

高速公路客運車輛旅行時間預測之 實證評析¹

EMPIRICAL VALIDATION OF FREEWAY BUS TRAVEL TIME FORECASTING

魏健宏 Chien-Hung Wei²

林士傑 Shih-Chieh Lin³

李 穎 Ying Lee⁴

(91年5月3日收稿, 91年11月12日第一次修改, 91年12月19日第二次修改,
92年2月18日第三次修改, 92年9月25日定稿)

摘 要

本研究係以先前構建之旅行時間預測模式為基礎, 運用類神經網路開發了具有良好預測能力的旅行時間模式後, 所進行的實證分析研究。主要是以真實車流資料對模式輸出結果進行充分驗證, 考慮單一群組、跨群組等不同路段長度與特性對於旅行時間之影響, 滿足實際生活中所可能發生的不同區間使用者需求, 彰顯出模式在各種狀況下的穩定性以及未來實務應用階段的準確可靠能力。本研究分別從使用者觀點與管理者觀點採用不同評估指標驗證分析結果, 初步確認了類神經網路於國內高速公路旅行時間預測之實務應用可行性與高度準確性, 亦將國內智慧型運輸系統的發展願景向前推進。

-
1. 感謝交通部運輸研究所、中華顧問工程司、警察廣播電台協助提供本研究所需之資料, 特此誌謝。
 2. 國立成功大學交通管理科學系教授 (聯絡地址: 701 台南市大學路 1 號成功大學交通管理科學系; 電話: 06-2757575 轉 53233; E-mail: louiswei@mail.ncku.edu.tw)。
 3. 國立成功大學交通管理科學系碩士。
 4. 國立成功大學交通管理科學系博士班研究生。

關鍵詞：高速公路；旅行時間；類神經網路；智慧型運輸

ABSTRACT

A travel time forecasting model has been developed satisfactorily in previous research using the artificial neural networks. In order to assess how effective the model is in the real traffic condition, we conducted this validation study. In this study, we discussed the model forecasting ability in different distances with different origin and destination pairs. In comparing real bus travel time with the forecasted travel times, we employed four criteria to evaluate the model outputs. The empirical results indicated stable and reliable performance of the proposed forecasting model. While more validations are required, this study showed very promising practical applicability of the proposed model in the Intelligent Transportation Systems (ITS) context.

Key Words: *Freeway; Travel time; Artificial neural networks; Intelligent transportation systems*

一、緒 論

由於運輸建設方案執行速度永遠不及交通需求之膨脹，供不應求狀況下所衍生出的行程不確定性乃相對提高。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，高速公路管理當局利用電腦、電子、通訊、控制、整合等技術，配合交通管理與控制策略，以提升運輸系統整體效能，逐步發展高速公路智慧化。為促進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，必須兼顧高速公路系統之運作效率，使得高速公路之管理工作顯得複雜許多。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，行駛至目的地的路線選擇性增加，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、交通資訊更符合旅行者之需求，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效益極大，因此擁有此項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。未來準確之旅行者資訊系統預測交通資訊服務，更可與交通電子地圖、即時資訊、先進偵測技術等功能相互結合擴充，提供如旅行時間地圖、替代道路、路徑導引之交通服務。

旅行時間主要可作為先進用路人資訊系統中的資訊服務內容之一，將旅行時間資訊即時、正確的提供給用路人，以為路徑導引策略實施之參考。再者可提供交通管理當局作為路網績效評估、控制策略研擬、駕駛人行為分析等決策應用分析。另外客運車輛營運業

者自身亦能即時掌握車輛狀態、位置、道路環境、旅行時間等資訊，進行車隊管理、人員排班、營運管理策略擬定等，提升國道客運服務水準與營運績效。

日前本研究已經成功整合多種資料來源（客運車輛 GPS 資料、路上車輛偵測器資料、事件資料等），運用類神經網路（Artificial Neural Network, ANN）構建一適用於國道 1 號台北—新竹路段之旅行時間預測模式，模式預測結果良好。此次實證分析目的主要是利用真實行車資料針對模式進行嚴格的評析，用以了解模式於真實環境下的應用性、穩定性與可靠性，以及檢測不同路段長度、特性與交通環境下的旅行時間預測績效。並分別站在使用者觀點與管理者觀點提供其不同的模式驗證分析指標，從不同角度用以說明模式績效。並且可作為未來旅行時間資訊提供實務應用單位、策略規劃單位或是交通管理單位之參考。

二、文獻回顧

近年來有關於旅行時間預測的研究廣泛地應用於動態交通量指派（Dynamic Traffic Assignment）領域中的旅行時間函數。在動態交通量指派中的旅行時間函數約可分為兩類^[1]，一類為利用統計分析方式，尋找出路段流量與路段旅行時間值之關係即為旅行時間函數。例如以路段中之車流量作為自變數、旅行時間值為因變數所構建之旅行時間線性模式最為廣泛使用，Carey 與 McCartney^[2]為符合真實情境下流量會隨時間變化，故於旅行時間函數中以路段流入量乘上旅行時間作為路段流量值，並證明在單一路段中，當流入量與流出量分配為相似時，以流量推估旅行時間值的簡單線性模式可有穩定的表現；當流量推估旅行時間值的模式為非線性時，相同的流入量下會推估出不同的旅行時間值，便需注意旅行時間值是否收斂在期望的區間內，顯示了以統計模式推估旅行時間此等屬於非線性問題時的風險。

另一類使用理論分析方式，以無流量狀態下之旅行時間為基準，考慮路段實際容量、流量、延滯等參數影響調整出旅行時間函數，此種方式可以反映路網特性改變之效果。Tong 與 Wong^[3]在交通量指派模式研究中以微觀模擬方式記錄每輛車經過路段的旅行時間，以路段距離與速度求出每車行駛時間。路段容量達飽和時，車輛行駛時間需加上等候時間才為旅行時間。當連續多路段時，便以進入本路段時刻加上本路段旅行時間作為進入下一路段的時刻。該研究中組合路段之技巧與其他旅行時間預測文獻相同，可為旅行時間預測模式構建之基礎架構。

除配合交通量指派研究外，國內外亦有針對旅行時間預測課題所進行之研究成果，以往研究中採用的演算法大致有濾波法、迴歸分析、模糊理論、類神經等數種，由於旅行時間預測牽涉多型態之交通參數、時空關係複雜，類神經網路具有資料融合、處理非線性問題的強大優勢，相當適合運用於旅行時間預測問題。

2.1 國外都市快速道路旅行時間預測

Lee^[4]採用 Kalman filtering 技術，於漢城奧運快速道路的 17 個影像偵測器、廣播報導、閉路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 與占有率 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、占有率與點速度資料，將之合成為 1 分鐘資料進行上述方法的推估，由 MAPE (Mean Absolute Percentage Error)、MSE (Mean Square Error)、EC (Equality Coefficient) 等指標得知 Kalman filtering 在此有較佳的績效。

此外，Chen^[5]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 演算法進行旅行時間預測。以 I-80 公路作為參考，選取其中含有 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，吾人認為可能是該研究只考慮了旅行時間，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，因此所構建的預測模式亦能較適用於真實道路。

2.2 國內高速公路旅行時間預測

國內亦有採用模擬方式獲得參考資料進行旅行時間預測之研究，張修榕^[6]以國道 1 號內壢交流道至中壢交流道約 1 公里之路段，採用模擬方式產生交通資料，以類神經網路法之倒傳遞演算法建立不同交通車流型態下之旅行時間預測模式，包括高、中、低流量下或是偵測器布設間距不同情況下，探討其差異。研究結果發現偵測器布設間距不影響旅行時間預測的準確性；在流量大小方面，當流量大於 1300 輛／小時，預測結果較差，但仍比其他旅行時間法則之預測誤差小。相較於林士傑^[7]之研究成果，該研究在研究範圍路段

上較短、空間小，只有兩匝道間一個路段，考慮之交通變化狀況少，較不符合真實車流情境。模擬資料進行之相關研究雖可以作為參考，但在未來實務應用上之真實性與變異性的掌握卻仍有不足之處。

相對於模擬資料的運用，國內已有相關研究採用真實交通環境資料進行旅行時間預測。吳佳峰^[8]將預測範圍切分成數個路段，以客運車輛 GPS 資料之車速度、位置、行駛時間等歷史資料庫整理預估出各路段車輛旅行時間，並以本車輛之當下速度以及前車速度、旅行時間等資訊調整本車旅行時間預估值，構建高速公路與一般平面道路皆可使用之通用模式。該模式將旅行時間分為車輛運行時間與停等時間兩部分分別計算之，再經過加總成為一完整的旅行時間值。最後以台汽客運台北－高雄線國光號班車 GPS 資料進行高速公路旅行時間預估之驗證，以新竹客運市區路線 2 路班車進行市區一般道路旅行時間預估之驗證。驗證結果在高速公路一般行車狀況下，旅行時間預估結果良好，但在尖峰時段則出現較大誤差，市區道路由於無法準確預估車輛停等時間以掌握車輛行車狀況，預估模式誤差較大。該模式因預測範圍過長，使其長距離路段之預測績效明顯不可靠，所提供之預測值亦因誤差大而需逐步調整。

林士傑^[7]以國道 1 號台北－新竹約 70 公里的路段為研究範圍，將該區間依幾何特性、匝道進出流量與地區重要性等準則分為 8 個群組路段，以台汽客運 GPS 資料之車速及時間、車輛偵測器之點速度、事件數、尖離峰、假日非假日、調查流量等真實環境資料作為輸入參考變數，排列組合前述之變數，構建數種模式，包括簡單時間序列模式、考慮前後群組時間關係模式等。整體而言，以考量前後群組輸入變數時空關係之模式在訓練與測試階段呈現之預測績效最佳、最穩定。本研究即是以該研究為基礎，進行模式的實證分析，藉此了解所構建之旅行時間預測模式的預測績效與未來實務應用價值。

三、構建高速公路旅行時間預測模式

3.1 資料來源

本研究蒐集對於旅行時間預測有助益之相關資料如表 1，包括客運車輛 GPS 資料：旅行時間、速度等；車輛偵測器資料：速度；事件資料：事件類型、事件數等；道路幾何資料：車道數、匝道數、收費站等；時間資料：假日非假日、尖離峰等。所有資料需同步啟動蒐集，以利本研究尋找出其影響旅行時間預測之關係，本研究之資料為民國 89 年 12 月 1 日（週五）至 12 月 4 日（週一）同時蒐集而得。蒐集時程從週五跨越週末假日至週一，內容包含了假日與非假日、尖峰與非尖峰時段、白天與夜晚等各種交通特性下產生的真實資料。初期目標為發展一整合性的旅行時間預測模式，未來資料充足時，可再依不同時段之交通特性分別構建模式。

本研究蒐集之客運車輛 GPS 資料包含該車通過交流道定點時當下之車速率、位置、

時刻值，經過比對後可立即計算出該車通過每一群組路段之旅行時間值，本研究以此客運車輛 GPS 資料計算而得之路段實際旅行時間值作為模式預測之基準，再將模式預測值與之比較，即為本研究衡量模式預測能力的績效。輸入資料、輸出資料、驗證資料之說明，詳見表 1。

表 1 各種資料來源及形式

	資料類型	資料內容	資料單位	資料值域	更新時間間隔	資料來源
輸入資料	客運車輛 GPS 資料	速度	公里／小時	0 ~ 200	每 1 ~ 3 分鐘	台灣汽車客運公司 (國光客運前身)
	車輛偵測器資料	速度	公里／小時	0 ~ 200	每 5 分鐘	高速公路局
	事件資料	各事件類型個數	類型 A ~ I 分別的個數	0 ~ N	每 2 ~ 3 分鐘	警察廣播電台
		事件總個數	個數	0 ~ N		
	時間資料	時段	時	0 ~ 23	無更新問題	
		假日／非假日	個	1 表假日 2 表非假日		
		尖／離峰	個	1 表尖峰 2 表離峰		
	流量資料	匝道入口流量	輛／小時	11 ~ 3256	依時段查表而得	國道高速公路局 ^[9]
		匝道出口流量	輛／小時	12 ~ 2474		
		主線流量	輛／小時	20 ~ 2378		
		收費站流量	輛／小時	480 ~ 5365		
	幾何資料	群組路段長	公尺	1 ~ 26	依據高速公路幾何設計資料	國道高速公路局 ^[9]
		車道數	個	2 ~ 5		
		收費站數	個	1 表有收費站		
		收費站車道數	個	6 ~ 10		
		群組內入口匝道數	個	0 ~ 4		
		群組內出口匝道數	個	0 ~ 4		
輸出資料	客運車輛 GPS 資料	本群組路段之旅行時間預測值	秒	50 ~ 1450		
驗證資料	客運車輛 GPS 資料	本群組路段之旅行時間實際值	秒	25 ~ 1300		

3.2 模式架構

從過去文獻中可知類神經網路法則在預測功能上有著極佳的成效，其中又以類神經網路法中的倒傳遞網路 (Back Propagation Network, BPN) 模式最為廣泛應用，在實務與研究上具有高度的利用價值與相當可靠的模式構建能力，故本研究便以類神經網路法則作為旅行時間預測模式構建之方法論。

本研究係依幾何特性與交通瓶頸特性細分成數段特性相似之群組路段，每個群組路段內可能包含不同交流道數、車道數與收費站等交通環境差異。個別群組路段構建自屬的類神經網路模式，主要係依照不同資料來源、不同輸入變數之組合，調整模式架構，進行訓練與測試。

研究範圍是將國道 1 號新竹往台北方向道路分為數個群組路段，每個群組路段構建自屬的類神經網路預測模式，待用路人提出起迄旅行時間之資訊需求時，方進行起迄點間對應群組路段旅行時間之各別預估工作，並進行各路段預測值之加總以給予用路人所需之起迄點間旅行時間值。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－新竹交流道間路段分群如表 2 所示。

表 2 本研究群組別

群組別	交流道起迄 (里程數)	距離 (公里)
群組 1	三重(27)→台北(25)	2
群組 2	五股(33)→三重(27)	6
群組 3	桃園(49)→五股(33)	16
群組 4	桃園與機場間(51)→桃園(49)	2
群組 5	機場(52)→桃園與機場間(51)	1
群組 6	幼獅(67)→機場(52)	15
群組 7	楊梅(69)→幼獅(67)	2
群組 8	新竹(95)→楊梅(69)	26
合 計	新竹(95)→台北(25)	70

各路段模式以類神經網路展現之架構如圖 1 所示。輸入層為 GPS 資料、VD 資料、事件資料，資料內容與格式可參見表 1。變數輸入類神經網路後，計算輸入層對隱藏層每一條線的影響權重，透過隱藏層中轉換函數之處理，再傳送至輸出層判定網路所運算出的旅行時間值即為公式(1)之 y 值，此一運算值與實際旅行時間值會有差距，故再以微分調整隱藏層對輸出層的影響權重以及輸入層對於隱藏層的權重，如此反覆運算與更新權重值，直到績效呈現穩定為止，即為最終之旅行時間預測值^[10]。

$$y = g \left(\sum_j w_{hj} \times f \left(\sum_i w_{ih} \times x_i - \theta_h \right) - \theta_j \right) \quad (1)$$

y ：輸出值；

i ：輸入層單元個數；

x_i ：輸入單元；

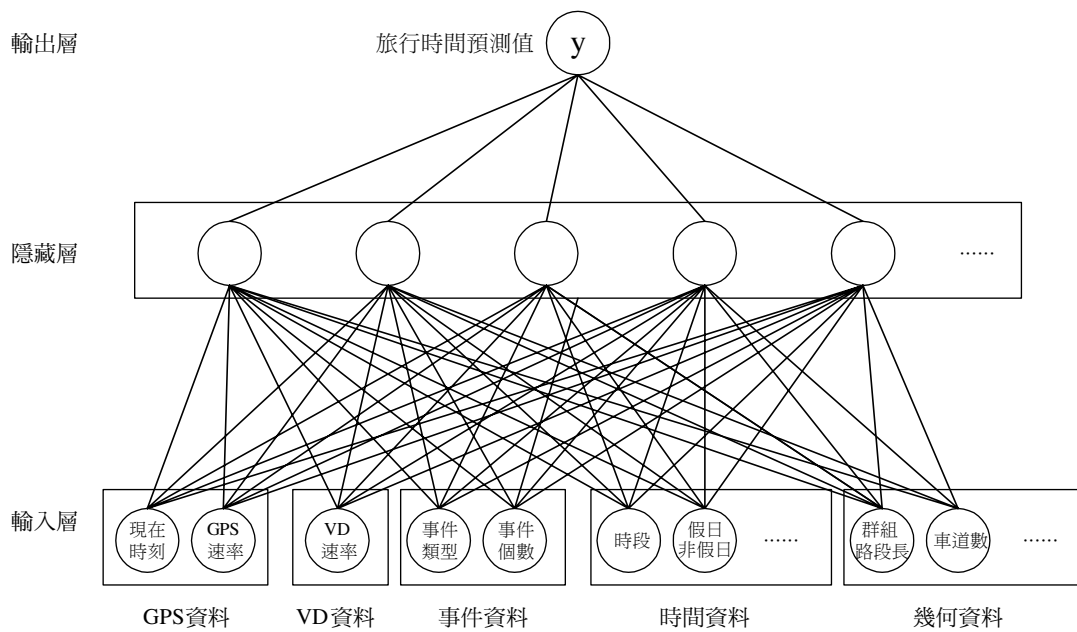


圖 1 本模式類神經網路架構圖—以 ANN6 為例

h ：隱藏層單元個數；

θ_h ：隱藏層門檻值；

w_{ih} ：輸入層與隱藏層之間的權重值；

f ：隱藏層之轉換函數；

θ_j ：輸出層門檻值；

w_{hj} ：隱藏層與輸出層之間的權重值；

g ：輸出層之轉換函數。

3.3 各旅行時間預測模式意義

本研究於每個群組皆構建出 6 種不同資料型態之旅行時間預測模式，各類模式的特性、構建概念與輸入變數說明詳見表 3、表 4。

模式構建之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。此種方式可免除為數過多之起迄時間預測模式，也與國外研究報告^[4,5]及交通資訊網站^[11]之作法一致。

表 3 旅行時間預測模式總覽

模式名稱	模式特性	模式構建概念	輸入變數類型
ANN1 時間序列模式	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 + 交通特性模式	時間序列 + 交通特性變數模式	由於歷史旅行時間資料間隔過大，恐不能即時反映目前之交通特性，準確地預測目前的旅行時間，因此納入含有交通特性之變數，以改善僅有一個旅行時間變數類型之時間序列模式，增加預測績效	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 + 車道特性模式	路段與速度模式 ANN31_(路段速度) ANN33_(路段速度 + 時間)	由於速度與路段長度已知，則可計算出各車輛偵測器路段之旅行時間；若速度更新時間愈短，所預測之旅行時間愈準確，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、車道數與車輛偵測器速度
ANN4 客運車輛 GPS 資料 + 車道特性模式	只利用客運車輛 GPS 資料及幾何特性	考量僅有客運車輛 GPS 資料更新的情況下，其旅行時間預測績效	客運車輛 GPS 速度、車道變化路段數、各路段之長度、車道數與位置
ANN5 總體資料融合時間考量模式	ANN51_總體資料融合時間考量模式(僅考量現在時間範例) ANN52_總體資料融合時間考量模式(現在時間 + 時間推移後衍生範例)	ANN51 是將客運車輛 GPS 資料、車輛偵測器、事件、交通幾何特性等因素一併考量以構建預測模式，ANN52 則是再加入用前群組之預測值為本群組起始時間而衍生出的範例樣本進行模式訓練、測試	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 總體資料融合空間考量模式	總體資料融合並考慮上游群組交通狀況在未來時間對本群組的影響	此模式特性是將客運車輛 GPS 資料、車輛偵測器、事件、交通幾何特性、上游路段交通狀況等因素一併考量以構建預測模式	同上 + 上一群組路段之客運車輛旅行時間與車輛偵測器速度

輸入資料之蒐集與處理必須考量旅行時間為連續性路段預測，應避免到達下個路段時造成先前所獲得的旅行時間預測值名實不符，因為到達下個路段時，交通狀況已更新為原時間加上通過該路段旅行時間後的情形，造成加總的部分路段旅行時間值會有誤差。所以為了達到準確且合理的預測，輸入資料時不應只考慮輸入原時間所蒐集到的即時交通參數，必須納入預測未來的概念。因此 ANN6 (總體資料融合空間考量類神經網路模式) 就是結合空間概念來表達此一未來時間特性，加入上游路段的交通狀況 (客運車輛旅行時間與車輛偵測器速度值) 為輸入變數，推論上游路段的交通流會伴隨著在一段時間後影響本路段，展現本模式預測之未來性。但若僅加入單一變數 (本車於上游群組旅行時間) 有可

能會產生一種數值狀態對應出兩種情況，例如，當上游群組旅行時間過長時，可能是發生事件或交通擁擠等，但是發生事件或交通擁擠對於下游路段的影響卻有所不同。發生事件後會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，本路段旅行時間將不會過長。相反地，如果上游路段旅行時間過長的原因乃由於交通擁擠，本路段所需之旅行時間勢必受影響，產生較長的旅行時間。為了避免類似判別錯誤情形發生，因此本研究納入「上游路段最末個車輛偵測器速度」變數。

表 4 時空類神經網路所考量之輸入變數

輸入變數	內容／單位	ANN1	ANN2	ANN3	ANN4	ANN51	ANN52	ANN6
時間	時 0 ~ 23		V			V	V	V
上下午	1, 2					V	V	V
星期	星期 1 ~ 7					V	V	V
前車之旅行時間	Sec	V	V					
本車前一群組路段之旅行時間	Sec							V
本車前一群組路段之車輛偵測器速度	KPH							V
偵測器速度	KPH		V	V		V	V	V
客運車輛 GPS 速度	KPH				V	V	V	V
各事件類型之事件個數	整數					V	V	V
事件總個數	A ~ I					V	V	V
群組內車道變化路段數	整數			V	V	V	V	V
群組內各路段車道數	整數			V	V	V	V	V
群組內各路段長度	KM			V	V	V	V	V
群組內交流道數	整數					V	V	V
主線流量	車輛數		V			V	V	V
各交流道進口匝道匝道數						V	V	V
各交流道出口匝道匝道數						V	V	V
各進口匝道流量	車輛數					V	V	V
各出口匝道流量	車輛數					V	V	V
群組內收費站個數						V	V	V
各收費站車道數						V	V	V
收費站車種車道數 (小型車不找零)						V	V	V
收費站車種車道數 (小型車找零)						V	V	V
收費站車種車道數 (大貨車)						V	V	V
收費站車種車道數 (聯結車)						V	V	V
收費站車種容量 (小型車不找零)	輛／時					V	V	V
收費站車種容量 (小型車找零)	輛／時					V	V	V
收費站車種容量 (大貨車)	輛／時					V	V	V
收費站車種容量 (聯結車)	輛／時					V	V	V
收費站流量	車輛數					V	V	V

四、模式訓練測試與實證概念

所有預測模式之網路訓練次數皆在 50,000 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 50,000 次作為固定條件，試誤出隱藏層處理單元數，並針對其網路績效加以說明。

本研究之網路以 Sigmoid、TanH 函數為轉換函數，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。

4.1 模式訓練測試評選方式

訓練、測試階段對於相同類神經網路模式在架構上的評比是以 ANN 軟體所提供的測試均方根誤差 (Root Mean Square Error, RMSE) 指標為依據；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平均絕對誤差率 (Mean Absolute Percentage Error, MAPE) 指標來評選最佳的 ANN 模式，MAPE 指標之定義與評估標準請參閱本文 5.1 節。表 5 即為群組 1 三重至台北路段各模式網路績效比較表，以 ANN1 為例，本研究以類神經網路訓練測試後之 RMSE 值評選最佳的轉換函數、隱藏層數與處理單元個數組合，ANN1 模式之最佳架構在訓練與測試階段 RMSE 值分別為 0.0639 與 0.0610，詳細架構請參閱文獻 [7,12]；其他模式亦是如此評選出該模式最佳的架構組合方式。各模式確定最佳架構方式後，計算各模式最佳架構之 MAPE 值，在各模式間選取 MAPE 值最小者，群組 1 中以 ANN1 模式的 MAPE 值最低，故評選出群組 1 之最佳模式為 ANN1。其他路段同此作法評選最佳模式。

表 5 「群組 1 三重－台北」之各類型網路績效初步評選

模 式	評選模式最佳組合架構		評選路段最佳模式
	訓練 RMSE	測試 RMSE	MAPE
ANN1	0.0639	0.0610	12.10
ANN2	0.0630	0.0604	13.69
ANN31	0.2691	0.3792	17.08
ANN33	0.1020	0.1458	16.99
ANN4	0.1034	0.1231	17.85
ANN51	0.0490	0.0625	14.96
ANN52	0.0496	0.0550	13.37
ANN6	0.0130	0.3590	12.25

群組 1 至群組 8 依照前述之方式評選後，各模式的績效表現順序如表 6 所示。由於沒有一個模式能夠在 8 個群組路段中皆表現絕對優異，而各模式之 MAPE 值亦相去不遠，故本研究選取在各群組路段中表現相對較佳的模式，即為 ANN1、ANN2、ANN51、ANN52、ANN6 等 5 種模式，從事進一步實證分析。

表 6 群組別之網路績效排名

群組別	排名 1	排名 2	排名 3
群組 8	ANN1 (6.13)	ANN33 (7.37)	ANN2 (7.65)
群組 7	ANN1 (20.88)	ANN2 (22.15)	ANN51 (25.28)
群組 6	ANN2 (9.18)	ANN6 (9.66)	ANN51 (9.80)
群組 5	ANN2 (26.78)	ANN6 (27.22)	ANN51 (32.26)
群組 4	ANN6 (19.72)	ANN2 (21.70)	ANN4 (23.36)
群組 3	ANN51 (5.22)	ANN6 (5.72)	ANN2 (5.90)
群組 2	ANN6 (8.06)	ANN1 (8.14)	ANN4 (8.72)
群組 1	ANN1 (12.10)	ANN6 (12.25)	ANN52 (13.37)

註：括號內為 MAPE 值。

4.2 模式實證概念

經由上述類神經網路構建與初步測試評選工作後，表 6 顯示明確的成果即類神經網路模式可以相當精確地估計各路段之旅行時間。至此階段，核心模式開發工作可說已滿足大多數學術領域的標準，然而旅行者之途程可能由不同起點經過若干長度、到達任一迄點，旅行時間資訊之提供必須符合此種真實需求，因此進一步的實證分析是有必要的。

為了解預測模式實際應用上的績效水準，探討網路預測績效之實證分析時，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 2 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間加總所得，此個別旅行時間之實際數值可由資料庫內蒐尋特定車輛由 A 經 B、C、D，以迄於 E 之時刻而求得。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，其主要關切者乃總旅行時間，並非各段之個別時間，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總時間之差異。本研究實證採用「未來時間模式」，以預測未來到達下一群組起點的到達時刻所對應的各項交通資料，進行下一群組的旅行時間預測，以此方式依序推衍，求出總旅行時間值。而非如「目前時間模式」般於各路段皆以現在時刻對應搜尋各項交通資料同時求出各段旅行時間值，予以加總成為總旅行時間。比較現在時間模式與未來時間模式的實證程序概念，未來時間模式程序利用有效的估計方法，考量了車輛運行時的時空推移，較符合現實交通情境，估計出之預測值亦較為合理。但「目前時間模式」之作業程

序極單純，僅為直接引用預測模式，在較短的距離內仍可提供旅行時間服務，美國^[11]與日本^[13]之系統現階段僅提供此功能，尚未能真正預測未來旅行時間。

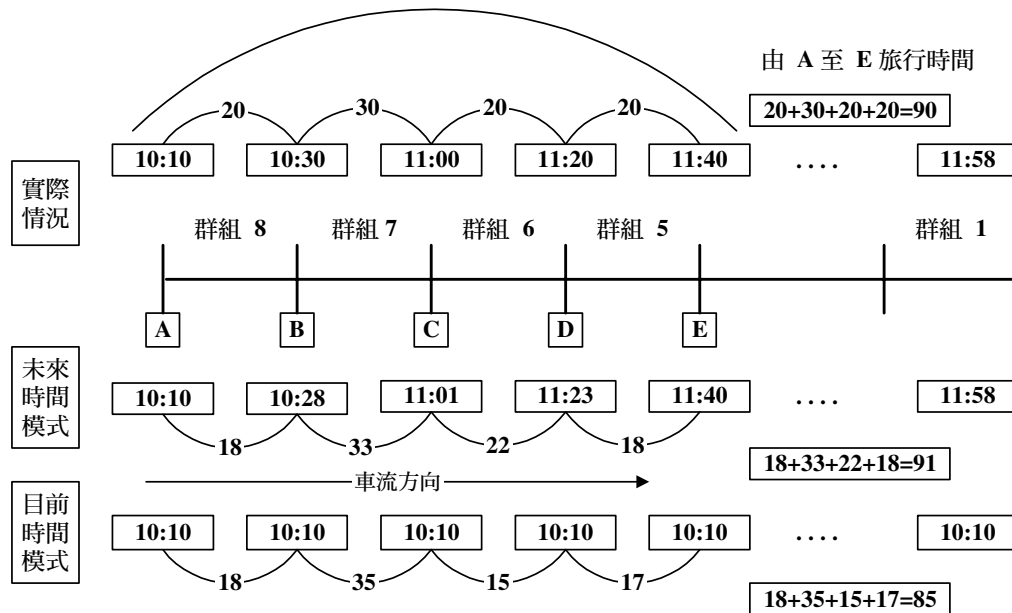


圖 2 實證分析示意圖

完整的實證分析應考量依照不同的起迄組合，編制出不同起迄之旅行時間需求矩陣表，亦即有由群組 8 出發、群組 7 出發、群組 6 出發…群組 1 出發，而欲到達之迄點有可能是任一個下游群組。但是，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。於是乎評選出測試過程中績效較佳的 ANN1、ANN2、ANN51、ANN52、ANN6 來進行實證分析。

4.3 實證資料分布特性

首先對於實證資料之分布情況繪製次數分配圖，以說明由群組 7 出發通過不同群組個數時的實際旅行時間分布特性。圖 3 為通過一個群組之旅行時間分布情況，其中可以看出由楊梅至幼獅所需之旅行時間以 60 ~ 90 秒之 68 筆為最多，在實證資料中群組 7 的平均旅行時間為 80.7 秒。

下圖 4 則為通過二個群組時之旅行時間分布情況，由楊梅→機場所需之旅行時間以 600 ~ 800 秒最多，共有 79 筆資料，在實證資料中由楊梅至機場的平均旅行時間約為 864.6 秒。




圖 3 通過群組 7 所需旅行時間次數分配圖




圖 4 通過群組 7 至群組 6 所需旅行時間次數分配圖

圖 5 是由楊梅至桃園半處，通過了三個群組所需要花費的旅行時間分布情形，以 600 ~ 800 秒為最多，共有 70 筆資料，在實證資料中由楊梅至桃園半處的平均旅行時間約為 917 秒。

圖 6 是由楊梅至桃園，通過了四個群組所需旅行時間次數分配圖，旅行時間 700 ~ 1000 秒之間共有 78 筆為最多，實證資料中楊梅至桃園的平均旅行時間約為 1007.6 秒。

圖 7 為楊梅至五股，通過五個群組時所需旅行時間的分布情形，旅行時間在 1300 ~ 1600 秒之間共有 50 筆，實證資料中楊梅至五股平均旅行時間約為 1790.8 秒。

圖 8 為楊梅至三重，通過六個群組所需旅行時間分布情況，旅行時間在 1600 ~ 1900 秒之間，共 55 筆為最多，實證資料中楊梅至三重之平均旅行時間約為 2046.3 秒。




圖 5 通過群組 7 至群組 5 所需旅行時間次數分配圖




圖 6 通過群組 7 至群組 4 所需旅行時間次數分配圖




圖 7 通過群組 7 至群組 3 所需旅行時間次數分配圖




圖 8 通過群組 7 至群組 2 所需旅行時間次數分配圖

圖 9 為楊梅至台北，通過七個群組所需旅行時間分布情形，旅行時間在 1900 ~ 2200 秒之間最多，共有 19 筆資料，實證資料中楊梅至台北平均旅行時間約為 2158.8 秒。




圖 9 通過群組 7 至群組 1 所需旅行時間次數分配圖

整體而言，若旅行時間分配情形愈集中，表示車輛行駛時間離散程度較小，在模式預測方面亦較易掌握。由前述可知，通過不同群組個數時所繪製出的旅行時間次數分配圖仍有相當程度的差異，顯示各群組的交通環境有明顯異質性。亦表示實際旅行時間值分布狀況與通過路段長度並無關連。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，除了模式內含的判斷分析能力需強大外，輸出預測值的穩定性也是考量要項。

五、模式實證評析

5.1 實證指標

本研究對於路段旅行時間之實證分析採用了 4 項績效指標^[13]：平均每車誤差 (Error)、平均每車誤差之絕對值 (|Error|)、平均誤差率 (Mean Percentage Error, MPE)、平均絕對誤差率 (Mean Absolute Percentage Error, MAPE)。前二者為實際誤差秒數，較為主觀感受，主要用途是展現個別駕駛人所關心的資訊，使其易於了解；後二者則為相對比率值，用於分析判斷上較為客觀，適合相關交通管理單位參考。公式定義與符號說明如下：

$$1. \text{Error}_{ji} = \frac{1}{M_{ji}} \sum_{k=1}^{M_{ji}} [\hat{x}_{ji}(k) - x_{ji}(k)]$$

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 i ，類神經網路模式 j 中的資料筆數；

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

i ：群組別；

k ：實證資料編號別；

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

$\hat{x}_{ji}(k)$ ：群組 i ，類神經網路模式 j 中第 k 個估計值。

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

符號定義同上，而 $|\text{Error}|_{ji}$ 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；

$$3. \text{MPE}_{ji} = \frac{1}{M_{ji}} \sum_{k=1}^{M_{ji}} \left[\frac{\hat{x}_{ji}(k) - x_{ji}(k)}{x_{ji}(k)} \right] * 100\%$$

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；

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

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

差率。MAPE 為相對性指標，不受實際值與估計值之單位與數值大小的影響，能客觀了解實際值與估計值之間的差異程度，本研究於模式構建時亦採用此指標評選出同一群組中最佳的網路類型。MAPE 值越接近零，表示模式估計效果越佳。Lewis^[14]認為 MAPE 值是最有效的評估指標，並對於 MAPE 值的大小與績效關係提出說明，如表 7 所示。

表 7 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

5.2 實證資料評析

在比較所有模式績效時發現，群組 7 因距離短，若績效指標為相對比率則結果顯得格外不佳，故增加群組 8* (26 公里)，並且與群組 7 (2 公里) 相互比較單一群組之距離與實證績效值的差異。選取群組 8 進行實證時，由於路段距離較群組 7 為長，其績效即呈現合理結果。由此可說明影響群組 7 績效之原因為路段距離過短，使得誤差相對比率值偏大，而非單一群組個數的影響。

表 8 為平均每車之實際值與估計值，實際值指客運車輛實際的旅行時間平均值，估計值指模式預測出之旅行時間平均值。由表 8 可以清楚看到隨著通過群組個數的增加及距離增長，平均每車之實際旅行時間與各預測模式估計值的差異程度皆會有所不同。以下分別由前述 4 項指標衡量差異程度。

表 8 平均每車旅行時間之實際值與估計值

單位：秒／車

路 段	ANN1		ANN2		ANN51		ANN52		ANN6	
	實際值	估計值	實際值	估計值	實際值	估計值	實際值	估計值	實際值	估計值
群組 8* (通過 1 個群組)	1175	1174	1197	1194	1184	1193	1184	1193	1184	1195
群組 7 (通過 1 個群組)	80	79	81	82	80	79	81	79	81	80
群組 7-6 (通過 2 個群組)	867	847	867	852	863	847	863	860	863	857
群組 7-5 (通過 3 個群組)	921	899	919	900	915	900	915	912	915	910
群組 7-4 (通過 4 個群組)	1013	983	1010	985	1005	986	1005	1001	1005	1000
群組 7-3 (通過 5 個群組)	1777	1758	1779	1753	1799	1785	1800	1799	1799	1799
群組 7-2 (通過 6 個群組)	2036	2020	2045	2018	2049	2035	2051	2055	2050	2048
群組 7-1 (通過 7 個群組)	2157	2157	2175	2168	2154	2152	2154	2174	2154	2157

1. 平均每車誤差 (Error)

表 9 為實際客運車輛行駛時間與模式預測旅行時間 (秒) 之誤差加總後的平均值，隱含有正負差數相互抵銷的概念，為整體平均的意義。

由圖 10 可發現在通過 1 至 5 個群組數時模式預測誤差以 ANN52 最低，形成此一現象有二種可能，一為模式預測極為準確，二為模式正誤差與負誤差相抵銷之結果，此點疑慮可於 |Error| 績效驗證中得知。在通過 6 個與 7 個群組長度的部分則以 ANN52 模式預測誤差最多 (+20 秒)，顯示此模式在預測路段大於 36 公里以上時較不可靠。整體而言，不論預測距離長短，ANN6 模式預測誤差皆低且穩定。

表 9 實證指標—平均每車誤差 (Error)

路 段	$\text{Error} = \frac{1}{M} \sum_{k=1}^M [\hat{x}(k) - x(k)]$				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8* (通過 1 個群組)	-1.19	-2.44	9.80	9.80	11.18
群組 7 (通過 1 個群組)	-1.36	0.95	-0.66	-1.86	-1.03
群組 7-6 (通過 2 個群組)	-20.10	-15.15	-16.50	-3.69	-5.98
群組 7-5 (通過 3 個群組)	-22.69	-18.90	-15.76	-3.54	-5.56
群組 7-4 (通過 4 個群組)	-29.93	-24.81	-19.62	-4.61	-5.32
群組 7-3 (通過 5 個群組)	-19.07	-26.35	-13.94	-0.54	0.22
群組 7-2 (通過 6 個群組)	-16.18	-26.75	-14.49	3.67	-1.71
群組 7-1 (通過 7 個群組)	-0.14	-6.53	-1.57	20.60	3.02




圖 10 實證指標—平均每車誤差 (Error)

2. 平均每車誤差之絕對值 |Error|

整體而言，如表 10 所示，旅行時間誤差乃隨距離增加而變大，此係各段誤差累積所造成，應為合理現象，其中以 ANN2 模式表現最佳，ANN52 最差，證明了 ANN52 模式預測誤差呈現明顯的正負擺盪，預測能力並不穩定。在圖 11 中選取較佳的 2 個模式 ANN2 與 ANN6，觀察其曲線，呈現出誤差增加率逐步減緩的趨勢，亦即誤差絕對值將隨距離增加而逐漸遞減，表示兩模式為隨距離增加而預測能力逐漸穩定的模式。

表 10 實證指標—平均每車誤差之絕對值 (|Error|)

路 段	$ Error = \frac{1}{M} \sum_{k=1}^M \hat{x}(k) - x(k) $				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8* (通過 1 個群組)	93.17	30.07	33.99	33.99	34.80
群組 7 (通過 1 個群組)	19.79	15.46	15.86	16.72	16.25
群組 7-6 (通過 2 個群組)	57.81	42.70	74.18	77.42	53.86
群組 7-5 (通過 3 個群組)	66.27	47.90	76.15	79.85	55.67
群組 7-4 (通過 4 個群組)	70.39	52.95	74.09	78.88	54.19
群組 7-3 (通過 5 個群組)	100.00	68.31	91.36	94.40	71.14
群組 7-2 (通過 6 個群組)	106.00	71.21	97.96	105.36	76.91
群組 7-1 (通過 7 個群組)	96.70	75.01	94.22	103.36	93.42




圖 11 實證指標—平均每車誤差之絕對值 (|Error|)

3. 平均誤差率 (MPE)

由表 11 與圖 12 可以發現通過 1 個群組時，平均誤差率較為不佳，大於 10%，原因即為前述所提及群組 7 路段距離過短，導致計算出之平均誤差率指標值較大。整體而言，本研究所構建之模式其預測誤差的比率皆低，ANN2 模式其預測值較實際值為小，屬於風險較大之預測模式；ANN6 模式的平均誤差率最小，其預測值僅略大於實際值，誤差程度亦較為穩定，屬於穩定且保守型模式。

表 11 實證指標－平均誤差率 (MPE)

路 段	$\text{MPE} = \frac{1}{M} \sum_{k=1}^M \left[\frac{\hat{x}(k) - x(k)}{x(k)} \right] * 100\%$				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8* (通過 1 個群組)	0.88	-0.26	0.78	0.78	0.91
群組 7 (通過 1 個群組)	14.34	11.52	12.55	10.50	11.12
群組 7-6 (通過 2 個群組)	-0.69	-1.27	-0.67	0.68	0.19
群組 7-5 (通過 3 個群組)	-0.72	-1.60	-0.53	0.69	0.27
群組 7-4 (通過 4 個群組)	-1.07	-1.89	-0.85	0.63	0.36
群組 7-3 (通過 5 個群組)	0.05	-1.19	-0.39	0.29	0.40
群組 7-2 (通過 6 個群組)	0.19	-0.99	-0.34	0.47	0.33
群組 7-1 (通過 7 個群組)	0.67	-0.35	0.08	0.94	0.52




圖 12 實證指標－平均誤差率 (MPE)

4. 平均絕對誤差百分比 (MAPE)

從表 12 與圖 13 中發現以 MAPE 為績效指標時亦與 MPE 績效指標有著相同的現象，通過 1 個群組時所有模式皆看似不佳， $MAPE > 25\%$ ，其原因同前述說明，因為通過群組 7 之總旅行時間值過短，以致於誤差時間雖少卻會因分母小而造成比值放大的現象，若轉換成旅行時間值，則僅有約 20 秒之誤差，對整體路段旅行時間預測影響不大。或是以 MAPE 指標分析法則評析績效， $MAPE = 30$ ，是一合理的預測模式。除此之外，在通過 2 個群組以上的距離長度時，所有模式的 MAPE 值皆非常優良，為高精確度的預測模式，又以 ANN2 模式表現最佳，ANN6 模式次之，然而差別非常微小。

表 12 實證指標－平均絕對誤差百分比 (MAPE)

路 段	$MAPE = \frac{1}{M} \sum_{k=1}^M \left \frac{\hat{x}(k) - x(k)}{x(k)} \right * 100\%$				
	ANN1	ANN2	ANN51	ANN52	ANN6
群組 8* (通過 1 個群組)	7.93	2.55	2.68	2.68	2.78
群組 7 (通過 1 個群組)	31.28	26.09	27.65	27.04	27.18
群組 7-6 (通過 2 個群組)	6.12	4.77	7.88	8.16	6.12
群組 7-5 (通過 3 個群組)	6.80	5.04	7.62	7.87	5.99
群組 7-4 (通過 4 個群組)	6.30	4.97	6.71	7.07	5.28
群組 7-3 (通過 5 個群組)	5.25	3.59	4.79	4.85	3.84
群組 7-2 (通過 6 個群組)	4.94	3.31	4.54	4.82	3.66
群組 7-1 (通過 7 個群組)	4.45	3.41	4.37	4.65	4.34

MAPE平均絕對誤差百分比




圖 13 實證指標－平均絕對誤差百分比 (MAPE)

運用實際客運車輛旅行時間資料進行實證分析後，比較 4 項績效指標，可歸納成如表 13 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。指標 1 平均每車誤差 (Error) 與指標 2 平均每車誤差之絕對值 |Error| 目的是以簡單的誤差時間提供道路使用者一容易了解本研究績效之判斷依據。

在旅行時間實際值與估計值誤差相同的情況下，旅行時間實際值與估計值仍有可能為不同的組合，例如估計值 50 秒與實際值 10 秒之誤差，估計值 90 秒與實際值 50 秒之誤差，兩者皆為 40 秒，但其誤差比率卻有明顯的不同。因此採用指標 3 平均誤差率 (MPE) 與指標 4 平均絕對誤差百分比 (MAPE) 將誤差值與旅行時間長度做一百分比關係之分析，在評估模式績效時可較為嚴謹，適合提供交通管理當局決策之用。

從表 13 中，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，所以考量上游路段旅行時間、車輛偵測器速度值及時空幾何資料的 ANN6 類神經網路模式，其預測旅行時間能力最為優良。

表 13 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、ANN6					

經過本研究實際驗證了不同模式與通過路段長度之間的績效關係後，評選出預測能力最好、最穩定的 ANN6 模式，除了以前述 4 項指標表達出模式的平均結果外，再進一步繪製出旅行時間實際值與其估計值之殘差關係圖以展現每一預測值與實際值的誤差程度，殘差圖如圖 14 至圖 20 所示。從圖形可以清楚了解，本研究於每起迄對進行實證分析時具備了充足的資料數量，包含假日與非假日、尖峰與非尖峰等不同交通特性狀態下的實際旅行時間值，所構建的旅行時間預測模式，僅有少數誤差在 200 秒以上，更為詳實的證明了本研究的預測績效，不論通過路段長短，ANN6 模式皆能提供穩定可靠的旅行時間預測值。

茲再以另一種方式呈現本模式實際值與估計值之間的相似度，如圖 21 所示。圖 21 之 x 軸表示每一筆樣本的實際旅行時間值，y 軸表示每筆樣本的預測旅行時間值，每一點是依據 (實際值，估計值) 座標型態繪製而成。在三重—楊梅路段的資料分布自 1500 秒至 3900 秒皆有，表示本模式的資料包含了在各樣交通狀況影響下的旅行時間資料。驗證結果顯示，不論交通狀況如何，本研究預測誤差皆小，亦即大多數資料點的分布接近在對角線上，展現本模式對於現實交通複雜狀況的優良掌握能力。




圖 14 ANN6—通過群組 7 旅行時間估計值與實際值之殘差圖




圖 15 ANN6—通過群組 7 至群組 6 旅行時間估計值與實際值之殘差圖




圖 16 ANN6-通過群組 7 至群組 5 旅行時間估計值與實際值之殘差圖




圖 17 ANN6-通過群組 7 至群組 4 旅行時間估計值與實際值之殘差圖




圖 18 ANN6-通過群組 7 至群組 3 旅行時間估計值與實際值之殘差圖




圖 19 ANN6-通過群組 7 至群組 2 旅行時間估計值與實際值之殘差圖




圖 20 ANN6-通過群組 7 至群組 1 旅行時間估計值與實際值之殘差圖




圖 21 旅行時間實際值與估計值之散布圖

六、結論與建議

6.1 結論

綜合前述實證分析結果，約略可提出下列數點結論：

本研究採用類神經網路法則為方法論，構建之旅行時間預測模式，成果豐碩績效優

良，顯示類神經網路充分展現其預測課題方面的強大功能，成功的應用於旅行時間預測研究中，證明類神經網路實為構建旅行時間預測模式之有利工具。

模式 ANN52 實證分析時於平均每車誤差指標中績效最佳，但是從平均每車誤差絕對值中，卻發現了其誤差為正負擺盪嚴重之模式，顯示本研究之實證分析不但考量使用者主觀感受與管理者客觀分析判斷之需求，更以多元的角度、完整的剖析出各模式的實際成效。

綜合比較中發現本研究構建之數種旅行時間預測模式，隨著路段距離增長，預測值誤差率有逐漸低降，漸趨穩定的趨勢，路段長為 12 公里時，各模式的 MAPE 值約在 4.5% ~ 8.5% 之間，隨著路段距離增長，預測誤差持續降低，路段長 70 公里時，誤差已降低至 3.4% ~ 4.7% 之間。表示本研究將路段切分數段再分別構建旅行時間預測模式的概念正確且可行，模式預測能力除在單一路段展現其高準確的預測成效以外，組合各路段之模式後提供更長距離的旅行時間預測，其預測績效非但無隨距離增長、交通影響變異增加而降低，甚而誤差更小，預測更為精準。

因此本研究旅行時間預測結果績效優良，乃是歸因於本研究提出之網路架構、輸入變數種類與型態以及考慮前後路段之相互影響關係等概念構建模式後，模式掌握旅行時間趨勢之結果。

本研究成功的利用交通資訊的蒐集整合構建出旅行時間預測模式，未來的智慧型車輛可一邊行駛一邊接收即時交通資訊，故未來的旅行時間預測模式可隨時間逐漸更新輸入變數內容，即時將下游路段所需的輸入變數內容帶入模式中，獲得更為即時、準確的旅行時間預測值。

實證分析結果，融合多樣資料來源的 ANN6 模式預測績效最佳，而單純考慮時間序列與客運車輛 GPS 資料的 ANN2 模式次之。現有經驗顯示，良好的預測模式必須同時包含公部門（車輛偵測器）與私部門（客運車輛 GPS）所蒐集的動態資訊，經過適當的處理與融合，始可達到實用程度。因此公私部門合作（Public-Private Partnership）乃為推動 ITS 之重要基石。

經過真實交通資料的嚴格實證分析考驗，證明了本研究所構建之 ANN6 總體資料融合空間考量模式，相當成功的整合了多種資料來源，運用類神經網路與真實行車時間資料，呈現出準確的旅行時間預測績效，不論是短至 1 公里，甚或長至 70 公里，都能提供一穩定且可靠的預測值。並針對使用者與管理者的需求，分別以不同的績效指標進行驗證工作，提供其易於了解本模式績效，讓不同類型的使用者都有可採納參考的依據。此項研究成果，不論是在國內或是國外的旅行時間預測課題上，皆是一大重要突破與發現，也證明了類神經網路於旅行時間預測方面的適用性，由此確認了以類神經網路於旅行時間預測實務應用課題上之價值。另外，在旅行時間資訊提供服務方面，模式構建後之預測能力、個人化服務的提供程度與資訊服務範圍等三項目標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，本研究之分析過程與成果可提供後續旅行時間資訊服務實務應用時參考。更期望本研究的成果分析，能為國內積極推展之智慧型運輸（Intelligent Transportation Systems, ITS）計畫貢獻一己之心力。

6.2 建議

最後，針對未來應用類神經網路於旅行時間預測課題方面提出下列建議：

本文於研究時間內已整理事件延續時間表，唯因事件資料蒐集天數僅為一星期，待未來增加事件資料後，即可進一步編制出更具代表性的事件持續時間範例表，以期了解高速公路事件特性，並且掌握事件延續時間對於旅行時間預測之影響。事件延時範例表應用上可分成兩種方式：(1) 不更新概念，乃利用起點時刻為基準，下游各路段皆於此時刻尋找目前下游存在之事件個數與類型，並自事件延續時間範例表中尋找出該類型事件在該時段、該地點的平均延續時間，若旅行預測時間與平均延續時間相比較，發現當車輛到達下游路段起點時事件仍存在且延續，此時便可調整旅行時間估計值。(2) 持續更新概念，基本運作方式與不更新概念相同，唯將事件平均延續時間值更改為車輛行駛過程中持續獲得最新的交通即時資料，以最新的下游群組路段事件延續時間估計值為事件延續時間值，符合真實交通狀況，亦降低事件延續的影響誤差。

本研究的旅行時間預測概念是以第一個群組路段起點之起始時間為準，推估到達下游群組路段時間，因未來時間尚無交通資料，故建議可長期蒐集各項交通資料，如客運車輛GPS資料、車輛偵測器資料等，編制各資料來源的歷史資料範例表以為查詢之用。利用本群組路段之預測旅行時間估計值作為推估本車輛未來行駛至下游群組路段起點之時刻，並且將之作為下游路段搜尋相對應時刻之其他輸入變數資料的依據。

經過實證分析發現，群組路段的長度，影響旅行時間驗證績效，這是否意味群組長度影響旅行時間預測結果，值得未來後續研究深入了解。

參考文獻

1. 呂蕙美，「城際公路網動態交通量指派之研究」，成功大學交通管理科學系碩士論文，民國八十四年六月。
2. Carey, M. and McCartney, M., "Behaviour of a Whole-link Travel Time Model Used in Dynamic Traffic Assignment", *Transportation Research Part B*, Vol. 36, Issue 1, 2002, pp. 83-95.
3. Tong, C. O. and Wong, S. C., "A Predictive Dynamic Traffic Assignment Model in Congested Capacity-constrained Road Networks", *Transportation Research Part B*, Vol. 34, Issue 8, 2000 pp. 625-644.
4. Lee, Y. I. and Choi, C. Y., "Development of a Link Travel Time Prediction Algorithm for Urban Expressway", 5th ITS World Congress, 1998.
5. 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.
6. 張修榕，「高速公路旅行時間之研究」，中央大學土木工程研究所碩士論文，民國九十年。

六月。

7. 林士傑，「高速公路旅行時間預測模式之研究－類神經網路之應用」，成功大學交通管理科學系碩士論文，民國九十年六月。
8. 吳佳峰，「有 GPS 資訊提供下之車輛旅行時間預估模式之研究」，交通大學運輸工程與管理學系碩士論文，民國九十年六月。
9. 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**，民國八十五年十月。
10. Zurada, J. M., *Introduction to Artificial Neural Systems*, PWS publishing company, 1995.
11. www.transguide.dot.state.tx.us/index.php
12. 魏健宏、林士傑，「高速公路客運車輛旅行時間預測」，**土木水利工程學刊**（審查中），民國九十一年。
13. www.jartic.or.jp/traffic/roadtrafficinfo.html
14. Lewis, C. D., *Industrial and Business Forecasting Method*, Butterworth Scientific, 1982, pp. 38-41.

