

國道路段事故密度分析與高風險區段預測模型之建構

林芮亘¹、賴昱璇²

摘要

本研究探討臺灣國道系統交通事故之空間分布特徵，運用事故資料與機器學習技術，辨識高風險路段並提出改善建議。本研究範圍涵蓋國道 1 號至國道 3 甲等 9 條路線，分析面向包括事故總數、事故密度及事故主要肇因。另為排除路段長短對風險評估的干擾，本採用事故密度與核密度估計 (KDE) 進行空間分析，結果顯示國道 1 號與 2 號存在事故集中現象。透過上述結果，本研究進一步針對國道主線進行分區分析，發現國道 1 號 (0-74.86K)、國道 2 號 (4.09-8.16K) 及國道 3 號 (0-86.58K) 為高風險路段。上述路段之肇事因素主要以未保持安全距離、駕駛分心及變換車道不當最常見。另有關事故預測部分，本研究首先建構邏輯迴歸模型，針對標準化後之事故數與事故密度進行分析，並以事故密度平均值 (24.86 件 / 公里) 作為高低風險劃分門檻。結果顯示事故密度為風險分類的主要判斷因子，模型分類表現良好，成功辨識出國道 1 號、2 號與 3 號等高風險路段。後續再以此結果為基礎，建構隨機森林與決策樹模型進行風險分級，進一步驗證事故密度與事故數具正相關，並可依據特徵值將路段區分為高、中、低風險等級。綜上，本研究之方法與結果可供交通主管機關作為設施優化、科技執法與行為管理等策略之參考，俾利提升國道整體安全與管理效能。

關鍵字：事故密度、事故熱點分析、風險評估

一、前言

交通事故受多重因素交互影響，尤以道路型態、交通流量與周邊環境為關鍵。在交通高度仰賴道路運輸的臺灣，國道系統串聯城市與區域，其安全性攸關運輸效能與用路人生命財產。由於車速高、車流密集且肩負城際運輸，一旦發生事故，往往造成嚴重衝擊，不僅導致財損與延誤，亦干擾地區道路的順暢與秩序。

雖然高速公路道路長度 (含連絡道及高架路段) 僅占全國道路總長之 2.5%，卻承載尖峰車流與城際客貨運輸之重大任務，且艾嘉銘、楊宗璟 (2010) 也指出高速公路雖然事故率相對較低，但一旦發生，往往造成更嚴重的後果；另根據交通部統計處資料顯示，國道事故雖非最多但重大事故比例明顯偏高。上述文獻及資料反映國道部分區段潛藏事故高風險因子，若此類因子所產生之事故類熱點無法及時掌握與預防，國道事故造成之社會與經濟負擔將無法有效降低。

過去已有諸多文獻探討事故資料之空間分群與統計模式。葉志宏 (2007) 運用 GIS 與 Moran's I 分析臺北市事故分布，指出僅依事故件數排序易忽略空間關

¹ 逢甲大學運輸與物流學系學生，臺中市西屯區文華路 100 號，04-24517250 分機 4652，d1258495@o365.fcu.edu.tw。

² 逢甲大學運輸與物流學系學生。

聯，應輔以空間統計工具提升準確度；簡筑君（2023）結合主成分分析、K-means、階層式與 DBSCAN 方法分析臺中市事故，成功辨識 7 類高風險群體；Anderson（2009）則結合 KDE 與 K-means 分析倫敦事故，顯示空間分析搭配統計建模有助事故治理與政策應用；胡大瀛與李岳洪（2022）利用臺南市事故資料，結合 CatBoost、Random Forest 及不平衡資料處理技術，提升少數類型事故的辨識能力。另有研究著重事故預測，例如：陳威男（2008）針對國道 1 號與 3 號建構多元迴歸模型，指出事故集中於都會區，且與車道數、聯結車流量相關；黃燦煌（2020）透過迴歸分析建立事故與違規因子之模型，誤差低於 5%；張斯涵（2023）以大客車 ADAS 資料建構駕駛行為預測模型，發現邏輯迴歸在穩定性與解釋力上優於 SVM，並以 Lasso 與 RFE 篩選出車速、車距與環境因素等關鍵變數。惟現有文獻多未處理事故密度之系統化分級與風險預測之關聯，本研究遂以事故密度為核心，結合核密度估計（KDE）進行高速公路事故熱點分析，並導入機器學習建構風險預測與分級模型，期能精確識別高風險區段，並提供交通主管機關具操作性的改善建議，以提升國道安全管理效能。

二、事故資料蒐集與分析

2.1 資料蒐集與處理

本研究利用交通部高速公路局所提供之 2024 年事故資料為依據，首先針對原始事故資料進行篩選與前處理，包含刪除資料缺漏、不合理數值及非主線事故紀錄，確保後續分析之準確性與一致性。經資料查驗後發現，2024 年 1 月至 3 月以及 10 至 12 月間共計約 319 筆事故紀錄存在欄位遺漏、異常數值或座標錯置等問題，若將此資料納入使用則可能影響分析結果之穩定性與代表性。因此，本研究最終採用 2024 年 4 月至 9 月的完整資料進行後續分析與建模。

2.2 資料分析

為深入探討各國道事故之分布特性與潛在高風險區段，本研究從以下四個面向進行資料分析含：事故數與密度統計、熱區辨識、路段區分分析與肇因結構探討。

2.2.1 事故數與密度統計

由本研究所使用之資料結果（如表 1）顯示，2024 年國道系統中以國道 1 號事故發生件數最多，全年共計 24,485 件，占總體事故量近四成，反映其高車流與密集通行特性；國道 3 號則以 11,504 件居次，亦為全台主要南北向幹道之一，具高度交通負荷；國道 2 號全長僅 20.4 公里，但事故達 1,226 件，經本研究換算後事故密度高達 60.09 件／公里，僅次於國道 1 號的 65.41 件／公里，顯示其事故集中度偏高，並呈現顯著的區域風險特徵。


另透過圖 1 說明國道 1 號、2 號與 3 號三條路線占 2024 年國道事故總數約 95.7%，係為所有國道事故最密集之道路。為兼顧資料代表性與完整性，本文之研究範疇將聚焦此三路線，並據以進行熱點與肇因分析，深入探討事故空間分布與潛在風險因子。

表 1 2024 年 4 月至 9 月國道事故數彙析

路線類型	總長度	事故數量	事故密度（件 /km）
國道 1 號	374.3	24485	65.4154
國道 2 號	20.4	1226	60.0980
國道 3 號	432.9	11504	26.5743
國道四號	26.8	437	16.3060
國道五號	54.2	534	9.8524
國道六號	37.6	363	9.6543
國道八號	15.5	184	11.8710
國道二甲	2.6	17	0.8333
國道三甲	5.6	130	23.2143

資料來源：高速公路總局

各國道事故密度占比



資料來源：本研究繪製

圖 1 各國道事故密度占比

2.2.2 熱區辨識與熱力圖分析

本研究運用兩種空間視覺化技術進行國道事故熱區辨識包含：核密度估計法（KDE）與區間熱力圖。前者強調事故的空間聚集程度，後者則呈現分段密度變異，兩者相輔相成，能有效補足事故風險空間資訊。

1. 國道 1 號：透過 KDE 熱力圖（如圖 2）可見，國道 1 號事故最密集的區段集中於約 40 公里處，該區域呈現高度事故聚集現象；此外，約在 100 公里、200 公里與 350 公里處亦出現明顯的次級高峰，顯示多處路段存在潛在風險。本研究為便於整體區段風險比較，採取等距里程劃分法，將國道 1 號全長約 374.3 公里平均分為五個區段（每段約 74.86 公里），再計算各區段之事故密度，製作區間熱力圖進行比較（如圖 4）。此劃分方式並非基於事故數或演算法分群，而是以道路全長為基準之等距切分。結果顯示 0K 至 74.86K 路段事故總數居各區段之首，與 KDE 主熱點區段吻合，進一步證實該區段屬於高風險事故熱點。




圖 2 國道 1 號 KDE 熱力圖 (X 軸：公里，Y 軸：每公里的相對密度值)




圖 3 國道 1 號區間熱力圖

2. 國道 2 號：透過 KDE 熱力圖 (如圖 4) 可見，國道 2 號事故密度最高區段約位於 7 公里處，顯示約 3.5 公里至 7 公里路段事故聚集程度顯著；此外，約在 11 公里與 18 公里處也呈現次高峰。本研究為便於整體區段風險比較，採取等距里程劃分法，將國道 2 號全長約 20.4 公里平均分為五個區段 (每段約 4.08 公里)，再計算各區段之事故密度，製作區間熱力圖進行比較 (如圖 5)。此劃分方式並非基於事故數或演算法分群，而是以道路全長為基準之等距切分。結果顯示，4.09K-8.16K 區段事故總數居冠，與 KDE 主熱點區段吻合，進一步證實該區段屬於高風險事故熱點。




圖 4 國道 2 號 KDE 熱力圖 (X 軸：公里，Y 軸：每公里的相對密度值)




圖 5 國道 2 號 區間熱力圖

3. 國道 3 號：透過 KDE 熱力圖（如圖 6）可見，國道 3 號事故密度最高區段約位於 50 公里左右，該路段事故聚集明顯；此外，在約 130 公里與 200 公里處也出現次級事故高峰。本研究為便於整體區段風險比較，採取等距里程劃分法，將國道 3 號全長約 432.9 公里平均分為五個區段（每段約 86.58 公里），再計算各區段之事故密度，製作區間熱力圖進行比較（如圖 7）。此劃分方式並非基於事故數或演算法分群，而是以道路全長為基準之等距切分。結果指出，0K-86.58K 公里區段之事故總數居各區段之冠，與 KDE 主熱點區段吻合，進一步證實該區段屬於高風險事故熱點。




圖 6 國道 3 號 KDE 熱力圖（X 軸：公里，Y 軸：每公里的相對密度值）



圖 7 國道 3 號 區間熱力圖

2.2.3 路段區分分析

為進一步瞭解高事故密度區段之特徵與潛在風險因素，本研究針對事故最集中的國道 1 號與國道 2 號進行分段數據分析，並結合道路功能、地理位置與交通特性，進行空間風險辨識。

根據國道 1 號（全長 374.3 公里）事故熱區分布特性，將其劃分為五個區段進行統計。結果顯示，0–74.86 公里區段事故件數達 8,978 件，占全線 36.65%，為最嚴重之高風險區段。此區涵蓋大台北、桃園與新竹等都市通勤帶，車流密集，尖峰時段車速變化大，易導致追撞與變換車道事故。此外，該段交流道密集，包括汐止、五股、新竹等大型系統與轉接路口，頻繁的分流與匯流加劇交通衝突風險。

其他區段方面，74.87–149.72 公里事故數為 3,281 件，橫跨苗栗至台中以北路段，南來北往交通匯集特性，使得路段雖仍屬中高通行壓力，但因都市密度下降，事故相對較少。中南部區段如 224.59–299.44 公里僅有 2,346 件事故，為全線最低，推測因地形筆直、高架路段多、交通量較低，整體事故風險顯著偏低。

國道 2 號方面，雖僅 20.4 公里長，但全線事故密度極高，平均每公里 60.09 件。依等距劃分為五段後發現，4.09–8.16 公里段事故達 370 件，占全線 30.2%，為主熱點。該段橫跨南崁至桃園機場聯絡路，為航空站與地方接駁核心，且交流道（如南崁、機場系統）緊密配置，車流複雜，駕駛決策時間短，易發生變換車道與未保持安全距離事故。

此外，0–4.08 公里段（含大園匝道與國道 1 號銜接）事故數達 108 件，推測與接駁匯流密度及混合車流（含客運與貨運）有關；而 12.25–20.4 公里段則因路段筆直、車流穩定，事故風險明顯趨緩。

2.2.4 肇因結構探討

為深入剖析各國道路段事故背後之成因與結構，本研究彙整 2024 年 4 月至 9 月間之事故肇因資料，並聚焦於國道 1 號、2 號與 3 號三條主要幹道，針對其事故件數前 5 大肇因進行分類統計與比較，同時輔以空間與交通特性進行通盤解析，茲說明如下：

1. 國道 1 號主要肇因：國道 1 號為國道中交通量最大之高速公路，貫穿北中南主要都會區，短途通勤與長途運輸車流密集。根據本計畫統計資料顯示，該系統事故前 5 大肇因如下：




圖 8 國道 1 號事故肇因排名

圖 8 顯示「未保持行車安全距離」為國道 1 號最常見肇因，顯示駕駛未能與前車保持安全間距，在高流量情境下尤為顯著；而分心駕駛類型（合計占比近 7%）亦為另一核心風險，反映出駕駛注意力容易被都會區複雜交通環境或意外狀況干擾；變換車道不當則多見於進出匝道頻繁路段，如五股、臺中、大雅及岡山等區段。

2. 國道 2 號主要肇因：本路段為機場聯絡道雖全長僅 20.4 公里，卻為事故密度第 2 高（60.1 件 / 公里）之國道。其肇因結構顯示出明顯的短程高密度風險特徵：




圖 9 國道 2 號事故肇因排名

在僅 20 公里的範圍內，高達 32.7% 的事故為未保持行車距離所致，反映其路段設計之加減速頻繁與駕駛者應變壓力。第 2 高肇因為變換車道不當，顯示進出匝道與高速匯流對駕駛判斷要求高。另「物品滾落」進入前 5 肇因，顯示該路段貨運比例較高，且部分裝載安全問題需被重視。

3. 國道 3 號主要肇因：國道 3 號路程最長（432.9 公里），貫穿西部山區及外圍都會區，為國道 1 號之替代幹道，事故特性略有不同：




圖 10 國道 3 號事故肇因排名

國道 3 號之事故肇因仍以車距不足與變換不當為主，但分心駕駛比例相對國道 1 號略低，可能與較低的車流密度與環境干擾有關。另「車輛或機械操作不當」為國道 3 號特有前五肇因，可能與長途行駛、坡道較多、車輛負荷重等條件有關，顯示此類物理性故障風險較高。

4. 綜合分析與結論：從上述 3 條國道的事故肇因分布可歸納出 3 個主要趨勢。

- (1) 共通風險因子：3 路線皆以「未保持行車安全距離」為首位肇因，顯示高速環境下車距維持的風險普遍存在。
- (2) 分心與判斷失誤：分心駕駛（恍神、觀看外界）與變換車道不當交錯構成主要人為失誤來源，在都市化區段或交流道密集區尤為顯著。
- (3) 特殊肇因類型：國道 2 號出現「物品滾落」、國道 3 號則有「操作不當」，呈現出各國道路段潛在結構與車流組成對肇因構成的差異性。

這些結果不僅可作為政策單位訂定區域性改善措施（如匝道設計、警示系統、貨物固定檢查）的依據，也有助於未來風險預測模型之特徵選擇與精準化調整。

三、事故風險預測模式建立

為深入探究國道路段事故風險之特性並提升預測精度，本研究採用邏輯迴歸、決策樹及隨機森林等多元統計與機器學習方法，針對相關事故資料進行系統性分類與預測。首先，運用邏輯迴歸模型構建高低風險路段之判別架構，進而透過決策樹模型解析各項特徵於風險分級過程中的影響機制，最後以隨機森林迴歸模型預測事故發生數量並評估特徵重要性。經由多種模型交互驗證，本研究不僅強化事故風險辨識之科學基礎，亦為交通管理單位提供更具實證依據之決策參考。

3.1 邏輯迴歸模型建構與風險分類

本研究首先利用二元邏輯迴歸模型（Binary Logistic Regression），針對 9 條國道路段的事務數與事故密度進行風險分類。依據事故密度的平均值 24.86 件/公里作為分類門檻，將路段劃分為「高風險（>24.86）」與「低風險（≤24.86）」兩類，作為模型的因變數。自變數則包含事故數與事故密度兩項指標。由於事故數與密度的單位不同，為避免尺度差異影響模型判斷，因此先將這兩項資料進行標準化處理後再帶入模型中。其邏輯迴歸模型（式 1）可表示如下：

$$p(Y = 1 | z_{\text{事故數}}) = \frac{1}{1 + \exp[-(30.1526 + 63.5268 z_{\text{事故數}})]} \quad (1)$$

其中，Y=1 表示高風險路段，z 事故數為事故數的標準化值。分類規則採用常見的方式：若 $p \geq 0.5$ 則判定為高風險，否則為低風險。

模型估計結果（如表 2）所示，由於目前僅列出截距（const）與事故數的係數，從係數值來看事故數對模型影響較大；截距項則代表在所有自變數為平均水準時的基礎風險。在模型的分類表現部分（如表 3），整體準確率約為 77.8%。其中，對於低風險路段的預測相當準確，召回率達到 1.0，代表模型成功找出所有低風險案例；但在高風險路段部分，召回率僅有 0.5，也就是說模型只正確預測了一半的高風險路段。這顯示目前模型雖具辨識能力，但仍有進步空間，特別是在資

料筆數較少的情況下，可能導致過度擬合。後續若能增加樣本數或採用交叉驗證，將更有助於提升模型的穩健性與預測表現。

表 2 邏輯迴歸模型參數校估表

變數	係數值	p-value
const	30.1526	0.360
事故數	63.5268	0.343

表 3 事故風險分類關聯指標說明表

分類 \ 指標	precision	recall	f1-score	support
0	0.7142	1.0000	0.8333	6.0000
1	1.0000	0.5000	0.6666	4.0000
accuracy	0.7777	0.7777	0.7777	0.7777
macro avg	0.8571	0.7500	0.7500	9.0000
weighted avg	0.8412	0.7777	0.7592	9.0000




圖 11 邏輯迴歸風險分類

為了讓結果更直觀，我們將風險分類畫成散佈圖並加上決策邊界，如圖 11 所示。圖中紅色區域為模型判斷的高風險區，藍色則為低風險區，每一個點代表一條國道路段，也標示了預測的風險機率。從圖中可以看到，像是國道 1 號、2 號與 3 號，事故密度都在平均值以上，模型也成功判斷為高風險；相對地，國道 2 甲、5 號與 6 號的密度都偏低，因此被歸為低風險，這與實際的事故分布相當一致，整理結果如表 4 所示。

表 4 邏輯迴歸風險分類及風險密度

高風險路段	低風險路段		
道路名稱	風險密度	道路名稱	風險密度
國道 1 號	65.42	國道二甲	0.83
國道 2 號	60.10	國道五號	約 9.8~9.6
國道 3 號	26.57	國道六號	約 9.8~9.6

3.2 決策樹風險分類模型

接續本研究利用決策樹模型對國道路段之事故風險進行分級，並採用事故密度、國道編號、事故時間及主要肇事因素等 4 項特徵變數。其中類別型變數（如國道編號、肇事因素、事故時間）主要係透過 LabelEncoder 進行編碼，使模型能有效處理類別特徵，為避免模型過度複雜，決策樹設定最大深度為 3，以維持結構簡潔並便於追蹤每個節點的分裂條件。

模型結果如圖 12 所示，第一層節點以「事故密度」為主要分裂依據，顯示其為判別風險等級最關鍵的變數。具體而言，當事故密度小於約 20.07 時，該路段被歸類為「低風險」；若事故密度介於約 20.07 至 48.59 之間，則被分類為「中風險」；若密度高於 48.59，則直接歸為「高風險」路段。由此可見，模型幾乎完全仰賴「事故密度」進行風險分層，其資訊貢獻度遠高於其他變數。雖本模型同時納入了「國道編號」、「事故時間」與「主要肇事因素」作為特徵變數，惟因其在資料中的資訊增益相對較低，最終並未進入決策樹的分裂節點，顯示這些變數對於風險判斷的貢獻相對有限。




圖 12 決策樹分類

整體而言，決策樹模型能有效辨識國道路段之風險等級，並透過圖形化的節點結構呈現風險分類邏輯。第 1 層與第 2 層節點皆凸顯「事故密度」的主導性影響，節點中清楚標示各類別的樣本數與風險分類結果，使模型具備高度可解釋性與實務應用價值，有助於交通管理單位針對高密度事故區段優先施以改善策略。

3.3 隨機森林迴歸模型

最後本研究採用隨機森林迴歸模型，預測國道路段之事故數量，並剖析各特徵對模型預測的貢獻程度。資料集涵蓋 9 條主要與支線國道，包括事故數、事故密度、事故類別、天氣狀況、時間帶、事故發生位置及主要肇因等變數。類別型變數（如路線名稱、天氣、時間、肇因）以 One-Hot Encoding 進行轉換，數值型變數「事故密度」則保留原始數值以維持其實際意義。經資料切分後進行模型訓

練與測試，結果顯示模型的均方誤差（MSE）為 103071046.66，顯示模型具一定的預測能力，但同上述邏輯迴歸一樣，受限於樣本數不足影響，可能導致過度擬合的風險。茲將結果呈現如圖 13 並說明如下：

1. 事故密度：對事故數量呈顯著正向影響，當事故密度升高時，預測事故總量隨之增加，為模型中最具解釋力的特徵。
2. 路線編號：國道 1 號在其他條件相似的情況下，其事故數預測值明顯高於其他路線，可能與其交通量大、涵蓋範圍廣及車流複雜度高有關；國道 3 號次之，亦具有一定貢獻；而國道 2 號影響較小，其他支線國道未出現在主要預測特徵中，顯示其預測力相對較低。

表 5 數值型變數敘述統計

變數	平均值	標準差	最小值	最大值	中位數
事故數	4320	7930.655	17	24485	437
事故密度	54.86	21.519	0.833	65.415	16.306




圖 13 隨機森林迴歸模型

整體來看，隨機森林在多特徵混合情境下仍能保持良好的擬合能力，且其特徵重要性排序與邏輯迴歸及決策樹模型結果一致，皆指出事故密度是高風險的重要判斷依據。透過部分依賴圖展示主要特徵對預測結果的影響：

1. 事故密度的依賴曲線明顯呈現單調上升，顯示其與預測事故數之間存在正向關係。
2. 國道 1 號與國道 3 號的 One-Hot 特徵對預測結果具正向貢獻，其中以國道 1 號最為顯著，反映其實際交通壓力與風險程度相對較高。

3.4 結果探討

本研究分別應用邏輯迴歸、決策樹與隨機森林迴歸三種模式，針對國道路段事故風險進行分類與預測。首先，邏輯迴歸模型以事故數及事故密度為輸入變數，透過標準化處理後進行高低風險分類，並利用 p-value 檢驗變數顯著性。分析結果顯示，事故密度對風險分類的影響最為顯著，遠高於事故數，顯示單位長度內事故發生頻率是路段風險判斷的主要依據。決策樹模型則進一步納入事故密度、國道編號、事故時間及肇事因素等特徵，並以事故密度作為主要分裂依據，將路段分為低、中、高風險。其分層規則直觀且結構可視化，有助於釐清各特徵對風險分級的貢獻。隨機森林迴歸模型則結合多元特徵進行事故數預測，並透過特徵重要性排序，發現事故密度仍為預測事故數最關鍵的變數，其次為國道 1 號及 3 號等路線編號。整體而言，三種模式雖在分析架構及適用情境上各有優缺點，然結果皆一致指出事故密度為影響國道路段事故風險與事故數量的核心因素。由此可見，未來在交通安全管理與資源配置上，應優先聚焦於事故密度較高之區段，以提升國道路網整體安全性。

四、結論與建議

本研究針對台灣國道系統進行交通事故密度分析與高風險路段之預測模型建構，透過實際事故資料、熱區分析與機器學習方法，成功辨識出風險較高之路段，並進一步探討事故肇因及風險分級模式。結果顯示，國道 1 號、2 號與 3 號事故數與事故密度明顯偏高，應作為優先改善的重點路段。在肇因方面，「未保持行車安全距離」為最主要因素，其次為變換車道不當與分心駕駛，均屬於駕駛行為問題，凸顯提升駕駛人安全意識之重要性。此外，不同國道亦呈現不同風險特徵，例如國道 2 號因貨車比例高，常發生物品掉落事故；國道 3 號則因坡道與長路段較多，易出現操作不當情況。模型分析部分，邏輯迴歸、決策樹與隨機森林三種方法均顯示事故密度為最關鍵變數，再次驗證事故密度作為風險判斷依據之合理性。

然而，本研究仍存在若干限制。資料僅涵蓋 2024 年 4 月至 9 月，無法全面反映全年事故樣態；樣本數僅限於 9 條國道路段，規模有限，可能影響模型穩健性與泛用性。自變數僅納入事故數與事故密度，未涵蓋交通流量、道路設計特徵、氣候條件等潛在影響因子，限制了模型對不同路段與情境的外部效度。未來研究若能擴增樣本數、涵蓋跨年度資料，並引入更多維度的變數，不僅有助於提升模型預測精確度與解釋力，也能強化其在不同時空背景下的適用性，進一步為國道交通安全管理與政策規劃提供實證基礎。

綜上，本研究建立了一套具操作性與可讀性的風險分析與預測流程，不僅凸顯事故密度在風險判斷中的關鍵性，也為後續研究提供清晰方向。在資料擴充與模型優化後，該流程可更有效支援國道安全政策與管理決策，提升國道系統整體安全與效率。

五、參考文獻

交通部（2023），第一章 國道高速公路管理維護及新建拓寬—第一節 交通管理，收錄於 112 年交通年鑑，交通部（編），臺北：交通部。

- 交通部臺灣高速公路局（2013 年），高速公路相關資訊，擷取日期：2025 年 7 月 21 日，網站 <http://www.freeway.gov.tw/Publish.aspx?cnid=1906>。
- 艾嘉銘、楊宗璟（2010），「高速公路多事故路段發生頻率與傷亡機率影響因素分析」，99 年道路交通安全與執法研討會論文集。
- 吳健生、李嘉祺、曾招雄、楊雲榮（2002），「結合地理資訊系統特性之事故分析研究」，91 年道路交通安全與執法研討會論文集。
- 胡大瀛、李岳洪（2021），《數據不平衡下以機器學習方法預測交通事故嚴重性之分析》，收錄於《運輸計劃季刊，第五十一卷，第四期》。
- 張斯涵（2023），利用統計預測與機器學習從駕駛行為預測事故風險之研究，國立陽明交通大學運輸與物流管理學系碩士論文。
- 陳威男（2008），高速公路交通事故之巨觀與微觀分析，逢甲大學交通工程與管理學系碩士在職專班碩士論文。
- 黃燦煌、劉泰吾（2020），「以迴歸模型探討高速公路交通事故特性」，109 年道路交通安全與執法研討會論文集。
- 葉志宏（2015），以空間分析方法探索臺北市交通事故頻次之分布型態，國立陽明交通大學運輸與物流管理學系碩士論文。
- 簡筑君（2023），應用分群技術分析台中市交通事故調查資料之研究，國立中興大學應用數學系碩士論文。
- Anderson, T. K. (2009), "Kernel Density Estimation and K-Means Clustering to Profile Road Accident Hotspots," *Accident Analysis & Prevention*, Vol. 41, No. 3, pp. 359-364.

