

基於多重時空尺度車流資料之 高速公路事故風險 AI 模型評估

AI-Based Assessment of the Relationship Between Multiscale Spatiotemporal Traffic Flow Characteristics and Highway Traffic Accident Risk

洪百賢 Pai-Hsien Hung¹

傅崇逸 Tang-Yi Fu

葉宇婕 Yu-Chien Yeh

賴亭羽 Ting-Yu Lai²

摘要

高速公路是整體運輸系統的重要骨幹，其封閉式交通環境提供較高的車流運行效率，也相對提供區域間的大量運能。但也由於車流速度高且系統封閉，當發生事故時，往往伴隨較嚴重的人車損傷與車輛壅塞等龐大的社會成本。因此，若能改善事故的風險管理對於降低社會成本有明顯的幫助。由於高速公路是封閉的運輸系統，過去的研究也發現車流特性與事故發生有一定程度的關聯性，而傳統的研究大多利用偵測器或小範圍的影像偵測為資料來源。但受限於佈設點位稀疏，難以呈現大範圍的車流特性。透過電子收費系統能獲得所有車輛的旅行資料，並轉換為路段車流特性。本研究利用高速公路電子收費系統原始旅次資料，結合交通事故紀錄，探討國道車流特性與事故發生之相關性，並利用 XGBoost 演算法建立事故風險評估模型。研究結果顯示，將原始旅次資料轉換為速度、流量與密度之時空矩陣後，模型能有效從時空變化角度評估事故風險。而在不同時空尺度組合的比較中，發現「500 公尺×5 分鐘」之模型表現最佳，其 F1-score 達 94.23%，Recall 高達 99.51%，漏判率為 0.49%。若進一步從空間解析度而言，發現 500 公尺之空間尺度較能保留事故前局部的車流特徵，其評估效果優於容易將特徵平均化的 1000 公尺空間尺度。在改善策略的應用方面，本研究將模型輸出之事故發生機率進一步劃分為「極高、高、中、低」四個風險層級，以提升結果的可解讀性。依據前述研究結果，本研究提供交通管理單位在規劃主動式高速公路安全策略時的重要依據。參考模型之預測結果，藉由高解析度車流資料辨識高風險時空單元，並結合即時交通管控措施，如速度管理、動態分流或巡邏調度等方式，以強化國道交通安全管理之實際效益，達成提前預警與預防事故之目標。

關鍵字：高速公路、車流特性、多重時空尺度、事故風險評估

¹ 逢甲大學運輸與物流學系助理教授，407 臺中市西屯區文華路 100 號，電話：04-24517250 分機 4663，E-mail: phhung@fcu.edu.tw。

² 逢甲大學運輸與物流學系四年級學生。

一、前言

高速公路為國內長距離運輸之主要骨幹，具有高車速、高容量及封閉式道路等特性，可有效提升運輸效率。然而，當高速公路發生交通事故時，往往因車速較高及車流密集，不僅容易造成較嚴重之人員傷亡，更可能引發大範圍壅塞、旅行時間增加及龐大的社會成本。因此，如何及早辨識事故發生前的車流狀態，建立有效的事故風險評估機制，已成為智慧交通與道路安全管理的重要課題。

過去高速公路事故相關研究多利用車輛偵測器（Vehicle Detector, VD）分析事故與車流特性之關聯，並以速度、流量、密度等參數建立事故預測模式。然而，此類資料大多屬於定點觀測，受限於偵測器設置位置及空間涵蓋範圍，較難完整呈現事故發生前車流於時間與空間上的連續變化。此外，高速公路交通事故的形成通常受到多項因素交互影響，其關係具有高度非線性與複雜性，傳統統計分析方法較難有效描述各項變數之間的交互作用，亦限制了事故風險預測的準確性。

近年來，人工智慧（Artificial Intelligence, AI）相關應用快速發展，機器學習已廣泛應用於交通安全、事故預測及智慧運輸等領域。其中，極端梯度提升（Extreme Gradient Boosting, XGBoost）具有良好的非線性特徵學習能力、運算效率及泛化能力，能有效處理大量且高維度資料，同時透過梯度提升決策樹逐步修正模型誤差，提升分類效能。相較於傳統方法，XGBoost 更能掌握車流特性與事故發生之間複雜且非線性的關聯，因此近年已成為交通事故預測研究中經常採用之人工智慧模型之一。

另一方面，隨著高速公路電子收費系統全面建置，由高速公路局所開放之 M06A 各旅次路徑原始資料可完整記錄車輛於各門架間之通行資訊，相較於傳統定點式偵測資料，具有較高的時間與空間解析能力。因此，將原始旅次資料轉換為速度、流量及密度等車流特性，並建立不同時間與空間尺度之分析資料，作為人工智慧模型之輸入，以探討不同時空解析度對事故風險評估之影響。

基於上述背景，本研究利用高速公路電子收費系統所提供之 M06A 原始旅次資料結合交通事故資料，以 XGBoost 建立高速公路事故風險評估模型，並比較不同時空尺度組合下模型之預測表現，同時透過模型訓練與參數調整提升事故辨識能力，進一步分析不同尺度下之模型差異與最佳化結果。研究成果可提供交通管理單位建立主動式事故預警機制之參考，並作為智慧交通安全管理及後續 AI 事故預測模型發展的重要依據。

二、文獻回顧

2.1 人工智慧於高速公路事故研究之應用

近年來，隨著智慧型運輸系統及大數據分析技術快速發展，人工智慧已廣泛應用於車流分析、道路安全管理及交通事故預測等領域。交通事故通常受到車流狀態、道路環境及駕駛行為等多項因素共同影響，各項因素間具有非線性及複雜交互關係，因此傳統統計方法較難完整描述事故形成機制，而機器學習技術則能透過大量資料學習變數間的非線性關係，提高事故預測能力。

目前交通事故預測研究多利用事故發生前之速率變化以及速度、流量、密度等車流特性作為模型輸入，建立事故發生機率或事故風險評估模型。You et al. (2017) 利用支持向量機建立即時高速公路事故預測模型，研究指出透過資料平衡及特徵篩選可有效提升模型辨識能力。Bibb et al. (2025)則利用深度神經網路預測交通事故嚴重程度，並透過降維及類別權重改善事故樣本不足造成之模型偏誤。上述研究顯示，人工智慧已逐漸取代部分傳統統計分析方法，成為交通事故預測的重要工具。

2.2 XGBoost 於交通事故風險評估之應用

在眾多機器學習演算法中，XGBoost 因具有高運算效率、良好的泛化能力及優異的分類效能，近年來常應用於交通事故風險評估研究。XGBoost 以梯度提升決策樹為基礎，透過逐步建立多棵決策樹修正模型誤差，並加入正則化機制降低模型過度擬合，使模型兼具預測能力與穩定性。Chen and Guestrin (2016)指出，XGBoost 除具有良好的非線性學習能力外，亦能有效處理高維度資料、缺失值及大量資料，因此相當適合應用於交通大數據分析。Chen et al. (2025) 進一步結合 SMOTE 資料平衡技術與 XGBoost 建立交通事故預測模型，結果顯示可有效改善事故樣本不平衡問題，提升模型之準確率與召回率。

由於高速公路事故資料具有事故樣本比例低、資料量龐大及交通特徵關係複雜等特性，因此需要兼具分類能力及處理非線性資料能力之模型。綜合相關研究可知，XGBoost 能有效分析車流特性與事故風險間之關聯，因此本研究選用 XGBoost 作為高速公路事故風險評估模型。

2.3 M06A 原始旅次資料介紹

高速公路電子收費交通資料蒐集系統 (Traffic Data Collection System, TDCS) 所提供之 M06A 各旅次路徑原始資料，主要記錄車輛於高速公路通行期間之完整旅次資訊，包括起迄門架、通行時間、車種、旅次距離及各門架通行紀錄等資料。相較於 VD 僅能取得固定地點之交通資訊，M06A 資料可完整保留車輛於高速公路行駛過程之時間與空間資訊，能更完整反映車流變化情形。

2.4 小結

綜合上述文獻可知，人工智慧已廣泛應用於交通事故預測，其中 XGBoost 具備優異的非線性特徵學習能力、分類效能及大規模資料處理能力，適合作為高速公路事故風險評估模型。此外，M06A 原始旅次資料能提供完整且連續的車流時空資訊，可建立不同時間與空間尺度之速度、流量及密度等車流特性。因此，本研究利用 M06A 原始旅次資料結合交通事故資料，建構不同時空尺度之車流特性，並以 XGBoost 建立高速公路事故風險評估模型，比較不同時空尺度下之模型預測表現，以探討最佳之事故風險評估模式。

表 1 M06A 原始旅次資料欄位說明

英文名稱	中文名稱	資料範例	定義
VehicleType	車種	31	31 小客車、32 小貨車、41 大客車、42 大貨車、5 聯結車
DetectionTimeO	起點時間	下午 11：43：15	旅次中通過第 1 個門架時間
GantryO	起點門架	01F3398N	旅次中通過第 1 個門架編號
DetectionTimeD	迄點時間	下午 11：43：15	旅次中通過最後 1 個門架時間
GantryD	迄點門架	01F3398N	旅次中通過最後 1 個門架編號
TripLength	旅次距離長度，單位為公里	4	
TripEnd	旅次標記(Y 正常結束，N 異常)	Y	Y 正常結束，N 異常
TripInformation	本旅次經過的各門架之通過時間及門架編號	2018-08-19 23:43:15+01F3398N	

M06A 資料中的 TripInformation 欄位可還原車輛完整行駛路徑與通過門架時間，進一步推估區間旅行時間及平均速度、流量及密度等車流特性，可應用於交通壅塞分析及交通安全等相關研究。此外，M06A 資料可依不同時間與空間尺度建立車流特性資料，相較於定點式交通資料，更能呈現事故發生前之時空變化，因此適合作為 AI 模型的輸入資料，以提升高速公路事故風險評估能力。

三、研究方法

3.1 模型輸入資料蒐集及建構

本研究以高速公路局開放之 2023 年 M06A 原始旅次資料作為主要資料來源。M06A 資料為車輛於高速公路行駛過程中通過各電子收費門架所蒐集之旅次資料，可利用車輛通過不同門架之時間與空間資訊還原車輛行駛路徑，進一步推估相鄰門架間之旅行時間與個體行駛速率，作為後續車流特性分析之基礎。此外，本研究結合高速公路交通事故資料，將事故發生時間、位置、行駛方向等資訊與車流特性資料進行空間與時間上的對應，以建構事故風險評估之分析資料。

為確保 M06A 資料品質與後續分析結果之可靠性，本研究首先針對原始旅次資料進行篩選與預處理，主要包含路線一致性、行駛方向一致性、速率合理性及旅次資訊完整性等原則。首先，在路線一致性方面，考量本研究分析範圍為國道一號主線，僅保留單一旅次中全部通行門架皆屬於「01F」之旅次資料。若單一旅次包含非「01F」門架，例如經由交流道轉換至其他道路之紀錄，則予以排除，以確保所有分析樣本皆屬於國道一號主線路段。

其次，在行駛方向方面，僅保留方向一致之旅次，並將資料依北向（N）與南向（S）分別處理，以避免不同方向之車流特性相互混合，維持後續分析之空間與方向一致性。接者，在速率合理性方面，利用相鄰門架間之空間距離與車輛通行時

間推估個體行駛速率，並設定合理之速率範圍。最低速率設定為 5 km/h，低於此門檻之樣本可能涉及車輛於服務區、休息區或其他非正常停滯情形，因此予以排除；最高速率設定為 160 km/h，高於此門檻之樣本則可能為系統感應誤差或時間戳記異常，亦予以剔除。透過上述篩選，可降低異常旅次對後續車流特性計算與模型分析結果之影響。另一方面，凡符合合理速率範圍之低速或壅塞行駛樣本均予以保留，以避免過度篩選而無法反映國道實際交通狀況。

完成 M06A 資料篩選後，利用車輛通過不同 eTag 門架之時間與空間位置資訊重建車輛行駛軌跡，並取得相鄰 eTag 門架間之行駛時間與速率資訊，再依據不同時間與空間解析度進行資料整合與彙整，以建立具時空特性之車流資料。

事故資料部分，原始資料包含事故時間、事故地點、道路類型、行車方向及其他事故相關資訊。考量本研究主要目的為將事故事件與車流特性資料進行對應，因此針對時間、道路路線、行駛方向及空間位置等欄位進行整理與轉換。時間資訊利用事故資料中的「發生日期」與「發生時間」欄位，篩選 2023 年間之事故紀錄，並將日期與時間合併為「事故發生時間」欄位，以利後續與不同時間尺度之車流特性資料進行匹配。

道路路線則利用「2-2.發生一路線—公路(國道/省道/縣道/鄉道)」欄位進行篩選，僅保留發生於國道一號之事故資料，以排除非本研究範圍內之道路事故。行駛方向則利用「2-2.發生一路線—車道方向(國道/省道/縣道/鄉道)」欄位區分南向與北向事故資料，以對應後續建立之不同方向車流特性資料。空間位置則利用「2-2.發生一路線—公里處」及「2-2.發生一路線—公尺處」欄位取得事故位置，並將兩者整合轉換為「公里點位(km)」欄位，以利後續與車流特性資料之空間區段進行匹配。例如，當事故資料中公里處為 323 公里、公尺處為 200 公尺時，經轉換後之事故位置為 323.2 km。

完成 M06A 與事故資料之整理後，考量事故發生前不同路段與時段所呈現之車流特性可能存在差異，本研究依據不同時間與空間解析度進行資料整合，建立具時空特性之車流資料。時間尺度分別設定為 5 分鐘與 10 分鐘，空間尺度則設定為 500 公尺與 1000 公尺，並建立 500 公尺×5 分鐘、1000 公尺×5 分鐘及 500 公尺×10 分鐘三種時空尺度組合，以比較不同時空尺度下之車流特性資料對事故風險評估模型表現之影響。

完成各時空尺度資料建構後，針對每一時空單元計算相關車流特性，包括速度、流量及密度，以反映不同路段與時段之交通狀態。接著依據事故資料所提供之發生時間、道路方向及公里位置，進行事故事件與車流資料之對應。當事故發生時間、行駛方向及公里點位皆能與車流特性資料中的相同時空單元相互對應時，則將該時空單元標記為事故樣本「1」，代表該時空範圍內發生事故事件；反之，若車流特性資料之時空單元未與任何事故資料匹配，則標記為非事故樣本「0」，代表該時段與路段未發生事故。

透過上述資料篩選、清理、時空尺度建構及事故標記流程，最終建立包含速度、流量、密度及事故標籤之分析資料集，作為後續事故風險評估模型之輸入資料與模型建置基礎，整體資料建構流程如圖 1 所示。




圖 1 模型輸入資料建構流程

經由上述資料處理流程後，整合車流特性變數與事故標記結果，建立供 AI 模型分析使用之事故風險評估資料。該分析資料包含模型輸入所需之特徵，以及作為模型事故分類的判斷依據，可供後續 AI 事故風險評估模型進行訓練、測試與驗證。經上述資料處理與整合後之結果彙整如表 2 所示。

表 2 500 公尺x5 分鐘車流特性結合事故資料整合表

資料類型	欄位定義	資料範例
基本資料	日期時間	2023-01-01 08:25:00
	路段區間	2.0-2.5km
	速度（公里／小時）	95.0
	密度（輛／公里）	3.03
	流量（輛）	288.0
	有無發生事故（0 表該時空無事故）	1
鄰近時空車流特性	事故發生前 5 分鐘 0.5km 處_速度	91.31
	事故發生前 5 分鐘 0.5km 處_密度	3.94
	事故發生前 5 分鐘 0.5km 處_流量	360.0
	事故發生前 10 分鐘 0.5km 處_速度	90.59
	事故發生前 10 分鐘 0.5km 處_密度	3.58
	事故發生前 10 分鐘 0.5km 處_流量	324.0
	事故發生前 5 分鐘 1km 處_速度	91.55
	事故發生前 5 分鐘 1km 處_密度	3.01
	事故發生前 5 分鐘 1km 處_流量	276.0
	事故發生前 10 分鐘 1km 處_速度	88.86
	事故發生前 10 分鐘 1km 處_密度	2.7
	事故發生前 10 分鐘 1km 處_流量	240.0

3.2 XGBoost 事故風險評估模型資料設定及建構流程

本研究採用 XGBoost 演算法建立高速公路事故風險評估模型。首先，讀取已完成建構之時空車流特性矩陣，並依據模型需求整理輸入特徵與事故標記，建立模型訓練所需之資料格式。考量時空車流資料量龐大，模型訓練過程採用分批讀取方式進行，以降低資料處理過程之記憶體使用量。

完成模型輸入資料建立後，將資料依比例切分為訓練集、驗證集及測試集。其中，訓練集用於 XGBoost 模型訓練，使模型學習車流特性與事故發生間之關聯性；驗證集主要用於模型建立過程中的調整，協助選擇較佳的模型參數與模型設定，使模型能達到較佳的分類效果。透過驗證集評估不同模型設定下之表現，可作為模型調整之依據，並降低模型過度依賴訓練資料之情形；測試集則是在模型完成訓練與參數設定後使用，用來檢驗模型面對未參與訓練之資料時的預測表現，以評估模型於事故風險辨識上的實際應用效果。

由於事故樣本數量相較於非事故樣本明顯較少，資料中存在類別不平衡問題，可能使模型偏向預測多數類別。因此，本研究針對訓練集進行樣本平衡處理，保留所有事故樣本，並由非事故樣本中抽取部分資料建立訓練資料，同時計算樣本權重，使模型訓練過程能提高對事故樣本特徵之學習能力。驗證集與測試集則維持原始資料分布，以確保模型評估結果符合實際事故發生情形。

模型訓練過程中，透過驗證集評估不同參數設定下之模型表現，以選擇較佳模型設定；完成模型訓練後，利用測試集進行最終效能評估，並輸出各筆資料之事故發生機率與分類結果。最後，依據模型預測之事故發生機率進行風險程度劃分，區分低、中、高風險等級，作為高速公路事故風險評估與風險辨識之依據。上述模型建構與預測流程如圖 2 所示。




圖 2 模型建構與預測流程

3.2.1 模型輸入資料設定與資料切分

完成時空車流特性矩陣建構後，將其作為 XGBoost 事故風險評估模型之輸入資料。模型輸入資料包含時間區間、路段區間及行車方向等時空資訊，並保留各時空單元內之車流特性變數，包括平均速度、流量及密度等，作為事故風險判斷之重要依據。

為掌握事故發生前之車流變化情形，除納入當下時間與路段範圍內之車流特性外，亦加入事故發生前不同時間間隔及鄰近路段範圍內之車流資訊作為模型特徵。透過建立事故前 5 分鐘、10 分鐘等不同時間尺度，以及不同空間範圍內之速度、流量與密度欄位，使模型能學習事故發生前可能存在之車流特徵。考量高速公路南、北向車流型態可能存在差異，例如交通量、壅塞程度及事故分布情形不同，

因此將不同方向資料分開處理，避免不同方向之車流特性相互混合而影響模型判斷結果。同時，針對不同時間尺度、空間尺度及行車方向組合所建立之資料，分別進行模型訓練與評估，以比較不同時空尺度下對事故風險辨識效果之影響。

在目標變數設定方面，以「有無發生事故」作為模型預測目標，建立二元分類方法。其中，0 代表該時間與路段範圍內未發生事故，1 代表該時間與路段範圍內發生事故。透過輸入車流特徵與事故標記之整合，建立 XGBoost 模型所需之分析資料。

完成模型輸入資料建立後，將資料依比例切分為訓練集、驗證集及測試集，比例分別設定為 60%、20%及 20%。其中，訓練集用於 XGBoost 模型訓練，使模型學習速度、流量、密度及事故前車流特徵與事故發生之間的關聯性；驗證集主要用於模型建立過程中的調整，協助選擇較佳的模型參數與模型設定，並作為觀察模型表現之依據；測試集則於模型完成訓練與參數設定後使用，用以檢驗模型面對未參與訓練資料時之預測表現，評估模型於事故風險辨識上的實際應用效果。

透過上述資料設定與切分方式，使模型訓練、參數調整及最終效能評估階段分別使用切分後之訓練集、驗證集與測試集進行分析，降低模型過度依賴訓練資料之可能性，並提升事故風險評估結果之可靠性。

3.2.2 類別不平衡處理方法

由於高速公路事故屬於低發生率事件，事故樣本數量遠低於非事故樣本，因此模型訓練資料具有類別不平衡特性。若直接使用原始資料進行模型訓練，模型容易偏向學習數量較多之非事故樣本，雖可能獲得較高之整體分類準確率，但對事故樣本之辨識能力有限，進而影響事故風險評估結果。

為改善類別不平衡對模型訓練之影響，本研究於 XGBoost 模型中採用樣本權重調整機制(scale_pos_weight)。其概念係依據事故樣本與非事故樣本之數量比例，提高事故樣本於模型訓練時之權重，使模型在學習過程中更加重視事故樣本。當事故樣本被誤判時，模型將提高對事故樣本之重視程度，使模型更有效地學習事故樣本特徵，進而提升其辨識能力。

例如，若訓練資料包含 10,000 筆非事故樣本及 500 筆事故樣本，則事故樣本數量約為非事故樣本的二十分之一，因此模型訓練時將依據兩類樣本數量比例，提高事故樣本之權重，使事故樣本在模型學習過程中具有較高的重要性，而非僅受樣本數量影響。

透過樣本權重調整，可降低模型偏向非事故類別之情形，使模型更有效學習事故發生前之車流特性，包括速度、流量及密度等車流特性特徵，進而提升事故樣本的辨識能力及事故風險評估之可靠性。

四、事故風險評估模型訓練結果討論

4.1 模型訓練結果

XGBoost 模型進行事故風險評估時，並非直接輸出事故與非事故之分類結果，而是先依據輸入資料之車流特徵計算模型輸出分數。由於該分數範圍不限於 0 至 1 之間，無法直接解讀為事故發生機率，因此於二元分類問題中，透過 Sigmoid 函數

將模型輸出分數轉換為介於 0 至 1 之間的機率值，作為該筆資料屬於事故類別之可能性，其公式如下：

$$p_i = \frac{1}{1 + e^{-z_i}}$$

其中， z_i 表示模型對第*i*筆資料所計算之輸出分數， p_i 則表示轉換後之事故發生機率。當 z_i 值增加時， p_i 將逐漸接近 1，代表模型判斷該筆資料較可能屬於事故類別；反之，當 z_i 值降低時， p_i 則會接近 0，表示該筆資料較可能屬於非事故類別。

事故發生機率並非由人工設定，而是模型依據輸入之車流特徵所計算之結果。本研究模型輸入包含速度、流量、密度，以及事故發生前不同時間與空間範圍內之車流變化資訊，模型透過學習上述特徵與事故樣本間之關聯性，計算各筆資料發生事故之可能性。例如，當某筆資料之事故發生機率為 0.99 時，代表模型判斷該筆資料屬於事故類別之可能性為 99%。

為將模型輸出的連續型機率值轉換為明確之分類結果，本研究設定 0.5 作為事故分類門檻值。當事故發生機率大於或等於 0.5 時，則將該筆資料判定為事故樣本，並將「預測事故 0/1」設定為 1；當事故發生機率低於 0.5 時，則判定為非事故樣本，並設定為 0。透過此分類方式，可將模型輸出結果與實際事故標記進行比較，並進一步計算 Accuracy、Precision、Recall 及 F1-score 等模型評估指標。

除二元分類結果外，本研究亦將事故發生機率進一步轉換為事故風險層級，以提升模型結果之可讀性。由於原始事故資料僅包含事故與非事故標記，並未提供不同程度之風險分類；因此，依據模型輸出之事故發生機率範圍，參考四分位數概念分級，將 0 至 1 之機率區間劃分為四個風險等級。其中，以 0.25、0.50 及 0.75 作為固定門檻值，將事故風險區分為低風險、中風險、高風險及極高風險。

需要說明的是，上述門檻值並不是由資料分布產生，而是將模型輸出的事故發生機率範圍設定為固定區間，並依機率高低分為不同風險等級。透過此設定，可將原本單純的機率數值轉換為較直觀的風險分類結果，方便後續進行事故風險分析與比較。

表 3 事故預測機率與風險層級門檻值

欄位	門檻值	輸出結果
預測事故 0/1	事故發生機率 < 0.50	0
	事故發生機率 ≥ 0.50	1
風險層級	0 ≤ 機率 < 0.25	低風險
	0.25 ≤ 機率 < 0.50	中風險
	0.50 ≤ 機率 < 0.75	高風險
	機率 ≥ 0.75	極高風險

完成模型預測後，將結果回寫至車流特性結合事故資料整合表中，使每筆時空資料皆能對應模型輸出結果。模型預測後新增之欄位主要包含「預測事故 0/1」、「事故發生機率」及「事故風險層級」三項。其中，「預測事故 0/1」為模型對事故是否可能發生之二元判斷結果，當欄位值為 0 時，表示模型判斷該筆資料較可能未發生事故；當欄位值為 1 時，則表示模型判斷該筆資料較可能發生事故。此欄位

可作為模型最直接之分類結果，並與實際事故標記比較，以評估模型預測能力。

「事故發生機率」則表示模型判斷該筆資料屬於事故類別之可能性，相較於僅呈現事故與非事故結果之「預測事故 0/1」，事故發生機率可進一步反映不同資料間之風險差異。例如，兩筆資料皆被判定為非事故，但其中一筆事故發生機率為 0.48，另一筆為 0.05，代表前者雖未達分類門檻，但其潛在事故風險仍高於後者。因此，事故發生機率可作為比較不同時間、路段及方向條件下事故風險程度的重要依據。

「事故風險層級」則為依據事故發生機率轉換後之結果，其目的在於將模型輸出的數值化結果轉換為較直觀之風險分類。透過三項輸出欄位，可分別呈現模型之分類結果、事故可能性及風險程度，使模型結果更容易應用於後續事故風險分析。

下表為模型預測完成後回寫至車流特性結合事故資料整合表之欄位範例。資料除保留原始時間、路段、速度、密度、流量及事故標記外，亦包含事故發生前鄰近時空範圍內之車流特徵，以及模型預測結果。

表 4 事故預測機率與風險層級之預測結果範例

資料類型	欄位定義	資料範例
基本資料	日期時間	2023-01-01 08:25:00
	路段區間	2.0-2.5km
	速度（公里／小時）	95.0
	密度（輛／公里）	3.03
	流量（輛）	288.0
	有無發生事故（0 表該時空無事故）	1
鄰近時空車流特性	事故發生前 5 分鐘 0.5km 處_速度	91.31
	事故發生前 5 分鐘 0.5km 處_密度	3.94
	事故發生前 5 分鐘 0.5km 處_流量	360.0
	事故發生前 10 分鐘 0.5km 處_速度	90.59
	事故發生前 10 分鐘 0.5km 處_密度	3.58
	事故發生前 10 分鐘 0.5km 處_流量	324.0
	事故發生前 5 分鐘 1km 處_速度	91.55
	事故發生前 5 分鐘 1km 處_密度	3.01
	事故發生前 5 分鐘 1km 處_流量	276.0
	事故發生前 10 分鐘 1km 處_速度	88.86
	事故發生前 10 分鐘 1km 處_密度	2.7
	事故發生前 10 分鐘 1km 處_流量	240.0
預測後結果	預測事故 0/1	1
	事故發生機率	99%
	事故風險等級	極高風險

4.2 模型評估與分析

完成模型訓練後，本研究進一步針對不同時間尺度、空間尺度及行車方向之模型結果進行評估，以比較不同資料切分方式對事故預測效果之影響。模型比較組合包含 $0.5\text{ km} \times 5\text{ min}$ 、 $1\text{ km} \times 5\text{ min}$ 及 $0.5\text{ km} \times 10\text{ min}$ 三種時空尺度，並分別針對南向與北向資料建立模型，以分析不同時空尺度組合下，模型對事故發生前車流特徵之辨識能力。

由於高速公路事故資料具有明顯的類別不平衡特性，事故樣本數量通常遠低於非事故樣本，因此若僅使用整體準確率（Accuracy）判斷模型表現，可能會受到大量非事故資料影響，無法完整反映模型對事故樣本之辨識能力。因此採用混淆矩陣作為基礎，並搭配 Accuracy、Precision、Recall、F1-score、漏判率及誤判率等指標進行綜合評估，以更全面分析模型之事故預測能力。本研究採用混淆矩陣檢視模型預測結果與實際事故標記之對應情形，其分類結果如表 5 所示。

表 5 混淆矩陣說明

類型	意義	在研究中的解釋
TN	實際無事故，模型也預測為無事故	正確判斷無事故
FP	實際無事故，但模型預測為有事故	誤判，模型將無事故判為事故
FN	實際有事故，但模型預測為無事故	漏判，模型未成功預測事故
TP	實際有事故，模型也預測為有事故	正確預測事故

其中，TP 與 TN 代表模型正確分類結果，而 FP 與 FN 則代表分類錯誤情形。於事故預測應用中，FN 是最需要注意的指標，因其代表實際發生事故但模型未能成功辨識，可能降低事故預警系統之應用價值。為比較不同資料切分方式下模型之預測表現，本研究依據混淆矩陣之分類結果，進一步計算 Accuracy、Precision、Recall、F1-score、漏判率及誤判率等評估指標，其計算方式與指標意義如表 6 所示。

表 6 模型評估指標說明

評估指標	計算公式	指標意義
Accuracy	$\text{Accuracy} = \frac{(\text{TP} + \text{TN})}{(\text{TP} + \text{TN} + \text{FP} + \text{FN})}$	評估模型整體預測正確比例
Precision	$\text{Precision} = \frac{\text{TP}}{(\text{TP} + \text{FP})}$	模型預測為事故資料中，實際事故所占比例，用於判斷誤警程度
Recall	$\text{Recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})}$	實際事故資料中，被模型成功辨識之比例，用於衡量事故辨識能力
F1-score	$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{(\text{Precision} + \text{Recall})}$	綜合考量 Precision 與 Recall 之平衡表現
漏判率	$\text{漏判率} = \frac{\text{FN}}{(\text{TP} + \text{FN})} = 1 - \text{Recall}$	實際事故未被模型辨識之比例
誤判率	$\text{誤判率} = \frac{\text{FP}}{(\text{TN} + \text{FP})}$	實際無事故但被模型判定為事故之比例

其中，Accuracy 可用於觀察模型整體預測效果，但由於事故資料存在類別不平衡問題，因此本研究主要參考 Recall、Precision、F1-score、漏判率及誤判率等指標，評估模型是否能有效辨識事故樣本，以及是否產生過多錯誤警示。下表為不同時空尺度與行車方向之模型評估結果。

表 7 不同時空尺度與行車方向之模型評估結果

資料切分方式	方向	Accuracy	Precision	Recall	F1-score	漏判率	誤判率
0.5km×5min	北向	99.49%	89.49%	99.51%	94.23%	0.49%	0.51%
0.5km×5min	南向	99.39%	87.38%	99.00%	92.83%	1.00%	0.60%
1km×5min	北向	99.35%	86.94%	99.51%	92.80%	0.49%	0.66%
1km×5min	南向	81.75%	14.96%	69.72%	24.64%	30.28%	17.71%
0.5km×10min	北向	99.41%	87.34%	99.39%	92.97%	0.61%	0.59%
0.5km×10min	南向	99.48%	88.14	99.36%	93.41%	0.64%	0.52%

由表 7 可知，除 1 km × 5 min 南向模型外，其餘模型之 Accuracy 皆達 99% 以上，且 Recall 多接近 99%，顯示多數時空尺度設定下，XGBoost 皆能有效利用事故發生前之速度、流量及密度變化特徵進行事故辨識。

然而，由於事故資料具有高度類別不平衡特性，Accuracy 較高並不代表模型一定具有良好的事故預測能力，因此仍需搭配其他指標進行分析。由結果可發現，0.5 km × 5 min 與 0.5 km × 10 min 兩種資料設定整體表現較為穩定，其 F1-score 皆維持在 92% 以上，且漏判率低於 1%，代表模型能有效掌握事故樣本特徵，並降低漏判事故之情形。

相較之下，1 km × 5 min 南向模型之表現明顯低於其他組合，其 Precision 僅 14.96%、F1-score 為 24.64%，且漏判率達 30.28%，顯示此資料設定下模型較難有效辨識事故樣本。由於相同資料切分方式之北向模型仍具有良好表現，因此該結果可能與南向資料本身之事故分布、車流型態或事故發生前車流變化特徵有關，而非單純受到空間尺度影響。

以本研究的空間組合而言，0.5 km 較能保留較細緻之局部車流變化，使模型較容易學習事故發生前速度下降、流量變化或密度增加等特徵；反之，較大路段範圍如 1km 可能使局部異常車流變化被平均化，降低模型辨識事故前兆之能力。此外，不同行車方向之模型表現亦存在差異，顯示事故風險評估除了受到時空尺度影響外，也可能與道路方向之車流特性及事故分布情形有關。

綜合上述結果，XGBoost 模型能有效利用時空車流特性矩陣與事故前車流特徵進行事故風險評估，其中 0.5 km × 5 min 及 0.5 km × 10 min 兩種資料設定具有較佳且穩定之預測效果，可作為後續事故風險分析與結果呈現之主要依據。

五、結論與建議

本研究結果顯示，XGBoost 適合作為高速公路事故風險預測模型，主要原因在於其具備處理大量資料、學習非線性特徵關係及處理類別不平衡資料之能力，能有效分析由 M06A 原始旅次資料建構之速度、流量、密度及事故前車流特徵。此外，XGBoost 具有良好的運算效率與模型穩定性，並可透過特徵重要性分析了解不同車流變數對事故風險判斷之影響，因此適合作為高速公路事故風險評估之分析方法。

模型評估結果顯示，除 1 km × 5 min 南向模型外，其餘模型皆具有良好預測效能，其中以 0.5 km × 5 min 北向模型表現最佳，Accuracy 為 99.49%、Precision 為 89.49%、Recall 為 99.51%、F1-score 為 94.23%。結果顯示，較細緻之空間尺度能保留事故發生前局部車流變化，使模型較容易辨識速度、流量及密度變化所形成之事故前兆特徵。然而，不同方向資料仍可能受到車流型態、事故分布及道路環境差異影響，因此後續分析仍需考量不同方向之交通特性。

在交通管理應用上，本研究結果可作為事故風險預警的基礎。由於 0.5 km × 5 min 模型表現較佳，未來可每 5 分鐘更新一次車流資料，將各 500 公尺路段的速度、流量及密度輸入已訓練好的 XGBoost 模型，取得各路段的事故發生機率及風險層級。由於不需要每次重新訓練模型，只需處理最新的車流資料，因此可減少資料處理時間，讓風險資訊能更快更新。預測結果可提供交通管理人員掌握各路段的風險狀況，並作為巡邏調度、道路警示或動態分流等措施的參考。不過，本研究目前使用 2023 年超過 3,000 萬筆 M06A 資料進行模型建置與驗證，尚未實際串接即時資料，因此未來仍需測試資料更新及模型預測所需的時間，以確認是否能符合即時預警的需求。

未來研究可進一步擴充模型輸入變數，以提升事故風險預測能力。目前模型主要利用車流特性進行分析，後續可加入降雨量、降雨強度、能見度、氣溫、路面狀況等天候因素，以及道路縱坡、曲線半徑、車道數、匝道位置、速限等道路幾何特性。此外，亦可納入大型車比例、車種組成、施工資訊、交通事件、連續假期及尖離峰時段等交通環境變數，以更完整描述事故發生可能受到之影響因素。

另外，未來研究可進一步比較不同機器學習方法，例如 Random Forest、LightGBM 或深度學習模型，以分析不同模型於高速公路事故風險預測上的適用性。同時，可結合 SHAP 等模型解釋方法，深入了解各項特徵對事故風險之影響程度，提升模型結果之可解釋性。透過增加資料來源、改善模型架構及強化分析方法，可使事故風險預測模型更符合實際交通管理需求，作為未來高速公路事故預警與安全改善措施之參考。

參考文獻

- 交通部高速公路局(2024)，高速公路電子收費交通資料蒐集支援系統（Traffic Data Collection System, TDCS）資料使用手冊（V4.1）。
- Bibb, M., Rivas, P., & Tayba, M. (2021). Predicting traffic accident severity with deep neural networks. In Proceedings of the 17th International Conference on Data Science (ICDATA 2021).

- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System, KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 785-794.
- Chen, F., Liu, X. Q., Yang, J. J., Liu, X. K., Ma, J. H., Chen, J., & Xiao, H. Y. (2025). Traffic Accident Severity Prediction Based on an Enhanced MSCPO-XGBoost Hybrid Model. *Scientific Reports*, 15(25729).
- You, J., Wang, Junhua, & Guo, Jingqiu. (2017). Real-Time Crash Prediction on Freeways Using Data Mining and Emerging Techniques. *J. Modern Transportation*, 25(2), 116–123.