，也會進一步增加行車異常事件的發生機率，提高駕駛風險。

表 4.2-21 第 III 類管理方式行駛國道全線段高風險駕駛模式

項目	係數	標準誤
(截距)	-1.569 ***	0.359
超速	-2.071 *	0.841
晚上	-0.975 **	0.321
年資	-0.079 *	0.033
TITG_09_n3p3	0.362 **	0.121
雙手離開方向盤_真值	2.318 ***	0.399
拿東西	1.974 ***	0.503
用手機_真值	2.487 ***	0.657
AIC	288.32	
平均 AUC	0.805	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-22 第 III 類管理方式行駛國道全線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	擺頭	人工/影像
2	左手離開方向盤	人工/影像
3	右手離開方向盤	人工/影像
4	單手離開方向盤	人工/影像
5	雙手離開方向盤	影像
6	身體前傾	人工/影像
7	身體右傾	人工/影像
8	操作車內設備	人工/影像
9	拿東西	人工
10	用手機	影像
11	手靠近嘴巴	人工/影像
12	本車變換車道	-
13	前車變換車道	-
14	本車變換車道且擺頭	人工/影像
15	前車變換車道且擺頭	人工/影像
16	未變換車道但擺頭	人工/影像

表 4.2-23 為第 IV 類管理方式 (OBD+GPS+ADAS+DMS+車外環境) 所得之高風險駕駛模式，係基於第 III 類管理方式之模式顯著變數再加入車外環境資料，如道路線型、天候狀況、周圍車輛狀況等變數，可更清楚本車與周圍車輛環境互動關係對行車異常事件產生造成之影響，表 4.2-24 為因不顯著而刪除之變數。本計畫發現車外環境相關變數皆不顯著，顯示橫向警示與車外環境及周圍互動較無關聯，故若想減少橫向警示相關行車異常事件，可注意駕駛員車內行為並提醒注意與前方車距的保持。

上述模式為橫向警示發生下，本車行駛元國道全線的最佳模式，說明若駕駛員有以下行為時，可能導致行車異常事件產生之機率提高：

- (一) 警示前後 3 秒，本車與前車之秒距小於 0.9 秒之秒距與累積時間積分。
- (二) 駕駛員雙手離開方向盤。
- (三) 駕駛員伸手拿取物品。
- (四) 駕駛員使用手機(違規行為)。

表 4.2-23 第 IV 類管理方式行駛國道全線段高風險駕駛模式

項目	係數	標準誤
(截距)	-1.682 ***	0.389
超速	-2.026 *	0.843
晚上	-0.889 **	0.341
年資	-0.078 *	0.033
TITG_09_n3p3	0.350 **	0.122
雙手離開方向盤_真值	2.365 ***	0.404
拿東西	2.018 ***	0.507
用手機_真值	2.530 ***	0.659
周圍有大車 (p3)	0.104	0.129
AIC	289.71	
平均 AUC	0.803	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-24 第 IV 類管理方式行駛國道全線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	彎道半徑	-
2	坡度	-
3	左彎	-
4	右彎	-
5	下雨	-
6	周圍有車	警示前 3 秒
7	周圍有車	警示前後 3 秒
8	周圍有車	警示後 3 秒
9	周圍有大車	警示前 3 秒
10	周圍有大車	警示前後 3 秒

4.2.4 橫向警示事件：本車行駛國道主線段

表 4.2-25 為第 I 類管理方式 (OBD+GPS) 管理方式所得之高風險駕駛模式，由下表可知，若國道里程愈大，愈有可能降低行車異常事件發生機率，因本計畫之研究對象車輛主要行駛於國道 1 號台北至台南路線，隨著國道里程的增加表示車輛愈往南部行駛，也因此主線段的車輛會隨之減少，經確認國道 1 號易塞車路段為汐止、內湖、中壢、竹北等北部主要城市，故南部路段相較之下較為順暢，故行車異常事件產生之機率可能降低，但其顯著性並不高，說明此變數仍須加入其他的相關解釋變數，表 4.2-26 則為篩選時刪除之變數。「超速」及「夜晚」兩變數同樣指出，

若道路狀況較為順暢時，針對橫向警示事件(車道偏移警示)，本車行駛於國道主線段時將不易使警示事件發展為行車異常事件。

表 4.2-25 第 I 類管理方式行駛國道主線段高風險駕駛模式

項目	係數	標準誤
(截距)	-0.660 *	0.336
國道里程	-0.003 ~	0.002
超速	-1.899 *	0.748
晚上	-0.893 **	0.287
AIC	330.94	
平均 AUC	0.685	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-26 第 I 類管理方式行駛國道主線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	左方向燈	-
2	右方向燈	-
3	年資	-
4	平均速度	警示前 3 秒
5	平均速度	警示前後 3 秒
6	平均速度	警示後 3 秒
7	最大加速度絕對值	警示前 3 秒
8	最大加速度絕對值	警示前後 3 秒
9	最大加速度絕對值	警示後 3 秒
10	平均加速度絕對值	警示前 3 秒
11	平均加速度絕對值	警示前後 3 秒
12	平均加速度絕對值	警示後 3 秒

表 4.2-27 為第 II 類管理方式(OBD+GPS+ADAS)所得之高風險駕駛模式，係基於第 I 類管理方式之模式中顯著之變數再加入 ADAS 資料，可判斷前車與本車之相對車距，本計畫發現行駛於國道主線段時，車距與行車異常事件的行程較無關聯，值得注意的是，若放入車距變數，將會使國道里程的變數變為不顯著，表 4.2-28 為因不顯著而刪除之變數。

表 4.2-27 第 II 類管理方式行駛國道主線段高風險駕駛模式

項目	係數	標準誤
(截距)	-0.845 *	0.370
國道里程	-0.003	0.002
超速	-1.928 *	0.751
晚上	-0.845 **	0.290
TITG_09_n3p3	0.147	0.115
AIC	331.39	
平均 AUC	0.686	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-28 第 II 類管理方式行駛國道主線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	本車與前車秒距之累積時間 (TETG)	0.3~1 秒
2	本車與前車之秒距與時間積分 (TITG)	0.3~0.8, 1 秒 ²
3	最小車距	警示前 3 秒
4	最小車距	警示前後 3 秒
5	最小車距	警示後 3 秒
6	前方無車	警示前 3 秒
7	車距範圍	警示前 3 秒
8	車距範圍	警示前後 3 秒
9	車距範圍	警示後 3 秒

表 4.2-29 為第 III 類管理方式 (OBD+GPS+ADAS+DMS) 所得之高風險駕駛模式，係基於第 II 類管理方式之模式中顯著之變數再加入車內影像資料 (DMS)，可使用車內影像判斷駕駛員的分心狀況。值得注意的是，本計畫除使用人工觀看影片紀錄分心行為外，也利用影像辨識軟體進行分心行為之辨識作業，為求精準，本計畫將人工及影像辨識之變數一併放入，表 4.2-30 為因不顯著而刪除之變數。當車輛行駛於國道主線段且橫向警示作動下，駕駛員的分心行為對行車異常事件的產生有極大的關聯，本計畫發現「雙手離開方向盤」、「拿東西」以及「使用手機」等分心行為皆有較高機率造成行車異常事件的發生，顯示駕駛員若將手放開方向盤、拿東西、使用手機或其他可能造成視線離開前方的行為，會使駕駛員將手離開方向盤，進而影響車輛的穩定操作，導致警示事件的發生而若無法及時修正警示，也會進一步增加行車異常事件的發生機率，提高駕駛風險，此結果與行駛於國道主線段模式之校估結果相近。

表 4.2-29 第 III 類管理方式行駛國道主線段高風險駕駛模式

項目	係數	標準誤
(截距)	-1.649 ***	0.431
國道里程	-0.003	0.002
超速	-2.020 *	0.829
晚上	-0.905 **	0.320
TITG_09_n3p3	0.314 *	0.123
雙手離開方向盤_真值	2.130 ***	0.389
拿東西	1.798 ***	0.489
用手機_真值	2.523 ***	0.648
AIC	286.77	
平均 AUC	0.803	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-30 第 III 類管理方式行駛國道主線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	擺頭	人工/影像
2	左手離開方向盤	人工/影像
3	右手離開方向盤	人工/影像
4	單手離開方向盤	人工/影像
5	雙手離開方向盤	影像
6	身體前傾	人工/影像
7	身體右傾	人工/影像
8	操作車內設備	人工/影像
9	拿東西	人工
10	用手機	影像
11	手靠近嘴巴	人工/影像
12	本車變換車道	-
13	前車變換車道	-
14	本車變換車道且擺頭	人工/影像
15	前車變換車道且擺頭	人工/影像
16	未變換車道但擺頭	人工/影像

表 4.2-31 為第 IV 類管理方式 (OBD+GPS+ADAS+DMS+車外環境) 所得之高風險駕駛模式，係基於第 III 類管理方式之模式中顯著之變數再加入車外環境資料，如道路線型、天候狀況、周圍車輛狀況等變數，可更清楚本車與周圍車輛環境互動關係對行車異常事件產生造成之影響，表 4.2-32 為因不顯著而刪除之變數。本計畫發現對於車外環境相關變數皆不顯著，說明橫向警示的發生與車外環境及周圍互動關係較無關聯，可多加注意駕駛員的車內行為及保持安全車距，以減少行車異常事件的發生。

表 4.2-31 第 IV 類管理方式行駛國道主線段高風險駕駛模式

項目	係數	標準誤
(截距)	-1.760 ***	0.463
國道里程	-0.003	0.002
超速	-1.981 *	0.831
晚上	-0.830 *	0.340
TITG_09_n3p3	0.304 *	0.124
雙手離開方向盤_真值	2.173 ***	0.395
拿東西	1.833 ***	0.493
用手機_真值	2.559 ***	0.650
周圍有大車 (p3)	0.091	0.132
AIC	288.3	
平均 AUC	0.800	

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

表 4.2-32 第 IV 類管理方式行駛國道主線段高風險駕駛模式刪除變數

項次	刪除變數	範圍
1	彎道半徑	-
2	坡度	-
3	左彎	-
4	右彎	-
5	下雨	-
6	周圍有車	警示前 3 秒
7	周圍有車	警示前後 3 秒
8	周圍有車	警示後 3 秒
9	周圍有大車	警示前 3 秒
10	周圍有大車	警示前後 3 秒

上述模式為橫向警示發生下，本車行駛國道主線段的最佳模式，若駕駛員有以下行為，可能導致行車異常事件產生之機率提高：

- (一) 警示前後 3 秒，本車與前車之秒距小於 0.9 秒之秒距與累積時間積分。
- (二) 駕駛員雙手離開方向盤。
- (三) 駕駛員伸手拿取物品。
- (四) 駕駛員使用手機(違規行為)。

4.3 高風險駕駛行為之風險評估

為明確針對各類高風險駕駛行為建立門檻值，供相關安全管理人員參考及實施，本計畫進一步將 4.2 節所列出之最佳高風險模式中所有連續變數，使用提升迴歸樹模式 (BRT) 方法找出產生異常機率大幅升高的變數類別，訂為各模式下的高風險駕駛行為門檻值，並將連續變數類別化後找出更精準的高風險駕駛行為與門檻。接著，本研究進一步將各類別變數逐步放入對應之高風險模式後找出係數最大、最顯著之變數列為對應情境下之高風險駕駛行為門檻值，隨後將係數標準化訂為風險值後重新排列、並逐步將變數放入後計算其加總之風險值，其計算方式如下式 (4.3-1)，依據所繪製之高風險駕駛行為分布圖定義低、中、高風險範圍，並針對每一項變數計算各變數在高風險範圍中出現的比例，計算方式如式 (4.3-2) 所示。

$$Risk_n = \frac{\text{第 } n \text{ 種組合列係數和}-\text{最小係數和 (截距)}}{\text{最大係數和 (全)}-\text{最小係數和 (截距)}} \quad (4.3-1)$$

$$\text{高風險比例} = \frac{\text{每項行為在「高風險區」分佈數量}}{\text{該項行為出現總數}} \times 100\% \quad (4.3-2)$$

本計畫依據變數組合所在之範圍定義其風險值，並記錄風險轉變範圍 (低轉中、中轉高)，以提供業者相關管理建議，以下將針對各情境之風險評估做更詳細的說明。

4.3.1 縱向警示風險評估：本車變換車道

針對本車變換車道情境，本計畫對連續變數建立之 BRT 模式如下圖，同時，本計畫也依據圖 4.3.1 中異常機率提高之處，新增類別變數，整理如表 4.3-1 所示。

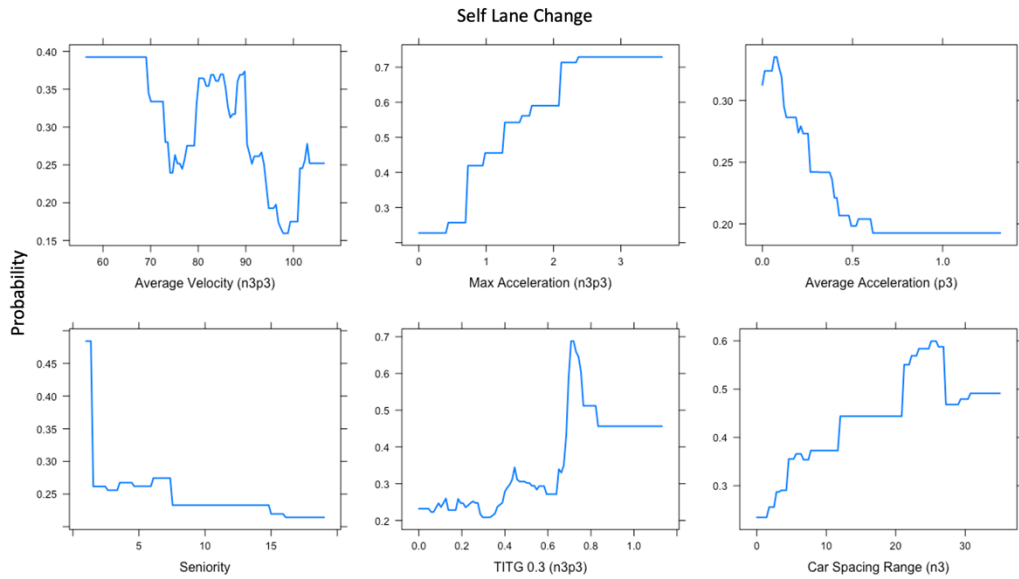


圖 4.3-1 BRT 模式圖形 (縱向警示：本車變換車道)

表 4.3-1 類別化變數選取範圍 (縱向警示：本車變換車道)

項次	項目	範圍
1	警示前後 3 秒平均車速	80~90 公里/小時
		< 70 公里/小時
2	警示前後 3 秒最大加速度	≥ 1.2 公尺/秒 ²
		≥ 2 公尺/秒²
		≥ 3 公尺/秒 ²
3	警示後 3 秒平均加速度	≤ 0.5 公尺/秒 ²
		< 0.4 公尺/秒 ²
		≤ 0.25 公尺/秒 ²
4	駕駛年資	< 3 年
		< 8 年
5	警示前後 3 秒與前車之秒距少於 0.3 秒之秒距與時間積分	≥ 0.7 秒 ²
6	警示前 3 秒與前車之車距範圍	≥ 20 公尺
		≥ 21 公尺
		12~26 公尺

根據上表之類別變數逐一嘗試放入模式，並刪除依據 BRT 結果類別化後變為不顯著之變數「警示後 3 秒平均加速度」後，本計畫得到之修正模式如下表 4.3-2：

表 4.3-2 類別化修正模式 (縱向警示：本車變換車道)

本車變換車道 (類別化修正模式)			
變數型態	項目	係數	標準誤
	(截距)	-1.924 ***	0.192
駕駛員相關	年資少於 3 年	1.059 ***	0.253
車輛動態	平均速度 80~90 公里/小時(n3p3)	0.685 ***	0.202
	最大加速度大於 2 公尺/秒 ² (n3p3)	2.104 ***	0.617
車內行為	雙手離開方向盤	0.876 *	0.429
	操作與安全無關設備	1.349 ~	0.691
車外環境	晚上	0.814 ***	0.234
	與前車之秒距少於 0.3 秒之秒距與時間積分 ≥ 0.7 秒 ² (n3p3)	1.277***	0.376
	車距範圍介於 12~26 公尺(n3)	1.437 ***	0.419
	周圍有大車(n3p3)	0.125 *	0.060
AIC: 652.82			
平均 AUC: 0.685			

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

依據修正模式，可得到縱向警示下，本車變換車道之高風險駕駛行為情境如下：

- (一) 警示前後 3 秒，平均車速介於 80~90 公里/小時；
- (二) 警示前後 3 秒，最大加速度 ≥ 2.5 公尺/秒²；
- (三) 駕駛時間為夜晚時；
- (四) 駕駛年資 < 3 年；
- (五) 警示前後 3 秒，與前車之秒距少於 0.3 秒之秒距與時間積分 ≥ 0.7 秒²；
- (六) 警示前 3 秒，與前車之車距範圍介於 13~26 公尺；
- (七) 駕駛員雙手離開方向盤；
- (八) 駕駛員操作與安全無關之設備；

(九) 警示前後 3 秒，周圍有大車。

依據圖 4.3-2 本計畫選擇斜率改變的切分點，設定為低風險、中風險以及高風險 3 個範圍，如以下所述：

(一) 0 至 75：低風險

(二) 76 至 450：中風險

(三) 451 至 512：高風險

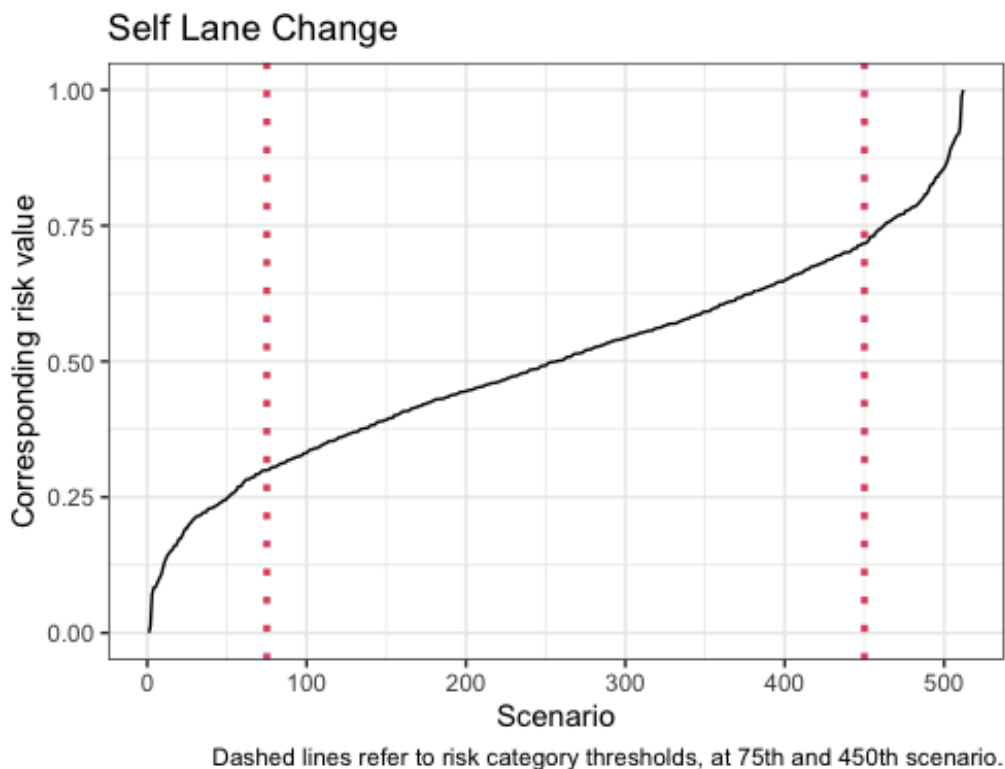


圖 4.3-2 各風險值選取範圍 (縱向警示：本車變換車道)

各類別變數之係數、高風險比例及組合如表 4.3-3 所示，其中，若在駕駛行為組合中加入「雙手離開方向盤」或「操作與安全無關設備」變數，可能讓駕駛行為組合之風險值產生變化。因此本計畫認為，此縱向警示且本車變換車道時，最需要注意的高風險項目即為「雙手離開方向盤」及「警示前 3 秒之車距範圍介於 12~26 公尺」。本計畫亦推測車距範圍的大幅度變化可說明行車當下可能經歷突然壅塞，或本車變換車道後使得與前車之距離大幅縮短，進而造成警示及行車異常事件。

表 4.3-3 風險嚴重度劃分 (縱向警示：本車變換車道)

項目	係數	高風險 駕駛行為比例	駕駛行為								
(截距)	-1.9	-	Y	Y	Y	Y	Y	Y	Y	Y	Y
周圍有大車(n3p3)	0.13	12.5%	Y	Y	Y	Y	Y	Y	Y	Y	Y
平均速度 80~90 公里/小時(n3p3)	0.68	16.4%		Y	Y	Y	Y	Y	Y	Y	Y
晚上	0.81	17.2%			Y	Y	Y	Y	Y	Y	Y
雙手離開方向盤	0.88	17.2%				Y	Y	Y	Y	Y	Y
年資少於 3 年	1.06	17.2%					Y	Y	Y	Y	Y
與前車之秒距少 於 0.3 秒之秒距與 時間積分 ≥ 0.7 秒 ² (n3p3)	1.28	19.5%						Y	Y	Y	Y
操作與安全無關 設備	1.35	19.9%							Y	Y	Y
車距範圍介於 12~26 公尺 (n3)	1.44	19.9%								Y	Y
最大加速度大於 2 公尺/秒 ² (n3p3)	2.1	23.4%									Y
加總係數			-1.80	-1.11	-0.30	0.58	1.63	2.91	4.26	5.70	7.80
風險等級			低	低	低	中	中	中	中	高	高

4.3.2 縱向警示風險評估：前車變換車道

針對前車變換車道情境，本計畫對連續變數建立之 BRT 模式如圖 4.3-3，同時，本計畫也依據圖 4.3-3 中異常機率提高之處，新增類別變數，詳如下表 4.3-4 所示。

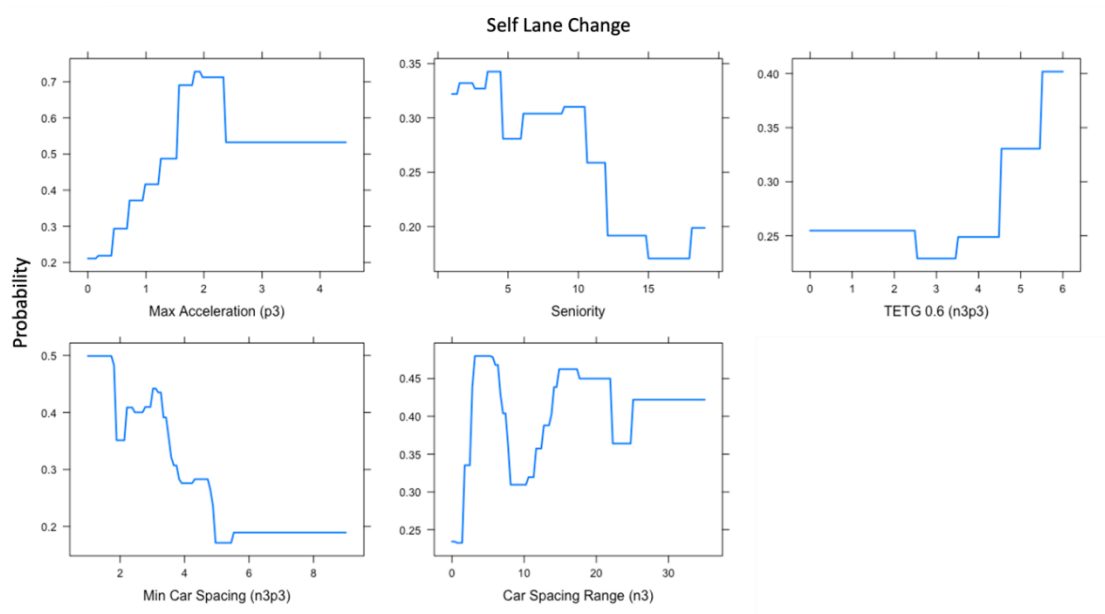


圖 4.3-3 BRT 模式圖形 (縱向警示：前車變換車道)

表 4.3-4 類別化變數選取範圍 (縱向警示：前車變換車道)

項次	項目	範圍
1	警示後 3 秒最大加速度	1.5~2.5 公尺/秒 ²
		≥ 1.5 公尺/秒 ²
		≥ 2 公尺/秒 ²
2	駕駛年資	≤ 4 年
		≤ 10 年
3	警示前後 3 秒與前車秒距少於 0.6 秒之持續時間	≥ 4 秒
		≥ 5 秒
4	警示前後 3 秒與前車之最小車距	≤ 3 公尺
		≤ 4 公尺
		≤ 5 公尺
5	警示前 3 秒與前車之車距範圍	≥ 10 公尺
		≥ 11 公尺
		11~21 公尺

根據上表之類別變數逐一嘗試放入模式，並刪除依據 BRT 結果類別化後變為不顯著之變數「警示前 3 秒與前車之車距範圍」後，本計畫得到之修正模式如表 4.3-5。

表 4.3-5 類別化修正模式 (縱向警示：前車變換車道)

前車變換車道 (類別化修正模式)			
變數型態	項目	係數	標準誤
	(截距)	-2.292 ***	0.345
駕駛員相關	年資少於 10 年	0.498 *	0.232
行車動態	最大加速度大於 1.5 公尺/秒 ² (p3)	1.789 ***	0.409
車內行為	右手離開方向盤_真值	0.791 **	0.265
	雙手離開方向盤	0.912 *	0.464
	前車變換車道且擺頭_真值	-1.205 *	0.531
車外環境	與前車秒距少於 0.6 秒之持續時間≥4 秒 (n3p3)	0.940 ***	0.227
	最小車距少於 4 公尺(n3p3)	0.777 **	0.246
AIC: 515.91			
平均 AUC: 0.759			

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

依據修正模式，可得到縱向警示下，前車變換車道之高風險駕駛行為情境如下：

- (一) 警示後 3 秒，最大加速度 ≥ 1.5 公尺/秒²。
- (二) 駕駛年資 < 10 年。
- (三) 警示前後 3 秒，與前車秒距少於 0.6 秒之持續時間 ≥ 4 秒。
- (四) 警示前後 3 秒，最小車距少於 4 公尺。
- (五) 駕駛員雙手離開方向盤。
- (六) 駕駛員右手離開方向盤。
- (七) 駕駛員未於前車變換車道時擺頭。

值得注意的是「前車變換車道且擺頭_真值」變數，因為其係數為負值，表示若駕駛員於前車變換車道時擺頭，將會降低行車異常事件的發生，故本研究將後續將高風險駕駛行為定義為「未於」前車變換車道時擺頭，調整後續分析架構；「警示後 3 秒周圍有車」變數則因為不顯著，不列入高風險駕駛情境統計項目中。

依據圖 4.3-4 本計畫選擇斜率改變的切分點，設定為低風險、中風險以及高風險 3 個範圍，如以下所述：

- (一)0 至 25：低風險。
- (二)26 至 100：中風險。
- (三)100 至 128：高風險。

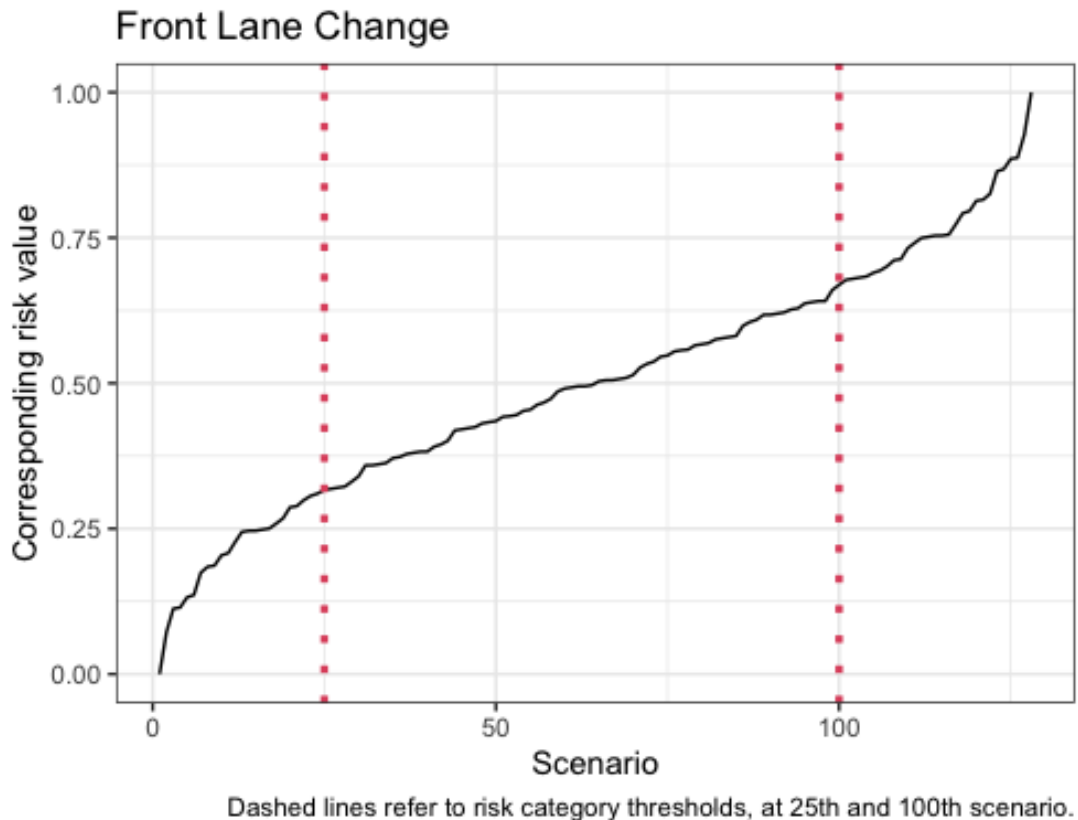


圖 4.3-4 各風險值選取範圍 (縱向警示：前車變換車道)

依據表 4.3-6 可知，若在駕駛行為組合中加入「雙手離開方向盤」變數或「未於前車變換車道時擺頭」變數，可能使駕駛行為組合之風險值產生變化，因此，本計畫認為，縱向警示發生且前車變換車道時，最需要注意的高風險項目即為「雙手離開方向盤」及「未於前車變換車道時擺頭」。

表 4.3-6 風險嚴重度劃分 (縱向警示：前車變換車道)

項目	係數	高風險 行為比例	駕駛行為						
(截距)	-3.50	-	Y	Y	Y	Y	Y	Y	Y
年資≤10 年	0.50	26.6%	Y	Y	Y	Y	Y	Y	Y
最小車距≤4 公尺 (n3p3)	0.78	29.7%		Y	Y	Y	Y	Y	Y
右手離開方向盤 _真值	0.79	29.7%			Y	Y	Y	Y	Y
雙手離開方向盤	0.91	31.3%				Y	Y	Y	Y
與前車秒距少於 0.6 秒之持續時間 ≥4 秒(n3p3)	0.94	31.3%					Y	Y	Y
未於前車變換車 道時擺頭_真值	1.20	34.4%						Y	Y
最大加速度≥ 1.5 公尺/秒 ² (p3)	1.79	42.2%							Y
加總係數			-3.00	-2.22	-1.43	-0.52	0.42	1.63	3.42
風險等級			低	低	低	中	中	高	高

4.3.3 橫向警示風險評估：國道全線段 (含匝道)

針對本車行駛於國道全線段 (主線及匝道) 之情境，本計畫對連續變數建立之 BRT 模式如下圖 4.3-5，同時，本計畫也依據下圖 4.3-10 中異常機率提高之處新增類別變數，整理如下表 4.3-7 所示：

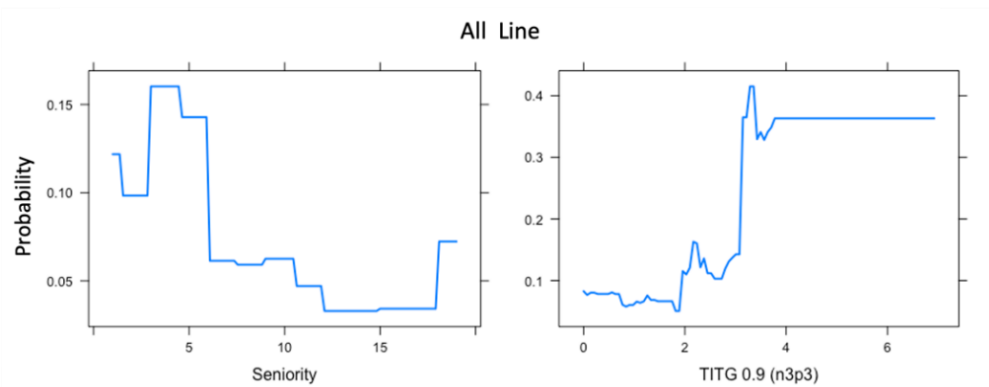


圖 4.3-5 BRT 模式圖形 (橫向警示：本車行駛國道全線段)

表 4.3-7 類別化變數選取範圍 (橫向警示：本車行駛國道全線段)

項次	項目	範圍
1	駕駛年資	≤ 5 年
		≤ 6 年
2	警示前後 3 秒與前車之秒距少於 0.9 秒之秒距與時間積分	≥ 2 秒 ²
		≥ 3 秒 ²

根據上表之類別變數逐一嘗試放入模式，並刪除依據 BRT 結果類別化後變為不顯著之變數「警示後 3 秒周圍有大車」後，本計畫得到之修正模式如下表 4.3-8。

表 4.3-8 類別化修正模式 (橫向警示：本車行駛國道全線段)

國道全線 (含匝道) (類別化修正模式)			
變數型態	項目	係數	標準誤
	(截距)	-2.617***	0.337
駕駛員相關	年資少於 6 年	1.100**	0.336
行車動態	超速	-2.283**	0.864
車內行為	雙手離開方向盤_真值	2.322***	0.396
	拿東西	2.007***	0.504
	用手機_真值	2.405***	0.662
車外環境	晚上	-1.053**	0.327
	與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒 ² (n3p3)	1.938***	0.516
AIC: 280.28			
平均 AUC: 0.811			

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

依據修正模式，可得到橫向警示下，本車行駛於國道全線段之高風險駕駛行為情境如下：

- (一) 駕駛年資少於 6 年。
- (二) 警示前後 3 秒，與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒²。
- (三) 駕駛員雙手離開方向盤。
- (四) 駕駛員用手拿取物品。

(五)駕駛員使用手機。

值得注意的是「超速」及「晚上」變數之係數為負值，表示若駕駛員使用較快車速駕駛或在行駛時間在夜間時，將會降低行車異常事件的發生，此結果與「本車行駛於國道主線段」之分析結果相同，本研究推斷橫向警示的行車異常事件與駕駛員手部分心較有相關，此2變數不屬於高風險駕駛行為，於後續分析中予以刪除；「警示後3秒周圍有車」變數則因為不顯著，不列入高風險駕駛情境統計項目中。

依據圖 4.3-6 本計畫選擇斜率改變的切分點，設定為低風險、中風險以及高風險3個範圍，如以下所述：

- (一)0 至 25：低風險。
- (二)26 至 100：中風險。
- (三)100 至 128：高風險。

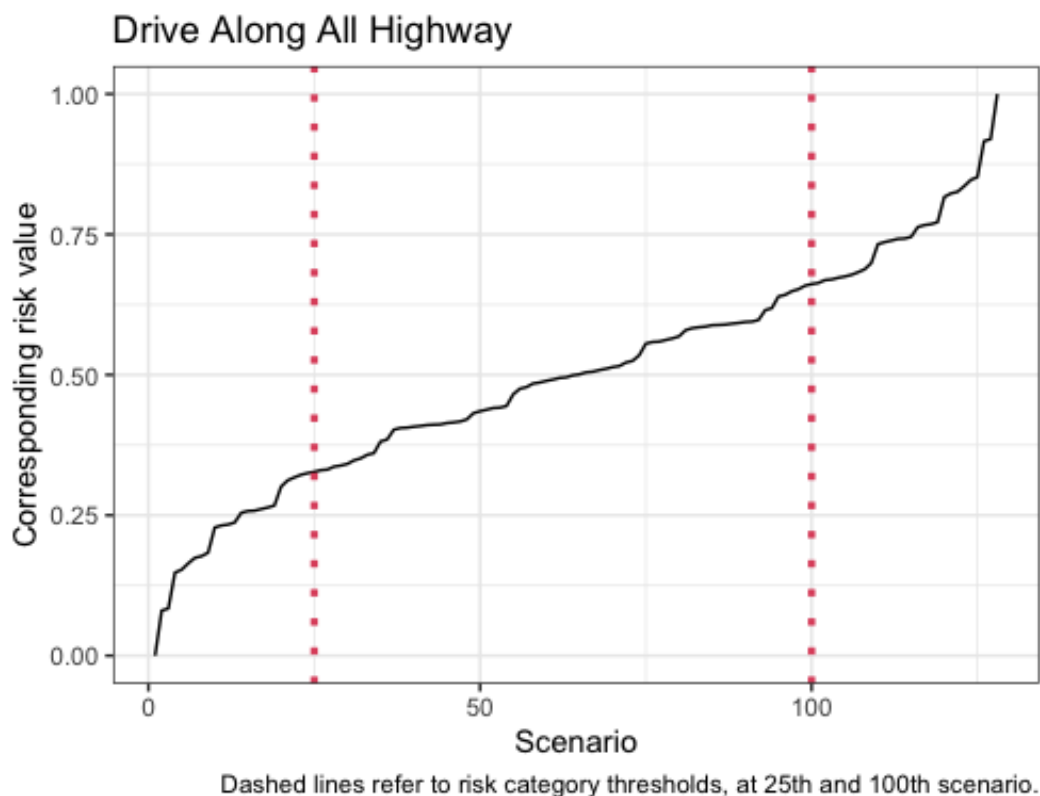


圖 4.3-6 各風險值選取範圍 (橫向警示：本車行駛國道全線段)

依據表 4.3-9 可知，若於駕駛行為組合中加入「拿東西」或「雙手離開方向盤」變數，可能使駕駛行為組合之風險值產生變化，因此，本計

畫認為，橫向警示發生且本車行駛於國道全線時，最需要注意的高風險項目即為「拿東西」及「雙手離開方向盤」。

表 4.3-9 風險嚴重度劃分 (橫向警示：本車行駛國道全線段)

項目	係數	高風險 行為比例	駕駛行為						
(截距)	-2.62	-	Y	Y	Y	Y	Y	Y	Y
白天	1.05	29.7%	Y	Y	Y	Y	Y	Y	Y
年資≤6 年	1.10	29.7%		Y	Y	Y	Y	Y	Y
與前車之秒距少 於 0.9 秒之秒距 與時間積分 ≥ 3 秒 ^{2(n3p3)}	1.94	31.3%			Y	Y	Y	Y	Y
拿東西	2.01	31.3%				Y	Y	Y	Y
未超速	2.28	35.9%					Y	Y	Y
雙手離開方向盤 _真值	2.32	35.9%						Y	Y
用手機_真值	2.41	35.9%							Y
加總係數			-1.56	-0.46	1.47	3.48	5.76	8.09	10.49
風險等級			低	低	低	中	中	高	高

4.3.4 橫向警示風險評估：國道主線段

針對本車行駛於國道主線段之情境，本計畫對連續變數建立之 BRT 模式如圖 4.3-7，同時，本計畫也依據圖中異常機率提高之處，新增類別變數，如表 4.3-10 所示：

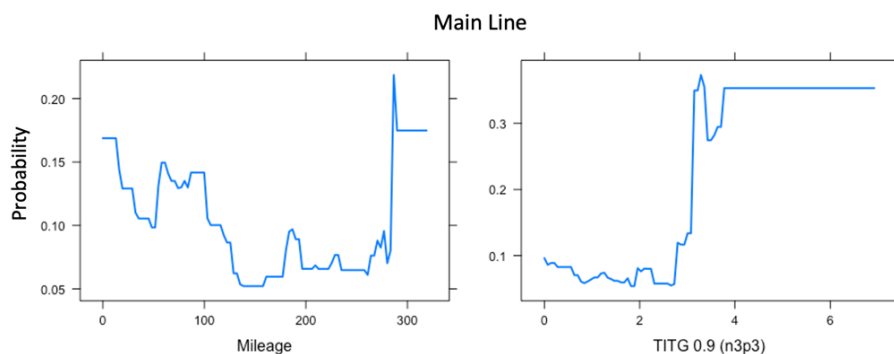


圖 4.3-7 BRT 模式圖形 (橫向警示：本車行駛國道主線段)

表 4.3-10 類別化變數選取範圍 (橫向警示：本車行駛國道主線段)

項次	項目	範圍
1	國道里程	0~100 公里
		50~100 公里
		≥ 280 公里
2	警示前後 3 秒與前車之秒距少於 0.9 秒之秒距與時間積分	≥ 3 秒 ²

根據上表之類別變數逐一嘗試放入模式，並刪除依據 BRT 結果類別化後變為不顯著之變數「警示後 3 秒周圍有大車」後，本研究得到之修正模式如表 4.3-11：

表 4.3-11 類別化修正模式 (橫向警示：本車行駛國道主線段)

國道主線段 (類別化修正模式)			
變數型態	項目	係數	標準誤
	(截距)	-2.208***	0.288
駕駛員相關	-	-	-
行車動態	超速	-1.909*	0.817
車內行為	雙手離開方向盤_真值	2.233***	0.397
	拿東西	1.905***	0.493
	用手機_真值	2.485***	0.647
車外環境	國道里程介於 0~100 公里之間	0.617~	0.348
	晚上	-0.940**	0.324
	與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒 ² (n3p3)	1.714***	0.510
AIC: 281.13			
平均 AUC: 0.801			

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

依據修正模式，可得到橫向警示下，本車行駛於國道主線段之高風險駕駛行為情境如下：

(一)本車行駛於國道里程 0 至 100 公里之主線段時。

(二)警示前後 3 秒，與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒²。

(三)駕駛員雙手離開方向盤。

(四)駕駛員用手拿取物品。

(五)駕駛員使用手機。

值得注意的是「超速」、「晚上」變數之係數為負值，表示若駕駛員使用較快車速行駛及夜晚時，較不易造成橫向警示下的行車異常事件，故本研究於後續分析將變數更改為「未」超速以及「白天」做為於行駛於國道主線段車道的高風險駕駛行為。

依據圖 4.3-8，本計畫選擇斜率改變的切分點，設定為低風險、中風險以及高風險 3 個範圍，如以下所述：

(一)0 至 25：低風險。

(二)26 至 100：中風險。

(三)100 至 128：高風險。

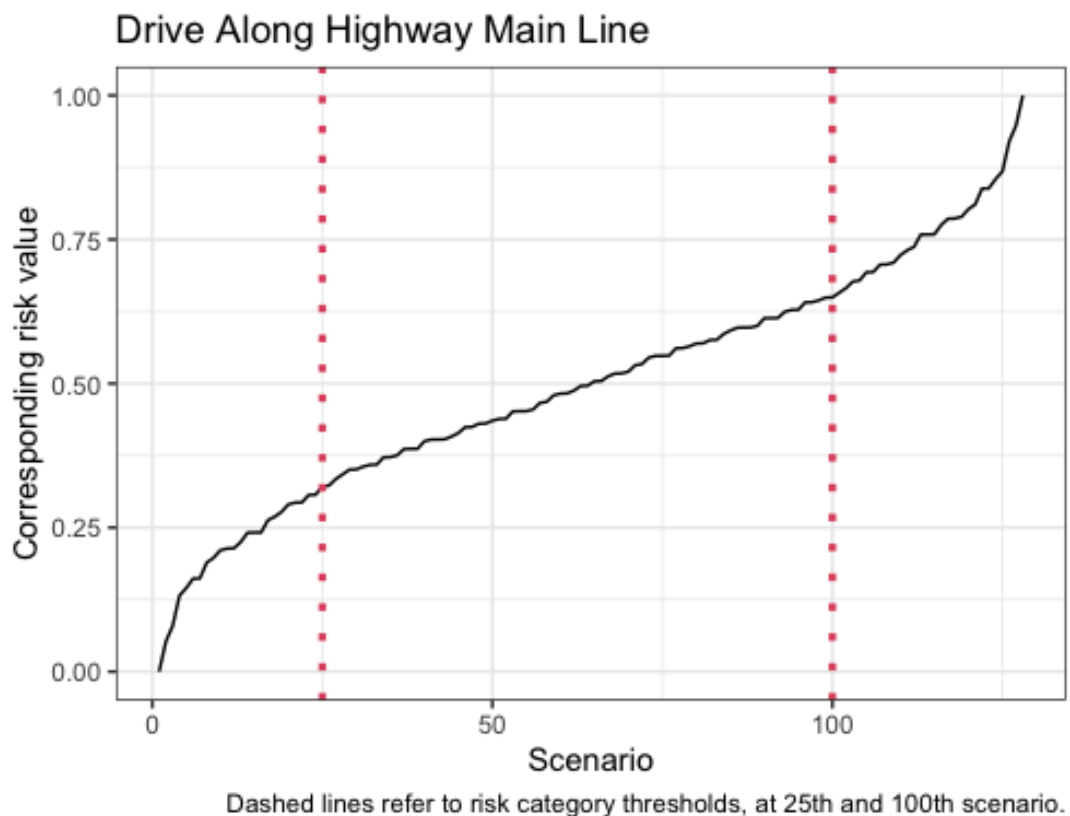


圖 4.3-8 各風險值選取範圍 (橫向警示：本車行駛國道主線段)

依據表 4.3-12 可知，若於駕駛行為組合中放入「拿東西」或「雙手離開方向盤」變數，可能使駕駛行為組合之風險值產生變化。因此，本計畫認為，縱向警示發生且本車行駛於國道主線段時，最需要注意的高風險項目即為「拿東西」及「雙手離開方向盤」，此結果與行駛國道全線段相同。本計畫推測因研究對象客運公司行駛台南至台北來回路線，未頻繁上下匝道，故行使主線段機會較大，因此有類似結果。

表 4.3-12 風險嚴重度劃分 (橫向警示：本車行駛國道主線段)

項目	係數	高風險 行為比例	駕駛行為						
(截距)	-5.06	-	Y	Y	Y	Y	Y	Y	Y
國道里程介於 0~100 之間	0.62	25%	Y	Y	Y	Y	Y	Y	Y
白天	0.94	25%		Y	Y	Y	Y	Y	Y
與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒 (n3p3)	1.71	32.8%			Y	Y	Y	Y	Y
拿東西	1.90	34.4%				Y	Y	Y	Y
未超速	1.91	34.4%					Y	Y	Y
雙手離開方向盤_真值	2.23	35.9%						Y	Y
用手機_真值	2.49	37.5%							Y
加總係數			-4.44	-3.50	-1.79	0.12	203	4.26	6.75
風險等級			低	低	低	中	中	高	高

4.4 以機器學習方法預測行車異常事件

本節使用機器學習方法預測並分類行車異常事件。本計畫使用的機器學習方法為常見的決策樹、XGBoost 與隨機森林，而分析的資料層級則分為四個層級，分別為層級 I (有 OBD、GPS)、層級 II (有 OBD、GPS、ADAS)、層級 III (有 OBD、GPS、ADAS、DMS，且有車內影像系統，可與 ADAS 結合使用)、層級 IV (與層級 III 類似，且有外部環境資料可供使用，如道路線型、天氣狀況等)。另外，本計畫為了探討更細節的資料類型，對於行車異常事件分類結果之影響，在資料層級 III 及 IV 中，再區分僅影像識別之變數、僅分心之變數以及僅人工判斷真值動作之變數 3 種類

別。因此，本研究最終將以資料層級 I、II、III(僅影像)、III(僅分心)、III(僅人工動作)、IV(僅影像)、IV(僅分心)及 IV(僅人工動作)等 8 個資料類型進行機器學習的分析與分類。

本章節使用的資料庫共有 2,524 筆國道客運行車異常事件發生與否的樣本，本計畫首先將 2,524 筆樣本區分為訓練樣本 (training dataset) 與測試樣本 (test dataset)，並使用 10-fold 的交叉驗證 (cross validation) 進行分析。首先，本計畫先將不同資料層級設定一致之方法的參數，接著，使用 python 進行決策樹、XGBoost 與隨機森林的分析，再進行 10-fold 之交叉驗證。

然而，本計畫在實際操作決策樹、XGBoost 與隨機森林的機器學習方法時，許多績效指標都不盡理想 (包括 AUC 值、Recall、Precision 值等)，因此，本計畫接著使用過採樣 (oversampling) 與欠採樣 (undersampling) 的方法，探討在使用平衡樣本的方法下，是否在各種績效指標上有其進步。最後，本計畫再將所有的樣本分為橫向警示與縱向警示，進一步了解在全部警示拆分為橫向與縱向警示後，是否能在績效指標上有所改變。以下章節主要分為 4.4.1 的 XGBoost 與 4.4.2 的隨機森林，個別探討不同機器學習方法的優劣。

4.4.1 XGBoost

在 XGBoost 的方法中，本計畫先將不同資料層級的所有變數與所有樣本納入機器學習的分析中，並設定一致之方法的參數，接著，使用 python 進行決策樹與 XGBoost 的分析，刪除變數重要性小於 0.01 之變數，再進行 10-fold 之交叉驗證。本小節分析方法流程圖如圖 4.4-1 所示。

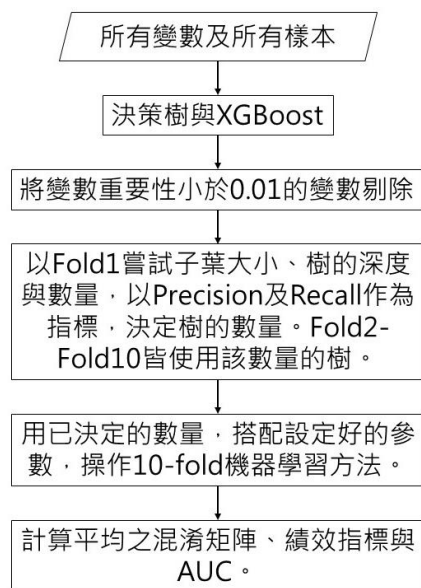


圖 4.4-1 XGBoost 方法操作流程圖

表 4.4-1 為決策樹與 XGBoost 之分析結果，包含子葉大小、樹的深度與樹的數量等參數設定，本計畫將 XGBoost 之學習率參數設定為 0.3，根據圖 4.4-1，表中之參數設定均為試誤後之最佳績效，故在每一個資料層級中的參數設定方呈現相異之結果。根據表 4.4-1，資料層級 III (分心) 與 IV (分心) 之 AUC 值最高，分別為 0.7632 及 0.7478，人工動作與影像則次之，而資料層級 I 最低，僅 0.6066。從表中可以發現，資料層級 I 所建構之 XGBoost 機器學習分析結果，與資料層級 II 後之結果，AUC 值差異較大，代表僅有 OBD 與 GPS 的相關變數，在分類行車異常事件的過程中，表現較為不好。但若有 ADAS 輔助系統，則可以約增加 0.1 的 AUC 值，表示 ADAS 對於判斷行車異常事件具有良好的效果。

表 4.4-1 決策樹與 XGBoost 之分析結果

資料層級	子葉大小	樹的深度	樹的數量	平均 AUC
I	20	20	20	0.6066
II	15	15	20	0.7052
III 影像	15	10	50	0.6923
III 分心	15	20	20	0.7632
III 人工動作	20	20	20	0.7415
IV 影像	15	15	20	0.7019
IV 分心	20	20	40	0.7478
IV 人工動作	20	20	20	0.7167

本計畫進一步探討 XGBoost 機器學習方法在各個資料層級的重要變數，發現資料層級 I 之重要變數包含最大加速度、平均加速度、車速與速限差異、是否為夜晚、平均車速與道路速限等。而資料層級 II 之重要變數則主要為與前車最小車距、與前車車距之累積時間、與前車之時距與時間積分等。至於資料層級 III 與 IV 之重要變數為用手機 (手持)_真值、拿東西_真值、使用車內設備 (與安全無關)_真值、是否為分心等。其中，「是否為分心」之變數之重要性相當高，在每一個 fold 中均高於 0.14，而本計畫認為分心變數之重要性，可能為導致資料層級 III 分心與 IV 分心之 AUC 值最高的主要原因。

除了 AUC 值以外，本計畫使用 Accuracy、Recall 及 Precision 指標判斷各類資料層級之變數分類的表現。上述三個績效指標的計算均來自於混淆矩陣 (confusion matrix)，混淆矩陣之涵義如表 4.4-2 所示，而各指標之計算方式亦分述如下：

表 4.4-2 混淆矩陣

	Predicted Positive	Predicted Negative
Actual Positive	TP	FN
Actual Negative	FP	TN

Accuracy 又可稱為準確率，該指標可視為機器學習方法中正確分類的比例，其計算方式如式 (4.4-1)。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (4.4-1)$$

Recall 是指在所有的 positive 類別中，分類正確的比例，其計算方式如式 (4.4-2)。

$$Recall = \frac{TP}{TP + FN} \quad (4.4-2)$$

Precision 是指所有被機器學習方法分類為 positive 的資料中，機器學習方法分類正確的比例，其計算方式如式 (4.4-3) 所示。

$$Precision = \frac{TP}{TP + FP} \quad (4.4-3)$$

根據混淆矩陣與上述公式，本計畫針對 XGBoost 方法之不同資料層級的績效指標分析結果如表 4.4-3 所示。從表 4.4-3 可以發現，XGBoost 機器學習方法在訓練樣本的表現相當好，不論是 Accuracy、Recall 或是 Precision，其值多數均在 0.95 以上，也反映 XGBoost 在機器學習方法上的突出之處。然而，測試樣本的績效指標則遠遠不如訓練樣本之分析結果，為該機器學習方法較為可惜之處。

表 4.4-3 XGBoost 績效指標

資料層級	訓練樣本			測試樣本		
	Accuracy	Recall	Precision	Accuracy	Recall	Precision
I	1.000	1.000	1.000	0.745	0.123	0.642
II	0.988	0.948	1.000	0.765	0.345	0.506
III 影像	0.988	0.947	1.000	0.760	0.312	0.525
III 分心	0.995	0.981	0.998	0.766	0.345	0.504
III 動作	0.992	0.966	1.000	0.778	0.368	0.467
IV 影像	0.978	0.906	1.000	0.767	0.324	0.501
IV 分心	0.997	0.990	0.997	0.752	0.321	0.547
IV 動作	0.989	0.954	1.000	0.765	0.337	0.494

4.4.2 隨機森林

表 4.4-4 為決策樹與隨機森林之分析結果，包含子葉大小、樹的深度與樹的數量等參數設定，根據圖 4.4-1，表中之參數設定均為試誤後之最佳績效，故在每一個資料層級中的參數設定方呈現相異之結果。根據表 4.4-4，資料層級 III (分心) 與 IV (分心) 之 AUC 值最高，分別為 0.7808 及 0.7866，而資料層級 I 最低，僅 0.6566。然而，其實資料層級 II 往後之資料類型，模式間的 AUC 值皆差異不大，代表在隨機森林的分析結果中，資料層級 II 之變數可視為較為重要的變數，此部分可透過變數重要性之排序觀察得知。在隨機森林的機器學習方法中，本計畫發現 III 與 IV 資料層級的變數，相較於 I 與 II 資料層級，較為不顯著，其隨機森林分析結果之變數重要性多小於 0.01，以至於無法被納入後續的 10-fold 交叉驗證分析中，也進而導致表 4.4-4 中 AUC 值所呈現的結果。另外，本計畫進一步探

討變數重要性較高的變數種類，主要包含「與前車之時距與時間積分 (資料層級 II)」、「平均加速度 (資料層級 I)」、「最大方向盤轉動角度 (資料層級 I)」、「與前車最小車距 (資料層級 II)」及「車速與速限差異 (資料層級 I)」等。由上述所列之重要變數也得以驗證資料層級 III 與 IV 的變數，重要性較低之事實。

表 4.4-4 決策樹與隨機森林之分析結果

資料層級	子葉大小	樹的深度	樹的數量	平均 AUC
I	15	15	20	0.6566
II	20	20	40	0.7461
III 影像	20	20	20	0.7385
III 分心	10	15	30	0.7808
III 人工動作	15	20	50	0.7443
IV 影像	20	20	20	0.7357
IV 分心	20	20	20	0.7866
IV 人工動作	20	20	20	0.7432

本計畫進一步探討出現該結果之可能因素，並將其關係繪製如圖 4.4-2。由於分心、人工動作相關變數可能會直接影響與其他車輛的互動，例如駕駛在使用手機、拿取東西時可能使其與周圍車輛接近，進而導致行車異常事件的發生，反而分心、人工動作相關變數並不會在隨機森林中直接影響行車異常事件的發生與否，而是透過與其他車輛互動後間接導致。因此，本計畫認為隨機森林的運算機制，可能有以下變數間的關係，而使得分析結果之呈現可能不如本計畫之預期。



圖 4.4-2 隨機森林資料層級與行車異常事件之關係示意圖

同樣地，本計畫使用 Accuracy、Recall 及 Precision 指標，針對不同資料層級的績效指標分析結果如表 4.4-5 所示。從表中可以觀察到，隨機森林訓練樣本之 Accuracy 與 Precision 值的表現均相當不錯，代表正確分類

的比例高，且仍為「分心」之資料類別的 Accuracy 最高。然而，經過 10-fold 交叉驗證後，本計畫分析結果之測試樣本的績效指標表現較差，尤其是 Recall 與 Precision 值與訓練樣本之差異較大。在多數資料層級的模式中，Recall 值皆小於 0.3，代表當事實上為行車異常事件時，隨機森林預測其確實為行車異常事件之比例僅約 30%；而 Precision 值多小於 0.5，代表當機器學習預測其為行車異常事件時，其真實為行車異常事件之比例約為 50%。

表 4.4-5 隨機森林績效指標

資料層級	訓練樣本			測試樣本		
	Accuracy	Recall	Precision	Accuracy	Recall	Precision
I	0.890	0.533	0.987	0.753	0.072	0.653
II	0.913	0.647	0.969	0.777	0.275	0.462
III 影像	0.909	0.639	0.955	0.777	0.290	0.462
III 分心	0.961	0.837	0.993	0.768	0.299	0.497
III 動作	0.933	0.716	0.990	0.773	0.280	0.478
IV 影像	0.910	0.643	0.955	0.771	0.266	0.483
IV 分心	0.922	0.708	0.942	0.765	0.321	0.507
IV 動作	0.909	0.643	0.949	0.765	0.266	0.508

不論是 XGBoost 或是隨機森林之機器學習方法，測試樣本的 Recall 與 Precision 值均不高，因此，本計畫將所有變數均納入隨機森林方法中進行預測，並使用過採樣 SMOTE 與欠採樣 Tomek Link 的平衡樣本方法，希望能進一步提高績效指標。以下分別介紹 SMOTE 與 Tomek Link 如何達到平衡樣本的目的。

SMOTE 為一種過採樣的方法，目的是將少數樣本 (在本計畫中是行車異常事件) 數量增加，而多數樣本數量不變，以達到平衡的目的，其示意圖如圖 4.4-3 所示。首先，該方法需要先找到一個少數樣本點 (圖中紅點)，並設定 K 個鄰近點 (圖左中箭頭指向的三個樣本點)，從這三個樣本點中，再找尋最近點 (圖右中綠點)，並設定參數為需要合成多少個新的樣本，即為圖右中三個紫色樣本點。根據上述步驟，就能夠獲得新的少數樣本點。

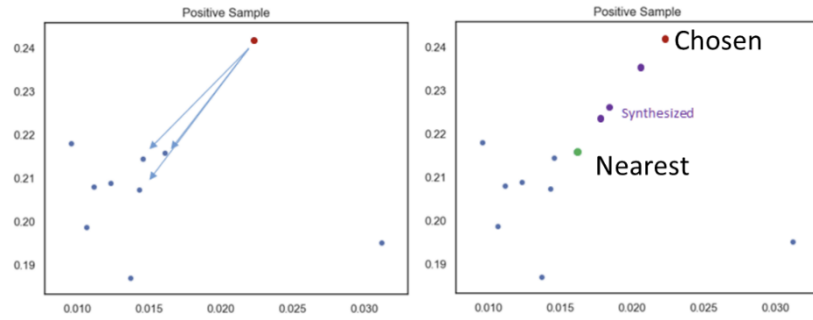


圖 4.4-3 SMOTE 方法示意圖

綜上所述，在 SMOTE 中，有數個參數需要設定，如下所示：

- (一)random_state：控制分析過程的虛擬隨機數，其所生成的種子或初始化值，使其可以確保分析結果的重複性。
- (二)k_neighbors：用於指定生成新樣本時考慮的最近鄰數目。它決定了合成樣本在特徵空間中的位置。
- (三)sampling_strategy：用於控制合成的新樣本數量。表 4.4-6 為過採樣後，將異常的樣本設定為非異常的 80%的情況。

表 4.4-6 訓練樣本在 SMOTE 前後之異常與非異常數量

	SMOTE 前	SMOTE 後
異常	518	1403
非異常	1754	1754
異常與非異常比例	3:10	8:10

表 4.4-7 是所有變數納入隨機森林方法的分析結果，從表中觀察，部分資料層級之 AUC 值有達到 0.8 (III 分心、III、IV)，為使用機器學習以來最高的 AUC 值結果。然而，關於 AUC 值的分布，也可以發現 AUC 不一定是在 SMOTE 前或是 SMOTE 後較高，因此，以 AUC 值而言，本計畫並無法得到 SMOTE 後會有較好的分析結果之論述。最後，從表中可以發現，AUC 值較高的資料層級仍為分心與全部變數均納入的情況。

表 4.4-7 SMOTE 前後之 AUC 值比較

資料層級	SMOTE 前 (所有變數)	SMOTE 後 (所有變數)
I	0.6850	0.6987
II	0.7633	0.7647
III 分心	0.802	0.800
III 動作	0.7770	0.7808
III 影像	0.7557	0.7615
III	0.8074	0.8003
IV 分心	0.7991	0.7818
IV 動作	0.7753	0.7684
IV 影像	0.7618	0.7538
IV	0.8080	0.7982

若以 Recall 值做為評斷標準，則可以比較 SMOTE 前後之 Recall 值的表現。如表 4.4-8 所示，在所有資料層級中，SMOTE 後的 Recall 值均較高，且部分資料層級之 Recall 值甚至有達到 0.5，若以警示事件在全部警示中的比例為 0.232 而言，本計畫認為機器學習的方法有一定程度之預測分類能力，較單純擲銅板得出結果的分類更好。

表 4.4-8 SMOTE 前後之 Recall 值比較

資料層級	SMOTE 前 (所有變數)	SMOTE 後 (所有變數)
I	0.072	0.284
II	0.275	0.501
III 分心	0.299	0.504
III 動作	0.280	0.504
III 影像	0.290	0.455
IV 分心	0.321	0.494
IV 動作	0.266	0.468
IV 影像	0.266	0.441

除了 SMOTE 之外，本計畫也使用欠採樣的 Tomek Link 方法，藉由減少多數樣本的數量，希望更加平衡多數與少數樣本之間的比例關係。本計畫以圖 4.4-4 做為 Tomek Link 實際操作的示意圖。

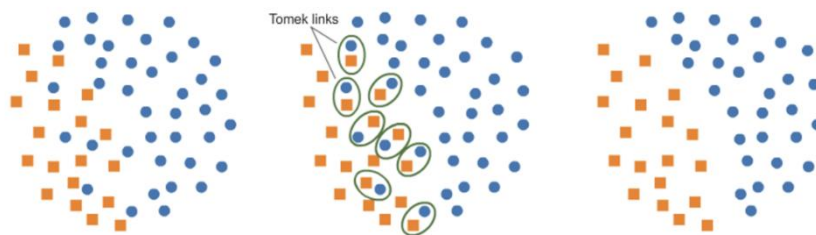


圖 4.4-4 Tomek Link 方法示意圖

圖中藍色的點為多數樣本點，橘色為少數樣本點。Tomek Link 會尋找多數樣本與少數樣本最鄰近的兩個點組合，如圖中的「Tomek Links」，並在這個組合中，移除多數樣本點，以此平衡多數樣本與少數樣本的個數。

表 4.4-9 為所有變數納入隨機森林方法的分析結果，從表中觀察，部分資料層級之 AUC 值有達到 0.8 (III 分心、III、IV)，為使用機器學習以來最高的 AUC 值結果。而比較 SMOTE 與 Tomek Link 後，本計畫發現 Tomek Link 有比 SMOTE 更好的 AUC 值結果，尤其是在變數較多的資料層級，Tomek Link 的 AUC 值普遍皆高於 SOMTE，但兩者差距依然不大。

表 4.4-9 SMOTE 與 Tomek Link 之 AUC 值比較

資料層級	無處理	SMOTE 後	Tomek Link 後
I	0.6850	0.6987	0.6755
II	0.7633	0.7647	0.763
III 分心	0.802	0.800	0.8044
III 動作	0.7770	0.7808	0.7761
III 影像	0.7557	0.7615	0.7573
III	0.8074	0.8003	0.8067
IV 分心	0.7991	0.7818	0.7926
IV 動作	0.7753	0.7684	0.7700
IV 影像	0.7618	0.7538	0.7658
IV	0.8080	0.7982	0.8064

最後，由於縱向警示與橫向警示發生的主要原因與變數可能有極大的差異，因此本計畫最後將警示類別區分為橫向警示與縱向警示，並使用隨機森林之機器學習方法分別建構預測模式，目的為了解分別建構之模式是否能各自有更好的分類能力。

首先在縱向警示的部分，主要有高速前車碰撞 (FCWH)、低速前車碰撞 (FCWL)、未保安全距離 0.4 (SDW_0.4) 與未保安全距離 1.2 (SDW_1.2)，共包含 2,524 筆中的 2,083 筆，本計畫以 10-fold 的交叉驗證方式進行模式

的建構。在縱向警示樣本的分類結果中，所有資料層級之測試樣本的 Recall 值在 SMOTE 方法中均在 0.29 以上，甚至多個資料層級達到 0.5。由於縱向警示的行車異常事件比例約為 0.252，因此分類結果之 Recall 值也顯示，利用機器學習方法的結果比隨機分類更具有預測能力。另外，從 Recall 值的大小分布進一步觀察，SMOTE 與 Tomek Link 的 Recall 值均大於無任何處理時之指標，且 SMOTE 又表現得較 Tomek Link 佳。最後，縱向警示 Recall 值大於全部警示納入之 Recall 的資料層級包含 I、III 分心、III 影像、IV 分心、IV 動作及 IV 影像，代表在縱向警示中，區分樣本確實有助於模式整體的績效提升。

而橫向警示主要包含向左車道偏移 (LDWL)、向右車道偏移 (LDWR) 及嚴重車道偏移 (SLDW)，共包含 2,524 筆中的 441 筆。由於筆數不多，因此以 5-fold 的交叉驗證方式進行模式的呈現。然而，從分類結果觀察，橫向警示的 Recall 值均較低，若以橫向警示之行車異常事件比例為 0.141 來看，許多資料層級測試樣本的 Recall 值均低於該值，代表本計畫所選用之變數，較不足以成功地預測橫向警示。因此，本計畫認為，使用機器學習方法雖然能有效地預測行車異常事件與非行車異常事件，但若將異常分為橫向與縱向，則目前所擁有的變數較難以精準預測橫向警示，故未來若能獲得較能預測橫向警示發生的變數，那麼應可以使橫向警示的預測能力提升。

4.5 小結

4.5.1 高風險駕駛行為及風險評估

本計畫於 4.2 及 4.3 節，將警示事件分為縱向及橫向警示，並將各項警示再更細分為不同情境，分述如下：

(一)縱向警示：包含前方車距警示 (SDW 0.4)、前方碰撞警示 (FCWH)

1. 本車變換車道；
2. 前車變換車道。

(二)橫向警示：包含車道偏離警示 (LDW)、嚴重車道偏離警示 (SLDW)

1. 本車行駛於國道全線 (含匝道)；
2. 本車行駛於國道主線。

根據 4.2 節之分析結果，本計畫得知若於縱向警示下且本車變換車道時，高風險駕駛行為將會與加速度、車趟時間、車距、駕駛員年資、駕駛員分心行為 (雙手離開方向盤、操作與安全無關設備、手靠近嘴巴) 等行為有關；若為前車變換車道時，高風險駕駛行為則會與加速度、車距、駕駛員分心行為 (右手及雙手離開方向盤) 等有關。根據前述可知，縱向警示的發生主要與本車行駛時的加速度、與前車車距以及駕駛員分心行為有極大相關。

橫向警示部分，若在警示當下本車行駛於國道全線 (含匝道) 時，高風險駕駛行為會與車距及駕駛員分心行為 (雙手離開方向盤、拿東西及用手機) 等行為有關；若橫向警示當下行駛於國道主線時，高風險駕駛行為則會與行使距到全線段相同，本計畫推斷因研究對象客運公司為台南至台北直達，行使匝道機會相對較少，故模式校估結果會趨近相同。

4.3 節則是針對上述高風險駕駛行為類別化，並將找出各模式之中的風險轉變點與高風險駕駛行為的關係，如縱向警示下本車變換車道時，若駕駛員將雙手離開方向盤，則整體風險將由低風險轉變為高風險，此時便是客運業者須多加注意之處，同時，中風險轉變為高風險時的駕駛行為，亦是亟須關注之處，須由客運業者主動提醒駕駛，以減少此類高顯行為之發生。本計畫利用 4.2 節的最佳模式，放入提升迴歸數模式 (Boosted Regression Tree, BRT) 列出各個連續變數的風險異常提高處，並使用最顯著的範圍將變數類別化。本計畫更定義 Risk 及高風險比例，前者針對各高風險駕駛行為的組合所造成之風險定義低、中、高風險範圍；後者則利用高風險比例計算單一變數在高風險範圍出現的次數多寡，以釐清該變數的風險程度。

針對不同情境將會對應不同行為組合，值得注意的是，即使是橫向警示下本車行駛國道全線或主線段時，雖高風險模式有相似的高風險駕駛行為，但在風險評估模式下，仍有部分差異存在，如行駛國道主線段

時，會因為行駛路段(里程)導致行車異常事件的機率提高，但在行駛國道全線時卻無此變數；行駛國道全線段時則會與駕駛年資有關，行駛主線段則否。本研究推測此結果與發生之路段形態差異有關，而國道里程介於 0 至 100K 為北部路段，更是國道 1 號的易雍塞路段，自然對於行車異常事件的發生有較大的影響；駕駛員年資亦會影響到警示下的處理方式，模式顯示若加入匝道路段則與年資有顯著關係，說明年資及駕駛經驗對於行車異常事件的應對有極大的關聯，而匝道路段更是需要有豐富的經驗方可完善處理。

至於縱向警示部分，本車變換車道與前車變換車道的高風險駕駛行為皆與車距、年資、駕駛員行為有關外，本計畫將變數類別化後發現，變數門檻及駕駛員分心項目部分亦有差異產生。如本車變換車道時，駕駛員年資在 3 年以下才會提高駕駛風險，前車變換車道則增加到 10 年以下即會提高駕駛風險；本車變換車道與周圍是否有大車有關，然前車變換車道的駕駛風險則與駕駛員是否注意前車動態有關。

根據上述結果，模式說明在不同的車輛動態下，即便是相同的警示事件，在不同的情境下亦會對應到不同的高風險駕駛行為，可使客運業者及時介入進行駕駛員行為管理，及建立風險管控措施。表 4.5-1 為本計畫針對業者的不同管理方式將業者分為 I 至 IV 類，並由 4.3 節分析得到之高風險駕駛行為及門檻，對應到各情境下的高風險駕駛行為，客運業者可依照下表尋找對應管理項目。

表 4.5-1 不同情境下各類管理方式對應可管理項目

情境	對應可管理項目	資料來源
第 I 類管理方式		
縱向警示：本車變換車道	平均車速介於 80~90 公里/小時 最大加速度 ≥ 2.5 公尺/秒 ² 駕駛時間為夜晚時 駕駛年資 < 3 年	OBD
縱向警示：前車變換車道	最大加速度 ≥ 1.5 公尺/秒 ² 駕駛年資 < 10 年	
橫向警示：本車行駛國道全線段(含匝道)	駕駛年資少於 6 年	
橫向警示：本車行駛國道主線段	本車行駛於國道里程 0 至 100 公里之主線段時	

表 4.5-1 不同情境下各類管理方式對應可管理項目 (續)

情境	對應可管理項目	資料來源
第 II 類管理方式		
縱向警示：本車變換車道	第 I 類以及： 警示前後 3 秒，與前車之秒距少於 0.3 秒之秒距與時間積分 ≥ 0.7 秒 ² 警示前 3 秒，與前車之車距範圍介於 13~26 公尺	OBD ADAS
縱向警示：前車變換車道	第 I 類以及： 與前車秒距少於 0.6 秒之持續時間 ≥ 4 秒 最小車距少於 4 公尺	
橫向警示：本車行駛國道全線段(含匝道)	第 I 類以及： 與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒 ²	
橫向警示：本車行駛國道主線段	第 I 類以及： 與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒 ²	
第 III 類管理方式		
縱向警示：本車變換車道	第 II 類以及： 駕駛員雙手離開方向盤 駕駛員操作與安全無關之設備	OBD ADAS DMS
縱向警示：前車變換車道	第 II 類以及： 駕駛員雙手離開方向盤 駕駛員右手離開方向盤 駕駛員未於前車變換車道時擺頭	
橫向警示：本車行駛國道全線段(含匝道)	第 II 類以及： 駕駛員雙手離開方向盤 駕駛員用手拿取物品 駕駛員使用手機	
橫向警示：本車行駛國道主線段	第 II 類以及： 駕駛員雙手離開方向盤 駕駛員用手拿取物品 駕駛員使用手機	
第 IV 類管理方式		
縱向警示：本車變換車道	第 III 類以及： 周圍有大車。	OBD ADAS DMS 車外環境資料應用
縱向警示：前車變換車道	與第 III 類相同	
橫向警示：本車行駛國道全線段(含匝道)	與第 III 類相同	
橫向警示：本車行駛國道主線段	與第 III 類相同	

值得注意的是，本計畫對於第 IV 類管理方式可納入之外部環境相關變數，僅「周圍有大車」在縱向警示事件：本車變換車道，校估結果能顯著增加行車異常事件發生機率，本計畫推測，其原因為本車周圍有大型車輛且本車正變換車道時，可能造成駕駛員無法及時應對週遭其前方車輛狀況，除導致縱向警示發生外更易造成行車異常事件。然而，其他情境下第 IV 類管理方式與第 III 類管理方式可辨識項目並無不同。

表 4.5-2 為各情境下需關注項目，其定義為 4.3 節中由低風險轉變為中風險、或由中風險轉變為高風險的駕駛行為。其中，較值得注意的是，表列所有項目皆至少需利用 ADAS 系統資料方能完成辨識，因此，若客運業者希望管控更完整的高風險駕駛行為，則須至少導入 ADAS 系統，並利用系統資料建立駕駛員管理機制。

表 4.5-2 各情境下需關注項目

情境	需關注項目
縱向警示： 本車變換車道	低風險轉中風險： 雙手離開方向盤 中風險轉高風險： 警示前 3 秒之車距範圍介於 12~26 公尺
縱向警示： 前車變換車道	低風險轉中風險： 雙手離開方向盤 中風險轉高風險： 未於前車變換車道時擺頭
橫向警示： 本車行駛國道全線段(含匝道)	低風險轉中風險： 拿東西 中風險轉高風險： 雙手離開方向盤
橫向警示： 本車行駛國道主線段	低風險轉中風險： 拿東西 中風險轉高風險： 雙手離開方向盤

以目前本計畫可得到之變數項目，可以發現除縱向警示：本車變換車道發生時，第 IV 類管理方式能新增環境相關變數外，其他三種情境皆不顯著，除說明本計畫變數可能可再視情況增加外，可能亦說明在大部分警示事件及行車異常事件下，第 III 類管理方式之管理強度已足夠辨識

高風險駕駛行為，客運業者僅需依據相關門檻進行駕駛員訓練及管理即可降低行車異常事件的發生機率。

4.5.2 混合方法與機器學習之比較

本計畫比較混合方法(計量模型)、隨機森林與 XGBoost 的分析結果，表 4.5-1 為計量方法、隨機森林與 XGBoost 的 AUC 值比較。本計畫發現在機器學習的比較中，無論資料層級，AUC 值均為隨機森林較高。其可能原因為 XGBoost 可能有較嚴重過度配適之問題，可能原因為樣本數不足、樣本涵蓋的多樣性不足及樣本之變數類別的不平衡所導致，使在測試樣本中，AUC 值表現不如預期之結果。然而，若以績效指標討論兩種機器學習方法在測試樣本分類的結果，我們卻發現 XGBoost 的表現優於隨機森林。上述之指標呈現的落差，可能來自於操作機器學習的過程。由於本計畫挑選隨機森林與 XGBoost 之參數設定時，是根據 Accuracy 與 Recall 值，而非 AUC 值的大小，且 Recall 值代表真實為行車異常事件之樣本，被判定為行車異常事件的機率，因此其數值高低更加重要。故可能在操作過程中，才會出現績效指標與 AUC 值在不同機器學習方法上的落差。綜上所述，本計畫所使用的兩種方法，以不同指標來看，其模式績效則會出現相異之結果。

此外，從表 4.5-3 也可以發現，其實隨機森林與混合模型之 AUC 值差異不大，證明在本計畫中的資料庫分析，混合模型之分析結果並不比機器學習的方法差，且混合模型可以觀察自變數與應變數間的影響方向與影響大小關係，甚至可以發展較為複雜的模式，如變數間的交互效果項等。

表 4.5-3 混合模型、隨機森林與 XGBoost 之平均 AUC 值

	隨機森林	XGBoost	混合模型
I	0.6566	0.6066	0.636
II	0.7461	0.7052	0.738
III 人工	0.7443	0.7415	0.739
III 分心	0.7808	0.7632	0.786

表 4.5-3 混合模型、隨機森林與 XGBoost 之平均 AUC 值 (續)

	隨機森林	XGBoost	混合模型
I	0.6566	0.6066	0.636
II	0.7461	0.7052	0.738
III 人工	0.7443	0.7415	0.739
III 分心	0.7808	0.7632	0.786

最後，本計畫將混合模型與隨機森林的 Recall 值進行比較，發現混合模型的 Recall 值在縱向警示時較低，但在橫向警示時則較高。在縱向警示中，混合模型分為本車變換車道與前車變換車道，而 Recall 值分別為 30% 與 31%，對比隨機森林之 50% 左右，為隨機森林的表現較佳。然而，若為橫向警示，混合模型分為行駛國道主線與行駛國道全線，而 Recall 值分別為 30% 與 25%，對比隨機森林之 15-20%，混合模型明顯地優於隨機森林。因此，同樣地，若考慮整體結果，機器學習與以計量方法為主的混合模型，在績效指標上仍差異不大，且在混合模型可以獲得更多資訊下，本計畫仍以混合模型為主要的發展架構。

第五章 特定警示之高風險駕駛行為分析：前車碰撞與橫向偏移

5.1 資料與分析流程

本期計畫新增 2023 年 5 月之資料做為後續分析驗證之用，共 15 台車輛、43 位駕駛員、383 趟次之 ADAS 警示事件資料，其中因前期發現高速前車碰撞 (FCWH)、嚴重車道偏移 (SLDW) 等 2 種警示事件與高風險駕駛行為較為相關，故將此 2 種警示事件獨立出來分析。以下為前 2 期計畫與本期所用之 FCWH、SLDW 警示之基本特性敘述性統計，如表 5.1-1 所示，因本期蒐集之樣本趟次數多於前期，故 FCWH、SLDW 警示事件數皆多於前 2 期。

而在分心事件中發生 FCWH、SLDW 警示事件的各類動作列表如表 5.1-2 所示，3 期統計中以單手離開方向盤為多數，操作車內設備為少數。

表 5.1-1 三期 FCWH、SLDW 警示事件類別統計

警示事件種類/ 三期樣本件數	高速前車碰撞 FCWH	嚴重車道偏移 SLDW	總計
第一期樣本警示件數	90	61	151
第二期樣本警示件數	65	24	89
本期樣本警示件數	375	113	488

表 5.1-2 三期 FCWH、SLDW 警示當下之分心事件中各動作類別統計

FCWH、SLDW 次數/ 動作類別	第一期	第二期	本期
雙手離開方向盤	10	1	4
單手離開方向盤	7	15	36
軀幹移動	3	1	26
擺頭	0	1	5
操作車內設備	6	0	3
拿東西	1	7	14
用手機	1	0	8
手靠近嘴巴(飲食或抽菸)	0	6	5
總計	28	31	101

5.1.1 風險評估模式及模式驗證資料

本期計畫使用前期取得之警示事件發展高風險評估模式，警示事件包含：未保持安全距離警示，與前方車輛秒距小於 0.4 秒 (SDW 0.4)、高速前方碰撞警示 (FCWH)、車道偏移警示 (LDW)、嚴重車道偏移警示 (SLDW)，前二者為縱向警示事件，共 1,397 筆；後二者為橫向警示事件，共 441 筆，如表 4.1-1 所示。

本期因影像辨識作業不及之故，與人工標示資料合併後共新增 112 筆，分別為縱向警示 57 筆、橫向警示事件 55 筆，分布如表 5.1.3 所示。

表 5.1-3 用以模式驗證之本期新增行車異常事件數量統計

	縱向警示	橫向警示
	FCWH	SLDW
不是異常	17 (29.8)	22 (40%)
異常	40 (70.2%)	33 (60%)
合計	57	55

5.1.2 警示鏈分析資料

本計畫使用人工標示之車內分心行為真值，併入前期之 2,558 個警示事件中，建立警示鏈分析資料庫，新增 414 筆警示資料後，共 2,978 筆資料，其中新增 FCWH 共 339 筆、SLDW 共 75 筆，分心行為類別統計如下表 5.1-4。值得注意的是，因警示當下及警示後 10 秒之分心行為常以組合形式出現，故各項分心行為之加總將大於資料總數，如警示當下之分心行為加總為 3,892 項；警示後 10 秒之分心行為共 4,606 項。

表 5.1-4 用於警示鏈分析之各分心行為類別統計

分心行為類別	警示當下		警示後 10 秒	
	次數	百分比	次數	百分比
正常駕駛	905	23.25%	666	14.46%
單手離開方向盤	1,634	41.98%	1,952	42.38%
擺頭	349	8.97%	783	17.00%
軀幹移動(身體前傾)	265	6.81%	238	5.17%
雙手離開方向盤	168	4.32%	207	4.49%
手靠近嘴巴	159	4.09%	280	6.08%

表 5.1-4 用於警示鏈分析之各分心行為類別統計 (續)

分心行為類別	警示當下		警示後 10 秒	
	次數	百分比	次數	百分比
操作車內設備：撥桿	248	6.37%	273	5.93%
操作車內設備	59	1.52%	74	1.61%
拿東西	73	1.88%	107	2.32%
用手機(手持)	21	0.54%	16	0.35%
軀幹移動(身體右傾)	11	0.28%	10	0.22%
總計	3,892	100%	4,606	100%

註：一個警示事件樣本可能包含多於一個動作，因此動作頻次總和會大於總事件數 2,972。

5.2 分析結果

5.2.1 警示事件風險評估模式驗證

本小節將本期計畫取得新資料放入 4.3 節之各警示事件風險評估模式，用以計算各警示事件下為行車異常事件之機率(縱軸)，並與人工觀看行車紀錄影像後標示之真值(橫軸)做為比較，其中，本節使用之風險評估模式係因應離型系統建立，僅針對縱向及橫向警示作風險評估，並未針對各警示下的情境(如變換車道、行駛主線等)加以分類，換言之，本節將就 4.3.1 及 4.3.2 節之縱向風險評估模式合併；4.3.3 及 4.3.4 節之橫向風險評估模式合併，進行模式驗證並繪製盒鬚圖如下圖 5.2-1 及圖 5.2-2 所示。

圖 5.2-1 為縱向警示下之行車異常事件機率與人工標示真值之盒鬚圖，本期計畫新增資料共 58 筆警示事件，皆為 FCWH，透過下圖可以明確看見人工標示為可能異常或行車異常事件之機率，其中位數及 75 百分位數皆大於不是異常之事件，雖有部分離群值出現，但整體機率依然高於不是異常之事件，本計畫選定以機率值 0.39 為切分點，此時將有 75%之可能異常或行車異常事件之機率值高於 0.39，意即，預測機率大於 0.39 則有較高機率為可能異常或異常，故本計畫認定若縱向警示事件之風險評估機率值大於 0.39，則可視為行車異常事件。

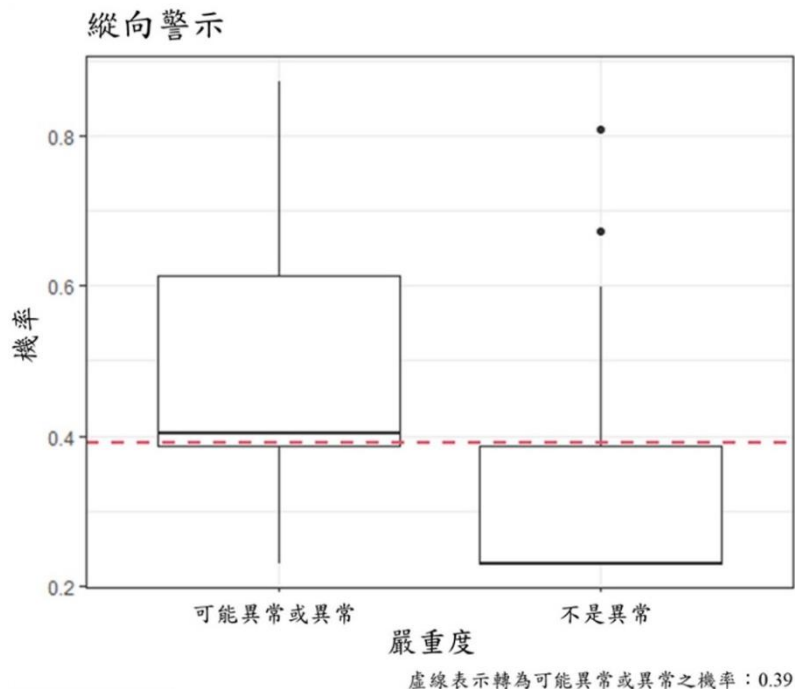
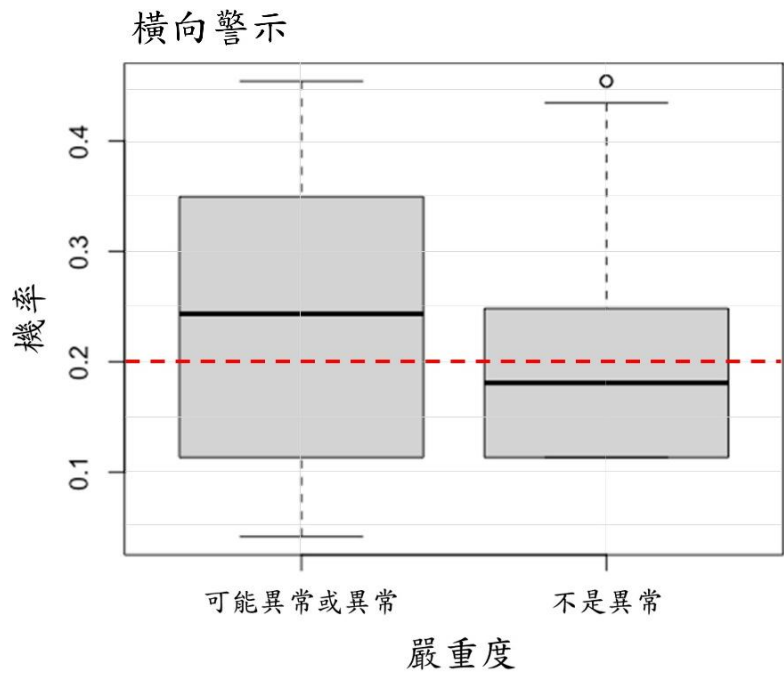


圖 5.2-1 行車異常事件機率及真值盒鬚圖 (縱向警示)

圖 5.2-2 為橫向警示下之行車異常事件機率與人工標示真值之盒鬚圖，本期計畫共新增 21 筆警示事件，皆為 SLDW。雖行車異常事件機率之 25 百分位數幾乎相同，且有部分離群值出現，然被標示為可能異常或異常之事件的中位數及 75 百分位數依然高於不是異常之機率，本計畫使用機率預測值 0.2 為切分點，此時約有 60% 的可能異常或行車異常事件之機率落於 0.2 之上，且約 60% 的不是行車異常事件落於 0.2 之下，意即，預測機率大於 0.2 時，有較高的機率為可能異常或異常，故本計畫認定若橫向警示事件之風險評估機率值大於 0.2 時，可視為行車異常事件。



虛線表示轉為可能異常或異常之機率：0.2

圖 5.2-2 行車異常事件機率及真值盒鬚圖 (橫向警示)

5.2.2 警示鏈分析

考量不同行車動態下之警示發生原因可能不同，本計畫依前車變換車道、本車變換車道以及本車車道偏移三種行車動態類別分別進行警示鏈分析，序列規則分析結果綜整如表 5.2-1、表 5.2-3 及表 5.2-5，各規則依提升度由大至小排序，並列出至提升度變化處；前期之序列規則整理如表 5.2-2、表 5.2-4 及表 5.2-6。

根據下表之整理，不論是前車變換車道、本車變換車道或本車車道偏移，各規則之支持度小於 0.01，說明各規則在各項情境下之出現頻率皆不高；信賴度皆接近 1，表示一旦出現表格中所列之「警示當下分心行為 ➔ 警示類別 ➔ 警示後 10 秒分心行為³」行為規則，則此警示事件便高度可能發展為行車異常事件。另，各規則的提升度約介於 1 至 7 之間，則代表此分心行為規則成為可能異常或異常之機率，約為對應之事件總體發生次數的 1 至 7 倍。

³ 為警示結束後的 10 秒，本計畫藉此分析駕駛員於警示的緩解作為。

表 5.2-1 警示當下分心行為、發生警示類別、警示後 10 秒分心行為序列法則：前車變換車道 (本期)

編號	警示當下	警示類別	警示後 10 秒	支持度	信賴度	提升度
1	身體前傾 操作車內設備 擺頭	FCWH	身體前傾 操作車內設備 擺頭	0.0016	1.0000	3.3784
2	身體前傾 單手離開方向盤 擺頭	FCWH	身體前傾 操作車內設備 擺頭	0.0016	1.0000	3.3784
3	操作車內設備：撥桿	FCWH	(正常駕駛)	0.0016	1.0000	3.3784
4	手靠近嘴巴	FCWH	手靠近嘴巴	0.0016	1.0000	3.3784
5	單手離開方向盤	FCWH	身體前傾 操作車內設備：撥桿 擺頭	0.0048	1.0000	3.3784
6	單手離開方向盤	FCWH	單手離開方向盤 手靠近嘴巴	0.0032	1.0000	3.3784
7	單手離開方向盤 擺頭	FCWH	身體前傾 操作車內設備 擺頭	0.0016	1.0000	3.3784
8	擺頭	FCWH	身體前傾 單手離開方向盤	0.0032	1.0000	1.6578
9	(正常駕駛)	FCWH	身體前傾 操作車內設備：撥桿 擺頭	0.0016	1.0000	3.3784
10	(正常駕駛)	FCWH	操作車內設備：撥桿 擺頭	0.0016	1.0000	3.3784
11	(正常駕駛)	FCWH	手靠近嘴巴	0.0016	1.0000	3.3784

表 5.2-2 警示當下分心行為、發生警示類別、警示後 10 秒分心行為序列法則：前車變換車道 (前期)

編號	警示當下	警示類別	警示後 10 秒	支持度	信賴度	提升度
1	手靠近嘴巴	FCWH	(正常駕駛)	0.0051	1.0000	3.7261
2	單手離開方向盤	FCWH	(正常駕駛)	0.0085	1.0000	3.7261
3	操作車內設備：撥桿	FCWH	(正常駕駛)	0.0017	1.0000	3.7261
4	(正常駕駛)	FCWH	手靠近嘴巴	0.0154	1.0000	3.7261
5	(正常駕駛)	FCWH	身體前傾	0.0017	1.0000	3.7261
6	(正常駕駛)	FCWH	操作車內設備：撥桿	0.0017	1.0000	3.7261
7	(正常駕駛)	FCWH	擺頭	0.0051	1.0000	3.7261
8	(正常駕駛)	FCWH	(正常駕駛)	0.0239	0.8235	3.0686

表 5.2-3 警示當下分心行為、發生警示類別、警示後 10 秒分心行為序列法則：本車變換車道(本期)

編號	警示當下		警示類別	警示後 10 秒		支持度	信賴度	提升度
1	身體前傾	操作車內設備	FCWH	單手離開方向盤	擺頭	0.0014	1.0000	3.3839
2	身體前傾	操作車內設備	FCWH	身體前傾	操作車內設備	0.0014	1.0000	3.3839
3	身體前傾	操作車內設備	FCWH	身體前傾	操作車內設備	0.0014	1.0000	3.3839
4	操作車內設備		FCWH	單手離開方向盤		0.0084	0.8571	2.9005
5	擺頭		FCWH	操作車內設備：撥桿		0.0014	1.0000	3.3839
6	(正常駕駛)		FCWH	身體前傾	單手離開方向盤	0.0014	1.0000	3.3839
7	(正常駕駛)		FCWH	雙手離開方向盤	擺頭	0.0014	1.0000	3.3839
8	(正常駕駛)		FCWH	手靠近嘴巴		0.0014	1.0000	3.3839

表 5.2-4 警示當下分心行為、發生警示類別、警示後 10 秒分心行為序列法則：本車變換車道(前期)

編號	警示當下		警示類別	警示後 10 秒		支持度	信賴度	提升度
1	擺頭		FCWH	操作車內設備		0.0015	1.0000	3.5912
2	(正常駕駛)		FCWH	手靠近嘴巴		0.0015	1.0000	3.5912

表 5.2-5 警示當下分心行為、發生警示類別、警示後 10 秒分心行為及導致事件異常程度序列法則：本車車道偏移(本期)

編號	警示當下				警示類別	警示後 10 秒	支持度	信賴度	提升度
1	拿東西	雙手離開方向盤	身體前傾	身體右傾	手靠近嘴巴	擺頭	SLDW (正常駕駛)	0.0019	1.0000
2	拿東西	雙手離開方向盤	身體前傾	身體前傾	手靠近嘴巴	擺頭	SLDW (正常駕駛)	0.0019	1.0000
3	拿東西	雙手離開方向盤	身體前傾	身體前傾			SLDW (正常駕駛)	0.0019	1.0000
4	拿東西	雙手離開方向盤	身體右傾	身體右傾	手靠近嘴巴	擺頭	SLDW (正常駕駛)	0.0019	1.0000
5	拿東西	雙手離開方向盤	身體右傾	身體右傾			SLDW (正常駕駛)	0.0019	1.0000

表 5.2-5 警示當下分心行為、發生警示類別、警示後 10 秒分心行為及導致事件異常程度序列法則：本車車道偏移(本期)(續)

編號	警示當下		警示類別		警示後 10 秒	支持度	信賴度	提升度
6	拿東西	雙手離開方向盤	手靠近嘴巴	擺頭	SLDW (正常駕駛)	0.0019	1.0000	3.7899
7	拿東西	身體前傾	身體右傾	手靠近嘴巴	SLDW (正常駕駛)	0.0019	1.0000	3.7899
8	拿東西	身體前傾	身體右傾	擺頭	SLDW (正常駕駛)	0.0019	1.0000	3.7899
9	拿東西	身體前傾	身體右傾		SLDW (正常駕駛)	0.0019	1.0000	3.7899
10	拿東西	身體前傾	手靠近嘴巴	擺頭	SLDW (正常駕駛)	0.0019	1.0000	3.7899
11	拿東西	身體右傾	手靠近嘴巴	擺頭	SLDW (正常駕駛)	0.0019	1.0000	3.7899
12	拿東西	手靠近嘴巴	擺頭		SLDW (正常駕駛)	0.0019	1.0000	3.7899
13	拿東西	手靠近嘴巴			SLDW 單手離開方向盤	0.0038	1.0000	1.4097

表 5.2-6 警示當下分心行為、發生警示類別、警示後 10 秒分心行為序列法則：本車車道偏移(前期)

編號	警示當下		警示類別		警示後 10 秒	支持度	信賴度	提升度
1	身體前傾	雙手離開方向盤	SLDW	(正常駕駛)	SLDW	0.0066	1.0000	7.2903
2	身體前傾		SLDW	擺頭	SLDW	0.0022	1.0000	7.2903
3	擺頭	拿東西	SLDW	擺頭	SLDW	0.0022	1.0000	7.2903
4	雙手離開方向盤	擺頭	SLDW	雙手離開方向盤	SLDW	0.0022	1.0000	7.2903
5	雙手離開方向盤	拿東西	SLDW	擺頭	SLDW	0.0022	1.0000	7.2903
6	雙手離開方向盤	拿東西	SLDW	雙手離開方向盤	SLDW	0.0022	1.0000	7.2903
7	(正常駕駛)		SLDW	手靠近嘴巴	雙手離開方向盤	0.0022	1.0000	7.2903

另比較前期序列規則，加入本期新增之 FCWH 警示事件後，「縱向警示：本車變換車道」之行為組合同樣與手靠近嘴巴、單手離開方向盤或操作撥桿有關，而警示前擺頭、警示後單手離開方向盤等行為組合，亦可能使警示事件發展為行車異常事件；「縱向警示：本車變換車道」之行為組合皆與身體前傾有關，且行為組合中亦與單手離開方向盤或操作車內設備有關，說明若於警示當下駕駛出現身體前傾、單手離開方向盤或操作車內設備時，警示事件容易進一步發展為行車異常事件，然與前期則與擺頭較有相關；警示後 10 秒之行為組合也較前期更為複雜，多與身體前傾、單手離開方向盤或操作車內設備及擺頭有關，與前期存有差異。

針對本期計畫新增之 SLDW 警示事件，「橫向警示：本車車道偏移」中序列規則新增身體右傾、手靠近嘴巴或單手離開方向盤，值得注意的是，警示當下行為規則皆與拿東西有關，顯示若駕駛在警示當下有拿東西的行為，則易發展為行車異常事件；警示後則僅 1 項規則與單手離開方向盤之行為有關，說明 SLDW 警示是否發展為行車異常事件，將與警示當下駕駛員的行為較有關係，此結果也與前期之序列規則較為不同。

5.3 小結

5.2.1 節之模式驗證係使用針對雛型系統設計之風險評估模式，以驗證該模式是否能正確應用於預測警示事件發展為可能異常或行車異常事件，模式僅針對縱向警示及橫向警示設計，未針對本計畫第四章細分之情境，且因為本次新增之 FCWH 及 SLDW 警示事件可用於分析之數量分別僅 57 及 55 件，故本計畫分別將縱向及橫向警示之各情境合併後放入模式進行分析。

本計畫透過盒鬚圖之資料分布，比對人工標示之異常程度為「不是異常」或「可能異常或異常」之機率預測值之分布後，將機率預測值大於「不是異常」之 75 百分位數之值設為切分點：縱向警示 (FCWH) 為 0.39；橫向警示 (SLDW) 為 0.25，後續管理時將可透過機率預測值之切分點，將大於此值之事件視為行車異常事件；反之則為不是異常之事件。

5.2.2 警示鏈分析主要針對本期新增之 FCWH 及 SLDW 兩種警示，可看出序列規則與前期分析結果的不同之處，尤以警示當下之行為組合改

變最多，可看出無論是何種警示或情境，皆較前期增加許多行為，組合也更為複雜。另外，透過上述序列規則可發現，縱向警示 (FCWH) 若發展為行車異常事件，多與警示後的行為有關，若駕駛員在警示發生後未及時針對警示做出反應，仍有其他手部分心行為 (手靠近嘴巴、操作車內設備等)，將可能使警示之狀況未能及時消除，進而發展為行車異常事件；橫向警示 (SLDW) 相關之事件則多與警示當下之動作有關，且每一項列出之序列規則皆有「拿東西」的行為，亦說明駕駛員在警示發生當下通常正在分心做其他與駕駛無關之事，此外，列出的 13 項規則中，有 6 項與雙手離開方向盤有關，此亦解釋車輛行駛之不穩定狀況，及為何駕駛無法及時針對車道偏移做出緩解措施，屬風險相對較高之警示事件。

第六章 行車影像辨識技術與解析

本期研究持續以深度學習技術為基礎，導入新型物件偵測模型，發展車外、車內影像辨識與駕駛行為分析研究。在車外影像辨識部分，比較並分析新型模型的辨識效果改善，新型模型包含 YOLOv7 與 YOLOv8，同時也針對偵測不穩定的事件進行情境分析和模型測試比較。在車內影像辨識部分，比較並分析新型模型的辨識效果改善，新型模型包含 YOLOv7、YOLOv8、ViTPose。以下章節將說明駕駛者關節點偵測穩定性的評估與比較，並針對偵測不穩定的事件進行分析與歸納影響因素。

6.1 車外模型比較及改善

6.1.1 Scaled YOLOv4

Scaled YOLOv4 是基於 YOLOv4 的一個延伸演算法，它的目標是在保持物件偵測偵測性能的同時，提高模型的計算效率和速度。Scaled YOLOv4 通過在 YOLOv4 的基礎上進行一系列簡化和優化來實現這一目標。

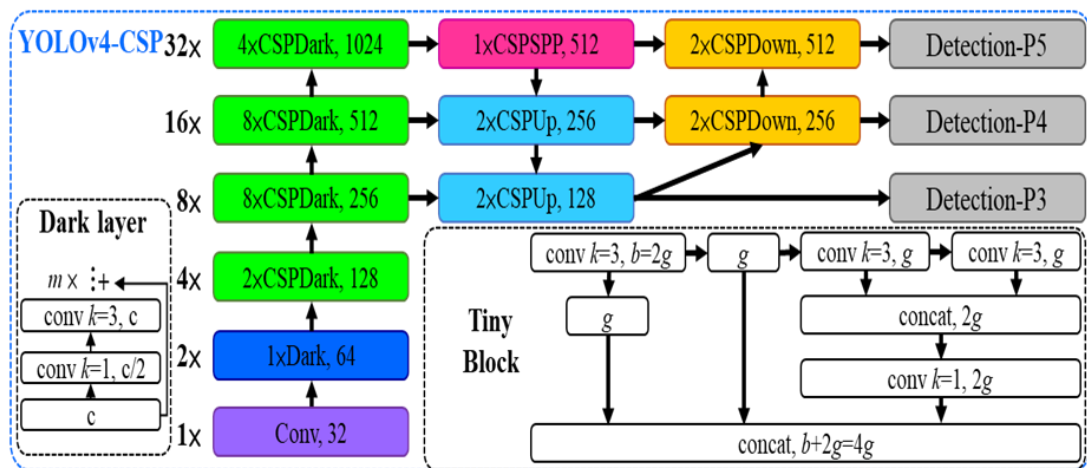


圖 6.1-1 Scaled YOLOv4 架構圖

以下是 Scaled YOLOv4 的一些特點和優化：

- (一)網路結構精簡：Scaled YOLOv4 精簡了 YOLOv4 的網路結構，減少了網路的深度和參數數量。這有助於減少計算量，提高模型的速度和效率。

(二)小尺寸輸入影像：Scaled YOLOv4 將輸入影像的尺寸縮小，通常在 416×416 或 320×320 的範圍內。這樣可以進一步減少計算量，同時在一定程度上犧牲一些偵測偵測的細節。

(三)特徵金字塔簡化：Scaled YOLOv4 簡化了特徵金字塔網路 (FPN) 的結構。它可能減少了特徵金字塔的層數或減少了每個層的特徵通道數量。這樣可以減少特徵的維度，降低計算負擔，同時保持對不同尺度目標的偵測偵測能力。

(四)更小的偵測偵測模型輸出：Scaled YOLOv4 通常減少了偵測偵測輸出的維度。這意味著模型可能只偵測偵測特定尺度或特定數量的目標。這樣可以進一步降低計算量，同時可能導致在某些情況下偵測能力的降低。

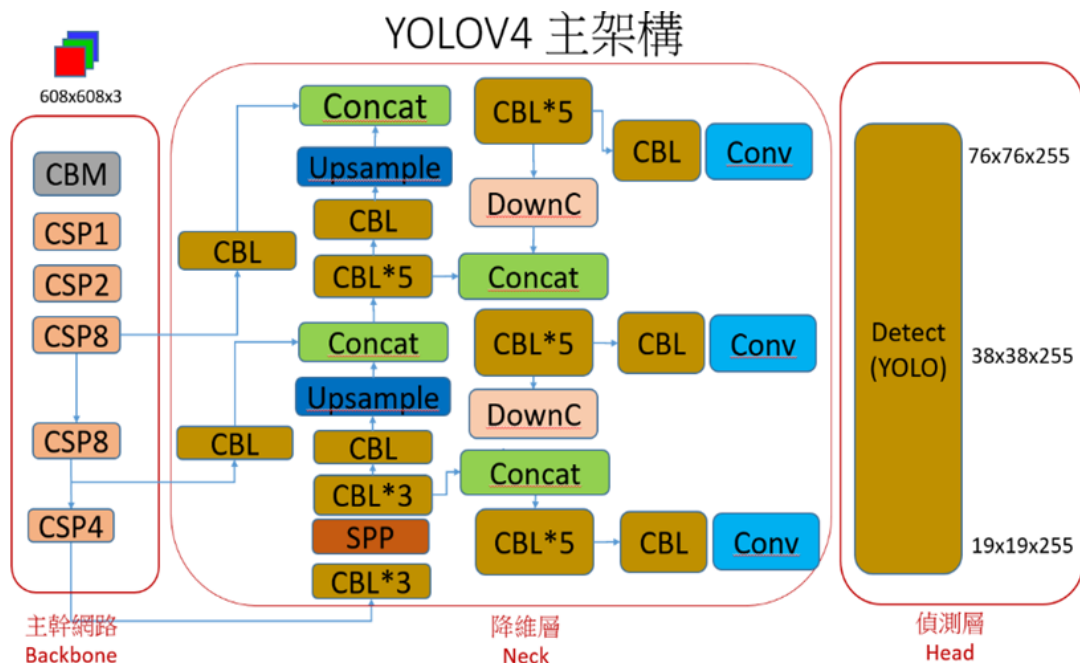


圖 6.1-2 YOLOv4 架構圖

以下是 YOLOv4 的網路架構的概述：

(一)主幹網路 (Backbone)：

CSPNet (Cross Stage Partial Network) 是一個用於深度學習模型的主幹網路結構，它在 YOLOv4 中被引入。它的設計旨在提高模型的計算效率和性能，並有效地處理目標偵測任務。

以下是 CSPNet 的結構和特性：

1. 跨層部分連接 (Cross Stage Partial Connections)：CSPNet 通過在不同層次之間引入部分連接，以達到更好的特徵傳遞和重用。具體來說，CSPNet 將主幹網路分為兩個部分：前部分和後部分。前部分負責進行特徵萃取，而後部分則對萃取的特徵進行處理和編碼。這兩個部分之間的部分連接允許特徵在不同層次之間流通，從而提高特徵的表達能力。
2. 低維度特徵傳遞：CSPNet 使用 1×1 卷積層將高維度特徵映射到低維度特徵。這樣可以減少計算量並加速特徵傳遞。然後，將低維度特徵用於後續的處理，如偵測和分類。
3. 特徵金字塔網路 (Feature Pyramid Network)：CSPNet 引入了特徵金字塔網路，用於多尺度特徵的萃取。這是通過在不同層所構建和融合特徵金字塔來實現的。特徵金字塔網路能夠有效地處理不同尺度的目標，提高模型對不同大小目標的偵測能力。
4. 加重特徵的編碼：CSPNet 使用額外的卷積層和殘差連接來進一步編碼特徵。這些操作有助於改進特徵的表示能力，使模型更好地理解圖像中的目標特徵。

(二)降維層 (Neck)：

CSPPANet with Mish activation 是一種結合了 CSPPANet 結構和 Mish 激勵函數的變體，旨在進一步提高目標偵測模型的性能。

1. CSPPANet 結構：CSPPANet 是一種結合了 CSPNet 和 PANet 的網路結構。CSPNet 通過部分連接的方式在不同層級之間進行訊息的傳遞和融合，從而提高特徵的表示能力。PANet 則用於進一步整合多尺度的特徵，以捕捉不同尺度目標的訊息。這樣的結合可以提高模型對多尺度目標的偵測性能。
2. Mish 激勵函數：Mish 是一種新型的激勵函數，相對於傳統的 ReLU 或 Leaky ReLU，它在某些情況下被認為具有更好的性

能。Mish 激勵函數具有非線性和平滑的特性，能夠更好地保留和傳遞特徵的細節訊息。這有助於提高模型的表示能力和偵測精度。

結合 CSPPANet 結構和 Mish 激勵函數，可以期望獲得更好的性能和準確度。CSPPANet 提供了強大的特徵萃取和整合能力，可以捕捉不同尺度目標的特徵。同時，Mish 激勵函數的使用能夠更好地保留特徵的細節和上下文訊息，增強模型的表達能力。

SPP (Spatial Pyramid Pooling) 模塊是一種用於空間金字塔池化的模塊，常見於目標偵測和影像分類任務中。它的主要目的是在不同尺度下對特徵進行固定大小的池化操作，以捕捉不同物體的上下文訊息。

SPP 模塊的主要特點和功能如下：

1. 多尺度金字塔池化：SPP 模塊通常基於特徵圖進行多尺度的金字塔池化操作。它將特徵圖分為多個不同尺度的子區域，並對每個子區域進行池化操作。每個尺度的子區域的大小根據特徵圖的尺寸和特定的金字塔層級而定。
2. 固定大小的池化操作：SPP 模塊對每個子區域進行池化操作，以固定大小的輸出。這意味著無論子區域的尺寸如何，最終的池化結果都具有相同的大小。這有助於確保特徵表示的一致性，無論物體在圖像中的尺寸如何。
3. 捕捉多尺度上下文訊息：由於 SPP 模塊對特徵進行了多尺度的金字塔池化操作，它能夠捕捉到不同尺度上下文的訊息。這有助於提高模型對不同尺度目標的感知能力，從而改善偵測和分類的性能。
4. 可應用於不同尺度的輸入：SPP 模塊的輸入可以是不同尺度的特徵圖。這使得它能夠在不同尺度的影像或特徵上進行操作，具有一定的通用性和靈活性。

SPP 模塊通常做為主幹網路中的一部分，用於萃取和固定特徵表示，以供後續的偵測或分類模型使用。它在目標偵測任務中被廣泛應用，例如在 YOLOv3 和 Fast R-CNN 等模型中。

Spatial Attention Module (SAM) 是一種用於增強特徵圖的空間感知能力的模塊。它可以有效地捕捉特徵圖中的重要上下文訊息，以提高目標偵測、影像分割等任務的性能。

以下是 Spatial Attention Module 的一些特點和功能：

1. 通道注意力機制：SAM 通常使用通道注意力機制來學習和分配特徵圖中不同通道的重要性權重。它利用卷積和池化操作來萃取通道的相關訊息，然後通過全連接層、激勵函數等來生成通道注意力權重。這些權重可以用來調整特徵圖中各個通道的重要性，以更好地捕捉上下文訊息。
2. 空間注意力機制：SAM 還可以使用空間注意力機制來學習特徵圖中不同空間位置的重要性權重。它通常使用卷積和池化操作來萃取空間位置的相關訊息，然後通過全連接層、激勵函數等來生成空間注意力權重。這些權重可以用來調整特徵圖中各個空間位置的重要性，以更好地捕捉上下文訊息。
3. 特徵融合：SAM 通常將通道注意力權重和空間注意力權重應用於特徵圖上，以實現特徵的融合。這可以通過對特徵圖進行元素級別的乘法或加權平均等操作來實現。透過特徵融合，SAM 能夠將重要的上下文訊息傳遞到後續的處理模塊，提高模型對目標的感知能力。
4. 可嵌入不同模型：SAM 可以做為主幹網路中的一部分，也可以集成到其他任務模型中，如目標偵測、影像分割等。它提供了一種通用的機制，用於增強特徵圖的空間感知能力，從而提高不同任務的性能。

(三)偵測層 (Detection Head)：

1. 偵測層結構：YOLOv4 的偵測層結構是基於 YOLOv3 的偵測層進行改進的。它使用了多個 3×3 卷積層，以及 1×1 卷積層用於通道數的調整。偵測層通過這些卷積層來預測目標的位置和類別。
2. 網格生成：偵測層將圖像分為不同的網格，每個網格負責預測該網格內是否存在目標以及目標的位置和類別。
3. 預測框調整：在偵測層中，每個網格生成多個預測框 (bounding box)，每個預測框都有一個相應的信心分數 (confidence score)。偵測層使用錨框 (anchor box) 來調整預測框的大小和形狀。
4. 非極大值抑制 (Non-Maximum Suppression, NMS)：在偵測層的最後階段，通過應用非極大值抑制算法，選擇具有最高信心分數並消除重疊的預測框，從而得到最終的偵測結果。

(四)損失函數 (Loss Function)：

YOLOv4 中的目標偵測損失由兩個部分組成：定位損失和信心損失。

1. 定位損失 (Localization Loss)：定位損失衡量預測框的位置準確度。它使用均方誤差 (Mean Squared Error, MSE) 或者平滑 L1 損失 (Smooth L1 Loss) 來計算預測框的中心點偏移和寬高的誤差。定位損失的計算只應用於那些與真實目標有重疊的預測框。
2. 信心損失 (Confidence Loss)：信心損失衡量了預測框是否包含目標並且預測其 IoU 的準確度。信心損失的計算包括兩部分：對於包含目標的預測框，計算其 IoU 預測值與真實 IoU 之間的均方誤差；對於不包含目標的預測框，計算其 IoU 預測值與 0 之間的均方誤差。這鼓勵模型將高 IoU 分配給真實目標的預測框，並將低 IoU 分配給背景的預測框。

此外，YOLOv4 還使用了分類損失 (Classification Loss)，該損失衡量預測框的類別預測準確度。分類損失通常使用交叉熵損失 (Cross-Entropy Loss) 來計算預測類別概率分佈與真實類別標籤之間的差異。

6.1.2 YOLOv5

YOLOv5 是一種目標偵測算法，它是 YOLO (You Only Look Once) 系列的其中一個版本，架構圖如圖 6.1-3。

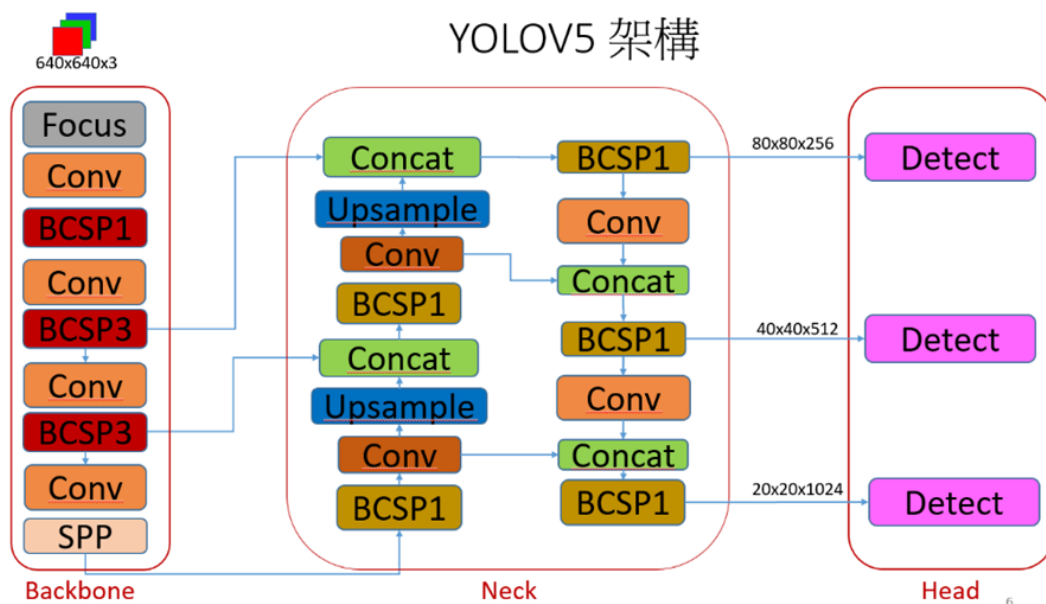


圖 6.1-3 YOLOv5 架構圖

以下是 YOLOv5 的網路架構的概述：

(一)主幹網路 (Backbone)：YOLOv5 使用 CSPDarknet53 做為主幹網路。

CSPDarknet53 是一個深度卷積神經網路，它具有 53 個卷積層。CSP (Cross Stage Partial) 是一種特殊的結構，通過在主幹網路的不同層之間引入跨階段的連接，提高了特徵的表達能力和訊息流動。

(二)降維層 (Neck)：YOLOv5 在主幹網路之後添加了一個降維層，稱為 PANet (Path Aggregation Network)。PANet 通過使用上採樣和下採樣的動作，將不同尺度的特徵圖進行融合，以捕獲不同層次的物體訊息。

(三)偵測層 (Detection Head)：YOLOv5 的偵測層使用一系列的卷積層和全連接層進行目標偵測。偵測層通過在不同尺度上應用卷積和激勵函數，生成預測框的位置和類別訊息。

(四)損失函數 (Loss Function)：YOLOv5 使用的損失函數是 YOLO 損失函數。該損失函數包括定位損失、信心損失和類別損失。定位損失衡量預測框的位置準確度，信心損失衡量預測框是否包含目標並且預測其 IoU 的準確度，類別損失衡量預測框的類別預測準確度。

(五)訓練策略 (Efficient Training Strategy)：YOLOv5 採用了一些高效的訓練策略，如隨機擴增 (Random Augmentation) 和 Mosaic 擴增 (Mosaic Augmentation)，以增加數據的多樣性和模型的泛化能力。此外，YOLOv5 還引入了 Self-Adversarial Training (SAT) 技術，通過對抗損失來進一步提高模型的泛化性和準確性。

6.1.3 YOLOv7

YOLOv7 是由 YOLOv4 團隊提出的一種目標偵測算法，該算法在實時性和準確率方面超越了現有的目標偵測算法，架構圖如圖 6.1-4。

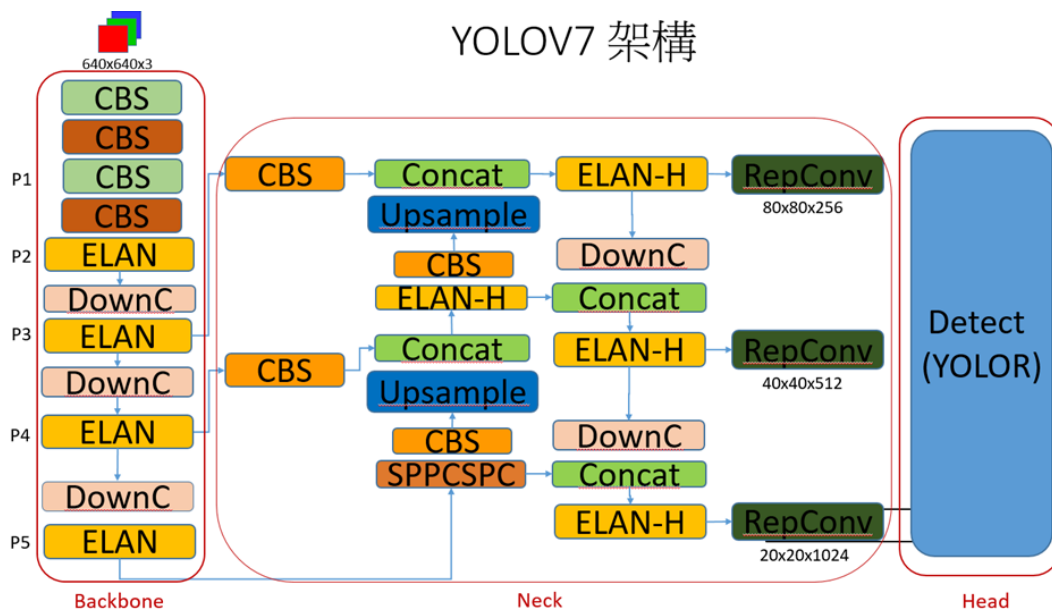


圖 6.1-4 YOLOv7 架構圖

以下是對 YOLOv7 的闡述：

- (一)創新點：YOLOv7 的創新點主要包括模型結構重參化和動態標籤分配。模型結構重參化是通過分析梯度的傳播路徑，對網路中的不同層進行優化。動態標籤分配則是通過引導頭和輔助頭的學習，生成從粗到細的層次標籤，用於訓練模型。
- (二)高效的聚合網路設計：YOLOv7 使用了 CSPVoVNet 做為其聚合網路架構。該架構考慮了模型設計中的參數量、計算量、內存訪問次數、輸入輸出通道比、元素級操作等方面，以提高網路的實時性和偵測性能。
- (三)卷積重參化：YOLOv7 引入了卷積重參化技術，將多個模塊合併為一個模塊，從而減少模型的大小並提高推理速度。該方法分析了重參化卷積與殘差連接或跨層連接結合時的影響，並設計了適應不同網路結構的重參化卷積。
- (四)基於 concatenate 的模型縮放：YOLOv7 通過基於 concatenate 的方法對模型進行縮放，調整模型的大小以生成不同尺度的模型。這種方法可以平衡參數量、計算量、推理速度和精度，並保持模型的特性。
- (五)動態標籤分配：YOLOv7 引入了引導頭和輔助頭的標籤分配方法。這些頭部使用引導頭的推理結果生成從粗到細的層次標籤，並根據這些標籤來訓練模型。這種標籤分配方法可以提高模型的學習能力和性能。

除此之外，YOLOv7 還採用了一些訓練時的其他策略，如 Batch Normalization、YOLOv7 中的加法和乘法方法、EMA 等。

YOLOv7 是一種在目標偵測領域具有優異性能的算法，通過模型結構重參化、動態標籤分配、聚合網路設計、卷積重參化和模型縮放等技術，提高了模型的實時性、準確率和學習能力。該算法的創新設計使得它在目標偵測任務中取得了出色的成果。

6.1.4 YOLOv8

YOLOv8 是 YOLO (You Only Look Once) 系列的最新版本，由 Ultralytics 開發，用於物件偵測、影像分類和實例分割。它在先前版本 YOLOv5 的基礎上進行了改進，並被開放原始碼供大眾使用，架構圖如圖 6.1-5。

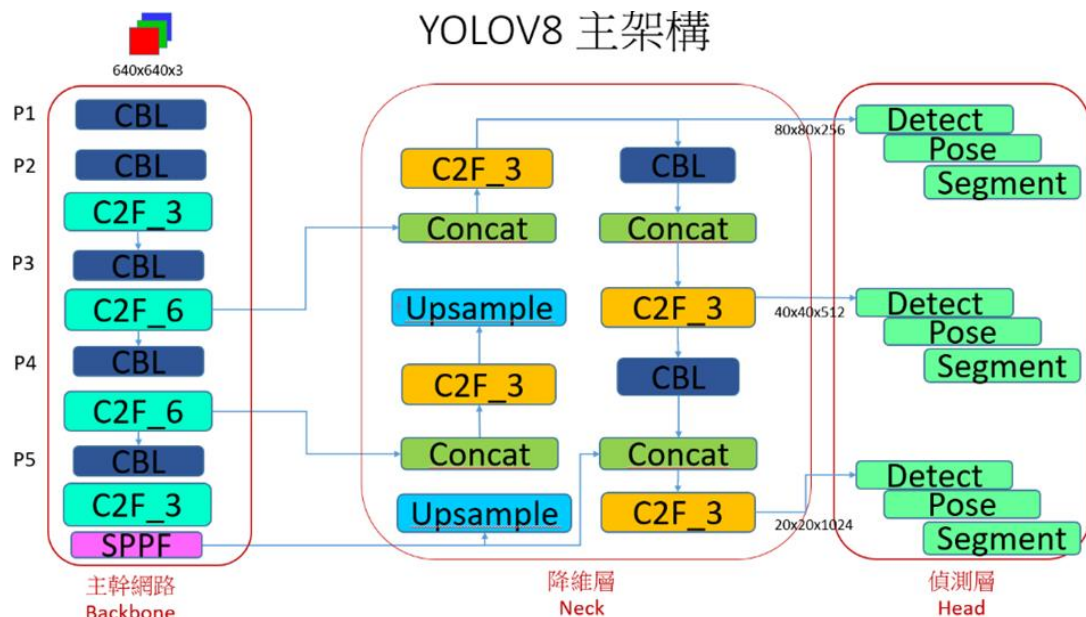


圖 6.1-5 YOLOv8 架構圖

以下是有關其實作的一些關鍵點：

- (一)骨幹網路 (Backbone)：骨幹網路是 YOLOv8 架構的基礎，主要負責從輸入影像中提取特徵。YOLOv8 使用了改進版的 CSPDarknet53 做為其骨幹網路。這個網路包含多個卷積層，這些層經過精心設計，以有效地捕捉影像中的細節和模式。
- (二)特徵處理層：在骨幹網路提取特徵之後，YOLOv8 利用多個特殊層來進一步處理這些特徵。其中包括：
 1. SPPF 層 (Spatial Pyramid Pooling-Fast)：這個層用於在不同尺度上處理特徵，從而增強模型對於不同大小物件的偵測能力。
 2. 卷積層：繼續處理和細化特徵，準備進入檢測階段。
 3. Upsample 層：這些層用於增加特徵圖的分辨率，使模型能夠更細緻地定位小物件。

(三)進階的骨幹和頸部架構：YOLOv8 在其骨幹和頸部架構上進行了創新，以提升特徵提取和物件偵測的性能。這包括使用最先進的卷積技術和激活函數。

(四)無錨點分割 (Anchor-Free Split)：YOLOv8 引入了無錨點技術，意味著不再使用預先定義的錨點尺寸來預測物體的位置。相反，它通過 TaskAlignedAssigner 類別來直接對齊真實目標框和預測框。

(五)特徵提取器和檢測頭部：這部分包括：

1. 特徵提取器：負責從經過骨幹網路和特徵處理層的数据中提取有用的特徵。
2. 檢測頭部：使用這些特徵來預測物件的類別和位置。它包括一系列卷積層來定位和分類物件。

(六)模型尺寸和調整：YOLOv8 提供了不同的模型尺寸 (N, S, M, L)，以適應不同的計算需求和精確度。這些變體在層的深度和寬度上有所不同，從而在運算資源和性能之間取得平衡。YOLOv8 的設計允許模型根據不同的應用和数据集進行自適應訓練和調整，增強其適用性和效能。

(七)自適應訓練和參數調整：YOLOv8 的設計允許模型根據不同的應用和数据集進行自適應訓練和調整，增強其適用性和效能。

6.1.5 模式辨識效果及改善流程

本專案的客製化模型均經過 500 個事件影片的完整測試，判定物體辨識效果原則如下所述：

- (一)一個事件影片有任何辨識不良的片段即判定為辨識有問題的事件。
- (二)在 ROI 九宮格區域內，無遮蔽狀態的最近物體判定是否辨識良好。
- (三)大車和小車種類頻頻切換，判定辨識有問題。
- (四)物體辨識錯誤或無偵測或一物體出現多偵測框或因角度切換問題誤判，判定辨識有問題。

客製化模型改善流程：轉移學習是一種利用在大規模數據集上訓練好的深度學習模型做為基礎，然後在特定的任務（例如車輛或行人識別）上進行微調的策略。這通常可以在數據有限的情況下，提高模型的性能。

在原有模型的訓練和測試狀況方面，第一年度我們利用和欣客運行車紀錄器的影片，並加以人工標記和進行模型的訓練，經過測試後選定了 Scaled YOLOv4 做為偵測的模型，然後經過討論加以過濾篩選出各種事件的樣本，經過演算法計算，在九宮格區域產出各種事件發生時的前方車輛距離，和相對車速等相關數據。然而這些數據的準確與否是基於模型偵測的效果，因此本年度首先由改善模型偵測效果來著手改進。

模型偵測的影響因素主要是來自影像的品質，而行車紀錄器的好壞直接影響影像的效果，但是本案無法藉由改善行車紀錄器來改善影像的品質，因此較可行的方式是改善模型的偵測能力。我們藉由深度學習模型 YOLO 系列的幾個代表性模型來逐一進行客製化的訓練，並逐一測試模型偵測的效果。

對於上述的偵測不良狀況，以下是一種人工標記、資料分組和模型遞增訓練的策略：

- (一)人工標記：在所有出現問題的影像中，明確地標記出物體的邊界和類別。如果可能的話，標記出可能影響偵測的特定特徵，例如光暈、雜訊、過曝或過暗區域等。
- (二)資料分組：將資料根據出現問題的情況進行分組。例如，一組是在大太陽下產生的影像，一組是在陰天情況下的影像，一組是在夜間的影像，另一組是在下雨時的影像等。每組都應該包含正常和異常的樣本，並以標記明確的方式表示。
- (三)模型遞增訓練：首先，用一個基本的資料集來訓練模型，這個資料集包含各種情況但不特定於任何一種特殊情況。然後，依序引入不同的資料組，進行遞增訓練。對於每個資料組，要確保模型在訓練過程中達到了一定的性能水平，再進行下一組資料的訓練。這種遞增的方式有助於模型學習到如何在不同情況下偵測物體。

(四)災難性遺忘處理：在引入新的資料組進行遞增訓練時，要持續監控模型在舊資料組上的表現，避免出現災難性遺忘。如果發現模型在某一個舊資料組上的表現下降，可以透過再次訓練該資料組來恢復性能。也可以嘗試使用一些避免災難性遺忘的技術，如彈性權重共享 (Elastic Weight Consolidation) 或漸進式網路 (Progressive Networks)。

(五)模型評估和調整：在遞增訓練過程中，要持續評估模型的性能，包括精確度 (accuracy)、召回率 (recall)、F1 分數等。如果發現模型在某一種情況下的表現不佳，可以考慮調整模型的架構或參數，或者增加該情況下的訓練資料。

進一步的技術細節包含：

(一)訓練基本模型：首先使用一個包含各種情況的基本資料集訓練模型，確保模型在一般條件下的表現達到一定的水準。

(二)創建子資料集：再將所有出現問題的影像按照問題的類型進行分組。每一組都應該包含正常和異常的樣本。例如，可以創建一個「大太陽下影像」的子資料集，一個「陰天影像」的子資料集，一個「夜間影像」的子資料集，和一個「雨天影像」的子資料集。

(三)進行遞增訓練：對於每個子資料集，遞增地訓練模型。在訓練新的子資料集前，可以先評估模型在該子資料集上的性能。如果性能不足，可以先調整模型的參數或結構，或者增加該子資料集的樣本數量，然後再進行訓練。

(四)防止災難性遺忘：在每次遞增訓練後，要確保模型在所有先前訓練過的子資料集上的表現都沒有明顯下降。如果發現模型在某一個舊子資料集上的性能下降，則需要重新訓練該子資料集，或者嘗試使用一些防止災難性遺忘的技術。

(五)評估模型性能：在整個訓練過程中，持續監測模型的性能。主要關注的指標可能包括精確度、召回率、F1 分數等。這可以幫助識別哪些子資料集的性能不足，並對模型進行相應的調整。

(六)調整模型和資料：如果發現模型在某些特定情況下的性能不足，可以考慮增加這些情況下的訓練資料，或者調整模型的架構或參數，以改善其在這些情況下的性能。

對於 YOLOv7 偵測，偵測物件種類以及樣本數以及訓練收斂後之精度。另提供各物件類別，計算混淆矩陣，以評估其實用精度。

6.1.6 針對車外偵測不穩定的事件情境分析和模型測試比較

(一)夜間情境分析

1. 強光影像過曝和雜訊，特徵細節丟失。

夜間時，因為光線環境的特殊性，很容易在行車紀錄器的影像中產生強光過曝或雜訊問題，導致特徵細節丟失；範例如圖 6.1-6，說明如下。

(1) 強光過曝：在夜間，若遇到前方車輛的車燈或街燈等強烈光源直射，行車紀錄器的影像可能因此產生過曝問題。過曝區域通常會變成白色或亮色，並且在這些區域中的細節特徵會完全丟失，這就使得模型難以從這些區域識別出任何物體。

(2) 雜訊：在光線較暗的環境下，鏡頭為了獲得更多的亮度，通常會提高感光度(ISO)。但感光度提高的同時，影像中的雜訊也會增加，這些雜訊可能會使影像中的特徵細節變得模糊，甚至被掩蓋，從而導致模型的偵測和識別變得困難。



圖 6.1-6 強光影像過曝和雜訊，特徵細節丟失偵測效果比較

2. 強光影像過曝水珠或地面反光特徵細節模糊

在下雨夜晚的狀況下，強光過曝、水珠或地面反光，導致特徵細節模糊的問題可能更為嚴重；範例如圖 6.1-7，說明如下。

- (1) 強光過曝：夜晚時遇到車燈、街燈或其他強烈光源，影像可能出現過曝區域，過曝部分會成為白色或亮色，且細節特徵會丟失，使得模型難以辨認過曝區域中的物體。

(2) 水珠或地面反光：下雨時，水珠可能會附著在鏡頭上，使得影像變得模糊。此外，雨水也會使路面反射性增加，可能導致影像出現強烈的反光或光暈，進一步干擾影像中的特徵細節。

(3) 特徵細節模糊：雨夜的光線條件加上雨水和反光的影響，可能使得影像中的物體輪廓變得不清晰，物體的特徵細節也可能會被模糊或掩蓋，使得模型的識別和分類變得困難。



圖 6.1-7 強光影像過曝水珠或地面反光特徵細節模糊偵測效果比較

3. 低光照影像過暗和雜訊水珠或地面反光

在下雨夜間，低光照影像過暗、雜訊增加以及水珠或地面反光都可能成為影響模型在行車紀錄器影片偵測能力的問題。

- (1) 低光照影像過暗：在夜間或光線不足的情況下，由於鏡頭感光元件接收到的光線較少，影像可能會顯得過暗，導致物體的特徵細節不足，使得模型難以準確辨認和分類。
- (2) 雜訊增加：在低光照條件下，鏡頭為了嘗試捕捉更多的光線和細節，可能會增加感光元件的增益或使用較長的曝光時間，這可能會使影像中的雜訊增加，影響影像的清晰度和特徵細節。
- (3) 水珠或地面反光：下雨時，雨滴可能會附著在鏡頭上，造成影像模糊，同時，由於路面的反射性增加，可能會產生強烈的反光或光暈，這些反光可能會使原本已經暗淡的影像更加難以識別。

4. 低光照影像過暗和雜訊，輪廓和特徵細節丟失

在夜間或者光照條件不足的情況下，低光照影像過暗、雜訊增加以及輪廓和特徵細節的丟失確實是相關偵測模型面臨的一個挑戰；範例如圖 6.1-8、圖 6.1-9，說明如下。

- (1) 低光照影像過暗：在夜間或者光照條件不足的情況下，鏡頭的感光元件可能無法接收到足夠的光線，導致影像過暗。這可能導致物體輪廓模糊，特徵細節丟失，使得偵測模型難以準確地辨識和分類目標。
- (2) 雜訊增加：在低光照的條件下，為了嘗試增加影像的亮度和保留更多的細節，鏡頭可能會增加感光元件的增益或者使用較長的曝光時間，這可能導致影像的雜訊增加，進一步影響影像的清晰度和特徵的可辨識性。

YOLOV4 IOT ↵
偵測失敗 ↵



YOLOV5 IOT ↵
偵測失敗 ↵



YOLOV7 IOT ft50 ↵
偵測失敗 ↵



YOLOV7 IOT ft600 ↵
偵測失敗 ↵



YOLOV7 enh. IOT ↵
偵測失敗 ↵



YOLOV5 EF-IOT ↵
偵測失敗 ↵



YOLOV7 EF-IOT ↵
偵測正確 ↵



圖 6.1-8 低光照影像過暗和雜訊水珠或地面反光偵測效果比較

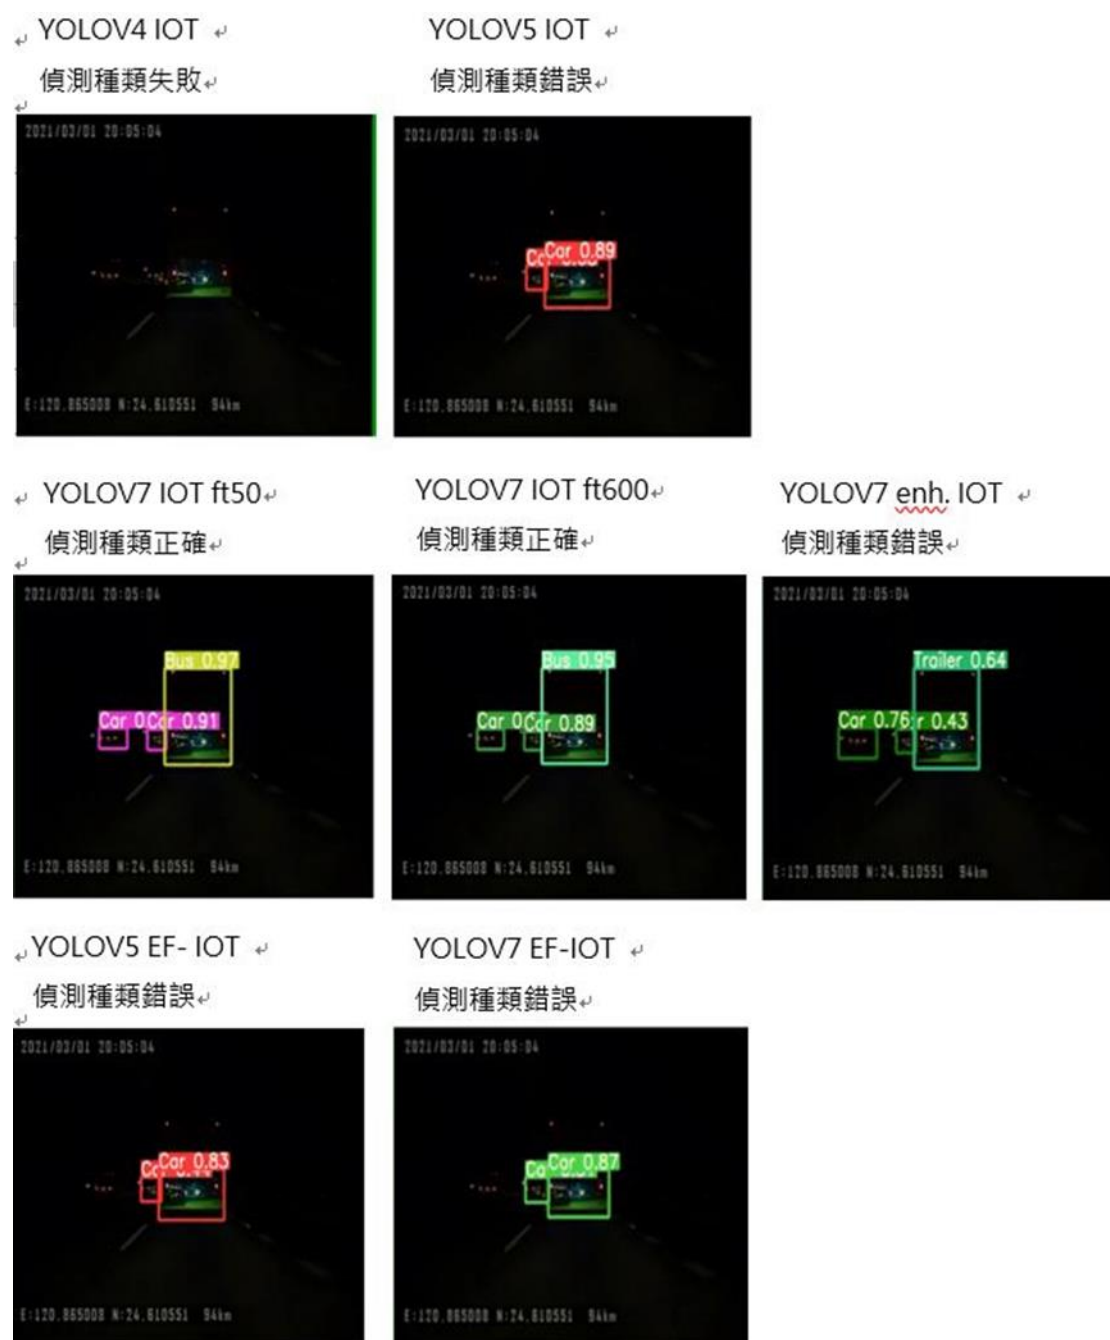


圖 6.1-9 低光照影像過暗和雜訊，輪廓和特徵細節丟失偵測效果比較

5. 低光照影像過曝和雜訊輪廓和特徵細節丟失

在夜間或低光照條件下，影像過曝的情況可能來自於高亮度的光源，例如對向來車的頭燈或者前方煞車燈。這些高亮度的光源可能會使相機的自動曝光系統誤判，結果造成整體影像的過曝。過曝的部分會導致該區域的影像細節丟失，無法識別出目標物體的輪廓和特徵。此外，由於大部分的環境光照較弱，

鏡頭在嘗試抓取更多的光線以顯示環境細節時，可能會引入更多的影像雜訊，使得影像的清晰度降低；範例如圖 6.1-10。



圖 6.1-10 低光照影像過曝和雜訊輪廓和特徵細節丟失偵測效果比較

6. 夜間其他燈光雜訊干擾

在夜間駕駛時，來自街燈、對向車輛的頭燈、前方車輛閃爍的方向燈等各種外部光源可能會對鏡頭造成干擾，這種干擾在影像中通常表現為光斑或光暈，這可能導致影像中的特徵變得模糊或不清晰，影響模型的偵測效果；範例如圖 6.1-11。



圖 6.1-11 夜間其他燈光雜訊干擾偵測效果比較

(二)日間情境分析

1. 過曝影像對比過低，輪廓及陰影特徵模糊

產生過曝的影像通常是由於相機接收到的光線過多，導致影像中的某些區域亮度過高，超過了相機的動態範圍，因此導致細節丟失。在這種情況下，對比度可能會降低，輪廓和陰影的特徵可能會變得模糊不清。

在影像過曝的情況下，模型其性能可能會受到影響。因為過曝的影像可能導致原本應該清晰的邊界變得模糊，使得物體難以被識別，同時，陰影的細節也可能會丟失，進一步影響模型的識別能力；範例如圖 6.1-12。



圖 6.1-12 過曝影像對比過低，輪廓及陰影特徵模糊效果比較

2. 強光影像過曝水珠或地面反光特徵細節模糊

下雨的這種情況主要由於強光(如太陽直射或者車燈的反射)引起的過曝，也可能來自雨滴或地面濕潤而產生的反射。在這些情況下，影像的某些部分可能會因為光線過亮而變得模糊，特徵細節難以辨識，這對於需要進行物體識別的 AI 系統來說，可能是一個挑戰；範例如圖 6.1-13。



圖 6.1-13 強光影像過曝水珠或地面反光特徵細節模糊偵測效果比較

3. 濃霧視野不清偵測距離有限

在濃霧天氣下，行車紀錄器或其他類型的鏡頭可能會遇到許多挑戰，其中一個主要的挑戰就是視野不清，這可能會影響到物體的偵測和識別。濃霧可以使相機鏡頭模糊，降低影像清晰度。另外，濃霧以使視線變得非常模糊，使得近距離的物體變得難以識別；範例如圖 6.1-14。

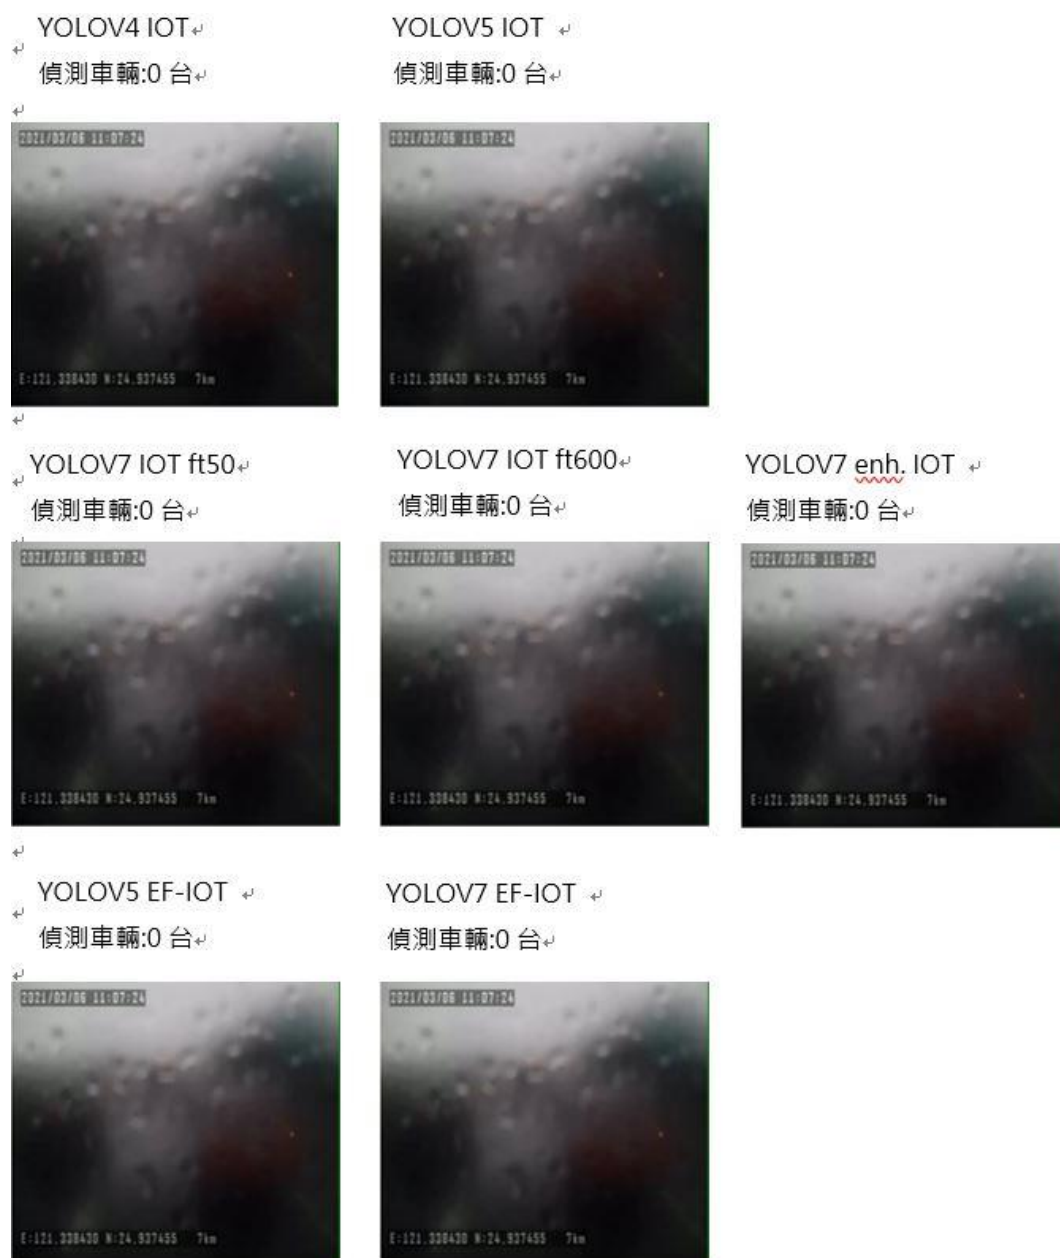


圖 6.1-14 濃霧視野不清偵測距離有限偵測效果比較

4. 陰天影像對比過低，輪廓特徵模糊

在陰天條件下，光線通常較為柔和且分布均勻，缺乏明顯的陰影和強烈的明暗對比。這樣的環境可能會導致影像的對比度降低，使得物體的邊緣輪廓與背景融合，從而導致特徵模糊，影響模型的正確識別；範例如圖 6.1-15。

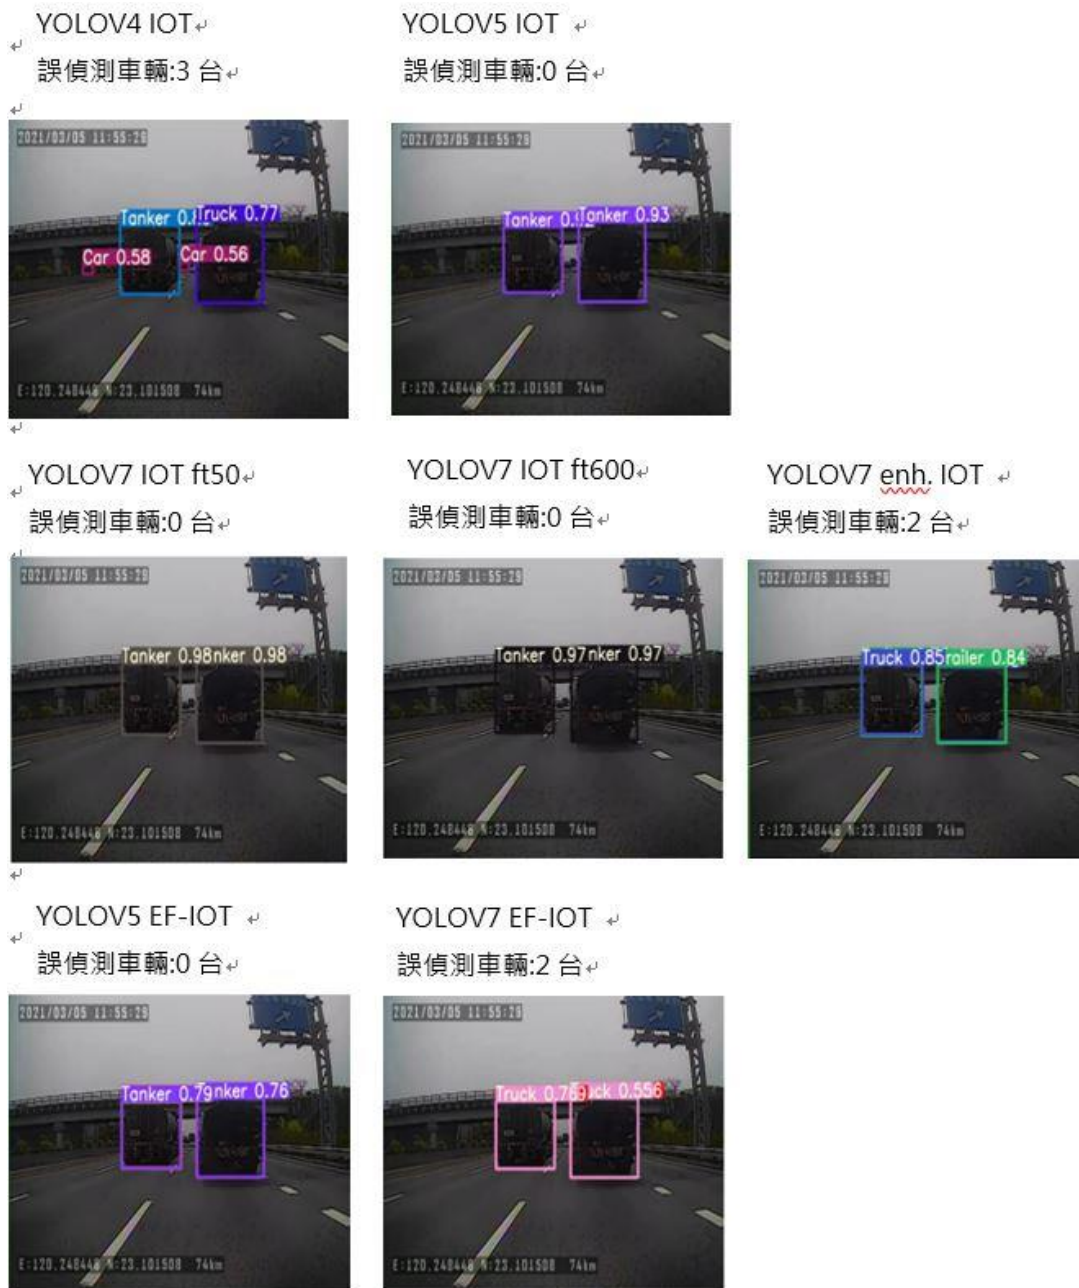


圖 6.1-15 陰天影像對比過低，輪廓特徵模糊偵測效果比較

5. 雨滴大小和密度的遮蔽干擾

雨滴的大小和密度會對行車紀錄器的影像產生重要影響。當雨滴覆蓋在鏡頭上，或者在空中飄落時，會造成視覺效果的變化，進而導致影像的部分區域模糊或視線受阻，這種現象稱為遮蔽干擾；範例如圖 6.1-16，說明如下。

- (1) 遮蔽物體：雨滴可能遮蓋視線，使得行車紀錄器無法清楚看見物體，導致物體的特徵萃取和識別變得困難。
- (2) 干擾光線傳播：雨滴在空中飄落時，會對光線的傳播產生干擾，進一步增加影像的模糊度和噪點。
- (3) 產生反射和繞射：雨滴可能會將光線反射或繞射，使得原本的物體邊緣模糊不清，特徵難以萃取。

6. 角度變換和紋理干擾

行車紀錄器所拍攝的影像資料可能受到各種影響，其中包括攝影角度的變換和環境及目標物本身紋理的干擾，這兩種因素都可能對模型的物體識別產生挑戰；範例如圖 6.1-17，說明如下。

- (1) 角度變換：車輛行駛過程中，因路況變化或轉彎等情況，會造成攝影機的拍攝角度變化，這可能使同一物體的視覺特徵出現變化，給模型識別帶來難度。
- (2) 紋理干擾：路面或其他物體的紋理，可能與目標物體的視覺特徵相似或混淆，這稱為紋理干擾。例如，斑馬線、人行道的磚塊紋理，甚至是車輛本身的廣告圖案，都可能干擾模型對車輛、行人等目標的識別。

偵測種類:汽車



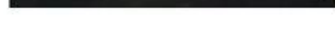
偵測種類:汽車



偵測種類:巴士



偵測種類:巴士



偵測種類:卡車↓



偵測種類:汽車



偵測種類:巴士



圖 6.1-16 雨滴大小和密度的遮蔽干擾偵測效果比較

YOLOV4 IOT ↵
偵測到卡車 ↵



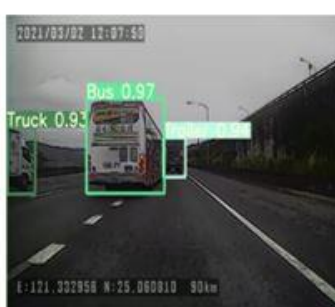
YOLOV5 IOT ↵
偵測到巴士 ↵



YOLOV7 IOT ft50 ↵
偵測到巴士 ↵



YOLOV7 IOT ft600 ↵
偵測到巴士 ↵



YOLOV7 enh. IOT ↵
偵測到聯結車 ↵



YOLOV5 EF-IOT ↵
偵測到巴士 ↵



YOLOV7 EF-IOT ↵
偵測到巴士 ↵

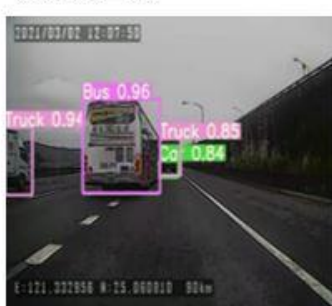


圖 6.1-17 角度變換和紋理干擾偵測效果比較

綜整以上比較，各種模型在車外物體辨識不穩定的事件統計，如表 6.1-1 至表 6.1-4。

表 6.1-1 YOLOv4 iot 車外辨識不穩定統計

日間	過曝影像 對比過 低，輪廓 及陰影特 徵模糊	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	濃霧視野 不清，偵 測距離有 限	陰天影像 對比過 低，輪廓 特徵模糊	雨滴大小 和密度的 遮蔽干擾	角度變換 和紋理干 擾	合計不 穩定/樣 本數量
車輛 1	3	5	0	1	2	0	11/126
車輛 2	5	0	0	0	0	8	13/143
車輛 3	0	0	4	0	0	0	2/19
車輛 4	0	0	0	0	0	0	0/13
車輛 5	0	0	0	0	0	0	0/53
夜間	強光影像 過曝和雜 訊，特徵 細節丟失	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	低光照影 像過暗和 雜訊，水 珠或地面 反光	低光照影 像過暗和 雜訊，輪 廓和特徵 細節丟失	低光照影 像過曝和 雜訊，輪 廓和特徵 細節丟失	夜間其他 燈光雜訊 干擾	合計不 穩定/樣 本數量
車輛 1	7	0	2	12	3	1	23/47
車輛 2	0	0	0	33	0	2	35/65
車輛 3	2	2	0	0	3	0	5/10
車輛 4	0	0	0	1	1	0	2/3
車輛 5	4	0	1	3	8	0	16/18

表 6.1-2 YOLOV7 ef-iot 車外辨識不穩定統計

日間	過曝影像 對比過 低，輪廓 及陰影特 徵模糊	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	濃霧視野 不清，偵 測距離有 限	陰天影像 對比過 低，輪廓 特徵模糊	雨滴大小 和密度的 遮蔽干擾	角度變換 和紋理干 擾	合計不 穩定/樣 本數量
車輛 1	1	5	0	0	2	0	8/126
車輛 2	8	0	0	5	0	3	16/143
車輛 3	3	0	4	0	0	0	7/19
車輛 4	0	0	0	0	0	0	0/13
車輛 5	0	0	0	0	0	0	0/53
夜間	強光影像 過曝和雜 訊，特徵 細節丟失	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	低光照影 像過暗和 雜訊，水 珠或地面 反光	低光照影 像過暗和 雜訊，輪 廓和特徵 細節丟失	低光照影 像過曝和 雜訊，輪 廓和特徵 細節丟失	夜間其他 燈光雜訊 干擾	合計不 穩定/樣 本數量
車輛 1	2	0	2	5	3	1	13/47
車輛 2	0	0	0	31	0	2	33/65
車輛 3	3	2	0	1	1	0	7/10
車輛 4	0	0	0	1	0	0	1/3
車輛 5	3	0	1	1	8	0	13/18

表 6.1-3 YOLOV7 iot-ft50 車外辨識不穩定統計

日間	過曝影像 對比過 低，輪廓 及陰影特 徵模糊	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	濃霧視野 不清，偵 測距離有 限	陰天影像 對比過 低，輪廓 特徵模糊	雨滴大小 和密度的 遮蔽干擾	角度變換 和紋理干 擾	合計不 穩定/樣 本數量
車輛 1	2	1	0	0	1	0	8/126
車輛 2	13	0	0	20	0	6	39/143
車輛 3	0	0	3	0	0	0	3/19
車輛 4	0	0	0	0	0	0	0/13
車輛 5	0	0	0	0	0	0	0/53
夜間	強光影像 過曝和雜 訊，特徵 細節丟失	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	低光照影 像過暗和 雜訊，水 珠或地面 反光	低光照影 像過暗和 雜訊，輪 廓和特徵 細節丟失	低光照影 像過曝和 雜訊，輪 廓和特徵 細節丟失	夜間其他 燈光雜訊 干擾	合計不 穩定/樣 本數量
車輛 1	1	2	1	2	3	0	9/47
車輛 2	0	0	1	11	0	12	24/65
車輛 3	1	2	0	0	1	0	4/10
車輛 4	0	0	0	1	0	0	1/3
車輛 5	2	0	2	1	8	0	13/18

表 6.1-4 YOLOV7 iot-ft600 車外辨識不穩定統計

日間	過曝影像 對比過 低，輪廓 及陰影特 徵模糊	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	濃霧視野 不清，偵 測距離有 限	陰天影像 對比過 低，輪廓 特徵模糊	雨滴大小 和密度的 遮蔽干擾	角度變換 和紋理干 擾	合計不 穩定/樣 本數量
車輛 1	4	2	0	2	1	0	9/126
車輛 2	9	0	0	30	0	5	44/143
車輛 3	0	0	3	0	0	0	3/19
車輛 4	0	0	0	0	0	0	0/13
車輛 5	0	0	0	0	0	0	0/53
夜間	強光影像 過曝和雜 訊，特徵 細節丟失	強光影像 過曝，水 珠或地面 反光，特 徵細節模 糊	低光照影 像過暗和 雜訊，水 珠或地面 反光	低光照影 像過暗和 雜訊，輪 廓和特徵 細節丟失	低光照影 像過曝和 雜訊，輪 廓和特徵 細節丟失	夜間其他 燈光雜訊 干擾	合計不 穩定/樣 本數量
車輛 1	3	1	1	2	4	0	11/47
車輛 2	0	0	0	15	0	5	20/65
車輛 3	3	2	0	1	1	0	3/10
車輛 4	0	0	0	1	0	0	1/3
車輛 5	2	0	0	0	9	0	11/18

模型改善觀察與分析：

- (一)改善前的模型，在夜間和雨天出現較多偵測錯誤和偵測失敗的例子，其他天候有一些偵測種類變化等不穩定的現象。
- (二)改善後的模型，以偵測種類變化及光暈現象等偵測不穩定現象為主，整體偵測不良率降低。
- (三)加了 EF 資料集，白天偵測效果相差不多，晚上效果稍好。
- (四)相同資料集，模型不同，遞增訓練資料問題，白天效果變差，晚上效果變好。
- (五)YOLOv7 在偵測物體光暈現象效果較佳。

(六)YOLOv7 在陰暗雨滴和地面反光有偽陽性偵測出現。

YOLOv8 相比於 YOLOv7，在幾個方面有所改進和提升：

(一)速度：YOLOv8 比 YOLOv7 更快一些。這對於需要快速進行物件偵測的實時應用來說非常關鍵。YOLOv8 提供更快的偵測速度，同時保持準確度。

(二)準確度：YOLOv8 在偵測小物件方面的準確度更高。它採用動態頭部網路來提高物件偵測的準確性，使得檢測小物件更為準確。

(三)無錨點架構：YOLOv8 使用無錨點架構，消除了對錨點框的需求，這使得在不同數據集上訓練模型變得更加容易。

(四)多尺度預測：YOLOv8 使用多尺度預測來改善物件偵測的準確性，能夠更容易地偵測不同大小的物件。

(五)改進的骨幹網路：YOLOv8 使用了更先進的骨幹網路，使得在具有挑戰性的環境中檢測物件更為容易。

(六)更友好的用戶介面：YOLOv8 被設計得更加用戶友好和易於使用。它有一個用戶友好的介面，使得各種物件偵測任務的實施和定制更加容易。

總結來說，YOLOv8 相比於 YOLOv7，在速度、準確度、無錨點架構、多尺度預測和骨幹網路方面都有所改進。這些改進使得 YOLOv8 成為一個更有效率、更準確且更容易使用的物件偵測模型，然而對於本案的應用而言，經過和欣客運影片實測，因為警示區域在九宮格內，偵測物體較大及在伺服器離線進行偵測，YOLOV8 優點較不易顯現出來，挑戰性的情境偵測效果和 YOLOV7 相比亦在伯仲之間。

6.1.7 新樣本影片觀察模型效果

新樣本影片採用新訓練的 YOLOV8 ef-iot-ft249 模型進行辨識，加上原本的九宮格距離內插計算和物體相對速度以及物體相對加速度的程式進行估計，並且輸出在畫面和 csv 檔內進行結果的紀錄。原本表列 615 支影片，減去無影片 8 支和不用辨識(不在班表時間內)的 127 支影片及影像

解析度錯誤 13 支及打不開的影片及部分無車速資料的影片實際可測試的影片數為 434 支，共計 15 輛車。如果來源影片不是 1920x1080 經過人工進行調整放大到 FHD，偵測效果會有一定程度的降低，因此不在本次觀察模型改善的評估範圍之內。

樣本影片方面：此次影片左右邊緣區域均經過人工或 DVR 的處理影響正常偵測效果，因此排除在偵測範圍之內。本批影片的資料可能是鏡頭成像的關係，夜間部分影片出現煞車燈的炫光現象，如圖 6.1-18，可能會影響模型的偵測效果。

模型觀察方面：YOLOv8 對於燈光或雨滴相對於其他的模型似乎較為敏感，因此出現一些誤偵測的現象，如圖 6.1-18 至圖 6.1-24。



圖 6.1-18 夜間部分影片出現煞車燈的炫光現象



圖 6.1-19 豪雨狀況物件偵測拖車出現 bounding box 範圍過大的異常



圖 6.1-20 豪雨狀況偵測大客車出現 bounding box 範圍過大的異常



圖 6.1-21 擋風玻璃雨滴附著出現偵測機車的異常



圖 6.1-22 擋風玻璃雨滴附著出現偵測卡車的異常



圖 6.1-23 地面反光出現偵測大客車的異常



圖 6.1-24 地面反光出現偵測卡車的異常

因為這些誤偵測為隨機出現或固定在某一處，因此相對速度或相對加速度都很小，沒有由遠而近或由兩側出現的正常物件軌跡，或面積很大，與真實物件狀態有一定的差異。而且演算法設定車速為 0 的狀況不啟動物件偵測，正常塞車狀況不會偵測出相對速度為 0 的過近和過大物體。定速跟車狀況下，相對速度亦有一定程度的變化起伏，不會是一個固定的小數值。綜合以上分析，過濾誤偵測方式相對容易。

新樣本影片觀察 YOLOv8 的車外辨識不穩定，以各種情境分類統計如表 6.1-5、表 6.1-6。

表 6.1-5 日間情境偵測不穩定統計

日間	過曝影 像對比， 輪廓及特 徵模糊	強光影 像過水， 珠或地反 光，特節 徵細節模 糊	大雨視 野不偵 測距離有 限	陰天影 像對比過 低，輪廓 特徵模糊	雨滴大 小和密遮 蔽干擾	角度變 換和紋理 干擾	合計 不穩定/ 樣本數
車輛 6	0	0	0	1	1	1	3/10
車輛 7	0	0	0	0	0	1	1/4
車輛 8	0	0	0	1	1	4	6/32
車輛 9	0	0	0	0	0	0	0/4
車輛 10	1	0	0	0	0	3	4/11
車輛 11	0	0	0	0	0	0	0/7
車輛 12	0	0	0	1	0	4	5/18

表 6.1-6 夜間情境偵測不穩定統計

夜間	強光影 像過曝雜 訊，細節 丟失	強光影 像過水， 珠或地反 光，特節 徵細節模 糊	低光照 像過暗和 雜訊，水 珠或地面 反光	低光照 像過暗和 雜訊，輪 廓和細節 丟失	低光照 像過曝和 雜訊，輪 廓和細節 丟失	夜間其 他燈光干 擾	合計 不穩定/ 樣本數
車輛 6	0	0	1	3	0	2	6/24
車輛 7	0	0	0	2	0	2	4/20
車輛 8	0	0	0	2	1	2	5/26
車輛 9	0	0	0	0	0	4	4/16
車輛 10	0	0	0	2	0	4	6/45
車輛 11	0	0	0	1	0	1	2/7
車輛 12	0	0	0	0	0	2	2/8

6.1.8 車外物件偵測及計算相對速度和距離所需時間

車外物件偵測及計算相對速度和距離的所需時間，在本專案分為數個階段來運行，車前定位點需要人工進行處理，本車速度和方向燈需要從車身訊號獲得，然後影像經由深度學習網路進行偵測和辨識。另外需要計算前方物件的速度和加速度則由程式來進行相關的運算，最後產出的是加上實際時間的 CSV 檔和標記相關數據資料的影片。

運作流程首先是物件偵測網路進行偵測前處理的資料才能正確的運行後續的計算，假設輸入影片為 25FPS，輸入大小：704x480，評估的單位是以每一分鐘的原始影片，需要多少分鐘的處理時間，來進行整個過程的所需時間，分析如表 6.1-7：

表 6.1-7 物件偵測及計算相對速度和距離所需時間

物件偵測及計算相對速度流程	一分鐘影片的處理時間
偵測車前物件	0.7500(分鐘)
產生偵測結果 csv 檔	0.0600(分鐘)
產生對應事件 OBD 資料	0.2500(分鐘)
計算相對速度/加速度	0.5000(分鐘)
辨識影片畫面上的時間資訊(OCR)	0.2650(分鐘)
加上實際時間 csv 檔	0.0003(分鐘)
產生結果觀察影片檔	0.1750(分鐘)
總計	2.0003(分鐘)

正常的影片經過程式運作評估，不包含影片裁切和事件對齊以及人工定位點標記的時間在內。因為不同的車輛所架設的鏡頭角度和位置不同，所以每台車必須進行另外的人工定位點標記，經過物件偵測網路確定位置和種類後，才能正確的計算內差距離，並且計算出相對的速度和加速度。

6.2 車內模型比較及改善

行車影像記錄系統的應用普及，大多商用車隊業者初期在記錄車輛駕駛狀況之需求而導入，而前期計畫藉由行車影像記錄系統中既有的車內影像分析駕駛行為，並進而分析車內駕駛行為所造成行車異常事件及

其關聯性。本期研究期望在前期的車內駕駛行為分析架構下，進一步增加分析的正確性和穩定性。

在前期的車內駕駛行為分析架構中，會先對原始影像進行關節點預測以得到駕駛關節點位置，再透過得到的關節點位置和其他的資訊去判斷各項的駕駛行為，如下圖 6.2-1 所示。在此架構中，由於關節點位置是判斷各項駕駛行為的依據，其正確性直接地影響後續的判斷，因此在本期研究中首先重點針對關節點預測模組進行改善，也就是圖 6.2-1 中紅框部分。

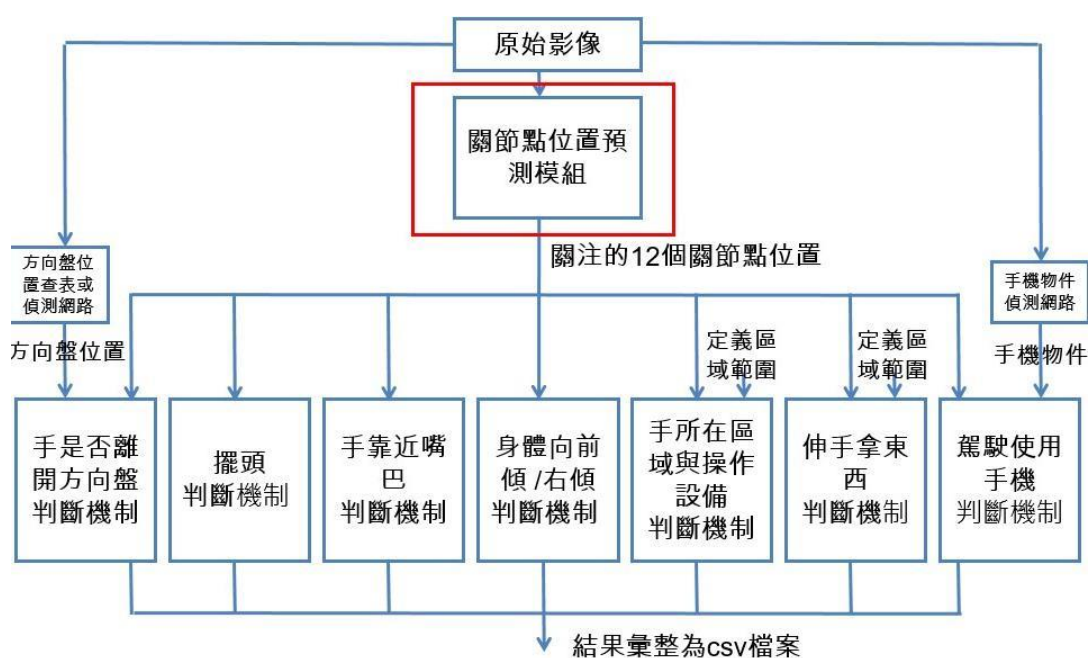


圖 6.2-1 車內駕駛行為分析架構

在前期主要使用 OpenPose 進行關節點偵測，而在本期上半年研究中改以 YOLOv7 Pose 做為關節點偵測網路，而在後半年則是測試使用 YOLOv8 Pose 和 ViTPose 架構嘗試進一步改善關節點偵測效果。

另外考慮到副駕駛座可能有乘客，所以可能出現在駕駛和乘客間跳換的狀況，也有針對駕駛目標選擇方式進行改善：認定所有偵測到的物件中信心度高於最高信心度-0.2 且物件框面積 ≥ 15000 之物件中，物件中心最靠右者為駕駛，目標選擇改善效果如圖 6.2-2 所示。



圖 6.2-2 車內模型偵測時遇到多物件狀況目標選擇方法改善

6.2.1 影像相關前處理測試

在影像輸入關節點位置預測網路之前，透過影像前處理嘗試提高關節點位置預測網路的正確性。嘗試影像強化和影像轉正兩種方法，以下分別討論測試的方法和結果。

影像強化方法針對亮度較不足或對比不明顯影像，強化對比以調高可辨識能力。在本期研究中測試了三種強化方法，分別為一個傳統影像處理方法：Dynamic Histogram Equalization，以及兩個用不同資料集學習的 MBLEN 類神經網路。影像強化後的結果比較如圖 6.2-3 所示，結論上來說對人眼觀看有幫助，機器觀看沒有明顯幫助。強化有效的影像無論有沒有進行處理關節點位置預測都有一定正確性，如圖 6.2-3 上半部的範例，而強化沒有有效的影像大多發生在相機成像不佳、IR 導致形成區域亮塊無法區分、遮蔽的情境，如圖 6.2-3 下半部的範例。

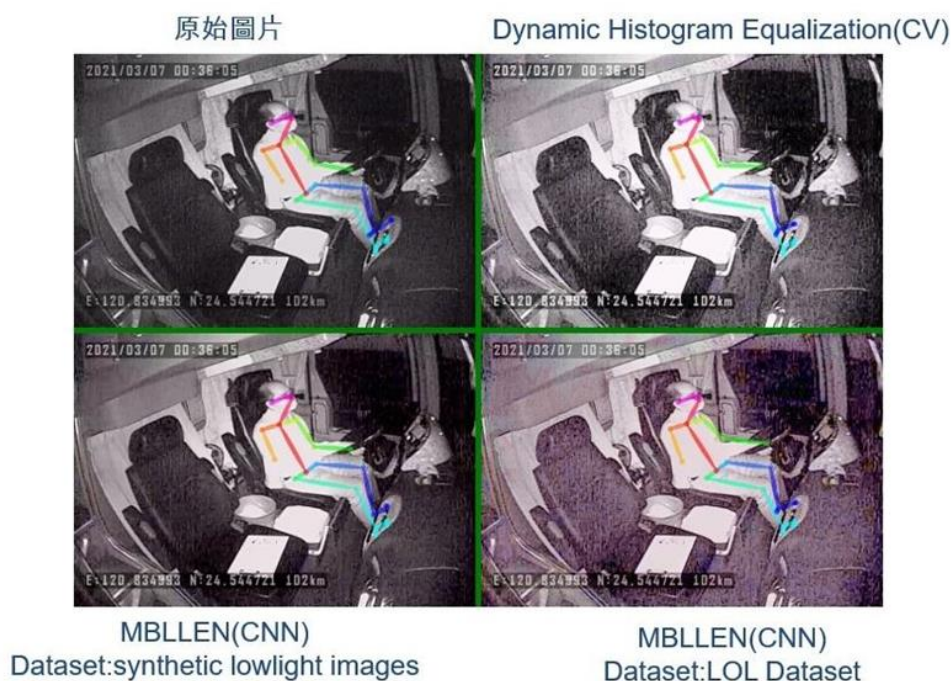
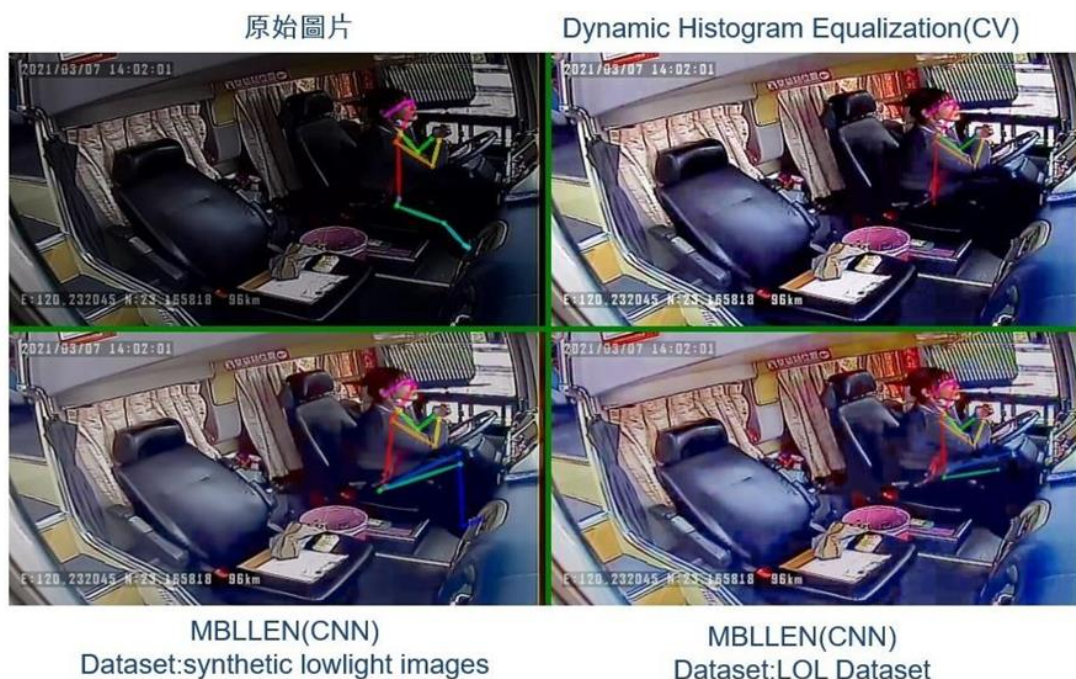


圖 6.2-3 車內影像強化前處理測試結果

影像轉正方法是使用透視轉換方法，嘗試將影像轉至駕駛的正面。經過測試後觀察透視轉換效果不佳，而原因可以歸納以下幾點：首先最直接的問題是無法定義轉換平面，駕駛是有深度起伏且不固定的物件，駕駛的各部位不會在同一個固定平面上。其他比較次要的原因包含原始拍攝角度距離駕駛正面差距太大，轉換後資訊很容易不足；以及車內沒有良好參考點只能靠人眼大致判斷。圖 6.2-4 上半部是原始影像，下半部

是針對座椅所在平面進行影像轉正的結果，原始影像中綠色框是人工定義的轉換目標平面，以椅背為參考畫出。而紅色框是列舉出駕駛各個身體部位可能所處的平面，駕駛整個人因為不在同一個平面（距離正前方的遠近不同），所以無法透過透視轉換將駕駛轉正。

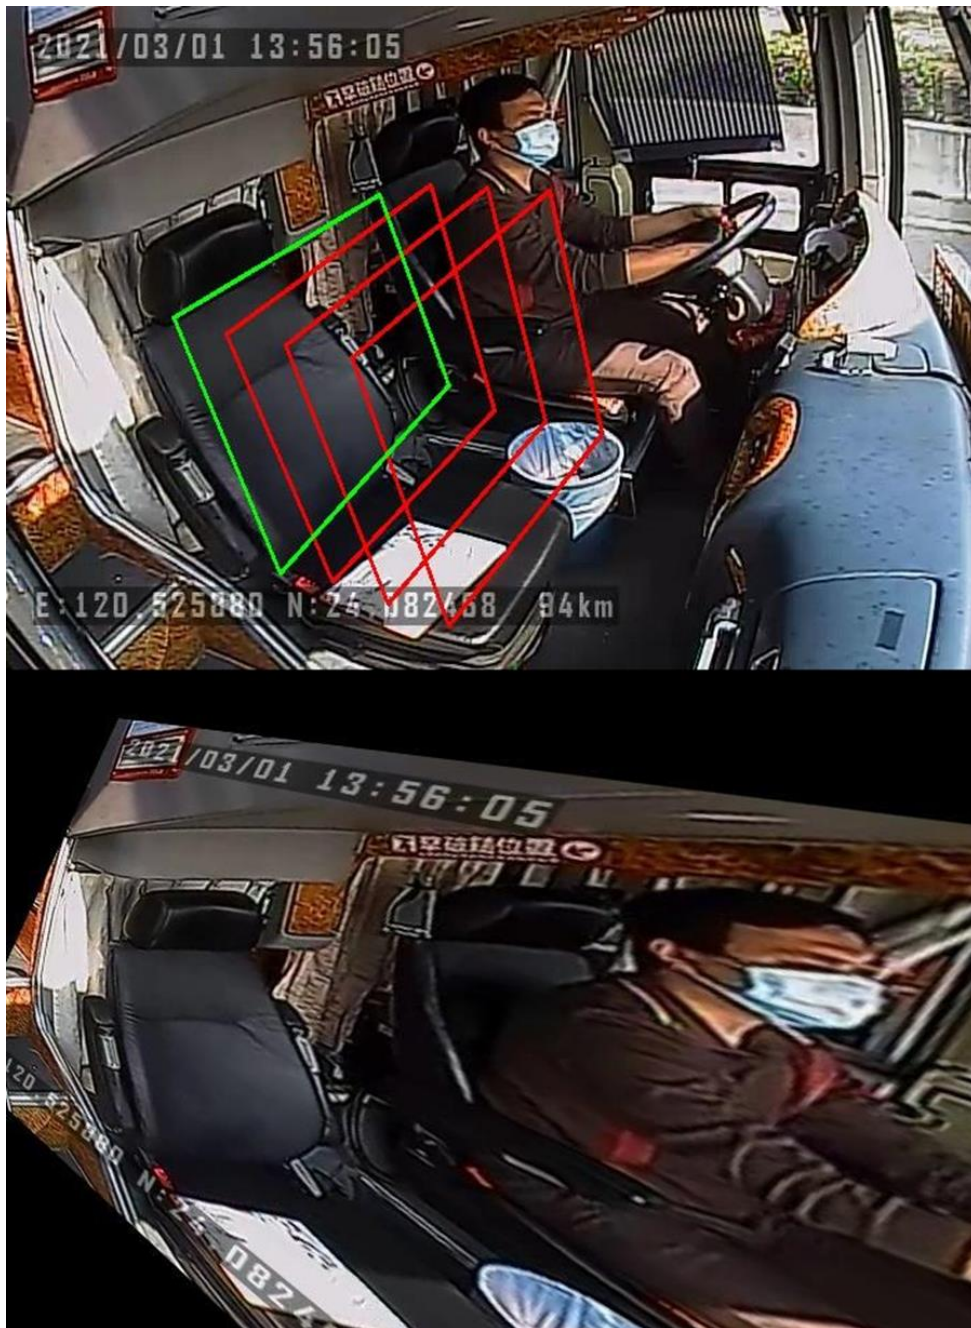


圖 6.2-4 車內影像轉正測試結果

6.2.2 關節點偵測穩定性的評估與比較

由於駕駛行為事件的判斷會使用關節點的資訊，所以分心事件判斷的正確性取決於關節點偵測的穩定度，因此以下針對關節點偵測較不穩定狀況進行分析與討論。

關節點辨識結果不穩定之判斷依據，以比較前後兩影格 (frame) 關節點位移量，總位移量太大代表偵測不穩定。觀察關節點為扣除腳部 (辨識上因遮蔽較困難且非本研究所需要資訊) 和左耳 (因鏡頭角度關係大多為遮蔽情況) 後的 12 個關節點。其分析計算方式為 12 個關節點分別計算和前一個 frame 之位移量後總和，其中若有關節點未偵測到則給予固定量的位移量處罰 (34)，總和之位移量超過一定門檻值 (100) 的 frame 認定為關節點偵測不穩定的 frame。一個事件中若有超過 10% 的 frame 關節點偵測不穩定，則稱之為關節點偵測不佳的事件。

目前標的事件合併後總計 2104 個事件，其中若使用 OpenPose 有 342 個事件被判斷為關節點偵測不穩定，所以 OpenPose 關節點偵測不穩定比例為 16.25%；而使用 YOLOv7 Pose 有 152 個事件被判斷為關節點偵測不穩定，YOLOv7 Pose 關節點偵測不穩定比例為 7.22%；而使用 YOLOv8 Pose 有 192 個事件被判斷為關節點偵測不穩定，YOLOv8 Pose 關節點偵測不穩定比例為 9.13%。而使用 ViTPose 有 66 個事件被判斷為關節點偵測不穩定，ViTPose 關節點偵測不穩定比例為 3.14%。由於 YOLOv7 Pose 和 YOLOv8 Pose 運行速度接近，而 YOLOv7 Pose 在關節點偵測能力上又優於 YOLOv8 Pose，所以在後續的分析比較中只會探討分析 YOLOv7 Pose 和 ViTPose 兩個關節點偵測網路表現。

分析 YOLOv7 Pose 與 ViTPose 和前期使用的 OpenPose 三者偵測不穩定事件重疊關係可以得到圖 6.2-5 結果。

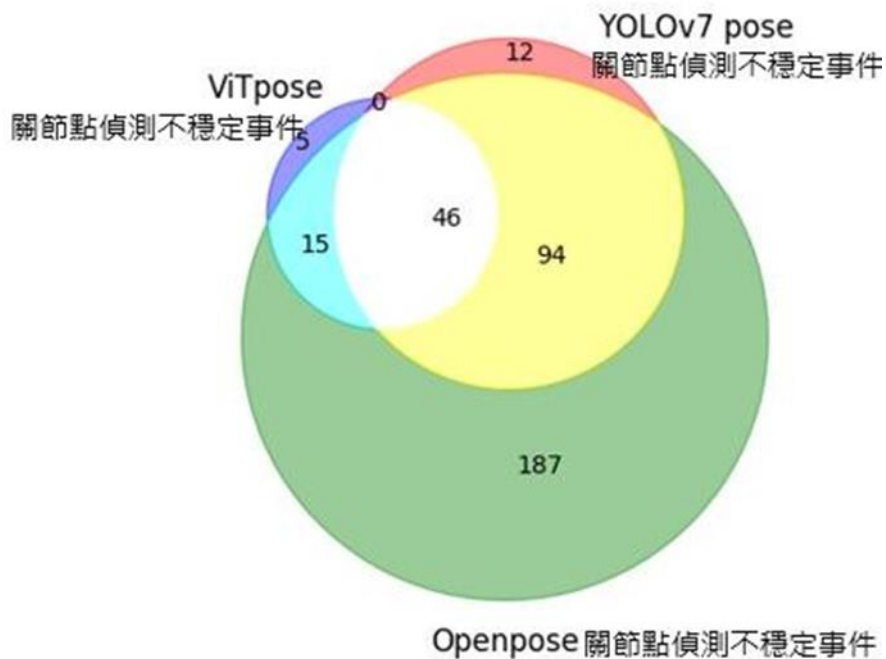


圖 6.2-5 駕駛關節點偵測不穩定的事件數量與重疊狀況

透過觀察關節點偵測不佳的事件時間分布可以歸納出，OpenPose 關節點偵測不穩定的事件比較多分布在晚上到半夜的時間，而 YOLOv7 Pose 的關節點偵測相較於 OpenPose 在除車輛 1 以外的車輛在夜間到半夜的時間段不穩定事件數有明顯減少，而車輛 1 的不穩定事件數則是比較平均，各個時間段都有減少。而 ViTPose 不再有夜晚時段較多不穩定的趨勢，較平均地分布在各時間段。如圖 6.2-6 所示。

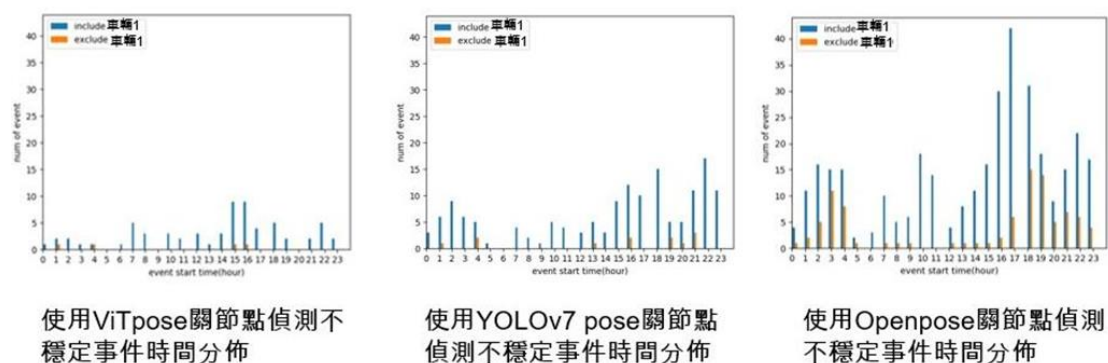


圖 6.2-6 駕駛關節點偵測不穩定的事件時間分布

透過觀察關節點偵測不佳的事件在各車分布可以歸納出，原始資料中各車事件數量分布平均，使用 OpenPose 偵測，偵測不穩定事件約四分之三集中在車輛 1，而使用 YOLOv7 Pose 或 ViTPose 偵測不穩定事件超過

90%集中在車輛 1，ViTPose 相較於 YOLOv7 Pose 各車不穩定事件較平均下降，數量約降為一半，如圖 6.2-7 所示。

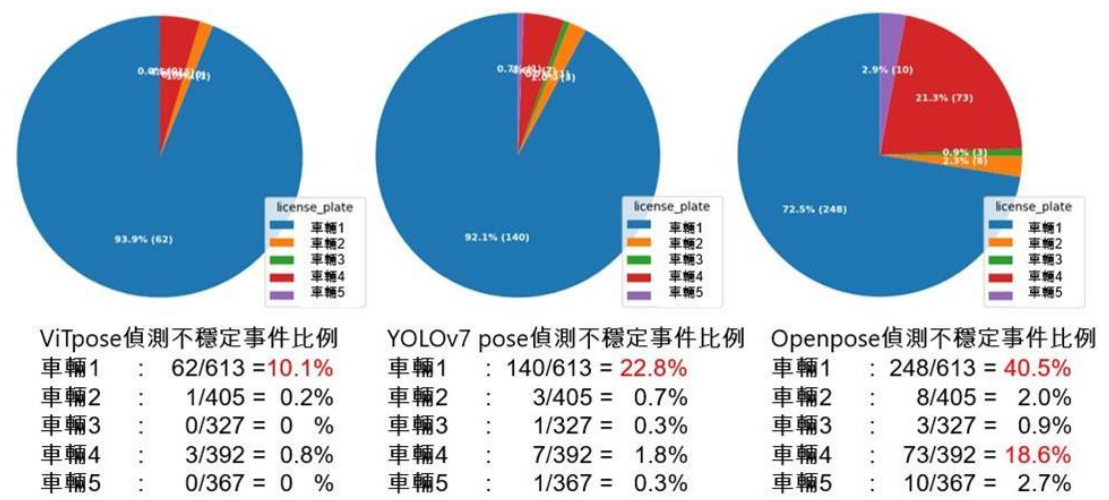


圖 6.2-7 駕駛關節點偵測不穩定事件各車分布比較

另外，從圖 6.2-7 中可以觀察到車輛 4 在改用 YOLOv7 Pose 或 ViTPose 後不穩定的事件數量明顯減少，進一步去分析這些改善的事件，發現其中大多是夜間 IR 畫面。夜間 IR 狀態下若司機的衣服變化性較低，身體容易變成一個色塊，較難分辨身體部位，YOLOv7 Pose 或 ViTPose 在處理這類狀況時，雖然正確性也會受到影響，但相對 OpenPose 跳動會比較少，如圖 6.2-8 的比較。



圖 6.2-8 駕駛關節點偵測在夜間 IR 狀態下的改善

6.2.3 針對關節點偵測不穩定的事件整理並分類因素

為了解可能造成關節點偵測不穩定的因素並觀察各因素發生的背景與頻率，以人工方式觀看 ViTPose 關節點偵測不穩定的 66 個事件，並紀錄其不穩定的因素與相關資訊，最後進行歸納並統計數據。

影響關節點偵測因素可以簡單歸納成以下六項：夜間 IR 影響、車內光線不足、駕駛衣著色彩較單一不易區分部位、較難辨識的駕駛動作、部分身體部位被遮蔽、副駕駛座有乘客且特徵較駕駛明顯。若是發生其中一項且特別嚴重，或是雖然沒有到特別嚴重但是受到複數項影響，就很可能造成關節點偵測不穩定。表 6.2-1 列出白天事件各車輛受到各因素影響的詳細統計數據，表 6.2-2 則是夜晚事件的數據。

表 6.2-1 車內關節點偵測不穩定事件影響因素各車統計-白天

車輛別	夜間 IR 影響	光線不足	駕駛衣著	駕駛動作	遮蔽	副駕駛座問題	事件數量
車輛 1	0	37	38	15	36	3	43
車輛 2	0	0	0	0	0	0	0
車輛 3	0	2	1	0	2	0	2
車輛 4	0	0	0	0	0	0	0
車輛 5	0	0	0	0	0	0	0
總計	0	39	39	15	38	3	45

表 6.2-2 車內關節點偵測不穩定事件影響因素各車統計-夜晚

車輛別	夜間 IR 影響	光線不足	駕駛衣著	駕駛動作	遮蔽	副駕駛座問題	事件數量
車輛 1	0	19	18	7	18	0	19
車輛 2	0	0	0	0	0	0	0
車輛 3	1	0	1	0	0	0	1
車輛 4	0	0	0	0	0	0	0
車輛 5	1	0	1	0	1	0	1
總計	2	19	20	7	19	0	21

其中副駕駛座有乘客且特徵較駕駛明顯案例如圖 6.2-9，在副駕駛座有乘客的情況下，雖然已經有用機制處理多目標之間跳動問題，但是在乘客的信心度比駕駛高太多的狀況，例如乘客衣服對比清楚且駕駛光線不足且衣著不明顯的情境，還是可能偶爾出現選錯目標的狀況。



圖 6.2-9 副駕駛座有乘客且特徵較駕駛明顯問題說明

由於一個事件可能受到複數個因素影響，所以可以進一步觀察各因素之間重疊狀況。這裡為了分析上的方便，將夜間 IR 影響、車內光線不足、駕駛衣著三項相依的因素合併為光線因素來進行分析。各因素的重疊關係如圖 6.2-10 所示，大部分關節點預測不穩定的事件都同時受到遮蔽和光線的影響，少部分事件主要受到光線或遮蔽其一影響，而駕駛姿勢相對影響相對較小。

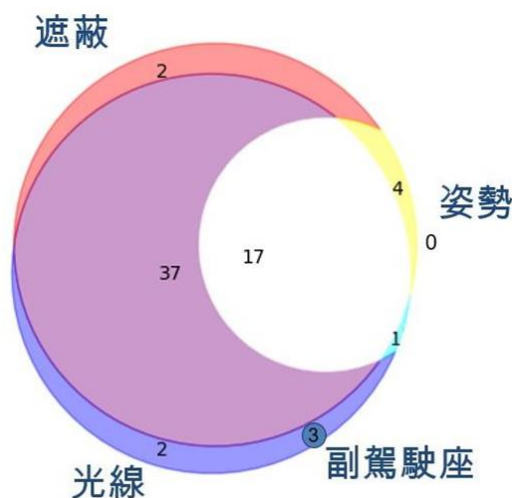


圖 6.2-10 車內關節點偵測不穩定影響因素之間的重疊關係

若從車輛別進行分析，66 事件中 4 個事件屬於車輛 2 到 5，其中 2 個是夜晚事件，2 個是白天事件。夜晚事件偵測主要受到 IR 與衣著關係影響，如圖 6.2-11 左方 2 位駕駛，白天事件 2 個事件則是身體部位被遮蔽，如圖 6.2-11 右方的 2 位駕駛。

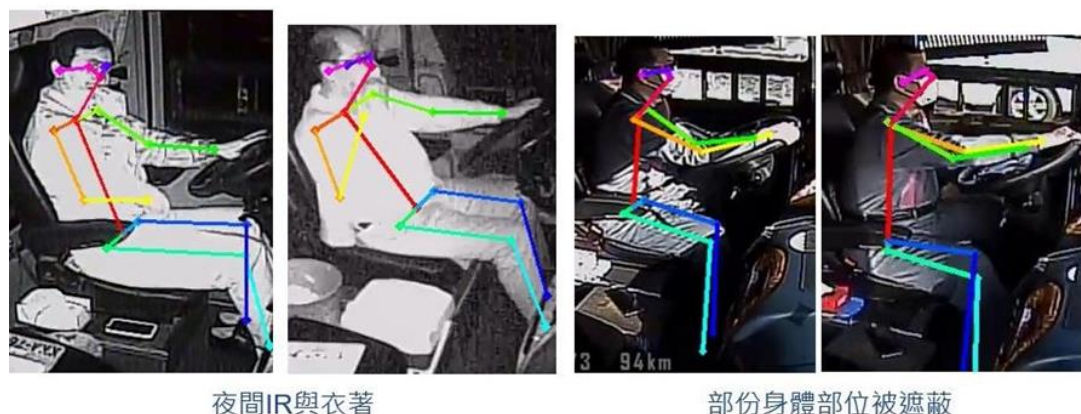


圖 6.2-11 車內關節點偵測不穩定影響因素分析-車輛 2 到 5

比較本期前半年使用的偵測網路 YOLOv7 Pose 和後半年的 ViTPose 造成不穩定事件的原因統計數據，比較結果如圖 6.2-12，各原因數量大致上降低的幅度都差不多，約為 YOLOv7 Pose 的二分之一到三分之一，但相對的 ViTPose 所需要的計算時間也會比較久，此節說明詳如於 6.2.6 節。

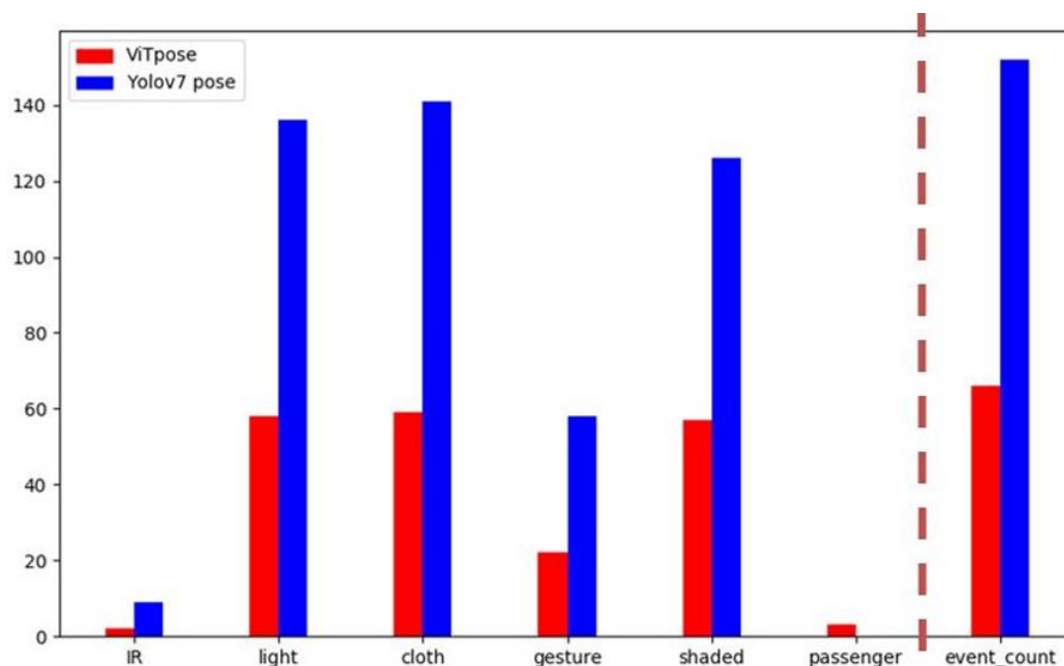


圖 6.2-12 車內關節點偵測網路 ViTPose 相較於 YOLOv7 Pose 不穩定事件的原因數量比較

6.2.4 造成車內關節點偵測不穩定的各因素說明與可能改善方式

本節針對前面提到的影響關節點預測的六個因素：夜間 IR 影響、車內光線不足、駕駛衣著色彩較單一不易區分部位、較難辨識的駕駛動作、部分身體部位被遮蔽、副駕駛座有乘客且特徵較駕駛明顯，個別描述造成影響的原因並提出範例以及可能的改善方式。其中「副駕駛座有乘客且特徵較駕駛明顯」一項起因於駕駛位置相對光線不足與駕駛衣著問題，因此不單獨探討。

(一)夜間 IR 影響

由於夜間 IR 太強造成身體變成一個亮色塊，無法區分身體部位，通常是因為右手手肘會融入身體的背景中，導致右手位置判斷不正確，共影響全部 66 件事件中的 2 件。只有部分受到 IR 影響的情境，例如手肘部分無法區分但是有看到手部的狀況，如圖 6.2-13 左側駕駛，ViTPose 在這樣的情境可以一定程度推論右手位置。但是如果是連手部都無法區分或是雖然可以稍微看到手部但資訊不足，如圖 6.2-13 右側駕駛，就無法正確偵測，應只能透過硬體設備改善，例如更換相機或行車影像記錄系統。



圖 6.2-13 夜間 IR 對車內關節點偵測影響

(二)車內光線不足

由於光線不足車內較昏暗，或光線時有時無，造成偵測困難。主要是在車輛 1 發生，共影響全部 66 件事件中的 58 件。亮度有點不足但勉強可以分辨身體部位線條的狀況，如圖 6.2-14 左側駕駛，ViTPose 在這樣的情境已經改善。但是如果是車內光線嚴重不足，人

眼都很難區分身體部位的狀況，如圖 6.2-14 右側駕駛，就無法正確偵測，應只能透過硬體設備改善，例如更換相機或行車影像記錄系統。

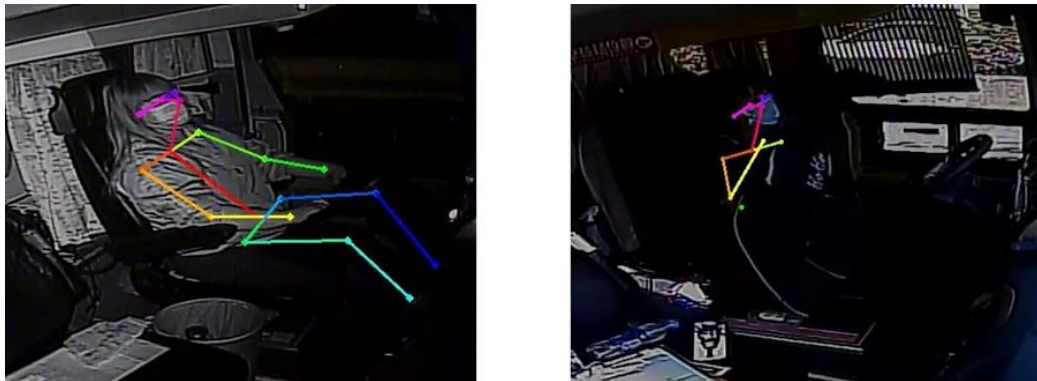


圖 6.2-14 車內光線不足對車內關節點偵測影響

(三) 駕駛衣著色彩較單一不易區分部位

由於駕駛穿著顏色較單一或是過於深色導致身體部位不易區分，通常都是隨著光線或是 IR 問題產生，例如同時光線不足而且駕駛衣著較深色就會很難偵測。駕駛衣著因素共影響全部 66 件事件中的 59 件。衣著深色但光線還算充足，如圖 6.2-15 左側駕駛，ViTPose 在這樣的情境已經改善。但是如果是同時光線不足而且駕駛衣著較深色的狀況，甚至駕駛將外套披著或是反穿，如圖 6.2-15 右側駕駛，基本上人眼也難以確認，就無法正確偵測，應只能透過駕駛衣著改善，例如指定制服，如手部和身體顏色不同的背心或是衣服上有一些顯眼的線條都有幫助。



圖 6.2-15 駕駛衣著對車內關節點偵測影響

(四)較難辨識的駕駛動作

部分駕駛動作對偵測來說較為困難，共影響全部 66 件事件中的 22 件。比較沒有造成自我遮蔽的動作，如圖 6.2-16 左側駕駛手放在窗沿的這個動作，ViTPose 在這樣的情境已經改善。但是如果是明顯有造成自我遮蔽的動作，如圖 6.2-16 右側駕駛，會有部分身體部位看不到，就無法正確偵測。

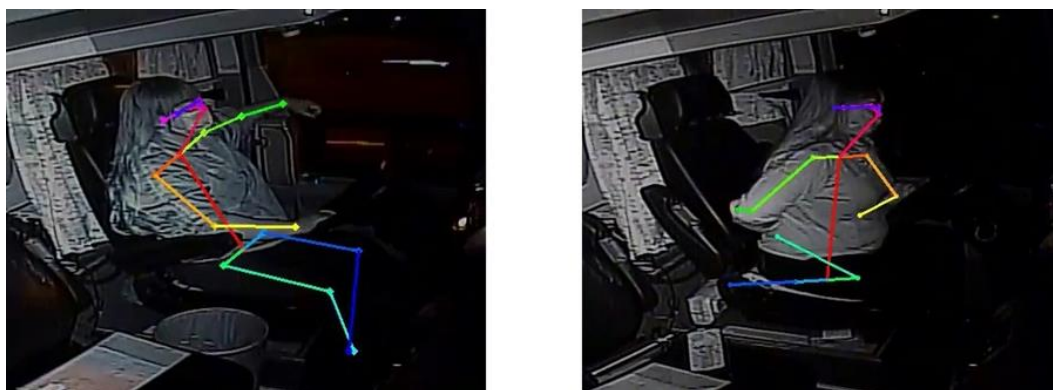


圖 6.2-16 較難辨識駕駛動作對車內關節點偵測影響

(五)部分身體部位被遮蔽

由於駕駛部分身體部位被自己或其他物件遮蔽，通常是左半身被遮蔽，導致關節點實際位置無法得知，共影響全部 66 件事件中的 57 件。如果只有比較小範圍身體中段的遮蔽，如圖 6.2-17 左側駕駛，ViTPose 在這樣的情境已經改善。但是如果是比較大範圍的遮蔽，如圖 6.2-17 右側駕駛左半身都被遮蔽，左半身沒有任何資訊，偵測網路可能會猜測左手在任何地方，這樣的狀況應只能透過硬體設備改善，例如將相機架設位置從側方往駕駛前方方向移動。

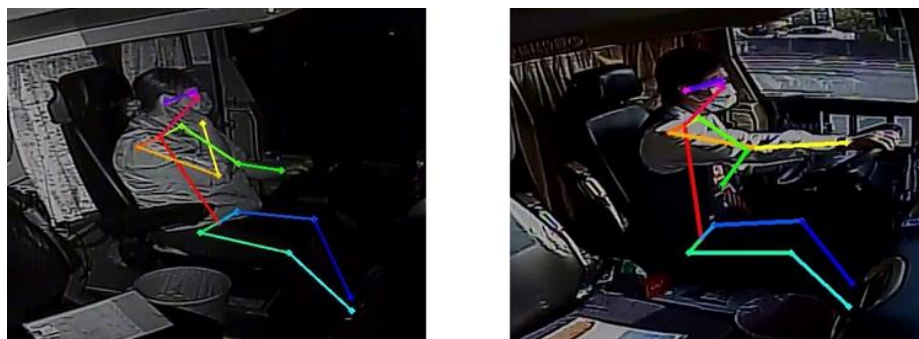


圖 6.2-17 部分身體部位被遮蔽對車內關節點偵測影響

6.2.5 新樣本影片觀察模型改善效果

為避免過於聚焦在前述五輛車，本期研究也針對排除前述五輛車的新樣本影片進行測試，觀察改善後模型偵測能力。針對額外的 15 輛車(稱作車輛 6 至車輛 20)，每輛車平均測試 30 個事件片段，每個片段平均長度 66.7 秒。依 6.2.2 節提到的標準進行關節點辨識結果穩定判斷。總計 446 個事件，使用 ViTPose 有 13 個事件被判斷為關節點偵測不穩定，所以關節點偵測不穩定比例為 2.91%。統計各車輛關節點偵測不穩定的數量可以得到圖 6.2-18。

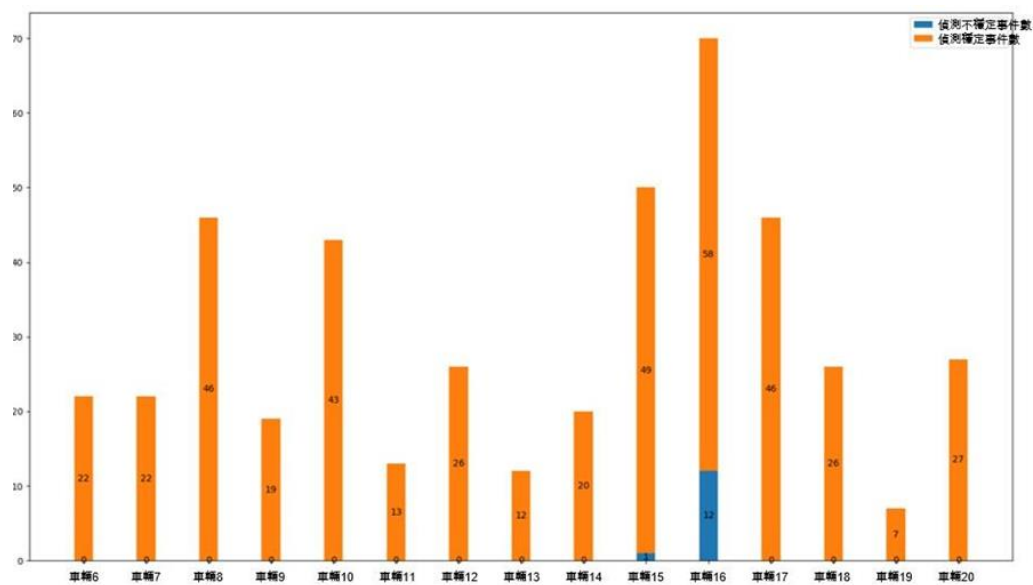


圖 6.2-18 車內新樣本影片中各車輛關節點偵測不穩定的數量

深入觀察偵測錯誤的事件，有 1 件發生在車輛 15，發生原因是駕駛左手被自己遮蔽無法看出正確位置，剩餘 12 件發生在車輛 16。車輛 16 的相機 IR 功能或是濾光片自動切換功能沒有正確開啟，導致在光線不足的時候(夜間)畫面就會很暗且雜訊很多無法辨識，如圖 6.2-19 所示。



圖 6.2-19 車內 IR 或是濾光片自動切換功能沒有正確開啟的車輛成像

6.2.6 車內駕駛分心行為偵測所需時間

本節計算車內駕駛分心行為偵測所需要的時間，測試的輸入影片影格速率為 25 FPS，輸入畫面大小為 704x480。測試的硬體環境：CPU 使用 Intel i7-7700，GPU 使用 NVIDIA GeForce GTX 1080 Ti。所需要的時間計算結果紀錄在表 6.2-3，單位為每一分鐘的原始影片需要多少分鐘的處理時間。其中方向盤位置偵測一項因為所需時間較久，且一般情況下在駕駛過程中不會去調整方向盤位置，所以是每 10 個影格偵測一次，再將整個事件的偵測結果進行平均做為方向盤位置。

表 6.2-3 車內駕駛分心行為偵測所需要的時間

	YOLOv7 Pose	ViTPose
偵測關節點位置	0.7500 (分鐘)	4.7500 (分鐘)
關節點資訊格式轉換	0.0030 (分鐘)	0.0030 (分鐘)
方向盤位置偵測	0.5770 (分鐘)	0.5770 (分鐘)
手機物件偵測	0.6500 (分鐘)	0.6500 (分鐘)
加上分心行為判斷機制並整理成 csv 檔 (無實際時間)	0.0650 (分鐘)	0.0650 (分鐘)
辨識影片畫面上的時間資訊(OCR)	0.2650 (分鐘)	0.2650 (分鐘)
加上實際時間 csv 檔	0.0003 (分鐘)	0.0003 (分鐘)
加總	2.3103 (分鐘)	6.3103 (分鐘)

雖然以 ViTPose 進行關節點偵測相較於使用 YOLOv7 Pose 會得到比較準確的結果，但是相對也需要比較多的時間，這部分可能視需求而進行取捨。

6.3 影像辨識結果討論與建議

由於本計畫自第一年起以客運業者安裝之「行車視野輔助系統」錄製之行車紀錄影片進行車外與車內影像辨識與風險行為分析。市面上販售之「行車視野輔助系統」的基本架構大致為四支攝影機（分別拍攝：車前、車外左側、車外右側、車內駕駛）、7吋液晶螢幕與一台數位錄影主機，以成套方式進行銷售，其售價金額介於新台幣 5,000 元至 10,000 元間。在目前管理條例中其規定規格如下所述：

- (一)攝影鏡頭解析度高於 640x480 像素 (pixels)，且照度應優於 1 lux，訊號/雜訊比不得低於 40 分貝 (dB)，並使攝影之影像能清晰顯示於螢幕。
- (二)攝影鏡頭動態範圍值大於 70 分貝 (dB)。
- (三)本輔助系統之運作，不受磁場或電場之不良影響。
- (四)系統由車輛本身進行供電，各項功能應於每次車輛啟動時自動開啟，且不得設置手動關閉裝置。

因此本計畫從第一年起至今於影像辨識之挑戰在「低解析度」與「成像品質較差」之行車紀錄影片上以深度學習技術盡可能達到人類肉眼視覺能辨識之能力效果。從上述車內外影像辨識實驗結果可得知本年度目前實驗成果相較前兩年有顯著提昇，然而仍有目前技術無法辨識情境成像品質則為其限制，即便是人類肉眼視覺仍難從影片觀察辨識出。不論車輛前裝或後裝市場，「行車視野輔助系統」產品並非「先進駕駛輔助系統」所定義之產品，因此對於攝影機與數位錄影系統並未有其較嚴格之要求規範。但若為協助客運業者與車隊管理業者提昇在駕駛風險行為分析管控之品質，本計畫提出一版軟硬體規格建議如表 6.3-1 所示：

表 6.3-1 建議「行車視野輔助系統」規格

影像解析度(Pixel)	1280×720
動態範圍 (dB)	大於 70 dB
可視角度 (Degree)	水平：120 垂直：50
對焦範圍 (Meter)	1 to ∞
影像幀率 (FPS)	30
視訊編碼	H.264
快門類型	Rolling Shutter

6.4 小結

在行車影像辨識技術部份，本年度持續以深度學習技術為基礎，導入新型物件偵測模型，發展車內外影像辨識與駕駛行為分析研究。本年度所導入的新型物件偵測模型計有 YOLOv7、YOLOv8、ViTPose。從實驗結果來看，YOLOv7 和 YOLOv8 的辨識正確度與辨識速度相近。相較於 YOLOv7 或 YOLOv8，ViTPose 具備較為準確的辨識結果，但需較長的辨識處理時間。因此建議可從「辨識正確度」或「辨識速度」的使用需求，選擇相對應的辨識方法。

第七章 高風險駕駛行為與行車異常事件之時空分析

本期計畫延續前期之車外警示與行車異常事件、車內影像資料，並基於將業者之智慧車載設備進行第 I 至 IV 類分類定義，結合迄今三期陸續蒐集之資料，分別說明在擁有不同設備或資料來源時可進行之分析，以及模式建構之結果。不同分析程度與目的係考量各業者所安裝之車載系統功能不盡相同，亦可對應不同模式建構與分析應用。此外，透過智慧車載設備所蒐集之駕駛行為資料(如：車速、加速度與剎車等)，初步將第四章所歸納定義之高風險駕駛行為納入時空分析，並說明後續延伸至僅 OBD、GPS 資料時之分析構想。

7.1 時空分析架構與資料庫說明

車載資訊系統包含最基本之車機資料紀錄車速、加速度與剎車、GPS 資料，至有車外 ADAS、車內視野等不同程度之輔助設備，又可再透過外部資料嫁接進行更全面之分析。本計畫將資料類別分為四大類，如表 7.1-1。基本上，可依照資料內容進行不同程度之分析，且可視情況進行微調，當資料愈趨完整，則可應用之變數愈多。

表 7.1-1 各類型業者管理系統特徵彙整

管理系統類別	特徵
I	無 ADAS 系統；有 OBD、GPS
II	無 DMS；有 OBD、GPS、ADAS
III	無外部環境資料；有車內影像系統且與 ADAS 整合
IV	有外部環境資料，可加入天候、道路與車流狀況資料

從基本的第 I 類係基由 OBD 資料紀錄車速、加速度，並整合 OBD 以連結地點、幾何資訊，透過全程資料逐秒蒐集，爾後亦可切割合理空間長度分段(似趟次分析之概念)，與高風險駕駛行為結合分析。第 II、III、IV 類則再透過影像辨識篩選出警示事件中達到行車異常事件等級之資料，依照所定義之資料涵蓋內容，進一步探討各項行為特性與行車異常事件發生之關聯性，據以歸納可能造成行車異常事件發生的高風險駕駛行為。

意即，透過行車影像辨識技術與影像資料之整合，預計警示與行車異常事件之樣本與資料欄位將增加或擴大。雖前期已有針對車內外行車異常事件進行初步時空分析，7.3 節初步將以影像辨識所增加之車內影像資料結合高風險駕駛行為，以及車外周遭車流狀況資訊，對警示事件進行初探，找出事件與高風險駕駛行為之關聯，並向下延伸至 OBD 為主之資料後續可能擴充應用之構想。

圖 7.1-1 為時空分析架構圖，其中底色為黃色處，為本年度所新增初探分析，另包含灰底色處包含以 OBD、GPS 對應國道幾何資料、班表資訊為主，所預計後續分析之以各事件為單位，或依各趟次於單位空間下高風險駕駛行為好發之時空環境分析。以及巨觀分析下，以司機特性進行分析之模式。

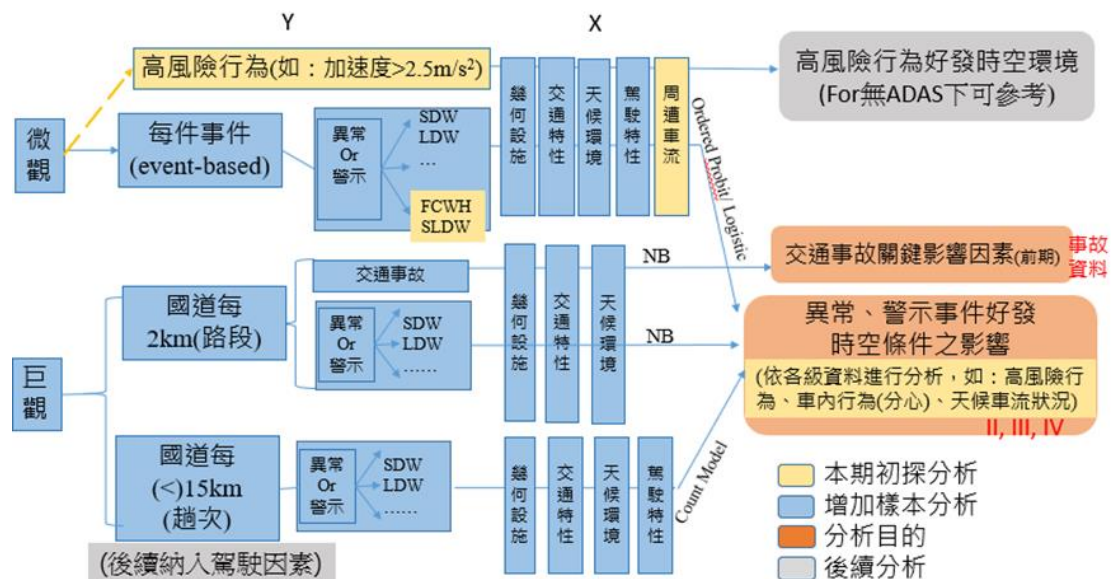


圖 7.1-1 時空分析架構圖

另外，前期事件分析，以及趟次分析之單位中，有因事件類型樣本數過少無法建立計數模式；或零占比過高，即發生異常、警示事件與高風險駕駛行為次數甚少，無法建立負二項迴歸，而採羅吉斯迴歸分析。本年度再擴大蒐集資料，事件分析部分新增 FCWH、SLDW 兩類警示之樣本，使發展計數模式；另趟次分析部分，後續預計以司機區分為單位分析，先列出可能以計數模式分析，後續依資料型態決定，目前則相較於前期透過羅吉斯模式分析(有無在分析空間長度中發生警示)，本年度以零膨脹模式(紀錄發生頻次次數)初探。

底色為藍色部分則相較前期計畫，透過前述原因增加個別類別之事件樣本數時，同步將增加總樣本數，因而既有項目可擴大分析。且本年度增加客運公司台北(板橋)往返高雄地區之路線，可蒐集西部路廊主要區段之資料，分析事件好發之時空特性更為完善。同時，擬透過車載資訊系統，整理車內外影像的更多資料欄位，因此針對異常或警示事件之事件類型分類建模分析，可更加精進。圖中除列出各項時空分析之模式與分析目的外，亦在旁列出其可對應之資料類別等級，此亦可做為若後續分析之使用者擁有不完全相同於下方架構或表 7.1-1 時，仍足以自行判斷並進行分析之用，於後逐一進行呈現。

針對前述分析架構，包含所提及擴充樣本部分，本年度所採用之資料樣本包含前 2 期計畫已蒐集 350 趟次大客車行駛路線外，並再增加 2023 年 5 月間，包含臺北或板橋，往返臺南或高雄，8 種路線組合近 400 趟次相同業者路線之警示資料，總資料庫現已整理 700 餘趟警示事件資訊。

以上資料擴充確保納入車內異常行為與車外警示事件之樣本能較為充足，並針對數量較少的高速接近前車(FCWH)與嚴重車道偏移(SLDW)足數進行單一事件異常程度之分析建模。由於市區道路路況較為複雜，研究範圍與樣本蒐集仍以國道一號行經路段進行紀錄，但隨著路線不同，將由 27K 至 367K 中，該車輛所行經區間進行分析。樣本蒐集時間範圍則為第一期 2021 年 3 月與 6 月，第二期 2022 年 4 至 6 月期間，本期 2023 年 5 月期間之樣本。有關資料庫建置之規劃與說明則羅列如下：

(一)資料庫基本說明

本計畫針對車外 ADAS 警示事件發生時，車外紀錄蒐集基本資料欄位；為滿足時空分析與警示之額外功能，可依照設備架構對車內影像紀錄與否，而彈性增加欄位，透過後續可由人工或影像辨識車內分心行為、警示發生時車外狀況與駕駛因應行為等。即整合資料庫以每件車外 ADAS 警示事件做為樣本。而前述巨微觀三類型之分析所需之交通與幾何資料之尺度各有相似與相異處，以下分別進行簡介。

單一的 ADAS 警示事件包含發生時間與類型、CAN 資料庫之車輛動態相關數據，當有車內影響支援時，追加紀錄駕駛因應、分心行為(警示前、中、後)。此外，依照其單一事件之微觀基礎，整合當班次之駕駛資訊，如：駕駛年資、排班趟次、發車時段、天氣狀況，並依照發生地點介接該地點國道幾何資訊、當下車流資訊。其中，駕駛因應(可分辨警示事件異常程度)與車內(分心等)行為，前兩期係由人工登記真值，本期則僅在有目的性擴充 FCWH 與 SLDW 樣本時，進行人工真值辨識，其他類型則無針對此 ADAS 警示再做相關分級紀錄(未來可能由影像辨識進行標記分級)。因此，本年度後續針對單一事件分析時，增加的 400 趟次僅有 FCWH 與 SLDW 對分級樣本有樣本擴充之用；其餘未分級者，則只能反映在已經整合至巨觀的趟次與路段模式(單純反映警示事件發生次數)。

在單一事件之上，再針對巨觀的趟次分析與路段分析，分別將國道 27 至 367K 範圍依照前期資料整理所得出最適建議，分別以 15 公里與 2 公里決定分析路段長度，再透過單一事件資料進行加總整合，將欄位資訊進行整理。趟次分析因考量駕駛路線，並納入駕駛人該趟次之排班工作狀況，紀錄每一趟次在分析長度中是否發生警示、異常、分心行為，駕駛特性依然保留，而因分析長度擴大，將當下幾何、車流、天氣等資訊依照路段長度整合(例如分析單位內，最大坡度、交流道數等)。其中，本年度觀測與擴充樣本並未全數進行車內標記，因此樣本數大量增加，但以討論警示數量為主，巨觀分析不再討論前期著重之分心行為發生數量。

最巨觀之路段分析則側重於駕駛事件好發的道路交通環境。將一定長度做為分析單位，主要蒐集為長期固定之幾何條件(最大坡度、車道數、最小內外側路肩寬、是否有彎道等)、鄰近設施(服務區、交流道、開放路肩、測速照相等)，及以月為單位之交通量、車種比例、雨量資料，並不涉及駕駛特性資訊。也增加較多該段路段中幾何資訊，包含該段中路肩、彎道、坡度等巨觀資訊。

(二)資料庫架構

本計畫以日常行車環境、駕駛行為等因素，預先定義出與事故發生具有高度相關的事故前兆或高風險駕駛行為，進而依據不同類型高風險駕駛行為研擬改善方案，為了能夠滿足分析需求、未來平臺的加值運用，本計畫建立一資料庫，蒐集模型開發所需之相關資料，該資料透過程式清洗並整理成分析所需相關資料，依分析需求產出本計畫之整合資料庫，其架構如圖 7.1-2、圖 7.1-3 所示，針對事件好發路段、甚至是車內駕駛行為，或供後續時序判別或 GIS 等應用，進行分析所用，本計畫使用資料來源如下：

1. 高速公路局

(1) VD 靜態資料：VD 編號、公里數等資訊

(2) 5 分鐘即時/歷史交通量資料：VD 編號、交通量、速率
(2022 年 12 月起改為 1 分鐘資料，需預先進行整理)

(3) 設施特性資料

(4) 國道幾何資料

2. 客運業者

(1) 車機紀錄資料：行駛時間、行駛距離、警示事件

(2) 班表資料：駕駛資料、班次資訊

(3) 車內影像資料：發生時間、駕駛行為、駕駛反應、當下天氣、降雨與光線等狀況

依上所述為現階段離線資料庫所需資料表，以及處理過程與下方所示之產出示意圖。若為當下之車流交通，於路段、趟次分析所需時，再進行平均、加總之處理。

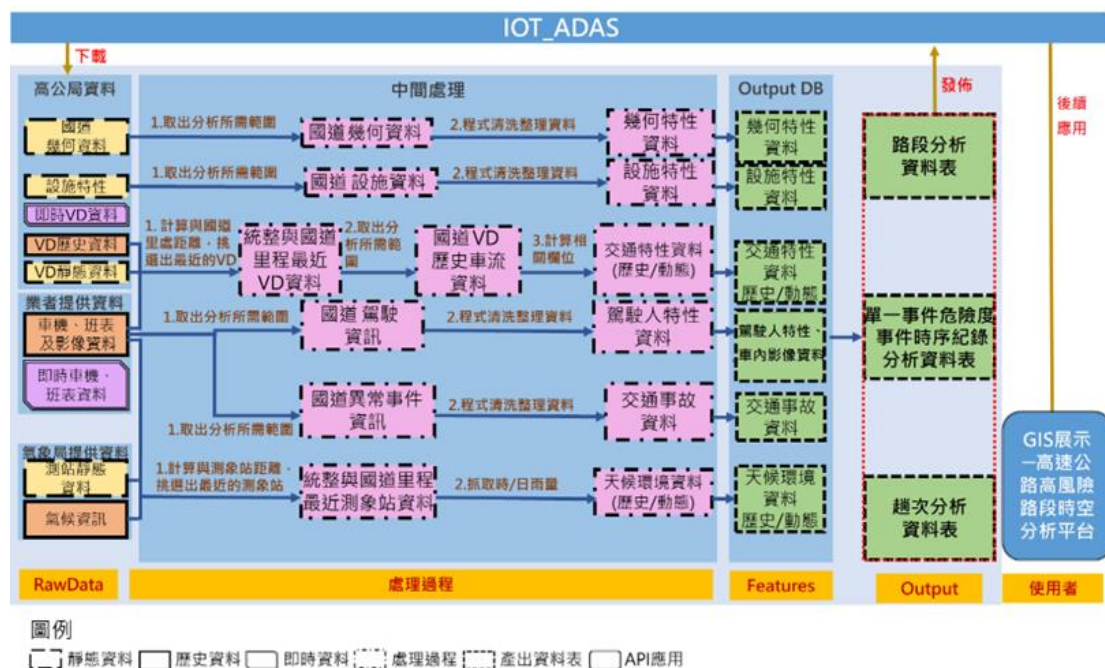


圖 7.1-2 資料庫架構設計示意圖

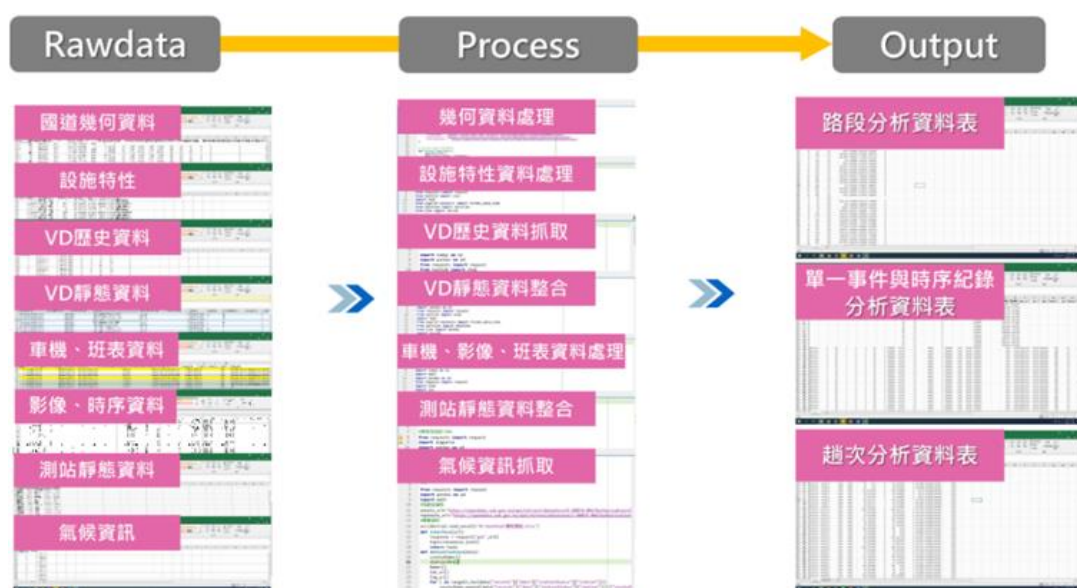


圖 7.1-3 資料庫建構流程示意圖

本計畫預期產出資料依照分析模式分為 3 大項：路段分析資料表、趨勢分析資料表，單一事件分析資料表，整合資料庫欄位說明如表 7.1-2 所示。針對車機、班表資料主要是依行經之班車決定，前期則已針對車內影像紀錄車內行為增加相關欄位資料。氣象資料在單一事件與趨勢分析下依照車機所紀錄天氣狀況進行紀錄較為準確，在路段資料則以氣象局之月雨量進行記載。VD 資料則會依空間尺度不同而改變，於路段、趨勢

分析下，車流採定義區間內所有 VD 資料再進行處理；於單一事件分析資料，車流只採最近 VD 資料。另外，國道幾何資料也與分析單位大小而有差異。

表 7.1-2 整合資料庫主要欄位定義說明

資料來源	項次	欄位名稱	說明	型態	長度
國道幾何資料	1	彎道半徑	以公尺為單位	FLOAT	
	2	最大上坡度	特定範圍內最大上升公尺數(m/100m)	FLOAT	
	3	最大下坡度	特定範圍內最大下降公尺數(m/100m)	FLOAT	
	4	車道寬	以公尺為單位，取小數一位	FLOAT	
	5	車道數	不含爬坡車道數	INT	
	6	路肩寬	以公尺為單位，取小數一位	FLOAT	
VD 歷史資料	7	平均每日交通量	當月不分車種平均交通量	FLOAT	
	8	小車比例	小車數佔小客車當量數比例	FLOAT	
	9	大車比例	大車數佔小客車當量數比例	FLOAT	
	10	聯結車比例	聯結車數小客車當量數比例	FLOAT	
	11	五分鐘交通量	特定 VD 五分鐘小客車當量數	FLOAT	
	12	平均速度	特定 VD 偵測平均速度(Km/Hr)	FLOAT	
設施特性資料	13	速限	路段速度限制(Km/Hr)	INT	
	14	速限座標	經緯度(WGS84)	FLOAT	
	15	服務區、休息站	服務區、休息站名稱	NVARCHAR	(500)
	16	服務區、休息站座標	經緯度(WGS84)	FLOAT	
	17	固定式測速照相	固定式測速照相編號	NVARCHAR	(500)
	18	固定式測速照相座標	經緯度(WGS84)	FLOAT	
	19	交流道	交流道名稱	NVARCHAR	(500)
	20	交流道公里數	交流道公里數(Km)	INT	
氣象局測站資料	21	月平均雨量	當月平均雨量(mm)	FLOAT	
	22	天氣狀況	事件發生當下晴雨狀況	NVARCHAR	(500)
	23	日夜	事件發生當下日夜情形	NVARCHAR	(5)

表 7.1-2 整合資料庫主要欄位定義說明 (續)

資料來源	項次	欄位名稱	說明	型態	長度
車機、班表資料	24	行駛時間	完成旅次花費的時間	FLOAT	
	25	行駛距離	完成旅次行駛的距離	FLOAT	
	26	發車時間	特定旅次起程時間	DATETIME	
	27	發車時間時段區分	分為五時段，含凌晨、晨峰、白天、昏峰、晚上	NVARCHAR	(5)
	28	班表星期	平假日	NVARCHAR	(5)
	29	旅次方向	旅次行經方向(S,N)	NVARCHAR	(1)
	30	駕駛員排班 24 小時內趟次數	特定駕駛 24 小時內負責班次數	FLOAT	
	31	駕駛員排班 72 小時內趟次數	特定駕駛 72 小時內負責班次數	FLOAT	
	32	駕駛員排班 168 小時內趟次數	特定駕駛 168 小時內負責班次數	FLOAT	
	33	駕駛年齡	行車駕駛年齡	INT	
	34	駕駛年資	行車駕駛年資	FLOAT	
	35	警示事件	警示事件類型	NVARCHAR	
影像資料	35	主序列	依照不同警示事件，將觸發警示之情境分類	NVARCHAR	(5)
	36	副序列		NVARCHAR	(5)
	37	駕駛因應	警示發生時加減速與移動綜合判斷	INT	
	38	是否分心	發生警示事件前 15 秒至發生警示時是否有分心或其他動作	INT	
	39	雙手離開方向盤	警示發生時駕駛人動作	INT	
	40	單手離開方向盤	警示發生時駕駛人動作	INT	
	41	身體前傾	警示發生時駕駛人動作	INT	
	42	身體右傾	警示發生時駕駛人動作	INT	
	43	擺頭	警示發生時駕駛人動作	INT	
	44	操作車內設備	警示發生時駕駛人動作	INT	
	45	拿東西	警示發生時駕駛人動作	INT	
	46	使用手機	警示發生時駕駛人動作	INT	
	47	手接近嘴部	警示發生時駕駛人動作	INT	

3 種模式路段與幾何變數之差異，將經過資料庫基本變數紀錄後再依照分析需求，以表 7.1-3 所示。由於警示事件係由車載 ADAS 系統以事件為單位，表 7.1-2 中所整理資料庫之欄位，若為駕駛動作、該車輛、周遭車流與幾何資訊相關，則取當下時間地點所對照之數值；若為趟次基礎

之資料，則以該切割 15 公里路段中，針對交通、幾何特性取極值或計算區段內總數量，但由於考量一定路段長度，最即時的當下車速、已行駛時間則未能納入。再至路段基礎之分析，為所有蒐集資料時間內，該 2 公里路段所集合之所有事件，因此交通量、降雨量、車種組成比例等皆以加總 aggregate 之方式呈現，且排除各趟次班表、司機駕駛當下的資訊。詳細則依照路段、趟次、事件分析，逐一說明於 7.4 節。

表 7.1-3 分析模式與整合資料庫變數關係

項目類型	路段基礎(2km)	趟次基礎(15km)	單一事件基礎
幾何特性			
最小路肩寬(公尺)	O	O	X
最大車道數	O	O	X
最大坡度(%)、坡道	O	O	O
彎道	O	O	O
交通環境特性			
總交通量(pcu)	O(月)	O(通過時段)	O(5 分鐘)
降雨量(mm)/有無降雨	O(月)	O(有無降雨)	O(有無降雨)
車種比例	O(月)	X	O(5 分鐘)
當下車速(kph)	X	X	O
旅次方向	X	X	O
夜間	X	X	O
設施特性			
速限(=110kph)	Y/N	X	X
固定式測速照相	Y/N	X	X
開放路肩	Y/N	Y/N	X
服務區	Y/N	Y/N	X
交流道	Y/N	數量	X
駕駛特性			
班表星期	X	O	O
24 小時內趟次	X	O	O
72 小時內趟次	X	O	O
168 小時內趟次	X	O	O
發車時段區分	X	O	O
資歷	X	O	O
該趟次已行駛時間(min)	X	X	O
是否分心、車內動作	X	O(若有車內影像)	O(若有車內影像)

7.2 時空變數應用說明與樣本數量統計

如前述，本年度將車載系統資料分為 I 至 IV 類，可對應不同車載系統設備，進行不同類型的分析目的與監管建議。實務應用上，則可依照 ADAS 資料支援程度以及分析目的，進行適度的外部資料勾稽。延續 7.1 節說明資料庫資料部分，表 7.2-1 說明累積三年期資料各自紀錄欄位。

表 7.2-1 三年期間 ADAS 警示資料分析欄位

項目類型	第一年期 樣本數：2,181	第二年期 樣本數：1,408	第三年期(車內 行為有標記) 樣本數：318	第三年期(車內 行為未標記) 樣本數：6,312
幾何特性				
最大坡度(%)、坡道	O	O	O	O
彎道	O	O	O	O
交通環境特性				
當下交通量(pcu)	O	O	O	O
有無降雨	O	O	O	O
車種比例	O	O	O	O
當下車速(kph)	O	O	O	O
旅次方向	O	O	O	O
夜間	O	O	O	O
駕駛特性				
班表星期(假日)	O	O	O	O
24 小時內趟次	O	O	O	O
72 小時內趟次	O	O	O	O
168 小時內趟次	O	O	O	O
發車時段區分	O	O	O	O
資歷	O	O	O	O
該趟次已行駛時間(min)	O	O	O	O
車內行為、事件時駕駛因應				
是否分心	O	O	O	X
車內動作	O	O	O	X
其他項目(註)				
	初增警示前 後 OBD 與 ADAS 周遭車流環境資 料			
本年度分析項目樣本建構				
路段	O	O	O	O
趟次	O	O	O	O
單一事件	O	O	O	X

其中，為增加單一事件中 FCWH、SLDW 之樣本，使此類較為嚴重但頻次較少之警示類型，可以透過其駕駛因應行為適當與否，使警示事件異常程度分級，進行好發時空環境分析，故本年期資料分為標記車內行為與否。參考圖 7.2-1，則呈現經整理後，本年度分析路段、趟次、事件資料所採用之各項子資料庫項目以及資料庫目前與後續可進行之分析架構。

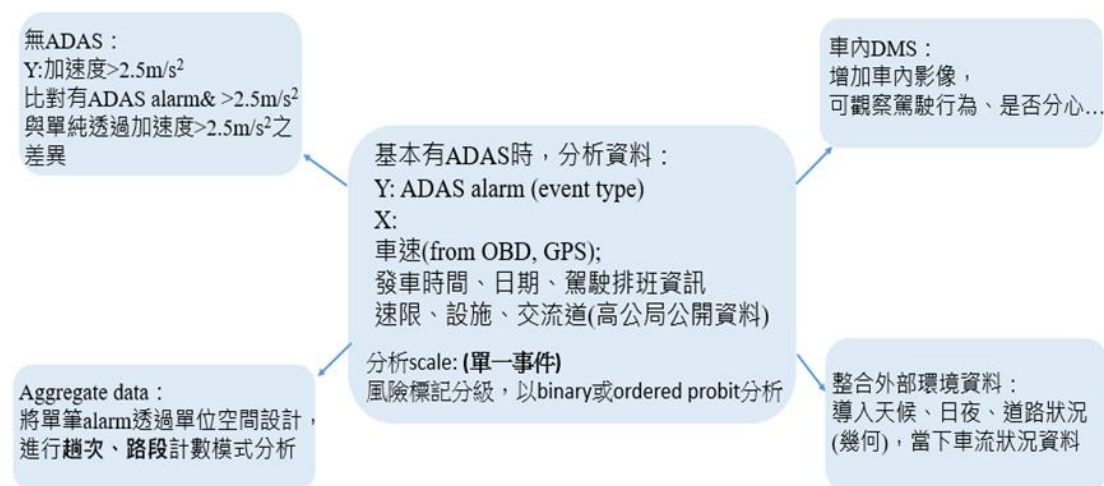


圖 7.2-1 ADAS 警示事件資料分級與後續分析方向示意圖

基本的警示資料如圖中所示，發生時會紀錄 1 筆樣本，包含其警示型態 (SDW, LDW, FCWH...等)，其與當下 CAN 記載的 GPS 資料以及車速等 OBD 資訊結合，便可再由所在地點連結至國道相關的公開資料，如：速限、交流道、服務區等設施；業者內部也可以將駕駛當班次的相關資訊進行勾稽，對應至表 7.1-1 的第 II 類資料。

本計畫自第 1 期開始，則是以第 II 類整合外部環境資料，導入天候、日夜、以及國道幾何資訊、高速公路局 VD 車流資訊，如圖右下所示。當年度尚未紀錄車內駕駛行為，因此並不屬於完整的第 IV 類，但高於第 II 類，且仍可進行高風險路段時空分析，探索警示事件好發時空環境。故應用時，並不一定需完全符合某項車載系統分級，而是著重在目前備有資料程度，是否已能進行分析，並逐步落實至管理或訓練層級。

計畫第 2 期則加入車內影像之相關標記，較首期計畫更為著重於車內駕駛行為與分心之餘，並在硬體與分析規格達到第 IV 類程度，係為圖 7.2-1 右半部分。本年度則針對 FCWH、SLDW 擴充樣本，進行更細緻之

分析。而從警示事件分析尺度整合到巨觀的趟次、路段資料時，如圖左下，目的則是從單一事件提升至能包含較多道路資訊 (趟次分析有一定空間長度，相較於單一事件僅為當下某處之瞬時資料)，以及以路段分析時，除卻單一駕駛人因素，而能看出更普遍性的好發時空情境。

由於過往主要關注於警示事件當下，若自事件發生時點前後一定秒數間蒐集資料，本計畫在第四章透過 OBD 資訊針對高風險駕駛行為進行探索與相關定義。時空分析部分則將在 7.3 節進行簡單介紹，初採第一期資料，將事件前後幾秒 OBD 之加速度、車外影像之車距納入模式初步建模，找尋關聯後，並隨機挑選一趟次，嘗試以無 ADAS，僅透過車機全趟逐秒 OBD 資料，依照該些高風險門檻篩選出一些資訊，如圖左上，但僅為嘗試探索，未來可再納為後續分析之項目。

本年度時空分析整體仍以路段、趟次、事件進行分析。表 7.2-2 至表 7.2-4 則分別將三者樣本數分類進行整理，詳細的敘述性統計與分析模型，則在 7.4 節呈現。其中，路段分析長度採用 2 公里、趟次分析長度採用 15 公里，係由第一期計畫時經過不同切割路段長度單位進行比較後選定之結果，其考量到計數 0 樣本比例，以及包含駕駛資訊以及道路交通幾何環境精細度之取捨。單一事件的則為每件事件單獨為一個樣本，其被解釋變數為警示事件的異常程度，故僅有進行標記分級程度的樣本納入。基此，路段總計分為國道一號 27K 至 367K 每兩公里為一個路段，南北向分開計算，有 340 個樣本，涵蓋 21,541 個警示事件。趟次樣本雖亦為巨觀分析，但須有駕駛員排班、發車時間以及車流量的相關資訊，故一旦有資料缺失而無法插補時，便會予以排除。最後有 673 個樣本涵蓋 12,018 個警示事件。單一事件樣本為微觀分析，且其被解釋變數為事件異常程度分級，需透過標記所得，故樣本數共計為 3,907 件 (2,181+1,408+318 件)。

表 7.2-2 路段被解釋變數之敘述性統計

路段(分析長度：2 公里)					
被解釋變數	平均值	標準差	範圍	該路段資料為零比例	總和
總警示	63.35	30.20	1-168	0%	21,541
未保安距(警示)	57.71	28.33	1-164	0%	19,623
車道偏移(警示)	5.64	4.95	0-27	10.29%	1,918

表 7.2-3 趟次被解釋變數之敘述性統計

趟次(分析長度：15 公里)					
被解釋變數	平均值	標準差	範圍	該路段資料為零比例	總和
總警示	0.79	1.33	0-21	58.40%	12,018

表 7.2-4 單一事件異常程度-事件分析被解釋變數之敘述性統計

事件分類	樣本數	危險度	
總事件	3,907	警示	2,859
		異常	1,048
未保安距	3,295	警示	2,361
		異常	934
車道偏移	612	警示	498
		異常	114

7.3 以 OBD 資料為基礎之高風險駕駛行為之時空分析

本小節係考量若業者尚無 ADAS 設備，無法透過車外影像與實際警示進行分析時，嘗試以第 I 類的 OBD 資料紀錄回放，整合 GPS 資料，由 OBD 資料記載車輛自啟動後逐秒之車速，以及車輛行駛時駕駛操作燈號等資訊進行分析。

因此，本計畫先透過第四章所分析之高風險駕駛行為門檻，並挑選業者可對應管理項目中，最大加速度 $\geq 2.5\text{m/s}^2$ (前 3 後 3)、最小車距 Caspacing $< 4\text{m}$ (前 3 後 3)。惟探索時空分析時，應重於為何發生警示事件，故微調成僅考量警示前有達到相關門檻。同步於第四章，初採第一年期對應發生警示事件前後的 OBD 資料與代表周遭車流環境的 Caspacing 車距資料做為解釋變數，由表 7.3-1 知，對警示發生時的異常程度，最小車距與最大加速度 $\geq 2.5\text{m/s}^2$ 皆為正向顯著，車內分心行為在操作設備、取物、身體前傾結合單手離開方向盤時有正向顯著；發車時段間部分時段有顯著差異，幾何條件與外部因素則未有顯著影響。

然而，警示事件本即為車輛前後關係的 SDW、FCW 為大宗，因此最小車距 $< 4\text{m}$ 、最大加速度 $\geq 2.5\text{m/s}^2$ 相關係數雖尚可，但後續暫時不放入單一事件分析之模型中。

表 7.3-1 周遭車流資訊、OBD 加速度對警示事件之事件分析模式

Y=單一事件異常程度		Coef.	Z
車速		0.00186	1.27
最小車距Caspacing<4m		0.92761	10.38
加速度>2.5m/s ²		0.38896	3.89
發車後駕駛時間		-0.0003	-0.53
發車時段(base: 白天)	凌晨	-0.2023	-2.09
	晨峰	0.28901	3.53
	昏峰	-0.1801	-0.9
	晚上	-0.4378	-3.27
假日		0.17874	0.22
方向(南下)		0.09365	1.4
24小時內班次數		0.0391	0.63
72小時內班次數		0.04589	1.36
168小時內班次數		-0.0148	-0.66
夜晚		0.06058	0.65
下雨		-0.1679	-1.44
年資>10年		-0.1684	-2.47
車內分心行為	手離開方向盤+嘴巴	0.12086	0.37
	手離開方向盤+擺頭	0.63317	1.24
	手離開方向盤+操作設備	0.89136	1.95
	手離開方向盤+取物	1.04961	2.77
	手離開方向盤+前傾	0.73279	2.23
	其他車內行為	0.50965	1.76
大彎道		0.05082	0.66
彎道		-0.1205	-0.17
坡道		0.12947	1.42
5分鐘流量		0.0001	-0.44
小車比例		237042	0.11
/cut1		1.11308	
/cut2		2.240718	
n=2181			
LR Chi ² = 205.56 Prob. > Chi ² =0.000			
Pseudo R ² = 0.0714			

當欲探索高風險駕駛行為與時空環境之關鍵因素時，本計畫將 GPS 資料與 OBD 資料透過時間進行串接；再依照 GPS 之經緯度勾稽國道幾何資料，則可得到車輛、時間、車速、經緯度、駕駛班次、方向、國道里程、道路幾何 (包含道路寬度、彎道半徑、坡度、限速等資訊)，如圖 7.3-1 示。由於每趟次的 OBD 資料由車輛發車至結束逐秒紀錄，其樣本數多，且須再與國道幾何、外部車流資訊進行多重勾稽結合，本節後續先透過隨機挑選一趟次之 OBD 資料，透過其 OBD 內建之車速進行最大加速度之篩選，進行初步比對。

license_pl-n	speedx	data_timex	latitudeux	longitudeux	employee_id	route_id	dir	speed_limit	freeway_km	road_width	inner_shoulder_h	outer_shoulder-h	Variables
551-D9	98	2021-03-01 10:54:04	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	Filter variables
551-D9	99	2021-03-01 10:54:05	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	Name
551-D9	99	2021-03-01 10:54:06	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	climb_lane_area
551-D9	98	2021-03-01 10:54:08	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	grade
551-D9	98	2021-03-01 10:54:09	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	radius
551-D9	98	2021-03-01 10:54:10	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	climb
551-D9	98	2021-03-01 10:54:11	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	curve
551-D9	98	2021-03-01 10:54:12	24.75	120.98	9108015	750001	S	100	100633.5	14.8	0.5	0	year
551-D9	97	2021-03-01 10:54:16	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	month
551-D9	97	2021-03-01 10:54:17	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	date
551-D9	97	2021-03-01 10:54:18	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	min
551-D9	97	2021-03-01 10:54:19	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	sec
551-D9	96	2021-03-01 10:54:20	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	hr
551-D9	96	2021-03-01 10:54:21	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	trip
551-D9	95	2021-03-01 10:54:22	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	newtrip
551-D9	95	2021-03-01 10:54:23	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	Variables
551-D9	95	2021-03-01 10:54:24	24.76	120.99	9108015	750001	S	100	99114.5	16.4307692307692	0.8	1.96153946153946	Sn

圖 7.3-1 OBD、GPS 資料逐秒串接國道幾何資訊示意圖

經過隨機挑選一趟臺北開往臺南的客運班次後，依照 OBD 的車速欄位計算其加速度，該趟次總計發生 17 次加速度 $\geq 2.5\text{m/s}^2$ 之情形，如圖 7.3-2 示。

var1	data_time_new	idx	speedx	caspadding	tripx	latitudeux	longitudeux	speedy	路線名稱	acc	Variables
1	693	2023/5/15 08:52	18263022851	17	0	14	0	0	台北->台南	-2.561933	Filter va
2	1307	2023/5/15 09:02	18263095151	27	0	14	25.0474	121.5153717	23.87228	6.631189	Name
3	1621	2023/5/15 09:07	18263118001	8	0	14	25.05719	121.49394	9.50076	2.6391	latitudey
4	1692	2023/5/15 09:08	18263118072	56	0	14	25.06302	121.49042	57.54164	2.741988	longitudey
5	1751	2023/5/15 09:09	18263118131	11	0	14	0	0	台北->台南	-2.654533	route_idy
6	2123	2023/5/15 09:15	18263162896	42	14	14	25.07635667	121.4959967	40.48472	4.269888	speed
7	2310	2023/5/15 09:19	18263163082	32	0	14	25.073325	121.4535483	36.577	-3.302733	gpspeed
8	2311	2023/5/15 09:19	18263163083	25	0	14	25.073295	121.4534833	27.35404	-2.561933	trip
9	4074	2023/5/15 09:48	18263346007	25	0	14	25.03154	121.299305	25.3724	-2.757422	location
10	4077	2023/5/15 09:48	18263346010	6	0	14	25.03167167	121.299345	9.3526	-2.613378	time_tripst
11	11895	2023/5/15 11:58	18264160286	82	14	14	23.70943	120.4759783	82.6918	-2.510489	trip_no
12	11898	2023/5/15 11:58	18264160289	66	10	14	23.70886167	120.4759167	65.32004	-2.69569	路線名稱
13	11900	2023/5/15 11:58	18264160291	54	10	14	23.70856667	120.4758783	51.80044	-2.649389	班次日期
14	13934	2023/5/15 12:32	18264353620	85	14	14	23.26706667	120.2625117	85.69204	-2.942621	班次時間
15	16489	2023/5/15 13:14	18264608220	6	0	14	23.03049	120.2255317	8.48216	-2.983778	車號
16	17108	2023/5/15 13:25	18264698884	13	0	14	23.01201167	120.2089	8.75996	-2.556789	員工編號
17	18504	2023/5/15 13:48	18264836197	13	0	14	23.00422	120.210645	10.66752	2.814011	Variables

圖 7.3-2 透過 OBD 計算加速度後，趟次觸發條件次數

再對照圖 7.3-3 為該趟次發生警示事件之資料表，由時間欄位對照，大部分 OBD 在加速度有觸及的時間點前後幾分鐘內，幾乎都有警示事件發生，但並無 OBD 一觸及門檻後，警示事件隨即發生的狀況。目前僅有初步隨機挑選一趟次，後續建議除了增加趟次數進行比對外，可以再挑選更多高風險駕駛行為之相關條件，進行篩選。以及再觀察是否與當下的車流狀況有關聯，再考量 OBD 可由觸發門檻的事件進行分析，或需要先進行一定時空範圍的選定後，以類似趟次分析的方式先整合後再進行時空比較與分析。

整體而言，第 I 類資料主要係以無 ADAS 時的條件下才使用與進行高風險條件分析與管理，後續應可先透過實際發生 ADAS 警示事件的樣本輔助，並應著重於車輛動態相關之高風險駕駛行為，對應在此單位樣本

內所發生之頻次做為應變數，以車輛資訊、國道幾何資訊做為自變數，建立計數模式，以分析此些高風險駕駛行為，好發於何些時空環境。

id									id									Variables								
trip									event_id									Filter varia								
route_id									speed									Name								
gpspeed									km									var2								
事件時間年月日時分秒									事件時間年月日時分秒									rain								
1	5209	14	SDW_0_4	台北->台南	46	43	36.4585	2023/5/15 09:23	25	5232	14	SDW_0_4	台北->台南	99	99	149.902	2023/5/15 11:03	surrogate2								
2	5210	14	SDW_0_4	台北->台南	81	79	42.301	2023/5/15 09:32	26	5253	14	SDW_1_2	台北->台南	99	99	150.192	2023/5/15 11:04	distract								
3	5212	14	SDW_0_4	台北->台南	84	85	50.748	2023/5/15 09:54	27	5233	14	SDW_0_4	台北->台南	97	97	183.276	2023/5/15 11:24	employee_id								
4	5213	14	SDW_0_4	台北->台南	85	84	51.0355	2023/5/15 09:54	28	5254	14	SDW_1_2	台北->台南	94	93	186.057	2023/5/15 11:26	seniority								
5	5214	14	SDW_0_4	台北->台南	98	96	69.3575	2023/5/15 10:08	29	5234	14	SDW_0_4	台北->台南	98	97	191.936	2023/5/15 11:29	in24								
6	5249	14	SDW_1_2	台北->台南	90	90	73.6175	2023/5/15 10:10	30	5235	14	SDW_0_4	台北->台南	98	98	193.926	2023/5/15 11:31	in72								
7	5215	14	SDW_0_4	台北->台南	99	99	80.8365	2023/5/15 10:15	31	5236	14	SDW_0_4	台北->台南	79	78	203.928	2023/5/15 11:37	in168								
8	5216	14	SDW_0_4	台北->台南	68	68	97.784	2023/5/15 10:31	32	5237	14	SDW_0_4	台北->台南	97	98	218.163	2023/5/15 11:46									
9	5250	14	SDW_1_2	台北->台南	74	75	97.6255	2023/5/15 10:31	33	5238	14	SDW_0_4	台北->台南	95	94	226.91	2023/5/15 11:51									
10	5251	14	SDW_1_2	台北->台南	103	103	119.508	2023/5/15 10:45	34	5239	14	SDW_0_4	台北->台南	103	103	227.581	2023/5/15 11:51									
11	5220	14	SDW_0_4	台北->台南	99	98	123.957	2023/5/15 10:47	35	5255	14	SDW_1_2	台北->台南	95	95	227.021	2023/5/15 11:51									
12	5252	14	SDW_1_2	台北->台南	95	95	130.895	2023/5/15 10:51	36	5210	14	SDW_0_4	台北->台南	95	95	233.507	2023/5/15 11:55									
13	5221	14	SDW_0_4	台北->台南	91	92	131.829	2023/5/15 10:52	37	5211	14	SDW_0_4	台北->台南	95	95	233.507	2023/5/15 11:55									
14	5222	14	SDW_0_4	台北->台南	84	82	133.154	2023/5/15 10:53	37	5219	14	SDW_0_4	台北->台南	100	100	244.643	2023/5/15 12:02									
15	5223	14	SDW_0_4	台北->台南	81	80	140.23	2023/5/15 10:57	38	5240	14	SDW_0_4	台北->台南	89	88	284.964	2023/5/15 12:27									
16	5224	14	SDW_0_4	台北->台南	81	80	141.216	2023/5/15 10:58	39	5256	14	SDW_1_2	台北->台南	79	78	300.313	2023/5/15 12:36									
17	5225	14	SDW_0_4	台北->台南	90	90	141.775	2023/5/15 10:58	40	5241	14	SDW_0_4	台北->台南	100	101	309.051	2023/5/15 12:54									
18	5207	14	FCWH	台北->台南	71	72	142.1	2023/5/15 10:59	41	5245	14	SDW_0_4	台北->台南	98	96	310.428	2023/5/15 12:55									
19	5208	14	FCWH	台北->台南	84	83	142.4	2023/5/15 10:59	42	5244	14	SDW_0_4	台北->台南	105	105	311.377	2023/5/15 12:55									
20	5226	14	SDW_0_4	台北->台南	75	70	142.26	2023/5/15 10:59	43	5243	14	SDW_0_4	台北->台南	100	99	310.929	2023/5/15 12:55									
21	5231	14	SDW_0_4	台北->台南	98	92	146.072	2023/5/15 11:01	43	5242	14	SDW_0_4	台北->台南	95	96	309.861	2023/5/15 12:55									
22	5228	14	SDW_0_4	台北->台南	91	90	145.294	2023/5/15 11:01	44	5242	14	SDW_0_4	台北->台南	95	96	309.861	2023/5/15 12:55									
23	5229	14	SDW_0_4	台北->台南	101	100	145.634	2023/5/15 11:01	45	5246	14	SDW_0_4	台北->台南	87	89	315.455	2023/5/15 12:58									
24	5230	14	SDW_0_4	台北->台南	100	102	147.827	2023/5/15 11:02	46	5247	14	SDW_0_4	台北->台南	78	77	316.455	2023/5/15 12:59									

圖 7.3-3 對應趟次之警示事件表

7.4 以 ADAS 資料為基礎之高風險駕駛行為之時空分析

相較 OBD 需透過每趟次全程逐秒資料，ADAS 資料則如圖 7.1-1 之微觀、巨觀兩大部分所示。不論是微觀事件分析模式、巨觀趟次或路段分析模式，基本上皆為有 ADAS (即：第 II 類以上資料) 之 event-based 情境條件下，再進行資料處理、建模。

本計畫前年度考量樣本數量在各類警示、異常發生頻率，部分異常行為或是警示事件類別發生次數較少，已逐年蒐集由 2021 年 200 趟次及 2022 年 150 趟次之 ADAS 警示資料。惟部分如趟次分析、車道偏移資料樣本仍較少，使得模式僅能採用羅吉斯迴歸分析。尤其是較為關鍵的 FCWH 與 SLDW 兩種警示狀態，仍應盡可能以計數模式推估反應之。

基此，本年度增加蒐集 2023 年 5 月份約 400 趟次之 ADAS 警示資料，除了確保前數兩類關鍵之樣本數足夠建模外，也為之後趟次分析模式可以區分駕駛人月預作準備。依照時空分析之分析架構，下方逐節則分別針對路段、趟次、事件之分析模式說明。

其中，有關警示事件之駕駛反應、車內行為，未來可能以影像辨識方式處理，故今年 400 趟次共有約 8,000 筆警示事件僅有 318 筆 FCWH、SLDW 事件進行標記，扣除有資料缺失的部分後，再依照可擴充程度整理

至路段、趟次、單一事件異常程度之各項模式中。為了能更清楚3年分別整理之樣本與路段、趟次、事件之關係，以圖 7.4-1 進行示意。

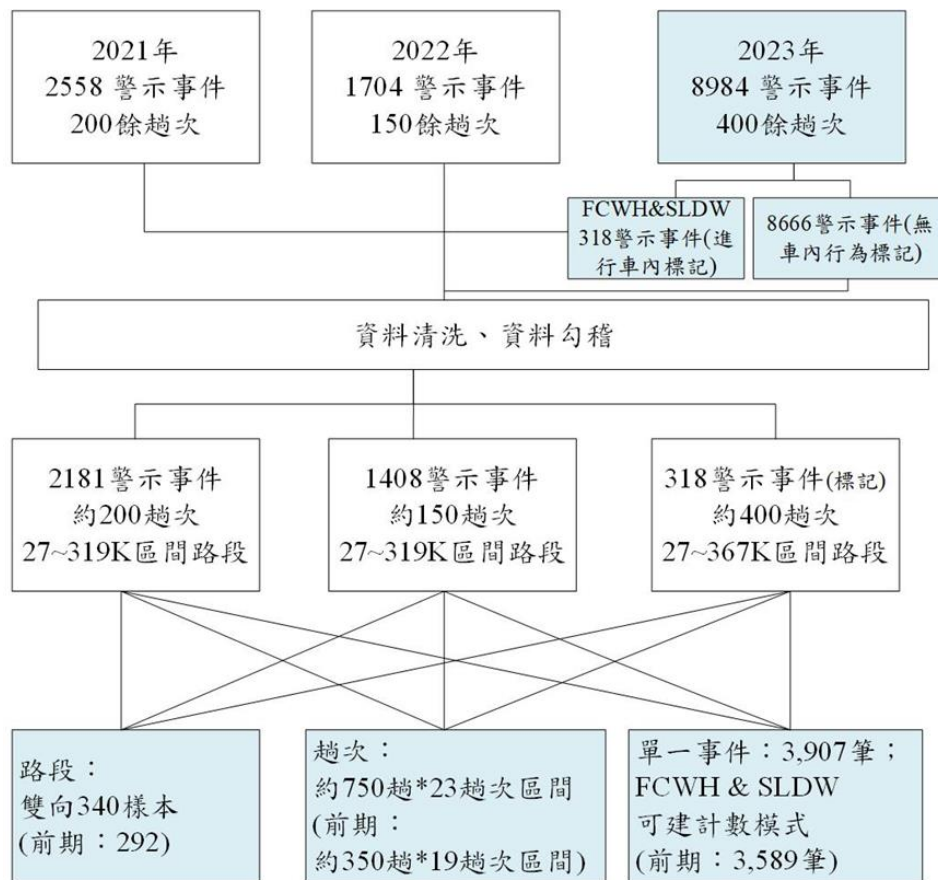


圖 7.4-1 整合資料分析架構圖

7.4.1 以路段為基礎之分析

前期計畫針對路段分析蒐集警示事件、行車異常事件，並且針對車內異常行為之分心事件次數建模；除了先以分心當作被解釋變數，探索分心事件好發路段之時空特性外，再將分心次數當作解釋變數，針對路段中的每個警示事件或行車異常事件建立計數模式，觀察好發時空特性。本期計畫主要增加大量樣本，係為了從足夠多的趟次獲得 FCWH 與 SLDW 之事件數；以及未來在趟次分析時，可以將駕駛當作群組，建立階層模式分析。本年度

路段分析概念示意圖如圖 7.4-2，並因新增趟次多數僅有警示次數，未標記警示事件異常程度，因此並無行車異常事件；分心事件亦須車內行為標記，因此也不在本期進行分析。

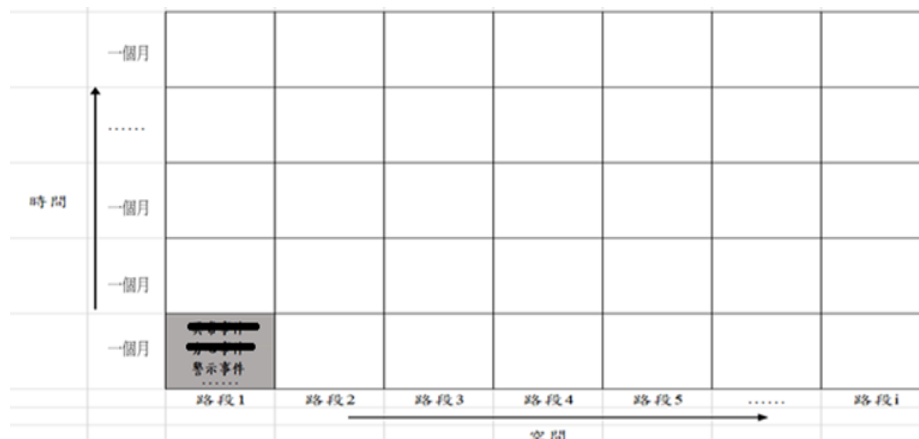


圖 7.4-2 路段分析概念示意圖

因此，針對路段分析部分，本年度主要僅針對蒐集臺北至高雄的客運路線，讓主要的國道路段皆有警示數量可進行模式建構，探索更完整路段與警示事件的好發關係。也因本年度增加的 400 趟次，大部分都有待未來透過影像辨識進行車內行為與駕駛因應的標記，難以將每個警示再進行異常程度分析，因此，在原先之模式基礎下，以負二項迴歸建立計數推估模式，一樣探索警示事件與好發時空環境之關聯。基本之被解釋變數敘述統計已在 7.2 節整理，本年度則針對警示事件建模，分為全模式、未保安距模式，以及車道偏移模式分析。

後續分析建構模式以道路交通環境資料做為解釋變數，大致可區分為幾何特性、交通特性以及設施特性等三大類，分別說明如表 7.4-1 與表 7.4-2。由表 7.4-1 可知，幾何特性中之內外側路肩寬以各分析路段最小值做為代表值，而上下坡度及車道數則以各分析路段最大值做為代表值，並且當各分析路段之彎道半徑小於三千公尺時視其為大彎道路段。交通特性則皆為連續變數，交通量以小客車當量值 (pce) 折算後的 pcu 表之，並依此計算各車種之比例，車種以高速公路車輛偵測器 (VD) 紀錄之車種代碼為分類依據，小車為小型車，而大車則包括大型車及聯結車。設施特性皆以類別變數表之，其中的開放路肩、服務區及交流道用於反應高速公路車流交織情形。

表 7.4-1 解釋變數之敘述性統計 (連續變數)

解釋變數	平均值	標準差	最小值	最大值
幾何特性				
最小內側路肩寬(公尺)	0.75	0.30	0.00	4.00
最小外側路肩寬(公尺)	1.05	1.38	0.00	3.70
最大上坡度(%)	0.28	0.71	0.00	2.04
最大下坡度(%)	0.27	0.69	0.00	2.02
最大車道數	3.16	0.51	0.00	6.00
交通特性				
總交通量(千小客車當量)	69.17	18.27	23.74	140.36
小車比例(小型車流量*1.0/總交通量)	0.57	0.11	0.21	0.91
大車比例((大型車流量*2.0+聯結車流量*3.0)/總交通量)	0.43	0.11	0.09	0.79

表 7.4-2 解釋變數之敘述性統計 (類別變數)

解釋變數	定義	計數(比例)		
		0	1	2
幾何特性				
彎道	分析路段是大彎道為 2，彎道為 1，直線為 0	68 (20%)	154 (45%)	118 (35%)
設施特性				
速限	分析路段之公告速限 110km/hr 為 1，餘為 0	140 (41%)	200 (59%)	
固 定 式 測速照相	分析路段上有設置為 1，餘為 0	290 (85%)	50 (15%)	
開放路肩	分析路段開放行駛路肩為 1，餘為 0	301 (89%)	39 (11%)	
服務區	分析路段上有設置為 1，餘為 0	328 (96%)	12 (4%)	
交流道	分析路段有包含為 1，餘為 0	214 (63%)	126 (37%)	

如前所述，本年度路段部分新增蒐集 400 餘趟未特別針對警示事件異常程度標記之樣本，故建立皆為警示事件之影響模式，包含所有警示事件數、未保持安全距離警示事件數、車道偏移警示事件數，個別發展負二項迴歸式，總交通量取自然對數，做為曝光量之指標。表 7.4-3 為模式

推估結果，推估係數旁之星號為該係數之顯著性（三個星號代表 p 值低於 0.001、兩個星號代表 p 值低於 0.01、一個星號代表 p 值低於 0.05、句點符號則代表 p 值低於 0.1），而括號內則為該係數之估計標準誤。當推估係數為正值時，代表該變數對警示事件數有正向影響。

表 7.4-3 路段分析模式-警示事件推估結果

解釋變數	被解釋變數		
	所有行車異常事件	未 保 安 距 (警示)	車 道 偏 移 (警示)
截距項	-5.890*** (0.856)	-6,726*** (0.887)	-0.674 (2.328)
幾何特性			
最大上坡度	0.022 (0.253)	0.025 (0.262)	0.004 (0.066)
最大下坡度	0.027 (0.026)	0.021 (0.026)	0.104 (0.066)
最大車道數	0.041 (0.035)	0.036 (0.036)	0.152 (0.095)
彎道	0.007 (0.042)	-0.009 (0.043)	0.236* (0.118)
大彎道	-0.049 (0.045)	-0.098** (0.048)	0.429*** (0.125)
交通特性			
小車比例	1.224*** (0.176)	1.357*** (0.182)	-0.179 (0.492)
總交通量	0.641*** (0.074)	0.701*** (0.077)	0.014 (0.202)
設施特性			
速限 110km/hr	-0.160*** (0.049)	-0.167*** (0.050)	-0.038 (0.133)
有固定式測速照相	0.105** (0.444)	0.121** (0.459)	-0.047 (0.122)
開放路肩	-0.004 (0.050)	0.009 (0.052)	-0.162 (0.138)
有服務區	-0.057 (0.087)	-0.084 (0.091)	0.178 (0.231)
有交流道	-0.142*** (0.037)	-0.151*** (0.038)	-0.048 (0.101)
路段行經趟次數	0.007*** (0.000)	0.008*** (0.000)	0.005*** (0.000)
模式績效			
AIC	2874.5	2826.131	1794.664
BIC	2939.592	2891.223	1859.756
LL(C)	-1541.431	-1513.6722	-895.983

解釋變數	被解釋變數		
	所有行車異常事件	未 保 安 距 (警示)	車 道 偏 移 (警示)
LL(β)	-1420.2498	-1396.0653	-880.33207
ρc^2	0.1475	0.1475	0.0710
觀察值	340	340	340

模式分為全部警示事件、未保安距警示事件、車道偏移警示事件，根據推估結果。「有交流道」代表車流狀況可能較為複雜，使駕駛更專注於駕駛，對全部以及未保安距行車異常事件數負向影響，單就未保安距模式中，彎道也為負向影響，可能也是在彎道處駕駛需要更注意駕駛，而比較不容易導致警示事件發生。此外，「速限為 110km/hr」在全模式與未保安距中也是負向，有可能在速限越高的狀況下所需反應時間與距離較長，駕駛傾向保持較多距離。但「小車比例」、「總交通量」與「有固定式測速照相」則為正向顯著因素，前者可能是車種越同質，反而降低駕駛心理壓力與專注力，致使跟車等較不注意，其次則是車流需求高、交織與干擾預期也多；後者則可能也屬外部環境對駕駛有額外駕駛任務造成，對全部與未保安距行車異常事件數正影響。

車道偏移之好發情境則與全部警示事件、未保安距警示事件不同，並且主要由彎道與大彎道反映，此兩變數對車道偏移警示呈現顯著正向關係，應皆與彎道幾何、操駕車輛之駕駛任務與難度較高有關。

7.4.2 以趟次為基礎之分析

以趟次為基礎之分析並未考量駕駛者特性，本節將臺北(或板橋)至臺南(或高雄)共約 750 趟次大客車趟次之行車資料為分析基礎，著重於觀察以趟次為單位時，警示事件在國道上的分布情形與好發情境。與路段分析一樣，本年度大量增加樣本屬於未標記事件異常程度者，若為了特別分出異常與警示分開建模而放棄新增約 400 趟的資料，並不理想。因此，趟次如圖 7.4-3 所述，本年度以約 750 趟次，並追加了臺南至高雄路段新增雙向共 8 個分析趟次路段，進行警示事件的好發情境建模。

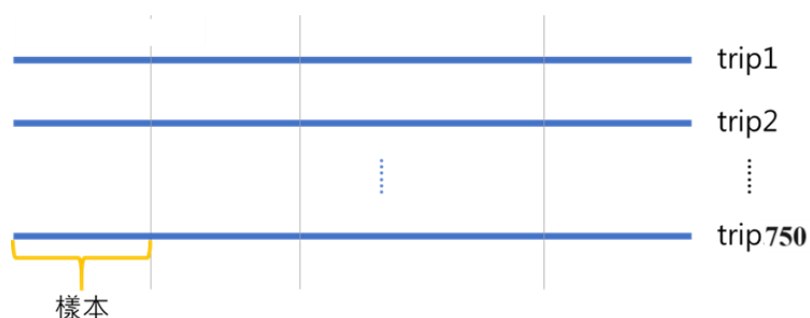


圖 7.4-3 趟次分析概念示意圖

趟次切割後，在蒐集該趟次經過每個分析單位時，由於不見得會發生警示事件，因此本計畫以有發生警示事件的時間點，以內 (外) 插法推估通過各分析單位的時間，並得到當時段交通量之資訊，再針對於該分析單位有無發生警示之計數同樣地，若該趟次全程僅發生一次或零次警示事件，則無法推估其通過各路段之時間，而致使各個分析單位區間皆無警示。

考量趟次分析中本小節針對警示事件進行分析，於所有趟次單位中之分布狀況與 750 趟次可蒐集之樣本數如表 7.2-3 所示，共有 12,018 個樣本，每個樣本紀錄警示事件的頻次，範圍由 0 至 21 次，共計 9,518 筆警示事件。由於路段長度再以更長路段切割可能模糊幾何、交通環境以及設施特性，亦不適合分割太長，以 15 公里做為一個趟次分析長度單位，但仍需考量其零占比，後續以零膨脹負二項迴歸建立警示事件之好發情境模式。

使用道路交通環境資料和客運班表資料建構趟次分析模式，大致可區分為幾何、交通環境、設施以及駕駛特性等四大類解釋變數，分別說明如表 7.4-4 至表 7.4-7。

表 7.4-4 解釋變數之敘述性統計 (連續變數)

解釋變數	平均值	標準差	最小值	最大值
幾何特性				
最小內側路肩寬(公尺)	0.51	0.19	0.00	0.80
最大上坡度(%)	0.70	0.96	0.00	2.04
最大下坡度(%)	0.69	0.95	0.00	2.02
最大車道數	3.37	0.76	3.00	6.00
交通環境特性				

總交通量(千小客車當量)	1.72	0.97	0.06	6.38
設施特性				
交流道數量	2.66	1.42	1.00	7.00
駕駛特性				
駕駛資歷(月)	94.52	69.42	0.00	256.00

表 7.4-5 解釋變數之敘述性統計(類別變數)

解釋變數	定義	計數(比例)	
		0	1
設施特性			
開放路肩	分析路段開放行駛路肩為 1，餘為 0	8,816 (73%)	3,202 (27%)
服務區	分析路段上有設置為 1，餘為 0	9,253 (77%)	2,765 (23%)
駕駛特性			
班表星期	由班表紀錄該趟旅次之日期，週六和週日為 1，週一至週五為 0	9,027 (75%)	2,991 (25%)

表 7.4-6 駕駛人排班趟次統計分布

24 小時內	計數(比例)	72 小時內	計數(比例)	168 小時內	計數(比例)
1	2,701(22%)	1	239(2%)	<5	423(4%)
2	8,041(67%)	2	358(3%)	6	369(3%)
3	1,276(11%)	3	1,928(16%)	7	814(7%)
		4	2,012(17%)	8	860(7%)
		5	4,768(40%)	9	2,052(17%)
		6	2,545(21%)	10	2,897(24%)
		7	168(1%)	11	2,847(24%)
				12	1,447(12%)
				13	309(2%)
總計	12,018	總計	12,018	總計	12,018

表 7.4-7 發車時間之時段區分統計

發車時間之時段區分	計數
凌晨	2,863(24%)
晨峰	1,448(12%)
白天	4,680(39%)

昏峰	914(8%)
晚上	2,185(18%)
總計	12,018

由表 7.4-4 知，幾何特性中之內側路肩寬以各分析單位最小值做為代表值，而上下坡度及車道數則以各分析單位最大值做為代表值。交通環境特性則皆為連續變數，交通量變數代表行車趟次經過分析單位時該處平均交通量 (介接該區間 VD 資料，以 30 分鐘交通量計)，並以小客車當量值 (pce) 折算後的 pcu 表示。相較路段分析，此時的交通環境特性變數更能反映事件發生當下的交通環境狀況。設施特性同樣用於反映高速公路車流交織情形，惟在十五公里的高速公路單位中均含有至少一座交流道，因此交流道變數定義調整為十五公里內的交流道數量。

駕駛特性變數之駕駛資歷以該位駕駛人到職時之時間起算至事件發生時經過之月數，可反映駕駛人對路況熟悉程度。此外，考量年資以連續變數於模式中反應之係數偏小，本期於趟次與單一事件分析時，以十年為基準將年資改為二元變數。此門檻係由此三年的資料蒐集，皆發現約有 3 成的駕駛員年資超過 10 年，應屬較為穩定、熟悉公司路線路況，也較能預判駕駛大型車輛容易發生較具風險情境者。班表星期是由班表紀錄該趟旅次之日期，分為平日之週一至週五，假日之週六、週日；駕駛人排班 24 小時內及 72、168 (一週) 小時趟次數則期能反映駕駛疲勞程度；並依據國道尖離峰時段，將駕駛人的發車時間分為凌晨 (0am~6am)、晨峰 (6am~8am)、白天 (8am~5pm)、昏峰 (5pm~7pm)、晚上 (7pm~12pm) 等五個時段。

將趟次分析單位之總交通量取自然對數，做為曝光量指標分別對分析單位中是否發生警示進行模式推估，結果如表 7.4-8。其中，顯著性若有星號則代表該變數顯著 (三個星號代表 p 值低於 0.001、兩個星號代表 p 值低於 0.01、一個星號代表 p 值低於 0.05、句點符號則代表 p 值低於 0.1)，並紀錄估計標準誤。當係數為正值時，代表該變數對警示或行車異常事件發生有正向影響。模式結果則顯示，「交通量」呈現正向影響，表示車流量、需求較高時較容易發生警示事件，此外「72 小時內排班趟次」也呈現正向影響，表示短時間讓駕駛員開行太多班次，其發生警示事件的

風險較高；而幾何特性的「最小內側路肩寬」則反映容錯空間若較大，相對較不好發警示與行車異常事件、「服務區」則可能預期將有較多交織而較為謹慎。當該趟次發車時段為以「白天」發車的趟次為基準，其餘不論是凌晨、晨峰、昏峰、晚上，整體交通需求與車流狀況，反而皆較不易發生警示。最後，由於本期將警示事件自有無發生，轉換為發生次數，因此以計量模式呈現，在發生次數 0 值仍多的狀況下，嘗試以 NB 及 ZINB 建模，最後，ZINB 模式以 Vvong 檢定顯著優於 NB，故最後以 ZINB 模式呈現分析結果。

表 7.4-8 趟次分析模式-警示事件推估結果

解釋變數	被解釋變數
	警示事件
截距項	0.476*** (0.177)
幾何特性	
最小內側路肩寬(公尺)	-0.141** (0.070)
最大上坡度(%)	0.005 (0.019)
最大下坡度(%)	0.011 (0.023)
最大車道數	-0.003 (0.020)
交通環境特性	
總交通量(ln)	0.039* (0.021)
設施特性	
交流道數量	-0.006 (0.014)
開放路肩	-0.007 (0.029)
服務區	-0.076*** (0.029)
駕駛特性	
駕駛資歷(10 年)	-0.019 (0.025)
班表星期	-0.007 (0.025)
24 小時內排班趟次	0.008 (0.206)
72 小時內排班趟次	0.033*** (0.011)
168 小時內排班趟次	-0.012. (0.007)
發車時間時段 凌晨	-0.085** (0.034)
發車時間時段 晨峰	-0.116*** (0.032)
發車時間時段 昏峰	-0.096** (0.042)
發車時間時段 晚上	-0.192*** (0.039)
模式績效	
AIC	16075.32
BIC	16230.6
LL(C)	-8056.4528

解釋變數	被解釋變數
	警示事件
LL(β)	-8016.66
Vvong test of zinb vs negative binomial	Z=163.25 (Pr>z=0.0000)
觀察值	12,018

7.4.3 以事件為基礎之分析

本節則以單一事件為單位進行分析，紀錄前兩期 350 趟次中所發生的每件警示事件，以及本期 400 趟次中的警示事件，但由於有進行真值標記警示時的駕駛因應與車內行為僅有 FCWH 與 SLDW (其餘事件，未來可能透過影像辨識方式處理或以其他模式運算)，計有 3,907 筆。以上資料須介接高速公路局 VD 資料、駕駛員相關資料。圖 7.4-4 為單一事件之說明，每個點皆為一個警示事件，發生於各個趟次駕駛期間的不同時空環境中，而紅點大小則是若有透過標記，能標示出該事件的異常程度為何。

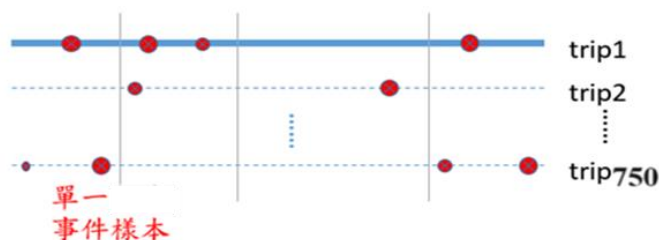


圖 7.4-4 單一事件分析概念示意圖

針對單一事件分析之重點，本期以高速接近前車 (FCWH) 與嚴重車道偏移 (SLDW) 之樣本擴充，並可透過各自之類別建立模式分析。並且與前兩期計畫略作區隔，本期進行單一事件分析時針對事件異常程度由 3 個等級 (僅為警示、稍微異常、異常)，調整為：僅為警示 (非異常) 與異常兩類並以 binary probit 分析，此係因原先最高等級的比例相當低，先進行整合，以求模式結果之解釋力能較為改善。此外，就所有事件、未保安距系列、車道偏移系列，再追加高速接近前車 (FCWH) 與嚴重車道偏移 (SLDW) 共五類進行模式校估與比較。不過，此些單一事件都有進行標記，即有記載車內異常行為可判斷分心，因此分心列為其中一個解釋變數，此亦為本章節最先所述，可依需求選擇資料蒐集並分析。

以事件為基礎建構好發情境模式，所採用的道路環境與駕駛人相關資料大致可分為幾何特性、交通環境特性與駕駛特性，以及班表資料，分別如表 7.4-9 至 7.4-12 所示。在連續變數，交通環境特性方面，蒐集當下車輛的車速、上下游最接近的 VD 資料。若有資料遺失之 VD 則改採其他 VD 資訊，並計算小車比例做為車種單純化或較為混雜之用，以上反映交通車流環境因子。此外，駕駛特性方面，則在資料蒐集時獲得駕駛資歷，並以 10 年為門檻轉換為二元變數，以及車輛發生 ADAS 警示事件時，已距離發車多長時間(分鐘)。而屬於類別變數中，則包含幾何特性，事件發生處是否為彎道、坡道，另亦透過班表資料與車機資料，得知發車時段、行駛方向、是否為假日，以及發生當下是否為夜間。表 7.4-11 則紀錄駕駛在開此趟車時，在 24、72、168 小時(即：1 日、3 日、7 日內)，總共駕駛了多少趟次；表 7.4-12 則紀錄該趟次發車時段為何，並依照車流特性分為凌晨 (0a.m.~6a.m.)、晨峰 (6a.m.~8a.m.)、白天 (8a.m.~5p.m.)、昏峰 (5p.m.~7p.m.) 以及晚上 (7p.m.~12p.m.) 5 個時段。

表 7.4-9 解釋變數之敘述性統計(連續變數)

解釋變數	平均值	標準差	最小值	最大值
交通環境特性				
事件發生時車速(公里/小時)	85.05	22.56	0.00	111
當下 5 分鐘 VD(小客車當量)	333.37	158.42	1.00	1625
當下 5 分鐘 VD 平均小車比例	0.79	0.15	0.05	1.00
駕駛特性				
駕駛資歷(月)	104.67	78.20	0.00	256.00
該趟次已行駛時間(分)	152.75	62.87	17.70	356.07

表 7.4-10 解釋變數之敘述性統計(類別變數)

解釋變數	定義	計數(比例)	
		0	1
幾何特性			
大彎道	事件發生處為大彎道為 1，餘為 0	2,896 (72%)	1,101 (28%)
彎道	事件發生處為彎道為 1，餘為 0	2,709 (69%)	1,198 (31%)
坡道	事件發生處為坡道為 1，餘為 0	3,361 (86%)	546 (14%)
交通環境特性			

假日	由班表紀錄該趟旅次之日期，假日為 1，平日為 0	3,000 (77%)	907 (23%)
南下班次	由班表紀錄該趟旅次。南下為 1，北上為 0	1,913 (49%)	1,994 (51%)
夜間	由事件發生當下若已日落則為 1，否則為 0	2,746 (70%)	1,161 (30%)
雨天	由事件發生當下若下雨為 1，否則為 0	3,512 (90%)	395 (10%)

表 7.4-11 駕駛人排班趟次統計分布

24 小時內	計數(比例)	72 小時內	計數(比例)	168 小時內	計數(比例)
1	728(19%)	1	20(<1%)	<=5	50(<1%)
2	2,874(74%)	2	110 (3%)	6	114(3%)
3	305(8%)	3	567(15%)	7	234(6%)
		4	778(20%)	8	343(9%)
		5	1,501(39%)	9	535(14%)
		6	913(23%)	10	1,061(27%)
		7	18(<1%)	11	823(21%)
				12	652(17%)
				13	95(2%)
總計	3,907	總計	3,907	總計	3,907

表 7.4-12 發車時間之時段區分統計

發車時間之時段區分	計數
凌晨	595(15%)
晨峰	583(15%)
白天	2,022(52%)
昏峰	301(8%)
晚上	406(10%)
總計	3,907

前述共分 5 種單一事件分類之二元普羅比模式推估結果如表 7.4-13 所示，針對常發生事件之好發情境分析。其中，顯著性若有星號則代表該變數顯著 (3 個星號代表 p 值低於 0.001、2 個星號代表 p 值低於 0.01、1 個星號代表 p 值低於 0.05、句點符號則代表 p 值低於 0.1)，並紀錄估計標準誤。當係數為正值時，代表該變數對該類型事件發生有正向影響。

除了高速接近前車(FCWH)模式以外，分心對警示事件異常程度的影響皆正向顯著且係數值相對其他變數影響大。另由模式之間可分別觀察，全模式、未保安距兩者的變數正負較為一致，係因事件大多數是未保安距類型的事件(SDW_1.2、SDW_0.4、FCWH)，因此車道偏移相關的事件宜可另外建模。而此兩模式中，幾何的影響並不顯著，「假日」與「南下班次」則為顯著正向影響警示事件異常程度；「駕駛資歷 10 年以上」與「車速」則是負向影響，可能係較為熟練的駕駛較有可能對駕駛動態與危急狀態事先感知。發車時段方面，以白天為基礎，晨峰發生警示的異常程度，顯著大於白天，而白天又顯著大於晚上，這可能是與晨峰的車流環境較為擁擠複雜有關。

車道偏移模式則可看出幾何特性中，「大彎道」對此類事件的正向影響，此外當下「小車比例」越高，可能車種較為單純，駕駛較不注意，導致切換車道或駕駛時較為不小心。因此，「分心」也呈現顯著正向影響警示的異常程度，其餘日期、方向性、天候與駕駛班表等因素，則未有顯著影響之結果。

本年度新增的高速接近前車(FCWH)模式在模式中的顯著因子較少，僅有車速為負向顯著，可能與事件類別定義為高速接近本身即有一定矛盾處，其餘則為稍微(10%)顯著之「當下車流量」、「雨天」、以及發車時段「凌晨」較白天較不易發生異常程度高的警示事件。

而嚴重車道偏移(SLDW)其定義係在短時間內發生數次車道偏移(向左或向右，LDWL & LDWR)，幾何特性包含「彎道」皆不顯著，但分心的係數與正向顯著程度皆相當明顯，表示短時間內觸發多次車道偏移相關的警示事件，駕駛可能已難以正常平穩駕車，而開始有沿途車身動態搖晃擺動之跡象。橫跨所有模式比較，會發現縱使樣本不多，但車道偏移的模型解釋力，其 ρc^2 皆明顯較高。也可能是不同的警示項目類別，關鍵的危險情境不同，而側向偏移的已有相當的模式解釋力，而車距相關的外因尚多，尚有後續研究改善的空間。後續章節則也針對業者或道路主管機關如何落實教育與管理進行討論。

表 7.4-13 事件異常程度普羅比模式校估結果

解釋變數	警示事件類型				
	全類型	未保安距	車道偏移	高速接近前車(FCWH)	嚴重車道偏移(SLDW)
幾何特性					
大彎道	0.022 (0.056)	0.031 (0.606)	0.295. (0.177)	0.440 (0.188)	0.198 (0.418)
彎道	0.002 (0.053)	0.006 (0.061)	0.114 (0.179)	0.267 (0.172)	-0.125 (0.423)
坡道	0.069 (0.066)	0.048 (0.072)	0.213 (0.190)	-0.050 (0.2133)	0.555 (0.459)

表 7.4-13 事件異常程度普羅比模式校估結果 (續 1)

解釋變數	警示事件類型				
	全類型	未保安距	車道偏移	高速接近前車(FCWH)	嚴重車道偏移(SLDW)
交通環境特性					
事件發生時車速(公里/小時)	-0.005*** (0.001)	-0.005*** (0.001)	-0.012 (0.086)	-0.015*** (0.008)	-0.018 (0.018)
當下 5 分鐘 VD(pce)	0.000 (0.001)	-0.000 (0.000)	0.000 (0.000)	-0.001. (0.000)	0.000 (0.000)
當下 5 分鐘 VD 平均小車比例	0.215 (0.161)	-0.170 (0.182)	1.169** (0.424)	-0.702 (0.502)	1.359 (0.935)
假日	0.182*** (0.053)	0.219*** (0.057)	-0.065 (0.175)	-0.071 (0.320)	-0.846. (0.489)
南下班次	0.205*** (0.047)	0.226*** (0.051)	0.206 (0.153)	0.490*** (0.163)	-0.539 (0.399)
雨天	-0.072 (0.075)	-0.040 (0.081)	-0.200 (0.248)	-0.409. (0.246)	-0.982 (0.632)
夜間	-0.003 (0.071)	0.077 (0.077)	-0.268 (0.230)	-0.570** (0.227)	0.649 (0.467)
駕駛特性					
分心事件	0.500*** (0.062)	0.417*** (0.080)	1.290*** (0.141)	-0.472 (0.363)	1.746*** (0.456)
駕駛資歷(10 年)	-0.084. (0.047)	-0.099* (0.050)	-0.020 (0.159)	-0.124 (0.165)	-0.513 (0.585)
該趟次已行駛時間	-0.000 (0.001)	0.000 (0.001)	0.000 (0.001)	-0.000 (0.000)	-0.016 (0.001)
駕駛 24 小時內排班趟次	-0.083. (0.047)	-0.078 (0.051)	-0.019 (0.155)	-0.055 (0.164)	-0.012 (0.384)
駕駛 72 小時內排班趟次	-0.000 (0.025)	-0.022 (0.027)	-0.002 (0.082)	-0.019 (0.078)	0.315 (0.203)

解釋變數	警示事件類型				
	全類型	未保安距	車道偏移	高速接近前車(FCWH)	嚴重車道偏移(SLDW)
駕駛 168 小時 內排班趟次	0.017 (0.016)	0.025 (0.018)	0.023 (0.049)	0.007 (0.045)	-0.034 (0.114)
發車時段為 凌晨	-0.015 (0.074)	0.029 (0.081)	0.164 (0.227)	-0.576 (0.306)	-0.358 (0.516)
發車時段為 晨峰	0.281*** (0.063)	0.312*** (0.066)	-0.100 (0.254)	-0.115 (0.256)	0.682 (0.644)
發車時段為 昏峰	-0.152 (0.102)	-0.207 (0.108)	0.268 (0.376)	-0.188 (0.284)	-0.719 (1.026)
發車時段為 晚上	-0.247** (0.100)	-0.132 (0.115)	-0.243 (0.284)	-0.104 (0.279)	0-0.584 (0.608)

表 7.4-13 事件異常程度普羅比模式校估結果 (續 2)

解釋變數	警示事件類型				
	全類型	未保安距	車道偏移	高速接近前車(FCWH)	嚴重車道偏移(SLDW)
AIC	4395.147	3843.993	488.169	473.799	130.144
BIC	4526.828	3972.096	580.921	555.465	190.841
LL(C)	-2271.91	-1964.45	-294.23	-249.73	-45.88
LL(β)	-2176.57	-1900.99	-223.08	-215.90	-44.07
ρc^2	0.0420	0.0323	0.2418	0.1355	0.3561
觀察值	3,907	3,295	612	361	133

7.5 時空分析結果之管理意涵

本計畫針對時空分析，從巨觀的路段、趟次，到微觀的警示事件異常程度，且尚可分不同的警示類型進行建模，並且從各項模式中，檢視出影響發生警示事件的關鍵變數，可分別針對業者內部訓練，以及路權機關管理所用。

以業者而言，更偏向使用端，通常不會針對 ADAS 系統與營運時產生的資料再進行相關分析，因此本計畫可直接就長期蒐集的資料建模呈現的結果，明確告訴業者，哪些車內行為可能與警示事件，甚至異常程度高的警示事件有明顯的關聯，應該要在平常落實教育訓練，駕駛需要

盡可能避免相關動作。例如交通特性、幾何與設施特性，可看見車流量、服務區，時段性(假日、方向等)，有些可能警示反而較少，是因為交織較多，駕駛人多加注意而使得模式影響為負向，但有警示紀錄資料代表仍會發生，司機應該多加注意；內部則在排班時也須注意，長時間派班越多時，從趟次模式中發現發生警示事件的次數也較多。

以路權機關而言，道路線型與幾何常在模式中為正向影響警示事件發生頻次或異常程度，但土建與幾何更動並非容易且可隨時更動，因此在部分警示頻次較高處，或許未來可以提供用路人資訊。簡單者如標誌牌面立牌，如目前道路上常見提醒險降坡、易肇事路段等提醒；其他則可能在未來，由於本計畫有透過路段切割，或許可以將路段風險以指標量化，以等高線或是色塊方式，提供用路人即時或非線上即時的高風險路段、路廊資訊。

本計畫第1年期曾將巨觀的路段分析模式與事故資料進行比對，除了事故與部分警示事件有較高相關性外，路段分析雖然幾乎無法掌握駕駛者資訊，但反映的是長時間較為穩定不變的道路狀態影響，當時即已透過「交通事故觀察值」，以及「未保持安全距離警示事件預測值」，將模式結果分為4個象限，期能找出高風險路段(或匝道)，且可劃分出路段風險管理象限圖(如圖 7.5-1)，指出最優先、盡量改善路段，以及長期觀察、低風險等路段。優先改善的方式則可由初步的標誌牌面、CMS 提供駕駛人資訊，並評估是否有機會針對該路段所被評為高風險的關鍵因素，是否能夠透過交通管理或幾何更動的方式改善。

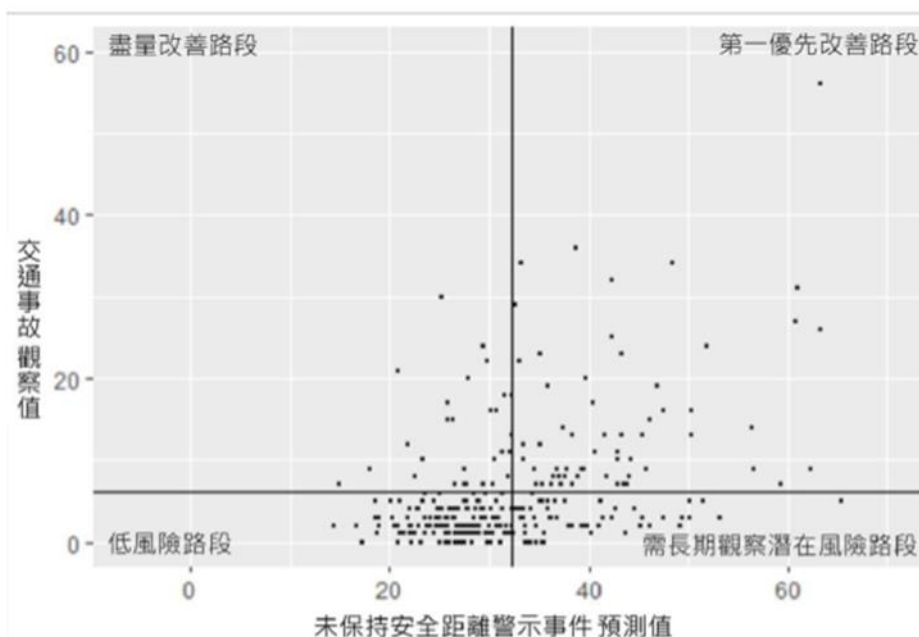


圖 7.5-1 前期分析路段風險管理象限圖

7.6 小結

本年度之時空分析主要著重在完整各項由巨觀到微觀的樣本，以及延伸連接的資訊流。透過本計畫已定義之 ADAS 系統等級，從中可整理出 ADAS 與 GPS、OBD 結合為第 II 類；加入車內影像資料、DMS，則為第 III 類；若再向外部勾稽資料，包含國道幾何、車流等資訊，則為第 IV 類。此外，也呈現若資料有某方面的不足，可以就現有資料的部分，挑選合適的模式與欄位，進行有需要的分析及對應的應用。

本計畫針對時空分析，目前除了 7.5 節所述，可發展出供管理機關提供給用路人的高風險路段、路廊通報之構想外，尚有兩個部分可再於日後進行延伸，其一為單以 OBD 資料的分析方法以及準確度。OBD 資料以觸及高風險駕駛行為門檻，從逐秒的資訊撈取可能的潛在警示事件候選樣本，並透過時間、地點與國道幾何、車流等勾稽，進行分析建模。未來尚可透過既有的 ADAS 資料，再與這些 OBD 資料由觸發高風險門檻之紀錄，兩相比對是否有關連性。

此外，為探索各自駕駛是否有自己的駕駛習慣，以及是否時間變化，其駕駛習慣有所改變，也較利於業者可以找出個別司機的駕駛特色，以及較常遇到、發生的警示事件。是故，將嘗試再以「司機」為分析單位

之新架構，此架構分析概念如圖 7.6-1，並由圖可知，月份與時間變化也可能使駕駛特色改變，宜應一併考量。依照此三年期計畫，已蒐集約 100 人月之樣本，惟目前各月份中駕駛趟次數量變異較大，部分司機開行趟數較少，樣本是否足夠，尚待未來繼續嘗試與確認。如此，若可依照各司機進行分析，亦將依照一定之路段長度進行分析單位切割，以掌握適用於個人的高風險路段或匝道處。

	一個月							
							
時間	一個月							
	一個月							
	一個月	異常事件 分心事件 警示事件						
		駕駛 1	駕駛 2	駕駛 3	駕駛 4	駕駛 5	駕駛 i
		駕駛						

圖 7.6-1 各司機依月份分析概念示意圖

相較於路段分析，以每位司機依月份進行分析，即為以個人為單位，將其在當月份所駕駛之所有異常、警示、高風險駕駛行為事件進行加總，目的是看出該司機個別的駕駛型態，以及好發各類事件之地點，可讓公司能重點教育與管理。因此，若能依照個別司機，則可以同時針對一定長度時間內，鎖定每位駕駛員各自發生的行車異常事件，可以獲得更多駕駛人因素的資訊。同時，若某位駕駛有較為特別之駕駛習慣或該駕駛有較好發行車異常事件、高風險駕駛行為之地點，則不會被路段、趟次分析方式模糊化，較能針對個人對症下藥，加強教育。

第八章 行車異常事件管理雛型系統開發

8.1 雛型系統架構

本節將介紹結合先前章節之分析結果與行車影像後建立之管理平台，期能透過此平台協助運輸業者提升管理效率。

8.1.1 概念說明

現今的運輸業者在車隊管理上面臨幾個主要的問題，包括駕駛在外行駛之行為難以控管、資料量龐大人工處理成本過高、無法量化風險值難以管理預防等。其中若無法量化事件風險值，僅由管理階層根據其主觀想法認定事件之危險程度，將難有足夠說服力促使旗下駕駛改善其駕駛行為，達到駕駛安全管理教育之目的。因此本計畫建置之管理平台將藉由 AI 辨識結合車載系統等客觀資料識別行車異常事件並計算其風險值，在節省處理資料所花費之大量時間及人力成本的同時也能夠量化各個行車異常事件之風險值，協助運輸業者更有效率執行車隊管理。

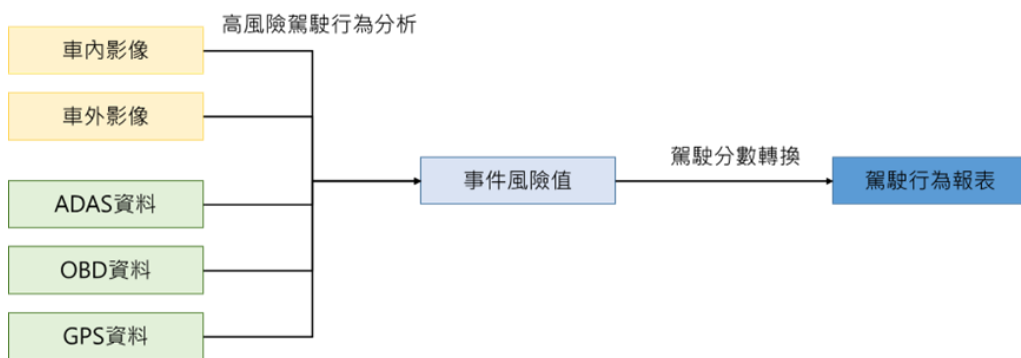


圖 8.1-1 雛型系統概念圖

8.1.2 系統組成與業者管理之連結

本計畫開發之系統欲協助業者節省資料處理成本並量化高風險駕駛行為進行管理，因此需快速找出高風險駕駛並優先將改善資源投注於該類別駕駛，介面設計分為四個部分，包含首頁呈現車隊所有駕駛員的行為報表（圖 8.1-2）、深入瞭解各駕駛表現之駕駛綜合報表、關注特定事件

之行車異常事件報表以及上傳車機及影像資料之行車影像風險分析，各介面所含之功能如表 8.1-1 所示，以下也將分別說明各區在應用於管理之構想。

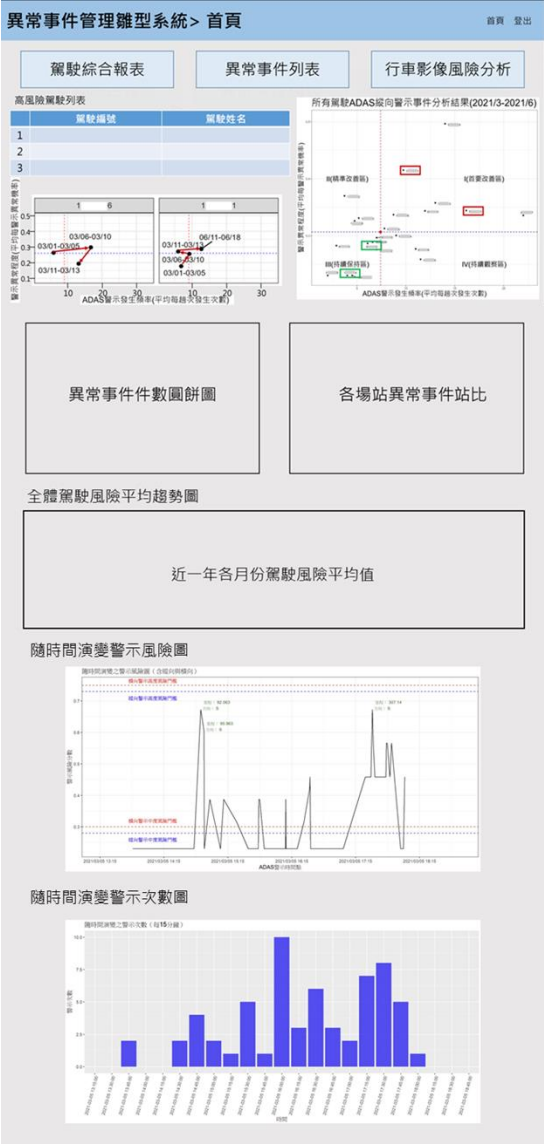


圖 8.1-2 首頁報表介面

表 8.1-1 雛型系統功能列表

功能名稱	是否開發完成
首頁	
駕駛綜合報表按鈕	是
行車異常事件列表按鈕	是
行車影像風險分析按鈕	是
高風險駕駛列表	否
時間動態之駕駛風險變化圖	否
駕駛風險象限圖	否
行車異常事件件數圓餅圖	是

表 8.1-1 雛型系統功能列表 (續)

功能名稱	是否開發完成
首頁	
近一年各月份駕駛分數趨勢圖	否
各場站行車異常事件占比	否
隨時間演變之警示風險圖	否
隨時間演變之警示與異常行為次數圖	否
駕駛綜合報表	
駕駛搜尋	是
駕駛風險判定	是
駕駛行車異常事件雷達圖	是
近一年駕駛風險變化趨勢圖	否
行車異常事件列表	是
檢視影片	是
行車異常事件列表	
近一年行車異常事件件數變化趨勢圖	否
行車異常事件列表	是
檢視影片	是
行車影像風險分析	
手動輸入駕駛姓名、車號、日期	是
影像、車機資料上傳	是
資料分析	是

首頁 (圖 8.1-2) 最上方提供三個按鈕供使用者依需求進行點選，按鈕下方右側呈現一橫軸為所有 ADAD 警示事件/趟次，縱軸為加總風險分數/警示事件的象限圖 (圖 8.1-3)，本圖之象限界線以橫軸與縱軸之中位數做為範本呈現，未來業者在應用上仍可依需求調整。圖上點位為一駕駛在車隊中的相對表現，第一象限定義為首要改善區代表不論是警示事件或是警示風險程度皆偏高之族群；第二象限定義為精準改善區表示警示次數雖少但發生的風險值皆偏高之族群；第三象限定義為持續保持區該區駕駛數值皆偏低；第四象限定義為持續觀察區警示頻率雖高但風險程度大多不高。藉由象限圖可供業者快速辨別不同風險族群之駕駛，位於第一象限 (紅色) 範圍內之駕駛也將列於象限圖左側之列表中，另若選取列表中之駕駛將於列表下方呈現時間動態之駕駛風險變化圖，確認駕駛是否常態處在高風險的區域或是在實施教育後的變化。在高風險駕駛列表下方則將車隊總行車異常事件件數、駕駛分數趨勢變化與場站行車異常事件站比分別列出，幫助業者在資源分配上做出決策。

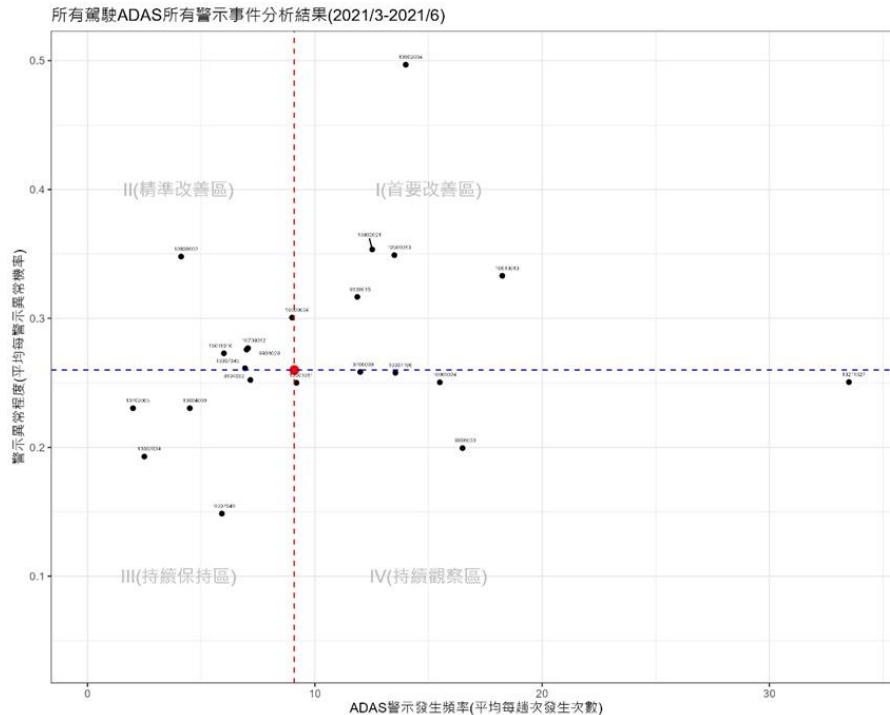


圖 8.1-3 駕駛風險象限圖

除了上述的象限圖之外，本計畫預計在未來的離型系統中，增加每一位駕駛在每一個趟次的風險報表。該風險報表主要顯示每個駕駛趟次中，警示風險的高低值隨時間的變化，以及分心動作與超速隨時間變化而產生的次數，最後，甚至也包含了發生警示的事件在每個 15 分鐘為間隔的時段內發生的次數。

圖 8.1-4 為隨時間演變之警示風險圖，而警示事件包含縱向與橫向，圖中藍色虛線表示縱向警示的中度風險與高度風險門檻值，紅色虛線則為橫向警示的中度風險與高度風險門檻值。從這四條線所在的位置，可以非常清楚地了解該趟次的整體警示風險狀況。如圖 8.1-4 所示，該趟次不論是縱向或橫向警示，均未達高度風險的門檻。此外，本計畫亦會在風險較高處標示里程與行駛方向(由北往南或由南往北)，希望藉由這個額外增加的文字，能夠提醒業者與駕駛者該段里程處可能為容易發生風險較高警示之地方。

此外，本計畫也嘗試將縱向警示與橫向警示分別作圖，如圖 8.1-5，為另一趟次之橫向警示的風險值，隨趟次時間變化之高低起伏變化。從圖 8.1-5 可以發現，該趟次之橫向警示的風險值均未達中度風險，表示該趟次在橫向警示上，風險並不高。綜上所述，隨時間演變之警示風險圖，

可以非常清楚地呈現該趟次的風險變化，因此，做為駕駛的風險報表，能夠從中做出許多管理策略，如若某一位駕駛在該趟次後半段較容易出現風險較高之警示，可能代表該駕駛在長距離旅次下，容易感到疲憊或分心，因此，相關業者與管理單位則可以進一步加強駕駛在趟次後半段之注意力，以避免事故發生之風險。

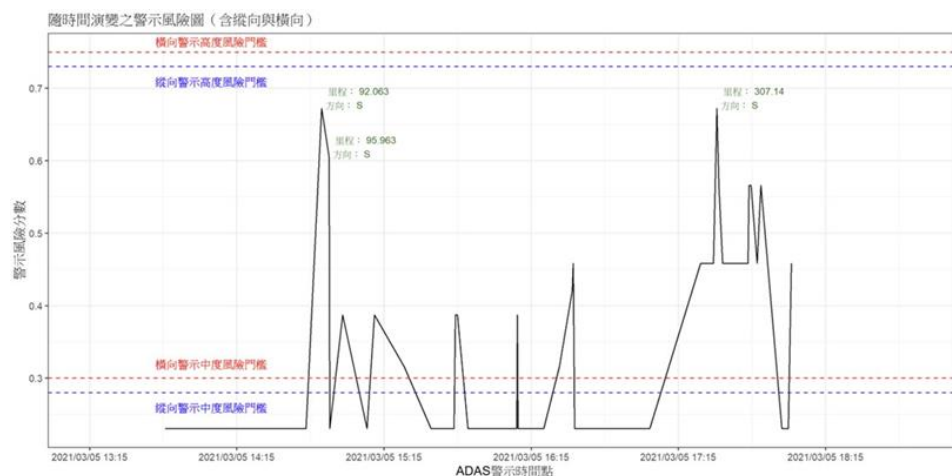


圖 8.1-4 隨時間演變之警示風險圖 (含縱向與橫向警示)

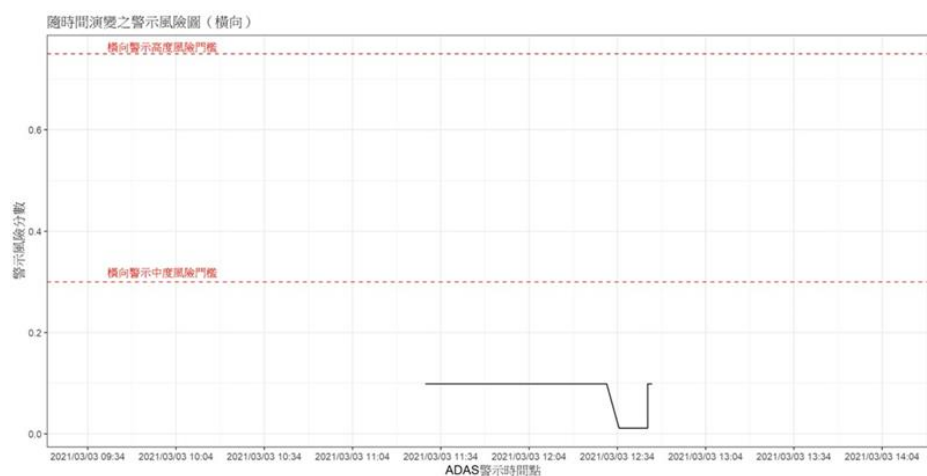


圖 8.1-5 隨時間演變之警示風險圖 (橫向警示)

本計畫在駕駛風險報表中，也預計將隨時間變化之分心動作次數放入圖層。如圖 8.1-6 為每 15 分鐘為一個級距，駕駛者右手離開方向盤的次數總和；圖 8.1-7 則為駕駛者超速的次數總和。透過這些報表的呈現，可以使駕駛者或管理單位比較風險高低圖與分心動作次數圖，探討分心動作出現的次數是否可能與風險高低有所關聯。此外，也能夠藉由這些圖層，了解不同駕駛者較容易出現的分心動作，直接地修改不應出現之分心動作，改善整體駕駛安全文化。最後，圖 8.1-8 為隨時間演變之 ADAS

警示次數圖，更直觀地，駕駛與管理單位可以透過此圖了解駕駛整個趟次的粗略的駕駛狀況。雖然警示數量不完全代表異常的數量，但仍可以透過此圖，大致了解該位駕駛在該趟次的駕駛表現。

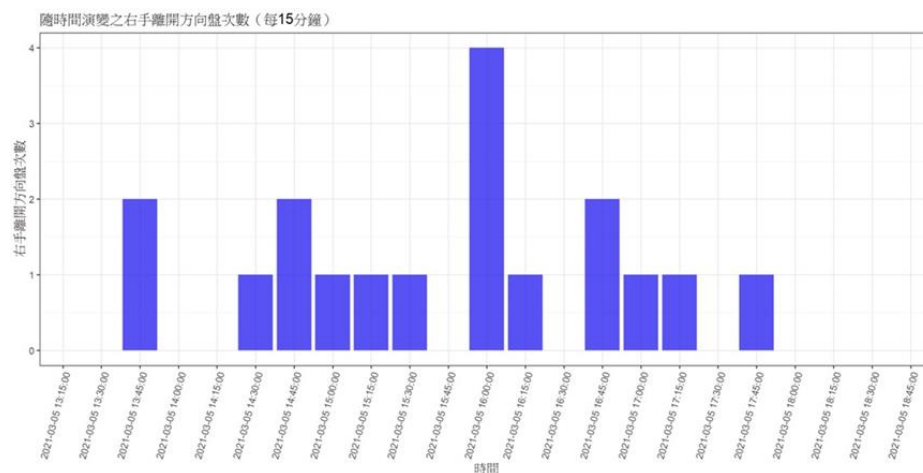


圖 8.1-6 隨時間演變之右手離開方向盤次數

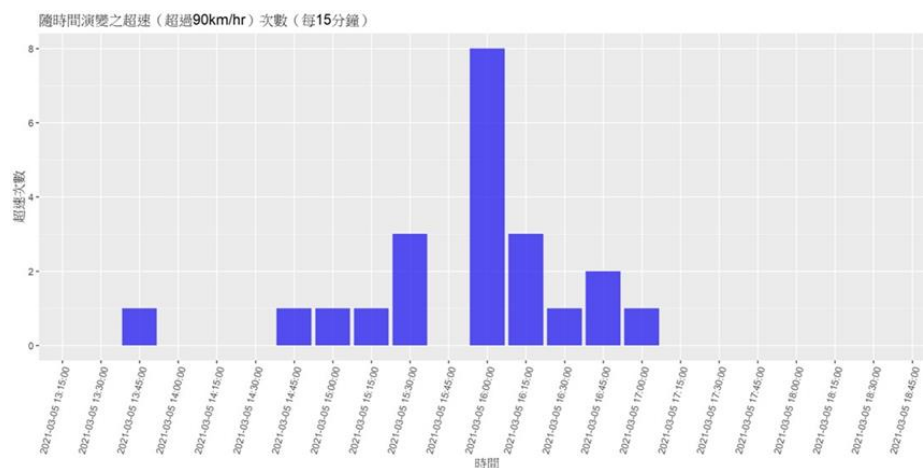


圖 8.1-7 隨時間演變之超速次數

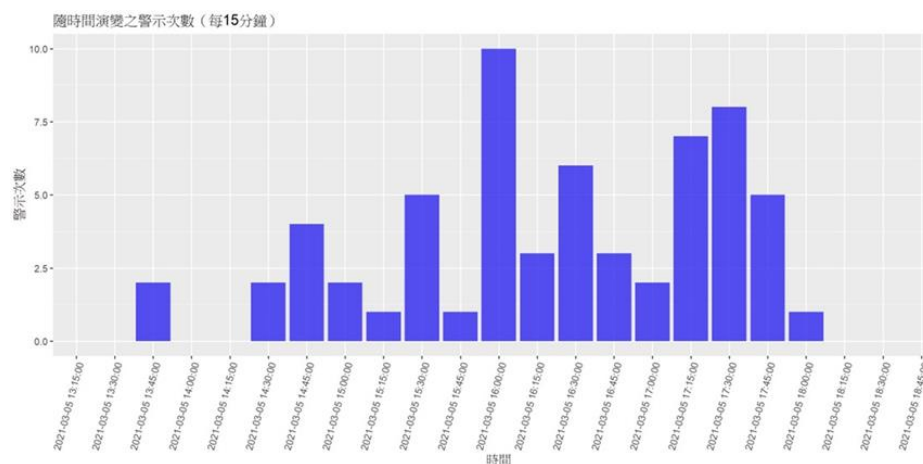


圖 8.1-8 隨時間演變之警示次數

在車隊管理上業者的首要目標便是改善高風險駕駛行為以降低事故發生的機會，若欲深入瞭解特定駕駛可進入駕駛綜合報表介面 (圖 8.1-9)，介面除了顯示駕駛的風險等級外與駕駛異常雷達圖供業者確認該名駕駛哪一類異常行為事件發生次數較多外，也將以折現圖呈現駕駛近期表現的變化趨勢。此外會於最下方列出駕駛所有的行車異常事件資訊，包含樣態、時間、地點、影像等，業者可透過影像檢視發生當時的路況或駕駛做出的舉動做統整分類，研擬一套駕駛行駛過程中的標準作業程序，不僅對高風險駕駛有對症下藥的效果之外也能做為日後新進或定期駕駛安全教育訓練之教材使用。



圖 8.1-9 駕駛綜合報表介面

如車道偏移警示作用可能因駕駛在欲變換車道的同時正好在拿東西的狀態下導致未提前使用方向燈外也未確實注意路況。在標準作業程序上可將整個過程拆解為變換車道前、變換車道中兩階段，變換車道前應

先確認行駛車道與目標車道的路況以及是否有足夠的安全距離，接著確認後視鏡與盲區是否有其他車輛存在，待一切無虞後即可使用方向燈示意後方車輛本車即將變換車道提供後車足夠反應時間並雙手操控方向盤變換車道，在變換車道的過程中除須調整車速保持與前方車輛之安全距離外也須時刻注意由後方接近之車輛動態。

若業者欲擬定方案優先改善特定行車異常事件則可選擇行車異常事件列表 (圖 8.1-10)，介面將呈現該行車異常事件近期的件數變化趨勢圖，供業者確認改善成效。趨勢圖下方則列出所有該類行車異常事件，並如駕駛綜合報表介面列出事件相關資訊以及對應影像片段提供業者檢視。



圖 8.1-10 行車異常事件列表介面

最後行車影像風險分析介面 (圖 8.1-11) 做為將影像與車機資料上傳至系統與執行之區域。



圖 8.1-11 駕駛警示次數雷達圖

8.1.3 系統軟硬體架構

(一)硬體架構：

一部符合 Intel 或 AMD 架構的伺服器主機，並安裝具有 10GB 以上記憶體之 NVIDIA GPU 顯示卡。

(二)軟體架構：

雛型系統軟體架構由前後端組成，前端主要負責資料的呈現與使用者操作功能。後端則包含資料庫、車內外影像辨識模組、風險分析邏輯程式、高風險駕駛行為風險分數判定模組，請參閱下圖 8.1-12：

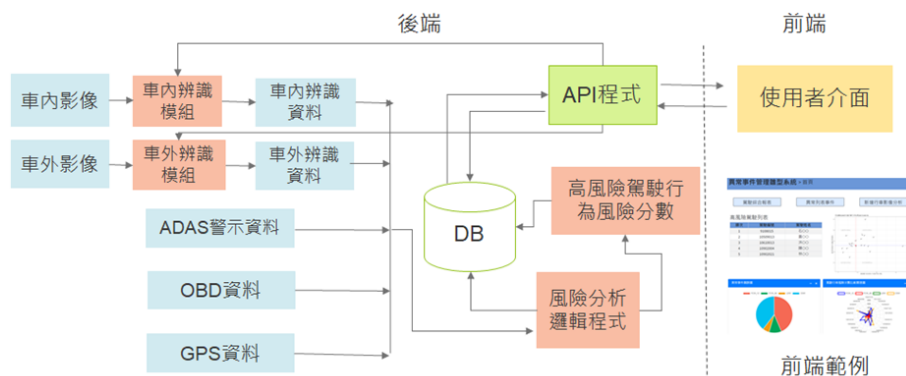


圖 8.1-12 雛型系統軟體架構圖

車外辨識模組主要負責車外道路物件辨識，並推算與前車的安全距離，請參閱 6.1 節說明。車內辨識模組負責駕駛員行為樣態辨識，請參閱 6.2 節說明。高風險駕駛行為風險分數判定程式使用 R 語言實作，主要整合各種資料來源，包含車內外辨識結果、ADAS 警示資料、OBD 資料、GPS 資料，並歸類駕駛行為風險以及判定其風險分數，如圖 8.1-13 所示。後端資料庫採用關聯式資料庫 MariaDB，儲存風險分析的結果以及駕駛員風險分數。前端與後端的溝通透過 HTTP API 來實現，使用者可在前端選擇開始進行駕駛行為風險分析，或是查看駕駛風險分數以及行車異常事件紀錄。

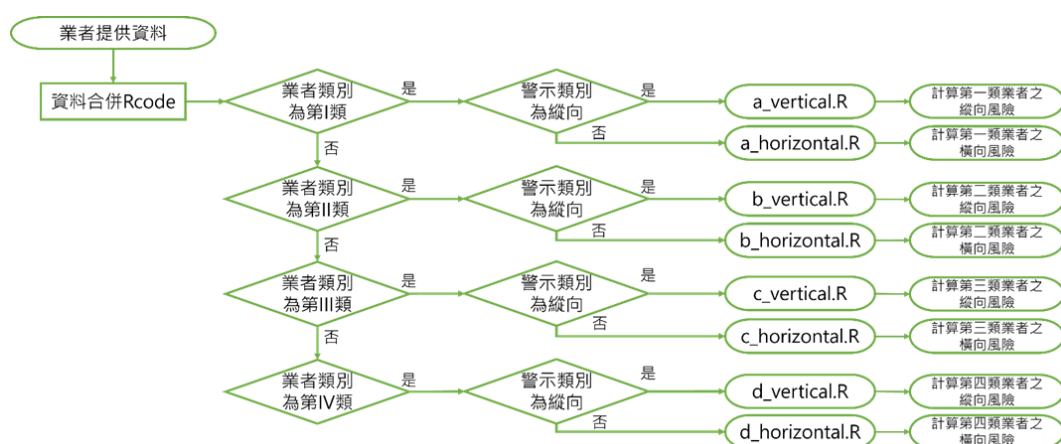


圖 8.1-13 離型系統資料處理邏輯設計架構

(一)軟體架構建置(1)：

軟體建置的第一階段是資料庫建置，並且建立資料表。其次建立系統主程式，連接資料庫。再其次，建立前端主頁以便與後端程式溝通。參閱下方示意圖 8.1-14：

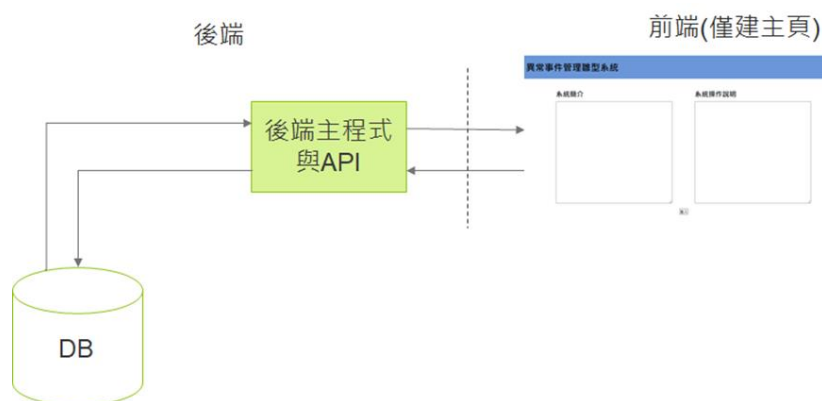


圖 8.1-14 離型系統軟體架構分部解說(1)

(二)軟體架構建置(2)：

第二階段實現核心模組整合，包含車內影像辨識模組、車外影像辨識模組、風險分析邏輯程式。此外，前端頁面提供使用者操作功能，包含輸入即將進行分析的行車日期、駕駛員資訊，並存放影片檔案與ADAS、GPS、OBD 資料檔案。系統透過 API 開始進行影像辨識，取得結果後呼叫風險分析邏輯程式。參閱下方示意圖 8.1-15：

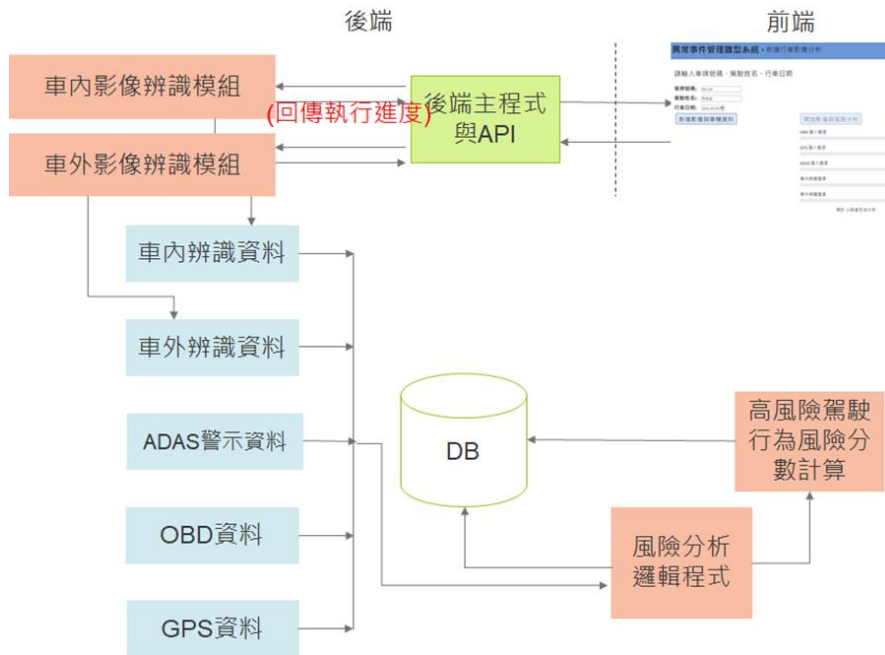


圖 8.1-15 離型系統軟體架構分部解說(2)

(三)軟體架構建置(3)：

第三階段實現使用者端操作功能，包含顯示查詢資料、選擇行車異常事件影片以及影片播放等。參閱下方示意圖 8.1-16：

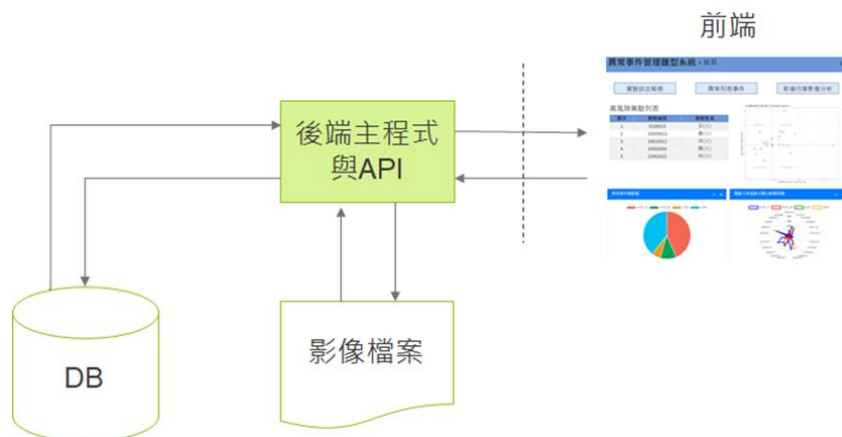


圖 8.1-16 離型系統軟體架構分部解說(3)

8.2 資料輸入格式與報表輸出樣式

系統所需資料共可分為兩類別，格式為 csv 之 ADAS、OBD 與 GPS 資料以及車輛行駛過程紀錄之影像資料，運輸業者可透過於車輛裝設之設備取得車輛行駛過程中之資料並將其上傳至平台，待上傳完成後系統即透過高風險駕駛行為分析計算事件風險值(詳見第四章)，接著透過羅吉斯回歸計算各駕駛之風險等級(詳見第七章)。資料部分由於各家業者安裝之設備皆有些微差異，可取得之資料也不盡相同，故本計畫將運輸業者分為四個類別，如表 8.2-1 所示。

表 8.2-1 各類型業者管理系統特徵彙整

管理系統類別	特徵
I	無 ADAS 系統；有 OBD、GPS
II	無 DMS；有 OBD、GPS、ADAS
III	無外部環境資料；有車內影像系統且與 ADAS 整合
IV	有外部環境資料，可加入天候、道路與車流狀況資料

以下將說明本期計畫完成開發並呈現於介面上之功能，首頁最上方共有三個按鈕提供業者更深入了解特定駕駛或事件以及上傳資料的區域，按鈕下方呈現所有行車異常事件之比例、各駕駛風險事件次數共兩個圖表提供業者參考是否需要就特定樣態或駕駛實施更積極的管理作為。



圖 8.2-1 首頁介面

駕駛綜合報表(圖 8.2-2)與行車異常事件列表(圖 8.2-3)功能大致符合 8.1.2 節提出之設計，惟本期計畫使用之資料時間區段較短無法呈現長期

趨勢，故系統介面皆尚未加入趨勢圖。另檢視影片欄位目前是將車內與車外影像分開呈現 (圖 8.2-4)，預計將於下一期計畫整合至同一視窗內供業者同時檢視。



圖 8.2-2 駕駛綜合報表介面



圖 8.2-3 行車異常事件列表介面



圖 8.2-4 影片呈現方式

8.3 雛型系統操作使用說明

雛型系統的主要功能是讓客運業者輸入行車資料並進行駕駛行為風險分析，然後在雛型系統的使用者介面檢視分析結果，包含駕駛綜合報表、行車異常事件紀錄、事件影像紀錄。

因此雛型系統的使用者介面設計包含四個主要頁面：「首頁」、「新增行車影像分析」、「駕駛綜合報表」、「行車異常事件列表」。

8.3.1 首頁頁面

首頁頁面是進入雛型系統後的第 1 個頁面，如圖 8.3-1 所示，這個頁面提供了 3 個功能按鈕「新增行車影像分析」、「駕駛綜合報表」與「行車異常事件列表」，點擊後可進入相對應的頁面。

首頁頁面同時也提供數個列表和數據圖，包含「高風險駕駛列表」、「駕駛 ADAS 警示事件分析結果圖」、「行車異常事件圓餅圖」、「駕駛行車風險次數比較雷達圖」。使用者在首頁頁面可快速瀏覽系統的風險分析結果。



圖 8.3-1 雛型系統首頁頁面

8.3.2 新增行車影像分析頁面

新增行車影像頁面用來將欲進行分析的行車資料輸入雛型系統，使用者可以輸入錄影檔案、ADAS 警示資料、OBD 資料、GPS 資料，連同輸入行車班次的駕駛者姓名、行車日期、車牌號碼。完成輸入行車資料後，點擊「開始影像與風險分析」按鈕，雛型系統開始進行影像與風險分析。畫面將顯示目前處理進度，並提供完成分析所需的預估時間，如圖 8.3-2 所示。

8.3.3 駕駛綜合報表頁面

駕駛綜合報表頁面顯示系統資料庫中駕駛者的行車異常事件紀錄與風險次數比較雷達圖，如圖 8.3-3 所示。使用者可在頁面上選取駕駛姓名，畫面將會顯示等級判定與上述相關風險分析結果。

請輸入車牌號碼、駕駛姓名、行車日期

車牌號碼: KKA-7662

駕駛姓名: 李先生

行車日期: 03/09/2021

新增影像與車機資料

請按下方說明置放資料

已在 /hdd/in_cabin 建立資料夾

請將影像放入 /hdd/in_cabin/video/KKA-7662/2021/0309

請將event_log.csv, gps.csv, obd.csv放入 /hdd/in_cabin/csv/KKA-7662/2021/0309

已確認放置完成

開始影像與風險分析

OBD 匯入進度

100%

GPS 匯入進度

100%

ADAS 匯入進度

100%

車內辨識進度

車外辨識進度

預計 60 分鐘後完成分析

圖 8.3-2 雛型系統新增行車影像分析頁面



圖 8.3-3 雛型系統駕駛綜合報表頁面

8.3.4 行車異常事件列表頁面

行車異常事件列表頁面顯示系統資料庫中已完成分析的行車異常事件紀錄，如圖 8.3-4、圖 8.3-5 所示。使用者可在頁面上選取各種行車異常事件種類，行車異常事件紀錄以列表方式呈現。行車異常事件紀錄中包含該事件的影片片段，點擊「車內」或「車外」按鈕，可開啟視窗播放事件影片。

異常事件管理雛型系統 > 異常列表事件

首頁 登出

異常事件: ALL

選定事件列表 共 1838 件

順次	駕駛編號	駕駛姓名	時間	地點	車速	檢視影片
1	10501011	黃○媛	2021-03-01 02:10:06	0	75.4286	車內 車外
2	10501011	黃○媛	2021-03-01 02:33:03	87.019	92.7143	車內 車外
3	10501011	黃○媛	2021-03-01 02:53:03	119.206	94.5676	車內 車外
4	10501011	黃○媛	2021-03-01 02:57:43	126.596	88.4615	車內 車外
5	10501011	黃○媛	2021-03-01 02:53:03	126.596	92.381	車內 車外
6	10501011	黃○媛	2021-03-01 03:28:23	175.915	94.4762	車內 車外
7	10501011	黃○媛	2021-03-01 04:20:45	261.154	101.962	車內 車外
8	10501011	黃○媛	2021-03-01 04:20:51	261.376	101.314	車內 車外
9	10501011	黃○媛	2021-03-01 04:20:45	261.376	101.692	車內 車外
10	10610013	洪○翔	2021-03-01 08:01:20	132.24	97.8571	車內 車外

上一頁

1

2

...

184

下一頁

圖 8.3-4 雛型系統行車異常事件列表頁面

異常事件管理雛型系統 > 異常列表事件

首頁 登出

異常事件: ALL

選定事件列表 共 1

順次	駕駛編號	駕駛姓名	時間	地點	車速	檢視影片
71	10211027					車內 車外
72	10211027					車內 車外
73	10211027					車內 車外
74	10211027					車內 車外
75	10211027					車內 車外
76	10211027					車內 車外
77	10211027					車內 車外
78	09307049					車內 車外
79	09307049	王○宏	2021-03-03 20:20:37	197.029	94.4062	車內 車外

圖 8.3-5 雛型系統播放行車異常事件影片紀錄

8.4 雛型系統資料前處理說明

車內的分心行為判斷中，部分行為（手所在區域、操作車內設備、伸手拿東西）的判斷需要知道車內的區域，並根據駕駛手部在其中哪個區域。因此每一輛車需要事先定義車內空間區域劃分，包含以下區域：前方儀表板區、冷氣與音響設備、左邊車門置物區、方向盤附近、駕駛座與副駕駛座中間、副駕駛座附近、駕駛座後方，依序定義為 A 至 G 區域，如圖 8.4-1 所示。可以透過各標記工具，例如 LabelMe，以多邊形方式標記車內區域。



圖 8.4-1 車內區域劃分範例說明

第九章 國道客運駕駛安全管理策略建議

本章統整本期與前兩期計畫之研究成果，分別由駕駛管理 (9.1 節)、車隊管理 (9.2 節)、設備管理 (9.3 節) 三個面向，提出客運業者安全管理之影響因素及相關改善與管理策略建議，供客運業者參考。

9.1 駕駛管理

針對駕駛管理部分，可分為三部分：課程、評分機制、個人管理。在課程部分，分為兩類：設備操作、道路環境，業者可藉由開設教育訓練課程，教育駕駛員有關設備操作，如安全使用車內設備、對講機、攝影機等，道路環境相關課程，如哪裡是好發事故、行車異常事件之地點與交通環境及高風險的路段或情境，如第一期計畫中所建置之高速公路風險路段時空分析平台，產出趟次路線中好發交通事故、警示事件、行車異常事件之路段，如圖 9.1-1 所示；在評分機制部分，可利用固定期間評分的駕駛分數做為一種管理方式；在個人管理部分，分為三類：衣著管理、配備使用、個人習慣，主要藉由駕駛員自身的職業素養與業者之培訓，達到在駕駛期間著正式制服、正確的車內配備使用及良好的個人習慣與駕駛習慣。



圖 9.1-1 趟次路線中好發交通事故、警示事件、行車異常事件之路段示意

而業者可將這些駕駛管理手段製作成教育訓練手冊或規劃成教育訓練流程，將每個駕駛員皆須遵守之安全設備操作、ADAS 警示提醒、不可有之違規舉動，如圖 9.1-2 所示之使用手機、圖 9.1-3 所示之抽菸等項目皆列入其中，並透過駕駛員之不同路線安排給予不同交通環境不同課程內容的教育方針，強化各駕駛員對於所駕駛之路線及交通環境有更深的了解，同時注重個人習慣與駕駛習慣，如圖 9.1-4 所示之擺頭、著正式制服等，讓駕駛員皆能安全駕駛，並加入業者內部的評分獎懲制度，達到實

際落實教育訓練成果之目的，駕駛管理之安全管理策略架構如圖 9.1-5 所示。



圖 9.1-2 違規舉動—使用手機



圖 9.1-3 違規舉動—抽菸



圖 9.1-4 良好之個人習慣與駕駛習慣—擺頭、著正式制服

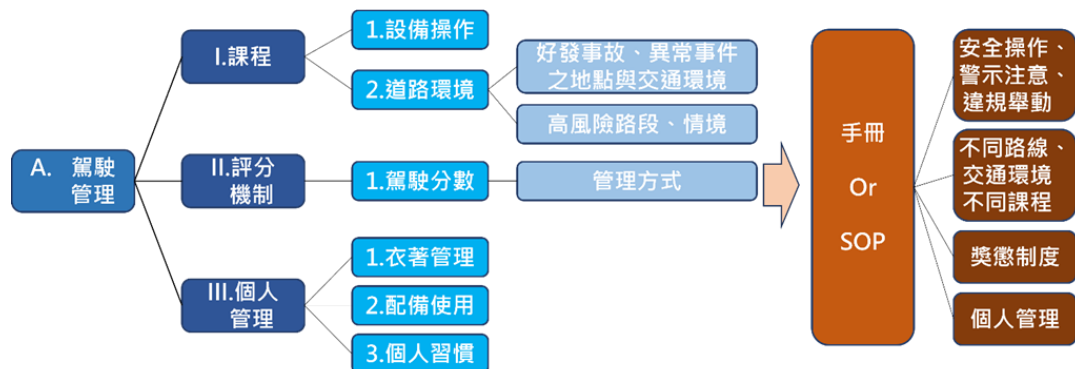


圖 9.1-5 駕駛管理之安全管理策略架構

本計畫經過三年期之研究，蒐集並彙整與駕駛管理相關影像辨識影響因素、改善策略及管理策略，與駕駛管理有關之行車異常事件、時空分析、高風險駕駛行為改善策略及管理策略，如表 9.1-1、表 9.1-2 所示，期望能對於業者實際進行駕駛管理時有較明確的改善目標。

表 9.1-1 與駕駛管理有關之影像辨識影響因素、精進策略及管理策略

分類	影像辨識影響因素	影像辨識精進策略	業者管理策略
日間	天氣不佳 (濃霧、陰天)	使用改善後的模型 YOLOV7，增加辨識正確率。	1. 參考技術、規格、功能在建置系統的成本考量下，提供適當的警示功能與駕駛行為訓練，以提昇習駕駛及用路人之道路安全。 2. 影像辨識以人眼可視的鏡頭成像品質為基本要求，且支援需求算力足夠的運算平台。
	降雨	選取可降低鏡頭前凝水效果之方法 (如使用防潑水劑)。	
夜間	路燈照明影響	1. 選取夜間成像效果較佳的影像鏡頭感光元件。 2. 使用改善後的模型 YOLOV7，增加辨識正確率。	
	降雨	選取可降低鏡頭前凝水效果之方法 (如使用防潑水劑)。	
駕駛車內動作	遮蔽身體部位	1. 改善偵測網路，使用 YOLOX-x + ViT Pose 的新型偵測架構。 2. 既有行車影像記錄器設備增設智慧設備(AI Box)。 3. 整合車輛控制器區域網路數據。	1. 硬體設備改善，例如更換相機、行車影像記錄系統。 2. 依據管理駕駛需求特性、主要行駛區域環境與情境，以及車隊運行常發分心事件等因素，提供適當的警示功能與駕駛行為訓練，以提昇駕駛及用路人之交通安全。
	動作短暫微小		
	姿勢不良		
駕駛員本身	衣著色彩單一	改善偵測網路，使用 YOLOX-x + ViT Pose 的新型偵測架構。	駕駛衣著改善，例如指定制服，如手部和身體顏色不同的背心或是衣服上有一些顯眼的線條。

表 9.1-2 與駕駛管理有關之行車異常事件、時空分析、高風險駕駛行為改善措施及管理策略

分類	研究結果	改善措施	管理策略
行車異常事件	<ol style="list-style-type: none"> 1. 手離開方向盤、身體前傾、身體右傾、操作與行車安全無關之設備、拿東西、用手機及手靠近嘴巴等變數，皆與分心有顯著正相關。 2. 前車變換車道時，駕駛高速接近前車(FCWH)，容易發生行車異常事件。 3. 本車變換車道時，本車離前車太近(SDW0.4)且駕駛有操作非撥桿的車內設備動作，容易發生行車異常事件。 4. 本車車道偏移時，當駕駛有身體前傾、雙手離開方向盤、拿東西等無法即時適當控制車輛的動作，容易發生行車異常事件。 	<p>建議業者教育駕駛員於以下情境時之駕駛行為：</p> <ol style="list-style-type: none"> 1. 前車變換車道情境—應降低車速同時減少分心動作，以避免發生行車異常事件。 2. 本車變換車道情境—應避免離前車過近以及操作非撥桿的車內設備。 3. 行駛當下情境—應減少手離開方向盤、拿東西這種無法即時適當控制車輛的動作與行車無關之動作，且避免用手機之違規舉動發生，並應確實保持安全車距。 	<ol style="list-style-type: none"> 1. 短期建議主管機關敦促業者注意駕駛員之車內異常行為狀況。 2. 中期則蒐集車內分心行為所導致之行車異常事件案例，並將其納入職業駕駛考照及回訓中，使駕駛員產生警惕。 3. 建議主管機關於長期建立車內異常行為之查核機制，針對異常行為進行查核，如：納入評鑑指標等。 4. 建議主管機關可針對駕駛員之生理需求(如吃東西、喝水等)
時空分析	分心行為不論從巨觀至微觀的角度，都對警示事件、行車異常事件造成顯著正向之影響。	建議業者針對設施、幾何、交通環境因素分析出的熱區外，也教育與約束駕駛員不應做出車內異常行為、分心行為。	研擬操作指引，敘明上述行為發生之合適情境，於考照及回訓時教導駕駛員，並輔導客運業者建立 SOP 以利駕駛人安全管理。
高風險駕駛行為需特別關注之風險項目	<ol style="list-style-type: none"> 1. 雙/單手離開方向盤 2. 拿東西 3. 用手機 4. 未於前車變換車道時擺頭 5. 車距 6. 加速度 	<p>建議業者需關注之風險項目：</p> <ol style="list-style-type: none"> 1. 駕駛動作：手離開方向盤、拿東西、用手機與前車變換車道時擺頭。 2. 行車動態：保持安全車距、加減速度變換。 	

9.2 車隊管理

針對車隊管理部分，可分為兩部分：車內管理、後臺管理。在車內管理部分，分為三類：設備、監控系統、座艙特性，車內設備除了基本座位設施、通訊設備，裝設之攝影設備需有能清晰錄製車內環境或駕駛動作之規格，並時間要與車機設備相同，車隊管理才容易持續進行，而

監控系統需與 ADAS 系統及其他車機系統進行整合與更新，在座艙特性中，包含座位位置、方向盤位置固定、光線強度位置等皆會影響車內管理的統一性，若座艙位置不佳或光線不足恐造成車內行為辨識不佳而使車內管理不易，如圖 9.2-1 所示；在後臺管理部分，分為兩類：設備、系統，後臺管理的設備包含業者進行車隊管理之後臺電腦及資料庫，兩者皆需要一定規格及效能來進行大量駕駛員資料的處理分析，而系統則包含運用 ADAS 警示之風險門檻值、影像辨識之車內外行為指標與本計畫目前開發之雛型系統，做為車隊管理中後臺管理之重要項目，車隊管理之安全管理策略架構如圖 9.2-2 所示。



圖 9.2-1 車內光線不足造成影像辨識困難

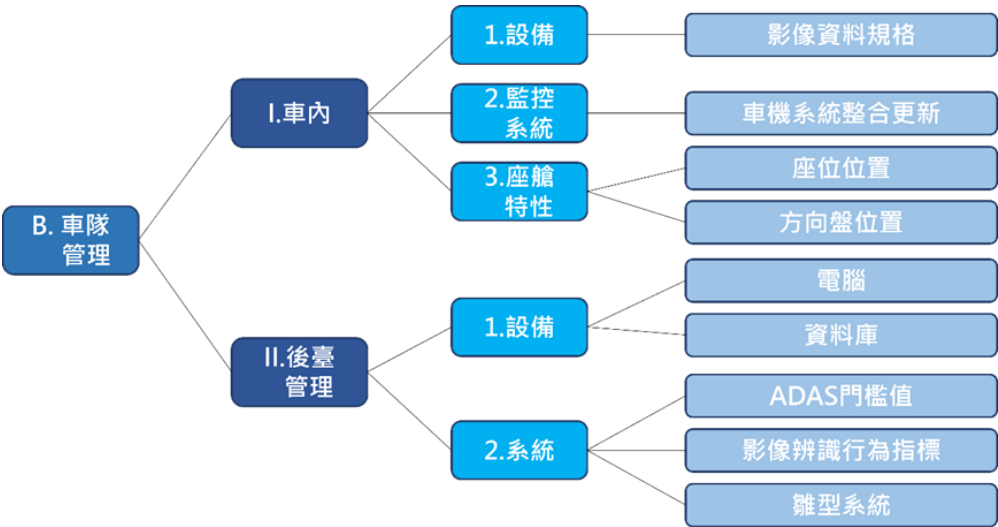


圖 9.2-2 車隊管理之安全管理策略架構

下表亦蒐集並彙整與車隊管理相關影像辨識影響因素、改善策略及管理策略，與車隊管理有關之行車異常事件、時空分析、高風險駕駛行為改善策略及管理策略，如表 9.2-1、表 9.2-2 所示，期望能對於業者實際進行車隊管理時有較明確的改善目標。

表 9.2-1 與車隊管理有關之影像辨識影響因素、精進策略及管理策略

分類	影像辨識影響因素	影像辨識精進策略	業者管理策略
車內管理	車內光線不足	改善偵測網路，使用 YOLOX-x + ViT Pose 的新型偵測架構。	1. 針對不同的駕駛身形、座艙特性(如座位前後高低、方向盤角度位置、光線強弱)等環境特性設定或自動調整其系統相關參數，同時納入安全駕駛績效考評制度當中。
	車內座艙、攝影機架設位置		

表 9.2-2 與車隊管理有關之行車異常事件、時空分析、高風險駕駛行為改善措施及管理策略

分類	研究結果	改善措施	管理策略
行車異常事件	<ol style="list-style-type: none"> 1. 車速較快、高速公路路段與爬坡段容易有行車異常事件和可能異常發生。 2. 下雨天、晚上和北上行駛行車異常事件與可能異常發生機率較小。 3. 與格位-1 車輛相對距離小於 40 公尺時，為可能異常之好發情境。 <p>未保安距中，演變成行車異常事件比例以「前車突然減速」最高，其次「前車由右變換車道」、「前車由左變換車道」。</p>	<p>建議業者車隊管理應改善之措施：</p> <ol style="list-style-type: none"> 1. 使用影像辨識指標與 ADAS 系統資料建立行車異常事件門檻值，提升行車異常事件分析之精度與準確度。 2. 在行車異常事件發生較高之時空條件下，提供業者車隊管理與操作階層警示提醒。 3. 訂立影像資料相對應之設備規格與儲存格式規範。 <p>定期更新整合車機系統。</p>	<ol style="list-style-type: none"> 1. 影像辨識與車機資料在應用上互補，車機排除系統性的誤差，透過影像辨識可以進行更全面的行車環境監控，強化行車偵測資料在安全管理上的應用。 <p>透過政府相關計畫的推動，除持續強化與教育業者透過車機系統改善行車安全的重要性外，也提供實務上可運用之工具給業者使用與參考。</p>
時空分析	<ol style="list-style-type: none"> 1. 路段：內側路肩窄、直線段未保安距警示較多、事故較多。 2. 趟次：一定區段內有服務區或交通量大時，發生未保安距警示較多。 <p>事件：駕駛資歷豐富即使發生行車異常事件也較易傾向非嚴重，但 72 小時內排班越多，發生異常則容易較嚴重。清晨及白天發車發生異常較為嚴重。</p>		<ol style="list-style-type: none"> 1. 道路主管機關可針對好發事故及行車異常事件之地點及交通環境，透過 CMS 提醒用路人或匝道儀控穩定主線車流，以提高行車安全。 <p>營運業者則可掌握那些路段及情境風險較高，並做為駕駛獎懲及安駕訓練的參考。</p>

表 9.2-2 與車隊管理有關之行車異常事件、時空分析、高風險駕駛行為改善措施及管理策略(續)

分類	研究結果	改善措施	管理策略
高風險駕駛行為需特別關注之風險項目	1. 警示前 3 秒之車距範圍介於 12~26 公尺 2. 駕駛員年資 車趟時間	建議業者需關注之風險項目： 1. 行車動態：安全車距。 車隊排班：駕駛員年資、車趟時間。	1. 業者透過車班安排準確調配駕駛與班次，並參考駕駛員年資安排不同教育訓練項目。 透過保持安全車距以達到減少警示發生，提高行車安全。

9.3 設備管理

針對設備管理部分，可分為兩部分：購買、安裝。在購買設備部分，分為四類：攝影影像資料規格、車機系統規格、整合程度、維修更新，在購買相關車機系統或攝影機時需考慮其資料規格、品質，做為後續的成像品質、警示頻率之參考依據，同時也需考量設備間的整合程度，設備、系統整合度越高對於後續業者管理會更有益處，而在購買相關設備時也需注意其維修更新保養等事宜；在安裝設備部分，分為三類：位置、功能、防水，包含安裝之設備需擺放的位置是否會造成駕駛員不便或遮蔽，如圖 9.3-1 所示、空間是否足夠放置等，安裝功能是否符合業者需求、各項功能敏感度測試等，如夜間 IR 功能過強也易造成影像辨識失真，如圖 9.3-2 所示，設備本身的防水防撞程度也需多加考慮，設備管理之安全管理策略架構如圖 9.3-3 所示。



圖 9.3-1 駕駛員動作被遮蔽

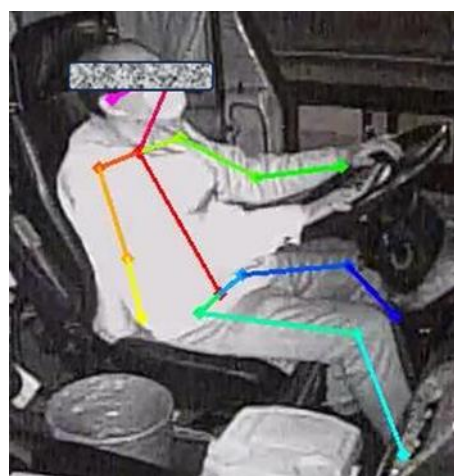


圖 9.3-2 夜間 IR 功能過強

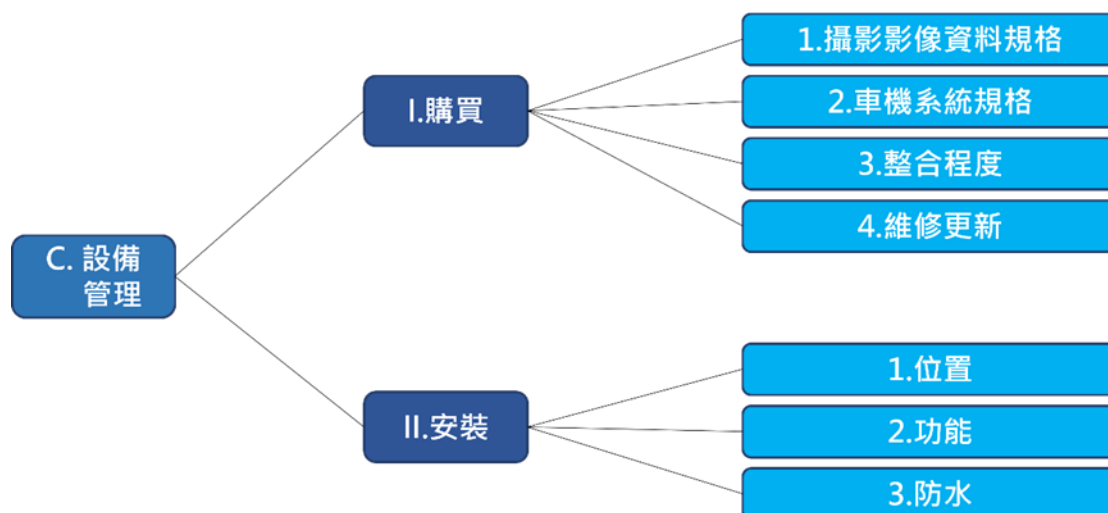


圖 9.3-3 設備管理之安全管理策略架構

下表亦蒐集並彙整與設備管理相關影像辨識影響因素、改善策略及管理策略，如表 9.3-1 所示，期望能對於業者實際進行設備管理時有較明確的改善目標。

表 9.3-1 與設備管理有關之影像辨識影響因素、精進策略及管理策略

分類	影像辨識影響因素	影像辨識精進策略	業者管理策略
設備管理	鏡頭視角位置不佳	1. 將攝影機鏡頭視野角度置中於車輛前方。 2. 視野範圍置中於鏡頭畫面。	1. 依照不同的行車區域(如高快速道路、市區、場區)環境特性，提供相對應之安全警示系統與功能(如FCWS、LDWS、BSIS、LCAS、RCTA)。 2. 硬體設備改善，例如將相機架設位置從側方往側前方方向移動。
	夜間 IR 功能影響	使用改善後的模型YOLOV7，增加辨識正確率。	
	攝影機過曝		

第十章 結論與建議

道路交通事故存在隨機、稀少等重要特性，過去無論是運輸業者、監理機關或道路交通安全主管機關多以事故件數、死傷人數做為安全績效指標的作法，除在統計上難以真正代表安全績效水準改善或惡化，亦難找出真正問題並將其連結至駕駛行為對安全之影響；近年部分運輸業者應用先進駕駛輔助系統所產生之各項警示做為安全績效指標，然而此等方式仍無法有效建立警示發生、駕駛行為及安全意涵，更遑論找出具有較高風險的駕駛人對症下藥，換言之，若不善加應用影像資料做為輔助，以 ADAS 警示做為單一指標可能造成誤判及管理資源錯誤配置。

因此，本 4 年期計畫透過蒐集車內、外行車影像、駕駛行為、ADAS 警示紀錄及各項環境資訊等資料，並導入影像辨識技術，期望從大量 ADAS 警示當中，找出真正具有安全隱憂及管理價值的行車異常事件。本計畫為 4 年期計畫第 3 年，以第 1、2 年計畫成果為基礎，進一步開發高風險駕駛行為分析模式及開發離型系統，做為後續推廣應用之基礎。

10.1 結論

本計畫研究成果對於 ADAS 系統之應用著重於後端管理，為輔助即時警示之準確率及正確性，而非取代 ADAS 系統，並針對高風險駕駛行為有清楚之定義及風險評估。

針對高風險駕駛行為分析方面，本期計畫有幾點結論：

(一)高風險駕駛行為之風險評估

根據 4.2 節之分析結果，縱向警示的發生除與駕駛個人特徵相關外，也與本車行駛時的加速度、與前車車距以及雙手離開方向盤、操作與安全無關設備及手靠近嘴巴等駕駛員分心行為有關；橫向警示的發生主要與前車車距及雙手離開方向盤、拿東西與用手機等駕駛員分心行為有關。

4.3 節將 4.2 節之最佳模式，利用提升迴歸數模式 (Boosted Regression Tree, BRT) 將連續變數類別化，本計畫另定義 Risk 及高風險比例，前者針對各高風險駕駛行為的組合所造成之風險定義低、

中、高風險範圍；後者則利用高風險比例計算單一變數在高風險範圍出現的次數多寡，以釐清該變數的風險程度。

針對縱向警示事件，須關注項目為雙手離開方向盤、警示前 3 秒之車距範圍介於 12~26 公尺、未於前車變換車道時擺頭等行為；橫向警示事件則為拿東西及雙手離開方向盤等行為，皆與駕駛員之駕駛行為及手部分心有關係。

(二)特定警示之高風險駕駛行為分析：前車碰撞與橫向偏移

本期計畫新增 FCWH 及 SLDW 警示事件分別為 57 及 55 件，透過繪製盒鬚圖可看出各警示事件下，人工標示之異常程度為「不是異常」及「可能異常或異常」之機率分布差異，本計畫亦透過盒鬚圖之資料分布，將機率預測值 0.39 設為縱向警示 (FCWH) 之切分點；將機率預測值 0.2 設為橫向警示 (SLDW) 之切分點，後續管理時將可透過機率預測值之切分點，將大於此值之事件視為行車異常事件；反之則為不是異常之事件。

警示鏈分析可看出序列規則與前期結果不同之處：縱向警示下若駕駛員在警示發生後未及時針對警示做出反應，仍有其他手部分心行為 (手靠近嘴巴、操作車內設備等)，進而發展為行車異常事件；橫向警示時若駕駛員在警示發生當下出現其他與駕駛無關之分心行為則易發展為行車異常事件。

在機器學習分類方法方面，本期計畫比較隨機森林與 XGBoost 的分析結果，以及有無採取過採樣與欠採樣的結果差異。結果發現在機器學習的比較中，不論是哪一個資料層級，AUC 值均為隨機森林較高。其可能原因為 XGBoost 可能有較嚴重過度配適之問題，導致在測試樣本中，AUC 值表現不如預期之結果。然而，若以績效指標討論兩種機器學習方法在測試樣本分類的結果，卻發現 XGBoost 的表現優於隨機森林。此外，從各種績效指標而言 (如 Recall 與 Precision)，本計畫發現有使用 SMOTE 之過採樣方法所得到的值，均較沒有使用 SMOTE 更佳。因此，適時的採取平衡樣本的方法，確實能夠大大地提高模式的整體分類結果。

在行車影像辨識技術部份，本期計畫持續以深度學習技術為基礎，導入新型物件偵測模型，發展車外、車內影像辨識技術，進而分析研究

駕駛行為。本期所導入的新型物件偵測模型計有 YOLOv7、YOLOv8、ViTPose。從實驗分析來看，YOLOv7 和 YOLOv8 的辨識正確度與辨識速度相近。相較於 YOLOv7 或 YOLOv8，ViTPose 則具備較為準確的辨識結果，但需較長的辨識處理時間。

在車外影像辨識部分，本期使用物件偵測的相對距離和本車速度判斷前車相對速度和相對加速度，因此相對速度和相對加速度以及距離判斷的正確性取決於物件偵測框的穩定度。影響物件框偵測不穩定的因素，夜間部分可以歸納為六項：強光影像過曝和雜訊、強光影像過曝水珠或地面反光、低光照影像過暗和雜訊，水珠或地面反光、低光照影像過暗和雜訊、低光照影像過曝和雜訊、夜間其他燈光雜訊干擾。日間部分可以歸納為六項：過曝影像對比過低、強光影像過曝水珠或地面反光、濃霧視野不清偵測距離有限、陰天影像對比過低、雨滴大小和密度的遮蔽干擾、角度變換和紋理干擾。本期亦分析影像資料範例並提出可能的模型訓練改善方式。

在車內影像辨識部分，本期計畫使用駕駛者的關節點資訊判斷其駕駛行為事件，因此分心事件判斷的正確性取決於關節點偵測的穩定度。影響關節點偵測穩定度的因素可以歸納為六項：夜間 IR 影響、車內光線不足、駕駛衣著色彩較單一不易區分部位、較難辨識的駕駛動作、部分身體部位被遮蔽、副駕駛座有乘客且特徵較駕駛明顯。本期亦分析影像資料範例並提出可能的改善方式。

在時空分析方面，本期計畫主要著重在完整第 I、II、III、IV 類各項由巨觀到微觀的樣本，以及延伸連接的資訊流，透過不同資料完整度之業者來呈現時空分析巨觀至微觀之樣態。同時利用第 I 類僅有 OBD 資料之業者類型進行高風險駕駛行為之時空分析，以隨機單一趟次為樣本發現，大部分 OBD 在加速度有觸及的時間點前後幾分鐘內，幾乎都有警示事件發生，但並無 OBD 一觸及門檻後，警示事件隨即發生的狀況。另第 II、III、IV 類以 ADAS 為基礎之高風險駕駛行為之時空分析部分，透過路段、趟次、事件分析，發現車流量大、服務區，時段性差異 (假日、方向等)，可能警示發生較少，是因為交織情形多，駕駛人原就會更加注意而

使得模式影響為負向；業者排班時也須注意，長時間派班越多，從趟次模式中發現發生警示事件的次數也較多。

在安全管理策略建議方面，本期計畫已擬定雛型系統總體概念與功能，功能部分目前雖尚未全數開發完成，但已可執行影像辨識、影像切割等工作，預期將能大幅減少業者於調閱行車異常事件所花費之時間與人力成本，並結合本期與前期計畫之研究成果，統整出針對國道客運業者安全管理策略架構，包含駕駛管理、車隊管理、設備管理，彙整與影像辨識相關之影響因素、與行車異常事件、時空分析、高風險駕駛行為相關之改善策略及管理策略，做為實際管理時之明確的改善目標。

10.2 建議

針對高風險駕駛行為分析方面，本期計畫有幾點建議：

- (一)透過本計畫之高風險評估模式，無論縱向警示事件 (SDW 0.4 及 FCWH) 或橫向警示事件 (LDW 及 SLDW)，須關注項目皆與駕駛員之駕駛行為及手部分心有關係，縱向警示事件則另與車距相關，建議相關客運業者若欲辨識前述高風險駕駛行為，需安裝 ADAS 系統且透過車內影像進行分析，方可正確辨識。
- (二)本計畫發現「晚上」變數在 FCWH 及 SLDW 之校估結果為正負異號，值得注意的是，此變數除為時間描述外，尚可能因此影響其他變數，如車輛密度及車流速率等差異，亦可能駕駛本身狀況有關 (如疲勞或因無車而分心等)，因此建議客運業者若欲進行車道偏移警示 (LDW) 管理，可針對夜間的车流狀況、駕駛員分心、疲勞狀況，納入後續教育訓練重點。
- (三)針對高風險評估模式之行車異常事件預測機率值，本計畫建議之切分點為縱向警示 0.39、橫向警示 0.2，後續業者使用雛型系統進行管理高風險駕駛行為辨識時，可透過切分點將大於此值之事件視為行車異常事件；反之則為不是異常之事件。
- (四)縱向警示之序列規則與警示發生後 10 秒之駕駛員分心行為有關，橫向警示則與警示發生當下之駕駛員分心行為關聯較大，建議客運業者須針對不同類型之警示進行分段管理。

(五)本期計畫對於能掌握之車外相關變數及駕駛人特性仍有限，針對車流狀況(如順暢或壅塞)除無定義外，亦無相關變數可供分析；駕駛員特性除年資外皆為未知，建議未來能就此部分提出量化指標，可供客運業者納入教育訓練。

在行車影像辨識技術部份，本期計畫之挑戰在「低解析度」與「成像品質較差」之行車紀錄影片上以深度學習技術盡可能達到人類肉眼視覺能辨識之能力效果。從實驗結果可得知本期研究成果相較前兩期有顯著提昇，然而仍有目前技術無法辨識的情境，即便是人類肉眼視覺仍難從影片觀察辨識。不論車輛前裝或後裝市場，「行車視野輔助系統」產品並非「先進駕駛輔助系統」所定義之產品，因此對於攝影機與數位錄影系統並未有其較嚴格之要求規範。但若為協助客運業者與車隊管理業者提昇在駕駛風險行為分析管控之品質，本期計畫提出一版軟硬體規格建議如表 6.3-1。除軟硬體規格之外，攝影設備之安裝位置，以能夠完整取得駕駛者上半身軀體影像，且不會造成上半身部位遮蔽的位置為主。以目前大客車之駕駛座空間區域為例，建議的安裝位置為駕駛座右前方的位置點。

在時空分析方面，建議後續利用 OBD 資料進行高風險駕駛行為之時空分析時，可先透過實際發生 ADAS 警示事件的樣本輔助，並著重車輛動態相關之高風險駕駛行為，以發生之頻次做為應變數，車輛資訊、國道幾何資訊做為自變數，以分析此些高風險駕駛行為，好發於何些時空環境；另建議可嘗試再以「司機」為分析單位之新架構，目的在於找出該司機個別的駕駛型態，以及好發各類事件之地點，可讓公司重點教育與管理，且不會被路段、趟次分析方式模糊化。

在安全管理策略建議方面，建議業者能參考本期計畫之國道客運安全管理策略架構：駕駛管理、車隊管理、設備管理，做為業者內部駕駛員教育訓練、車隊管理方式、採購設備等之參考依據，同時業者能先行確保車隊駕駛理解現有設備警示作用的門檻以及雛型系統運作的方式與機制，再透過系統找出的高風險駕駛進行管理，避免駕駛在一無所知狀況下被召回訓練或懲處，引發車隊駕駛反感或不安情緒。

參考文獻

- 日本国土交通省ドライブレコーダーの映像を活用した指導・監督マニュアル
- 邱裕鈞、傅強，「不同嚴重程度及碰撞型態之多變量高速公路事故頻次模式」，運輸學刊，27(3)，345 - 384，2015 年。
- 美國商用車輛安全管理署官網：<https://www.fmcsa.dot.gov/>
- 盛郁淳，「分時段高速公路事故頻次模式」，國立交通大學交通運輸研究所，碩士論文，2014 年。
- 馮輝昇、王義川，臺中市高風險路口整合平台，道路交通安全與執法研討會，2017 年。
- 黃珮芬，「最佳時空分段下之高速公路事故頻次模式」，國立交通大學交通運輸研究所，碩士論文，2014 年。
- 獨立特派員 日本大客車安全：<https://www.youtube.com/watch?v=P8ty6IGgAKc>
- 魏健宏、陳宥欽、李佩憶、賴家偉 (2018)。人格特質影響駕駛風險之分級模型建構—以國道客運駕駛員為例。運輸學刊，30 (3)，219-245。
[https://doi.org/10.6383/JCIT.201811_30\(3\).0003](https://doi.org/10.6383/JCIT.201811_30(3).0003)
- Abdel-Aty, M. A., & Radwan, A. E. (2000). Modeling traffic accident occurrence and involvement. *Accident Analysis & Prevention*, 32(5), 633-642.
- Anastasopoulos, P.C., & Mannering, F.L. (2009). A note on modeling vehicle accident frequencies with random parameters count models. *Accident Analysis & Prevention*, 41(1), 153-159.
- Bagdadi, O. (2013). Assessing safety critical braking events in naturalistic driving studies. *Transportation research part F: traffic psychology and behaviour*, 16, 117-126.
- Bagdadi, O., & Várhelyi, A. (2011). Jerky driving—an indicator of accident proneness?. *Accident Analysis & Prevention*, 43(4), 1359-1363.
- Bell, J. L., Taylor, M. A., Chen, G. X., Kirk, R. D., & Leatherman, E. R. (2017). Evaluation of an in-vehicle monitoring system (IVMS) to reduce risky

- driving behaviors in commercial drivers: Comparison of in-cab warning lights and supervisory coaching with videos of driving behavior. *Journal of safety research*, 60, 125-136.
- Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934.
- Cai, M., Yazdi, M. A. A., Mehdizadeh, A., Hu, Q., Vinel, A., Davis, K., Xian, H., Megahed, F. M., & Rigdon, S. E. (2021). The association between crashes and safety-critical events: Synthesized evidence from crash reports and naturalistic driving data among commercial truck drivers. *Transportation research part C: emerging technologies*, 126, 103016.
- Camden, M. C., Glenn, T. L., Manke, A., & Hanowski, R. J. (2022). Fleet-based Driver Monitoring Systems: Accelerating Commercial Motor Vehicle and Occupational Driver Acceptance of Driver-facing Cameras.
- Camden, M. C., Soccolich, S. A., Hickman, J. S., & Hanowski, R. J. (2019). Reducing risky driving: Assessing the impacts of an automatically-assigned, targeted web-based instruction program. *Journal of safety research*, 70, 105-115.
- Chen, H. K., Chou, H. W., Su, J. W., & Wen, F. H. (2019). Structural interrelationships of safety climate, stress, inattention and aberrant driving behavior for bus drivers in Taiwan. *Transportation research part A: policy and practice*, 130, 118-133.
- Chiou, Y. C., Lan, L. W., & Chen, W. P. (2013). A two-stage mining framework to explore key risk conditions on one-vehicle crash severity. *Accident Analysis & Prevention*, 50, 405-415.
- D'Souza, K. A., & Maheshwari, S. K. (2012). Improving performance of public transit buses by minimizing driver distraction. *WIT transactions on the built environment*, 128, 281-293.
- Dai, X., Kummert, A., Park, S. B., & Neisius, D. (2009, June). A warning algorithm for Lane Departure Warning system. In 2009 IEEE Intelligent Vehicles Symposium (pp. 431-435). IEEE.

- Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends® in signal processing*, 7(3–4), 197-387.
- Deng, W., & Wu, R. (2019). Real-time driver-drowsiness detection system using facial features. *Ieee Access*, 7, 118727-118738.
- Docomo business : <https://www.ntt.com/business/services/docodesucar/safety.html>
- Dula, C. S., & Ballard, M. E. (2006) . Development and evaluation of a measure of dangerous, aggressive, negative emotional, and risky driving 1. *Journal of Applied Social Psychology*, 33 (2) , 263-282.
- Farhadi, A., & Redmon, J. (2018, June). Yolov3: An incremental improvement. In *Computer vision and pattern recognition* (Vol. 1804, pp. 1-6). Berlin/Heidelberg, Germany: Springer.
- Feng, F., Bao, S., Sayer, J. R., Flannagan, C., Manser, M., & Wunderlich, R. (2017). Can vehicle longitudinal jerk be used to identify aggressive drivers? An examination using naturalistic driving data. *Accident Analysis & Prevention*, 104, 125-136.
- Feng, S., Li, Z., Ci, Y., & Zhang, G. (2016) . Risk factors affecting fatal bus accident severity: Their impact on different types of bus drivers. *Accident Analysis & Prevention*, 86, 29-39.
- FMCSA Safety Program Effectiveness Measurement: Carrier Intervention Effectiveness Model (CIEM)
- Ghamari, A., Rezaei, N., Malekpour, M. R., Azadnajafabad, S., Jafari, A., Ahmadi, N., ... & Farzadfar, F. (2022). The effect of non-punitive peer comparison and performance feedback on drivers' behavior using the telematics: the first randomized trial in Iran. *Journal of safety research*.
- Ghasemzadeh, A., & Ahmed, M. M. (2018) . A framework to enhance the transferability of the SHRP2 naturalistic driving study by considering heterogeneity of driver behavior using spatial-temporal factors in a trajectory level. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)* (pp. 1826-1833) . IEEE.

- Ghasemzadeh, A., & Ahmed, M. M. (2018). A framework to enhance the transferability of the SHRP2 naturalistic driving study by considering heterogeneity of driver behavior using spatial-temporal factors in a trajectory level. In 2018 21st International Conference on Intelligent Transportation Systems (ITSC) (pp. 1826-1833). IEEE.
- Gitelman, V., Bekhor, S., Doveh, E., Pesahov, F., Carmel, R., Morik, S., 2018. Exploring relationships between driving events identified by in-vehicle data recorders, infrastructure characteristics and road crashes. *Transp. Res. Part C Emerg. Technol.* 91, 156–175.
- Glaser, Y. G., Guo, F., Fang, Y., Deng, B., & Hankey, J. (2017). Investigate moped-car conflicts in China using a naturalistic driving study approach. *Journal of safety research*, 63, 171-175.
- H. Farah, O. Musicant, Y. Shimshoni. T. Toledo, E. Grimberg, H. Omer, and T. Lotan, 2013, the First Year of Driving : Can an In-Vehicle Data Recorder and Parental Involvement Make It Safer, *Transportation Research Record : Journal of the Transportation Research Board*, vol. 2327, pp.26-33.
- Han, W., & Zhao, J. (2020). Driver behaviour and traffic accident involvement among professional urban bus drivers in China. *Transportation research part F: traffic psychology and behaviour*, 74, 184-197.
- Hickman, J. S., & Hanowski, R. J. (2012). An assessment of commercial motor vehicle driver distraction using naturalistic driving data. *Traffic injury prevention*, 13(6), 612-619.
- Higgs, B., & Abbas, M. (2013). A two-step segmentation algorithm for behavioral clustering of naturalistic driving styles. In 16th International IEEE Conference on Intelligent Transportation Systems, 857-862.
- Irwin, C., Monement, S., & Desbrow, B. (2015). The influence of drinking, texting, and eating on simulated driving performance. *Traffic injury prevention*, 16(2), 116-123.
- jae Kim, S., Joo, J., ho Choo, S., Lee, H., & Authority, K. T. S. (2018). Analysis of Dangerous Bus Driving Behavior Using Express Bus Digital Tacho

- Graph Data. *The Journal of The Korea Institute of Intelligent Transport Systems*, 17(2), 87-97.
- Jiang, L., Wen, H., & Xue, G. (2022). Investigating spatio-temporal characteristics and evaluation of heavy goods vehicle risky driving behaviours based on vehicle networking dataset during naturalistic driving. *International Journal of Heavy Vehicle Systems*, 29(4), 389-406.
- Jun, J., Ogle, J., & Guensler, R. (2007). Relationships between crash involvement and temporal-spatial driving behavior activity patterns: use of data for vehicles with global positioning systems. *Transportation Research Record*, 2019(1), 246-255.
- Kaplan, S., & Prato, C. G. (2012) . Risk factors associated with bus accident severity in the United States: A generalized ordered logit model. *Journal of safety research*, 43 (3) , 171-180.
- Khan, M. N., Ghasemzadeh, A., & Ahmed, M. M. (2018). Investigating the impact of fog on freeway speed selection using the SHRP2 naturalistic driving study data. *Transportation research record*, 2672(16), 93-104.
- Kim, D. G., Lee, C., & Park, B. J. (2016). Use of digital tachograph data to provide traffic safety education and evaluate effects on bus driver behavior. *Transportation research record*, 2585(1), 77-84.
- Klauer, C., Dingus, T. A., Neale, V. L., Sudweeks, J. D., & Ramsey, D. J. (2006). The impact of driver inattention on near-crash/crash risk: An analysis using the 100-car naturalistic driving study data.
- Lawton, R., Parker, D., Manstead, A. S., & Stradling, S. G. (1997). The role of affect in predicting social behaviors: The case of road traffic violations. *Journal of applied social psychology*, 27(14), 1258-1276.
- Li, N., Jain, J. J., & Busso, C. (2013). Modeling of driver behavior in real world scenarios using multiple noninvasive sensors. *IEEE transactions on multimedia*, 15(5), 1213-1225.
- Liu, W., Li, H., & Zhang, H. (2022). Dangerous Driving Behavior Recognition Based on Hand Trajectory. *Sustainability*, 14(19), 12355.

- Lollett, C., Kamezaki, M., & Sugano, S. (2022). Driver's Drowsiness Classifier using a Single-Camera Robust to Mask-wearing Situations using an Eyelid, Lower-Face Contour, and Chest Movement Feature Vector GRU-based Model. In 2022 IEEE Intelligent Vehicles Symposium (IV) (pp. 519-526). IEEE.
- Lourenço, A., Alves, A. P., Carreiras, C., Duarte, R. P., & Fred, A. (2015, August). CardioWheel: ECG biometrics on the steering wheel. In Joint European conference on machine learning and knowledge discovery in databases (pp. 267-270). Cham: Springer International Publishing.
- Lyu, N., Duan, Z., Ma, C., & Wu, C. (2021). Safety margins—a novel approach from risk homeostasis theory for evaluating the impact of advanced driver assistance systems on driving behavior in near-crash events. *Journal of Intelligent Transportation Systems*, 25(1), 93-106.
- Mallia, L., Lazuras, L., Violani, C., & Lucidi, F. (2015). Crash risk and aberrant driving behaviors among bus drivers: the role of personality and attitudes towards traffic safety. *Accident Analysis & Prevention*, 79, 145-151.
- Masello, L., Sheehan, B., Castignani, G., Shannon, D., & Murphy, F. (2023). On the impact of advanced driver assistance systems on driving distraction and risky behaviour: An empirical analysis of irish commercial drivers. *Accident Analysis & Prevention*, 183, 106969.
- Miaou, S. P., & Lum, H. (1993). Modeling vehicle accidents and highway geometric design relationships. *Accident Analysis & Prevention*, 25(6), 689-709.
- Moslem, S., Farooq, D., Jamal, A., Almarhabi, Y., Almoshaogeh, M., Butt, F. M., & Tufail, R. F. (2022). An integrated fuzzy analytic hierarchy process (AHP) model for studying significant factors associated with frequent lane changing. *Entropy*, 24(3), 367.
- Musicant, O., Bar-Gera, H., & Schechtman, E. (2010). Electronic records of undesirable driving events. *Transportation research part F: traffic psychology and behaviour*, 13(2), 71-79.

- Navarro, J., Deniel, J., Yousfi, E., Jallais, C., Bueno, M., & Fort, A. (2017). Influence of lane departure warnings onset and reliability on car drivers' behaviors. *Applied ergonomics*, 59, 123-131.
- Nidamanuri, J., Nibhanupudi, C., Assfalg, R., & Venkataraman, H. (2021). A progressive review: Emerging technologies for ADAS driven solutions. *IEEE Transactions on Intelligent Vehicles*, 7(2), 326-341.
- Peer, S., Muermann, A., & Sallinger, K. (2020). App-based feedback on safety to novice drivers: Learning and monetary incentives. *Transportation research part F: traffic psychology and behaviour*, 71, 198-219.
- Reason, J. (1990). Human error. Cambridge university press.
- Reason, J., Manstead, A., Stradling, S., Baxter, J., & Campbell, K. (1990). Errors and violations on the roads: a real distinction?. *Ergonomics*, 33(10-11), 1315-1332.
- Reddy, B., Kim, Y. H., Yun, S., Seo, C., & Jang, J. (2017). Real-time driver drowsiness detection for embedded system using model compression of deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 121-128).
- Salmon, P. M., Young, K. L., & Regan, M. A. (2011). Distraction 'on the buses': A novel framework of ergonomics methods for identifying sources and effects of bus driver distraction. *Applied ergonomics*, 42(4), 602-610.
- Seo, H., Shin, J., Kim, K. H., Lim, C., & Bae, J. (2022). Driving Risk Assessment Using Non-Negative Matrix Factorization With Driving Behavior Records. *IEEE Transactions on Intelligent Transportation Systems*, 23(11), 20398-20412.
- Shankar, V., Mannering, F., & Barfield, W. (1995). Effect of roadway geometrics and environmental factors on rural freeway accident frequencies. *Accident Analysis & Prevention*, 27(3), 371-389.
- Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE access*, 7, 53040-53065.
- Smart Fleet 官網 : <https://smartdrive.co.jp/company/>

- Stutts, J., Feaganes, J., Reinfurt, D., Rodgman, E., Hamlett, C., Gish, K., & Staplin, L. (2005). Driver's exposure to distractions in their natural driving environment. *Accident Analysis & Prevention*, 37(6), 1093-1101.
- Toledo, G., & Shiftan, Y. (2016). Can feedback from in-vehicle data recorders improve driver behavior and reduce fuel consumption?. *Transportation Research Part A: Policy and Practice*, 94, 194-204.
- Tran, D., Do, H. M., Lu, J., & Sheng, W. (2020). Real-time detection of distracted driving using dual cameras. In 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (pp. 2014-2019). IEEE.
- Tsao, L. J. (2008). Driver drowsiness detection and warning under various illumination conditions. Institute of Computer Science and Information Engineering National Central University Chungli.
- Tselentis, D. I., Vlahogianni, E. I., & Yannis, G. (2021). Temporal analysis of driving efficiency using smartphone data. *Accident Analysis & Prevention*, 154, 106081.
- Useche, S. A., Ortiz, V. G., & Cendales, B. E. (2017). Stress-related psychosocial factors at work, fatigue, and risky driving behavior in bus rapid transport (BRT) drivers. *Accident Analysis & Prevention*, 104, 106-114.
- Verizon Networkfleet 官網 : <https://www.verizonconnect.com/>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2023). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 7464-7475).
- Wang, C., Quddus, M. A., & Ison, S. G. (2009). Impact of traffic congestion on road accidents: A spatial analysis of the M25 motorway in England. *Accident Analysis & Prevention*, 41(4), 798-808.
- Wang, L., Wang, Y., Shi, L., & Xu, H. (2022). Analysis of risky driving behaviors among bus drivers in China: The role of enterprise management, external environment and attitudes towards traffic safety. *Accident Analysis & Prevention*, 168, 106589.

- Wang, T., Chen, Y., Yan, X., Chen, J., & Li, W. (2020). The relationship between bus drivers' improper driving behaviors and abnormal vehicle states based on advanced driver assistance systems in naturalistic driving. *Mathematical Problems in Engineering*, 2020, 1-12.
- Wang, X., & Xu, L. (2021). Factors influencing young drivers' willingness to engage in risky driving behavior: continuous lane-changing. *Sustainability*, 13(11), 6459.
- Wang, X., Huang, K., & Yang, L. (2019). Effects of socio-demographic, personality and mental health factors on traffic violations in Chinese bus drivers. *Psychology, health & medicine*, 24(7), 890-900.
- Xian, H., Hou, Y., Wang, Y., Dong, S., Kou, J., & Li, Z. (2022) . Influence of Risky Driving Behavior and Road Section Type on Urban Expressway Driving Safety. *Sustainability*, 15 (1) , 398.
- Yu, B., Bao, S., Chen, Y., & LeBlanc, D. J. (2021). Effects of an integrated collision warning system on risk compensation behavior: An examination under naturalistic driving conditions. *Accident Analysis & Prevention*, 163, 106450.
- Ziakopoulos, A., Petraki, V., Kontaxi, A., & Yannis, G. (2022). The transformation of the insurance industry and road safety by driver safety behaviour telematics. *Case studies on transport policy*, 10(4), 2271-2279.

附錄一 期中報告審查意見回覆

交通部運輸研究所合作研究計畫

期中報告審查會議

審查意見處理情形表

計畫名稱：IOT-112-SCF001 應用人工智慧分析技術探勘高風險路段 (3/4)—行車
異常事件及高風險駕駛行為分析

執行廠商：國立陽明交通大學

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
(一) 國立成功大學交通管理科學系魏健宏教授		
1. 報告書 198 頁表 6.1-1，車載系統若以「分級」方式呈現，其所含資料建議應從較低層級到較高層級逐層增加，建議可參考簡報第 31 頁的呈現方式。	1. 遵照辦理。	同意。
2. 報告書 81 頁、198 頁等處，「客運業者類別」、「資料類別」兩者都在呈現同樣的分類或分級，但實際上本計畫並非再針對業者做分類，而是針對不同車隊管理系統功能分類，另同一公司也可能針對不同路線或營運區有不同類型車隊管理系統，建請釐清。	2. 本計畫並不是針對單一客運公司或單純的國道客運進行影像的分析，而是一般的高風險駕駛行為。故本計畫希望發展出一套流程，建立一般化的系統，不同業者進行管理時能夠遵循該流程，定義自身之高風險駕駛行為。	同意。
3. 報告書 83 頁圖 3.2-1，「技術性失效」字樣經黑白印刷後，無法確定是特別顏色強化說明或刷淡，請修正。	3. 遵照辦理。	同意。
4. 報告書 87、88 頁，SDW1.2、SDW0.4 在前期計畫以及本期 5 月趟次資料的樣本數分布趨勢不一致，請確認。	4. 前期計畫並非原始資料，是本計畫抽樣過後的樣本。由於 SDW 的警示對於和欣客運而言，大多皆為 False positive，因為其 SDW1.2 的門檻太低，並非急需關注的警示事	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
	件。但為了保守起見，本計畫亦將其部分抽樣，放入模式訓練。實際的樣態應如本期 5 月趟次資料所示。	
5. 報告書 102 頁，高風險駕駛行為定義流程包含計量模式與機器學習模式兩類型方法，但整體目錄卻沒有出現「計量分析」方法，建議調整小節標題。	5. 遵照辦理，本計畫會嘗試使用 Hybrid model 一詞做為替代方案。	同意。
6. 時空分析模式分為巨觀、中觀、微觀，但在報告書 201、205 頁呈現方式不一樣，報告書 201 頁沒有提到中觀，205 頁則有提到中觀，請修正。	6. 微觀時空分析依照每個警示事件做為樣本單位；巨觀時空分析則依照趟次、路段之單位切割，故稱為中觀、巨觀。惟因都將事件進行整合 (aggregate) 後分析，故於 201 頁中統稱巨觀分析。感謝委員建議，後續報告書中會將此些分析架構層次釐清。	同意。
7. 報告書 205 頁圖 6.3-3，請說明圖例。	7. 遵照辦理，將於後續報告書中詳細說明，圖中紅色圓圈大小代表單一事件嚴重度之層級，由大至小分別為異常、可能異常、不為異常 (一般警示事件)；黃色則代表該事件經由車內影像判斷該事件有車內分心之動作。	同意。
8. 報告書第三章標題為「高風險駕駛行為之分析與管理」，但本章主要著重於「分析」，並未探討「管理」，請釐清。	8. 遵照辦理，本計畫會將「管理」一詞刪除。	同意。
9. 請加入前期計畫以及本期計畫的重要內容摘要說明，針對前期計畫的研究成果，建議可在本期計畫引用。	9. 遵照辦理。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
10. 對駕駛人而言，後車變換車道亦會影響本車駕駛行為，有些駕駛人也會透過照後鏡觀察後方車流方向燈，建議可納入討論。	10. 在車外影像有納入左側與右側向後照的影像，但該變數放入模式後並未達顯著，因此分析模式並未放入這些變數。本計畫認為可能會因為後方車輛變換車道導致的危險，但因本計畫所擁有之大客車後方影像角度較為垂直、影像距離不夠遠，因此影像分析時並未使用後車影像進行分析。	同意。
(二) 本所運輸安全組張開國前組長		
1. 1. 報告書 80 頁，將「使用車外影像進行分析」放到第四類業者的理由是：雖所有大型車輛皆有車外影像，但實際會使用影像進行分析之業者並不多見。本計畫為研究案，若研究上可用，才能引導現在不會利用車外影像的業者使用；另外外部影像資料也可搭配第一或第二類業者應用，建議重新說明。	1. 本計畫在文字敘述上表達較不清楚。基本上，不同車隊有不同資料的完整度，本計畫希望給予它們不同的資料層級應用方式。本計畫在敘述上會再進行調整。	同意。
2. 報告書 212 頁，目前分析結果，多數變數因為不顯著而刪除，但 7.1 節說明未來將根據資料庫評估增加外部環境變數，請說明預計增加的外部環境相關變數，那些可以精準預測？請補充說明。	2. 基本上，高速公路局提供的幾何資料，與氣象署的天候變數，甚至本計畫從影像看到的天候狀況，都並未在模式中呈現顯著效果。但許多文獻有談到環境對於行車異常事件有其影響，此關係可以在後續的時空分析中，以巨觀的角度探討其相互關係。在用詞上本計畫會再進行修正。	同意。
3. 報告書 179 頁圖 5.1-17，在濃霧狀態下，不同影像辨識模式皆無法偵測出車輛，但在最初標示時，是如何發現前方有車輛？請說明偵測方式，程式是否可能學習人眼辨識的程序？請說明。	3. 人工標示時，所有事件皆為連續影像組成之影片，該車輛從初始時間便被人工識別直到移動到本車前方。目前深度學習影像辨識技術仍需要大量訓練資料學習才能接近人眼辨識水準。	同意。
4. 本計畫使用的資料來源有限，但在此限制下又將資料分為 4 種業者，	4. 本計畫與運安組討論後，希望能夠使該架構與研究成果讓大多數業者	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
建議思考本計畫之結果是只能用於特定業者，還是可以在業界普遍使用？例如：其他業者是否可用表 4.3-3 及表 4.3-6 於其車隊管理？若只能用於特定業者，建議提出分析程序。若可普遍應用，建議規劃具體應用方式。	使用，不會僅限於特定幾家業者使用。	
(三) 東吳大學資料科學系呂明穎教授		
1. 考量未來在即時影像辨識運算需求，建議除 AUC 之外，可進一步說明運算時間。	1. 遵照辦理。	同意。
2. 在行車異常事件樣本數相對偏少的狀況下，若採 10-fold 方式分析，是否可能造成在某些資料切割的狀態下無法觀察到足夠行車異常事件，進而造成部分特徵重要度偏低，以及目前測試效果比訓練效果差，可能出現過度配適狀況；建議釐清說明，也請進一步說明 10-fold 資料分布樣態及預測結果。	2. 遵照辦理。	同意。
3. 以本計畫資料樣態，建議可以嘗試 stacking 的做法，另本計畫資料屬於非平衡資料，建議可先用 oversampling 或 undersampling 方式預處理樣本資料。	3. BRT 內有 stacking 的機制，本計畫亦會使用其他方法改善 stacking 之部分。另外，本計畫使用 smote 實施 oversampling 之結果亦不如預期。本計畫會再嘗試其他方法處理樣本資料。	同意。
4. 本期計畫已將 YOLO v4 提升至 v7，今年 YOLO v8 也已發布，未來雖不可能無止盡追尋最新演算法，但建議可以就 v8 演進做一說明及建議。	4. 遵照辦理，相關實驗說明將於期末審查呈現。	同意。
5. 風險行為分級部分，目前所定義的「高風險」很難真正確認其是否屬於「高風險」，建議可討論各個變數對風險程度的影響，藉以確認	5. 本計畫檢視在門檻值前後風險情境的組合中，有無應該進一步被關注，如此會比單獨檢視某個情境還要好。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
「高風險」的認定方式。		
6. 建議可從資料蒐集、資料處理、資料分析三層面討論影像辨識資料，例如 IR 造成的部分問題可以透過 ICR 過濾紅外線，衣服色系問題可能可以透過調整對比或加上單一顏色方式處理，建請說明。	6. 在 IR 影像部份，會以影像前處理技術強化內容特徵再進行深度學習辨識觀察其效果。衣服色系會建議客運公司用色與邊緣強烈對比的設計。	同意。
7. 未來技術應用不只針對單一業者，未來業者攝影機可能架設在正面、駕駛者左側或其他地方，建議可評估透過視覺化軟體將影像轉成正面，辨識能力可能會提升。	7. 將評估把所偵測到駕駛姿態特徵點投影到正規化座標空間一致呈現。	同意。
(四) 國家運輸安全調查委員會		
研究團隊成果將帶回至本會，提供相關同仁參考應用。	敬悉。	同意。
(五) 財團法人車輛安全審驗中心		
本次會議暫無意見，後續倘有相關意見將再洽承辦人員討論。	敬悉。	同意。
(六) 中華民國公共汽車客運商業同業公會全國聯合會		
1. 研究團隊所開發之相關技術與分析成果，未來可以提供業者做為教育訓練，建議後續可以透過教育訓練方式，讓業者更了解研究內容。	1. 遵照辦理。	同意。
2. 目前計畫所蒐集資料皆以和欣客運為主，建議第 4 年或未來後續計畫可增加其他客運業者資料，以增加資料代表性。	2. 若往後有機會執行該計畫，本計畫會往此方向努力。	同意。
(七) 交通部高速公路局		
1. 報告書 84 頁圖 3.2-2，高風險駕駛情境分析架構當中的「駕駛員性格」描述太過籠統且難以量化，建議可釐清；另前置狀況的光線部	1. 本計畫會再將「駕駛員性格」之文字多做補充與修正，亦會將「人工」、「無光」等詞彙修正。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
分，建議可將「人工」、「無光」兩屬性合併探討。		
2. 報告書 87 頁表 3.4-1，前 2 期計畫分心事件中各動作類別統計中，「擺頭」是否有考慮其並非分心，而是提神或看後照鏡之動作，建請說明。	2. 前期計畫中有區分「擺頭」的幅度狀況。基本上，本期計畫中的「擺頭」已經超過一定之門檻值，故可以排除看後照鏡之動作。	同意。
3. 報告書 90 頁表 3.4-5，第 I 類業者之資料欄位中，若須記錄「位於國道公里數哪一段」，建議後續依照各路段之資料，進一步以路段特性進行分析。	3. 本計畫後續會再加入路段車流資料。	同意。
4. 報告書 97 頁表 3.4-8，第 IV 類業者新增之資料欄位表中，「爬坡」欄位是否考慮下坡路段，建請補充說明。	4. 本計畫有考慮下坡路段，而本計畫亦會修正文字敘述方式。	同意。
(八) 交通部公路局		
本次會議暫無意見，後續倘有相關意見將再洽承辦人員討論。	敬悉。	同意。
(九) 本所陳天賜副所長		
1. 本計畫歸納之 4 種等級或 4 種分類的業者，並在本期計畫各自發展高風險駕駛行為模式，但就模式分析結果發現，第 1 類到第 4 類業者對應之 AUC 似無明顯差異，是否代表第 1 類業者相對較少的設備與資料要求即可應用？或是第 1 類至第 4 類的 AUC 提升其實具有意義？另目前模式 AUC 值是否足夠做為後續推動基礎？請補充說明。	1. 本計畫無法證實 AUC 值 0.7 為足夠的基礎，但本計畫使用我們所知的方法，甚至是機器學習的方法，得出該 AUC 值之結果為可以接受之數值範圍。	同意。
2. 請說明目前國道客運業者屬於 1 至 4 類的分布；考量到第 3 類與第 4 類業者若要蒐集影像，並導入影像	2. 透過前期的訪談，目前客運業者多為第 1 類業者，有裝設 GPS 車機系統，而第 2 類業者有裝設 GPS 車	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
<p>辨識技術來找出各項變數進行行車異常事件分析，所需投入成本與時間相當龐大，也不一定可做為第 1 類、第 2 類業者安全管理應用，此與本計畫以及相關技術未來發展方向有關，請補充說明。</p>	<p>機、ADAS 系統的比例也逐漸提升，約佔六成以上，而第 3 類業者因受限於影像設備的裝設及整合，故業者比例較低，本計畫的合作業者同樣為第 3 類，第 4 類業者因需整合外部環境資訊，目前尚無業者為此類。</p> <p>第 1、2 類業者在某些警示類別、前後有車的情境下可以找到較準確的行車異常事件，惟橫向移動的情境表現較不佳，而第 3、4 類業者未來若要應用此技術，可提升其車內影像辨識的技能，或透過後續研究找出更適合應用於業者之方法。</p> <p>現今 AI 技術日新月異，雖本期計畫中尚無法做出讓業者簡單應用的模型，但隨著技術發展，未來能做到的可能性也會大大增加。</p>	
(十) 國立臺灣大學土木工程學系韓仁毓教授(書面意見)		
<p>1. 本案以領先指標分析駕駛者行為，目的為藉此找出肇事因子並加以防範，主題相當明確且重要。且本計畫接續前期研究成果，已有初步成效。本年度計畫主要於高風險駕駛行為分析、工具優化以及提出管理應用策略。</p>	<p>1. 敬悉。</p>	<p>同意。</p>
<p>2. 報告書中對於相關研究之文獻回顧完整，並有整合性討論，相當不錯。</p>	<p>2. 敬悉。</p>	<p>同意。</p>
<p>3. 報告書 43 頁，除所提到之 AI 模型外，建議也可討論實例分割模型在行車影像自動辨識之應用。</p>	<p>3. 將評估採用 SOTA 之 Instance Segmentation 模型應用在本計畫實驗影像中觀察效果。</p>	<p>同意。</p>
<p>4. 報告書 164 頁，針對行車影像 YOLOv7 偵測，請說明偵測物件種類以及樣本數(訓練、驗證、測試)</p>	<p>4. 將於後續報告中補充物件辨識相關評估數據。</p>	<p>同意。</p>

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
各多少)？並說明訓練收斂後之精度。另針對各物件類別，計算混淆矩陣，以評估其實用精度。		
5. 報告書 190 頁，針對 openpose 與 YOLOv7pose 夜間偵測不佳狀況，或可建議駕駛員穿著易於辨識姿態之服裝，以提升辨識效果。	5. 衣服色系會建議客運公司用色與邊緣強烈對比的设计。	同意。
6. 報告書 211 頁，肇事路段時空分析可找出優先改善路段，但能否建議改善方式？建請說明。	6. 感謝委員建議，本研究將在期末報告中清楚說明如何指認高風險路段及改善對策。其中，高風險路段可由期中報告中初擬的事故與事件數象限圖中，事故多、事件多(第一象限)、事故多、事件少(第二象限)應屬亟需改善與盡量優先改善之路段，再利用事故／事件頻次模式中之顯著解釋變數，包含：幾何、設施、交通量等特性，提出道路主管機關在工程面及交通管理面，以及業者駕駛訓練面之相關改善對策與建議。	同意。
7. 瞭解肇事因素或路段，並提出改善策略為本研究之核心價值，在結論建議應具體描述兩者如何串連，才能達到改善交通肇事率之最終目標。	7. 敬悉。	同意。
(十一) 國家運輸安全調查委員會葉名山副主任委員(書面意見)		
1. 報告書 18-19 頁，有關表 2.1-1、2.1-3，建議以流程圖補充說明，方容易瞭解其發生之時間序。	1. 遵照辦理，將於期末報告中補充。	同意。
2. 報告書 38 頁，表 2.2-4 在危險駕駛行為之行車異常事件中，請補充說明其如何蒐集資料並蒐集那些變數。	2. 遵照辦理，將於期末報告中補充。	同意。
3. 報告書 86 頁，請補充說明何謂 12	3. 本計畫接續前期計畫使用 12 宮格	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
宮格之影像變數資料與哪 12 宮格？	之概念架構進行車外影像辨識，橫向以車道、縱向以 20 公尺為單位，以本車為核心劃分出行車動態 12 宮格，主要採集車上三個鏡頭方位（車前、左後、右後側方照後鏡視角）之輸入影像與本車車身網路數據，對 12 宮格方位經運算後進行輸出之變數數據，除了大、小車的類別辨識、車流量（該畫面時間內的車輛數），包含前方車輛相對距離等幾何關係、左右兩側車輛的幾何關係等，這些數值將做為異常駕駛事件辨識的特徵。	
4. 報告書 87 頁，未保持安全距離採用 0.4 sec 與 1.2 sec 之依據為何？請補充說明。	4. 未保持安全距離採用 0.4 sec 與 1.2 sec 的依據為業者提供的警示事件種類。	同意。
5. 報告書 93 頁，TITG_03_n3p3 至 TITG_1_n3p3 前三秒至後三秒與前車時距與時間積分之差如何計算？請補充說明。	5. 前期計畫中針對安全中介指標項目，增加 TETG 與 TITG 兩變數，其中，TETG (Time Exposed Time Gap)為計算本車與前車之時距小於門檻值之時間間隔依據文獻回顧及 ADAS 使用現況，本研究將門檻值設定為 0.3~1.0 秒，TETG 愈大表本車風險愈大；TITG (Time Integrated Time Gap)則表示為本車與前車之時距與設定門檻值之差異積分，若本車與前車時距越小，則累積之總時距將越大，此項指標同樣設定門檻值為 0.3~1.0 秒，TITG 愈大則本車風險愈大。計算公式如下： $TETG_i = \sum_{t=0}^T [TG^* - TG_i(t)] \cdot \tau_{SC},$ $0 \leq TG(t) \leq TG^*$ $TITG_i = \int_0^T [TG^* - TG_i(t)] dt$ TG^*為設定門檻值，本研究為 0.3~1.0 秒；TG_i(t)為本車與前車	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
	<p>之時距；τ_{SC} 為時間間隔，本研究為 1 秒。</p> <p>此計算公式將於期末報告中補充。</p>	
<p>6. 報告書 98 頁，在表 4.1-1，如何判斷出行車異常事件？是人工或機器判斷，其門檻值為何？要說明清楚。報告書 100-101 頁，是否可採同一時間採用影像辨識與人工辨識之相似性或差異性？以瞭解機器判斷之準確度？請補充說明。</p>	<p>6. 前期報告中選出三大行車異常事件做為目標行車異常事件：未保持安全距離、車道偏移、過彎（匝道）車速過快，並選擇以「未保持安全距離」做為目標駕駛行為，分別量化有裝載 ADAS 與沒有裝載 ADAS 下的本土化指標與門檻值。</p> <p>以事件發生當下之情境是否危險、與前車之相對距離、駕駛人之因應動作等該三準則為判斷依據，逐一以人工過濾 ADAS 警示事件是否為真正的行車異常事件。在有裝載 ADAS 系統之下，以 $TTC < 0.4$ 秒為單一指標，其 ROC 值為 0.79、真陽性率為 74.3%（漏報率為 25.7%）、真陰性率為 84.5%（誤報率為 15.5%）。在多個指標組合比較下，「$TTC < 0.4$ 秒 + 事件持續時間 ≥ 2 秒」指標之結果較佳，真陽性率達 34.6%，真陰性率達 96%。</p> <p>影像辨識與人工辨識之相似性或差異性及其判斷準確度在第二期報告書中亦有呈現，在方向盤操作上準確率達八成，擺頭的準確率約五成，手部動作的準確率達八成五，身體傾向的準確率約九成。</p> <p>以上之結果將於期末報告書中補充。</p>	<p>同意。</p>
<p>7. 在表 4.2-5 至 4.3-2，表中 AIC、AUC 模式中數值代表之意義，否則不易瞭解此表之作用為何？請補</p>	<p>7. AIC (Akaike Information Criterion, 赤池信息量準則)是衡量模型的指標，用來預測誤差的估計量、確定</p>	<p>同意。</p>

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
充說明。	<p>給定數據集的統計模型的相對質量，AIC 越小，表示模型越好；AUC(Area under the Curve)為 ROC 曲線之下所覆蓋的面積，除以總面積的比率，AUC 介於 0 到 1 之間，值越大，正確率越高。</p> <p>其定義說明將於期末報告書中補充。</p>	
8. 報告書 130-141 頁，表 4.3-3、4.3-6、表 4.3-9、表 4.3-12 為本研究重要之研究成果，在後續研究中，建議要考量如何運用在車隊管理或在影像辨識中，將此判定門檻納入晶片設計中或程式中加以擴大運用。	8. 敬悉。	同意。
9. 報告書 145 頁，在 4.4.1 節隨機森林中，其預測異常比例僅 30%，代表其預測能力仍比擲銅幣之正負二面 50%還差，故其離實踐運用尚有一大距離要走。	9. 依照委員之建議在嘗試修正模式，結果於期末報告中呈現。	同意。
10. 報告書 156 頁，圖 5.1-1 YoLov4 架構圖字太小，並且不易閱讀，可否在實作方式將其重點摘要放在本文，其他放在附錄，增加易讀性。	10. 遵照辦理，於期末報告中調整。	同意。
11. 整體而言，運用影像加入 ADAS 看到該駕駛異常行為並不容易，研究單位也很用心，但不容易讀懂本報告，建議寫作方式要強調日前之技術那些參數確實可以採用，那些尚未成熟或現階段尚需加強研發。其次所建模式太多太複雜，做研究可以多方嘗試，而本報告僅需呈現建議之模式及其實踐可以用在駕駛員管理，亦應考量其實踐運用面，並指出後續研究與科技研發之重點。	11. 敬悉。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
(十二) 交通部高速公路局卓明君副總工程司(書面意見)		
1. ADAS 本身的誤差或誤判如何排除，以從中找出屬於駕駛者的疏忽，請補充說明。	1. 建議業者可以採用跟本案類似的流程修正 ADAS 警示的原則。	同意。
2. 國道客運駕駛行駛於國道路線之道路幾何線型多已熟悉，故如何分析該變數對駕駛行為之影響？請補充說明。	2. 感謝委員意見，本計畫建立時空分析模式時，亦將駕駛服務年資、趟次行駛時間、排班等納入變數，期能發現專業資歷、駕駛時間長度是否仍有細部影響；或可再進行更細緻之模式建構進行探討。另本年期計畫亦將駕駛以人、月為單位進行樣本單位建模，將在期末報告階段進行分析。	同意。
(十三) 本所運輸安全組(書面意見)		
<p>1. 本計畫為第 3 年期，前 2 年期分別完成車外行車異常事件、車內潛在分心影像辨識技術開發，但目前所發展的技術並不是把影像資料輸入後，即可全自動化找出行車異常事件；請研究團隊於本年度計畫綜整前期計畫成果，說明業者應用方式。</p> <p>(1) 第 1 年期計畫成果可由影像擷取出周圍車輛、車種、所在車道位置及相對速度等關鍵參數，本年度或下一年度呈現的完整工具當中，應要能夠將這些重要參數如何找出行車異常事件的規則定義出來，才能讓業者應用。</p> <p>(2) 第 2 年期計畫成果應可自動化辨識駕駛人的肢體動作，判斷是否符合本計畫定義的潛在分心，後續應有整合第 1 年期成果的明確應用方式，讓業者知</p>	1. 遵照辦理。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
道行車異常行為加上潛在分心 之後果，以及如何預防。		
2. 本計畫第四章針對 4 類業者，提出對應的可管理項目，其中應能歸納出重要危險情境及分心態樣，對於裝設有先進設備業者而言可據以建立高風險駕駛行為的分析模式，但對於沒有先進設備的業者，以及對於監理單位而言，此一結果可轉化為教育訓練或強化稽查的依據，對於業者幫助可能更大，請研究團隊思考如何將相關成果做更全面性的推廣應用。	2. 本計畫之分析結果可以提供給業者互相參考，但因目前僅蒐集一家業者的資料，未來可考慮擴大資料蒐集的對象，讓結果更一般化。	同意。
3. 本年度除了高風險駕駛行為分析外，還有一項工作是提出業者可應用或融入其安全管理系統及日常運作的操作模式，請團隊在後續期間能強化相關論述說明，讓業者可以清楚了解及應用。	3. 本計畫會將研究成果整合至雛形系統，供合作之客運業者使用，讓業者更加瞭解三期計畫研究成果之應用方式。	同意。
4. 報告書第 38 頁，報告內文說明表 2.2-4 為行車異常事件觸發門檻值，惟表 2.2-4 之標題卻為危險駕駛行為，表 2.2-5 亦有同樣狀況，請釐清確認。	4. 遵照辦理，並於期末報告中修正。	同意。
5. 報告書第 39 頁，本頁倒數第 2 段回顧 ADAS 警示相關文獻，但此節 (2.2.3) 為回顧行車異常事件相關研究，請與報告書第 29 頁及表 2.2-1 整合。	5. 遵照辦理，並於期末報告中修正。	同意。
6. 報告書第 46 頁，倒數第 2、3 段所提「本計畫」，係指回顧文獻？抑或是指「本計畫」？請檢視用字妥適性，避免誤解。	6. 遵照辦理。	同意。
7. 報告書第 57 頁，有關 FMCSA 各項	7. 遵照辦理。期中報告書中原始分數	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
指標原始分數之計算，式 2.5-1「違規事件權重」應以「違規風險權重」(與報告內文一致)，另公式為個別事件加權分數，若該指標係為評估業者轄下車輛(駕駛)風險程度，則公式應為所有曾發生事件的加總，請釐清(餘 6 項指標亦同)。	公式(式 2.5-1)為過去兩年間所有事件時間權重與違規事件權重之成績總合，除以平均車輛數與使用率因子的乘積(餘 6 項指標亦同)，原表達不適當處將於期末報告修正敘述。	
8. 報告書第 58 頁，表 2.5-3 呈現業者分組以違規次數分組，但分組依據並未考量車輛數，請說明分組方式原意，及以此方式分組之意涵。	8. 原始分數公式已考量業者車隊規模，用途為將業者依風險程度排名。以違規次數最為業者分組依據，目的為篩選組內風險程度較高之業者，並優先著手介入管理。	同意。
9. 報告書第 58 頁，表 2.5-4 標題應為「危險駕駛指標門檻值」，請修正。	9. 遵照辦理。	同意。
10. 第二章文獻回顧，國內外相關文獻是否曾探討駕駛者(被管理者)對於相關 ADAS 設備應用至安全管理的支持度或接受度，以及影響支持度或接受度之關鍵因素，請補充。	10. 現有文獻較無著墨於車隊駕駛之支持度與接受度，將於期末報告補充。	同意。
11. 報告書第 81 頁，請列表說明本計畫 4 類業者在不同設備等級下，應至少取得資料的規格，如資料種類、格式、單位、取樣率等，以利後續應用。	11. 本計畫 4 類業者在不同設備等級下之資料的規格已提供於報告書中圖 3.2-2，細部定義請參照表 3.4-5 至表 3.4-8。	同意。
12. 報告書第 83 頁，圖 3.2-1 呈現之事故鏈，最後事件為「事故」，但在後續內文又提及「資料中無，本計畫中為警示事件」，似在說明本計畫將「警示事件」當做事故鏈當中的「事故發生」，又或是警示事件應發生在行車異常事件之前？請釐清。	12. 本計畫分析之對象為行車異常事件，而警示事件是發生在行車異常事件之前，此部分將依委員之意見修正於期末報告中。	同意。
13. 報告書第 84 頁，請於圖 3.2-2 加入	13. 遵照辦理，並於期末報告中補充。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
警示事件，以扣合本計畫所定義之各種事件，以及各種事件關聯性與管理意涵。		
14. 報告書第 101 頁，本計畫以警示事件可能轉變成行車異常事件的機率(以及各項變數校估所得之係數)做為「風險程度」，請於 4.2 節強化說明。	14. 遵照辦理。	同意。
15. 報告書第 141 頁，第 5 項變數組合加總係數應為 2.03，請修正。	15. 遵照辦理。	同意。
16. 報告書第 130、134、138、141、152 頁，表 4.3-3、4.3-6、4.3-9、4.3-12 依係數由小至大逐步加總係數做為風險等級之計算，但此表要以「駕駛行為組合」加總後的係數來解讀風險值，亦或是要以個別變數(個別駕駛行為組合)的係數大小來判斷風險程度？實際上出現的駕駛行為組合不會是「依序」，以表 4.3.12 為例，「拿東西」是低風險與高風險的交界，但可能只是在此順序下剛好處於交界處，不一定代表「拿東西」即為關鍵因素，請釐清。	16. 表 4.3-3、4.3-6、4.3-9、4.3-12 只是舉例，並沒有列出所有結果，且強調的是組合非順序，而個別變數的絕對值大小是該變數對成為行車異常事件影響程度的大小。 以表 4.3.12 為例，此處的表做為舉例，表示其駕駛行為是有風險的行為組合，「拿東西」不代表為關鍵因素，應改為關鍵組合(情境)。 此部分內容將於期末報告中修正。	同意。
17. 報告書第 199 頁，國道里程切割分為每 2 公里或每 15 公里切割為一段，請說明以此里程切割之基礎。	17. 感謝意見，本計畫考量樣本單位與頻次模式建構需求，找尋適當之零占比後，分別選定路段分析、趟次分析之最適切割長度。 由於路段分析將所有趟次之警示事件一併採計，故每 2 公里為單位即可建模；趟次分析為一趟次中之警示事件，經嘗試後，以 15 公里為單位時，其零占比才滿足建模需求。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
(十四) 主席裁示		
1. 審查會議各委員及與會單位研提之口頭及書面意見，請國立陽明交通大學研究團隊整理「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。	1. 遵照辦理。	同意。
2. 本計畫經徵詢審查委員意見，期中報告初稿審查通過，請國立陽明交通大學研究團隊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。	2. 遵照辦理。	同意。

附錄二 期末報告審查意見回覆

交通部運輸研究所合作研究計畫

期末報告審查會議

審查意見處理情形表

計畫名稱：IOT-112-SCF001 應用人工智慧分析技術探勘高風險路段 (3/4)—行車異常事件及高風險駕駛行為分析

執行廠商：國立陽明交通大學

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
(一) 本所運輸安全組張開國前組長		
1. 報告書第 170 頁，最後一段就警示鏈分析成果說明「此結果也與前期之序列規則較為不同」，究竟是因為樣本數不夠或是模式設定不同，怎麼樣才能得到穩定結果供業者應用，建請補充說明。	1. 同意委員說法，的確存在樣本數的問題，由於團隊是依時序性規則進行分析，也就是排列組合，所以如果樣本數夠多，可以知道所有的組合所對應到的頻率有多少，其實就不會出現新的組合，所以增加樣本數的確可以將其相對重要性辨識出來，也不會出現比較獨特的組合。	同意。
2. 報告書第 236-237 頁，研究團隊提出行車視野輔助系統的規格建議，此一規格是否經測試確認較現有規格適合影像辨識，應說明清楚；倘無做相關測試，此一結論應保留，建請說明。	2. 報告書表 6.3-1 所建議為目前多數行車視野輔助系統產品能達到規格，也優於本計畫研究使用之影片規格，故其影片辨識效果上應能優於本計畫使用之影片。但決定影片成像畫質優劣最大因子仍在於「感光元件」與「攝影機鏡頭」，此兩項元件於成像畫質上評估仍屬於市場主觀價值評比，較難以量化方法產出畫質評價分數。若以車電前裝 ADAS 次系統 (如：Mobileye 6 Series，單一攝影機模組要價新台幣 35,000 元左右) 使用之攝影機規格，其成本皆高於目前市面行車視野輔助系統 (四攝影機、一小螢	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
	<p>幕、一錄影主機價格約在新台幣 5,000 元至 10,000 元間)。由於行車視野輔助系統被定位給提供駕駛者自主判讀，而非車電前裝 ADAS 次系統用於提供給車輛主動警示控制系統所用並經車安驗證之產品。因此，得考量主要用途及對應市場需求，便能得知市面上行車視野輔助系統價格及其對應規格。本計畫並非提出「必須遵守」的規格，而是提出本計畫確認可行的規格，可做為後續應用之參考建議。</p>	
<p>3. 部分情境仍有無法辨識的狀況，是否係因為分屬不同車輛、日夜、天候等多種情境，經分類後每種情境樣本數偏低，而導致無法成功訓練到該種樣態，建請說明。</p>	<p>3. 當處理複雜的物體識別問題時 (例如車輛識別)，在極端天氣或光照條件下，數據集的多樣性和豐富性對於訓練有效的深度學習模型至關重要。以下為可能的原因：</p> <p>(A)資料集多樣性不足：如果資料集中極端天氣或光照條件下的樣本數量不足，模型可能無法學習這些條件下的特徵。這會導致模型在遇到這些情境時表現不佳。</p> <p>(B)類別不平衡：在許多資料集中，某些類別 (如常見的車輛類型) 的樣本數量可能遠多於其他類別 (如特定天氣或光照條件下的車輛)。這種不平衡會導致模型對數量較少的類別學習不足。</p> <p>(C)複雜環境的挑戰：極端天氣和光照條件本身就是一個挑戰，因為它們可能顯著改變物體的外觀。例如強光、低光照或雨霧可能遮擋或扭曲車輛的視覺特徵，使得模型難以識別。</p> <p>(D)特定情境特徵的缺乏：如果模型在訓練階段沒有接觸到足夠的、</p>	<p>同意。</p>

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
	代表性的極端天氣或光照情境下的數據，它可能無法學習到這些情境的關鍵特徵。	
4. 報告書第 250 頁，OBD 資料相當寶貴，目前計畫僅隨機挑選一趟次資料進行分析，建議未來應增加樣本，搭配 ADAS 警示進行分析，相關結果應可做為後續系統發展，甚至是自駕車發展之參考。	4. 感謝委員建議，OBD 資料由車輛起駛至該趟次結束逐秒紀錄，其與 ADAS 警示、國道幾何、交通狀況等資料須進行多階段之勾稽組合。本期僅先挑選一趟次進行初探，並將於下一年期增加趟次，探索 OBD 所記載之資訊，若達本期針對高風險駕駛所判定之門檻時，與 ADAS 警示之相關性，進行後續詳細分析。	同意。
5. 報告書第 296-297 頁，團隊所提出之業者策略偏向通用性建議，不一定是透過本計畫才能得到的結論，建議從因應業者的需求與想法，將策略做整理；例如在報告書第 305 頁 10.2 節第 1 點建議即為透過計畫可得且針對國道環境的具體建議，另報告書第 338 頁業者 C 提問是否適用於市區客運，雖就研究本身確實不一定可以直接應用在市區，但某些行為特性(如用手機)對市區客運業者就是可以立即納入管理的，此類管理策略就是偏向通用性質，建議調整論述。	5. 同意委員意見，在管理情境之撰寫不夠明確。由於目前分析之結果(較常出現異常之情境、行為組合)較局限於和欣客運的樣本，因此在策略建議方面也偏向給予和欣客運相關建議。倘若分析結果同樣適用於其他業者，後續團隊也會將此部分進行調整，敘述地更加明確。另針對業者 C 的提問，原本回覆之內容係考量到市區客運與國道客運在邏輯上分析及考慮點不相同，所以認為無法直接將本計畫之結果應用於市區客運，但在此次審查報告後會參考委員之建議，在用詞上進行修正。	同意。
6. 業者對於將行車異常事件影像辨識技術應用至市區客運有所期待，但考量問題複雜，建議可以在國道環境相關技術發展完成後，另外啟動計畫來蒐集影像資料、找出問題及評估可行方案。	6. 同意委員之建議，後續關於行車異常事件影像辨識技術應用至市區客運的相關發展，待與運研所及相關業者討論後，可於後續相關計畫實施。	同意。
(二) 國家運輸安全調查委員會葉名山副主任委員		

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
1. 部分建議屬於改善報告易讀性，例如圖 2.1-1 可透過繪圖方式說明會更清楚、表 2.5-5 調查次數定義不清、圖 3.4-1 請放大、圖 6.1-1 請放大、圖 7.1-2 請放大、表 7.2-4 增加百分比等，提供團隊參考。	1. 遵照辦理。	同意。
2. 報告書第 24 頁，過去文獻顯示「職業駕駛者年收入勝算比隨收入增加而降低」，是否為交通違規群組？建請釐清。	2. 此部分為全部受訪者納入分析之樣本，並沒有特定是交通違規群組或非交通違規群組。	同意。
3. 報告書第 40 頁，SHRP2 縱向加速度行車異常事件門檻值為 0.5g，此一數值通常是性能較好的小型車才有可能達到，是否適合做為大型車觸發行車異常事件的門檻，建請說明。	3. 敬悉，第 40 頁表 2.2-4 係文獻回顧，後續建立之各項模式皆未使用此門檻值定義。	同意。
4. 報告書第 75 頁，引用日本一家公司在導入安全管理系統後，急煞車事件出現非常明顯的降低，建議可補充相關做法或管理措施，對國內運輸業者應有幫助。	4. 該案例由於涉及公司商業機密，未提供其內部詳細的管理措施與做法。	同意。
5. 報告書第 193-195 頁圖 6.1-20 至圖 6.1-22，內容搭配說明部分難以理解，建議強化說明。	5. 遵照辦理，調整報告書內容。	同意。
6. 報告書第 243 頁，建議補充說明本計畫使用的各種資料庫內容。	6. 感謝委員建議，有關時空分析由微觀至巨觀之模式，在表 7.1-3 已進行整理，並增加更詳細之文字敘述說明資料庫內容。	同意。
7. 報告書第 248 頁表 7.2-1，第 3 年樣本數(車內行為有標記)僅有 318 件，相較其他年度少很多，建請說明原因。	7. 表 7.2-1 針對本期樣本係分為兩欄，分別是車內行為有標記的 318 件，與車內行為未標記，有 6,312 件。由於車內行為目前需透過人工真值標記異常程度，故僅針對前兩期蒐集較少的 FCWH 與 SLDW 事	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
	<p>件特別處理。</p> <p>但本期時空分析部分，新增約 450 趟次的警示事件共有 6,630 件，其餘 6,312 件未特別標記車內行為與異常程度，但仍是警示事件發生，後續有再將其集合 aggregate 至趟次、路段模式中加以分析。</p>	
8. 報告書第 251 頁，模式 R2 僅有 0.0714，是因為關聯性低或是有其他原因，建請說明。	8. 感謝委員意見，該模式係透過次序普羅比模式分析駕駛行為(含 OBD 之資訊進行換算加速度、ADAS 系統之車距)，可能係因未將 SDW 與 LDW 兩大類型分別建模，使 rho-square 值較低，後續可再針對模式進行詳細分析與調整。	同意。
9. 報告書第 277 頁圖 8.1-4、圖 8.1-5，縱向與橫向代表意義為何，建請補充說明。	9. 縱向與橫向分別代表縱向警示與橫向警示，縱向警示包含 FCWH、FCWL、SDW_0.4 與 SDW_1.2；橫向警示包含 LDWR、LDWL 及 SLDW；後續將於期末報告加註說明。	同意。
10. 從本計畫影像辨識發現的問題，是否可能回饋至設備廠商，由設備端改良，建請說明。	10. 可從影像辨識結果，未來針對攝影機解析度、光照度、噪訊度、視訊編碼等因素回饋給設備廠商做為產品設計參考。	同意。
11. 運安會目前針對大型車輛相關調查已有累積 8 至 12 案，建議團隊可以參考並從中整理大型車的重要事故肇因(例如手離開方向盤、下山未用低速檔造成煞車失靈)，可以呼應本計畫成果。	11. 遵照辦理，已補述至報告書中。	同意。
(三) 國立臺灣大學土木工程學系韓仁毓教授		
1. 本計畫為多年期計畫，每年度都有不同重點，建議在報告一開始就有個完整年期計畫內容的摘要，以利閱讀者了解整體內容。	1. 遵照辦理，後續會與運研所討論該如何撰寫，以符合運研所之規範。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
2. 報告內很多圖表用橫式，建議從排版調整為直式，可優化報告的可讀性。	2. 遵照辦理。	同意。
3. 簡報第 112 頁彙整了事故發生可能相關的各種駕駛行為、駕駛人特性、環境、車輛屬性等，前 3 年計畫重點在於透過人工智慧技術將這些重要變數從影像中萃取出來，建議在第 4 年可以彙整成風險評估工具。	3. 感謝委員建議，將再進行研擬並與運研所討論第四年產出呈現方式。	同意。
4. 本計畫未能納入行人、設施、散落物等來自路側造成之影響，建議未來可以納入考量。	4. 同意委員建議，此部分的確需要一併納入探討，但本期計畫著重於國道、匝道等封閉環境，關於路側所造成之影響較不易發生，倘若未來要將平面道路納入探討，此部分的確需要一併討論。	同意。
5. 計畫可以落地應用為計畫重要目標，建議要讓客運業者加入團隊或要有機會取得業者的反饋，了解其實際營運需求及蒐集營運資料，彼此互惠，才能讓研究成果更加實用。	5. 同意委員建議，此部分會持續進行。	同意。
6. 目前影像辨識都是後處理，未來有沒有可能納入駕駛行為、環境、車流等特性，做到駕駛危險行為的即時告警，建請說明。	6. 本計畫使用之軟體演算法 (AI 辨識模型、警示機制演算法) 可用於駕駛警示系統，但其運算效能仍取決於成本與市場接受度。若因為成本考量，採用低算力 AI 運算嵌入式系統，必然會犧牲軟體辨識部份精度達到即時運算。即時警示與後端管理在資料分析處理，及對判斷精準度、運算速度及資料需求等要求不一樣，現階段本計畫研究成果旨在輔助即時警示之正確性，而非取代 ADAS 即時警示功能，部分內容則可建議精進警示門檻。	同意。
7. Recall rate 相對較低，測試結果顯示	7. 後續若有增加業者或樣本，可以再	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
機器學習、計量模型成果差異不大，以及可能有 overfitting 的狀況，這些可能是因為樣本數不足、樣本態樣(diversity)不足及樣本 imbalance，建議可以探討目前資料狀況與解決方法。	討論此部分是否有改善之可能性。	
8. 影像辨識所需時間為關注重點，團隊有建議為可用輕量化的模型加快辨識速度，但是辨識效果比較不好；但若以分析駕駛行為的需求，影像是否需要達到 26 fps，事實上 1 秒鐘內不太可能變動 26 個姿勢，建議可以測試降低 fps 及調整適當之解析度，藉以維持辨識成效但同時縮短辨識時間。	8. 依照委員建議，後續可再與運研所討論，視後續工作項目調整，評估進行實驗相關參數調整來觀察其效果。	同意。
9. 當外在成像環境不佳(例如下雨或濃霧等情境)下很難做影像辨識，但如果影像本身看不清楚，駕駛人眼也不可能看得清楚，本身就是危害因子，這些資訊建議納入安全管理。	9. 感謝委員指導建議，因物理性遮蔽限制所造成辨識困難，後續會整理相關危害因子做為安全管理規劃。	同意。
(四) 東吳大學資料科學系呂明穎教授		
1. 主持人先前提到目前市區部分的資料並沒有納入分析，有關這些資料，是否在第 4 期或未來計畫應用；另現階段研究成果僅適用國道環境，但就目前成果是否可能有部分較具通用性的指標或方法，可以讓市區客運業者應用，建請說明。	1. 目前是將目標設定在國道客運業者的使用，但參考委員建議後，會將通用性的部分再敘述清楚，即除了國道客運業者外也同樣能使用的部分。	同意。
2. 本計畫未來若要走向 POS 階段，對於不同業者資料的適用性將會受到挑戰，除了目前團隊的合作業者外，是否有可能與其他業者合作蒐集資料來進行訓練及學習，建請說	2. 後續將與運研所研商擴大資料蒐集的可行性與作法。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
明後續規劃。		
3. 團隊在連續變數離散化過程，係以目標值最佳化的觀點去做切割，但會造成同一變數在不同模式的切割方式不一樣，此一做法對業者而言很難應用管理，建議在業者應用方便性及切割方式對模式貢獻度之間思考如何權衡。	3. 敬悉，報告書第 303 頁結論中已指出：「縱向警示事件須關注項目為雙手離開方向盤、警示前 3 秒之車距範圍介於 12~26 公尺、未於前車變換車道時擺頭；橫向警示事件須關注項目為拿東西及雙手離開方向盤等行為」，係方便業者管理之作法。	同意。
4. 未來系統若要朝向即時警示發展，系統運算速度就相當重要，建議委託單位與研究團隊可再評估。	4. 即時警示與後端管理在資料分析處理，及對判斷精準度、運算速度及資料需求等要求不一樣，現階段本計畫研究成果旨在輔助即時警示之正確性，而非取代 ADAS 即時警示功能，部分內容則可建議精進警示門檻。	同意。
5. 影像輸入的格式與規範應明確列出來；另若有業者自行處理影像辨識，是否有可能容許將影像處理過後的資料輸入系統進行風險評估，亦即未來系統可能可以發展成輸入影像或輸入資料兩種模式，建請說明。	5. 感謝委員建議，會將影像輸入格式與規範於分析平台列出，資料匯入也將擴增為影像輸入與資料輸入兩種模式，並考量系統資安議題。	同意。
6. 未來是希望各家業者自行建置系統，或是有一個共通性平台讓所有業者可以上傳資料共同做訓練學習，建請補充說明。	6. 考量業者對於上傳資料至特定平台作法多採保留態度，本計畫暫以各家業者自行建置系統為目標。	同意。
7. 提醒團隊應注意資安課題，建議應照數位發展部相關規定定義清楚本系統的資安等級，避免後續稽查可能衍伸問題。	7. 遵照辦理。	同意。
(五) 中華民國公共汽車客運商業同業公會全國聯合會		
1. 目前資料僅來自於一家客運業者，團隊 11 月辦理的座談會也有業者表	1. 後續進行方式會與運研所進行詳細評估與討論。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
達願意提供資料合作，有機會讓模式更為完善，建議團隊評估。		
2. 報告書第 237 頁表 6.3-1 列出行車視野輔助系統規格，考量資訊系統技術日新月異，此一規格可能隨時間而有更迭，建議可說明是最低規格或是註明此一規格訂定的年度。	2. 感謝委員建議，後續規格建議資訊會加上最低規格與訂定年度時間資訊。	同意。
3. 運管組與運安組都有應用 ADAS 系統進行安全管理的相關研究，建議運研所評估將各個計畫資源整合應用，達到最大安全改善效果。	3. 敬悉。	同意。
(六) 交通部公路局		
1. 報告書第 297 頁，計畫分析結果呈現在車道偏移警示響起時，駕駛若有以下動作時可能導致行車異常事件發生，但有無可能是因為有這些動作，才導致車道偏移警示音響起，建請釐清。	1. 敬悉，報告書中所指應為基於警示事件發生之情況下，「駕駛員若有以下動作」則可能由警示事件發展為行車異常事件，就各項影片中觀察，造成警示事件的成因相當多，但若有報告書所指之特殊動作則會進一步發展為行車異常事件。	同意。
2. 報告書第 303 頁，結論建議第 1 點列出可能造成高風險駕駛行為，例如前車車距過近或雙手離開方向盤，建議可以增加量化數據呈現，可讓駕駛在接受教育訓練時更可以理解減少特定動作或行為可以降低多少事故風險。	2. 請參照本期報告書中第四章高風險駕駛行為對照行車異常事件機率之結果，如在縱向警示中，本車變換車道情境下若做了雙手離開方向盤此舉動，會使警示事件變為行車異常事件之機率增加。	同意。
3. 警示鏈序列規則結果論述部分，有提及縱向警示係因「駕駛人未對警示即時做出反應」，橫向警示部分則是在「警示當下」，兩者差異為何，建請說明。	3. 敬悉，報告書中說明 FCWH 發展為行車異常事件多與警示後之行為有關；SLDW 與警示當下之行為有關，故有此論述。	同意。
4. 報告書第 306 頁，本計畫建議當中說明「縱向警示之序列規則與警示發	4. 敬悉，此 10 秒為警示結束後的 10 秒，可說明駕駛員於警示結束後的	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
生後 10 秒之駕駛員分心行為有關」，此「10 秒」為何？建請團隊說明。	緩解作為。已於報告書中補充說明。	
(七) 交通部高速公路局		
1. 報告書第 274 頁，有關本表中高風險駕駛列表、時間動態之駕駛風險變化圖、駕駛風險象限圖、近一年各月份駕駛分數趨勢圖、各場站行車異常事件占比、隨時間演變之警示風險圖、隨時間演變之警示與異常行為次數圖、近一年駕駛風險變化趨勢圖、近一年行車異常事件件數變化趨勢圖項目，未完成開發之原因？建請說明。	1. 有關雛型系統部分內容尚未開發完全之原因為本期計畫主要是透過此系統展示車內外影像辨識技術、駕駛風險報表、行車異常事件報表等相關功能，實際完整之系統將於下期計畫中呈現，故本期計畫先將此系統概念及預期展現的功能呈現於本期報告書中。	同意。
2. 報告書第 275 頁，因本系統之使用對象為業者，建議本報表介面僅直接提供高風險駕駛列表或以儀表板模式呈現)即可，毋須提供「駕駛風險象限圖」，讓業者可直觀進行決策。	2. 有關未來系統介面部分，將再與運研所討論，及參考貴局與業者意見。	同意。
(八) 本所葉祖宏組長		
1. 本計畫已完成相關影像辨識技術、行車異常事件及高風險駕駛行為模式開發，未來應該朝向 POS 方向發展，力求讓技術落地應用；團隊若能順利承接下一期計畫，後續將由本所與團隊研商如何蒐集應用其他業者的資料進行分析。	1. 遵照辦理。	同意。
2. 管理面向包含駕駛人、業者、設備商等，重中之重還是業者本身的管理能量提升，本計畫提出模式可以很複雜，但管理模式必須簡單好操作，讓業者好應用；建議可以先從通用性意見著手，讓業者可以先納入教育訓練或其他改善措施，長期	2. 遵照辦理。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
則是發展針對個別駕駛人做風險評估的高風險駕駛行為分析模式，建議團隊針對不同階段提出適當之管理策略。		
3. 行車異常事件分析可以觀察到個別駕駛人的行為，除此之外，若只透過 OBD 資料，應也可有對應到特定的風險分析指標，請團隊於後續年度評估。	3. 遵照辦理。	同意。
4. 業者規模、設備及資料分析程度差異甚大，本計畫應針對中小型業者提供簡易型的工具，以利其應用，請團隊思考可行性。	4. 遵照辦理。	同意。
(九) 本所王穆衡副所長		
1. 本計畫分 4 年期，每年期皆有特定主題與關注焦點，請在本年期報告增加一個摘要報告，完整說明本 4 年期計畫迄今的重要成果，以利讀者掌握。	1. 遵照辦理。	同意。
2. 計畫過去 3 年期蒐集大量資料，過程中勢必會對資料做些處理或有所取捨，實務上不可能解決所有問題，後續也有可能持續增加資料來解決新的問題，但請團隊務必說明清楚研究的各項假設或限制條件，忠實呈現成果。	2. 遵照辦理。	同意。
3. 基於目前可掌握的資料以及這些資料帶來的限制，未來可以有什麼方法、技術進展可以進一步突破這些限制，補強目前計畫無法完成的分析，請團隊補充。	3. 敬悉，已於報告書中建議第五點中補充。	同意。
4. 未來工作重點應該在於技術落地應	4. 今年本計畫先發展分析雛型平台，	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
<p>用，本計畫在系統開發過程中，應可提出在應用階段應該注意的重點，以及本計畫發現的重要成果在安全管理或系統發展上的機會與應用為何，例如輸入資料應有的規格及最低資料需求等，即可回饋至設備廠商去做發展，長期則可能成為設備驗證、審驗標準，請團隊歸納說明。</p>	<p>後續將針對使用者回饋與委員建議評估來調整與開發後續平台功能。</p>	
<p>5. 本計畫目前是以離線管理模式設計，未來若要朝向整合至車機上做前端處理或雲端運算，可能面臨運算速度、資料精度、資料格式不一等困難，請團隊就執行過去3年期計畫之經驗提出建議。</p>	<p>5. 因本研究目的為高風險駕駛分析，需精準辨識各型車輛物件並分析其位置與軌跡便能進行後續分析。在以上需求，由於不做為即時性駕駛安全警示，要求的是精準辨識分析，因此可在雲端平台以離線式運算分析。反之，若做為駕駛警示系統，則需根據業者產品成本需求調整 AI 辨識模型輕量化來滿足「警示安全」規範所需之效果。</p>	<p>同意。</p>
<p>6. 後端管理可以找出問題所在，委員也有提到後端管理提升至即時警示的可行性，本計畫成果未來長期發展是否可進一步在行車異常事件發生前即有警示，從預防角度避免其發生，請團隊說明。</p>	<p>6. 即時警示與後端管理在資料分析處理，及對判斷精準度、運算速度及資料需求等要求不一樣，現階段本計畫研究成果旨在輔助即時警示之正確性，而非取代ADAS即時警示功能，部分內容則可建議精進警示門檻。</p>	<p>同意。</p>
<p>7. 當進到即時警示階段時，駕駛人在實際道路上面臨的各種高風險情境常常都是同時發生，在當下如何處理多重風險來源的多重資訊，有些資訊可能要即時警示，有些資訊可能只需要提醒，有些資訊則是要制動車輛設備，請團隊納入系統長期發展的課題評估。</p>	<p>7. 遵照辦理。</p>	<p>同意。</p>
<p>8. 本計畫在 113 年結案時，應綜整 4 年</p>	<p>8. 遵照辦理。</p>	<p>同意。</p>

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
期成果，並從中說明可以應用到市區環境的技術，以及其他必須更精進處，以利本所在 114 年後進一步探討將此技術應用到市區環境的可行性。		
9. 另在 113 年度成果報告應以 4 年期完整觀點撰擬總結報告，系統性說明本計畫已經處理的問題、還沒有處理的問題，尤其是對未來制度、管理與技術發展的建議；另計畫開發之系統要移轉回本所時，應對系統的功能、資料規格等有明確說明，對於如何將此系統推廣出去，以及呂委員所提到的資安問題等，也請團隊預為思考。	9. 遵照辦理。	同意。
(十) 交通部高速公路局卓明君副總工程司 (書面意見)		
1. 報告書第 245 頁表 7.1-2，項次 15 休息站、16 休息站座標，與報告後面出現之服務區是否相同？另國道目前有 15 處服務區、4 處休息站，建請確認。	1. 感謝委員指正，本報告係考量相關設施與事件之影響，服務區與休息站皆有考量，已修正並確認相關資訊，並將文字調整為「服務區、休息站」。	同意。
2. 報告書第 256 頁，幾何特性之最小值均為 0，查國道幾何特性均依規範採標準值設計為原則，僅隧道橋梁等特殊路段採最小值設計，惟路肩寬、車道數等不應為 0；另表 7.4-5 之內側路肩寬為 0 等情，請說明。	2. 採用最大或最小值，係因路段或趟次分析時將一定空間長度切割為分析單位，因此針對路肩寬、坡度則取該分析單位中之極值，探索與警示數之關係。而相關幾何資訊則由高速公路局提供以每公尺為單位所紀錄之幾何資訊，進行資料串接。	同意。
3. 報告書第 256 頁，交通特性之大、小車比例之計算標準為何？依國道全年交通量統計顯示，小車佔總交通量比約為 86%，故本計畫以北高路段之客運旅次資料同時，是否有不同解釋定義，建請說明。	3. 本計畫計算交通量時已將各車種依照設定當量值進行換算為 pcu (小型車為 1、大型車為 2、聯結車為 3)，因此小車比例係為小車交通量 (pcu)/總交通量 (pcu)。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
(十一) 本所運輸安全組(書面意見)		
1. 報告書第 1 頁, 111 年道路交通事故統計已更新, 全年共計 3,064 人死亡、498,887 人受傷, 請更新相關統計數據。	1. 遵照辦理。	同意。
2. 對於 ADAS 系統之應用, 本計畫著重於「後端管理」, 而非「即時警示」, 而「即時警示」及「後端管理」兩種用途的指標在準確率、誤報/漏報的要求不同, 請強化說明本計畫指標之定位, 及如何將「後端管理」指標成果應用在「即時警示」指標之精進。	2. 遵照辦理, 已補充至報告書結論。	同意。
3. 報告書第 85 頁表 3.1-1, 此處針對不同類別業者特徵係以設備、資料處理分析能力區分, 但不只是具有設備即可, 請完整說明各項設備對應規格、資料輸出項目、資料格式等, 另 ADAS 僅是泛稱, 應說明何種 ADAS (如第 91 頁列出之警示類別)。	3. 本案研究方向所指之 ADAS 功能, 包含: 前方碰撞警示 (Forward Collision Warning; FCW)、盲區偵測警示 (Blind Spot Detection; BSD)。	同意。
4. 報告書第 87 頁第二段後半段及第 88 頁圖 3.2-1, 本計畫並非將「警示事件」做為事故發生的替代指標, 在時序上或因果上, 警示皆在行車異常事件之前, 請修正論述。	4. 敬悉, 已調整指標順序並修正於報告書。	同意。
5. 報告書第 88 頁第二段, 「上圖以顏色做區分」應為誤繕, 請釐清修正。	5. 遵照辦理。	同意。
6. 報告書第 91 頁, FCWH、FCWL 兩項警示的定義為「與前車可能發生碰撞時且本車時速大於/低於 30kph」, 請說明「與前車可能發生碰撞時」的具體門檻。	6. 敬悉, 針對 FCWH 及 FCWL 之與前車可能發生碰撞, 係為速差達到一定的門檻值, 然此門檻值依據和欣客運使用之設備為碰撞前 3 秒, 可能因各家設備不同而有差異, 已於報告書中補充說明。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
7. 報告書第 92 頁表 3.4-2，請於本表加註「SDW 1.2」因樣本數過多且多數為非行車異常事件，爰於本期計畫分別以抽樣方式，抽出 500、300、2,000 件警示事件進行分析。	7. 遵照辦理。	同意。
8. 報告書第 93 頁，請刪除表 3.4-3 及相關內容，另本計畫蒐集資料對象，請以 A 車、B 車表達，而非以車牌號碼區分。	8. 遵照辦理，修正報告書內容。	同意。
9. 報告書第 97 頁，平均速度、平均加速度、最大加速度部分，請說明是幾秒內之平均、最大值，另此部分變數使用平均而非瞬時速度、瞬時加速度，是為做資料平滑化或是其他原因，請說明。	9. 敬悉，報告書中第 97 頁表 3.4-6 已敘明前 3 秒、前 3 秒至後 3 秒及後 3 秒之平均，原因為表示目標車輛在特定時間段下之行駛動態。	同意。
10. 報告書第 99 頁，TETG、TITG 為 ADAS 系統內建或本計畫另外計算，若是有裝設行車紀錄器之第 I 類業者，能否透過影像辨識取得此 2 變數，請說明。	10. 敬悉，TITG 及 TETG 之計算係依據車距資料，惟僅有 OBD 及 GPS 之管理方式是無法取得上述車距資料的，爰將此類資料歸納於第 II 類管理方式中，已於報告書中補充說明。	同意。
11. 報告書第 99 頁，TERCRI 追撞風險指數，請說明此變數定應及本計畫應用方式，若無，請刪除此變數(或為求完整呈現可取得之資料欄位，可以標註方式註明本計畫未使用)，其餘類似變數亦同。	11. 敬悉，因 TERCRI 變數未於後續模式中放入，故刪除此一變數，已於報告書中修正。	同意。
12. 報告書第 104 頁，FCWH 樣本數偏低，但經檢視近半為行車異常事件，是否意味者對無法做影像辨識的業者，可直接將 FCWH 做為安全管理指標，或至少可以優先調閱相關影片做審視。	12. 敬悉，FCWH 定義即為高速下之前車碰撞警示，原本風險就較其他警示事件高，故以人工判讀時判斷為行車異常事件的比例較高，本團隊亦建議業者可 FCWH 加以管理。	同意。
13. 報告書第 109 頁，本計畫將業者依設	13. 敬悉，本研究模式原就是以 ADAS	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
<p>備及資料處理分析能力區分為4級，但實際在資料分析階段，係以第 IV 類業者的資料，降規至 I、II、III 類進行分析，但目前所提高風險駕駛分析模式皆是在 ADAS 有發生警示的前提下(有警示事件)，對於第 I 類沒有 ADAS 的業者而言，如何取得平均速度(n3p3)、最大加速度絕對值(n3p3)、平均加速度絕對值(p3)，請釐清說明。</p>	<p>警示事件進行分析，第 I 類管理方式的業者是無法獲得 ADAS 警示事件。然本研究使用的平均速度、最大加速度及平均加速度絕對值等資料，皆由車輛上 OBD 或 GPS 取得，對第 I 類管理方式(未安裝 ADAS 系統之業者)應無取得上之困難。</p>	
<p>14. 報告書第 109 頁，第二段提及「警示後平均加速度提高也痛樣表示駕駛員在變換車道後能以較高之速率行駛」，惟該項變數為「絕對值」，亦即駕駛人不一定以較高速率行駛，也可能是減速，請釐清並修正。</p>	<p>14. 敬悉，此結果係依據車速及平均加速度綜合說明，因車速與平均加速度為同號，故解釋為路段順暢，故變換車道後駕駛能用較高速率行駛，另經檢視影像，變換車道後駕駛行為較為一致，較未出現加速後再急減速之狀況；最大加速度於上述二者不同號，則解釋為駕駛的激進操作，包含急加速、急減速。已於報告書中補充說明。</p>	<p>同意。</p>
<p>15. 報告書第 110 頁表，平均速度(警示前 3 秒)、平均速度(警示後 3 秒)為 2 個不同變數，請分為 2 個項次呈現，避免誤解，其餘類似表格亦同。</p>	<p>15. 已修正報告書。</p>	<p>同意。</p>
<p>16. 報告書第 110 頁第 I 類至第 IV 類模式，是否為在 I 類顯著的變數上，再增加 II 類變數進行校估，同理 III 類、IV 類是否亦為同樣方式，請補充說明。</p>	<p>16. 已修正報告書。</p>	<p>同意。</p>
<p>17. 報告書第 111 頁，TITG 為本車與前車秒距小於門檻值的積分，但在計算時並非實際進行積分，而是將每秒或每 0.1 秒低於門檻的秒距相加，請確認並補充說明。</p>	<p>17. 經確認，報告書中計算方式為積分(秒距乘上時距再行加總)，故數值單位為秒平方，惟選用之秒距為 1 秒，可能因此造成誤會。</p>	<p>同意。</p>

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
18. 報告書第 122 頁，分析結果顯示「超速」會降低警示事件演變成行車異常事件的機率，此一結果有違速度管理基本原則，請強化說明。	18. 計劃書中警示事件之是否異常係為人工判斷之，且並未考慮警示發生時的車速狀況，然深夜因道路順暢之故，即使產生警示也較不易被判斷為異常。因此可能出現超速，但非為行車異常事件的狀況，已在報告書中補充說明。	同意。
19. 報告書第 122 頁，縱向警示及橫向警示在「晚上」變數的校估結果正負號相反，其原因為何，後續應可納入為教育訓練重點，請補充說明。	19. 考量 FCWH 及 SLDW 為兩種完全不同的警示，因此形成原因亦不盡相同。一駿報告書中所述結果，「晚上」變數除時間描述外，尚可能存在其他變數，如車輛密度差異、平均車速差異等，亦與駕駛本身精神狀況有關，因此建議若欲進行車道偏移警示(LDW)管理，可針對夜間的車流狀況、駕駛員分心、疲勞狀況，納入後續教育訓練重點。已補充至報告書建議第二點。	同意。
20. 報告書第 167 頁 5.2.1 節，本期計畫取得之新資料納入風險評估模式，此處「風險評估模式」應是指高風險駕駛行為分析模式？請說明納入哪一個模式。	20. 本節所指之風險評估模式係為 4.3 節針對各情境下之高風險駕駛行為類別化後，建立之風險評估模式，已補充說明至報告書中。	同意。
21. 第四章至第五章各個模式分析結果多數都有年資、夜間變數，就教育訓練層面，可針對特定情境(夜間)、特定駕駛員(新進)做重點教育，但若從安全績效評估方面，將此 2 變數做為評估使用是否合適(亦即新進駕駛在評分上就輸在起跑點，或是較多夜班車的司機在縱向警示評分可能較低)，請說明。	21. 本期計畫發展風險評估模式之最初目的，即為針對高風險族群進行管控，新進駕駛員因對於公司程序、駕車方式及狀況排除等應對可能較為不熟；夜間則因為道路狀況、駕駛本身精神狀況等因素將有潛在風險，故年資及夜間於風險評估模式中列為不利因素應屬適當。	同意。
22. 本計畫是否可用不同類型道路環境之行駛里程等做為曝光量，建立國道客運行車異常事件安全績效函	22. 感謝建議，將於後續計畫與運研所進行討論。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
數，並以此函數為基礎，找出實際事件數高於期望值的駕駛員強化管理，請評估納入後續計畫。		
23. 報告書第 236 頁表 6.2-3，此處應用不用影像辨識技術的所需時間，請補充時間單位，例如每分鐘影像需要多少分鐘進行辨識。	23. 遵照辦理，修正報告書內容。	同意。
24. 請於下期計畫提出完整作業程序，其中部分未授權的技術或服務，請依契約規定正式函報本所，並請就未授權的技術或服務提出替代方案，以利業者應用。	24. 遵照辦理，下年度計畫將盤點計畫中所使用之未授權技術與服務，並請所屬單位提供相關授權資訊參考。	同意。
25. 報告書第 241 頁圖 7.1-1，圖中分析架構所用資料為「警示或異常」，但實際上巨觀分析部分僅用警示，請說明。	25. 感謝委員意見。由於今年增加之 ADAS 事件樣本，僅針對部分 (FCWH、SLDW) 進行人工標記區分異常程度等級，其餘皆只能反映發生警示。 故集合至巨觀分析時，本年度以警示數量做為 Y 建模分析。唯前兩期所有 ADAS 事件皆有標記真值，且再分為異常與警示兩類各自建模分析，為了呈現全計畫架構整體性，圖 7.1-1 中仍將異常與警示皆放入架構中說明。	同意。
26. 報告書第 292 頁圖 8.4-1，有關 ROI 定義是否會納入離型系統的相關功能，請說明預期做法。	26. ROI 定義可使用第三方軟體標定，例如：LabelMe，應無需自行開發。	同意。
27. 本計畫建構在 ADAS 警示上，在 ADAS 可能出現誤差或不精準的前提下，如何透過本計畫成果找出讓人信服的績效指標，及找出真正問題與對應之解決方案，請說明。	27. 在 ADAS 可能出現誤差或不精準時，可透過本計畫之分析方法降低偽陽性，找出行車異常事件，但若是偽陰性則可透過下期計畫嘗試應用 OBD 資料做為行車異常事件之指標，連結與 ADAS 警示之間之關係。	同意。

審查委員/單位 之意見	執行廠商處理情形	本所 審查意見
28. 本計畫迄今已辦理3年期，分別針對車內、外行車影像開發影像辨識技術，以及透過高風險駕駛行為分析模式與離型系統，提出可供業者應用的工具；惟目前成果奠基於單一業者所提供的資料，後續能否跟更多業者合作推廣，以及如何納入平台、設備商力量，將本項技術融入其產品，請說明本計畫成果後續應用之願景與規劃。	28. 目前已將多個資料時間同步之業者較少，若後續要與更多業者合作推廣，需先了解業者之設備狀況加以評估，而未來也將平台、設備商列為下期計畫之訪談對象。	同意。
(十二) 主席裁示		
1. 審查會議各委員及與會單位研提之口頭及書面意見，請國立陽明交通大學研究團隊整理「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。	1. 遵照辦理。	同意。
2. 本計畫經徵詢審查委員意見，報告初稿審查通過，請國立陽明交通大學於112年12月22日前提送報告書修正定稿。	2. 遵照辦理。	同意。
3. 本次採購為4年期計畫之第3年，經審查會議通過後，可由國立陽明交通大學執行第4年期計畫，請運安組儘速辦理相關程序。	3. 敬悉。	同意。

附錄三 雛型系統說明會討論事項

【業者 A - 現場回饋】

Q1、一次匯入約 100 台的車輛及影像資料大概需要多久的處理時間？
A1、在影像方面的處理時間與片長大約呈 1：1 的比例，而處理時間也關乎到所使用硬體設備之等級，本次資策會展示系統之硬體屬於一般硬體設備。
Q2、是否能夠考慮以班表時間來進行分析，省去一天中未出車的時間？
A2、同意業者提出的建議，後續可以考慮以班表來進行分析，以減少系統運作之負擔與時間。
Q3、想知道關於司機於駕駛期間的特殊行為（如：抖腳、盤腿等）是否能夠辨識得到？
A3、由於精準影像辨識之前提是需要充足光線及未被遮蔽的肢體，因此，上述業者所提及之行為一但被遮蔽在影響辨識上是非常有難度的。
Q4、肢體異常行為的部分是可查詢的嗎？是屬於一個事件還是僅針對 ADAS 的事件？
A4、未來可能會將此部分納入探討。

【業者 B - 現場回饋】

Q1、不同廠商的 ADAS 設備品質、門檻定義不一，如果使用這一套標準是否能應用在所有的 ADAS 設備上？
A1、在前期計畫中已有檢測過，以和欣的資料而言，有 ADAS 警示的部分才有異常，沒有 ADAS 警示通常無異常，表示和欣 ADAS 的門檻已經校正到一個可以接受的角度。若一家公司的 ADAS 門檻值尚未校正過，可能需要一個校正的前置過程。
Q2、想了解 OBD2.0 產出的資料是什麼？
A2、每秒的時速、轉速、左右方向燈、剎車燈、GPS、經緯度、車前車距。
Q3、在進行 AI 辨識時，是透過軀幹、關節來辨識人的行為，而進行辨識影像之鏡頭像素及角度也會影響辨識，因此業者想了解目前要達到姿態偵測，在鏡頭像素及安裝角度位置有何要求？
A3、在鏡頭像素部分並沒有需要特別高的解析度，以目前大部分業者所使用的鏡頭設備來說，都是能夠辨識的。安裝角度在分析前並無特別要求，目前係以和欣提供之影像做為分析標準，後續各家業者也需以所期望辨識之範圍來進行鏡頭角度設置。
Q4、為何未將司機疲勞納入探討？
A4、前期有嘗試去辨識，但效果不佳。疲勞偵測算是本計畫的限制。
Q5、業者認為司機手往前伸及身體前傾也是能夠做為辨識的方向。
A5、這部分在科技的允許下都是能夠辨識出來的，但辨識出的結果對管理單位有甚麼幫助就需要與業者討論。
Q6、業者是否能夠拿到此模型並於自家環境進行系統整合，或是需要將影片都上傳到公部門、資策會等？
A6、目前運研所主要是想發展一個核心概念，以運研所的立場不會架設一個平台讓各家業者上傳資料，但完整的程序會交代清楚，未來可能需要

業界來去執行運作。
Q7、由於關乎到硬體設備的要求，想了解此模型算是大模型還是小模型？
A7、模型大小與辨識之精準度有關，需視各家業者之要求決定。
Q8、若全是走影像辨識的方式，是否會有業者光是下載影片的時間就遠大於辨識及分析時間的問題？
A8、目前有技術是能夠直接在攝影機上去計算，後續有無可能採用，要看運研所未來計畫的方向。

【業者 C - 現場回饋】

Q1、這套雛型系統適不適合用於市區客運？
A1、系統的概念同樣適用於市區客運，但倘若要用於市區客運，需要從頭設計一遍，因為分析的重點、判斷的邏輯也會有所不同。未來運研所也會朝此方向發展，需要各家業者的指教。
Q2、圖像化的分析結果，高齡駕駛與年輕駕駛會有不同的判斷結果，其中的高齡駕駛是否能有效判斷是業者有疑問之處。
A2、系統計算出的風險分數是提供一個客觀的數字來幫助管理階層判斷，至於數字是屬於低、中、高風險就需要有經驗人士來判斷。

【業者 D - 現場回饋】

該業者董事長提出願意與研究單位合作進行市區客運相關研究或是系統開發。

【業者 E - 網路問卷回饋】

Q1、請問您認為該雛型系統的管理概念是否符合客運業者的需求，以及是否有建議改善的方向？
A1、有 edge side 即時反應管理中心或是駕駛的設計機制，對業者可能有預測事件提前預防的幫助。
Q2、請問您認為在實務上，大客車車機設備的安裝及整合可能遇到的困難為何？
A2、車廠與設備商不同，裝設過程是否會導致業者失去車廠原廠保固進而影響意願。
Q3、請問您認為在後臺管理時，發展大客車駕駛之管理指標可能的方向及建議為何？
A3、公部門提供研究數據做參考依據，對業者與司機具有一定溝通共識。

ISBN 978-986-531-612-9
00550



9 789865 316129

GPN : 1011300847

定價 550 元