

國立成功大學
交通管理科學研究所
碩士論文

高速公路旅行時間預測模式之研究-
類神經網路之應用

研 究 生：林 士 傑
指導教授：魏健宏 博士

中 華 民 國 九 十 年 六 月

摘 要

由於台灣地區車輛持有比率逐年增加，加上路網日趨複雜，因此對於旅次所衍生的不確定性亦相對提高。目前中山高仍未有相關單位提供旅行時間資訊以協助用路人作為路線選擇與管理單位制訂策略上的依據，徒增旅行時間與成本，亦降低了運輸系統的效率。本研究欲整合中華顧問工程司交通千里眼(E-traffic)所提供之即時交通播報資訊（如事件、施工、車輛偵測器等），再加上高速公路幾何、交通量調查與客運車輛 GPS 等資料，盡可能地呈現出真實的行車環境，並運用類神經網路準確預測高速公路旅行時間，提供用路人參考以降低不確定性。

模式基本構想是以北部區域路段為研究範圍、主要都市交流道為預測對象。有鑑於道路使用者之起迄點不同，若要個別發展單獨的預測模式，模式數量將會過多且應用上亦過於複雜。故本研究將研究範圍分成數個群組、構建多個預測模式，且範例資料考慮實際應用上之未來時間概念，爾後分別進行類神經網路之訓練與測試工作，以評選績效較佳的模式。最後，實證分析發現所採用的 4 種分析指標中，以 ANN6 模式最為穩定且預測能力佳。在未來發展上，旅行時間預測所提供之交通資訊亦可與電子地圖、即時資訊等先進用路人系統(ATIS)相互結合，有著無可限量的商機。

關鍵詞：不確定性、旅行時間、類神經網路、群組、未來時間概念

ABSTRACT

Due to the increasing amount of vehicle and the complex road networks, the uncertainty of trip is raising year by year. However, the information about travel time on freeway is not yet offered to help drivers to choose route and to the management authorities to make strategy, and it give rise to the loss of time and cost and lower the efficiency of transportation system. This research contains the real time traffic informations (e.g., accidents, construction and vehicle detector informations) from the E-traffic of the China Engineering Consultants, Inc.. Furthermore, it also contains the informations of freeway geometry, traffic investigation and the GPS data of passenger transport vehicle. This research can offer the information from the reappearance of the real driving environment. It also apply ANN to forecast the travel time on freeway precisely to help travelers to reduce uncertainty.

The basic conception of this model is defined the range of research on the northern region, and the forecasting target is the intersections of main city. Because of the different origin and destination of travelers, there will be too many models to apply if we establish a single forecasting model. Therefore, this research will divide the range of research into several groups, build several models. The data set will be considered the “future time”concept of real application on-line. Then we implemented ANN training and testing individually to evaluate the more efficient model. Finally, we find that the ANN6 model is the stablest one and has the better ability in forecasting under the four analytical indexes. The traffic informations provided by the travel time forecasting can be integrated with ATIS for electric traffic map and real time informations, It would have many business opportunities in the future development.

Keywords: Uncertainty, Travel Time, Artificial Neural Network, Group, Future Time Concept

目 錄

第一章 緒論.....	1
1.1 研究背景與動機.....	1
1.2 研究目的.....	3
1.3 研究範圍與限制.....	5
1.4 研究內容與方法.....	6
1.5 研究流程.....	9
第二章 文獻回顧	10
2.1 旅行時間相關文獻.....	10
2.1.1 公車之旅行時間預測方面.....	11
2.1.2 都市幹道旅行時間預測.....	12
2.1.3 快速道路、高速公路旅行時間預測.....	13
2.2 類神經網路.....	16
2.2.1 類神經網路於交通領域之應用.....	17
2.2.2 類神經網路於旅行時間預測之應用.....	18
2.3 相關研究文獻.....	20
2.3.1 交通擁擠推論.....	20
2.3.2 相關預測技術.....	21
2.3.3 資料融合.....	23
2.3.4 路徑導引.....	24
2.4 國內外執行計劃.....	26
2.4.1 國內高速公路智慧化之兩年行動方案.....	26
2.4.2 國外方面.....	29
第三章 模式理論	31
3.1 類神經網路.....	31
3.1.1 類神經網路分類與網路架構.....	31
3.1.2 倒傳遞網路.....	33
3.2 旅行時間預測模式之網路架構.....	36
3.2.1 資料蒐集與處理.....	36
3.2.2 旅行時間預測模式之網路架構.....	39
第四章 資料分析	42
4.1 資料分析流程與說明.....	42
4.1.1 資料處理流程圖.....	46

4.1.2 資料來源處理流程說明.....	47
4.2 資料特性.....	49
4.2.1 高速公路幾何資料.....	49
4.2.2 交通量資料.....	54
4.2.3 車輛偵測器(VD)資料	57
4.2.4 事件(Event)資料.....	59
4.2.5 客運車輛 GPS 資料	61
4.3 資料分析.....	66
4.3.1 不同資料來源間關係.....	66
4.3.2 資料庫特性.....	66
第五章 模式構建與網路績效評估.....	68
5.1 模式構建.....	68
5.1.1 構建之類神經網路類型.....	68
5.1.2 訓練與測試範例製作.....	79
5.1.3 預測模式之群組路段.....	83
5.2 網路訓練與測試工作.....	84
5.2.1 網路訓練步驟.....	84
5.2.2 各網路輸入變數.....	84
5.3 網路績效評估.....	85
5.3.1 估計指標.....	85
5.3.2 網路績效.....	87
5.3.3 實證分析網路之評選.....	97
第六章 實證結果分析.....	102
6.1 驗證程序.....	102
6.2 實證資料分析.....	104
6.3 實證分析.....	108
第七章 結論與建議.....	115
7.1 結論.....	115
7.2 建議.....	117
參考文獻	118

圖目錄

圖 1-1 高速公路近年交通量	1
圖 1-2 研究流程圖	9
圖 2-1 旅行時間推估之最長距離	14
圖 3-1 基本之倒傳遞網路架構圖	34
圖 3-2 交通千里眼北部區域路段交通狀況（依顏色區別）	38
圖 3-3 旅行時間預測之類神經網路模式架構圖-依時間概念	40
圖 3-4 旅行時間預測之類神經網路模式架構圖-依資料來源概念	41
圖 4-1 本研究各資料來源處理流程	46
圖 4-2 車輛偵測器(VD)與事件資料資料處理流程	47
圖 4-3 原始 GPS 資料處理流程圖	48
圖 4-4 國道北區路網及設施位置示意圖	50
圖 4-5 11/27(一)事件等級比率	60
圖 4-6 12/2(六)事件等級比率	60
圖 4-7 1127(一)各等級事件之南北方向比率	61
圖 4-8 1129(三)各等級事件持續時間	61
圖 4-9 GPS 各日台北-新竹旅行時間	62
圖 4-10 客運車輛各群組平均旅行時間	62
圖 4-11 客運車輛各群組各車輛(依車輛編號)旅行時間(全部群組)	63
圖 4-12 客運車輛各群組各車輛(依車輛編號)旅行時間(群組時間長)	63
圖 4-13 客運車輛各群組各車輛(依車輛編號)旅行時間(群組時間短)	64
圖 4-14 群組 1、群組 2 客運車輛旅行時間次數分配圖	65
圖 4-15 群組 3、群組 4 客運車輛旅行時間次數分配圖	65
圖 4-16 群組 5、群組 6 客運車輛旅行時間次數分配圖	65
圖 4-17 群組 7、群組 8 客運車輛旅行時間次數分配圖	65
圖 5-1 NeuralWorks Professional II/Plus (NW2) 軟體介面	69
圖 5-2 上下游路段與事件關係	71
圖 5-3 上下游群組路段交通特性關連性	72
圖 5-4 本研究模式構建與績效評估流程圖	78
圖 5-5 各群組路段 ANN 範例製作流程圖	80
圖 5-6 未來時間概念資料範例之衍生步驟-ANN52	81
圖 5-7 各群組路段範例製作概念-ANN52	82
圖 5-8 輸入資料考量未來概念特性-納入旅行時間估計值	83
圖 5-9 各群組最佳模式之 MAPE 值	97
圖 5-10 各群組之平均實際旅行時間值	97
圖 5-11 群組 1 之實際旅行時間值與網路估計值	99
圖 5-12 群組 2 之實際旅行時間值與網路估計值	99

圖 5-13 群組 3 之實際旅行時間值與網路估計值	99
圖 5-14 群組 4 之實際旅行時間值與網路估計值	100
圖 5-15 群組 5 之實際旅行時間值與網路估計值	100
圖 5-16 群組 6 之實際旅行時間值與網路估計值	100
圖 5-17 群組 7 之實際旅行時間值與網路估計值	101
圖 5-18 群組 8 之實際旅行時間值與網路估計值	101
圖 6-1 實證分析示意圖	102
圖 6-2 群組 7 (1 個路段) 次數分配圖	104
圖 6-3 群組 7-6 (2 個路段) 次數分配圖	105
圖 6-4 群組 7-5 (3 個路段) 次數分配圖	105
圖 6-5 群組 7-4 (4 個路段) 次數分配圖	106
圖 6-6 群組 7-3 (5 個路段) 次數分配圖	106
圖 6-7 群組 7-2 (6 個路段) 次數分配圖	107
圖 6-8 群組 7-1 (7 個路段) 次數分配圖	107
圖 6-9 實證指標-平均每車誤差(Error)	111
圖 6-10 實證指標-平均每車誤差之絕對值(Error)	112
圖 6-11 實證指標-平均誤差率(MPE)	113
圖 6-12 實證指標-平均絕對誤差百分比(MAPE)	114

表目錄

表 1-1 歷年通過收費站交通量	5
表 2-1 類神經網路於預測課題上之應用	18
表 2-2 整合分析演算法融合階段	24
表 2-3 高速公路智慧化兩年行動方案預計完成目標與時程表	27
表 3-1 類神經網路之主要應用	32
表 3-2 各種常用類神經網路的特點對照表	33
表 3-3 倒傳遞網路之優缺點	36
表 3-4 國道一號/中山高速公路 (南下) 即時路況資訊	38
表 3-5 資料更新時間之影響	39
表 4-1 車輛偵測器 (北部路網) 建置分類數量表	42
表 4-2 研究範圍路段各預測模式起迄群組別	45
表 4-3 客運車輛時間轉換成一天累積秒數	49
表 4-4 收費站各車種車道數與車道容量	50
表 4-5 北區交流道	52

表 4-6 所蒐集之交通量資料 (附錄六)	54
表 4-7 北上方向一般日主線上午尖峰時段流量	54
表 4-8 北上方向一般日主線下午尖峰時段流量	55
表 4-9 北上方向一般日主線非尖峰時段流量	55
表 4-10 本研究範圍各北上交流道之交通量特性	57
表 4-11 中華顧問之事件分類種類	59
表 4-12 客運車輛各群組旅行時間 (往北方向)	62
表 5-1 本研究所建構之類神經網路模式	73
表 5-2 時空類神經網路所考量之輸入變數	77
表 5-3 本研究群組別	83
表 5-4 MAPE 的評估標準	86
表 5-5 本研究「群組 1 三重-台北」之各類型網路績效	88
表 5-6 本研究「群組 2 五股-三重」之各類型網路績效	89
表 5-7 本研究「群組 3 桃園-五股」之各類型網路績效	90
表 5-8 本研究「群組 4 機場桃園半處-桃園」之各類型網路績效	91
表 5-9 本研究「群組 5 機場-機場桃園半處」之各類型網路績效	92
表 5-10 本研究「群組 6 幼獅-機場」之各類型網路績效	93
表 5-11 本研究「群組 7 楊梅-幼獅」之各類型網路績效	94
表 5-12 本研究「群組 8 新竹-楊梅」之各類型網路績效	95
表 5-13 各群組路段選取之最佳網路模式、架構與績效	96
表 5-14 群組別之網路績效排名	98
表 6-1 實證分析之樣本數(各起迄)	103
表 6-2 實證分析-實證模式於各群組之最佳架構	104
表 6-3 實證指標-平均每車之實際值與估計值	109
表 6-4 實證指標-平均每車誤差(Error)	110
表 6-5 實證指標-平均每車誤差之絕對值(Error)	111
表 6-6 實證指標-平均誤差率(MPE)	112
表 6-7 實證指標-平均絕對誤差百分比(MAPE)	113
表 6-8 各群組數建議之類神經網路模式	114

第一章 緒論

1.1 研究背景與動機

中山高速公路自民國 67 年通車以來，由於服務水準較一般公路高出甚多，具有省時、便利，且較為舒適安全之特性，因此隨著經濟蓬勃發展，與民眾生活密不可分，儼然成為西部走廊南北交通運輸的大動脈。根據統計，高速公路分擔了台灣地區西部走廊 55 % 的交通量，且依據高速公路所統計的 1999 年年平均日交通量約為 119 萬輛次（約 140 萬小客車當量數）【國道高公局，2000】來看，為設計服務流量之 1.37 倍，每年更約有 4 % ~ 5 % 的成長（圖 1-1）【高速公路年報，民 88 年】，行車交通不但日益擁擠，交通問題亦相對顯得複雜許多，大眾對於交通服務品質的要求不斷提高，因此如何在交通急遽增加的情況下，提供更安全、便捷、有效率的行車環境更顯得格外重要。




圖 1-1 高速公路近年交通量

台灣地區之高速公路除了作為城際運輸用途之外，對於都會區亦具快速道路功能，故其交通量在部分時段及路段已大於原設計服務水準之下之道路設計服務流量，造成用路人在高速公路行駛時間益形增加，連續假期與上下班尖峰時間尤甚。

高速公路之所以會發生交通壅塞的原因有：(1) 重現性擁擠與 (2)

非重現性擁擠。所謂重現性擁擠(recurrent congestion)係指車流的壅塞情形為週期性方式產生，例如每日上下午尖峰及年節前後的大量車流，假日部分區段之方向性車流等均屬之，原因多為超負載、幾何瓶頸因素。道路建設甚難以適應最大交通需求進行設計，而須考量整體經濟效益，以每日量負荷為思考，針對重現性交通問題則需以交通管理或需求管理手段來進行緩和，以提昇其安全與減輕壅塞之情形。除了上述的經常性擁擠問題有賴適當的處理之外，高速公路上亦常會有因突發事故（車禍發生）或可預期事件（如天候不佳）造成局部性路段之突發性壅塞，此一意外現象會降低道路容量與其通行效率，並甚而引發更為嚴重之二次交通事故連鎖反應，稱為非重現性擁擠(non-recurrent congestion)。此有賴交通管理機構在事前擬定應變措施，事件發生時即時偵測及反應作出適當處置。

由於台灣車輛持有比率逐年增加，交通問題更顯複雜許多，所衍生出的不確定性(Uncertainty)亦相對提高。再者，運輸建設方案執行速度永遠不及交通需求之膨脹，因此為了改善現有交通問題，在觀念與作法上已逐漸由增加道路容量的供給方式，轉變成有效利用現有資源與交通設施的管理措施；隨著科技的進步，高速公路利用電腦、電子、通訊、控制、整合等技術，配合交通管理與控制策略，以提昇運輸系統整體效能，以發展高速公路智慧化。

近來智慧型運輸系統(Intelligent Transportation System, ITS)在運輸領域上蓬勃發展，而先進旅行者資訊系統(Advanced Traveler Information System, ATIS)即為 ITS 中的一子系統，為的是將不同來源之交通參數資料作整合，期能提供用路人即時或預測交通資訊，以降低在旅次發生時之不確定性。因此如何準確地預測旅行時間亦為 ATIS 應用中一關鍵課題，協助旅行者在行前規劃、管理單位在策略制訂上的工作。

為促使高速公路用路人行旅之便利，台灣地區近年來陸續完成許多高快速道路，在安全第一的前提下，增進高速公路系統之運作效率，使得高速公路之管理工作亦顯得複雜許多。然而路網形成後，運輸系統管理與控制措施也就日益重要，對於用路人而言，行駛至目的地的選擇增加，如何運用有效方法，準確地預測旅行時間，並即時(real-time)顯示於相關資訊系統，以協助駕駛者作為路線選擇之依據，將對行旅大眾有極大助益，進而

改善運輸系統之服務水準。

旅行時間的預測即為利用交通參數資料所創造出的附加價值，使得運輸行為之不確定性降低、交通資訊更為透明化，提供輔助的決策資訊，以減少無謂的時間與成本。準確的旅行時間預測對於用路人裨益大，因此擁有此項專利技術之服務業者將會在提供旅行時間廠商中，扮演一舉足輕重的地位。未來準確之旅行時間預測交通資訊服務，更可與交通電子地圖、即時資訊、先進偵測技術等擴充功能相互結合，提供如旅行時間地圖、替代道路、路徑導引之交通服務。對於預測旅行時間之課題而言，所構建模式之預測能力、個人化的服務與所涵蓋的範圍乃是交通資訊服務提供業者利基與吸引旅行者使用的主要關鍵因素。

1.2 研究目的

就本研究而言，首先我們必須要瞭解到高速公路旅行時間預測之功用為何，在一套有效的預測方法下，如何善用此一資訊，使得運輸系統發揮其應有效率。針對旅行時間預測所能結合之相關運輸課題深入思考，以得知其未來發展前景，並可作為不同系統間連結之要件。高速公路旅行時間可應用於：

先進用路人資訊系統(ATIS)之相關技術有：可變資訊標誌、地理資訊系統、自動車輛辨識、車內顯示系統、最佳路線導引、車與中心雙向無線電通訊、防碰警示系統、收音機/電視廣播、電話查詢、旅行服務資訊等。ATIS 為 ITS 中運作靈魂，用路人的行為會隨著國情的不同有極大的差異，應該加以著手研究，由其整合其他各項的功能。

在長期路網計劃之運輸需求分析中，運輸需求為一種引申需求，為了解釋居民在當地活動的旅次行為，傳統的運輸規劃系統(UTPS)把人的旅次分為四個步驟來分析，人是否要從事這行為？-旅次產生、當決定要從事此一旅次時，他會去哪裡？-旅次分佈、他會搭何種運輸工具？-運量分配、經過哪些路線才會抵達？-交通量指派。一般交通量指派，是利用前三項預測結果，轉換得到各交通區間的尖峰小時車旅次，將這些車旅次輸入實際

的運輸路網模擬車流狀況中，可以推估得到路網上每一路段的交通量與旅行時間，或大眾運輸路線上的乘客數【張有恆，民 82 年】。經交通量指派後，即可分析運輸供給與需求是否互相配合，因此交通量指派的結果，可以用來決定道路改善、路網設計或大眾運輸路線之依據。此外，一般道路交通量指派的方法中，最短路徑之選擇皆為重要依據，因此本研究所發展之旅行時間預測方法則可作為協助交通量指派工作上的參考。

在智慧化交通監測、需求預測與管理方面之研究【國道高公局，2000 年】：主要係透過交通資訊蒐集、交通狀況（量、特性）預測及交通管理策略執行，並將結果傳送至 ITS 各系統，以發揮最佳功能。內容如建立車流模式、交通量指派工作、路網績效評估與控制策略之研擬原則、路線導引模式與駕駛人行為分析。

在路徑導引中，由於現今路網趨於完整，提供用路人更多的路線選擇機會，因此若能採用有效的引導策略，將資訊及時、正確地提供給用路人，定能使公路系統發揮最大效用。有鑑於此，本研究乃採用類神經網路 (Artificial Neural Network, ANN) 來構建一高速公路旅行時間預測模式，以提供路線導引策略實施時之參考。

具體而言，本研究欲採用類神經網路發展高速公路旅行時間之預測模式，期能藉由類神經網路的強大資料處理功能，以達成準確預測的目標。本研究主要目標有：

1. 利用類神經網路(ANN)來建立一準確之旅行時間預測模式，以期能配合其它運輸之相關課題。(CH.5)
2. 探討類神經網路之特性與其資料彙整處理之功能。(CH.5)
3. 利用所蒐集到的實際資料來觀察高速公路運行情況與評估旅行時間預測之績效。(CH.4、CH.6)
4. 探討如何整合多種來源之交通資訊，以有效地即時運用於預測模式中。(CH.5)
5. 提供高速公路用路者又快、又準確之旅行時間預測，降低旅客

之不確定性與額外成本等負面效應。

1.3 研究範圍與限制

本研究所建構之類神經網路預測模式，乃是利用各資料來源所蒐集到的交通參數資料與幾何資料等來作為網路的訓練，以期能準確地反應未來行駛高速公路時所需之旅行時間。研究範圍為我國中山高速公路北部區域（往北方向）。

研究對象：以行駛中山高速公路的客運車輛為主，探討與預測在交通狀況、時間、幾何設計等不同因素下，其行駛高速公路所需之旅行時間，作為用路人資訊系統、路徑導引等相關研究之參考，進而促進各運輸系統之發展。

在高速公路通過收費站的交通量中（表 1-1），吾人可清楚觀察到由於小客車具有體積小、私密性高、速度快與較為便利等特性，在民國 88 年時通過收費站之小型車、客貨車與聯結車的數量各為 3 億 4684 萬、5297 萬與 3415 萬，佔通行車輛數約為 80 %、12.2 %與 7.87 %。

表1-1 歷年通過收費站交通量

	小型車	客貨車	聯結車	合計	成長率
民國 86 年	313,538,925	50,133,044	32,652,093	396,324,062	4.05 %
民國 87 年	331,629,688	50,054,717	32,565,448	414,249,853	4.52 %
民國 88 年	346,846,068	52,979,020	34,156,987	433,982,075	4.76 %

資料來源：【高速公路局】

不過若將高速公路通行車輛單位轉換為 PCU（小型車：客貨車 = 1：2），小型車：客貨車約為 20：6.1，若再換成服務旅客數（大約服務旅客為 4：40）大致為 1：3，由此可見雖然大客車在高速公路比率不如小客車，不過在經由實際轉換成服務旅客數後，大客車之效用較小客車來得顯著。

此外由於小型車與客貨車特性有所不同，在高速公路上所需之行駛時

間亦會有所不同，可能程度上會有某種比例的關係。若能先準確預測大客車之旅行時間，並透過相關研究成果，相對地亦可順利推論出小型車所需之旅行時間。本研究礙於資料蒐集上的困難，故將研究對象集中於客運公車上，期能獲得良好旅行時間預測模式，裨益相關研究。

並且目前所面臨困難有下列幾點：

1. 國內目前有關中山高速公路即時路況資訊提供，僅有相鄰交流道之間的路段平均速度與廣播電台所提供的路況說明資訊而已，實為相當匱乏且不完整。
2. 中山高速公路各交流道之幾何設計、各路段之交通情況與外在環境皆不盡相同，如何利用類神經網路來架構預測高速公路旅行時間模式值得深入思考。
3. 高速公路路段資訊僅為一個「點」資料，如何表現出數公里路段狀況亦為研究重點。
4. 由於目前交通資料來源不一，資料格式不同，有「點」資訊、「路段」資訊、路況敘述資訊與車輛相關資訊等型式，未來在資料處理方面必須將之整合並轉為類神經網路所需之格式。

1.4 研究內容與方法

近年來，類神經網路已逐漸運用於各交通課題上，類神經網路是由簡易的基本元件(Processing Element, PE)所組成，皆具有資訊接收、處理、傳遞、儲存等功能。網路視問題特性，各元件以適當方式連接，依方向性、連結權重強度與資料特性而構成各類型之類神經網路。有鑑於此，本研究吾人乃採用類神經網路來建構高速公路旅行時間預測模式，並探討模式之績效與其運用性。並且嘗試結合不同行車環境（如時間、事件發生、幾何設計等）以因應不同路段特性之旅行時間預測，期能達到準確性高、適用性強之高速公路旅行時間預測模式績效。

在建構類神經網路時，利用以往文獻作為參考，選擇助益大且易蒐集

資料作為輸入變數，並且結合不同演算法或網路架構來嘗試使網路之預測能力提高，達到一滿意水準。重要的是，如何以國內外攸關旅行時間預測之相關文獻與運作實例作為參考依據，建構一個適用於國內高速公路交通特性之類神經網路預測模式，使其得以本土化且實務化，即為本研究當下之重要課題。

研究內容如下：

1.文獻回顧部分

就本研究而言，欲構建一預測高速公路旅行時間之類神經網路，所應回顧之參考文獻大致可包含三部分：第一部分為探討類神經網路概念與其應用；第二部分則為國內外有關旅行時間方面之研究，以確定本研究之理論基礎，促使網路模型之預測功能更為強大、準確；第三部分則是對於高速公路之相關課題進行研讀，瞭解本研究未來之實用性與適用狀況，並可進一步與相關課題相互作整合，促進彼此的發展。

2.高速公路特性與相關執行計劃

探討在國內外高速公路上交通資訊系統所運用之技術設備與執行計劃，促使吾人得以瞭解到國內外之差異，所需考量之技術與因素有所不同，以及目前相關計劃執行之成效為何。並且由多個來源處蒐集本研究所需之交通資料，如運研所網站上所提供的即時資訊：偵測器/台汽客運 GPS 所提供之平均速度資料；警察廣播電台之事件相關資訊：事件發生時間、地點、型態與路況；中華顧問工程司之交通千里眼(E-traffic)所提供之高速公路即時相關路況資訊：如事件資訊、道路施工、即時路況、即時影像等；台汽、統聯與尊龍等客運公車所蒐集到的 GPS 交通資訊；其它諸如交通調查報告與高速公路幾何資料等。

3.資料分析與整理

為了更加瞭解各資料來源特性與各地區之交通現況，在資料蒐集完成之初，則必須事先整理各種資料並深入進行分析，以促使類神經網路輸入資料概念逐漸成形。

4.蒐集實際資料作為模式分析及驗證

利用前述之多種資料來源所蒐集到的交通參數資料，來作資料的整理與分析，並將之應用於類神經網路模式之訓練、測試與研究最終之模式績效評估。

5.構建目前時間概念之類神經網路-各資料來源別與全部考量

在蒐集有關預測旅行時間所需資料後，著手進行資料處理工作，重新將資料重新編碼為類神經網路所需之格式，供研究網路作為輸入之用。

6.考慮未來時間概念之類神經網路-ANN52 與 ANN6

考量實際上線之應用與預測路段和上游路段彼此間關係，調整類神經範例資料或輸入變數，而發展出之旅行時間預測模式，試圖增加類神經網路在旅行時間預測上之適用程度與績效。

7.網路績效評估-實證分析

目前有關高速公路旅行時間預測的績效評估，採用方法有數種，因此利用網路績效評估來驗證本研究所構建出的網路預測模式，說明類神經網路在高速公路旅行時間之預測上的效果。

8.結論與建議

在蒐集相關交通參數資料與參考相關文獻後，本研究將構建出應用性高之高速公路旅行時間預測模式，藉由資料分析、網路訓練與測試及實證分析推導出本研究所得結論，並提出相關建議。

1.5 研究流程

本研究之研究流程如圖 1-2所示

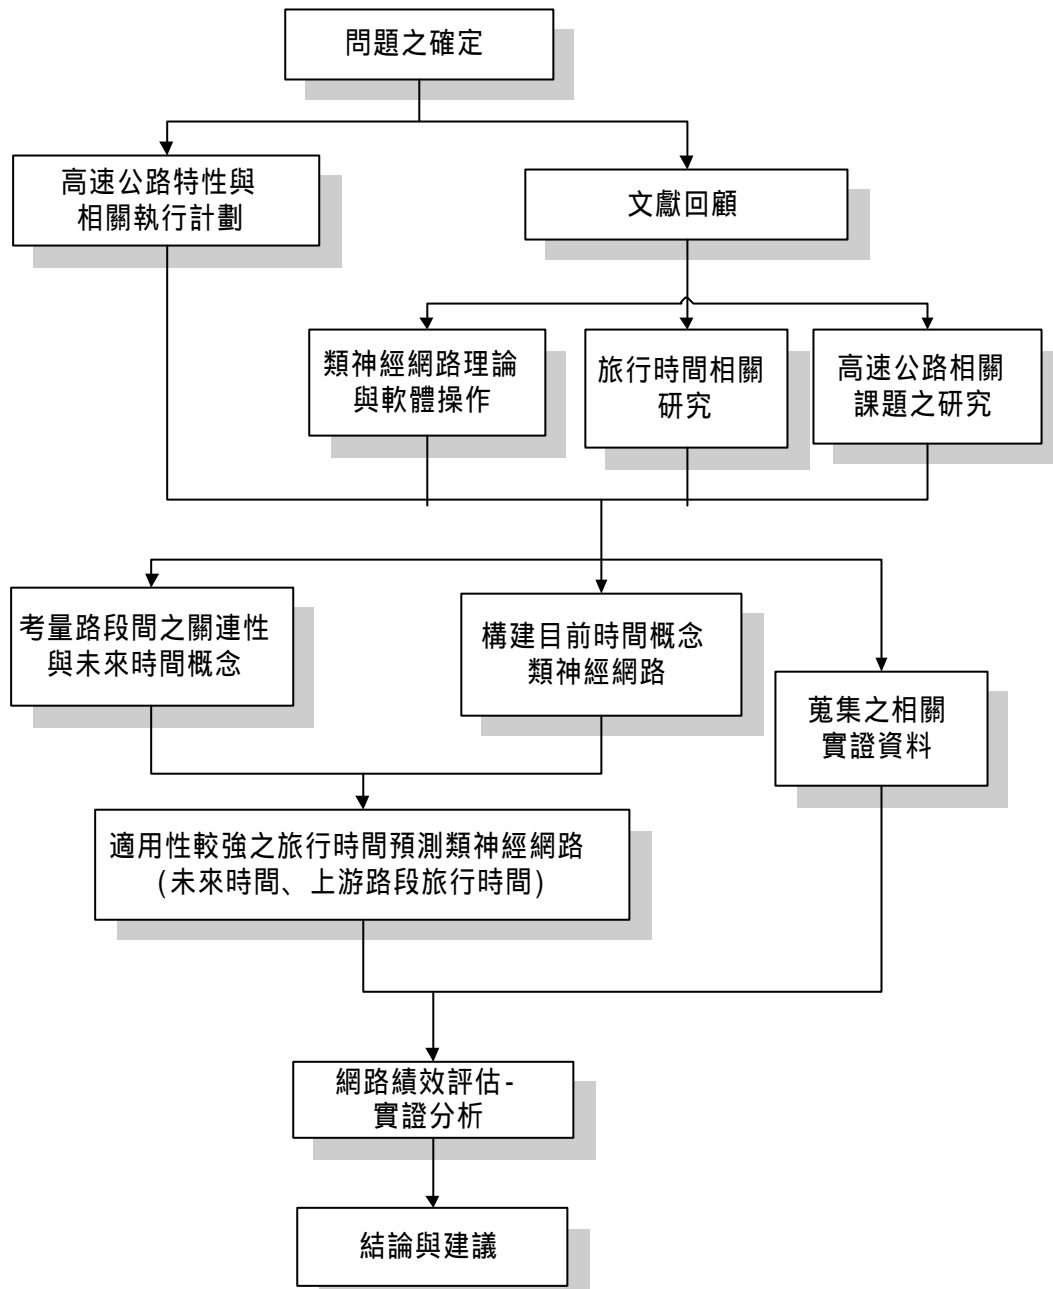


圖 1-2 研究流程圖

第二章 文獻回顧

2.1 旅行時間相關文獻

有關旅行時間預測的研究課題，大致皆有 2 個步驟，一步驟為預測各段鏈結的旅行時間，另一步驟則連接各段鏈結時間以獲得距離較長之運輸走廊旅行時間預測值。大多數之文獻中皆視各鏈結之旅行時間互相獨立，因此所得之旅行時間預測值乃為個別旅行時間相加總而求得，不過在 Park【1999】文獻中有針對此點作一說明，如果各鏈結之旅行時間並不互相獨立，則運輸走廊旅行時間將不會僅有各鏈結旅行時間相加如此簡單，問題會變得複雜許多。

對於預測旅行時間之概念大致可分為前向式方式與回饋方式。所謂前向式概念是由旅行駕駛者行為建構行為模式來推導旅行時間，利用行為模擬模式來模擬創造出分析駕駛人行為之假設性資料；回饋方式則是利用即時或事後所偵測之交通參數資料來進一步分析流量與旅行時間之預測值，此方式較為常見。

在相關文獻之輸入變數方面，亦可將之分為 2 類，一為僅利用速度之時間序列資料作為輸入變數；而另一種則以速度、佔有率、流量、車道容量與車輛數等為主要的輸入變數。在 Al-Deek【1999】文獻中，說明單一變數再經過校估程序後（將輸入之速度資料給予平滑化），其績效會優於多個輸入變數之模式績效。

Suzuki【2000】乃利用路段之交通總車輛數、平均速度與下匝道車輛數來預測起迄點之旅行時間與車流量。運算過程採用矩陣加以計算，並配合類神經網路模式來得出其中的參數數據值，以便於流量與旅行時間之預測。

Zietsman【2000】則針對總和與非總和輸入資料所預測之旅行時間差異作探討，若僅考量歷史資料而未加入『不同個別天』因素，則會較有考

量者有 35%的錯估比率。其中，走廊之旅行時間亦為個別旅行時間之加總。比較兩者在旅行時間估計的差異上，研究中指出如果單獨採用總和資料（歷史旅行時間資料）來預測旅行時間的話，其個體之預測旅行時間變化會較加以考量非總和資料（利用些先進技術，如 AVI 所蒐集到的交通參數資料）來得不準確。

Otokita【1998】則認為旅行時間的預測包括延滯的時間，且預測方法可以定期由時間序列資料中獲得。因此欲建立一含有歷史交通流量與先前旅行時間序列資料庫，希望能在相近的資料中準確預測未來的旅行時間值。系統所需的要素有自動車輛辨識、雙向通訊、紅外線車輛偵測器與上述資訊的資料庫，利用距離和速度來求取旅行時間，在相同的交通情況下，則會有相近的旅行時間。不過利用過去的旅行時間序列資料並非為最佳的方法，必需再考量交通車流，以增加時間延滯的影響。在方法的驗證上，本研究利用 AVI 技術蒐集 3 天的交通資料，前兩天作為資料庫，第三天則用來進行績效的評估（藉由實際觀測資料與建議方法所求得之旅行時間值相比較）。

Jasperse【1999】亦認為對於使用者而言，為了提供有用且準確的交通資訊，一套計算旅行時間與等候長度之演算法是必須的。演算法大致的步驟為：資料的前處理、長期間流入與流出之校正、車輛估計數、旅行時間估計；在旅行時間估計上有兩項原則：一為基於所測得之速度，另一為車輛數的總數。並藉由連結兩項原則，視道路為封閉或開放、道路長度、等候情況來決定旅行時間。

2.1.1 公車之旅行時間預測方面

有關大眾運輸動態到達時間預測方面，Ding【Ding et al.,1999】將公車動態到達旅行時間的預測方法分成兩種，一為路段為準(Link-based)的模式，計算出兩個公車停靠點間所有路段之旅行時間，並將之儲存加總而求得，另一則為停靠點為準(Stop-based)的預測模式，採用兩點間之交通參數資料(如交通流量、速度與延滯之平均數與變異數)。而在兩種方法的準確度驗證方面皆採用由 CORSIM 與模擬 NJ 大眾運輸路線#39 所擴充之微觀

模擬程式進行。由於交通狀況隨時空變化而驟變，車輛到達時間等交通資訊的預測變得非常困難，此文獻利用類神經網路進行公車到站時間的預測。

就所回顧的文獻而言，用來預測公車動態到達時間的模式可分為三類：單一變數預測模式、多變數預測模式與類神經網路模式。單一變數模式又包含機率估計模式與時間序列模式如加權移動平均(WMA)、自動迴歸整合移動平均(ARIMA)，通常針對 5-15 分鐘的交通情況。在多變數預測模式中又可分為迴歸模式與 state-space Kalman Filtering model 兩種。迴歸的主要缺點是共線性的限制，使得其運用受到限制。Abdelfattah and Khan【1998】利用迴歸分析處理模擬之大眾運輸路線行駛資料，其情境包括三種情況下的大眾運輸：一般營運情況下、重車比例高時與一車道被封閉時。類神經網路預測模式之績效並不需像前述之單一變數與多變數模式，須指定的函數型態，而且有關解釋變數的一些限制皆可較為寬鬆。

2.1.2 都市幹道旅行時間預測

Choi【1998】利用 GPS 與數位化道路地圖來計算路段之動態旅行時間。對於動態交通資訊而言，旅行時間為一項必需的要素。本文利用 GPS 與 GIS 技術來蒐集都市街道之動態路段旅行時間，並對於測量路段旅行時間的技術作比較。監測結果與專家建議顯示旅行者資訊系統應該要基於使用者的需求，並且要考慮到不同用路人類型會有不同資訊的需要。在都市幹道網路上，路段旅行時間為行駛時間與延滯時間的總和，受到號誌系統與環境交通因素所影響。最常用的技術是流動車輛法(floating car method)，用以得到點至點的旅行時間，不過此方法需要蒐集較多的交通資料，如每個車道、方向、時段的交通參數資料。最後利用所蒐集到的實際路網資料來與本研究計算出之旅行時間值進行績效評估，證實結果準確。

在 Jung【1998】文中說道，時間序列分析是基於歷史性旅行時間資料的提供，以作為旅行時間預測的方法，且近來類神經網路亦被應用來作旅行時間的預測。不過在傳統的方法中都假設網路模式為靜止狀態，鮮少有人嘗試動態預測，本研究致力於動態旅行時間的估計，以便未來先進旅行

者資訊系統(ATIS)上的應用。試驗結果則採用監測方式，對象為一四車道之號誌化路口。在觀測時將觀察的路段區分成數個不同特性的區域，如交叉路口區、非交叉路口區，並且為了達到動態估計效果，不像一般交通資料以每 15 分鐘為區間，而採取交叉路口區每 5 分鐘、非交叉路口區每 2 分鐘更新交通資料一次。對於估計方式則將預測模式分為兩種，一為非交叉路口之估計密度與交通量的關係，另一為交叉路口。藉由公式的計算得到最後所估計的旅行時間，並將其值與實際觀測車輛之旅行時間值相比較。

2.1.3 快速道路、高速公路旅行時間預測

鄭志平【民 81 年】應用衝擊波理論於高速公路封閉部分車道時，對於旅行時間的推算。在其旅行時間推估方式的建立中，將推估方法分成兩大類，一為靜態的推估方式，另一類則為動態的推估方式。在靜態的推估方式中即假設意外事件發生後或進行短時程的（二小時以內）之施工時，對於車道封閉的時間能夠事先預知，對於上游需求流量之變化不加以考量進去（即視為穩定），稱為靜態的推估。相對地，動態的推估方式即假設意外事故或施工路段的上游需求流量，隨著時間而變化調整。此種即時的推估方式，較能掌握到高速公路的實際車流狀況，對於事件的管理亦有較佳的效果。

不過此研究中所進行的旅行時間推估，最長距離僅限於意外事件地點至上游最近的交流道處（如圖 2-1），意即推估旅行時間的路段範圍並不包含上下匝道的車流干擾。在靜態的旅行時間推估中，利用衝擊波理論將時空圖繪出並找尋車輛之時空軌跡，以進行旅行時間的推估工作。對於一些假設及輸入變數必須事先決定，如所計算旅行時間之距離，車道封閉時間、需求流量、車流模式曲線、受阻路段容量等。故鄭君根據車道封閉地點至上游可變標誌位置的距離作為計算的基準；在事故發生方面，則以事件的嚴重程度，經驗上判斷所需之清除時間。又根據封閉車道的時間長短，可分為短時程的意外事件與長時間的施工型態，長時間的車道封閉影響較為長久，故不考慮清除時間，分析的重點亦針對流量變動對於旅行時間的影響。




圖 2-1 旅行時間推估之最長距離

又研究中對於車流模式曲線僅採用林貴璽君【民 75 年】所求出的模式曲線，根據國外研究指出不同車流模式曲線對於旅行時間的推估有一定的影響，故此為一需加以探討的地方。且另一方面，對於研究中旅行時間的推估並未包含整個交流道的車流影響，應擴大範圍以利用路人資訊與相關交通策略的發展。在於事件影響方面僅考慮施工路段作為分析對象，若能加入肇事路段的因素則必能提高其貢獻性。

Al-Deek【1999】說明單一變數由時間序列之速度資料來決定下一時期的速度值(S_{n+1})， $S_{n+1} = (3^{an} - 1)S_n - S_{n-1}$ ，其中 S_n 由 a_{n-1} 所求出，因此先估計出 a_n 的估計量，然後由 a_n 估計量再求得 S_{n+1} 的估計量，最後再由公式計算出旅行時間預測值。在多變數的情況下，利用車道佔有率、交通量、車道長度來計算出平均速度（公式：平均速度 = 車長 * (車輛數/佔有率)），如點 24 至點 25 之旅行時間為 $T_{24-25} = (\text{距離}_{24-25})/V_{24} + (\text{距離}_{24-25})/V_{25}$ ，故總旅行時間為各段所計算出之旅行時間相加。

有關快速道路之交通管理課題上，漢城奧運之旅行時間資訊乃是利用 AVI 技術所獲得，其快速道路安裝了 AVI 系統，並且利用「資料融合」技術來發展旅行時間估計演算法【Shin, 1998】。利用通訊技術、AVI 技術來測量旅行時間，而準確度測試則利用所蒐集到的樣本值與人工方式測量到的旅行時間作卡方適合度檢定，以驗證其是否為一致的分配。目前旅行時間資訊提供乃利用 17 個影像偵測系統所蒐集到的交通流量、速度與佔有率交通資料來提供旅行時間，其準確性並不佳。在所建議的旅行時間演算法步驟中，首先利用探測車與影像偵測技術來獲得即時的資料，將資料轉換成旅行資料所需型式，利用加權平均公式融合資料，最後再運用移動平

均方法(Moving Average Method)來計算。線上利用最大與最小值的限制來掃描資料以削減不適當的資料，由影像偵測所蒐集到不同車道資料所求得之旅行時間平均值與標準差、偵測車所測到的資料所計算的旅行時間，利用加權方式來算得融合資料後的旅行時間。最後利用濾波(filtering)係數與公式計算出平滑的旅行時間值。

在 1995 年 VicRoad 安裝駕駛設備於時間 Melbourne 高速公路上，以提供駕駛者旅行時間與壅塞資訊，不過這項資訊的提供並未包含整個長 1000 公里的幹道【Kloot, 1999】。旅行時間資訊的提供對於駕駛者而言是一種非常有助益的資訊，在日本的幾個城市與城市間快速道路則提供有這樣的資訊，例如 Tomei 快速道路與 Meishin 快速道路。旅行時間的估計通常是利用車輛偵測器所測得的車輛平均行駛速度計算而來，但仍非真實的旅行時間。為了增加旅行時間估計的準確性，此研究提出新的旅行時間預測法-交通瓶頸容量法(Traffic Capacity at the Bottleneck)。此方法在瓶頸路段中比較瓶頸路段容量與車輛數，並且比較自由車流與受阻車流下之旅行時間。

此外，Chen【2001】以紐澤西長途流量為主之重要路廊 I-80 公路為研究對象，採用 Kalman filtering method 演算法進行旅行時間預測。以 I-80 公路作為參考，選取之中含有 5 個匝道之路段，分為 9 個 node 與 8 個 link，用 CORSIM 模擬建立出與現實交通車流狀態相似之車流資料，並且取模擬資料中的 1 %作為交通偵測車之資料，建立預測模式，時段為晨峰 2 小時，每 5 分鐘進行一次預測。

其預測模式分為 Path-Based：起點至終點的旅行時間與 Link-Based：各節點之間的旅行時間算數和，結果濾波法演算之預測值與實際值蠻接近，且 Path-based 模式比 Link-based 模式的績效好。研究上亦發現選取模擬資料中 3 %車輛作為交通偵測車之資料，所建立之預測模式績效僅較採用 1 %的模式好一點，故未來在偵測車數量不足時，可取 1 %的資料來替代，所構建的模式一樣有不錯的效果。

至於 Path-based 模式較 Link-based 模式的績效好與一般概念有所突兀，吾人認為可能是現階段之變數只考慮了旅行時間，未考量事件、道路

環境等影響變數特性所致，相對地本研究考量因素較符合實際行車環境，因此所構建之預測模式亦能較適用於真實道路。

2.2 類神經網路

類神經網路(Artificial Neural Network, ANN)在交通領域中已逐漸成形，成為在人工智慧(Artificial Intelligence)中一重要的應用工具，其特性在於具有學習、容錯、可分散式儲存知識的能力，並且可結合其它方法以提昇效用。類神經網路應用上可說是不分學科領域，在各學門範疇中相關的研究從未間斷，近來也因為新觀念與新理論的引入，更有大幅地成長。

在資料來源輸入部分，類神經網路運作績效端賴正確且豐富之相關數據資料，以便能進行網路的學習、訓練過程與績效評估等工作。由於國內相關研究所採用的資料量常因資料庫不健全、蒐集資料技術尚未廣泛應用，造成研究上有所不便。且因國內文獻大多皆採用倒傳遞網路架構，就監督式之網路而言，分類與預測功能最重要的是對於研究課題評選較為相關的輸入變數，因此資料蒐集亦會影響網路權重關係的推導與良好網路模式的建立。

因為類神經網路具有生物神經系統的功能，對於人工智慧上所面臨到的一些問題亦可找出解決之道，而類神經網路應用領域很廣，各處皆有運用的蹤跡出現，ANN 包括的功能【魏健宏、陳奕志，民 88 年】：

1. 分類功能：類神經網路可以依據先前所學習過的圖形資料對比找出輸入圖形之類別，並加以分類，如影像信號分類：車種分類與道路維修等。
2. 歸納功能：類神經網路可將輸入資料根據自有特性加以分類。如車牌辨認、手寫字辨認。
3. 關聯功能：輸入不完整的資訊或圖形，類神經網路依據先前所訓練過的完整圖形作對比，利用不完整的圖形或資料決定正確的圖形。
4. 推理功能：類神經網路可以進行推理訓練，將物體的形狀依某種規

則加寬延伸，邊數不同的多邊形，若加長某一邊的話，新輸入的多邊形亦會根據這規則加寬。

5. 預測功能與最佳化功能：類神經網路利用網路連結型式及權重變化之不同，可以代替統計方法與作業研究的技術，求得預測值或最佳解。預測功能如駕駛人行為、旅運預測等，最佳化功能則如交通控制、方案評估或路線與排程問題。

2.2.1 類神經網路於交通領域之應用

事件偵測演算法主要是以事件發生後的交通特性有顯著變化，作為判斷事件發生之依據，鄭雅文【民 86 年】對於事件偵測則有一新的概念。其事件偵測亦含有預測功能，對於交通安全的助益實大。

邱顯鳴【民 84 年】以巨變理論為基礎，並與傳統偵測之交通參數（平均速度、佔有率）及影像式新偵測參數（車道變換率）三個參數發展出高速公路新的事件偵測演算法。研究中所採用的是倒傳遞網路架構，而輸入變數則由模擬模式所得出，其中共有三個車道、以三分鐘為一計算週期，每 20 秒為傳輸週期，車道內亦包含平均速度與佔有率的資料，每週期有車道變換率，利用 90 個輸入單元作為訓練網路之用，輸出變數則有 6 個，分別代表不同的事件情況程度。

類神經網路在交通運輸領域的應用逐漸受到重視，此外類神經網路與以往所使用之傳統模式結果作分析比較，可驗證類神經網路確實具有相當的效果。由於交通運輸現象是為一非常複雜之研究課題，所需考量的因素多，對此，多數僅能對於交通問題設法提出治標方式來加以改善，無法根本地解決問題之起因，類神經網路能夠對於問題進行不同方向的切入，使綜合的結果優於其它單一方面較強的方法。類神經網路對於影響交通問題之因素可試圖找出其間之相關性，而在文獻上對於因果關係之課題則有採用統計方法來進行探討。不過，礙於統計方法之先前假設與獨立性之限制，造成變數的選擇發生錯誤與未納入變數之貢獻程度未考量進去的情況發生。相對地，類神經網路則可處理共線性的問題【Gately, 1996】，故可同時選擇一些在統計方法上相關程度較高的變數進行輸入，而不致影響其

網路績效。

2.2.2 類神經網路於旅行時間預測之應用

1.公車方面

Ding【Ding et al.,1999】研究中有關兩種預測旅行時間模式之輸入變數，包括有路段距離、路段平均交通量、路段平均速度、路段平均延滯與路段平均等候時間，所有路段個別之交通量、速度與延滯之平均數與標準差。其類神經網路架構依路段或停靠站不同基準亦有不同，在路段基準(Link-Based)的模式中，每個路段有個別之子系統架構來預測個別之旅行時間，並結合到達時間、出發時間等資訊連結來預測公車之到達時間。在停靠站為基準(Stop-Based)的網路模式中，則是以站間 m 個路段之流量、速度與延滯之平均數與標準差、站與站之間的路口數來建構網路子系統，再結合旅客需求數、到達時間與到站時間來得到預測之旅行時間值。下表 2-1 為類神經網路於預測課題上之應用。

表2-1 類神經網路於預測課題上之應用

作者/年份	所預測之主題	應用網路類型	網路架構 (層數)	決定變數
Dougherty, Kirby and Boyle(1993)	交通擁擠	倒傳遞網路 (BP)	3	流量、等候長度、交通量
Chang and Su(1995)	路口等候長度	BP	3	流量佔有率、速度、歷史等候長度
Chin, Hwang and Pei(1994)	O-D 流量	BP	3	現在交通量
Hua and Faghri(1994)	旅行時間	BP	2(僅輸入與輸出兩層)	交通量、阻礙指標 (blockage index)
Smith and Demetsky(1994)	交通量	BP	3	歷史交通量、速度
Kalaputapu and Demetsky(1995)	排班偏差	BP	3	排班公車之道達時間、歷史排班之誤差

Zhang, Ritchie and Lo(1997)	旅行速度	BP	3	歷史性速度、密度與匝道進入率
-----------------------------	------	----	---	----------------

資料來源：【Ding, 1999】

2.都市快速道路旅行時間預測

有關都市快速道路路段旅行時間預測演算法，Lee【1998】採用 Kalman filtering 技術，並於漢城奧運快速道路的 17 個影像偵測器、廣播報導、閉錄電視上蒐集相關的交通資訊。相關的預測技術如時間序列分析、類神經網路與 Kalman filtering 技術皆引用來作為預測短期旅行時間之工具。對於演算法的績效評估則以平均絕對誤差、均數平方差。在時間序列演算法中，Box-Jenkins 方法即是適合預測時間序列類型的方法。文中所採用之類神經網路為多層前向式模式，共有 4 層網路，第一層與第二層隱藏層各為 6 個神經元，利用偵測器的時間序列資料（速度_t、流量_t與佔有率_t）作為輸入變數，計算出下一時間之行駛速度。在 Kalman filtering 中則利用動態與隨機處理過程來估計變數。在績效評估上，此研究於 1998 年 5 月 17 日進行 2 小時之樣本蒐集，利用影像偵測器每 30 秒蒐集交通流量、佔有率與點速度資料，將之合成 1 分鐘資料進行上述方法的推估，由 MAPE（絕對相對誤差平均數）、MSE（均方差）、EC（Equality Coefficient）等指標得知 Kalman filtering 在此有較佳的績效。

3.旅行時間在路徑導引之應用

林旭濱【民 84 年】乃是利用類神經網路(ANN)來進行旅行時間的預測，構建一動態路徑導引系統整合模式，並且對於引導策略實施後之交通績效作深入探討。基本構想認為北部地區已逐漸構成高速公路路網，可供用路人作較多的路徑選擇，若能採用有效的引導策略，便能發揮公路的效用。在此研究中，由於尚有部分路段仍未通車，故採用模擬分析方式來建構車流模擬模式，並導入衝擊波的理論進行路網的測試工作。分別以不同流量的方式來進行模擬工作，觀察瓶頸上游路段車流變化之情況，最後對於不同之引導策略進行模擬分析比較其差異。利用路段之實際旅行時間、即時旅行時間與歷史資料庫旅行時間三者的關係對未來此路段之旅行時

間作一預測。

在報告中林君採用之訓練範例為準動態路徑導引與吳廣南君【民 82 年】之動態路徑導引所得之結果中取得，準動態路徑導引的結果作為歷史資料，吳君之動態導引所得之結果作為實際之旅行時間。著重的是高速公路車流受阻所產生之影響，先對於虛擬路段進行模擬實驗以驗證研究中所採用之車流模擬模式，在車流模式確認中主要是以垂直等候分析法與衝擊波分析法兩種方法建構模擬模式，並針對不同的狀況，如流量、封閉車道數及封閉時間等因素的變化進行模擬分析。

在準動態路徑導引中，假設路網上設有導引系統，並以最近一次蒐集到的路網中所有路段之旅行時間為基礎，判斷所有路徑的總旅行時間，決定具有最短旅行時間之路徑，並將車輛導引至其中；而動態路徑引導則以歷史、即時旅行時間為依據，運用類神經網路對未來行經路段之旅行時間進行推估。有關其路徑導引控制則比較駕駛者經驗、準動態路徑與動態路徑導引三種引導策略，而在不同預測區間下，如果範圍包含路網比率越大，績效將會越佳，如 60 或 30 分鐘之績效較 15 或 5 分鐘績效（總旅行時間與實際旅行時間相差程度）為佳（其值小）。

2.3 相關研究文獻

2.3.1 交通擁擠推論

由於偵測器設備價格昂貴，通常只設置於重要地點之路段，因此若部分路段缺少偵測器，有關其交通資訊的推論是必須的。Choi【1998】乃利用智慧型交通擁擠資訊推論相關路段之特性，主要的課題是將多個偵測器交通資料來源所決定之擁擠水準聯合求得未裝設偵測器路段之交通擁擠程度。推論過程中最重要的即是資料的融合，最常用的三種屬性關聯(attribute association)來進行資料融合方法，一為 Dempster-Shafer's 確証推論法(Evidential Reasoning Method)，再者為模糊邏輯理論(Fuzzy Logit Method)，最後為 Pearl's Hierachy-Bayesian Method。此文獻則針對第一種

Dempster-Shafer's 確証推論法，並且亦考慮不確定性與反常理(counter-intuitive)兩種問題。

文中敘述交通擁擠推論(Traffic Congestion Inference, TCI)演算法主要概念是將個別偵測器所推得之交通擁擠水準(採用速度進行分類)利用 Dempster-Shafer's 技術資料融合，並且將結果外加補充性的資訊(如天氣、交通量等)，最後得到所估計出的擁擠程度。若能得到每個路段的交通流量，即可得知鄰近路段對於研究路段的影響，重要的一點是鄰近路段與研究路段擁擠程度相同的機率為何。首先先依時段進行分類，分成 3 個較高擁擠水準的時段(週日、週末、假日)與 12 個較低水準的時段，因此進行推論時需先瞭解到時段為何，然後將統計資料運用連結法則(Dempster-Shafer's rule of combination)求出各個路段之混合函數機率，最後得出未設置偵測器路段之擁擠程度。

2.3.2 相關預測技術

You【1998】於各種不同的預測工具，如歷史資料型態(Historical Profile Approach)、時間序列、類神經網路、非參數(nonparametric)迴歸模型、交通模擬模式與動態交通指派模式下，採用專家系統(Expert System)與地理資訊系統(GIS)來進行資料融合預測旅行時間與擁擠分析。交通管理有賴準確的評估與預測，學者無不花費心思來發展一合理且可靠的預測模式。以往採用單一方法卻無明顯令人滿意的預測結果，須綜合 2 個以上演算法所發展的模式結果方能令人滿意。因此本研究將對各種預測方法進行探討，並發展一整合其它技術之綜合預測模式。旅行時間預測為 ITS 中一重要要素，以便交通管理中心事先在擁擠發生前著手採取交通策略，以避免延滯產生，並且亦可運用在相關系統如 ATIS、CVO、ATMIS 上。未來的旅行時間為諸多交通特性之函數，如交通流量、速度、等候與事件等，需考量各種特性方能準確地預測旅行時間，且一般預測旅行時間多以 15 至 60 分鐘為範圍。上述方法之特性摘述如下：

1. 歷史資料型態(Historical Profile Approach)基於交通量或旅行時間可以推導出歷史的輪廓，如利用過去的平均交通量可以預測未來交通量，這種

週而復返的交通流特性的演算法已被運用於歐洲的幾個旅行者資訊系統，包括 AutoGuide 與 LISB 系統。

2. 時間序列演算法則利用一連串的統計觀察值依據時間的順序排列著，觀察的交通量序列包含有實際過程(real process)與干擾(noise)兩部分，最重要的部分是如何削減去外在環境所造成的干擾，因此自動迴歸(autoregressive)與移動平均模式(moving average model)就這樣產生。基於這兩種基本模型，任何不連續但固定間距的序列則可以自動迴歸移動平均模式(autoregressive moving average model, ARIMA)來表示。此外最先進的時間序列模式之一，Kalman 濾波(filtering)模式即考量誤差最小。
3. 類神經網路基於無固定演算法且平行處理的特性，運用於人工智慧領域中，其學習能力促使網路能夠處理複雜問題，如由交通流量估計現在的旅行時間【Palacharla, 1995】。
4. 無參數迴歸(Non-parametric Regression)為一多鏈結分析，其為單一鏈結分析之擴充，利用此路段與相鄰路段前期的交通資訊以進行預測。由於辨認“鄰近路段”複雜，故利用來預測旅行時間的不多。
5. 模擬模式則是設計模擬真實世界系統的行為模式，有不連續/連續事件模式、微觀/中觀/巨觀模式，大部分的交通模擬模式為不連續時間模式。基本上，若使用模擬模式來預測旅行時間，必須要有進出系統的交通流量資料。

動態交通指派模式為傳統靜止均衡指派模式(Static equilibrium assignment model)之進化。不像靜止的指派模式，動態模式假設尖峰時段之路段交通流量與旅次時間極不穩定，因此非常適用於路網擁擠時之即時交通控制。基本上，動態指派模式可分成兩種類型，描述性與規範性模式。所謂的描述性模式是企圖在固定交通狀況下捕捉使用者行為（使用者最佳化），規範性模式則試圖使系統最佳化。

一般而言，統計性與模擬模式適用於非常短期(小於 15 分鐘)預測；動態指派模式則較適用於 15 至 60 分鐘的預測。集中式交通資訊中心須接受多種不同來源的輸入資料，如迴圈偵測器、歷史性資料、警察單位與緊急救援單位的報導，因此資料掃描與融合處理對於旅行時間預測的準確性提昇是有必要的。

2.3.3 資料融合

資料融合技巧亦可應用於類神經網路輸入資料中，所謂資料融合是將多種來源之資料，透過運算處理之後，融合成最有效的資料。

Ivan【1995】利用類神經網路將資料融合，以便即時偵測幹道發生事件與否。其資料來源有二：一為迴圈式偵測器，另一為車內監視設備。對於資料融合有兩種方式：一為整合性融合(Integrated fusion)，將所觀察蒐集到的資料利用類神經網路來進行連結；另一為演算法輸出融合(Algorithm output fusion)，區分開個別來源的事件演算法，進行處理後才利用類神經網路將每個來源的輸出值作連結。結果可以得知，輸出融合網路的效果會較其它方法來的優良，不過程序上較為複雜。

其另一文獻中【1997】，認為採用多種資訊來源能夠使號誌化幹道之事件偵測績效更佳。文中，可依照不同的輸入方式與結構分成四種網路架構，一為兩種資料來源個別採用獨自的演算法(Two input network)，最後方用類神經網路加以連接；二亦為相同方式而再將先前的輸出值加權回饋至原網路(Output memory network)；三為相鄰路段網路(Adjacent link network)，將路段與上下游所蒐集到的資料作為輸入變數，利用類神經網路進行訓練；四為 Full network input module detail，利用一個輸入變數來架構輸入模式，最終輸出值有二，再連結至類神經網路的隱藏層，構成事件偵測網路。其中網路績效以第四種最佳，輸出記憶網路次之。

劉國偉等(民 86 年)考慮未來路段交通資訊可經由多種管道於同一時間獲得，交通資料來源包括：1.車輛偵測器資料；2.實驗車資料；3.歷史資料；4.預測資料；5.其他資料。為將不同管道所獲得之資料加以有效精確的融合運用，採用了整合分析演算法，分成兩階段加權平均法來組合各種資料來源。在融合階段 1，依資料準確性給予不同權重值再融合之，而融合階段 2 是在融合階段 1 的資料來源（偵測器、實驗車、回報資料）均無資料時，才啟用融合階段 2 之規則，融合規則與階段如表 2-2所示。

表2-2 整合分析演算法融合階段

規則 資料 來源	1	2	3	4	5	6	7	8	9	10	11	12
偵測器 (D1)	V	V	V	V								
實驗車 (D2)	V			V	V	V						
回報資料 (D3)	V	V			V		V					
歷史資料 (D4)									V	V		
預測資料 (D5)									V		V	

V：表示使用該筆資料

規則 1： $T = D1 \times a1 + D2 \times a2 + D3 \times a3$,

規則 2： $T = D1 \times b1 + D3 \times b2$,

規則 3： $T = D1$,

規則 4： $T = D1 \times c1 + D2 \times c2$,

規則 5： $T = D2 \times d1 + D3 \times d2$,

規則 6： $T = D2$,

規則 7： $T = D3$,

規則 8：進入第二階段融合

規則 9： $T = D4 \times e1 + D5 \times e2$,

規則 10： $T = D4$,

規則 11： $T = D5$,

規則 12： $T = \text{無資料}$,

T 為路段旅行時間， $a1, a2, a3, b1, b2, c1, c2, d1, d2, e1, e2$ 為參數值。

2.3.4 路徑導引

Hobeika【1998】研究事件發生情況下，動態路線導引之適應性策略。由於動態路線導引系統(DRGS)對於用路人提供即時最佳路線資訊有潛在性的發展，不過受人爭議的是該使整個系統利益最佳化或是個人效用最大化。站在營運者觀點而言，期望能於固定時間內盡可能地移動更多人，不過實際上駕駛者卻會站在自己的角度上來選擇道路，兩者觀點有所不同，特別在擁擠的情況下，這種現象更明顯。而 DRGS 則提供駕駛人又快又安

全的路線建議。本文獻提供動態路線導引系統一適應性策略，滿足系統與個體最佳化的目標，並且利用模擬模式來量化 DRGS 的效益。在北維吉尼亞真實路網中，適應性路徑導引可以節省總使用者旅行時間至少 3-10 %，在事件發生的情形下，效果更大。高速公路若有替代道路時，在總需求達容量 50 %時，系統最佳化(SO)與使用者均衡(UE)所相差的總旅行時間為最多。在一般正常車流下，多條替代道路兩者之旅行時間差異大致與單一替代道路時相似；不過在有事件發生的情況下，由使用者均衡轉換至系統均衡所造成的效益（總旅行時間減少）相當顯著。

在所建議的適應性路徑導引方法中，步驟大致為：1.決定使用者在系統均衡下所能容忍的最大旅行時間，2.進行路況監視與交通情況偵測，3.事件發生時自動促使事件評估單位偵測事件位置、地點、型態、時間等且建立平均事件時間表，4.開始進行 UE 與 SO 路線導引策略的計算，5.比較並選擇路線，6.對所建議的策略進行評估：利用事件發生時使用者均衡與適應性策略兩者之旅行時間作比較。結論是所建議的適應性路線導引策略較旅行者均衡路線導引來得有效率。

Kim【1999】亦認為旅行時間估計對於路徑導引與先進旅行者資訊系統是一重要基本功能，然而交通情況十分複雜且多變，因此如何準確預測旅行時間是非常困難的工作。研究中採用修正的 Dijkstra 演算法來估計最短旅行時間，並將其值與模擬模式的結果相互比較。路段旅行時間乃為出入此路段之時間差，並且包括了幾種延滯時間、車道擁擠、號誌延滯、行人穿越等因素，由於這些因素具有方向性且富變化性，故最短路徑法的計算須加以考量方向性的問題。

一開始須確定起點與終點為何，方能計算兩者間之最短路徑；接續選擇最短路徑為行駛路線，而本研究採用 FHWA 發展之交通模擬程式 NETSIM 來作為實際驗證工具，構建的路網包含 14 個外部結點、16 個內部結點、76 條路段與 16 個交叉路口。模擬程式每 90 秒蒐集一次，共模擬 800 輛車，模擬結果可分兩種情形，一種為穩定靜止(Static Method)，另一種為動態更新方式(Dynamic Method)。所謂靜止方式則利用 Dijkstra 演算法來求得最短路徑；而動態法則利用先前靜態法所求得之最短路徑作動態更新，以更加符合真實網路車流情形。

Hellinga【1999】則是基於旅行時間的變化性來考量路線的選擇。大部分傳統的路線導引系統皆基於最小期望旅行時間值來選擇最佳路線，不過結果通常不是高估旅行時間就是低估。駕駛者對於自己所估計的旅行時間與實際行駛旅行時間二者誤差有一定的容忍度，因此希望所提供的旅行時間資訊能有較少的差異（變化性）。考慮旅行時間差異性，若將原先路線選擇以平均旅行時間為最短的方式或以 95 %信賴區間旅行時間為基準的方式計算，路徑上之車流量將會有所變化。此一結果可得知現存路線選擇策略仍有改善的空間。

2.4 國內外執行計劃

2.4.1 國內高速公路智慧化之兩年行動方案

1998 年 7 月交通部第 905 次部務會報部長指示將以建立智慧型運輸系統為重要政策目標之一，並成立 ITS 專案小組統籌辦理相關事務。由國道高速公路局負責辦理「高速公路智慧化」專案，亦配合成立 ITS 專案小組負責推動相關事務，訂定兩年近期行動方案，內容除了加強交通管理系統與用路人系統外，並進行智慧化整體規劃之研究及加強既有系統功能之規劃，有關高速公路預計執行計劃（表 2-3）如下：

即時交通資料蒐集

除了匝道儀控系統、交通控制系統及設置於國道一號之車輛偵測器蒐集交通資訊外，並結合交通部研究計劃於行駛高速公路之台汽車輛上加裝衛星定位系統以蒐集路段行駛速率及廣播電台蒐集之事件資訊。

表2-3 高速公路智慧化兩年行動方案預計完成目標與時程表

			1999		2000
			6 月 30 日	12 月 31 日	12 月 31 日
城際高 (快) 速公路 智慧化	先進用路 人資訊系 統(ATIS)	行 前 交 通 資 訊	<ul style="list-style-type: none"> ➢ 北區路況影像上網之增設 ➢ 以網際網路發佈匝道儀控與北區交通資訊 	<ul style="list-style-type: none"> ➢ 以自動傳真回覆方式發佈交通資訊 ➢ 以電話語音系統發佈交通資訊 	<ul style="list-style-type: none"> ➢ 有線電視試播
		行 程 中 交 通 資 訊		<ul style="list-style-type: none"> ➢ 台北都會區聯絡道路之資訊可變標誌增設 ➢ 國道一號中、南區重要路段設置簡易型資訊可變標誌 	<ul style="list-style-type: none"> ➢ 國道一號中、南區資訊可變標誌增設
		預 計 成 果 與 目 標	預計可以提供高速公路全線之路況資訊		預計可進一步提供高速公路全線詳細路況與匝道儀控管制資訊

資料來源：【國道高速公路局，2000】

(1) 研究及規設計劃

「高速公路智慧化之整體規劃」委託研究，研究期間自 1999 年 7 月開始，為期 10 個月，目前期末報告已經審查完竣。研究內容包括下列 6 項：1.規劃高速公路智慧化目標、整體架構及應有功能；2.規劃提昇既有交通控制及匝道儀控系統功能方案；3.研擬電子收費系統配合交通管理功能；4.高承載智慧化之研究；5.評估相關標準與通訊協定；6.研訂未來智慧化之執行計劃，提供推動時程與經費概估。

藉由前述之高速公路智慧化整體規劃原則所訂之 20 項產品組合，包括交通監測（路網交通監視、探測車交通監視、交通預測及需求管理、空氣污染間側、虛擬交控中心與智慧型探測資料、道路天候監測）、交通控制項（高速公路控制、交通資訊發佈、區域性交通控制、事件管理）、資

訊服務（廣播式旅行者資訊、互動式旅行者資訊、自主式路線導引、動態式路線導引、ISP 路線導引、整合運輸管理與路線管理、車內顯示）電子收費、高乘載車道管制及智慧型運輸規劃系統等，依整體規劃成果檢核既定系統建置計劃，並提出提昇北區既設交通控制及匝道控制系統功能方案外，且研擬後續推動計劃。

提昇北區高速公路交通控制及匝道儀控系統功能計劃

依據「高速公路智慧化之整體規劃原則」研究所得之整體架構及系統建置、運作準則，進行提昇現有交通控制及匝道儀控系統功能之推動計劃，以符合智慧化需求。預定 2000 年 9 月開始執行，執行期間 3 年，有關本研究旅行時間資訊提供方面敘述如下：

1. 增設資訊可變標誌：依據管理需求增設主線及聯絡道路資訊可變標誌；加大顯示面版及顯示彈性；顯示板上方增設閃光黃燈，可啟動警示用路人。
2. 設置旅行時間看板：於進出都會區路段之主線上設置，以提昇資訊服務；配合旅行時間之顯示，一併檢討圖誌可變標誌顯示方式以利識讀，達到路徑導引功能。

（2）智慧化後續推動計劃

用路人資訊服務提供

1. 配合偵測器與閉路電視系統建置，設置資訊可變標誌，逐步加強行前及行程中資訊提供。
2. 考量設置旅行時間看板，供用路人行程參考。
- 3.
4. 加強路線導引功能
5. 提供資訊供民間加值運用，如車內導航系統、行動電話、呼叫器及電視台等，以節省建置成本。

6. 加強結合偵測車交通監控
7. 提供整合性資訊提供，透過資訊交換，結合替代道路、市區道路及省道資訊，並納入大眾運輸、停車及其它相關交通資訊，以方便使用路人查詢。

2.4.2 國外方面

TransGuide 提供聖安東尼奧用路人旅行時間資訊，亦在網頁上顯示出此項交通資訊【Newsletter, 2000/4/19】。原本僅由 AVI 提供所偵測到之行駛速率資料，而目前則連結 TxDOT 的事件資訊與警察機關部門，並完成網頁上封閉車道資訊的提供。關於旅行時間預測演算法則利用迴圈偵測器所蒐集到的點速度資料來求得高速公路旅行時間。在非尖峰時段，計算旅行時間較為簡單，相反地，如果在尖峰時段且遇到擁擠、事件發生等交通變化大的情況，此時必須個別計算路段之平均速度，利用演算法自動得出最後 2 分鐘之預測旅行時間曲線，以觀察辨識交通趨勢。在旅行時間預測之準確度方面，非尖峰時段所計算出的旅行時間幾乎為 100 %，故在績效的探討上，僅針對非尖峰時段而言來進行測試工作，預測路段約有 85-87 % 的準確度。而所提供旅行時間預測的地區僅限於有偵測器設置的範圍內，資料來源並不仰賴 AVI 技術，因為在尖峰時段雖然可以有豐富的交通資料，不過在非尖峰時段時則會面臨資料短缺的困境，且資料缺乏可能導致旅行時間預測之信賴度被破壞掉。

在網頁上，即使預測時間可達到 40-50 分，最高也僅提供 30 分鐘的旅行時間資訊而已，其原因是大部分的路段皆為 5 至 10 英哩，最長並不會超過 12 英哩，亦即正常的路況下，旅行時間應不至於超過 30 分鐘，若時間超過則必定是路段上有事件發生，事故的相關即時訊息需求就遠較於旅行時間預測資訊來得重要，而資訊上將顯示出『到達某目的地的旅行時間超過 30 分鐘』。附帶一提的，本路段之可變資訊標誌(CMS)設置距離約為 2-3 英哩。

Lee【1998】則對於韓國首都漢城之交通資訊系統作一介紹，如漢城快速道路管理系統等。在資料庫建置方面，資料須於線上即時融合，連結

與處理多個不同來源之交通資訊，對於旅行時間的估計會較單一來源資料所得出的估計時間來得準確許多。資訊中心亦須建議用路人理想的路線為何，並以用路人本身為預測對象，而非先前的用路者。在多種資料來源下，測試交通資料的可靠度即為一重要的先前處理工作，而即時交通資訊的提供上，將速度分為 5 個等級加以分析，並且每 10 分鐘更新一次，運用在奧運的快速道路走廊上、其它幹道與橋樑上等。

Yuyama【1998】對為期 16 天之久的第十八屆冬季奧運進行交通資訊上的探討。在奧運舉行之前，預測交通需求是一件非常重要的工作，惟有準確地預測交通需求才能規劃後續的交通管理策略。在離家之前、進入道路中以及在擁擠的道路中，這三個時期最需要交通擁擠資訊，因此交通資訊系統必須就此加強相關資訊的提供。

小結

在目前各交通即時網站所提供的交通資訊中，來源大致皆為運研所網頁上之即時資訊加以轉換，不然則再結合警廣廣播電台、台北市交通局與 26 座 CCTV 所獲得的影像，利用人工判別方式將路況資訊輸入，其時效性與所花費成本較大。在旅行時間預測研究上，國外由於相關技術發展成熟，所能蒐集到的資料較為完臻，故主要是針對預測模式上的探討。相對地，國內則因相關技術未能發展至一定水準，促使相關研究常侷限於有限的交通資料，不然則是利用模擬方式獲得資料，其結果與實際交通情況會有一定誤差。本研究乃結合相關網站上所提供之交通即時資訊，再加上額外所蒐集之客運公車 GPS 資料、高速公路幾何、交通調查報告、施工、事件時間與等級等多來源資料，使本研究所需資料得以相當完善豐富，加上類神經網路之資料整合與應用優良功能以構建出準確的旅行時間預測模式，提供高速公路用路人即時交通資訊，增加高速公路行車效率。

第三章 模式理論

3.1 類神經網路

雖然科技發展日新月異，電腦善於計算複雜且費時的工作，然而卻仍有許多工作是電腦所不能跟上的。對於電腦而言，一些辨識、專門的決策工作，或是學習經驗的累積等可說是一件困難的事。對於較高等生物而言，不須特別教導則可以輕易辨認事物，對於學習方面的能力則更不用多作說明。所以簡單的說電腦與生物腦幾乎沒有關連，只能說是一種超級的計算器。

而類神經網路(ANN)就定義【葉怡成，民 89 年】而言：「一種計算系統，包含軟體與硬體，它使用大量簡單的相連人工神經元來模仿生物神經網路的能力。人工神經元是生物神經元的簡單模擬，它從外界環境或者其它人工神經元取得資訊，並加以非常簡單的運算，輸出其結果到外界環境或者其它人工神經元」，因此類神經網路可說是將電腦與生物腦加以連結的運算系統。

類神經網路的演進過程，最早是於 1957 年電腦發展初期所提出的第一種類神經網路模式-感知機(Perceptron)。不過卻因為其無法在本身理論上突破，漸趨於沒落。所幸自 1980 年代中期，因為類神經網路如霍普菲爾網路(Hopfield neural network)與倒傳遞網路(Back-propagation)在理論上的突破、電腦技術發展快速，促使類神經網路相關研究又復興起來，短短數年之內蔚為風潮。

3.1.1 類神經網路分類與網路架構

以類神經網路進行分類與預測的計算，一般常用的方法可分為「監督式網路」與「非監督式網路」。對於具有週期性與循環性且能提供大量歷史資料的問題，「監督式網路」透過歷史資料的訓練調整其網路權重值，

因此，較適用於內在對應規則進行運算之問題，而網路的功能亦較類似於迴歸分析與判別分析。「非監督式網路」的運算毋需大量的歷史資料，利用某組變數資料之內在聚類規則加以分類，適合運用於方案組合的分類與評選，其功能類似統計分析的「聚類分析」。監督式網路與非監督式網路的運算方法與網路結構都不相同，而對於不同資料型態的分類問題皆有其適用範圍。下表 3-1與表 3-2為類神經網路之應用與特點：

表3-1 類神經網路之主要應用

分類	模 式	研 發 者	研發年	主 要 應 用 領 域
監督型	認知機	Rosenblatt	1957	字母識別
	倒傳遞網路	Werbos(1974) Parker(1985) Rumelhart Hinton & R.J. Williams(1985)	1974- 1985	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、預測
	機率神網路	Specht	1988	樣本識別、分類問題
	學習向量化網路	Kohonen	1988	樣本識別、分類問題
	反傳遞網路	Hecht-Nielsen	1986	樣本識別、函數合成、資料壓縮、分類問題
非監督型	自組織映射圖網路	Kohonen	1980	拓撲映射、聚類問題
	自適應共振理論網路	Grossberg Carpenter	1976- 1986	樣本辨識、聚類問題
聯想型	霍普菲德網路	Hopfield	1982	聯想記憶問題、雜訊過濾、資料擷取
	雙向聯想記憶網路	Kosko	1985	資料擷取、雜訊過濾
最適化	霍普菲德-坦克網路	Hopfield Tank	1985	組合最適化問題
	退火神經網路	Ven den Bout Miller	1988	組合最適化問題

資料來源：【葉怡成，民 89 年】

表3-2 各種常用類神經網路的特點對照表

類神經網路名稱	特點
倒傳遞網路	<ol style="list-style-type: none"> 1.可解 XOR 問題 2.應用最普遍 3.成功案例多 4.學習精度高 5.學習速度慢 6.回想速度快 7.理論簡明
機率神經網路	<ol style="list-style-type: none"> 1.學習速度快 2.回想速度慢 3.理論簡明
學習向量化網路	<ol style="list-style-type: none"> 1.學習速度快 2.回想速度快 3.理論簡明
自組織映射圖	<ol style="list-style-type: none"> 1.學習速度快 2.具有臨近區域觀念
適應共振理論	<ol style="list-style-type: none"> 1.網路具穩定性 2.網路具可塑性 3.學習速度快 4.模式非常複雜 5.具警戒值觀念
霍普菲爾網路	<ol style="list-style-type: none"> 1.學習速度快 2.回想速度慢 3.理論簡明 4.平行處理 5.聯想性 6.分散式儲存 7.模擬即時性
模糊類神經網路	<ol style="list-style-type: none"> 1.最適合不明確資料處理

資料來源：【林鄉鎮，民 86 年】

3.1.2 倒傳遞網路

倒傳遞網路是目前類神經網路學習模式中最具有代表性，應用最普遍的網路模式。Werbos 於 1974 年在其博士論文中提出了隱藏層的學習演算法，這是已知最早的倒傳遞類神經網路模式。

倒傳遞類神經網路架構如圖 3-1所示，包括：




圖 3-1 基本之倒傳遞網路架構圖

1. 輸入層：即網路之輸入變數，其處理單元數目依問題而定。使用線性轉換函數，即 $f(x) = x$ 。
2. 隱藏層：用以表現輸入處理單元間的交互影響，其處理單元數目並無標準方法可以決定，經常須以試驗方式決定其最佳個數。使用非線性轉換函數，而網路架構可以不只一層隱藏層，亦可無隱藏層。
3. 輸出層：用以表現網路的輸出變數，其處理單元依問題而定，並使用非線性轉換函數。

在檢驗 ANN 學習與測試績效，研究者須事先進行範例的製作-即資料蒐集與整理，並將範例分成兩部分，一為訓練範例，另一部份作為測試範例，在網路學習階段中，可多次循環學習，將網路加以訓練至收斂。關於網路測試工作則採用相關指標作為模式衡量標準，如誤差均方根、總錯率或相關係數等。

倒傳遞網路有幾個重要參數，包括：

(1) 隱藏層處理單元

通常隱藏層個數越多，網路的收斂速度越慢，但可達到更小之誤差，特別是「訓練範例」之誤差程度。但是若超過一定數目後，所增加之隱藏層處理單元則對於降低「測試範例」誤差幾乎沒有幫助，徒然增加網路執行時間。這可解釋成隱藏層處理單元數目過少，不足以反映變數間之交互作用，造成誤差較大。而數目越多，雖然可使誤差值達到更小，但卻因網路複雜度提高，收斂過慢。隱藏層處理單元個數取決原則如下【葉怡成，民 89 年】：

$$\text{隱藏層單元個數} = (\text{輸入層單元數} + \text{輸出層單元數}) / 2$$

$$\text{隱藏層單元個數} = (\text{輸入層單元數} * \text{輸出層單元數})^{1/2}$$

若問題雜訊過高，隱藏層單元數目宜少。

若問題複雜性高，隱藏層單元個數宜多。

測試範例誤差遠高於訓練範例誤差，隱藏層單元個數宜減少。

(2) 隱藏層層數

通常隱藏層個數為一層至二層，過多層反而會造成網路收斂結果較差。有關隱藏層個數的解釋，沒有隱藏層則不能反映問題輸入變數的交互作用，而一至二層的效果最佳，越多的隱藏層反而促使網路過於複雜，造成局部最小值過多，網路加權值容易掉於一個誤差函數的局部最小值，無法收斂。根據經驗，一般問題可取一層隱藏層，較複雜的問題則取兩層隱藏層。

(3) 學習速率

通常學習速率過大或過小對於網路的收斂均有不利影響，過大的學習速率會有較大的網路加權值修正，造成修正可能過量，難以達到收斂的目的。

倒傳遞網路之優缺點說明如下（表 3-3）：

表3-3 倒傳遞網路之優缺點

	優點	缺點
倒 傳 遞 網 路	1. 因為輸出值為連續值，適用於樣本識別、分類問題、函數合成等，應用範圍最廣。 2. 學習精度高，可處理複雜的樣本辨識與高度非線性的函數合成問題。 3. 回想速度快	1. 學習速率慢 2. 執行時間太長 3. 網路架構與網路動態的決定尚缺乏非常系統化的方法

資料來源：【葉怡成，民 89 年】

3.2 旅行時間預測模式之網路架構

3.2.1 資料蒐集與處理

資料蒐集上，國外因有先進技術之應用，可以獲得較豐富多樣之實際交通資料，國內則多為偵測器資料與模擬所得資料；研究對象：國外多為實際公路之旅行時間預測，國內則多為較短之起迄點與模擬路網旅行時間預測；研究驗證工作，國外多數採用 AVI 所蒐集到的實際資料來進行預測模式績效之驗證，國內則礙於實際資料不易獲得，大多採用模擬方式來評估模式績效。

1. 資料來源

本研究所需之交通資料，如運研所網站上所提供的即時資訊：偵測器/台汽客運 GPS 所提供之平均速度資料；警察廣播電台之事件相關資訊：事件發生時間、地點、型態與路況；中華顧問工程司之交通千里眼(E-traffic)所提供之高速公路即時相關路況資訊：如事件資訊、道路施工、即時路況、即時影像等；台汽、統聯與尊龍等客運公車所蒐集到之 GPS 交通資訊；其它諸如交通調查報告與高速公路幾何資料等。

2.蒐集資料型式

由於本研究所蒐集到的相關輸入資料種類多樣，其來源亦有所不同，在資料型式(data format)上可分為可數量化資料(quantifiable data)，如平均旅行速度、事件地點、時間；質化資料(quality data)，如事件型態、道路施工、路況等。故如何整合差異大、數量多且型式類型不同的交通資料，乃為本研究一主要課題。

3.多種資料來源，資料整合課題

在資料更新時間方面，運研所所提供的即時資訊為 4 分鐘更新一次，交通千里眼(E-traffic)所提供的路況資訊則 5 分鐘更新一次，而在客運車輛 GPS 方面，所蒐集到的資料大致每 20 秒傳回一次。由此可知多種交通資料來源不但交通資料種類不一，其資料蒐集時間亦有明顯的差異，針對不同資料更新時間進行資料處理與組合，以構建出最佳之預測網路模式。初步構想是以 GPS 資料時間為準，將不同資料來源的時間計算調整以與之相對應。

表 3-4說明：運研所之即時資訊目前提供北部路段(基隆~新竹系統)完整偵測器平均速率資訊，其餘路段陸續建置中。尚未完成之路段由台汽 GPS 系統提供速率資訊，空白部分表示該路段目前無加裝 GPS 設備之台汽車輛經過，故無法提供速率資訊，另外還有警察廣播電台所提供之現況資訊。而圖 3-2則為交通千里眼北區路網，以不同顏色顯示各種交通狀況，與其它資料相對應。

表3-4 國道一號/中山高速公路 (南下) 即時路況資訊

車速 0~40 公里 ● 41~60 公里 ● 61~80 公里 ● 80 公里以上 ●

89-04-13 21:59

起點 交流道	終點 交流道	高公局/ 台汽客運	警察廣播電台		
起點	基隆	偵測器/GPS 系統	時間地點	路況說明	資料提供
基隆	八堵				
八堵	五堵				
五堵	汐止				
汐止	汐止系統				
汐止系統	內湖	● 74			
內湖	圓山	● 70			
圓山	台北	● 79			
台北	三重	● 85	89/04/13 17:19 南下 25Km	交通障礙 中、大保險桿	熱心聽眾 (警廣總台)
三重	五股	● 86	89/04/13 17:21 南下 26.5Km	交通障礙保險 桿，中間車道	熱心聽眾 (警廣總台)

資料來源：【運研所之即時資訊】

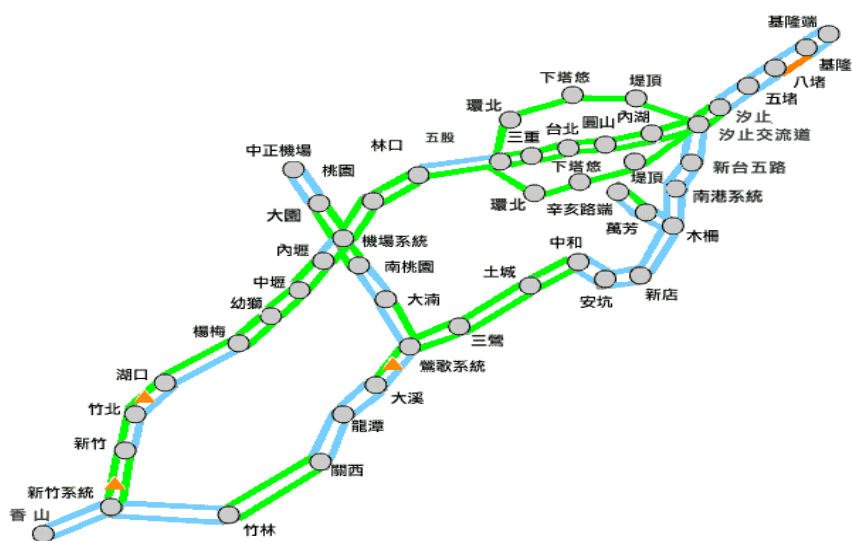


圖 3-2 交通千里眼北部區域路段交通狀況 (依顏色區別)

4.交通資料處理

在各資料來源之更新時間間距(time interval)方面(表 3-5),由於多種資料來源所接收時間不一,網站資料大多為 4~5 分鐘更新一次,而客運公車 GPS 則每 20 秒~1 分鐘接收一次,未來在資料整合上將會探討合適的時間間隔,以獲得較佳模式。一般而言,時間間距過短,資料處理的成本將會有所提高,而偵測的資料值會因樣本少而造成誤差較高,不過其資料卻較具即時性、符合民眾所需。相對地,資料更新時間間距過長則會有相反的情形產生。

表3-5 資料更新時間之影響

資料更新時間間距	優點	缺點
時間間距過小	1. 資料更新較快,較為即時 2. 所預測出來的旅行時間較符合實際情況	1. 資料處理成本高 2. 所獲得資料誤差較大
時間間距過大	1. 資料量較少 2. 可以將時間細分多段,求出平均交通資料值,誤差會較小	1. 難免會因時間過久,與實際交通情況有些許差距 2. 較不能滿足使用者的需求

3.2.2 旅行時間預測模式之網路架構

依本研究問題之特性,提出可能之網路架構(圖 3-3、圖 3-4):

大致而言,一般相關文獻所選擇之輸入變數大多為可量化之變數,如偵測器所測得之速度、佔有率與流量,鮮少採用質化交通狀況或事件嚴重程度作為輸入變數。而本研究由於所蒐集之交通資料包含多來源,且同時具有量化與質化資料,其實時間間隔又有所不同,因此所構建之類神經網路必須合理且有效地運用所蒐集到的交通資料。

用路人所需之旅行時間資訊會因個人起迄點不同而有不同起迄組合對(each O-D pair)之旅行時間需求,若依此概念構建旅行時間預測模式,不同起迄組合則會產生新的預測模式,如此一來,模式構建的工作即變得複

雜且困難。為了避免任一起迄組合套用一個預測模式，本研究將區分中山高速公路北部區域往北方向道路為數個群組路段，每個群組路段構建自身的類神經網路預測模式，待用路人提出起迄旅行時間需求時，方進行 OD 之間群組路段旅行時間之預估工作，並進行加總以給予用路人所需之 OD 旅行時間值。

本研究初始構想將視幾何設計與交通瓶頸特性細分成數段特性相似之群組路段，每個群組路段內將可能包含不同交流道數、車道變化與收費站等設施。個別群組路段構建特屬的類神經網路模式，可能之 ANN 模式會依照資料來源、不同輸入變數組合，也會依概念不同而在範例與變數上進行修改，詳細路段切分割見 4.1 節。

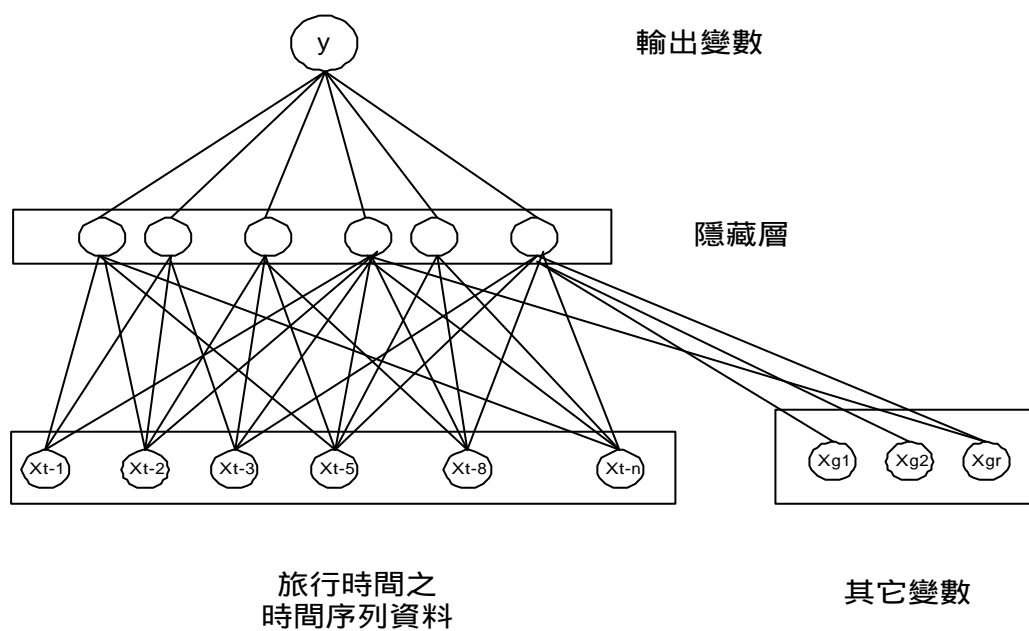


圖 3-3 旅行時間預測之類神經網路模式架構圖-依時間概念

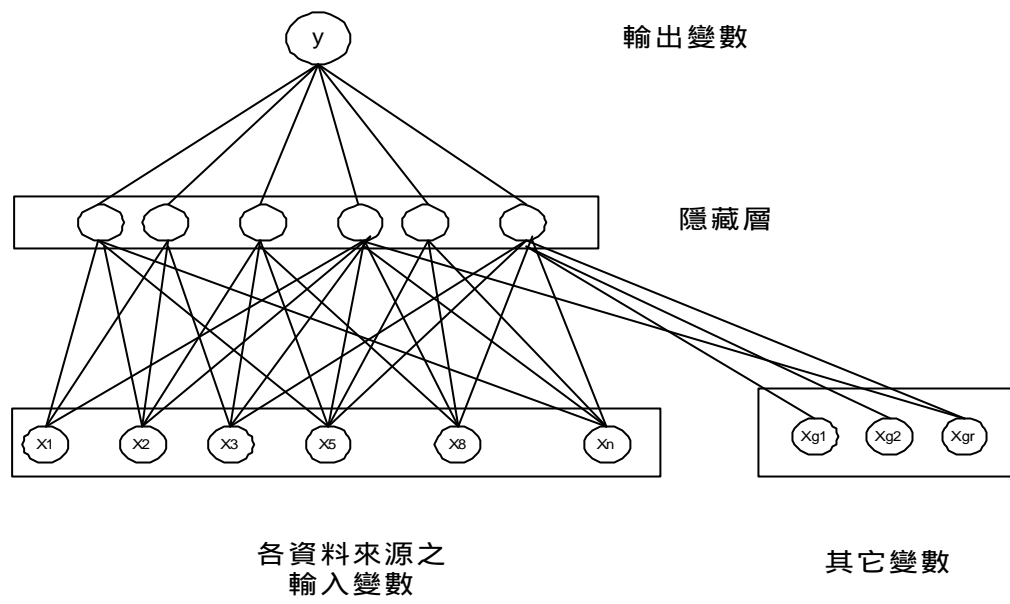


圖 3-4 旅行時間預測之類神經網路模式架構圖-依資料來源概念

第四章 資料分析

本章主要是針對本研究所蒐集到之相關資料進行整理與分析，期能藉由相關的分析來找出資料特性，對於往後進行模式構建工作時，選取之輸入變數能夠切宜，變數的型態亦能夠符合實際情況，以善用資料構建良好的旅行時間預測模式。

有關高速公路客運車輛旅行時間預測課題，為求預測模式能更精準，吾人則考量車輛在高速公路行駛時所面臨到的交通狀況，包括高速公路事件資料、車輛偵測器資料、高速公路幾何資料與交通量資料等，期能藉由模式網路找出彼此間的關係，準確預測車輛之旅行時間。

4.1 資料分析流程與說明

本研究模式構想是以中山高速公路北部區域（往北方向）為研究範圍，以主要都市交流道間路段為預測對象。因此在資料分析上則較偏向北部區域，而各資料來源與其資料內容分別為所蒐集之台汽客運車輛 GPS 資料所轉換得之實際旅行時間資料、高速公路車輛偵測器資料（如表 4-1）所得車輛時刻速度資料、交通千里眼網站所提供之事件資料與其它文獻報告中所調查之交通參數資料等，說明如下。

1. 車輛偵測器

表4-1 車輛偵測器（北部路網）建置分類數量表

國道編號	區位/路段				
	一般	匝環道	聯絡道	合計	備註
國道一號（基隆-新竹系統交流道）	189	123	-	312	含 IPVD 乙座
國道二號（桃園環線、機場支線）	14	20	-	34	
國道三號（汐止系統-香山交流道）	93	102	-	195	

國道三甲（台北聯絡道）	11	8	0	19	
合計	307	253	0	560	

資料來源：【高公局交管組，民國 88 年】

資料蒐集時間由 89 年 11 月 27 日上午開始，定期每分鐘抓取一次的方式寫入資料庫，程式抓取運研所偵測器(VD)資料，預計於 12 月 5 日星期二上午 10:10 分自動關閉，共計 8 天，每天 24 小時連續運轉，預計有 $96(\text{固定筆/次}) \times 60(\text{分}) \times 24(\text{小時}) \times 8(\text{天}) = 110$ 萬筆資料於資料庫中。

2. 台汽客運 GPS 資料

包含客運車輛 GPS 速度、GPS 時間與高速公路里程數資料。在台汽 GPS 資料蒐集上，透過中華顧問工程司間接向台汽 GPS 資料庫存取 89 年 12 月 1 日至 8 日資料進行分析研究，原始資料經由 GPS 接收訊息依序儲存。

3. 統聯與尊龍等客運公車所蒐集到的 GPS 交通資訊

原先本研究預計加入其它客運車輛資料以增加資料量，不過由於統聯與尊龍等客運 GPS 資料僅有經緯度資料，並無高速公路里程數資料，因此本研究須利用高速公路里程數-經緯度座標對照表（附錄一）加以轉換成高速公路里程數以便進行相關研究。

不過不可預期的問題發生-高速公路里程數並不平滑改變，客運車輛行駛有不合理的情況產生，再進一步探討後，可能是 GPS 資料發生問題，由於此為客運公司與負責其 GPS 項目的廠商之間系統建置的問題，因此此部分客運 GPS 資料目前暫不加以考量納入。

4. 事件相關資訊

包含事件發生時間、地點、型態與路況、事件資訊、道路施工、即時路況、即時影像等資料欄位。而另一程式亦定期每分鐘抓取一次的方式寫入資料庫，這隻程式抓取運研所事件(Event)資料，亦共計 8 天，每天 24 小時連續運轉，預計共有 $40(\text{平均筆/次}) \times 60(\text{分}) \times 24(\text{小時}) \times 8(\text{天}) = 46$ 萬筆

資料於資料庫中將再轉出成為 Excel 檔案。

5.交通參數資料

可分主線交通流量、匝道流量與收費站流量（一般日與例假日之尖離峰時段）等不易取得之交通資料；主線速度等可利用歷史資料自行產生資料庫以便未來查詢。

本研究中因模式考量需要須蒐集以交流道間隔之各時段交通量，不過礙於與其它資料相同期間之交通參數資料取得困難，因此部分交通參數資料（如各時段主線、匝道與收費站流量）則必須採用調查報告所蒐集之交通量資料。

原先考量道路容量與旅行時間有明顯關係，需將道路容量因素加以考量，不過輸入資料已包含每路段總車道數不盡相同，由交工相關理論中可瞭解車道數與其道路設計容量有關，車道數可替代隱含設計容量之特性，所以預測模式暫不將路段設計容量考量進去。

本研究一般日之交通量資料來源係參考高速公路局委託邱穀顧問公司之 84 年度『高速公路交通動態資料調查報告』為主（高速公路局提供）。報告調查範圍包括中山高速公路、機場支線及北部第二高速公路已通車路段及其內所包含之交流道、服務區域休息站、聯絡道路等地點，其動態資料調查符合本研究之資料需求，故直接引用以補資料之缺乏。

連續假日則引用運研所匝道儀控案之分析資料，為起始假日之主線流量南下僅內湖至王田段，收假日北上僅西螺至圓山段有資料，其餘資料闕如，幸本研究之範圍乃為北部區域（台北-新竹），因此沒有交通量資料缺乏的問題。

6.幾何設計

大致包含高速公路車道數、路段長度、主線車道數、車道寬、路肩寬、匝道型式、收費站特性資料。車道數、路段長度：本研究初始構想乃採用交流道為分界構建個別旅行時間預測模式，不過進而由高速公路主線車道數與主線交通量來區分數個群組路段別（表 4-2），每個路段各自建立個別

的 ANN 模式。

上述數種資料為本研究實際著手蒐集之資料類型，由於攸關預測模式績效，故實際納入模式之輸入變數，須深入探討分析，以決定模式所需要的資料與類型為何。

表4-2 研究範圍路段各預測模式起迄群組別

本研究預測模式之各路段 (台北、三重 新竹)_北上部分				群組編號	
交流道起迄	主線車道數	路段數目	各路段車道數	本研究區分之模式群組	
8.台北-三重	4	3	4,4,4	群組一	
9.三重-五股	4	4	4,4,4,4	群組二	
10.五股-林口	4	6	4,4,10,4,4,4	群組三 (處理車道數 10 的區段)	
11.林口-桃園	4	5	4,4,4,4,4	群組三	
12.桃園-機場	4	4	3,3,4,4	群組四	群組五
13.機場-內壢	3	4	3,3,3,3	群組六	
14.內壢-中壢	3	4	3,3,3,3	群組六	
15.中壢-幼獅	3	4	3,3,3,3	群組六	
16.幼獅-楊梅	3	3	3,3,3	群組七	
17.楊梅-湖口	2	10	2,2,2,2,2,6,2,2,3,3	群組八	
18.湖口-新竹	2	6	2,2,2,2,2,2	群組八	
19.新竹-新竹系統	2	4	2,2,2,2	群組九	

其中，交流道起迄名稱粗體者為尖峰流量大者(附錄六)，必須自視為一個群組。而本研究分組依此為主要依據，並且加以考量主線車道數，將其它路段合併或分割成共同群組。本研究主要是以重要之交流道為路段分割依據，若就原先交流道設計來切割則又顯得過細，預測分析上較不適合。

4.1.1 資料處理流程圖

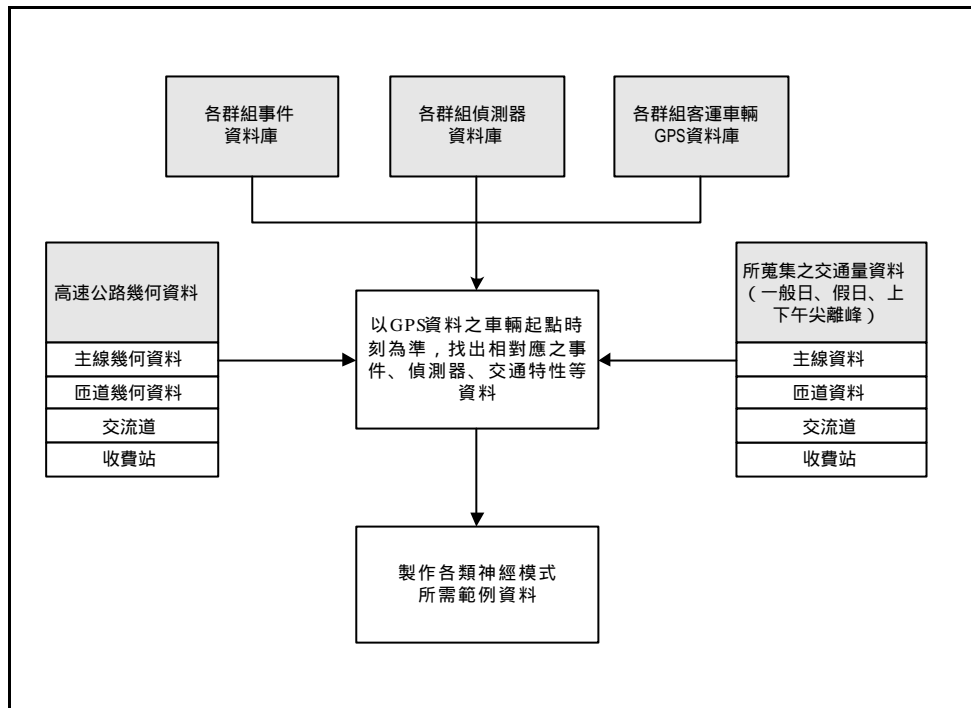


圖 4-1 本研究各資料來源處理流程

由上圖 4-1與之前有關本研究蒐集資料之說明，可以清楚看到資料類型大致為 6 種，在實際篩選本研究所需資料之前，單整理各資料來源之原始資料成為適用資料庫實為耗時的工作。

原始資料過大的原因在於程式執行存檔工作時並沒有判別重複的問題。相對地，如果程式有判別重複的功能時，如事件資料即無法找出事件發生至結束所持續的時間為多久。依照一週實際蒐集到的資料量而言，事件資料共有 21 萬筆資料，資料大小有 105.3MB，大約一天為 3 萬筆資料。另一偵測器資料來源則一週的資料量有 89 萬筆資料，但因資料格式較簡單，所以資料大小只有 71.1MB，大約一天為 12.7 萬筆資料量，必須再加以切割方能儲存於 Excel 檔案中，因此增加了資料處理上的困難。

4.1.2 資料來源處理流程說明

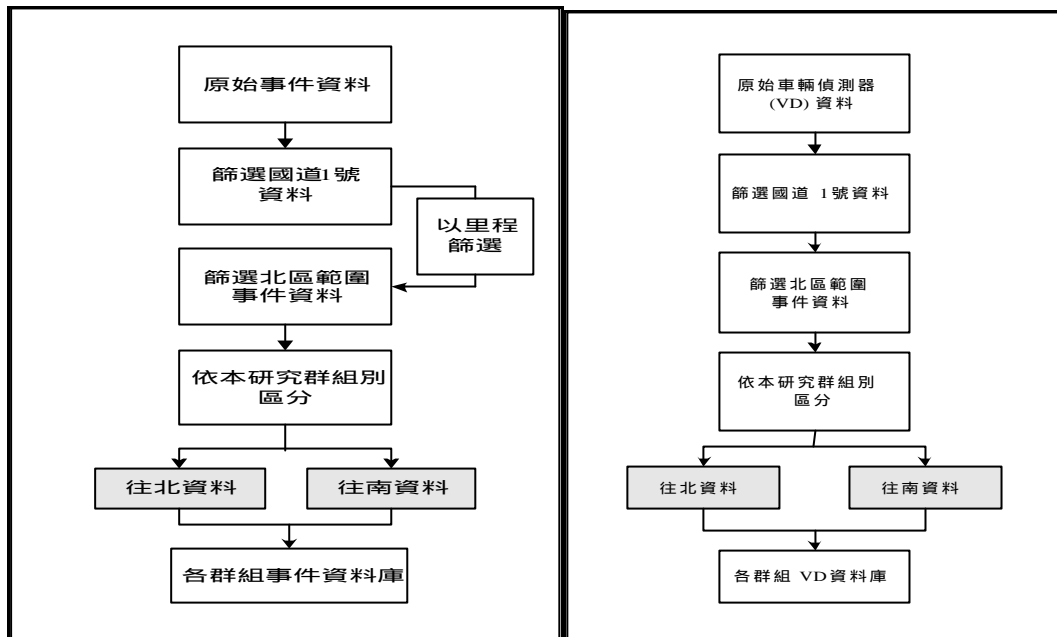


圖 4-2 車輛偵測器(VD)與事件資料資料處理流程

在車輛偵測器(VD)與事件資料的處理過程（圖 4-2）上，皆考量國道 1 號（中山高）範圍為北部區域、方向，並依據本研究之後的群組分類分割資料以製成合適之每日事件歷史資料庫與車輛偵測器歷史資料庫。

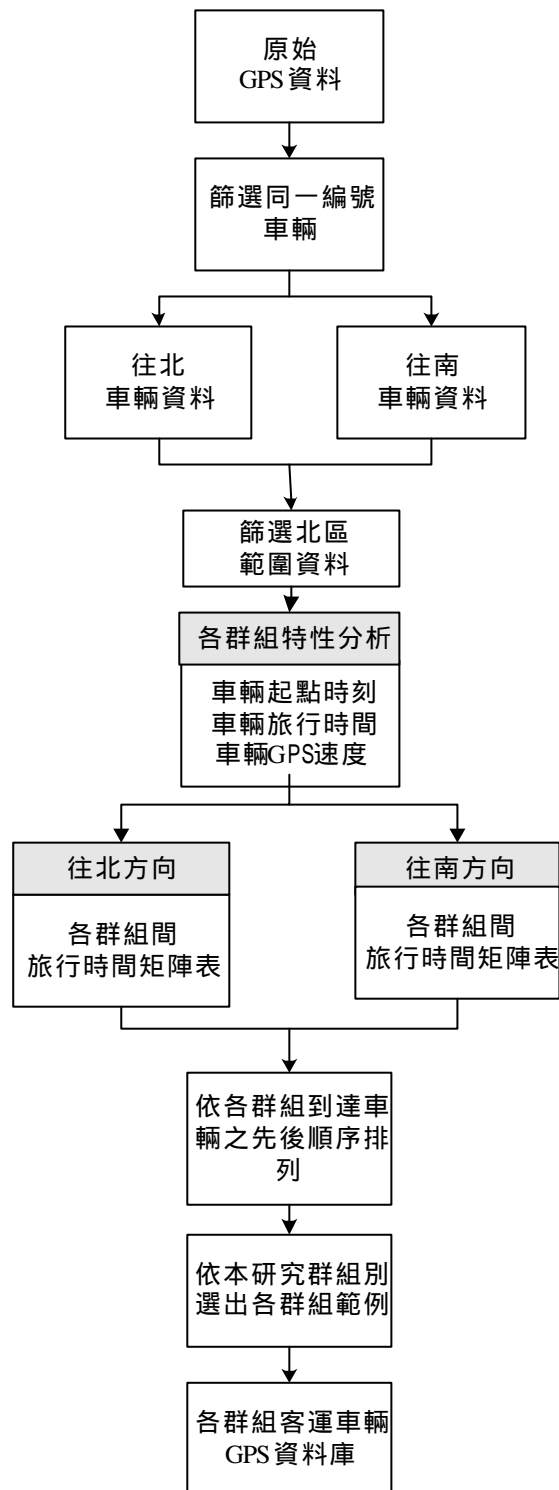


圖 4-3 原始 GPS 資料處理流程圖

而在客運車輛 GPS 資料處理流程（圖 4-3）方面，較為困難之處乃為篩選同一車輛資料、挑出北部區域資料、依本研究之群組別尋找起迄點資料、將時間轉換成一天累積秒數（表 4-3），進而計算各車輛各群組起迄旅行時間矩陣表（如附錄二），處理後所獲得之實際旅行時間值方可作為監

督式類神經網路之實際值時間序列與實證結果分析之用。

表4-3 客運車輛時間轉換成一天累積秒數

	原來出發時刻	小時	分鐘	秒數	累積秒數	群組編號
群組 9_新竹系-新竹	232145	23	21	45	84105	9
群組 8_新竹-楊梅	232302	23	23	2	84182	8
群組 7_楊梅-幼獅	232450	23	24	50	84290	7
群組 6_幼獅-機場	232550	23	25	50	84350	6
群組 5_機場-半處	233537	23	35	37	84937	5
群組 4_半處-桃園	233608	23	36	8	84968	4
群組 3_桃園-五股	233708	23	37	8	85028	3
群組 2_五股-三重	234844	23	48	44	85724	2
群組 1_三重-台北	235246	23	52	46	85966	1
最後到達台北時間	235448	23	54	48	86088	0

4.2 資料特性

4.2.1 高速公路幾何資料

1.中山高速公路道路特性（運研所，民 83 年）

北起基隆、南迄高雄，全長 373 公里（另有機場支線 8.5 公里），其中計有 40 個交流道，六個服務區，及十個收費站（如圖 4-4）。在車道佈設方面，除了圓山-台北、機場-楊梅路段為 6 車道（雙向），台北-機場路段為 8 車道（雙向）外，其餘路段均為 4 車道（附錄三、附錄四、附錄五）。不過目前車道進行拓寬工程，已陸續完成中。而本研究範圍北部區域新竹-台北，將會依車道數與交通資料分割成 8 個群組路段別，每個群組路段間有明顯的差異性存在。

2.全線交通特性（運研所，民 83 年）

- (1) 主線與匝道交通組成之車種比率、一般日收費站之交通組成、例假日等收費站之交通組成資料

- (2) 方向性比率資料：探討一般日、例假日兩類型
- (3) 交通量：一般日與例假日、收費站之交通量資料

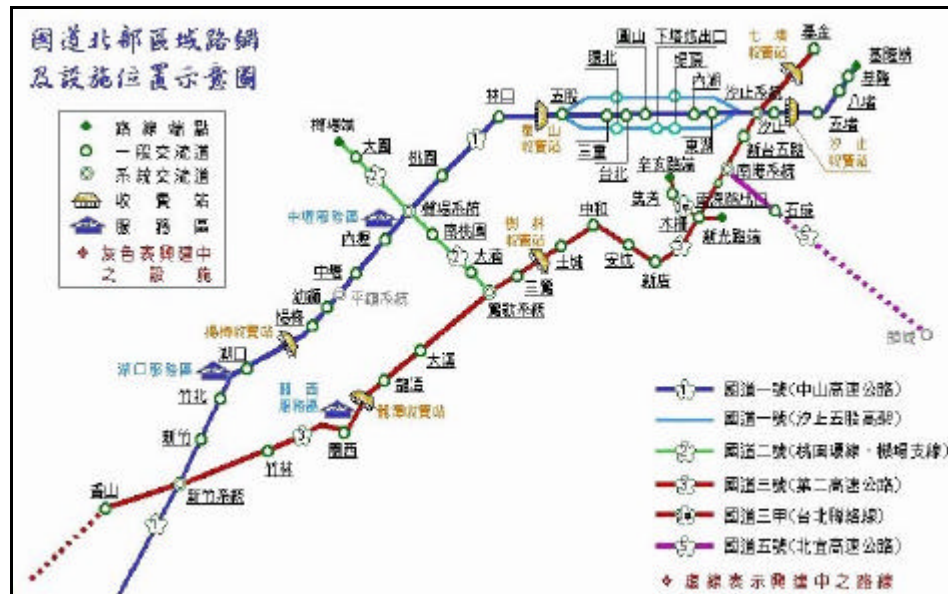


圖 4-4 國道北區路網及設施位置示意圖

3.收費站

在收費站資料中（表 4-4），以泰山收費站之車道數為最多，共 10 個車道，而所有的收費站中車道數最多的類型為小型車不找零。如果就收費站的車道容量來看，由於小型車速度快、體積小，因此相對地小型車車道亦有較高的容量，可以處理較多的車輛數，而泰山收費站則因車道數最多，故提供的車道容量亦最高。

表4-4 收費站各車種車道數與車道容量

車道數	汐止收費站		泰山收費站		楊梅收費站	
1.小型車不找零	2	2515	5	5365	3	3465
2.小型車找零	1	2515	1	5365	1	3465
3.大貨車	1	480	2	960	1	480
4.客聯車	1	517	2	1034	1	517

資料來源：【高公局，民國 84 年】

4.交流道（表 4-5）

高速公路上各交流道型式與交通環境不盡相同，可分成苜蓿型交流道、鑽石型與喇叭型等交流道型式。若依照分類可分成功能交流道與系統交流道 2 種等級，相鄰環境與交通組成不同，幾何設計上亦會有所不同。

表4-5 北區交流道

交流道名稱	台北交流道	三重交流道	五股交流道	湖口交流道
圖示	<p>台北交流道 25K+125</p> <p>士林 重慶北路 台北市區</p>	<p>三重交流道 27K+122</p> <p>蘆洲 仁愛街 蘆洲 [103] [104] 台北橋 三重</p>	<p>五股交流道 33K+057</p> <p>五股 環北交流道 [104] 新莊</p>	<p>湖口交流道 83K+700</p> <p>湖口 新埔</p>
主線與匝道行車方向	<p>4 台北交流道</p>	<p>5 三重交流道</p>	<p>6 五股交流道</p>	<p>14 湖口交流道</p>

表4-5 北區交流道（續）

交流道名稱	林口交流道	桃園交流道	機場系統交流道	內壢交流道
圖示	<p>林口交流道 40K+854</p>	<p>桃園交流道 49K+059</p>	<p>機場系統交流道 52K+191</p>	<p>內壢交流道 56K+980</p>
交流道名稱	幼獅交流道	楊梅交流道	新竹交流道	新竹系統交流道
圖示	<p>幼獅交流道 67K+289</p>	<p>楊梅交流道 69K+136</p>	<p>新竹交流道 94K+930</p>	<p>新竹系統交流道 99K+390</p>

4.2.2 交通量資料

先前提到由於有些交通參數資料無法取得與所蒐集之車輛偵測器、客運車輛與事件資料相同時間的交通量資料，因此本研究將採用調查報告資料來取代這些無法獲得的資料。資料來源為民國 85 年，國道高速公路局委託、中華民國運輸學會辦理，高速公路高乘載車輛專用設施初步規劃研究。

在中山高速公路調查中，因為須調查一般日與例假日之不同時段交通量資料，因此調查日期也有所不同。所蒐集之交通量資料如表 4-6 所示。

表4-6 所蒐集之交通量資料（附錄六）

一般日交通量				
主線流量	北上	上午尖峰	下午尖峰	上午非尖峰
主線流量	南下	上午尖峰	下午尖峰	非尖峰
匝道流量	南北向	上午尖峰	下午尖峰	非尖峰
例假日交通量				
主線流量	北上			
主線流量	南下			
匝道流量	北上	尖峰		
匝道流量	南下	尖峰		

資料來源：【高公局委託、運輸學會辦理，民 85 年】

1.高速公路主線部分

由表 4-7 所蒐集之交通量調查資料中，在北上方向一般日主線上午尖峰時段流量以幼獅-楊梅區段範圍之交通流量最高，有 23667 輛次，最低的則為內壢-中壢，只有 3780 輛次。

表4-7 北上方向一般日主線上午尖峰時段流量

區段範圍	交通流量			
	編號	小客車	大客車	大貨車
8.台北-三重	S8	5697	126	1908
9.三重-五股	S9	4479	125	1230
10.五股-林口	S10	3323	204	1288

11.林口-桃園	S11	3390	188	958
12.桃園-機場	S12	2597	198	1358
13.機場-內壢	S13	2692	177	1225
14.內壢-中壢	S15	2248	176	1356
15.中壢-幼獅	S16	2378	163	1269
16.幼獅-楊梅	S17	22327	154	1186
17.楊梅-湖口	S18	1486	146	1076
18.湖口-新竹	S19	1647	139	1007
19.新竹-新竹系統	S20	12272	118	918

而在一般日北上主線之下午尖峰流量（表 4-8）最高者為台北-三重區段，有 9509 輛次。最低者則為新竹-新竹系統只有 2151 輛次。而在一般日北上主線之非尖峰流量（表 4-9）亦以台北-三重區段之交通流量為最高，新竹新竹系統最少，分別為 5618 輛次與 1851 輛次。

表4-8 北上方向一般日主線下午尖峰時段流量

區段範圍	交通流量			
	編號	小客車	大客車	大貨車
8.台北-三重	S8	7382	164	1963
9.三重-五股	S9	5281	150	1787
10.五股-林口	S10	4666	191	1493
11.林口-桃園	S11	3841	173	1223
12.桃園-機場	S12	3644	184	1220
13.機場-內壢	S13	2783	144	1341
14.內壢-中壢	S15	2233	158	1148
15.中壢-幼獅	S16	2047	161	1188
16.幼獅-楊梅	S17	1943	157	1173
17.楊梅-湖口	S18	1304	150	1017
18.湖口-新竹	S19	1359	123	939
19.新竹-新竹系統	S20	1079	114	958

表4-9 北上方向一般日主線非尖峰時段流量

區段範圍	交通流量			
	編號	小客車	大客車	大貨車
8.台北-三重	S8	3712	112	1794
9.三重-五股	S9	3433	149	1189
10.五股-林口	S10	2837	171	1190

11.林口-桃園	S11	2402	157	1038
12.桃園-機場	S12	2473	148	1218
13.機場-內壢	S13	2380	134	1146
14.內壢-中壢	S15	1867	102	1107
15.中壢-幼獅	S16	1735	125	1069
16.幼獅-楊梅	S17	1615	136	1044
17.楊梅-湖口	S18	1404	99	780
18.湖口-新竹	S19	1292	109	786
19.新竹-新竹系統	S20	1012	81	758

在 4.1 與 5.1.3 節視交通量資料為一重要因素來分割研究路段(台北-新竹)成為小的群組別，屆時將會依照群組別將交通量予以合併或分割計算。

2.高速公路匝道部分

由附錄六所蒐集之匝道交通量調查資料中，在北上方向一般日上午尖峰時段進口匝道流量以之五股交流道交通流量最高，有 2815 輛次，湖口交流道最低為 432 輛次。北上方向一般日上午尖峰時段出口匝道流量則亦以五股交流道交通流量最高，有 1421 輛次，最低為 341 輛次之楊梅交流道。

在北上方向一般日下午尖峰時段進口匝道流量以之五股交流道交通流量最高，有 3301 輛次，幼獅交流道最低為 415 輛次。北上方向一般日下午尖峰時段出口匝道流量則亦以台北交流道交通流量最高，有 4619 輛次，最低為 237 輛次之幼獅交流道。

在北上方向一般日非尖峰時段進口匝道流量以之三重交流道交通流量最高，有 2602 輛次，幼獅交流道最低為 323 輛次。北上方向一般日非尖峰時段出口匝道流量則以台北交流道交通流量最高，有 3039 輛次，最低為 296 輛次之楊梅交流道。

3.收費站

在收費站各時段流量資料（附錄七）中，就泰山收費站而言，北上方向之一般日流量以 17-18 時之 7687 輛次為最高，4-5 時之 1101 輛次為最少。楊梅交流道北上方向則亦以 17-18 時為最高，有 2903 輛次，最低則為 4-5 時，僅有 896 輛次。

由上述可整理出北部區域中山高速公路北上交流道之交通量最高與最低者如下表 4-10所示：

表4-10 本研究範圍各北上交流道之交通量特性

北上一般日 交通量		最多者	最少者
主線流量	上午尖峰	幼獅楊梅	內壢中壢
	下午尖峰	台北三重	新竹新竹系統
	非尖峰	台北三重	新竹新竹系統
匝道流量 (進口)	上午尖峰	五股	湖口
	下午尖峰	五股	幼獅
	非尖峰	三重	幼獅
匝道流量 (出口)	上午尖峰	五股	楊梅
	下午尖峰	台北	幼獅
	非尖峰	台北	楊梅
收費站		泰山 17-18 時	楊梅 4-5 時

4.2.3 車輛偵測器(VD)資料

就所蒐集之車輛偵測器資料內容加以說明，資料欄位有資料記錄日期與時間、道路類型（國道 1 號、2 號與 3 號等）、偵測器編號（附錄八）與偵測之速度值。如果就北區範圍偵測器之故障率（附錄十）來看，上午尖峰時段平均為 54%，南下為 45%，下午尖峰時段北上平均 53%，南下平均 42%，離峰時段北上則為 65%，南下為 59%。

再者，將所蒐集到的 VD 資料刪除因偵測器故障所遺失的部分資料後，整理出各區域之 VD 速度資料，將其繪製成圖表（附錄九），以方便分析各區車流特性，下面即簡單說明數個較具明顯交通特性之區域。

1.北上方向

一般日上午往北圖表中，可以發現台北-三重路段，在 AM6:30 之前速率呈現變動較大的情況，之後相對呈現較穩定的狀態，在 8 點至 9 點則有一波速率降低的情況，顯示此尖峰時段車況較為擁擠。三重五股間之速率亦在 6 點左右呈現明顯的不同，深夜速率較上午來得高且不穩定。機場內壢段則可

以發現其尖峰時段為 6:30-8:00 間，速率明顯減緩，上午 9:50 之後速率亦明顯降低。內壢中壢路段 6:00~8:30 為其尖峰時段。中壢至幼獅間之速率變化較大，在幼獅楊梅段亦在深夜 4:30 之前有速率較高且不穩定的情況，楊梅湖口路段則呈現較穩定的速率。

一般日下午往北之台北三重路段 7:30 之前速率較低，在 80 公里/小時左右，而之後在 80 公里/小時以上。桃園-機場段則速率低，約 50 公里/小時左右，5 點至 7 點間速率更低。機場系統-內壢段一般速率皆為 90 公里/小時左右，但於 4 時-8 時之間則明顯降低為 40 公里/小時左右。內壢-中壢與中壢-幼獅之尖峰時段明顯可看出分別為 4:30-8:00 與 4:30-6:30，速率皆在 40 公里/小時左右。幼獅楊梅段與楊梅湖口段之速率約為 80-90 間，呈現非常穩定的狀態，顯示車流行進非常順暢。

2.南下方向

一般日上午往南方向，三重-五股路段尖峰時段可以明顯看出為 7 點至 8 點 30 分之間，速率最低為 38 公里/小時左右。桃園至機場深夜時段之速率呈現較大的波動，而上午時段則相對較為平緩，不過速率較低，且尖峰時段在 9 點 30 分之後，速率更低；五股-林口段與桃園-機場段亦有相同情形，不過其分切點為 6 點半與 5 點半左右，上午尖峰時段亦出現速率下降情形。機場-內壢段與中壢-幼獅段在 9:30 之後速率明顯下降，只有 30 公里/小時上下。楊梅-湖口段與湖口-竹北段之車輛速率皆非常穩定。最後，竹北-新竹與新竹-新竹系統則皆以 6:30 分為分界，之前時段之速率較不穩定。

在一般日下午往南方向，台北-三重段之間車輛速率非常穩定，而在三重-五股路段，在 PM8:00 之後速率有下降的情況發生。桃園-機場間交通情況在 2 點半至 7 點半幾近癱瘓，速率只有 20 公里/小時左右。在中壢-幼獅路段下午 5 點之前車流速率較低，大約為 80 公里左右。楊梅-湖口段、湖口-竹北段與竹北-新竹段之下午時段速率皆非常穩定。

4.2.4 事件(Event)資料

中華顧問工程司之交通千里眼中將事件分類成不同的類型與等級，目前網頁上所提供的交通資訊有突發事件、道路施工、路況總覽、高速公路壅塞路段即時報導等，在資料庫此 Table 中有個欄位為事件等級（Class），該 Class 分別有 A I 九種狀況（表 4-11），分述如下：A 為事故（突發事故）、B 為交通障礙（車輛掉落物，人員行走，動物等等但不造成阻塞）、C 為交通阻塞（因事或物所造成交通阻塞）、D 為交通管制（依照單位發佈管制命令）、E 為號誌故障、F 為道路施工、G 為災變、H 為正常、I 為其他。

表4-11 中華顧問之事件分類種類

等級	事件類型
A	事 故
B	交 通 障 礙
C	交 通 阻 塞
D	交 通 管 制
E	號 誌 故 障
F	道 路 施 工
G	災 變
H	正 常
I	其 他

在資料表中以 Class 做區分，篩選 class 為 A 即為突發事件；篩選為 F 則為道路施工；全部選取則為路況總覽，配合車輛偵測器(VD)速度資料即可找出壅塞路段位置和發生時間，可再進一步察看此路段之事件資料是否有異常之處。

在一般日與週六發生事件之等級比率中（如圖 4-5、圖 4-6），我們可以發現到在週六時道路施工（等級 F）較一般日來得少，而在交通阻塞（等級 C）與事故（等級 A）比率即較一般日來得較多。




圖 4-5 11/27(一)事件等級比率




圖 4-6 12/2(六)事件等級比率




圖 4-7 1127(一)各等級事件之南北方向比率




圖 4-8 1129(三)各等級事件持續時間

在 11/27(一)各等級事件之南北方向比率 (圖 4-7) 中可以發現事件等級以道路施工類型為最多，而其中各事件等級皆以往北方向比率為較高。圖 4-8 之 11/29(三)各等級事件持續時間亦以道路施工為最久，平均大約需要 3 小時以上，其它類型事件之持續時間則差異不大，大致為 30-50 分鐘左右。

4.2.5 客運車輛 GPS 資料

經由台汽所蒐集到之 GPS 資料，吾人將轉換後所得之各車輛旅行時間進行分析，依研究群組區分，計算出各群組之平均旅行時間，並且將資料細分以計算每日各群組通過客運車輛之平均旅行時間，結果如下表 4-12 所示。

表4-12 客運車輛各群組旅行時間（往北方向）

	每車平均旅行時間(sec)					資料個數
	1201(五)	1202(六)	1203(日)	1204(一)	平均	
群組 8_新竹-楊梅(26)	1080	1093	1298	1038	1127	21
群組 7_楊梅-幼獅(2)	78	72	91	77	79	113
群組 6_幼獅-機場(15)	848	770	865	719	801	116
群組 5_機場-半處(1)	51	38	45	43	44	110
群組 4_半處-桃園(2)	87	83	103	83	89	110
群組 3_桃園-五股(16)	975	746	804	765	822	105
群組 2_五股-三重(6)	342	248	258	260	277	104
群組 1_三重-台北(2)	114	189	197	189	172	35
各車輛旅行時間加總(70)	3574	3239	3661	3174	3412	

()內為群組路段之距離，長度單位為公里

可以明顯看到不同日（12/1-12/4）之新竹-台北之北上車輛平均旅行時間（圖 4-9），其中以週日與週五往北方向之旅行時間為最長，平均大約需要 1 小時。最快則為星期一，所需花費的旅行時間大約為 52 分鐘，這些情形大致與一般認知的觀念相同，而各群組之旅行時間（圖 4-10）亦大致類似。週日以群組 8、週五以群組 3 為較久。




圖 4-9 GPS 各日台北-新竹旅行時間




圖 4-10 客運車輛各群組平均旅行時間

另一方面，若將所有車輛行駛各群組之旅行時間依日期時間順序繪製圖表（圖 4-11），其所隱含之概念亦與車輛偵測器相同，可以使人瞭解各群組不同時間之交通狀況為何，可以作為各群組旅行時間預測課題之參考。

我們可以由圖 4-12 發現到群組距離較遠之路段（如群組 8、6、3），旅行時間變動的幅度亦越大。旅行時間明顯增長的時間為星期五與週日晚上，星期一之旅行時間最為穩定。在圖 4-13 之群組距離較短之路段（如群組 1、2、4、5、7）則因旅行時間短，差異較不明顯，不過仍可發現其旅行時間明顯增加之日期時段與群組距離長之日期時段相吻合。




圖 4-11 客運車輛各群組各車輛(依車輛編號)旅行時間(全部群組)




圖 4-12 客運車輛各群組各車輛(依車輛編號)旅行時間(群組時間長)




圖 4-13 客運車輛各群組各車輛(依車輛編號)旅行時間(群組時間短)

而就實際客運車輛行駛於高速公路上之旅行時間來看，將各群組路段之旅行時間繪製成次數分配圖（圖 4-14、圖 4-15、圖 4-16、圖 4-17），以瞭解本研究所區分之各群組車輛行駛時間分佈的情況。在群組 1_三重->台北所需花費的旅行時間以 200-220 秒鐘為最多，大多車輛旅行時間小於 200 分鐘。群組 2_五股->三重路段則以 240-280 秒鐘為絕大部分。群組 3_桃園->五股路段則大約需要 700-800 秒鐘行駛。群組 4_桃園與機場間->桃園所需旅行時間為 2 分鐘以內。群組 5_機場->桃園與機場間之客運車輛旅行時間絕大部分為 1 分鐘。群組 6_幼獅->機場間車輛行駛大約在 500-750 秒鐘間。群組 7_楊梅->幼獅路段之旅行時間大約為 50-100 秒左右。群組 8_新竹->楊梅則因資料數較少，以 1000-1100 秒鐘次數為較多，其它車輛行駛時間在 900-1600 秒皆有樣本。





圖 4-14 群組 1、群組 2 客運車輛旅行時間次數分配圖





圖 4-15 群組 3、群組 4 客運車輛旅行時間次數分配圖





圖 4-16 群組 5、群組 6 客運車輛旅行時間次數分配圖





圖 4-17 群組 7、群組 8 客運車輛旅行時間次數分配圖

4.3 資料分析

4.3.1 不同資料來源間關係

若各資料來源蒐集期間相同，皆代表同一時間、地區之交通特性，只是以不同方式呈現。在個別資料來源中，車輛偵測器的故障率（附錄十）頗高，可能會造成未來搜尋與客運車輛 GPS 資料相同時間上發生無法對應的情形，資料對於旅行時間預測會有所誤差，勢必要結合其它資料來源以進行資料融合工作，互補彼此間的不足。

雖然旅行時間與交通狀況關係非常密切，不過旅行時間乃為交通狀況之結果，因此兩者間顯示之時間上會有所差異，有一段時間的誤差。舉例而言，在高速公路上剛發生某一事件，就車輛偵測器與旅行時間資料並不能立刻顯示出來，而最先是在事件資料上有所紀錄，如此一來預測時便能事先略知未來旅行時間應有增加的趨勢。相反的，當事件處理完畢消失時，事件資料上便刪除此一事故資料，因此如果資料來源僅有事件資料的話，便不能考慮到目前車輛受之前交通壅塞所造成的影響，必須持續一段時間方能逐漸減緩，此時其它資料來源如偵測器速率資料即可將車速仍是緩慢的情形納入考量，增加旅行時間預測模式之正確性。

對於重現性擁擠所造成的影響，由於即時資料為當時所蒐集到之最新資料，並沒有預知尖離峰、例假日的功能，如能再利用所蒐集到的交通參數資料彙整成歷史資料庫，勢必能由以往的交通資料大致抓住整體交通變動的方向，事先瞭解發生重現性擁擠之時段為何時，亦可增加本研究旅行時間預測模式之準確度。

4.3.2 資料庫特性

本研究所蒐集到的資料大致為台汽客運車輛 GPS 資料、高速公路車輛偵測器資料、交通千里眼網站所提供之事件資料（包含警廣事件資料）

高速公路幾何資料與其它文獻報告中所調查之交通參數資料等。大體而言可以加以區分成質化與量化兩種類型資料，而本研究為預測交流道間之旅行時間，因此若就其所隱含的特性來觀察，亦可將所蒐集到的資料分成「具有未來概念性」與「不具有未來概念性」資料。

舉例來說，如高速公路幾何資料皆不因時間變動而有所變化，因此屬於「不具有未來概念性資料」。而主線流量與匝道流量等交通參數資料則因為可依據之前的歷史資料庫來尋找未來某時刻所對應的資料，因此為「具有未來概念性」。在後面章節將會對本研究旅行時間預測模式所考量之輸入變數做一詳細的介紹，說明考量未來概念後，資料範例的產生方式。

為何需要考量資料是否「具有未來概念性」呢？吾人認為本研究範圍高速公路北部區域行駛之駕駛人所需旅行時間資訊會因個別起迄點不同（each O-D pair）而有不同的需要，而且各群組旅行時間預測模式之輸入變數資料若直接帶入駕駛人起點時刻所蒐集到的資料的話，會造成愈後面群組路段之旅行時間預測值誤差愈大，因此各群組的輸入變數資料上亦會根據車輛起點至本群組路段所估計的時間往後尋找具有未來概念性輸入變數的資料，期能將全部群組路段考量同一時刻之輸入變數資料所造成的誤差給予減少，以增加網路預測的準確性與提供旅行時間的實用性，而有關類神經網路旅行時間預測模式之範例如何製作成隱含具有未來概念的方式將會在後面 5.1.2 節加以詳細說明。

小結

由上述資料分析說明中，大致可以瞭解到資料的內容與特性，在未來則可作為構建類神經網路模式之基礎。就資料量而言，可以發現本研究所蒐集之資料量非常龐大，處理工作上亦顯得格外複雜。為了方便往後類神經網路預測模式範例之製作方便，勢必要對於各資料來源所蒐集到的資料整理成容易彼此對照的格式，以便找尋相同時刻資料。而範例中最重要的是包含未來概念範例，因此資料格式亦需考量其製作的方便性。

第五章 模式構建與網路績效評估

5.1 模式構建

每個用路人所需之旅行時間資訊是以 OD 起迄點組合對 (each O-D pair) 為主要需求，不過若每個起迄組合須建立一個預測模式，預測模式與構建工作將會變得多樣且複雜。為此，本研究特別以群組路段為模式構建之基準每個群組路段皆有特定的類神經網路模式，待旅行時間需求發生時，OD 決定後，再個別預測之間的旅行時間加總而來，如此便能有系統且管理上更有效率。

5.1.1 構建之類神經網路類型

1.類神經網路軟體(NeuralWorks Professional II/Plus (簡稱 NW2))介紹

NW2 是一套完整的類神經網路建構環境，它不但適合企業界用以發展實際的應用，也適合學術界用以發展新穎的網路。它的特色包括：

- a. 多樣的網路模式：提供多種著名的類神經網路模式，使用者只要透過功能表即能產生所需的網路，適合用以快速發展實際的應用。
- b. 效率的發展環境：提供多種稱為「儀表」的繪圖視窗，可以在螢幕上以圖形方式顯示網路學習過程時的誤差與連結權重值的調整變化情形，以及「修枝」(Purge)網路連結等功能，使用者可以藉此有效率地改進網路學習品質，發展最佳效率的網路模式。
- c. 開放的網路輸出與輸入 (IO)：除了鍵盤與檔案可作為網路 I/O 外，還提供更具威力的「使用者輸出入程式」方式作為網路之輸出與輸入，可作為前處理、後處理、傳遞訊息給使用者控制程式，從儀表讀入資料，使用者可以撰寫 C 語言程式，連結它所提供的 C 程式庫，達到這些目的。

- d. 實用的系統整合：提供介面將網路轉換成標準 C 語言程式能力，以便將網路嵌入應用系統中。
- e. 豐富的應用實例：在國內外工商界/學術界已有很多個成功的案例。

NW2 的軟體介面如圖 5-1 所示：




圖 5-1 NeuralWorks Professional II/Plus (NW2) 軟體介面

2. 模式類型與目的

基本構想是先依照個別資料來源建立類神經網路預測模式，探討單一資料來源（VD 與 GPS 資料）之預測能力，另外還有構建其它類型之預測模式，ANN1-時間序列類神經網路、ANN2-時間序列+交通特性之類神經網路與 ANN51、52、6-考量完整資料之類神經網路。若未來實用上任何資料來源出現問題，則可採用次佳的預測模式來替代原先較為準確的類神經網路模式。本研究所建構之類神經網路模式如表 5-1：

先說明時間序列概念，時間數列的種類簡單可分成下列幾種：

a. 穩定型時間數列的預測

設 X_n 為時間數列 $\{X_n\}$ 之最後一個觀測值。預測從 n 時間起 1 個預測值 X_{n+1}, \dots, X_{n+l} ，通常記作 $X_n(1), \dots, X_n(l)$ 。

b.非穩定型時間數列的預測

在股票、匯率、期貨等資料中，其時間數列走勢常呈現高者越高，低者越低的情形。此類資料並沒有固定的平均值，而且趨勢漂浮不訂，若以隨機漫步模式(Random Walk)來解釋則頗實用。

c.趨勢型時間數列分析

針對時間數列的走勢，具有向上遞增或向下遞減的傾向（非穩定型數列但有點穩定）。例如呈穩定性指數增加或沿著一斜率水準前進的時間數列。

d.季節性時間數列分析

對於有相差固定時間間隔的觀測值，彼此間有高度的相關性，期間格時間長以日、月、或季..為單位，以符號表示，此特性的時間數列稱為季節性的時間數列。例如冰品的銷售產量可知每年的 7 月份銷售量，與前後幾年 7 月份的銷售量關係大於當年度的前後月份銷售量情形，因此則適用此模式分析。

而本研究之 ANN1-時間序列模式：以預測群組路段為對象，依序列出各車輛通過此群組路段之旅行時間，即輸入變數分別為此群組路段前一車之旅行時間、前面第二車之旅行時間..等依此類推，然後再探討構建各群組路段 ANN1 模式所需之輸入變數個數。

ANN2-時間序列 + 交通特性之類神經網路模式：用意乃是為了增加不同時期的交通參數資料，期能有效改善 ANN1 的不足之處。

ANN3 與 ANN4-速度路段模式：希望藉由群組車道長度與速率資料相結合以計算估計所需之旅行時間。

ANN51 類神經網路模式：將所有蒐集到的交通幾何資料納入考量。

ANN52 類神經網路模式：除了 ANN51 之目前時間範例資料外，更額外衍生出未來時間範例資料，期能利用這些範例資料來讓類神經網路學習群組之間的關連性與未來實際應用時的適用性。另外考量未來實際運用

上，除第一群組路段外，其它下游路段之時間皆由預測時間所推估，為了促使類神經網路學習此一特性，特將此種概念範例加入。

ANN6 類神經網路模式：為簡化 ANN52 未來時間模式中衍生範例之製作，且考量上游路段旅行時間為輸入變數對於網路所帶來的影響，若僅加入單一變數（鄰近上游路段旅行時間）可能會出現一對二的情況發生，舉例來說：上游群組旅行時間長，可能原因如發生事件或交通擁擠等，不過其影響卻有所不同。發生事件（如圖 5-2）會促使事件點之前交通呈現阻塞情況，而事件點之後的路段則因沒有交通瓶頸而順暢許多，旅行時間亦縮短。相反地，如果上游路段旅行時間長的原因乃由於交通擁擠，本路段所需之旅行時間勢必相異不遠，仍須花費較長的旅行時間。為了避免類似判別錯誤情形發生，因此本研究考量納入「上游路段最末個 VD 速度」變數加以修正此一缺點。

加入鄰近上游群組路段中最後一個車輛偵測器之速度主要原因是為了修正上述模式可能判別錯誤之缺點。如果加入偵測器速度值後，即可由 VD 速度來判別上游路段與本路段之間的關係。另一方面，GPS 速度為變動性的資料，並沒有固定的位置，為避免群組內沒有資料的情形產生，因此決定採用偵測器速度為主。

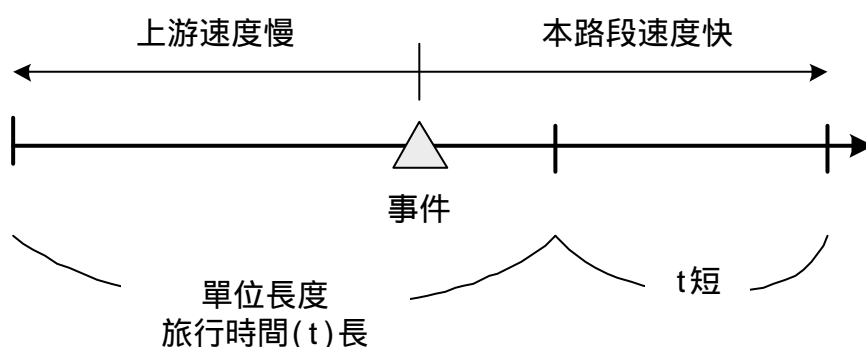


圖 5-2 上下游路段與事件關係

採用上游群組路段之旅行時間為輸入變數之原因

1. 找出上游與下游路段之關係
2. 上游路段交通特性可隱含包括於旅行時間內。

3. 交通情形就如同衝擊波 (圖 5-3), 隨著時間而逐漸移動, 將上游交通特性傳遞至下游路段
4. 經過 t 時間後, 交通情況向右平移至下游群組路段 (如由 A->B)。
5. 若固定時間觀之, C、D 兩處地點交通情況不同, 有 t 時間差。




圖 5-3 上下游群組路段交通特性關連性

取一個上游群組路段之旅行時間為輸入變數。簡單而言，一個鄰近之上游路段旅行時間所隱含的意義已經包含在這之前所有的上游路段交通特性，亦表示本路段旅行時間受到所有上游路段旅行時間之影響可用一個上游路段旅行時間變數加以表達即可。

表5-1 本研究所建構之類神經網路模式

旅行時間預測模式 (皆為倒傳遞模式)	建構網路模式概念	目的	輸入變數
ANN1-時間序列類神經網路	時間序列模式	利用歷史旅行時間資料預測旅行時間	不同時期之旅行時間
ANN2-時間序列+交通特性之類神經網路	時間序列 + 幾個其它交通特性變數	由於歷史旅行時間資料間隔過大，恐不能即時反應目前之交通特性，準確地預測目前的旅行時間，因此考慮納入含有交通特性之變數，以期改善原僅有一個旅行時間變數類型之時間序列模式，增加其預測績效。	不同時期之旅行時間、交通特性變數（流量、速度、時間）
ANN3-車輛偵測器(VD)+車道特性之類神經網路	路段與速度模式 ANN31_(路段速率) ANN33_(路段速率+時間)	由於速度與路段長度已知，則可計算出個路段之旅行時間，若速度更新時間愈快，所預測之旅行時間亦愈準確，交流道間之旅行時間預測值亦不會誤差過大。	車道變化路段數、 各路段之長度、 車道數與 VD 速度
ANN4-GPS+車道特性之類神經網路	單用偵測器資料	僅車輛偵測器資料的情況下，其旅行時間預測績效	GPS 速度、車道變化路段數、各路段之長度、

			車道數與位置)
ANN5_全部考量 ANN 模式範例 (目前 + 未來概念)	<p>(所有資料皆考量進去)</p> <p>ANN51_全部考量 ANN 模式範例 (僅目前概念)</p> <p>ANN52_全部考量 ANN 模式範例 (+ 考量未來概念衍生範例)</p>	包含車輛偵測器資料、事件資料、客運車輛 GPS 資料、交通量資料 (主線流量、匝道流量) 幾何特性資料 (路段長度、主線車道數、匝道型式與個數) 收費站特性 (收費站車道數、設計容量) 小路段車道數與長度、日期時間、車輛出發時間等	偵測器資料、事件資料、客運車輛 GPS 資料、交通量資料 (主線與匝道) 幾何特性資料 (主線車道數、長度) 匝道型式與個數、收費站設計容量與車道數、日期時間、車輛出發時間等
ANN6_全部考量 ANN 模式範例 (考量前一群組之旅行時間)		本群組與上游群組之關係	同上 + 上一群組路段之旅行時間與 VD 速度
(選取預測模式)	最終，各交流道選取個別較佳之網路模式進行實證分析	<p>原則是依照各交流道來細分成數個旅行時間預測模式，但亦應將主線車道數與交通特性考量進去，分割成幾個適當的路段 (群組)，每個路段 (群組) 必須自行建構特屬的預測模式 (即進行 1-6 的模式建構)。</p> <p>各路段 (群組) 最後則選取網路績效較佳的預測模式進行實證，以期使用者欲預測之起迄點旅行時間值最為準確。</p>	

3.輸入變數說明

大致而言，一般相關文獻所選擇之輸入變數大多為可量化之變數，如偵測器所測得之速度、佔有率與流量，鮮少採用質化交通狀況或事件嚴重程度作為輸入變數。而本研究由於所蒐集之交通資料包含多來源，且同時具有量化與質化資料，其時間間隔又有所不同，因此所構建之類神經網路必須合理且有效地運用所蒐集到的交通資料。類神經網路將會利用各群組所對應之資料（預測群組之事件資料、施工、路況、旅行時間序列資料、車輛速度、流量、道路幾何特性等）來作為輸入變數以預測每路段個別之旅行時間，在網路績效評估方面，則利用實際蒐集資料來進行網路驗證工作。

在時間序列之輸入變數選取上，徐國鈞(民國 90 年)應用時窗圖作為輸入資料設定之概念。其中有關車流動態資料的輸入，研究採用費伯納奇數列（去除第一數）所建立的時窗區域佔有率資料為輸入數列。意即取用決策時間 t 之前 2 秒、前 2 5 秒、前 5 秒 10 秒以此類推，如此時間間隔之平均區域佔有率為輸入變數。

而所有「面」的交通參數中，最簡易能代表車流運作現況的即是偵測區域的 t 時間內之平均區域佔有率，本研究將此定義為：

$$\%OCC_t = \frac{\sum \frac{A_{OCCUPANCY_ZONE}}{A_{detector_ZONE}}}{n}$$

其中， t ：依系統而運作需要與偵測設備功能限制而設定，其設為 1 秒。

$A_{OCCUPANCY_ZONE}$ ：在偵測時間點上，被車輛佔有的區域面積

$A_{detector_ZONE}$ ：整個偵測區域的面積

n ：在偵測設備 t 時間內，可進行偵測的次數。在車流運行狀態下，區域佔有率會隨著時間軸的推進而會有高低變化，此即隱藏流量的概念。另一方面，區域佔有率也可以視同巨觀的車流密度，就交通參數特性得

知，以密度來辨識交通狀況，並不會出現一個密度值對應兩種交通情況的困擾，因此乃為極佳的車流現況參數。

「費伯納奇數列」(Fibonnachi)是任意前二項之和為第三項，如 1, 2, 3, 5, 8, 13, 21 ..., 這種數列具有除去第一個數字「1」外，任何一個數字除以前一個數字，近似 1.618 的特性，此種計算方法稱為「黃金切割法」，常應用於統計預測趨勢上。

建構類神經網路之輸入層必須先決定所需回顧的時段數，這必須經由模擬實驗（試誤法）才能測試其最佳的時段數。而本研究時間序列類神經網路模式是以客運車輛 GPS 旅行時間為其輸入資料，資料輸入亦可採取上述概念取出範例，不過由於各群組資料量有明顯不同，若採用此一方式（以時間選取）車輛，將會有資料不足以進行類神經網路訓練與測試的情形發生。因此本研究最終決定依序挑選旅行時間序列資料（以車輛選取）來作為模式 1 之輸入資料，探討每一群組路段旅行時間預測模式需要變數個數多少，才能達到準確的預測值。

而其它類型網路各有不同輸入變數，下表 5-2 即為全部考量之類神經網路模式之輸入資料。

表5-2 時空類神經網路所考量之輸入變數

資料來源	資料型式	輸入變數(數字表示輸入 ANN 的順序)	內容	ANN1	ANN2	ANN31	ANN33	ANN4	ANN51	ANN52	ANN6
GPS	時間	1.時間	幾時 0-23		V		V		V	V	V
		2.上下午	1, 2						V	V	V
		3.星期幾	星期幾 1-7						V	V	V
GPS	travel time	28.前車之旅行時間	Sec	V	V						
		29.本車前一群組路段之旅行時間	Sec								V
VD	Speed	30.本車前一群組路段之 VD 速度	KPH								V
		4.偵測器速度	KPH		V	V	V		V	V	V
GPS		7.GPS 速度	KPH					V	V	V	V
事件	事件	5.事件種類個數	整數						V	V	V
		6.事件等級	A~I						V	V	V
幾何資料	主線部分	8.群組內車道變化路段數	整數			V	V	V	V	V	V
		9.群組內各路段車道數	整數			V	V	V	V	V	V
		10.群組內各路段長度	KM			V	V	V	V	V	V
		12.群組內交流道數	整數						V	V	V
交通流量		11.主線流量	車輛數		V				V	V	V
幾何資料	匝道部分	13.各交流道進口匝道匝道數							V	V	V
		14.各交流道出口匝道匝道數							V	V	V
交通流量		15.各進口匝道流量	車輛數						V	V	V
		16.各出口匝道流量	車輛數						V	V	V
幾何資料	收費站	17.群組內收費站個數							V	V	V
		18.各收費站車道數							V	V	V
		19.收費站車種車道數(小型車不找零)							V	V	V
		20.收費站車種車道數(小型車找零)							V	V	V
		21.收費站車種車道數(大貨車)							V	V	V
		22.收費站車種車道數(聯結車)							V	V	V
		23.收費站車種容量(小型車不找零)							V	V	V
		24.收費站車種容量(小型車找零)							V	V	V
		25.收費站車種容量(大貨車)							V	V	V
		26.收費站車種容量(聯結車)							V	V	V
交通流量		27.收費站流量	車輛數						V	V	V

經過模式構建後（圖 5-4），在各群組個別網路模式經過訓練與測試後，將得到之網路績效與旅行時間估計值相互比較，以評估各群組路段最佳類神經網路模式為何，個別挑出最佳模式合併來預測本研究範圍任一起迄點交流道間之旅行時間，其給予駕駛人一準確之估計值，以便進行旅程之規劃。

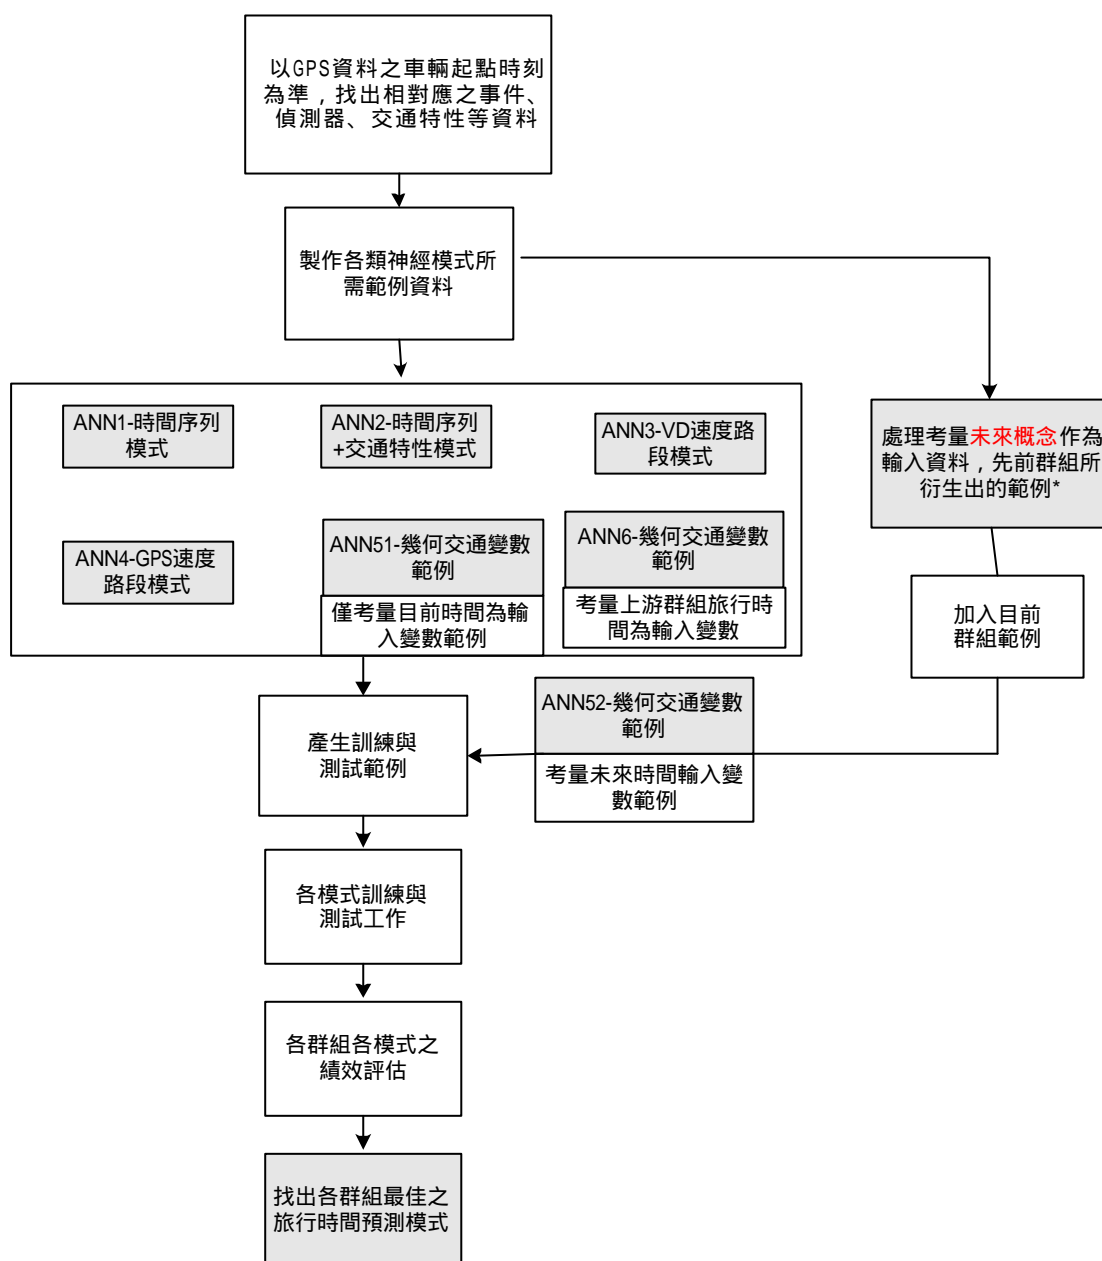


圖 5-4 本研究模式構建與績效評估流程圖

*即圖 5-3 與圖 5-4 中未來時間概念所衍生之範例

5.1.2 訓練與測試範例製作

1.ANN 範例製作流程圖

之前提到本研究所蒐集到的資料大致為台汽 GPS 資料、高速公路偵測器資料、事件資料（包含警廣事件資料）、高速公路幾何資料與交通參數資料等，就其所隱含的特性（4.3.2 節）來觀察，亦可將所蒐集到的資料分成「具有未來概念性」與「不具有未來概念性」資料。

若資料皆不因時間變動而有所變化，則屬於「不具有未來概念性資料」。相反地，如果交通參數資料則可依據之前的歷史資料庫來尋找未來某時刻所對應的資料，則為「具有未來概念性」資料。考量資料是否「具有未來概念性」則能對於 ANN52-類神經網路製作具有未來概念性範例時有明確的方向，那些輸入變數有歷史資料可供查詢，在額外衍生出的未來概念範例中，須考量預估車輛在未來到達此點時的資料為何。那些資料僅有固定型式或最近所蒐集到的資料，在衍生出的未來概念範例中，則不需加以預估未來資料。ANN 範例製作流程圖（圖 5-5）：

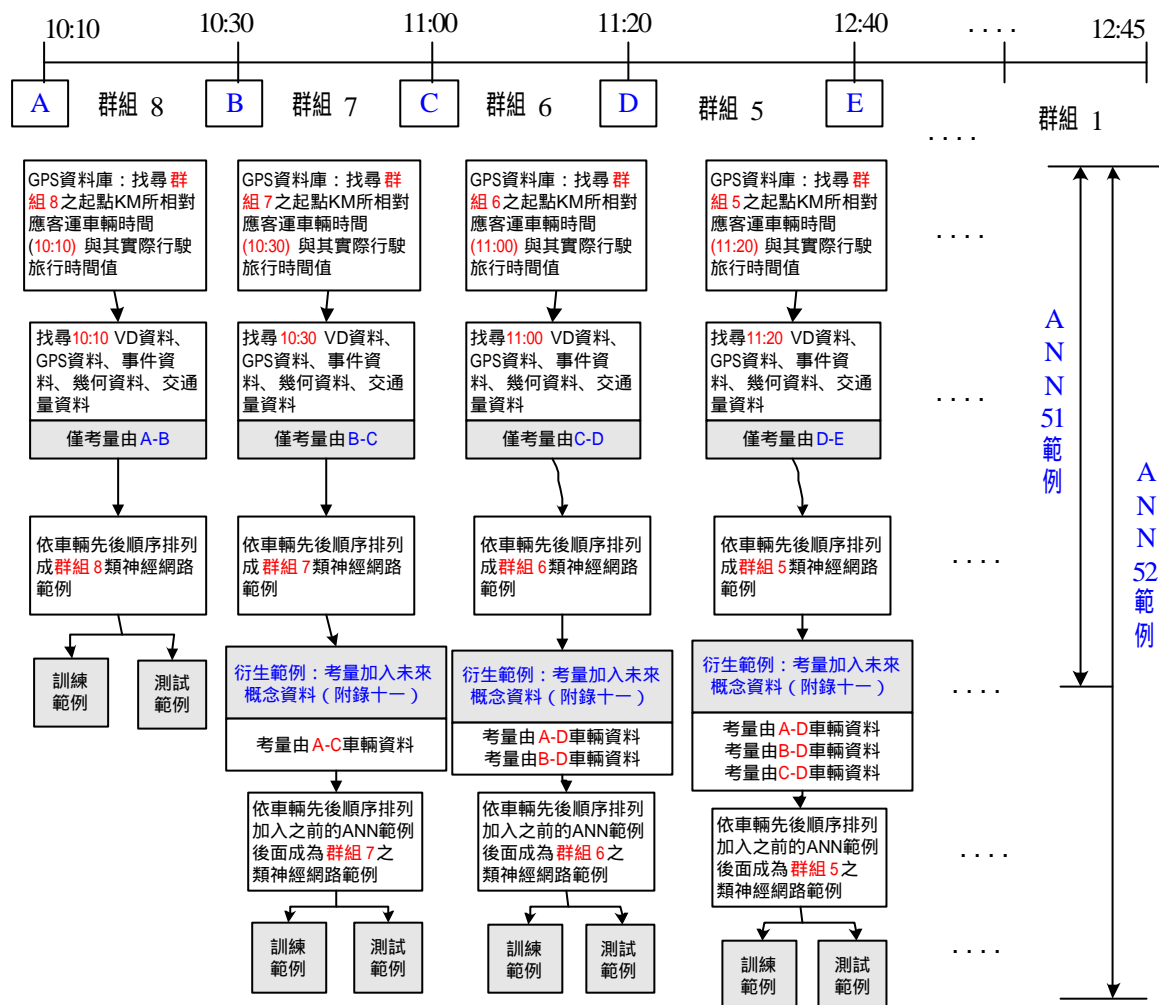


圖 5-5 各群組路段 ANN 範例製作流程圖

為了方便往後類神經網路預測模式範例之製作方便，勢必要對於各資料來源所蒐集到的資料整理成容易彼此對照的格式，以便找尋相同時刻資料。而範例中最重要的是衍生的未來概念範例，因此資料格式亦需考量其製作的方便性。

2.範例製作原則

不可避免地，在範例製作的過程中會面臨到一些值得注意問題，如遇到對應時間點沒有相對應資料的情況（因為各資料來源蒐集間隔時間不同），吾人利用其前後資料內差求得以替代缺少的資料。另外具有未來概念性之輸入資料，本研究將利用歷史資料建立其資料庫，以便製作範例之

查詢。

3.具有未來概念特性資料之範例-ANN52

步驟如圖 5-5之 ANN52 衍生範例與圖 5-6 (或參考附錄十一), 利用前面群組範例與其旅行時間估計值來作為本群組衍生性範例之基礎。利用歷史資料庫來查詢未來時刻之交通資料, 以作為估計車輛到達此群組可能的交通情況。

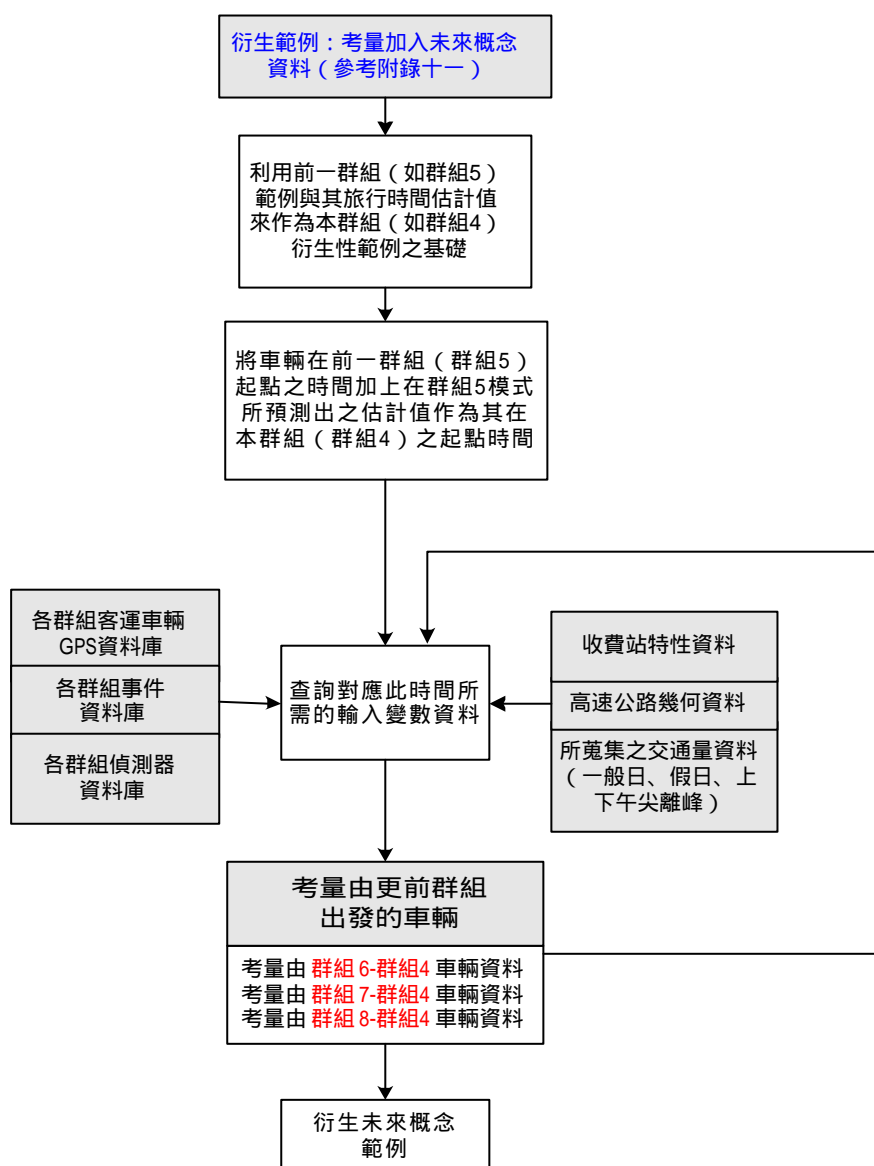


圖 5-6 未來時間概念資料範例之衍生步驟-ANN52

可以再深入說明以上游群組起點出發時間再加上其於上游群組模式所預估之旅行時間, 作為本群組假設之起點出發時間, 而其輸入變數亦根

據此估計出發時間來查詢相對應的輸入資料，其輸出實際旅行時間則與同輛車之旅行時間相同，亦即在範例中資料有 2 部分，一部份為真實出發時間與此群組實際之旅行時間的資料，另一部份則為推估之出發時間與此群組實際之旅行時間(如圖 5-7)。概念上是為了使類神經網路適應未來實際上線運作情形，且未來下游群組發車時間需由上游群組發車時間 + 上游網路旅行時間估計值，因此必須找出上下游群組推估時間的關係，以帶入類神經網路加以學習。

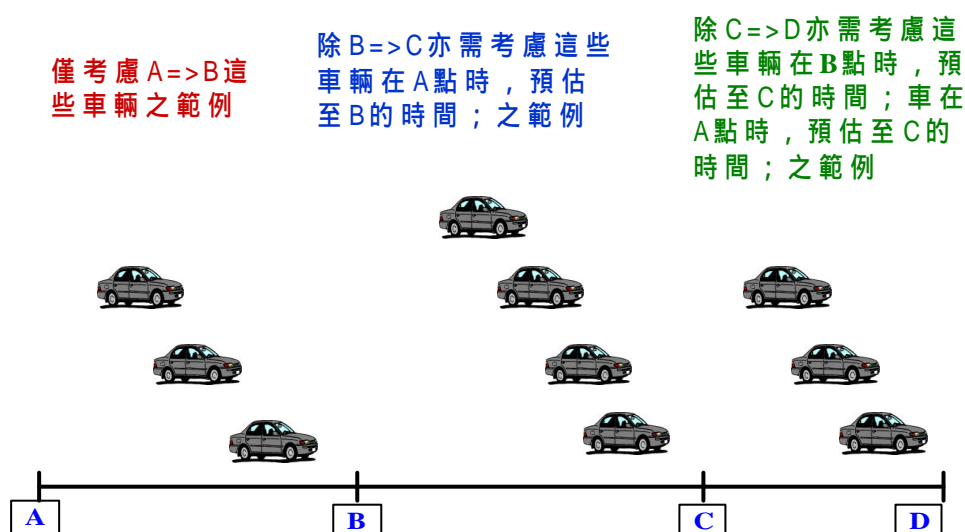


圖 5-7 各群組路段範例製作概念-ANN52

大致概念是將所要預測旅行時間之起迄點劃分為數個以主要交流道為基準(Interchange-based)之預測模式，最終將各區段結果加總起來獲得總旅行時間。以下圖 5-8 為例，輸入資料考量旅行時間為長期路段預測，必須避免到達下個路段時造成先前所獲得的旅行時間預測值意義不大（因到達下個路段時，輸入資料又有所更新變動（由 X_t 更新為 X_{t+T1} ），造成加總的部分路段旅行時間值會有誤差），為了達到相當程度的精確，因此並非皆為前一期(t)所蒐集到的即時交通參數，必須納入預測未來輸入資料的概念。換言之，鄰近路段旅行時間(T1)預測模式之輸入變數為所蒐集之即時(t)交通參數；而下游路段旅行時間(T2)預測模式之輸入資料則須採用未來（t+T1 分鐘後）的交通參數資料，亦即納入旅行時間 T1 方可到達下個路段的概念，同理由所估計之未來(t+T1+T2 分鐘後)輸入資料預測旅行時間(T3)，最後加總 $T1+T2+T3$ 得總旅行時間值，如此模式與資料才能達到準

確度。




圖 5-8 輸入資料考量未來概念特性-納入旅行時間估計值

5.1.3 預測模式之群組路段

研究範圍：因為限於上述各變數之實際蒐集資料，僅能針對台北、三重至新竹系統交流道進行旅行時間預測課題之分析。而本研究為求旅行時間預測誤差不致過大，考量高速公路各交流道特性與重要性，將所研究之台北交流道-新竹交流道路段切割成數個群組（表 5-3）。

表5-3 本研究群組別

本研究群組別	交流道起迄(里程數)	距離(KM)
群組 8	新竹(95)->楊梅(69)	26
群組 7	楊梅(69)->幼獅(67)	2
群組 6	幼獅(67)->機場(52)	15
群組 5	機場(52)->桃園與機場間(51)	1
群組 4	桃園與機場間(51)->桃園(49)	2
群組 3	桃園(49)->五股(33)	16
群組 2	五股(33)->三重(27)	6
群組 1	三重(27)->台北(25)	2
合計	新竹(95)->台北(25)	70

5.2 網路訓練與測試工作

在上述範例產生的過程中，本研究先暫時將範例依序排列，再進行切割訓練與測試範例。原則上為求往後實證分析之方便找尋，分割的方式亦有固定的規則，避免同一輛車於各群組旅行時間估計值加總時，不能順利相對應。測試(test)範例則是以全部範例為 3 的倍數列進行選取，其它的範例則作為網路訓練(train)之用。目前用於類神經網路的範例資料為日期為 12/1：8 筆，12/2：30 筆，12/3：37 筆，12/4：47 筆，共 122 筆。如果考慮未來概念範例的產生，所衍生出來的範例數會隨著群組別的增加而遞增快速（因增加前面群組的範例）。

5.2.1 網路訓練步驟

所有預測模式之網路訓練次數皆在 50000 次以內即呈現收斂的狀態，因此本研究各群組各類型網路預測模式皆以 50000 次作為固定條件，試誤出隱藏層處理單元數應為何，並針對其網路績效加以說明。

5.2.2 各網路輸入變數

「Ann1_時間序列」訓練各種時間序列變數數目，為歷史車輛之旅行時間。「Ann2_時間序列+交通特性」亦訓練各種時間序列變數個數，但輸入變數多加了時間、速率與主線流量資料。「Ann31_路段速率」則是以偵測器速度、路段變化數、車道與路段長度作為輸入變數，「Ann33_速率路段+時間」則是以 Ann31_路段速率再加上時間作為輸入變數、「Ann4_GPS 速率路段」輸入變數與 Ann31_路段速率相同，只不過 VD 速率改成 GPS 速率。「Ann51_僅目前時間概念」之全部考量 ANN 模式，範例僅考量此群組目前時間資料作為輸入、「ANN52_考量未來時間」則考量增加未來概念輸入變數範例。ANN6-「加入上游群組旅行時間」之全部考量類神經網路模式。

3.本研究之網路以 Sigmoid、TanH 函數為轉換函數，其它參數設定如下：

學習法則採用 Delta Rule，初始權重值以隨機方式產生，權重值區間為[-1,1]，慣性因子(Momentum)為 0.4，採用完全連結(Full Connection)的網路架構。

將選取網路測試之 RMSE 最低者作為此群組路段此類型網路架構之最佳預測模式。因此共可選出 8 群組別 * 8 種網路類型(ANN1_時間序列、ANN2_時間序列+交通特性、ANN31_路段速率、ANN33_速率路段+時間、ANN4_GPS 速率路段、ANN51_全部考量 ANN 模式範例 (僅目前概念)、ANN52_(考量未來概念輸入變數範例)與 ANN6_全部考量 ANN 模式(加入上游群組旅行時間為輸入變數) = 64 個績效佳的模式進行分析。

5.3 網路績效評估

本節將針對各類型神經網路績效進行評估 (網路輸出值(real output)與實際期望值(desired output)、RMSE、Correlation)。

5.3.1 估計指標

績效統計量(Lewis, 1982)

1. 平均絕對值誤差率 (平均絕對誤差百分比) (Mean Absolute Percentage Error; MAPE)

作為預測模式好壞的評估指標。主要是因為 MAPE 為相對數值，不受模擬值與估計值之單位及大小的影響，而能客觀地獲得估計值與模擬值間之差異程度，而本研究之選取模式 (同一群組不同網路類型間) 則亦採取此一衡量標準，將網路輸出值與實際值進行比較計算。

$$MAPE = \frac{1}{M} \sum_{k=1}^M \left| \frac{x(k) - x^{\wedge}(k)}{x(k)} \right| * 100\% , \text{ 其中 } x(k) - x^{\wedge}(k) = e_k$$

若值越接近於 0，表示估計效果越佳。另外，Lewis(1982)則認為 MAPE 是最有效的評估指標，並對於 MAPE 值的大小提出說明。如表 5-4 所示。

表5-4 MAPE的評估標準

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

2.均方誤差(Mean Square Error; MSE)僅作參考之用。

$$MSE = \frac{1}{M} \sum_{k=1}^M e_k^2$$

3.均方誤差平方根(Root Mean Square Error; RMSE)

反觀 MSE 或 RMSE 雖對誤差加以懲罰，但其非一相對數值，且每一誤差平方和皆使用相同的權數，故其會受到大小、單位不同等影響，因此僅能將其列為參考之用。而本研究之選取模式（同一群組相同網路類型間）則亦採取此一衡量標準。

$$RMSE = \sqrt{MSE}$$

4.平均誤差率(Mean Percentage Error; MPE)

$$MPE = \left[\frac{1}{M} \sum_{k=1}^M \frac{e_k}{x(k)} \right] * 100\%$$

5.平均絕對值誤差(Mean Absolute Error; MAE)

$$MAE = \frac{1}{M} \sum_{k=1}^M |e_k|$$

其它如相關係數(Correlation)、網路輸出值與實際值之殘差值(Error)

5.3.2 網路績效

表 5-5 表 5-12 即為各群組進行各種類神經網路構建工作時所得之網路績效，本研究對於相同類神經網路模式在架構上的選取是以 ANN 軟體所提供的測試 RMSE 指標為標準；而對於同一群組路段不同類神經網路模式之選取則是以客觀的 MAPE 指標來評選最佳的 ANN 模式。在表中所選取之網路模式架構符號定義說明如下：g1_ANN103_Sigmoid_H1 中，g1 表示群組別，ANN103 表示為 ANN1 模式，採用 3 個輸入變數作為時間序列輸入資料，並以 Sigmoid 為轉換函數，隱藏層 PE 個數為 1 個，其它網路架構依此規則類推。且表 5-13 為各群組路段選取之最佳網路模式與其績效。

表5-5 本研究「群組1三重-台北」之各類型網路績效

	群組 1 三重-台北	績效指標值*						
		訓練		測試		誤差百分比總和	平均絕對誤差百分比(MAPE)*	選取網路模式之架構
實際 Time =172(平均)	旅行時間預測模式(皆倒傳遞模式)	RMSE	相關係數	RMSE*	相關係數			
ANN1-時間序列	ANN1-時間序列類神經網路	0.063	0.834	0.061	0.442	-0.97	12.1	g1_ANN103_Sigmoid_H1
ANN2-時間序列 + 交通特性	ANN2-時間序列+交通特性之網路	0.063	0.839	0.060	0.461	-3.34	13.69	g1_ANN206_Sigmoid_H1
ANN3-車輛偵測器(VD)+車道特性之類神經網路	Ann31_路段速率	0.269	0.220	0.379	0.173	-6.00	17.08	g1_ANN31_TanH_H1
	Ann33_速率路段+時間	0.102	0.157	0.146	0.063	-4.07	16.99	g1_ANN33_Sigmoid_H1
ANN4-GPS+車道特性類神經網路	ANN4-GPS+車道特性之網路模式	0.103	-0.039	0.123	0.017	0.228	17.85	g1_ANN4_Sigmoid_H0
ANN5_資料全部考量之類神經網路模式	Ann51_全部考量(僅目前概念)	0.049	0.881	0.063	-0.895	-4.8	14.96	g1_ANN51_Sigmoid_H3
	Ann52_全部考量(考量未來概念)	0.049	0.916	0.055	0.874	-2.906	13.37	g1_ANN52_Sigmoid_H3
ANN6	ANN6_全部考量(前一路段旅行時間)	0.013	0.999	0.359	0.567	-5.640	12.25	g1_ANN6_TanH_H13

*本研究所選取之模式(同一群組不同網路類型間)採取測試平均絕對值誤差率(MAPE)相對數值最低者為衡量標準,將網路輸出值與實際值進行比較計算。此外本研究選取模式(同一群組相同網路類型間)則採取 RMSE 低者為衡量標準。

表5-6 本研究「群組2五股-三重」之各類型網路績效

	群組 2 五股-三重	績效指標值						
		訓練		測試		誤差百分比 總和	平均絕對誤差 百分比 (MAPE)	選取網路模式之架構
實際 Time =277(平均)	旅行時間預測模式 (皆倒傳遞模式)	RMSE	相關係數	RMSE	相關係數			
ANN1-時間序列	ANN1-時間序列類神經網路	0.1955	0.834	0.274	0.394	0.314	8.139	g2_ANN115_TanH_H3
ANN2-時間序列 + 交通特性	ANN2-時間序列+交通特性之網路	0.1050	0.619	0.1235	0.185	1.099	11.04	g2_ANN217_Sigmoid_H1
ANN3-車輛偵測器(VD)+車道特性之類神經網路	Ann31_路段速率	0.1181	0.117	0.117	0.181	1.44	9.46	g2_ANN31_Sigmoid_H0
	Ann33_速率路段+時間	0.1146	0.269	0.107	0.404	1.55	8.76	g2_ANN33_Sigmoid_H1
ANN4-GPS+車道特性類神經網路	ANN4-GPS+車道特性之網路模式	0.1066	0.444	0.107	0.424	0.94	8.72	g2_ANN4_Sigmoid_H0
ANN5_資料全部考量之類神經網路模式	Ann51_全部考量(僅目前概念)	0.0965	0.638	0.125	0.064	-1.19	9.923	g2_ANN51_Sigmoid_H7
	Ann52_全部考量(考量未來概念)	0.0496	0.427	0.027	0.232	-3.745	10.13	g2_ANN52_Sigmoid_H1
ANN6	ANN6_全部考量(前一路段旅行時間)	0.1062	0.449	0.103	0.459	0.9959	8.06	g2_ANN6_Sigmoid_H1

表5-7 本研究「群組3桃園-五股」之各類型網路績效

	群組 3 桃園-五股	績效指標值						
		訓練		測試		誤差百分比 總和	平均絕對 誤差百分比 (MAPE)	選取網路模 式之架構
實際 Time =822(平均)	旅行時間預測模式 (皆倒傳遞模式)	RMSE	相關 係數	RMSE	相關 係數			
ANN1-時間 序列	ANN1-時間序列類 神經網路	0.0661	0.7839	0.0665	0.611	0.37	6.68	g3_ANN104_ Sigmoid_H3
ANN2-時間 序列 + 交通 特性	ANN2-時間序列+ 交通特性之網路	0.0343	0.9694	0.0858	0.773	0.426	5.9	g3_ANN237_ Sigmoid_H5
ANN3-車輛 偵測器 (VD)+車道 特性之類神 經網路	Ann31_路段速率	0.2744	0.4661	0.2339	0.534	2.01	7.94	g3_ANN31_ TanH_H0
	Ann33_速率路段+ 時間	0.0975	0.5339	0.0864	0.555	4.07	9.15	g3_ANN33_ Sigmoid_H1
ANN4-GPS+ 車道特性類 神經網路	ANN4-GPS+車道特 性之網路模式	0.0986	0.5185	0.0867	0.549	3.55	8.85	g3_ANN4_ Sigmoid_H1
ANN5_資料 全部考量之 類神經網路 模式	Ann51_全部考量 (僅目前概念)	0.1116	0.9322	0.1055	0.869	1.45	5.22	g3_ANN51_ TanH_H2
	Ann52_全部考量 (考量未來概念)	0.1251	0.9110	0.1553	0.772	3.057	6.41	g3_ANN52_ TanH_H5
ANN6	ANN6_全部考量 (前一路段旅行時 間)	0.0969	0.9491	0.1230	0.831	1.833	5.72	g3_ANN6_ TanH_H2

表5-8 本研究「群組4機場桃園半處-桃園」之各類型網路績效

	群組 4 機場桃園半處 -桃園	績效指標值						
		訓練		測試		誤差 百分 比 總和	平均絕 對誤差 百分比 (MAPE)	選取網路模 式之架構
實際 Time =89(平均)	旅行時間預測模式 (皆倒傳遞模式)	RMSE	相關 係數	RMSE	相關 係數			
ANN1-時間 序列	ANN1-時間序列類 神經網路	0.1610	0.7285	0.3700	-0.009	-4.25	26.29	g4_ANN106_ TanH_H1
ANN2-時間 序列 + 交通 特性	ANN2-時間序列+交 通特性之網路	0.1400	0.8008	0.2729	0.605	-4.35	21.706	g4_ANN206_ TanH_H5
ANN3-車輛 偵測器 (VD)+車道 特性之類神 經網路	Ann31_路段速率	0.1779	0.6406	0.1924	0.725	4.13	24.16	g4_ANN31_ TanH_H1
	Ann33_速率路段+時 間	0.0678	0.6271	0.0903	0.749	-0.43	24.01	g4_ANN33_ Sigmoid_H1
ANN4-GPS+ 車道特性類 神經網路	ANN4-GPS+車道特 性之網路模式	0.1549	0.7478	0.2091	0.651	4.38	23.36	g4_ANN4_ TanH_H4
ANN5_資料 全部考量之 類神經網路 模式	Ann51_全部考量(僅 目前概念)	0.1402	0.7945	0.2725	0.591	-0.97	25.59	g4_ANN51_ TanH_H19
	Ann52_全部考量(考 量未來概念)	0.1668	0.6955	0.2405	0.726	5.2	25.50	g4_ANN52_ TanH_H5
ANN6	ANN6_全部考量(前 一路段旅行時間)	0.1196	0.8532	0.2348	0.735	2.405	19.72	g4_ANN6_ TanH_H17

表5-9 本研究「群組5機場-機場桃園半處」之各類型網路績效

	群組 5 機場-機場桃園半處	績效指標值						
		訓練		測試		誤差百分比總和	平均絕對誤差百分比(MAPE)	選取網路模式之架構
實際 Time =44(平均)	旅行時間預測模式(皆倒傳遞模式)	RMSE	相關係數	RMSE	相關係數			
ANN1-時間序列	ANN1-時間序列類神經網路	0.2848	0.4663	0.2420	0.226	15.7	34.37	g5_ANN102_TanH_H2
ANN2-時間序列 + 交通特性	ANN2-時間序列+交通特性之網路	0.2588	0.06049	0.2375	0.395	6.74	26.78	g5_ANN211_TanH_H0
ANN3-車輛偵測器(VD)+車道特性之類神經網路	Ann31_路段速率	0.2592	0.4360	0.2674	0.457	10.29	33.24	g5_ANN31_TanH_H1
	Ann33_速率路段+時間	0.2588	0.4371	0.2683	0.452	9.23	32.79	g5_ANN33_TanH_H1
ANN4-GPS+車道特性類神經網路	ANN4-GPS+車道特性之網路模式	0.2442	0.5306	0.2409	0.598	15.37	35.26	g5_ANN4_TanH_H2
ANN5_資料全部考量之類神經網路模式	Ann51_全部考量(僅目前概念)	0.2223	0.6392	0.2582	0.617	11.94	32.26	g5_ANN51_TanH_H19
	Ann52_全部考量(考量未來概念)	0.0929	0.5084	0.108	0.443	7.32	33.4	g5_ANN52_Sigmoid_H1
ANN6	ANN6_全部考量(前一路段旅行時間)	0.2194	0.6834	0.2173	0.737	7.62	27.22	g5_ANN6_TanH_H9

表5-10 本研究「群組6幼獅-機場」之各類型網路績效

	群組 6 幼獅-機場	績效指標值						
		訓練		測試		誤差百分比總和	平均絕對誤差百分比(MAPE)	選取網路模式之架構
實際 Time =801(平均)	旅行時間預測模式 (皆倒傳遞模式)	RMSE	相關係數	RMSE	相關係數			
ANN1-時間序列	ANN1-時間序列類神經網路	0.0053	0.999	0.1924	0.904	-1.82	15.01	g6_ANN136_TanH_H15
ANN2-時間序列 + 交通特性	ANN2-時間序列+交通特性之網路	0.0183	0.9988	0.1360	0.945	-4.72	9.183	g6_ANN226_TanH_H5
ANN3-車輛偵測器(VD)+車道特性之類神經網路	Ann31_路段速率	0.0588	0.8868	0.0647	0.886	1.06	11.019	g6_ANN31_Sigmoid_H1
	Ann33_速率路段+時間	0.0583	0.8887	0.0758	0.877	0.629	13.13	g6_ANN33_Sigmoid_H1
ANN4-GPS+車道特性類神經網路	ANN4-GPS+車道特性之網路模式	0.2483	0.6802	0.2841	0.642	1.44	16.37	g6_ANN4_TanH_H0
ANN5_資料全部考量之類神經網路模式	Ann51_全部考量(僅目前概念)	0.04	0.9488	0.0579	0.930	-2.34	9.8	g6_ANN51_Sigmoid_H7
	Ann52_全部考量(考量未來概念)	0.0486	0.9436	0.0529	0.931	-0.1203	9.93	g6_ANN52_Sigmoid_H5
ANN6	ANN6_全部考量(前一路段旅行時間)	0.0579	0.9858	0.1393	0.943	-1.268	9.66	g6_ANN6_TanH_H11

表5-11 本研究「群組7楊梅-幼獅」之各類型網路績效

	群組 7 楊梅-幼獅	績效指標值						
		訓練		測試		誤差百分比 總和	平均絕對誤差百分比 (MAPE)	選取網路模式之架構
實際 Time =79(平均)	旅行時間預測模式 (皆倒傳遞模式)	RMSE	相關係數	RMSE	相關係數			
ANN1-時間序列	ANN1-時間序列類神經網路	0.0748	0.3643	0.0744	0.375	3.36	20.88	g7_ANN102_Sigmoid_H1
ANN2-時間序列 + 交通特性	ANN2-時間序列+交通特性之網路	0.0484	0.8055	0.0660	0.738	5.084	22.15	g7_ANN223_Sigmoid_H3
ANN3-車輛偵測器(VD)+車道特性之類神經網路	Ann31_路段速率	0.0537	0.7008	0.0625	0.658	12.84	29.38	g7_ANN31_Sigmoid_H1
	Ann33_速率路段+時間	0.0516	0.7137	0.0752	0.594	19.33	40.7	g7_ANN33_Sigmoid_H1
ANN4-GPS+車道特性類神經網路	ANN4-GPS+車道特性之網路模式	0.1443	0.6818	0.1691	0.634	8.96	29.20	g7_ANN4_TanH_H2
ANN5_資料全部考量之類神經網路模式	Ann51_全部考量(僅目前概念)	0.0462	0.7804	0.0793	0.540	1.84	25.28	g7_ANN51_Sigmoid_H1
	Ann52_全部考量(考量未來概念)	0.0517	0.7233	0.0810	0.473	49.4	40.36	g7_ANN52_Sigmoid_H1
ANN6	ANN6_全部考量(前一路段旅行時間)	0.0460	0.7821	0.0793	0.538	19.94	42.082	g7_ANN6_Sigmoid_H3

表5-12 本研究「群組8新竹-楊梅」之各類型網路績效

	群組 8 新竹-楊梅	績效指標值						
		訓練		測試		誤差 百分比 總和	平均絕 對誤差 百分比 (MAPE)	選取網路模 式之架構
實際 Time =1127(平均)	旅行時間預測模式 (皆倒傳遞模式)	RMSE	相關 係數	RMSE	相關 係數			
ANN1-時間 序列	ANN1-時間序列類 神經網路	0.1207	0.7643	0.0921	0.7146	0.663	6.13	g8_ANN104_ Sigmoid_H0
ANN2-時間 序列 + 交通 特性	ANN2-時間序列+交 通特性之網路	0.0000	1.0000	0.2766	0.8123	-0.776	7.65	g8_ANN206_ TanH_H5
ANN3-車輛 偵測器 (VD)+車道 特性之類神 經網路	Ann31_路段速率	0.3116	0.6915	0.4374	0.4517	-3.34	7.89	g8_ANN31_ TanH_H5
	Ann33_速率路段+時 間	0.1289	0.6035	0.1755	0.3350	-4.76	7.37	g8_ANN33_ TanH_H1
ANN4-GPS+ 車道特性類 神經網路	ANN4-GPS+車道特 性之網路模式	0.1308	0.5876	0.1370	0.6621	-0.41	8.98	g8_ANN4_ Sigmoid_H3
ANN5_資料 全部考量之 類神經網路 模式	Ann51_全部考量(僅 目前概念)	0.0000	1.0000	0.4105	0.7617	2.58	8.94	g8_ANN51_ TanH_H11
	Ann52_全部考量(考 量未來概念)	0.0000	1.0000	0.4105	0.7617	2.58	8.94	g8_ANN51_ TanH_H11
ANN6	ANN6_全部考量(前 一路段旅行時間)	0.0000	1.0000	0.4209	0.7433	3.027	9.26	g8_ANN6_ TanH_H21

表5-13 各群組路段選取之最佳網路模式、架構與績效

群組別	實際旅行時間 平均值(sec)	本研究選取之類神 經網路類型	誤差百分比總和 (平均絕對值誤差 率(MAPE))	網路架構
群組 8	1127	ANN1-時間序列	6.13	g8_ANN104_ Sigmoid_H0
群組 7	79	ANN1-時間序列	20.88	g7_ANN102_ Sigmoid_H1
群組 6	801	ANN2-時間序列 + 交通特性	9.18	g6_ANN226_ TanH_H5
群組 5	44	ANN2-時間序列 + 交通特性	26.78	g5_ANN211_ TanH_H0
群組 4	89	ANN6-全部考量 + 前一群組旅行時間	19.72	g4_ANN6_ TanH_H17
群組 3	822	ANN51-全部考量 (僅目前概念)	5.22	g3_ANN51_ TanH_H2
群組 2	277	ANN6-全部考量 + 前一群組旅行時間	8.06	g2_ANN6_ Sigmoid_H1
群組 1	172	ANN1-時間序列	12.1	g1_ANN103_ Sigmoid_H1




圖 5-9 各群組最佳模式之 MAPE 值




圖 5-10 各群組之平均實際旅行時間值

由圖 5-9、圖 5-10 與發現到各群組之實際旅行時間與其網路績效 (MAPE) 呈現反像的關係，說明若群組距離越長，所需旅行時間越久，相對地預測估計的誤差會較小。下圖 5-11 圖 5-18 即為各群組實際旅行時間與網路估計值之對照。

5.3.3 實證分析網路之評選

本研究所構建的網路模式有 8 種類型：ANN1、ANN2、ANN31、ANN33、ANN4、ANN51、ANN52、ANN6，將研究範圍新竹-台北區分成 8 個群組別，每一群組路段皆進行上述 ANN 模式構建工作。同模式間依測試 RMSE 績效指標進行評選最佳網路架構（如 ANN Hidden Layer PE 數、學習法則與轉換函數等）；若要在不同模式間選出最佳類神經網路模式（即

ANN1-ANN6), 則依客觀之 MAPE 指標加以判別。最後由於實際用路人起迄點不同而有多種起迄對組合, 為了瞭解實際應用上的績效, 將會於下章進行實證分析工作, 而本研究最終則是挑出較佳的 ANN1、ANN2、ANN51 ANN52 與 ANN6 之類神經網路模式來進行實證分析(下表 5-14)

表5-14 群組別之網路績效排名

群組別	排名 1(最佳)	排名 2	排名 3
群組 8 (1127)	ANN1	ANN33	ANN2
群組 7 (79)	ANN1	ANN2	ANN51
群組 6 (801)	ANN2	ANN6	ANN51
群組 5 (44)	ANN2	ANN6	ANN51
群組 4 (89)	ANN6	ANN2	ANN4
群組 3 (822)	ANN51	ANN6	ANN2
群組 2 (277)	ANN6	ANN1	ANN4
群組 1 (72)	ANN1	ANN6	ANN52




圖 5-11 群組 1 之實際旅行時間值與網路估計值




圖 5-12 群組 2 之實際旅行時間值與網路估計值




圖 5-13 群組 3 之實際旅行時間值與網路估計值




圖 5-14 群組 4 之實際旅行時間值與網路估計值




圖 5-15 群組 5 之實際旅行時間值與網路估計值




圖 5-16 群組 6 之實際旅行時間值與網路估計值




圖 5-17 群組 7 之實際旅行時間值與網路估計值




圖 5-18 群組 8 之實際旅行時間值與網路估計值

第六章 實證結果分析

6.1 驗證程序

在經由類神經網路構建工作後，為了瞭解預測模式實際應用上的績效水準，此章探討網路預測績效之實證分析，主要利用客運車輛實際行駛之旅行時間來進行驗證的工作。驗證程序如圖 6-1 所示，某起迄對（O-D pair）之旅行時間係由其間若干群組之個別旅行時間加總所得，此個別旅行時間可由資料庫內蒐尋特定由 A 經 B、C、D，以迄於 E 之時刻而求得。各種預測模式也依此原則，預估個別群組之旅行時間，再以算數和作為該起迄對之預測旅行時間。例如駕駛人由 A 至 E，必須通過群組 8、7、6、5 等路段，其關切者乃總旅行時間，因此系統提供總旅行時間即符合駕駛人需求，實證之重點乃集中於實際總時間與預測時間之差異。

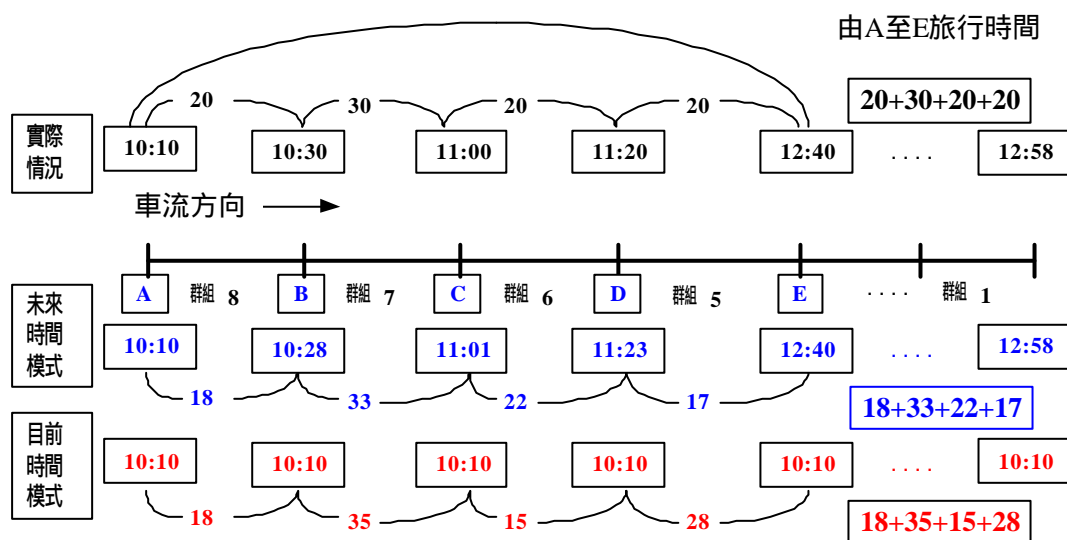


圖 6-1 實證分析示意圖

完整的實證分析應考量若依照不同的起迄組合，編制出不同起迄之資訊需求矩陣表，亦即有由群組 8 出發、群組 7 出發、群組 6 出發 .. 群組 1 出發，而可能之到達迄點如群組 8->1 或群組 8->3 等。本研究為了有系統

地操作實證工作之程序，乃將起始群組固定，探討不同迄點與各實證績效指標之間的關係。

實證所需資料有別於網路訓練與測試，採用新的資料。對於起始群組的選擇，本研究實證分析將由群組 7 開始，而不從群組 8 開始，原因乃是從群組 8 出發的車輛數過少（如表 6-1），且完全行駛全程（群組 8->群組 1）更少，為了不讓樣本數過少造成實證分析上的問題，故採用由群組 7 出發的車輛為探討對象。

表6-1 實證分析之樣本數(各起迄)

終點	起點	
	群組 8	群組 7
群組 8	0	
群組 7	1	0
群組 6	0	6
群組 5	0	0
群組 4	2	3
群組 3	0	1
群組 2	11	58
群組 1	6	26

就樣本數而言，6.2 節實證資料分析中各路段數之樣本個數皆代表實證資料總數，相對於上述固定起始群組 7，實證分析總樣本數則包含其它起始群組情況，因此樣本數較多，如群組 7-6（2 個路段）之樣本數共有 114 個，加總由群組 8 與群組 7 發車的車輛樣本。

另一方面，對於實證分析所驗證的模式，係由本研究 5.3.3 節各種預測模式中選出測試過程績效較佳的 ANN1 ANN2 ANN51 ANN52 ANN6 來進行實證分析。驗證的結果依四種指標進行評估，以判定最適當的預測模式。惟作法是任一起迄對的全部群組皆採用相同的網路模式，且在選擇網路模式後各群組皆依其最佳的網路架構來作預測，各群組在各網路模式之最佳網路架構如下表 6-2（詳見 5.3.2 節）。

表6-2 實證分析-實證模式於各群組之最佳架構

	ANN1	ANN2	ANN51	ANN52	ANN6
群組 7	g7_ANN102_Sigmoid_H1	g7_ANN223_Sigmoid_H1	g7_ANN51_Sigmoid_H1	g7_ANN52_Sigmoid_H1	g7_ANN6_Sigmoid_H3
群組 6	g6_ANN136_TanH_H15	g6_ANN226_TanH_H5	g6_ANN51_Sigmoid_H7	g6_ANN52_Sigmoid_H5	g6_ANN6_TanH_H11
群組 5	g5_ANN102_TanH_H2	g5_ANN211_TanH_H0	g5_ANN51_TanH_H19	g5_ANN52_Sigmoid_H1	g5_ANN6_TanH_H9
群組 4	g4_ANN106_TanH_H1	g4_ANN206_TanH_H5	g4_ANN51_TanH_H19	g4_ANN52_TanH_H5	g4_ANN6_TanH_H17
群組 3	g3_ANN104_Sigmoid_H3	g3_ANN237_Sigmoid_H5	g3_ANN51_TanH_H2	g3_ANN52_TanH_H5	g3_ANN6_TanH_H2
群組 2	g2_ANN115_TanH_H3	g2_ANN217_Sigmoid_H1	g2_ANN51_Sigmoid_H7	g2_ANN52_Sigmoid_H1	g2_ANN6_Sigmoid_H1
群組 1	g1_ANN103_Sigmoid_H1	g1_ANN206_Sigmoid_H1	g1_ANN51_Sigmoid_H3	g1_ANN52_Sigmoid_H3	g1_ANN6_TanH_H13

6.2 實證資料分析

首先對於實證資料之分佈情況繪製次數分配圖，來加以說明由群組 7 出發之不同群組數的實際旅行時間分佈特性。在圖 6-2中為一個群組數之旅行時間分佈情況，其中可以看出由楊梅-幼獅所需之旅行時間以 60-90 秒之 68 筆為最多，而群組 7 實證資料之平均旅行時間為 80.7 秒。




圖 6-2 群組 7 (1 個路段) 次數分配圖

在下圖 6-3 中則為二個群組路段數（楊梅-機場）之旅行時間分佈，由楊梅-機場所需之旅行時間以 600-800 秒佔絕大部分，有 79 筆資料，而其實證資料之平均旅行時間為 864.6 秒。




圖 6-3 群組 7-6（2 個路段）次數分配圖

在圖 6-4 中為三個群組數（楊梅-機場與桃園半處）之旅行時間分佈情形，大致發現由楊梅-機場與桃園半處所需之旅行時間亦以 600-800 秒為最多，有 70 筆資料，而群組 7-5 實證資料之平均旅行時間為 917 秒。




圖 6-4 群組 7-5（3 個路段）次數分配圖

圖 6-5 為四個群組數（楊梅-桃園）之旅行時間次數分配圖，可以瞭解由楊梅-桃園所需之旅行時間以 700-1000 秒之 78 筆為最多，而群組 7-4 實證資料之平均旅行時間為 1007.6 秒。




圖 6-5 群組 7-4 (4 個路段) 次數分配圖

在圖 6-6中為五個群組數 (楊梅-五股) 之旅行時間分佈情形，可以得知由楊梅-五股之旅行時間以 1300-1600 秒為最多，有 50 筆，且群組 7-3 實證資料之平均旅行時間為 1790.8 秒。




圖 6-6 群組 7-3 (5 個路段) 次數分配圖

圖 6-7為六個群組數之旅行時間分佈情況，可以清楚發覺由楊梅-三重所需之旅行時間以 1600-1900 秒之 55 筆為最多，而群組 7-2 實證資料之平均旅行時間為 2046.3 秒。




圖 6-7 群組 7-2 (6 個路段) 次數分配圖

最後，在圖 6-8 中乃為七個群組路段數之旅行時間分佈圖，其中由楊梅-台北所需之旅行時間以 1900-2200 秒最多，有 19 筆資料，而群組 7-1 實證資料之平均旅行時間為 2158.8 秒。




圖 6-8 群組 7-1 (7 個路段) 次數分配圖

整體而言，若旅行時間分配圖愈集中，表示車輛行駛時間離散程度較小，對於模式預測上有較大的助益。然而由上述可得知，不同群組數所繪製出來的旅行時間次數分配圖有相當差異，顯示各群組之交通環境有明顯異質性。用單一型態模式預測異質性路段之旅行時間乃是極大的挑戰，除了模式內含的判別分析能力需要足夠，其輸出值的穩定性也是重要考量要項。下節詳細闡述 ANN 模式之優良能力。

6.3 實證分析

本研究對於路段旅行時間之實證分析所採用的績效指標有 4 個：平均每車誤差 (Error)、平均每車誤差之絕對值 ($|Error|$)、平均誤差率 $MPE(error\%)$ 、平均絕對誤差百分比(MAPE)。其中前二者為實際誤差秒數，較為主觀，乃為個別駕駛人所關心的資訊；後二者則為相對比率值，對於分析判別上較為客觀，為相關交通管理中心所重視。其明確之公式定義與符號說明如下：

$$1. Error_{ji} = \left[\frac{1}{M_{ji}} \sum_{k=1}^{M_{ji}} x_{ji}^{\wedge}(k) - x_{ji}(k) \right]$$

其中符號 $Error_{ji}$ ：同一群組與類神經網路模式下平均每車旅行時間誤差；

M_{ji} ：群組資料筆數 for 群組 i ，類神經網路模式 j ；

j ：類神經網路模式別 ($j=1$ 為 ANN1， $j=2$ 為 ANN2， $j=3$ 為 ANN51， $j=4$ 為 ANN52， $j=5$ 為 ANN6)；

i ：群組別；

k ：實證資料編號別；

$x_{ji}(k)$ ：第 k 個實際值 for 群組 i ，類神經網路模式 j ；

$x_{ji}^{\wedge}(k)$ ：第 k 個估計值 for 群組 i ，類神經網路模式 j ；

$$2. |Error|_{ji} = \frac{1}{M_{ji}} \sum_{k=1}^{M_{ji}} |x_{ji}^{\wedge}(k) - x_{ji}(k)|$$

符號定義同上，而 $|Error|_{ji}$ 為同一群組與類神經網路模式下平均每車旅行時間誤差之絕對值；

$$3. MPE_{ji} = \left[\frac{1}{M_{ji}} \sum_{k=1}^{M_{ji}} \frac{x_{ji}^{\wedge}(k) - x_{ji}(k)}{x_{ji}(k)} \right] * 100\%$$

符號定義同上，而 MPE_{ji} 為同一群組與類神經網路模式下平均每車旅行時間誤差率；

$$4. \text{MAPE}_{ji} = \frac{1}{M_{ji}} \sum_{k=1}^{M_{ji}} \left| \frac{x_{ji}^{\wedge}(k) - x_{ji}(k)}{x_{ji}(k)} \right| * 100\%$$

符號定義同上，而 MAPE_{ji} 為同一群組與類神經網路模式下平均每車旅行時間絕對誤差百分比；

在所有績效表中，一個群組數的路段則增加群組 8*(1 個群組數)，為了與群組 7(1 個群組數)相互比較單一群組數之距離與實證績效值之間的差異。若績效指標為相對比率，群組 7 則因距離短，其比率指標較其它群組數顯得格外不佳，但若實證選取群組 8 作為單一群組數進行實證，則相對地會由於距離變長，其績效指標則顯得正常許多，用以說明群組 7 比率指標不佳的原因在於距離過短，而非 1 個群組數的網路績效會不佳。以下先就實際旅行時間值與網路估計值加以說明。

平均每車之實際值與估計值

表格（表 6-3）內每一儲存格皆包含有 2 個數值，第 1 個數值為在此模式下，此一群組中實證資料之平均旅行時間與模式預測出來之平均旅行時間估計值，此兩個數值之差即為下表 6-4 之平均誤差值。

表6-3 實證指標-平均每車之實際值與估計值

路段	(實際值,估計值) sec/每車				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8*(1 個群組數)	1175,1174	1197,1194	1184,1193	1184,1193	1184,1195
群組 7 (1 個群組數)	80.36,79	81.1,82	80,79	81,79	81,80
群組 7-6(2 個群組數)	867,847	867,852	863,847	863,860	863,857
群組 7-5(3 個群組數)	921,899	919,900	915,900	915,912	915,910
群組 7-4(4 個群組數)	1013,983	1010,985	1005,986	1005,1001	1005,1000
群組 7-3(5 個群組數)	1777,1758	1779,1753	1799,1785	1800,1799	1799,1799
群組 7-2(6 個群組數)	2036,2020	2045,2018	2049.8,2035	2051,2055	2050,2048
群組 7-1(7 個群組數)	2157,2157	2175,2168	2154,2152	2154,2174	2154,2157

由表可以清楚看到隨著群組數的增加，距離的增長，平均每車之實際旅行時間與各預測模式下的估計值差異程度會有所不同。就距離最長的群組 7-1 而言，ANN1 預測能力最佳；而整體而言，ANN6 預測模式最為穩定。

1.平均每車誤差(Error)

$$\text{Error} = \left[\frac{1}{M} \sum_{k=1}^M x^{\wedge}(k) - x(k) \right]$$

實際行駛時間與網路所預測之估計時間(sec)之誤差加總平均值（表 6-4），隱含有正負相互抵銷的概念，為整體平均的意義。若繪製圖表（圖 6-9）誤差值將隨群組數目增加而呈現 U 字型的情形。

由圖可得知模式預測正確性在 1-5 個群組數時以 ANN52 最佳,但於 6 與 7 個群組數時則以 ANN52 最差(+20sec)。相對地，在小於 4 個群組數中，以 ANN1 最差(-30sec)，但距離大於 4 個群組數時則績效漸佳。整體而言則以 ANN6 模式最為穩定，績效亦幾乎與最佳模式相同。

所有 ANN 模式皆低估旅行時間，僅 ANN52 在 7-1（7 個群組數）高估，可能是由於三重-台北資料所造成。

表6-4 實證指標-平均每車誤差(Error)

路段	$\text{Error} = \left[\frac{1}{M} \sum_{k=1}^M x^{\wedge}(k) - x(k) \right]$				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8*(1 個群組數)	-1.198	-2.44	9.8	9.8	11.18
群組 7 (1 個群組數)	-1.36	0.95	-0.658	-1.863	-1.028
群組 7-6(2 個群組數)	-20.1	-15.15	-16.5	-3.688	-5.98
群組 7-5(3 個群組數)	-22.69	-18.9	-15.76	-3.538	-5.556
群組 7-4(4 個群組數)	-29.93	-24.81	-19.62	-4.614	-5.32
群組 7-3(5 個群組數)	-19.07	-26.35	-13.94	-0.535	0.226
群組 7-2(6 個群組數)	-16.18	-26.75	-14.493	3.667	-1.71
群組 7-1(7 個群組數)	-0.138	-6.53	-1.57	20.6	3.02




圖 6-9 實證指標-平均每車誤差(Error)

2. 平均每車誤差之絕對值|Error|

$$|\text{Error}| = \frac{1}{M} \sum_{k=1}^M |x^{\wedge}(k) - x(k)|$$

整體而言，表 6-5 旅行時間隨距離增加而變長，各群組數以 ANN2 為最佳（時間序列 + 交通特性），ANN52 最差。若進一步分析，在圖 6-10 中吾人可選取最佳的 2 個模式（ANN2 與 ANN6），並且配適出一曲線，此一曲線將呈現遞減的趨勢，亦即表示誤差絕對值將隨距離增加而逐漸遞減，為一良好預測模式。

表6-5 實證指標-平均每車誤差之絕對值(|Error|)

路段	$ \text{Error} = \frac{1}{M} \sum_{k=1}^M x^{\wedge}(k) - x(k) $				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8*(1 個群組數)	93.17	30.07	33.987	33.987	34.80
群組 7 (1 個群組數)	19.79	15.46	15.86	16.72	16.25
群組 7-6(2 個群組數)	57.81	42.7	74.181	77.42	53.86
群組 7-5(3 個群組數)	66.27	47.9	76.145	79.85	55.67
群組 7-4(4 個群組數)	70.39	52.95	74.09	78.88	54.187
群組 7-3(5 個群組數)	100	68.31	91.36	94.4	71.143
群組 7-2(6 個群組數)	106	71.21	97.96	105.36	76.91
群組 7-1(7 個群組數)	96.7	75.01	94.22	103.36	93.421




圖 6-10 實證指標-平均每車誤差之絕對值(|Error|)

3.平均誤差率(MPE)

$$MPE = \left[\frac{1}{M} \sum_{k=1}^M \frac{x^{\wedge}(k) - x(k)}{x(k)} \right] * 100\%$$

由表 6-6與圖 6-11可以發現 1 個路段之平均誤差率較為不佳，大於 10%，原因即為前面所提到的是由於群組 7 路段的距離短，所以計算出之平均誤差率指標值較大。

表6-6 實證指標-平均誤差率(MPE)

路段	MPE= $\left[\frac{1}{M} \sum_{k=1}^M \frac{x^{\wedge}(k) - x(k)}{x(k)} \right] * 100\%$				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8*(1 個群組數)	0.876	-0.26	0.775	0.775	0.908
群組 7 (1 個群組數)	14.34	11.52	12.55	10.5	11.123
群組 7-6(2 個群組數)	-0.69	-1.27	-0.67	0.68	0.186
群組 7-5(3 個群組數)	-0.72	-1.6	-0.529	0.69	0.269
群組 7-4(4 個群組數)	-1.07	-1.89	-0.85	0.63	0.357
群組 7-3(5 個群組數)	0.05	-1.186	-0.39	0.29	0.397
群組 7-2(6 個群組數)	0.194	-0.99	-0.34	0.47	0.3316
群組 7-1(7 個群組數)	0.67	-0.354	0.078	0.94	0.518




圖 6-11 實證指標-平均誤差率(MPE)

4.平均絕對誤差百分比(MAPE)

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

表 6-7與圖 6-12亦出現與 MPE 相同的問題，1 個路段時所有模式皆不佳，MAPE>25%，其原因亦同上述說明，因為群組 7 之總旅行時間值過短，造成誤差時間少卻會因分母小而有放大的現象，不過若轉換成實際旅行時間，則僅有 20 多秒之誤差，對整體路段預測影響不大。甚至若單就指標來看，MAPE = 30，為一合理預測模式。相對地，2-7 個路段數後，則所有的模式 MAPE 變得非常優良，為高精確預測模式，且以 ANN2 為最佳。

表6-7 實證指標-平均絕對誤差百分比(MAPE)

路段	MAPE= $\frac{1}{M} \sum_{k=1}^M \left \frac{x^{\wedge}(k) - x(k)}{x(k)} \right * 100\%$				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8*(1 個群組數)	7.93	2.55	2.68	2.68	2.777
群組 7 (1 個群組數)	31.28	26.09	27.65	27.04	27.18
群組 7-6(2 個群組數)	6.12	4.77	7.878	8.16	6.12
群組 7-5(3 個群組數)	6.8	5.04	7.62	7.87	5.99
群組 7-4(4 個群組數)	6.3	4.97	6.71	7.07	5.278
群組 7-3(5 個群組數)	5.25	3.59	4.79	4.85	3.84
群組 7-2(6 個群組數)	4.94	3.313	4.54	4.815	3.66
群組 7-1(7 個群組數)	4.45	3.41	4.37	4.65	4.34




圖 6-12 實證指標-平均絕對誤差百分比(MAPE)

小結

經由實際資料進行實證分析後，比較主要的 4 個績效指標，若就個別指標來細分的話，可以歸納成如表 6-8 之建議預測模式對照表，用以提供不同群組數在考量不同指標下所應選取的預測模式。

吾人可以清楚的發現 ANN6 模式為整體最穩定之預測模式，且其預測能力亦與各群組數最佳之模式相差不大，所以 ANN6-考量上游路段旅行時間之全部時空幾何資料類神經網路模式之預測旅行時間能力最為優良。

表6-8 各群組數建議之類神經網路模式

實證績效指標	群組 7	群組 7-6	群組 7-5	群組 7-4	群組 7-3	群組 7-2	群組 7-1
Error	ANN52、 ANN6					ANN6	ANN1、 51、 6
Error	ANN2			ANN2、 ANN6			ANN2
MPE	ANN52	ANN6					ANN51
MAPE	ANN2	ANN2					

第七章 結論與建議

本研究主要是希望能透過類神經網路來發展高速公路旅行時間預測模式，期能提供使用者準確的旅行時間資訊。由於道路使用者之起迄點不同，若要個別發展單獨的預測模式，將會有指數次方之模式個數需要建立，且應用上亦非常複雜不便。本研究將高速公路研究範圍依照幾何與交通量因素區分成數個群組，在實際資訊之提供處理上相對較為便利，模式構建概念亦不致差異過大。下面則簡述本研究所得之結論與後續研究建議。

7.1 結論

1. 本研究資料來源有台汽客運 GPS 資料、中華顧問工程司之交通千里眼的事件資料、車輛偵測器資料與高速公路幾何交通量資料等，為多來源且不同類型之交通資訊轉換與處理、整合，不過可真實反映出高速公路行車環境，預測上亦符合實際情況。資料則分割成 3 個部分，一為進行類神經網路訓練之用，另一為網路測試之用，最後一部分資料則作實證分析之用。
2. 本研究考慮資料來源型態與模式概念不同，構建出 6 種類神經網路預測模式：ANN1-時間序列類神經網路、ANN2-時間序列 + 交通特性之類神經網路、ANN3-車輛偵測器 + 車道特性之類神經網路、ANN4-GPS + 車道特性之類神經網路、ANN51-考量全部時空幾何資料模式（僅目前時間範例）、ANN52-考量全部時空幾何資料模式（目前 + 未來時間範例）與 ANN6-考量全部時空幾何資料模式（加入前一群組之旅行時間變數）。
3. 本研究資料處理工作因個別資料來源格式不一，資料量甚大，造成資料處理上花費時間與人力甚多。在經由資料整理與分析後，方能進行類神經網路的訓練與測試工作。

4. 本研究將研究範圍區分成 8 個群組別，分別構建 6 種類神經網路模式。然後再根據類神經網路所提供的網路績效來評選較佳的類神經網路架構，最後模式間的選取則以客觀指標平均絕對誤差百分比(MAPE)來選取此一群組之最佳類神經網路模式。
5. 本研究各群組路段之網路構建，個別訓練與測試績效如下：群組 1-三重-台北以 ANN1 模式為最佳，MAPE 值為 12.1，群組 2-五股-三重以 ANN6 模式為最佳，MAPE 值為 8.06，群組 3-桃園-五股以 ANN51 模式為最佳，MAPE 值為 5.22，群組 4-機場桃園半處-桃園-以 ANN6 模式為最佳，MAPE 值為 19.72，群組 5-機場-機場桃園半處以 ANN2 模式為最佳，MAPE 值為 26.78，群組 6-幼獅-機場-以 ANN2 模式為最佳，MAPE 值為 9.183，群組 7-楊梅-幼獅-以 ANN1 模式為最佳，MAPE 值為 20.88，群組 8-新竹-楊梅-以 ANN1 模式為最佳，MAPE 值為 6.13。
6. 實證分析則利用實際客運車輛行駛之旅行時間來進行驗證工作，將起迄群組之間所得到的旅行時間估計值加總與實際旅行時間加總相互比較。選取類神經網路績效較佳的 ANN1、ANN2、ANN51、ANN52 與 ANN6 進行實證分析。
7. 實證分析採用 4 種指標：平均每車誤差(Error)、平均每車誤差之絕對值|Error|、平均誤差率 MPE(error%)、平均絕對誤差百分比(MAPE)。其中前二者為實際誤差秒數，較為主觀，乃為個別駕駛人所關心的資訊；後二者則為相對比率值，對於分析判別上較為客觀，為相關交通管理中心所重視。整體而言，ANN6 模式為最穩定之預測模式，且其預測能力亦與各群組數最佳之模式相差不大，所以 ANN6-考量上游路段旅行時間之全部時空幾何資料類神經網路模式之預測旅行時間能力最為優良。

7.2 建議

1. 因侷限本研究所蒐集之客運車輛實際旅行時間資料，網路訓練、測試與實證分析上不能有豐富的資料量，造成結果會有些偏誤，帶本研究確定研究流程與資料處理方式後，未來研究可增加蒐集資料時間，豐富資料量以提高網路預測之準確性。
2. 由於本研究模式構建概念乃屬初步發展階段，資料分析與整理工作即佔甚多時間與人力，因此未來應撰寫程式或發展資料庫來處理這些所蒐集到的資料，將之整理成各種類神經網路與實證分析時所需要的格式，以節省時間成本。
3. 本研究所採用之類神經網路為傳統之倒傳遞網路，未來可考慮視群組路段特性來建構群組自屬的類神經網路時空架構。
4. 由於本研究單就幾何與交通量來分割研究路段，未來可嘗試更適合的分段方式，甚至可以依照蒐集的資料擴大研究範圍。
5. 本研究所採用的交通調查報告雖可供未來時間資料之查詢，為其資料過久，可能造成偏誤，未來實際上線後所獲得之即時資料則可用來取代之。
6. 本研究各群組路段劃分尖離峰時段時間皆相同，未來可根據 VD 或 GPS 等資料所得之分析結果，不同群組地區有其特屬的尖離峰時間。
7. 模式構建之輸入變數與網路架構，須考量實際應用之可行性，並且嘗試結合相關業者，更可與交通電子地圖、即時資訊、先進偵測技術等擴充功能相互結合，進行商業化資訊提供，以獲得商機。

參考文獻

1. 交通部運輸研究所，高速公路匝道儀控現場督導、實施績效與衝擊評估，民國 83 年 11 月。
2. 吳廣南，高速公路中觀車流模式與路徑導引之研究，成功大學交通管理所碩士論文，民國 82 年。
3. 林旭濱，高速公路車流模擬模式與路徑導引控制之研究，成功大學交通管理所碩士論文，民國 84 年。
4. 林貴璽，高速公路基本路段容量暨相關影響因素特性之研究，交通大學交通運輸工程研究所，民國 75 年 6 月。
5. 林鄉鎮，高速公路小汽車駕駛者跟車行為之研究-以虛擬實境(VR)技術所構建之駕駛模擬系統為工具，成功大學交通管理所博士論文，民國 86 年。
6. 邱顯鳴，結合車道變換率之事件偵測新演算法研究，台灣大學土木所碩士論文，民國 84 年 6 月。
7. 徐國鈞，構建自學式適應性交通號誌控制模式之研究，成功大學交通管理所博士論文計劃書，民國 90 年。
8. 高速公路局，高速公路統計年報，民國 88 年。
9. 國道高速公路局，高速公路交通動態資料調查報告，民國 84 年 6 月。
10. 國道高速公路局交通管理組，『跨世紀高速公路交通管理-安全、順暢、智慧化』座談會報告資料，民國 88 年 8 月。
11. 國道高速公路局委託、中華民國運輸學會辦理，高速公路高乘宰車輛專用設施初步規劃研究，民 85 年 10 月。
12. 國道新建工程局，國道路網設置大眾運輸與高乘載車輛專用車道及設施之研究，民國 86 年 3 月。
13. 張有恆，運輸學，華泰書局，民國 82 年。
14. 葉怡成，應用類神經網路，儒林圖書公司，民國 86 年。
15. 葉怡成，類神經網路模式應用與實作，第七版，儒林圖書公司，民國 89 年 4 月。
16. 劉國偉、許仲仁、黃惠隆，「交通資料演算法之研究」，中華民國運輸學會第十二屆學術論文研討會論文集，1164-1172 頁，民國 86 年。

17. 鄭志平，應用衝擊波理論在高速公路封閉部分車道時旅行時間推算之研究，成功大學交通管理所碩士論文，民國 81 年。
18. 鄭雅文，高速公路追撞事故預測模式之研究，台灣大學土木所碩士論文，民國 86 年 6 月。
19. 魏健宏、汪志忠、黃文鑑、鄭子圳，「台北市公車專用道旅行時間預測之初步研究」，公元 2000 年台灣智慧型運輸系統 ITS 國際研討暨展覽會，民國 89 年。
20. 魏健宏、黃國平、陳昭宏，「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 25 卷第 2 期，209- 234 頁，民國 85 年。
21. 魏健宏、楊雨青，「高雄港轉口貨櫃運量預測-以類神經網路評選輸入變數」，運輸學刊第 11 卷第 3 期，1-20，民國 88 年。
22. 魏健宏、楊雨青，「智慧型運輸系統交通參數資料融合方法之研究-應用類神經網路」，第一屆台灣 ITS 國際研討會論文集，B1-26-B1-41 頁，民國 88 年。
23. Abdelfattah, A. M. and Khan, A. M. "Models for Predicting Bus Delays," Transportation Research Record, No. 1623, pp. 8-15, 1998.
24. Al-Deek, H. et al., "Travel Time Prediction for Freeway Corridors," Prepared for Presentation at the 78th Transportation Research Board Annual Meeting, Washington, D. C., 1999.
25. Bae, S., Lee, S. and Kim, T., "Development of A Dynamic Vehicle Location System," 5th ITS World Congress, 1998.
26. Chen, M. and Chien, I. J., "Dynamic Freeway Travel Time Prediction Using Probe Vehicle Data: Link-based vs. Path-based," Proceeding of Transportation Research Board Annual Meeting, Washington, America, Jan. 2001.
27. Choi, D. B., Ko, H. S., and Ahn, B. H., "On Multisensor Data Fusion using Attribute Association for Intelligent Traffic Congestion Information Inference," 5th ITS World Congress, 1998.
28. Choi, K., Shin, C. H., and Park, I., "An Algorithm for Calculating Dynamic Link Travel Times Using GPS and A Digital Road Map," 5th ITS World Congress, 1998.
29. Ding, Y., Chien, S. I., and Wei, C. H., "Dynamic Transit Arrival Time Prediction Using Link-Based and Stop-Based Artificial Neural Networks (Revised Version)," Submit to Transportation Research, October 2000.
30. Gately, E. "Neural Networks for Financial Forecasting", Technical Publishing Advistopy Board, 1996.
31. Hellinga, B., and Fu, L., "Route Selection Considering Travel Time Variability," 6th ITS World Congress, 1999.

32. Hobeika, A. G. and Lee, S. K., "An Adaptive Strategy for Dynamic Route Guidance Systems Under Incident Conditions," 5th ITS World Congress, 1998.
33. Ivan, J. N. et al., "Real-Time Data Fusion for Arterial Street Incident Detection Using Neural Networks," Transportation Research Record, No. 1497, pp. 27-35, 1995.
34. Ivan, J. N., "Neural Network Representations for Arterial Street Incident Detection Data Fusion," Transportation Research, Part C, Vol. 5, No. 34, pp. 245-254, 1997.
35. Jasperse, D. and Toorenborg, J. V., "Real-Time Estimation of Travel Times and Queue-Lengths A Practical Study," 6th ITS World Congress, 1999.
36. Jung, H. Y., Bae, S. and Shim, Y., "Development of A Dynamic Model for ATIS Application," 5th ITS World Congress, 1998.
37. Kato, T., Yuyama, M., and Tanaka, J., "Traffic Information System on The Expressway In The Event of The Nagano Olympic Games," 5th ITS World Congress, 1998.
38. Kim, H., Cohi, K. and Ahn, B., "Evaluation of Estimated Shortest Travel Time in Dynamic Traffic Network Using TRAF-NETSIM," 6th ITS World Congress, 1999.
39. Kloot, G., "Melbourne's Arterial Travel Time System," 5th ITS World Congress, 1998.
40. Kurokawa, T., and Ogawa, K., "A Study on Travel Time Prediction Method on Inter-City Expressways Using Traffic Capacity at The Bottleneck," 5th ITS World Congress, 1998.
41. Lee, Y. I. And Choi, C. Y., "Development of a Link Travel Time Prediction Algorithm for Urban Expressway," 5th ITS World Congress, 1998.
42. Lee, Y. I., "Prototype of Traffic Information Center for Seoul," 5th ITS World Congress, 1998.
43. Lewis, C. D. Industrial and Business Forecasting Method, 華泰書局, pp.38-41, 1982.
44. Otokita, T., Oda, T., and Hashiba, K., "Travel Time Prediction Based on Pattern Extraction from Database," 5th ITS World Congress, 1998.
45. Palacharla, P. V. and Nelson, P. C., "On-Line Travel Time Estimation using Fuzzy Neural Network," 2nd ITS World Congress, 1995.
46. Park, D. et al., "Spectral Basis Neural Networks For Real-Time Travel Forecasting," Journal of Transportation Engineering, pp. 515-523, Nov/Dec, 1999.

47. Shin, C. H. and Kim, S. H., "Development of Low-cost AVI System and a Travel Time Estimation Algorithm for the Olympic Expressway Traffic Management System in Seoul," 5th ITS World Congress, 1998.
48. Suzuki, H. et al., "A Neural-Kalman Filter for Dynamic Estimation of Origin-Destination(O-D) Travel Time and Flow on a Long Freeway Corridor," Prepared for Presentation at the 79th Transportation Research Board Annual Meeting, Washington, D. C., 2000.
49. TransGuide Expands its Traveler Information: A Discussion with TxDOT's Brian Friello, Newsletter of the ITS Cooperative Deployment Network, <http://www.nawgits.com/icdn/tgupdate.html>.
50. Wang, Y., and Sisiopiku, V. P., "Review and Evaluation of Incident Detection Method," 5th ITS World Congress, 1998.
51. You, J. and Kim, T. J., "Toward Developing an Expert GIS-Based Travel Time Forecasting Model With Congestion Pattern Analysis," 5th ITS World Congress, 1998.
52. Zhang, H., Ritchie, S. G., and Lo, Z., "Macroscopic Modeling of Freeway Traffic Using an Artificial Neural Network," Transportation Research Record, No. 1588, 110-119, 1997.
53. Zietsman, J. and Rilett, L. R., "A Comparison of Aggregate and Disaggregate Based Travel Time Estimation for Sustainability and ATIS Systems Applications," Prepared for Presentation at the 79th Transportation Research Board Annual Meeting, Washington, D. C., 2000.

著作人簡歷

姓 名： 林士傑

籍 貫： 台灣省彰化縣

生 日： 民國 66 年 9 月 23 日

學 歷： 彰化縣北斗國小

彰化縣立北斗國中

台灣省立彰化高級中學

國立成功大學交通管理科學系

國立成功大學交通管理科學研究所

賜教處： 彰化縣北斗鎮中山路二段 251 巷 6 號

電 話： 04-8883126 04-8875865

著作權聲明

☐

本論文同意全部影印

☐

本論文同意部份影印

☐

本論文不同意影印