

基於變分自動編碼器之異常駕駛行為辨識¹

ABNORMAL DRIVING BEHAVIOR DETECTION BASED ON VARIATIONAL AUTOENCODER

李威勳 Wei-Hsun Lee²
盧冠宏 Guan-Hong Lu³
吳姍姍 Shan-Shan Wu⁴
楊晶雅 Ching-Ya Yang⁵
趙燁庭 Yeh-Ting Chao⁶

(109 年 09 月 21 日收稿，110 年 1 月 8 日第一次修正，
110 年 3 月 15 日第二次修正，110 年 12 月 21 日定稿)

摘 要

為提升國道交通秩序，駕駛人行為的控制與管理為其關鍵。現況相關權責機關多透過歷史交通事故資料，或是巨觀車流狀態作為國道交通管理之依據。然而受限資料細緻度難以瞭解微觀駕駛行為，交通安全秩序提升管理仍有所不足。相關研究多使用車輛動態資訊坪林站 1 號出口萃取危險駕駛行為，作為事故預測與道路安全改善之主要依據。然而不同駕駛個體之反應與程度亦有所差異，並非所有駕駛面對突發狀況表現皆達到危險駕駛行為之標準。不同於危險駕駛行為具有固定、絕對性標準，異常駕駛行為是一種考量駕駛風格因人而異所產生的動態、相對性標準。本研究使用

-
1. 本文作者感謝審查委員提供的寶貴意見，及科技部專題研究計畫 (MOST108-2410-H-019-021) 之經費贊助。
 2. 國立成功大學交通管理科學系教授，國立成功大學 Fintech 商創研究中心（聯絡地址：臺南市大學路 1 號交通管理科學系，電話：06-2757575#53238，email：leews@mail.ncku.edu.tw）
 3. 國立成功大學交通管理科學研究所碩士。
 4. 國立成功大學交通管理科學研究所碩士。
 5. 倫敦帝國學院土木與環境工程研究所研究生。
 6. 國立交通大學運輸與物流管理研究所研究生。

國道客運車機資料進行駕駛行為分析，並引入異常駕駛行為概念，經變分自動編碼器所偵測之異常駕駛行為，其後與歷史交通事故資料進行比對，探討異常駕駛行為與交通事故之關聯。本研究結果可於事故發生以前，透過網羅更多潛在風險駕駛行為，達到積極道路安全管理。

關鍵詞： 深度學習；駕駛安全；異常駕駛行為；變分自動編碼器

ABSTRACT

To improve the highway safety, the regulation and management of driving behaviors is one of the most critical issues. The highway safety management policy which made by the concerned departments usually depends on the historical traffic crash events or macro traffic flow. However, it is hard to have a depth knowledge of microscopic driving behaviors due to the limited data granularity, which is insufficient to achieve the safety regulation improvement. Related studies usually take near crash events extracted from the driving behavior data as the main input of crash prediction and safety improvement. Nevertheless, the driving behaviors varies from drivers, not all drivers react dangerous while emergency. Different from near crash event which owns static and fixed standard, the standard of abnormal driving behavior is dynamic and comparatively. This research uses Variational Autoencoder to detect the abnormal driving behaviors from the data of highway bus and explores the relations between the historical traffic crashes with the comparison. This research can discover the potential risk before crash, which makes highway safer actively.

Key Words: *Deep Learning; Driving safety; Abnormal Driving Behavior; Variational autoencoder*

一、前言

根據交通部公路總局統計^[1]，民國 108 年我國國道客運業者計 31 家，路線 184 條，行車次數約 449 萬次，載客人數約為 8 千萬人次，總延人公里約為 63 億人公里，平均每—旅客運距 77.52 公里。大眾運輸面主要競爭者為高鐵、長途臺鐵，相較之下，儘管國道客運具有價格優勢，但在安全層面相對具有較高的風險。108 年第 9 週內政統計通報中^[2]調查顯示，大客車以每萬輛發生 6.46 件 A1 類道路交通事故位居 107 年車種別肇事率第二高。交通部高速公路局「108 年國道事故檢討分析報告」^[3]指出近 5 年人為因素(駕駛人因素與其他駕駛人因素)占肇事原因因素之 9 成以上。由此可見，欲提升國道交通秩序，駕駛人行為的控制與管理為其關鍵。目前相關主管機關多透過交通事故與違規資料，或是以平均車速、車流量等巨觀車流狀態作為國道交通管理之依據。然而上述兩類型資料細緻度

難以瞭解微觀駕駛行為，無法深入分析交通事故中的人為因素，用於交通安全秩序提升管理仍有所不足。

根據交通部公路總局「公路汽車客運動態資訊管理系統管理要點」^[4]，依規定公路汽車客運應裝置車機設備，將動態資訊即時上傳至管理設備。車機設備所記載之動態資訊包括：位置、速度、加速度、轉向角等多項微觀且動態駕駛行為，可藉此了解駕駛風格與推測當時道路狀況。若善加利用即時上傳的車輛動態資訊，巨量資料可成為駕駛安全與管理無可取代的珍貴資產。相關研究多使用車輛動態資訊萃取危險駕駛行為，作為事故預測與道路安全改善之主要依據。透過數學公式衡量危險程度，危險駕駛行為可納入尚未發生事故卻足以構成用路人危險之駕駛行為，可更為完整評估與辨識道路風險。異常駕駛行為多發生於行駛過程中，面對突發狀況以致駕駛產生不同於過往之異常表現，然而不同駕駛個體之反應與程度亦有所差異，並非所有異常駕駛行為表現皆達到危險駕駛行為之標準。不同於危險駕駛行為具有固定、絕對性標準，異常駕駛行為是一種考量駕駛風格因人而異所產生的動態、相對性標準。換言之，危險駕駛行為係用路人主動造成道路危險，可衡量道路危險強度；異常駕駛行為係用路人被動反應道路危險，可衡量道路危險頻率。

為強化客運營運安全與管理，本研究使用國道客運車機資料進行駕駛行為分析，並引入異常駕駛行為概念，經演算法偵測之異常駕駛行為結合時間、地點，其後與歷史交通事故資料進行比對，驗證異常駕駛行為與交通事故之關聯。期望藉此可於事故發生以前，透過網羅更多潛在風險駕駛行為，達到積極道路安全管理。

二、文獻回顧

異常駕駛行為 (Abnormal Driving Behavior) 為異於常態之駕駛行為，然而回顧相關研究，異常駕駛行為比較基礎仍多為正常、安全駕駛行為，而非以駕駛個人為單位，定義個人正常與異常之駕駛行為。例如 Hu et al.^[5] 透過分析正規化的駕駛行為 (normalized driving behavior) 以偵測異常駕駛行為，提出三種異常狀態：疲倦或飲酒、魯莽以及使用手機，並量化計算其異常程度；不同於以駕駛狀態或風格區分，Chen et al.^[6] 應用支援向量機 (Support Vector Machine, SVM) 於分類出現頻率較低之行為種類，該研究中所指涉之異常駕駛行為，例如急轉彎、急煞車、側滑等行為；Wu et al.^[7] 所關注異常駕駛行為同樣為急煞車、快速變換車道等出現頻率較低之行為種類，該研究結果顯示單純貝氏分類器 (naive Bayesian classifier) 分類效果遠優於支援向量機。多數研究定義異常行為仍然將所有駕駛視為一個集體，以安全作為比較基準，探討造成危險之不同駕駛狀態或行為。儘管此類研究結果可有效辨識並改善造成道路危險之駕駛行為，然而並非所有駕駛面對緊急狀況之行為反應皆達到危險標準。如圖 1 所示，不同類型之駕駛因個體差異，導致面對相同狀況時所產生之異常駕駛行為亦有所差異。因此，若單純僅使用危險駕駛行為於道路安全改善，則僅能衡量該路段之危險強度，無從了解多少駕駛於此路段產生異常行為，進而可能低估其存在之潛在風險。

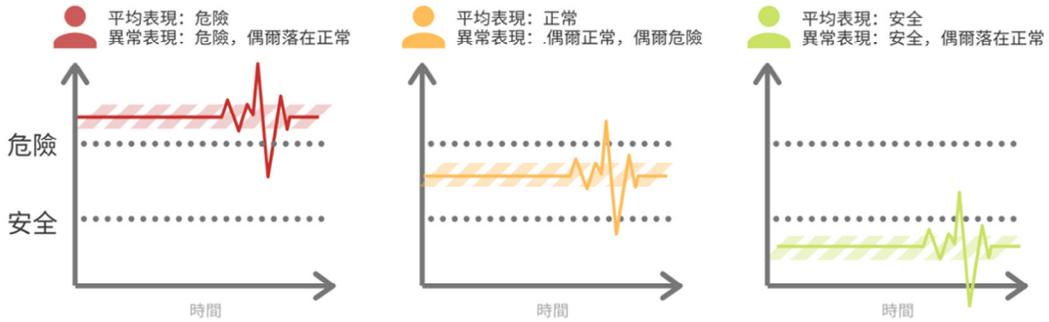


圖 1 不同駕駛面對相同狀況時產生不同異常駕駛行為

在資料中辨識出不符合預期模式的事件，稱為異常值偵測；異常值也被稱為離群值、噪聲、偏差和例外。檢測方式分為三大類：非監督異常檢測，自動尋找與其他資料最不符合的事件檢測出未標記測試資料的異常，自動找出資料中的特徵；監督式異常檢測，需定義正常和異常的事件，並訓練分類器辨識，運用於分類問題和迴歸問題；半監督式異常檢測，介於上述二者之間，同時訓練有樣本標記和無樣本標記的樣本。而本研究採用之變分自動編碼器屬非監督異常偵測。

變分自動編碼器 (Variational AutoEncoder, VAE) 是深度學習中一種生成模型 (generative model)，其模型主要可以分成編碼器 (encoder) 和解碼器 (decoder) 兩個部分，encoder 將原始資料編碼成資料平均值 (mean) 與資料標準差 (standard error) 進行參數化，並透過高斯分佈 (Gaussian distribution) 將平均值和變異數組成隱藏編碼，使其服從高斯分佈，並讓平均值趨近 0、標準差接近 1，之後再將隱藏編碼生成回原始資料。本研究利用 VAE 生成能力，當輸入值為其無法準確生成的資料時，即可以判斷是異常值。

VAE 通常被用於工業產品的瑕疵品檢測、金融市場信用卡交易異常監控、網路異常入侵偵測。相較於過去以駕駛行為、事故統計等方法無法呈現關鍵但異常資料，本研究使用 VAE 檢視駕駛異常行為更能夠捕捉到細小而未被定義規範的具風險駕駛行為。

三、研究方法與模型建構

本研究可以分成模型表現測試、實際資料異常行為辨識兩個部分，在模型表現測試的部分著重於 VAE 模型在異常駕駛動態的辨識表現，利用國外具公信力之已標記真值 (ground true) 的資料集作為模型可靠性驗證基礎；在實際異常駕駛偵測部分，本研究會將前期的測試模型加以推廣，針對目前臺灣交通環境能收集到的資料重新設計網路模型並結合地理資訊系統 (Geographic Information System, GIS)，將辨識結果與內政部警政署 A1、A2 事故資料進行交叉驗證，最後探討異常駕駛行為與事故之間的影響相關性。

3.1 前期模型表現測試資料蒐集

本研究選擇由 Romera, Bergasa, and Arroyo^[8] 所提出的 UAH-DriveSet 自然駕駛資料集進行模型測試與先行驗證工作。此資料集透過由 Bergasa, Almería, Almazán, Yebes, and Arroyo^[9] 所提出基於 iOS 系統開發應用程式：DriveSafe，蒐集超過 500 分鐘的西班牙道路自然駕駛數據，資料包含慣性感測器、攝影機、GPS 等車輛動態資料。實驗由不同的 6 臺小客車、6 位駕駛，於兩種道路型態模擬三種不同駕駛狀態，透過兩隻 iOS 手機執行 DriveSafe 應用程式，一隻負責錄影並進行影像資訊處理與 AR 資訊呈現，另一隻手機利用慣性感測器 (包含：陀螺儀、加速度計、GPS 等) 蒐集並記錄車輛動態變化。

每位駕駛在事先指定的道路上，模擬三種不同駕駛狀態其分別為：正常駕駛 (Normal driving)、精神不佳駕駛 (Drowsy driving) 與侵略性駕駛 (Aggressive driving)。正常駕駛狀態為受測駕駛維持其平常方式進行一般駕駛；精神不佳駕駛狀態為受測駕駛模擬稍微有點瞌睡、零星地未注意道路狀況，而侵略性駕駛狀態為受測駕駛在未暴露於風險情況下，盡量展現出較具侵略性的行為。

考慮到本研究實際實驗資料豐富性不如 UAH-DriveSet，故僅選擇臺灣車輛普遍可獲取之 GPS 資料作為前期測試模型的訓練資料 (x)。並選擇其已標記駕駛風格的記錄資料集 SEMANTIC_ONLINE 做為真值 (y)。在 UAH-DriveSet 中 GPS 與駕駛風格之資料特性如下：

1. Raw_Gps：由 GPS 所蒐集的資料，包含經緯度、速度，資料頻率為 1 赫茲。
2. SEMANTIC_ONLINE：為 DriveSafe 應用程式執行時，基於駕駛操作的行為強度，並加入道路型態、當下道路交通情況、駕駛者等情境資訊，透過模糊理論計算而得，並將其各項操作進行評分，以最高分數來分類駕駛風格。

3.2 實際資料蒐集

本研究選擇科技部計畫「車輛安全駕駛與駕駛行為巨量資料分析之研發」(計畫編:MOST106-2634-F006-002-CC2)^[10] 該研究所蒐集之自然駕駛行為資料，資料時間為 108 年 1 至 3 月，共 20 位客運駕駛，資料頻率為 1 赫茲，車機 GPS 數據共約 1,963 萬筆 (19,633,234 筆)，資料內容包含：資料紀錄時間、經緯度座標、車輛速度，其數據來源為客運車輛實際運行時，車機透過 4G 網路即時上傳至後端資料庫。後續為驗證異常駕駛行為之模型預測結果，使用內政部警政署 107 年歷史交通事故資料^[11]，包括 A1 類與 A2 類交通事故資料。

3.3 實際資料前處理

經檢視發現，原始資料存在跳秒、資料遺失等問題，故首先針對 GPS 遺失值使用該筆資料前後平均值進行插補 (Imputation)。接著，本研究將車輛動態資料處理定義為時間序列的分類問題，意即透過一段連續序列的車輛動態分析駕駛行為是否異常。因此，本研究

需將時序資料切成時間序列，故使用移動窗格 (rolling window) 於資料的時間軸上平移，將資料切成一段一段的序列。為避免資料於切割序列時，關鍵序列因窗格不同而被分割導致失真，本研究將資料以一半重疊一半 (1/2 overlap) 的方式進行窗格移動，窗格尺度設定為 6 秒。

3.4 資料特徵矩陣

為了將 GPS 的單一資料轉換為可供模型學習的特徵值，本研究參考 Guo et al^[12] 將 GPS 資訊透過單位時間內的統計特徵轉換的手段，利用下述公式將每個時間序列中 GPS 速度資料轉換為：超越 safety domain (δ)、速率平均 (v_a)、速率變異值 (v_s)、加速度變異值 (a_s)、正向加速度平均值 (a_a^+)、負向加速度平均值 (a_a^-)、正向加速度變異值 (a_s^+)、負向加速度變異值 (a_s^-) 共 8 個特徵 (式 1-7)。其中， v_m 為 GPS 於時間點 m 所紀錄之車輛瞬時速度， a_m 為 GPS 於時間點 m 所錄之車輛瞬時加速度， n 為樣本尺寸 (sample size)。

$$\delta = \begin{cases} 1, \sqrt{a_x^2} \geq \delta HOSD \times g \times \left[0.198 \times \left(\frac{v}{100}\right)^2 - 0.592 \times \left(\frac{v}{100}\right) + 0569 \right] \\ 0, otherwise \end{cases} \quad (式 1)$$

$$v_a = \frac{1}{n} \sum_{m=1}^n v_m \quad (式 2)$$

$$v_s = \sqrt{\frac{1}{n-1} \sum_{m=1}^n (v_m - v_n)^2} \quad (式 3)$$

$$a_m^\pm = \frac{v_m - v_{m-1}}{t} \quad (式 4)$$

$$a_a^\pm = \frac{1}{n} \sum_{m=1}^n a_m^\pm \quad (式 5)$$

$$a_s^\pm = \sqrt{\frac{1}{n-1} \sum_{m=1}^n (a_m^\pm - a_a^\pm)^2} \quad (式 6)$$

$$X_{GPS} = [\delta, v_a, v_s, a_s, a_a^+, a_a^-, a_s^+, a_s^-] \quad (式 7)$$

根據上述特徵轉換公式，本研究將 UAH-DriveSet 自然駕駛資料集、實際國道客運自然駕駛資料集的 GPS 資料都進行相同的資料前處理，處理後的每個 6 秒的時間序列之 GPS 速度轉換為 8 個特徵值 (X_{GPS})，並對處理完的特徵進行 z-score 正規化，讓每個特徵向量的投影至平均值為 0、標準差為 1 的空間，以此降低資料受離群值偏誤的影響。經過窗格運算和資料標準化後，本研究最終產生了 1.1 萬筆 (前期測試) 和 946 萬筆 (實際研究) 特徵，共 8 個向量的特徵矩陣。

3.5 模型前期測試

在建立測試變分自編碼網路 Variational AutoEncoder, VAE), 本研究選擇先建立較簡單網路, 並參考 Van Ly, Martin, and Trivedi (2013) [13] 使用敘述性統計將原始資料進行特徵向量的轉換, 衍生 5 個以單位時間為基礎的統計量 (式 8-12): 取樣時間最大加速度(\mathbf{a}_{max})、取樣時間最小加速度 (\mathbf{a}_{min})、取樣時間加速度大於 1 km/hr^2 次數(\mathbf{C}_{a_h})、單位時間加速度小於 -1 km/hr^2 次數 (\mathbf{C}_{a_l})、單位時間車速高於 95 km/hr 次數(\mathbf{C}_{v_h}), 共 13 個特徵進行測試模型訓練, 驗證模型對複雜資料的特徵萃取能力和維持模型穩健度。

$$\mathbf{a}_{max} = \max (\mathbf{a}_n) \quad (\text{式 } 8)$$

$$\mathbf{a}_{min} = \min (\mathbf{a}_n) \quad (\text{式 } 9)$$

$$\mathbf{C}_{a_h} = \sum_{m=1}^n x, \begin{cases} x = 1 \text{ if } a_m > 1 \text{ km/hr}^2 \\ 0, \text{ otherwise} \end{cases}, a_m \in a_n \quad (\text{式 } 10)$$

$$\mathbf{C}_{a_l} = \sum_{m=1}^n x, \begin{cases} x = 1 \text{ if } a_m < -1 \text{ km/hr}^2 \\ 0, \text{ otherwise} \end{cases}, a_m \in a_n \quad (\text{式 } 11)$$

$$\mathbf{C}_{v_h} = \sum_{m=1}^n x, \begin{cases} x = 1 \text{ if } v_m > 95 \text{ km/hr} \\ 0, \text{ otherwise} \end{cases}, v_m \in v_n \quad (\text{式 } 12)$$

訓練網路模型如圖 2 和圖 3 所示。

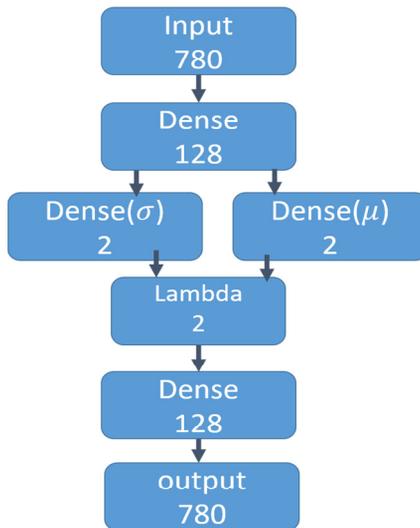


圖 2 測試 Variational AutoEncoder 網路結構

Layer (type)	Output Shape	Param #	Connected to
input_data (InputLayer)	(None, 780)	0	
dense_6 (Dense)	(None, 128)	99968	input_data[0][0]
dense_7 (Dense)	(None, 2)	258	dense_6[0][0]
dense_8 (Dense)	(None, 2)	258	dense_6[0][0]
lambda_2 (Lambda)	(None, 2)	0	dense_7[0][0] dense_8[0][0]
dense_9 (Dense)	(None, 128)	384	lambda_2[0][0]
dense_10 (Dense)	(None, 780)	100620	dense_9[0][0]
Total params: 201,488			
Trainable params: 201,488			
Non-trainable params: 0			

圖 3 測試 Variational AutoEncoder 訓練參數與結構表

首先於輸入網路前，本研究將所有序列的矩陣 (n, 60, 13) 整理為 (n, 780) 作為輸入，並選取真值 (y) 為「Normal (正常駕駛狀態)」的資料作為訓練資料。僅選取 Normal 資料的原因為模型學習 Normal 的駕駛行為後，當駕駛出現不同於 Normal 的駕駛狀態操作時，VAE 模型便會出現編碼異常，導致判斷該行為出現機率偏低時提出異常行為警告。

訓練參數部分，在考量梯度下降過程中可能因局部最小值導致模型停止優化，因此選擇 Nesterov 動量 Adam (Nadam) 作為訓練優化器，Nadam 引入物理動量的概念，當神經網路更新時會計算此次更新大小決定下次權重值的大小，以此突破局部最小值的困境，而學習率定為 0.0001 讓神經網路不會過度受更新大小而影響訓練表現。

根據訓練 200 次的模型，本研究將侵略性 (Aggressive) 作為異常值和普通 (Normal) 各輸入 20 筆測試，從編碼結果比較圖與相關統計值 (圖 4、表 1) 可見異常值較正常值的編碼結果偏大，而兩者變異數相當。

3.6 實際模型建構

由於客運車機 GPS 資料不若 UAH-DriveSet 收集準確，常因通訊不佳、車機硬體限制等實際道路環境問題，導致資料上傳掉點與延遲。因此，在實際研究模型中選擇排除前期模型中所使用的 5 個衍生性敘述統計特徵，避免關鍵資訊不齊全的問題，間接影響模型表現。實際研究資料透過 3.4 節特徵矩陣運算，將客運車機 GPS 資料前處理與轉換為 8 個特徵的矩陣作為輸入。在異常駕駛行為偵測問題中，特別的駕駛行為出現頻率較低，例如轉彎，若以出現機率作為門檻，則轉彎就會被視為異常行為。然而，本研究真正關注的是具有急加減速的轉彎行為，若維持使用傳統機率門檻，則關鍵資訊將被淹埋在異常誤報當

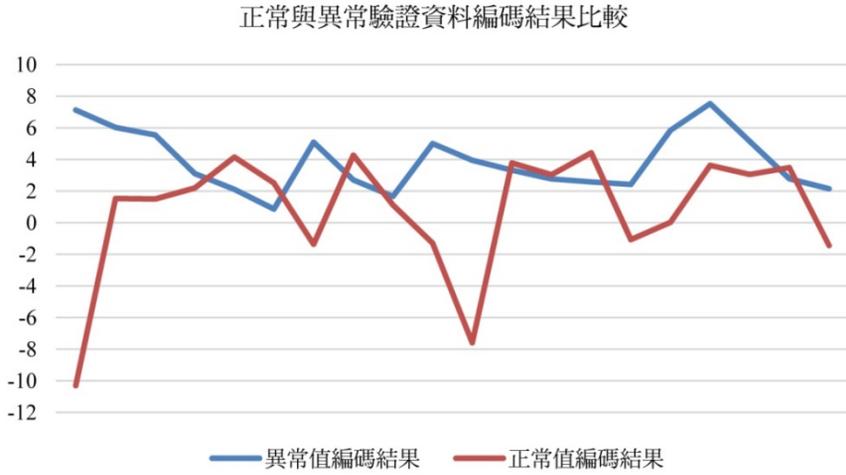


圖 4 正常與異常驗證資料編碼結果比較

表 1 正常與異常驗證資料編碼統計值

	異常值編碼	正常值編碼
平均數	1.89437	0.784
標準差	3.896211	3.89

中。為了解決上述傳統 VAE 以機率劃分門檻的問題，本研究之 VAE 模型參考 Matsubara et al.^[14] 所提出的架構。在 Matsubara et al.^[14] 中提到過去的 VAE 設計為使模型預測時可專注於正常值，使用 KL 散度 (Kullback - Leibler divergence) 進行資料正規化，然而此舉將使低出現頻率、非異常的資料被視為異常。因此 Matsubara et al.^[14] 重新修正其異常計算的公式，改以馬哈拉諾比斯距離 (Mahalanobis distance) 計算斜方差距離來衡量資料異常。

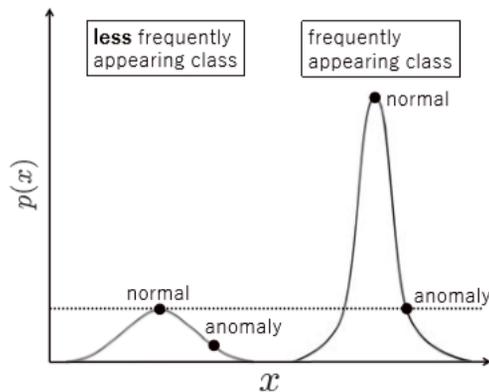


圖 5 Matsubara et al.^[14] 異常值解釋示意圖

為了計算資料的馬哈拉諾比斯距離所需的參數，本研究針對原始模型進行調整，將原本的重建資料再一次參數化，取出重建平均值 (re_mean) 和重建變異數 (re_var)，本研究將模型建立如下：

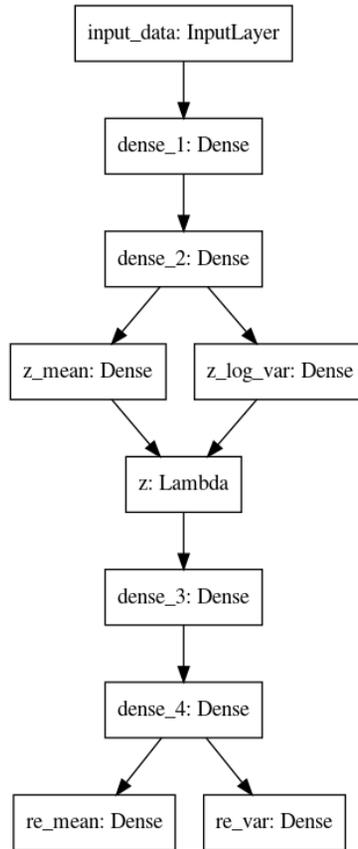


圖 6 實際研究 Variational AutoEncoder 網路結構

馬哈拉諾比斯距離的計算公式如式 13 所示，其中 x_{x_i} 為模型輸入之 X_{GPS} 特徵向量矩陣， μ_{x_i} 為其平均值， $\sigma_{x_i}^2$ 為其標準差：

$$M_{VAE}(x) = \sum_{i=1}^{N_x} \frac{1}{2} \frac{(\mu_{x_i} - x_{x_i})^2}{\sigma_{x_i}^2} \quad (式 13)$$

本研究所提出的 VAE 模型中，在隱藏層中已將資料轉換為成高斯分布，因此在最後重新參數化的平均值與變異數亦符合高斯分布，所以本研究透過以平均值與變異數計算馬哈拉諾比斯距離，作為異常值分數。接著，本研究設定超過平均數一倍標準差為門檻值，將高於門檻值的資料視為是異常值，根據數據統計被視為異常值的資料約佔總體數據 2% 左右。

Layer (type)	Output Shape	Param #	Connected to
input_data (InputLayer)	(None, 8)	0	
dense_1 (Dense)	(None, 128)	1152	input_data[0][0]
dense_2 (Dense)	(None, 64)	8256	dense_1[0][0]
z_mean (Dense)	(None, 2)	130	dense_2[0][0]
z_log_var (Dense)	(None, 2)	130	dense_2[0][0]
z (Lambda)	(None, 2)	0	z_mean[0][0] z_log_var[0][0]
dense_3 (Dense)	(None, 64)	192	z[0][0]
dense_4 (Dense)	(None, 128)	8320	dense_3[0][0]
re_mean (Dense)	(None, 8)	1032	dense_4[0][0]
re_var (Dense)	(None, 8)	1032	dense_4[0][0]
Total params: 20,244			
Trainable params: 20,244			
Non-trainable params: 0			

圖 7 實際研究 Variational AutoEncoder 訓練參數與結構表

四、模型應用結果

4.1 模型預測值

本研究將經過 VAE 模型所預測得出的異常分數，並根據模型所預測統計值，依照平均值加上一倍標準差的方式設定門檻值。經 VAE 分析表現為異常行為大約佔全體資料集共 2%左右，顯示極端的異常行為在道路行為中極為少見，極端異常行為通常會直接或間接導致事故發生，而異常行為與正常但相對危險行為中間是有段灰色地帶，使得 VAE 在學習駕駛行為的分佈上變異數與標準差偏大，但仍可以 VAE 所產生的統計分數作為異常行為的判斷依據，預測統計值如表 2 所示。

4.2 駕駛異常行為地圖

本研究將模型預測之異常駕駛行為根據 GPS 座標建立國道客運異常行為地圖(圖 8)，由於研究輸入資料行駛路線影響，故異常駕駛行為多集中於國道 1 號。其中，顏色越深者代表異常程度越高，並多集中於客運下客處，包括市區路段及停靠站附近之交流道為主，由南往北分別為高雄、臺南、新營、臺中、桃園與臺北等。

表 2 模型預測值

項目	模型預測統計值
計數 (count)	9.358021e+06
平均值 (mean)	6.454747e+00
標準差 (std)	2.650077e+02
最小值 (min)	8.694393e-02
第一四分位數 (25%)	2.388494e+00
第二四分位數 (50%)	3.441959e+00
第三四分位數 (75%)	5.037858e+00
最大值 (max)	2.768500e+05

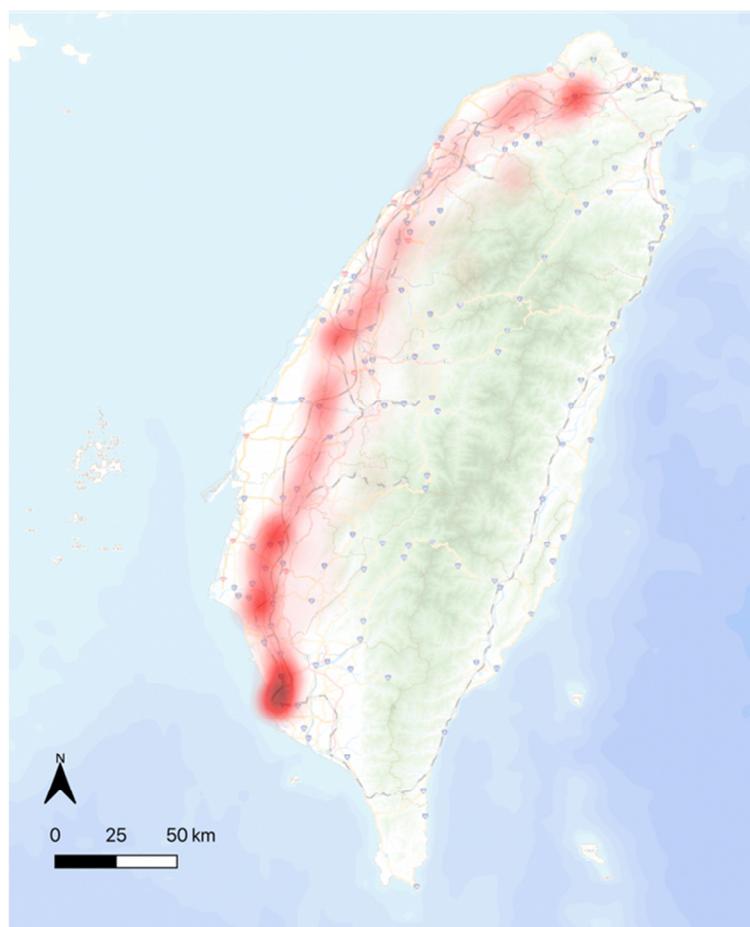


圖 8 國道客運異常行為地圖

進一步，將 107 年國道事故熱點納入一同分析與驗證。由圖 9 可發現，107 年國道事故，在國道 1 號上與駕駛異常行為可相互呼應，意即駕駛異常行為確實可作為大客車危險警示路段之參考依據。以下分別檢視各區域之危險路段與事故熱點，以進一步透過事故地異常駕駛行為。

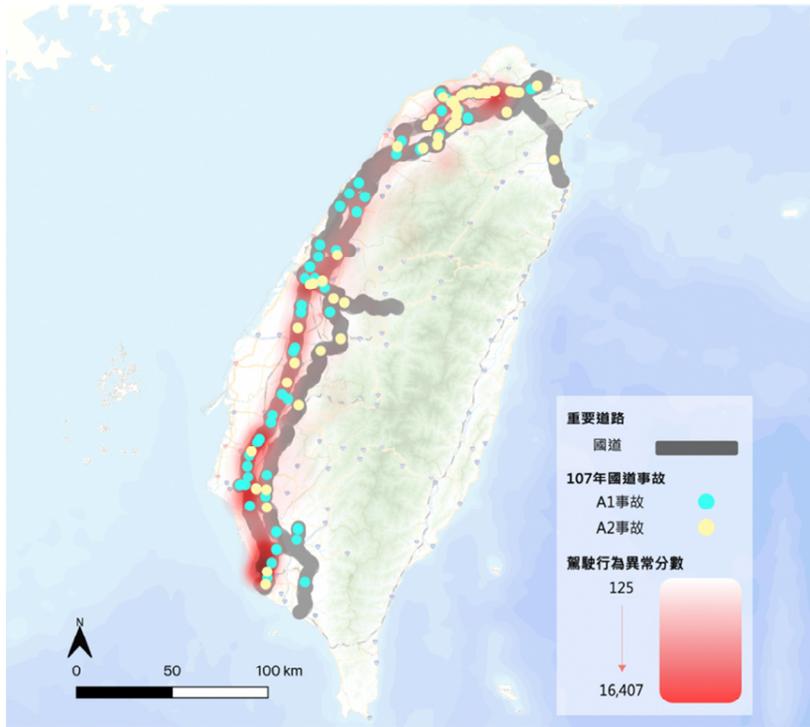


圖 9 駕駛異常行為地圖結合事故熱點

4.3 南部地區

由圖 10 可見，國道 1 號臺南地區異常駕駛行為好發於交流道前後以及轉彎處，並且一旦發生多為 A1 死亡事故。而事故發生地點多為駕駛行為異常程度較高者，故異常駕駛行為確實對於危險路段之警示具有一定程度助益。由圖 11 可見，嘉義雲林地區異常駕駛行為發生相當頻繁，建議可進一步針對道路環境與交通管理策略進行檢視。

4.4 中部地區

彰化地區 (圖 12) 之異常行為以交流道前後為主，而進一步分析彰化臺中地區 (圖 13) 之異常行為，除受道路線型所影響，此處為國 3 與國 1 之交會點，推測容易出現車流交織以及車速差異等現象，因此異常駕駛行為程度較高。同樣，此處事故之發生地點亦與異常駕駛行為之分佈趨於一致。



圖 10 臺南地區駕駛異常行為路段與事故位置



圖 11 嘉義雲林地區駕駛異常行為路段與事故位置

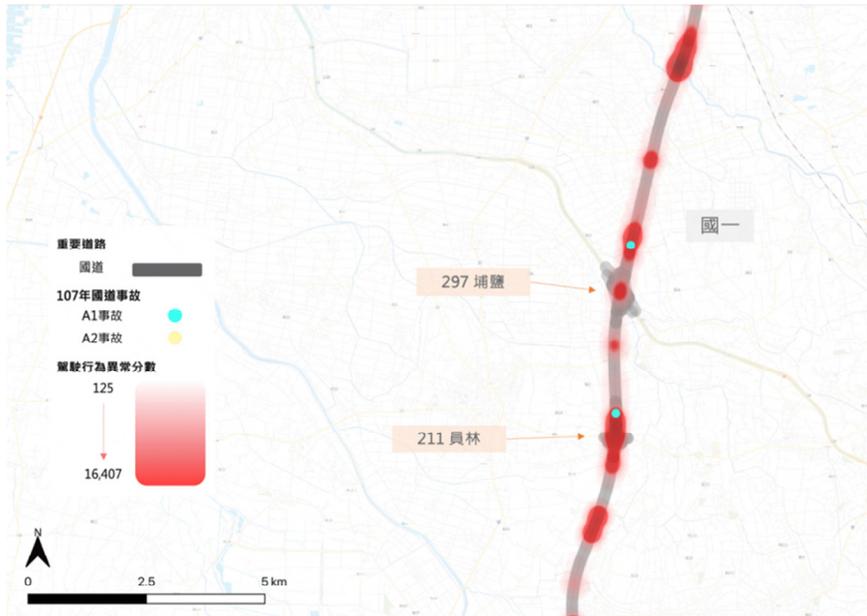


圖 12 彰化地區駕駛異常行為路段與事故位置



圖 13 彰化臺中地區駕駛異常行為路段與事故位置

苗栗地區(圖 14)異常駕駛行為推測與道路坡度以及線型具有相關性，新竹苗栗地區(圖 15)同樣為國 3 與國 1 之交匯處，推測同樣受到車流交織與車速變化程度較高等因素，導致駕駛行為異常程度較高。

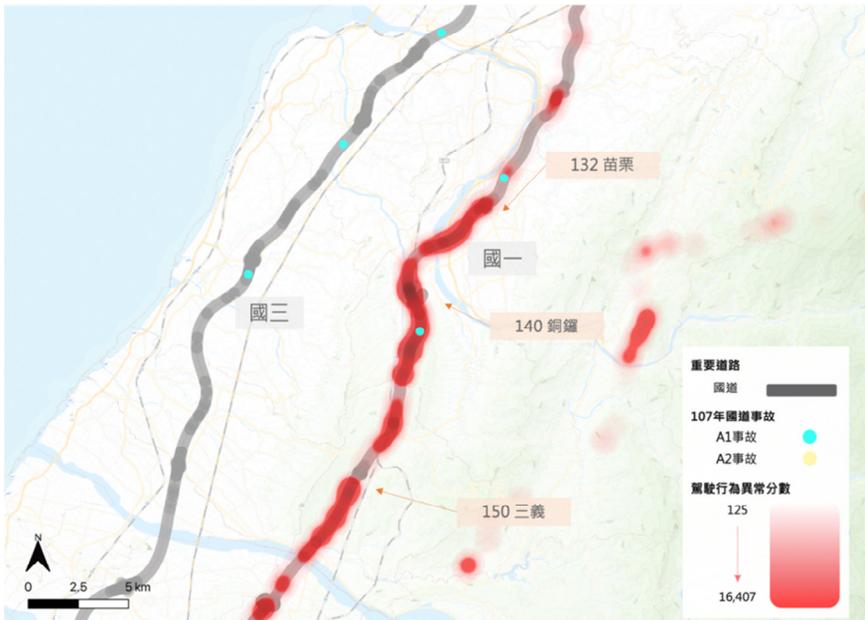


圖 14 苗栗地區駕駛異常行為路段與事故位置



圖 15 新竹苗栗地區駕駛異常行為路段與事故位置

4.5 北部地區

北部地區相對於南部地區而言 A2 事故較 A1 事故頻繁，而根據圖 16 可判斷之異常駕

駛行為受到各交流道之交通量影響，明顯集中於桃園與中壢交流道附近。而 A1 與 A2 事故之分布，與駕駛行為異常程度呈現正相關，異常程度越高者事故嚴重程度越高。桃園新北地區 (圖 17) 之異常駕駛行為與道路設計具有相關，五股高架轉接平面之泰山轉接道及其附近，駕駛行為異常程度明顯較高。同樣，事故發生地點分佈與駕駛行為異常趨於一致。

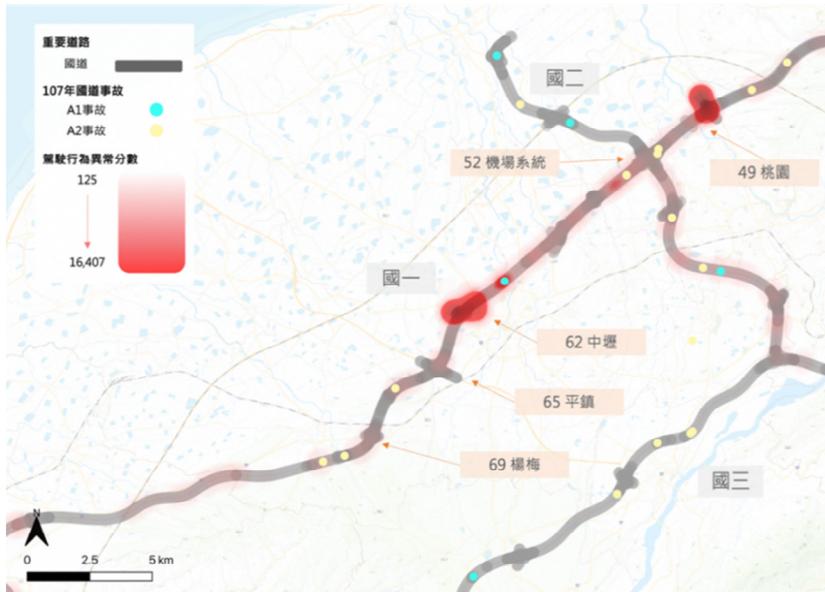


圖 16 桃園地區駕駛異常行為路段與事故位置

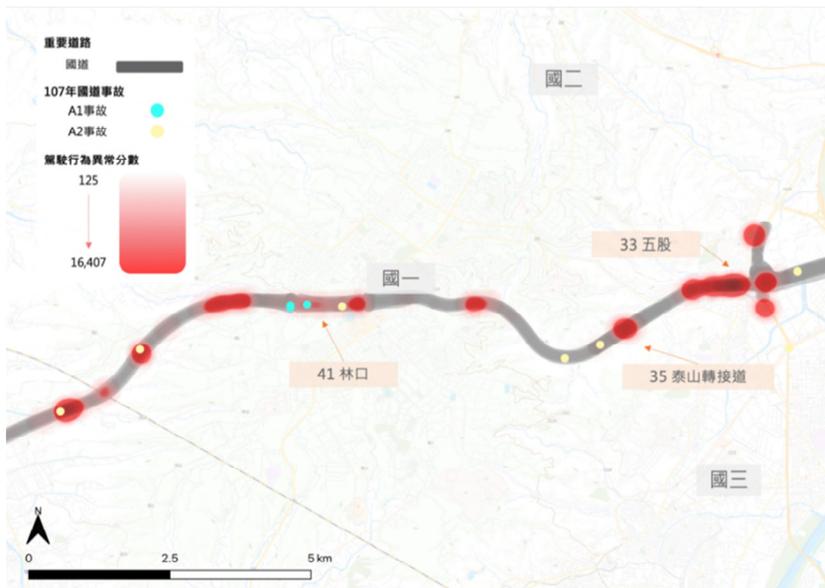


圖 17 桃園新北地區駕駛異常行為路段與事故位置

五、結論與建議

本研究運用客運駕駛 GPS 資料，以 VAE 模型辨識出其中異常值，再標示於地圖上。在此階段中，本研究使用 GPS 資料可關注的異常值包含急加速和急減速，並使用平均數一倍標準差做為門檻。此數據意義為駕駛異常加減速的地點、時間以及可能發生的事故樣態，例如：急加速急減速可能產生追撞。此一潛在事故熱點地圖，可提供的資訊更勝於現今事故發生後才產出的肇事地圖，能在事故發生前便推估高事故風險地段、時間，化被動改善為主動預防，提升交通安全、效率。本研究採用之方式與傳統最大的不同在於，使用更加積極主動與科技化的方式，並且不大幅更動現有設備基礎，初探客運異常駕駛行為與事故之關聯。

以客運經營管理層面而言，可透過此異常駕駛行為研究結果檢視不同駕駛好發異常值的時間以及路段，精確剖析駕駛感到疲累、注意力不足或容易超速違規的路段、時段及可能原因，排定最適當之班表與駕駛時數等，可採取較人性化之管理措施。透過考量個體差異之異常駕駛行為偵測，有助於提升駕駛管理的效率，同時也可降低人為因素造成事故的機率。

以國道交通管理與控制層面而言，此研究結果可協助相關權責單位瞭解用路人容易於不同時空下所產生之異常駕駛行為，因而可回溯探討該時空下該路段之潛在風險，並考量出現之駕駛行為、車流特性與事故結果，提出因地制宜之適切交通管理策略。

然而本研究仍有其侷限性，可發現異常駕駛行為頻率隨地點而有所差異，如嘉義雲林地區、苗栗地區所呈現之異常駕駛行為以連續帶狀呈現；臺南地區、桃園新北地區則呈現點狀，本研究推測此現象為駕駛行為受環境等影響，相關影響因素如：道路線型、鋪面設計、車流量變化與組成等。造成各路段之異常駕駛行為頻率與分佈不同，應由駕駛行為意義綜合外部因素共同分析探討。此外，各路段異常駕駛行為與事故發生地點之相對位置皆有不同，部分異常駕駛行為路段可涵蓋，部分則為異常駕駛行為發生地點之前或之後，此點可能受各路段之環境因素與用路人特性影響，應根據各路段道路與駕駛人特性綜合評估考量。

本研究著重於以 VAE 模型辨識「相對異常」之異常駕駛行為，嘗試呈現其模型辨識之異常結果與事故發生點位分佈，初探兩者之關聯，並作為客運經營與國道交通管理參考依據之一。儘管駕駛行為可呈現事故中最高重要的人為因素部分，然而事故發生之影響因素眾多且複雜，需綜合駕駛行為及相關外部因素共同考量分析，未來相關研究可針對此部分進一步探索分析。

參考文獻

1. 交通部公路總局，「交通部公路總局統計查詢網」，<https://stat.thb.gov.tw/hb01/>

- webMain.aspx?sys=100&funid=defjsp，民國 109 年。
- 內政部統計處，「內政統計通報」，https://www.moi.gov.tw/chi/chi_site/stat/node.aspx?Z=1&sn=5120，民國 109 年。
 - 交通部高速公路局，「108 年度國道事故檢討分析報告提要」，<https://www.freeway.gov.tw/Publish.aspx?cnid=516&p=2849>，民國 109 年。
 - 交通部公路總局，「公路汽車客運動態資訊管理系統管理要點」，<https://www.mvdis.gov.tw/webMvdisLaw/LawArticle.aspx?LawID=H0032000&KWD1=>，民國 109 年。
 - Hu, J., Xu, L., He, X., and Meng, W., “Abnormal Driving Detection Based on Normalized Driving Behavior.” *IEEE Transactions on Vehicular Technology*, Vol.66, No.8, 2017, pp. 6645-6652.
 - Chen, Z., Yu, J., Zhu, Y., Chen, Y., and Li, M. “D³: Abnormal Driving Behaviors Detection and Identification Using Smartphone Sensors”, 2015 12th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON). IEEE, 2015, pp. 524-532.
 - X. Wu, J. Zhou, J. An and Y. Yang, “Abnormal Driving Behavior Detection for Bus Based On the Bayesian Classifier”, 2018 Tenth International Conference on Advanced Computational Intelligence (ICACI), Xiamen, 2018, pp. 266-272.
 - Romera, E., Bergasa, L. M., and Arroyo, R., “Need Data for Driver Behaviour Analysis? Presenting the Public UAH-DriveSet”, 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), Rio de Janeiro, 2016.
 - L. M. Bergasa, D. Almería, J. Almazán, J. J. Yebes and R. Arroyo, “DriveSafe: An App for Alerting Inattentive Drivers and Scoring Driving Behaviors”, IEEE Intelligent Vehicles Symposium Proceedings, 2014, pp. 240-245.
 - 科技部，「車輛安全駕駛與駕駛行為巨量資料分析之研發」，民國 105 年。
 - 內政部警政署，「歷史交通事故資料」，<https://www.npa.gov.tw/NPAGip/wSite/lp?ctNode=12854&CtUnit=2633&BaseDSD=7&mp=1>，民國 109 年。
 - Guo, J., Liu, Y., Zhang, L., and Wang, Y., “Driving Behaviour Style Study With A Hybrid Deep Learning Framework Based on GPS Data.”, *Sustainability*, Vol.10, No.7, 2018, pp.2351.
 - Van Ly, M., Martin, S. and Trivedi, M. M., “Driver Classification and Driving Style Recognition Using Inertial Sensors”, 2013 Intelligent Vehicles Symposium (IV). IEEE, 2013, pp.1040-1045.
 - Matsubara, T., Tachibana, R. and Uehara, K., “Anomaly Machine Component Detection by Deep Denerative Model with Unregularized Score”, 2018 International Joint Conference on Neural Networks (IJCNN). IEEE, 2018, pp.1-8.

