

國立交通大學

運輸與物流管理學系碩士班

碩士論文

以機器學習演算法評估客運駕駛風險之研究

Research on the evaluation of bus drivers' driving risk
based on machine learning algorithm

研究生：王允

指導教授：王晉元 教授

中華民國一〇九年七月

以機器學習演算法評估客運駕駛風險之研究
Research on the evaluation of bus drivers' driving risk
based on machine learning algorithm

研究生：王允

Student : Yun Wang

指導教授：王晉元

Advisor : Jin-Yuan Wang

國立交通大學
運輸與物流管理學系
碩士論文

A Thesis

Submitted to Department of Transportation and Logistics Management

College of Management

National Chiao Tung University

in partial Fulfillment of the Requirements

for the Degree of

Master

in

Traffic and Transportation

July 2020

Hsinchu, Taiwan, Republic of China

中華民國一〇九年七月

以機器學習演算法評估客運駕駛風險之研究

研究生：王允

指導教授：王晉元

國立交通大學運輸與物流管理學系(研究所)碩士班

摘 要

本研究透過大客車配戴之先進駕駛輔助系統(ADAS)記錄之車機資料，從中提取駕駛特徵，以機器學習演算法建構駕駛風險評估模型來預測其風險層級。機器學習演算法包含以非監督式學習之分群法根據風險指標來標記風險等級，在使用監督式學習之分類法連結駕駛行為指標建立風險分類模型，並以 recursive features elimination 演算法依照特徵的重要性找出關鍵特徵。另外針對過去研究使用 2 階機器學習架構和區分駕駛特徵之兩個議題進行探討，建立 3 種分類模型來測試其必要性和準確度。本研究之測試範例為行駛國道由新竹至台北的國內客運公司提供 Mobileye 車距資料，透過 k-means 分群法將駕駛分別出風險等級，並找出關鍵駕駛行為特徵。結果顯示 3 種模型之正確率皆高於 90% 且 3 種模型的準確度差異不大。意味著駕駛風險之評定取決於風險標籤所使用之駕駛特徵，將駕駛風險分群後再進行第 2 階段使用分類法建立風險分類模型並沒有其必要性；相同的將特徵分為風險行為兩類型對模型評估的準確度並無差異。因此相對其他模型，1 階段混合特徵評估模型(Model-3)僅進行一次機器學習，較能避免球員兼裁判之情況。若考量日後資料蒐集和處理以及模型再訓練之時間，1 階段混合特徵預測模型為較佳的選擇。

關鍵詞：機器學習、駕駛風險、駕駛行為、先進駕駛輔助系統

Research on the evaluation of bus drivers' driving risk based on machine learning algorithm

Student : Yun Wang

Advisor : Dr. Jin-Yuan Wang

Department of Transportation and Logistics Management
National Chiao Tung University

ABSTRACT

This study extracts driving features from the vehicle data by the advanced driver assistance system (ADAS) on the bus, and uses machine learning algorithms to construct a driving risk assessment model. The machine learning algorithms include unsupervised learning (clustering) to label risk levels by risk features, and the supervised learning (classification) that use driving behavior features to establish risk classification models. Also, using recursive feature elimination algorithm to identify key features. Moreover, the two topics of using the second-order machine learning architecture and distinguishing driving characteristics in the past research were discussed, and three risk assessment models were established to test necessity and model accuracy. As a case study, using Mobileye data from domestic highway bus carrier, which operates from Hsinchu to Taipei. The k-means clustering method is used to cluster the driving risk levels and then find out the key driving behavior features by RFE. The results show that the accuracy of the three models are higher than 90% and not much different. It means that the assessment of driving risk depends on the driving features used by the risk label. So, it is unnecessary to carry out the risk classification model after risk label, divided features into two types neither. Therefore, among three models, the one-order mixed feature model (Model-3) only performs machine learning once, which can better avoid the situation of being players and referees in the same time. Considering the time for data collection and processing and the time of model retraining in the future, the one-order mixed feature model is the better choice.

Keywords : machine learning 、 driving risk 、 driving behavior 、 ADAS

誌 謝

本論文得以順利完成，首先一定是要感謝我的指導教授王晉元老師。從大學的畢業專題到現在的碩士論文，感謝老師這幾年來在我身上所花費的時間和心力。我是一個比較喜歡和人辯論和闡述己見的學生，很感謝老師一直以來的包容和耐心教導，在我面對困難和挫折時，手把手的把我引導到一個比較正確的方向。晉元老師所給予我的東西不僅僅是如何做好一個研究，像是在做北區宜蘭計畫的時候，從老師的經驗分享和執行計劃的過程中學習到了面對和處理問題該有的態度，也重新思考了人生價值觀。離開學校之後，在面對任何事情時，我會謹記老師這幾年來的教誨。

感謝蘇昭銘老師和黃家耀老師在碩論口試時給予我的指導和建議，另外也要謝謝鍾易詩老師和盧宗成老師在前面論文審查階段給予的指教，特別也要感謝健身好夥伴、亦師亦友的吳昆峯老師不時給予的幫助和各整層面的交流。因為有您們，我的論文才能得以更臻完善，非常謝謝您們。

感謝王 Lab 的好夥伴們，這兩年中因為有你們的鼓勵和幹話、時不時的打嘴砲才能支持我到現在即將完成學業。永遠會記得拿天龍國芭樂孝敬我的佑芳、聽我抱怨發牢騷的鏡芳和子勤，以及常常嘴我但實際上卻一直叮嚀、熱心協助我的品蓁學姊。感謝王 Lab 的學長姐，崑哥、煜民學長、宛樺學姊在我碩一懵懂之時以及在論文上給予的專業意見和幫助。

感謝在竹交和北交的同學和好友，Gary、林彤、Sunny、士軒、藍藍、Peggy...這兩年的碩士生活有你們，在乏味、難熬時添增許多滋潤感，感謝你們的陪伴！另外要特別感謝轉職成功未來高公局的扛霸子文哥，大學時給你罩了，想不到在碩士生涯中你也是各種鼎力相挺，不論是在技術上又或是在精神上的交流。你那英姿颯爽的身影不管是在召喚峽谷、安平老街、國華街、又或是淡水河畔都是那麼的讓人安心，能夠認識你真好，感恩的心。一起做個不油膩的男子漢吧！

最後要謝謝我的家人，在背後一直默默的支持我、鼓勵我，你們是促使我持續往前最大的動力和力量的根源，謝謝你們造就現在的我，也希望我一直會是讓你們引以為傲的家人。

王允 謹誌

中華民國一零九年七月

目錄

摘要	i
ABSTRACT	ii
誌謝	iii
目錄	iv
圖目錄	vi
表目錄	vii
第一章 緒論	1
1.1 研究背景與動機	1
1.2 研究目的	4
1.3 研究範圍	4
1.4 研究方法與流程	5
第二章 文獻回顧	7
2.1 駕駛行為相關研究	7
2.2 機器學習演算法	8
2.3 車機資料相關駕駛行為研究	10
2.4 小結	13
第三章 研究方法	15
3.1 資料蒐集與處理	15
3.1.1 研究資料	15
3.1.2 資料清洗	17
3.2 駕駛特徵提取	19
3.2.1 駕駛風險特徵提取	19
3.2.2 駕駛行為特徵提取	20
3.2.3 機器學習輸入資料	20
3.3 機器學習模型	21
3.3.1 Model-1	21
3.3.2 Model-2	25
3.3.3 Model-3	27
3.3.4 小結	29
3.4 駕駛風險評估	29
3.5 風險模型之評定	30
第四章 模式驗證與結果分析	31
4.1 實測資料	31
4.2 Model-1 驗證	33
4.2.1 風險層級標籤結果	33
4.2.2 特徵選擇結果	34

4.2.3 評估結果	35
4.3 Model-2 驗證	36
4.3.1 風險層級標籤結果	36
4.3.2 特徵選擇結果	37
4.3.3 評估結果	38
4.4 Model-3 驗證	39
4.4.1 風險層級標籤結果	39
4.4.2 風險分群模型	40
4.4.3 評估結果	41
4.5 評估結果分析	41
4.5.1 三種模型結果比較	42
4.5.2 小結	46
第五章 結論與建議	47
5.1 結論	47
5.2 建議	48
參考文獻	49



圖目錄

圖 1.2-1	近 6 年國道 1 號事故類型-按車種別分.....	3
圖 1.2-2	近 6 年國道 1 號各車種別肇事原因占比.....	3
圖 1.4-1	研究流程圖.....	6
圖 2.3-1	最終分類模型架構.....	11
圖 3.1-1	Mobileye 系統示意圖.....	15
圖 3.1-2	資料勾稽示意圖.....	19
圖 3.3-1	Model-1 架構圖.....	21
圖 3.3-2	駕駛風險分群結果示意圖.....	22
圖 3.3-3	K-means 示意圖.....	23
圖 3.3-4	分群法之輸入物件與預期輸出.....	24
圖 3.3-5	分類演算法架構.....	24
圖 3.3-6	RFE 範例.....	25
圖 3.3-7	10-fold stratified cross-validation 示意圖.....	25
圖 3.3-8	Model-2 架構圖.....	26
圖 3.3-9	駕駛風險分群結果示意圖.....	26
圖 3.3-10	Model-3 架構圖.....	28
圖 3.3-11	風險分群之群集中心特徵數值.....	28
圖 3.4-1	駕駛風險評估模型之結果.....	30
圖 4.2-1	RFE 篩選關鍵駕駛行為特徵結果.....	35
圖 4.2-2	駕駛行為特徵重要性排名.....	35
圖 4.3-1	RFE 篩選關鍵駕駛特徵結果.....	38
圖 4.3-2	駕駛特徵重要性排名.....	38

表目錄

表 1.1-1	中華民國城際運輸客運量表(千人次).....	1
表 1.1-2	近五年大客車道路交通事故概況.....	1
表 1.1-3	103~107 年前十大肇事原因.....	2
表 1.1-4	107 年前十大肇事原因.....	2
表 2.1-1	最後集群中心點.....	8
表 2.3-1	不同預測模型比較表.....	11
表 2.3-2	近年以車機資料分析並評估駕駛員風險之研究.....	14
表 3.1-1	Mobileye 資料欄位說明.....	16
表 3.1-2	Mobileye 資料內容.....	16
表 3.1-3	駕駛員班表資料欄位說明.....	17
表 3.1-4	駕駛員班表資料內容.....	17
表 3.1-5	異常值欄位示意表.....	18
表 3.1-6	駕駛員編號差補完成示意表.....	19
表 3.2-1	駕駛行為特徵提取變數與運算.....	20
表 3.2-2	機器學習輸入資料.....	20
表 3.3-1	K-means 執行步驟.....	23
表 3.3-2	三種風險評估模型比較表.....	29
表 4.1-1	Mobileye 資料.....	32
表 4.1-2	資料標準化後之駕駛趟次資料.....	32
表 4.2-1	駕駛風險分群之群中心結果(分 2 群).....	33
表 4.2-2	駕駛風險分群之群中心結果(分 3 群).....	34
表 4.2-3	分類法結果比較.....	34
表 4.2-4	Model-1 駕駛風險評估結果.....	36
表 4.3-1	駕駛風險分群之群中心結果.....	37
表 4.3-2	分類法結果比較.....	37
表 4.3-3	Model-2 駕駛風險評估結果.....	39
表 4.4-1	駕駛特徵相關係數.....	40
表 4.4-2	駕駛風險分群之群中心結果.....	40
表 4.4-3	風險分群模型.....	41
表 4.4-4	Model-3 駕駛風險評估結果.....	41
表 4.5-1	3 種模型結果比較.....	42
表 4.5-2	3 種模型之平均駕駛分數.....	42
表 4.5-3	3 種模型結果之誤差.....	44
表 4.5-4	3 種模型之駕駛排名.....	44

第一章 緒論

1.1 研究背景與動機

汽車客運為我國在公路公共運輸的重要運輸工具，據資料(民國 107 年交通部統計月報)顯示我國在 107 年之公路汽車客運量約 1 億 3 千 600 萬人次。雖然公路汽車運輸業之客運量近 10 幾年來受制於高鐵之成長而稍微下降，但仍占總運量近 32%，如表 1.1-1 所示。顯示出公路汽車客運仍為民眾在城際間交通時選擇之重要運具。

表 1.1-1 中華民國城際運輸客運量表(千人次)

年份	台鐵	高鐵	公路汽車客運
103	232,826	48,025	171,901
104	232,217	50,562	168,623
105	230,365	56,586	168,438
106	232,806	60,571	141,905
107	231,268	63,963	135,922

資料來源：交通部統計月報(民 107 年)、本研究整理

汽車客運業涉入交通事故所造成的影響程度相對小客車而言較為嚴重，且在高速公路所發生的事故往往會造成巨大的生命財產損失。據民國 107 年交通部統計月報顯示，近 5 年大客車每年平均肇事件數為 27.2 件，平均每萬輛死亡率為 7.16%；小客車每年平均肇事件數為 413.4 件，平均每萬輛死亡率為 0.4%。近五年大客車涉入道路交通事故概況如表 1.1-2 所示。另外，根據警政統計通報(108 年第 11 週，107 年 A1 類道路交通事故肇事原因與肇事者特性分析)指出，107 年每 10 萬輛「客運公車」發生 A1 類事故為 87.90 件，相較於「自用小客車」每 10 萬輛 5.29 件，高出近 16.6 倍。近 5 年大客車於高速公路肇事平均占比僅約為 3%，但近年來大客車在高速公路發生車禍事故造成重大傷亡的新聞仍屢見不鮮，如 2017 年蝶戀花事件造成 33 人死亡、2019 年阿羅哈客運事件造成 3 死 13 輕重傷。

表 1.1-2 近五年大客車道路交通事故概況

道路交通事故發生概況按第一當事者型態分			
年份	肇事件數	每萬輛肇事率	每萬輛死亡率
2014	29	0.91	0.91
2015	24	7.18	7.48
2016	33	1.45	1.45
2017	28	8.15	19.5
2018	22	6.46	6.46

資料來源：交通部統計月報(民 107 年)、本研究整理

為因應上述之問題，能夠找出肇事因子並有效地預預防事故發生無疑是非常重要的。

依統計資料(高公局, 107 年)顯示, 在 103~107 年國道前十大肇事原因中, 前三名肇事原因多為駕駛人因素, 十大肇因詳見表 1.1-3。另由表 1.1-4 可得知, 107 年之肇事原因也以「駕駛人因素」最高, 約占總事件數 80.67%; 「其他駕駛人因素」次之, 約占總事件數 13.90%, 此二大類約占總肇事原因因素之 9 成以上, 與警政統計通報指出在肇事原因逾 9 成 4 為駕駛人過失相符。若將肇因依事故嚴重程度區分, 107 年 A1 類事故肇事原因第 1 位為「未注意車前狀態」占 31.75%, 第 2 位為「變換車道或方向不當」占 15.87%; A2 類事故肇事原因第 1 位為「未保持行車安全距離」占 35.31%、第 2 位為「其他引起事故之違規」占 21.36%; A3 類事故肇事原因第 1 位為「未保持行車安全距離」共占 49.35%、第 2 位為「未注意車前狀況」占 12.92%。

表 1.1-3 103~107 年前十大肇事原因

1. 未保持行車安全距離 (49.06%)	6. 車輪脫落或輪胎爆裂 (1.61%)
2. 變換車道或方向不當 (12.46%)	7. 裝載貨物不穩妥 (1.24%)
3. 未注意車前狀態 (11.23%)	8. 酒醉(後)駕駛失控 (0.75%)
4. 其他引起事故之違規 (9.10%)	9. 未保持行車安全間隔 (0.72%)
5. 倒車未依規定 (2.84%)	10. 車輛零件脫落 (0.63%)

資料來源：高公局 107 年國道事故檢討分析、本研究整理

表 1.1-4 107 年前十大肇事原因

1. 未保持行車安全距離 (48.24%)	6. 車輪脫落或輪胎爆裂 (1.29%)
2. 未注意車前狀態 (13.33%)	7. 裝載貨物不穩妥 (1.27%)
3. 變換車道或方向不當 (12.21%)	8. 未保持行車安全間隔 (0.79%)
4. 其他引起事故之違規 (9.00%)	9. 車輛零件脫落 (0.67%)
5. 倒車未依規定 (3.10%)	10. 酒醉(後)駕駛失控 (0.52%)

資料來源：高公局 107 年國道事故檢討分析、本研究整理

單就大客車的肇事原因深入探討, 警政署統計資料(107 年)顯示在大客車所有的事務類型中(如圖 1.2-1 所示, 大客車為紫色圓圈)以「追撞」占 81%最高; 另外肇事主因「未保持行車安全距離」占大客車事故原因高達 61.1%, 大客車肇事主因為「未保持行車安全距離」的肇事率為大貨車的 1.4 倍、小客車的 2.8 倍(如圖 1.2-2)。

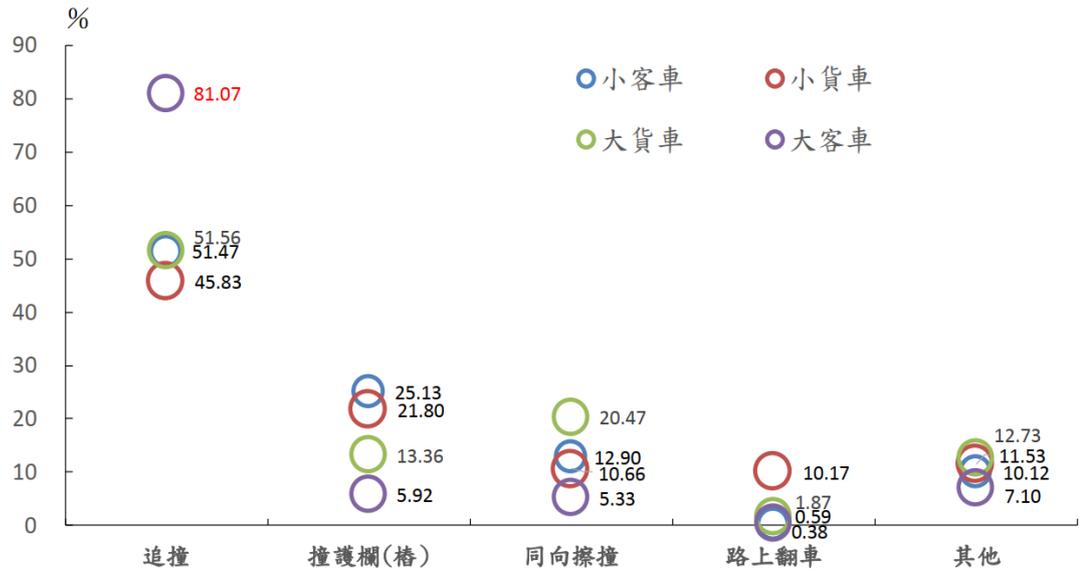


圖 1.2-1 近 6 年國道 1 號事故類型-按車種別分

資料來源：警政署 107 年道路交通安全肇事原因之地域與個人因素探討

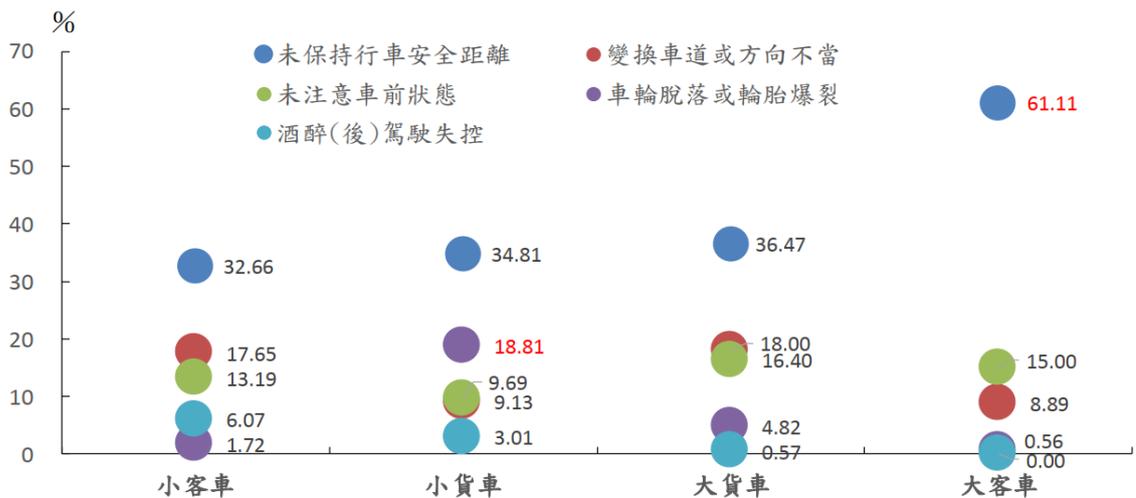


圖 1.2-2 近 6 年國道 1 號各車種別肇事原因占比

資料來源：警政署 107 年道路交通安全肇事原因之地域與個人因素探討

由上述統計結果可以得知，駕駛人的行為是影響交通事故的主要因子，其中又以未保持行車安全距離、變換車道或方向不當、未注意車前狀態最為嚴重。因此透過蒐集駕駛員的駕駛行為資料，針對駕駛員之駕駛行為進行分析以找出關鍵因子，用以評估駕駛員駕駛風險並了解駕駛員的駕駛情況即是預防交通事故不可或缺的重要一環。

隨著科技的進步和技術普及，現今客運業者多有在大客車上安裝車載機具，用以監測駕駛員之情況且能夠適時的提醒駕駛立即修正偏差行為。先進駕駛輔助系統 (Advanced Driver Assistance Systems; ADAS) 例如車道偏移警示系統、前車碰撞警示系統、

前方車距監測與警示等都能夠提醒駕駛修正其失誤並記錄當下相關數據。以 ADAS 所偵測之數據以及搭配行車紀錄器之監控影像，透過分析其資料可以有效地評估出駕駛員的行車風險、駕駛表現和方便監控管理駕駛員。

由於人工智慧的快速發展和逐漸成熟，在各領域都受到重視及應用，人工智慧的一個分支「機器學習」主要是建構設計出讓電腦可以自動「學習」的演算法，能夠透過大量資料中自動辨識出運行邏輯，並利用其邏輯規則對資料進行預測。機器學習已廣泛應用於資料探勘、自然語言處理、生物特徵辨識、語音和手寫辨識、遊戲等領域。近年來也逐漸應用於交通領域，例如：以機器學習方法分類都市快速道路的交通狀況(Cheng et al., 2018);觀察駕駛行為資料以分層機器學習分類法辨識次要任務(Osman et al. 2019)等。

綜合上述，本研究擬以機器學習演算法，利用客運業者所提供之車機資料建立駕駛風險評估模型，針對駕駛員進行風險分群，藉此找出具有較高駕駛風險之危險駕駛員，將其評估結果提供客運公司參考，可針對較高風險之駕駛員進行管理，以達預防事故發生之效。

1.2 研究目的

本研究之目的在於使用機器學習演算法結合客運業者提供之 ADAS 資料來建構一駕駛風險評估模型。ADAS 資料多有記錄人為因素為事故肇因的相關資料，如未保持行車安全距離、變換車道或方向不當、未注意車前狀態等。透過匯入駕駛行為資料於機器學習的模型，能夠將客運駕駛員進行不同的風險分群，其風險評估結果可針對駕駛風險較高之駕駛員進行管理修正。

1.3 研究範圍

本研究之研究對象為配有 ADAS 或是車機設備的汽車客運公司之國道客運駕駛員。由於國道高速公路相較於市區以及一般公路，路況和交通狀況相對較為單純，並沒有路側活動和號誌的干擾。且在國道發生的大客車事故的嚴重度也如同研究背景所述較小客車來的高，故本研究會以國道客運駕駛為分析對象。另外，為排除不同行駛路線對駕駛員的駕駛表現以及駕駛時間造成差異過大將導致分析基準不相同的緣故，會以駕駛相同路線的駕駛作為研究限制。

本研究以中華民國國內某一知名客運公司(以下皆簡稱為 H 公司)所提供之 ADAS 車機資料，其行駛路線為國道一號新竹至台北路線(雙向)。該資料包含 2019 年 H 公司 57 位駕駛員共 79 天的車機資料，本研究將會以上述資料提取駕駛行為相關特徵進行機器學習，再以訓練之模型將駕駛員依照其駕駛行為進行風險評估。

1.4 研究方法與流程

根據上述研究目的與研究範圍，擬定本研究之流程與架構如圖 1.4-1 所示，並詳述各項步驟說明如下：

- (1) **確認研究問題**：根據研究背景與動機，本研究期望能夠從客運駕駛之車機資料中提取駕駛行為特徵，以機器學習演算法訓練巨量資料，進行深度學習，建構出一有效之客運駕駛風險評估模型。
- (2) **文獻回顧**：針對駕駛行為分群、駕駛風險評估等相關研究議題進行文獻回顧，以了解各方學者針對該類問題的研究方法和其完成度，以及所面臨之問題和困境。另外，了解機器學習應用於交通領域之相關研究，掌握較主流之資料探勘理論與方法。
- (3) **資料蒐集與整理**：蒐集取得 H 公司巨量跟車車距資料，並將原始資料整理成適合進行機器學習的資料格式。
- (4) **建立機器學習演算法模型**：本研究擬以 H 公司駕駛員跟車車距資料為輸入資料，從中提取與駕駛行為和風險較相關之特徵，並將其分割為訓練資料和測試資料，先以訓練資料進行機器學習之模型訓練，再將測試資料匯入訓練好之模型進行風險評估測試，依據不同演算法之表現結果調整模型參數並決定最佳模型。
- (5) **資料實測與分析**：將符合格式資料帶入機器學習模型，測試評估模型預測之準確度，接續進行後續結果分析與討論。
- (6) **結論與建議**：確認本研究所建構之客運駕駛風險之機器學習模型，針對實際資料的分析結果提出結論，並根據本研究之結論，提出未來在此研究課題的具體建議。

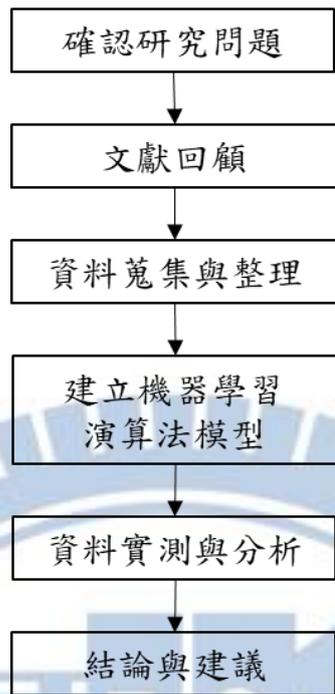
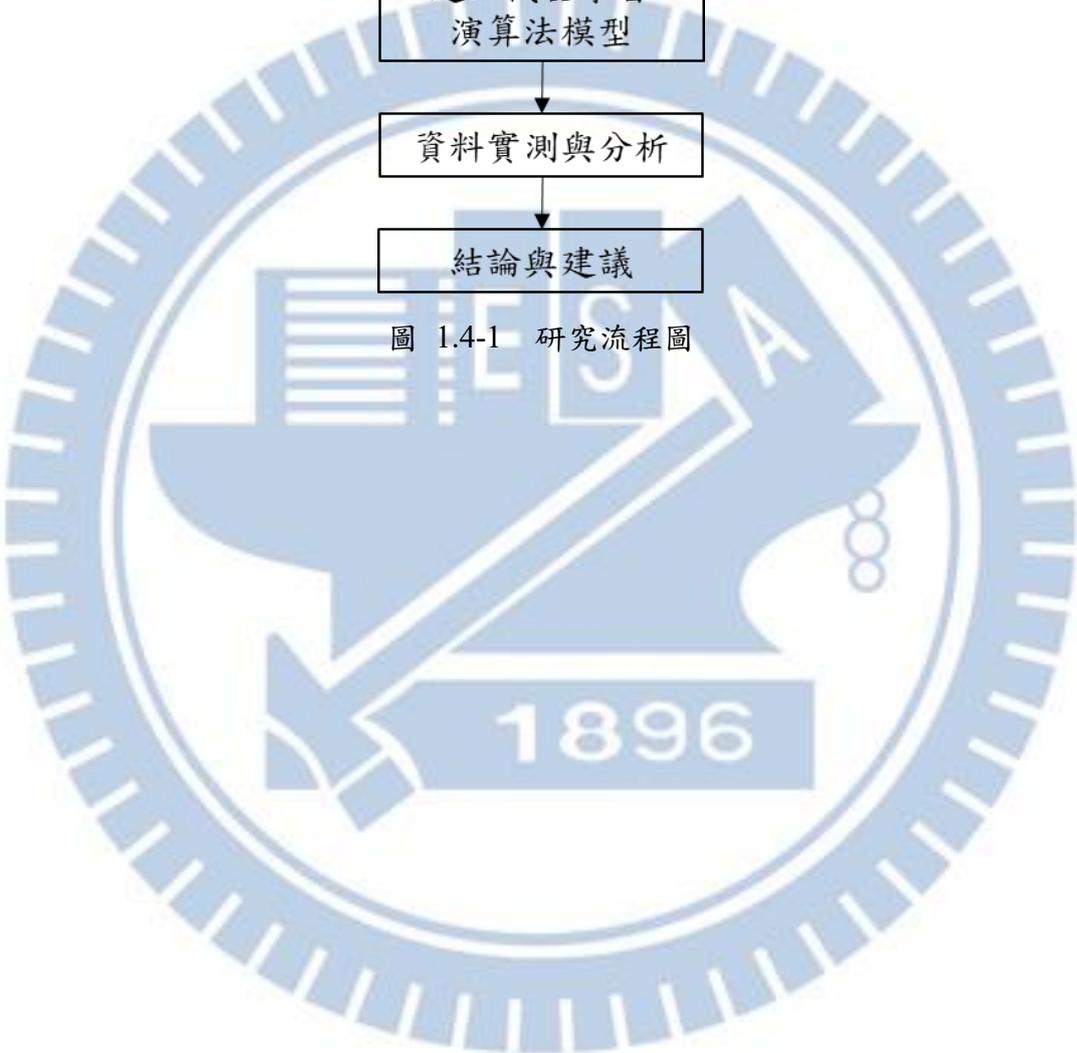


圖 1.4-1 研究流程圖



第二章 文獻回顧

本研究欲使用 ADAS 所記錄駕駛員駕駛行為資料來建構駕駛風險評估模型，以探討駕駛員的駕駛風險，為了解影響駕駛行為與駕駛風險之關鍵因子，因此將針對駕駛行為相關研究進行文獻回顧，藉此得知能夠使用哪些方法、哪種資料類型能夠用來作為駕駛行為風險評估之資料。另外會進一步對機器學習演算法和利用車機資料進行駕駛行為分析的研究進行文獻回顧，以了解目前使用之主流演算法、模型架構設計和數據分析方法。

2.1 駕駛行為相關研究

Reason et al.(1990)為較早期探討駕駛行為與風險的研究先驅，為了解駕駛失誤和違規的區別，透過調查 520 位駕駛員完成之駕駛行為問卷(DBQ)來分析駕駛發生不同類型的駕駛失誤與違規的頻率。其問卷設計將駕駛行為分為 4 類(unintentional violation, violations, mistakes, slips)，風險型態區分為 3 類(no risk to others, possible risk to others, definite risk to other)進行分析。其結果顯示，駕駛違規將隨著年齡增長而下降，而駕駛失誤則無此特性；男性在所有年齡層的違規都高於女性，然而女性相比於男性有著較高比例的較無傷害性的失誤。此研究說明駕駛發生駕駛失誤和違規是由不同的心理機制所導致：違規需要由社會和動機因子解釋；失誤則可能需要參考個人的資訊處理特徵。

Lourens et al.(1999)針對荷蘭交通數據庫中與駕駛員相關的變數(例如：駕駛員特徵、年里程數等)去分析駕駛員習慣的駕駛行為與相關事故涉入數。研究結果顯示，在於不同的年里程層級中，違規與事故之間的關係不盡相同；而在多變量分析結果表示男性和女性駕駛員的事故發生率沒有差異，年輕駕駛員的事故率最高，而受教育程度與事故的發生無關。

Wang et al.(2014)針對商業駕駛進行駕駛時間和休息時間對於駕駛性能和恢復能力之影響進行研究，將 33 位測試組員依駕駛時間分為 3 組(2h、3h、4h)再利用 Stanford Sleepiness Scale(SSS)來衡量駕駛的疲勞水平以及使用 ANOVA 來分析駕駛表現的變化。統計分析顯示，駕駛時間對三組的主觀疲勞和駕駛表現指標有顯著影響。然而一定量的休息時間能夠消除了疲勞的負面影響：15 分鐘的休息時間使駕駛員能夠從兩個小時的駕駛任務中恢復，對於連續行駛 3 到 4 小時的駕駛，休息時間需要延長到 30 分鐘。連續行駛超過 2 小時後，駕駛員的注意力，反應，操作能力和感知都會受到影響。在考慮安全的情況下，駕駛員在繼續駕駛之前，應獲得一定程度的休息以恢復疲勞感。

Feng et al.(2016)為改善大客車安全，針對不同類型大客車駕駛員找出風險因子以探討發生交通事故的嚴重程度不同的原因。該研究以次序邏輯特模型來評估不同類型駕駛危程度，研究資料為 2006-2010 年美國 BIFA(Buses Involved in Fatal Accidents)資料庫，此資料依死亡程度分為 3 個層級；駕駛員則以 K-means 分群法依特徵屬性區分為 3 個群。

第 1 群屬於中年齡者(33-55)且高比例有違規及肇事紀錄；第 2 群為青年(≤ 35)以及老高齡者(≥ 56)且高比例有違規及肇事紀錄；第 3 群為無違規紀錄駕駛。其結果顯示，一些因子對於 3 群駕駛員都有相同造成車禍嚴重程度影響，例如：季節、速限、路面狀況等；而某些因子只對某一群駕駛員有影響，如路段型態和車道數只對第 2 群駕駛有顯著影響。

李佩憶(2017)結合人格特質與駕駛行為對駕駛員潛在偏差行為進行風險評估並建立風險分級制度，以多元回歸、二元羅吉斯、次序羅吉斯模型分析不同人格特質因素對影響特定偏差駕駛行為之重要性與其可能之影響程度。分析行車記錄器資料與駕駛員人格調查資料，研究對象為國內國道客運 62 位駕駛員。駕駛員集群分析結果為 2 群(如表 2.1-1)，分別為未有明顯偏差駕駛行為(77%) 與具有明顯偏差駕駛行為(23%)，後者的特行包含：左右偏移、未保持安全距離、急加速、電磁剎車使用過久。在人格特質方面，五大人格特質並未完全與偏差駕駛行為有顯著影響。

表 2.1-1 最後集群中心點

	集群	
	1	2
左右偏移	.6060	.0825
未保持安全距離	.3536	.0631
引擎轉速過高	.0552	.0332
超速	.0323	.0257
急加速	.2124	.0309
電磁剎車使用過久	.2602	.0528

2.2 機器學習演算法

機器學習為人工智慧的發展的一分支，指的是將收集到的資料進行分類或做為預測模型訓練，能夠從大量數據中找出規律並讓機器能夠自主學習並增強的演算法。在未來中，當輸入新的數據資料時，可以透過演算法訓練出的模型進行預測，演算法也能夠持續的調整並做出更精準的分析。根據演算法機制，機器學習演算法可粗略分為監督式學習和非監督式學習。

(1) 監督式學習(Supervised Learning)

在機器學習模型訓練的過程中提供物件(向量)和預期輸出(標準答案)，例如有標籤的分類資料：輸入了大量已標示清楚標籤的機車和汽車圖片資料給予機器後，讓機器分辨沒有標籤的照片是機車還是汽車。其應用方面包含分類(Classification)及回歸(Regression)。常見的演算法有邏輯迴歸(Logistic Regression)、支援向量機(Support Vector Machines)、最鄰近法(K-nearest neighbors)以及決策樹(Decision tree)等。

(2)非監督式學習(Unsupervised Learning)

與監督式學習相比，訓練資料沒有人為事先標註的結果，此方式不需要人力事前的輸入標籤，僅直接以沒有標準答案的資料來訓練機器學習模型，演算法會嘗試擷取出有用特徵並分析其結構，自動找出資料結構和潛在類別的邏輯規則，並以經過反覆測試後的學習結果應用到新的資料上。主要應用包含分群(Clustering)及降維(Dimensionality reduction)。常見的演算法有 K 平均群聚法(K-Means)、模糊 C 平均法(Fuzzy C-Means)以及關聯規則學習演算法(Association Rule Learning Algorithms)等。

近年來機器學習也逐漸應用在運輸領域研究，尤其在交通流量預測、交通狀態分類上上有著良好的預測成效。Polson et al.(2017)開發一個深度學習模型來預測短期的交通流量，此深度學習架構結合線性模型與一系列 tanh 層，可以處理因為自由車流、故障、回復、壅塞等不同車流狀態間轉換所造之過渡時期所展現的非線性情形，能夠掌握非線性的時空效果；另外將天氣預測加入預測變數可以改善在下雪天和雨天的預測延遲效果。訓練資料為 2013 年芝加哥州際公路 I-55 共 13 英里路段 90 天的迴路探測器數據，測試資料為同一路段另外 90 天的交通流量資料，其中包含兩個特殊事件期間，這兩種情況都含有急劇的交通流量變化。結果顯示在正常和特殊情況都有著良好的預測結果。

Cheng et al.(2018)為提升都市交通管理，利用機器學習方法來對都市快速道路的交通狀態進行分類，此方法分為兩個部分，作者首先提出一個新的分類指標：路網豐富度(定義為給定時間路網中剩餘交通流量與最大交通流量之比，以更好地反映高速公路網絡的特徵)與交通量、車速、佔有率組成一個綜合的分類指標體系。並改善傳統 FCM(Fuzzy c-means)分群法的隸屬函數以及樣本權重處理，開發出一個新的機器學習方法。研究場域為上海南北高架高速公路共七公里路段，資料為一天 06:00~23:00 的迴路探測器數據，包含車流、車速、和佔有率。特過訓練模型並進行預測分析，並與傳統 FCM、SVM、決策樹與 KNN 方法比較，結果顯示此研究方法整體分類準確度相較前四種分別高出 10.10%、5.45%、30.92%和 35.66%，表明此改善之 FCM 機器學習方法可行且有良好的預測效果。

2.3 車機資料相關駕駛行為研究

林彥志(2009)利用大客車之車輛行車紀錄器的駕駛行為資料，針對駕駛員進行駕駛行為分析。結合車輛操作數位行車紀錄器異常紀錄(例如：超速、怠速過久、引擎轉速過高、急加速、未保持安全距離等)、駕駛員基本資料及經歷(年齡、性別、服務年資等)、駕駛員自律等變數(例如：獎懲紀錄、肇事紀錄等)資料進行多變量變異數分析、群集分析與多變項羅吉斯迴歸來對駕駛員進行分群與建立駕駛行為預測模型。其結果顯示，在駕駛安全性次數邏輯斯迴歸模式中，駕駛考驗經歷會影響發生超速次數、未保持安全距離次數的機率；在駕駛肇事及故障次數邏輯斯迴歸模式中，客運服務資歷及駕照駕駛考驗經驗會影響駕駛肇事及故障次數的機率。

交通部運輸研究所(2012)以城際客運大型車輛職業駕駛人為研究對象，利用研究所開發之外業系統之設備(例如：行車影像監視器、GPS、加速度計、 ODBII)，收集桃園汽車客運 150 人次駕駛行為資料，藉此以分析不安全之駕駛行為與能源消耗。該研究所收集的駕駛行為資料，在輔以人工觀察影像資料和相關程式判斷後進行建立駕駛行為分類準則。另外透過駕駛行為教育訓練，針對節能與安全兩面向進行教育以作為前後資料比對。該研究結果指出，在油耗方面，經過教育訓練後的平均實際燃油效率表現有所提升，而在跟車行為方面，經過教育訓練後的不安全跟車事件次數有所減少，但是平均 Headway 並未減少跟車距離是有統計上顯著的差異的，代表其教育訓練的具有一定成效。

Bell et al.(2016)為評估商用車載監控系統(IVMS)的反饋會是否對於能夠減少駕駛員危險駕駛行為的發生頻率，其研究對象為卡車運輸公司以及汽油供應商共 315 台安裝 IVMS 車輛。第一階段為實驗組駕駛若發生高風險的車輛操縱會有燈號警告，第二階段為實驗組駕駛員與監督者一起觀看有關其危險駕駛行為的影像，並由監督員指導了安全駕駛的做法。研究結果顯示，在有教練指導和燈光即時反饋的期間，危險駕駛行為的大幅下降；但僅燈光的反饋與對照組沒有顯著差異，表示 IVMS 的效果具有侷限性。

Vlahogianni et al.(2017)嘗試使用相較於車機較低成本的手機作為探針來識別極端駕駛，例如：急轉彎、急煞車和急加速等。透過手機含有的陀螺儀、加速度計、GPS 資訊來蒐集並校正資料，再透過基於粗糙集合理論所建立的機器學習架構來修正加速度相關的資料。研究的結果表明，以智能手機識別極端駕駛的正確率為 99.4%，而以 OBD-II 設備識別的正確率為 99.3%。代表相較於使用固定位置之設備收集的數據，和以與其他主流檢測方法，基於智能手機的演算法亦有相當的平均準確度來檢測四個不同的極端駕駛型態（煞停，加速，左轉彎和右轉彎）。

Tselentis et al.(2017)使用數據包絡分析法(Data Envelopment Analysis, DEA)來建立評估駕駛安全效率的分類架構。透過手機感測設備蒐集 56 位駕駛共 7 個月的駕駛駕駛行為的實時資料，包含行駛距離、速度、加速度、煞車和使用智慧手機的情況等數據，以

這些數據來作為 DEA 模型的輸入資料以估算樣本中每個駕駛員的相對駕駛效率指數。駕駛效率之檢視則依據是否違反速度限制、因使用行動電話而分散注意力和在城市或農村和公路上的侵略性和整體安全性等。研究結果根據駕駛特徵閾值的第 25 和第 75 百分位數，將駕駛分為三類（無效率、低效率和最高效率）。在包含所有道路類型的整體安全模型之結果亦顯示出就急加速度駕駛行為的事件來說，估算安全效率指數的關鍵因素為超速和使用行動電話的所佔之比例。

Osman et al.(2019)為探討注意力分散所導致駕駛行為偏差的影響。提出了一種使用機器學習的雙層層級分類方法，利用駕駛行為參數以識別駕駛員參與不同類型的次要任務。第一層級先識別確認駕駛屬於一般駕駛還是從事次要務，接著第二層級再識別駕駛從事哪一類型的次要任務。次要任務分為三種類型：手持手機呼叫、手機發短信以及與相鄰乘客的互動，輸入資料為 SHRP2 NDS 資料庫共 373 為駕駛員資料，駕駛行為特徵屬性包含速度、偏移率(Yaw rate)、水平加速度、垂直加速度、油門踩踏位置。透過比較 9 種監督式學習的分類法，決定出訓練模型。其結果顯示(圖 2.3-1)確認次要任務的精確度以決策樹(Decision Tree)99.8%為最佳分類法，而對於次要任務類型識別以隨機森林(Random Forest)方法 82.2%最高，整體辨識結果具有 82.03%的高準確度。

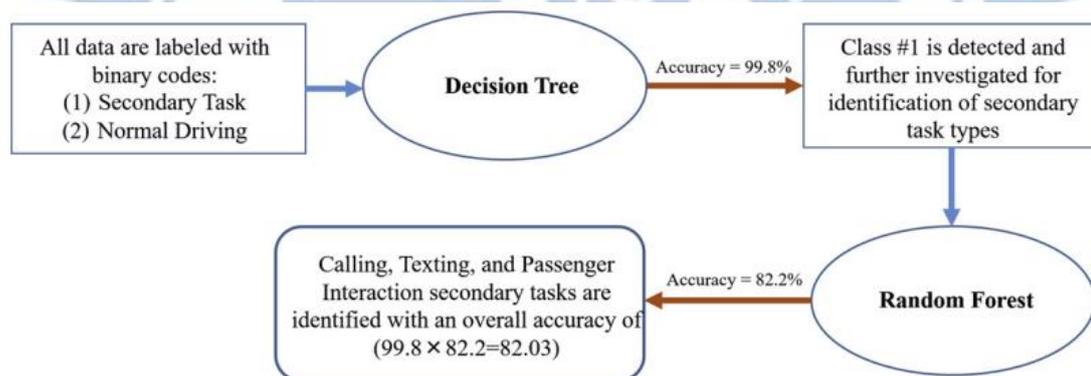


圖 2.3-1 最終分類模型架構

Yi et al.(2019)以機器學習方法建立一個個人化駕駛辨識系統，除了使用傳統的車機資料外，將個別駕駛員的特性納入辨識駕駛行為之條件，另外也考慮道路型態相關資訊，以增加辨識表現。此方法使用 t-SNE(t-Distributed Stochastic Neighbour Embedding)去分析不同駕駛的特性，再透過計算 Spearman distance 確認駕駛員相似度，藉以判斷資料是否需要個人化學習。訓練模型分群法的選擇為比較常用的五種分群法，擇優使用之。測試資料為 2016 年 UAH-DriveSet 資料庫透過智慧型手機 APP 蒐集的車機資料，包含 5 位駕駛員在 3 種情境及 2 種道路型態下的資料(例如：車速、三軸加速度、行駛方向等)。結果顯示(表 2.3-1)，相較於傳統預測模型，透過納入駕駛員個人化條件以及道路型態資訊可以增加駕駛行為(狀態)預測的準確度。

表 2.3-1 不同預測模型比較表

Comparisons for four different models.

Model	Generic model	Personalized model
Without road info	81.3%	89.5%
With road info	83.6%	91.6%

Shi et al.(2019)利用機器學習演算法 XGBoost，使用車輛軌跡數據中的駕駛行為特徵以及風險指標，來預測駕駛風險。此研究架構結合了基於學機器習的特徵選擇、無監督式學習的風險評級和處理數據不平衡的重採樣方法。根據演算法所選擇的關鍵特徵進行駕駛風險評估預測。測試資料為 FHWA(Federal Highway Administration) NGSIM 計畫的車輛軌跡數據，為 2015 年 6 月 15 日 5,084 輛車汽車在好萊塢高速公路(US Route 101)行駛 45 分鐘，共 3,203,867 筆記錄包含車輛軌跡、及時速度、加速度等資料。針對風險層級利用 Fuzzy c-means 分為 4 個級別，透過機器學習演算法確定 64 個關鍵駕駛行為特徵並進行作為最終訓練模型。結果顯示模型整體準確率為 89%，說明該研究方法對於識別駕駛評估的重要特徵以及對於駕駛風險評估的準確預測是有效且可靠的。

林玟姘(2019)使用車載系統 Mobileye 所記錄之駕駛員跟車車距資料作為輸入資料，考量不同因子(天氣、車速、日夜)篩選資料進行情境區分，再以 K-means 集群分析法對各情境中之跟車車距矩陣進行駕駛跟車行為分群。分群完畢後將跟車車距數值矩陣轉換為跟車車距矩陣圖，將矩陣圖作為輸入資料，以卷積神經網路演算法訓練出分類模型，藉此分類出駕駛員的跟車行為類型。研究結果顯示矩陣圖在經過圖片預處理步驟後分類能力有所提升，且在大多情境下有著良好的預測效果；K-means 分群法分將跟車矩陣分為積極型、保守型兩類之預測效過又高於分為積極型、穩健型、保守型三類，整體模型分類平均精確率為 97%。

施朝欽(2019)使用國道客運旅次資料，並結合行車動態與道路相關資訊建立評估駕駛人安全駕駛行為分數，進而找出駕駛表現較差之駕駛員。該研究資料為 100 個旅次與 21 位駕駛員，首先由 ADAS 預警事件中過濾出事故前兆，接著將「未保持安全距離」行為區分成不同的行車動態並建立其風險評估模型與前兆建立連結；在以同質旅次分割法結合上述模型建立駕駛人安全駕駛行為分數。研究結果顯示不同行車動態對於事故風險有著不同程度的影響；其結果產生之分數與駕駛員過去發生之肇事進行關聯性分析驗證，證實該研究之駕駛人安全駕駛行為分數表現優於過去業者採用之 ADAS 預警指標。

2.4 小結

針對評估駕駛行為之研究，方法包括問卷、統計分析方法、心理量測、自然駕駛研究等，然而上述部分方法存在著一些限制和缺點。例如：問卷與心理良次之受測者的選擇會偏向符合社會期待、樣本代表性不足、問項過少可能難以量測受測者之行為，而問項過多可能會讓受測者因疲勞而有亂答或誤答現象，間接造成蒐集資料之不精準。此外，駕駛行為因子與駕駛風險的因果關聯很難被證明，也造成統計分析方法之結果難以連結實際駕駛行為。近期駕駛行為研究多以自然駕駛研究方法，通過無干擾的數據收集設備並且沒有實驗控制，通過記錄駕駛員，車輛和周圍環境的詳細信息來進行深入研究，以了解駕駛員在日常旅行中的行為。隨著科技的發展與進步，車載裝置不管是在私人用車或是商業用車都已相當普及，透過車載裝置蒐集的巨量駕駛行為資料，所蒐集的大量資料相當於整個母體，可以有效地針對駕駛行為及風險進行相關分析，且車載裝置紀錄駕駛當下的實際駕駛行為數據，相較於問卷、心理測量較貼近實際情況。

綜合以上文獻，可以發現機器學習在交通領域分析是一個不錯的工具，雖然國外已有些許利用機器學習方法針對駕駛行為進行相關研究，但多以小客車駕駛員為研究對象，並沒有對大客車駕駛員風險深入探討；國內以機器學習算法作為分析方法分析大客車駕駛員風險之研究較少著墨。另外整理以車機資料分析並評估駕駛員風險之研究(如表 2.3-2)，研究問題大致可以分為駕駛風險分類評估、駕駛狀態識別兩種類型，而分析方法主要多以機器學習演算法。近期研究選用之駕駛行為變數以車速、車距、加速度、偏移等為重複性較高之變數；在駕駛風險評估指標部分大可以分為人工標記、中介指標、駕駛行為變數分群結果三種。另外，由於影響事故發生之因素相當複雜，本研究主要會參考 Shi 等人在 2019 年的研究，單僅以 ADAS 或是車機所記錄之駕駛直接行為表現作為駕駛風險評估因子。也因為駕駛行為因子與駕駛風險間存在複雜的機制且兩者之關聯性難以直接連結，例如：超速、急煞車、變換車道與車距等，以機器學習演算法能夠對車機記錄之車駕駛行為資料進行有較深入且全面的分析。

表 2.3-2 近年以車機資料分析並評估駕駛員風險之研究

	研究目的	研究對象	分析方法	駕駛行為變數	風險評估指標
李佩憶 (2017)	建立駕駛風險分級制度，並探討人格特質對其分級結果影響	國道客運 駕駛	問卷、 kmeans、 次序羅吉 斯	偏移、未保持 安全距離、引 擎轉速過高、 超速、急加 速、剎車使用 過久	駕駛行為變數 分群結果
Osman et al., (2019)	以駕駛行為 參數識別駕 駛員參與的 不同類型的 次要任務	小客車駕 駛	Decision Tree、 Random Forest	速度、偏移、 加速度、油門 踩踏位置	Normal driving、 Secondary task
Yi et al., (2019)	以車機資料 識別駕駛狀 態	小客車駕 駛	Random Forest	車速、偏移、 道路型態	Normal、 drowsy、 aggressive
Shi et al., (2019)	以車輛軌跡 資料評估駕 駛風險水平	摩托車、 汽車、卡 車駕駛	FCM、 XGBoost	軌跡、車道 數、車輛類 型、車長, 速 度、加速度、 車距	CPI、TTC
林玟姍 (2019)	以車距資料 分類駕駛跟 車類型	國道客運 駕駛	Kmeans、 卷積神經 網路	車距、速度、 日夜、天氣	車距分群結果
施朝欽 (2019)	以行車動態 與道路資訊 評估駕駛人 之安全駕駛 行為分數	國道客運 駕駛	Binary Logistic、 混合效果 頻次模式	未保持安全距 離、車道偏 移、超速	事故前兆、行 車動態次數

第三章 研究方法

參考第二章關於近期使用車機資料進行駕駛員風險評估之文獻回顧，本章將敘述本研究設計評估駕駛風險之研究方法。本章包含四個小節，分別為 3.1 小節資料蒐集與處理、3.2 小節特徵提取、3.3 小節機器學習模型、3.4 小節駕駛風險評估與 3.5 小節風險評估模型之評定。本研究之機器學習設計架構參考 Shi et al. (2019) 所設計之機器學習模型，為從匯入之車機資料中提取駕駛相關特徵進而評估駕駛風險層級。此機器學習架構分別會以機器學習演算法中 Clustering 與 Classification 兩類別做為主要演算法，用於資料分群標籤、特徵選取、風險預測等過程。研究方法以非監督式學習方式標籤駕駛風險層級結合以學習為基礎的特徵選取，再透過特徵過濾找出關鍵駕駛行為特徵並進行模型訓練，最終進行駕駛風險預測。另外，本研究會針對 Shi 提出之風險評估模型存在的一個問題：區別駕駛風險特徵與駕駛行為特徵必要性；以及部分研究 (林玟妘, 2019; Shi et al., 2019) 因車機資料不含有風險標籤所以使用 2 階段機器學習的必要性會設計出三種訓練模型來進行探討。

3.1 資料蒐集與處理

3.1.1 研究資料

研究資料包含 ADAS 資料與駕駛員班表資料。ADAS 資料為國內行駛國道一號新竹至台北的某知名客運公司(以下簡稱為 H 公司)於大客車所裝設之 ADAS: Mobileye 所蒐集之資料。Mobileye 為多功能前方碰撞警示系統，功能包含如車道偏移警示、前方碰撞警示、前方車距監測及警示等，能有效預防或降低交通事故的發生。Mobileye 會對車輛前方影像進行辨識，經由人工智慧判斷、計算是否有碰撞發生之潛在危險。透過不斷偵測車前狀況並計算己車與前方車輛、車道線以及行人間之距離及相對速度，提供駕駛人及時性的警示，如圖 3.1-1 所示，顯示表之數值 0.8 即為與前方車距為 0.8 秒。



圖 3.1-1 Mobileye 系統示意圖

資料來源：Mobileye

Mobileye 所記錄之資料類型包含事件回傳資料與定時回傳資料兩種。然而兩種資料都必須是在 Mobileye 有感應時才會有所記錄。H 公司採用之 Mobileye 最大偵測距離為 80 公尺，設定每 10 秒回傳資料。資料包含車牌號碼、跟車車距、車速、警示事件等資訊，其有效資料欄位共有 7 個欄位。欄位說明如下表 3.1-1，其中 SecUnit 為跟車車距，車距之定義為：兩車車距(本身車輛之車頭與前車車尾之距離)/本身車速。車機記錄的數值若要轉換為國際單位制的秒，須將(SecUnit-1)/20；如表 3.1-2 在第一列的 SecUnit 為 15，則是代表與前車車距為 0.7 秒。另外，也向 H 公司取得駕駛員班表資料，資料包含班表日期、發車時間、路線編號、駕駛員編號等共有 8 個欄位，欄位說明如下表 3.1-3，資料內容如表 3.1-4。

表 3.1-1 Mobileye 資料欄位說明

欄位名稱	欄位定義
Sno	資料流水號
CarNo	車牌號碼
SecUnit	跟車車距 (秒)
Speed	車速 (km/h)
Note	警示事件記錄
UpdDayTime	資料回傳時間
Employee_No	駕駛員編號

資料來源：本研究整理

表 3.1-2 Mobileye 資料內容

Sno	CarNo	SecUnit	Speed	Note	UpdDayTime	Employee_No
7734798	KKA-0520	15	78	nan	2019/2/9 00:01	nan
7734815	KKA-0520	11	81	向『右』偏移警示	2019/2/9 00:03	nan
7734816	KKA-0520	19	95	nan	2019/2/9 00:04	nan
7734825	KKA-0520	19	88	向『右』偏移警示	2019/2/9 00:05	nan
7734834	KKA-0520	21	83	nan	2019/2/9 00:07	nan

資料來源：本研究整理

表 3.1-3 駕駛員班表資料欄位說明

欄位名稱	欄位定義
Schedule_day	班表日期
Schedule_Time	發車時間
RouteId	路線編號
GoBack	往返程
Car_No	車牌號碼
Employee_No	駕駛員編號
Birthday	駕駛員生日
Start_Work_Date	駕駛員到職日期

資料來源：本研究整理

表 3.1-4 駕駛員班表資料內容

Schedule_day	Schedule_Time	RouteId	GoBack	Car_No	Employee_No	Birthday	Start_Work_Date
2019/2/9	00:00	1	1	KKA-0520	B1204	066/07/23	2017/11/28
2019/2/9	00:20	1	1	FAA-166	B1115	047/02/15	2016/8/1
2019/2/9	00:30	1	2	338-AC	B1176	061/06/11	2016/11/17
2019/2/9	01:00	1	1	371-FN	B1067	059/05/23	2017/3/13
2019/2/9	05:20	1	2	KKA-0206	B0021	049/08/23	2012/12/27
2019/2/9	05:30	1	2	337-AC	B0742	047/09/28	2018/4/17

資料來源：本研究整理

3.1.2 資料清洗

檢視 Mobileye 原始資料，可以發現一些欄位存在異常值或是缺失值的問題，本小節將針對 Mobileye 資料的合理性進行相關資料處理。

(1) 異常值處理

如表 3.1-5 所示，可以發現在第 1 列資料(Sno: 9525752)所記錄之車速為 255 km/hr 以及第 4 列資料(Sno: 11905824) 記錄之車速為 207 km/hr。此數值實為不合理之車速，故本研究定義車速大於 200 km/hr 之車速為異常車速，將該筆資料予以刪除。另外，在第 2 列資料(Sno: 10989709)所記錄之 SecUnit 為 1，表示 Mobileye 有感應到前車，但無法提供與前車距離秒數的資訊。因此於本研究中亦將此情況視為異常值，刪除該筆資料。

表 3.1-5 異常值欄位示意表

Sno	CarNo	SecUnit	Speed	Note	UpdDayTime	Employee_No
9525752	312-U8	13	255	超速	2019/3/21 05:45	B1204
10989709	980-U3	1	89	nan	2019/4/10 10:18	B1176
11056126	980-U3	31	90	nan	2019/4/11 10:38	B1067
11905824	980-U3	2	207	超速	2019/4/21 19:03	B0021
9160462	KKA-0256	41	80	nan	2019/3/15 14:23	B0742
10103183	KKA-0256	12	87	nan	2019/3/21 05:45	B1204
9694770	KKA-0257	37	91	nan	2019/2/11 13:21	B1115
9351461	KKA-0591	20	85	nan	2019/4/10 10:18	B1176

資料來源：本研究整理

(2) 缺失值處理

Mobileye 原始資料總筆數為 1,344,250 筆，經檢視後發現駕駛員編號欄位存在大量缺失值，共 1,211,807 筆。本研究為評估駕駛員之駕駛風險，駕駛員編號為進行資料分析的必要欄位，若缺少其編號將導致無法確認該筆 Mobileye 資料是由哪一位駕駛員產生，因此必須透過資料勾稽之方式來比對 Mobileye 資料與駕駛員班表資料以進行駕駛員編號缺失值的差補。資料勾稽步驟如下圖 3.1-2 所示，針對駕駛員編號缺失的 Mobileye 資料列，以該列之車牌號碼(KKA-0520)與資料回傳時間(2019/2/9 00:01)作為索引，從駕駛員班表資料中找出相同的車牌號碼資料列(第 1 列)，在依照資料回傳時間和班表日期、班表時間最相符的所對應的駕駛員編號(B1204)作為 Mobileye 資料中駕駛員編號缺失值的差補。處理完成之資料如表 3.1-6。

Mobileye 資料						
Sno	CarNo	SecUnit	Speed	Note	UpdDayTime	Employee_No
7734798	KKA-0520	15	78	nan	2019/2/9 00:01	nan
7734815	KKA-0520	11	81	向『右』偏移警示	2019/2/9 00:03	nan
7734816	KKA-0520	19	95	nan	2019/2/9 00:04	nan
7734825	KKA-0520	19	88	向『右』偏移警示	2019/2/9 00:05	nan
7734834	KKA-0520	21	83	nan	2019/2/9 00:07	nan

駕駛員班表資料			
Schedule_day	Car_No	Schedule_Time	Employee_No
2019/2/9	KKA-0520	00:00	B1204
2019/2/9	FAA-166	00:20	B1115
2019/2/9	338-AC	00:30	B1176
2019/2/9	371-FN	01:00	B1067
2019/2/9	KKA-0206	05:20	B0021

圖 3.1-2 資料勾稽示意圖

資料來源：本研究整理

表 3.1-6 駕駛員編號差補完成示意表

Mobileye 資料						
Sno	CarNo	SecUnit	Speed	Note	UpdDayTime	Employee_No
7734798	KKA-0520	15	78	nan	2019/2/9 00:01	B1204
7734815	KKA-0520	11	81	向『右』偏移警示	2019/2/9 00:03	B1204
7734816	KKA-0520	19	95	nan	2019/2/9 00:04	B1204
7734825	KKA-0520	19	88	向『右』偏移警示	2019/2/9 00:05	B1204
7734834	KKA-0520	21	83	nan	2019/2/9 00:07	B1204

資料來源：本研究整理

3.2 駕駛特徵提取

為評估駕駛風險，必須從 Mobileye 資料中提取駕駛特徵，以作為機器學習模型的輸入資料。這一小節將說明本研究如何產生機器學習輸入資料。根據近期以車機資料評估駕駛風險之研究，作為駕駛員行為之變數以車機所記錄之車速、車距、加速度、偏移等為重複性較高之變數。本研究使用之車機資料 Mobileye 可提取之駕駛行為變數為車速、車距。另外，由於本研究之車機資料並沒有自動或是人工標記駕駛風險層級，因此必須從 Mobileye 資料中提取駕駛風險特徵以作為駕駛風險分群的輸入特徵。以下針對駕駛風險特徵與駕駛行為特徵的提取進行說明。

3.2.1 駕駛風險特徵提取

近期研究除了原本資料有自動或是人工標記駕駛風險層級外，大多採用中介指標(如 CPI、TTC)或是車輛操作相關變數(如車距、車速、加速度)作為駕駛風險特徵，再以其分群結果來產生駕駛風險層級。本研究由 Mobileye 資料提取車距以及警示事件作數據做為駕駛風險特徵。根據每一個趟次計算平均車距、車距標準差、最小車距、超速警示次數、前方碰撞警示次數、向右偏移警示次數、向左偏移警示次數，產生共 7 個風險指標作為駕駛風險特徵。過去文獻(林彥志，2009；李佩憶，2017；交通部運輸研究所，

2012；林玟姘，2019；Shi et al., 2019；施朝欽，2019)都採用車距來做為評估駕駛風險的一個重要車輛操作變數，以及相關統計資料(高公局，107年；警政署，107年)皆顯示「未保持與前車之安全距離」為大客車駕駛肇事主因，也應證駕駛員在行駛其間的车距表現與駕駛風險有高度的連結。故本研究預期駕駛在行駛一個趟次所表現之平均車距越小、車距標準差越大、最小車距越小代表該趟次的駕駛風險相對較高，反之亦然。另外亦將 Mobileye 本身記錄之警示事件(中介指標)作為衡量駕駛風險的特徵，預期駕駛在行駛一個趟次中被警示的次數越多代表風險越高。

3.2.2 駕駛行為特徵提取

本研究使用 Mobileye 資料用於特徵提取。在每一個趟次中 Mobileye 記錄之車速和車距可以視為駕駛員行駛每一個趟次的駕駛行為整體反映，例如對風險的感知和駕駛風格。參考 Shi et al., (2019)，本研究對提取之駕駛行為變數：車速、車距進行相關運算(如表 3.2-1)，將車機數據轉換成有資訊意涵和價值的資料型態來捕捉駕駛行為樣態。變數經運算後可產生能夠描述以及解釋駕駛行為的數據並將其作為駕駛行為特徵(共 24 個)。

表 3.2-1 駕駛行為特徵提取變數與運算

變數	SecUnit(車距)、Speed(車速)
運算	Percentile(百分位數): 01、05、25、50、75、99 Statistical description(敘述性統計): min、max、mean、std、skewness、kurtosis

資料來源：本研究整理

3.2.3 機器學習輸入資料

將 Mobileye 資料進行駕駛特徵提取後，共可以得到 7 個駕駛風險特徵以及 24 個駕駛行為特徵。駕駛風險特徵用於標記駕駛的風險層級，以區分高風險駕駛員和較安全的駕駛。駕駛行為特徵用於後續機器學習模型中的監督式學習的輸入物件，所對應的風險層級為駕駛風險特徵的分群結果，輸入資料如表 3.2-2 所示(因版面限制只呈現部分欄位)。

表 3.2-2 機器學習輸入資料

Trip_ID	駕駛風險特徵					駕駛行為特徵					
	Sec_min	Sec_std	Sec_mean	Speeding	...	Sec_p01	Sec_p05	Sec_p25	Sec_p50	Sec_p75	...
0	1.20	0.28	1.60	3	...	1.20	1.20	1.40	1.80	1.80	...
1	0.80	0.43	1.51	2	...	0.81	0.84	1.28	1.80	1.80	...
2	0.90	0.30	1.68	5	...	0.96	1.18	1.80	1.80	1.80	...
3	0.60	0.48	1.14	0	...	0.60	0.60	0.90	0.90	0.90	...
4	0.50	0.24	0.83	1	...	0.51	0.55	0.73	0.90	0.90	...
5	0.80	0.53	1.68	2	...	0.81	0.86	1.60	1.80	1.8	...

資料來源：本研究整理

3.3 機器學習模型

本研究以機器學習演算法來建立駕駛風險評估模型，機器學習模型主要參考 Shi et al. (2019)的機器學習架構，從輸入之駕駛行為特徵中找出關鍵駕駛行為特徵，並利用關鍵駕駛行為特徵來評估駕駛風險。機器學習的架構包含非監督式學習的標籤駕駛風險層級、以及基於機器學習的特徵選擇。根據機器學習架構的差異，本研究設計出 3 種不同的機器學習模型，來探討在過去研究中的機器學習架構區分駕駛風險特徵與駕駛行為特徵之必要性(Shi et al., 2019)；以及比較過去機器學習模型中先以非監督式學習演算法標籤駕駛風險層級，在以監督式學習演算法進行駕駛風險評估的 2 階段機器學習模型(Shi et al., 2019；林玟妘, 2019)與只有使用非監督式學習簡算法建立駕駛風險分群模型的評估結果是否有顯著差異。以下 3.3.1~3.3.3 將針對 3 種駕駛風險評估模型進行詳細說明。

3.3.1 Model-1

Model-1 為 Shi et al.(2019)所設計之機器學習模型，將輸入特徵區分為兩種：駕駛風險特徵與駕駛行為特徵。機器學習架構如下圖 3.3-1 所示，包含非監督式學習的標籤駕駛風險層級、以及基於機器學習的特徵選擇共 2 階段機器學習。標籤駕駛風險層級是以非監督式學習演算法利用駕駛風險特徵來標籤風險層級；基於機器學習的特徵選擇是以駕駛行為特徵和對應之風險層級來建立風險評估模型並篩選出關鍵駕駛行為特徵提升模型準確度，以下針對此 2 階段機器學習進行說明：



圖 3.3-1 Model-1 架構圖

(1)標籤駕駛風險層級

此步驟利用聚類分析演算法，將駕駛風險特徵作為衡量特徵，把具有相似駕駛風險樣態的駕駛員趟次歸納為同一風險層級。鑑於本研究採用之 Mobileye 資料沒有關於駕駛風險層級的真實標籤(ground-truth labels)，使用非監督式學習的資料標籤能夠透過機器學習演算法，從巨量車機資料中自動找出駕駛風險分群的規則，其分群結果可做為標籤駕駛風險層級的一個依據。如下圖 3.3-2，本研究將 7 種駕駛風險特徵作為駕駛分群的輸入特徵，再利用機器學習演算法為其標籤風險層級。常用資料分群的機器學習演算法有許多種，例如 K-means、Mean-Shift Clustering、DBSCAN、Gaussian Mixture Models 等。根據國內近期在大客車駕駛風險評估研究使用 K-means 演算法進行資料分群來標籤駕駛風險都有不錯的表現(李佩憶，2017；林玟姘，2019)，本研究將採用 K-means 演算法來進行風險層級標籤。

Trip_ID	駕駛風險特徵							風險層級
	Sec_min	Sec_std	Sec_mean	Speeding	FCW	right_warn	left_warn	
0	1.20	0.28	1.60	3	0	0	2	0
1	0.80	0.43	1.51	2	1	1	1	1
2	0.90	0.30	1.68	5	1	1	1	1
3	0.60	0.48	1.14	0	0	0	0	0
4	0.50	0.24	0.83	1	0	0	3	0
5	0.80	0.53	1.68	2	2	4	0	0

圖 3.3-2 駕駛風險分群結果示意圖

資料來源：本研究整理

K-means 為分割式分群法，屬於非監督式學習演算法，處理之資料是沒有正確答案(標籤)可供參考，依據欲分群的資料物件自身特徵(屬性)計算彼此間的相似度將其分為 K 個群集。K-means 所採取的是質量中心概念，目標為最小化群集內的資料和群集中心的誤差平方和，即為盡量減少每一個群集中，每一資料點至該群集中心的距離誤差。K-means 演算法執行步驟如下表 3.3-1 所示，K-means 範例如圖 3.3.2。K-means 產生之群集中心為該群集的代表點，其數值可代表該群平均表現，分群結果的可解釋能力較高，且 K-means 具有計算快速(收斂速度快)、每一筆資料都可以被分群等優點。

表 3.3-1 K-means 執行步驟

Step0. 設定欲將資料集區分成多少(K)群
Step1. 隨機指派群集中心：從資料集隨機選取 K 個資料點作為初始群集中心
Step2. 計算所有資料點到所有 K 個群集中心的歐式距離
Step3. 產生群集：將所有資料點指派給與之最近之群集中心
Step4. 更新群集中心：根據每個群集內所有資料點重新計算該群集中心
Step5. 重複 Step2- Step4，直到群集中心不便或收斂。

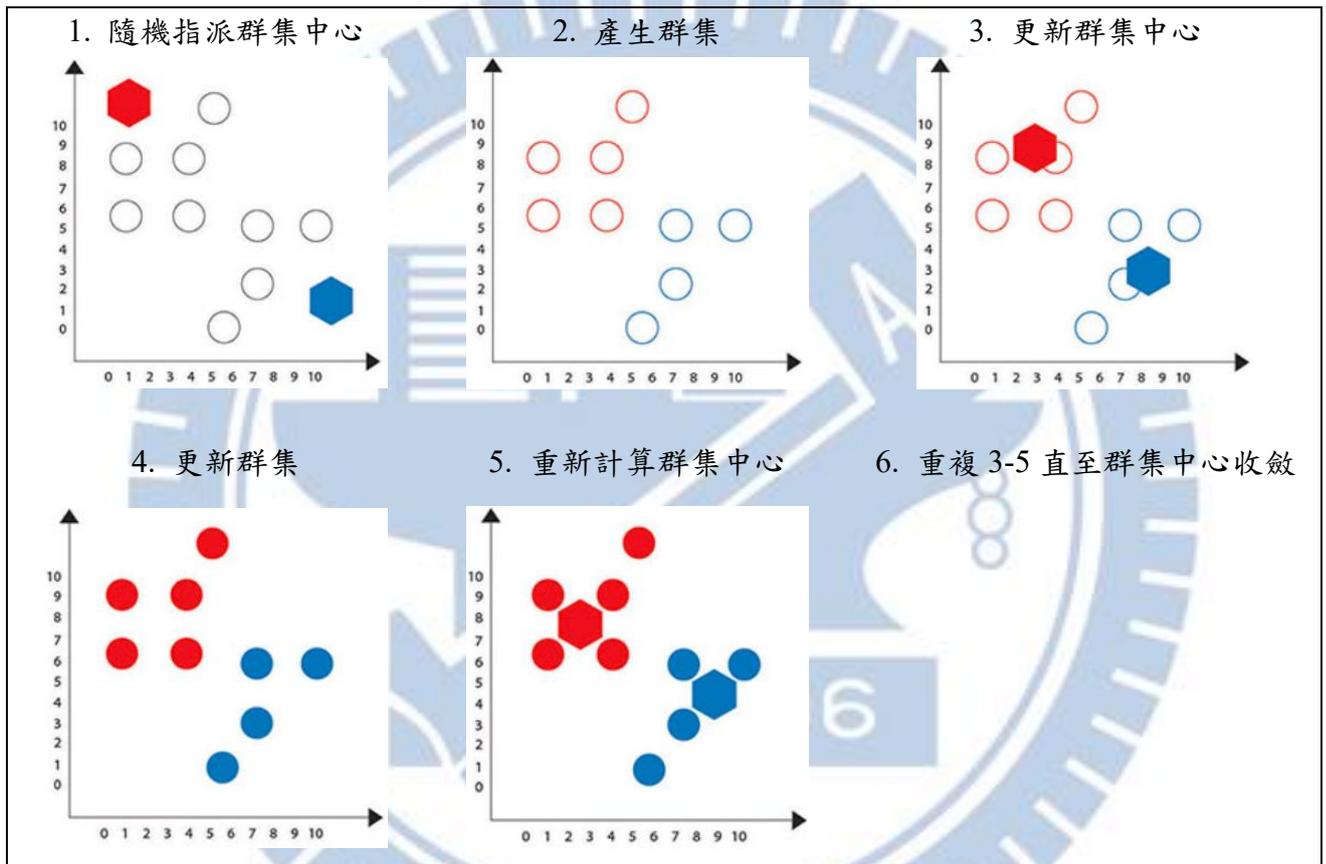


圖 3.3-3 K-means 示意圖

資料來源：Brandidea

(2)基於機器學習的特徵選擇

此部分包含風險評估模型的建立以及關鍵駕駛行為特徵的篩選兩部分。本研究採用分類法做為風險評估模型之演算法。分類法屬於一種監督式機器學習演算法，透過電腦程式從輸入的資料中試圖找出每筆數據所屬分類的規則來建立分類預測模型，主要目標是預測新數據所屬的類別。本研究之輸入資料包含駕駛行為特徵作為輸入物件和其對應之風險標籤作為預期輸出(如圖 3.3-4)，建立風險評估模型，以駕駛行為特徵來評估對應的駕駛風險層級。分類演算法架構如圖 3.3-5，將輸入資料分拆分為訓練集和測試集，並

以分類法對訓練集中的資料尋找分類準則來建立風險評估模型，接著以測試集來測試分類模型之準確度。常用的機器學習分類法有：Logistic Regression、KNN、SVC、Decision Trees、Random Forest 等。本研究會對上述常使用的分類演算法進行測試，再根據模型評估結果決定出較適合的分類演算法。

Trip_ID	輸入物件：駕駛行為特徵				預期輸出：風險層級
	Sec_p01	Sec_p05	Sec_p25	Sec_p50	
0	1.20	0	1.40	1.80	0
1	0.81	1	1.28	1.80	1
2	0.96	1	1.80	1.80	1
3	0.60	0	0.90	0.90	0
4	0.51	0	0.73	0.90	0
5	0.81	0.86	1.60	1.80	0

圖 3.3-4 分群法之輸入物件與預期輸出

資料來源：本研究整理

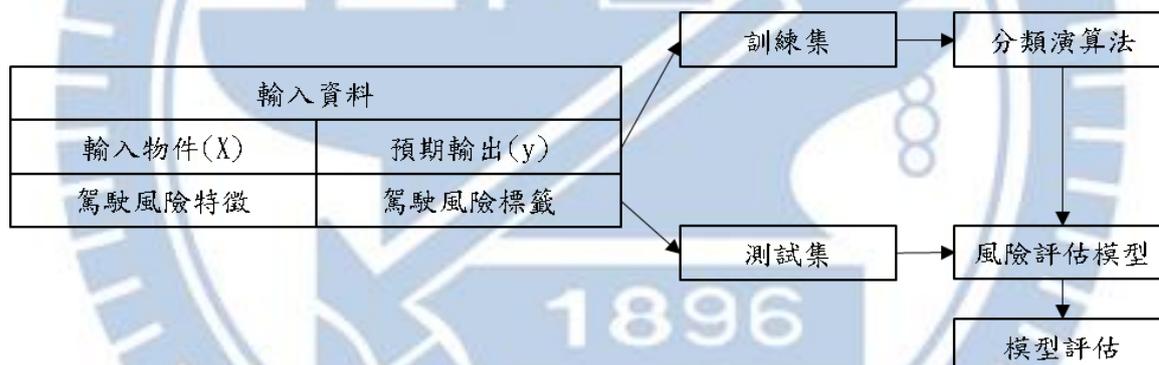


圖 3.3-5 分類演算法架構

資料來源：本研究整理

上述預測駕駛風險的輸入物件為所有駕駛行為特徵，然而駕駛行為特徵對於預期輸出的貢獻性並不相同，並非所有的駕駛行為特徵都是重要的輸入物件。因此在必須透過駕駛行為特徵的篩選來找出能夠評估駕駛風險的關鍵駕駛行為特徵。在機器學習中，Recursive feature elimination (以下簡稱 RFE) 演算法常被使用在徵篩選，透過模型重新訓練並從當前特徵集中以遞歸消除方式移除重要性最小的特徵。其目的為在考量模型的複雜度以及模型表現兩個因素下，決定出最適特徵數量和特徵組合。圖 3.3-6 為 RFE 的範例說明，假設初始輸入物件共有 4 個特徵：f1、f2、f3、f4，所有特徵訓練之模型準確率為 97%。經過第 1 次 RFE 迴圈得到以 f1、f2、f4 為特徵集合訓練出的模型會有最高的正確率 95%，因此刪除 f3；在第 2 次迴圈算出 f1、f4 為特徵集合訓練出的模型會有最高的正確率 92%，因此刪除 f2；在最後一個迴圈中以 f1 為特徵集合訓練出的模型會

有最高的正確率 60%，因此刪除 f4。在此範例中，f1、f4 為特徵集合訓練出的模型正確率與所有特徵訓練之模型正確率差異不大(5%)，故 f1、f4 可作為此範例最適特徵集合。

Iteration-1				
Features				Accuracy
f1	f2	f3	f4	97%

Subset	Features			Accuracy
1	f2	f3	f4	90%
2	f1	f3	f4	80%
3	f1	f2	f4	95%
4	f1	f2	f3	85%

Iteration-2				
Features			Accuracy	
f1	f2	f4	95%	

Subset	Features		Accuracy
1	f2	f4	70%
2	f1	f4	92%
3	f1	f2	60%

Iteration-3		
Features	Accuracy	
f1	92%	

Subset	Features	Accuracy
1	f4	45%
2	f1	60%

圖 3.3-6 RFE 範例

資料來源：本研究整理

為了避免訓練集所訓練出的模型有過度擬合的情況，因此使用 K-fold stratified cross-validation 來評估模型的學習成效。本研究採用 10-fold stratified cross-validation (如圖 3.3-7)，將輸入資料分為 10 分等分，9 等分作為訓練集進行模型訓練，其餘 1 份做為測試集來評估模型表現。共重複進行 10 次模型訓練並計算平均正確率來做為最終模型選擇依據。

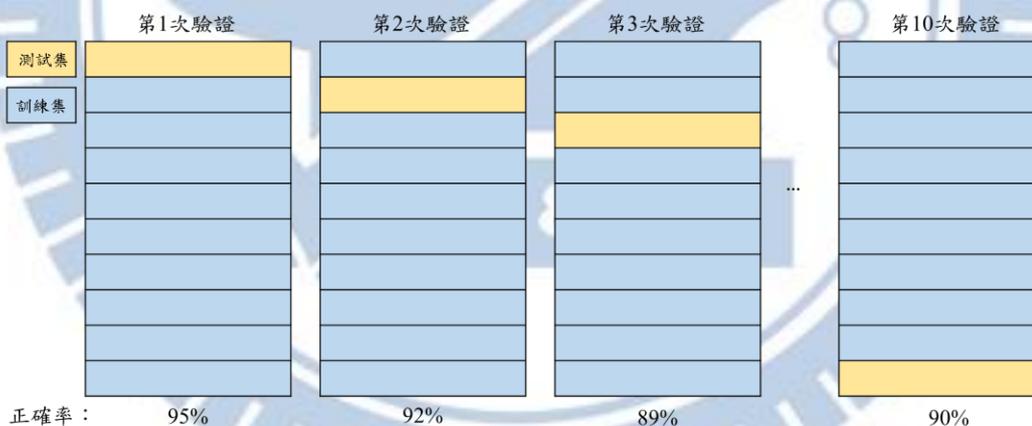


圖 3.3-7 10-fold stratified cross-validation 示意圖

資料來源：本研究整理

3.3.2 Model-2

Model-2 為探討為 Shi et al.(2019)所設計之機器學習架構其中存在的一個問題：區別駕駛風險特徵與駕駛行為特徵之必要性。如同 Model-1 所述，將駕駛特徵區分為駕駛風險特徵與駕駛行為特徵，前者用於標籤駕駛風險層級，後者作為評估模型之輸入物件。可以發現兩種特徵皆是由這輛操作變數進行相關計算得來，但其本質還是車機資料所記錄之車距、車速、加速度等駕駛行為變數。且駕駛的風險與駕駛的特徵間差異難以清楚

定義，例如平均車距可以做為評估駕駛風險高或低的風險特徵，但平均車距同時也可以視為一種駕駛行為的表現。

因此，本研究欲探討若是不區分駕駛特徵，是否也能達到相似的評估效果。如圖 3.3-8，在 Model-2 的機器學習架構中，將原先 Model-1 定義之駕駛風險特徵以及駕駛行為特徵混用，一起做為標籤風險層級的駕駛特徵。輸入資料和標籤結果如圖 3.3-9 (因版面限制只呈現部分欄位)，本研究以混合駕駛特徵共 28 個作為駕駛分群的輸入特徵，再同樣利用 K-means 對駕駛進行風險分群為其標籤風險層級。接著進行與 Model-1 相同的基於機器學習的特徵選擇步驟並找出關鍵駕駛特徵，在進行模型訓練與模型評估。

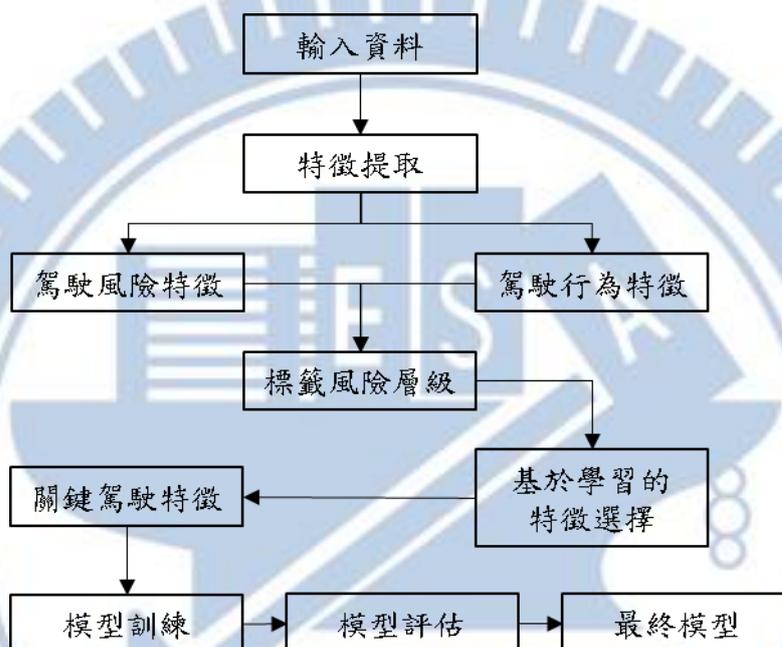


圖 3.3-8 Model-2 架構圖

Trip_ID	混合駕駛特徵								風險層級
	Sec_min	Sec_std	Sec_mean	Speeding	Sec_p01	Sec_p05	Sec_p25	...	
0	1.20	0.28	1.60	3	1.20	1.20	1.40	...	0
1	0.80	0.43	1.51	2	0.81	0.84	1.28	...	1
2	0.90	0.30	1.68	5	0.96	1.18	1.80	...	1
3	0.60	0.48	1.14	0	0.60	0.60	0.90	...	0
4	0.50	0.24	0.83	1	0.51	0.55	0.73	...	0
5	0.80	0.53	1.68	2	0.81	0.86	1.60	...	0

圖 3.3-9 駕駛風險分群結果示意圖

資料來源：本研究整理

3.3.3 Model-3

Model-3 為探討為部分研究(林玟妘, 2019; Shi et al., 2019) 因車機資料不含有風險標籤所以使用 2 階段機器學習的必要性進行探討。由於車機資料沒有相對應的風險標籤, 所以必須先從車機資料中提取駕駛風險特徵來進行駕駛風險標籤, 此為第一階段機器學習。第二階段機器學習為從車機資料提取駕駛行為特徵作為風險評估模型輸入物件並進行模型訓練。如同在 Model-2 所提到的駕駛風險特徵與駕駛行為特徵難以區別, 再加上第一階段機器學習完成後, 其實已經透過非監督式學習演算法利用駕駛特徵作為風險層級的評估依據, 將駕駛進行風險分群。其風險分群的結果應該可以直接作為駕駛風險評估之模型。

因此, Model-3 欲探討若是只以非監督式學習演算法, 使用駕駛特徵來進行風險分群, 其分群結果產生的風險分群模型是否也有 2 階段機器學習模型的評估效果。如圖 3.3-10, 在 Model-3 的機器學習架構中, 與 Model-2 相同地將駕駛風險特徵以及駕駛行為特徵混用, 一起做為標籤風險層級的駕駛特徵。因只做非監督式學習將會導致無法進行前述兩個模型架構含有的關鍵特徵篩選(監督式學習才能做 RFE), 但為了避免駕駛特徵間存在高度相關性因而導致模型預測失真, 且若省略特徵篩選步驟將會造成與前兩模型的比較基準不一致, 所以必須進行事特徵先篩選的程序。透過計算所有駕駛特徵間的 correlation coefficient, 本研究定義 correlation coefficient 的絕對值超過 0.8 屬於高度相關, 即刪除其中一個特徵。將篩選後的混合駕駛特徵作為駕駛分群的輸入特徵, 再利用 K-means 對駕駛進行風險分群為其標籤風險層級。K-means 最終產生的群集中心代表每個風險群集的平均駕駛表現, 各個群集中心內的特徵數值集合即為風險分群模型。如圖 3.3-11, 若是將駕駛風險區分為兩種風險層級, 可以得到兩分群中心包含的駕駛特徵數值(因版面限制呈現部分駕駛特徵), 分群 1 相對分群 2 而言有較高的風險表現, 例如 Sec_mean(平均車距)較小、Sec_std(車距標準差)較大、Speeding(超速警示次數)較多等駕駛特徵。此結果可作為風險分群模型, 透過計算新資料中的駕駛特徵與風險分群模型中駕駛特徵的距離, 與之距離較近之分群則為該筆資料的風險分群。

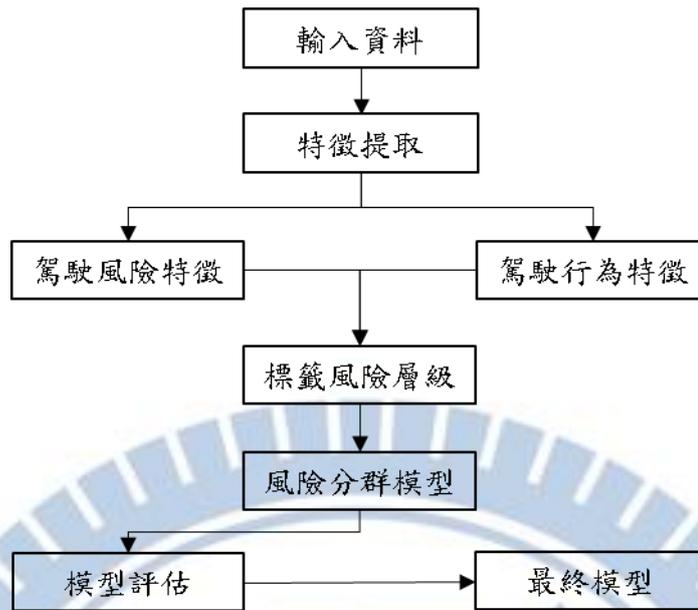


圖 3.3-10 Model-3 架構圖

駕駛特徵	群集 1	群集 2
Sec_min	1.20	1.30
Sec_std	0.28	0.12
Sec_mean	1.60	2.30
Speeding	3	1.50
Sec_p01	1.20	1.40
Sec_p05	1.25	1.65
Sec_p25	1.40	1.40
Sec_p50	1.80	1.80
Sec_p75	1.85	2.30
Sec_p99	2.00	2.50
...

圖 3.3-11 風險分群之群集中心特徵數值

3.3.4 小結

根據前面 3.3.1~3.3.3 三種模型之說明，本小結彙整並歸納出的三種風險評估模型的架構差異。如表 3.3-2 所示。

表 3.3-2 三種風險評估模型比較表

	Model-1	Model-2	Model-3
標籤風險層級之評估特徵	駕駛風險特徵	混合駕駛特徵	混合駕駛特徵
風險評估模型之輸入物件	駕駛行為特徵	混合駕駛特徵	無輸入物件，直接以風險分群結果作為風險評估模型
機器學習演算法	分群法、分類法	分群法、分類法	分群法
特徵選擇	RFE	RFE	以駕駛特徵間之相關係數進行事先篩選

Model-1 包含以駕駛風險特徵做為評估特徵來標籤駕駛風險層級，並將駕駛行為特徵作為風險評估模型的輸入物件，透過基於機器學習的特徵選擇篩選出關駕駛行為特徵來進行模型訓練。Model-2 與 Model-1 之差異在於使用混合駕駛特徵做為標籤駕駛風險層級的評估特徵以及將其作為風險評估模型之輸入物件。而 Model-3 僅以非監督式學習的分群法，利用事先篩選過的混合駕駛特徵來對駕駛進行風險層級標籤，並將其分群結果作為風險評估模型。

3.4 駕駛風險評估

本研究風險之評斷為相對駕駛風險，對每一位駕駛所行駛的趟次進行風險分群，再計算其平均表現。此相對風險會因為車機資料的樣本來源而有所差異，所分群出的風險為訓練樣本內所有司機的相對風險，例如分別以 A 和 B 公司的車機資料進行模型訓練，將駕駛分為高風險與一般風險 2 群。分群至高風險的 A 公司駕駛，是相對於其他同在 A 公司的駕駛有較高的風險，但若比較 B 公司的高風險駕駛，其結果為可能是相對較低風險的駕駛。

評估駕駛風險的分析單位為每一位駕駛員行駛的每一個趟次。透過前面 3.3 節所展示的 3 種駕駛風險評估模型，可以對每一個駕駛趟次評估出相對應的風險層級。本研究駕駛員風險評估之方式為，將每一位駕駛員行駛的趟次風險層級給予對應的駕駛表現分數，再依照定義的評估時間區間來計算駕駛員的平均表現分數。如圖 3.4-1，假設只有兩種風險層級，則將較高風險的風險層級給予-1 分，較低風險的風險層級給予 1 分；另外假設駕評估時間區間為 1 個月，駕駛員編號 B1204 的駕駛在 1 個月內總共有 5 個駕駛趟

次。統計 B1204 駕駛的所有駕駛趟次，高風險有 2 趟，一般有 3 趟，則編號 B1204 的駕駛員本月分的駕駛表現分數為 0.20。

Trip_ID	駕駛員編號	風險層級	駕駛表現分數
1	B1204	高風險	-1
2	B1204	高風險	-1
3	B1204	一般	1
4	B1204	一般	1
5	B1204	一般	1

圖 3.4-1 駕駛風險評估模型之結果

3.5 風險模型之評定

3 種模型評估駕駛風險之結果理論上應與客運公司內部專家評估之結果進行比對，來驗證模型的評估正確率。但受制於實務上無法取得客運公司對駕駛員的風險評估報告，因此僅比較 3 種模型的模型正確率，本研究將會以正確率最高的模型作為最適的風險評估模型。

第四章 模式驗證與結果分析

本章節會使用第三章所設計之方法來評估 H 公司駕駛員之駕駛風險，驗證三種模型的準確性並分析三種模型的評估結果是否有顯著差異。另外也會將本研究駕駛風險評估模型的評估結果與 H 客運公司實際評估駕駛員績效進行比較，來驗證本研究模型的評估是否有效且可靠的。本章包含 5 個小節，分別為 4.1 實測資料、4.2 Model-1 驗證、4.3 Model-2 驗證、4.4 Model-3 驗證和 4.5 模式結果與客運公司考績之比較。

4.1 實測資料

本研究所使用的車機資料為 H 公司提供的 Mobileye 車機資料。研究資料為行駛國道一號由新竹到台北之路線(相同起訖點、雙向)之 57 位駕駛員在 2019 年 2 月 9 日至 2019 年 4 月 28 日，共 79 天的 Mobileye 資料。原始 Mobileye 資料共記錄 1,344,250 筆車機資料(Mobileye 有偵測才會記錄)，經資料清洗後剩餘 436,553 筆車機資料(約刪除 7 成原始資料)，產生共 4,240 趟可分析之駕駛趟次，Mobileye 車機資料如表 4.1-1。另外，由於 Mobileye 車機資料記錄的屬性欄位具有不同的量綱和量綱單位，在進行資料分析或是模型訓練時，可能會遭遇因單位的不同(例如：車速與警示事件)，或數字大小的代表性不同(例如：車速 100 km/h 與車距 2.5 秒)等情況而影響到資料分析的結果；為解決此問題，在資料進行駕駛風險分群之前，須將研究資料進行資料的標準化(Standardization)，將原始資料轉換成無量綱(Dimensionless)的純量後，各駕駛特徵即能處於同一數量級，以利於後續的數據分析。且透過數據標準化，能夠提升模型的收斂速度和提高模型的精準度 (Shanker et al., 1996；Lantz, 2013)。Mobileye 車機資料標準化後之資料如表 4.1-2。標準化公式為統計上常用之 Z-分數，公式如下：

$$Z = \frac{x - \bar{x}}{S}$$

其中

x 為欲標準化之特徵屬性原始數值

S 為樣本的標準差

\bar{x} 為樣本的平均值

表 4.1-1 Mobileye 資料

CarNo	Date	Time	Sno	SecUnit	Speed	Note	UpdDayTime	Trip	Employee
312-U8	2019/2/9	17:01:53	7743041	1.2	45	nan	2019/2/9 17:01	1640	B0250
312-U8	2019/2/9	17:04:03	7743077	1.2	35	nan	2019/2/9 17:04	1640	B0250
312-U8	2019/2/9	17:23:17	7743332	1.8	92	nan	2019/2/9 17:23	1640	B0250
312-U8	2019/2/9	17:24:25	7743350	1.8	76	nan	2019/2/9 17:24	1640	B0250
312-U8	2019/2/9	17:44:34	7743560	1.8	99	nan	2019/2/9 17:44	1640	B0250
312-U8	2019/2/9	17:47:41	7743609	0.9	87	nan	2019/2/9 17:47	1640	B0250
312-U8	2019/2/9	17:48:24	7743617	1.6	96	nan	2019/2/9 17:48	1640	B0250
312-U8	2019/2/9	17:49:40	7743639	0.5	85	nan	2019/2/9 17:49	1640	B0250
312-U8	2019/2/9	18:00:17	7743746	1.8	88	nan	2019/2/9 18:00	1640	B0250
312-U8	2019/2/9	18:01:04	7743759	1.4	106	超速	2019/2/9 18:01	1640	B0250
312-U8	2019/2/9	18:08:31	7743857	1.8	50	nan	2019/2/9 18:08	1640	B0250
312-U8	2019/2/9	18:08:35	7743859	1.8	46	nan	2019/2/9 18:08	1640	B0250
312-U8	2019/2/9	18:12:21	7743903	1.6	53	nan	2019/2/9 18:12	1640	B0250
...

表 4.1-2 資料標準化後之駕駛趟次資料

Trip_ID	Employee_ID	Sec_min	Sec_std	Sec_mean	Speeding	Sec_p01	Sec_p05	Sec_p25	...
1	B1074	1.09	-0.94	-0.14	-0.17	1.01	0.68	0.05	...
2	B1218	0.27	-0.83	0.17	-0.17	0.27	0.61	1.43	...
3	B1211	-0.56	0.40	-1.97	-0.17	-0.80	-1.36	-1.66	...
4	A1107	-0.83	-1.25	-3.26	-0.17	-1.07	-1.55	-2.26	...
5	B1109	-0.01	0.74	0.20	1.08	-0.16	-0.48	0.74	...
6	B1109	1.09	-1.33	-0.04	-0.17	1.05	0.92	0.57	...
7	B1109	-0.28	0.17	-1.12	-0.17	-0.44	-0.71	-0.98	...
8	B0256	2.74	-0.54	1.47	0.46	2.82	2.72	1.43	...
9	B0296	-0.01	2.10	-1.15	0.46	-0.20	-0.68	-2.01	...
10	B1211	0.54	-1.09	-1.91	-0.17	0.41	0.00	-1.32	...
11	B1217	0.54	-0.61	-0.68	-0.17	0.46	0.27	-0.63	...
12	B0742	2.19	-1.90	0.67	0.46	2.24	2.18	1.43	...
13	B1148	0.27	-0.83	-1.01	-0.17	0.11	-0.34	-0.63	...
14	B1171	-0.28	0.92	-1.21	-0.17	-0.50	-1.02	-1.92	...
15	B0979	-0.28	0.07	-1.01	-0.17	-0.42	-0.59	-0.63	...
...

本研究使用之機器學習套件為 scikit-learn，使用之功能包含 Classification、Regression、Clustering、Model selection、Preprocessing 等，在以 Python 撰寫程式碼建立風險評估模型。研究使用之硬體環境為 Intel Core i7-8750H、32G RAM、Intel UHD Graphics 630、NVIDIA GeForce GTX1060。

4.2 Model-1 驗證

Model-1 包含非監督式學習的標籤駕駛風險層級、以及基於機器學習的特徵選擇共 2 階段機器學習。以下為 Model-1，2 階段機器學習模型之評估結果。

4.2.1 風險層級標籤結果

標籤駕駛風險輸入之駕駛風險特徵為：平均車距、最小車距、車距標準差、超速警示次數、向左偏移警示次數、向右偏移警示次數、前方碰撞警示次數，共 7 種駕駛風險特徵。利用 k-means 將駕駛依照駕駛風險特徵分成 2 群後的群集中心結果如下表 4.2-1 所示，其欄位顯示之數值為資料標準化之後的數值。標準化後的平均值為 0，標準差為 1，大於 0 代表高於平均，反之為低於平均。分群結果在最小車距、車距標準差、超速警示次數、向左偏移警示次數、向右偏移警示次數這 5 個駕駛風險特徵所代表的群集表現與本研究原先預期符合(例如車距標準差越大代表較高的駕駛風險)，前方碰撞警示次數在兩分群中差異並不大，因此本研究將分群 1 定義為較高風險的駕駛趟次、分群 2 為一般風險的駕駛趟次。

表 4.2-1 駕駛風險分群之群中心結果(分 2 群)

駕駛風險特徵	分群 1	分群 2
平均車距	0.14	(0.29)
最小車距	(0.54)	1.09
車距標準差	0.57	(1.14)
超速警示次數	0.05	(0.10)
向左偏移警示次數	0.00	(0.00)
向右偏移警示次數	0.02	(0.03)
前方碰撞警示次數	(0.01)	0.02
趟次數	2,823	1,417

註：括號為代表負值

表 4.2-2 是將駕駛分為 3 群的群集中心結果，其結果不如下分 2 群的群中心結果可以清楚定義出風險層級，即是沒辦法從 k-means 分 3 群的結果得知哪一群屬於高風險、一般風險和低風險分群，故以分 2 群作為較適當的分群數。後續 Model-2 和 Model-3 亦有相同情況，因此後續只呈現分 2 群的結果。

表 4.2-2 駕駛風險分群之群中心結果(分 3 群)

駕駛風險特徵	分群 1	分群 2	分群 3
平均車距	0.15	(0.29)	(0.39)
最小車距	(0.55)	1.08	(0.26)
車距標準差	0.58	(1.13)	0.18
超速警示次數	0.04	(0.10)	(0.17)
向左偏移警示次數	0.00	(0.00)	0.03
向右偏移警示次數	(0.01)	(0.03)	(0.13)
前方碰撞警示次數	(0.05)	(0.05)	0.25
趟次數	2,802	1,424	14

註：括號為代表負值

4.2.2 特徵選擇結果

本研究風險評估模型之輸入特徵共有 28 個(由車速、車距計算之駕駛行為特徵)，經過標籤後的兩種風險層級(一般、高風險)為預期輸出。如表 4.2-3，測試 6 種常見的分類演算法，並經過 10-fold stratified cross-validation 的驗證，以 Logistic Regression 平均正確率 99.27% 為最佳分類法。RFE 演算法篩選出關鍵駕駛行為特徵與特徵集合，如圖 4.2-1，在駕駛行為特徵數量為 8 個時，模型正確率為 99.53% 相比使用全部特徵(28 個)的平均正確率還要高，代表以重要性較高的 8 個關鍵駕駛行為特徵所建立的風險評估模型有良好的評估效果。根據關鍵駕駛特徵的重要性排名，圖 4.2-2 所示，車距標準差為評估駕駛風險最重要的駕駛行為特徵。其餘為車距第 1 百分位數、最小車距、車距第 5 百分位數、平均車距、車距第 75 百分位數、車距第 99 百分位數、最大車距。因此，最終模型即是使用 Logistic Regression 為分類演算法，且利用 8 個較關鍵的駕駛行為徵作為輸入物件訓練之的風險評估模型。

表 4.2-3 分類法結果比較

Classifier	Model Average Accuracy
SVC	98.04%
Decision Tree	97.48%
Ramdon Forest	98.04%
KNN	95.00%
Logistic Regression	99.27%
XGBoost	98.96%

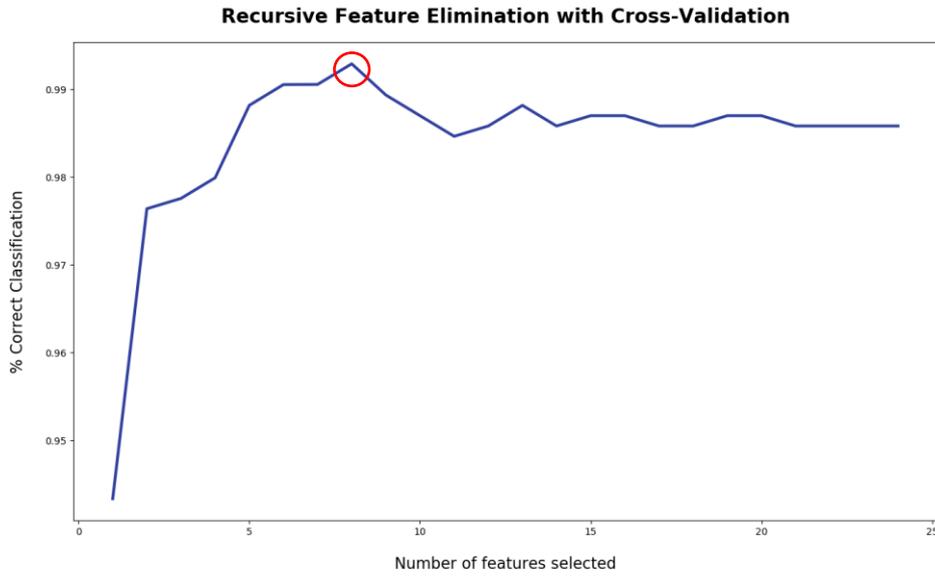


圖 4.2-1 RFE 篩選關鍵駕駛行為特徵結果

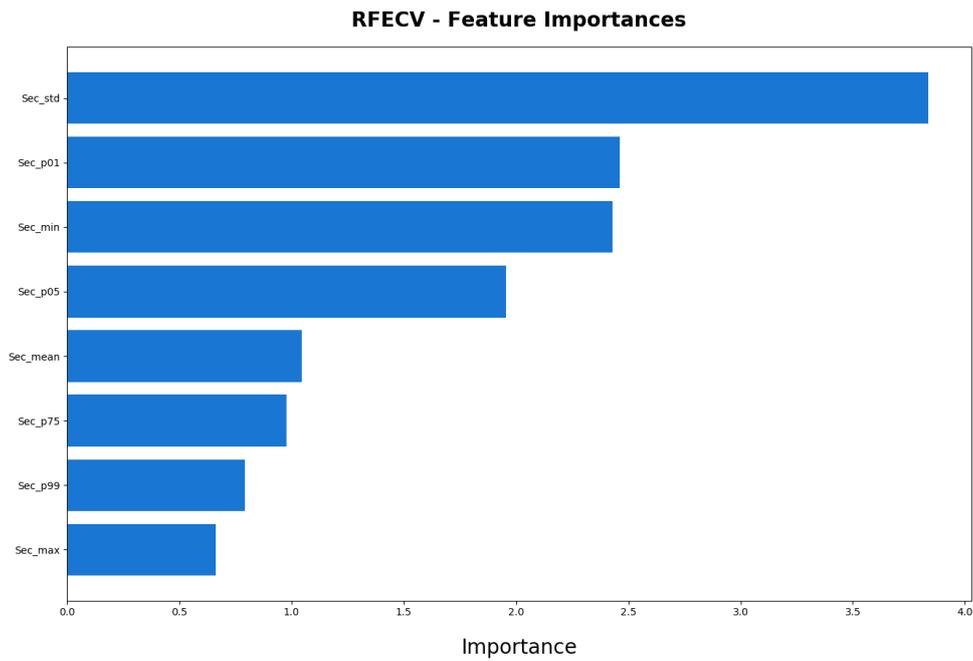


圖 4.2-2 駕駛行為特徵重要性排名

4.2.3 評估結果

根據 Model-1 最終模型所評估之結果如表 4.2-4 所示，可以為每一位駕駛員所行駛的每一個趟次的表現進行風險評估。

表 4.2-4 Model-1 駕駛風險評估結果

Trip_ID	Employee_ID	Performance
1	B1074	一般
2	B1218	一般
3	B1211	高風險
4	A1107	一般
5	B1109	高風險
6	B1109	一般
7	B1109	高風險
8	B0256	一般
9	B0296	高風險
10	B1211	一般
...

4.3 Model-2 驗證

Model-2 包含非監督式學習的標籤駕駛風險層級、以及基於機器學習的特徵選擇共 2 階段機器學習。以下為 Model-2，2 階段混合特徵機器學習模型之評估結果。

4.3.1 風險層級標籤結果

標籤駕駛風險輸入之駕駛特徵為：4 種事件警示次數(超速警示次數、向左偏移警示次數、向右偏移警示次數、前方碰撞警示次數)以及透過車速和車距之計算出的 24 種駕駛特徵，共 28 個駕駛特徵。利用 k-means 將駕駛進行風險分群後的群集中心結果如下表 4.3-1 所示。在與 Model-1 所採用之 7 個駕駛風險特徵中的最小車距、車距標準差、超速警示次數、向右偏移警示次數這 4 個駕駛特徵所代表的群集表現與研究原先預期符合，向左偏移警示次數與前方碰撞警示次數在兩分群中差異並不大，因此本研究將分群 1 定義為較高風險駕駛的趟次、分群 2 為一般風險的駕駛趟次。

表 4.3-1 駕駛風險分群之群中心結果

駕駛風險特徵	分群 1	分群 2
平均車距	0.52	(0.54)
最小車距	(0.55)	0.57
車距標準差	0.61	(0.63)
超速警示次數	0.13	(0.13)
向左偏移警示次數	(0.00)	0.00
向右偏移警示次數	0.02	(0.02)
前方碰撞警示次數	(0.02)	0.02
...
趟次數	2,158	2,082

註：括號為代表負值

4.3.2 特徵選擇結果

本研究風險評估模型之輸入特徵共有 28 個(由車速、車距計算之駕駛行為特徵)，經過標籤後的兩種風險層級(一般、高風險)為預期輸出。如表 4.3-2，測試 6 種常見的分類演算法，並經過 10-fold stratified cross-validation 的驗證，以 Logistic Regression 平均正確率 99.43% 為最佳分類法。RFE 演算法篩選出關鍵駕駛行為特徵與特徵集合，如圖 4.3-1，在駕駛行為特徵數量為 18 個時，模型正確率為 99.64%，相比使用全部特徵(28 個)的平均正確率還要高，代表以重要性較高的 18 個關鍵駕駛行為特徵所建立的風險評估模型有較好的評估效果。根據關鍵駕駛特徵的重要性排名，圖 4.3-2 所示，最大車距為評估駕駛風險最重要的駕駛行為特徵。其餘為車距第 99 百分位數、車速第 25 百分位數、最大車速、車距第 1 百分位數、車距第 50 百分位數、車速第 99 百分位數、最小車距、平均車距等。因此，最終模型即是使用 Logistic Regression 為分類演算法，且利用 18 個較關鍵的駕駛行為特徵作為輸入物件訓練之的風險評估模型。

表 4.3-2 分類法結果比較

Classifier	Model Average Accuracy
SVC	97.85%
Decision Tree	94.67%
Ramdon Forest	96.34%
KNN	96.06%
Logistic Regression	99.43%
XGBoost	97.38%

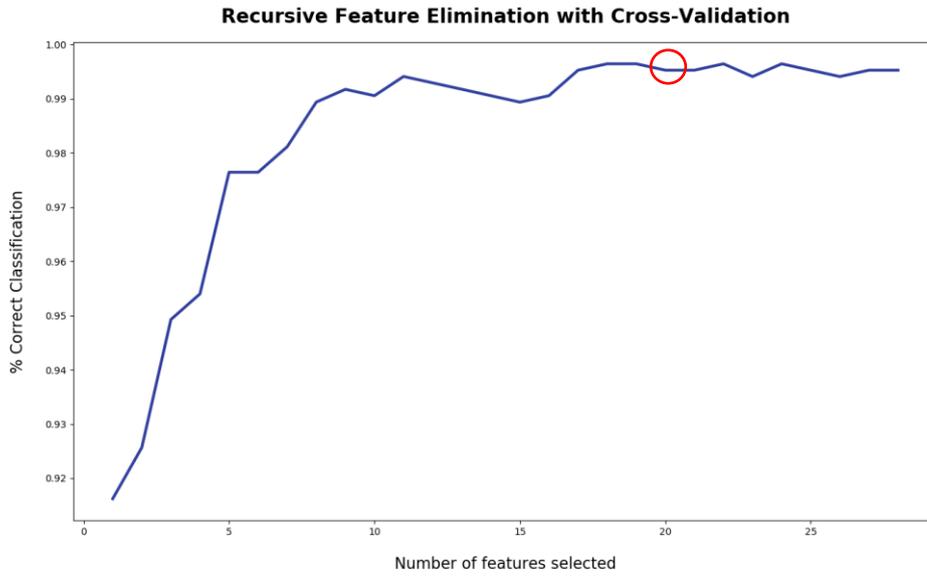


圖 4.3-1 RFE 篩選關鍵駕駛特徵結果

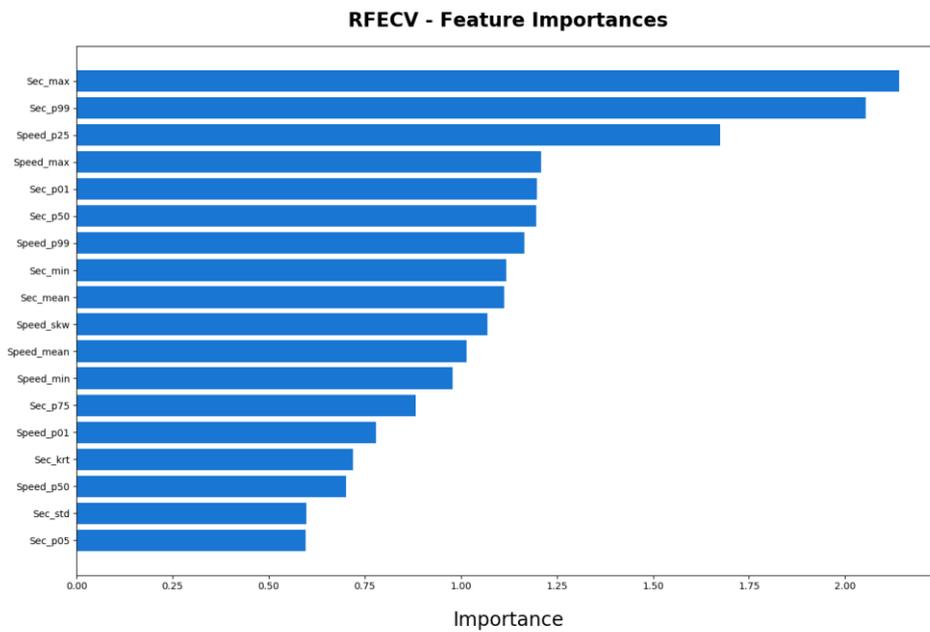


圖 4.3-2 駕駛特徵重要性排名

4.3.3 評估結果

根據 Model-2 最終模型所評估之結果如表 4.3-3 所示，可以為每一位駕駛員所行駛的每一個趟次的表現進行風險評估。

表 4.3-3 Model-2 駕駛風險評估結果

Trip_ID	Employee_ID	Performance
1	B1074	一般
2	B1218	一般
3	B1211	一般
4	A1107	一般
5	B1109	高風險
6	B1109	一般
7	B1109	一般
8	B0256	高風險
9	B0296	高風險
10	B1211	一般
...

4.4 Model-3 驗證

Model-3 包含事先篩選特徵以及非監督式學習的標籤駕駛風險層級共 1 階段機器學習來產生風險分群模型。以下為 Model-3，1 階段混合特徵機器學習模型之評估結果。

4.4.1 風險層級標籤結果

標籤駕駛風險輸入之駕駛特徵為：4 種事件警示次數(超速警示次數、向左偏移警示次數、向右偏移警示次數、前方碰撞警示次數)以及透過車速和車距之計算出的 24 種駕駛特徵，共 28 個駕駛特徵。在駕駛特徵的事先篩選流程會刪除大於兩駕駛特徵間相關係數之絕對值大於 0.8 的其中一個特徵。如下表 4.4-1 所示，Sec_p01 與 Sec_min 的相關係數為 0.97，代表兩者高度相關，因此會刪除 Sec_p01。在此流程會刪除共 13 個高度相關的駕駛特徵，因此在進行駕駛風險標籤時只會將剩下的 15 個駕駛特徵作為輸入特徵。利用 k-means 將駕駛進行風險分群後的群集中心結果如下表 4.4-2 所示。在與 Model-1 採用之 7 個駕駛風險特徵中的最小車距、超速警示次數、向右偏移警示次數這 3 個駕駛特徵所代表的群集表現與本研究原先預期符合，向左偏移警示次數與前方碰撞警示次數在兩分群中差異並不大。且因為有對於駕駛特徵進行事先篩選，能與前兩個模型比較基準相同之駕駛特徵較少，所以在觀察兩群集中心的特徵數值表現後，可以發現分群 1 相較於分群 2 有較高的最大車速和較高的平均車速表現。綜合以上特徵表現，本研究將分群 1 定義為較高風險的駕駛趟次、分群 2 為一般風險的駕駛趟次。

表 4.4-1 駕駛特徵相關係數

	Sec_mean	Sec_min	Sec_std	Speeding	Left_warn	Right_warn	FCW	...
Sec_mean	1.00	0.10	0.13	-0.05	0.03	-0.02	-0.03	...
Sec_min	0.10	1.00	-0.80	-0.06	0.05	-0.01	-0.01	...
Sec_std	0.13	-0.80	1.00	0.09	-0.01	0.03	0.00	...
Speeding	-0.05	-0.06	0.09	1.00	0.01	0.00	-0.01	...
Left_warn	0.03	0.05	-0.01	0.01	1.00	0.02	0.00	...
Right_warn	-0.02	-0.01	0.03	0.00	0.02	1.00	-0.01	...
FCW	-0.03	-0.01	0.00	-0.01	0.00	-0.01	1.00	...
Sec_max	0.73	-0.40	0.64	0.10	0.03	0.02	-0.01	...
Sec_p01	0.22	0.97	-0.80	-0.07	0.05	-0.01	-0.01	...
Sec_p05	0.47	0.86	-0.72	-0.09	0.05	-0.02	-0.02	...
...

表 4.4-2 駕駛風險分群之群中心結果

	分群 1	分群 2
平均車距	0.57	(0.54)
最小車距	(0.54)	0.52
超速警示次數	0.13	(0.13)
向左偏移警示次數	(0.01)	0.01
向右偏移警示次數	0.01	(0.01)
前方碰撞警示次數	(0.01)	0.01
最大車速	0.43	(0.41)
平均車速	0.39	(0.37)
...
趟次數	2,075	2,165

註：括號為代表負值

4.4.2 風險分群模型

Model-3 為利用機器學習分群演算法後所產生的群集中心特徵數值作為風險分群模型，來對駕駛進行風險評估。在模型評估部分，本研究假設全部數據之分群結果為標準答案(Ground-truth)，並採用 80%的數據作為風險分群模型的訓練資料。如表 4.4-3，顯示由 80%數據進行機器學習分群後產生之群集中心數值與表 4.4-2 的結果相近，代表 80%的分群結果的特徵表現與利用所有資料進行機器學習的表現一致。將剩餘 20%的資料做為測試資料，與標準答案比較後之結果顯示此風險分群模型之正確率為 99.53%。

表 4.4-3 風險分群模型

	分群 1	分群 2
平均車距	0.55	(0.54)
最小車距	(0.55)	0.52
超速警示次數	0.16	(0.13)
向左偏移警示次數	(0.01)	(0.03)
向右偏移警示次數	0.01	(0.00)
前方碰撞警示次數	(0.01)	0.02
最大車速	0.44	(0.43)
平均車速	0.40	(0.39)
...
趟次數	1,656	1,736

註：括號為代表負值

4.4.3 評估結果

根據 Model-3 所評估之結果如表 4.4-4 所示，可以為每一位駕駛員所行駛的每一個趟次的表現進行風險評估。

表 4.4-4 Model-3 駕駛風險評估結果

Trip_ID	Employee_ID	Performance
1	B1074	一般
2	B1218	一般
3	B1211	一般
4	A1107	一般
5	B1109	高風險
6	B1109	一般
7	B1109	一般
8	B0256	高風險
9	B0296	高風險
10	B1211	一般
...

4.5 評估結果分析

本小節將會對 3 種模型的結果進行分析，並就其結果來檢視將駕駛特徵區分為風險和行為，以及使用 2 階段機器學習之必要性。

4.5.1 三種模型結果比較

對於3種駕駛評估模型結果進行比較，如表4.5-1。可以發現使用混合特徵，即是不區分駕駛風險特徵與駕駛行為特徵建立的兩種模型(Model-2 和 Model-3)所評估出的駕駛風險層級是較為相近的。進一步計算57位駕駛員，共行駛79天的駕駛表現分數，其結果如表4.5-2。比較3種風險評估模型的駕駛員平均駕駛表現分數，使用混合特徵的Model-2與Model-3所評估的分數非常相近，也間接說明僅進行1階段機器學習的模型評估效果其實跟做2階段機器學習的模型並沒有太大的差別。(模型誤差如表4.5-3)

表 4.5-1 3種模型結果比較

Trip_ID	Employee_ID	Model-1_PERF	Model-2_PERF	Model-3_PERF
1	B1074	一般	一般	一般
2	B1218	一般	一般	一般
3	B1211	高風險	一般	一般
4	A1107	一般	一般	一般
5	B1109	高風險	高風險	高風險
6	B1109	一般	一般	一般
7	B1109	高風險	一般	一般
8	B0256	一般	高風險	高風險
9	B0296	高風險	高風險	高風險
10	B1211	一般	一般	一般
...

表 4.5-2 3種模型之平均駕駛分數

Employee_ID	Model-1	Model-2	Model-3
A1107	0.12	0.07	0.07
B0021	(0.55)	(0.55)	(0.52)
B0250	(0.54)	0.15	0.31
B0256	(0.31)	(0.23)	(0.23)
B0296	(0.67)	(0.64)	(0.56)
B0307	(0.33)	0.12	0.14
B0742	(0.49)	(0.51)	(0.51)
B0782	(0.50)	0.33	0.33
B0786	(0.26)	0.43	0.43
B0979	(0.26)	(0.03)	(0.03)
B1022	(0.33)	0.08	0.11
B1030	(0.39)	(0.20)	(0.20)
B1051	(0.27)	0.03	0.03

B1067	(0.12)	0.12	0.12
B1074	0.21	0.72	0.86
B1075	(0.80)	(0.80)	(0.80)
B1098	(0.88)	(0.88)	(0.88)
B1109	(0.61)	(0.22)	(0.08)
B1115	(0.60)	0.20	0.20
B1120	(0.53)	0.16	0.11
B1122	0.14	0.64	0.57
B1126	(0.75)	(0.43)	(0.43)
B1128	(0.27)	(0.06)	(0.06)
B1137	(0.32)	(0.04)	(0.06)
B1139	0.00	0.50	0.50
B1148	(0.12)	0.27	0.34
B1167	(0.36)	0.03	0.09
B1171	(0.34)	(0.19)	(0.18)
B1175	(0.03)	0.18	0.18
B1176	(0.67)	(0.34)	(0.34)
B1182	(0.86)	(0.79)	(0.79)
B1183	(0.23)	0.00	0.00
B1185	(0.56)	(0.60)	(0.60)
B1191	(0.14)	0.21	0.30
B1197	0.04	0.48	0.48
B1198	(0.75)	(0.69)	(0.75)
B1200	(0.16)	0.26	0.47
B1201	(0.33)	1.00	1.00
B1204	0.01	0.56	0.54
B1205	(0.24)	0.29	0.29
B1206	(0.30)	(0.20)	(0.20)
B1208	(0.10)	0.11	0.14
B1209	(0.42)	(0.08)	(0.05)
B1210	(1.00)	0.00	0.00
B1211	(0.26)	0.53	0.55
B1212	(0.23)	(0.04)	(0.04)
B1214	(0.43)	(0.43)	(0.43)
B1217	(0.43)	(0.06)	(0.04)
B1218	(0.28)	(0.04)	(0.04)
B1219	(0.44)	(0.03)	0.03

B1220	(0.17)	0.22	0.20
B1226	(0.33)	(0.24)	(0.24)
B1227	(0.49)	(0.29)	(0.12)
B1228	(0.22)	0.07	0.07
B1234	(0.73)	(0.47)	(0.47)
B1236	(1.00)	(0.75)	(0.75)
B1237	(1.00)	(1.00)	(1.00)

註：括號為代表負值

表 4.5-3 3 種模型結果之誤差

MAE (Mean Absolute Error)	
Model-1 & 2	0.33
Model-2 & 3	0.03
Model-1 & 3	0.35

若將駕駛分數由高至低排名，可以檢視所有駕駛員在 H 公司的相對表現排名，3 種模型的駕駛排名如表 4.5-4。約有 36.84% 的駕駛員在 3 種模型排名誤差不超過 5 名(紅色標籤)，如同駕駛員平均分數呈現之結果，Model-2 與 Model-3 在整體平均排名之誤差為 1.21 名，再次證明若是以類似的特徵作為機器學習的輸入物件，只進行 1 階段非監督式學習進行風險分群的結果會與 2 階段機器學習(先分群，再建立風險分類模型)相似，代表僅執行 1 階段機器學習模型也具有一定的評估能力。

表 4.5-4 3 種模型之駕駛排名

Employee_ID	RANK		
	Model-1	Model-2	Model-3
A1107	3	24	25
B0021	43	49	49
B0250	42	18	12
B0256	25	41	42
B0296	47	51	50
B0307	28	19	19
B0742	38	48	48
B0782	40	9	11
B0786	18	8	9
B0979	19	30	30
B1022	27	22	21

B1030	33	38	40
B1051	21	25	26
B1067	9	20	20
B1074	1	2	2
B1075	52	55	55
B1098	54	56	56
B1109	46	40	37
B1115	45	15	15
B1120	41	17	22
B1122	2	3	3
B1126	50	45	45
B1128	21	34	35
B1137	26	33	35
B1139	6	6	6
B1148	10	11	10
B1167	32	26	23
B1171	31	37	39
B1175	7	16	17
B1176	48	44	44
B1182	53	54	54
B1183	15	27	28
B1185	44	50	51
B1191	11	14	13
B1197	4	7	7
B1198	50	52	52
B1200	12	12	8
B1201	28	1	1
B1204	5	4	5
B1205	17	10	14
B1206	24	38	40
B1208	8	21	18
B1209	34	36	34
B1210	55	27	28
B1211	20	5	4
B1212	16	32	32
B1214	35	46	46
B1217	36	34	33

B1218	23	31	31
B1219	37	29	27
B1220	13	13	16
B1226	28	42	43
B1227	39	43	38
B1228	14	23	24
B1234	49	47	47
B1236	55	53	52
B1237	55	57	57

4.5.2 小結

由於三種模型的駕駛風險評估結果並非專家針對每位駕駛所做出的風險評估結果，即是這三種結果的欠缺標準答案來驗證模型的正確性。如同再前面第三章 3.5 風險模型之評定所述，由於缺乏標準答案，僅能依照模型的正確率來選出最適的風險評估模型，即為 Model-3(正確率 99.53%)且考量到 Model-3 僅使用 1 階段機器學習就有 2 階段學習之評估能力，省略了第 2 次機器學習中透過分類法建立分類模型的步驟。

第五章 結論與建議

本研究之目的為利用大客車所配戴 ADAS 系統所收集之駕駛行為資料來評估客運駕駛的風險，運用國內客運業者提供之車機資料，針對行駛國道駕駛員的駕駛行為表現以機器學習演算法來建立駕駛風險評估模型。研究以駕駛員與前車保持之距離、行駛速度、警示事件為判斷是否為高風險駕駛行為之變數，分析 57 位駕駛員行駛之 4,240 個駕駛趟次進行風險評估。根據前述各章節的分析與探討，本章節整理出以下結論和建議：

5.1 結論

- (1) 將駕駛特徵區別為風險、行為兩類型建立之機器學習模型正確率與使用混合特徵建立之模型沒有顯著差異(Model-1: 99.27%、Model-2: 99.43%)。在選擇機器學的輸入特徵時可以將會影響駕駛風險的所有駕駛特徵作為輸入特徵來建立評估模型。
- (2) 以駕駛特徵進行風險分群的群集中心結果，可作為風險分群模型，其評估結果與 2 階段機器學習訓練之模型沒有顯著差異(Model-2: 99.43%、Model-3: 99.53%)。後續研究採用之資料若是沒有風險標籤，可以從資料提取出駕駛特徵後以非監督式學習分群法將駕駛進行風險分群，將群集中心作為風險評估之依據，亦能達到有效可靠的評估結果。
- (3) 綜合上述(1)、(2)和第四章之結果顯示，本研究 3 種模型中以 Model-3 的正確率 99.53% 最高，且 Model-3 僅進行 1 階段機器學習，模型之效率較另外兩者高且保有相似的評估效果。故只使用分群法的 Model-3 為本研究最佳之風險評估模型。
- (4) 以機器學習方法建立的風險評估模型之結果與客運公司在實務上評估駕駛風險的結果可能有所差異，機器學習模型預測準確率雖然很高，但有可能只是訓練資料的過渡擬合，有球員皆裁判之疑慮。以另外一個角度來說，客運公司若只是以某些特定駕駛特徵作為風險評估之依據，可能無法捕捉真實的駕駛行為導致風險評估失真。
- (5) 經過基於機器學習的特徵篩選找出的關鍵駕駛特徵，可作為評估駕駛風險的主要指標。由 ADAS 系統偵測並產出的風險指標(如車輛偏移、前方碰撞警示)經過機器學習模型分析後，若不是關鍵駕駛特徵，則代表該風險指標無法對駕駛風險進行有效的分類或分群，因此可能必須對風險指標的設計或是含有的變數門檻值進行修正調整。

5.2 建議

- (1) 本研究建立之風險評估模型並未考慮駕駛員行駛的時間與駕駛當下的交通狀況。在駕駛員部分，後續研究可以分析行駛紅眼班次比例、休息時間與疲勞程度對駕駛風險的影響；交通狀況對駕駛風險的影響則嘗試結合車機資料與交通量資料(如車輛偵測器、eTag 等)設計出有條件的駕駛特徵來增進模型的評估能力。
- (2) 針對評估駕駛風險的駕駛特徵，可深入分析該駕駛特徵與其對應的駕駛風險間存在的機制與因果關係，嘗試給予駕駛特徵不同的權重，以增加風險評估模型的解釋能力。
- (3) 以分群法建立風險分群模型所標籤的風險層級與真正會發生車禍的機率難以連結，後續研究可蒐集有發生車禍且涉入之車輛配有 ADAS 系統或車載設備能記錄車禍前的駕駛行為。將真實有發生車禍的駕駛定義為高風險駕駛，其機器學習模型評估的駕駛風險結果與實際上會發生車禍的機率能有更好的因果連結。
- (4) 關於駕駛特徵的產出，除了從車機所記錄的變數中透過運算得來(如百分位數、平均、標準差等)，可嘗試將車機資料與其他外部資料進行連結，設計出能夠使風險評估更加可靠的駕駛特徵。
- (5) 本研究旨在分析車機記錄的駕駛行為對於駕駛風險的影響而建立風險評估模型，故假設外部因子對駕駛員所造成的影響是固定的。然而實際之駕駛行為是有可能會受到外在因子影響，例如環境因子：日照、下雨等因素會使得駕駛在面對不同情況下的任務難度而造成不同的駕駛行為；且駕駛員的個人屬性也可能會造成駕駛行為上的差異(例如年齡、性別等)。後續研究可以先確認外在因子是否顯著影響駕駛行為，若能確定外在因子對駕駛行為之影響，則可先將資料劃分，再進行風險評估模型之建立。

參考文獻

- [1] 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.
- [2] Cheng, Z., Wang, W., Lu, J., & Xing, X. (2018). Classifying the traffic state of urban expressways: A machine-learning approach. *Transportation Research Part A: Policy and Practice*.
- [3] 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.
- [4] Lourens, P. F., Vissers, J. A., & Jessurun, M. (1999). Annual mileage, driving violations, and accident involvement in relation to drivers' sex, age, and level of education. *Accident Analysis & Prevention*, 31(5), 593-597.
- [5] Ma, Y., Tang, K., Chen, S., Khattak, A. J., & Pan, Y. (2020). On-line aggressive driving identification based on in-vehicle kinematic parameters under naturalistic driving conditions. *Transportation Research Part C: Emerging Technologies*, 114, 554-571.
- [6] Osman, O. A., Hajji, M., Karbalaieali, S., & Ishak, S. (2019). A hierarchical machine learning classification approach for secondary task identification from observed driving behavior data. *Accident Analysis & Prevention*, 123, 274-281.
- [7] Polson, N. G., & Sokolov, V. O. (2017). Deep learning for short-term traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 79, 1-17.
- [8] 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.
- [9] Shen, Z., Wang, W., Shen, Q., Zhu, S., Fardoun, H. M., & Lou, J. (2019). A novel learning method for multi-intersections aware traffic flow forecasting. *Neurocomputing*.
- [10] Shi, X., Wong, Y. D., Li, M. Z. F., Palanisamy, C., & Chai, C. (2019). A feature learning approach based on XGBoost for driving assessment and risk prediction. *Accident Analysis*

& *Prevention*, 129, 170-179.

- [11] Tselentis, D. I., Vlahogianni, E. I., & Yannis, G. (2019). Driving safety efficiency benchmarking using smartphone data. *Transportation research part C: emerging technologies*, 109, 343-357.
- [12] Vlahogianni, E. I., & Barmponakis, E. N. (2017). Driving analytics using smartphones: Algorithms, comparisons and challenges. *Transportation Research Part C: Emerging Technologies*, 79, 196-206.
- [13] Wang, L., & Pei, Y. (2014). The impact of continuous driving time and rest time on commercial drivers' driving performance and recovery. *Journal of safety research*, 50, 11-15.
- [14] Yi, D., Su, J., Liu, C., Quddus, M., & Chen, W. H. (2019). A machine learning based personalized system for driving state recognition. *Transportation Research Part C: Emerging Technologies*, 105, 241-261.
- [15] 林彥志. (2009). 使用公路客運行車紀錄器資料探討營業大客車駕駛人行為適性之研究. 逢甲大學交通工程與管理所論文.
- [16] 李佩憶. (2017). 人格特質對於駕駛行為特性影響與駕駛風險分級制度之研究—以國道客運駕駛員為例. 成功大學交通管理科學系學位論文, 1-111.
- [17] 施朝欽. (2019). 考慮行車動態下之駕駛人安全駕駛行為分數 - 以國道客運為例. 國立交通大學運輸與物流管理學系論文.
- [18] 交通部運輸研究所(2012), 城際客運安全駕駛行為與節能策略之研究。
- [19] 交通部統計月報(民 107)
- [20] 交通部統計處(民 105), 「104 年民眾日常使用運具狀況調查 - 摘要分析」
- [21] 警政統計通報(民 108 年第 11 週)