

國道客運駕駛疲勞偵測模型之比較研究¹

A COMPARATIVE STUDY OF DROWSY DRIVING DETECTION MODELS FOR INTERCITY BUS DRIVERS

李威勳 Wei-Hsun Lee²

林政宇 Zheng-Yu Lin³

劉宗憲 Tsung-Hsien Liu⁴

陳羨邦 Hsien-Pang Chen⁵

張宏璿 Hung-Hsuan Chang⁵

(109 年 9 月 21 日收稿，110 年 3 月 15 日第一次修正，110 年 5 月 12 日第二次修正，
110 年 9 月 19 日第三次修正，111 年 1 月 4 日接受)

摘 要

疲勞駕駛為公路運輸安全一大隱憂，統計顯示超過七成事故來自包含疲勞駕駛在內的危險行為。由於疲勞駕駛之資料僅佔駕駛資訊的一小部分，具有高度不平衡的特性，本研究針對真值標記後之車輛動態數據，將數據以 SMOTE 進行數據不平衡處理後，使用支持向量機、隨機森林、啟動時間序列模型 (InceptionTime) 及堆疊式長短期記憶模型 (Stacked-LSTM) 等四種機器學習模型進行分析，結果顯示，應用 SMOTE 方法之四種模型，雖正確率達到 0.96，但模型對於疲勞駕駛風格並不具有辨識能力。因此本研究提出採用滑動時間窗格放大目標樣本並建立時間序列資料，進行數據不平衡之預處理，利用啟動時間序列模型及堆疊式長短期記憶模型深度學習方

-
1. 本研究承和欣客運公司、科技部專題計畫 (MOST109-2410-H-006-117-)、教育部「高教深耕計畫」以及成功大學「Fintech 商創研究中心」支持，謹以致謝。
 2. 國立成功大學交通管理系教授，國立成功大學 Fintech 商創研究中心，通訊作者（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. 國立成功大學電信管理研究所碩士。
 4. 國立清華大學工業工程與工程管理碩士。
 5. 國立成功大學交通管理系學士。

法進行模型訓練，學習危險行為與疲勞駕駛事件間的關聯，以利用車輛動態資料的標記達到預判即將發生疲勞駕駛事件。利用滑動時間窗格方法之深度學習模型，啟動時間序列模型獲得 0.7763 之準確度，但其 F1-score 則為 0.791，比 SMOTE 處理過的模型平均 F1-score 約 0.5 更高。代表其應用滑動窗格方法之深度學習模型，已可成功萃取與疲勞駕駛相關之特徵，並可穩定獲得七成以上正確率。

關鍵詞： 疲勞駕駛、駕駛行為辨識、深度學習、資料不平衡、時間序列分類

ABSTRACT

Fatigue or drowsy driving is one of the major concerns for road transport safety. Statistics show that more than 70% of vehicle accidents come from risky driving behaviors, including fatigue driving. Drowsy driving is hard to be detected by inspecting the vehicle dynamic data because it accounts for very small proportion, hence it is highly data imbalanced. Synthetic minority oversampling technique (SMOTE) is applied to preprocessing the vehicle dynamics data, which is labeled by the fleet manager, for the data imbalance issue. Four machine learning models are applied for predicting drowsy driving including support vector machine (SVM), random forest, InceptionTime, and Stacked-LSTM. Results show that although the average accuracy is 0.96 of these four models by using SMOTE, however, it cannot identify drowsy driving correctly. To more accurate predict the drowsy driving events by using the vehicle dynamic data, a time window slicing combining with target sample augmentation method is proposed for the data imbalance preprocessing issue. InceptionTime and Stacked-LSTM models are applied for training and learning the correlations within the vehicle dynamic data and drowsy driving style. Experiment results show the accuracy of proposed sliding window method with InceptionTime model is 0.7763, the F1-score is 0.791 which is better than the models using SMOTE method with the average F1-score 0.5. With the proposed sliding window method, it helps the deep learning models to better predict the drowsy driving.

Key Words : *Drowsy Driving, Fatigue Driving, Driving Behavior Recognition, Deep Learning, Data Imbalance, Time Series Classification*

一、簡 介

1.1 研究背景

近年來運輸安全的議題逐漸受到大眾重視，根據 WHO^[1] 統計，每年約有一億人因交

通意外而傷殘，其對於一國國內生產總值的影響可達 3% 之譜，到 2030 年，WHO 更預估交通意外會成為人類第七大死因。在多次的意外事故中，疲勞駕駛造成的重大傷亡屢屢浮上新聞版面，根據德國統計局 2018 年資料，過度疲勞在所有個人受傷事故占比大約 0.7%，而在死亡事故中則為 1.2% 左右。國內公路總局亦統計超過 7 成事故來自大客車駕駛的危險行為，其中包含疲勞駕駛。研究顯示疲勞衍生之後果如分心、無法集中注意力等現象造成 25 至 30% 的道路交通事故^[2]。由此可知，因疲勞駕駛所造成的交通意外實屬國內外運輸環境中一大隱憂，產官學界莫不投注極大心力制定防止職業駕駛過勞的法規，或是進行相關偵測、預警系統的開發，期望能降低駕駛人疲勞駕駛的狀況發生，或是在事件發生前給予告警以降低危害發生機率。

1.2 研究動機

目前市面上有多款疲勞駕駛偵測器問世，包括 PAPAGO 公司所推出的 FW-100 型疲勞駕駛警示器，利用眨眼監控、臉部識別以及眼鏡偵測的方式判斷駕駛員是否有疲勞現象並提供示警。臺北市公共運輸處亦於 2018 年開始於市區公車裝設疲勞駕駛偵測器，當發生頭部偏移、雙手離開方向盤、撥打手機等不當駕車行為時，系統便會發出警示音提醒駕駛員。惟這些裝備成本高昂，且藉由影像辨識判斷駕駛行為亦引發隱私權問題，導致感測器受到破壞、鏡頭被撥移，或是駕駛員使用帽子等配件遮擋等行為導致效率不彰。同時，影像辨識所需之器材、設備、技術在一般商用車隊裝設的車機難以運用，導致此疲勞駕駛偵測器在實用性層面上還有很大改善空間。

針對疲勞駕駛真值難以取得，本研究認為現有文獻針對判斷疲勞駕駛與否所需的時間區段過長，若將同一筆時間區段切分成數個相同長度的，更短的時間序列，則可以藉由增大資料量的方式克服疲勞駕駛真值難以取得，以致研究結果品質不佳的問題。學界提出以車輛動態資料作為判斷基礎，配合現今車輛配備多種如：OBD-II (On-Board Diagnostics)、CAN bus (Controller Area Network-BUS) 等資料源，智慧型手機裝置亦具備慣性測量單元與 GPS 等硬體設備，車輛資料的取得成本大幅降低，資料蒐集的品質與效率亦得以確保，相關研究期待透過特定駕駛行為導致的車輛運行特徵辨別出疲勞駕駛行為。但目前針對車輛動態分析結果多侷限於事後針對一整趟旅次的駕駛風格標記，即所謂批次管理，缺乏即時告警功能，故本研究欲提出一能整合於目前車機設備、改善穿透率低與成本高昂問題，同時達到即時預警功能的判斷模型。

1.3 研究目的

本研究將比較數種機器學習模型，透過將車機紀錄的車輛動態資料當作輸入值，藉由訓練成果判斷駕駛員是否發生疲勞駕駛現象而能提供示警。該模型使用車機資料當作輸入值取代傳統影像辨識，以現有設備即可達到預期效果而改善疲勞偵測器成本高昂、隱私權侵犯的問題。同時，考慮到目前文獻多著重於旅次結束後，針對該批次車輛資料進行歷史

分析，缺乏即時性告警的功能。為了提供即時性的提示功能，本研究嘗試把蒐集得知之車輛動態資料切分成不同時間長度的判斷區段，藉由實驗驗證本研究提出的深度學習模型達到即時告警功能所需的最短判斷時間序列，當判斷時間壓縮得越小，本研究之深度學習模型即可在一趟旅次中更新車輛動態資料越多次，並同時的判斷疲勞駕駛與否，未來若運用在商業車隊車機上，當駕駛員出現疲勞現象，與本研究提出之模型結合之車機可達到快速告警功能，減少因判斷時間過長導致危險駕駛行為持續，意外發生機會上升的風險；另當資料同步上傳雲端並使用該模型判斷後，車隊運轉中心也可即時介入處置，維護乘客及全體用路者之安全。使用深度學習模型使輸入資料源更加具有彈性，本研究期待藉由納入更多資料判斷，增加對疲勞駕駛事件的辨識度與準確性，解決市面上設備穿透率不高的缺陷，同時可以提供多樣的前端預警裝置可行方案，將本研究訓練的深度學習模型整合到如：手機 APP 等更易親近的運用裝置。

在駕駛過程當中疲勞駕駛風格 (Drowsy) 並非是經常性出現的駕駛風格，因此每趟旅次中之動態資料容易出現類別比例懸殊的資料不平衡問題，導致模型傾向選擇數量較多的類別；又因非疲勞駕駛狀態與正常駕駛狀態之駕駛行為，在短時間內之駕駛行為表徵類似，因此許多機器學習或深度學習方法，若本身並未考慮時間之連續性以及資料平衡問題，可能導致模型獲得高準確度，但召回率卻低下之狀況發生，代表該模型並不具備辨識能力以及可信度；因此本研究先將資料進行前處理，調整各類別的數據量，解決資料不平衡狀態期望可在資料比例懸殊狀況下，獲得更佳分類效果。

二、文獻回顧

2.1 車輛資料與疲勞駕駛

Lee 等人^[3] 選取根據過往研究顯示疲勞駕駛人與一般人行為差距最為顯著的幾項指標，且這些指標可以輕易地藉由模擬器或是實車實驗獲取，並計算出這些數值的平均數、標準差、全距等作為探討之用。該篇文獻使用 KATECH 的車輛模擬器，受測駕駛實驗前一晚上不休息以呈現疲憊的狀態，實驗內容要求受測者進行約 30 到 40 分鐘，長度為 80 公里的駕駛實驗，並且將環境設定為無其他車輛以營造容易瞌睡的好發情境，過程中蒐集包括：速度、以引擎轉速、煞車、油門位置、方向盤角度、車體偏移量等資料，最後得到 7 筆可以使用的資料集。根據上述蒐集的車輛動態資料，實驗結果偵測率約為 88%，且同時提到亦有若干特徵值與疲勞駕駛、瞌睡事件相關，包括：對於方向盤微幅調整的次數減少；對於車輛控制的動作減少；操作次數減少，但會突然發生大幅度的方向盤操作角度等，上述特徵於其他文獻亦有提及，本文選用他篇較易理解之圖示如圖 1。最後該文獻提出蒐集車輛動態資料判定疲勞駕駛具有一定判斷率，為正常駕駛中亦有可能出現預先設定的疲勞駕駛行為模式，導致當正常駕駛事件次數上升時，偵測率降低，若使用個人化演算法或引入擴增實境 (Augmented Reality, AR) 技術於車道偏移警示系統 (Lane Departure

Warning System, LDWS) 或前方碰撞警示系統 (Forward Collision Warning System, FCWS) 等服務上，對於疲勞駕駛事件的預警將更有助益。




圖 1 碰撞前方向盤較度變化 (資料來源：Ashouri 等人^[4])

Ashouri 等人^[4]藉由辨識車輛操控變數在時間延遲與頻率兩面向以找出適合快速偵測因疲勞駕駛所引起的瀕臨撞擊 (near crash) 與撞擊 (crash) 事件。該篇文獻亦闡述使用車輛動態資料相較於生理監測或影像辨識方法具有幾項優點，包括：目前車輛皆配備各式樣偵測裝置，資料來源充足；不必安裝具有侵入性或隱私侵害問題的偵測器；可用來偵測其他如酒駕、吸毒、憤怒等有害行車安全的行為。當輸入方向盤角度數值時會輸出車輛偏移率、偏移角度及車輛在車道中的橫向位置，藉由公車模擬器實驗，作者發現高階變數比起低階變數有較好的疲勞駕駛辨識作用，原因為高階變數有較長的前置判斷時間與次數資料。該文獻發現在偵測駕駛過度反應行為時，方向盤角度及車輛偏移率比車輛偏移角度快約 1.1 秒，比車輛橫向位置快約 2 秒，如圖 2 所示。另方向盤角度劇烈變動的頻率亦為偵測疲勞駕駛事件一大條件，另由於此變動受到車輛動態的影響，對於低階變數如車輛橫向位置影響幅度較小，如在圖 3 中，碰撞發生前 60 秒方向盤角度的振幅與偏移率的頻率經過正規化後分別為 0.8 與 0.6，而偏移角度與車輛橫向位置的變動頻率經正規化僅 0.1 與 0.05。因此，作者認為由於方向盤角度與車輛偏移率等變數具有時間延遲低且頻率變動資料較顯著的優點，因此車輛之動態數據，以及車輛之車輛偏移與橫向移動幅度，適合作為偵測因疲勞駕駛所引起的瀕臨撞擊與撞擊事件；而本研究利用 GPS 動態數據，作為車輛橫向偏移之依據，偵測車輛橫向偏移之幅度，作為模型訓練之輸入數據，期望可獲得高準確度之預測結果。




圖 2 車輛操控變數偵測時間差 (資料來源：Ashouri 等人^[4])

2.2 深度學習於車輛動態資料的運用

Saleh 等人^[5] 運用堆疊式長短期記憶模型 (Stacked-LSTM)，以智慧手機內部感測器所蒐集的駕駛數據為輸入，將駕駛行為分成正常、躁進、疲勞三類。文獻提及長短期記憶模型能完整的運用、詮釋不同車輛動態資料偵測源間在不同時間點的相依性與相關性，且針對傳統時間序列處理模型 RNN 解決其梯度消失問題，故適合作為車輛資料的處理分析模型。實驗結果使用仿真駕駛行為分析及分類資料集 UAH-DRIVESET 來評估，其 F1 評估分數達到 91%，與最相近的分類模型進步約 10%。該文獻所蒐集的車輛動態資料包括：x、




圖 3 疲勞駕駛對車輛動態資料影響 (資料來源：Ashouri 等人^[4])

y、z 三方向的加速度；滾動角度 (roll)；水平變化角度 (pitch)；偏移角度 (yaw)；GPS 偵測器得到車輛速度；相機偵測與前車距離及附近車輛數等。該文獻模型具有兩層記憶細胞層，每層有 100 個隱藏神經元，資料部分將 70%學習，30%進行測試。為了驗證堆疊式長短期記憶模型的結果，作者另外使用同一筆資料訓練決策樹模型及以類神經網路為基底的多層感知器 (Multilayer Perceptron, MLP) 模型，發現堆疊式長短期記憶模型相較兩者皆具

有較佳的 F1 分數。另該文獻亦將此模型與 UAH-DRIVESET 中的分類分數做比較，發現堆疊式長短期記憶模型在正陽性中分數高，偽陽性分數低，顯示堆疊式長短期記憶模型運用在車輛動態資料上具有較佳的結果呈現。

Jia 等人^[6]在 2020 年提出一種基於長短期記憶模型 (LSTM) 和卷積神經網路 (CNN) 的識別模型，來區分異常駕駛行為，該研究根據美國運輸安全管理局的數據，將數據集區分為急加減速、急左右偏與正常駕駛等五個類別，再將數據以 LSTM-CNN 模型進行深度學習。該研究首先將車輛的行駛數據，以極值點檢測法計算出極端加減速點，將數據集區分為五個類別，分為訓練樣本集，再將訓練集輸入到 LSTM 網絡中以進行特徵提取，由於該數據是在不同時間點下，每個維度的特徵值，相當於一個數據矩陣，因此 LSTM 的輸出可轉換為數據矩陣輸入至 CNN。最後，將 LSTM 的輸出作為 CNN 的輸入作為特徵提取之後，以 SoftMax 函數計算樣本數據所屬之駕駛行為類別。為了驗證 LSTM-CNN 深度學習算法的效率，該研究同時使用相同數據訓練單層 LSTM，結果顯示 LSTM-CNN 的準確度、損失函數以及測量模型準確度的 ROC 曲線皆優於 LSTM 網絡。

周建成^[7]針對電動車車隊的電動車相關資料，配合機器學習以及深度學習的方式，處理龐大且多樣的駕駛行為資料，針對駕駛者之駕駛行為進行分析，了解駕駛行為及能源消耗之間之關聯，更可進一步解決駕駛人必須隨時注意當前電池剩餘電量是否可到達下個充電站之里程焦慮問題；該研究利用增長層級式自我組織映射 (Growing Hierarchical Self-Organizing Map, GHSOM) 與深度遞歸類神經網路 (Deep Recurrent Neural Network, DRNN) 進行模型的建立，使用先分群再分類的概念，先利用 GHSOM 進行分群後，根據分群結果進行標記，再將模型利用 DRNN 進行分類，並且使用機器學習之 (Support Vector Machine, SVM) 進行比較，最後實驗模型出平均高達 90% 的辨識率。

陳柏瑋^[8]利用將搭載全球定位系統 (Global Positioning System, GPS)、加速度計、陀螺儀等感測器之車上單元 (On-Board Unit, OBU) 安裝於機車上，機車的相關感測資訊可以透過此 OBU 上的物聯網通訊模組 (NB-IoT) 上傳至雲端，後續配合深度學習自動編碼器 (AutoEncoder) 以及過採樣合成法 (Synthetic Minority Over-sampling Technique, SMOTE)，針對原始資料進行資料重疊以及資料預處理，接著利用隨機森林分類法 (Random Forest) 針對縱向事件以及橫向事件加以分析，評估出該駕駛事件是安全或是危險；其最後實驗結果，Random Forest 模型正確率於縱向及橫向事件辨識正確率皆可達 93% 以上。

2.3 小結

綜合上述車輛動態資料與疲勞駕駛關聯以及深度學習模型於車輛資料分析上運用的文獻回顧，針對疲勞駕駛之相關研究，多以生理監測以及影像辨識為主，相比於先進駕駛輔助系統 (Advanced Driver Assistance System, ADAS) 動態車輛資料，雖可避免安裝具有侵入性或隱私侵害問題的偵測器，但並非所有大客車業者所裝設之車機，皆為具備 ADAS 功能之車機；而國內依「道路交通安全規則」第 39-1 條第十八項規定^[9]，營業大客車、

總重量八噸以上貨車，根據法規都須裝設可記錄車輛瞬間速度、行駛時間、行車距離等內容的行車紀錄器。因此可確定各家大客車業者，皆裝設有 GPS 記錄設備，因此本研究採用 GPS 數據做為後續深度學習模型之輸入數據。

本研究預計使用深度學習模型餵入車輛動態資料以進行疲勞駕駛的偵測與即時預警目標皆獲得相關依據。我們確定從各種偵測端及車機蒐集得之車輛動態資料，當其具有在頻率、變動幅度等面向上一定特徵時，其與疲勞駕駛事件具有一定程度的相關性，我們得以藉由分析、確認這些特徵值而即時判斷疲勞事件的發生。

此外本研究亦將實驗分為兩部分，機器學習為利用正規化之車輛動態數據應用於支持向量機 (SVM) 以及隨機森林 (Random Forest) 兩種機器學習方法，而因車輛動態數據之間具有時間上之相關性，而機器學習之機器學習方法，無法直接餵入時間窗格滑動處理後之時間序列資料，因此本研究之深度學習，利用堆疊式長短期記憶模型 (Stacked-LSTM) 以及啟動時間序列模型 (InceptionTime) 二種深度學習方法，配合時間窗格滑動後之時間序列資料進行模型訓練以及比較其分類效能。

三、研究方法

以適合的深度學習模型配合車輛動態資料為本研究核心的進行條件，為了選取適合的模型進行訓練，本研究實際訪問資料源國內某國道客運業者，發現車機資料紀錄中確實存在疲勞駕駛所引發的動態資料特徵。在疲勞駕駛事件發生前及存續時間序列中，對於車輛輕微控制的次數降低，並通常伴隨突然間大幅度的動態資料變化，推測為駕駛從疲勞中驚醒，為了避免車輛失控所致，而上述特徵亦於第二章文獻回顧中得到論證、支持；鑒於 2.2 節中許多駕駛風格以及駕駛行為相關文獻皆採用隨機森林等機器學習方法，深度學習方面則時常使用 RNN (Recurrent Neural Network) 以及 CNN (Convolutional Neural Networks) 進行深度學習模型訓練，因此本研究於機器學習方面選用常見之支持向量機以及隨機森林等二種機器學習方法；深度學習方面，本研究參考 Saleh 等人^[5] 以及 Jia 等人^[6] 研究方法，採用 RNN 中專門解決時間序列問題之堆疊式長短期記憶模型 (Stacked-LSTM)，並參考 Fawaz 等人^[10] 之文獻中 CNN 中較新且可具備稀疏性與高計算效能之 Inception 神經網路結構，作為本研究之深度學習模型建立方法。

3.1 機器學習模型選擇

支持向量機 (SVM) 是一種監督式的學習方法，用統計風險最小化的原則來估計一個分類的超平面 (hyperplane)，其基礎的概念是找到一個決策邊界讓兩類之間的邊界最大化，使其可以完美區隔開來。隨機森林 (Random Forest) 為利用集成學習 (Ensemble learning) 中 Bootstrap Aggregating (Bagging) 的方式解決單一決策樹過度擬合 (over-fitting) 的問題。而其中決策樹的演算法則沒有限制、需視資料而定。其優點為可以在決定樣本類

別時，評估變數的重要性。此外，隨機森林可以處理大量的輸入變數、且模型訓練快速。

兩機器學習方法各有其優勢，支持向量機擅長針對高維度特徵的資料進行分類，並且分類之準確度以及模型泛化能力皆佳；隨機森林具備強大之抗干擾能力，即使資料存在缺失值或有資料不平衡之狀況時，皆可抗過度擬合以及抗干擾的能力。鑑於支持向量機以及隨機森林為駕駛行為及駕駛風格相關研究中時常使用之機器學習方法，因此本研究選擇此二機器學習方法與本研究所使用之 Stacked-LSTM、InceptionTime 深度學習方法進行比較。

3.2 深度學習模型選擇

3.2.1 堆疊式長短期記憶模型 (Stacked-LSTM)

疲勞特徵與時間序列高度相關。本研究在考慮不同動態資料之間具有先後的相關性，並閱讀相關文獻資料後，採用堆疊式長短期記憶模型作為車輛動態資料處理模型。堆疊式長短期記憶模型具有傳統 RNN 模型可處理時間序列資料的優點，同時其亦改進 RNN 中梯度消失的問題，藉由增加記憶細胞負責記憶流入當下位置的資訊，以及細胞單元為具有不同閘門決定多少的資訊可以流入或流出細胞中，解決當類神經網路架構增加，上層誤差梯度無法傳遞至下一層以更新權重參數，使誤差梯度在上層網路中為零的狀況。

在某國道客運中，總共定義出 37 種危險行為定義，惟部分與車輛動態資料關聯較低，故本研究選取其中 17 種與駕駛行為直接相關的危險行為作為樣本。本研究使用 Embedding 層來降低表示單個危險行為的維度，如此可節省記憶空間。最後本研究架構兩層 LSTM 層，分別有 30 及 100 個神經元，最後以 Dense 層將結果合而為一，架構如下圖 4 所示，




圖 4 本研究 Stacked-LSTM 架構圖

激活函數採用 sigmoid，損失函數為交叉熵損失函式 (binary_crossentropy) (參考式 1, 2)，最後以 Adam 當作優化器。Sigmoid 函數如下圖 5 所示，其微分最大值僅有 1/4，因此每一層至少都會被壓縮為原本的 1/4，通過兩層後為 1/16，隨著層數增加越來越接近 0；交叉熵損失函式多用於二分類，其函式如下所示，通常多是與 Sigmoid 配合使用；Adam 優化器是對隨機梯度下降 (Stochastic gradient descent, SGD) 的優化算法，具備計算效率高、記憶體需求較少、適合較大量之數據集運算、引數的更新不受梯度的伸縮變換影響等優點，在多數情況下為效能優秀之優化器。

$$loss = -\sum_{i=1}^n \hat{y}_i \log y_i + (1 - \hat{y}_i) \log(1 - y_i) \quad (1)$$

$$\frac{\partial loss}{\partial y} = -\sum_{i=1}^n \frac{\hat{y}_i}{y_i} - \frac{1-\hat{y}_i}{1-y_i} \quad (2)$$




圖 5 Sigmoid 函數示意圖

3.2.2 啟動時間序列模型 (InceptionTime)

啟動時間序列模型是一個基於深度卷積神經網路 (Convolutional Neural Networks, CNN) 的深度學習模型，利用將五個基於 Time Series Classification (TSC) 的 Inception 模組層疊組合的模型^[10]，針對時間序列數據具有良好效能，而本研究第二階段採用時間序列數據，因此選用啟動時間序列模型作為本研究之深度學習模型之一。啟動時間序列模型每個單獨的分類器模型將具有完全相同的架構，基本結構是將 CNN 中的卷積層以及池化層進行堆疊，經由卷積層萃取輸入的特徵資訊，利用 Bottleneck Layer 對卷積核的並行進行合併，達到在同一層中就可以萃取出稀疏以及非稀疏之特徵，隨後利用池化層，以減少空

間大小，有效防止過度擬合。但具有不同的隨機初始化的權重值。Inception 模組的核心思想是將多個過濾器同時應用於輸入時間序列，濾波器可以利用神經網絡從長、短時間序列中自動提取相關特徵，而啟動時間序列模型的計算複雜性則隨著訓練集的大小以及時間長度而線性增長。




圖 6 應用於時間序列之啟動時間序列深度學習模型 (資料來源：Fawaz 等人^[10])

3.3 車輛動態資料與危險行為

本研究參考科技部計畫「車輛安全駕駛與駕駛行為巨量資料分析之研發」結案報告書^[11]，該報告將巨量資料分析架構分為五層，如圖 7。現今車機蒐集車輛運行數據後，便會依定義將其轉換回相對應的車輛動態特徵，即是圖 7 中第三層的資料層級。選用經過轉換的危險行為資料而非只經清洗過的動態資料當作輸入值，除了可降低運算須處理的資料量，又危險行為本身即由車輛動態資料專換，仍保有原始資料的車輛移動特徵，與本研究欲藉此預警疲勞事件的初衷相符，也可無縫與車機運作結合，達到改善疲勞偵測器穿透率不佳的問題，因此，本研究即根據車機紀錄之第三層危險行為，配合車機打瞌睡紀錄標記為疲勞駕駛真值以作為深度學習模型之輸入值。相關危險行為定義可參照本文表 1。

表 1 危險行為之定義 (由國內某國道客運業者公司提供)

事件	警示條件
車道偏移 (左)	由 MOBILEYE 軟體設定
車道偏移 (右)	
前車碰撞	
行人警示	
未保安全距離	
mobileye 鏡頭異常	
mobileye 主機異常	
疲勞駕駛事件	車速 $\geq 60\text{km}$ ，且變化量 $\geq 30\text{km}$ ，且持續 30 分鐘
輕微超速	時速 $\geq 107\text{km/h}$ 且 $< 120\text{km/h}$ 持續 3 秒鐘
嚴重超速	時速 $\geq 120\text{km/h}$ ，且持續 3 秒鐘
低速行駛	時速介於 $85\text{km/h} \sim 90\text{km/h}$ ，且前方無車
急加速	時速時大於 70km/h ，且加速度大於等於 3km/h/s
急減速	時速時大於 70km/h ，每秒降速大於 10km/h/s
緊急煞車	每秒降速大於 10km/h/s
DVR 鏡頭訊號遺失	無訊號
DVR 聲音訊號遺失	無聲音




圖 7 巨量資料分析架構圖 (資料來源：李威勳等人^[11])

3.4 訓練資料處理流程

本研究整理車輛動態資料及訓練深度模型過程中分為幾個步驟進行，分別為：疲勞事件旅次萃取、旅次時間連續化、窗格時間切割及數據不平衡預處理等步驟。由於旅次資料繁雜龐大，為了加速學習過程避免不必要的計算，以及提供一個連續時間窗格使模型得以學習危險行為之前後相依性與疲勞駕駛之間的關聯，我們須藉由車機紀錄資料對完整旅次紀錄進行篩選，並填入與之相對應真值結果，並分入不同的訓練與測試子集合。各步驟詳細說明如下，本研究訓練過程示意如下圖 8 所示，疲勞事件旅次萃取、旅次時間連續化以及窗格時間切割及疲勞事件真值標記等細節將於下面章節說明：




圖 8 資料集資料前處理流程圖

3.4.1 疲勞事件旅次萃取

本研究所使用的國內某國道客運業者車機資料 2018 年的紀錄，被標示的疲勞駕駛事件時間從 2018 年 5 月起至同年 10 月結束，共有 125 筆疲勞駕駛事件。該車機根據定義之危險行為判斷標準將動態資料轉換為各式危險行為，如表 1，而本研究僅採用「疲勞駕駛事件」資料，作為本研究之疲勞駕駛數據。為解決疲勞駕駛真值獲取不易的問題，本研究假設國內某國道客運業者車機定義之疲勞事件為正確可靠的真值，進行訓練深度學習模型。本研究檢視後發現總體資料量極為龐大，然而疲勞事件發生之情況卻甚少，若將所有資料用以訓練，花費時間及資源會十分龐大，訓練結果相較於萃取資料亦不具有太多的優勢，因此本研究根據該旅次是否有疲勞事件進行篩選，若不具有疲勞事件的旅次會予以捨棄，擁有疲勞事件的旅次則保留，保留後的旅次隨後會依據窗格時間大小進行切割，區分該筆訓練資料是否有疲勞事件發生。

在駕駛過程當中疲勞駕駛並非是經常性出現的駕駛風格，因此每趟旅次中之動態資料容易出現類別比例懸殊的資料不平衡問題，導致模型訓練後可能出現傾向選擇數量較多的正常駕駛風格，仍能獲得不錯之預測表現，使得疲勞駕駛風格預測上更為困難；因此本研究使用縮短正常駕駛風格時間長度及利用時間窗格滑動增加數據量，並配合 Inception 神經網路架構進行深度學習，有效解決訓練資料有限狀況下之過度擬合情況，達到更佳之辨識效果。

3.4.2 旅次時間連續化

本研究欲藉由疲勞事件發生前的行為，作為判斷疲勞事件發生的基礎。考量本研究以國內某國道客運業者車機資料作為訓練資料，資料以不連續方式記錄特定駕駛行為發生時間，而部分深度學習模型，輸入資料須為連續之時間序列，因此為訓練固定時間內之駕駛行為資料，必須將客運旅程時間連續化，使得不連續之駕駛行為記錄以連續時間序列呈現，才能進一步進行訓練。本研究採用之國內某國道客運業者車機原始數據中，僅標記表 1 中，由車機所標記之疲勞事件之時間點，本研究將疲勞事件萃取過後的旅次，以一秒為單位將整趟旅程連續化，將旅次開始與結束時間段中間之正常駕駛狀態之真值以 0 補齊，使輸入值除特定時間辨識出的危險行為外，亦包括該趟旅次開始至結束，以每秒為單位的完整時間序列旅次資料，作為深度學習訓練資料，使得一趟旅次以依連續陣列呈現，作為時間序列資料的輸入值。

3.4.3 窗格時間切割及疲勞事件真值標記

透過分析疲勞事件發生前一段時間內之駕駛行為，預測疲勞事件發生，為本研究之目標，考慮到疲勞駕駛非某一特定時間點或短暫時間窗格瞬間發生並且快速結束的突發事件，本研究針對國內某國道客運業者車機事件資料，以疲勞事件結束時間點為基準，往前 30 分鐘為判定時間窗格，將一共 1800 筆以秒為單位的資料，作為一組訓練資料，並標記該組資料為疲勞事件真值。其餘萃取過後的國內某國道客運業者車機資料，則為非疲勞事

件的資料，本研究同樣以 30 分鐘，一共 1800 筆以秒為單位的資料，作為一組非疲勞事件的訓練資料。經過上述處理後，本研究使用包含疲勞及非疲勞事件總共 4081 筆資料，以及每筆資料往前推算 30 分鐘時間空間，共約 4081×1800 (即 7345800) 秒危險行為的紀錄，以之當作訓練深度模型用 x 值，另有 4081 筆疲勞真值資料作為 y 值，疲勞事件發生與否以 0 跟 1 區分，作為本研究機器學習之機器學習模型訓練數據。

3.4.4 資料不平衡處理

本研究先採用 SMOTE 來進行數據不平衡之處理，SMOTE 之原理為應用鄰近演算法，將僅佔少數的樣本資料經由鄰近之數據點之間的連線距離之間，隨機進行新的數據點生成，將正樣本以及負樣本資料比例得以調整至平均狀態^[12]。

另外本研究亦提出另一種資料不平衡處理方法，以下稱為「目標樣本切割放大法」，經由縮短正常駕駛風格之時間長度，以及利用各疲勞事件標記時間區間之 1800 秒，進行滑動窗格，利用滑動 60 次，產生 60 倍之疲勞駕駛時間序列資料，而正常駕駛風格，則由正常駕駛風格數據中，隨機取樣兩倍之數據，亦進行 60 次之時間窗格滑動產生 60 倍數據後，作為本研究深度學習之模型訓練數據，因該方法資料維度較為複雜，因此僅可應用於深度學習模型，無法套用於傳統機器學習模型。

四、模型結果與分析

4.1 訓練資料處理

本研究機器學習使用疲勞事件前 30 分鐘為危險行為分析區間，藉由將車機標示的疲勞事件紀錄時間轉換成 index 值，即可將總共 125 筆疲勞駕駛事件，每筆 1800 秒的時間區段條列出來，如此可以使用 pandas 中的 loc 函數依據先前的時間區段索引車機紀錄的危險行為，並將兩者結合，即得到在疲勞駕駛判斷時間區段內所有與之對應的車輛動態資料。本研究希望在訓練時與對應 y 值有較好的配對，在得到上述判斷時間區段內危險行為資料後，我們將結果真值列為 1，即是有疲勞事件的資料，與真值為 0，即無疲勞事件的資料，分開存入不同的 array 資料型態以利進行後續訓練。

而因機器學習所使用之數據，其中疲勞駕駛狀態僅 125 筆，正常駕駛狀態為 3956 筆，疲勞狀態資料僅佔總體資料 3.06%，比例相當懸殊，導致機器學習模型訓練後分類效果不佳；因此本研究深度學習利用縮短正常駕駛風格時間長度及利用時間窗格滑動增加數據量，再利用其處理過後之數據進行深度學習。

4.2 模型績效指標

模型指標除準確度 (Accuracy) 以外，還需要考慮其他指標如：精準度 (Precision)、召回率 (Recall)、F1 分數 (F1-Score)，F1-score 可看作為模型正確率以及召回率的加權平

均，其最大值為 1，最小值為 0。本研究之績效評估公式如下：

$$Accuracy = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (3)$$

$$Precision = \frac{T_p}{T_p + F_p} \quad (4)$$

$$Recall = \frac{T_p}{T_p + F_n} \quad (5)$$

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (6)$$

表 2 混淆矩陣元素表

	實際為真	實際為假
預測為真	T_p	F_p
預測為假	F_n	T_n

4.3 實驗結果與討論

4.3.1 機器學習

在駕駛過程當中疲勞駕駛風格並非是經常性出現的駕駛風格，因此每趟旅次中之動態資料容易出現類別比例懸殊的資料不平衡問題，導致模型傾向選擇數量較多的類別，而研究之資料分布中疲勞狀態資料僅佔總體資料 3.06%，比例相當懸殊，而因本研究深度學習所採用數據不平衡處理方法，採用滑動時間窗格建立時間序列資料，其資料維度無法直接套用至機器學習之機器學習模型，因此本研究利用 SMOTE，將疲勞狀態資料之比例調整至與正常駕駛為 1：1 之狀態，再輸入 SVM 以及 Random Forest 模型進行分析。

機器學習之研究結果如下表 3 所示，兩種模型在測試階段的正確率皆達到 96% 以上的準確度，且皆穩定收斂，但召回率 (Recall rate) 以及 F1-Score 數值皆為已利用 SMOTE 進行資料不平衡處理後之資料分佈比例之數值，皆約為 0.5；由此可知此 SVM 以及 Random Forest 二機器學習模型，雖已利用 SMOTE 進行資料不平衡處理，但仍無法順利萃取疲勞駕駛之相關特徵，傾向於將結果全數分類為正常駕駛，由此可知，本研究選擇之機器學習模型，在僅使用 GPS 資料做為訓練數據狀況下，並不具備疲勞駕駛之辨識能力，無法正確分類正常駕駛及疲勞駕駛。

4.3.2 深度學習

本研究深度學習採 Stacked-LSTM 以及 InceptionTime 架構進行深度學習訓練。比較經由 SMOTE 方法、以及使用「目標樣本切割放大法」以滑動時間窗格數據不平衡處理，兩

種不同數據不平衡處理方法之數據集進行比較。實驗結果參考下表 3，其中利用 SMOTE 進行數據不平衡處理之模型，雖然深度學習模型 InceptionTime 不管在準確性、精準度、F1 分數三方面都較 Stacked-LSTM, SVM, RandomForest 等三個模型為佳，但總體成績仍無大幅提升，傾向於將結果全數分類為正常駕駛，無法順利萃取疲勞駕駛之相關特徵。

而在使用「目標樣本切割放大法」以滑動窗格建立時間序列進行不平衡處理之數據集中，InceptionTime 以及 Stacked-LSTM 分別獲得 0.7763 以及 0.69 的正確率，大幅度提高了預測的準確度，主要原因推測為 SMOTE 方法僅對目標樣本加以等比例放大，但「目標樣本切割放大法」除了放大目標樣本之外，也同比例的縮減了其他樣本，以求取極少量目標樣本的特徵能夠被深度學習模型給萃取到。

以 InceptionTime 為例說明，其正確率雖然由 0.97 下降為 0.7763，但是召回率由 0.58 提升到 0.782，並且 F1 分數由 0.58 提升為 0.791，顯示本模型不會將所有樣本分類為「正常駕駛」，對於目標樣本（疲勞駕駛）的預測準確度有所升。在實務應用上，若要追求對不平衡的目標樣本預測準確度的需求上，召回率與 F1 分數更具有參考價值。

進一步使用 F1 分數的盒鬚圖來觀察兩種深度學習模型預測的準確度與穩定性，利用 InceptionTime 以及 Stacked-LSTM 進行 3 疊交互驗證之 F1-score 盒鬚圖結果如下圖 9 表示。由圖可知，InceptionTime 模型之跨度較小，且每疊中的 F1 分數皆優於 Stacked-LSTM 模型，由此可知 InceptionTime 對於預測疲勞駕駛之性能以及穩定性皆優於 Stacked-LSTM 模型。

表 3 機器學習與深度學習模型正確率及召回率數值表

模型	Accuracy	Recall	F1-Score
機器學習－SMOTE 處理			
Random Forest	0.9632	0.5	0.4906
SVM	0.9619	0.4993	0.4903
深度學習－SMOTE 處理			
InceptionTime	0.97	0.58	0.58
Stacked-LSTM	0.9559	0.5	0.49
目標樣本切割放大法			
InceptionTime	0.7763	0.782	0.791
Stacked-LSTM	0.69	0.684	0.712

五、結論與建議

駕駛過程當中疲勞駕駛風格並非是經常性出現的駕駛風格，因此每趟旅次中之動態資料容易出現類別比例懸殊的資料不平衡問題，且疲勞或困倦駕駛風格與正常駕駛風格在部




圖 9 InceptionTime 及 Stacked-LSTM 3 疊交互驗證之 F1-score 盒鬚圖

分駕駛行為表徵上非常類似，導致機器學習模型無法成功萃取疲勞駕駛之相關特徵，導致無法正確分類正常駕駛及疲勞駕駛。若實際應用於車機上，可能於實際為疲勞駕駛狀態時，卻辨識為正常駕駛，導致駕駛身處困倦狀態時，卻無法達到示警，使駕駛人無法即時應變，而使得駕駛身處危險。

本研究採用除採機器學習以及深度學習兩種模型以外，於深度學習模型亦同時採用 SMOTE 以及本研究所提出之滑動窗格駕駛序列，兩種方法進行數據不平衡處理作為比較；其中採用 SMOTE 之四種模型，雖在正確率上皆達 0.96 以上，但召回率以及 F1-Score 數值皆為已利用 SMOTE 進行資料不平衡處理後之資料分佈比例之數值，代表模型對於疲勞駕駛風格並不具有辨識能力。

因此本研究另外提出利用滑動窗格建立時間序列，應用於深度學習，先將數據經過數據不平衡之預處理後，另以 InceptionTime 以及 Stacked-LSTM 兩種神經網路架構進行深度學習，最後獲得 0.7763 以及 0.69 的準確度，其 F1 分數方面則分別獲得 0.791 以及 0.712，相比使用 SMOTE 方法之模型，使用「目標樣本切割放大法」以滑動時間窗格之深度學習模型可成功萃取與疲勞駕駛相關之特徵。

本研究所蒐集之車輛動態資料，皆可由現行大客車相關法規所規定需強制安裝之 GPS 車機設備獲得，並無增加大量額外裝備的需求，綜合成本面及上述即時性、隱私、外力干擾因素後，將可大幅提升目前疲勞警示器穿透率過低的問題，而本研究之研究資料來自於國內大客車業者之真實數據，相較以往使用國外或不同車種之定義以及數據之研究，更具備可靠性以及本土性。配合本研究提出之深度學習模型完成訓練後，未來疲勞真值資料筆數更為龐大時，可望將判斷時間進一步縮小；而若未來 ADAS 車機更為普及，可經由車機進一步獲取六軸加速規以及方向盤偏移角度等資料，進一步提升模型準確度，將可大幅改

變以往相關研究著重事後之歷史資料分析及批次管理手段，而車機等終端設備加入提示音功能後，更可達到即時警示、提前應變，提升道路運輸安全的目標。

本研究之學習模型未來可結合如手機應用程式，運用以直覺為導向、圖像化的頁面呈現相關疲勞警示資訊，提供駕駛人更易親近，且可及性更高的選擇，同時手機運用程式將可運用在擴及乃至私人運具等不同領域，大程度提升駕駛人對於自身疲勞駕駛的感知。同時，未來若能將躁進駕駛風格 (aggressive) 等駕駛風格納入，形成透過車輛動態資料辨識多種駕駛風格，將可更全面提示駕駛人注意其駕駛狀態，完善國內運輸安全之提升。

參考文獻

1. World Health Organization, "Road Traffic Injuries", <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>, 2022/6/20.
2. Klauer, S. G., Dingus, T. A., Neale, V. L., Sudweeks, J. D., & Ramsey, D. J., The impact of driver inattention on near-crash/crash risk: An Analysis Using the 100-car Naturalistic Driving Study Data, National Highway Traffic Safety Administration, Washington, 2006.
3. Lee, J.-W., Lee, S.-K., Kim, C.-H., Kim, K.-H., and Kwon, O.-C., "Detection of Drowsy Driving Based on Driving Information", Proceedings of IEEE International Conference on Information & Communication Technology Convergence (ICTC), 2014, pp. 607-608.
4. Ashouri, M. R. a. N., A. and Azadi, S., "Time Delay Analysis of Vehicle Handling Variables for Near-Crash Detection of Drowsy Driving Using a Bus Driving Simulator", Proceedings of the 6th RSI International Conference on Robotics and Mechatronics, 2018, pp. 243-249.
5. Saleh, K., Hossny, M., and Nahavandi, S. "Driving Behavior Classification Based on Sensor Data Fusion Using LSTM Recurrent Neural Networks", IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), 2017, pp. 1-6.
6. Jia, S., Hui, F., Li, S., Zhao, X., & Khattak, A. J., "Long Short-Term Memory and Convolutional Neural Network for Abnormal Driving Behaviour Recognition", *IET Intelligent Transport Systems*, Vol.14, Iss.5, 2020, pp.306-312.
7. 周建成，「一個結合增長層級式自我組織映射與深度遞歸類神經網路之混合模型應用於電動車駕駛模式分析」，國立高雄應用科技大學電機工程研究所碩士論文，民國 106 年。
8. 陳柏瑋，「NB-IoT 智慧車載系統於駕駛行為分析之研究」，國立臺灣科技大學電機工程研究所碩士論文，民國 107 年。
9. 交通部，101 年運輸政策白皮書，民國 101 年。
10. Fawaz, H. I., Forestier, G., Weber, J., Idoumghar, L., & Muller, P. A., "Deep Learning for Time Series Classification: A Review", *Data Mining and Knowledge Discovery*, Vol. 33, No. 4, 2019, pp.917-963.

11. 李威勳、周建銘、謝永達、蔡以誠、盧冠宏、蕭至良、邱繼億，**車輛安全駕駛與駕駛行為巨量資料分析之研發**，科技部巨量資料產學共創合作專案計畫報告（MOST 105-2634-F-006-001），民國 105 年。
12. Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P.. “SMOTE: Synthetic Minority Over-sampling Technique”, *Journal of Artificial Intelligence Research*, Vol.16, 2002, pp. 321-357.

機車租賃新規範

出遊代步 停聽看

「機車租賃定型化契約應記載及不得記載事項」
傳統機車、共享機車租賃均適用

租賃機車三原則

- ✓ 租借前充分了解契約內容
- ✓ 取車後，立即檢查車況
- ✓ 依約定地點還車，必要時拍照存證！

規範重點

- 1 業者應於契約中載明租金、租賃費率、租賃期間、營運範圍、還車地點等。
- 2 消費者於取車後一定時間內發現異常，並歸還者，業者不得收取費用。
- 3 發生交通違規，罰鍰由消費者負擔。

機車發生擦撞、毀損、遺失或被盜等情形，也都有規範



新聞稿專區

行政院消費者保護處宣導資訊