

逢甲大學
交通工程與管理學系碩士班
碩士論文

應用基因模糊邏輯控制建構事件偵測系統

**A Genetic Fuzzy Logic Controller-Based
Freeway Incident Detection System**



指導教授：邱裕鈞

研 究 生：陳怡霖

中 華 民 國 九 十 五 年 六 月

誌 謝

熬了兩個年頭，論文終於順利完成，喜悅與感恩之心溢於言表。首先感謝恩師邱裕鈞教授在論文上之指導與教誨，不僅增進學生專業知識與思考能力，其平易近人的教學方式及對於研究的嚴謹態度，亦深深影響學生，學生將永遠銘記在心。

論文口試期間承蒙馮正民教授以及魏建宏教授細心審閱，不吝指正，並提供寶貴意見，使本論文更臻完善，在此特表謝意。在受業期間也承蒙楊宗璟教授及劉需教授於交通專業知識上之啟發，以及徐耀賜教授於待人處世上之啟蒙，皆使學生受益匪淺，特此表示最深感謝。

論文初期每當遇到疑惑時，幸有雲慶及光鎧學長的幫助與解惑，尤其雲慶學長除須完成自己論文收尾部分，還要撥空讓我請教關於程式及方法論等相關問題，感激不盡。於接近論文口試初期，則非常感謝電機系黃思倫教授之論文口試建議並給予學生莫大的信心與鼓勵。

研究所同學，妍菁、勳哥、A超、梅舜、老賴、鵬升、欣翰、阿維、欣憲、耿禎、馬祖、阿展、姿雁、米奇、芋頤、阿狗、阿彰、韻珏、家勝、小雅、志淮、庭銀及小新等，感謝你們在我論文遇到問題時給予幫助並陪我一起渡過喜怒哀樂兩個年頭。另感謝摯友孟紋、詩涵、佩蓁、玉屏以及曉佩，能讓我隨時傾吐心事並陪我一同成長。

最後，謹將這份碩士學位之榮耀與喜悅，獻給我最愛的家人，爸爸、媽媽、哥哥、妹妹及銘賢，感謝你們一路的支持及鼓勵，使我於求學過程能無後顧之憂，在此表達我最真摯的感謝，我愛你們。

陳怡霖 謹誌於

逢甲大學交通工程與管理學系碩士班

摘 要

高速公路在國內南北城際運輸中扮演相當重要角色，一旦發生行車擁塞或交通事故，即可能造成嚴重之車流延滯，甚至發生追撞事故。因此，建立一套有效之事件自動偵測系統，能精確且快速地提供事件警報資訊給相關管理單位，以便進行及時之處置，實為一重要課題。基因模糊邏輯控制（GFLC）可透過自我學習之方式，尋得最佳之邏輯規則及隸屬函數組合，其精確性在許多應用領域中亦獲得相當驗證。基此，本研究嘗試利用 GFLC 建構一高速公路之事件自動偵測模式。

一般用以發展事件偵測系統，主要是利用車輛偵測器所偵測而得之交通即時資訊，包括流量、速度、佔有率等三種。本研究主要是利用上、下游偵測器或同一偵測器前、後時段所測得之交通資訊差作為區別，共歸納出 9 組變數組合。由於過多狀態變數會使得潛在邏輯規則大幅成長，導致求解精度降低之現象，故一般狀態變數不宜超過三個。因此，本研究利用 GFLC 建構了 4 個事件偵測模式，分別是流量模式、速度模式、佔有率模式及整合模式。其中，流量模式僅考慮上下游偵測器及同一偵測器之流量變數；速度模式則僅考慮其速度變數；佔有率模式則僅考慮其佔有率變數；整合模式則同時考慮不同偵測器下之流量、速度及佔有率等三種變數。此外，本研究進一步建構主成份模式，其利用主成份分析法能將 9 個變數經線性組合轉換成 3 個主成份，能有效解決 GFLC 之狀態變數最多三個之限制。惟建構之五個模式皆為 GFLC 模式，無以驗證其適用性，故本研究同時考慮此 9 種變數以建構類神經網路（ANN）模式並與本模式作進一步之比較分析。

為了驗證本模式之適用性，本研究主要蒐集國道一號中區路段每 20 秒一筆，共 30 個事件之交通資料進行事件偵測。並利用績效評估指標：偵測率（DR）、誤報率（FAR）與平均偵知時間（MTD）來評估模式之優劣。結果顯示，主成份模式優於其它偵

測模式，得到 $DR=100\%$ ， $FAR=0.92\%$ 及 $MTD=17.6$ 秒；ANN 模式得到 $DR=96.67\%$ ， $FAR=1.43\%$ 及 $MTD=16.0$ 秒；整合模式則得到 $DR=93.33\%$ ， $FAR=1.26\%$ 及 $MTD=18.2$ 秒，而其它三個僅利用單一交通資訊(流量、速度、佔有率)所建構成 GFLC 模式之績效，則相對較差。

關鍵字：事件偵測系統、基因模糊邏輯控制、類神經網路



ABSTRACT

Freeway system plays an important role in intercity transportation. Once traffic jams or accidents happen, the traffic would be seriously deterred and even causes other accidents. Thus, it is essential to establish an effectively incident detection system, which can provide correct and prompt alarmed incident signal to enhance the efficiency of accidents responsive actions. Genetic Fuzzy Logic Controller (GFLC) can not only self-learn the optimal combination of fuzzy rules and shapes of membership functions, but also performs very well in many applications. Based on this, the study aims to develop a GFLC-based freeway incident detection system.

The traffic information real-time detected by vehicle detection devices include volume, speed and occupancy, which are commonly used to develop incident detection system. An incident is said to be detected if a significant gap of these traffic information has been identified within different time horizons or at different vehicle detectors (upstream or downstream of the incident spot). Since the potential rules will rapidly get enlarged as the number of state variables increases, generally, the number of state variables would not exceed three. Therefore, this study develops four GFLC-based incident models based on detected traffics. They are volume model, speed model, occupancy model and integrated model, where volume model only considers the volume variables of different time horizons and vehicle detectors, speed model only considers speed variables, occupancy model only considers occupancy variables and integrated model simultaneously considers these three variables of different vehicle detectors. In addition, in order to consider as many as variables with subject to the number constraints, principal component method is used to choose three principal components,

which are the linear combination of nine variables, as state variables of GFLC. This model is named as principle components model. For comparison, an artificial neural network (ANN)-based incident system is also developed, which simultaneously considers all these nine variables.

To investigate the performance and applicability of proposed models, the 20-seconds traffic data of a total of 30 accidents on national No.1. Freeway in Taiwan are collected and used to conduct a case study. Three commonly used index: detection rate (DR), false alarm rate (FAR) and mean time for detection (MTD) are adopted to measure the performances of models. The results show that the principal component model outperforms among all these incident detections models with DR=100%, FAR=0.92% and MTD=17.6 seconds, followed by ANN model with DR=96.67%, FAR=1.43% and MTD=16.0 seconds and integrated model with DR=93.33%, FAR=1.26% and MTD=18.2 seconds. Other three GFLC models based on only one kind of traffic information (volume, speed and occupancy) perform relatively inferior.

Key Words: incident detection system, genetic fuzzy logic controller, artificial neural network

目 錄

目 錄	VI
圖目錄	VIII
表目錄	IX
第一章 緒論	1
1.1 研究背景與動機	1
1.2 研究目的	2
1.3 研究內容與流程	3
第二章 文獻回顧	6
2.1 道路事件偵測之相關文獻	6
2.2 基因模糊邏輯控制之相關文獻	15
2.3 事件偵測演算法分類	18
2.4 績效評估指標	26
第三章 研究方法	28
3.1 模糊邏輯控制	28
3.1.1 模糊邏輯控制之基本特性	29
3.1.2 假設前提與應用限制	31
3.1.3 模糊邏輯控制建構方式	32
3.2 基因演算法	32
3.2.1 基因演算法之基本觀念	33
3.2.2 基因演算法之特性	36
3.2.3 假設前提與應用限制	36
3.2.4 基因演算法之操作方式	37
3.3 基因模糊邏輯控制	38
3.3.1 邏輯規則庫之編解碼	38
3.3.2 隸屬函數之編解碼	39
3.3.3 遺傳演算法則之運作	41
3.3.4 GFLC 反覆演化法	43
3.4 類神經網路	44
3.4.1 神經網路架構	44
3.4.2 倒傳遞網路之基本概念	46

3.4.3 倒傳遞類神經網路	47
第四章 模式建構	51
4.1 變數選擇	51
4.2 事件偵測模式	52
4.3 GFLC 事件偵測模式	56
4.3.1 邏輯規則與隸屬函數之編解碼	56
4.3.2 遺傳演算法則之運作	56
4.3.3 GFLC 反覆演化機制	58
4.3.4 適合度值	58
第五章 實例應用	60
5.1 資料整理與特性分析	60
5.1.1 事件資料整理	60
5.1.2 事件資料特性分析	62
5.2 績效評估	66
5.3 模式參數分析及設定	69
5.4 學習結果分析	70
第六章 GFLC 與 ANN 之比較	75
6.1 ANN 之建構	75
6.2 ANN 模式之訓練及驗證	76
6.3 GFLC 與 ANN 之比較分析	79
第七章 結論與建議	81
7.1 結論	81
7.2 建議	82
參考文獻	84

圖目錄

圖 1.1 研究流程圖	5
圖 3.1 模糊邏輯控制基本架構圖	29
圖 3.2 速度變數之三角形隸屬函數	30
圖 3.3 蒙地卡羅轉盤示意圖	34
圖 3.4 邏輯規則庫編解碼方式示意圖	39
圖 3.5 隸屬函數之編解碼方式示意圖	41
圖 3.6 雙點交配方式示意圖	42
圖 4.1 遺傳演算法之演化流程圖	57
圖 4.2 GFLC 反覆演化示意圖	58
圖 5.1 事件資料輸入範圍圖	62
圖 5.2 上、下游偵測器所測得之交通資訊差距	63
圖 5.3 上、下游偵測器所測得之交通資訊	64
圖 5.4 第一主成份之最佳隸屬函數示意圖	71
圖 5.5 第二主成份之最佳隸屬函數示意圖	71
圖 5.6 第三主成份之最佳隸屬函數示意圖	72
圖 5.7 是否有事件之最佳隸屬函數示意圖	72
圖 5.8 GFLC 模式之演化尋優過程示意圖	73
圖 6.1 ANN 模式之架構圖	76

表目錄

表 2.1 道路事件偵測之相關文獻整理	13
表 2.1 道路事件偵測之相關文獻整理(續).....	14
表 2.1 道路事件偵測之相關文獻整理(續).....	15
表 2.2 基因模糊邏輯控制之相關文獻整理	17
表 2.3 事件偵測演算法之整理表	18
表 2.3 事件偵測演算法之整理表(續).....	19
表 4.1 主成份分析報表節錄(一)	54
表 4.2 主成份分析報表節錄(二)	55
表 5.1 交通事件分類表	65
表 5.2 五個模式之訓練結果	68
表 5.3 驗證資料於五個模式之預測結果	68
表 5.4 主成份模式訓練組之交配率與突變率之參數分析	69
表 5.5 主成份模式驗證組之交配率與突變率之參數分析	70
表 6.1 ANN 訓練模式之相關設定	77
表 6.2 ANN 模式之訓練結果	78
表 6.3 驗證資料於各 ANN 模式之預測結果	79
表 6.4 GFLC 及 ANN 之訓練結果評比表	80
表 6.5 驗證資料經 GFLC 及 ANN 之預測結果評比表	80

第一章 緒論

1.1 研究背景與動機

中山高速公路自民國六十三年通車以來已數十年，加上近年興建完成之第二條高速公路，兩條主要國道公路構成國內南北交通之主要動脈，於國內南北城際運輸中扮演著舉足輕重之地位。

正如同一般道路，高速公路上行車事件發生頻率相當高，一旦發生意外事故，極可能產生比一般道路更嚴重之車流延滯、財物損失、甚至更嚴重之追撞事故以及人員傷亡，其直接及間接影響範圍，往往遠超過一般道路系統。因此，為能減少意外事件所造成之衝擊，除了加強公路安全設計，以根本之方式減少事件發生之機率，另一方面，更應該設法於意外事件發生後之管理作改善，以節省運輸能源之消耗，降低整體社會成本之支出並縮小意外事件發生後對於正常車流之影響。

一般高速公路之偵測方式，大致可分為自動偵測及非自動偵測兩種。自動偵測主要是透過一些偵測儀器如：感應線圈、磁場感應、磁力計感應、超音波、影像處理、紅外線及電波等所蒐集之資料，經由電腦終端機演算法之分析而得知事件發生並發出警報，快速且直接通知管理人員及相關處理單位進行處置。非自動偵測則是依賴傳統人為方式，包括警車巡邏、用路人通報、閉路電視與空中偵測等方式，偵測或判斷事故之發生。

基此，建立一套有效之意外事件自動偵測系統，能精確且快速地提供事件警報資訊給相關管理單位，進而讓各相關單位快速處理國道高速公路上所發生之各種事件狀況，實為一重要課題。

本研究乃以高速公路為研究範圍，嘗試以實際事件資料及偵測器測得交通資料為基礎，利用基因模糊邏輯控制（genetic fuzzy logic

controller, GFLC) 建構一高速公路之意外事件自動偵測模式，除可透過模糊理論處理資訊之不確定性因素外，尚能利用遺傳演算法 (genetic algorithms, GAs) 自動學習邏輯規則與隸屬函數參數之校估，利用反覆尋優程序來建構 GFLC 事件偵測演算法，期使事件偵測績效達到最佳。最後，將本模式與廣為應用之類神經網路 (artificial neural network, ANN) 建構而成之模式作進一步之比較分析，以驗證 GFLC 模式於事件偵測上之可行性及適用性，以供相關單位未來在規劃高速公路事件偵測系統時之參考。

1.2 研究目的

本研究之主要目的是希望提供未來國內高速公路網事故偵測系統之研究與參考，其歸納如下：

1. 彙整高速公路事件自動偵測之相關文獻與模糊邏輯控制理論的文獻研析，了解其基本理論、假設及應用限制，藉以探討其應用於高速公路事故偵測之可行性。
2. 考量各種狀態變數組合，利用主成分分析方法將變數經線性組合轉換成新的變項（主成份），再利用基因模糊邏輯控制（GFLC）建構一套事件自動偵測系統，以達最佳之偵測效果。
3. 利用三項績效評估指標：偵測率（DR）、誤報率（FAR）與平均偵知時間（MTD）評估基因模糊邏輯控制於高速公路事件自動偵測之績效。
4. 最後，以類神經網路演算法 (ANN) 建構另一事件偵測模式，並與 GFLC 模式作進一步之比較分析，以驗證 GFLC 模式於事件偵測上之適用性。
5. 提供相關單位未來在規劃國內高速公路網，意外事故偵測系統建立之研究與參考。

1.3 研究內容與流程

本研究之主要研究內容與流程分述如下：

1. 界定研究目的與範圍

本研究主要蒐集現有國道高速公路之交通參數資料，利用實際事件資料與偵測器測得之交通參數資料為基礎，利用基因模糊邏輯控制（genetic fuzzy logic controller, GFLC）建構一高速公路之事件自動偵測系統。

2. 相關文獻回顧

根據相關課題進行文獻蒐集回顧，包含：

(1) 事件自動偵測演算法

回顧事件自動偵測之相關文獻，透過文獻之整理與彙析，了解目前已應用於事件偵測之各演算法及其適用性。

(2) 基因模糊邏輯控制

回顧國內外基因模糊邏輯控制之相關文獻，了解基因演算法之三大運算法則，主要包括複製、交配及突變等運作方式，並探討其在模糊邏輯控制之規則挑選與隸屬函數校估之選擇。

3. 資料蒐集分析

經由國道高速公路局之交通控制中心及國道公路警察局索取高速公路主線路段之 VD 資料及每日事件報表，進行各事件發生地點、時間及前後 5 分鐘內之上、下游偵測器，每 20 秒一筆之交通資訊，包括流量、速度及佔有率等資料。藉由比對交通參數資料及事件資料，可瞭解事件發生前後上、下游偵測器之交通參數資料，再針對事件資料作一整理與分析。

4. 模式構建

首先，利用主成份分析法利用線性組合將變數轉成主要之變數構面，以解決 GFLC 之狀態變數受限三個以下之限制。再利用 GFLC 建構一套事件自動偵測系統，模式之建構包括語意變數選定及隸屬函數參數設定，其後依據模糊化、模糊推論、解模糊化等模糊推理步驟完成初步階段。除可透過模糊理論處理資訊之不確定性因素外，尚能利用遺傳演算法（genetic algorithms, GAs）自動學習邏輯規則與隸屬函數參數之校估，利用反覆尋優之程序建構 GFLC 事件偵測演算法。

5. 實例應用

本研究主以國道一號中區路段之實際事件資料為例，利用實際有事件資料及無事件資料與偵測器測得之交通參數資料作為基礎，再以三項績效評估指標：偵測率（DR）、誤報率（FAR）與平均偵知時間（MTD）評估基因模糊邏輯控制模式應用於高速公路事件偵測之績效。

6. 模式比較

本研究最後以類神經網路演算法(ANN)建構另一事件偵測模式，並與 GFLC 所建構之事件自動偵測模式作進一步之比較分析，以驗證 GFLC 模式於事件偵測上之可行性。

7. 結論與建議

整理本研究之結果提出具體之結論，並檢討本研究過程中所遺漏不足之處，以提供後續研究者相關之建議。

綜上所述，本研究之研究流程如圖 1.1 所示

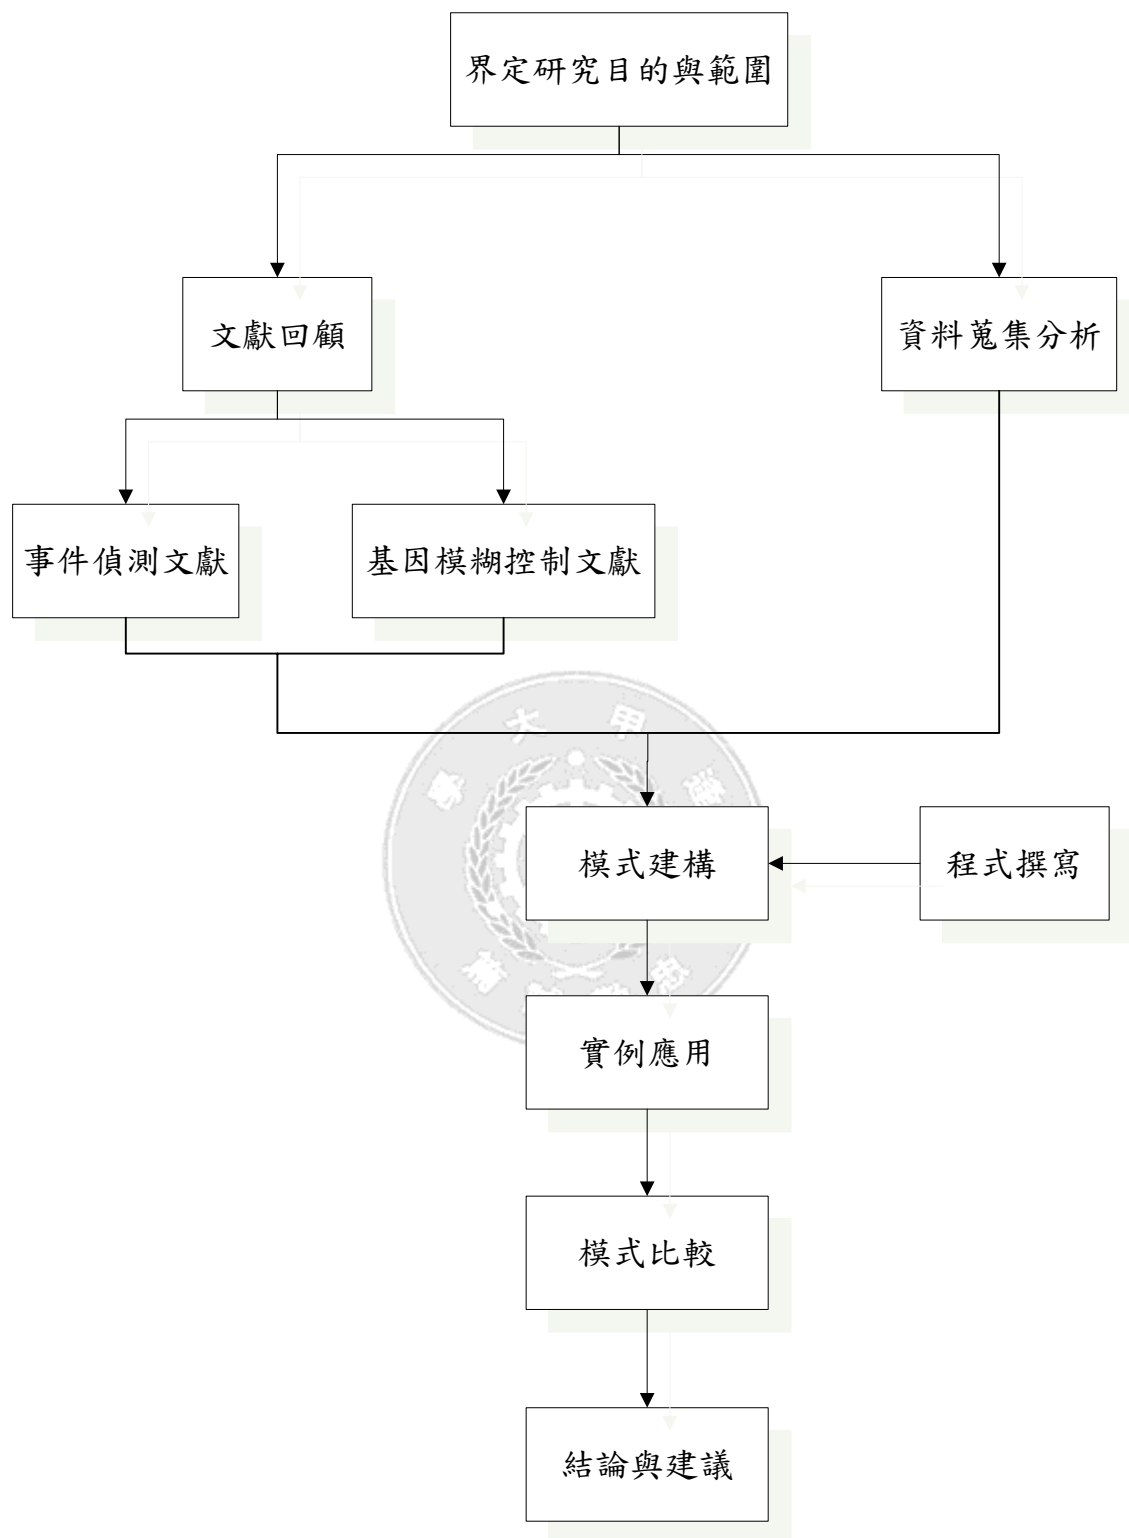


圖 1.1 研究流程圖

第二章 文獻回顧

2.1 道路事件偵測之相關文獻

黃振賢（1992）利用時間序列法或圖形識別法，針對中山高速公路基隆至楊梅段，進行事件自動偵測之離線測試，蒐集事件發生時間與事件發生前後之流量、佔有率資料。所需資料包括（1）每日事件報表，與（2）每 5 分鐘之流量、佔有率報表，皆從高速公路局交通控制中心取得。分別討論 TSC7 演算法、雙指數平滑法及卡門濾波法之評估結果及適用性分析。而三種演算法評估結果，以卡門濾波法較佳，TSC7 演算法次之，而雙指數平滑法之誤報率較高。

曾信忠（1993）採用模糊理論之邏輯架構，探討模糊型態識別法與模糊系統兩種方法，於事件自動偵測應用上之績效。針對中山高速公路基隆至楊梅路段，來進行事件自動偵測之離線測試，因此必須蒐集事件發生時間與事件發生前後之流量、佔有率和車速等資料。所需資料包括（1）每日事件報表，與（2）每 5 分鐘之流量、佔有率和速度報表，皆從高速公路局交通控制中心取得。結果發現，不論利用型態識別及系統識別都可得到相當令人滿意之結果，而且利用模糊理論所發展之事件自動偵測演算法較傳統事件自動偵測演算法（如 TSC7）簡單且容易。

葉源祥（1995）採用微觀車流特性參數，利用速度及時間間距值觀點，進行道路事件發生與否之偵測判斷，而資料內容分別來自三個地區之高速公路內外車道，分別為：汐止、台中一般路段及三重下匝道車流路段，包含一般時段及尖峰時段車流特性。由於觀測而得之車流變化現象，難以採用傳統參數門檻值設定方式偵測事件，故採用倒傳遞神經網路作為偵測事件發生之判別工具。經實際觀測記錄之事件資料訓練完成後之類神經網路，可完全辨別實際資料在非事件狀態下之車流壓縮波現象；至於在事件發生之偵測判別上，由於實際事件資料不易蒐集，故改採以模擬之事件資料進行。以模擬資料測試所得之

偵測績效：在不同流量狀況下，偵測率皆可達 100%；而在平均偵測時間之績效方面，各車道偵測站偵測事件花費時間由 8 秒到數十秒不等；誤報率方面，在一小時之偵測時間內誤報次數可由 2 次到 10 數次不等，因而目前演算法之誤報率績效尚不盡理想。

魏健宏（1996）使用倒傳遞神經網路發展高速公路意外事件自動偵測模式，利用意外事件模式所產生之車流資料，與實際由高速公路五分鐘報表抽樣之無意外事故車流資料進行訓練測試，並採用人工神經網路之軟體 NNP（neural net professional）plusII 來進行探討。意外事故自動偵測模式之雙偵測變數分析，以流量和佔有率為主，考慮兩組車流基本特徵變數，四組時間序列特徵變數與兩組空間特徵變數，作為高速公路意外事故自動偵測人工神經網路之輸入變數。最後在總錯率（篩選標準為 0.5）下，得到總對率 100%，總錯率 0%，與誤差平方根為 4×10^{-3} 之結果；在篩選標準 0.15-0.03 之間，得到總對率 100%，總錯率 0%，與誤差平方根為 8.37×10^{-5} 之結果，獲得良好之偵測結果。

楊雨青（1999）利用類神經網路整合高速公路事件偵測與匝道儀控此兩項管理工作，建構成為考量交通參數時空特性之含事件偵測類神經網路匝道儀控模式，而在所建構之事件偵測類神經網路中，輸入變數為上下游偵測器所蒐集到之前後兩期流量、速度、佔有率等共十二個變數，資料來源主要為高速公路每 5 分鐘報表資料與事件發生之車流模擬模式所產生之交通參數資料，其中訓練範例 150 筆，測試範例 50 筆。首創整合兩個倒傳遞類神經網路成為一新網路架構，建構含事件偵測匝道儀控模式，並利用相同之交通參數資料，同時處理事件偵測與匝道儀控率推估，其中事件偵測結果與匝道儀控率推估可得到不錯之績效。研究中結合含事件偵測類神經網路匝道儀控模式、邏輯控制模式、自我評估模式等模組，建構一智慧型先進匝道儀控系統，提供高速公路有效之交通管理策略與工具。

周義華（2000）利用偵測器所測得之即時交通資料，以時間與空間上之變化關係為基礎，應用模糊聚類分析之概念，依事故之特徵（流

量、位置、受阻塞車道)先進行分類,再透過事故發生前後,流量與密度在時空方面之變化趨勢構建即時鑑別演算法,用以即時辨別事故型態,並提供事故相關之屬性資料,包括事故位置、影響之車道數及車流特性資料。採用模糊聚類分析之概念,所發展出來之事故屬性鑑定演算法,兼具相對門檻值與偵知時間短之雙重優點,經由績效分析結果可得知確實有其發展之潛力。此外,在偵測方法中,對事故發生之可能性賦予一動態相關係數值。其輸出結果主要可供作即時事故偵測與管理所需決策資訊之用,以發展完整之智慧型高速公路系統,並可用於先進旅行者資訊系統,提供用路者重要之行前與行駛中資訊。

侯鈞元(2002)主要採用之偵測演算法是以 Y.I. Lee 與 J.H. Hwang(1999)所提出之市區道路事故偵測演算法為基礎加以改良,並探討其應用特性。該演算法以羅吉特模式為基礎(logit-based),利用羅吉特模式中之效用函數概念來描述事故發生之機率。利用 PARAMICS 定義事故之功能,於每模擬週期定義一事故,待 PARMAICS 模擬完畢,API 程式即以時階為單位,輸出一模擬週期內所有時階之交通資料。經過數次模擬週期,將所有輸出之交通資料中擷取所需資料,輸入 LIMDEP 中進行模式估計。模式所需之變數如,應變數:事故車道;自變數:上下游偵測器所測得之各車道之流量、平均速度或平均佔有率等。以 250m 路段、中流量之模擬環境作為校估模式之基準環境。並設定模擬週期為 60 分鐘、事故延時 20 分鐘、每一時階(偵知時間)1 分鐘。獲得了 96.1%之正確率與 1.02%之錯誤率。數據顯示本研究模式在此環境下之運作績效優良,具有可靠之偵測能力。

王秀帆(2003)針對中山高汐止—五股高架路段進行事件自動偵測,採用灰色預測模式之偵測邏輯,根據最近幾個時段之交通資料進行預測,並利用該預測值與實際觀測值進行比較,以兩者之間之差異程度為判斷事件發生與否之標準。因此必須蒐集事件發生至清除後,上下游偵測器之佔有率資料。所需資料包括(1)每 5 分鐘交通狀況報表(2)交通事件明細表,和(3)道路交通事故調查表;每 5 分鐘交通狀況報表和交通事件明細表,係由國道高速公路局交通控制中心取得,向

國道公路警察局第一警察隊索取交通事故調查。以上、下游門檻值分別為 1.06 和 -2.35，及上、下游門檻值分別為 1.79 和 -1.61 為例，結果發現前者之偵測率為 90.91%、誤報率為 2.05%；後者之偵測率為 90.91%、誤報率為 2.56%，兩者之偵測率皆大於 85%、誤報率小於 5%。最後結果，依 Lewis 對 MAPE 值之分類可知，利用灰色預測模式之預測結果，屬於「優良之預測」。

Cheu and Ritchie (1995) 使用類神經網路來發展高速公路事件自動偵測模式，類神經網路之三種類型，主要為多層前饋式 (MLF)、自我組織特徵映射圖 (SOFM) 與適應共振理論 2 (ART2) 等，數據是經由感應線圈所得到之交通監測分類資料取得，而輸入變數則以上下游平均通過所有車道之流量和佔有率，共 16 個變數來做分析。最後發現使用 MLF 方法所得之錯誤警示率 (FAR) 較 California、McMaster 與 Minnesota 演算法低，可得到較好之偵測結果。

Ai-deek *et al.*, (1996) 主要研究有哪些要素會影響高速公路事故率、事故偵測率及事故偵測演算法之效果。針對高速公路幾何和事故特性之影響來作一統計分析，由高速公路管理中心 I-4 資料庫，將其幾何特性歸類為水平線性（直線及彎曲路段）及垂直線性（上坡、水平及下坡路段）而匝道分為上匝道、下匝道及無匝道路段。其資料是由美國佛羅里達州，三線道高速公路之感應線圈蒐集各車道之流量、速度和佔有率。研究發現，加州演算法 #7 較 #8 及 #10 有最短之偵知時間，而偵測率以加州演算法 #7 為 66.1% 及演算法 #10 為 67.4% 高於演算法 #8 的 53.1%，由於演算法 #7 有較低之門檻值校準及較簡單之邏輯概念。利用幾何特性及演算法 #7 所獲得之門檻值來重新組合 I-4 資料庫之兩個要素：水平線性及匝道之形式。而駛出匝道路段之事故率和事故偵測率都很高；同樣的，在尖峰期間有較高之事故率和事故偵測率，上坡路段之事故率高於水平及下坡路段，而在最大之偵測率下維持 FAR 約 0.8%。

Dia and Rose (1997) 利用多層前饋式 (MLF) 神經網路，來發展高速公路意外事件自動偵測模式。100 件事件資料主要是由墨爾本

交通控制中心取得，其中 40 件由電腦進行驗證；另外 60 件則用來訓練，本模式透過在偵知時間 t 內平均通過所有車道之速度、流量和佔有率等資料，測試是否有事件之發生。透過 ANN 及 ARRB/VicRoads 模式來做比較，ANN 經由事件偵測率 (DR) 與錯誤警示率 (FAR) 之成果包絡曲線 (PEC) 可得到，DR 為 100% 而 FAR 為 0%，結果發現 ANN 優於 ARRB/VicRoads 模式可以提供快速且可靠之事件偵測於高速公路上。

Khan and Ritchie (1998) 使用統計學和類神經網路模式來偵測城際幹道上不同類型之事件問題。主要是透過傳統之感應線圈與監視器來取得所需之資訊，每一事件發生之時間、持續時間及位置都可以明確指出，使用 Netsim 來模擬訓練資料以並發展本模式。利用上下游偵測器所得各車道之流量和佔有率，來做訓練與驗證。持續測試可以降低誤警率和偵測率，在 0PT 下誤警率為 1.16%，1PT 下誤警率為 0.23%，偵知時間為 1.63 週期，偵測率之結果相當不錯。而最後結果顯示多層前饋式 (MLF) 神經網路之結果優於判別分析及時間序列分類法。

Ishak and Al-Deek (1999) 主要是在探討多層前饋式 (MLF) 與模糊適應性共振理論 (Fuzzy ART) 兩種類神經網路之應用與比較。主要使用奧蘭多市之 I-4 交通偵測系統所得之線圈偵測資料，取得每 30 分鐘下之流量、速度及佔有率等資料進行訓練。最後得到 Fuzzy ART 演算法之偵測率接近 90%，優於 MLF 演算法及加州演算法 #7 和 #8。

Abdulhai and Ritchie (1999) 主要利用統計學之概念，修改貝氏類神經網路 (Bayesian-based Neural Network, PNN) 成為更完善之演算法，來偵測高速公路事故之發生。主要是針對 PNN 演算法及 MLF (Multi Layer Feed Forward) 演算法做比較，利用高速公路上下游所偵測之流量、速度及佔有率來做訓練與驗證，資料取得於加州 I-880 及明尼蘇達州 I-35W 之高速公路資料庫。利用新結構能及時學習之能力，產生可轉移之事件偵測演算法，顯著改善事件資料重複自我訓練

之時間；且新方法 PNN 演算法之偵測率亦高於 MLF 演算法。

Adeli and Karim (2000) 使用模糊微波放射基礎類神經網路 (Fuzzy-Wavelet RBFNN)，來偵測高速公路事件之發生，本方法論有效結合模糊、微波及類神經，並結合 C++ 及 MATLAB 之規劃環境，利用電腦技術改善並強健演算法之可靠性，而微波基礎即是將感應器所偵測之雜訊資料降低。其資料來源是經由 I-880 資料庫所搜集加州之奧克蘭至聖荷西高速公路之真實資料來做測試。利用上下游偵測器所得到每一方向約 3-5 個車道數之流量、佔有率及速度，來做訓練與驗證，以偵測有無事件及事故種類、位置及時間之發生，最後得到 100% 之偵測率及 0% 之誤警率，是一個相當好的模式。

Karim and Adeli (2002) 比較模糊微波放射函數類神經網路與加州演算法 #8，來偵測高速公路事故之發生。資料搜集來源主要為：美國肯塔基之 ARTIMIS 高速公路系統及 FSP project's I-880 資料庫，針對上下游偵測器所得到之流量、速度及佔有率，來做訓練與驗證；主要是以偵測率、誤警率及偵知時間來評估兩種演算法。Fuzzy-Wavelet RBFNN 主要是使用單站型態之演算法，產生 100% 之偵測率；而在誤警率方面也以 0.07% 優於加州演算法之 3.82%。

Sheu (2002) 利用模糊類聚演算法來偵測高速公路事故之發生及其特性。而模糊類聚演算法之組成程序包含 (1) 確定交通流量情形 (2) 確定事故之發生及 (3) 事故之特性。考慮即時相關交通資料之缺漏，故藉由 CORSIM 模擬模式，Version 1.03 來模擬資料，共 27 種不同之交通流量情況與事件位置之案例組合，在離線測試下，主要在測試事件位置及持續之時間。利用流量、速度及佔有率來做模擬及測試。最後得到 100% 之偵測率，其效果相當不錯。

Khoury *et al*, (2003) 比較感應線圈偵測 (ILDs) 與車輛自動識別 (AVI) 兩系統，來偵測高速公路事故之發生。主要是在測試利用線圈所蒐集到之速度、佔有率、流量等變數資料及 AVI 之位置識別、車牌識別及當日數據與時間等資料，分別比較其偵測率、誤警率及偵

知時間結果。加州演算法 #8 及德州演算法分別使用線圈資料來校估；信賴區間上限限制法及德州演算法分別使用 AVI 資料來校估。資料來源主要為聖安東尼奧市之交通管理中心，TransGuide 所獲得。最後得到加州演算法 #8 使用感應線圈資料，獲得偵測率 100% 且有較低之誤警率；且使用線圈演算法效果也優於使用 AVI 演算法。

Lan and Huang (2005) 使用模糊類神經網路 (RTFNN) 演算法，透過滾動式訓練之過程來偵測高速公路事件之發生。主要是利用上下游偵測器所獲得之速度、流量和密度來做訓練。在相同網路結構下，利用 36 個事件類型來做模擬，最後得到 RTFNN 演算法偵測率為 92.11%，誤警率為 0.08%；而沒有滾動訓練過程之 FNN 演算法偵測率為 90.85%，得到結果 RTFNN 演算法優於 FNN 演算法。透過敏感度分析也發現最佳之滾動區間範圍為 45 分鐘及 90 個訓練樣本值。

Mak and M.ASCE (2005) 比較明尼蘇達法、標準常態變異法 (SND)、加州演算 #7 法及雙指數平滑法 (DES) 四種事件偵測演算法，分別利用新加坡及墨爾本高速公路之資料庫來偵測事件發生與否。主要是利用車輛偵測系統蒐集到之速度、流量及佔有率等交通參數資料做檢測。結果發現，在兩事件資料庫之使用下，單站式之 SND 演算法及雙站式之明尼蘇達法獲得相當好之偵測績效；而 DES 演算法及加州演算 #7 法，僅在墨爾本之資料庫獲得不錯績效，應用於新加坡之資料庫則缺乏移動性。

表 2.1 道路事件偵測之相關文獻整理

作者	方法	輸入	輸出	驗證資料	結果
黃振賢 (1992)	預測法、圖形 識別法 (TSC7 演算法、雙指 數平滑法、卡 門濾波法)	流量、佔有 率	有無事件	高速公路	—
曾信忠 (1993)	模糊理論 (型態/系統 識別法)	流量、佔有 率、速度	有無事件	高速公路	—
葉源祥 (1995)	類神經網路	速度、時間 間距值	有無事件	高速公路	偵測率=100%
魏健宏 等人 (1996)	類神經網路	流量、佔有 率	有無事件	模擬模式	總對率=100% 總錯率=0%
楊雨青 (1999)	類神經網路	流量、速 度、佔有率	有無事件	高速公路	—
周義華 等人 (2000)	模糊類聚分析	流量、密度	有無事 件、包含事 故位置及 相關屬性 資料	微觀車流 模擬軟體 (CORSIM)	—
侯鈞元 (2002)	羅吉特模式	流量、速 度、佔有率	有無事件 及事故位 置	模擬模式 (PARMA ICS)	偵測率=96.1% 誤報率=1.02%
王秀帆 (2003)	灰預測	上下游佔 有率	有無事件	高速公路	偵測率>85% 誤報率<5%
Cheu et al. (1995)	類神經網路	流量、佔有 率	有無事件	高速公路	—

表 2.1 道路事件偵測之相關文獻整理(續)

作者	方法	輸入	輸出	驗證資料	結果
Ai-deek et al. (1996)	加州演算法 # 7、#8 及 #10	流量、速 度、佔有率	有無事件	高速公路	偵測率=66.1% 誤報率=0.8%
Dia et al. (1997)	類神經網路	速度、流 量、佔有率	有無事件	高速公路	偵測率=100% 誤報率=0%
Khan et al. (1998)	統計與類神經 網路	流量、佔有 率	有無事件	高速公路	—
Ishak et al. (1999)	多層前饋式及 模糊適應性共 振理論類神經 網路、加州演 算法 #7 和 #8	流量、佔有 率、速度	有無事件	高速公路	偵測率=90%
Abdulhai et al. (1999)	貝氏類神經網 路、多層前饋 式類神經網路	流量、佔有 率、速度	有無事件	高速公路	—
Adeli et al. (2000)	模糊微波類神 經網路	流量、佔有 率、速度	有無事件 及事故種 類、位置及 時間等資 料	高速公路	偵測率=100% 誤報率=0%
Karim et al. (2002)	模糊微波類神 經網路、加州 演算法	流量、佔有 率、速度	有無事件	高速公路	偵測率=100% 誤報率=0.07%
Sheu (2002)	模糊類聚演算 法	流量、佔有 率、速度	有無事件 、事故特性 及位置等	模擬模式	偵測率=100%

表 2.1 道路事件偵測之相關文獻整理(續)

作者	方法	輸入	輸出	驗證資料	結果
Khoury et al. (2003)	加州演算法、 德州演算法、 信賴區間上限 限制法	流量、佔有 率、速度	有無事件	高速公路	偵測率=100%
Lan et al. (2005)	模糊類神經網 路演算法	速度、流 量、密度	有無事件	高速公路	偵測率=92.1% 誤報率=0.08%
Mak et al. (2005)	明尼蘇達法、 標準常態變異 法、加州演算 法 # 7 及雙指 數平滑法	流量、佔有 率、速度	有無事件	高速公路	—

2.2 基因模糊邏輯控制之相關文獻

Homaifar and McCormick (1995) 利用遺傳演算法能自我適應學習來建構邏輯規則與隸屬函數，用以解決最佳化之問題。以台車及倒車控制為案例作一研究，其狀態變數分別為台車位置、速度及倒車之位置、角度；控制變數皆為對車子之施力大小；在三角隸屬函數型態，在輸出變數分別為五個及七個語意等級下，產生 25 及 35 條推理規則數，產生不錯之效果。

Chen et al. (2000) 利用基因演算法可調節隸屬函數之功能，再透過自訂之模糊規則庫，設計出最佳模糊邏輯控制器。並利用 KFC，MFLC 及 OFLC 發展監控平台並比較其控制器之優劣，主要針對球桿系統迴路不穩定之問題作一研究，其主要狀態變數為球狀體之位置誤差、速度及橫桿角度；控制變數則為直流馬達之電壓，利用三角模糊數型態表示，最後產生 75 條推理規則數，並得到以基因搭配模糊控制器之方法有相當好之效果。

Xiong and Litz (2002) 以學習為前提之有效方法來建構模糊邏輯控制之規則庫，藉以降低規則數組合。主要是透過已建規則庫之「一致性指標」，此指標可以結合基因演算法，用以選取最適隸屬函數及最佳之規則組合，不僅可以產生優良之控制績效，亦可排除模糊知識庫之不一致。針對倒置單擺平衡問題作一研究，輸入變數為台車之移位及角度之旋轉；輸出變數為對汽車施力之大小，並以三角形及梯形模糊數型態及輸入、輸出變數分別為 3、3、5 個語意等級值表示，最後產生 12 條推理規則數，其效果優良。

Shieh (2002) 建構一全新之穩定度準則來穩定馬達轉速控制之連續不確定系統，其強健之 FLC 狀態回饋控制系統之規則數及隸屬函數建構原則，是經由基因演算法連續二次編製程序以穩定不確定模式。其輸入變數分別為誤差及誤差率轉換為極座標 R 及 θ ；輸出變數則為電流大小，並以三角模糊型態及輸入、輸出變數分別為 3、5、5 個語意等級表示，共產生 15 條推理規則數，其結果顯示，即便沒有使用專家知識所建構之規則庫及隸屬函數亦相當有效。

邱裕鈞、藍武王 (2001) 發展一套反覆演化之遺傳演算法 (Iterative evolution of genetic algorithms)，進行邏輯規則之選擇與隸屬函數之校估，以改善過去在建構模糊邏輯控制系統時，對語意變數或邏輯規則經常採主觀設定所可能產生之偏誤。以 GM 跟車模型所產生之跟車行為資料為例，驗證 GFLC 模式之適用性與精確度。GM 跟車模型之狀態變數有三：相對距離 (RD)、相對速度 (RS) 及後車速度 (FS)，控制變數為後車加速度，假設各變數均為五等級語意值，並均以三角模糊數表示。結果顯示，GFLC 模式確能精確地預測跟車行為。

賴建華 (2003) 利用基因模糊邏輯控制 (GFLC) 可克服傳統模糊邏輯控制需主觀設定邏輯規則及隸屬函數缺點。因此，可提昇模糊邏輯控制 (GFLC) 之應用性，建構一個獨立路口之適應性基因模糊邏輯號誌控制系統，以流量、停等車輛數為狀態變數，綠燈延長時間為控制變數，路口總延滯為控制績效指標，並已流體近似法估算之，假設各變數均為五等級語意值，並均以三角模糊數表示。結果顯示

GFLC 模式較現場調查之時制控制減少 19%總延滯，亦比韋伯定時號誌減少 16%總延滯。

表 2.2 基因模糊邏輯控制之相關文獻整理

作者	應用領域	狀態變數與 控制變數	隸屬函數型態與語意等級	推理 規則 數	設定 方式		
Homajfar et al. (1995)	推車中心 定位控制 系統	1.位置	1.三角形及梯形、五個等級	25	主觀		
		2.速度	2.三角形及梯形、五個等級				
	倒車控制 系統	1.施力大小	1.三角形、七個等級	35			
		1.位置	1.三角形及梯形、五個等級				
Chan et al. (2000)	球桿系統	2.角度	2.三角形、七個等級	75	主觀		
		1.施力大小	1.三角形、七個等級				
		1.位置誤差	1.三角形及梯形、五個等級			12	主觀
		2.速度	2.三角形及梯形、五個等級				
Xiong et al. (2002)	倒錘鐘擺 平衡系統	3.角度	3.三角形及梯形、三個等級	15			
		1.電壓大小	1.三角形、七個等級				
Shieh (2002)	馬達轉速 系統	1.速度	1.三角形及梯形、三個等級	99	客觀		
		2.角度	2.三角形及梯形、三個等級				
		1.施力大小	1.三角形及梯形、五個等級				
邱裕鈞 藍武王 (2001)	跟車行為	1.誤差	1.三角形、三個等級	25	客觀		
		2.誤差率	2.三角形、五個等級				
		1.電流大小	1.三角形、五個等級				
賴建華 (2003)	號誌控制 系統	1.相對距離	1.三角形、五個等級	99	客觀		
		2.相對速度	2.三角形、五個等級				
		3.候車速度	3.三角形、五個等級				
		1.後車加速度	1.三角形、五個等級				
賴建華 (2003)	號誌控制 系統	1.流量	1.三角形、五個等級	25	客觀		
		2.停等車輛數	2.三角形、五個等級				
		1.綠燈延長時間	1.三角形、五個等級				

2.3 事件偵測演算法分類

道路事件（incident），一般泛指任何足以影響車流正常通行之事件，同時造成道路容量減少以及行車延誤增加等狀況，例如拋錨車、掉落物及天候不良等。而事件自動偵測之相關研究，大致可分為形態識別法（pattern recognition algorithm）、預測法（forecasting algorithm）、巨變理論法（catastrophe theory approach）、人工神經網路法（artificial neural network approach）等四類，將事件偵測主要演算法依偵測變數、演算方法、門檻值設立與否、適用車流型態、是否具有自我學習、容錯能力及可否上線測試等六方面，整理如表 2.3 事件自動偵測之相關研究整理表，並分別介紹各型式演算法之種類與理論基礎如後。

表 2.3 事件偵測演算法之整理表

方 法	偵測變數			演算法	門 檻 值 設 立	適用車流 形 態		自 我 學 習 及 容 錯 能 力	上 線 測 試
	流 量	速 度	佔 有 率			擁 擠 車 流	非 擁 擠 車 流		
形 態 識 別 法	加州法			V	二元決策樹	V	V		V
	單特徵門檻演算法			V	二元決策樹	V			
	TSC 演算法 7			V	二元決策樹	V	V		
	TSC 演算法 8			V	二元決策樹	V			
	Bang 演算法			V	二元決策樹	V	V		
	貝氏演算法			V	二元決策樹	V	V		
	高佔有率演算法			V	二元決策樹	V			V
	PATREG 演算法		V		交叉相關法	V	V		
	McMaster 演算法	V	V			V			

表 2.3 事件偵測演算法之整理表(續)

方 法		偵測變數			演算法	門 檻 值 設 立	適用車流 形 態		自 我 學 習 及 容 錯 能 力	上 線 測 試
		流 量	速 度	佔 有 率			擁 擠 車 流	非 擁 擠 車 流		
預 測 法	SND 模式			V	移動平均值比較法		V			
	雙指數平滑法	V		V	軌跡信號法		V			V
	ARIMA 模式		V	V	時間序列分析		V			
	卡門濾波法			V	BLUE 法		V	V		V
	交叉相關法			V	期望時間延遲法			V		
	低流量事件偵測法		V		預測值比較法					
	Delft 法		V		預測值比較法					
巨變理論法		V		V	巨變法		V	V		
人工神經網路法		V		V	人工神經網路法		V	V	V	V

資料來源：【魏健宏、黃國平、陳昭宏，民85年。】

一、型態識別法

本類型演算法主要是利用偵測器實際所得到之交通資料及交通參數與過去事件狀況下所校估之門檻值做比較，用以偵測事件發生與否。此類型演算法包括加州演算法、單特徵門檻演算法、TSC 演算法 7、TSC 演算法 8、Bang 演算法、貝氏演算法、高佔有率演算法、PATREG 演算法、McMaster 演算法、APID 演算法、澳洲演算法、明尼蘇達演算法等。

1. 加州演算法 (California) /TSC演算法2：

加州演算法為一系列由加州 TSC (Technology Service Corporation) 和 IDOT (Illinois Department of Transportation) 所發展之數個演算法。主要是利用相鄰偵測器之佔有率及同一偵測器前後

時段佔有率之差異等資料，作為判斷之依據。以二元決策樹作為偵測程序之基本結構，決策點（Decision Node）中以特徵值與門檻值之比值作為比較之依據，再依序往下直至端點。目前此演算法因簡單且績效不錯，是使用廣泛之演算法，並常用來做為新演算法之評估標準。其缺點為難以訂定適當之門檻值，較易失去客觀性。

一般而言，加州演算法適用於高速公路中至高流量之情況。許多極具效率之事件偵測系統皆是由加州演算法改良而來，包括演算法 2（TSC2）、演算法 7（TSC7）與演算法 8（TSC8）。而演算法 2 比加州演算法多了事件終止測試之功能，但由於演算法 2 與加州法在測試事件發生與否時，所使用之特性參數及偵測邏輯完全相同，因此 TSC 演算法 2 亦可稱為加州演算法。

2. 單特徵門檻演算法(Single feature threshold algorithms)：

事件偵測演算法最初之研究方向在於找出單一最佳變數，再將單一變數與預設門檻值經由比較以判斷是否有事件之發生。雖此演算法以今日標準來看較不優良，卻是演算法持續發展之基礎。

3. TSC演算法7：

主要是以加州演算法為基礎，加入持續測試之門檻，並以下游佔有率之值取代下游佔有率時間相對差異值作為門檻值。TSC 演算法 7 之執行績效較加州演算法優良。

4. TSC演算法8：

主要是根據 TSC 演算法 7 之架構，加入壓縮波測試，以避免於高流量下由壓縮波所引起之誤報所改良而成。TSC 演算法 8 之執行績效較加州演算法及 TSC 演算法 7 為高，但卻較為複雜。

5. Bang演算法：

Bang 在評估加州演算法後，了解重現性壓縮波所引起之問題，

因而引進另一修正邏輯來降低誤報率，並建議呈報一事件之前，其事件信號應先持續一段期間，而此時間之大小應隨流量高低情況加以調整，並認為此法較加州演算法為佳。

6. 貝氏演算法 (Bayesian)：

利用有事件與無事件之車流特性歷史資料，建立機率模式並運用貝氏理論建構有、無事件狀況下發生事件之機率，進而建立門檻值來判斷是否有事件之發生。

7. 高佔有率演算法 (High occupancy, HIOCC algorithm)：

由英國運輸與道路研究實驗室(TRRL)所發展而成，係以偵測靜止及慢速車輛在偵測器佔據之時間長短來判斷是否有事件之發生。

8. PATREG 演算法(Pattern Recognition)

由英國 TRRL 發展而成，主要是監測相鄰兩偵測站之間，各車道之車速是否有顯著改變，來判斷是否有事件之發生。

9. McMaster 演算法：

以劇變理論 (Catastrophe Theory) 為基礎所發展而來，由加拿大 Ontario 之 McMaster 大學所發展出來。認為當車流由非擁擠狀態進入擁擠狀態時，車速急遽改變，但流量與佔有率卻平緩變化。因此，利用低速率、高佔有率及擁擠車流等資料來偵測擁擠及其造成之原因。本演算法可辨別重現性擁擠與非重現性擁擠，但在低流量時劇變理論不顯著，故不適合低流量狀況。

二、預測法

此類型演算法主要是利用最近時段之交通特性資料進行預測，根據該預測值及實際觀測值進行比較，兩者間之差異度即為判斷事件發生與否之標準。此類型演算法包括 SND 演算法、雙指數平滑法、

ARIMA 演算法、卡門濾波法等。

1. SND 演算法

標準常態變異法(Standard Normal Deviator, SND)由 Dudek 和 Messer (1974) 所發展，此法可能為最基本之預測演算法。其認為當意外事故發生時，交通參數之變動會較穩定車流狀況下大，故利用交通參數之變化率來判斷事件之發生。其將控制變數對平均值之差異以標準差加以標準化，標準化後之量度值作為判別交通參數變化率之依據，以變化率取代傳統絕對門檻值，尚能避免不同時間之變異所產生之偵測偏誤。

2. 雙指數平滑法

由 Cook 和 Cleveland (1973) 所發展，以雙指數平滑技術平滑輸入車流特性資料，然後利用一追蹤信號以顯示車流狀況偏離之趨勢，然後根據偏離趨勢之大小來判斷事件發生。

3. ARIMA 演算法

由 Ahmed 與 Cook (1979) 所發展，其利用自迴歸移動平均整合模式 (Autoregressive Integrated Moving Average, ARIMA) 處理及預測時間序列之交通資料，所採用之觀測值為佔有率，當實際值超過預測值之信賴區間時，則判斷事故發生。

4. 卡門濾波法

此法是一種動態系統之最佳狀態估計過程。由 Chui 及 Chen (1987) 利用卡門濾波 (Kalman Filtering) 進行即時偵測演算。由夾雜雜訊之資訊中找出最佳濾波，並利用過去交通資料建立動態方程式，再求得估計值，若估計值與實際值相差甚大，即表示有事件發生。

5. 交叉相關法

此法為利用上下游之間期望時間延遲之關係，若發現關係不符合時即判斷有事件發生。由 Busch 等人（1990）發現此法特別適合於低流量情況下之事件偵測。

6. 低流量事件偵測

由德州運輸研究所所發展，依據偵測進入某特定區段個別車輛之車速，產生該車離開該區段之最早與最晚離開之預測時間，再利用這些預期時間將車輛分群，在一時間段結束時，離開該區之車輛數少於預期之車輛數則給予警訊。此法誤報率高，因此績效並不優良。

7. Delft 法

此法乃是利用感應線圈所產生之車輛特徵訊號，將每一單獨車輛再做確認。當一車輛通過偵測點時，測量其速度並產生到達下一測點之期望時間，當車輛通過下一個測點，將其實際抵達時間與預測時間相比較並計算誤差，當累計誤差大於臨界值時，則產生事件訊號。

三、巨變理論法

此理論應用於事件偵測演算法之基礎，在於使用尖點巨變理論中跳動、雙重穩定模組、滯留現象、發散、不可觸及性等特性，設定流量為平行縱面之控制變數、佔有率為垂直縱面之控制變數、速率為狀態變數等方式，建立一般正常狀態之壅塞與非壅塞模式，藉由判讀實際交通量資料變化，來測知意外事件之發生。

四、人工智慧法

此類演算法是以人工智慧技術作為演算法之基礎理論，此類型演算法包括專家系統、類神經網路等。

1. 專家系統

L.A.Zadeh (1965) 提出 Fuzzy-Expert 偵測演算法，其偵測運作程序為：當偵測到異常之交通狀況，專家系統方法會啟動一連串之規則，由選取交通變數之型態變異之重要性及持續性去判斷此異常是否由主線之事故所引起。此方法不僅可偵測出事故發生，亦可得知事故發生之地點及其嚴重性。

2. 類神經網路

Cheu (1991) 提出三層之類神經網路事件偵測法，分別是：輸入層、隱藏層及輸出層，再利用 INTRAS (Integrated Traffic Simulation) 交通模擬軟體所產生之高速公路事件資料進行訓練及測試。此演算法是一種模仿生物神經單元之資料處理系統，具有平行處理之能力，當類神經網路之訓練學習資料愈完整，則其績效將會愈好，但礙於學習階段過長，故不適用於即時性資料。

五、模糊理論法

此類演算法是以模糊理論為基礎，包括模糊型態識別法、模糊系統識別法等。

1. 模糊型態識別法

此類型之主要原理為將其產生之車流資料，依其特性分配至近似程度最高之群組中。近似程度之定義由最大隸屬度原則與最近中心劃分法進行計算，兩種演算法進行計算之原則均要先假設樣本空間已經劃分成數個群組，而實際上群組之劃分必須經由一套系統之程序才能完成，這個系統程序一般稱為模糊分類 (Fuzzy Classification)。模糊分類不同於傳統之分類在於模糊分類不像傳統分類屬絕對之二分法，而是以最適模糊切割之方式進行。

2. 模糊系統識別法

此方法主要是利用不精確之語意資料來辨識、建構一個模糊系統，此模糊系統亦必須能夠粗略之表示資料之間之因果關係。資料間之因果關係以構建中之模糊關係加以表達，因而可將新資料輸入其模糊數，進行組合運算後再輸出模糊數之輸出資料，此即觀測系統之最新狀態結構資料。

六、其他方法

1. 影像識別法

Michalopoulos (1991) 等人發展了一套 Autoscope System，主要是利用即時之攝影機畫面，能描述車流狀況並提供路上交通資訊，如流量、速度、佔有率等事件偵測之基礎參數，可搭配其他演算法用以偵測事件之發生與否。

2. 聲音識別法

Naoaki、Hideki 及 Masahiro (1999) 發展一套以聲音為媒介之自動化事故偵測法。該偵測器能夠藉由聲音處理技術，自動辨別不尋常之聲音，再將此聲音發生前後之音頻圖傳送至交通控制中心。這些圖形可以用來分析事故發生，而偵測器主要功能即是能夠從其他聲音中辨別出事故引起之聲音。

3. 綜合法

凡是結合兩種以上不同演算法皆屬之，主要是取各演算法之優點而補其缺點，以增加各演算法之績效與穩定性。如 Abdulhai 及 Ritchie (1999) 結合貝氏理論與類神經網路法來偵測事件是否發生。

2.4 績效評估指標

為確認事故偵測演算法之適用性，必須藉助一些績效指標來評估，目前廣泛用來評估事件偵測演算法之績效指標有三種，分別為：偵測率(detection rate, DR)、誤報率(false-alarm rate, FAR)與平均偵知時間(mean time for detection, MTD)三項指標。以下將分別介紹此三種指標之意義與測試方式：

1. 偵測率 (DR)：

即經由演算法所偵測出發生事件之樣本數占實際發生事件之總數。

$$\text{偵測率} = \frac{\text{演算法所偵測出之事件總數}}{\text{所有實際發生之事件總數}} \times 100 \% \quad (2.1)$$

2. 誤報率(FAR)：

即經由演算法偵測出有事故信號，但實際上並無事件發生。可分為線上定義(on-line definition)及離線定義(off-line definition)兩種。線上誤報率之定義為：由演算法偵測出有事件之樣本數中誤報之比率。離線誤報率之定義為：以無事件樣本測試演算法時，產生誤報之比率。

$$\text{誤報率} = \frac{\text{無事件被判斷為有事件之樣本數}}{\text{演算法偵測出有事件之樣本數}} \times 100 \% \quad (\text{線上定義}) \quad (2.2)$$

$$\text{誤報率} = \frac{\text{無事件誤判為有事件之樣本數}}{\text{以無事件測試之樣本總數}} \times 100 \% \quad (\text{離線定義}) \quad (2.3)$$

3. 平均偵知時間(MTD)：

事件實際發生時間與被偵測出時間之平均延遲時間。一般演算法為求降低誤報率，常進行持續性測試，相對地會增加演算法之平均偵知時間，違反了自動偵測系統「快速偵測」原則。基本上，偵測率、誤報率與平均偵知時間彼此之間有不可避免之取捨 (trade-off) 關係。

小結

藉由事件偵測之相關文獻回顧後發現，已有相當多事件偵測之演算法發表，惟由於事件及其對應之偵測交通資料蒐集不易，許多研究大多利用車流模擬軟體，產生事件發生及交通變化狀況等資料，來進行模式之訓練與驗證。因此，各演算法雖均能達到一定水準之事件偵測準確率與誤報率，但能否實際應用於國內高速公路之事件偵測，仍有待考驗。因此，本文乃蒐集國內高速公路之實際事件與其對應之交通資料，建構事件偵測模式，以確保模式之可用性。

此外，針對基因模糊邏輯控制(GFLC)之應用績效，於許多文獻中亦獲相當驗證，但尚未有應用於事件偵測之相關研究發表。基此，本文乃嘗試利用 GFLC 建構一套事件自動偵測系統，並採客觀方式挑選邏輯規則及校估隸屬函數以建構知識庫，期使事件偵測績效達到最佳。

第三章 研究方法

3.1 模糊邏輯控制

模糊邏輯控制 (fuzzy logic controller；以下簡稱 FLC) 或稱為模糊專家系統 (fuzzy expert system)。提供一種演算法則，可將包含了專家知識之語言控制策略，轉換成自動控制策略，能夠用來表現一些無法明確定義之模糊性概念，尤其是人類語言特有之模糊現象。因此模糊邏輯控制是一種易於控制、掌握之非線性控制器。此控制是一種以 if-then 推理規則庫為基礎之專家人工智慧控制系統，可以克服傳統以實數 (crisp number) 建構專家系統無法處理之人為判斷與決策所存有之語意性 (linguistic)、模糊性 (fuzziness) 以及不確定性 (uncertainty) 問題，故更能有效地模仿專家之判斷與決策行為，達到智慧化控制之目的。

模糊邏輯控制主要是利用推理規則庫將輸入訊息 (inputs) 轉換為明確輸出訊息 (crisp outputs) 用來控制與決策；即利用模糊邏輯規則形成控制之機制，藉以將輸入資料產生與專家判斷相同之推論結果，是一種所謂之近似推論 (approximate reasoning)。由於 FLC 僅需界定出知識庫 (即規則庫及資料庫) 後，即可進行控制，不需要建構模式及設計求解之方法，因此，特別適用於無法以單純數值方法或數學模式加以求解之複雜問題。惟如果專家在進行系統控制時，必須考量之決定性因素過多，將會導致邏輯規則過多而難以挑選，因此 FLC 之狀態變數不宜過多，一般以三個內較為適當，而控制變數一般則為一個。

利用模糊邏輯之方式及專家知識與經驗所建構而成之知識庫，對現行狀態進行模糊推論，以推論出對應之控制策略，即為模糊邏輯控制之概念，模糊邏輯控制之基本架構，如圖 3.1 所示。

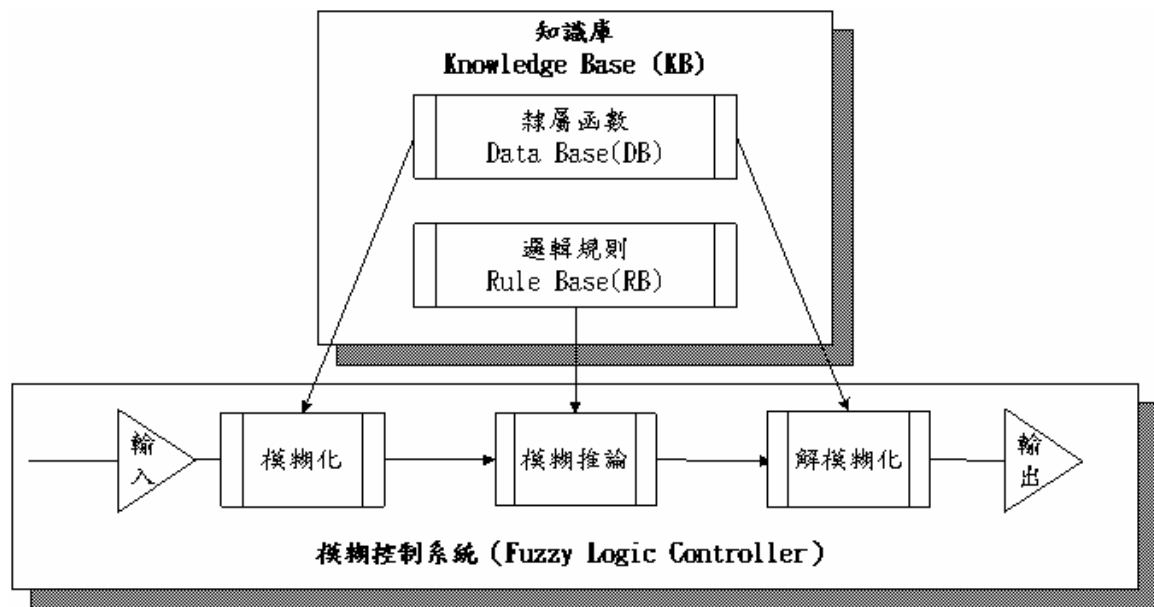


圖 3.1 模糊邏輯控制基本架構圖

3.1.1 模糊邏輯控制之基本特性

1. 隸屬函數 (membership function)

隸屬函數即所謂之模糊語意變數 (fuzzy linguistic variable)。語意變數依其在邏輯規則中所處之位置及功能，可劃分為狀態變數及控制變數，狀態變數係用以陳述現有狀態之相關資料，而控制變數則是控制系統輸出之結果。狀態變數與控制變數之語意值 (linguistic values) 均有其一定型態之隸屬函數及語意等級，據以映射明確數值隸屬於各語意值之隸屬度。一般常見之隸屬函數為三角形、梯形及鐘形等。例如：可以設定「很慢」、「慢」、「普通」、「快」、「很快」等五個等級來表示行車速度之快慢，其三角形隸屬函數繪製如圖 3.2 所示。

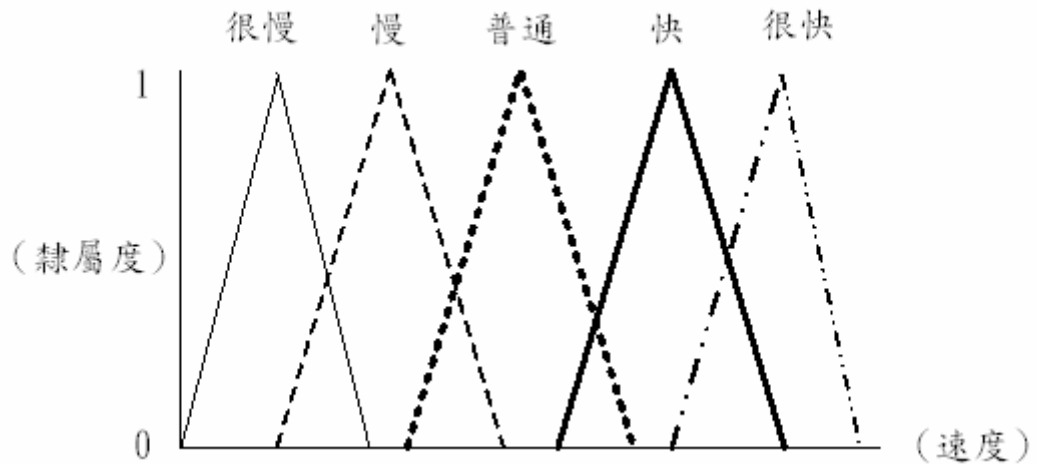


圖 3.2 速度變數之三角形隸屬函數

2. 邏輯規則(Logic rule)

邏輯規則一般之規則形式多以 if-then 之條件法則來呈現，而用於描述所有情境之邏輯規則，即組成邏輯規則庫 (rule base)。每個模糊邏輯控制系統均由有限數量之 If-then 規則所構成，各規則組合結果即形成其推論機制。例如，當邏輯規則：If $X=x_1$ and $Y=y_3$ then $Z=z_2$ ，即代表當語意變數 X 觸動第一語意等級，而 Y 觸動第三語意等級時，將推論出 Z 為第二語意等級之決策行為，其中 X 與 Y 代表狀態變數， Z 則代表控制變數。一般而言，邏輯規則之產生方式主要為以下六種：

- (1) 經由訪談專家學者後，所獲得到之知識以及經驗法則。
- (2) 藉由輸入狀況與輸出決策之實際資料建構而得。
- (3) 合併第一及第二種方式，先以實際資料建構，再由專家進行增減。
- (4) 根據被控系統之特性、型態來訂定規則。
- (5) 根據控制者之控制行為與習慣來訂定規則。
- (6) 藉由自我學習或樣本學習之方式來訂定規則。

3. 模糊化 (Fuzzification)

若輸入之變數為一明確數值時，為了解其觸動哪幾條規則及觸動程度之大小，因此，必須透過隸屬函數計算其隸屬度，此即為模糊化之過程。

4. 模糊推論 (Fuzzy inference)

即是一種在判斷句中敘述概念不明確時，所進行之推理方式，推理邏輯為“甲小則乙大”，其中「小」與「大」是以模糊集合表示語言變量之值。在現存之邏輯規則下，進行模糊理論之合成運算方式。一般常用之方式為最大-最小合成法、最大乘積合成、最大邊界積合成、最大激烈積合成等等。

5. 解模糊化 (defuzzifier)

由於一筆輸入資料可能同時觸動數條規則，解模糊化之程序是將各邏輯規則經由模糊合成運算所得到之模糊結果予以綜合整理，並轉為一明確輸出值。亦即經由解模糊函數轉成一適當之非模糊數，再經由比例應對輸出，方能據以控制系統。一般常用之解模糊化方法有重心法、加權平均法、面積法、最大隸屬度法等。

3.1.2 假設前提與應用限制

FLC 應注意下列三項限制：

1. 問題應用之切合性

問題本身若是可以最佳化模式(如數學規劃)或是以線性方式(如迴歸分析)即可處理，則應避免使用 FLC，FLC 適用於較為複雜之問題。

2. 邏輯規則與隸屬函數之建構

若以專家訪談方式主觀挑選邏輯規則或建立隸屬函數，應注意訪談方式是否能真正汲取專家之判斷與決策行為，以及訪談之專家是否

具有代表性與正確性。若利用 GAs 或 ANN 以訓練資料方式選取最佳規則組合與隸屬函數參數，則應注意訓練資料之代表性及正確性，並應妥善設計驗證 (validation) 之程序，以確保邏輯規則與隸屬函數篩選與校估結果符合所預期之設定。

3. 狀態變數與控制變數之選取

FLC 狀態變數與控制變數之選取，並無準則可供依循，端視 FLC 建構者對系統之了解與掌握。再設計 FLC 時，通常先確定控制變數，再從影響控制變數之重要因素中，選取狀態變數。但由於潛在邏輯規則及隸屬函數校估參數之數量會隨著狀態變數之增加而大幅成長。故一般在應用上，狀態變數之個數大多限制在三個以下，而控制變數通常僅有一個。

3.1.3 模糊邏輯控制建構方式

FLC 之建構方式可分為兩大類。其一是專家訪談法 (expert interviewing)，即透過訪談該領域專家後，藉由其知識與經驗，挑選邏輯規則及設定隸屬函數型式，以組成控制系統。此類方法可能因為專家選擇認定之過於主觀性以及不同專家間之綜整誤差等問題，造成系統建構之偏誤，進而阻礙 FLC 之推廣應用。因此，近年來逐漸興起以案例學習法 (learning from examples, LFE) 來建構 FLC 之相關研究。其主要係利用 GAs 或 ANN 透過輸入與輸出資料間之關係，進行 FLC 之訓練，客觀地完成邏輯規則之選擇與隸屬函數之校估，以確保規則之篩選結果符合預期，期使控制結果達到最佳。

3.2 基因演算法

基因演算法 (Genetic Algorithms, GAs) 之理論是由美國密西根大學 John Holland 教授於 1975 年首先提出，其理論係基於「物競天擇」及「遺傳法則」建構而成之尋優理論。所謂「物競天擇」是指 Gas 會在尋優過程中去蕪存菁，剔除較差之成員而保留較優良之成員。其操作方式主要以遺傳學之複製、交配及突變等三大運算法則為

基礎，故又稱為遺傳演算法。

3.2.1 基因演算法之基本觀念

1. 編碼、解碼(encoding and decoding)

GAs 之編碼即是將欲求解之所有決策變數，轉換為 GAs 之基因，常用之編碼方式為二元編碼(binary coding)、排列編碼(permutation coding)及實數編碼(value coding)。就二元編碼方式來說，即是以 0 或 1 之基因值形成染色體(chromosome)。例如，假設一染色體為 1100111010010001，其中 1 表入選，0 表未入選。至於解碼方式則為反之運作。

2. 適合函數(fitness function)與目標函數(objective function)

適合函數即為衡量染色體之性能指標，適合函數需能反應出不同物種間適應之程度差異，在基因變化後之每一世代族群，都需要檢查其適合函數值，以增加新物種進入新世代族群之機會，使得能將次級之物種快速淘汰以加速尋優過程。因此，適合函數是用來評估該染色體在演化過程中，被選中進行交配之機率高低。

而目標函數則是一個評估之措施，為一個純量值，可用來比較預期結果與實際結果間之誤差。誤差愈小對於控制器來說也就愈佳。因此，若是最小化問題，在進行基因演算法時，需將目標函數取倒數($1/\text{目標函數}$)來代表適合函數，亦即目標函數值或是誤差愈大時，染色體之適合函數值也就愈小，故被選擇成為下一代之機率也就愈小。

3. 複製或稱選擇(selection)

基因演算法中選擇機制主要係依據每一染色體之適合度高低，決定其繁衍子代多寡之機制。其處理方式多以蒙地卡羅轉盤(Monte Carlo wheel)之概念加以篩選，如圖 3.3 所示。所謂蒙地卡羅轉盤係以族群中各染色體之適合度作為判斷依據，根據每條染色體之適合度佔總適合度之比例作分配，如公式 3.1 所示：

$$P(n_i) = \frac{f_i}{\sum_{i=1}^p f_i} \quad (3.1)$$

其中， n_i 表第 i 個染色體， $P(n_i)$ 表第 i 個染色體被選中之機率， f_i 表第 i 個染色體之適合度值， p 為族群數。因此，適合度較高者佔據之面積百分比愈大，獲選留下來繁殖下一代之機率亦較高。

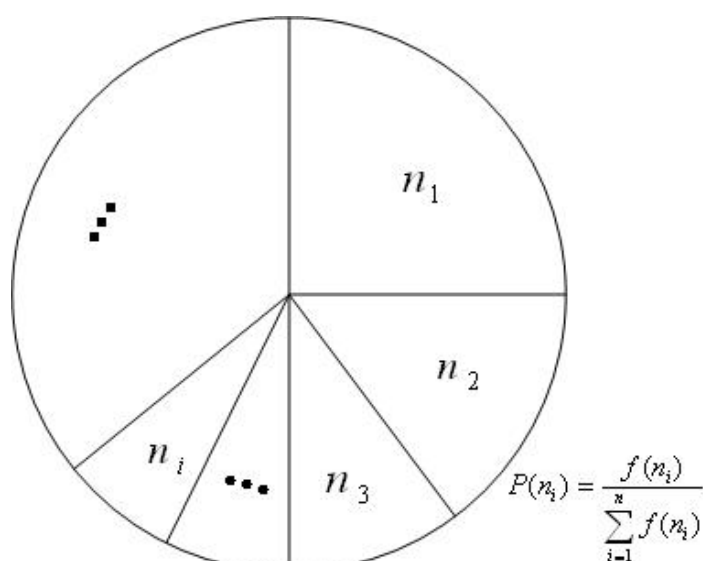


圖 3.3 蒙地卡羅轉盤示意圖

4. 交配(crossover)

交配乃是將經由複製過程篩選出之成對染色體以一設定機率(交配率)決定是否進行配對，藉由交換彼此位元資訊之機制進而組成新子代染色體，亦即經由累積前代之優良基因可以期望能夠產生更為優秀之後代。藉此，子代可同時具有母代之優良基因，組成更具適應能力之染色體。

經過複製程序篩選出成對染色體，以隨機方式產生 0~1 之亂數值，若低於交配率則進行交配，以新子代取代母代；反之，則不進行交配，直接將成對母代置回新族群內。其處理方式主要有兩步驟：第一步驟為進行篩選後族群之隨機配對；第二步驟則為隨機產生成對染

色體之配對點，再依配對點之位置，進行基因互換。交配方法一般較常採用之方法為以下三種：

- (1) 單點交配(one-point crossover)：乃於母代之基因碼位元字串上隨機選取一個交配點，並交換右邊也就是後面所有位元資訊。
- (2) 雙點交配(two-point crossover)：乃於母代基因碼位元字串上隨機選取兩個交配點，並交換兩個交配點間所有位元資訊。
- (3) 字罩交配(uniform crossover)：即首先產生與字串長度相同之字罩當作位元指標器，其中字罩是隨機由 0 與 1 所組成，字罩中為 1 之位元即為欲交換資訊之交配點位置。

交配率之高低會影響母代能否繼續生存於下一世代之機率。基本上，交配率通常設為 0.8~0.9 之間，由於交配率太高可能會造成優良染色體從族群中被取走之速度比交配出來之新染色體所產生之進化來的快，因而喪失交配原意；相反地，若交配率過低則會造成搜尋過程延滯。但如果交配機制是由兩個母代產生兩個子代時，不一定以子代取代母代，而是挑選適合度值較高之兩個置回族群中，另外兩個則刪除，故不必設交配率。

5. 突變(mutation)

突變乃是以一定之突變率，隨機選取染色體上之基因突變點，然後進行資訊更動控制。一般而言，突變率（通常發生機率很低）一般設為 0.05 以下，操作方式則利用亂數產生器產生亂數值對於染色體上之每一位元(基因)進行檢查，如果此亂數值小於設定之突變率則進行突變；反之則不進行。突變主要是防止染色體於複製及交配過程中，遺漏重要訊息或落入局部最佳解，亦即預防族群內各染色體之僵化。突變率之設定影響尋優甚鉅，該值過小，將無法發揮突變之功能，可能發生族群僵化現象；反之將破壞子代繼承母代之優良基因，如此則與隨機搜尋無異。一般突變之處理方有以下兩種：

- (1) 基因突變(gene mutation)：即當產生之亂數值低於設定之突變率時，即隨機更動某一基因值。

- (2) 移轉突變(shift mutation)：即僅變動同一染色體內各基因之位置，而不改變其值。

3.2.2 基因演算法之特性

基因演算法與一般傳統之尋優方法有四個明顯不同之特性：

1. 機率尋優法(Stochastic search)，以機率作為遺傳法則搜尋與運作之依據。因此，較能符合不同類型之最佳化問題，而傳統則以固定之尋優型態依循。
2. 多點尋優法(Multipoint search)，一次對於整個族群進行運算，而不是對於單一個體進行運算，亦即同時由多個起始點開始搜尋，最後收斂為一點，如此可避免且減少落入局部最佳解之機率，此項特點是與傳統演算法最大之相異點。
3. 直接尋優法(Direct search)，直接以適合度值作為研判染色體之優劣與否之評估指標，而不需要其他輔助資訊（如梯度）。因此，較能避免傳統繁複之數學運算。
4. 平行尋優法(Parallel search)，各染色體於遺傳法則下之運作，係平行且獨立地進行。

由於 GAs 尋優時，主要是依據三個遺傳法則之運作，而不需要輔助資訊，故原始問題之目標函數並不需要符合特定條件，如線性、可微分或連續問題，甚至複雜到無法以數學方式表達之目標函數，只要能計算其目標函數值者，皆可以藉由 GAs 求解，故 GAs 之求解彈性甚大。

3.2.3 假設前提與應用限制

GAs 之應用彈性甚大，並沒有特別之假設前提，惟為能達到求解之效率與效度，應注意下列事項：

1. 問題規模

GAs 係將決策變數編碼為基因方式組成染色體演化求解，若問題

之決策變數甚多，將導致染色體長度過長，超過電腦記憶體容量限制。且問題規模太大時，GAs 之尋優結果亦不佳。

2. 限制條件難以處理

利用 GAs 求解時，一般對於限制條件之處理方式有二：第一種是引用懲罰函數，當某一解（染色體）違反限制條件時，則令其適合度值加上（或減去）一大數，以大幅降低其獲選機率，使之於演化過程中，自然淘汰。惟若複製所得之染色體僅少數符合限制條件，則這些染色體將影響演化過程，使族群內差異性降低，造成早熟現象，而無法求得最佳解。第二種是重新設計 GAs 三個運算法則，使其於運算過程，不致產生不可行之解。惟此種方式必須配合問題特性加以設計，目前尚無一套標準設計準則可供依循。

3. 無法保證求得最佳解

許多文獻雖以實例證明 GAs 之求解結果，確實兼具效率與效度，惟仍無法證明其能找到整體最佳解，只能說找到近最佳解。

4. 許多變數須加以設定

利用 GAs 進行求解時，必須先對複製、交配、突變方式、交配率及突變率等參數加以主觀設定，不同於傳統尋優方法僅有少數參數需要設定。而 GAs 參數之不同設定值又可能會影響尋優績效，因此，一般需透過多次試誤(try-and-error)執行，方能嘗試出較佳之參數設定值與尋優結果。

3.2.4 基因演算法之操作方式

基因演算法之運作方式，大致分為以下 7 個操作步驟：

1. 設定編碼、解碼方式：基本參數(如交配率、突變率...等)之設定以及將欲求解之問題參數予以編碼。
2. 設定族群數：隨機地產生起始族群，即第 0 代之族群，以作為演

化之基礎。

3. 評估：將產生之世代族群，分別計算族群內各染色體針對問題所設定之適合函數值，用以評估是否繼續進化之依據，即是否繼續複製、交配以及突變。
4. 選擇：自現有族群中，以選後放回方式重複隨機選取成對之染色體。
5. 交配：將兩母代利用交配方式以隨機產生之交配點進行交配產生子代。
6. 突變：隨機改變子代某一基因值，以避免落入局部解。
7. 測試停止條件：測試是否符合停止條件。若是則停止，完成尋優之過程；若否則回至步驟四繼續重複執行。

3.3 基因模糊邏輯控制

本研究主要是採用邱裕鈞和藍武王【5】所發展之反覆演化 GFLC 模式為基礎，進行事件偵測模式之構建。以下將敘述該模式之編解碼與運作方式。

3.3.1 邏輯規則庫之編解碼

就建構邏輯規則庫部份，主要是根據 Thrift【16】所提之編解碼方式來操作。由於此一方法可使染色體長度最為精簡，有效減少尋優過程中花費之時間及電腦記憶體空間之需求。假設模式設定之狀態變數為 2 個，控制變數為 1 個，各具有五等級語意值，其染色體之長度為 $5 \times 5 = 25$ 個基因，每個基因值為 0~5，分別以 0 代表該條規則未入選，以 1~5 代表該規則獲選外，亦代表其控制變數之語意值，其編解碼方式如圖 3.4 所示。

假設一條染色體為 0000020030000000000004005，則代表共有 4 條邏輯規則入選，此 4 條規則分別為：

Rule 1 : IF $x_1 = NS$ AND $x_2 = NL$ THEN $y = NS$

Rule 2 : IF $x_1 = NS$ AND $x_2 = PS$ THEN $y = ZE$

Rule 3 : IF $x_1 = PL$ AND $x_2 = NS$ THEN $y = PS$

Rule 4 : IF $x_1 = PL$ AND $x_2 = PL$ THEN $y = PL$

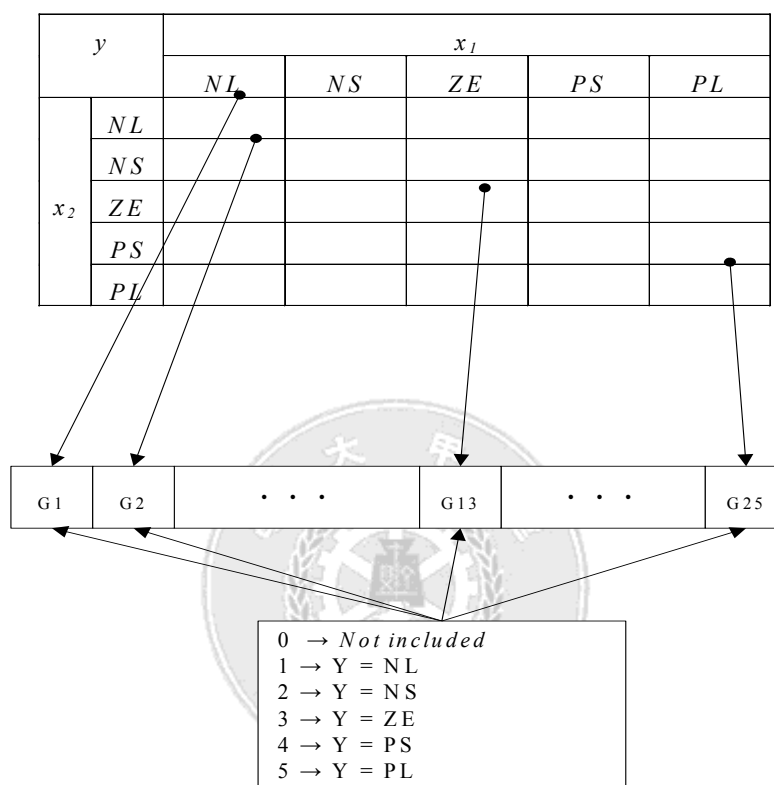


圖 3.4 邏輯規則庫編解碼方式示意圖

3.3.2 隸屬函數之編解碼

就隸屬函數建立部分，一般以三角模糊數為例，其第 k 等級之隸屬參數之左底角、頂點及右底角座標之參數值分別為 c_k^l 、 c_k^c 及 c_k^r ，假設一個具有五等級語意值之變數，則此變數所待校估之參數為 15 個。此外，由於各等級模糊數之參數間尚有一定程度相對大小之關係須先加以釐清。就同一等級模糊數而言：應符合 $c_k^r \geq c_k^c \geq c_k^l$ ；而就不同等級模糊數間則應符合 $c_k^r \geq c_{k-1}^r$ 、 $c_k^c \geq c_{k-1}^c$ 以及 $c_k^l \geq c_{k-1}^l$ 。如直接以基因演算法校估各參數，勢必要將這些限制條件皆納入模式中，對於模式尋優之績效將會有嚴重之影響。故邱裕鈞與藍武王【5】乃

建立一套隸屬函數之編解碼方式進行參數校估：假設隸屬函數形式：第 1 與第 5 等級之隸屬函數均為左傾及右傾之直角三角形，即 $c_1^c = c_1^l = c_{\min}$ 及 $c_5^c = c_5^r = c_{\max}$ ，其中， c_{\min} 及 c_{\max} 分別為該變數之最小值與最大值，為外生變數；第 2~4 等級之隸屬函數均為等腰三角形，即 $c_k^c = (c_k^r + c_k^l)/2$ ， $k=2, 3, 4$ ，因此，所須校估之參數僅 8 個。參數相對大小： $c_{\max} \geq c_4^r \geq \frac{c_5^l}{c_3^r} \geq \frac{c_4^l}{c_2^r} \geq \frac{c_3^l}{c_1^r} \geq c_2^l \geq c_{\min}$ ，其中， c_5^l 與 c_3^r 、 c_4^l 與 c_2^r 及 c_3^l 與 c_1^r 之相對大小未定。故設計 9 個位置變數： $r_1 \sim r_9$ ，用以代表其相對大小位置。每個位置變數 r_i 係以 4 個實數基因代表之(如圖 3.5)，使求解參數之精確度達小數點後兩位，其最大值為 99.99，最小為 0。因此，以 2 個狀態變數與 1 個控制變數，且各具有五等級語意值為例，其染色體長度共計 $3 \times 9 \times 4 = 108$ 個基因。最後，再計算參數值：各位置變數經校估後，再依公式(3.2)~(3.9)以及等腰三角形之特性，分別計算各參數值。

$$c_2^l = c_{\min} + r_1 \times sf \quad (3.2)$$

$$c_1^r = c_2^l + r_2 \times sf \quad (3.3)$$

$$c_3^l = c_2^l + r_3 \times sf \quad (3.4)$$

$$c_2^r = \max\{c_1^r, c_3^l\} + r_4 \times sf \quad (3.5)$$

$$c_4^l = \max\{c_1^r, c_3^l\} + r_5 \times sf \quad (3.6)$$

$$c_3^r = \max\{c_2^r, c_4^l\} + r_6 \times sf \quad (3.7)$$

$$c_5^l = \max\{c_2^r, c_4^l\} + r_7 \times sf \quad (3.8)$$

$$c_4^r = \max\{c_3^r, c_5^l\} + r_8 \times sf \quad (3.9)$$

$$\text{其中， } sf = \frac{(c_{\max} - c_{\min})}{\sum_{i=1}^9 r_i}$$

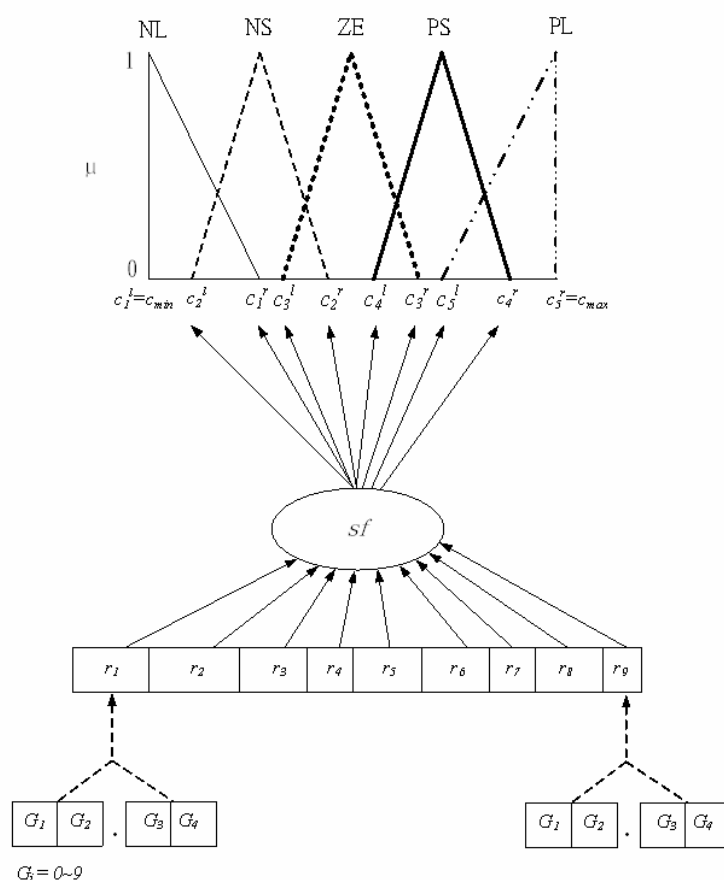


圖 3.5 隸屬函數之編解碼方式示意圖

3.3.3 遺傳演算法則之運作

針對遺傳運算法則之交配與突變方式，邱裕鈞與藍武王【5】除採用 Max-min-arithmetical 交配方式，同時納入雙點交配法(two-point crossover)如圖 3.6 所示，第一個交配點左半部基因與第二個交配點右半部之基因不做變動，僅是染色體中間部分做基因交換之動作。根據以上兩種交配運算機制，每次進行交配運作時，將由 2 個母代染色體產生 8 個子代染色體，再依據染色體適合度值挑選出最優 2 個染色體，置回族群中，其它 6 個則予以刪除。

1. Max-min-arithmetical 交配演化方式：

$$G_1^{t+1} = aG_w^t + (1-a)G_v^t \quad (3.10)$$

$$G_2^{t+1} = aG_v^t + (1-a)G_w^t \quad (3.11)$$

$$G_3^{t+1} \text{ with } g_{3k}^{t+1} = \min\{g_{wk}^t, g_{vk}^t\} \quad (3.12)$$

$$G_4^{t+1} \text{ with } g_{4k}^{t+1} = \max\{g_{wk}^t, g_{vk}^t\} \quad (3.13)$$

其中， G_i^{t+1} ($i=1\sim4$) 代表產生之子代染色體， g_{ik}^t 代表該染色體之第 k 個基因。

G_w^t 及 G_v^t 為獲選之母代染色體， g_{wk}^t 及 g_{vk}^t 分別代表其染色體之第 k 個基因。

a 為一設定之參數， t 代表演化之世代數。

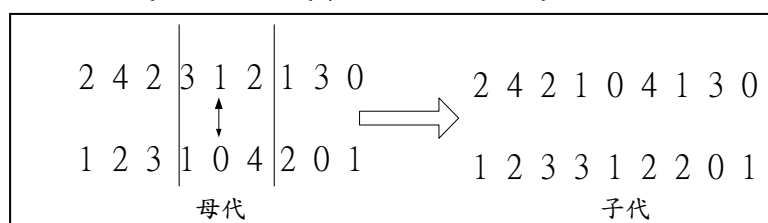


圖 3.6 雙點交配方式示意圖

2. Non-uniform 突變演化方式：

Non-uniform 突變方式，不同於 SGAs 之基因突變僅作 0 或 1 之變動，其納入模擬退火(simulated annealing)觀念，於尋優初期之突變率較大，隨著演化世代數之增加，突變率逐漸縮小，以便尋優結果達到收斂。其演化方式如下：

$$g_k' = \begin{cases} g_k + \Delta(t, g_k^u - g_k) & \text{if } b = 0 \\ g_k - \Delta(t, g_k - g_k^l) & \text{if } b = 1 \end{cases} \quad (3.14)$$

其中， g_k 為產生子代染色體之第 k 個基因。 g_k^u 及 g_k^l 分別為該基因之上、下限值。 b 為一隨機數值(random number)，其值為 $\{0,1\}$ 。 $\Delta(t, y)$ 為一機率函數，給定其參數後，將輸出一數值，位於 $[0, y]$ 。其機率函數型式為： $\Delta(t, y) = y(1 - r^{(1-t/T)^h})$ 。其中， r 為一隨機數值，其值位於 $[0,1]$ 。 T 為最大演化世代數。 h 為一設定之參數。

3.3.4 GFLC 反覆演化法

根據邱裕鈞和藍武王【5】所發展之反覆演化 GFLC 模式為基礎，進行事件偵測模式之構建，其基本觀念類似二階層數學規劃，上層係在下層求解所得之隸屬函數下，求解邏輯規則之最佳組成；下層則是在上層求解所得之邏輯規則下，求解隸屬函數之最佳參數。反覆演化之流程敘述如下：

Step 0：任意設定隸屬函數之起始參數值。

Step 1：邏輯規則之選擇

step 1-1：隨機產生 n 個染色體之起始族群。

step 1-2：以現有隸屬函數參數為基礎，計算各染色體之適合度值。

step 1-3：選擇。

step 1-4：交配。

step 1-5：突變。

step 1-6：令族群中各染色體最大適合度 $= f_s^{r*}$ ， s 表演化世代數。

step 1-7：測試停止條件(在此設定為成熟率達到 80%)是否成立。
若是，則至 Step 2；若否，則回到 step 1-3。

Step 2：隸屬函數之校估

step 2-1：隨機產生 n 個染色體之起始族群。

step 2-2：以現有邏輯規則組成為基礎，計算各染色體之適合度。

step 2-3：選擇。

step 2-4：交配。

step 2-5：突變。

step 2-6：令族群中各染色體之最大適合度 $= f_s^{d*}$ 。令 $f_s = f_s^{d*}$ 。

step 2-7：測試停止條件(成熟率達到 80%)是否成立。若是，則至 Step 3；若否，則回到 step 2-3。

Step 3：測試反覆演化之停止條件(設定為目標函數值之改善程度變動不大，即 $(fs+1-fs) \leq \varepsilon$ ， ε 為設定之極小數值)是否成立。若是，則停止演化，表示已尋得最佳之邏輯規則與隸屬函數；若否，則再回到 Step 1。

3.4 類神經網路

類神經網路(artificial neural network, ANN)係模仿生物神經網路之數學模型，最早是由 1962 年 Rosenblatt 提出，利用感知機來從事文字辨識工作，後來經過多位專家學者不斷開發研究，在此期間類神經網路研究雖一度陷入低潮，但在 1980 年代初期，美國物理學家 Hopfield，將能量函數觀念引進至神經網路，使的神經網路研究再次熱絡，現今神經網路已發展出多種不同型態。

就人類神經網路而言，其基本單元為神經元或稱為神經細胞(neuron)，主要結構包括細胞體(neuron cell body 或 soma)與神經纖維(nerve fibers)兩大部分，細胞體司職訊息處理，而神經纖維則旨在傳遞訊息，依其構造與功能可再分為樹突(dendrites)與軸突(axon)兩部份。其中，樹突之功能係將前端所接收到之訊息傳輸至細胞體，軸突則是用來將細胞體處理過之訊息傳達給其他神經元。因此，ANN 方式是以網路概念代表人類神經網路，以節點(node)代表細胞體，節線(link)代表樹突及軸突。

3.4.1 神經網路架構

所謂網路結構係指神經元在各層位置及各層間節線連結型態之安排方式。因此，一個網路結構應包括：層數(輸入層、隱藏層、輸出層)、各層神經元(節點)個數以及節線在層內或層間之連結方式。基本之三層類神經網路結構如圖 3.7 所示。

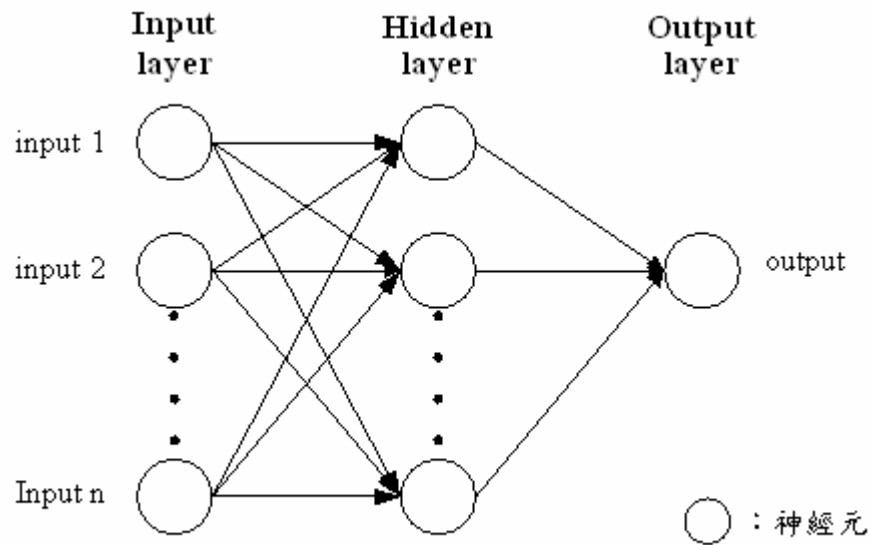


圖 3.7 類神經網路之架構

圖 3.8 是一個人工神經元模型，這些人工神經元又稱為處理單元 (processing unit)，每一個處理單元之輸出以扇狀送出，成為其他許多處理單元之輸入。處理單元其輸入值與輸出值之關係式，一般可用輸入值加權乘積和之函數來表示： $Y_j = f(\sum W_{ij}X_i - \theta_j)$

其中， Y_j ：人工神經元模型之輸出信號。 f ：人工神經元模型之轉換函數 (transfer function)，此轉換函數功能是将自其他處理單元輸入之輸入值加權乘積和轉換成該處理單元輸出值之一種數學轉換公式。 W_{ij} ：人工神經元模型之神經節強度，又稱連結加權值，表示第 i 處理單元對第 j 個處理單元之影響程度。 X_i ：人工神經元模型之輸入信號。 θ_j ：人工神經元模型之閾值，又稱偏權值。

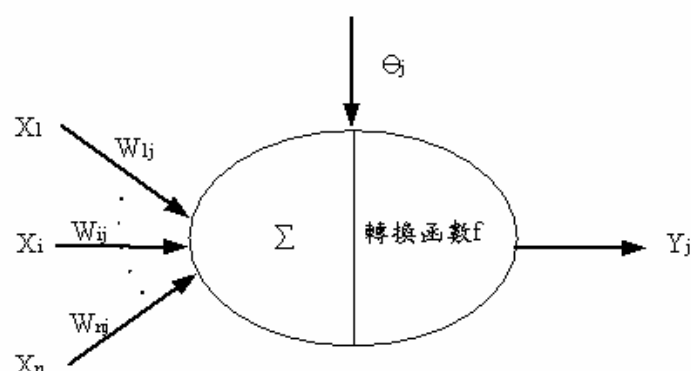


圖 3.8 人工神經元模型

3.4.2 倒傳遞網路之基本概念

倒傳遞網路 (Back-Propagation Network, BPN) 是目前類神經網路學習模式中最具代表性之模式，係由 Rumelhart et al. 在 1985 年所提出。其藉由網路架構方式將資料透過神經元或稱為處理單元—處理訊息之基本單元，經過彙整 (Σ) 與轉換 (T) 輸入資料後，針對輸入之個案作出分析、歸納並輸出預測結果。其基本原理是利用目標輸出值 (desired output) 與實際輸出值 (actual output) 之間之差異，由設計者定義出誤差函數 (error function)，然後利用梯度遞減法 (gradient descent method) 之觀念將誤差函數給予最小化，即每當輸入一個學習例子時，網路即小幅調整 W 權重值之大小。

倒傳遞類神經網路之學習包含兩個階段：順向傳遞 (forward pass) 與逆向傳遞 (backward pass)。順向傳遞是從輸入層開始，一層一層向前傳遞並計算各層處理單元之輸入值，然後連接權重，並經由轉換函數得到該層各處理單元之輸出值，該輸出值將成為下層各處理單元之輸入值，以此類推，直至網路之最後一層。逆向傳遞則是由輸出層向後傳遞，這一階段在於計算誤差及更新連接之權重，其權重更新方法為將前一層之誤差值向後傳遞，並以此為依據修改連接權重，接著計算該層之誤差，再將其往後傳遞，如此逐層往後傳遞計算修改權重，此即為該學習法則稱為倒傳遞法之原因。

1. 倒傳遞網路之優點如下：

- (1) 因為輸出值為連續值，適用於樣本識別、分類問題、函數合成、適應控制、雜訊過濾、資料壓縮、專家系統等應用，應用範圍最廣。
- (2) 學習精度高，可以處理複雜之樣本識別問題與高度非線性之函數合成問題。
- (3) 回想速度快

2. 倒傳遞網路之缺點如下：

- (1) 學習速度慢。
- (2) 有局部最小值之困擾。
- (3) 網路架構與網路動態之決定尚缺乏非常系統化之方法。

3.4.3 倒傳遞類神經網路

倒傳遞網路之架構一般分成輸入層、隱藏層、輸出層三層，如圖 3.9 所示。

1. 輸入層 (input layer)

用以表現網路之輸入變數，由輸入變數所組成之向量作為輸入層之輸入值，即輸入層並未將輸入做處理就直接輸出，使用線性轉換函數，即 $f(x) = x$ 。

2. 隱藏層 (hidden layer)

用以表現輸入處理單元間之相互影響，其處理單元須經試驗之方式以確定其最佳數目，並無一定標準，一般使用非線性轉換函數。隱藏層之層數可以為數層，也可以沒有隱藏層。

3. 輸出層 (output layer)

用以表現網路之輸出變數，其處理單元視問題本身而定，使用非線性轉換函數。

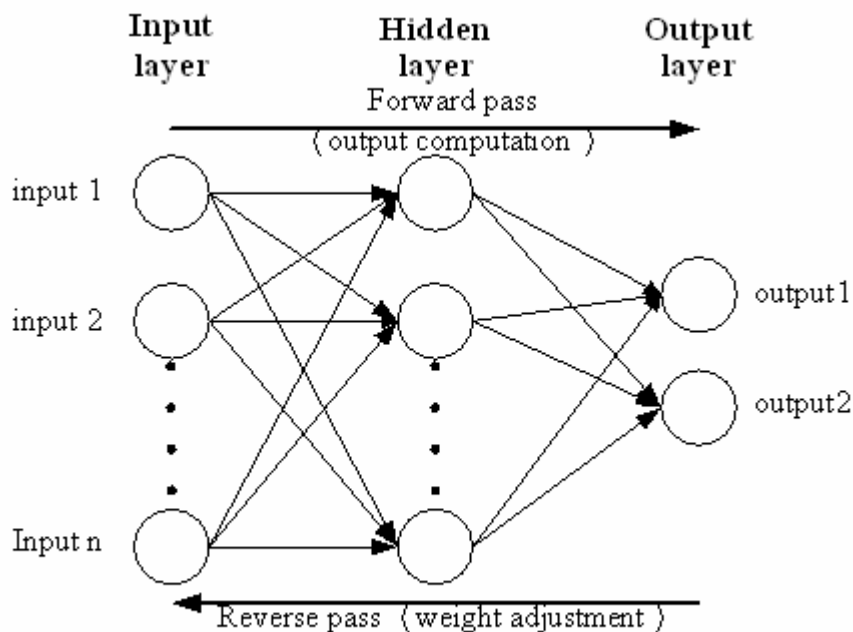


圖 3.9 三層之倒傳遞神經網路架構

倒傳遞網路之演算法以三層之 BPN 網路結構為例，如圖 5，其學法則分為三階段：學習範例之前推 (forward)、誤差之回饋 (feedback) 以及權重之調整。前推階段係將所有範例之輸入變數值 (x_i) 輸入網路，計算網路之輸出值 (y_j)。回饋階段則計算各輸出值 (y_j) 與對應範例原輸出變數值 (t_j) 之誤差 (δ_j)。調整階段，則依據誤差大小進行權重之調整。其演算法如下 (Fausett, 1994)：

Step 0：設定權重之起始值。

Step 1：若不符停止條件，執行步驟二至十。

Step 2：輸入一個訓練範例，執行步驟三至八，直到所有範例均輸入後，跳至步驟九。

前推階段

Step 3：輸入層各節點（ $X_i, i=1,2,\dots,n$ ）接收輸入資料。

Step 4：每一個隱藏層節點彙整輸入層各節點所傳來之資料，即：

$$z_in_j = v_{oj} + \sum_{i=1}^n X_i v_{ij},$$

再利用激發函數加以轉換，成為：

$$z_j = f(z_in_j)。$$

其中， v_{oj} 為隱藏層第 j 個節點之誤差項。

Step5：每一個輸出層節點彙整隱藏層各節點所傳來之資料，即

$$y_in_k = w_{ok} + \sum_{j=1}^p z_j w_{jk},$$

再利用激發函數加以轉換，成為：

$$y_k = f(y_in_k)。$$

其中， w_{oj} 為輸出層第 k 個節點之誤差項。

回饋階段

Step 6：計算每一個輸出層節點與其對應原範例輸出值之誤差，即：

$$\delta_k = (t_k - y_k) f'(y_in_k)。$$

並據以計算輸出層權重調整幅度，即：

$$\Delta w_{jk} = \alpha \delta_k z_j \text{ 及 } \Delta w_{ok} = \alpha \delta_k。$$

α 為學習率（learning rate），為一外生設定參數，其值大多介於 0, 1 間。

Step7：計算每一個隱藏層節點彙整輸出層傳回之誤差，即：

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk},$$

乘以其激發函數之偏微分，即：

$$\delta_j = \delta_{in_j} f'(z_{in_j})。$$

並據以計算隱藏層權重調整幅度，即：

$$\Delta v_{ij} = \alpha \delta_j x_i \text{ 及 } \Delta v_{0j} = \alpha \delta_j。$$

調整階段

Step 8：更新輸出層之權重，即：

$$w_{jk}(\text{new}) = w_{jk}(\text{old}) + \Delta w_{jk}，$$

以及隱藏層之權重，即：

$$v_{ij}(\text{new}) = v_{ij}(\text{old}) + \Delta v_{ij}。$$

Step 9：計算能量函數 E_l 值， $l=l+1$ 。

Step 10：測試停止條件。停止條件通常設為：

$$(E_l - E_{l-1}) \leq \varepsilon。$$

ε 為設定之極小值。

訓練完成後，進行預測時，其運作步驟如下：

Step 0：設定權重值（以訓練所得之權重值設定之）。

Step 1：輸入預測案例之輸入變數值，設其為輸入層各節點值 x_i 。

Step 2：計算隱藏層各節點值：

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij}， z_j = f(z_{in_j})。$$

Step 3：計算輸出層各節點值：

$$y_{in_k} = w_{ok} + \sum_{j=1}^p z_j w_{jk}， y_k = f(y_{in_k})。$$

第四章 模式建構

本章主要分三個小節來說明，第一節為事件偵測輸入變數之選取部份，即本模式如何整理歸納所有之狀態變數以輸入控制系統。第二節為事件偵測模式之建構，即針對不同之狀態變數來建構不同之事件偵測模式。第三節為本研究之核心部份，說明 GFLC 事件自動偵測模式之整體架構及其流程。

4.1 變數選擇

一般事件偵測之變數分析，主要是以不經過處理之基本交通資料或反應時間序列特徵與空間特徵之資料為主，即有關事件偵測之輸入變數，主要包括兩大類，一類是偵測器之偵測數值，包括事件上、下游偵測器或同一偵測器前、後時段所測得交通資訊。另一類則是上、下游偵測器或同一偵測器前、後時段所測得交通資訊之差距。

鑒於交通資訊差值之變數組合，可以區別非事件所造成之重現性壅塞及由於意外事件所造成之非重現性壅塞問題。就重現性壅塞而言，車流之變化應屬於持續而緩慢遞增之情況，上下游或前後偵測器所測得之交通資訊差，應該相差不大。就非重現性壅塞來說，則會使事件發生點之車流突然迅速增加，上下游或前後偵測器所測得之交通資訊差，將差異甚大。

由於事故之判斷涉及不同時段，若使用直接交通資料，其數據將如前述，無法明確指出是否為事件之發生。而廣為應用之加州演算法，即是利用相鄰偵測器及同一偵測器前後時段佔有率之差值，作為事件判斷之依據。

礙於基因模糊邏輯控制之變數個數受限在 3 個以下，為有效減少輸入變數，以及基因模糊邏輯控制不具有如類神經網路之隱藏層可將各實際偵測數值加以彙整(計算差值)之功能。因此，本

研究變數皆選取交通資訊差值作為變數組合之參考，僅針對由意外事件所造成之非重現性壅塞情況，作事件偵測之分析。利用點偵測器(線圈偵測器)所測得之交通資訊，包括流量、速度、佔有率等。參考相關文獻及考量所能蒐集資料，針對同一個偵測器和不同偵測器作區別，共歸納出 9 組變數組合。其變數歸納如下：

1. 同一個偵測器

- (1) 上游偵測器前、後時段之流量差； $(\Delta Q_u = Q_{u(t)} - Q_{u(t-1)})$ 。
- (2) 上游偵測器前、後時段之速度差； $(\Delta V_u = V_{u(t)} - V_{u(t-1)})$ 。
- (3) 上游偵測器前、後時段之佔有率差； $(\Delta K_u = K_{u(t)} - K_{u(t-1)})$ 。
- (4) 下游偵測器前、後時段之流量差； $(\Delta Q_d = Q_{d(t)} - Q_{d(t-1)})$ 。
- (5) 下游偵測器前、後時段之速度差； $(\Delta V_d = V_{d(t)} - V_{d(t-1)})$ 。
- (6) 下游偵測器前、後時段之佔有率差； $(\Delta K_d = K_{d(t)} - K_{d(t-1)})$ 。

2. 不同偵測器

- (1) 上、下游偵測器之流量差； $(\Delta Q = Q_u - Q_d)$ 。
- (2) 上、下游偵測器之速度差； $(\Delta V = V_u - V_d)$ 。
- (3) 上、下游偵測器之佔有率差； $(\Delta K = K_u - K_d)$ 。

其中，流量、速度、佔有率即 (Q, V, K) ；上、下游偵測器所測得之三項交通資訊之差值，流量差、速度差、佔有率差，即 $\Delta Q (= Q_u - Q_d)$ 、 $\Delta V (= V_u - V_d)$ 及 $\Delta K (= K_u - K_d)$ ；(u 表上游、 d 表下游)。

4.2 事件偵測模式

在建構 GFLC 之事件模式上，由於潛在邏輯規則及隸屬函數校估參數之數量會隨著狀態變數之增加而大幅成長，亦會造成尋優時間之大幅提升。故一般在應用上，狀態變數之個數大多限制在三個以下。本研究針對歸納而得之 9 組變數組合，建構了四個事件偵測模式，分別為：流量模式、速度模式、佔有率模式及整合模式。

1. 流量模式

流量模式主要是，上下游偵測器之流量差 ($\Delta Q=Q_u-Q_d$)、上游偵測器前、後時段之流量差 ($\Delta Q_u=Q_{u(t)}-Q_{u(t-1)}$) 及下游偵測器前、後時段之流量差 ($\Delta Q_d=Q_{d(t)}-Q_{d(t-1)}$) 等三項交通資訊之差值，作為狀態變數。控制變數則設為是否有事件。

2. 速度模式

速度模式主要是，上下游偵測器之速度差 ($\Delta V=V_u-V_d$)、上游偵測器前、後時段之速度差 ($\Delta V_u=V_{u(t)}-V_{u(t-1)}$) 及下游偵測器前、後時段之速度差 ($\Delta V_d=V_{d(t)}-V_{d(t-1)}$) 等三項交通資訊之差值，作為狀態變數。控制變數則設為是否有事件。

3. 佔有率模式

佔有率模式主要是，上下游偵測器之佔有率差 ($\Delta K=K_u-K_d$)、上游偵測器前、後時段之佔有率差 ($\Delta K_u=K_{u(t)}-K_{u(t-1)}$) 及下游偵測器前、後時段之佔有率差 ($\Delta K_d=K_{d(t)}-K_{d(t-1)}$) 等三項交通資訊之差值，作為狀態變數。控制變數則設為是否有事件。

4. 整合模式

整合模式主要是，上下游偵測器之流量差 ($\Delta Q=Q_u-Q_d$)、上下游偵測器之速度差 ($\Delta V=V_u-V_d$) 及上下游偵測器之佔有率差 ($\Delta K=K_u-K_d$) 等三項交通資訊之差值，作為狀態變數。控制變數則設為是否有事件。

由於流量模式、速度模式、佔有率模式及整合模式，此四個模式之輸入變數，主要是參考相關文獻及考量所能蒐集資料所挑選出來，無一標準規則可循。因此，本研究進一步建構一主成份模式，其利用主成份分析法能將變數經線性組合轉換成新變項(主成份)，能有效解決 GFLC 之狀態變數最多三個之限制，以提高事件偵測之績效。

所謂主成份分析模式(Principal Analysis)是指將 K 個分析變數(X_1, X_2, \dots, X_k)縮減成一個總指標之統計方法。其中這 K 個分析變數必須是連續性變數，而所謂之總指標，則是各分析變數之線性組合。理論上，主成份分析可自 K 個分析變數萃取 K 個主成份，而本研究礙於 GFLC 模式之狀態變數之個數限制在三個以下。因此，將採用第一個、第二個及第三個，即前三個主成份，作為新狀態變數之變項。

本研究主要是針對歸納而得之 9 組變數，共計 1663 個資料樣本，利用 SAS 軟體進行主成份分析，將 9 個變項：上游偵測器前、後時段之流量差、速度差、佔有率差；下游偵測器前、後時段之流量差、速度差、佔有率差及上、下游偵測器之流量差、速度差、佔有率差，分別給予不同之加權，以組合成 3 個新變項（稱為主成份）。其結果參考表 4.1 所示，在解釋度 60%（即 R-Square 值為 0.6）之情況下，可以將 9 個變數以 3 個主成份因子（PRIN1~PRIN3）來解釋。而其第一個主成份之解釋量為 0.2537，第二個主成份之解釋量為 0.1731，第三個主成份之解釋量則為 0.1695。

表 4.1 主成份分析報表節錄(一)

Principal Component Analysis				
Eigenvalues of the Covariance Matrix				
	Eigenvalue	Difference	Proportion	Cumulative
PRIN1	2.28355	0.72606	0.2537	0.2537
PRIN2	1.55748	0.03234	0.1731	0.4268
PRIN3	1.52514	0.52267	0.1695	<u>0.5962</u>

表 4.2 為經由相關矩陣解得之特徵向量，即主成份加權係數。本模式將 9 個變項分別命名為 V、S、O、V1、S1、O1、V2、S2、O2，並分別給予不同之權重，以組合成三個新主成份。參考表 4.2 可得其計算方式如(4.1)~(4.3)所示：

(1) PRIN1 (第一主成份)

$$=0.442043*V+(-0.3131185*S)+0.418047*O+(-0.255312*V1) \\ +0.136346*S1+(-0.233470*O1)+0.423519*V2+(-0.188220* \\ S2)+0.422697*O2 \quad (4.1)$$

(2) PRIN2 (第二主成份)

$$=0.220425*V+0.493003*S+(-0.416597*O)+0.165689*V1+(- \\ 0.231499*S1)+0.277286*O1+0.465907*V2+(-0.019260*S2) \\ +0.399293*O2 \quad (4.2)$$

(3) PRIN3 (第三主成份)

$$=(-0.313420*V)+(-0.416603*S)+0.186060*O+0.454482*V1 \\ +(-0.030762*S1)+0.564943*O1+0.073838*V2+(-0.341996* \\ S2)+0.210993*O2 \quad (4.3)$$

表 4.2 主成份分析報表節錄(二)

Principal Component Analysis Eigenvectors			
9 個變項	PRIN1	PRIN2	PRIN3
V(上、下游之流量差)	0.442043	0.220425	-0.131420
S(上、下游之速度差)	-0.313185	0.493003	-0.416603
O(上、下游之佔有率差)	0.418047	-0.416597	0.186060
V1(上游前、後時段之流量差)	-0.255312	0.165689	0.454482
S1(上游前、後時段之速度差)	-0.136346	-0.231499	-0.030762
O1(上游前、後時段之佔有率差)	-0.233470	0.277286	0.564943
V2(下游前、後時段之流量差)	0.423519	0.465907	0.073838
S2(下游前、後時段之速度差)	-0.188220	-0.019260	-0.341996
O2(下游前、後時段之佔有率差)	0.422697	0.399293	0.210993

5. 主成份模式

經由主成份分析法挑選出三個新主成份，將此三個新主成份設為模式之輸入變數，即主成份模式之三個狀態變數為第一主成

份、第二主成份及第三主成份，用以輸入控制系統；而控制變數則以是否有事件發生作為系統之產出。

4.3 GFLC 事件偵測模式

本研究主要是利用 GFLC 建構一套事件自動偵測系統，除可透過模糊理論處理資訊之不確定性因素外，尚能利用遺傳演算法（genetic algorithms, GAs）自動學習邏輯規則與隸屬函數參數之校估，利用反覆尋優程序來建構 GFLC 事件偵測演算法，期使事件偵測績效達到最佳。

就邏輯規則庫之編解碼、隸屬函數之編解碼及遺傳演算法則之運作主要是採用 3.3 節所介紹之方式來運作，而模式演化機制係採用邱裕鈞和藍武王【5】所發展之反覆演化 GFLC 模式為基礎，以進行事件偵測模式之構建。

4.3.1 邏輯規則與隸屬函數之編解碼

本研究五個模式：流量模式、速度模式、佔有率模式、整合模式及主成份模式，皆採用三個狀態變數作為輸入及一個控制變數作為輸出。各模式中每個變數之語意值均為五等級，且均為三角形之模糊數。各模式在邏輯規則之選擇部份，共計有 $5 \times 5 \times 5 = 125$ 條規則可供選擇，每一個基因代表一條規則，每一個染色體共有 125 個基因。

各模式在隸屬函數之校估部份，針對語意等級一之右底角及等級五之左底角與等級二至四，三個模糊數之左右底角，共計 8 個參數進行校估，設計 9 個位置變數（ $r_1 \sim r_9$ ），代表其相對大小位置關係，共計有 $4 \times 9 = 36$ 個參數可供校估，每四個基因代表一個參數，每一個染色體共有 $4 \times 9 \times 4 = 144$ 個基因。

4.3.2 遺傳演算法則之運作

本模式之遺傳演算法，主要係採用蒙地卡羅轉盤作為染色體

挑選之方法，以族群中各染色體之適合度作為判斷依據，即適合度越高之染色體被挑選用來產生下一代之機率越高。除了採用雙點交配法，並同時納入 max-min-arithmetical 交配方式，藉由 2 個母代染色體產生 6 個新子代染色體，加上原本 2 個母代染色體，共計 8 個染色體，再依據染色體適合度值挑選出最佳 2 個，置回族群中，其它 6 個則予以刪除。突變部分則採用 Non-uniform 之突變方式，其納入模擬退火(simulated annealing)之觀念，於尋優初期使突變率較大，以便做大幅度之跳動，避免落入局部解中，隨著世代之演化突變率逐漸縮小，以便尋優結果之收斂。圖 4.1 為遺傳演算法之演化流程圖。

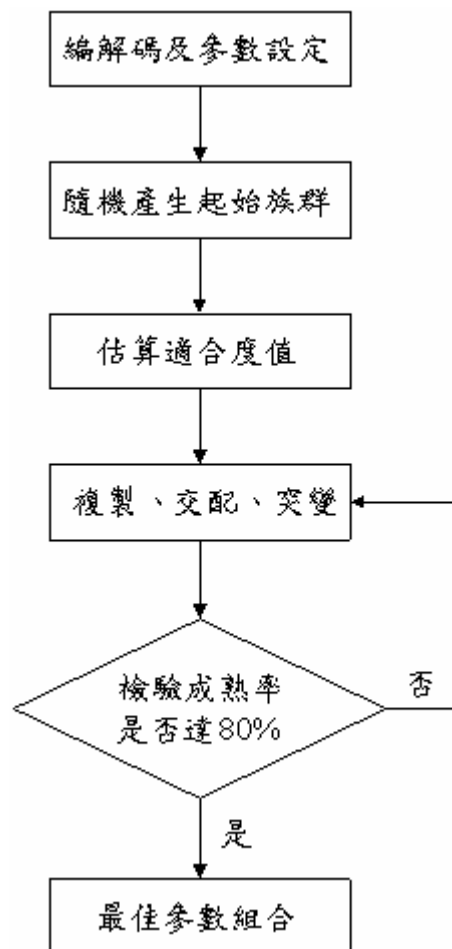


圖 4.1 遺傳演算法之演化流程圖

4.3.3 GFLC 反覆演化機制

本模式主要是利用反覆演化方式，進行模糊邏輯規則之挑選與隸屬函數參數之校估。模式在起始演化時，先自行設定各變數之隸屬函數參數，經由運算後得到最適之邏輯規則，以此規則組成下求解最佳之隸屬函數參數，如此反覆運算直至達到演化尋優條件為止，亦即可使隸屬函數參數與邏輯規則相互配合達到最佳之組合。其演化流程如下圖 4.2 所示。

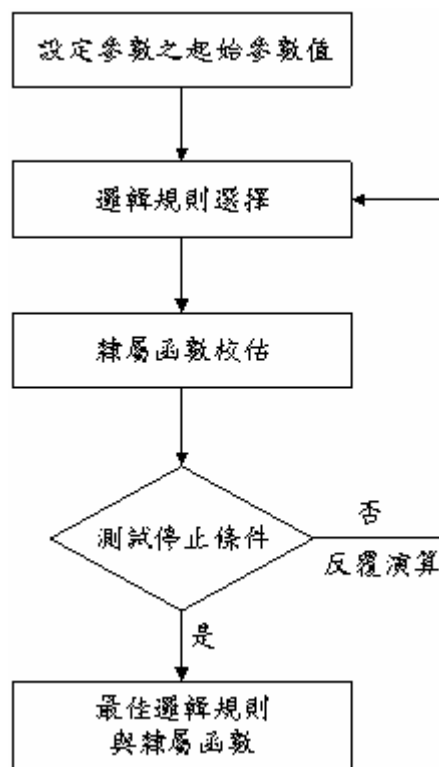


圖 4.2 GFLC 反覆演化示意圖

4.3.4 適合度值

本模式以 GFLC 建構之事件偵測系統之主要目標是在使訓練樣本值與預測值間之誤差達最小化。以下為總誤差平方和之計算方式：

$$E = \frac{1}{2} \sum_{i=1}^N [t_i - y_i]^2 \quad (4.12)$$

其中， E 為總誤差平方和。 N 為訓練樣本總數。 t_i 為第 i 個訓練樣本之事件發生與否模式預測值。 y_i 為第 i 個訓練樣本之事件發生與否值。GAs 之適合度值以值愈大為愈佳，故適合度值訂為 $f=1/E$ 。



第五章 實例應用

本章主要分四個小節來說明，第一節是將所蒐集到之事件資料予以整理分類並分析其特性，以供事件模式之建構使用。第二節主要是說明如何利用三項績效評估指標來評估 GFLC 模式之績效。第三節為 GFLC 所建構模式之參數敏感度分析，俾作為日後參數設定之參考。第四節則為最佳模式控制績效之分析，以說明本模式之可行性。

5.1 資料整理與特性分析

本研究所需資料為有事件發生與無事件發生時之高速公路偵測器資料及每日事件報表，利用偵測器測得之交通參數資料與實際事件資料作一比對，可得知事件發生前後上、下游偵測器之交通參數資料之變化。本章節將分別說明有無事件資料之取得方式及事件資料之特性分析。

5.1.1 事件資料整理

本研究是針對國道一號中區路段進行事件自動偵測，所需資料包括每日事件報表及每 20 秒記錄之交通狀況報表，蒐集事件發生時間與事件發生前後之流量、速度及佔有率等交通參數資料。分別從國道公路警察局及國道高速公路局交通控制中心取得。以下將說明資料蒐集時間及其輸入格式。

1. 事件資料取得時間

本研究蒐集之事件資料為民國 94 年 3 月至 8 月共 6 個月之中山高中區路段，北上車道及南下車道雙向之事件資料。蒐集事件發生地點、時間及發生前後之上下游偵測器，每 20 秒一筆記錄之流量、速度及佔有率等交通參數資料。

每日事件報表資料之內容包括：事件通報時間、位置及事件種類(包括事故、故障車、散落物及其他等)，主要由用路人經由行動電話、路邊緊急電話或由公路警察向交控中心通報；而偵測器資料之內容包括：各車道之小客車、大車及聯結車之流量、速度與佔有率等每 20 秒一筆之交通資料型態。

2. 事件資料輸入格式

為執行演算法，首先須將輸入資料予以格式化，就國內文獻在擷取資料格式上，使用 5 分鐘記錄一次交通狀況為黃振賢【8】之資料格式，擷取事件發生前 15 至 20 分鐘與事件發生後 45 分鐘，即事件發生前後約一小時之資料作為輸入格式。而國外文獻所擷取時間，於使用 1 分鐘記錄一次交通狀況下，其資料格式為事件發生前 5 分鐘與事件發生後 25 分鐘，即事件發生前後三十分鐘之資料作為輸入格式。

本研究之資料來源主要為高公局中區交通控制中心，取得每 20 秒一筆記錄之交通參數資料，不同以往文獻資料為每 5 分鐘、每 1 分鐘一筆記錄或多為模擬之方式所產生之交通資料，可能不夠嚴謹且於實際應用上，容易產生落差之問題。而每 20 秒記錄之交通資料，取樣時間較短，因此所得之交通資料較為精細且連貫，若採三十分鐘資料格式，則樣本點將太多，故本研究取捨事件資料輸入格式原則為，觀察事件發生時間點前後之流量、速度及佔有率等交通資料變化，以判斷事件發生可能影響之時間範圍。本研究擷取之資料為事件發生前後各 5 分鐘，即事件發生前後十分鐘之資料格式。圖 5.1 說明事件資料所擷取之範圍為事件發生前後各 5 分鐘之上、下游偵測器之流量、速度及佔有率等交通參數資料。

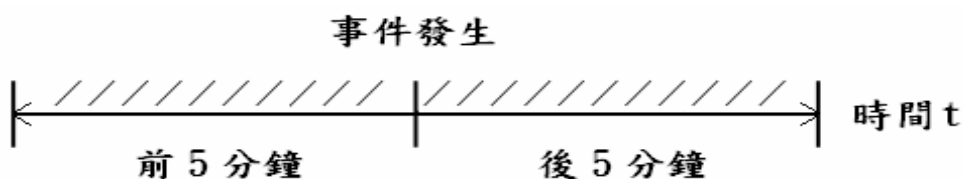


圖 5.1 事件資料輸入範圍圖

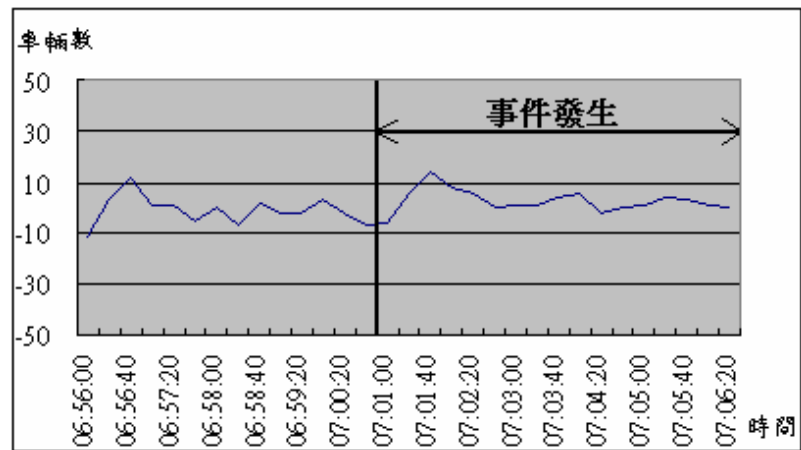
5.1.2 事件資料特性分析

1. 事件資料之比對

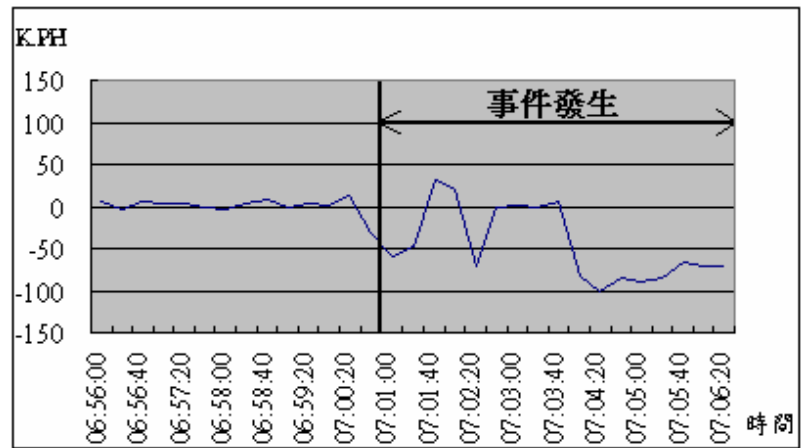
本研究所需之事件資料為事件發生及事件發生前後之上、下游偵測器之流量、速度及佔有率等交通參數資料。由於高速公路各車道均埋設有偵測器，故將同一地點各車道所測得之交通資料予以彙整(流量予以加總，速度及佔有率則加以平均)成路段交通資料。藉由比對每日事件報表及每 20 秒記錄之交通資料，以獲取所需事件資料。

然而，事件報表之資料來源為用路人或國道公路警察局所通報，而所記錄之時間為通報時間亦非發生時間，因此與實際發生之時間難免有所出入；又國道高速公路所佈設之感應儀器，除了系統本身會有故障之可能性外，每逢遇到大雨及傳輸系統電力中斷等情形，皆會造成偵測器資料之缺漏。因此，在事件之擷取時間上，將會適當延長以觀察事件發生前後各交通參數之變化。

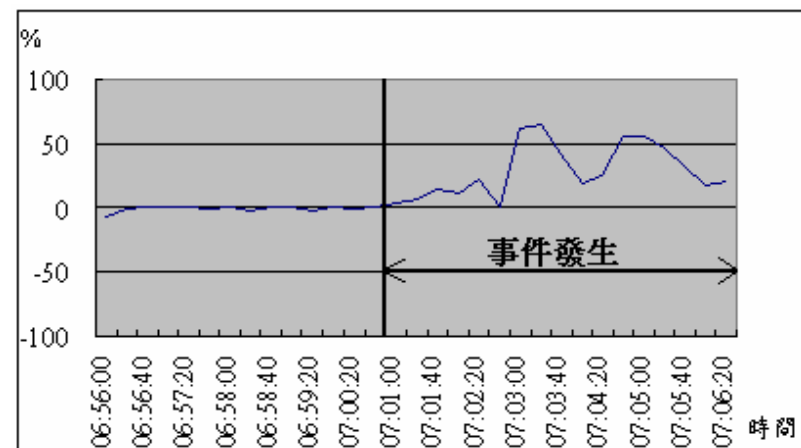
由於事件記錄或偵測資料有誤，將會影響模式之訓練與偵測績效。因此，本研究針對事件登錄時間及實際發生時間之誤差部份，先擷取事件發生前後約 20 分鐘之資料範圍，繪圖觀察其事件發生前後交通參數之變化，再加以調整實際之事件發生時間，以確保資料之正確性。本研究茲挑選某一事件之偵測資料加以繪圖分析，其結果如圖 5.2 及圖 5.3 所示。圖 5.2 為事件發生前後約 5 分鐘之上、下游偵測器所測得之交通資訊差距，圖 5.3 則為該事件發生前後約 5 分鐘之上、下游偵測器所測得之交通資訊。



(a) 流量差

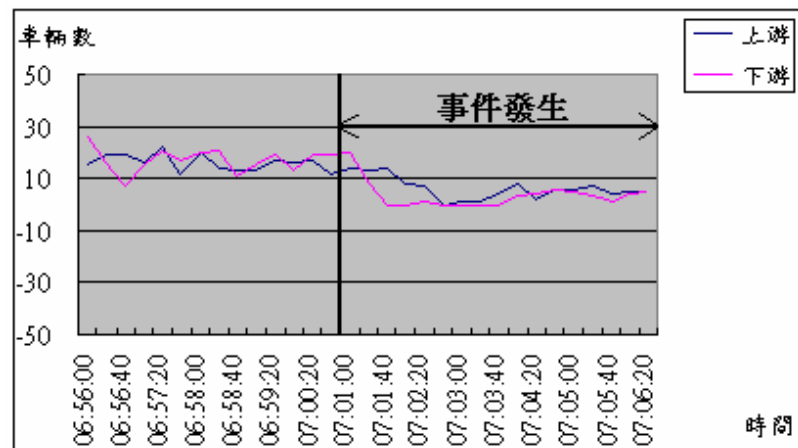


(b) 速度差

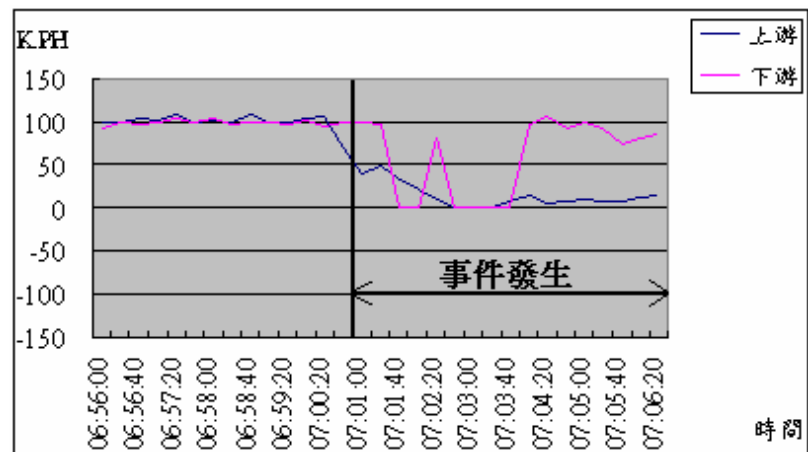


(c) 佔有率差

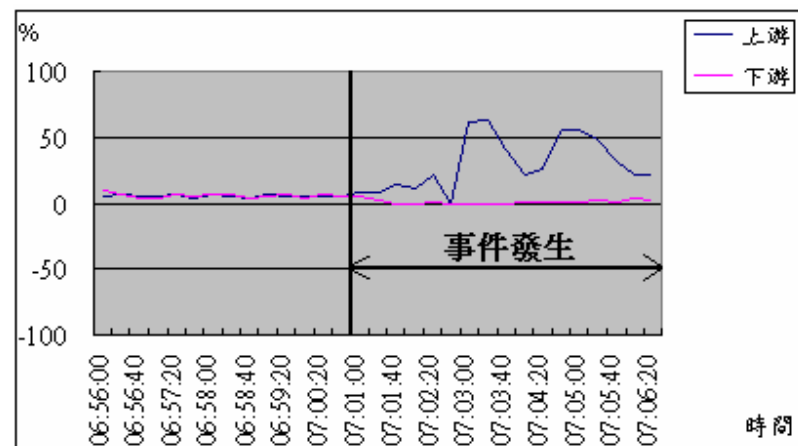
圖 5.2 上、下游偵測器所測得之交通資訊差距



(a) 流量



(b) 速度



(c) 佔有率

圖 5.3 上、下游偵測器所測得之交通資訊

2. 事件資料之分類

本研究主要針對中山高新竹(100K+800)至大林(251K+100)中區主線路段，北上車道及南下車道雙向之事件資料為研究範圍，此路段約每隔三百公尺至一千五百公尺等間距，佈設一感應儀器。

蒐集民國 94 年 3 月至 8 月之事件資料，經由比對事件報表與交通資料報表，過濾偵測器資料缺漏筆數及明顯有誤之事件，並考量上、下游偵測器之筆數需相同之狀況後，共挑選出 30 個有事件之資料樣本。於每 20 秒一筆之記錄，擷取事件發生前後各 5 分鐘之事件資料下，30 個有事件樣本(每個均約有 30 筆交通資料)約計有 890 筆事件資料筆數，以作為模式之訓練與驗證資料。本研究蒐集之事件資料種類及個數整理如下表 5.1 所示。30 個有事件之樣本中，包括事故 24 件、故障車 3 件及其他 3 件。

表 5.1 交通事件分類表

種類 個數	事故	故障車	其他	總計
事件個數	24	3	3	30

資料來源：本研究整理

本研究就無事件資料之部分，主要是扣除交通事件報表上之事件資料後，所取得之資料皆可視為無事件資料。無事件資料主要是擷取民國 94 年 7 月及 8 月之中山高中區路段，北上車道及南下車道雙向之無事件資料，共計 30 個無事件之資料樣本。避開有事件之資料部份，蒐集無事件發生地點、時間及前後之上下游偵測器，每 20 秒記錄之流量、速度及佔有率等交通參數資料，如同有事件樣本，蒐集 30 個無事件樣本前後各 5 分鐘，即一個無事件樣本約有 30 筆無事件資料筆數，但礙於偵測器資料之缺漏及考量上、下游偵測器之筆數需相同之情況下，30 個無事件樣本約計有 773 筆無事件資料筆數，以作為模式之訓練與驗證資料。

本研究在進行模式之建構與驗證前，先分別將 30 個有事件樣本，共 890 筆事件資料分為模式訓練組與模式驗證組。其選取方式為：首先將 30 個有事件樣本分成前面、中間、後面各 10 個事件樣本，再將其擷取成三組樣本資料，分別去建構其模式。第一組樣本資料為前面 10 個加上中間 10 個，共 20 個事件樣本作為模式之訓練組，再以後面 10 個事件樣本作為模式之驗證組；第二組樣本為前面 10 個加上後面 10 個，共 20 個事件樣本作為模式之訓練組，而中間 10 個樣本則為模式之驗證組；第三組樣本為中間 10 個加上後面 10 個，共 20 個事件樣本作為模式之訓練組，再以前面 10 個事件樣本作為模式之驗證組。

將此三組樣本資料分別予以訓練，以建立其預測模式，然後再將其結果加總平均以得到訓練組之績效結果，最後再將分別建立之預測模式輸入驗證組資料，並以同樣計算方式予以驗證，以提高整個樣本資料建構及驗證之全面性及準確性。而 30 個無事件樣本，共 773 筆事件資料亦分為模式訓練組與模式驗證組，如同有事件資料之作法予以建構及驗證。

5.2 績效評估

本研究之事件績效評估指標主要為三種，分別為：偵測率 (DR)、誤報率 (FAR) 與平均偵知時間 (MTD) 用以評估模式之績效。其定義及測試方式如下所述。

1. 偵測率 (DR)：

本研究在偵測率之計算上，主要是針對有事件資料來進行績效之評估。在 30 個有事件之資料中，每一個事件資料皆擷取該事件發生前後各 5 分鐘之資料（一個事件資料，即是指該事件發生前後 10 分鐘之資料）。

在偵測率認定上，是設定同一個事件之警訊，只要該事件發生後至事件結束前，此過程中無論產生多少次事件發生警訊，皆

視為同一個事件之訊息。即在事件發生後 5 分鐘期間內，若有一次判斷訊息為事件發生之警訊，則判斷偵測到該事件。舉例來說，在 30 個有事件資料中，若判斷偵測到 25 個有事件，則其偵測率之計算方式為： $25/30=0.83$ ，即偵測率為 83%。其公式如 5.1 所示。

$$\text{偵測率} = \frac{\text{演算法所偵測出之事件總數}}{\text{所有實際發生之事件總數}} \times 100 \% \quad (5.1)$$

2. 誤報率(FAR)：

本研究所採用之誤報率為離線定義：使用無事件之資料進行離線測試時，產生錯誤訊息次數佔總訊息次數之比率。在 30 個無事件資料之筆數中，若發出一有事件之訊息，則視為一次誤判。舉例來說，在 300 筆無事件資料中，若發出 10 次錯誤之訊息，則其誤報率之計算方式為： $10/300=0.033$ ，即誤報率為 3.3%。其公式如 5.2 所示。

$$\text{誤報率} = \frac{\text{無事件誤判為有事件之樣本數}}{\text{以無事件測試之樣本總數}} \times 100 \% \quad (5.2)$$

3. 平均偵知時間(MTD)：

指事件實際發生時間與由演算法確定事件發生間之時間差距。在 30 個有事件之樣本中，分別計算每一個事件實際發生時間與偵測到事件間之延遲時間，再予以加總後除以偵測到之事件數。舉例來說，若假設 30 個事件全部皆被偵測到，故偵測率為 100%，首先加總每一個事件從發生至被偵測到之時間，再將其除以偵測到之事件數，假設加總後為 120 秒，則其平均偵知時間之計算方式為： $120/30=4$ ，即平均偵知時間為 4 秒。

本研究於模式初始操作時，將五個由 GFLC 建構之模式參數統一設定為：族群數=200，交配率=0.9，突變率=0.01，成熟率=80%， $e=0.01$ ，採用面積法來解模糊化。將此五個模式經過訓練及驗證後，再利用事件偵測績效評估指標：偵測率(DR)、誤報率

(FAR)和平均偵知時間(MTD)分別去評估其績效結果，如表 5.2 及表 5.3 所示。

表 5.2 五個模式之訓練結果

模式	偵測率(%)	誤報率(%)	平均偵知時間(sec)
流量模式	75.00	1.28	49.6
速度模式	96.67	0.97	19.6
佔有率模式	90.00	1.27	42.3
整合模式	96.67	1.19	15.1
主成份模式	100	1.29	13.7

表 5.3 驗證資料於五個模式之預測結果

模式	偵測率(%)	誤報率(%)	平均偵知時間(sec)
流量模式	73.33	3.97	63.0
速度模式	90.00	2.35	15.6
佔有率模式	80.00	0.50	60.0
整合模式	93.33	1.26	18.2
主成份模式	100	1.52	16.0

由表 5.2 及表 5.3 顯示，主成份模式不論在訓練組亦或是驗證組中皆可得到 100%之偵測率，而其誤報率及平均偵知時間也有相當不錯之績效。然流量模式、速度模式、佔有率模式與整合模式之誤報率及平均偵知時間則稍差，偵測率也不到 100%。因此，可判定主成份模式為此五個模式中最優良之模式。

5.3 模式參數分析及設定

由於基因演算法於整個演化過程中，隨著不同參數設定值，將可能會產生不同之尋優結果而影響整個尋優績效。因此，以下將針對主成份模式於基因演算法中之交配率、突變率等參數值進行調整(一般交配率設定為 0.8~0.9，突變率設定為 0.01~0.03)，嘗試找出較佳之參數設定值及尋優結果。主成份模式訓練組及驗證組之交配率與突變率等參數分析結果如表 5.4 及表 5.5 所示。

表 5.4 主成份模式訓練組之交配率與突變率之參數分析

交配率	突變率	偵測率(%)	誤報率(%)	平均偵知時間(sec)
0.7	0.01	98.33	1.42	19.2
	0.02	100	1.60	12.6
	0.03	100	0.78	11.6
0.8	0.01	100	0.97	12.6
	0.02	100	0.97	15.0
	0.03	100	1.21	12.3
0.9	0.01	100	1.29	13.7
	0.02	100	0.97	15.7
	0.03	100	1.24	14.3

表 5.5 主成份模式驗證組之交配率與突變率之參數分析

交配率	突變率	偵測率(%)	誤報率(%)	平均偵知時間(sec)
0.7	0.01	100	2.86	24.0
	0.02	100	1.30	20.0
	0.03	100	0.92	17.6
0.8	0.01	100	1.43	23.3
	0.02	100	1.55	18.0
	0.03	100	1.30	16.0
0.9	0.01	100	1.52	16.0
	0.02	100	1.03	25.3
	0.03	100	1.03	15.3

根據表 5.4 及表 5.5 主成份模式訓練組及驗證組之交配率與突變率等參數分析表中，可發現利用偵測率、誤報率及平均偵知時間三項績效指標予以評估後，結果顯示主成份模式於交配率為 0.7 及突變率為 0.03 之組合於模式訓練組及驗證組中，皆可得到 100% 之偵測率，而誤報率及平均偵知時間也最低，故以此組合為主成份模式參數之設定值。

5.4 學習結果分析

本研究將主成份模式經由參數敏感度分析後，將參數設定為族群數=200，交配率=0.7，突變率=0.03，成熟率=80%， $e=0.01$ ，採用面積法來解模糊化。由於模式輸出之結果為一 $[0,1]$ 間之連續變數，為能明確預測是否有事件發生。本文以 0.5 作為判斷門檻，輸出值大於 0.5 則預測有事件發生，小於 0.5 則預測無事件發生，以界定其事件發生與否。

由於模式於訓練及驗證過程中，茲將樣本資料分成 3 組分別去建構模式。因此，模式於訓練用以建立其預測模式後，將會產

生三組之最佳規則、隸屬函數參數及演化尋優過程。本研究將主成份模式經由訓練後所得之三組結果中，挑選其中一組呈現其最佳邏輯規則、隸屬函數參數及演化尋優過程，並分述如下。

1. 最佳邏輯規則其染色體為

54554244244155521244442543234545141431154545545555454
55555345510004105555555445555555430003312011555545535
5555555554545551454，於 125 條規則中共有 117 條規則入選。

2. 各語意變數之最佳隸屬函數如圖 5.4、圖 5.5、圖 5.6 及圖 5.7 所示。

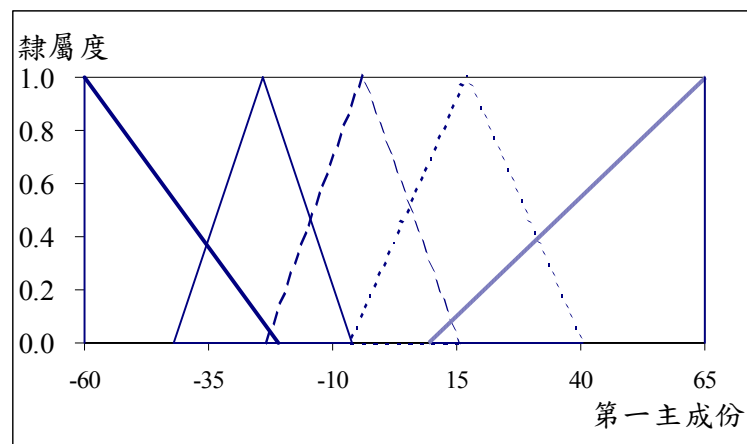


圖 5.4 第一主成份之最佳隸屬函數示意圖

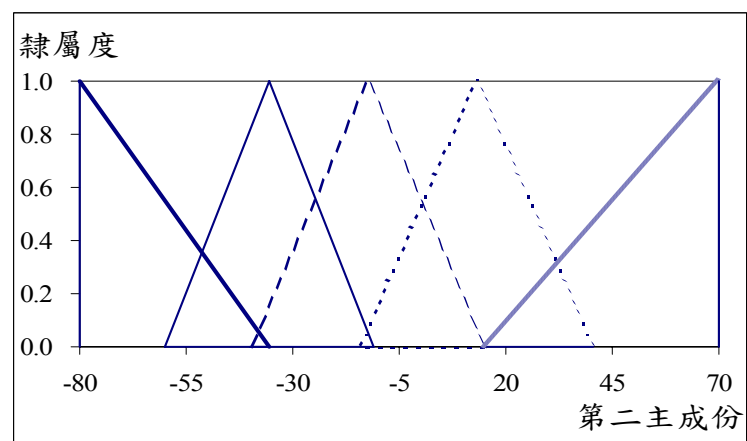


圖 5.5 第二主成份之最佳隸屬函數示意圖

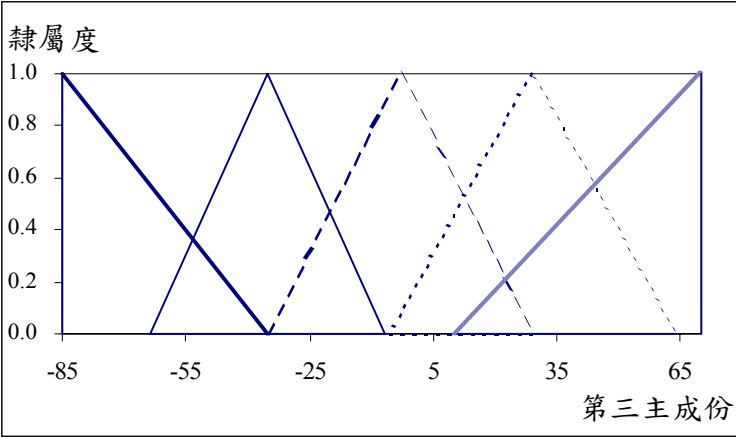


圖 5.6 第三主成份之最佳隸屬函數示意圖

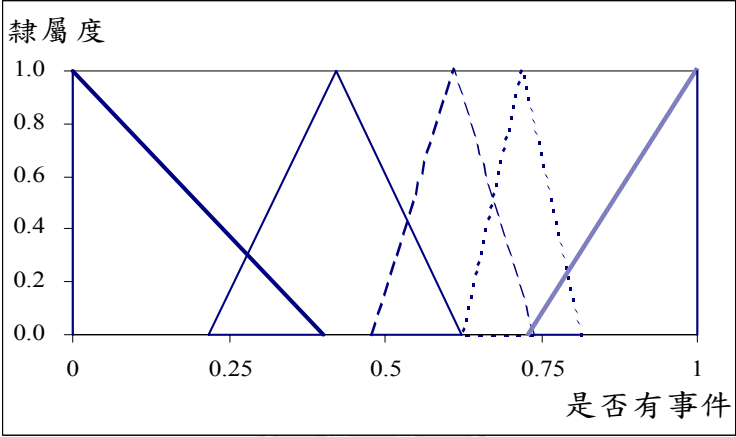


圖 5.7 是否有事件之最佳隸屬函數示意圖

3. 基因演算法演化尋優過程如圖 5.8 所示。

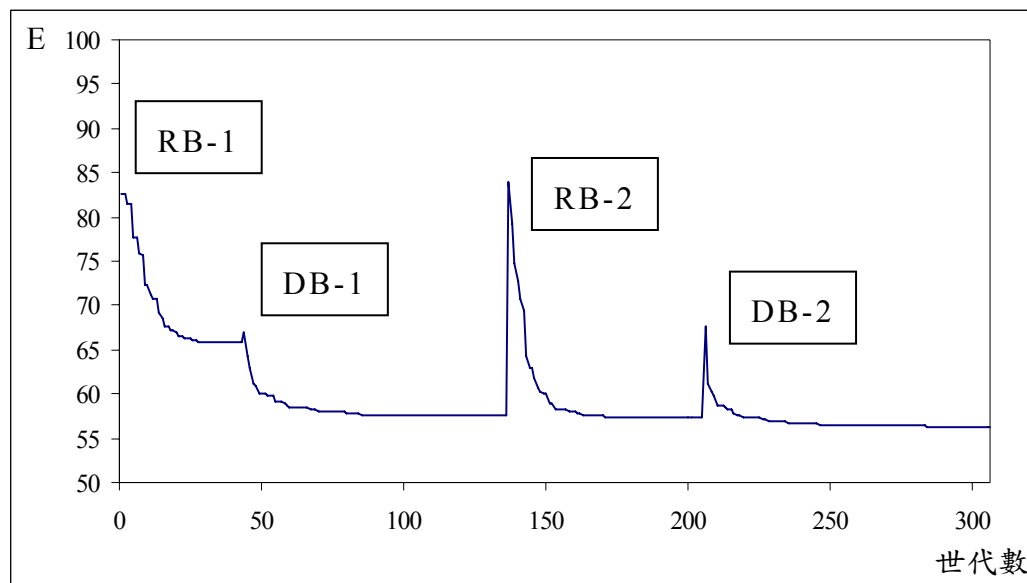


圖 5.8 GFLC 模式之演化尋優過程示意圖

圖註：RB-N 代表邏輯規則挑選第 N 次之尋優過程；DB-N 代表隸屬函數校估第 N 次之尋優過程。

本模式之學習演化結果顯示共經過兩次反覆運算得到最佳解(一次完整演化運算過程係 RB 加上 DB)，如圖 5.8 所示。即 RB-1 和 DB-1 為第一次尋優結果；RB-2 和 DB-2 為第二次尋優結果，經由兩次反覆運算，得到最佳邏輯規則及隸屬函數共經過 306 個世代之尋優過程。其中第 1~43 世代為 RB-1(最高值為 82.51，收斂值為 65.81)，第 44~136 世代為 DB-1(最高值為 67，收斂值為 57.48)，第 137~205 世代為 RB-2(最高值為 83.84，收斂值為 57.34)，第 206~306 世代為 DB-2(最高值為 67.11，收斂值為 56.33)，即事件發生與否之總誤差平方和，由最初之 82.51 收斂至最佳之 56.33。

此外，亦可發現其各別收斂值呈現一向右傾斜之趨勢，即第二次演化運算所得之最高值較第一次演化運算所得之值小，而其收斂值亦是如此，其原因係由於第一次演化中之 DB-1 是在 RB-1

之基礎下所求得之近似最佳解；而第二次演化中之 RB-2 是在 DB-1 之基礎下所求得之近似最佳解，以此方式類推尋得最佳之邏輯規則及隸屬函數參數。此外，如何確定模式經過兩次演化即停止，亦可由圖 5.8 觀測出第一次演化之 DB-1 與第二次演化之 DB-2 差異在本研究所設定之 0.01 內，故停止繼續反復演化，因而得到最佳邏輯規則 RB-2 及最佳隸屬函數參數 DB-2。



第六章 GFLC與ANN之比較

由於類神經網路(artificial neural network, ANN)演算法為目前道路事件偵測演算法中，最廣為應用並能得到相當不錯之績效結果之演算法。因此，本章節將以 ANN 演算法建構另一新事件偵測模式，再將基因模糊邏輯控制(GFLC)演算法與 ANN 演算法所分別建構之事件自動偵測模式，作進一步之比較分析，以驗證 GFLC 模式於事件偵測上之可行性。

6.1 ANN 之建構

倒傳遞網路(back-propagation network, BPN)是目前類神經網路學習模式中最具有代表性，其相關應用亦最為普及之網路模式。因此，本研究將以倒傳遞網路建構一新事件偵測模式。

ANN 架構中，其輸入層(Input Layer)之作用為接受外界之輸入訊號，再經由連結鏈將訊號傳至網路內部之隱藏層(Hidden Layer)。而隱藏層則是類神經網路運作之主要層次，其結構及數目將決定 ANN 之功能及能力。經由隱藏層運算之後，再將訊號傳至輸出層(Output Layer)以得到類神經網路對外界輸入訊號所產生之反應訊號。本研究所建構之 ANN 模式如圖 6.1 所示。

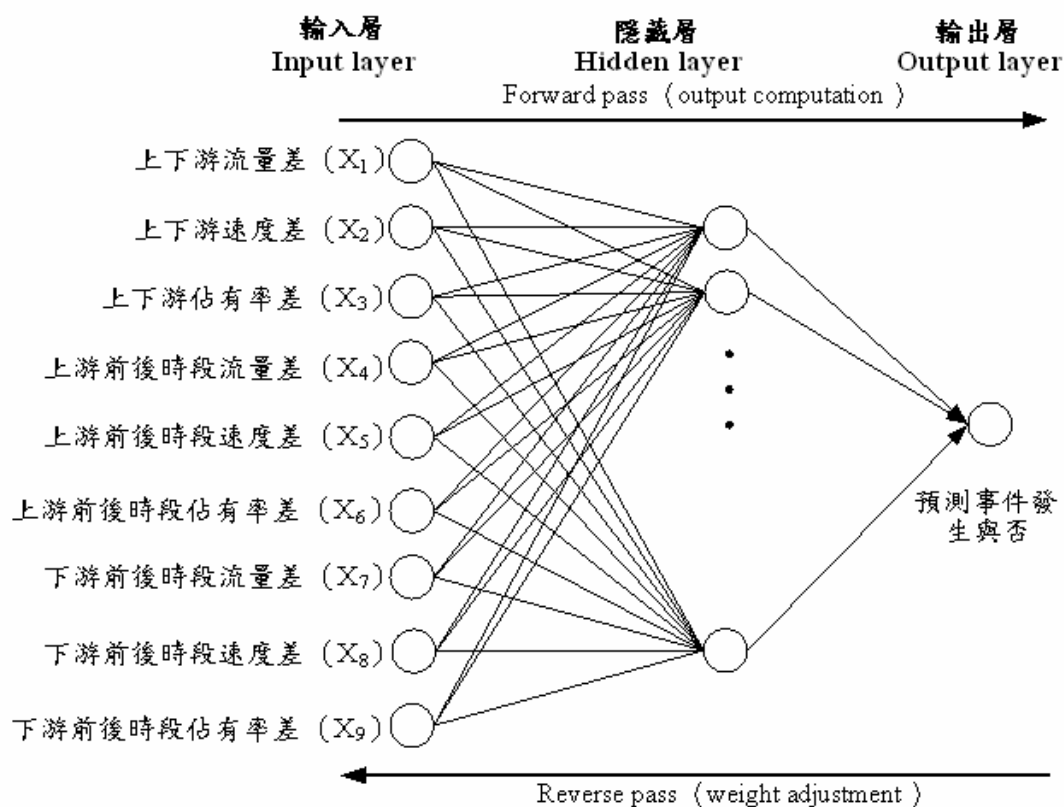


圖 6.1 ANN 模式之架構圖

6.2 ANN 模式之訓練及驗證

本研究於進行模式建構與驗證前，其資料樣本分類如同 5.1.2 節資料整理部份，首先將樣本資料分成三組，分別予以訓練以建立其預測模式，旋即將其結果加總平均得到訓練組之績效結果，最後再將分別建立之預測模式輸入驗證組資料，並以同樣計算方式予以驗證，以達建構兩組模式基礎資料之一致性。

惟 ANN 與 GFLC 之資料建構主要不同處為：ANN 模式可同時考量許多輸入變數，而 GFLC 之狀態變數則最多以三個為限制。因此，可將先前歸納而得之 9 組變數組合一次輸入至 ANN 模式中，再利用軟體 MATLAB6.5 所提供之環境配合撰寫程式，以進行事件偵測模式之建構與驗證，而其訓練與驗證結果將分述如下。

1. 模式之訓練

訓練 ANN 前，首先要進行網路訓練模式設定，如表 6.1 所示。三層之網路架構，主要包括輸入層、隱藏層及輸出層，至於隱藏層神經元個數之設定，並無可供依循之法則，本研究嘗試設定 5 個、10 個及 15 個三種不同數量之神經元個數，以期得到最佳之預測模式。

表 6.1 ANN 訓練模式之相關設定

網路相關參數設定	設定值
隱藏層數量	1 層
隱藏層節點數	分別為 5、10、15 個節點數
輸出層節點數	1 個
隱藏層轉換函數	對數雙彎曲轉換函數
輸出層轉換函數	線性轉換函數
學習演算法	Levenberg-Marquardt 演算法
設定訓練次數	3000 次
設定績效目標	10^{-6}

本研究將所整理之 30 個有事件樣本共 890 筆及 30 個無事件樣本共 773 筆資料，如同 GFLC 模式之資料建構方式，首先將資料分成三組分別予以訓練並建立其預測模式，再將其結果加總平均以得到訓練組之績效結果，並將各模式訓練後所得之預測結果與實際結果進行迴歸分析，以了解所訓練資料之實際值與訓練後預測值之相關性。另一方面，也分別將各模式訓練後所得之預測與實際結果利用事件偵測評估指標：偵測率(DR)、誤報率(FAR)及平均偵知時間(MTD)進行績效評估。若模式預測結果與實際值相差小於 0.5，則預測有事件發生，若相差大於 0.5，則預測無事件發生，用以界定事件發生與否。各模式之訓練結果如下表 6.2

所示。

表 6.2 ANN 模式之訓練結果

模式	誤差均方和	相關係數	偵測率 (%)	誤報率 (%)	平均偵知時間 (sec)
5 個隱藏 層節點	0.073	0.803	100	0.88	6.4
10 個隱藏 層節點	0.072	0.800	100	1.36	7.5
15 個隱藏 層節點	0.071	0.805	100	0.85	5.7

由表 6.2ANN 模式之訓練結果顯示，以 15 個隱藏層節點之模式所得到訓練結果與實際結果之誤差平方和 (MSE) 最低為 0.071，而透過迴歸分析所得之相關係數亦最高為 0.805。另外，在其所得到之績效結果顯示，偵測率為 100%、誤報率為 0.85%、偵知時間為 5.7 秒，為三個模式中最優良。故 15 個隱藏層節點之模式為此三個模式中最佳之訓練模式。

2. 模式之驗證

本研究再將分類好之三組驗證組資料（沒有以類神經網路訓練與學習之資料）輸入於訓練完成之各個網路模式，以了解透過訓練後各模式對於驗證資料之預測結果準確性。各模式之預測結果如表 6.3 所示。

表 6.3 驗證資料於各 ANN 模式之預測結果

模式	相關係數	偵測率 (%)	誤報率 (%)	平均偵知時間 (sec)
5 個隱藏 層節點	0.522	96.67	3.32	28.3
10 個隱藏 層節點	0.521	96.67	7.20	15.0
15 個隱藏 層節點	0.528	96.67	1.43	16.0

由表 6.3 ANN 模式之預測結果顯示，以 15 個隱藏層節點之模式透過迴歸分析所得之預測結果與實際結果之相關係數最高為 0.528。另外，其所得之績效結果中，偵測率為 96%、誤報率為 1.43%、偵知時間為 16 秒為最佳。因此，15 個隱藏層節點之模式為 ANN 之最佳預測模式。

6.3 GFLC 與 ANN 之比較分析

根據 GFLC 所建構之流量、速度、佔有率、整合及主成份五個模式之績效結果顯示，主成份模式無論在建構抑或驗證結果中，皆可得到相當優良之事件偵測績效。惟此五個模式皆由 GFLC 所建構之模式，無足以驗證本模式之可行性。因此，本研究最後納入廣為應用之 ANN 模式，以相同之資料結構為基礎，建構另一事件自動偵測模式並與本模式作進一步之比較分析，以驗證 GFLC 事件偵測模式之可行性。GFLC 及 ANN 兩模式經過訓練及驗證後之績效結果如下表 6.4 及表 6.5 所示。

表 6.4 GFLC 及 ANN 之訓練結果評比表

模式	偵測率 (%)	誤報率 (%)	平均偵知時間 (sec)
GFLC 之主成份模式	100	0.78	11.6
類神經網路模式	100	0.85	5.7

表 6.5 驗證資料經 GFLC 及 ANN 之預測結果評比表

模式	偵測率 (%)	誤報率 (%)	平均偵知時間 (sec)
GFLC 之主成份模式	100	0.92	17.6
類神經網路模式	96.67	1.43	16.0

經由表 6.4 及表 6.5 之結果顯示，GNN 模式於績效指標平均偵知時間較 GFLC 模式優良外，偵測率及誤報率則以 GFLC 所建構之主成份模式不論在訓練抑或預測結果，皆較 ANN 模式優良。綜上所述，GFLC 經由主成份法所建構之事件自動偵測模式可得到相當不錯之績效結果，可驗證其可行性。

第七章 結論與建議

本研究旨在利用基因模糊邏輯控制(GFLC)建構一高速公路之事件自動偵測系統，除能透過模糊理論處理資訊之不確定因素外，尚可利用基因演算法採用反覆演化之方式，搜尋最佳之邏輯規則及隸屬函數參數組合以建構本模式，期使事件偵測績效達到最佳。其績效評估指標主要是利用偵測率(DR)、誤報率(FAR)與平均偵知時間(MTD)，來評估模式應用於高速公路事件自動偵測之績效。最後，再將 GFLC 與 ANN 分別建構之事件自動偵測模式，作進一步之比較分析，以驗證 GFLC 模式於事件偵測上之可行性。依據本研究之結果，得到以下幾點之結論及建議。

7.1 結論

1. 本研究旨在以實際事件資料及偵測器測得之交通資料為基礎，利用基因模糊邏輯控制(GFLC)建構一高速公路之事件自動偵測模式，以避免以往依據車流模擬產生事件資料所建構之事件自動偵測模式於實際應用時，可能產生落差之問題。
2. 本研究之資料來源主要為高公局中區交通控制中心，取得每 20 秒一筆記錄之交通參數資料，其取樣時間較短，不同以往文獻資料為每 5 分鐘或每 1 分鐘一筆記錄之交通資料，可能不夠精細及連貫。
3. 在建構 GFLC 之事件模式上，由於潛在邏輯規則及隸屬函數校估參數之數量會隨著狀態變數之增加而大幅提升。故一般在應用上，狀態變數之個數大多限制在三個以下。本研究除了建構流量模式、速度模式、佔有率模式及整合模式外，更進一步建構主成份模式，其利用主成份分析法能將變數經線性組合轉換成新的變項(主成份)，能有效解決 GFLC 之狀態變數最多三個之限制，以提高事件偵測之績效。
4. 本研究利用 GFLC 建構之流量、速度、佔有率、整合及主成份

共五個模式，分別經過訓練及驗證後，以事件偵測績效指標：偵測率、誤報率和平均偵知時間，分別去評估其績效結果，得到主成份模式可達到 100% 之偵測率，而其誤報率及平均偵知時間也相當低。故其績效結果相當優良。

5. 本研究就 GFLC 所建構之模式中，主成份模式變數之選取方式是將 9 組變數皆納入模式中予以考量，其所得之績效結果相當不錯亦優於其它僅以三組變數作為考量之 GFLC 模式。此發現有別於以往之研究，可能僅使用一個或少數幾個變數就足以偵測事件之發生。
6. 本研究最後納入廣為應用並可得到相當不錯績效之類神經網路(ANN)所建構之事件偵測模式，並進一步與 GFLC 所建構之事件偵測模式作一評比。結果得到 GFLC 所建構之主成份模式除了平均偵知時間較 ANN 模式高外，偵測率及誤報率不論在訓練結果或是預測結果皆較 ANN 優良。因此，可驗證 GFLC 於事件自動偵測上之可行性。

7.2 建議

1. 本研究於 GFLC 之模式中，對於狀態變數與控制變數之隸屬函數參數極小、大值之設定問題，主要是採主觀之方式設定，並無一套設計準則可供依循，此一部分仍有待日後進一步研究探討。
2. 本研究之 GFLC 模式，乃是採用反覆演化之方式得到最佳邏輯規則及最佳隸屬函數參數，建議未來研究可建立同時尋優之 GFLC 模式，以避免反覆求解可能導致之狀況解問題。
3. 利用 GAs 建構 FLC 系統之績效已獲相當研究驗證，惟本研究利用 GFLC 所建立之模式，主要是採用三個狀態變數及一個控制變數，所需尋優時間稍長，建議後續研究可進一步研擬更有效率之編解碼方式或尋優技巧，以克服此一問題。
4. 礙於本研究之樣本數有限，因此無法針對事件型態、事件嚴重性、事件位置及不同流量組合情況下，對於事件偵測績效

之影響，尚有待日後作進一步之研析。

5. 由於無論是那一種事件偵測模式，均需奠基於正確之交通資訊，方能成功。惟目前所使用之車輛偵測器，無論是環狀線圈、紅外線、微波或影像辨識，均存有相當程度之誤差，在無法克服此一技術問題前，未來或可考慮建立一套交通偵測資料之調校模式，以產生更可信、精確之交通資訊，以利事件自動偵測系統之落實應用。
6. 礙於國內事件之資料來源，主要為用路人或國道警察所通報，而所記載之時間為通報時間並非實際發生時間，故事件資料與實際發生時間難免有所出入。因此，如何蒐集更為正確之事件資料及其所對應之交通資料，值得未來作進一步之研究探討。



參考文獻

1. 中文部分

- 【1】 王秀帆，民 92 年，「應用灰色預測於高速公路事件自動偵測之研究」，國立中央大學土木工程學所碩士論文。
- 【2】 王雲慶，民 94 年，「應用基因模糊邏輯建構適應性匝道儀控系统」，逢甲大學交通工程與管理學系碩士班碩士論文。
- 【3】 方守傑，民 93 年，「鑑定專家系統之建構與驗證」，逢甲大學交通工程與管理學系碩士班碩士論文。
- 【4】 周義華、許鉅秉、李啟仲，民 89 年，「高速公路事故屬性即時自動鑑別之方法研究」，運輸計劃季刊，第二十九卷第三期， pp.499~528。
- 【5】 邱裕鈞、藍武王，民 90 年，「應用遺傳演算法建構適應性模糊邏輯控制系統—以跟車行為為例」，中華民國運輸學會第 16 屆學術論文研討會，第 515-526 頁。
- 【6】 侯鈞元，民 91 年，「應用羅吉特模式於市區道路事故偵測系統」，國立成功大學交通管理科學研究所碩士論文。
- 【7】 楊雨青，民 88 年，「高速公路事件偵測與匝道儀控整合模式之研究-類神經網路之應用」，國立成功大學碩士論文。
- 【8】 黃振賢，民 81 年，「高速公路事件自動偵測方法之研究」，國立中央大學土木工程學所碩士論文。
- 【9】 曾信忠，民 82 年，「模糊理論應用於高速公路事件自動偵測之研究」，國立中央大學土木工程學所碩士論文。
- 【10】 馮正民、邱裕鈞，民 93 年，「研究分析方法」，建都文化

事業股份有限公司。

- 【11】 彭國倫，民 90 年，「Fortran 95 程式設計」，基峰資訊股份有限公司。
- 【12】 葉源祥，民 84 年，「高速公路事件偵測之微觀車流參數法」，國立台灣大學土木工程學研究所碩士論文。
- 【13】 賴建華，民 92 年，「適應性基因模糊邏輯號誌控制系統」，國立交通大學交通運輸研究所碩士論文。
- 【14】 魏健宏、黃國平、陳昭宏，民 85 年，「應用人工神經網路發展高速公路意外事件自動偵測模式」，運輸計劃季刊，第二十五卷第二期，pp.209~234。

2. 英文部分

- 【1】 Ai-Deek, H.M., Ishak, S.S. and Khan, A.A., “Impact of freeway geometric and incident characteristics on incident detection,” Journal of Transportation Engineering, Vol.122, No.6, pp.440-446, 1996.
- 【2】 Adeli, H. and Karim, A., “Fuzzy-wavelet RBFNN model for freeway incident detection,” Journal of Transportation Engineering, Vol.126, No.6, pp.464-471, 2000.
- 【3】 Abdulhai, B. and Ritchie, S.G., “Enhancing the universality and transferability of freeway incident detection using a Bayesian-based neural network” Transportation Research Part C7, pp261-280, 1999.
- 【4】 Cheu, R.L. and Ritchie, S.G., “Automatic Detection of Lane-Blocking Freeway Incident Using Artificial Neural Networks”, Transportation Research Part C, Vol.3 , NO.6, pp.371-388, 1995.

- 【5】 Chan, P.T., Xie, W.F. and Rad, A.B., “Tuning of fuzzy controller for an open-loop unstable system: a genetic approach” Fuzzy Sets and Systems, 111, pp.137-152, 2000.
- 【6】 Chiou, Y.C. and Lan, L.W., “Genetic fuzzy logic controller: An iterative evolutionary algorithm with new encoding method,” Fuzzy Sets and Systems, Vol.152, Issue 3, pp.617-635, 2005.
- 【7】 Dia, H. and Rose, G., “Development and evaluation of neural network freeway incident detection models using field data,” Transportation Research Part C , Vol.5 , No.5 , pp.313-331, 1997.
- 【8】 Homaifar, A. and McCormick, E., “Simultaneous design of membership functions and rule sets for fuzzy controllers using genetic algorithms” IEEE Transactions on fuzzy systems, Vol.3, No.2, pp.129-139, 1995.
- 【9】 Ishak, S. and Al-Deek H., “Performance of automatic ANN-Based incident detection on freeways” Journal of Transportation Engineering, Vol.125, No. 4, pp.281-290, 1999.
- 【10】 Khan, S.I. and Ritchie, S.G., “Statistical and neural classifiers to detect traffic operational problems on urban arterials” Transportation Research Part C6 pp.291-314, 1998.
- 【11】 Karim, A. and Adeli, H., “Comparison of fuzzy-wavelet radial basis function neural network freeway incident detection model with California algorithm” Journal of Transportation Engineering, Vol.128, No. 1, pp.21-30, 2002.

- 【12】 Khoury, J.A., Haas, C.T., Mahmassani, H., Logman, H. and Rioux, T., “Performance caparison of Automatic vehicle identification and inductive loop traffic detectors for incident detection” Journal of Transportation Engineering, Vol.129, No. 6, pp.600-607, 2003.
- 【13】 Lan, L.W. and Huang, Y.C., “A rolling-trained fuzzy neural network (RTFNN) approach for freeway incident detections”, 2005.
- 【14】 Mak, C.L. and Henry S.L., “Transferability of expressway incident detection algorithms to Singapore and Melbourne” Journal of Transportation Engineering, Vol.131, No. 2, pp.101-111, 2005.
- 【15】 Shieh, C.S., “Genetic fuzzy control for time-varying delayed uncertain systems with a robust stability,” Applied Mathematics and Computation, 131, pp.39-58, 2002.
- 【16】 Sheu, J.B., “A fuzzy clustering –based approach to automatic freeway incident detection and characterization” Fuzzy Sets and Systems, 128, pp.377-388, 2002.
- 【17】 Thrift, P., “Fuzzy logic synthesis with genetic algorithms,” Proceeding of the Fourth International Conference on Genetic Algorithms, pp.509-513, 1991.
- 【18】 Xiong, N. and Litz, L., “Reduction of fuzzy control rules by mans of premise learning-method and case study,” Fuzzy sets and systems, 132, pp.217-231, 2002.