

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

Investigating The Effect of Precise Enforcement 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回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，多元線性回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，但精準執法之外顯特徵-「見警率」對於事故防制則有顯著效果；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比例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 30% 以上。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、多元線性回歸、隨機森林、局部累積效應

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。

¹中央警察大學交通學系暨交通管理研究所研究生。

²中央警察大學交通學系暨交通管理研究所兼任助理教授，d04521010@ntu.edu.tw。

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見警率以及執法件數的變化如何影響交通事故增減。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, 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。

目前針對精準執法尚無文獻加以研究及明確定義，然而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。

實務上雖有精準執法及精緻執法等不同用語，但均具備相同本質，本研究統一以精準執法稱之，且僅討論派遣警力執行攔停取締(physical policing)之精準執法策略，運用科技執法之策略則不在本研究範圍內。

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，可同時取締各類違規行為，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會一同增加；另因執法取締件數與作為反應變數的交通事故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，可獲得更優異的預測結果，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)，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，以多元線性迴歸模型及可解釋的機器學習模型探討精準執法對於交通事故件數增減的影響，藉由洞察變數間複雜的關聯性，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，作為執法實務單位規劃相關勤務及執法策略的參考。

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。本研究蒐集桃園市政府警察局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。

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回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，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

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)。因本研究蒐集的資料涵蓋期間僅 4 個月，且探討執法活動的效果為本研究之主要目標，本研究遂以多種交通執法取締項目作為模型之解釋變數；然若交通事故頻率分析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，爰本研究以路口交通事故之變化比例作為分析模型之反應變數，並以路口範圍內交通執法取締件數之變化比例作為分析模型之解釋變數，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。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。

本研究所稱之執法解釋變數，包含全般違規、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，「重大違規」依據內政部警政署所訂頒之項目，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；另本研究所稱之「違停」則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，並試圖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，平均而言交通事故件數減少 2.05 件。交通事故件數增減比例統計如表 2 所示，交通事故件數至多可減少 1 倍(即減少 100%)，件數增加最多之路口可達 1.25 倍，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。

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

交通執法取締件數變化如表 2 所示，在實施精準執法後，至多會減少 1 倍(即減少 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，增加比例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，全般違規件數增加比例平均僅達 0.09 倍，顯示總執法取締件數變化不大。

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	事故件數增減比例	-1	1.25	-0.40	0.46
解釋變數	全般違規增減比例	-1	3.4	0.09	0.73
	重大違規增減比例	-1	10.33	0.07	1.19
	爭道行駛增減比例	-1	30.67	0.48	2.95
	違規迴轉增減比例	-1	4	0.01	0.45
	違停增減比例	-1	16	0.50	1.79
	不禮讓行人增減比例	-1	43	0.64	3.16
	違反標誌標線號誌指示增減比例	-1	9	0.34	1.4
	行人違規增減比例	-1	1	0	0.13

交通事故增減比例與各交通執法變數增減比例之次數分配如圖 2 所示，橫軸為增減比例，縱軸為路口數量；多數路口的事故增減比例呈負值，僅少數路口成長，顯示交通事故減少情形明顯；各執法解釋變數之增減程度雖有個別差異，但取締件數未增加或減少之路口多於取締件數增加的路口。




圖 2 交通事故及交通執法變數次數分布圖

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回歸模型進行分析，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，以探討多元線性回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回歸模型探討 8 項執法解釋變數對交通事故變化比例的影響，多元線性回歸模型如式(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，執法件數增減無法解釋的反應變數—交通事故的增減比例，可視為僅有見警率但執法件數無變化時的效果。多元線性回歸模型之前提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回歸模型的診斷後，發現 VIF 值均小於 2，因此多元線性回歸模型可適用於 8 項執法解釋變數之建模。

3.2.2 隨機森林演算法

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�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，若用以建立回歸模型，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)。本研究有 8 個執法解釋變數，因此可將解釋變數隨機子集合的大小設為 3。

相較於線性回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,可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:

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

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:

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

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 多元線性回歸

交通事故件數增減比例之多元線性回歸模型估計結果如表 3 所示。

表 3 多元線性回歸模型估計結果

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
全般違規增減比例	-0.007	0.049	-0.139	0.890
重大違規增減比例	0.034	0.029	1.166	0.245
爭道行駛增減比例	0.008	0.011	0.789	0.431
違規迴轉增減比例	0.005	0.068	0.076	0.940
違停增減比例	0.028	0.017	1.659	0.099
不禮讓行人增減比例	0.017	0.010	1.725	0.086
違反標誌標線號誌指示增減比例	-0.012	0.022	-0.573	0.567
行人違規增減比例	-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比例的變化，此外，各執法解釋變數之迴歸係數亦不具顯著性($P > 0.05$)，顯示各項違規行為的執法取締件數變化對交通事故增減比例影響有限。值得注意的是，模型截距項之校估值為-0.431， $P < 0.001$ ，其可能展現出精準執法之外顯特徵—「見警率」對於交通事故防制有顯著效果，無論執法取締件數如何變化，只要有多事故路口實施明顯執法作為，即可在數週至數月的短期內有效防制交通事故發生，交通事故件數降低比例可達 0.43 倍，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，此結果亦可呼應表 2 的敘述統計結果，儘管各執法項目平均取締件數增幅有限，交通事故件數減少之比例仍可達 0.4 倍。

4.2 隨機森林演算法

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比例，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，以全般違規增減比例、重大違規增減比例及爭道行駛增減比例對模型輸出結果較為重要，違規迴轉增減比例、行人違規增減比例及違停增減比例的影響力則較低。在表 2 中，全般違規增減比例之平均值僅為 0.09，但隨機森林模型卻指出全般違規增減比例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。

隨機森林模型的變數相對重要性排序與多元線性回歸模型的參數估計結果不同，主要原因是演算法之原理迥異，且隨機森林演算法基於決策樹的模型架構，可進一步萃取出解釋變數對於反應變數的非線性關係，故隨機森林模型之變數相對重要性的分析結果，與多元線性回歸模型的參數估計結果無從相互比較。




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

局部累積效應分析萃取出解釋變數對於反應變數的非線性關係如圖 4 所示，各子圖的橫軸為執法解釋變數增減比例，縱軸為事故件數增減比例。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，但可發現一致性的現象：即使執法取締件數未明顯改變，路口交通事故仍可降低 0.3 倍以上，最高甚至可降低超過 0.5 倍；在執法取締件增加的情形下，除了違規迴轉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。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比例大於 0 之後，防制交通事故的效果先急遽下降後再微幅進步。

本研究為圖 4 的分析結果提出可能原因；首先，精準執法策略是在肇事的主要時段、熱點進行執法，如果該執法作為是「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；實務上無法在所有地點 24 小時持續監控違規行為，但實施精準執法策略後，因為警察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其舉發)。故在圖 4 中可以發現，交通事故減少比例最多的情況，幾乎都發生在執法取締件數減少的情形下。

此外，雖然圖 4 顯示執法件數增加與較差的交通事故防制效果有關，卻不能以此認定執法件數增加導致事故防制效果變差的因果關係。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，僅依靠執法仍無法大幅降低交通事故，且在實施精準執法後，這些易造成事故的違規行為遭到舉發而形成取締紀錄，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所致。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 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。




圖 4 局部累積效應分析結果

五、結論與未來研究建議

交通事故的增減變化一直是交通執法單位關注並評估執法成效的重要指標，而執法的成效往往未受到嚴謹的研究與分析(Wu 與 Hsu, 2021)。為了探討警察機關實施精準執法之成效，本研究以桃園市 238 處實施精準執法路口之事故與執法數據進行分析，運用多元線性迴歸、隨機森林演算法及局部累積效應，分析交通事故增減比例與交通執法取締件數增減比例之間的關係。多元線性迴歸模型指出各執法解釋變數對事故增減比例之影響有限，而精準執法的外顯特徵—「見警率」對交通事故防制則具顯著效果；隨機森林模型還指出全般交通違規、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，交通事故件數比例原則可降低 30%以上，且儘管執法取締件數減少，仍可能產生相當優異的交通事故防制成效。因此本研究認為，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情形太多，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 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，可能需要評估以工程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；(3)本研究以總事故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。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故件數變化之關聯性，更精確地探討精準執法的成效。

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，研究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。

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>。

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.
- 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.