

第五章 模式構建與結果分析

本章主要敘述類神經網路模式構建過程、結果與其應用方法，內容主要分為五個部分，分別為模式構建、路口肇事嚴重度類神經網路模式與路段肇事嚴重度類神經網路模式分析，其次為模式應用，最後進行結論與分析。

5.1 模式構建

本研究採用模式係以目前應用相當普遍的倒傳遞類神經網路模式，將所蒐集到肇事案件依據當事人之死亡、重傷、輕傷等情形分為兩種類別，一是重傷或死亡案件，另一是輕傷案件，並將路口肇事案件與路段肇事案件分開進行模式構建，網路結構如圖 5-1。另本研究所使用類神經網路參數及績效評估的準則，亦將於本節詳細說明。

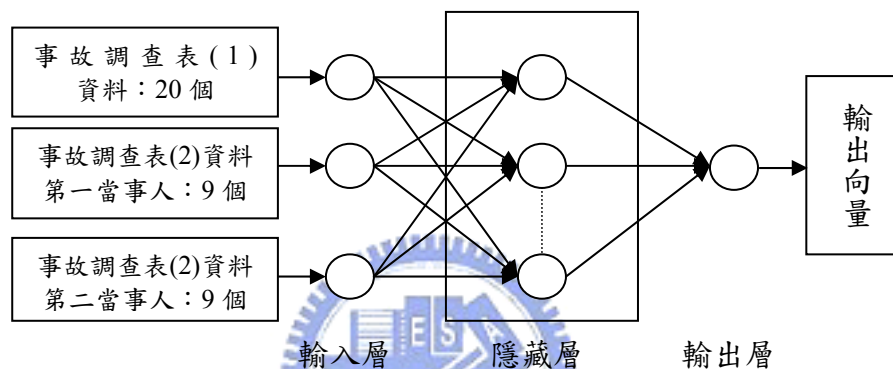


圖 5-1 預測肇事嚴重程度類神經網路結構圖

5.1.1 網路結構

類神經網路的架構可區分為(1)輸入層：表示輸入變數，處理單元則依問題決定；(2)隱藏層：表示輸入變數之間的交互影響，可分為單隱藏層與多隱藏層，其處理單元數目可依問題特性與多項法則決定；(3)輸出層：表示輸出變數，處理單元則依問題決定。為使構建的類神經網路模式所得結果與實際狀況儘可能相符，本研究採用監督式學習方法，以正確的目標輸出值作為依據，並藉由隱藏層的設定及非線性作用函數之特質，有效反應危險因子之交互作用並學習非線性的資料型態，「層」與「層」之間的網路連結則採用完全連結之前向網路；網路的學習法則是以最小平方差為基礎，採用非線的轉換函數，依輸入值計算網路輸出值，並和該輸入的目標輸出值比較，調整連結權重，並重複此一訓練過程，直至誤差在容許範圍內或完成學習設定的學習次數後停止訓練，有關訓練過程及計算方法業於第三章予以詳述說明，不再贅述。

5.1.2 輸入層

無論任何預測模式均是以過往資料對未來未知的情形進行推測，模式構建所使用的資料，其前提是該資料與所欲推導、預測的結果有一定的相關性，故輸入變數的選擇，關係著模式推測的績效，如果輸入變數給得不佳的話，就算模式的理論、方法如何優秀，其預測出結果必定大打折扣。另 Zurada (1992)提出高維度 (High Dimension)的類神經網路的效果比低維度的效果來的好，但高維度的網路

其複雜度較大，所需運算處理所花費的時間成本較大，因此必須在網路運算效率與績效之間作權衡(Trade-off)。所以根據現有所蒐集到的肇事資料中篩選出相關的項目，則是模式績效優劣的重要關鍵。

本研究所蒐集的資料，係由臺北市政府警察局交通警察大隊針對肇事案件所作的道路交通事故調查報告表(附錄一)內的各項資料，而事故調查報告表分為道路交通事故調查報告表(1)與道路交通事故調查報告表(2)兩個部分，道路交通事故調查報告表(1)資料係由肇事的時空、環境及部分道路設施資料組成，道路交通事故調查報告表(2)資料則由肇事當事人之各項基本資料所組成。以下針對事故調查報告表的資料內容稍作說明，並予以篩選作為模式構建之輸入層。

首先針對道路交通事故調查報告表(1)資料，包括發生時間、天候、光線、道路類別、速限、道路型態、事故位置、路面狀況、道路障礙、號誌、車道劃分設施、事故類型及型態分別說明，並決定是否納入輸入層變數。

1. 發生時間

係指肇事發生之年、月、日、時、分、星期等，鑑於交通事故的傷亡的嚴重程度與交通量大小有一定的關係，而都市地區的交通量常有重現的情況，因肇事時之交通量無法取得之故，本研究打算以肇事發生之月份、時段、星期等三項資料作為交通量的替代項，列入輸入層之一。

2. 天候

係指肇事時的天候狀況，一般而言，不良的天候會使得駕駛人的視線不良，視距變短，又或者降雨使得路面濕滑等，均可能增加交通事故的傷亡程度，另外以天候狀況與肇事嚴重程度進行 χ^2 檢定，結果顯示天候與肇事嚴重程度有顯著性，故將本項資料納入輸入層變數。

3. 光線

係指肇事時的自然光線及照明狀況，共分成四種類型，良好適當的道路照明，對於行車安全有一定程度的幫助，另外以光線類別與肇事嚴重程度進行 χ^2 檢定，結果顯示光線與肇事嚴重程度有顯著性，故本項資料作為輸入層中的一項，對於模式效果應有幫助。

4. 道路類別

這一項資料是記錄肇事道路所屬之管轄層級，雖然說省道設計的等級會比縣道或鄉道高，但是本研究的對象是市區道路，市區道路雖然也有不同的道路類別，但是整體工程及設計的等級並沒有太大的差異，故本項資料不列入輸入層項目。

5. 速限

係指交通事故第一當事人所行駛道路之速限，行車速度與肇事嚴重程度有絕對的關係，因肇事時車輛之行車速度無法取得，又速限越高的道路，在交通順暢的情況下，駕駛人的行車速度也比較快，如果不幸發生肇事，亦會導致較為嚴重的肇事案件，故本項資料納入輸入層變數以代替肇事時駕駛人之行車速度。惟該項資料，僅記載第一當事人所行駛道路的速限，其他當事人所行駛之道路

速限則未記載。

6.道路型態

係指交通事故發生第一次撞擊位置之道路型態，共分為平交道、交岔路、單路、圓環廣場四大類，不同的道路型態所發生的肇事型態均不相同，肇事當事人的受傷程度亦有輕重之分，所以道路型態自當為輸入層中的一項重要變數。

7.事故位置

係指交通事故發生第一次撞擊位置，事故位置不同與肇事嚴重程度是否有關聯，經以事故位置類別與肇事嚴重程度進行 χ^2 檢定，結果顯示事故位置與肇事嚴重程度有顯著性，故將此項資料列為輸入層項目之一。

8.路面狀況

良好的路面狀況，是安全的行車環境所必備的條件之一，不良的路面狀況會增加駕駛人的反應時間，進而使肇事發生的機會增加或甚至可能會使得肇事當事人的受傷嚴重程度加重，因此將本項資料列為輸入層的項目。

9.道路障礙

道路障礙與路面狀況亦同，有障礙存在的道路，駕駛人必須分心注意，自難將所有的注意力集中在其他道路狀況，且道路障礙與視距是否良好有相當大的關係，視距不足會造成駕駛人遇到狀況無法及時反應，因而肇事，故將本項資料列為輸入層變數之一。

10.號誌

該欄資料包括有號誌種類及號誌動作，一般而言，號誌化的路口的安全性通常高於非號誌化路口，Greibe(2003)分析丹麥 1987-1991 的路口道路交通事故資料亦得到上述的結果，因此路口或路段是否號誌化對於肇事發生有一定程度的影響，故將本項列為輸入層變數。

11.車道劃分設施

車道的劃分對於肇事嚴重程度有絕對的影響，舉個例子，對撞的事故，因車輛的動能較大，所以肇事傷亡嚴重程度較大，如道路中央設有劃分島，則對撞的事故發生的機率就相當低，所以車道劃分設施對於肇事嚴重程度一定有影響，因此將本項列為輸入層變數，惟各個肇事案件，此項資料僅記載第一當事人部分。

12.事故類型及型態

事故類型及型態係指肇事的部撞型態，通常對撞的交通事故會有較為嚴重的傷亡狀況，而一般的小擦撞事故，當事人的傷亡程度自然較低，另外以事故類型及型態與肇事嚴重程度進行 χ^2 檢定，結果顯示事故類型及型態與肇事嚴重程度有顯著性，故將本項資料納入輸入層變數對於預測肇事嚴重程度應有相當大的幫助。

表 5-1 道路交通事故調查表(1)經選用輸入層變數編碼表

輸入變數	分類方式	變數型態	分類數	χ^2 檢定是否顯著 *代表顯著
月份	一月~十二月：1~12	類別變數	12	未檢定
時段	0 時至二十四時：0~23	類別變數	24	未檢定
星期	星期日~星期六：0~6	類別變數	7	未檢定
速限	0~20 公里：1 20~70 公里：2~6 70 公里~：7	類別變數	7	
天候	如事故調查報告表(1)分類	類別變數	8	*
光線	如事故調查報告表(1)分類	類別變數	4	*
道路型態	如事故調查報告表(1)分類	類別變數	17	
事故位置	如事故調查報告表(1)分類	類別變數	21	*
路面鋪裝	如事故調查報告表(1)分類	類別變數	5	未檢定
路面狀態	如事故調查報告表(1)分類	類別變數	5	
路面缺陷	如事故調查報告表(1)分類	類別變數	4	未檢定
障礙物	如事故調查報告表(1)分類	類別變數	5	未檢定
視距	如事故調查報告表(1)分類	類別變數	7	未檢定
車道劃分-分向	如事故調查報告表(1)分類	類別變數	10	
車道劃分 A -快車道	如事故調查報告表(1)分類	類別變數	5	
車道劃分 B -快慢車道	如事故調查報告表(1)分類	類別變數	5	
車道劃分 C -路面邊緣	如事故調查報告表(1)分類	類別變數	2	
事故類型 及型態	如事故調查報告表(1)分類	類別變數	34	*
號誌種類	如事故調查報告表(1)分類	類別變數	4	
號誌動作	如事故調查報告表(1)分類	類別變數	4	

道路交通事故調查表(2)資料，主要記載肇事當事人的相關資料，包括性別、受傷程度、主要傷處、保護裝備、打行動電話、當事者區分(類別、車種)、車輛用途、當事者行動狀態、駕駛資格、駕駛執照種類、飲酒情形、車輛撞擊部位、肇事原因、肇事逃逸、職業、旅次目的等。然肇事發生通常具有兩個當事人以上，但為避免輸入項目個數過多，使得類神經網路訓練耗時過久，本研究僅選定第一、第二當事人資料作為輸入層變數，各項資料選用情形，說明如下。

1. 第幾當事人

交通事故調查報告表將當事人，依照肇事責任及受傷程度分別排序，肇事責任最重的列為第一當事人，如肇事責任相當，則以受傷較輕的列入第一當事人。為使當事人之各別資料能反映出肇事嚴重程度並兼顧網路訓練的效率，僅使用第一、第二當事人資料作為輸入變數，其餘當事人資料予以捨棄。

2. 性別

當事人的性別與駕駛行為的瘋狂程度有相當大的關係，一般而言，女性駕駛比男性安全，另外以性別分類與肇事嚴重程度進行 χ^2 檢定，結果顯示兩者間具有顯著性，故將本項資料列入輸入層變數。另無或物的情形，亦予採用，至於性別為肇事逃逸，則將整筆肇事案件資料捨棄不用。

3. 年齡

當事人的年齡與駕駛行為的瘋狂程度有相當大的關係，一般而言，年齡較大的駕駛人因心態較為成熟兼之多已成家立業且駕駛經驗較為豐富，所以駕駛行為通常會比年齡較小的安全，另外以年齡類別與肇事嚴重程度進行 χ^2 檢定，結果亦顯示兩者間具有顯著性，故將本項資料列入輸入層變數。

4. 當事者區別

該項資料記錄駕駛人駕駛的車種或者未駕駛的情形(行人、乘客)，駕駛的車種越大，肇事發生後，另一方當事人之傷亡程度也越高，又或者當事人為道路弱勢者(行人)，則發生車禍時也會較為嚴重的傷亡情況，另外以當事者區別與肇事嚴重程度進行 χ^2 檢定，結果顯示兩者間具有顯著性，可知本項資料為道路交通事故調查表(2)資料中與肇事嚴重程度有相當程度關係的一項，故將之列為輸入層變數。

5. 車輛用途

車輛用途的分項與當事者區別所記載的資料相當類似，因輸入層項目已採用當事者區別資料，故本項資料無須重複採用。

6. 駕駛執照種類

駕駛執照的種類與肇事嚴重程度無任何關聯，且只要是合法取得駕駛執照，均可認為當事人有足夠的駕駛能力，故本項資料不列入輸入層變數。

7. 駕駛資格

駕駛資格係指肇事當事人是否有駕駛執照，其駕駛能力是否經過政府機關認可，其駕駛行為是否具備有合法性，通常有駕駛執照的人我們可認為他具有足夠的駕駛能力，而無駕駛照者，可能是未受過駕駛訓練、駕駛經驗不足的駕駛人或是遭吊扣(銷)駕駛執照的高危險駕駛人，因此駕駛資格的有無亦會影響肇事後當事人的傷亡程度，另外以駕駛資格與肇事嚴重程度進行 χ^2 檢定，結果顯示兩者間具有顯著性，故將本項納入輸入層變數。

8. 受傷程度與主要傷處

受傷程度的資料與輸出層資料相近，另外，如有主要傷處的資料，即可輕易判斷受傷程度，將導致模式的實用性降低，故不以採用。

9. 違規情形

違規情形可分為，未使用保護裝備、打行動電話、飲酒及肇事原因等，不同的違規行為會導致肇事嚴重程度不同，另外以 χ^2 檢定上列違規情形與肇事嚴重程度間是否具有相關性，結果顯示，除未使用保護裝備未達顯著水準外，其餘均達顯著水準，即違規行為與肇事嚴重程度具有相關性，故將違規情形列入輸入層變數。

10. 車輛撞擊部位

車輛撞擊部位，因資料缺漏嚴重，故不予採用。

11. 職業

職業資料，以「不明」佔絕大多數，故不採用此項資料作為輸入層變數。

12. 旅次目的

旅次目的資料，以「不明」佔絕大多數，故不採用此項資料作為輸入層變數。

表 5-2 道路交通事故調查表(2)經選用輸入層變數編碼表

輸入變數	分類方式	變數型態	分類數	χ^2 檢定是否顯著 *代表顯著
性別	男：1 女：2 無或其他：3	類別變數	3	*
配帶安全帽(帶)	如事故調查報告表(2)分類 無須填寫：0	類別變數	5	
當事者區分(車種)	如事故調查報告表(2)分類 無須填寫：0	類別變數	44	*
當事人行動狀態	如事故調查報告表(2)分類 無須填寫：0	類別變數	22	*
駕駛資格	如事故調查報告表(2)分類 無須填寫：0	類別變數	9	*
駕駛人飲酒情形	如事故調查報告表(2)分類 無須填寫：0	類別變數	10	*
打行動電話	如事故調查報告表(2)分類 無須填寫：0	類別變數	6	*
肇事原因	如事故調查報告表(2)分類 無須填寫：0	類別變數	65	*
年齡	0~60 歲：1~6 60 歲~：7 無須填寫：0	類別變數	8	*

5.1.3 隱藏層

其主要作用為連接反應前一層與後一層的互動關係，由於層數太多，會造成收斂速度慢、過度學習等缺點，通常一至二層隱藏層之網路，其效果最好(Yoon,1993)。這可解釋成沒有隱藏層時，不足以反應輸入變數間的交互作用；而層數太多時，將使網路過於複雜，容易落入局部極小值，而無法達到收斂。

此外，在使用到傳遞網路解決問題時，一定要先用無隱藏層架構嘗試之，如

果其精確性比有隱藏層為佳，則此問題必不適合用倒傳遞網路，其理由為無隱藏層之倒傳遞網路其效果接近統計方法上一些有線性假設的方法，例如線性迴歸、區別分析，因此無理由用一個複雜的網路解答去取代一個有明確公式的統計方法解答(葉怡成，1993)。

至於隱藏層處理單元數目之決定，目前並無理論上根據，通常可以網路修剪法(pruning algorithm)或網路增長法(constructive algorithm)來尋找最佳的處理單元數目。一般而言，當其數目越多時，網路的收斂愈慢，但可達到較小的誤差值。相反的當其數目越少時，網路的收斂越快，但其誤差值將會增加。這可解釋為當隱藏層處理單元數目太少時，不足以反應輸入變數目的交互作用，因而有較大的誤差。而數目太多時，則網路將會過於複雜，因而使收斂速度降低。

一般處理單元數為輸入層與輸出層處理單元和平均；或輸入層與輸出層相乘後，再開根號所得，至於確切的數目，需以模式的訓練實驗配合之。隱藏層處理單元數目選取原則如下：

1. 目題雜訊越高，隱藏層數目宜少。
2. 問題複雜性越高，即非線性、交互作用程度高，隱藏層處理單元數目宜多。
3. 測試範例誤差遠高於訓練範例的誤差，則發生過度學習，隱藏層處理單元數目宜減少；反之，可增加。

以 P4 的 CPU，512MB 的 RAM 進行運算，1600 筆訓練範例，隱藏層神經元 25 個時，運算時間高達 30 分鐘，當隱藏層持續增加，訓練時間亦等比增加，因此為避免過多無用的運算，有關神經元個數，本研究打算採用網路增長法逐一增加網路隱藏層神經元直到適當的個數為止。

5.1.4 輸出層

本研究所欲構建之模式，主要是用以判斷肇事嚴重程度，輸出層僅利用一個處理單元表示，即當肇事為死亡或重傷時為 1，受傷 0。至於財損類之交通事故，因交通事故調查表(1)資料未有查填，故將之捨棄，不納入模式建構的範圍。

5.1.5 網路參數說明

類神經網路模式是否能執行穩定且良好，目前大都是在實驗過程中，依各模式之收斂性與預測的準確度加以認定之。因此本研究之類神經網路模式的構建針對有關實驗所需考慮因素之內容包括：訓練範例與測試範例的準備、輸入變數的評選、網路架構(如隱藏層層數及其處理單元數目之決定)、學習速度、慣性因子、轉換函數、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，最後視其訓練與測試結果銀好與否而輸出，詳述如下：

1. 模式發展的軟體

本研究將運用 Matlab 6.5，對各種可能之模式組合進行訓練與測試，並選擇較具代表性的模式，供肇事危險鑑定之用。

2. 學習速率(Learning Rate)

學習速率是指控制每次權重值改變量幅度的參數，本研究中將直接使用此軟體的內定值 0.1。此值太大或太小均不宜，有較大的學習速率，表示有較大的騷

路權值修正量，雖可較快逼近誤差最小值，但也容易導致修正過量，造成數值的振盪，不易達到收斂的目的。一般認為學習速率介於 0~1 之間均可，最佳的方式為一開始須以較大的學習速率，而收斂至某程度時，須以較小的學習速率慢慢逼近，隨著每一次學習週期改變學習速率。因此先設定初始學習速率，再設定學習速率變化，為避免學習速率變為零，故須設定最小值。

3. 轉換函數(Transfer Function)

轉換函數是指將作用函數輸出值轉換成處理單元的輸出值的函數，本研究中採用最常用的非線性轉換函數為雙彎曲函數(Sigmoid)。這種函數當自變數趨近於無限大時，函數值域在[0,1]之間。

4. 學習週期

在學習過程中，每次學習一筆範例，直至所有範例全部學習過一次，稱為一個學習週期，網路常須重複很多次的學習週期，方能達到所要求的收斂程度。本研究以訓練範例的個數為學習週期(epoch size)，並且以訓練範例個數的 500 倍為學習次數又或者 MSE 小於 0.001 時停止學習。

5. 誤差判斷

一般倒傳遞類神經網路之訓練測試結果通常係以誤差均方根(RMS)來表示，誤差均方根小即表示訓練結果與實際資料較為接近，亦即網路績效較佳。但本研究中之輸出結果為 1 或 0，而較適合以正確率成功表的方式來判斷網路好壞。

6. 學習法則(Learning Rules)

學習法則是指利用訓練範例來調整網路權重值的方法，本研究採用 Delta Rule，也就是說每學習一個範例，網路的權重值就會更新一次。

7. 權重初值

初始權重矩陣係由亂數產生。

5.2 路口肇事嚴重度類神經網路模式

有關路口肇事嚴重度類神經網路模式構建過程及結果說明如下，主分為兩個部分，首先就模式構建過程的資料篩選、參數設定、隱藏層神經元個數等予以說明，其次則就實證結果如以說明解釋。

5.2.1 模式構建過程

模式構建過程主要針對資料篩選（包括訓練範例與測試範例的選取），參數設定及隱藏層神經元個數設定說明如下：

1. 資料篩選

九十二年道路肇事資料共二八、一八四筆，惟一般財損車禍案件，未查填道路型態、車道劃分設施、事故位置、號誌種類、號誌動作等等與肇事嚴重程度有關的資料，如此將使所得的預測模式績效不佳，故在選用肇事資料時予以刪除，經資料初步篩選剩餘一五、四六三筆，其中有八、九三一筆屬路口肇事案件，再剔除資料內錯漏、空缺等無法補正之肇事案件，所餘輕傷、重傷及死亡案件共八、六九五筆，其中重傷或死亡肇事案件共七十六筆，輕傷肇事案件為八、六一九筆，惟 Matlab6.5 單一變數無法容納如此龐大的資料量，致使訓

練過程無法一次完成，訓練時間過長，訓練效率不佳，為解決此一問題，本研究決定適當減少訓練及測試資料。經隨機亂數的方式選取三組範例：

- 範例一：重傷、死亡案件五十二筆、輕傷案件一、五四八筆，共一、六〇〇筆資料作為訓練範例；重傷、死亡案件二十四筆、輕傷案件七七六筆，共八〇〇筆資料作為測試範例。
- 範例二：重傷、死亡案件五十二筆、輕傷案件四四八筆，共五百筆資料作為訓練範例；重傷、死亡案件二十四筆、輕傷案件二二六筆，共二五〇筆資料作為測試範例。
- 範例三：重傷、死亡案件五十二筆、輕傷案件五十二筆，共一百零四筆資料作為訓練範例；重傷、死亡案件二十四筆、輕傷案件二十四筆，共四十八筆資料作為測試範例。

2. 參數參定

有關網路訓練的各項參數之意義及系統設定業於本章第一節詳細說明，各項參數設定如下：

- 學習速率(Learning Rate)：系統內定值 0.1
- 轉換函數(Transfer Function)：sigmoid 函數
- 學習週期：500epoch 即停止
- 誤差判斷：MSE<0.001 即停止
- 學習法則：Delta Rule



3. 隱藏層神經元個數

· 範例一

為求能找到一個適當的網路模式，本研究以神經元 1~40 個，隱藏層層數 1 層的神經網路，以範例一進行訓練及測試，所得路口肇事嚴重度類神經網路模式績效如圖 5-2，其中神經元個數多者收斂效果多比神經元個數少者佳，亦有相反的情形，可能原因是，因為其初始權重的不同，導致網路結構落入局部最小值的情形，使得收斂效果不佳，另外由績效表顯示，隱藏層神經元個數超過 7 個時所得的類神經網路模式測試績效值差異並非很大，且測試範例之正確率高達 95%以上，其中測試範例輕傷部分的預測正確率多可達到 90%以上，惟測試範例重傷或死亡部分的預測正確率最高僅 45%，不甚理想，這可能是因為訓練範例輕傷部分遠高於重傷部分，使得模式預測結果偏向輕傷，因此有增加重傷、死亡訓練範例或是減少輕傷案件訓練範例的必要，但宥於蒐集到的重傷、死亡交通事故案件數不多，且其中一部分仍要留做測試範例之用，故範例二則是採用減少輕傷案件訓練範例的方式，期能提高重傷、死亡案件的預測正確率。

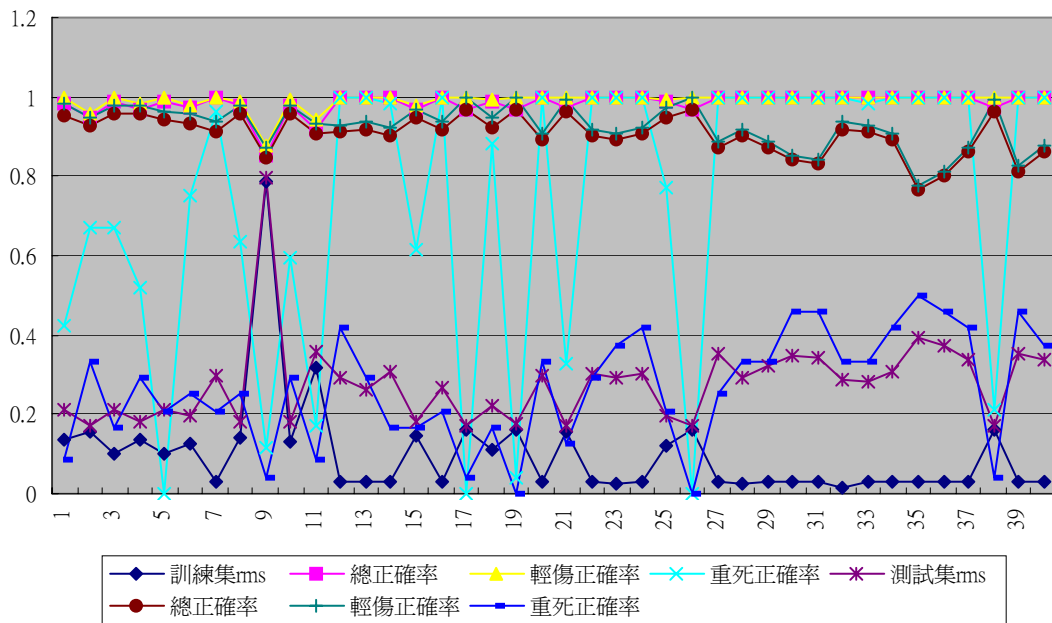


圖 5-2 路口肇事嚴重度類神經網路模式績效圖(範例一)

· 範例二

為確保所構建的類神經網路既簡單、績效又好，避免因輕傷、重傷死亡範例之比例相差過度懸殊，改以訓練範例二進行訓練，採用網路增長法，逐一增加神經元個數的方式進行模式構建，每增加一個神經元，即重覆五次同樣的訓練過程，避免單一次的訓練過程，因初始權重不良導致收斂效果不佳或是落入局部最小值的情形發生，此外為避免過度學習的情況，訓練過程中每訓練 10 個批次就將網路模式記錄，最後從中選取一個收斂、預測效果最好的模式，以確保所選取的係最佳的網路結構，表 5-3 即為各網路結構訓練過程中最佳模式之績效表，以隱藏層神經元個數 9 個所得到的測試績效值最佳，總正確率為 90%，輕傷正確率為 95%，重傷或死亡正確率 41.6%，另外如果以所蒐集到的肇事資料扣除訓練範例部分所得的 8195 筆資料進行測試，得到總正確率 93.3%，輕傷正確率 93.5%，重傷或死亡正確率 41.6%，雖然預測績效良好，但是重傷或死亡正確率仍然不高。

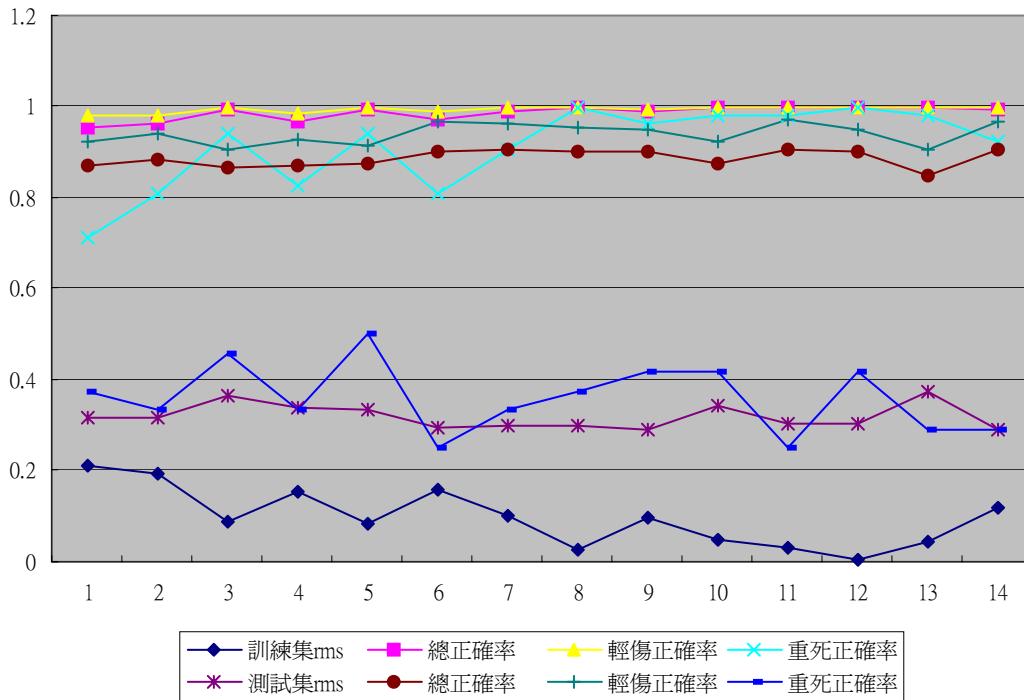


圖 5-2 路口肇事嚴重度類神經網路模式績效圖(範例二)

表 5-3 路口肇事嚴重度類神經網路模式績效(範例二)

神經元數	訓練集rms	總正確率	輕傷正確率	重傷死正確率	測試集rms	總正確率	輕傷正確率	重傷死正確率
1	0.20884	0.952	0.97991	0.71154	0.31828	0.872	0.92478	0.375
2	0.19446	0.962	0.97991	0.80769	0.31686	0.884	0.94248	0.33333
3	0.089447	0.992	0.99777	0.94231	0.36563	0.864	0.90708	0.45833
4	0.15234	0.968	0.98438	0.82692	0.33894	0.872	0.9292	0.33333
5	0.082664	0.992	0.99777	0.94231	0.33539	0.876	0.91593	0.5
6	0.15775	0.972	0.99107	0.80769	0.29544	0.9	0.96903	0.25
7	0.10235	0.99	1	0.90385	0.29875	0.904	0.9646	0.33333
8	0.025586	1	1	1	0.29777	0.9	0.95575	0.375
9	0.095845	0.99	0.9933	0.96154	0.29214	0.9	0.95133	0.41667
10	0.047492	0.998	1	0.98077	0.34396	0.876	0.92478	0.41667
11	0.032935	0.998	1	0.98077	0.30504	0.904	0.97345	0.25
12	0.002261	1	1	1	0.3026	0.9	0.95133	0.41667
13	0.044803	0.998	1	0.98077	0.37489	0.848	0.90708	0.29167
14	0.1185	0.992	1	0.92308	0.29168	0.904	0.96903	0.29167

· 範例三

範例二雖然已經將輕傷的訓練範例減少，但是仍難有效提高重傷死亡案件的預測正確率，因此，為進一步提高重傷、死亡案件預測的正確率，範例三則將輕傷訓練範例與重傷、死亡訓練範例的比例調整成 1:1，以進行網路的訓練，隱藏層個數採用網路增長法，逐一增加神經元個數的方式進行模式構建，每增加一個神經元，即重覆五次同樣的訓練過程，避免單一次的訓練過程因初始權重不良，導致收斂效果不佳或是落入局部最小值的情形，此外為避免過度學習的情況，訓練過程中每訓練 10 個批次就將網路模式記錄，最後從中選取一個收斂、預測效果最好的模式，以確保所選取的係最佳的網路結構，表 5-4 即為各網路結構訓練過程中最佳模式之績效表，以隱藏層神經元個數 5 個所得到的測試績效值最佳，總正確率為 85.4%，輕傷正確率為 95.8%，重傷或死亡正確率 75%，另外如果以所蒐集到的肇事資料扣除訓練範例部分所得的 8591 筆資料進行測試，得到總正確率 74.95%，輕傷正確率 74.95%，重傷或死亡正確率 75%，由此結果可知，減少輕傷訓練範例以提高訓練範例重傷、死亡案件的比例，雖可有效提高重傷、死亡案件的預測正確率，可是卻會導致輕傷的案件的預測正確率降低。

表 5-4 路口肇事嚴重度類神經網路模式績效(範例三)

神經元數	訓練集 rms	總正確率	輕傷正確率	重傷死亡正確率	測試集 rms	總正確率	輕傷正確率	重傷死亡正確率
1	0.13608	0.98077	0.96154	1	0.38608	0.83333	0.83333	0.83333
2	0.38115	0.81731	0.90385	0.73077	0.45001	0.72917	0.875	0.58333
3	0.36583	0.83654	0.76923	0.90385	0.4221	0.77083	0.83333	0.70833
4	0.15955	0.97115	0.94231	1	0.39924	0.83333	0.91667	0.75
5	0.098234	0.99038	0.98077	1	0.38892	0.85417	0.95833	0.75
6	0.16577	0.97115	0.94231	1	0.36964	0.85417	0.95833	0.75
7	0.15955	0.97115	0.96154	0.98077	0.42346	0.8125	0.95833	0.66667
8	0.069533	0.99038	0.98077	1	0.48521	0.77083	0.91667	0.625
9	0.098058	0.99038	0.98077	1	0.42121	0.8125	0.91667	0.70833
10	0.067478	1	1	1	0.51541	0.72917	0.79167	0.66667
11	0.051325	1	1	1	0.41359	0.79167	0.91667	0.66667
12	0.050649	1	1	1	0.36753	0.85417	1	0.70833
13	0.004271	1	1	1	0.43079	0.79167	0.91667	0.66667
14	0.000556	1	1	1	0.43549	0.8125	0.91667	0.70833

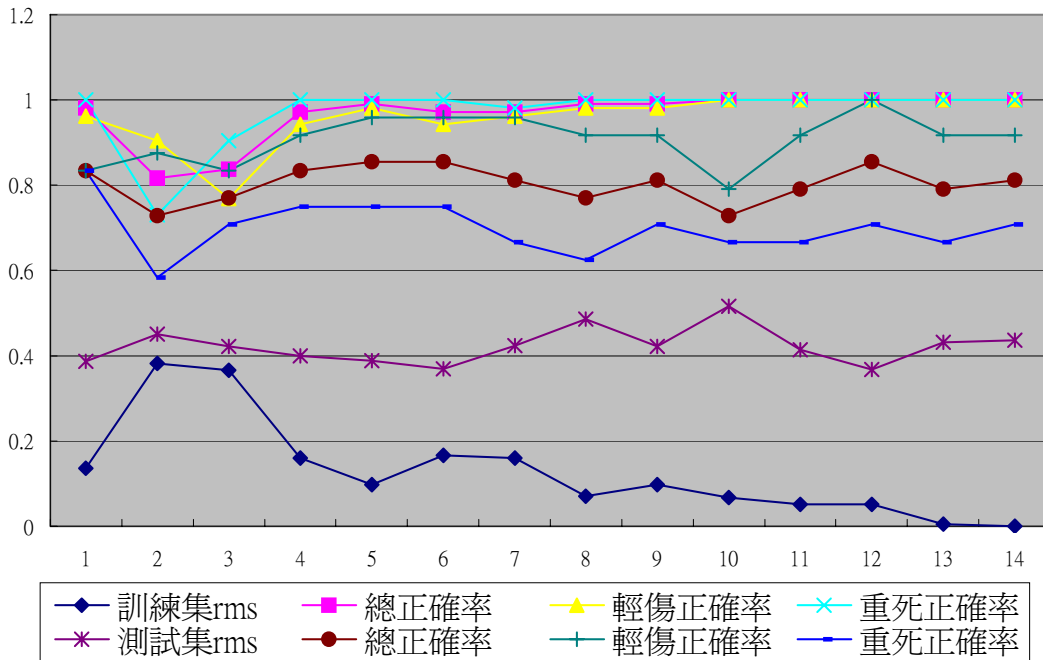


圖 5-3 路口肇事嚴重度類神經網路模式績效圖(範例三)

5.2.2 實證結果

有關路口肇事嚴重度類神經網路模式構建績效結果，以訓練範例二而言(如表 5-3)，其中隱藏神經元數 9 個，第一次訓練過程，學習次數 70 批次，所得到網路模式有一致的且效果良好的績效值，其績效亦高於其他模式，該模式已將訓練範例完全學習，訓練範例的總正確率高達 100%，測試範例的總正確率達 90%，其中輕傷範例正確率 95.13%，重傷、死亡範例正確率為 41.66%有偏低的情形。若以本研究以所蒐集到的肇事資料扣除訓練範例二部分進行測試，得到總正確率 93.3%，輕傷正確率 93.5%，重傷或死亡正確率 41.6%，可知該模式具有推廣性，可適用大多數的範例。

其次以訓練範例三而言(如表 5-4)，其中以隱藏神經元數 5 個，第三次訓練過程，學習次數 110 批次，所得到網路模式有一致的且效果良好的績效值，其績效亦優於其他模式，該模式幾乎將訓練範例完全學習，訓練範例的總正確率高達 99%，測試範例的總正確率為 85.4%，輕傷正確率為 95.8%，重傷或死亡正確率 75%。若以本研究以所蒐集到的肇事資料扣除訓練範例三部分進行測試，得到總正確率 74.95%，輕傷正確率 74.95%，重傷或死亡正確率 75%，可知該模式雖非甚佳，但仍可接受。另外值得一提的是，訓練範例三，其範例個數僅 104 筆，經過訓練所得模式，透過所蒐集的 8591 筆資料驗證，確信其預測正確率高達 75% 強，這更證明了類神經網路方法運用在肇事嚴重程度預測的問題有相當優異的效果。

5.3 路段肇事嚴重度類神經網路模式

有關路段肇事嚴重度類神經網路模式構建過程及結果說明如下，主分為兩部

分，首先就模式構建過程的資料篩選、參數設定、隱藏層神經元個數等予以說明，其次則就實證結果加以說明解釋。

5.3.1 模式構建過程

模式構建過程主要針對資料篩選(包括訓練範例與測試範例的選取)，參數設定及隱藏層神經元個數設定說明如下：

1. 資料篩選

九十二年道路肇事資料共二八、一八四筆，因一般財損車禍案件，未查填道路型態、車道劃分設施、事故位置、號誌種類、號誌動作等等與肇事嚴重程度有關的資料，所以在選用肇事資料時即予以刪除，避免所得的預測模式績效不佳，經過初步篩選，共剩餘一五、四六三筆，其中有五、五五三筆屬路口肇事案件，再剔除資料內錯漏、空缺等無法補正之肇事案件，所餘輕傷、重傷及死亡案件共八、六九五筆，其中重傷或死亡肇事案件共七十六筆，輕傷肇事案件為五、四〇三筆，惟 Matlab6.5 單一變數無法容納如此龐大的資料量，致使訓練過程無法一次完成，導致訓練時間過長，訓練效率不佳，為解決此一問題，本研究決定適當減少訓練及測試資料。最後經隨機亂數的方式，選取三組範例：

- 範例一：重傷、死亡案件四十九筆、輕傷案件一、五一一筆，共一、六〇〇筆資料作為訓練範例；重傷、死亡案件二十筆、輕傷案件七八〇筆，共八〇〇筆資料作為測試範例。
- 範例二：重傷、死亡案件四十九筆、輕傷案件四五二筆，共五百筆資料作為訓練範例；重傷、死亡案件二十筆、輕傷案件二三〇筆，共二五〇筆資料作為測試範例。
- 範例三：重傷、死亡案件四十九筆、輕傷案件四十九筆，共九十八筆資料作為訓練範例；重傷、死亡案件二十筆、輕傷案件二十筆，共四十筆資料作為測試範例。

2. 參數參定

有關網路訓練的各項參數之意義及系統設定業於本章第一節詳細說明，各項參數設定如下：

- 學習速率(Learning Rate)：系統內定值 0.1
- 轉換函數(Transfer Function)：sigmoid 函數
- 學習週期：500epoch 即停止
- 誤差判斷：MSE<0.001 即停止
- 學習法則：Delta Rule

3. 隱藏層神經元個數

· 範例一

為求能找到一個適當的網路模式，本研究以神經元 1~40 個，隱藏層層數一層的神經網路，以範例一進行訓練及測試，所得路段肇事嚴重度類神經網路模式績效如圖 5-4，其中神經元個數多者收斂效果多比神經元個數少者佳，亦有相反的情形，可能原因是，因為其初始權重的不同，導致網路結構落入局部

最小值的情形，使得收斂效果不佳，另外由績效表顯示，隱藏層神經元個數超過 7 個時所得的類神經網路模式測試績效值差異並非很大，且測試範例之正確率高達 95% 以上，其中測試範例輕傷部分的預測正確率多可達到 90% 以上，惟測試範例重傷或死亡部分的預測正確率最高僅 50%，不甚理想，該結果與路口肇事嚴重程度預測模式相同，可能是因為訓練範例輕傷部分遠高於重傷部分，使得模式預測結果偏向輕傷，因此有增加重傷、死亡訓練範例或是減少輕傷案件訓練範例的必要，但宥於蒐集到的重傷、死亡交通事故案件數不多，且其中一部分仍要留做測試範例之用，故範例二則是採用減少輕傷案件訓練範例的方式，期能提高重傷、死亡案件的預測正確率。

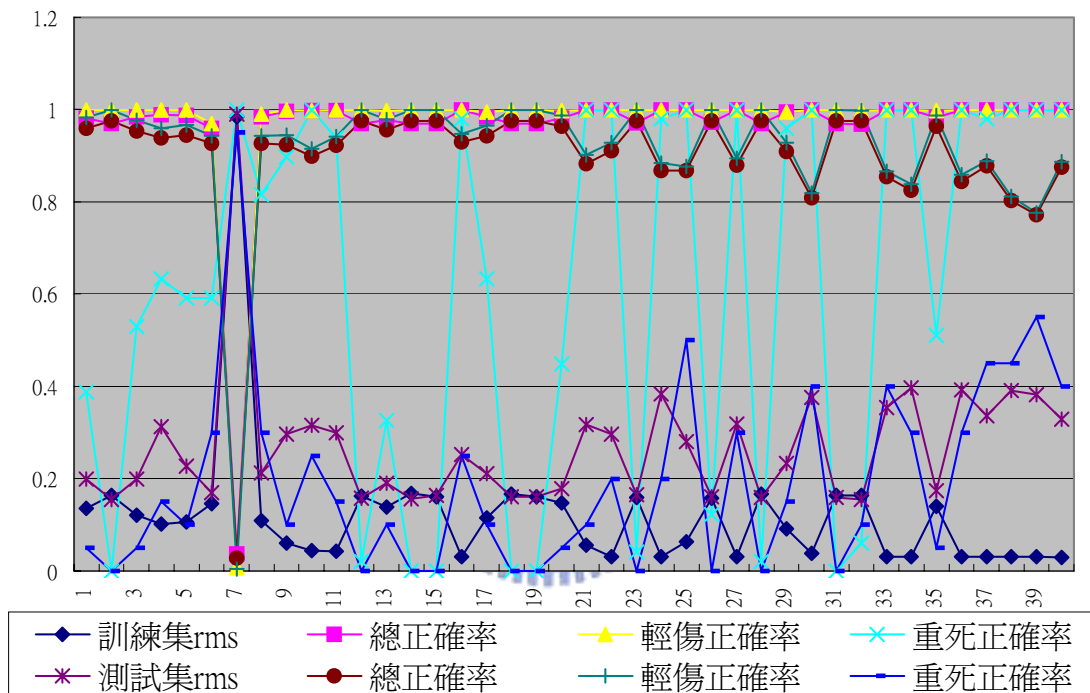


圖 5-4 路段肇事嚴重度類神經網路模式績效圖(範例一)

· 範例二

為簡化類神經網路的複雜程度、並提高預測績效，同時避免因輕傷、重傷死亡範例之比例相差過度懸殊，改以訓練範例二進行訓練，採用網路增長法，逐一增加神經元個數的方式進行模式構建，每增加一個神經元，即重覆五次同樣的訓練過程，避免單一次的訓練過程，因初始權重不良導致收斂效果不佳或是落入局部最小值的情形發生，此外為避免過度學習的情況，訓練過程中每訓練 10 個批次就將網路模式記錄，最後從中選取一個收斂、預測效果最好的模式，以確保所選取的係最佳的網路結構，表 5-5 即為各網路結構訓練過程中最佳模式之績效表，以隱藏層神經元個數 11 個所得到的測試績效值最佳，總正確率為 88%，輕傷正確率為 91.7%，重傷或死亡正確率 45%，另外如果以所蒐集到的肇事資料扣除訓練範例部分所得的 4903 筆資料進行測試，得到總正確

率 89.5%，輕傷正確率 89.7%，重傷或死亡正確率 45%，雖然預測績效良好，但是重傷或死亡正確率仍然不高。

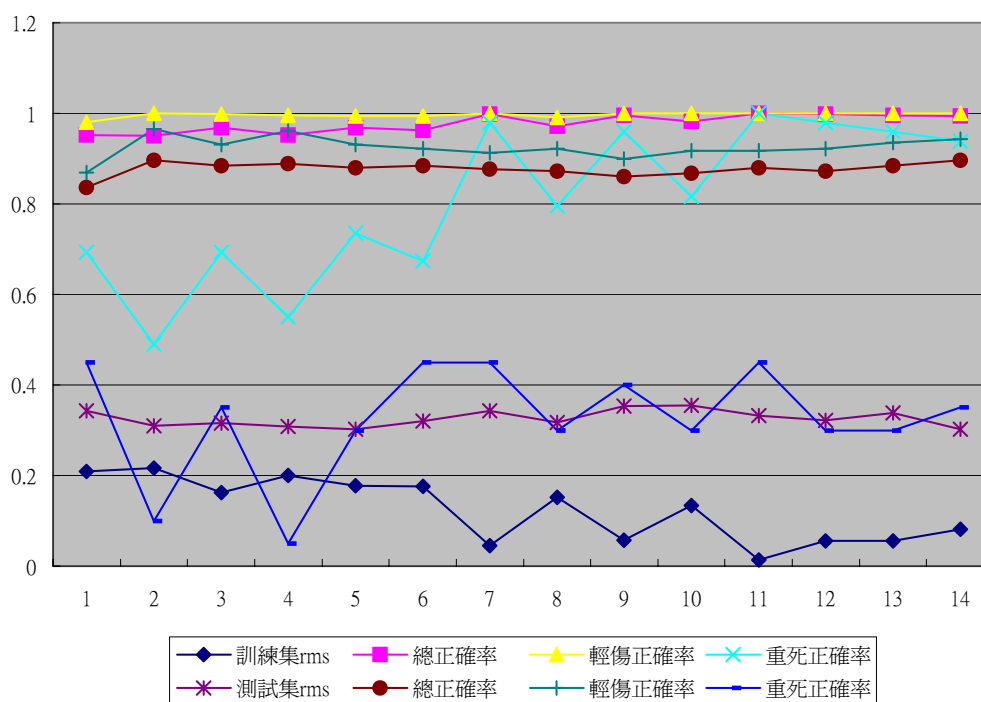


圖 5-5 路段肇事嚴重度類神經網路模式績效圖(範例二)

表 5-5 路段肇事嚴重度類神經網路模式績效(範例二)

神經元數	訓練集rms	總正確率	輕傷正確率	重傷死正確率	測試集rms	總正確率	輕傷正確率	重傷死正確率
1	0.20829	0.952	0.98004	0.69388	0.34251	0.836	0.86957	0.45
2	0.21588	0.95	1	0.4898	0.30939	0.896	0.96522	0.1
3	0.16192	0.968	0.99778	0.69388	0.31577	0.884	0.93043	0.35
4	0.20012	0.952	0.99557	0.55102	0.30832	0.888	0.96087	0.05
5	0.17712	0.968	0.99335	0.73469	0.30257	0.88	0.93043	0.3
6	0.1764	0.962	0.99335	0.67347	0.31956	0.884	0.92174	0.45
7	0.044847	0.998	1	0.97959	0.34274	0.876	0.91304	0.45
8	0.15219	0.972	0.99113	0.79592	0.31784	0.872	0.92174	0.3
9	0.057341	0.996	1	0.95918	0.35317	0.86	0.9	0.4
10	0.13416	0.982	1	0.81633	0.35512	0.868	0.91739	0.3
11	0.013462	1	1	1	0.33187	0.88	0.91739	0.45
12	0.055491	0.998	1	0.97959	0.32119	0.872	0.92174	0.3
13	0.055614	0.996	1	0.95918	0.3379	0.884	0.93478	0.3
14	0.081854	0.994	1	0.93878	0.30174	0.896	0.94348	0.35

· 範例三

雖然範例二已經將輕傷案件的訓練範例減少，但提高重傷死亡案件的預測正確率幫助不大，因此，為進一步提高重傷、死亡案件預測的正確率，範例三則將輕傷訓練範例與重傷、死亡訓練範例的比例調整成 1:1，以進行網路的訓練，隱藏層個數採用網路增長法，逐一增加神經元個數的方式進行模式構建，每增加一個神經元，即重覆五次同樣的訓練過程，避免單一次的訓練過程因初始權重不良，導致收斂效果不佳或是落入局部最小值的情形，此外為避免過度學習的情況，訓練過程中每訓練 10 個批次就將網路模式記錄，最後從中選取一個收斂、預測效果最好的模式，以確保所選取的係最佳的網路結構，表 5-6 即為各網路結構訓練過程中最佳模式之績效表，以隱藏層神經元個數 5、6、7、11、13 個，所得到的測試績效值較佳，以隱藏層神經元個數 6 個而言，總正確率為 75%，輕傷正確率為 80%，重傷或死亡正確率 70%，績效表現並不突出，另外如果以所蒐集到的肇事資料扣除訓練範例部分所得的 5305 筆資料進行測試，得到總正確率 67.16%，輕傷正確率 67.15%，重傷或死亡正確率 70%，由此結果可知，減少輕傷訓練範例以提高訓練範例重傷、死亡案件的比例，雖可有效提高重傷、死亡案件的預測正確率，可是卻會導致輕傷的案件的預測正確率降低。

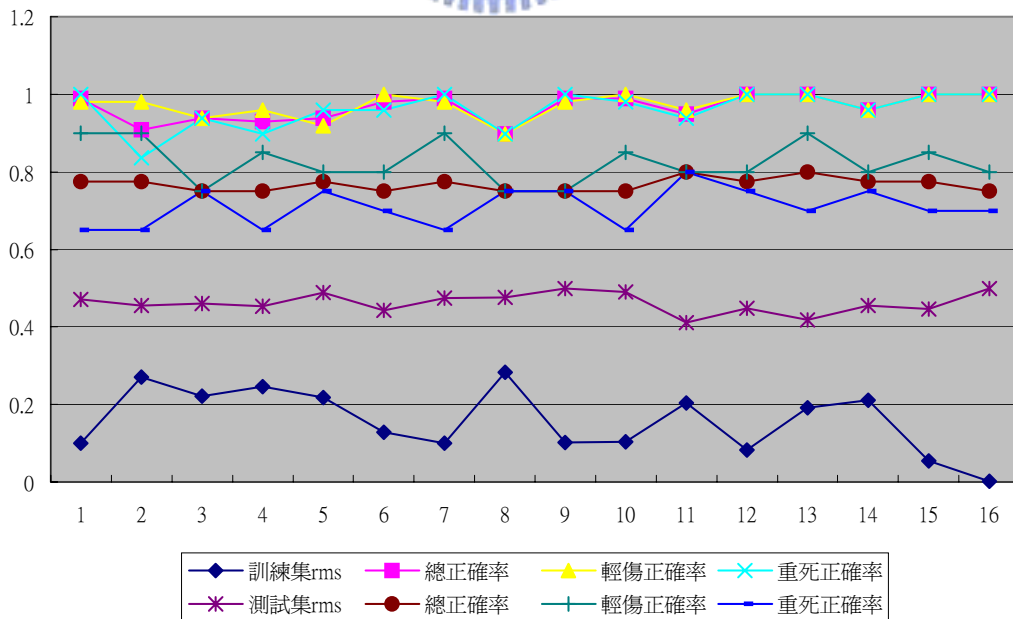


圖 5-6 路段肇事嚴重度類神經網路模式績效圖(範例二)

表 5-5 路段肇事嚴重度類神經網路模式績效(範例三)

神經元數	訓練集 rms	總正確率	輕傷正確率	重傷死正確率	測試集 rms	總正確率	輕傷正確率	重傷死正確率
1	0.10029	0.9898	0.97959	1	0.47137	0.775	0.9	0.65
2	0.27	0.90816	0.97959	0.83673	0.4553	0.775	0.9	0.65
3	0.22216	0.93878	0.93878	0.93878	0.46034	0.75	0.75	0.75
4	0.24538	0.92857	0.95918	0.89796	0.4536	0.75	0.85	0.65
5	0.21825	0.93878	0.91837	0.95918	0.48862	0.775	0.8	0.75
6	0.12912	0.97959	1	0.95918	0.44241	0.75	0.8	0.7
7	0.10102	0.9898	0.97959	1	0.47493	0.775	0.9	0.65
8	0.28258	0.89796	0.89796	0.89796	0.47577	0.75	0.75	0.75
9	0.10107	0.9898	0.97959	1	0.4995	0.75	0.75	0.75
10	0.10372	0.9898	1	0.97959	0.48986	0.75	0.85	0.65
11	0.20436	0.94898	0.95918	0.93878	0.41109	0.8	0.8	0.8
12	0.082788	1	1	1	0.44742	0.775	0.8	0.75
13	0.19097	1	1	1	0.41742	0.8	0.9	0.7
14	0.2109	0.95918	0.95918	0.95918	0.45577	0.775	0.8	0.75
15	0.054057	1	1	1	0.44597	0.775	0.85	0.7
16	0.001392	1	1	1	0.49963	0.75	0.8	0.7

5.3.2 實證結果

有關路段肇事嚴重度類神經網路模式構建績效結果，以訓練範例二而言(如表 5-6)，其中隱藏神經元數 11 個，第三次訓練過程，學習次數 100 批次，所得到網路模式有一致的且效果良好的績效值，其績效亦高於其他模式，該模式已將訓練範例完全學習，訓練範例的總正確率高達 100%，測試範例的總正確率達 88%，其中輕傷範例正確率 91.74%，重傷、死亡範例正確率為 45%有偏低的情形。若以本研究以所蒐集到的肇事資料扣除訓練範例二部分進行測試，得到總正確率 89.5%，輕傷正確率 89.67%，重傷或死亡正確率 45%，可知該模式具有推廣性，可適用大多數的範例。

其次以訓練範例三而言(如表 5-5)，其中隱藏神經元數 5、6、7、11、13 個，經學習訓練所得到網路模式優於其他模式，惟所得模式之正確率僅達 70%左右死亡正確率 75%，最主要的原因仍是訓練範例過少所導致，另透過所蒐集的 5305 筆資料驗證，確信其預測正確率達 67.16%，可知類神經網路方法運用在輸入變數間複雜程度高的預測問題，只需少量分的資料即可達到有相當一定程度的預測

水準，充分的顯示出類神經網路方法的優點。

5.4 模式應用

通常，我們在進行肇事防制時，對於肇事嚴重的案件，必定詳細分析其肇事原因，並透過各種可能方式進行防制，然而，這些防制的作為必須以已發生的死亡或重傷肇事案件記錄進行分析，這或可找出有效的防制方法，代價可說是相當龐大，但是透過本研究所構建的模式進行肇事模擬，則可避免這種情形。

5.4.1 模式應用方式說明

我們可以想像，經訓練完成且正確率高的類神經網路肇事嚴重程度預測模式是一個虛擬肇事的系統，我們可將未曾在此某些地點發生過的肇事情形，透過網路模擬的方式預測其肇事嚴重程度，並對於可能產生嚴重肇事的情形設法事先防制，以避免這類情形於現實生活中發生，如此可大大減少社會成本。

因為本研究所構建的模式所可能產生的組合共有 2.551×10^{36} 種，如此大的運算量非一般的個人電腦所能負荷，因此，本研究打算以臺北市易肇事路段，中正路，由隨機方式產生肇事組合的方式套用於績效最佳的類神經網路模式，來進行肇事模擬，可分成以下四個步驟：

一、設定固定輸入項(交通工程狀態)

道路固定不變的道路交通工程設施可直接於輸入層參數中設定，以臺北市中正路為例，分別為 1.速限：50 公里 2.道路狀態：直路 3.路面鋪裝：柏油 4.路面狀態：濕潤或乾燥 5.路面缺陷：無缺陷 6.障礙物：無障礙物 7.視距：良好 8.車道劃分-方向：寬式(50 公分以上) 9.車道劃分-快車道：車道線(無標記) 10.車道劃分-快慢車道：未繪設快慢車道分隔線 11.車道劃分-路面邊緣：有 12.號誌種類：行車管制號誌(附設行人專用號誌) 13.號誌動作：正常，等十三個輸入項。

二、隨機選取變動輸入項暨模擬

變動輸入項有肇事時間、天候、光線及第一、第二當事人資料，經隨機選取組成多種肇事情況，將之輸入所構建的類神經網路，模擬其肇事嚴重程度，並記錄產生嚴重肇事的情形組合。

三、刪除不合理的肇事情形

對於肇事情形的組合予以刪除，如當事人是無或物者、肇事原因輸出結果為 0(無須填寫)。

四、分析及研擬對策

經過刪除後所餘之肇事情形組合，我們可對其肇事原因加以分析，對於易造成嚴重交通違規的行為，可建議警察機關加強該違規的執法強度，或作為選擇性執法的參考。

5.4.2 實例分析及對策研擬

本研究以中正路作為模式應用的標的，經 10000 次的隨機肇事組合，透過訓練範例二之路段肇事料資料所構建的路段肇事嚴重程度預測模式(隱藏層神經元 11 個)進行肇事嚴重程度預測，將可能會發生嚴重傷亡的肇事情形組合記錄 1265 筆後，再將不合理的肇事情形刪除後，僅餘 101 筆肇事情形組合，分析如下：

一、肇事因素

經統計上述模擬交通事故案件，其肇事原因中有相當多的次數係屬「非車輛駕駛人」的肇事因素，包括有機件因素如煞車失靈、方向操縱系統故障、燈光系統故障等，交通管制設施因素如交通管制設施失靈或損毀、路況危險無安全設施、其他交通管制不當等，由於絕大部分的造成交通事故發生的肇事原因多是人為因素，實際發生這此情形的機會相當少，所以這一個部分實用參考價值不高，而且肇事原因中有關交通管制設施的語意相當模糊，亦難作為工程單位參考之用。

表 5-6 是「行人或乘客」的肇事因素次數統計表乘客受傷的因素以上下車輛未注意安全、頭手伸出車外而肇事的次數較多，另外行人的部分則為未依規定行走行人設施穿越道路、在道路嬉戲或奔走不定的次數較多。

表 5-6 行人或乘客的肇事因素次數統計表

肇 事 原 因	次 數	
非駕駛人因素 行人或乘客	54 上下車輛未注意安全	4
非駕駛人因素 行人或乘客	55 頭手伸出車外而肇事	4
非駕駛人因素 行人或乘客	58 其他引起交通事故之疏失	4
非駕駛人因素 行人或乘客	49 未依規定行走行人設施穿越道路	3
非駕駛人因素 行人或乘客	52 在道路嬉戲或奔走不定	3
非駕駛人因素 行人或乘客	56 乘坐不當而跌落	2
非駕駛人因素 行人或乘客	53 未待車輛停妥而上下車	1
非駕駛人因素 行人或乘客	57 在路上工作未設適當標識	1

表 5-7 是車輛駕駛人肇事因素次數統計表，其中車輛駕駛人肇事因素以「吸食違禁物後駕駛失控」、「酒醉(後)駕駛失控」、「違反號誌管制或指揮」、「未依規定讓車」、「倒車未依規定」的次數較多(達五次以上)，除「倒車未依規定」較難理解外，其他均是一般可能會導致嚴重傷亡的肇事因素，可見模式所模擬的結果與一般常理相差不遠。

由於「吸食違禁物後駕駛失控」的輸入值為 20、「疲勞(患病)駕駛失控」輸入值 22 均與「酒醉(後)駕駛失控」的輸入值 21 相當接近，實際上這此違規行為會導致駕駛人注意力無法集中，行為失序，可能在短時間內喪失駕駛能力，應可歸為同一類違規行為，鑑於訓練範例中並無「吸食違禁物後駕駛失控」與「疲勞(患病)駕駛失控」案件，或可將之歸為「酒醉(後)駕駛失控」。

輸入值 25「違反號誌管制或指揮」、輸入值 26「違反特定標誌(線)禁制」兩者違規型態相似，且合計次數達 10，至於輸入值 24「搶越平交道」次數達 4 次，查臺北市中正路並無鐵路平交道，不可能發生這項違規，而其輸入 24 與「違反號誌管制或指揮」及「未注意車前狀態」相近，又「未注意車前狀態」次數 2 次

相當低，故將「搶越平交道」納入「違反號誌管制或指揮」計次，則「違反號誌管制或指揮」與「違反特定標誌(線)禁制」次數高達 14 次。

至於「未依規定讓車」部分，因其輸入值為 6，同時輸入值 7「變換車道或方向不當」亦有三件，經比對「未依規定讓車」實際肇事人數 2 人，受傷 869 人，而「變換車道或方向不當」實際肇事案件無人死亡，144 人受傷，吾人或將「變換車道或方向不當」歸為「未依規定讓車」一類，由於未依規定讓車屬動態違規，一瞬即過，且認定事實不明確，在執法上有實務上的困難。

表 5-7 車輛駕駛人肇事因素次數統計表

肇 事 原 因		次 數
車輛駕駛人因素 駕駛人	20 吸食違禁物後駕駛失控	7
車輛駕駛人因素 駕駛人	21 酒醉(後)駕駛失控	7
車輛駕駛人因素 駕駛人	25 違反號誌管制或指揮	6
車輛駕駛人因素 駕駛人	6 未依規定讓車	5
車輛駕駛人因素 駕駛人	12 倒車未依規定	5
車輛駕駛人因素 駕駛人	3 蛇行、方向不定	4
車輛駕駛人因素 駕駛人	9 右轉彎未依規定	4
車輛駕駛人因素 駕駛人	15 搶越行人穿越道	4
車輛駕駛人因素 駕駛人	16 未保持行車安全距離	4
車輛駕駛人因素 駕駛人	22 疲勞(患病)駕駛失控	4
車輛駕駛人因素 駕駛人	24 搶越平交道	4
車輛駕駛人因素 駕駛人	26 違反特定標誌(線)禁制	4
車輛駕駛人因素 駕駛人	1 違規超車	3
車輛駕駛人因素 駕駛人	4 逆向行駛	3
車輛駕駛人因素 駕駛人	7 變換車道或方向不當	3
車輛駕駛人因素 駕駛人	14 未依規定減速	3
車輛駕駛人因素 駕駛人	17 未保持行車安全間隔	3
車輛駕駛人因素 駕駛人	19 起步未注意他車(人)安全	3
車輛駕駛人因素 駕駛人	2 爭(搶)道行駛	2
車輛駕駛人因素 駕駛人	5 未靠右行駛	2
車輛駕駛人因素 駕駛人	10 迴轉未依規定	2
車輛駕駛人因素 駕駛人	11 橫越車道未依規定	2
車輛駕駛人因素 駕駛人	18 停車操作時，未注意其他車(人)安全	2
車輛駕駛人因素 駕駛人	23 未注意車前狀態	2
車輛駕駛人因素 駕駛人	8 左轉彎未依規定	1

二、年齡

表 5-6 是第一、第二當事人年齡次數統計表，由表中可發現第一當事人(通常是受傷較輕者)多數較年輕，這與一般認知年輕人的駕駛行為較為衝重，駕駛風險較高的認知相符。其次第二當事人(通常是受傷較為嚴重者)的部分，61 歲以上佔了 23.76%，由表 5-6 可看出，第二當事人 60 歲以上的次數呈現增加的情形，這也代表 60 歲以上的用路人發生肇事死亡的風險相對較高。所以我們可以針對年輕的用路人採取加強取締的方式防制肇事，而年紀較大的用路人，則採取加強宣導的方式，告知其用路的風險，進而規避風險。

表 5-8 當事人年齡次數統計表

年齡	第一當事人		第二當事人	
	次數	百分比	次數	百分比
1-30	64	63.37%	36	35.64%
31-40	13	12.87%	15	14.85%
41-50	10	9.90%	13	12.87%
51-60	6	5.94%	13	12.87%
61 以上	8	7.92%	24	23.76%
總計	101	100.00%	101	100.00%

三、車種

表 5-6 是第一、第二當事人車種統計表，由表可看出，大型車輛如大客車、大貨車、聯結車、特種車之次數較多，這些車種因其體積大、操作不易，易導致肇事的其他當事人死亡，另外值得一提的是，機車、慢車的次數亦相當高，這是因為機車與慢車平衡性不佳，且駕駛人係曝露於車體之外，所以肇事發生後容易導致嚴重的傷亡情形。因此大型車輛、機車、慢車這些車種，應該是警察機關加強執法取締，維護其行車安全的對象。

表 5-9 當事人車種統計表

車種	第一當事人		第二當事人	
	次數	百分比	次數	百分比
大客車	12	11.88%	9	8.91%
小客車	2	1.98%	13	12.87%
大貨車	10	9.90%	15	14.85%
全聯結車	8	7.92%	16	15.84%
半聯結車	12	11.88%	4	3.96%
曳引車	6	5.94%	9	8.91%
小貨車	4	3.96%	5	4.95%
特種車	13	12.87%	8	7.92%

表 5-9 當事人車種統計表

車種	第一當事人		第二當事人	
	次數	百分比	次數	百分比
軍車	6	5.94%	5	4.95%
機車	10	9.90%	8	7.92%
慢車	11	10.89%	4	3.96%
其他車	4	3.96%	3	2.97%
人	3	2.97%	2	1.98%
總計	101	100.00%	101	100.00%

綜上所述，經過模擬的結果我們可歸納幾個執法策略，首先警察機關應加強取締酒醉駕車、不依號誌、標誌、標線駕駛之違規行為，另外行人的部分應加強取締行人不依規定穿越車道，特別是年長者的行人行違規行為，其次大型車種及機、慢車等亦是道路上高風險的車種，應透過各種方式維護其行車安全。

5.5 結果分析與討論

有關路口肇事嚴重度類神經網路模式，以訓練範例二，隱藏神經元數 9 個所構建的模式為最佳模式，路段肇事嚴重度類神經網路模式，以訓練範例二，隱藏神經元數 11 個所構建的模式為最佳模式，這兩個模式均將訓練範例完全學習，訓練範例的總正確率高達 100%，測試範例的總正確率達 90%、88%，其中輕傷範例正確率均超過 90%，重傷、死亡範例正確率約為 40%~45%有偏低的情形，雖然測試範例的正確率均高達約 9 成，但是對於本研究所著重的重傷死亡部分的正確率並不高，這可能是由於訓練範例(約 50 筆)不足所導致，如可增加重傷或死亡範例的訓練樣本，或可提高其正確率。

一般來說，路口的肇事情形比路段複雜，但是路口績效最佳的模式，其隱藏層神經元 9 個，少於路段的 11 個，這或許是因為路口肇事案件較為複雜，雜訊也較多，而較簡單的模式結構卻能消除較多雜訊，使得預測績效提高。

有關模式應用部分，由於模式的組合高達 2.551×10^{36} ，如果要分析各種可能的組合，非一般 PC 可為，但是一個預測正確率高的類神經網路模式，可視為一個肇事模擬器，我們可利用隨機的方式產生小規模肇事組合，並將可能發生嚴重肇事的結果進行分析，採取預防措施，以臺北市易肇事路段第一名中正路為例，隨機模擬 10000 種不同的肇事組合，模擬出 101 組合理的嚴重肇事組合，經分析其肇事原因，與實際情形頗能相符，並能有效運用於道路交通執法。

第六章 結論與建議

本章內容主要就本研究所得結論進行總結說明，並就研究過程及結果發現有不足及可作為後續研究發展部分進行譯述。

6.1 結論

有關路口肇事嚴重度類神經網路模式，以隱藏神經元數 9 個為最佳模式，路段肇事嚴重度類神經網路模式，以隱藏神經元數 11 個為最佳模式，這兩個模式均將訓練範例完全學習，訓練範例的總正確率高達 100%，測試範例的總正確率達 90%、88%，其中輕傷範例正確率均超過 90%，重傷、死亡範例正確率約為 40%~45%，可知，類神經網路是一個相當不錯的模式構建方法。

由於路口的肇事情形較路段肇事複雜，雜訊亦高於路段肇事，而較簡單的類神經網路結構可消除較多雜訊，進一步提高預測績效。而本研究所構建的路口肇事嚴重程度預測績效最佳的模式，其隱藏層神經元 9 個，少於路段肇事嚴重程度預測績效最佳的模式，11 個隱藏層神經元，顯與上述情形相符。

有關模式應用部分，由於模式的組合高達 2.551×10^{36} ，如果要分析各種可能的組合，非一般 PC 可為，但是一個預測正確高的類神經網路模式，我們可利用隨機的方式產生小規模肇事組合，透過所構建的類神經網路模式模擬出傷亡程度嚴重的肇事組合，並分析其肇事原因，與實際肇事統計結果相互比對，確可有效運用於道路交通執法，可用以選擇加強取締交通違規項目的參考，避免警力濫用。

6.2 後續研究建議

無論路口肇事嚴重度類神經網路模式，或是路段肇事嚴重度類神經網路模式，雖然測試範例的正確率均高達約 9 成，但是對於重傷、死亡範例正確率約為 40%~45%，正確率不高，有偏低的情形，可推測是因為重傷、死亡肇事案件訓練範例(約 50 筆)不足所導致，如可增加重傷或死亡範例的訓練樣本，或可提高其正確率，由於本研究所構建的模式係從個體觀點著手，與一般常用以總體觀點進行肇事率或相對危險程度的研究不同，如果使用長期間的資料，使樣本個數充足，並不會因此導致個體間之差異盡被隱藏，影響行車安全因子難以深入探討的疑慮，因此建議後續如有類似研究，可蒐集較長時期的肇事資料作為模式構建之用，以有效提高嚴重傷、亡肇事的預測正確率。

本研究所輸入的道路環境資料，僅有第一當事人行駛道路部分，而未有第二當事人，此係因警察機關填製事故調查報告表時，未將第二當事人行駛之道路環境進行查填，以路段肇事而言，第一當事人與第二當事人所行駛之道路環境大都相同，但是路口肇事則否，故路段肇事嚴重度類神經網路模式較之路口模式有較充分的輸入項目，建議日後警察機關所設計之事故調查報告表，增加此一項目，將可使肇事資料更趨完整，進行研究時亦可獲得較佳的結果。

道路交通事故調查報告表的道路交通工程特徵過於簡化，連最基本的車道數、車道寬度、號誌時制資料均付之闕如，必須透過檢視處理交通事故的警察人員所繪製的道路交通事故現場圖才可得知，使得道路交通工程特徵資料難以取

得，不利於相關研究進行，如可將道路交通工程特徵更詳細列入道路交通事故調查報告表中，將有助於研究的進行，另外建議後續有意研究者，可詳細檢視道路交通事故現場圖，擷取肇事地點的交通工程特徵作為輸入層的選項，應有助於預測正確率的提高。

因肇事時的交通流量在取得有實際的困難，本研究雖以都市地區交通流量常有重現的特性，以肇事發生的時間取代，難謂與實際情形相符，建議後續研究者可蒐集各個研究道路的交通量調查結果，再以肇事時間的交通量調查結果來作為肇事時的交通流量代表，或可產生較佳的預測結果。

在模式構建過程發現，網路結構的學習效率，可能因初始權重隨機設定的不同而有相當大的差別，初始權重的好壞其差別猶如天才與白痴的分別，一個好的初始權重可使訓練過程收斂迅速，測試訓練績效良好，因此建議使用類神經網路方法進行研究時，可先以同模式結構進行數次不同的較短學習過程的訓練，再挑選效果較佳模式作進一步的訓練，將可避免過多無謂的電腦運算。

有關模式應用部分，我們除可利用隨機的方式產生小規模肇事組合來分析其肇事原因，進行肇事防制，另外，由於科技的進步，未來所有車輛亦可能裝設車上電腦，我們或可將此預測模式安裝於車上電腦系統中，透過外在環境的偵測，在預測可能發生嚴重肇事的情形下，事先向駕駛人提出警告，使駕駛人能適時的提高注意力，進而避免肇事發生。



參考文獻

中文部分：

- 林郁志，1997，都市地區肇事嚴重程度之分析研究-以臺南市為例，國立成功大學交通管理科學研究所碩士
- 吳銘山，1998，易肇事路段與路口改善績效評估與指標之建立—以台南市為例，國立交通大學交通運輸研究所碩士論文。
- 吳志文，2002，以類神經網路探討船舶事故之研究，國立交通大學交通運輸研究所碩士論文。
- 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科學研究所碩士論文。
- 周鵬程，2001，遺傳演算法原理與應用-活用 MATLAB，全華科技圖書股份有限公司。
- 戚培芳，1997，中山高速公路肇事分析模式之研究，國立交通大學交通運輸研究所碩士論文。
- 陳高村，1997，道路交通事故處理與鑑定，著者自印。
- 陳志和，1999，都市地區肇事嚴重程度預測模式之研究，國立成功大學交通管理科學研究所碩士論文。
- 陳國彰，2003，比較多變量分析與類神經網路績效評估模型，國立交通大學科技管理學程碩士班碩士論文。
- 莊秋明，1998，道路交通易肇事路段改善方法與其案例研討，八十七年道路交通安全與執法研討會，P125-138。
- 張智星，2000，MATLAB 程式設計與應用，清蔚科技股份有限公司。
- 張斐章、張麗秋、黃浩倫，2003，類神經網路理論與實務，東華書局。
- 葉怡成，1997，應用類神經網路，儒林圖書。
- 葉怡成，1998，類神經網路模式應用與實作，儒林圖書公司。
- 林豐裕、曾平毅，1999，路口安全程度評估模式之評析，八十八年道路交通安全與執法研討會，p205-215。
- 曾國雄，1991，多變量解析及其應用，華泰書局。
- 楊雅媛，2002，迴歸分析與類神經網路預測能力之比較，國立政治大學統計研究所士論文。
- 趙崇仁，1996，應用類神經網路鑑別高速公路危險路段之研究，中央警察大學警政研究所碩士論文。
- 謝浩明，1980，台北市號誌路口路段交通肇事多變量解析及其改善對策，國立交通大學交通運輸工程研究所碩士論文。
- 羅華強，2001，類神經網路-MATLAB 的應用，清蔚科技股份有限公司。
- 魏開元，1999，由肇事碰撞構圖及類神經網路推導肇事工程因素研究，國立成功大學交通管理科學研究所碩士論文。
- 蘇木春、張孝德，1997，機器學習類神經網路、模糊系統以及基因演算法則，全華科技圖書股份有限公司。

英文部分：

- Al-Ghamdi, Ali S., 2002, Using logistic regression to estimate the influence of accident factors on accident severity, *Accident Analysis and Prevention*, Vol. 34, No. 6, pp. 729-741.
- Al-Ghamdi, Ali S., 2003, Analysis of traffic accidents at urban intersections in Riyadh, *Accident Analysis and Prevention*, Vol. 35, No. 5, pp. 717-724.
- Evans, Andrew W., 2003, Estimating transport fatality risk from past accident data, *Accident Analysis and Prevention*, Vol. 35, No. 4, pp. 459-472.
- Greibe, P., 2003, Accident prediction models for urban roads, *Accident Analysis and Prevention*, Vol. 35, No. 2, pp. 273-285.
- Hashemi, Ray R., Le Blanc, Louis A., Rucks, Conway T., Shearry, Angela, 1995, A neural network for transportation safety modeling, *Expert Systems with Applications*, Vol. 9, No. 3, pp. 247-256.
- Miaou, S.P., Hu, P.S., Wright, T., Rathi, A.K., Davis, S.C., 1992, Relationship between Truck Accident and Highway Geometric Design: a poisson regression approach, *Transport Research Record* 1376.
- Miaou, S.P., Lum, H., 1993, Modeling vehicle accidents and highway geometric design relationships, *Accident analysis and prevention*, Vol.25, No.6, pp. 689-709.
- Mussone, L., Rinelli, S., Reitani, G., 1996, Estimating the accident probability of a vehicular flow by means of an artificial neural network, *Environment and Planning B: Planning & Design*, Vol. 23, No. 6, pp. 667-675.
- Mountain, L., Maher, M., Fawaz, B., 1998, The influence of trend on estimates of accidents at junctions, *Accident Analysis and Prevention* Vol. 30, No. 5, pp. 641-649.
- 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.
- Poch, M., Mannering, F., 1996, Negative binomial analysis of intersection-accident frequencies, *Journal of Transportation Engineering*, Vol. 122, No. 2, pp. 105-113.
- Greibe, P., 2003, Accident prediction models for urban roads, *Accident Analysis and Prevention*, Vol. 35, No. 2, pp. 273-285
- Shankar, V., Mannering, F., Barfield, W., 1996, Statistical analysis of accident severity on rural freeways, *Accident Analysis and Prevention* Vol. 28, No. 3, pp. 391-401.
- Sayed, T., W. Abdelwahab, 1998, Comparison of fuzzy and neural classifiers for road accident analysis, *Journal of Computing in Civil Engineering*, Vol. 12, No. 1, pp. 42-47.
- Zurada, J.M., 1992, Introduction to artificial neural system, Info Access Distribution Pte Ltd., Singapore, pp.207-219.

附錄一

道路交通事故調查報告表

