

國道事件分析與事件持續時間預測之研究

魏健宏¹ 何旺宗²

摘要

高速公路由於具有路段封閉性質，當事故發生時除了造成人員與車輛的損傷外，往往造成後方車輛的堵塞，因此事件持續時間的預測，可以提供後方駕駛人必要的交通資訊，讓駕駛人避開事件路段，減少高速公路因為事件產生之擁擠。受限於現有即時資訊系統建置的數量與區位，如何在有限的資訊記錄中準確預測出事件持續時間的長短，是本研究第一個面臨的問題。另外，該如何整合事件發生資訊與當時道路交通相關資訊來進行預測事件持續時間，在偵測器帶來多樣訊息的過程中，由於格式單位的不一致性，造成資料判斷的困難，也是必要解決的部分。本研究首先回顧文獻找出影響事件持續時間長短的主要因素，其次使用資料融合技術進行資料的處理，完成從不同機構取得的資料格式統一化與初步的篩選，讓多種來源的資料整合後具有說明事件發生的描述能力。接著分析造成事件的組成因子，包含時間、地點地理特性、參與事件的車輛類型與數量、事件的種類等因素，輔以車流量資料來確認影響事件持續時間的因子，再引用類神經網路模式來進行影響因子輸入與事件持續時間預測結果輸出。對於輸出的結果採用 MAPE 來進行評估，俾以有效預測事件持續時間。案例數據顯示，事件持續時間在一小時以內的預測結果其 MAPE 值為 29.41%，說明類神經網路模式架構對於事件延遲時間的預測有一定的預測能力。本研究準確性合理的結果可以作為事件處理單位客觀評估之基礎，而給予適當之配套交通資訊提供給受事件影響後方駕駛人與現場處理人員，降低交通之衝擊。

關鍵詞：事件延遲、時間預測、資料融合、類神經網路

一、前言

台灣地區高速公路自通車以來，對於城際運輸用途以及紓解都會區道路擁擠具有相當大的作用。在過去十年之間，由於東西向快速道路陸續完工，與原本二

¹成功大學交通管理科學系教授 (聯絡地址：台南市大學路 1 號，電話：06-2757575 轉 53233，E-mail:louiswei@mail.ncku.edu.tw)。

²成功大學交通管理科學系碩士生。(聯絡地址：台南市大學路 1 號，電話：0952-234996，E-mail:kagamipoki@gmail.com)。

條主要南北向高速公路相互結合形成區域型路網，使得每年平均交通量成長率大約為 2.82%，顯示大多數駕駛人會選擇擁有專用路權的高速公路作為選擇。由於高速公路具有路段封閉性，當行車的速率與數量增加，造成的交通問題變得複雜許多，一旦發生事件，往往帶來相當可觀的影響，因此如何在第一時間通報相關處理人員，極小化因為事件所帶來的影響變得很重要。

近年來由於智慧型運輸系統的蓬勃發展，旅行資訊的提供變得十分重要，早期受限於資訊的不確定性太多，導致駕駛人不熟悉路況的資訊下，以致前方發生事件而受困於車陣中無法進行改道的選擇。現在由於資訊數位化以及網路傳輸方式、速度提升與普及的情況之下，造就了即時動態交通資訊系統的誕生。不同智慧型運輸系統技術結合之後，駕駛人可以藉由身邊資訊接收器如手機查詢、電台廣播、車輛上自行安裝的衛星導航資訊等獲得相關交通資訊包含交通擁擠路段、交通意外事件地點、總旅行時間等，並提供合適的解決替代方案，讓駕駛人可以自我判斷選擇最佳化模式(路徑最佳化或旅行時間最小化)，避開交通障礙以順利到達目的地。

本研究目的除了建構並驗證資料收集、處理與篩選之程序，由於交通資料的來源多樣化，因此整合多樣的交通資訊，了解影響延遲時間因素與交通之關聯性，以便於即時預測事件延遲時間，建立準確之預測模式，期望藉由資料融合技術找出在限制條件下適合進行資料融合之交通資料蒐集與處理篩選程序，最後引用類神經網路建構事件延遲時間預測模式，能夠有預測績效良好的時間預測模式。

本研究首先利用資料融合技術，把不同單位蒐集的資料進行系統性整合，建構高速公路事件延遲時間預測模式。資料融合程序是蒐集多項資訊後，進行系統性的資料管理，透過資料融合環境開始做初步篩選的動作並進行資料簡化作業，根據限制條件透過不同層級以及不同方法論之應用，產生較清楚的訊息以供決策者作為參考。因為交通資訊來源相當的多樣化，每個資訊所提供的內容、格式與單位不一致，考量到此預測問題關係到時間與空間的同時變化，不管是間斷記錄的交通資訊，還是連續性的資料，必須透過記錄蒐集、篩選、整理與選取等步驟予以系統性整理，根據不同的條件下選定不同的影響因子資訊進行資料融合，因此把交通資訊利用資料融合技術，透過系統性的整理、篩選與融合結果，可以獲得較為簡單用來作為決策用的資訊，提升交通資料的利用附加價值與便利性，增加交通運輸服務品質。

本研究其次使用類神經網路為工具運用在時間數列預測問題上面，優勢在於不需要針對離散型變數或連續型變數做特殊的處理與改良即可同時輸入模式中運算，得出的結果績效優良。類神經網路在各個領域都有相當多的研究成果與實務應用，在交通專業領域逐漸成形，成為一個重要的應用工具(Dougherty, 1995)。類神經網路的特性在於具有針對不同問題發展出來的網路結構與學習法則，極佳的容錯力與分散式儲存知識的能力，可以結合其他方法來增進其功能。

本研究最後將類神經網路所運算的結果利用 MAPE 進行準確性判定，如果 MAPE 值小於 50%，則可以稱為是合理的預測，考量到資料來源的完整度，分別進行資料的調整與預測，以期能夠得到有效的分析與預測結果，整體架構流程於圖 1 表示。最後透過結論與建議部分，本研究在事件延遲時間預測模式中，透過滿足不同條件限制，在績效評估上面有好的表現，根據其結果下結論與提出相關建議以供交通單位作為參考。

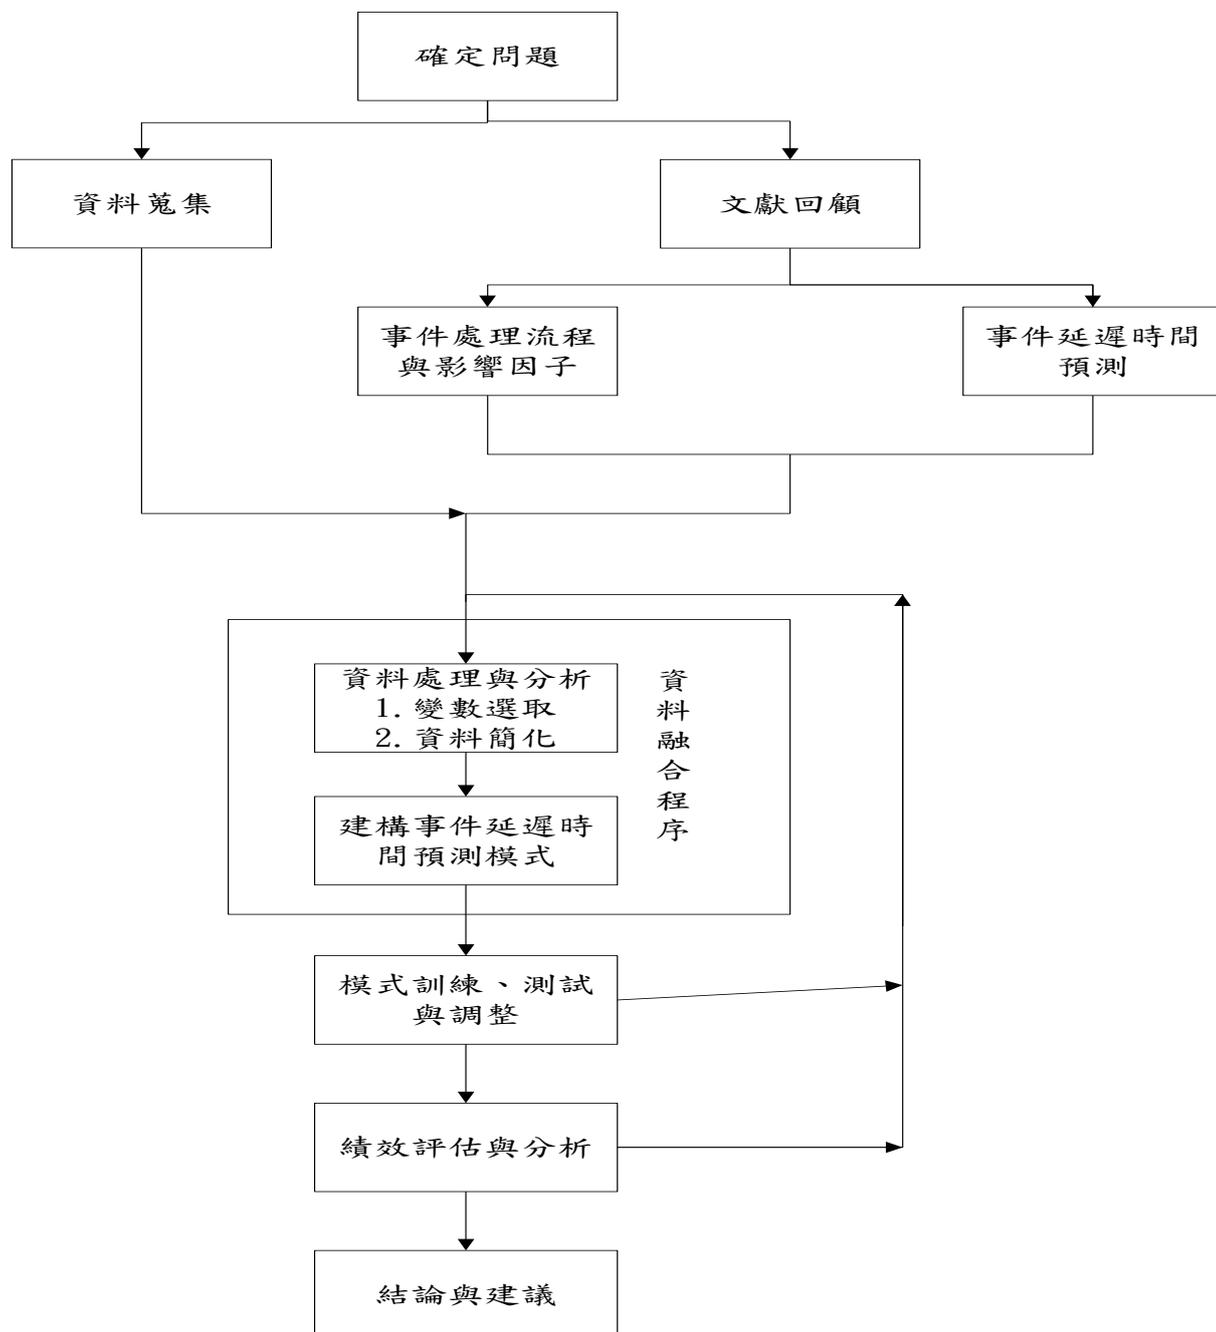


圖 1 研究架構圖

二、文獻回顧

2.1 事件處理流程

當高速公路發生事件時，受到影響的不只是事故當事人，連同其他用路人也會因為事件的影響增加其旅行時間，因此排除事件以盡快回復正常的車流通行就成為高速公路事件管理最主要目的。事件處理程序可以分為四個部分，如圖2所示，依序分別為道路事件發生偵測與確認(偵測時間)、救援單位對事件反應準備與前往現場(反應時間)、救援單位於事件現場的管理與清除(清除時間)。每一項環節都會影響到整體事件延遲時間，關連到人員、地理位置與科技之整合結果。

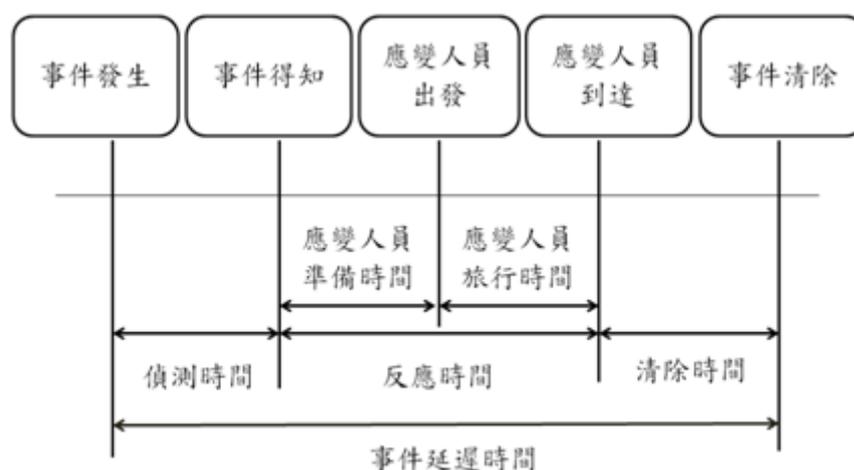


圖 2 事件管理時間流程

2.2 資料融合

不同格式與單位藉由資料融合技術，把資料進行處理運算之後，整合化單位資訊提供決策者，在最短的時間內做出適當的處理(Saporta, 2002)。在有測量器具提供數據下，可以對高速公路任何時間與空間面進行記錄，無論使用測量數據和預測數據系統都可以提供讓管理人員有機會決定最佳的狀況以配合運作的需求(Sitzabee, 2009)。透過各式資料收集設備例如固定式的偵測器與移動式的行車GPS資料之外，須考量環境與人為判斷的推論等資訊，進行資料的管理與收集。為執行資料融合環境，需透過初步篩選過濾資料與整理資料格式。此處理程序需要資料庫管理系統、支援資料庫、與狀態資料庫互動配合，再轉換成人機介面展示資料融合成果與進行系統評估工作。

Ivan (1995)利用類神經網路將資料融合，以便即時偵測幹道發生事件與否。Dailey (1996)利用偵測器所收集的流量、佔有率等資料，以資料融合方式推估出車流速度。Nelson (1996)利用偵測器收集高速公路之流量、佔有率等資料推估車輛延滯時間並建置出使用者可以操作的資料融合電腦系統。Jia (2008)讓偵測器的

記錄資料可以融合實際地圖座標系統，增加對車輛行進資料的蒐集。Zhao (2007) 使用SVM設計相對應的模式，提高數據資料的品質，讓資料的準確性增加。魏健宏與李穎(2003)嘗試收集現有國內高速公路的相關資料，包含路面車輛偵測器資料、客運車上的GPS定位資料以及事件資料庫資料，利用資料融合方式以獲取旅行時間的預測資訊。上述研究資料證明了資料融合技術應用於智慧型運輸系統之可實現性，並擴展至即時行旅資訊服務之應用。

2.3 事件延遲時間預測

時間預測應用於動態交通量指派領域中的時間函數，林士傑(民90)以客運GPS車輛運轉之車速及時間、車輛偵測器之點速度、事件數、尖離峰、假日非假日、調查流量等真實環境資料作為輸入參考變數，構建數種旅行時間預測模式。張修榕(民 90)利用模擬路網以類神經網路法之倒傳遞演算法建立不同交通車流型態下之旅行時間預測模式。李穎(民 96)利用類神經網路融合多樣交通資料構建一旅行時間預測模式，並改善模式績效與節省資料收集時間運用了資料組合、資料集群與基因演算法資料篩選等三種資料簡化方法之效果。Chung (2009)利用Log-logistic、AFT矩陣模型與Hazard-based延續模式對於韓國高速公路進行事件延遲時間預測，其預測績效為普通。利用不同方法來進行延遲時間相關預測，其預測結果都有較佳的表現，可以提供給相關單位進行改進不足的部分。

三、模型架構

3.1 事件延遲時間預測模式架構

針對此預測問題通常可以從兩個不同的資料屬性來進行思考，一個為時間序列構面，主要是針對一特定觀察目標，持續且不間斷地收集資料長達一時間區段；另外一個為橫斷面構面，主要是在一固定時間點收集一特定目標及其相關影響因素進行因果關係之分析。在預測時間階段，可以運用類神經網路進行時間預測，或者運用迴歸分析得到預測變數與準則變數之函數關係式，經由函數關係式推得預測數值，而車輛偵測器提供的車輛類型、數量、行經該路段的流量與速度以及車道佔有率均隨著時間和空間改變，因此必須考慮到前後相鄰路段和前後相鄰時間所帶來的相關差異性影響，構築該路段在事件發生時造成的延遲時間預測，事件延遲時間預測模式架構如圖3 所示。

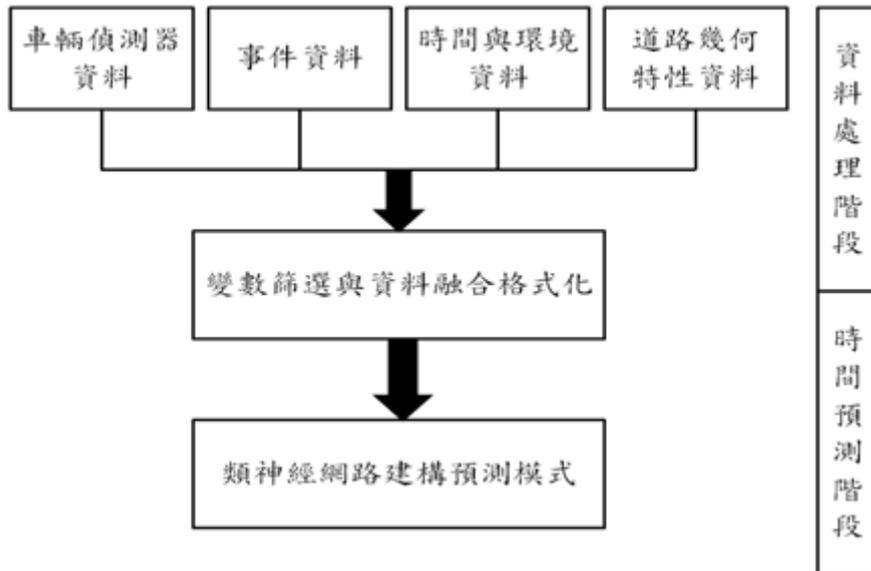


圖 3 事件延遲時間預測模式架構

3.2 影響事件延遲時間的因子

影響事件延遲時間的因子包含時間與空間部分，各自有其影響的範圍，其結果則根據兩者因子間的顯著性來呈現。

時間因子對於事件延遲時間影響，李穎(民96年)在研究中指出針對不同的時間點會造成車流量增加與行車速率的變化，以致發生事件時造成該路段大量車輛的滯留，因此本研究除了把一天分成包含上午尖峰以及傍晚尖峰等四個區段來進行探討，讓事件延遲時間預測研究範圍在時間點上面可以有24小時延續性而不侷限於特定時段，持續延伸探討至每星期、每月及全年度的情形。

空間因子包含事件發生地點的地理資訊與事件所造成的道路佔用情形。事件發生時地理資訊一般常提到的考量因素有：車流量、行車速率、道路車道數量、地理位置等；事件造成佔用資訊事件發生距離交流道出口的距離、佔用車道數與位置、事件車輛數與類型、多重事件重疊等。另外探討主線、交流道與收費站的上下游關係，針對不同型態地理位置所造成事件延遲時間關鍵在於車流量、車速與救援單位旅行時間的影響，有其納入討論的地方。

3.3 類神經網路

類神經網路已經被廣泛運用在時間數列預測問題上面，實證的結果也指出類神經網路為一具有潛力的預測工具，優勢在於不需要針對離散型變數或連續型變數做特殊的處理與改良即可同時輸入模式中運算，得出的結果績效優良。本研究把GPS資料、VD資料與事件資料作為計算事件延遲時間的輸入變數，網路架構如圖4所示。變數輸入類神經網路之後，計算輸入層對隱藏層每一條線的影響權重，透過隱藏層中轉換函數之處理，最後傳送至輸出層判定此網路所運算出的預

測時間值，此運算值與實際時間值會有差異性，除了做相關檢定之外，必須反覆來調整隱藏層對輸出層的影響權重與輸入層對隱藏層的權重，直到績效穩定為止，即為最終的時間預測值，其公式如下：

$$y = g \left(\sum_j w_{hj} \times f \left(\sum_i w_{ih} \times x_i - \theta_h \right) - \theta_j \right)$$

y 為輸出值

i 為輸入層單元個數

x_i 為輸入單元

h 為隱藏層單元個數

θ_h 為隱藏層門檻值

w_{ih} 為輸入層與隱藏層之間的權重值

f 為隱藏層之轉換函數

θ_j 為輸出層門檻值

w_{hj} 為隱藏層與輸出層之間的權重值

g 為輸出層之轉換函數

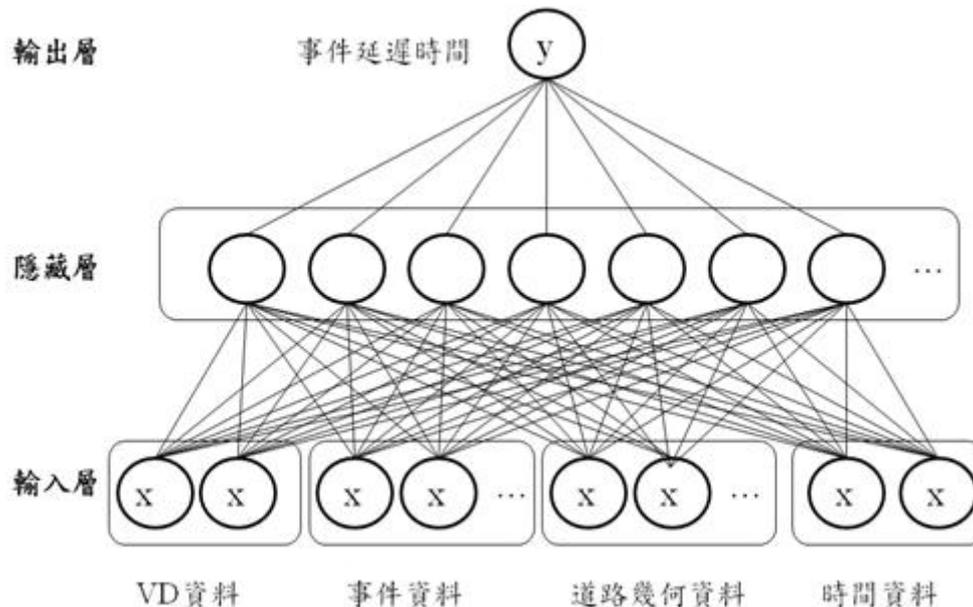


圖 4 類神經網路架構圖

四、資料蒐集與結果分析

4.1 資料分析

本研究路段為中山高速公路大林至楠梓交流道共106.3公里，包含3個收費站、2個服務區與14個交流道、包含高雄、台南、嘉義等3個大型都市，資料來源為98年度全年國道高速公路的車輛偵測器資料以及交通部運輸研究所事件資料。從原始10569筆資料中，考量資訊不完全性無法清楚地描述事件發生的內容，多重單位來源訊息告知同事件導致重複記錄於事件資料庫，整理出1302筆事件延遲時間資料來進行分析。整體來說，平均每月發生事件件數為108.5次，換算成每日約為3.6次，以通過大林至楠梓路段車輛曝光量來計算，該路段每日大約15000輛次通過才會遇到一起事件。進一步把一日區分成四個時段，分別為夜間至清晨時段(20 - 07時)、上午尖峰時段(07 - 09時)、白天時段(09 - 16時)與下午尖峰時段(16 - 20時)，其結果呈現於表1，發現該路段事件發生以白天所占的比例最高為49%，但如果把個別時段所包含的時數給予單位化發現，事件發生於下午尖峰與白天的百分比皆為7%，遠高於夜間時段的1.2%，唯在夜間發生事件，由於視線較差需要較多的處理時間，導致延遲時間平均值高達66.45分，明顯比其他時段增加20分鐘以上。

表 1 民國 98 年各時段事件發生數量統計

時間統計	件數	比例(%)	每小時比例(%)	平均事件延遲時間(分)
20~07 夜間與清晨	171	13.13	1.19	66.45
07~09 上午尖峰	124	9.52	4.76	43.56
09~16 白天	640	49.16	7.02	46.42
16~20 下午尖峰	367	28.19	7.05	39.42
總計	1302	100.00	--	46.80

本研究事件的類型依照高速公路局對於事件列舉的方式重新分類為五大項，依序為：肇事事故、車輛故障、交通障礙、視線影響與施工。肇事事故是包含附數車輛碰撞以及單一車輛碰撞道路分隔島或護欄。車輛故障是指單一車輛因為機械發生問題導致無法正常行車打滑或翻覆在車道上，拋錨與火燒車皆屬於此範圍內。交通障礙包含車輛掉落物與動物屍體等足以妨礙正常行車的物品。視線影響的部分包含道路旁邊燃燒物品所造成的煙霧、濃霧、豪大雨等嚴重妨礙正常行車視線的狀況。施工即為高速公路主線與周邊工程進行，基於保護工作人員安全與道路施工，需要進行封鎖車道而影響到行車狀況。事件類型與事件造成的延遲時間結果呈現在表2，事件的平均延遲時間為46.8分鐘，主要是因為施工的影響把

整體平均值提高，其他類型的延遲時間皆介於30分鐘至40分鐘之間，由於肇事事事件牽涉到肇事者與受害者的鑑定問題，因此所需要的時間排在次高的部份為38.74分鐘。另外，事件數數量較多的為肇事事事故與交通障礙，其發生的頻率在大林至楠梓路段每天平均要面臨1起肇事事事故與交通障礙的問題。

表 2 事件類型與所造成延遲時間

類型	件數	事件所造成延遲時間(分)			
		最小值	最大值	平均值	標準差
肇事事事故	547	4	255	38.74	35.80
車輛故障	110	5	171	30.00	27.20
交通障礙	514	3	201	32.61	21.02
視線影響	43	5	186	29.72	33.28
施工	88	18	1440	208.45	241.63
總計	1302	3	1440	46.80	81.38

接著比較車輛型態與延遲時間的關係，在下表3 中可以發現小型車與大型車參與肇事事事件的比例相當懸殊，由於大型車輛肇事事事件現場清理時間需要比較長，因此相互比較單純小型車肇事事事件與單純大型車肇事事事件所延遲的時間，在本路段的數據結果顯示差距快要接近一倍的時間，分別為小型車輛34.43分鐘與大型車輛61.78分鐘。另外也考量到混合車輛肇事事事件的情形，但就本路段統計結果來看，雖然比單純小型車肇事事事件要高，但是並沒有高於單純大型車的肇事事事件所帶來的延遲時間，只有40.53分鐘。在車輛故障的部分，小型車輛與大型車輛的因為故障產生的延遲時間各自為28.32分鐘與33.05分鐘，彼此差距並沒有像是肇事事事件般的大，不過二者的共通點一致，即為小型車比大型車處理來得快。

表 3 事件車輛與延遲時間關係

事件車輛數	小型車輛數	平均延遲時間(分)	大型車輛數	平均延遲時間(分)	混合車輛數	平均延遲時間(分)
肇事事事件	901	34.43	103	61.78	141(78+63)	40.53
車輛故障	72	28.32	40	33.05	--	--

本研究探討車道數對於事件延遲時間的影響，呈現在表4，單一車道數發生的事件數量為908，所造成的延遲時間平均為40.15分鐘，而複數車道發生的事件數量為352，但延遲時間平均卻大幅增加為66.26分鐘。無論在哪種事件類型發生於複數車道上，其嚴重性普遍大於單一車道上，導致延遲時間較長。

透過資料來源整理與分析後，大致可以了解到不同來源單位的資料內容以及各種資料特性，得知路段發生之事件相關影響因子與延遲時間長度有關，可以做為構建類神經網路模式之基礎。由於車輛偵測器與事件資料庫，其記錄資訊數量與樣本數相當龐大，處理相關之資料量非常龐大且複雜，需要進行數值格式統一與資料過濾，以方便於後續類神經網路預測模式之輸入變數，對於不同來源的資料格式須加以整合與分析，以期可以做到完整對於該路段之狀態描述與事件延遲時間之結合，對於接下來採用類神經網路進行延遲時間預測有相當大的幫助。

表 4 事件延遲時間與佔用車道數關係

類型	單一車道		複數車道	
	事件數	延遲時間(分)	事件數	延遲時間(分)
肇事事件	384	32.10	163	54.37
車輛故障	61	24.15	49	37.29
交通障礙	400	31.58	115	37.52
施工	63	159.16	25	332.00
總計	908	40.15	352	66.26

4.2 變數輸入與輸出

本研究運用MATLAB軟體所包含的類神經網路工具，對各種可能之模式組合進行訓練與測試，以便選擇較具代表性的模式，利用資料融合技術來處理各項資料來源，整理成可以帶入類神經網路模式之資料格式，在輸入變數與輸出變數的部分整理在表5 所示。

輸入變數方面，首先在時間因子部分，包含一星期七日、24小時分成四個時段包含白天夜間與上下午尖峰時段；事件因子部分，事件類型以5種不同型態呈現包含車禍、事故、掉落物、視線影響與施工，參與事件的大小型車數量，事件佔用車道的數量、位置與方向；其他因子部分，記錄上游與下游路段型態分別為主線、交流道與收費站，使用連續變數記錄該路段在事件發生期間與其前一時段之平均速率值。輸出變數方面，採用類神經網路運算之後，得到事件延遲時間的預測值，其結果將與實際事件結果進行預測時間準確性比較。

表 5 輸入變數與輸出變數

變數編號	變數名稱	變數型態	變數內容	
輸入變數	1	星期	連續變數	1~7
	2	時間類型	類別變數	1=夜間，2=上午尖峰， 3=白天，4=下午尖峰
	3	事件類型	類別變數	1=車禍，2=事故，3=交通障礙， 4=視線影響，5=施工
	4	小車數量	連續變數	小型車數量
	5	大車數量	連續變數	大型車數量
	6	佔用車道數量	連續變數	佔用車道數量
	7	佔用車道位置	類別變數	1=內，2=中，3=外，4=外路肩， 5=中內，6=中外，7=內外， 8=主線，9=封閉全線
	8	方向	類別變數	1=北上，2=南下，3=雙向
	9	上游路段型態	類別變數	1=主線，2=鄰近交流道與服務區， 3=鄰近收費站
	10	下游路段型態	類別變數	1=主線，2=鄰近交流道與服務區， 3=鄰近收費站
	11	路段發生事件前速率	連續變數	平均時速值
	12	路段發生事件期間速率	連續變數	平均時速值
輸出變數	13	事件延遲時間	連續變數	事件延遲時間預測值

4.3 類神經網路績效評估

本研究採一般常用的評估指標平均絕對誤差比率(Mean Absolute Percentage Error, MAPE)來評估模式績效。平均絕對誤差比率為相對比較數值，不受實際值與估計值單位及數值大小的影響，而能客觀地獲得實際值與估計值間之差異程度，而本研究模式亦採取此一衡量標準，將網路輸出之估計值與實際值進行比較計算，以瞭解該模式的績效結果，其公式如下：

$$MAPE = \frac{1}{M} \sum_{k=1}^M \left| \frac{\hat{x}(k) - x(k)}{x(k)} \right| \times 100\%$$

$\hat{x}(k)$ ：表網路輸出估計值

$x(k)$ ：表實際值。

若MAPE值越接近於0，表示估計效果越好，一般在小於50%就可以算是合理的預測。另外，Lewis (1982)則認為MAPE是最有效的評估指標，並對於MAPE值大小與其代表含意提出說明於表6。

表 6 MAPE 的評估標準

MAPE(%)	說明
<10	高精準的預測
10~20	優良的預測
20~50	合理的預測
>50	不準確的預測

4.4 模式評估結果

透過類神經網路運算結果輸出值經過換算成MAPE值，在不做時間分群的情況下對全體資料進行模式運算，其測試結果的平均值於表7，MAPE值為88.19%，屬於不準確的預測，為了了解樣本內容的差異性是否會對於事件延遲時間預測模式產生影響，需要逐一進行分析。

表 7 全體事件延遲時間預測模式績效評估

事件類型	訓練樣本數	預測樣本數	MAPE(%)	績效評估
原始數據	1040	262	88.19	不準確的預測

表 8 事件延遲時間與數量

事件延遲時間(分)	事件數量
$X \leq 20$	385
$20 < X < 40$	520
$X \geq 40$	397

在對樣本做時間分群後，首先找出樣本數最集中的部分，從表8 得知，延遲時間介於20至40分鐘的事件數最多有520起，因此將以這一段範圍的事件資料當做訓練樣本並命名為樣本A，剩下的離散樣本命名為樣本B。接著把樣本A經由類神經網路訓練後，除了對樣本A做預測外，並將樣本B與全部樣本來當作預測目標進行網路演算，其平均值如表9 所示。樣本A可以得到優良的預測MAPE值為19.54%，但是離散的樣本B是非常不精確的預測，其MAPE為103.81%，顯見樣本離散部分可能對於事件延遲時間無法有效的進行預測，需要進行再次的篩選。以樣本A為訓練樣本再與全部樣本進行網路演算結果可以得到MAPE值為69.55%，仍舊是不準確的預測，但相較於以全部樣本作為訓練主體所得到的預測結果，有明顯的改善預測的精準度。

表 9 訓練集中樣本後對離散樣本與全體樣本比較分析

樣本類型	訓練樣本數	預測樣本數	MAPE(%)	績效評估
樣本 A	520	119	19.54	優良的預測
樣本 B	520	782	103.81	不準確的預測
全部樣本	520	1302	69.55	不準確的預測

對於樣本B的部分在進行延遲時間上面的交叉比對，其結果在表10，發現延遲時間小於20分鐘的部分無法進行預測，MAPE高達156.49%，但是在40分鐘至60分鐘這一時間段，其MAPE值為36.88%為合理的預測結果，可以納入整體訓練之樣本，另外大於60分鐘的樣本，其MAPE值為69.68%為不準確的預測。

根據表10，把40分鐘至60分鐘的事件樣本與樣本A結合命名為樣本C，換句話說，樣本C是由事件延遲時間20至60分鐘的樣本所組成，而剩餘的離散樣本命

名為樣本D。接著把樣本C經由類神經網路訓練後，除了對樣本C做預測外，並將樣本D與全部樣本來當作預測目標進行網路演算，其平均值如表11 所示。

表 10 離散樣本結果的比較分析

事件延遲時間(分)	訓練樣本數	預測樣本數	MAPE(%)	績效評估
<20	520	385	156.49	不準確的預測
40~60	520	207	36.88	合理的預測
>60	520	190	69.98	不準確的預測

發現樣本C以此模式進行預測績效評估得到MAPE值為29.47%，屬於合理的預測，但是精確度並沒有像樣本A做訓練樣本進行預測時來得小。在離散樣本D與全部樣本的部分，在整體表現上面有提高準確性的趨勢，但仍屬於不合理的預測結果，分別為樣本D的88.32%與全部樣本的55.49%，其影響原因除了在於延遲時間較短的部分無法有效的預測，另外也與重大事件延遲長時間的樣本數較少有關。

表 11 篩選後樣本進行預測之結果

事件延遲時間(分)	訓練樣本數	預測樣本數	MAPE(%)	績效評估
樣本 C	727	167	29.47	合理的預測
樣本 D	727	575	88.32	不準確的預測
全部	727	1302	55.49	不準確的預測

我們探討了影響事件延遲時間預測模式的因子，從時間、日期、時段、事件類型、參與車輛類型與數量、佔用車道的數量與位置、上下游的地理分布、南北方向性、車輛速度等因子，透過類神經網路的方式得到預測值，與實際值比較之後其MAPE值為29.47%，屬於合理的預測結果，唯預測小於20分鐘以內的準確性有嚴重不足之處。在路網訓練過程上面，藉由隱藏層處理神經元個數變異的動態調整，得到了穩定的績效得以延用至模式上面。在樣本的問題上，基於呈現高速公路各種的事件現象，把有效範本列入考量，造成資料離散的問題，導致影響網路運作進行延遲時間預測的結果，因此對於樣本的選取，使用相關檢定方式來過濾與採用樣本是否會失真的問題，是可以值得探討的部分。

五、結論與建議

綜合前面所描述的資料蒐集、模式建構與模式績效分析部分，提出下列幾點結論。首先，本研究透過交通部所屬單位蒐集事件資料與車輛偵測器資料，根據

文獻探討及資料整理分析出對於後續模式構建有用之變數因子，並利用資料融合程序與步驟，從不同資料來源單位蒐集相異格式、單位之資料，成功彙整成對於構建事件延時預測模式有用之格式，以便預測模式發展之用。其次，本研究建構之事件延時預測模式方面，其 MAPE 值 29.41% 展現合理的預測績效，證明研究中所選取之變數足以充分表達事件延時預測模式之描述。最後，經過真實交通資料的模式構建與分析，證明了本研究對於整合了多種資料來源，運用類神經網路與真實事件、行車資料之結合，呈現出準確之事件延時預測績效，面對多種事件類型的處理結果，能提供一穩定且可靠之預測值，證明類神經網路於事件延遲時間預測模式之適用性，確認類神經網路於事件延時預測實務應用課題上之價值。

針對未來應用資料融合於事件延時間預測課題方面提出下列建議。首先，對於資料蒐集方面，研究中之資料分別來自於不同單位，考量到交通部各單位的資料授權範圍不同，導致其資料格式、單位均相異，若往後在資料蒐集與紀錄方面能夠即時匯流、同步運作，統一格式與授權單位，以滿足未來用路人資訊需求之即時性與正確性以邁向實務之應用。其次，對於事故延遲時間預測模式之構建，由於事件資料多數筆資料完整性尚顯不足。不管是車道佔用位置、事件始末時間、修正訊息內容的單位、事件內容的真實性確認與錯誤排除等，在事件資料庫紀錄下鮮少單純一筆事件從發生到結束之正確紀錄，導致許多事件並無法取得完整資料，對於整體預測所需要的資料部分造成過多的空洞。若以後在事件通報與紀錄下能夠更為完善，此部分模式所需要之真實資料亦可更為完整。

隨著事件延遲時間預測之進行，同時反應出整體路網對道路事件之真實交通現象，相關單位運用智慧型運輸系統進行資料蒐集與處理道路問題外，應提供用路人正確的預測資訊，減少事件所造成之衝擊，以提升道路的服務品質。

參考文獻

- Chung, Y.(2010), "Development of an accident duration prediction model on the Korean Freeway Systems," *Accident Analysis & Prevention*, Vol. 42, pp. 282-289.
- Dharia, A. & Adeli, H.(2003), "Neural network model for rapid forecasting of freeway link travel time," *Engineering applications of artificial intelligence*, pp. 607-613.
- Keay, K., & Simmonds, I.(2006), "Road accidents and rainfall in a large Australian city," *Accident Analysis & Prevention*, Vol. 38, Issue 3, pp. 445-454.
- Lee, Y. & Wei, C. H. (2007), "Data Fusion and Feature Composition Approach To Sequential Accident Duration Forecasting," *Journal of the East Asia Society for Transportation Studies*, Vol. 7, pp. 2546-2560.
- Tsai, T. H., Lee, C. K. & Wei, C. H. (2009), "Neural network based temporal feature models for short-term railway passenger demand forecasting," *Expert Systems*

with Applications, Vol. 36, No. 2P2, pp. 3728-3736.

Wei, C.H., & Lee, Y. (2007), "Sequential forecast of incident duration using artificial neural network models." *Accident Analysis & Prevention*, Vol. 39, Issue 5, pp. 944-954.

Wei, C. H. & Lee, Y. (2007), "Development of freeway travel time forecasting models by integrating different sources of traffic data," *IEEE Transactions on Vehicular Technology*, Vol. 56, No. 6, November, pp. 3682-3694.