

基於多元線性迴歸模型及可解釋機器學習模型之精準執法成效分析

Investigating The Effect of Precision Enforcement by Using Multiple Linear Regression and Explainable Machine Learning Models

盧冠仁 Guan-Ren Lu¹

吳元維 Yuan-Wei Wu²

摘要

近年警察機關為提升交通執法防制交通事故之成效，漸從以往追求執法件數之績效管理過渡至針對多事故時空因素投入警力之精準執法策略。精準執法策略不強調執法件數之成長，透過縝密的執法勤務規劃嚇阻交通違規行為發生，進而達到交通違規及交通事故同時減少的目標。本研究分別以多元線性迴歸及基於隨機森林演算法之局部累積效應模型，探討 238 處多事故路口在實施精準執法後，執法取締件數變化與交通事故件數變化之關係。結果發現，多元線性迴歸模型中各執法解釋變數之迴歸係數均不具顯著性，顯示實施精準執法後，執法取締件數變化對交通事故件數之增減影響有限，但可能因精準執法之外顯特徵-「見警率」，對事故防制產生顯著效果；隨機森林之模型顯示全般違規、重大違規及爭道行駛等項目之取締件數增減倍率對交通事故變化影響程度最大；局部累積效應模型指出，實施精準執法後即使執法取締件數未增加，路口交通事故仍可降低 20% 至 40%。本研究之成果展現精準執法之成效，並討論了在多違規路口加強交通執法以防制事故的成效與其極限，可作為執法實務單位規劃、推動及評估執法策略之參據。

關鍵詞：精準執法、多元線性迴歸、隨機森林、局部累積效應

¹中央警察大學交通學系研究生。

²中央警察大學交通學系兼任助理教授及桃園市政府警察局交通警察大隊警務員(聯絡地址：33304 桃園市龜山區大崗里樹人路 56 號，E-mail: d04521010@ntu.edu.tw)

Abstract

In recent years, to enhance the traffic enforcement effectiveness and prevent crashes, police agencies have shifted their focus to precision enforcement. This strategy considers spatial and temporal factors associated with high crash frequencies, rather than solely relying on counting traffic citations. The growth of traffic citations, which was the core of conventional policing performance management, is no longer emphasized. Precision enforcement aims to deter traffic violations and reduce traffic crashes by planning police duty meticulously at crash-prone locations. This study investigated the relationship between changes in traffic citation numbers and crash frequencies after the implementation of precision enforcement projects at 238 crash-prone intersections. Multiple linear regression (MLR) and accumulated local effects (ALE) models with random forest algorithm were employed. The results show that the changes in traffic citation numbers have limited influence on crash frequency changes, evidenced by the non-significant regression coefficients of explanatory variables in the MLR model. However, increased police visibility, a hallmark of precision enforcement, might be a significant factor that contributes to crash prevention. The result of random forest model reveals that the total number of citations, major violation citations, and illegal lane usage citations are the most influential predictors of crash frequency changes. The ALE model demonstrates that precision enforcement can achieve a reduction in crash frequency of 20% to 40%, even if traffic citation numbers decrease. This study highlights the effectiveness of precision enforcement and demonstrates the limitations of traffic enforcement at violation-prone intersections.

Keywords : *Precision Enforcement*、*Multiple Linear Regression*、*Random Forest*、*Accumulated Local Effects*

一、緣起

交通違規行為是影響交通安全的關鍵，交通事故經常是因侵略性駕駛行為或交通違規所引起(Mccartt 與 Hu, 2014)，若道路上的交通違規行為減少，可預期交通事故的傷亡會隨之降低(Factor, 2014)，提升交通執法強度可以促使用路人遵守交通規則，但隨著執法強度降緩，遏止交通違規的效果可能會逐漸消失(Stanojević 等人, 2013)，可見交通執法活動確實會對駕駛人的行為和態度產生影響，進而在一定程度上影響交通事故發生的可能性。

依交通部道安資訊查詢網資料(交通部, 2023)，近五年(107 至 111 年)全國共發生 175 萬 8,533 件死傷交通事故，且呈逐年上升趨勢，111 年較 107 年增加 17.3%。近五年發生在路口之死傷交通事故計 99 萬 4,986 件，佔總件數達 56.6%，防制路口交通事故已成為交通及警政單位當務之急。此外，依據內政部警政署資料(警政統計年報, 2023)，各警察機關 107 年至 111 年全般交通取締件數亦呈上升趨勢，111 年相較 107 年之增幅已超過 30%，顯示持續增加交通執法取締件數仍難以遏止交通事故增加之趨勢，亦使得警察機關開始思考長久以來的交通執法作為是否仍能有效防制交通事故，以

及警力是否確實在多事故之熱時、熱點進行執法。內政部警政署自 112 年 5 月起要求各縣市政府警察局針對路口編排「高發事故路口精緻執法」專案勤務，而早在 112 年 1 月起，桃園市已率先針對多事故路口試辦精準執法策略，投入警力於肇事之熱時、熱點，提升見警率並加強各類違規行為之執法取締工作。

目前交通安全研究領域並無警察機關實施精準執法成效之探討，本研究將探討桃園市 112 年 1 至 4 月實施精準執法防制事故的成效，從而深入了解精準執法之勤務作為以及執法件數的變化如何影響交通事故增減，探知交通執法勤務對交通安全的貢獻程度，預期成果將可供警察機關作為交通執法勤務規劃及成效評估之參據。本文後續章節安排如下：第二章探討以交通執法防制交通事故及交通安全建模之相關文獻，第三章介紹資料蒐集與研究架構、資料敘述統計及所使用的研究方法，第四章則逐一討論不同模型之分析結果，最後在第五章提出結論以及未來研究建議。

二、文獻回顧

2.1 交通執法與交通安全

2.1.1 以交通執法防制交通事故

以交通執法防止駕駛人的交通違規行為，是普遍認為可以改善交通安全的具體方法，基本原理是認為交通執法能對駕駛人產生威懾作用，因為不願受處罰，進而改變其駕駛行為，或改變對違規行為的態度，趨向保守及遵守法令規定。對防制交通事故所需的成本而言，交通執法相比其他改善措施，具有非常高的成本效益 (European Transport Safety Council, 1999)；另有研究指出在缺乏交通執法的地區，交通違規和侵略性駕駛行為會更頻繁發生(Stanojević 等人，2013)，顯見交通執法確實對道路交通秩序與安全產生顯著的助益。Ali 等人(2019)的研究則發現，中高收入國家(UMICs)交通執法不力的現況，可能是交通事故傷亡人數不斷上升的一項因素。

為了解交通執法對事故防制效果的延續程度，有學者探討交通執法的時間光圈效應(Time halo effect)，其意義是在具有威懾交通違規效果的執法人員離去、或駕駛人遭受違規舉發後，交通執法對駕駛人行為能約束多久的時間。Elliott 與 Broughton(2005)的研究指出時間光圈效應可持續 2 小時至 8 週不等，Wu 與 Hsu (2021)以臺灣的交通執法資料進行研究後指出，時間光圈效應可達 30 天以上，相關研究都指出交通執法對駕駛人行為和態度產生的作用，可在數週的期間內持續發揮效用。

交通違規既然是潛在的交通安全危害因子，交通違規行為應可作為交通事故預測模型的預測因子(predictor)之一；然而，全面且持續地監控道路上各式各樣的交通違規行為，將耗費大量資源且不切實際，基於交通執法的光圈效應研究成果，將交通違規取締資料(例如：警察舉發的交通罰單數量)作為數週或數月等較短期間分析模型中違規行為的替代因子，遂成為可行的方案；但迄今為止的相關研究中，仍只有少數研究利用交通違規取締資料作為交通安全分析模型的預測因子(Coruh 等人, 2015; Wu 與 Hsu, 2021)，因此，利用交通違規取締資料進行交通安全分析，仍極富研究潛力且值得深入探討與關注。

2.1.2 精準交通執法策略

交通執法是透過派遣警力、擴大巡邏區域等提升見警率的作為加以實行，並針對員警所見的交通違規行為予以舉發，近年則應用科學儀器的輔助，不受時間與警察勤務編排之限制，不間斷地監控特定地點之違規行為並予以舉發；Pantangi 等人(2020)指出，提高交通執法的能見度，能讓駕駛人清楚了解旅次中可能遭遇到交通執法活動，有助於減少危險駕駛(超速、逼車迫近、驟然變換車道)、闖紅燈、未依規定讓車及其他侵略性的駕駛行為。

雖然針對高風險和侵略性的駕駛行為，規劃明顯且精準的執法勤務作為，將能促使駕駛人更確實遵守交通法規，減少因違規所導致的交通事故，但如同第一章所討論的我國現況，近年交通執法件數與交通事故件數同步增加，顯示當前的執法實務可能無法有效防止事故發生。此現象或與警察機關長期採用績效管理制度有關，在強調執法績效達成率的要求下，忽略執法與交通事故防制目標的關聯性，具體現象是多事故的時間和地點仍缺乏有效的執法勤務或科技執法設備。注意到此現象的警察機關已逐步開始推動精準執法策略，如內政部警政署自 112 年 5 月起要求各縣市政府警察局針對路口編排「高發事故路口精緻執法」專案勤務，加強取締車不讓人、非號誌化路口未依標誌標線號誌停車再開、人行道違規停車、道路障礙等違規行為，桃園市亦在 112 年 1 月起試辦實施精準執法策略。

內政部警政署的「精緻執法」與桃園市執行之「精準執法」，名稱雖有不同，但究其內涵及概念係屬同質，雖然內政部警政署列舉出多項違規作為執法重點，但本研究參考醫界強化患者基因分析、對症下藥之「精準醫療」(Precision medicine)趨勢與概念(Pelter 與 Druz, 2022)，認為依據各地區肇事之時空特性所規劃的執法策略，與「精準執法」一詞更為契合，故本研究將嘗試為「精準執法」進行明確的定義，以作為警察機關規劃執法策略之參據。

目前針對精準執法尚無文獻加以研究及明確定義，綜觀近年警察機關執法之相關指導原則，以及交通執法防制交通事故的本質，本研究嘗試將精

準執法定義為：「分析交通事故集中之時、空特性，將造成交通事故之違規行為作為執法對象，據以規劃交通執法勤務實施之時段、地點，以及科技執法設備之部署地點與取締項目，以達到同時降低交通違規及交通事故件數的最終目標」。精準執法異於傳統績效管理制度下的執法策略，因其不要求基層警察單位增加執法件數，而是以防制並降低交通事故為目標，透過勤務員警立於路口明顯位置嚇阻違規、在指定路段增加巡邏密度，或設置科技執法設備，以精準提高見警率及明確打擊目標違規行為等方法，減少違規行為發生頻率、防制交通事故發生，從而確認實施精準執法的終極目標與實施過程，都希望達到違規取締件數(含未被警方發現的違規行為)與交通事故件數同時下降的成果，不僅可解決現行交通執法績效管理制度中，基準件數逐年增加、與防制事故目標脫鉤等問題，亦可更有效運用有限警力，並避免社會輿論站在交通執法的對立方，進而支持警方執法作為。

2.2 交通安全分析模型

傳統交通安全分析模型的主要目的是為了探討影響交通事故發生頻率(件數)或交通事故嚴重程度的因子，交通事故頻率的探討可在巨觀層級(國家、州、縣、市或特定地理空間範圍)或微觀層級(路口、路段)進行，美國公路容量手冊(Highway Capacity Manual)將特定地點的年平均交通事故件數分析方法稱為安全績效函數(Safety Performance Functions)。相較於交通事故頻率模型，交通事故嚴重程度的分析則在個別交通事故當事人或肇事案件的尺度進行。

交通事故頻率分析可從政策實行者的角度發掘影響交通事故增加或減少的因子，相關知識可應用於後續改善政策的推行，文獻中常見的潛在影響因子包含交通特性、道路幾何設計與設施配置、社會經濟特性及天氣與環境等因子。然而許多國家或地區由於缺乏相關的資訊系統或數據資料，使得蒐集交通安全分析模型所需資料的時間及人力成本昂貴而難以進行。此外，交通量、道路幾何設計及社會經濟等特性在短期(數週至數月)內的變化相對較小，難以解釋短期內交通事故頻率的變化；相較之下，警方取締交通違規的資料因容易蒐集，且有相關文獻支持交通執法與防制交通事故的關聯性，使執法取締資料有潛力成為短期交通事故頻率分析模型的解釋變數(Wu 與 Hsu, 2021)。

數十年來，Poisson 迴歸模型(Poisson Regression)、負二項式迴歸模型(Negative Binomial Regression)、貝葉斯模型(Bayesian Models)和時間序列模型(Time Series Models)等統計方法已廣泛運用於交通事故頻率分析和預測上。近年隨著電腦運算能力的大幅進展，交通安全領域中許多研究開始應用最新的機器學習和深度學習方法提升模型的能力，這些演算法包括推進法

(Boosting)、隨機森林(Random Forest)、支持向量機(Support Vector Machine)、反向傳播神經網絡(Back Propagation Neural Network)、卷積神經網絡(Convolutional Neural Network)、長短期記憶神經網絡(Long-Short Term Memory Neural Network)以及可結合各種神經網路和機器學習方法的融合深度學習(Fusion Deep Learning)模型(Wu 與 Hsu, 2021)。

傳統的交通安全分析模型並未特別側重交通執法解釋變數的探討，且僅以交通執法件數作為解釋變數，模型可能遭受潛在的多重共線性影響，因為實務上警方的執法勤務，尤其是攔停執法，可同時取締多種違規行為，使得某項交通違規取締件數增加的同時，其他交通違規取締件數也可能一同增加；另因執法取締件數與作為反應變數的交通事件數之間的變數內生性，會使得建模結果難以合理解釋。在此情境下使用機器學習或深度學習方法進行建模，可獲得更優異的分析結果，不僅無須困擾於變數內生性的解釋，也不用為了消除多重共線性而自模型中排除任何變數，這代表可詳細探討所有與執法取締有關的解釋變數，更符合實務上的應用。

機器學習和基於類神經網路等數據驅動(data-driven)方法，雖然具有優秀的預測與分析能力，但這些方法經常被稱為「黑箱(black-box)」，因其難以揭示特定解釋變數如何影響模型的輸出(Mannering 等人, 2020)。為了讓優秀的數據驅動模型不至於犧牲太多解釋能力，近年來可解釋的機器學習模型(explainable machine learning models)逐漸獲得重視並已應用於交通安全分析領域(Wu 與 Hsu, 2021; Yuan 等人, 2022)，相關應用方法如基於隨機森林演算法之局部累積效應分析(Accumulated Local Effects, ALE)，其原理主要是計算演算法中目標式的改善程度，及計算變數增減後的邊際效用，揭露出解釋變數對模型輸出的影響。

為探討目前交通安全領域尚未受到關注的精準執法議題，本研究將作為先驅，探討精準執法防制交通事故的成效。具體作法是運用以迴歸為基礎的模型，探討執法取締件數的變化是否會對交通事故件數之消長造成影響。本研究先以多元線性迴歸模型探討實施精準執法的地點中，數個主要執法取締項目與交通事故件數變化間的關係，並考量多元線性迴歸模型可能無法有效解析資料間複雜的非線性關係，本研究進一步以可解釋的機器學習模型萃取資料中的潛在訊息，藉由洞察變數間複雜的關聯性，探討精準執法對於交通事故件數增減的影響。研究成果將可揭示精準執法及各項交通違規取締作為防制交通事故的成效，可成為執法實務單位規劃執法策略與交通事故防制勤務的參考。

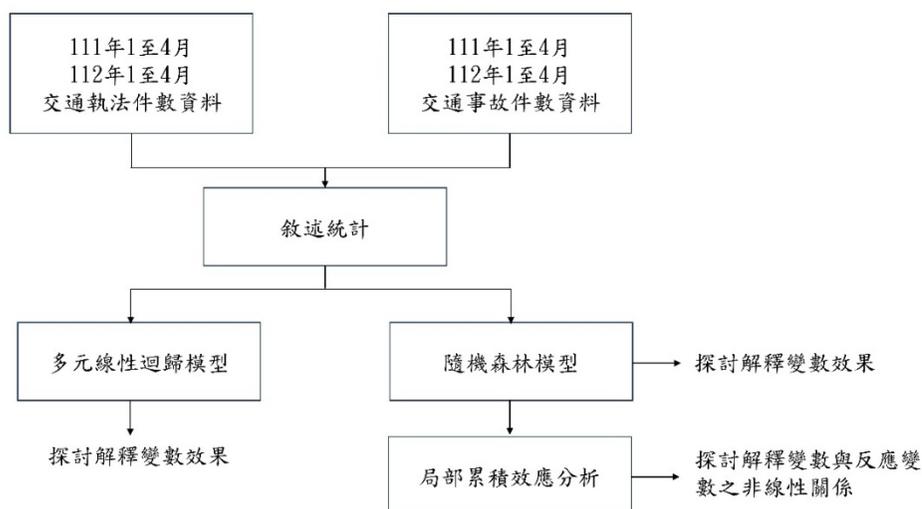
三、資料準備與研究方法

3.1 資料準備與研究架構

桃園市政府警察局於 112 年 1 至 4 月，針對 111 年 1 至 4 月發生交通事故件數超過 4 件(每月平均超過 1 件)以上之 281 處多事故路口試辦精準執法策略。本研究針對試辦精準執法策略路口之執法成效進行分析，但為聚焦在警察機關派遣警力維護交通安全成效之探討，本研究僅討論派遣警力執行攔停取締(physical policing)之精準執法策略，運用科技執法設備之策略則不在本研究範圍內。

本研究蒐集桃園市政府警察局試辦精準執法策略之 281 處路口之交通事故及執法資料，排除 111 年 5 月至 112 年 4 月間實施工程改善及科技執法之路口計 43 處，針對餘 238 處路口，分析 111 年 1 至 4 月及 112 年 1 至 4 月交通事故件數與執法取締件數之變化，探討精準執法之成效以及執法強度變化對交通事故件數增減程度的影響。另因研究期間較短，本研究假設研究期間內之社會經濟條件、交通量、駕駛人整體行為表現均視同不變。

本研究之研究架構如圖 1 所示。首先蒐集交通事故及執法取締件數等資料並加以整理後，先以敘述統計進行初步討論，再將資料輸入多元線性迴歸模型及隨機森林模型進行解釋變數的探討，最後基於隨機森林模型實行局部累積效應之分析，完成可解釋機器模型的分析模式，以探討變數間的非線性關係。



資料來源：本研究整理。

圖 1 研究架構

本研究採用之多元線性迴歸模型及隨機森林模型之模型及變數設定說明如下：

(1)模型基本設定：

影響路口發生交通事故件數之因素可能包含交通工程、曝光量及其他社會經濟特性，但這些因子在短期(數週至數月)內的變化程度較低，與之相較，交通執法在短期內對交通安全績效的影響較為明顯(Wu 與 Hsu, 2021)。許多交通事故頻率模型以道路幾何設計及交通狀況作為解釋變數，但目前已有研究(Wu 與 Hsu, 2021)將交通違規取締變數作為較短期間內交通事故件數的預測因子(predictor)，因本研究蒐集的資料涵蓋期間僅4個月，且為探討執法活動防制交通事故的效果，本研究遂以多種交通執法取締項目作為模型之解釋變數，交通事故發生情形作為反應變數。但模型的反應變數與解釋變數並非直接使用交通事故件數與違規取締件數，容後詳細討論。另基於警察攔停執法對於違規人之行為可能有立即影響之假設，本研究並未考量介入行為與產生結果間的時間落差(time lag)。

(2)反應變數與解釋變數：

一般交通事故頻率模型係直接以樣本地點之交通事故件數作為解釋變數，然若交通事故頻率模型中僅有交通執法解釋變數，形同以交通執法取締件數決定交通事故發生件數，並非合理的模型設定。另為避免樣本地點因交通工程、曝光量及其他社會經濟特性的異質性影響建模結果的合理性，本研究以路口交通事故之變化倍率作為模型之反應變數，並以路口範圍內交通執法取締件數之變化倍率作為模型之解釋變數，此設定除了在變數關係的設定上較為合理，亦符合實務應用與理解。因本研究並非以文獻中常見的交通事故頻率作為反應變數，必須注意模型輸出結果的解釋方式。

(3)解釋變數之違規項目選擇：

- a.本研究首先將「全般違規」納入模型，目的在於能分析總取締件數增減的效果。
- b.其次將「重大違規」納入模型，因重大違規係內政部警政署實施多年且最受各警察機關重視的執法專案，包含闖紅燈、嚴重超速、酒後駕車、逆向行駛、轉彎未依規定、機車行駛禁行機車道、機車未依規定兩段式左轉等7項違規樣態。
- c.本研究接著將重大違規以外、警察機關取締交通違規件數最多的4項違規樣態納入模型，包含爭道行駛、違規迴轉、違停及違反標誌標線號誌指示等違規行為；該4項違規行為及重大交通違規行為之取締

基於多元線性回歸模型及可解釋機器學習模型之精準執法成效分析

件數合計，已占警察機關取締交通違規件數之 55% 以上(警政統計年報，2023)。

d. 本研究亦納入 112 年與「行人地獄」議題有關、深獲中央及輿論重視的未禮讓行人及行人違規等 2 項違規行為。

以上總計 8 項執法解釋變數，分別為全般違規、重大違規、爭道行駛、違規迴轉、違停、不禮讓行人、違反標誌標線號誌指示及行人違規等 8 項取締違規樣態。其中須注意的是，除了「重大違規」內含 7 項違規樣態，「違停」亦包含違規停車及違規臨時停車。本研究將重大違規之 7 種違規樣態及將違規停車與違規臨時停車等 2 種違規樣態分別納為同一項變數，主要是為了降低模型之複雜度，利於分析討論及解釋，並避免執法解釋變數間產生多重共線性。此外，「重大違規」本為警察機關執法之重點專案名稱，所包含之 7 種違規樣態合併討論亦符合實務情境；違規停車與違規臨時停車在執法作為上性質相近，納為同一執法解釋變數亦屬合理。

本研究所探討實施精準執法之 238 處路口，交通事故件數及增減情形之敘述統計如表 1 所示。部分路口至多減少 8 件交通事故，但亦有路口之交通事故件數增加，增加最多達 5 件，平均而言每處路口交通事故件數減少 2.05 件。

表 1 路口交通事故件數敘述統計表

項目	最小值	最大值	平均值	標準差
111 年 1 至 4 月事故件數	4	14	5.03	1.49
112 年 1 至 4 月事故件數	0	11	2.98	2.32
事故件數增減	-8	5	-2.05	2.26

交通事故件數增減倍率統計如表 2 之第一列所示，各樣本路口中，交通事故件數至多可減少 1 倍(減少 100%)，件數增加最多之路口可達 1.25 倍(增加 125%)，所有實施精準執法之路口交通事故件數平均可減少 0.4 倍(減少 40%)。

交通執法取締件數之變化臚列於表 2 之第二列至最末列。可發現在實施精準執法後，各項違規之取締件數至多會減少 1 倍(減少 100%)，但整體而言 8 類違規取締件數均增加 0.01 倍至 0.64 倍之間(增加 1%至 64%)，增加倍率較多的取締項目包含不禮讓行人(至多達 43 倍)、爭道行駛(至多達 30.67 倍)；然而，全般違規件數增加倍率平均僅達 0.09 倍(增加 9%)，顯示實施精準執法後，總執法取締件數未發生明顯變化。

表 2 變數敘述統計表

變數		最小值	最大值	平均值	標準差
反應變數	事件數增減倍率	-1	1.25	-0.40	0.46
解釋變數	全般違規增減倍率	-1	3.4	0.09	0.73
	重大違規增減倍率	-1	10.33	0.07	1.19
	爭道行駛增減倍率	-1	30.67	0.48	2.95
	違規迴轉增減倍率	-1	4	0.01	0.45
	違停增減倍率	-1	16	0.50	1.79
	不禮讓行人增減倍率	-1	43	0.64	3.16
	違反標誌標線號誌指示增減倍率	-1	9	0.34	1.4
	行人違規增減倍率	-1	1	0	0.13

交通事故增減倍率與各交通執法變數增減倍率之次數分配如圖 2 所示，其中，各子圖之橫軸為增減倍率，縱軸為路口數量；從圖 2(a)可發現，大多數路口之事故增減倍率呈負值，甚至有近 30 路口之事件數減少 1 倍(即減少 100%)，且僅有少數路口成長，顯示所研究之樣本路口在實施精準執法後交通事故減少情形相當明顯；自圖 2(b)至圖 2(i)中可發現，各執法解釋變數之增減程度雖有差異，但大抵呈現明顯的右偏資料分布型態，且路口計數最多的取締件數增減倍率為 0，除顯示取締件數未增加或減少之路口多於取締件數增加的路口，亦代表精準執法實施後，有相當高比例的路口違規取締件數仍與過往相近。

基於多元線性回歸模型及可解釋機器學習模型之精準執法成效分析

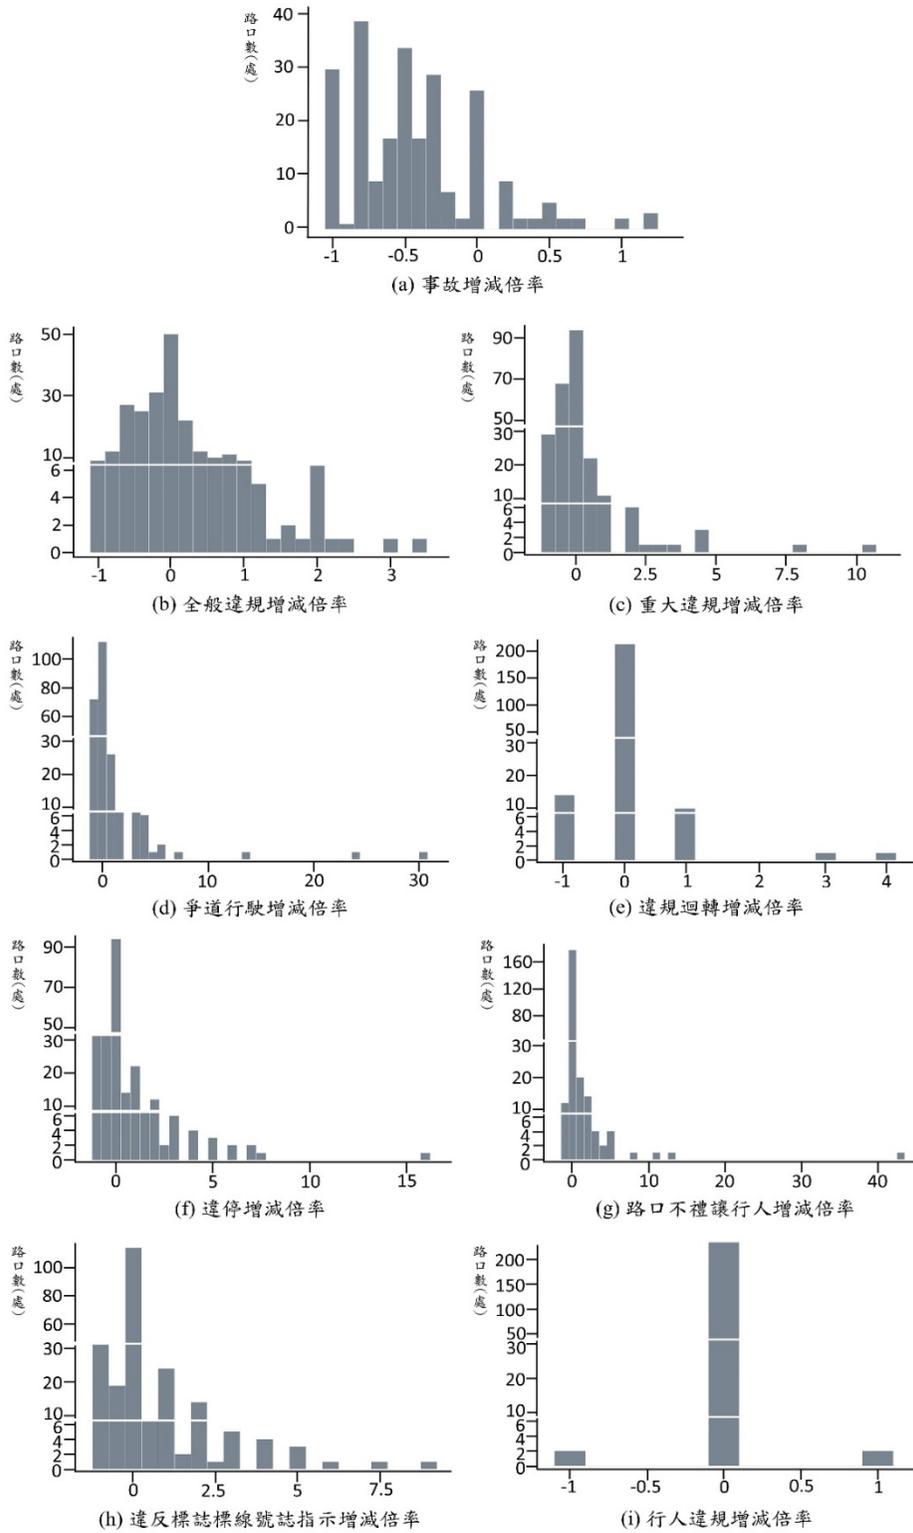


圖 2 交通事故及交通執法變化倍率次數分布圖

3.2 研究方法

為探討執法取締件數變化對交通事故件數增減程度的影響，本研究先以多元線性迴歸模型進行分析，再使用可解釋的機器學習模型—隨機森林演算法搭配局部累積效應分析，以探討多元線性迴歸模型無法掌握的變數間潛在非線性關係。

3.2.1 多元線性迴歸

本研究先以多元線性迴歸模型探討 8 項執法解釋變數對交通事故變化倍率的影響，多元線性迴歸模型如式(1)：

$$y = \beta_0 + \sum_{k=1}^K \beta_k x_k + \varepsilon \quad (1)$$

其中， y 為反應變數， β_0 為截距項， x_k 及 β_k 分別為解釋變數及其估計之係數， ε 則為誤差項。截距項在此模型中的意義為：實施精準執法後，執法件數無變化時交通事故的增減倍率，可視為僅有見警率但執法件數無變化時的效果。多元線性迴歸模型之前提條件是解釋變數不具多元共線性，本研究以變異數膨脹因子(Variance Inflation Factor, VIF)診斷模型是否具多元共線性，計算方式如下：

$$VIF_i = \frac{1}{1 - R_i^2} \quad (2)$$

式(2)中， VIF_i 為第 i 個解釋變數之 VIF 值， R_i^2 為將第 i 個解釋變數視為反應變數所得之判定係數。一般而言，當 VIF 值大於等於 10 時，可認定解釋變數之間有共線性問題，需考慮移除該解釋變數或進行模型調整。本研究進行多元線性迴歸模型的診斷後，發現 VIF 值均小於 2，因此多元線性迴歸模型可適用於 8 項執法解釋變數之建模。

3.2.2 隨機森林演算法

考量多元線性迴歸模型可能無法有效萃取出解釋變數與反應變數間複雜的非線性關係，本研究另使用機器學習模型進行深入探討。隨機森林是一種以集成決策樹為基礎的機器學習演算法，Breiman(2001)提出之後，隨即在各研究領域及實務中獲得廣泛的應用。集成決策樹演算法是基於原始資料集多次重複自我抽樣(bootstrap)的資料集建立多個決策樹，應用於分類問題時，使用多數投票算法(majority voting)決定模型輸出，若用以建立迴歸模型，則會將每棵決策樹的預測結果進行平均作為最終模型輸出。然而，若建立決策樹時的每次分支都考量所有解釋變數(即為 bagging，套袋法)，對演

算法目標式較為有效的解釋變數會主導分支的過程，而使得大部分的決策樹具高度相關性，無法有效提升模型能力。隨機森林演算法透過降低決策樹間的相關性以提升模型表現，具體方法是在建立決策樹的分支過程只考量解釋變數的隨機子集合，各決策樹的預測結果具有高變異及低誤差的特性，從而提升集成決策樹的模型輸出表現。

隨機森林演算法中，解釋變數的隨機子集合大小 m 並無明確規範，基本原則是要小於解釋變數的個數 p ，有學者(James 等人, 2013)建議 $m \approx \sqrt{p}$ ，而部分分析軟體的套件預設值則設定為 $m \approx p/3$ (如 R 軟體的 randomForest 套件)。

相較於多元線性迴歸或單一決策樹的模型，集成決策樹模型無法直接指出解釋變數對反應變數的影響效果，但可以透過集成決策樹的演算法中目標式的改善程度，如殘差平方和(Residual Sum of Squares, RSS)下降或 Gini 係數(一種衡量資料亂度的指標)下降的累積量，計算各解釋變數對於模型輸出結果的相對重要性，較大之數值即代表該解釋變數較為重要，以此維持集成決策樹模型的解釋能力。

3.2.3 局部累積效應

前一小節討論的解釋變數相對重要性，雖然可提供解釋變數對反應變數影響程度的資訊，但仍不足以獲知解釋變數對模型輸出的具體影響程度。Friedman(2001)提出部分相依圖(Partial Dependence Plot, PDP)以探討特徵變數(feature)對反應變數的邊際效果。然而 PDP 之分析須假設各特徵變數間為獨立，應用上較為受限，為解決特徵變數可能非獨立的情形，Apley 與 Zhu(2019)提出了累積局部效應(Accumulated Local Effects, ALE)代替 PDP 萃取特徵變數對反應變數的邊際效果，ALE 與 PDP 的差異容後討論。令 X_j 為欲探討的特徵變數， X_C 為其他特徵變數的集合， $f(\cdot)$ 表示用來預測反應變數所配適的模型，則特徵變數 x_j 對可微分的函數 $f(\cdot)$ 的局部效應定義為：

$$f^j(x_j, x_c) \equiv \frac{\partial f(x_j, x_c)}{\partial x_j} \quad (3)$$

ALE 計算指定的特徵變數在其值 $x_j = z_j$ 且其他特徵變數的值為 x_c 時的局部效應，並將此局部效應在所有 x_c 所組成的參數空間中以權重 $p_{c_j}(x_c | z_j)$ 進行平均。最後，ALE 累加所有 x_j 可能值 z_j 的平均局部效應，得到 ALE 的主要效應，表示如下：

$$\begin{aligned}
 g_j ALE(x_j) &= \int_{X_{min,j}}^{X_j} E[f^j(X_j, X_C) | X_j = z_j] dz_j \\
 &= \int_{X_{min,j}}^{X_j} \int p_{c|j}(X_C | z_j) f^j(z_j, X_C) dx_c dz_j
 \end{aligned}
 \tag{4}$$

其中， $g_j ALE(x_j)$ 表示特徵變數 X_j 未中心化的 ALE 主要效應。與其相對，中心化的 ALE 主要效應另以 $f_j ALE(x_j)$ 表示。中心化的意義在於 ALE 相對於 X_j 的邊際分布具有平均值為 0 的特性，可定義為：

$$\begin{aligned}
 f_j ALE(x_j) &= g_j ALE(x_j) - E[g_j ALE(X_j)] \\
 &= g_j ALE(x_j) - \int p_j(z_j) g_j ALE(z_j) dz_j
 \end{aligned}
 \tag{5}$$

相較於 PDP 是基於特徵變數的邊際分布而可能產生與實際資料分布不同的問題，ALE 則考慮實際資料的條件分布，以解決特徵變數之間相關性造成的影響，應用情境更廣，還可萃取出資料中的非線性關係，且運算速度比 PDP 更快。ALE 十分適合應用在被稱為黑箱的機器學習模型，以分析特徵變數對反應變數的貢獻。本研究使用 ALE 結合隨機森林模型，以探討執法解釋變數如何影響模型輸出結果。

四、分析結果討論

4.1 多元線性迴歸

交通事故件數增減倍率之多元線性迴歸模型估計結果如表 3 所示。

表 3 多元線性迴歸模型估計結果

解釋變數	估計值	標準差	t 統計量	p 值
截距項	-0.431	0.032	-13.298	<0.001
全般違規增減倍率	-0.007	0.049	-0.139	0.890
重大違規增減倍率	0.034	0.029	1.166	0.245
爭道行駛增減倍率	0.008	0.011	0.789	0.431
違規迴轉增減倍率	0.005	0.068	0.076	0.940
違停增減倍率	0.028	0.017	1.659	0.099
不禮讓行人增減倍率	0.017	0.010	1.725	0.086
違反標誌標線號誌指示增減倍率	-0.012	0.022	-0.573	0.567
行人違規增減倍率	-0.232	0.240	-0.965	0.336
R-squared	0.04			

由模型估計結果可知，因判定係數(R-squared)過低，顯示執法解釋變數的變化無法有效解釋交通事故件數倍率的變化，此外，各執法解釋變數之迴歸係數亦不具顯著性(P 值 > 0.05)，顯示各項違規行為的執法取締件數變化對交通事故增減倍率影響有限，或兩者之間具有多元線性迴歸模型無法分析的複雜非線性關係，因此，本研究將再以可解釋的機器學習模型探討資料中是否確實具有複雜非線性關係。

值得注意的是，模型截距項之估計值為 -0.431 ， $P < 0.001$ ，說明即使違規取締件數沒有增減，實施精準執法的路口仍能達到大幅降低交通事故件數達 0.43 倍(減少 43%)。因本研究之 238 處樣本路口已排除工程改善或裝設科技執法設備之介入，且研究期間僅 4 個月，社會經濟環境的改變有限，故推測這顯著降低交通事故件數的成果可能來自於精準執法之外顯特徵—「見警率」。亦即在多事故路口實施明顯執法的作為，有機會可在數週至數月的短期內有效防制交通事故，此結果或可推測係因民眾發現有員警執勤而遵守交通規則，使得交通事故件數隨之降低。

4.2 隨機森林演算法

在 4.1 節中，多元線性迴歸分析模型可能無法有效解釋執法解釋變數的變化與交通事故件數倍率變化的關係，故本研究進一步運用機器學習模型，嘗試萃取出解釋變數與反應變數間的非線性關係。隨機森林模型具有良好的預測能力，但本研究運用隨機森林模型並非用以預測未來事故變化倍率，而是為了達成以下二項目的：(1)探討何種交通執法項目對交通事故變化具有較大的影響，以及(2)作為後續局部累積效應分析的基礎模型；局部累積效應分析的結果將在 4.3 節討論。

隨機森林模型的變數相對重要性分析結果如圖 3 所示，以全般違規增減倍率、重大違規增減倍率及爭道行駛增減倍率對模型輸出結果較為重要，違規迴轉增減倍率、行人違規增減倍率及違停增減倍率的影響力則較低。在表 2 中，全般違規增減倍率之平均值僅為 0.09，但隨機森林模型卻指出全般違規增減倍率是相對最重要的執法解釋變數，在多數路口事故件數皆減少的情形下，此分析結果或可代表精準執法防制交通事故的成效，已不需建立在大幅增加執法取締件數的基礎之上。

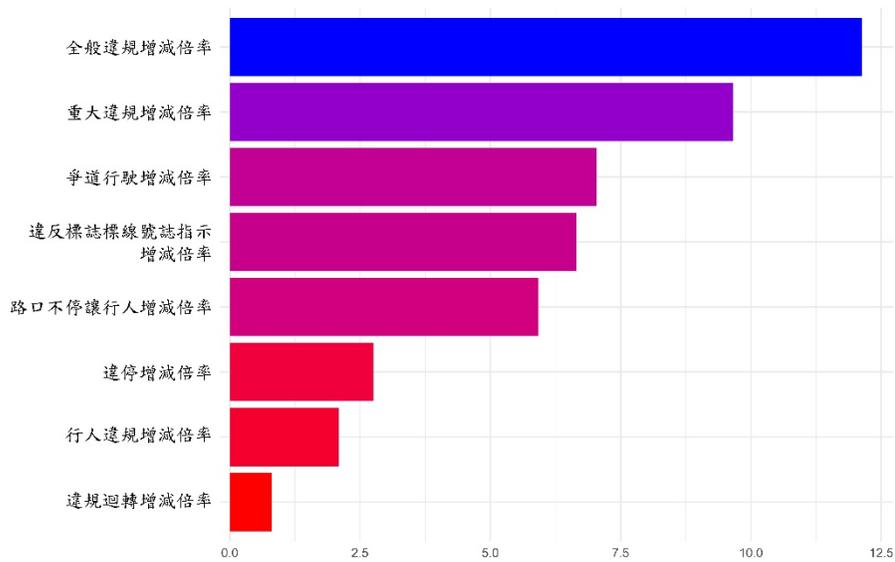


圖 3 隨機森林模型之變數相對重要性

4.3 局部累積效應分析

本研究運用局部累積效應分析，搭配隨機森林演算法，建立可解釋之機器學習模型，嘗試萃取出解釋變數與反應變數間的非線性關係，結果如圖 4 所示，各子圖的橫軸為執法解釋變數增減倍率，縱軸為事故件數增減倍率。須注意的是，圖 4 各子圖中交通事故防制效果在主要趨勢內的非線性變化，可能受各樣本地點特性與背景資料的影響而有所差異，因本研究未將各樣本路口之交通、環境與道路幾何特性納入分析，故僅針對主要趨勢進行探討。

雖然各執法解釋變數對交通事故增減的影響程度與趨勢不同，並且呈現出明顯的複雜非線性關係，仍可發現一致性的現象：即使執法取締件數未明顯改變，甚至是減少(即橫軸在 0 以下)的情形，路口交通事故仍可降低 0.3 倍(減少 30%)以上，最高甚至可降低超過 0.5 倍(減少 50%)，而且交通事故件數減少最明顯的情形，大多發生在執法取締件數未明顯改變，甚至是減少的情形之下。在個別執法解釋變數部分，則可發現全般違規取締倍率與重大違規取締倍率等 2 項變數減少後，可達到最好的事故減少效果(降低超過 0.5 倍)，此結果也與圖 3 隨機森林之變數重要性分析結果相呼應。其他 6 項執法取締變數減少交通事故備率的最佳效果僅落在 0.4 至 0.47 倍之間，整體而言，降低交通事故之最佳效果順序分別為重大違規、全般違規、路口不禮讓行人、行人違規、爭道行駛、違停、違規迴轉及違反標誌標線號誌指示。

基於多元線性回歸模型及可解釋機器學習模型之精準執法成效分析

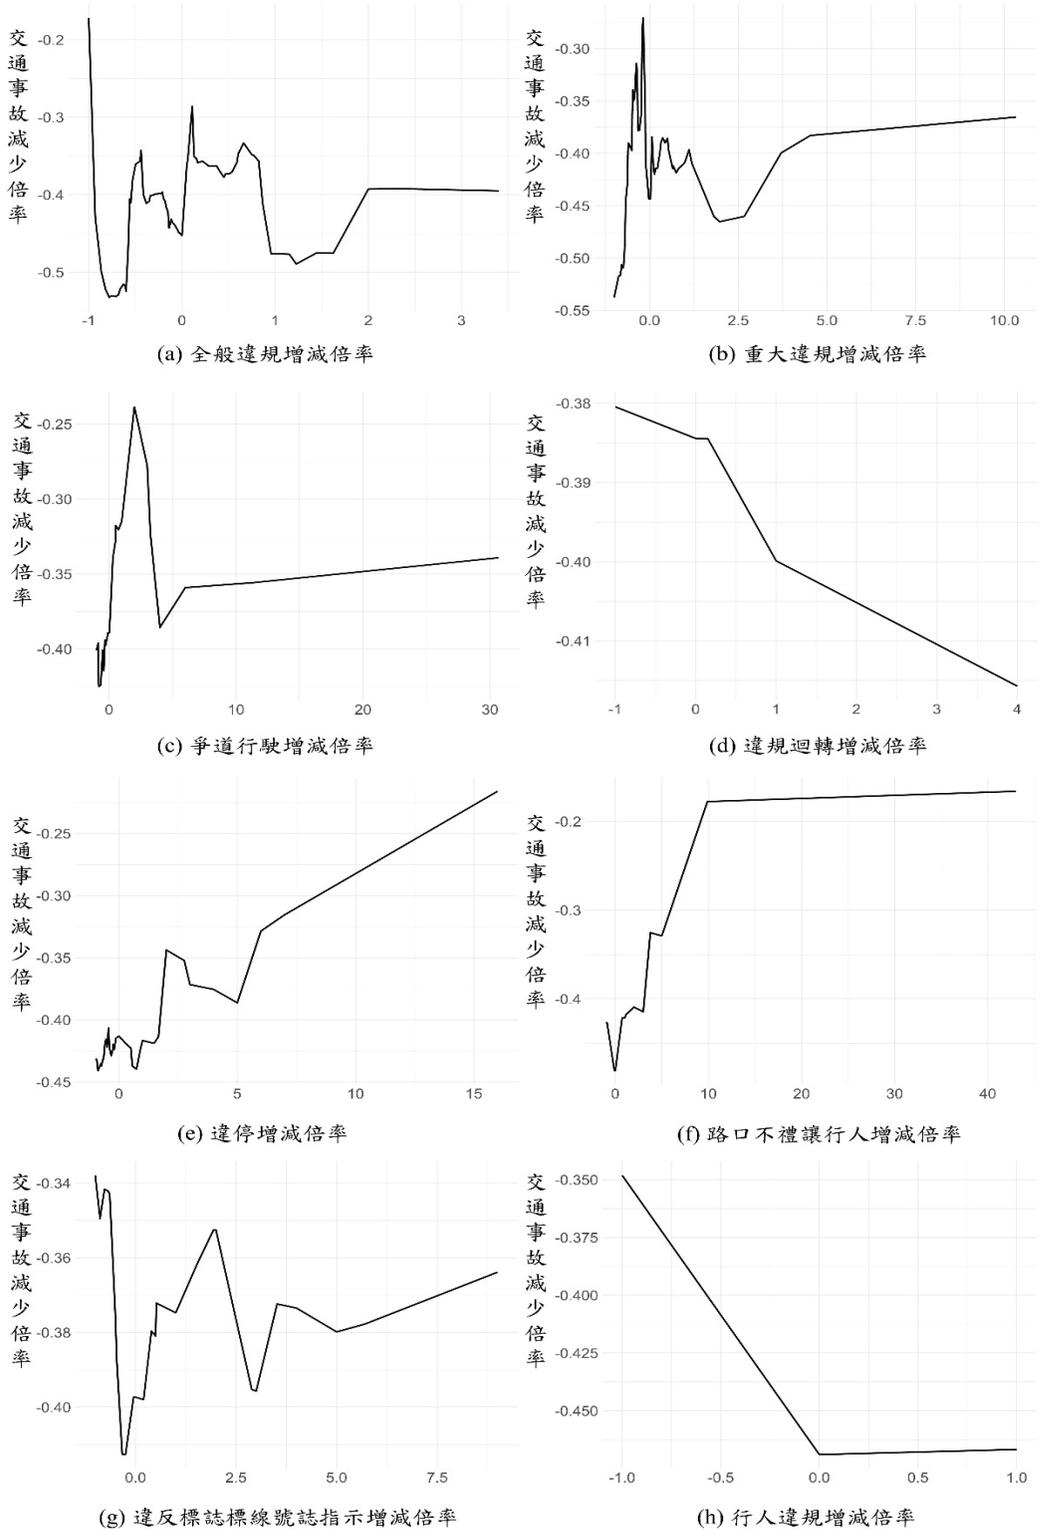


圖 4 局部累積效應分析結果

另外，在執法取締件增加的狀況中(即橫軸大於 0 的情形)，除了取締違規迴轉的件數增加能進一步降低交通事故件數，其他執法解釋變數的增加，反而對應到較差(但仍有效)的交通事故防制效果；以圖 4(e)為例，違規停車取締件數增加以後，交通事故降低的倍率反而自-0.44(減少 44%)左右增加至-0.25(減少 25%)以上。另外可發現全般違規、爭道行駛、違停、路口不停讓行人及違反標誌標線號誌指示的執法件數增加倍率大於 0 之後，防制交通事故的效果先急遽下降後再微幅進步，最終維持在較差的防制效果。

本研究為圖 4 的分析結果提出可能原因；首先，若精準執法策略是「有效的」，應能顯著地防制違規行為繼續發生，進一步減少交通事故，故有效的精準執法應能同時減少違規行為及交通事故件數；實施精準執法策略後，因為警察受指派在指定地點的勤務作為獲得保證，應可在一定程度上維持該地點監控強度的穩定，使得執法取締件數減少的情況，可視為實際違規行為真的減少之重要指標(即警察雖有執行執法勤務，卻沒有違規行為可被舉發)。故在圖 4 中可以發現，交通事故減少倍率最多的情況，幾乎都發生在執法取締件數減少的情形下，即是達成「違規少、事故少」的交通安全理想狀態。

此外，圖 4 顯示交通事故減少倍率低(防制交通事故有成效但沒那麼好)的結果對應到取締件數增加的情境，顯示執法件數增加與較差的交通事故防制效果有關。本研究認為不能以此認定執法件數增加是導致事故防制效果變差的原因。本研究推測前揭結果的潛在原因，可能是部分路口原本即有較多的違規行為，即「違規多、事故多」的情境，在此情境下，假設警方勤務強度在精準執法專案實施後提升並維持在一定的水準，那麼在違規取締件數下降之前，都代表違規情形在有警察執法的情況下仍持續發生(所以才有大量的取締件數)，並持續導致交通事故發生。故模型呈現出取締件數增加但交通事故防制成效卻較差的結果，實則可能是因為路口原本違規情形嚴重且尚未徹底改善所致；然而，在此情境下的交通事故增減倍率仍可達約-0.2 倍(-20%)至-0.4 倍(-40%)，顯示執法活動仍有一定程度的事故防制效果。因此圖 4 中執法件數增加的情形，代表在實施精準執法後，警方的執法活動雖無法完全消弭違規情形，但仍可達到減少交通事故 0.2 倍(減少 20%)以上的效果，同樣顯示出執法對於防制事故的有效性；更重要的是，此亦可視為警方的加強執法作為，在多違規地點防制交通事故成效的極限，需要思考其他工程改善方案以澈底消除造成交通事故及違規的根本原因。

4.4 分析結果之管理應用

本研究之分析結果，除了展現出機器學習模型在交通執法研究領域中的潛力，更提供了精準執法、交通違規取締與交通事故防制關聯性之珍貴洞

見，基於模型中萃取的知識，可有效指引警察機關研擬、規劃執法專案的方向，精進執法品質以有效防制交通事故。本研究之成果在交通執法實務管理與應用之重點如下：

(1)了解風險管理才是交通執法的目標

執行交通執法的本質是透過取締手段，遏止交通違規發生，進而減少因交通違規而發生的交通事故。然而，除了交通違規行為，仍有許多因素會導致交通事故發生，故本研究基於精準執法可達到「違規少、事故少」理想狀態之研究結果，建議執法工作先著眼在分析交通事故高風險的時空因素，再聚焦「減少導致交通事故發生的行為風險情境」，從而將目標自「減少交通事故」轉移至「減少交通違規行為」，不僅可引導建立更合理的管考基準，亦能協助研擬發現其他改善策略。

(2)建立合理的管考基準

長年以來警察機關對執法作為的管考方式，多著重於執法件數的增加，常見者如：與去年同期比較是否增加(多在警察機關內部檢討時使用)，或是與前2年或前3年平均值比較是否增加(如內政部警政署在院頒道路交通秩序與交通安全改進方案之年度考評基準)。強調執法件數增加的管考機制，導致執法件數增加卻無法有效降低交通事故的困境，甚至讓基層官警為了達到績效目標，選擇民眾易違規的地點執法，利用大量取締件數及員警的苦勞來對上級交差，忽略了執法作為與違規肇事時空特性的連結，甚至造成執法陷阱、民怨等負面效應。

本研究結果顯示，有效的交通事故防制勤務，可同時減少交通事故與取締件數，故建議交通安全主管機關莫再強調交通違規取締件數之成長，可考量以「多事故之時、地之交通違規行為是否減少」作為管考基準，依行政能量挑選適當數量的地點持續進行觀測考核，才能結合交通執法作為與風險管理思維以改善交通安全。

(3)透過執法效能極限另尋防制策略

本研究結果也指出在交通違規情形嚴重的地點，交通執法防制交通事故的效果有其極限，需要進一步分析交通工程、或其他可能的改善方案，透過工程或相關手段徹底改善造成違規的原因。因此警察機關可檢視精準執法實施之成效，將執法後仍未能有效降低違規肇事的地点、併同違規行為之分析結果回饋予主管機關，以研議其他防制策略。

五、結論與未來研究建議

5.1 結論

本研究蒐集桃園市 238 處實施精準執法路口之交通事故與執法取締數據，以探討警察機關實施精準執法防制交通事故之成效。本研究運用多元線性迴歸、隨機森林演算法及局部累積效應，分析交通事故增減倍率與交通執法取締件數增減倍率之間的關係，據以探討實施精準執法策略後，執法取締活動如何影響交通事故發生之變化。

多元線性迴歸模型指出各執法解釋變數對事故增減倍率之影響有限，顯示針對特定違規的執法活動對於總體交通事故件數的防制效果並不明顯；然而，精準執法的外顯特徵—「見警率」對交通事故防制則可能具顯著效果；隨機森林模型則指出全般交通違規、重大交通違規對交通事故變化的影響程度相較其他執法變數更高；局部累積效應分析結果則顯示，實施精準執法的路口，交通事故件數倍率原則可降低 0.3 倍(減少 30%)以上，且儘管執法取締件數減少，仍可產生相當優異的交通事故防制成效。

本研究認為，精準執法應能同時達到減少違規行為及交通事故的目標，而部分路口可能因實際交通違規事件太多，在實施精準執法後產生執法取締件數增加的現象，但降低交通事故的成效仍可達 0.2 倍(減少 20%)以上，雖同樣顯示出執法活動對於防制事故的有效性，但對比執法取締件數減少的路口，成效相對較弱，此部分應解釋為警方的加強執法作為，在多違規地點防制交通事故的效果仍有極限，可能需要評估實施交通工程或其他改善方案，消除造成用路人違規的根本原因，才能真正降低肇事的潛在風險。

本研究分別對交通執法之學術研究與警政實務具有以下貢獻：

- (1)本研究利用可解釋機器學習模型成功萃取出執法解釋變數與交通事故反應變數間的非線性關係，展現出可解釋機器學習模型應用在執法研究上的潛力，可作為後續相關研究之參考應用。
- (2)本研究明確定義警政實務上「精準執法」之意涵，並基於模型分析結果，提出警政實務在設定執法目標、建立管考基準與研擬交通事故防制策略時應有的思維轉變。

5.2 研究限制與未來研究建議

本研究具有以下幾點限制：(1)蒐集的資料僅包含實施精準執法之路口，使得本研究無法針對有實行及未實行精準執法的路口進行事故防制效果的

比較；(2)本研究未蒐集到員警在路口進行交通執法的實際執勤時數、時段與勤務班次等資料，無法評估實際執行之時段、時數對於防制交通事故的效果，亦暫無法檢討執法勤務作為是否在時間因素中達到精準；(3)本研究以總事件數的增減變化作為模型反應變數，未針對不同肇事原因個別建模討論；(4)本研究囿於資料限制，僅蒐集 112 年 1 至 4 月及 111 年 1 至 4 月之交通事故發生件數與交通違規取締資料，無法將長期交通事故趨勢之變化納入分析並持續追蹤分析執法效果。爰建議未來相關研究可擴大資料蒐集範圍，將有實施及未實施精準執法的路口分列為實驗組及對照組進行比較分析，並透過分析員警執勤時段、時數、執法取締件數與不同肇事因素的交通事件數變化之關聯性，或嘗試與實務機關進行研究合作以控制執勤方式、強度等變項，更精確地探討精準執法的成效，並建立評估精準執法成效之模式，引以引領警政實務單位妥適規劃精準執法交通事故防制之勤務。此外，因交通事故資料具有均值迴歸(regression to the mean)特性，未來研究資料蒐集期間宜再延長，並與過去數年的交通事故趨勢的情形進行比較，以確保研究成果及相關模式能更加客觀及泛用，且若能蒐集到更長的精準執法實施期間的資料，預期圖 4 的分析結果會出現其他型態，如執法解釋變數減少倍率在 0 以下時可能對應至更佳的道路防制效果，且執法解釋變數倍率增加的情形，道路防制效果亦會出現變化，可供研究人員進一步探討執法活動強度對於防制交通事故之邊際效益。

本文作為交通安全領域中首次探討精準執法主題的研究，運用傳統的統計模型及最新的可解釋機器學習模型分析精準執法的成效，展現出相關研究方法被應用在交通執法研究領域中的潛力，研究之成果能提供執法實務單位進行規劃、推動及評估執法策略之參據，轉變執法機關強調執法件數增加的舊思維，以更有效率、更有效果的策略改善交通安全。

參考文獻

- 交通部道安資訊查詢網(2023)，擷取日期：2023 年 7 月 20 日，網站：<https://roadsafety.tw/Dashboard/Custom?type=%E7%B5%B1%E8%A8%88%E5%BF%AB%E8%A6%BD>。
- 警政統計年報(2023)，重要統計結果表-表 26 舉發違反道路管理事件成果，擷取日期：2023 年 7 月 20 日，網站：<https://www.npa.gov.tw/ch/app/data/view?module=wg056&id=2217&serno=fbf5a752-9c50-4eb1-a3ac-8d4f7112c70a>。
- Ali, Q., Yaseen, M.R., Khan, M.T.I. (2019), The causality of road traffic fatalities with its determinants in upper middle income countries: a continent-wide

- comparison. *Transportation Research Part A: Policy and Practice*. 119, 301–312.
- Apley, D. W., Zhu, J. (2019), Visualizing the Effects of Predictor Variables in Black Box Supervised Learning Models. arXiv preprint arXiv: 1612.08468.
- Breiman, L. (2001), Random Forest. *Machine Learning* 45(1), 5–32.
- Coruh, E., Bilgic, A., Tortum, A. (2015), Accident analysis with aggregated data: the random parameters negative binomial panel count data model. *Analytical Methods in Accident Research*. 7, 37–49.
- Elliott, M.A., Broughton, J. (2005), How Methods and Levels of Policing Affect Road Casualty Rates. TRL Report TRL637. TRL Limited, Wokingham.
- European Transport Safety Council. (1999), Police Enforcement Strategies to Reduce Traffic Casualties in Europe. European Transport Safety Council, Brussels.
- Factor, R. (2014), The effect of traffic tickets on road traffic crashes. *Accident Analysis and Prevention*. 64, 86–91.
- Friedman, J.H. (2001), Greedy function approximation: a gradient boosting machine. *Annals of Statistics*. 29 (5), 1189–1232.
- James, G., Witten, D., Hastie, T., Tibshirani, R. (2013), *An Introduction of Statistical Learning*. 2nd ed. Springer-Verlag, New York, NY, USA.
- Mannering, F., Bhat, C.R., Shankar, V., Abdel-Aty, M. (2020), Big data, traditional data and the tradeoffs between prediction and causality in highway-safety analysis. *Analytical Methods in Accident Research*. 25, 110113.
- Mccartt, A.T., Hu, W. (2014), Effects of red light camera enforcement on red light violations in Arlington County, Virginia. *Journal of Safety Research*. 48, 57–62.
- Pantangi, S.S., Fountas, G., Anastasopoulos, P.C., Pierowicz, J., Majka, K., Blatt, A. (2020), Do high visibility enforcement programs affect aggressive driving behavior? An empirical analysis using naturalistic driving study data. *Accident Analysis and Prevention*. 138, 105361.
- Pelter, M.N., Druz, R.S. (2022), Precision Medicine: Hype or hope? *Trends in Trends in Cardiovascular Medicine*. Article in Press.
- Stanojević, P., Jovanović, D., Lajunen, T. (2013), Influence of traffic enforcement on the attitudes and behavior of drivers. *Accident Analysis and Prevention*. 52, 29–38.

Wu, Y.W., Hsu, T.P. (2021), Mid-term prediction of at-fault crash driver frequency using fusion deep learning with city-level traffic violation data. *Accident Analysis and Prevention*. 150, 105910.

Yuan, C., Li, Y., Huang, H., Wang, S., Sun, Z., Wang, H. (2022), Application of explainable machine learning for real-time safety analysis toward a connected vehicle environment. *Accident Analysis and Prevention*. 171, 106681.

(收稿 112/09/24，第一次修改 112/10/20，接受 112/11/09，定稿 112/12/01)

