

# 以 ADAS 警示為基礎之國道大客車高風險 駕駛行為辨識與預測<sup>1</sup>

## IDENTIFYING AND PREDICTING RISKY DRIVING BEHAVIORS IN HIGHWAY BUS DRIVERS BASED ON ADAS WARNINGS

鍾易詩 Yi-Shih Chung<sup>2</sup>  
呂昫謙 Yun-Chen Lu<sup>3</sup>  
劉曜峯 Yao-Feng Liu<sup>4</sup>  
余嘉萱 Chia-Hsuan Yu<sup>5</sup>  
黃士軒 Shih-Hsuan Huang<sup>6</sup>  
葉祖宏 Tsu-Hung Yeh<sup>7</sup>

(113 年 2 月 1 日收稿，113 年 5 月 25 日第一次修正，113 年 7 月 12 日第二次修正，  
113 年 7 月 15 日接受)

### 摘 要

先進駕駛輔助系統 (Advanced Driver Assistance System, ADAS) 已是大客車必備的車輛設備，然而 ADAS 警示並非完全準確，頻繁假警示可能會導致駕駛習慣性忽略警示，反而增加行車危險。為解決此問題，本研究發展一套以 ADAS 警示為基礎之高風險駕駛行為辨識流程，首先定義及標示行車異常事件作為 ADAS 警示之真值，接著利用二元羅吉特迴歸 (binary

- 
1. 本研究為交通部運輸研究所委託國立陽明交通大學運輸研究中心研究計畫「應用人工智慧分析技術探勘高風險路段 (3/4)-車內異常事件影像辨識技術開發」之部分研究成果，特此感謝。
  2. 國立陽明交通大學運輸與物流管理學系教授 (聯絡地址：臺北市中正區忠孝西路一段 118 號 4 樓，電話：02-23494963，Email: yschung@nycu.edu.tw)。
  3. 國立陽明交通大學運輸與物流管理學系博士班研究生。
  4. 國立陽明交通大學運輸與物流管理學系博士班研究生。
  5. 桃園市政府交通局技士，時任國立陽明交通大學管理學院運輸研究中心專任研究助理。
  6. 中央警察大學交通學系暨交通管理研究所助理教授，時任交通部運輸研究所副研究員。
  7. 交通部運輸研究所主任秘書。

logit regression) 篩選與事件異常程度顯著相關變數，並以增幅式迴歸樹 (boosted regression tree) 辨識連續變數與異常事件的非線性關係，據以制定連續變數門檻，最後計算各變數組合下之車內外情境對應之事件異常化機率，以評估並找出高風險駕駛情境。本研究以國道客運 576 個縱向警示 (例如高速前車碰撞) 及 425 個橫向偏移警示之資料驗證所提方法之可行性，分析結果發現車內分心行為 (例如拿東西、用手機等) 為橫向偏移高風險駕駛行為的關鍵特徵；辨識為低風險之動作組合縱橫向陽性率分別為 29.2% 及 6.9%，中高風險則上升至 81.8% 及 47.7%，偽陽性大幅下降。整體而言，本研究所提之辨識流程對高風險駕駛行為具一定程度預測力，辨識結果可用以調整 ADAS 系統警示門檻，提高 ADAS 警示準確度。

**關鍵詞：** 先進駕駛輔助系統、高風險駕駛行為、國道客運、職業駕駛、序列探勘

## ABSTRACT

*Advanced Driver Assistance System (ADAS) is an essential vehicle equipment. An ADAS provides a real-time warning for drivers to pay attention to their own and surrounding vehicles. However, ADAS has been known for its false alarm issue, which, when the false alarm rate is high, would lead drivers to ignorance of ADAS warnings and thus raise the danger of driving. To resolve this issue, the study develops an ADAS-based risky driving behavior identification process; the identification results could be used to adjust the warning thresholds of ADAS alarms and enhance the accuracy of ADAS. The study first defines and labels dangerous events as the true values for ADAS warnings, followed by a binary logit analysis for selecting significant variables and a boosted regression tree analysis for examining possible nonlinear relationships between continuous explanatory variables with the onset of dangerous events. Accordingly, the continuous variables were discretized. The study applied the proposed framework to empirical data, which consisted of 576 longitudinal warnings and 425 lateral warnings. The results showed that the identified low-risk scenarios had a true alarm rate of 29.2% and 6.9%, respectively, for the longitudinal and lateral warnings, while the true alarm rate in the high-risk scenarios was 81.8% and 47.7%, respectively; the result validated the effectiveness of the proposed procedure. Overall, the proposed approach has a certain accuracy in predicting risky driving behaviors.*

**Key Words:** ADAS ; risky driving behavior ; highway passenger bus ; occupational driver ; sequential data mining

## 一、緒 論

先進駕駛輔助系統 (Advanced Driver Assistance System, ADAS) 是大客車重要的車輛

設備，其提供之即時警示可提醒駕駛人注意周遭車流或自身車況。例如日本、美國、澳洲在 2021、2022 年分別以法規逐步要求車廠將自動緊急煞車導入 ADAS，中國大陸在 2020 年即將前車碰撞示警入法導入 ADAS，歐洲則在 2020 至 2022 年間分別將自動緊急煞車、車道偏移、智慧速度輔助、酒精偵測/車輛上鎖、疲勞注意力偵測、駕駛人分心警示、事故資料紀錄器、緊急煞車燈號、倒車偵測等 ADAS 功能導入智慧車與電動車。國內則分別在 2014、2017、2019 年，針對特定車種新車，強制要求裝設胎壓偵測輔助系統、行車視野輔助系統以及車道偏離與緊急剎車輔助系統(車輛型式安全審驗管理辦法)<sup>[1]</sup>。另外，交通部運輸研究所<sup>[2]</sup>訪談國內 18 家客運業者發現，受訪客運業者普遍都裝設有 GPS 系統與數位影像紀錄器，少數業者有裝設 ADAS 與 OBD2 (或 CAN bus)。交通部運輸研究所<sup>[3]</sup>則調查國內 25 家客運業者使用車載設備資訊系統的情況，其調查結果發現有超過 90% 業者安裝數位行車紀錄器、車載數位錄影系統、行車視野輔助，ADAS 系統的裝設則集中於國道客運，尤其是車道偏離及前方碰撞警示。由此可知，利用 ADAS 提升駕駛安全已是目前的趨勢。

然而目前業者使用 ADAS 的方式，多半為直接使用 ADAS 即時警示作為提醒駕駛人行車安全的工具以及用於車輛狀態的監控，或部分可以記錄或影像儲存的設備業者除了安全之外主要也會用來作為處理客訴之依據，尚未有業者能積極使用 ADAS 系統資料進行主動的駕駛行車風險管理，其根本原因之一為 ADAS 警示並非完全準確。交通部運輸研究所<sup>[4]</sup>檢測國內某國道客運業者近 1 萬 8 千筆資料，發現當其 ADAS 系統偵測前方無車時，約有 8.6% 其實前方有車；當其 ADAS 系統偵測前方 40 公尺內有車時，其有 46.7% 之前方車輛距本車超過 40 公尺遠。其研究進一步發現，該 ADAS 偵測不準的狀況常出現在他車或本車變換車道時。若 ADAS 常出現假警示 (false alarm) 狀況，駕駛可能會習慣性忽略警示，反而增加行車危險 (Ayoub 等人<sup>[5]</sup>)。導致業者雖有裝設 ADAS，但多以超速、與前車未保持安全距離、不當變換車道、急加減速次數、交通違規次數、乘客投訴件數等指標作為駕駛行為的安全管理。如何善用 ADAS 作為駕駛安全管理工具，仍是待研究的課題。

ADAS 藉由感測設備偵測本車與周遭車輛動態，當觸發預設門檻，即給予對應之警示。然由過去研究可知道，本車與周遭車流並非高風險駕駛行為的唯一決定因素，其他如駕駛分心行為、道路環境等，皆是影響駕駛行為風險的重要因素。若能將 ADAS 系統蒐集之豐富資訊另結合其他資料，預期將更能有效判斷高風險駕駛行為。

早期高風險駕駛行為或偏差駕駛行為 (aberrant driving behavior) 多是以駕駛自我填答問卷資料為基礎，歸納數種駕駛行為樣態；例如 Reason 等人<sup>[6]</sup>將偏差駕駛行為區分為錯誤 (error) 及違規 (violation)，接續則有大量研究依 Reason 等人<sup>[6]</sup>的理論架構，發展各種不同的量表。

近年在 GPS 及 ADAS 逐漸普及後，有愈來愈多的研究以自然駕駛 (naturalistic driving) 的方式蒐集行車資料並定義高風險駕駛行為。舉例而言，Yu 等人<sup>[7]</sup>在其研究以 0.3 g 作為急減速的門檻值，將其視為應變數，並以隨機森林 (random forest) 探討道路線型、交通環境、速限、分心駕駛等因素對急減速之影響。其研究結果顯示使用隨機森林之測試資料

集可以達到 83.2% 的整體準確度。而以變數重要性而言，分心駕駛及超速為最重要之變數。另外，Glaser 等人<sup>[8]</sup>以急減速、橫向加速度、高偏移率及方向盤轉向角度篩選作為衝突事件，其發現在 119 個事故衝突中，有 74 起事件急減速高於 0.4 g。此外，Glaser 等人<sup>[8]</sup>亦進一步分析上述之衝突事件與道路環境之關係，並發現不同急減速門檻與不同的道路環境有顯著之相關性。Feng 等人<sup>[9]</sup>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)，而其研究結果指出若駕駛每 100 英里超過 12.7 次較大的負衝度，則該駕駛會被分類至高事故風險的群組。Bagdadi<sup>[10]</sup>在其自然駕駛研究中，使用衝度作為參數，並將其門檻值設為 1.0g/s，而其識別碰撞事件的成功率高達 86%。最後，Bagdadi 與 Várhelyi<sup>[11]</sup>探討衝度駕駛與事故傾向間的關係，其使用 -9.9 m/s<sup>3</sup> 之衝度值，作為事故衝突的門檻值，並發現衝度對於女性駕駛的安全駕駛行為，是較好的指標。

綜合言之，近年已有不少研究利用車機或 ADAS 設備資料作為分析高風險駕駛行為的基礎，然多數研究定義之高風險駕駛行為多植基於主觀的門檻定義。少部分連結高風險駕駛行為與事故頻次決定的研究，則顯示以行車資料定義高風險駕駛的可能性；然道路事故具稀少性，以道路事故作為定義高風險之標的，需要相當之樣本數。而速度或其他本車動態變數，亦不足以完整定義高風險駕駛行為。

依據前述之研究缺口，本研究發展一套以 ADAS 警示為基礎之高風險駕駛行為辨識流程，所建議之流程以偵測設備可得資料定義異常事件，避免以道路事故作為定義高風險駕駛依據之樣本數問題，其辨識流程主要目的在進行 ADAS 與駕駛資料的離線分析，以了解 ADAS 警示與異常事件的關係，提供辨識出之高風險駕駛行為給業者作駕駛管理與教育訓練之參考。另外，本研究所建議之高風險駕駛定義範疇，除本車動態外，尚包括駕駛分心動作、與周遭車流互動關係、道路環境與天候狀況等變數，相較過去研究，本研究定義之高風險駕駛行為更為完整；所使用之資料來源皆為目前 ADAS 系統可得資料，亦具一定可行性。本研究以國道客運業者實際資料驗證所提辨識流程，分析結果顯示所辨識出之高風險駕駛行為的確可大幅降低 ADAS 偽陽性警示問題。文中亦討論實證資料中，縱橫向高風險駕駛行為之差異、不同資料完整度對辨識高風險駕駛行為之差異，以及本流程如何應用至駕駛安全管理。

## 二、高風險駕駛行為之定義與考量範疇

高風險駕駛行為或偏差駕駛行為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 等人<sup>[6]</sup>)，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)。

早期研究多透過問卷以及自我報告的方式，歸納偏差駕駛行為的樣態。例如 Lawton 等人<sup>[12]</sup>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 等人<sup>[13]</sup>以前述三種分類為基礎，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。Dula 與 Ballard<sup>[14]</sup> 則透過文獻回顧，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，作者認為其成因為漠視他人 (Disregard of others) 或具有敵意 (Hostility)。Han 與 Zhao<sup>[15]</sup> 透過修訂後的駕駛行為問卷 (Driver 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。

值得注意的是，分心通常被視為提高道路交通事故發生風險的主因之一。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。D'Souza 與 Maheshwari<sup>[16]</sup> 在其研究中使用多項羅吉特 (Multinomial Logit, MNL) 模式評估解釋變數與分心程度間的關係。其研究結果指出較為年長的駕駛較容易出現「些微分心」的情況，而「分心」則呈現相反之結果。另外，模式的估計結果顯示駕駛經驗與「分心」程度呈正相關。Stutts 等人<sup>[17]</sup> 則在其研究中提到，駕駛者於駕駛過程中食用食物與飲料是常見的駕駛行為，並且可能是分心的主要來源。不論是何種車輛的駕駛，都常常出現此行為，縱使其影響程度較使用手機低，但在行車過程中仍是存在風險的行為。此外，Irwin 等人<sup>[18]</sup> 以查看或寄送簡訊、飲食在自然駕駛場景中對駕駛之影響進行模擬實驗，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，無意的車道偏離比例顯著增加。更甚者，Wang 等人<sup>[19]</sup> 認為分心容易對駕駛過程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。在 2014 至 2018 年澳洲阿德萊德的事務資料中，發現駕駛人的分心與注意力不集中 (inattention) 之行為與死亡或重傷事故呈現顯著之相關性 (Wundersitz<sup>[20]</sup>; Edwards 與 Wundersitz<sup>[21]</sup>)。

在偏差駕駛行為的基礎上，了解造成此駕駛行為之原因或情境對於交通安全而言有其政策與管理上的重要意涵。魏健宏等人<sup>[22]</sup> 透過行車紀錄器發現可能造成事故風險之偏差駕駛行為，其利用問卷調查訪問 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。該研究將偏差駕駛行為區分為：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，並使用極值正規化 (min-max normalization) 獲得每位駕駛人的個別偏差行為之風險值。該研究使用順序性羅吉特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。Chen 等人<sup>[23]</sup> 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，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。Wang 等人<sup>[19]</sup>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（例如塞車、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（包括闖紅燈、超速、疲勞、分心及強制變換車道）的關聯性。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。Useche 等人<sup>[24]</sup>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，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。

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 與 Maheshwari<sup>[16]</sup>；Hickman 與 Hanowski<sup>[25]</sup>；Salmon 等人<sup>[26]</sup>；Wang 等人<sup>[19]</sup>)。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，Xian 等人<sup>[27]</sup>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。另外，許多既有文獻也證實急加速或急減速之駕駛行為，與交通事故或交通衝突存在顯著之關係 (Bagdadi<sup>[10]</sup>；Glaser 等人<sup>[8]</sup>)。故本研究選擇將急加減速視為高風險駕駛行為，探討其與異常事件之關係。更甚者，學者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異常事件之關係。魏健宏等人<sup>[22]</sup>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，雖本研究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極高風險。

透過上述文獻可發現，高風險駕駛行為的組成及影響因素包括駕駛的個人特質、車輛操作行為以及外在道路環境。過去道路交通事故多以事故鏈 (accident chain) 的角度分析事故發生的原因，亦即事故的發生是由一連串原因同時出現引起，因此推論事故發生原因時，不能僅看近因，而須完整解構事故發生的過程。例如美國 SHRP2 NDS (自然人駕駛) 計畫將事件由發生的時間軸由最上游至最下游依序分為事件前 (pre-incident)、突發事件 (precipitating event)、駕駛感知 (perception)、閃避 (evasive)、事後 (post) 及事故發生與否六個階段。另外，過去研究多以問卷自我填答歸納出高風險駕駛行為，或以車機資料透過主觀定義之門檻值分析異常駕駛行為 (例如急加減速)，高風險駕駛行為的定義過程較為主觀 (Ghasemzadeh 與 Ahmed<sup>[28]</sup>；Khan 等人<sup>[29]</sup>)。

根據以上討論，本研究希望以事故鏈的概念為基礎，發展一個相對客觀且能包含車

輛、道路環境以及駕駛行為等因素的高風險駕駛行為辨識流程，以提供業者安全監督管理之用。

### 三、研究方法

#### 3.1 研究架構

本研究之基本概念如圖 1 所示。依據事故鏈 (Reason<sup>[30]</sup>) 以及事故前兆 (surrogate) 的概念，本研究假設異常事件為事故發生之前兆，而 ADAS 警示事件又為異常事件之前兆。其中異常事件定義為文獻常見之事故前兆 (crash surrogate)，即為事故關聯性高的特定型態安全相關事件之子集合。本研究以國道客運駕駛行為為分析對象，事件之異常程度依據事件發生當下之情境是否危險、與周遭車輛之相對距離、駕駛人之因應動作等三個準則判定 (交通部運輸研究所<sup>[2][31]</sup>)。

本研究以 ADAS 警示為基礎進行分析，因此假設 ADAS 警示事件為異常事件發生之前兆，另假設高風險駕駛行為為此 ADAS 警示事件異常化的主要原因；當駕駛應對 ADAS 警示得宜，此警示不會轉化為異常事件，但若駕駛忽略警示或應對不當，則此警示有可能轉化為異常事件 (如圖 1 所示)。考量影響事故發生的原因眾多，本研究假設 ADAS 警示事件、高風險駕駛行為與異常事件彼此之間為不確定性關係，以計量模式分析觀察到之駕駛行為與異常事件關係，以機率分布捕捉因資料不完整或純粹隨機誤差之不確定性。

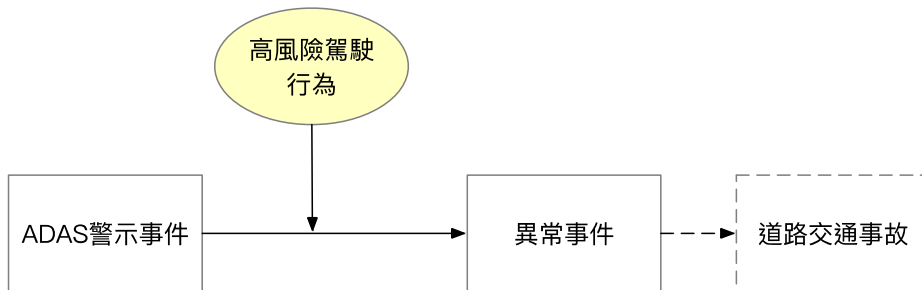
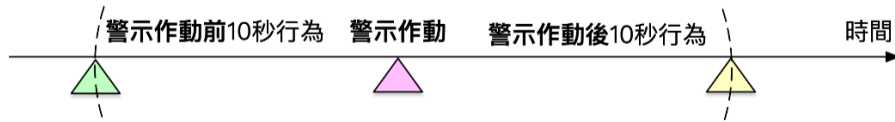
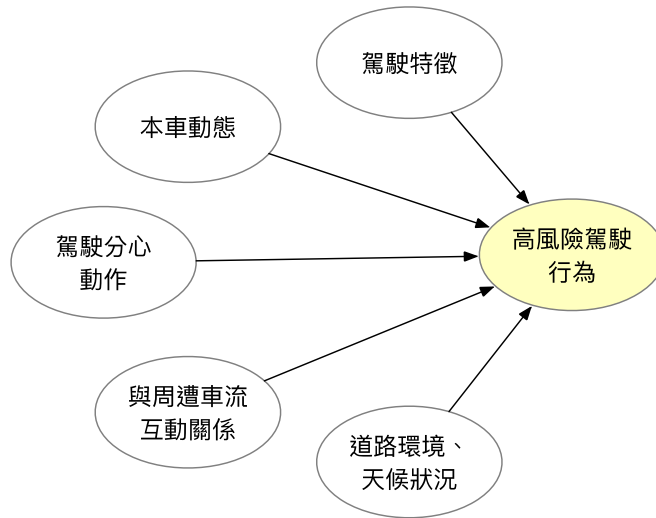


圖 1 高風險駕駛情境研究架構

駕駛行為在本研究定義為 ADAS 警示作動前及後 10 秒之行為，此行為包括車內的肢體動作以及車輛駕駛行為。另由文獻回顧結果得知，本車與周遭車流的關係 (例如跟車行為)、道路環境以及天候狀況、駕駛特徵 (例如駕駛經驗) 等因素皆有可能影響事故的發生。綜合以上因素，本研究以駕駛特徵、本車動態、駕駛分心動作、本車與周遭車流互動關係、道路環境以及天候狀況描述高風險駕駛行為 (如圖 2)。易言之，本研究之高風險駕駛行為為 ADAS 警示前後，會顯著提升警示事件異常化之駕駛特徵、本車動態、駕駛分心動作、本車與周遭車流互動關係、道路環境以及天候狀況之組合。



(a) 時間範圍



(b) 高風險駕駛行為組成

圖 2 高風險駕駛行為定義

### 3.2 變數定義與資料來源

為完整描述前述定義之高風險駕駛行為並定義異常事件，本研究蒐集國道客運業者實際營運資料，並與國道幾何資料及天候資料串連。資料來源為單一業者，僅擷取國道上資料，包含主線及匝道，不使用平面段資料。業者資料採用 2023 年 5 月之部分營運趟次資料，其資料源包括車輛車機、全球定位系統 (global positioning system, GPS)、車上攝影設備錄製之影像、ADAS 警示類別與時空間位置、駕駛基本資料，所蒐集之趟次資料中駕駛人數為 38 人，其年齡與年資分布如圖 3、圖 4 所示；其中車上攝影設備錄製影像包括一顆車輛對外部環境正前方鏡頭，以及兩側照後鏡角度兩顆鏡頭。系統設備與各設備之間串連關係，可參考交通部運輸研究所<sup>[31]</sup>之說明。

由於高風險駕駛行為由許多因素組成，但並非所有國道業者在實務管理上皆能蒐集完整資料，因此本研究將高風險駕駛行為資料源依國道業者目前擁有之設備普及度 (交通部運輸研究所<sup>[31]</sup>) 分為四個層級：第 I 層級為業者本身具備之駕駛人個人特徵資料以及法規規定客運業者必須裝設之車機與 GPS 設備資料；第 II 層級為市售之 ADAS 資料，此資料多為基於對外感測設備之警示；第 III 層級為駕駛管理系統 (driver management system,

DMS)，此資料主要提供駕駛在車內的狀態，通常用以辨識駕駛之疲勞或分心行為；第 IV 層級為外部資料，例如道路幾何或天候資料。在前述資料中，第 III 層級資料亦可稱作 ADAS 資料的一部分，但綜觀國內國道客運之 ADAS 系統，幾無業者使用 DMS 系統，因此本研究將 DMS 資料另區分為第 III 層級；換句話說，就國內狀況而言，第 III 層級資料是業者取得成本相對高之資料。本研究所使用四個層級資料與變數整理如表 1 所示。

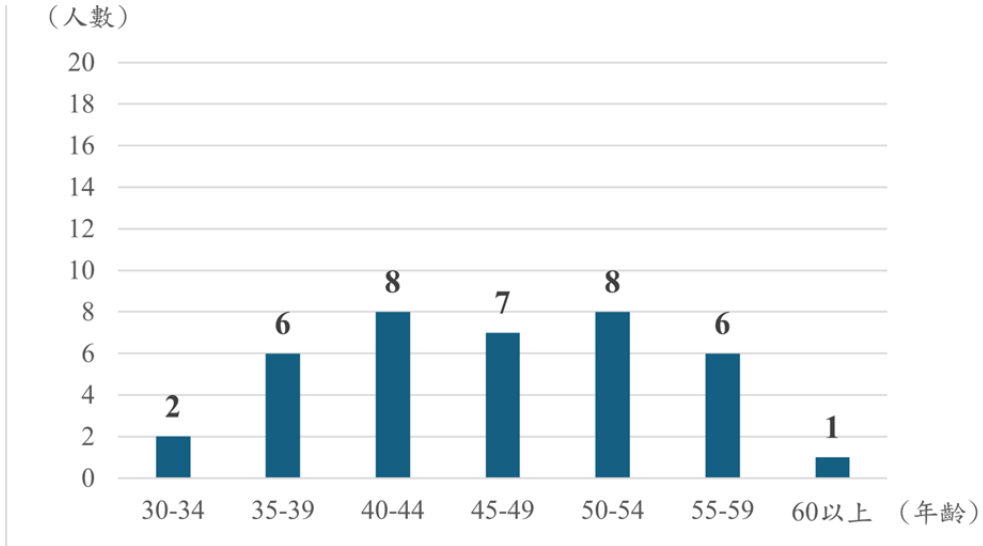


圖 3 駕駛年齡分布

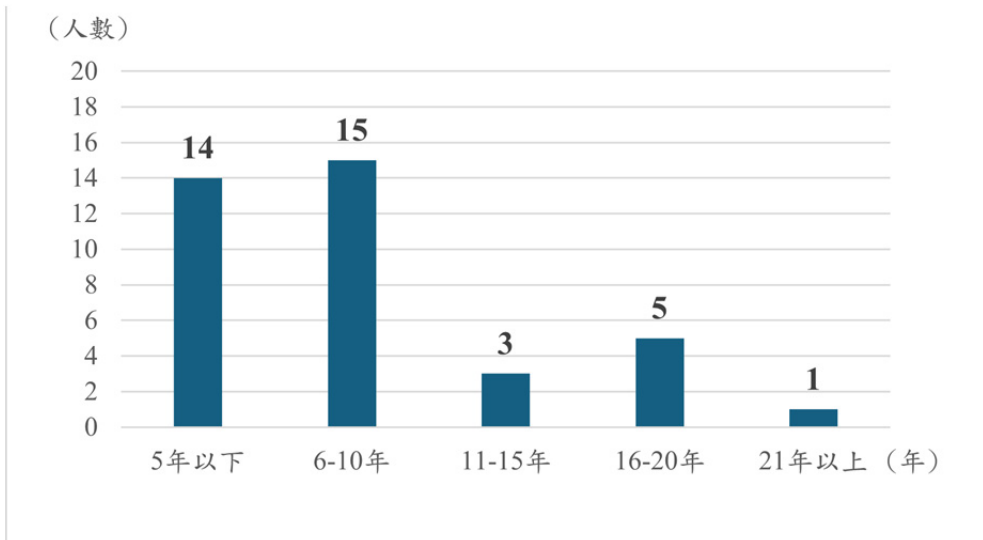


圖 4 駕駛年資分布

表 1 變數定義、資料來源與層級

資料層級	變數	時間範圍	單位
I (車機與 GPS)	左方向燈是否開啟		0/1
	右方向燈是否開啟		0/1
	平均車速	前 3 秒/前後 3 秒/後 3 秒	km/hr
	平均加速度絕對值	前 3 秒/前後 3 秒/後 3 秒	g
	最大加速度絕對值	前 3 秒/前後 3 秒/後 3 秒	g
	是否超速		0/1
	國道里程		km
	是否為夜晚		0/1
	駕駛員公司年資		年
II (ADAS)	與前車車距之累積時間	門檻：0.3~1 秒	秒
	追撞風險指數	-	-
	與前車之時距與時間積分	門檻：0.3~1 秒	秒 <sup>2</sup>
	與前車最小車距	前 3 秒/前後 3 秒/後 3 秒	m
	與前車車距範圍	前 3 秒/前後 3 秒/後 3 秒	m
	前車最小車距 40 公尺	前 3 秒	0/1
III (DMS)	分心	警示當下	0/1
	擺頭	警示當下	0/1
	左手離開方向盤	警示當下	0/1
	右手離開方向盤	警示當下	0/1
	雙手離開方向盤	警示當下	0/1
	單手離開方向盤	警示當下	0/1
	身體前傾	警示當下	0/1
	身體右傾	警示當下	0/1
	使用車內設備	警示當下	0/1
	使用車內設備：與駕駛任務無關	警示當下	0/1
	拿東西	警示當下	0/1
	手持手機	警示當下	0/1
	手靠近嘴巴	警示當下	0/1
	本車變換車道且駕駛擺頭	警示當下	0/1
前車變換車道且駕駛擺頭	警示當下	0/1	
未變換車道且擺頭	警示當下	0/1	
IV (外部資料)	是否有下雨	警示當下	0/1
	轉彎半徑	警示當下	m
	道路線形：爬坡	警示當下	0/1
	道路線形：右彎	警示當下	0/1
	道路線形：左彎	警示當下	0/1
	周圍是否有車	前 3 秒/前後 3 秒/後 3 秒	0/1
	周圍是否有大車	前 3 秒/前後 3 秒/後 3 秒	0/1

表 1 為自原始資料綜整的變數，本研究僅擷取偵測設備可得且可能與異常事件相關之變數。另外，為因應異常事件分析，同一個資料源可能出現多個變數，以第 I 層級之速度為例，本研究共使用了平均車速、平均加速度絕對值、最大加速度絕對值、是否超速等四個變數，單一資料源多變數主要源自於參考文獻以及後續實證資料的試誤結果。部分變數需定義在一定時間範圍的基礎上，例如平均車速為警示作動前 3 秒、前後 3 秒或後 3 秒，則是完全透過實證資料的試誤結果判定，以模式配適度最佳的結果作為選擇之時間範圍。

表 1 之變數多可由其名稱直接判斷其定義，另亦可參考交通部運輸研究所<sup>[31]</sup>內之定義。其中與前車車距之累積時間 (time exposed time gap, TETG) 及與前車之時距與時間積分 (time integrated time gap, TITG)，TETG 與 TITG 皆是基於 TTC (time to collision) 來評估在某一閾值以下 TTC 的持續時間與積分 (Chai 等人<sup>[32]</sup>；Mahmud 等人<sup>[33]</sup>)，如圖 5 所示。圖 5 之縱軸為 TTC (秒距)，橫軸為時間，黑色實線曲線即為本車與前車 TTC 隨時間變化值。給定一門檻水準下，若 TTC 比此門檻低，即表示此時本車與前車有相對高之碰撞風險。就圖 5 而言， $[t_1, t_2]$  與  $[t_3, t_4]$  即為 TTC 小於門檻水準之時間。在此基礎下，TETG 及 TITG 之變數定義如下：

- 與前車車距之累積時間 (time exposed time gap, TETG)：為 TTC 小於門檻水準之時間長度總和，即  $(t_2 - t_1) + (t_4 - t_3)$ 。警示發生前後特定時間範圍內，本車與前車之時距小於門檻值之時間間隔 (見圖 5)，門檻值與時間範圍依迴歸分析結果決定。
- 與前車之時距與時間積分 (time integrated time gap, TITG)：為 TTC 小於門檻水準時間之積分值，即圖 5 標示之黃色區域。警示發生前後特定時間範圍內，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 (見圖 5)，門檻值與時間範圍依迴歸分析結果決定。

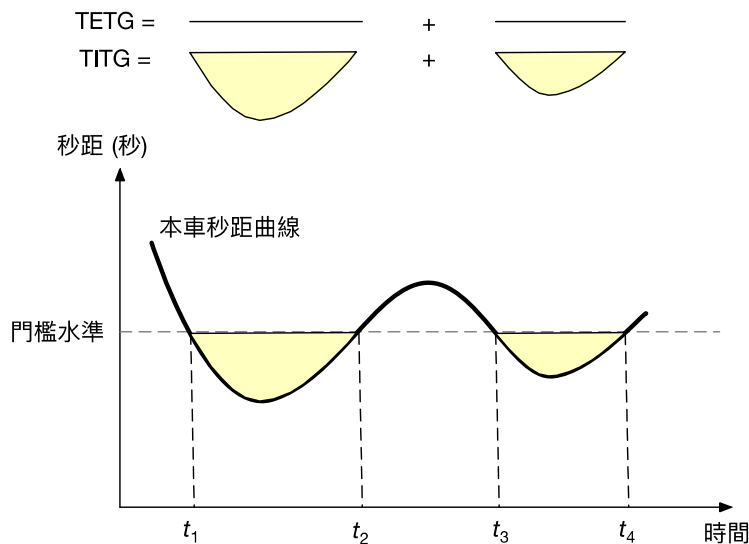


圖 5 TETG 與 TITG 定義

本研究使用之資料為國道客運業者營運之臺北至臺南來回 200 趟次中 576 筆縱向警示以及 425 筆橫向警示，其中縱向警示包括高速前車防碰撞警示 (forward collision warning under high speed driving, FCWH) 以及未保持 0.4 秒之安全距離 (safety distance warning, SDW 0.4)，橫向警示則包括車道偏移警示 (lane departure warning, LDW) 以及嚴重車道偏移 (serious lane departure warning, SLDW)，SLDW 定義為指 300 秒內發生 2 次車道偏移。

在異常事件定義的部分，本研究以人工觀看各警示事件之車外及車內影像，依據各警示事件發生前後之車外狀況及駕駛應對警示行為，標示其是否為異常事件。異常事件定義為：學理上狹義之事故前兆，且為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、與周遭車輛之相對距離、駕駛人之因應動作等不同情境組合判定。

### 3.3 高風險駕駛行為辨識流程

本研究定義高風險駕駛行為為「ADAS 警示前後，會顯著提升警示事件異常化之駕駛特徵、本車動態、駕駛分心動作、本車與周遭車流互動關係、道路環境以及天候狀況之組合」。為建立各種駕駛情境組合與警示事件異常化關係，本研究設計了一個計量與機器學習混合模式分析流程 (繪如圖 6)：

- (1) 根據各類管理系統方式，統整其能獲取之所有變數 (詳見表 1)，例如第 I 類系統之資料為車機與 GPS 資料。
- (2) 使用計量模式分群篩選與異常事件顯著之相關變數：如研究架構圖 1 所示，不同的警示類別及行車動態下，警示事件異常化之原因可能不同，因此本研究依縱向與橫向警示分別建立模式。其中縱向警示發生情境包括本車或他車變換車道時，考量兩種情境發生的原因不同，本研究僅選取本車變換車道案例進行分析。本研究之異常事件為一二元變數：不為異常或異常，因此使用二元羅吉特迴歸 (binary logit regression) 來串連候選變數與異常事件之關聯。
- (3) 以機器學習模式辨識連續變數與異常事件之關係，並將其轉換為類別變數：為獲得描述高風險駕駛情境之變數組合，本研究進一步透過機器學習模式將連續變數類別化，本研究選用之方法為增幅迴歸樹 (boosted regression tree, BRT)。BRT 演算法有兩個機制與事故資料特性有關，一為 bagging，也就是 BRT 會生成多棵決策樹，並以多棵樹估算值的加權平均作為整體預測值；此機制可減少納入多個解釋變數時，造成預測變異過大的問題。另一個機制為 boosting，也就是 BRT 在生成多棵樹時，會針對預測結果較為不好的案例 (例如發生情境較特別的異常事件) 加強預測，可減少事故獨特性的疑慮。另一個利用 BRT 的好處在於，此模式可計算連續變數對警示異常化的邊際影響效果，利於門檻值判斷。
- (4) 根據第 (3) 步驟獲取之非線性關係，嘗試不同門檻值將連續變數類別化，並以類別化後之變數加上原本之類別變數，發展二元羅吉特迴歸模式，並從中選擇配適度最高之模式

作為判定高風險駕駛情境之機率模式。

- (5) 為確保本研究發展之高風險駕駛行為判定模式具一定準確度，並了解將連續變數類別化對異常事件預測準確度之影響，需使用其他模式與其比較。據此，本研究另發展機器學習模式，並比較兩者之異常事件預測能力。本研究選用之機器學習方法為道路交通事故常使用之隨機森林以及 XGBoost (eXtreme Gradient Boosting)。之所以選擇上述兩種模式，是因為其為過去文獻上常見分析道路交通事故嚴重度之機器學習模式 (Parsa 等人 [34]; Wu 等人 [35]; Dogru 與 Subasi [36])，且其分析結果之績效亦優於其他機器學習模式 (Dogru 與 Subasi [36]; Yu 等人 [7])，故本研究選擇隨機森林與 XGBoost 作為比較之模式。
- (6) 在確認所發展之高風險駕駛行為機率模式具相當之預測力後，最後估計不同情境組合下，若發生 ADAS 警示，其異常化之機率，並以此機率為基礎計算相對風險值，以辨識高風險情境。

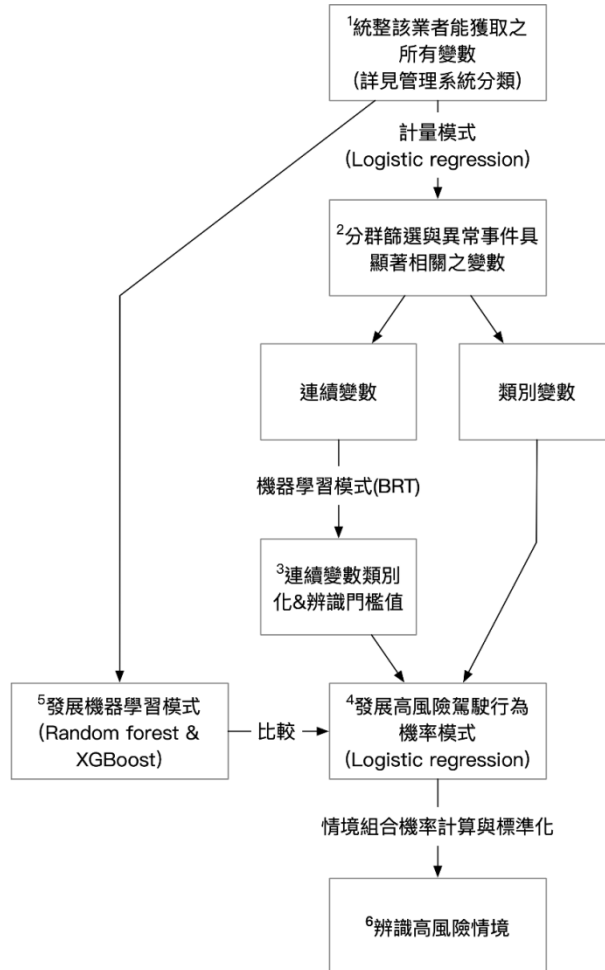


圖 6 高風險駕駛行為定義流程

### 3.4 分析方法

本研究主要使用的方法包括二元羅吉特迴歸以及增幅迴歸樹，皆為交通運輸領域常用之方法，其中增幅迴歸樹的功能在辨識各連續型解釋變與異常事件發生機率之關係，並據此結果將連續型變數轉換為類別型變數。

雖大部分的機器學習方法都能模化解釋與被解釋變數的非線性關係，但通常需另外依賴可解釋機器學習 (interpretable machine learning) 方法 (例如 Shapley values) 來估計所辨識之非線性關係。而增幅迴歸樹不需額外使用可解釋機器學習方法即可達成此目的，且此方法在過去亦被證實可有效分析道路事故嚴重度 (Chung<sup>[37]</sup>)，因此本研究選擇增幅迴歸樹作為類別化連續變數之分析基礎。

假設異常事件 ( $y_i$ ) 為一二元變數，當該警示為異常事件時，其值為 1，不為異常事件其值為 0。二元羅吉特迴歸模式可寫成：

$$P(y_i = 1) = \text{logit}^{-1}(X_i\beta)$$

其中  $X_i$  為解釋變數、 $\beta$  為待估計參數向量， $\text{logit}^{-1}$  為羅吉特反函數，定義為  $\text{logit}^{-1} = e^x / (1 + e^x)$ 。

在增幅迴歸樹的部分，首先須定義損失函數  $L(y, f(x)) = (y - f(x))^2$ ，其中  $f(x) = \sum_m f_m(x) = \sum_m \beta_m b(x; \gamma_m)$ ， $b(x; \gamma_m)$  為單一決策數、 $\gamma_m$  用以控制節點的關係、 $\beta_m$  決定每一棵決策樹之間的權重關係。在本研究中，每一棵決策樹使用的是二元羅吉特模式的迴歸樹，詳細的演算法可參考 Chung<sup>[37]</sup>。

在模式配適度方面，本研究分別使用 AIC (Akaike information criterion) 及平均 AUC (Area under the ROC curve) 以討論模式之建立效果。AIC 為日本統計學家 Akaike<sup>[38]</sup> 創建，其假設模式的誤差為常態分布，為使用模式本身之參數數量及概似函數對數 (Log-likelihood function) 計算之，AIC 之值愈小表示模式之配適度愈高。AUC 則表示模式之 ROC 曲線 (Receiver operator characteristic) 下之涵蓋面積，主要用以討論模式的預測能力，一般而言 AUC 大於 0.7 可視為高預測能力、大於 0.5 則表示模式優於隨機預測有參考價值，本研究使用 10-fold 交叉驗證法，將資料隨機拆分後計算 10 次再取平均，故所得之平均 AUC 皆為校估 10 次之平均。

## 四 分析結果

### 4.1 樣本基本特性

表 2 為所蒐集 1,001 筆 ADAS 縱橫向警示中，異常事件及各項駕駛員分心行為統計。由統計結果可知，在縱向警示中有 30.6% 的警示為異常事件，屬於真警示 (true alarm)，而橫向警示中僅 14.1% 為異常事件，偽警示 (false alarm) 的比例高。初步觀看事件影像結果

可以發現，橫向警示偽報率高的原因通常在於，該警示發生時多為周遭車流稀疏的狀況，且警示觸發後，駕駛多能立即導正車行方向，恢復在車道內行駛，無明顯提升事故風險之疑慮。

另由表 2 之統計亦可得知，車內分心行為以單手離開方向盤（縱向 33.7%；橫向 49.2%）及擺頭（縱向 13.6%；橫向 14.1%）為多，單手離開方向盤的行為中，以縱向警示以右手離開方向盤為多（17.9%）；橫向警示以左手離開方向盤為多（25.6%）。本研究透過車內影像檢視，得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。

在所有 ADAS 的警示事件下，縱向警示（FCWH 及 SDW0.4）之異常事件分別為 4 件及 172 件，假警報率為 63.6%及 69.6%，平均假警報率為 69.4%；橫向警示（LDW 及 SLDW）之異常事件則分別為 52 件及 8 件，假警報率為 85.8%及 86.2%，平均假警報率為 85.9%。由此可推測，在不考慮特殊情境下之 ADAS 系統警示大多為假警報，易造成駕駛員傾向忽略其存在，可能無法明確達到減緩駕駛風險之目標。

表 2 分心動作及異常事件數

	縱向警示			橫向警示		
	FCWH	SDW 0.4	合計	LDW	SLDW	合計
分心動作						
左手離開方向盤	0	94	94 (16.3%)	96	13	109 (25.6%)
右手離開方向盤	1	102	103 (17.9%)	81	19	100 (23.5%)
單手離開方向盤	1	193	194 (33.7%)	177	32	209 (49.2%)
雙手離開方向盤	0	5	5 (0.9%)	37	8	45 (10.6%)
擺頭	2	78	80 (13.9%)	47	13	60 (14.1%)
身體前傾	1	20	21 (3.6%)	54	11	65 (15.3%)
身體右傾	0	0	0 (0.0%)	3	4	10 (1.6%)
拿東西	0	5	5 (0.9%)	19	7	26 (6.1%)
操作車內設備：與駕駛任務有關	0	34	34 (5.9%)	1	4	5 (1.2%)
操作車內設備：與駕駛任務無關	1	11	12 (2.1%)	3	1	4 (0.9%)
使用手機	0	0	0 (0.0%)	10	2	12 (2.8%)
手靠近嘴巴	0	14	14 (2.4%)	27	9	36 (8.5%)
異常事件	4	172	176 (30.6%)	52	8	60 (14.1%)
警示事件總數	11	565	576	367	58	425

註：括弧內數字為占該類警示總件數比例。同一個警示中，駕駛可能出現多個肢體分心動作，分心動作數量之和可能大於該類警示總件數。

## 4.2 高風險駕駛行為初始模式

本節呈現辨識流程中發展之第一組模式，亦即由車機、GPS、ADAS、DMS 以及外部資料獲取，含類別及連續變數之二元羅吉特迴歸模式。

值得注意的是，本節依照實務上業者所具備資料的完整度將資料層級細分為 I 至 IV，易言之，若業者未配置 ADAS 系統，則其僅具備資料層級 I 之變數；而少部分業者有配備 DMS 系統，則可使用層級 I 至 III 之變數；若業者能再加入外部資料者進行分析時，則可使用層級 IV 之變數。本節之二元羅吉特迴歸模式即利用四個資料層級分為不同模式，使得本研究之分析架構能更趨完整。另本節各模式績效之指標主要為 AIC 及 AUC，並使用交叉驗證 (cross-validation) 將資料拆分為訓練與測試集 (即 10-fold)，能更有效衡量各模式之配適度並校估模式之預測能力。

### 4.2.1 縱向警示高風險駕駛行為初始模式

表 3 及表 4 為縱向警示下本車變換車道時，各類業者管理方式所得之高風險駕駛行為初始模式整理。由表 3 可知，第 I 類系統初始模式之警示前後 3 秒之最大加速度愈大，愈有可能是異常事件；本車之警示前後 3 秒平均速度以及警示後 3 秒平均加速度會降低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，使得警示事件較不易形成異常事件；駕駛年資愈高，愈不易產生異常事件。第 I+II 類系統初始模式分析結果發現，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，導致警示事件有較高機率發展為異常事件。第 III 類系統初始模式結果發現「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異常事件有可能造成視線離開前方的行為，會使其無法及時針對前方車輛動態進行反應，提高駕駛風險。第 IV 類系統初始模式結果發現，「警示前後 3 秒周圍有大車」將增加異常事件產生之機率，本研究推測，若本車駕駛員發現前方有狀況時，通常會優先使用變換車道的方式避讓，但換車道當下若周圍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異常事件發生。

由分析結果可以發現，當資料愈趨完整時 (即由第 I 類至第 IV 類)，初始模式之 AUC 值皆逐步增加，顯示資料愈完整之模式預測力愈佳。由第 I 類模式轉至第 II 類模式時 AUC 增幅最大，說明若加入本車與前車之車距狀況後，模式之預測能力增加，可說明縱向警示下，異常事件的產生與車距之關聯程度較大。

在四個模式中，以模式 IV 的表現最佳，表示在本車變換車道之縱向警示發生時，可能導致異常事件產生機率提高之行為：警示前後 3 秒最大加速度愈大；車趨時間為夜間；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；警示前 3 秒車距範

圍變動幅度愈大；駕駛員操作與安全無關之設備；駕駛員將手靠近嘴巴；警示前後 3 秒，周圍有大型車時。

表 3 縱向警示高風險駕駛行為初始模式：資料類別 I、II

變數	資料類別 I		資料類別 I+II	
	係數	標準誤	係數	標準誤
截距	1.543	1.042	1.796	1.123
平均速度	-0.027*	0.011	-0.036**	0.013
最大加速度絕對值	1.730***	0.351	1.664***	0.353
平均加速度絕對值	-2.875**	0.893	-2.828**	0.904
晚上	0.674**	0.223	0.724**	0.227
年資	-0.040**	0.016	-0.041**	0.016
TITG_03 (前後 3 秒)			1.082*	0.522
車距範圍			0.039***	0.012
AIC	673.7		660.72	
10-fold 平均 AUC	0.659		0.683	

~  $p < 0.1$ , \*  $p < 0.05$ , \*\*  $p < 0.01$ , \*\*\*  $p < 0.001$

表 4 縱向警示高風險駕駛行為初始模式：資料類別 III、IV

變數	資料類別 I~III		資料類別 I~IV	
	係數	標準誤	係數	標準誤
截距	1.737	1.133	1.508	1.151
平均速度	-0.037**	0.013	-0.036**	0.013
最大加速度絕對值	1.758***	0.360	1.803***	0.362
平均加速度絕對值	-3.086***	0.924	-3.153***	0.928
晚上	0.694**	0.229	0.771***	0.234
年資	-0.038*	0.016	-0.040*	0.016
TITG_03 (前後 3 秒)	1.106*	0.529	1.241*	0.536
車距範圍	0.038**	0.012	0.038**	0.012
使用車內設備：與駕駛任務無關	1.557*	0.645	1.440*	0.652
手靠近嘴巴	1.264*	0.584	1.269*	0.585
本車周圍有大車(前後 3 秒)			0.106~	0.058
AIC	654.14		652.88	
10-fold 平均 AUC	0.696		0.697	

~  $p < 0.1$ , \*  $p < 0.05$ , \*\*  $p < 0.01$ , \*\*\*  $p < 0.001$

#### 4.2.2 橫向警示高風險駕駛行為初始模式

表 5 及表 6 為本車行駛於國道主線時橫向警示下，各類業者管理方式所得之高風險駕駛行為初始模式整理。第 I 類系統之初始模式顯著變數為「國道里程」、「超速」及「夜晚」三變數，皆為負向顯著，推測國道里程大(越往南部)或夜晚時道路狀況較為順暢故駕駛員行車時較易超速，在此情境下雖超速但不易發展為異常事件。國道里程部分，因本研究對象之車隊主要行駛於國道 1 號臺北至臺南路線，隨著國道里程的增加表示車輛愈往南部行駛，同時經確認後國道 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，故異常事件產生之機率可能降低，然其顯著性並不高，說明此變數仍須加入其他的相關解釋變數。

第 II 類系統初始模式分析結果發現，行駛於國道主線段時，車距與異常事件的行程較無關聯故不顯著，值得注意的是，若放入車距變數，亦會使國道里程的變數變為不顯著。第 III 類系統之初始模式之 AUC 值大幅提高，說明此模式相較於第 I 類及第 II 類模式能更好的預測異常事件的發生，換言之，此情境下駕駛員的分心行為對異常事件的產生有極大的關聯，本研究發現「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，將進一步增加異常事件的發生機率，提高駕駛風險。

第 IV 類系統之初始模式結果發現，車外環境相關變數皆不顯著，且 AUC 值小幅下降，說明橫向警示的發生與車外環境及周圍互動關係較無直接關聯。

綜合上述分析結果，本車行駛於國道主線段，可能導致橫向警示事件異常化之行為如後：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；駕駛員雙手離開方向盤；駕駛員伸手拿取物品；駕駛員使用手機(違規行為)。

表 5 橫向警示高風險駕駛行為初始模式：資料類別 I、II

變數	資料類別 I		資料類別 I+II	
	係數	標準誤	係數	標準誤
截距	-0.660*	0.336	-0.845*	0.370
國道里程	-0.003~	0.002	-0.003	0.002
超速	-1.899*	0.748	-1.928*	0.751
晚上	-0.893**	0.287	-0.845**	0.290
TITG_09(前後 3 秒)			0.147	0.115
AIC	330.94		331.39	
10-fold 平均 AUC	0.685		0.686	

~  $p < 0.1$ , \*  $p < 0.05$ , \*\*  $p < 0.01$ , \*\*\*  $p < 0.001$

表 6 橫向警示高風險駕駛行為初始模式：資料類別 III、IV

變數	資料類別 I~III		資料類別 I~IV	
	係數	標準誤	係數	標準誤
截距	-1.521***	0.423	-1.575***	0.451
國道里程	-0.003	0.002	-0.003	0.002
超速	-1.786*	0.771	-1.765*	0.772
晚上	-0.936**	0.321	-0.894**	0.343
TITG_09 (前後 3 秒)	0.291*	0.121	0.285*	0.122
雙手離開方向盤	1.667***	0.397	1.687***	0.401
拿東西	1.581**	0.510	1.575**	0.510
用手機	2.570***	0.649	2.587***	0.650
本車周圍有大車(後 3 秒)			0.046	0.130
手靠近嘴巴	-1.521***	0.423	-1.575***	0.451
AIC	289.84		291.71	
10-fold 平均 AUC	0.796		0.790	

~  $p < 0.1$ , \*  $p < 0.05$ , \*\*  $p < 0.01$ , \*\*\*  $p < 0.001$

### 4.3 增幅迴歸樹分析結果與連續變數類別化

本研究進一步將以前小節最佳高風險模式中所有連續變數，使用增幅迴歸樹模式找出各變數與警示事件異常化的關係，並透過視覺化圖形判斷可能將該變數類別化之門檻值，最後透過迴歸模式選擇最佳門檻值。

針對本車變換車道之縱向警示情境，對連續變數建立之 BRT 模式分析結果如圖 7 所示，本車行駛於國道主線之橫向警示情境分析結果則如圖 8 所示。由分析結果可以看出，部分變數與異常事件的確呈現非線性關係，例如縱向警示中，平均速度介於每小時 80 至 90 公里之間的異常機率較介於每小時 70 至 80 公里之間或大於每小時 90 公里來的高 (圖 7 左上方)；或當本車與前車之時距與時間以 0.3 秒作為門檻，其累積時長超過 0.65 秒，警示事件異常化機率大幅提升 (圖 7 中下方)。而橫向警示分析結果亦可看出，駕駛年資及 TITG 數值在一定門檻值前後，警示事件異常化的機率有明顯變化 (圖 8)。以圖 7 及圖 8 分析結果為基礎，本研究測試不同的類別化方式，並以二元羅吉特迴歸進行分析，最後選擇模式配適度最高之類別化變數組合。

### 4.4 高風險駕駛行為最終模式

以前述增幅迴歸樹分析結果類別化連續變數為基礎，發展之高風險駕駛行為最終模式結果如表 7 及表 8。依據最終模式分析結果，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後：警示前後 3 秒，平均車速介於 80~90 公里/小時；警示前後 3 秒，最大

加速度 $\geq 2.5$  公尺/秒<sup>2</sup>；駕駛時間為夜晚時；駕駛年資 $< 3$  年；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 $\geq 0.7$  秒<sup>2</sup>；警示前 3 秒，與前車之車距範圍介於 12~26 公尺；駕駛員操作與安全無關之設備；警示前後 3 秒，周圍有大車。

橫向警示之高風險駕駛行為情境則為：國道里程介於 0 至 110 公里間；駕駛時間為白天；駕駛員未超速；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 $\geq 3$  秒<sup>2</sup>；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。值得注意的是「未超速」及「白天」兩變數與本研究之預期稍有不同，顯示駕駛員若使用較慢車速駕駛或在行駛時間在白天時，將會提高異常事件的發生，本研究推測此情形應與車多或壅塞有關；另，異常事件的產生與駕駛員手部分心有極大相關；「警示後 3 秒周圍有大車」變數則因為不顯著，不列入高風險駕駛情境統計項目中。

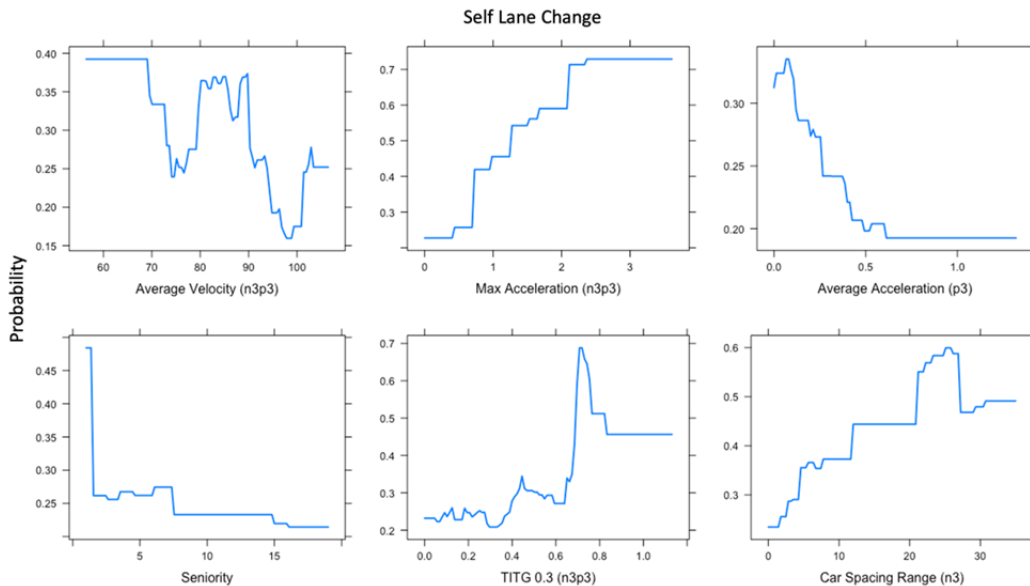


圖 7 連續變數對警示事件異常化之關係：BRT 模式分析縱向警示結果

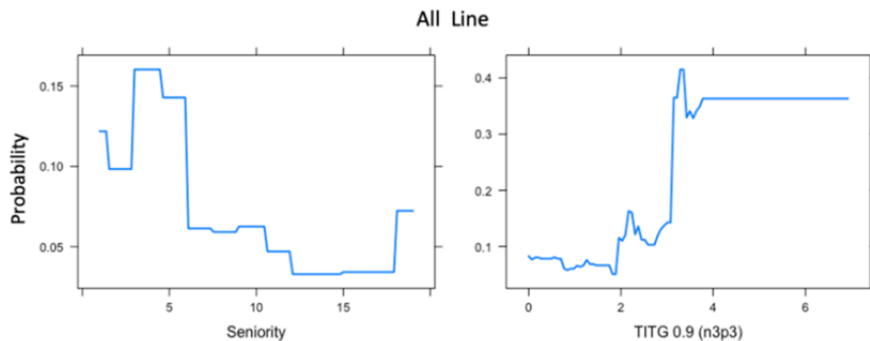


圖 8 連續變數對警示事件異常化之關係：BRT 模式分析橫向警示結果

表 7 縱向警示高風險駕駛行為最終模式：資料類別 I~IV

變數類別	變數	估計值	標準誤
--	截距	-1.859***	0.186
駕駛員相關	年資少於 3 年	0.946***	0.251
車輛動態	平均速度 80~90 公里/小時	0.685***	0.201
	最大加速度大於 2 公尺/秒 <sup>2</sup>	2.271***	0.612
車內行為	使用車內設備：與駕駛任務無關	1.341~	0.685
	手靠近嘴巴	1.004~	0.580
車外環境	晚上	0.786***	0.234
	與前車之秒距少於 0.3 秒之秒距與時間積分 ≥ 0.7 秒 <sup>2</sup>	1.297***	0.375
	車距範圍介於 12~26 公尺	1.373**	0.419
	周圍有大車（前後 3 秒）	0.108~	0.059
AIC	652.82		
10-fold 平均 AUC	0.685		

~ p < 0.1, \* p < 0.05, \*\* p < 0.01, \*\*\* p < 0.001

表 8 橫向警示高風險駕駛行為最終模式：資料類別 I~IV

變數類別	變數	估計值	標準誤
--	(截距)	-4.830***	0.805
車輛動態	未超速	1.713*	0.763
車內行為	雙手離開方向盤	1.748***	0.403
	拿東西	1.701***	0.513
	用手機	2.593***	0.654
車外環境	國道里程介於 0~110 公里之間	0.732*	0.339
	白天	0.974**	0.325
	與前車之秒距少於 0.9 秒之秒距與時間積分 ≥ 3 秒 <sup>2</sup>	1.500**	0.505
AIC	6283.33		
10-fold 平均 AUC	0.797		

~ p < 0.1, \* p < 0.05, \*\* p < 0.01, \*\*\* p < 0.001

#### 4.5 駕駛行為情境風險估計及分級

以最終模式為基礎，可計算出各種情境行為下對應之警示事件異常化機率，以此機率為基礎可進一步定各行為情境風險，作為業者風險管理之參考。本研究提出之計算方式如

下：(1) 計算解釋變數組合下之警示事件異常化機率，(2) 將機率正規化至 0 與 1 之間作為風險值，並依數值升冪排列，(3) 就其風險曲線轉折點設為情境風險區分的門檻，將行為情境分為低、中、高風險；其中行為情境  $n$  之風險值 (估計機率正規化) 計算方式如下：

$$r_n = \frac{p_n - p_{min}}{p_{max} - p_{min}}$$

其中  $p_n$  為第  $n$  個行為情境成為異常事件的機率， $p_{min}$  及  $p_{max}$  分別為所有行為情境成為異常事件機率的最小值與最大值。

根據表 7 及表 8 的分析結果所繪製之各行為情境風險值如圖 9 及圖 10 所示。在縱向警示風險曲線中，本研究選擇情境組合 1 至 75、76 至 450 以及 451 至 512 分別作為低、中、高風險的行為情境；在橫向警示風險曲線中，本研究選擇情境組合 1 至 20、21 至 110 以及 111 至 128 分別作為低、中、高風險的行為情境。

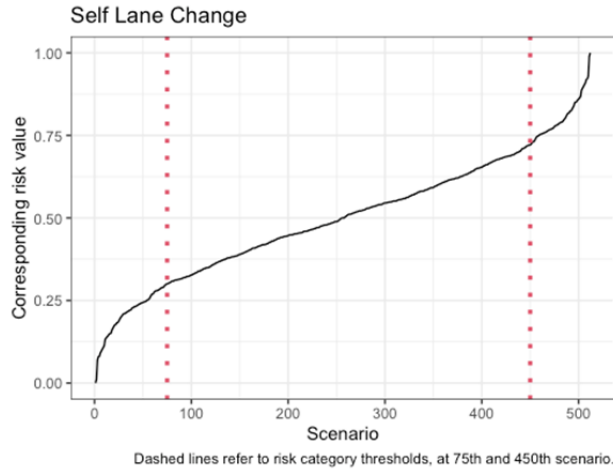


圖 9 縱向警示各行為情境組合對應之風險估計值

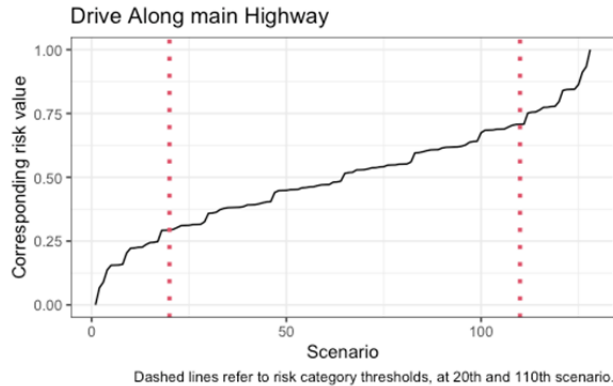


圖 10 橫向警示各行為情境組合對應之風險估計值

#### 4.6 風險等級驗證

為了解本研究切分之風險等級是否符合預期，本研究計算不同風險等級下之高風險駕駛行為組合之 ADAS 陽性率。分析結果顯示，本研究歸類為低風險之行為情境在 SDW0.4、LDW 以及 SLDW 之陽性率分別為 29.2%、6.9%以及 7.5% (見表 9)，歸類為中高風險行為情境之陽性率分別為 81.8%、47.7%以及 31.3% (見表 10)。另與此三類警示的原始資料中陽性率 (分別為 30.4%、13.8%以及 14.2%) 相比，本研究篩選出之中高風險情境之陽性率亦明顯較高。此結果證明本研究之風險等級切分方式，可有效增加 ADAS 警示之陽性率，有助於業者在進行安全管理時，能優先處理風險高之行為情境。

表 9 低風險駕駛行為之陽性率統計

	不是異常	異常	陽性率
<b>SDW 0.4</b>	226	93	29.2%
<b>LDW</b>	306	21	6.9%
<b>SLDW</b>	37	3	7.5%

表 10 中高風險駕駛行為之陽性率統計

	不是異常	異常	陽性率
<b>SDW 0.4</b>	2	9	81.8%
<b>LDW</b>	65	31	47.7%
<b>SLDW</b>	11	5	31.3%

#### 4.7 最終模式預測力驗證

前述發展之高風險駕駛行為結合了二元羅吉特迴歸與 BRT 模型，分析過程包括變數篩選、變數轉換以及連續變數類別化等處理程序。最終模型發展過程中包含了分析者的選擇判斷，為了解此是否會顯著影響最終模型的預測力，本研究另發展隨機森林與 XGBoost 模型，在同樣的變數與資料之下，透過 10-fold 交叉驗證，以其平均 AUC 與最終模式進行比較。

此部分比較驗證所採用的資料為所有警示類別資料 (例如縱向警示除前述之 FCHW 與 SDW0.4 外，尚包括 FCHL 與 SDW1.2)，警示數為 2,524，本研究同樣應用圖 6 流程發展計量與 BRT 混合模式。此驗證樣本數較前述分析大 (縱向警示 576、橫向警示 425)，對隨機森林與 XGBoost 等機器學習模式應相對有利。另外，為簡化比較流程，此部分分析不區分縱橫向警示，而是整體樣本一起進行分析。

表 11 綜整了計量與 BRT 混合模式、隨機森林、XGBoost 預測力分析結果。由 10-fold 平均 AUC 的值可以發現，隨機森林為三種模式中表現較佳的模式；在資料層級 I、I+II、I-IV 中，其 AUC 值皆為最高。另檢視隨機森林與 XGBoost 之混淆矩陣 (confusion matrix)

可以發現，兩模式間的 Recall 值完全相同 (0.323)，而模式整體準確度 (Accuracy) 亦差異不大 (隨機森林為 0.767、XGBoost 為 0.751)。本研究建議之計量與 BRT 混合模式則在 I~III 資料層級中表現最好，在其餘資料層級中，10-fold 平均 AUC 值亦僅略低於隨機森林模式，表示本研究建議之混合模式具一定之預測力，所辨識出之高風險駕駛行為組合應具有一定外部效度。

表 11 計量與 BRT 混合模式、隨機森林、XGBoost 10-fold 平均 AUC 比較

資料層級	計量與 BRT 混合模式	隨機森林	XGBoost
I	0.636	0.657*	0.607
I+II	0.738	0.746*	0.705
I~III	0.786*	0.781	0.763
I~IV	0.785	0.787*	0.748

\* 表該資料層級中，表現最佳的模式。

## 五 結論與建議

本研究發展一套以 ADAS 警示為基礎之高風險駕駛行為辨識流程，首先定義及標示行車異常事件作為 ADAS 警示之真值，接著利用二元羅吉特迴歸篩選與事件異常程度顯著相關變數，並以增幅式迴歸樹辨識連續變數與異常事件的非線性關係，據以制定連續變數門檻，最後計算各變數組合下之車內外情境對應之事件異常化機率，以評估並找出高風險駕駛情境。相較過去研究多以問卷自我填答歸納出高風險駕駛行為，或以車機資料透過主觀定義之門檻值分析異常駕駛行為 (例如急加減速)，本研究建議之高風險駕駛行為辨識流程相對客觀，且與異常事件有直接連結，符合文獻事故前兆之要求。透過交叉驗證並與機器學習方法預測力進行比較，本研究辨識出之高風險駕駛行為的確具一定效度，辨識結果應可用以調整業者 ADAS 系統警示門檻，提高 ADAS 警示準確度。

由分析結果得知，若於縱向警示下且本車變換車道時，高風險駕駛行為與加速度、車越時間、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；易言之，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。而在橫向警示部分，若在警示當下本車行駛於國道主線時，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；且根據模式 AUC 值，若於橫向警示之情境下加入車內行為，其值將大幅提升，易言之，模式之預測能力在加入車內行為後將大幅提升，說明車內分心行為對橫向警示下之異常事件形成有高度相關。研究結果另顯示，縱向警示下本車變換車道時，若駕駛員將雙手離開方向盤，則整體風險容易由低風險轉變為高風險，建議客運業者加強此類駕駛行為管理，以降低高風險駕駛行為發生之機率。

值得注意的是，在縱向警示部分，本車變換車道時，若駕駛員年資在 3 年以下即會提高駕駛風險，說明若駕駛員年資較低時可能相對容易出現異常事件；而異常事件的產生亦與周圍是否有大車有關。橫向警示下本車若行駛於國道主線段時，會因為行駛路段（里程）導致異常事件的機率提高，而國道里程介於 0 至 110K 為北部路段，更是國道 1 號的易壅塞路段，對於異常事件的發生有較大的相關，其中國道里程變數僅用以解釋本車行駛國道不同路段時的空間變異，與 ADAS 之誤判率降低較無關聯。外部環境相關變數，僅「周圍有大車」在縱向警示事件之情境下顯著，本研究推測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，更易造成異常事件；另本研究建立模式之初並未將本車加速度與減速度之參數進行獨立校估，考量模式之簡潔度及配適度後，僅在最終模式時納入最大加速度絕對值，然加速度確實可考慮其方向性，建議可於未來研究中進行更深入之探討。

利用本研究辨識出中、高風險下之駕駛行為情境相對低風險情境有較高的陽性率（縱向 81.8%；橫向 47.7%），換言之，若只考慮中、高風險駕駛行為，ADAS 系統確實較能精準預測異常事件之產生，適時提供駕駛必要的警示；低風險駕駛行為組合下，系統雖持續提供警示，但相較而言卻較為敏感、陽性率較低（縱向 29.2%；橫向 6.9%），其中低風險駕駛行為對應之警示，相較於高風險駕駛行為而言可能相對為無效警示（假警報），亦表示該警示之設定（例如時間範圍）有改善空間，本研究亦建議未來可進一步針對 ADAS 警示觸發之條件進行更深入討論，以更進一步減少無效警示之發生。

本研究雖在縱向警示及橫向警示之中各警示類別之樣本數稍有不均，然而由起始模式至最終模式（表 3 至表 8）可發現，本研究估計之參數值皆未出現過大或過小的狀況（除截距外，絕對值皆在 3 以內），且估計值皆為顯著，故應無樣本數極端分布不均之問題。然未來研究仍建議增加樣本數，尤其是樣本數相對較少的橫向警示；若新增樣本能包含的警示產生樣態，對於模式預測準確度提升，將有一定助益。

由本研究分析結果可知，即便是相同的警示事件，在不同的車輛動態及駕駛環境下，可能會對應到不同風險程度之駕駛行為，此反應出目前多數市售 ADAS 系統偽陽性警示率問題。然若能透過合理的資料分析流程（如本研究建議之高風險駕駛行為辨識流程），根據經營路線與駕駛行為特性，持續修正使用之 ADAS 系統參數或門檻值，雖 ADAS 本身有誤判或漏判等問題，惟透過本研究之資料分析流程的確可能提升 ADAS 之安全效果，利用 ADAS 警示辨識高風險駕駛行為，提供給業者作駕駛管理與教育訓練之參考，建議可作為政府未來輔導業者精進安全管理之方向。

## 參考文獻

1. 交通部，**車輛型式安全審驗管理辦法**，2024。
2. 交通部運輸研究所，**駕駛行為分析工具開發及行為特性探討**，2020。

3. 交通部運輸研究所，應用人工智慧分析技術探勘高風險路段(2/4) - 車內異常事件影像辨識技術開發，2022。
4. 交通部運輸研究所，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異常事件影像辨識技術發展，2021。
5. Ayoub, J., Wang, Z., Li, M., Guo, H., Sherony, R., Bao, S., and Zhou, F.. "Cause-and-effect analysis of adas: A comparison study between literature review and complaint data.", *AutomotiveUI '22: 14th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, Association for Computing Machinery, 2022, pp. 139-149.
6. Reason, J., Manstead, A., Stradling, S., Baxter, J., and Campbell, K. "Errors and violations on the roads: a real distinction?", *Ergonomics*, Vol. 33, Iss. 10-11, 1990, pp.1315-1332.
7. Yu, B., Bao, S., Chen, Y., and LeBlanc, D. J. "Effects of an integrated collision warning system on risk compensation behavior: an examination under naturalistic driving conditions", *Accident Analysis & Prevention*, Vol. 163, 2021, 106450.
8. Glaser, Y. G., Guo, F., Fang, Y., Deng, B., and Hankey, J. "Investigate moped-car conflicts in China using a naturalistic driving study approach", *Journal of Safety Research*, Vol. 63, 2017, pp.171-175.
9. Feng, F., Bao, S., Sayer, J. R., Flanagan, C., Manser, M., and Wunderlich, R. "Can vehicle longitudinal jerk be used to identify aggressive drivers? An examination using naturalistic driving data", *Accident Analysis & Prevention*, Vol. 104, 2017, pp.125-136.
10. Bagdadi, O. "Assessing safety critical braking events in naturalistic driving studies", *Transportation Research Part F: Traffic Psychology and Behaviour*, Vol. 16, 2013, pp.117-126.
11. Bagdadi, O., and Várhelyi, A. "Jerky driving—an indicator of accident proneness?", *Accident Analysis & Prevention*, Vol. 43, Iss. 4, 2011, pp.1359-1363.
12. Lawton, R., Parker, D., Manstead, A. S., and Stradling, S. G. "The role of affect in predicting social behaviors: the case of road traffic violations", *Journal of Applied Social Psychology*, Vol. 27, Iss. 14, 1997, pp.1258-1276.
13. Mallia, L., Lazuras, L., Violani, C., and Lucidi, F. "Crash risk and aberrant driving behaviors among bus drivers: the role of personality and attitudes towards traffic safety", *Accident Analysis & Prevention*, Vol. 79, 2015, pp.145-151.
14. Dula, C. S., and Ballard, M. E. "Development and evaluation of a measure of dangerous, aggressive, negative emotional, and risky driving", *Journal of Applied Social Psychology*, Vol. 33, Iss. 2, 2006, pp.263-282.
15. Han, W., and Zhao, J. "Driver behaviour and traffic accident involvement among professional urban bus drivers in China", *Transportation Research Part F: Traffic Psychology and Behaviour*, Vol. 74, 2020, pp.184-197.
16. D'Souza, K. A., and Maheshwari, S. K. "Improving performance of public transit buses by minimizing driver distraction", *WIT Transactions on The Built Environment*, Vol. 128, 2012, pp.281-293.
17. Stutts, J., Feaganes, J., Reinfurt, D., Rodgman, E., Hamlett, C., Gish, K., and Staplin, L. "Driver's exposure to distractions in their natural driving environment", *Accident Analysis & Prevention*,

- Vol. 37, Iss. 6, 2005, pp.1093-1101.
18. Irwin, C., Monement, S., and Desbrow, B. “The influence of drinking, texting, and eating on simulated driving performance”, *Traffic Injury Prevention*, Vol. 16, Iss. 2, 2015, pp.116-123.
  19. Wang, L., Wang, Y., Shi, L., and Xu, H. “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*, Vol. 168, 2022, 106589.
  20. Wundersitz, L. N. “Driver distraction and inattention in fatal and injury crashes: findings from in-depth road crash data”, *Traffic Injury Prevention*, Vol. 20, Iss. 7, 2019, pp.696-701.
  21. Edwards, S. A., and Wundersitz, L. N. “Distracted driving: prevalence and motivations”, CASR Report Series, 2019, CASR160.
  22. 魏健宏、陳宥欽、李佩憶、賴家偉。「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*，第 30 卷，第 3 期，2018，頁 219-245。
  23. Chen, H. K., Chou, H. W., Su, J. W., and Wen, F. H. “Structural interrelationships of safety climate, stress, inattention and aberrant driving behavior for bus drivers in Taiwan”, *Transportation Research Part A: Policy and Practice*, Vol. 130, 2019, pp.118-133.
  24. Useche, S. A., Ortiz, V. G., and Cendales, B. E. “Stress-related psychosocial factors at work, fatigue, and risky driving behavior in bus rapid transport (BRT) drivers”, *Accident Analysis & Prevention*, Vol. 104, 2017, pp.106-114.
  25. Hickman, J. S., and Hanowski, R. J. “An assessment of commercial motor vehicle driver distraction using naturalistic driving data”, *Traffic Injury Prevention*, Vol. 13, Iss. 6, 2012, pp.612-619.
  26. Salmon, P. M., Young, K. L., and Regan, M. A. “Distraction ‘on the buses’: a novel framework of ergonomics methods for identifying sources and effects of bus driver distraction”, *Applied Ergonomics*, Vol. 42, Iss. 4, 2011, pp.602-610.
  27. Xian, H., Hou, Y., Wang, Y., Dong, S., Kou, J., and Li, Z. “Influence of Risky Driving Behavior and Road Section Type on Urban Expressway Driving Safety”, *Sustainability*, Vol. 15, Iss. 1, 2023, pp.1-15.
  28. Ghasemzadeh, A., and Ahmed, M. M. “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”, 2018 21st International Conference on Intelligent Transportation Systems (ITSC), Intelligent Transportation Systems Society (ITSS), 2018, pp.1826-1833.
  29. Khan, M. N., Ghasemzadeh, A., and Ahmed, M. M. “Investigating the impact of fog on freeway speed selection using the SHRP2 naturalistic driving study data”, *Transportation Research Record*, Vol. 2672, Iss. 16, 2018, pp.93-104.
  30. Reason, J. “The contribution of latent human failures to the breakdown of complex systems”, *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, Vol. 327, Iss. 1241, 1990, pp.475-484.
  31. 交通部運輸研究所，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，2023。

32. Chai, C., Zeng, X., Wu, X., and Wang, X. "Evaluation and optimization of responsibility-sensitive safety models on autonomous car-following maneuvers", *Transportation Research Record*, Vol. 2674, Iss. 11, 2020, pp.662-673.
33. Mahmud, S. S., Ferreira, L., Hoque, M. S., and Tavassoli, A. "Application of proximal surrogate indicators for safety evaluation: A review of recent developments and research needs", *IATSS Research*, Vol. 41, Iss. 4, 2017, pp.153-163.
34. Parsa, A. B., Movahedi, A., Taghipour, H., Derrible, S., and Mohammadian, A. K. "Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis", *Accident Analysis & Prevention*, Vol. 136, 2020, 105405.
35. Wu, S., Yuan, Q., Yan, Z., and Xu, Q. "Analyzing accident injury severity via an extreme gradient boosting (XGBoost) model", *Journal of Advanced Transportation*, Vol. 2021, 2021, pp.1-11.
36. Dogru, N., and Subasi, A. "Traffic accident detection using random forest classifier", 2018 15th Learning and Technology Conference (L&T), Effat University, 2018, pp.40-45.
37. Chung, Y. S. "Factor complexity of crash occurrence: an empirical demonstration using boosted regression trees", *Accident Analysis & Prevention*, Vol. 61, 2013, pp.107-118.
38. Akaike, H. "A new look at the statistical model identification", *IEEE Transactions on Automatic Control*, Vol. 19, Iss. 6, 1974, pp.716-723.