

類神經網路應用於都市幹道事故延遲時間預測 之研究—以高雄市民族路為例

魏健宏¹
葉妙珊²

摘要

交通事故的發生必定會導致事故延遲的產生，除了造成用路人時間和金錢上的浪費與降低路網服務品質外，更可能導致二次事故的發生或龐大的車流延滯。因此若能在事故發生時，提供事故地點上游路段之駕駛人即時的路況資訊，使駕駛有充足的準備行經事故地點以減緩車流之衝擊，同時亦可建議駕駛改道行駛，減少事故發生所產生之擁擠。事故延遲資訊是提升事件管理績效的關鍵因素之一。有鑑於此，為提昇我國市區道路事故管理系統之績效，本研究欲構建一套市區事故延遲預測模式以準確預測事故所造成延遲之時間長度。本研究以高雄市台1線民族路作為分析對象，透過高雄市交通大隊所紀錄之事故歷史資料及高雄市智慧運輸中心車輛偵測器等資料進行彙整，並篩選出影響事故延遲時間組成之影響因子，最後利用類神經倒傳遞網路(Back-Propagation Neural Network, BPN)為運算核心建立一套事件持續時間預測模型，預測意外事故從發生到排除的持續時間。本研究構建之事故延遲預測模式係採用均方根誤差(RMSE)及平均絕對誤差率(MAPE)兩項指標進行績效評估，俾以探討及分析模式有效性。

關鍵詞：倒傳遞網路、事件延遲時間預測、市區道路。

一、緒論

1.1 研究背景與動機

隨著台灣地區家戶小客車持有率的增加，使得具有高服務水準的公路車流量呈現飽和的局面，因而造成旅行時間增加，行車效率低落，行車安全也因此受到影響。然而，民族路為高雄都會區南北向主要活絡幹道，當車輛行駛於民族路過程中若遭遇突發狀況造成交通阻礙，如車禍、車輛拋錨、掉落物與道路施工等意外事件，將導致都會區路網的車流受到影響。民族路全線均有快慢車分隔島，因此若路段中發生事故，在有限的道路容量下車輛很難變換車道避開事故點，即可能造成嚴重之車流延滯，甚至發生二次事故或增加廢氣排放之環境污染。

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:06-2757575 轉 53271 轉 5020, E-mail:dtk1313@hotmail.com)。

當行車的速率及數量增加，造成的交通問題變得複雜許多，因此高雄市智慧運輸中心及事件相關單位人員，必須知道如何利用已掌握即時性資訊的條件下預測事件的影響程度及事件可能的持續時間(incident duration)，進而提供系統分析交通事件對於旅行時間(travel time)的延遲以及影響路況的嚴重程度，以輔助包含交通管理單位在最短時間內下達有效之控制策略，減緩交通事件所帶來之影響。幹道上突發性的事件狀況將會快速的影響既有道路上的車流續進及其安全，近年來智慧型運輸系統被廣泛地應用，例如先進交通管理系統及先進用路人資訊系統等子系統中，交控中心蒐集各種路況資料進行整合後，將有用之資訊提供給用路人或是下達管制策略，以降低異常車流所產生的負面效果。

有鑑於此，可靠的事務延遲時間預測對於事故管理具有一定之重要性，若能有效應用於市區事故反應機制，減少事故發生時交通壅塞程度，避免二次事故的發生，同時提供即時交通資訊與管制訊息給用路人，讓用路人選擇更安全、更快速的交通方式或是交通路徑以達到目的地，使得都會區路網的運作效率提升，停等延滯時間降低，降低油耗與廢氣排放量，效率與環保兼顧，有效提升都會區路網之運作效率。

類神經網路在各個領域皆有相當多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。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。本研究將類神經網路模型所運算的結果利用平均絕對誤差比率(Mean absolute percentage error, MAPE)及均方根誤差(Root Mean Square Error, RMSE)兩項指標進行準確性判定，考量到資料來源的完整度，分別進行資料的調整與預測，以得到有效的分析與預測結果。

1.2 研究目的與研究範圍

本研究將所蒐集到的民族路事故歷史資料庫及 VD 資料進行系統性的整合，進而利用此事故所建立之資訊推估出受事故影響下之延遲時間。本研究主要目標有：

1. 探討如何整合多樣性之交通資訊，以符合現實交通時空環境，有效且即時地運用於預測模式中。
2. 利用類神經網路建構民族路段事故延遲時間之預測模式，以配合其他交通管理與控制之相關課題。

在透過高雄市智慧運輸中心取得民族路段車輛偵測器資料、高雄市交通大隊授權下所提供 2010 年民族路段歷史事故資料。由於 VD 偵測器佈設位置之限制，因此研究範圍設定為高雄市民族路(中正路-鼎金路)路段，每起事故延遲時間以 VD 所偵測到的車流狀況作為事故延遲時間之判斷準則。本研究建立事故延遲時間預測之流程架構如圖 1 所示。

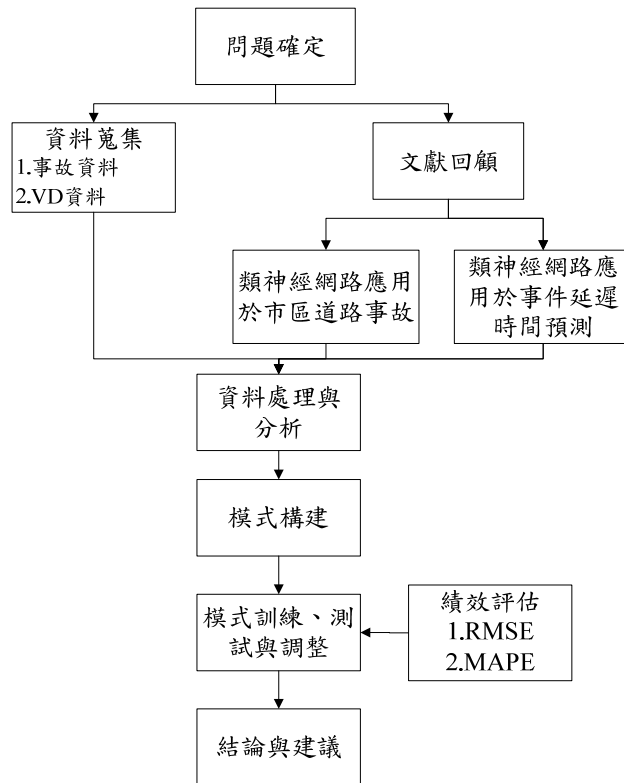


圖 1 研究架構圖

二、文獻回顧

2.1 類神經網路

類神經網路(Artificial Neural Network, ANN)是一種計算系統，利用大量連結的神經元(neuron)來模擬人類腦神經細胞網路的運作。每一種神經元均掌管不同的感知、推理、記憶與學習工作所構建成的一個網路，透過網路中學習過程找出符合訓練特性之最佳參數以解問題。

目前類神經網路中最具代表性及應用最普遍的模式為倒傳遞網路(Back propagation Network, BPN)，倒傳遞網路是屬於監督式學習法，可結合非線性的因素，並不會限定於矩形的解答空間中，BPN 可以結合所有項目的各種組合去找到較佳的結果。BPN 的優點為可解 XOR 問題、應用普遍、學習精度高、學習速度慢及回想速度快等。倒傳遞網路架構如圖 2 所示，其架構可分為三層。

- 1.輸入層：呈現網路的輸入變數，其處理單元數目依問題而定。
- 2.隱藏層：表示輸入變數之間的關連影響，其處理單元的數目並無標準依循，通常以實驗的方式來判別最佳個數。
- 3.輸出層：表示網路的輸出變數，與經由網路訓練呈現之結果，輸出個數可由使用者決定。

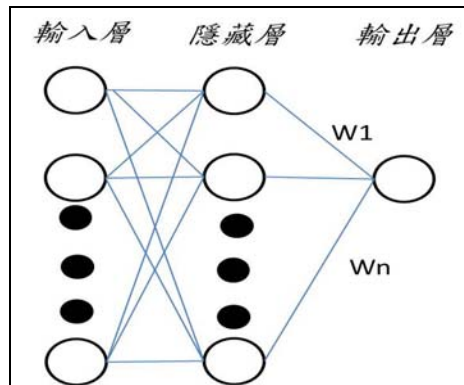
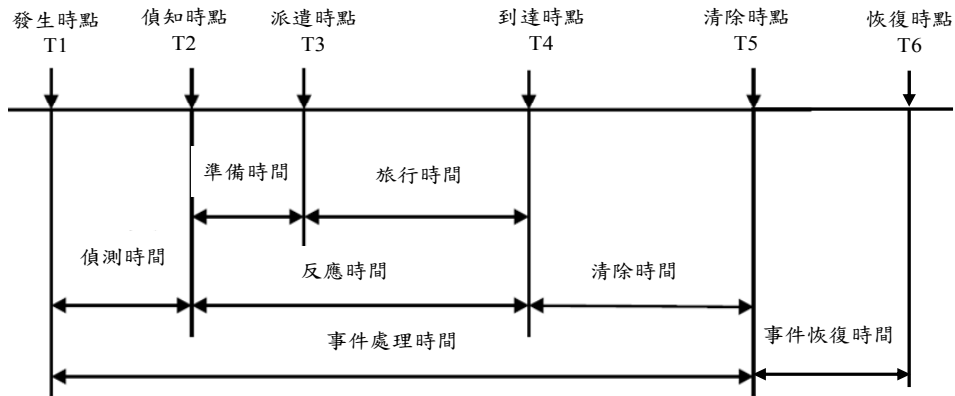


圖 2 倒傳遞網路架構圖

類神經網路的研究，已受到各界的肯定與廣泛使用。在國內交通領域中，各類研究都具有高複雜性、即時性及不明確性等特性，因此考量類神經網路的優點與交通議題的特性，類神經網路已成功地解決許多以往交通領域的瓶頸。在交通流量預測與分析方面，黃泰林(1994)利用類神經網路將不同的流量組合與路口轉向比下進行模擬分析比較，推估路口車流之可能動向。在事件管理方面，黃志偉(2002)依據公路警察隊的筆事事件記錄資料，在考量事故發生處理程序之時間特性與合理性的情況下，以倒傳遞網路建立二階段處理時間預測模式。魏健宏等(2001)以蒐集國內交通運輸界近十年來與類神經相關之論文、報告等資料，並加以有系統分類整理，並評析其研究與應用特性。其中類神經網路以倒傳遞網路模最常被應用在國內交通領域上，包括分類與歸類問題、最佳化問題、預測等問題。

2.2 事件管理機制

當在行駛途中發生事件時，受到影響的不只是事件當事人，連同其他用路人也會因為事件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，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)及事件恢復時間。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。事件管理處理程序可分為四個主要部分，其內容如圖 3 所示：



資料來源：公路路網交控及資訊系統架構設計與建置準則(2009)。

圖 3 事件反應管理處理程序圖

1. 事件偵測與確認(T2-T1)：一般常用之事件偵測設備包括車輛偵測器、影像式偵測器與探測車等三類，其所蒐集資料須達到一定之可用性，最後則依據所蒐集到的資料來界定事件影響之範圍。
2. 事件反應時間(T4-T2)：當偵測到事件發生時，所有的事件回報資訊將透過「高速公路交通行控中心」進行狀況研判與通報確認。
3. 事件現場管理與清除時間(T5-T4)：通報派遣與資訊提供，行控中心確認事件之發生後，即通知各救援單位(公警單位、工務單位與拖吊公司)動員，根據事件嚴重程度逐步或同時啟動事件管理控制策略，以通知用路人避免進入或離開事件區域。
4. 事件恢復時間(T6-T5)：其公警單位與工務維護單位之工作內容包括撤除路障、切換設施至正常模式、設施重新開放、提供設施開放資訊等。

2.3 事件延遲預測相關文獻

在探討事件延遲預測之相關文獻中，其中 Messer et al.(1973)利用 Greenshields' 所推導之車流模式，並結合衝擊波之觀念，利用時空圖繪出意外事故個別車輛之行駛軌跡，根據其軌跡於通過意外事故地點前後，最後推算車輛於高速公路上通過意外事故地點所花費之總旅行時間，以透過不同之操作控制策略轉移車流量。林士傑(2001)以中山高為研究範圍，依幾何特性、匝道進出流量與地區重要性等準則分為 8 個群組路段，以台汽客運 GPS 車輛行駛之速度及時間、VD 偵測器速度、事件數、尖離峰、假日非假日、調查流量等真實環境資料作為事件延遲時間影響重要因子，以構建數種模式，包括簡單時間序列模式、考慮前後群組時間關係模式等，其研究結果類神經在旅行時間預測具有穩定且一定之預測能力。李穎(2002)融合國道客運班車 GPS 資料、VD 資料、事件資料等真實資料，以類神經網路法尋找各項資料來源其參數與旅行時間之關係，構建中山高西螺至永康交流道路段之旅行時間預測模式。模式構建的同時亦分別探討四種不同切分方式其旅行時間預測績效。

Guan (2010) 利用類神經探討高速公路上事故延遲之預測相關研究，作者蒐集了高速公路管理中心 660 件交通事故資料，經過資料篩選後可用事件資料為 170 件，以構建一類神經網路模式來預測事故延遲時間之預測。作者將原有 21 項事故資訊進行篩選後得出 8 項關鍵因子作為模式之輸入值。根據模式訓練結果表示，透過模式所得出之結果對於實際之延遲時間具有一定相關性及可靠性。

Valenti (2010)以義大利高速公路為研究對象，蒐集了 237 件事務資料進行事故延遲預測之研究，作者構建了 MLR、CHAID、ANN、RVM 及 KNN 等五種不同的模式探討事故延遲時間預測之績效，並採用 MAPE、MAE 及 RMSE 三項指標作為衡量模型之績效。結果表示，這五種模型對於特定不同的延遲時間範圍皆能達到不錯的預測能力。Li (2010)探討北京市高速公路作為事故延遲時間之預測，根據所記錄之事故資料中分別挑選出 16 項事故延遲影響因子作為模式預測之用，其因子包括發生尖離峰、事故開始至結束時間、碰撞的車種、人員傷亡、事故影響車道數、是否有提供用路人事故資訊等，再引用多項羅吉特模式(MNL)來進行影響因子輸入與事件持續時間之預測。其結果顯示，MNL 模式應用在事故延遲課題上亦具有一定之準確性及預測能力。Lee and Wei (2010)利用類神經網路融合 VD 資料及事故資料構建一事故延遲時間預測模式，並利用基因演算法簡化模式輸入之單元數，有效減少運算時間及改善延遲時間預測之績效。

2.4 類神經應用在市區道路相關文獻

Mussone et al. (1999)蒐集米蘭市區道路肇事紀錄資料，針對市區路口碰撞相對危險程度使用三層、完全連結及向前式的類神經網路來預測，選定 10 種變數(時間、流量、路口型態、事故型態、鋪面及天氣等)，輸出變數為第 i 個路口碰撞相對危險程度。周雍傑(2000)以台南市都市地區道路交通事故調查表為基礎資料，測試不同的類神經模式(例如自變數、隱藏層數及訓練測試等的不同)，找出最佳模型。探討都市地區路口與路段每件肇事的死傷嚴重程度構建預測模式，結果可提早處理單位及民眾提出警訊。黃昶斌(2004)利用類神經網路模式探討都市地區事故嚴重性之預測，根據台北市道路交通事故調查報告表中選定關鍵影響(時間、道路型態、光線、事故位置及號誌等)變數預測出某路口、路段在發生肇事後，當事人之傷亡程度，測試結果顯示，類神經網路方法所構建的預測肇事嚴重程度模式有相當良好的績效。

楊雯鈞 (2009)選定台北市作為意外事件持續時間之研究地區，作者採用倒傳遞網路構建交通事件持續時間預測模型，並整合不同來源之交通資訊，如警察廣播電臺即時路況、中央氣象局之台北氣象站觀測資料及 Google 網路地圖等，以測試分析預測模型之適用性，並評估其預測績效。作者針對市區道路及高架橋兩種不同道路特性建立預測模型，探討影響交通事件持續時間長短之輸入變數有發生時間、位置、事件類型、道路型態、天候、車道數及事件型態等變數，其預測結果顯示，市區道路 MAPE 值 28.37%，高架橋 MAPE 值 18.72%，皆具有合理且優良之預測績效，因此兩個模型皆具有可實際應用

於真實交通上之能力。

2.5 小結

從上述文獻回顧中了解到採用不同之方法論、不同之變數及資料來源在事故延遲時間預測課題上皆有不錯之預測能力，可提供給相關單位作為事故反應管理上之參考依據。在過去文獻所表現之成果，事故延遲時間預測對於事故管理與控制均有正面之影響，因此更確立本篇之研究方向。但多數事故延遲時間預測相關研究以高快速公路為考量，鮮少對於市區事故所造成之延遲時間作一探討，因此本研究在構建預測模型時，主要藉由高快速公路事故延遲時間預測相關文獻之概念，作為本研究所使用之研究方法。

三、模型架構

本章節將探討交通意外事故的類別與特性，進行資料處理分析並預測意外事故從發生至排除之持續時間。考量意外事故資料的變異性較大，因此利用具有高度學習、過濾雜訊及容錯能力的類神經網路之倒傳遞網路(Back Propagation Network, BPN)，來預測路網中所發生之即時事故的持續時間，將預測出之持續時間作為執行控制策略之參考依據。

3.1 事故延遲時間預測模式架構

本研究欲探討之事故延遲時間係指當事故發生時，所有的事故回報資料將透過「高雄市警察大隊」進行狀況研判與通報確認，以此作為事故延遲之起始時間。楊雯鈞(2009)係採用警察廣播電台之即時路況作為事故資料之基礎，主要係依據一般民眾、交通大隊或事件當事人主動通報後，作為事件持續之起始時間。兩者所認定之事故延續時間皆指事故發生通報派遣與資訊提供，根據事故嚴重程度逐步或同時啟動事件管理控制策略；但在事故持續之終止時間方面，本研究係以車流恢復正常之時點作為事故延遲之終止時間，楊雯鈞則以事故排除時點作為事故持續之終止時間。

茲本研究依照事故發生現場資料特性可分為四項資料特性，分別為車輛偵測器資料、事故特性資料、時間天候環境資料及道路幾何特性資料。在時間預測階段，運用類神經網路擁有績效較好的預測能力進行時間預測，將蒐集到的 VD 資料、事故資料、時間與環境資料及道路幾何特性等資料，經過整理與篩選之後，以構建該路段在事故發生時所造成的延遲時間預測，其模式架構如圖 4 所示。

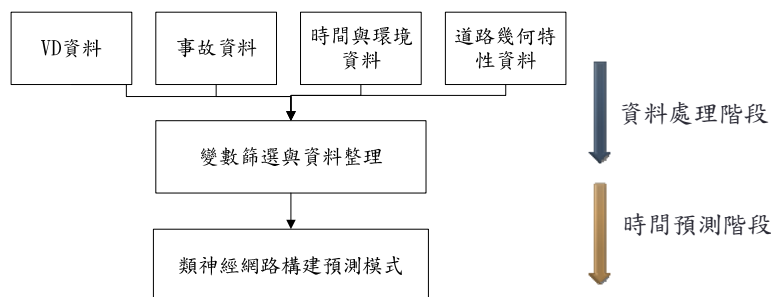


圖 4 事故延遲時間預測模式架構

3.2 類神經網路

類神經網路近年來被廣泛使用在各類實務或研究中，其優勢即在不需針對離散型變數或連續型變數做特殊處理即可同時輸入模式中運算，得出之運算結果績效優良，因此本研究將該方法運用於市區事故延遲時間預測模式。本研究將市區 VD 資料、事故資料、時間與環境及道路幾何等資料經過整理與篩選之後，以構建出計算事故延遲時間模式，其網路架構模式如圖 5 所示。此架構包含輸入層(事故特性因子)、隱藏層及輸出層(事故持續時間)。隱藏層的個數將會影響權重值於運算過程中訓練調整的結果，可為使用者定義來調整。最後輸出的結果即為預測值之事故持續時間。而此模型為依據大量的資料輸入，並經由重複地訓練與調整權重，直到模型效能的收斂以完成預測模型。

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 : 輸出值

i : 輸入層單元個數

x_j : 輸入單元

h : 隱藏層單元個數

w_{hj} : 隱藏層與輸出層之間的權重值

θ_h : 隱藏層門檻值

w_{ih} : 輸入層與隱藏層之間的權重值

f : 隱藏層之轉換函數

θ_j : 輸出層門檻值

g : 輸出層之轉換函數




圖 5 事故延遲時間預測之倒傳遞網路模型架構

四、資料蒐集與結果分析

一個完整意外事故持續時間的預測模型的建立，首先必須考量事故資訊的內容來選擇適合的模型事故特性影響因子作為輸入之變數，而影響因子的選擇則須依照所擷取的資訊內容來設定。本研究將採用高雄市智慧運輸中心所提供之固定點車輛偵測器資料與高雄市交通大隊所提供之事故資料，作為事故延遲時間預測之主要資料來源。

4.1 資料來源處理

本研究路段為高雄市民族路段(中正路至金鼎路)，全長約 4 公里，其範圍包含車輛偵測器及事故資料，資料來源為 99 年度全年高雄市民族路的 4 處車輛偵測器資料以及高雄市交通大隊事故資料，透過兩種資料交互比對後，彙整出有效事故及車流資料作為本研究預測之對象。偵測器資料以全天候 24 小時不間斷地進行偵測，資料為每 5 分鐘記錄一次，其內容包含日期、時間、車道位置、大小車流量、大小車速度、平均速度、車道佔有率等資料，本研究主要採用流量與速度兩項指標。事故資料以高雄市交通大隊提供 99 年度歷史事故資料庫作為比對之基礎，該資料庫所匯出之資料包含發生日期及時間、死傷情形、事故類別、天候、光線、速限、道路型態、事故位置、車道劃分設施、事故類型及型態等資料。

本研究將所蒐集到的市區事故歷史資料庫進行系統性的整合，符合現實交通時空環境，進而利用類神經網路建構市區事故延遲時間之預測模式。根據事故紀錄資料之時間、日期及事故位置進行與偵測器資料的比對，從原始 1137 筆資料中，篩除資訊不完全無法清楚地描述事故發生的內容、重複記錄於事故資料庫及事故發生時車流因其他轉向分散導致無突顯出事故車流等狀況，整理出 68 筆有效事故延遲時間資料來進行分析。圖 6 分別表示研究範圍內偵測器佈設位置及其有效偵測事故車流之範圍。



圖 6 事故有效偵測範圍示意圖

4.2 路段資訊分析

由於在不同時段所產生車流狀況亦所不同，為瞭解在各個時段區間內事故發生之情況，本研究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)，其資料分析結果呈現於表 1。針對不同時段的分類，各自平均觀察每時段區間所佔之百分比。經由時段分組統計結果可發現，事故發生以白天時段(09 - 16 時)比例最高為 51.47%，其平均事故延遲時間為 34.51 分；清晨時段(20 - 07 時)比例最低為 7.35%，延遲時間為 26 分；事故所造成平均延遲時間最長時段為上午尖峰(07-09 時)，平均延遲時間為 38.78 分。

表 1 事故發生時段分組統計

發生時段(時)	件數	比例(%)	平均事故延遲時間(分)
20-07	5	7.35	26.00
07-09	9	13.24	38.78
09-16	35	51.47	34.51
16-20	19	27.94	30.63
合計	68	100.00	33.37

若以事故發生日作為分類可整理成表 2 所示，在 68 筆比對成功的事故資料中，每日平均發生件數方面，平常日及假日為 9.8 件及 9.5 件，兩者差異不大，惟有在平均事故延遲時間上，平常日為 31.53 分，假日為 38.1 分鐘，本研究初步研判係由於假日車潮延續時間較長，使得平均事故延遲時間有較長之現象。

表 2 事故發生日分組統計

發生日	件數	每日平均發生件數	平均事故延遲時間(分)
平常日	49	9.8	31.53
假日	19	9.5	38.10
合計	68	—	33.37

在事故發生類型部分共分為六類，分別是追撞、側撞、同向擦撞、倒車撞、撞護欄及路口交岔撞。本研究依據各事故類型所造成之延遲時間彙整如表 3 所示，整體平均延遲時間為 33.37 分鐘，其中側撞所佔比例為最多，平均延遲時間為 31.47 分鐘；其次為追撞事故類型，平均延遲時間為 33.55 分鐘。

表 3 事故類型分組統計

事故類型	件數	比例(%)	平均事故延遲時間(分)
追撞	22	32.35	33.55
側撞	23	33.82	31.47
同向擦撞	14	20.59	44.15
倒車撞	1	1.47	25.00
撞護欄	1	1.47	15.00
路口交岔撞	7	10.29	21.31
合計	68	100.00	33.37

表 4 為事故發生時間類型與天候狀況所統計之延遲時間，首先事故發生在晴天離峰時段下平均延遲時間為 34.17 分鐘，陰天為 38 分鐘，雨天為最短 26.33 分；接著當事故發生在晴天尖峰時段下平均延遲時間為 29.86 分鐘，雨天為最長為 56.17 分鐘。

表 4 事故時間類型與天候狀況之延遲時間統計

發生時間	晴天(分)	陰天(分)	雨天(分)
離峰	34.17	38	26.33
尖峰	29.86	--	56.17

透過資料來源整理與分析後，大致可以了解到事件相關資料內容及特

性，以得知路段發生事故相關影響因子。本研究亦參考過去針對影響市區事故嚴重性相關文獻中探討之相關交通參數，如事件發生時間點與事故發生類型與延遲時間長度有一定之關聯性。因此，本研究依據此概念作為後續構建類神經網路模式之基礎(在後續 5.2 章節說明)。由於車輛偵測器與事故資料庫記錄資訊數量與內容呈現方式皆不同，需要進一步將每項資料之內容進行描述，以方便於後續類神經網路預測模式之輸入變數，俾以完整將該路段之狀態描述與事件延遲時間結合。

五、模式構建與績效評估

5.1 模式構建

本研究首先將前述所彙整的事故資料及 VD 資料進行比對，將其比對成功之 68 筆事故及 VD 資料來進行模式構建。一般事故資料所擷取之資訊如：事故發生之地點、時間與其相關敘述，其中隱含著事故產生後於該環境狀況的一些重要關聯因素，則模型須根據這些因素來判斷出事故的嚴重性，進而預測出可能影響路網的時間，本研究將該等影響因子稱為影響事故延遲時間因子。最後利用模型來呈現出事故因素與持續時間之間的關連，為預測模型建立之目的，故如何擷取影響事故的重要因子，為建立預測模型效能表現之重要基礎。

本研究運用 EzNeuron 類神經網路軟體，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。本研究構建之類神經網路模式需要考慮參數之內容包括：訓練範例與測試範例的準備、網路架構(如隱藏層層數以及處理單元數目之決定)、學習速度、慣性因子、學習法則以及收斂範圍等加以選定，進而調整模式之整體網路，最後是其訓練與測試結果是否良好。如表 5 所示：

表 5 類神經網路參數說明及設定值

網路參數	說明	設定值
訓練週期 (Epoch Size)	全部樣本學習過一次稱為一個週期，網路通常需重複多次的訓練週期才能達到所要的收斂程度。	300
學習率 (Learning Rate)	每次權重值改變量幅度的參數，其大小會影響學習效果。	0.5
慣性因子 (Momentum Factor)	計算權重值修正量時，加上某比例上次權重值之修正量，以解決訓練過程中震盪現象及加速收斂。	0.5
誤差判斷	一般倒傳遞網路係採用誤差均方根來表示，來衡量訓練結果與實際值是否為接近。	--

在本研究模式績效評估準則方面，係採用類神經網路法則中的均方根誤差值(RMSE)以及一般常用的評估指標平均絕對誤差比率(MAPE)評估模式績

效。均方根誤差值為類神經網路法中的誤差結果指標，可作為比較模式彼此之間的績效優劣。均方根的定義為實際值與網路輸出值差的均方根，而 RMSE 值愈小則代表網路之收斂情形愈佳，模式愈穩定，預測誤差值愈小。一般而言 RMSE 值小於 0.1 時，即代表網路達收斂之績效甚佳。RMSE 計算公式如下：

$$RMSE = \sqrt{\frac{\sum_P^M \sum_j^N (T_j^P - Y_j^P)^2}{M * N}}$$

T_j^P ：第 P 個範例的第 j 個輸出單元之實際輸出值

Y_j^P ：第 P 個範例的第 j 個輸出單元之網路輸出值

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，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。

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

$\hat{x}(k)$ ：網路輸出估計值

$x(k)$ ：實際值

若 MAPE 值越接近於 0，表示估計效果越好。Lewis(1982)認為 MAPE 是最有效評估指標之一，並對於 MAPE 值大小與其代表含意提出說明，如表 6 所示。

表 6 MAPE 評估指標

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

5.2 事故延遲預測模式

本節主要介紹事故延遲時間模式之構建、整理先前所描述之事故資料，並參考相關文獻之概念，進一步找出影響事故延遲時間之變數因子，而構建事故延遲時間預測模式。本研究所採用之變數為配合類神經網路結構設定，將模式輸入變數與輸出變數的彙整如下表 7 所示：

表 7 事故延遲時間預測模式變數之設定

變數編號	變數名稱	變數型態	變數內容
輸入變數	1	發生時間	類別變數 0=非尖峰、1=尖峰
	2	事故期間 流量	連續變數 車輛數(pcu)
	3	事故期間 速率	連續變數 平均速率(kph)
	4	天候	類別變數 0=未下雨、1=下雨
	5	事故類型	類別變數 1=追撞、2=側撞、3=同向擦撞、4= 倒車撞、5=撞護欄、6=路口交岔撞
	6	影響車道數	類別變數 1=1 車道、2=2 車道、3=3 車道
輸出變數	7	事故延遲 時間	連續變數 事故延遲時間預測值(min)

根據表 7 所彙整之變數類別、名稱及其內容概略分成以下 7 點描述：

1. 發生時間變數內容：主要係前章節對於事故發生時段分組與事故發生日分組作一結合，彙整後以尖峰或非尖峰類別變數表示其事故發生時間。
2. 事故期間流量：係根據車輛偵測器所紀錄之車流量，將大車換算成 pcu 後與小車作加總，視為事故期間之車流量，屬連續變數類型。
3. 事故期間速率：事故發生期間之平均速率，屬連續變數類型。
4. 天候狀況：原始格式為晴、陰及雨三種天氣狀況，本研究彙整為下雨及未下雨之類別變數。
5. 事故類型：將事故類型分為追撞、側撞、同向擦撞、倒車撞、撞護欄及路口交岔撞等六種類別變數。
6. 影響車道數：將事故影響之車道數分為以 1-3 類別變數表示之。
7. 事故延遲時間：以連續變數型態紀錄事故路段在發生期間至排除時間。

由於市區車流轉向頻繁，且偵測器佈設間距過長，使得上下游路段型態及車流狀況近似獨立於事故地點，因此本研究暫不納入上下游路段型態及速率等變數。根據上述變數引入類神經網路模式進行運算，事故延遲時間為輸出結果(以分為單位)，依據模式所得結果以 MAPE 及 RMSE 指標進行事故延遲時間預測之績效評估。本研究比對成功共為 68 筆有效事故資料，分別探討在三種不同訓練及測試樣本分配下之績效，其中訓練資料(Training Set)分別為 40、34、50 筆用來建立初始模型，測試資料組(Test Set)分別為 28、34、18 筆用來將初始模型調整成更具廣泛效力、更不受限於訓練資料組的局限，經隨機亂數方式進行樣本分類。

5.3 事故延遲時間預測模式評估結果

根據前面所彙整之時間、流量、速度、天候、事故類型及影響車道數等六項變數作為預測模式之輸入值，以全連結方式至兩個隱藏層單元後，經過

一系列訓練後得出事故延遲時間之預測值，如圖 7 所示。

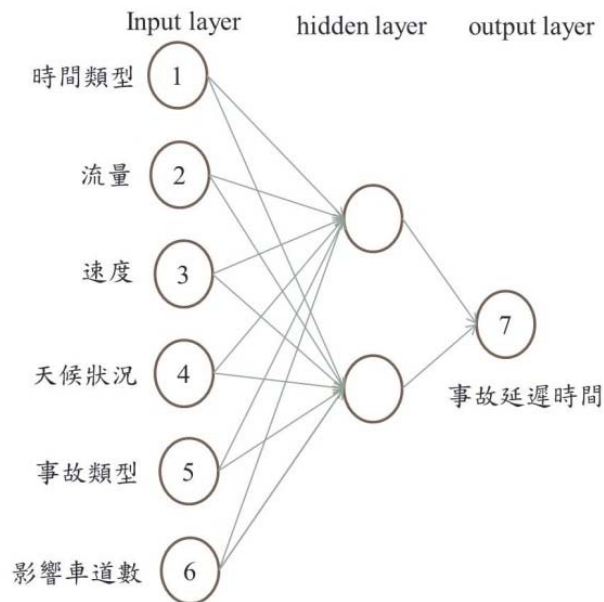


圖 7 事故延遲時間預測網路架構

透過類神經網路運算結果輸出值經過換算成 RMSE 及 MAPE 值，其測試結果如表 8 所示。首先在不做時間分群的情況下對總體資料依據不同訓練及測試樣本數分配進行模式運算，其測試結果為總體 1 所得平均 RMSE 值 0.10，MAPE 值 34.53% 為最佳；以訓練及預測樣本各半分配之總體 2 所得 RMSE 值 0.14，MAPE 值 38.04%，預測結果較為最差。整體而言，本研究所切分三種不同訓練樣本及測試樣本數所得出之 MAPE 值皆屬於合理之預測，代表本研究所構建模式對於事故延遲時間之預測具有不錯之能力。

表 8 總體事故預測模式績效評估結果

樣本分類	訓練樣本數	測試樣本數	RMSE	MAPE(%)	績效評估
總體 1	40	28	0.10	34.53	合理的預測
總體 2	34	34	0.14	38.04	合理的預測
總體 3	50	18	0.13	35.36	合理的預測

將資料進一步區分為尖峰及非尖峰各進行模式訓練及測試。透過表 9 內容可發現尖峰事故延遲時間預測誤差較非尖峰預測誤差高，MAPE 值分別為 38.64 及 29.85，但兩者皆落於合理之預測水準內。從此結果可以推測，由於尖峰時段車流變化大，因此當發生事故時，其不確定性亦較高；相對地，由於非尖峰時段車流變化較小，因此所造成之不確定亦較低。

表 9 以事故發生時段為條件分群預測績效

樣本分類	訓練樣本數	測試樣本數	RMSE	MAPE(%)	績效評估
尖峰	20	14	0.14	38.64	合理的預測
非尖峰	20	14	0.10	29.85	合理的預測

六、結論與建議

6.1 結論

綜合先前各章節所描述的資料蒐集、模式構建與績效評估部分，提出下列三點結論：

1. 本研究係透過高雄市交通大隊 2010 年事故資料及智慧運輸中心 VD 資料，根據文獻探討及資料整理分析對於後續模式構建有用之變數資料。彙整成對於事故延遲預測模式有用之格式，以便預測模式發展之用。
2. 本研究所構建之事故延遲預測模式，其總體樣本 MAPE 值 34.53% 展現合理的預測能力與績效，證明研究中所選取之變數足以充分表達事件延遲預測模式之描述，也證實類神經網路於事故延遲時間預測模式之適用性，突顯出類神經網路實務應用課題之價值。
3. 從不同時段切分進行模式訓練及測試結果可發現，尖峰時段因車流變化大，預測結果誤差較高；反之，非尖峰時段車流變化小，其預測結果準確度較高。因此在考量事故延遲時間預測同時，車流資料係影響預測準確性之重要影響因子。

6.2 建議

針對未來應用市區道路事故延遲時間預測課題方面提出下列建議：

1. 市區道路車流變化較大且路網結構複雜，VD 佈設位置不同於高速公路規則性的佈設，事故地點之交通流量在比對上有實際的困難，亦較難比對成功事故所對應車流資料。建議未來可針對佈設 VD 較密集之道路進行研究，以減少資料處理的難度，或可產生較佳的預測結果。
2. 本研究經過篩選後可用之事故資料僅為 68 筆，無法表顯出整體市區道路事故延遲時間之特性，建議未來拉長蒐集期間使樣本數充足，減少樣本間之差異，使模式所預測出之結果更趨近於真實性。

參考文獻

李穎 (2002)，類神經網路應用於國道客運班車旅行時間預測模式之研究，國立成功大學交通管理研究所碩士論文。

周雍傑 (2000)，以類神經網路探討都市地區肇事嚴重程度之研究，國立成功大學交通管理研究所碩士論文。

林士傑 (2001)，高速公路旅行時間預測模式之研究-類神經網路之應用，國立成功大學交通管理研究所碩士論文。

張新立、吳宗修、李明山 (1995)，交通事故鑑定作業資料電腦化系統，公路

局新竹區監理所委託。

黃志偉 (2002)，高速公路肇事處理時間預測之研究-應用類神經網路分析，國立中央大學土木工程學系碩士論文。

黃昶斌 (2004)，以類神經網路探討都市地區肇事嚴重程度，國立交通大學交通運輸研究所碩士論文。

黃泰林 (1993)，構建智慧型適應性網路號誌控制模式之研究，國立成功大學交通管理研究所博士論文。

楊雯鈞 (2009)，交通意外事件持續時間預測之研究，國立嘉義大學運輸與物流工程研究所碩士論文。

資拓科技股份有限公司 (2009)，公路路網交控及資訊系統架構設計與建置準則，交通部運輸研究所。

魏健宏、陳奕志 (2001)，「類神經網路模式在國內交通運輸研究之成果評析」，*運輸計劃季刊*，第三十卷，第二期，第 323-348 頁。

Guan, L., Liu, W., Yin, X., Zhang, L. (2010), "Traffic Incident Duration Prediction Based on Artificial Neural Network," International Conference on Intelligent Computation Technology and Automation.

Lee, Y., Wei, C. H. (2010), "A Computerized Feature Selection Method Using Genetic Algorithms to Forecast Freeway Accident Duration Times," *Computer-Aided Civil and Infrastructure Engineering*, Vol. 25, pp. 132-148.

Lewis, E. B. (1982) Control of body segment differentiation in *Drosophila* by the bithorax gene complex, *Embryonic Development, Part A: Genetics Aspects*, Edited by Burger, M. M. and R. Weber. Alan R. Liss, New York, pp. 269-288.

Li, R., Zhao, X., YU, X., Cheng N., Zhu, J. (2010), "Incident Duration Model on Urban Freeways Based on discrete choice model," International Conference on Electrical and Control Engineering.

Messer, C. J., Dudek, C. L., and Friebele, J. D. (1973), "Method for predicting travel time and other operational measures in real time during freeway incident condition," *Highway Research Board*, Vol. 461, pp. 1-16.

Mussone, L., Ferrari, A., Oneta, M. (1999), "An analysis of urban collisions using an artificial intelligence model," *Accident Analysis and Prevention*, Vol. 31, No. 6, pp. 705-718.

Valenti, G., Lelli, M. and Cucina, D. (2010), "A comparative study of models for the incident duration prediction," *European Transport Research Review*, Vol. 2, No. 2, pp. 103-111.

