國　立　交　通　大　學
運　輸　與　物　流　管　理　學　系

博士論文

具非重現性擁擠特性之高速公路旅行時間預測

Forecasting the Travel Time of Freeway with Non-recurrent Congestion

研 究 生：李 季 森

指導教授：陳 穆 臻

中　華　民　國　一　〇　四　年　一　月

具非重現性擁擠特性之高速公路旅行時間預測

Forecasting the Travel Time of Freeway with Non-recurrent Congestion

研 究 生：李季森　　Student：Chi-Sen Li

指導教授：陳穆臻 博士　　Advisor：Dr. Mu-Chen Chen

國 立 交 通 大 學

運輸與物流管理學系

博 士 論 文

A Dissertation

Submitted to Department of Transportation and Logistics Management

College of Management

National Chiao Tung University

in Partial Fulfillment of the Requirements

for the Degree of Doctor of Philosophy

in

Traffic and Transportation

June 2015

Taipei, Taiwan, Republic of China

中華民國一〇四年一月

摘要

旅行時間資訊之提供一直為促使智慧型運輸系統(Intelligent Transportation System, ITS)更為成功之重要因素。以往研究更指出非重現性擁擠(non-recurrent congestion)為造成高速公路延滯之主因。因此，如何提高含非重現性擁擠下之旅行時間預測能力，為旅行時間預測領域之重要且必須克服議題。本研究透過類神經 (Artificial Neural Network, ANN)建構台灣中山高速公路 36.1 公里長路段(包含 8 個交流道)之旅行時間預測模型，並且為提高模式於含非重現性擁擠之預測能力，本研究除蒐集雨量與時間特徵等資料外，更包含車輛偵測器(Vehicle Detector, VD)所蒐集到之平均線點速度(average spot speed)與大型車流量等資料，並且進一步整合電子收費系統(Electronic Toll Collection, ETC)原始資料所推得之歷史旅行時間(Historical Travel Time, HTT)，並以 ETC 所推得之真實旅行時間(Actual Travel Time, ATT)做為訓練目標(target)，以建立一穩健型之預測模式。

本研究整合分群(*K*-means)、分類迴歸樹(Classification and Regression Tree, CART)與類神經網路(Artificial Neural Network, ANN)等三種資料探勘技術，透過創造虛擬變數(dummy variable)與萃取關鍵變數(critical variables extraction)方式，不僅可於不增加設備投資情況下提高預測能力，亦同時獲得關鍵地點之關鍵變數資訊，以有效協助管理單位進行系統維護。本研究所發展之混合專家概念為基之預測方法(Mixture of Experts Based Method, MEBM)與整合分群分類為基之預測方法(Integrated Clustering-Classification Method, ICCM)，不論是否採用 ETC 系統所產生之資料，相較於直接預測而言，皆能提高模式預測能力，且同時降低 MAPE 值大於 20%之樣本百分比。再者，本研究以決策樹成功萃取出三個關鍵變數，分別為星期(day of week)，時間(Time)，51.6 公里車輛偵測器(VD)所蒐集之現點速度(即 speed5160)。最後，本研究構建之類神經為基之預測方法(Neural Network Based Method, NNBM)、混合專家概念為基之預測方法(Mixture of Experts Based Method, MEBM)、整合分群分類為基之預測方法(Integrated Clustering-Classification Method, ICCM)等三個預測架構，其 MAPE 值介於 6%~9%之間，皆屬於 Highly accurate prediction 之模式。

關鍵詞：旅行時間預測、高速公路、非重現性壅擠、資料探勘、分群、決策樹、類神經網路

Abstract

The provision of travel time information has been a major factor facilitating the Intelligent Transportation System (ITS) to become more successful. Previous studies have pointed out that non-recurrent congestion is the major cause of freeway delay. Hence, how to improve the prediction capability of travel time in the case of non-recurrent congestion is an important issue that must be overcome in the field of travel time prediction. This study constructs the travel time prediction model for a segment of 36.1 KMs (including eight interchanges) in the National Freeway No. 1, Taiwan by using the Multilayer Perceptron (MLP). To improve the prediction capability of the model in the case of non-recurrent congestion, this study collects data of average spot speed and heavy vehicle volume gathered by vehicle detectors (VDs), and rainfall and temporal features. Furthermore, the historical travel time inferred from the original data of Electronic Toll Collection (ETC) system is also used as the input variable, and the actual travel time inferred from ETC is used as the training target to establish a robust prediction model.

This study integrates three data mining techniques, *K*-means clustering, classification and regression tree, and neural networks, to predict the travel time of freeway with non-recurrent congestion. By creating dummy variables and identifying important variables, not only increase the prediction performance without additional investment, but also important variables are obtained concerning the important locations of equipment in order to effectively assist public transit agencies with system maintenance. The experimental results show that, whether or not the data generated by the Electronic Toll Collection (ETC) system is used as input variables, the travel time prediction method, Mixture of Experts Based Method (MEBM), Integrated Clustering-Classification Method (ICCM), developed in this study is able to improve the prediction performance. Meanwhile, the proposed approach also reduces the percentage of samples with Mean Absolute Percentage Error (MAPE) > 20%. Furthermore, in this study, important variables are extracted from the decision tree in order to predict the travel time. Finally, the prediction models constructed in Neural Network Based Method (NNBM), Mixture of Experts Based Method (MEBM), Integrated Clustering-Classification Method (ICCM), are highly accurate due to the low MAPE values, which are from 6% to 9%.

Keywords: Travel time prediction; Freeway; Non-recurrent Congestion; Data Mining; Clustering; Decision Tree; Neural networks

誌 謝

想要對這塊土地人事物有所貢獻，必須具備一定能力才能逐步踏實。當初這點初心踏入繼續專研的未知。回首過往有太多波折難以道盡。然而這段旅程實在有太多貴人相助，才能讓我達到階段性終點並繼續邁向下一個美好。

能遇見我的指導教授陳穆臻老師是最值得慶幸的事。所謂師者傳道、授業、解惑也。這幾年來在陳教授身上學到的不只是專業知識，更包含許多理念的堅持。感謝陳穆臻老師對我觀念的啟迪以及生活點滴的關心。當我面對各種疑惑時，老師總是願意撥空給予客觀的建議與協助，我想我是幸運的。此外，求學過程中不論是在大學時期接觸到的啟蒙老師林良泰教授或是碩士班時期的顏上堯教授，乃至目前有幸跟著陳穆臻教授學習。經由他們的指導進而逐漸累積了面對挑戰的豐富資糧。教育，真的是需要願意無私奉獻的人投入，才能有機會讓苗圃成長茁壯。

口試期間特別感謝顏上堯教授、馮正民教授、丁慶榮教授、邱裕鈞教授與盧宗成教授的逐字輔正。正因為各位老師的細心指正才能使這份研究更為完備。求學期間更感謝交研所所有教授的細心指導與授課，讓學生有機會奠定良好的研究基礎。博士班論文研討期間承蒙邱裕鈞教授與盧宗成教授細心指導。感謝邱裕鈞教授時常針對研究內容提出重要建議，促使論文的順利完成。

博士班期間感謝沛儒、嘉陽、士軒、彥蘅、彥斐、文斌、傅強、牧民、喬文、裕文、志偉等博士班學長姊、同學與學弟的生活點滴與討論。此外更感謝吳淵展博士、湯慶輝老師、陳俊穎老師與施佑林博士等學長與學弟的鼓勵。口試期間承蒙志偉與裕文特地撥空協助，真是非常感謝。碩士班學弟妹偉丞、璽源、佳縈、文嘉、昶律等，感謝你們平時的幫忙與執行計畫的協助。另外，我得特別感謝從小到大的好兄弟欣記。謝謝你不斷的提醒與關心，相信我們定能邁向美好的未來，並且達成我們預定的目標。這一路上眾多相互支持的好朋友們，請原諒我無法在這一一唱名，然而我感激的心永遠存在。

最後，我最重要的家人，謝謝你們的支持。最辛苦的莫過於老婆惠美，感謝妳的支持與包容。相信齊恩與柏澄在成長過程中，有了我們的支持，除了平安健康長大外，亦能在幫助他人的路上持續圓滿自己。

李季森 2015/01

目 錄

第一章 緒論 1
1.1 研究背景 1
1.2 研究動機 3
1.3 研究目的 5
1.4 研究範圍 7
1.5 研究流程 8
1.6 論文組織 9
第二章 文獻回顧 11
2.1 資料探勘 11
2.1.1 資料探勘簡介 11
2.1.2 分群技術 13
2.1.3 分類技術 14
2.1.4 類神經網路 16
2.1.5 重要變數選擇 23
2.2 旅行時間預測 24
2.2.1 線性迴歸 26
2.2.2 ARIMA 27
2.2.3 卡門濾波 27
2.2.4 MLP 28
2.3 小結 29
第三章 旅行時間預測方法發展 35
3.1 旅行時間預測方法架構 35
3.2 方法一 37
3.3 方法二 39
3.4 方法三 45
第四章 資料分析 55
4.1 資料前處理 55
4.1.1 資料蒐集 55
4.1.2 雨量資料 56
4.1.3 VD 穩定度 56
4.1.4 遺漏值填補 57
4.2 交通特性分析 62
4.2.1 事件資料分析 62
4.2.2 非重現性特性分析 63
第五章 實證結果與分析 71

5.1 NNBM 結果與分析 71
5.1.1 實驗設計 71
5.1.2 實驗結果 74
5.2 MEBM 結果與分析 83
5.2.1 實驗設計 83
5.2.2 實驗結果 84
5.3 ICCM 結果與分析 86
5.3.1 實驗設計 86
5.3.2 實驗結果 88
5.4 比較分析與討論 92
第六章 結論與建議 94
6.1 結論 94
6.2 未來研究方向與建議 96
參考文獻 98

圖目錄

圖 1 研究範圍 8
圖 2 研究流程 9
圖 3 人工神經元模型 17
圖 4 監督式和非監督式學習網路 19
圖 5 前饋式神經網路 20
圖 6 反饋式神經網路 21
圖 7 旅行時間預測方法架構 36
圖 8 倒傳遞神經網路架構 38
圖 9 NNBM 旅行時間預測流程 39
圖 10 MEBM 旅行時間預測流程 41
圖 11 ICCM 旅行時間預測流程 46
圖 12 創造虛擬變數之流程 51
圖 13 關鍵變數萃取與旅行時間預測模式構建之過程 53
圖 14 研究範圍示意圖 56
圖 15 各區段 VD 之蒐集與採用數量 57
圖 16 遺漏值填補流程 61
圖 17 事故資料統計 63
圖 18 所有天數之旅行時間 65
圖 19 星期 1 之旅行時間 65
圖 20 星期 2 之旅行時間 66
圖 21 星期 3 之旅行時間 66
圖 22 星期 4 之旅行時間 67
圖 23 星期 5 之旅行時間 67
圖 24 星期 6 之旅行時間 68
圖 25 星期日之旅行時間 68
圖 26 9 月 22 日(二)旅行時間、肇事與雨量綜合圖 69
圖 27 9 月 29 日(二)旅行時間、肇事與雨量綜合圖 69
圖 28 10 月 6 日(二)旅行時間、肇事與雨量綜合圖 70
圖 29 10 月 13 日(二)旅行時間、肇事與雨量綜合圖 70
圖 30 Scenario 5 之決策樹 87
圖 31 Scenario 6 之決策樹 88

表目錄

表 1 資料探勘功能與相關技術 12
表 2 相關資料探勘技術適合之任務 12
表 3 各種決策術演算法特性說明 16
表 4 神經元轉換函數 18
表 5 類神經網路特性 22
表 6 類神經網路應用範圍 22
表 7 旅行時間預測相關文獻研究內容 31
表 7(續) 旅行時間預測相關文獻研究內容 32
表 8 旅行時間預測相關文獻研究績效 33
表 8(續) 旅行時間預測相關文獻研究績效 34
表 9 研究範圍內各路段事故次數、受傷人數與碰撞車輛統計 62
表 10 NNBM 輸入變數 73
表 11 NNBM 參數設定 74
表 12 兩量變數於 24 種實驗組合之平均績效值 75
表 13 兩量變數各組合於 RMSE 之 t 檢定 76
表 14 兩量變數各組合於 MAPE 之 t 檢定 76
表 15 兩量變數 MAPE>20%樣本數之 t 檢定 77
表 16 兩量變數 MAPE>50%樣本數之 t 檢定 77
表 17 VD 變數於 56 種實驗組合之平均績效值 79
表 18 VD 變數各項績效指標之 t 檢定 79
表 19 星期變數於 84 種實驗組合之平均績效值 80
表 20 星期變數各項績效指標之 t 檢定 81
表 21 ETC 變數於 84 種實驗組合之平均績效值 82
表 22 ETC 變數各項績效指標之 t 檢定 82
表 23 時間變數於 84 種實驗組合之平均績效值 83
表 24 時間變數各項績效指標之 t 檢定 83
表 25 MEBM 實驗情境設計 84
表 26 MEBM 實驗結果彙整 85
表 27 第一種混合專家類型各群預測能力 86
表 28 ICCM 實驗情境設計 88
表 29 Scenario 3 於 CART 分類模式之判中率 89
表 30 Scenario 4 於 CART 分類模式之判中率 90
表 31 ICCM 實驗結果彙整 91
表 32 3 種預測架構績效值 93

第一章 緒論

1.1 研究背景

旅行時間資訊之提供為促進先進交通管理系統(Advanced Traffic Management System, ATMS)與先進旅行者資訊系統(Advance Traveler Information System, ATIS)等系統更為成功之重要因素之一(Lam *et al.*, 2005)。再者，ATMS 與 ATIS 等系統之建置，不僅可以提升現有運輸系統之效能，亦可讓有限的資源使用更有效率，並減少污染排放量，以減緩地球暖化的速度，因此旅行時間預測一直為備受重視之研究領域。高速公路旅行時間預測範圍越長，其所包含之交流道數量越多，致使車流特性變化越複雜，進而增加預測之困難度。此為旅行時間預測研究中，重要且必須克服之議題。再者發展一連續型之旅行時間預測模式，則會面臨因事件發生所造成非重現性擁擠(non-recurrent congestion)之交通狀況。

依據 Oak Ridge National Laboratory(Chin *et al.*, 2004)之研究指出，駕駛人於美國高速公路上所面臨的延滯，有 55%是非重現性事件(non-recurrent events)所造成的，其中高速公路事故(accidents)佔 72% (Skabardonis *et al.*, 2003)。因此提高事故之預測能力(Chang, 2005; Santosh *et al.*, 2009)，尋找影響事故之關鍵變數(Gevrey *et al.*, 2003)與預估衝擊程度(Chung, 2001; Wei *et al.*, 2007; Hall, 2002)等，皆為研究單位與管理單位所重視之議題。然而依照現有通報機制，無法第一時間獲得事件發生時間、影響車道數與排除時間等。因此，當事件發生時，高速公路旅行時間資訊顯示看板並未顯示旅行時間預測資訊。有鑑於旅行時間資訊對於用路人與促進智慧型運輸系統之成功有其重要性。因此如何在現有通報機制限制下，採用現有資訊蒐集設備所蒐集之資料，發展適用於事件發生與非事件發生下之情境，進而擴大旅行時間預測資訊之適用時機，為學術界與管理單位所重視且尚待克服之議題。

以往針對影響車流特性之顯著變數已有若干研究。Chang(2005)的研究指出，影響車流特性之因素主要可區分為幾何變數(geometric variables)、交通變數(traffic

characteristics)、環境變數(environmental factors)等三大類別。另外 Wei *et al.* (2007)則採用交通變數(Traffic data)、時間變數(Time)、空間變數(Space)、幾何變數(Geometric)等屬性探討不同車流特性對肇事持續時間之影響，並獲得良好研究成果。然而基於變數之不同編碼與組合方式對車流特性之解釋能力有不同程度之影響。例如：星期之編碼方式採用 1~7 進行編碼較好？亦或是將星期六~日與星期二~四視為有相同車流特性並以此進行編碼較好？另外，雨量為影響車流特性之重要變數，然而對累積雨量之回朔是否越遠越好 (1 小時、2 小時或 3 小時等)？ ETC 即時資訊、速度、大型車流量等變數是否真的有助於提升旅行時間預測能力？為解決上述問題並發展一穩健與高預測能力之旅行時間預測模式。本研究針對變數之編碼與組合方式進行分析，使影響車流特性之變數分析更為完整且能充分解釋國內車流行為。

由於車流特性之變異程度與研究範圍成正比，且 van Lint *et al.* (2005) 在研究中指出，當擁擠發生時，其旅行時間將產生更大的變異。基於上述原因，致使旅行時間預測模式於車流特性變異較大之地區，更難維持良好預測能力。相反的，當研究範圍內之車流特性變異不大時，便能更為有效的建立準確的預測模式。有鑒於此，資料探勘之分群方法即為一有效分析方法。由於分群分析係追求組內變異最小與組間變異最大化，因此，若能針對關鍵變數之最佳編碼與組合方式，求取最適之分群結果，並透過混合專家(Mixture of Experts, ME) (Hu *et al.*, 1997) 概念建立各群之預測模式，則能解決資料變異過大的問題，並提高模式預測能力。然而在提高模式預測能力之同時，亦應考量實務操作之適用性，避免變數過多而降低模式之可用度。

國內現有高速公路系統除已建立大量蒐集交通資料之路側設備，近年來為提供更快更準確之資料，亦編列預算逐年翻修且增設新設備。雖然，以自動化設備蒐集資料具有長時間蒐集、大範圍調查與誤差較小且具一致性等優點，然而由於例行檢修、施工、電纜失竊、天候及許多不可抗力等因素，易造成系統故障與穩定度不佳等情形發生。因此，相關單位於維持設備可用率上，往往付出相當大之人力與物力。由此可知，一個良好、穩定與可靠之旅行時間預測模式，應能以最精簡變數提供符合管理者、使用者與經營者等三方面皆可接受之預測能力，此不僅可降低硬體設備建置費用，亦能提高模式之可用

性。

1.2 研究動機

不可否認的，預測旅行時間對智慧型運輸系統(Intelligent Transportation System , ITS)而言有其重要性與必要性。以往研究(Chen *et al.*, 2003; Stathopoulos and Karlaftis, 2003; Dion and Rakha, 2006; Li and Rose, 2011)主要專研於如何在現有設備下提升預測能力。近幾年相關研究已經成功運用類神經模型(Artificial Neural Network, ANN)於交通領域，並且藉由 ANN 複雜學習能力獲得較佳之研究成果(Mazloumi et al., 2011)。另外僅有少部分研究預測非重現性下之旅行時間。雖然相關研究針對短時間旅行時間預測已有豐碩成果，然而就旅行時間預測之議題而言，主要包含 4 個議題須克服。

1.在現有設備下提升預測能力。

2.發展準確之遺漏值填補方式，並且找出重要偵測器與關鍵變數。

3.發展同時適用非重現性擁擠之高預測能力模式。

4.自動辨別交通特性並且發展高準確度之預測模式。

以往研究(Chen *et al.*, 2003; Stathopoulos and Karlaftis, 2003; Dion and Rakha, 2006; Li and Rose, 2011)主要專注於第一個議題，並且有少數研究針對第三個議題進行研究。然而就管理單位而言，如何在改善模式預測能力之同時降低設備維護成本與操作成本為一不可避免之取捨問題。本研究主要發展一個系統性架構去整合多種資料探勘方法解決上述 4 項議題。針對第 1 個議題，無庸置疑的，尋找重要變數作為預測模式之輸入變數將有助於提升模式預測能力。以往旅行時間相關研究(Chen and Chien, 2001; Chen *et al.*, 2003; Stathopoulos and Karlaftis, 2003; Dion and Rakha, 2006; Li and Rose, 2011)主要透過模式推估、系統模擬、參數較估或者是非線性模型等方式產生交通資料並且藉此提升對車流特性之解釋力。因此，解析 t 時刻之交通特性將有助於改善模式之預測精準度。此外，蒐集更多完整交通資料將更有效解析交通特性。例如，當高速公路每 1 公里埋設一個車輛偵測器下，其對車流特性之解析能力一定高於每 10 公里埋設一個車輛偵測器。然而，硬體投入之成本除了初期建置成本之外，更要花費巨額維運成本且增加維運困難

度。因此長期以來增加設備與提升車流解釋能力之間一直是一個難以權衡且有待解決的問題。本研究針對此問題提出解決方案，在避免增加設備下同時提升對車流特性之解析能力，在此同時一併提升模式之預測能力。為達成上述目標，本研究蒐集現況資料並透過各種實驗組合建立 ANN 預測模式，並且透過統計方法了解各項重要變數對預測模式之實質影響力，進而探掘重要變數組合與編碼方式。

針對第 2 個議題，相較於用人力長時間調查交通資訊而言，無庸置疑的，透過設備進行交通資料蒐集不僅可廣泛蒐集資料且長期而言成本較低。再者，相較於人力蒐集而言，透過設備進行資料蒐集其誤差值較易控制，然而卻無法避免發生遺漏值之狀況。因此，相關研究 (Zhong *et al.*, 2004; Raj and Stern, 2005; Cerisara *et al.*, 2007; Demange *et al.*, 2009; Lederman and Wynter, 2011)針對遺漏值提出有效填補方式以還原實際之交通特性。然而，就高速公路旅行時間預測之議題而言，顯少研究針對探掘關鍵變數與重要偵測器等進行研究。例如，若能探掘出 A 偵測器所測得之每 5 分鐘累計雨量，B 偵測器所蒐集之每 5 分鐘現點速率，C 偵測器所蒐集之每 5 分鐘大型車流量等 3 個偵測器所個別測得之變數為某研究路段內解析車流特性之關鍵變數，則對管理單位而言，不僅可清楚獲得維運目標，且可針對上述偵測器之關鍵變數發展遺漏值填補方式。由此可知，透過此議題之研究不僅可減少資料蒐集設備投入費用，降低維運成本，同時可提升預測模式之適用範圍。因此，此研究成果對管理單位具有重要性之影響。為解決此議題，本研究提出整合性架構並且採用決策樹方法探掘關鍵變數與重要偵測器，更以此建立旅行時間預測模式。經由模式預測能力分析關鍵變數對模式預測能力之影響。

針對第 3 個議題。為建立一個同時適用於非重現性擁擠(non-recurrent congestion)下之高速公路旅行時間預測模式。本研究提出系統性之架構，整合 *K*-means、CART 與 ANN 方法，並測試不同隱藏層單元數(number of hidden nodes)尋找最佳 ANN 架構，以此建構具有準確預測能力之模式。再者，為獲得預測模式之實際應用績效，本研究將所有樣本(含事件發生下之樣本)區分為訓練組(training data set)與驗測組(test data set)資料，藉此模擬實際應用情形。

針對第 4 個議題。若針對不同交通特性建立不同預測程序並發展各自預測模式，不

僅增加實際應用下之複雜度，且亦增加維運人力與需培養不同技術人員。此外，目前尚無有效方法可明確區別不同交通特性之起始與結束時間。例如，當某長路段於不同地點有多起交通事故發生時，難以精確獲得實際發生時間與事故影響時間。然而，發展單一模式且同時適用於不同交通狀態之預測模式則有其困難度。本研究提出整合架構採用混合專家(mixture of experts)概念與虛擬變數等方法，在同一個預測程序下可辨析不同車流特性且針對各車流特性發展預測模式，以此達成自動辨別交通特性並且發展高準確度之預測模式之目標。

綜合以上所述，本研究為解決上述 4 個議題，並提供一符合用路人與管理者需求之準確旅行時間預測結果。係以中山高速公路最繁忙之路段作為研究對象，針對長距離且含非重現性擁擠下車流特性建立旅行時間預測模式。本研究採用資料探勘技術，以 ANN 之倒傳遞類神經(Back-Propagation Neural Network, BPN)、*K*-mean、CART 等方法，並納入混合專家(Hu *et al.*, 1997)之概念，針對最佳變數編碼與組合進行分析，以此有效掌握車流變異之特性，並以最精簡之維度，提供一準確且穩健之連續型預測模式。

1.3 研究目的

目前學者針對高速公路旅行時間預測議題皆有深入研究。但較少針對長距離且含非重現性擁擠下之車流狀況進行探討。此乃因車流特性之變異不易掌握，進而降低模式預測能力。因此，如何尋找關鍵影響變數以確實掌握車流特性，即為高速公路旅行時間預測領域中重要的議題。面對長距離且考量非重現性擁擠影響下之車流環境，必須進一步分析關鍵變數之編碼與組合方式，才能探索出各種變數組合與不同編碼方式對旅行時間預測能力之影響程度。透過此必要且繁瑣的探索過程後，以此研究基礎為出發點，即可藉由資料探勘的分群方法有效降低車流特性變異過大的問題，並且基於實務上之考量，在確保預測能力於管理者與使用者能接受之前提下，進一步縮減預測模式之輸入變數。有鑒於此，如何提升在長距離下且含非重現性擁擠之旅行時間預測能力即具有研究之必要性。

基於前述之研究背景及動機，本研究之研究目的分述如下：

1.應用資料探勘之 ANN 進行高速公路旅行時間預測，探索符合國內複雜流特性之最佳變數組合與編碼方式。

2.藉由資料探勘中的分群方法，挖掘符合國內車流變異之最適分群方式。另以混合專家概念發展預測模式，以提昇高速公路旅行時間預測能力。

3.透過資料探勘之決策樹方法，達到縮減輸入變數之目的，並結合分群之結果新增重要變數，藉此交通資料收集設備投入與維護經費並確保模式預測能力之目標。

4.針對各種模式之預測結果，分析輸入變數特性與模式之適用性，以提供符合長距離下含非重現性擁擠之最適預測模式。

5.依實際收集之資料進行模式測試，以此構建一穩健之預測模式，並供實務界參考使用。

本研究透過資料探勘技術中之類神經網路、分群、分類與混合專家概念等方法，建構國內高速公路長距離旅行時間預測模式，以協助國內高速公路管理者解析國內車流特性之重要變數屬性為何，並選擇適當之預測模式達到下述成效：

1.探索有效變數組合與編碼，以提升對車流特性之辨析能力

目前旅行時間預測之相關研究，已針對重要變數進行探討，例如：速度、雨量、大型車流量與星期屬性等皆為反映車流特性之重要變數。就理論上而言，納入具有解析力之變數越多，對提升模式之預測力有正向之幫助，然而卻未必具有必然的關係。以大型車流量而言，由於現有高速公路大型車之速限、行駛車道限制、爬坡與轉彎能力等因素，致使其駕駛特性皆與小汽車不同，因此無庸置疑的，大型車數量為干擾車流運行之重要因素。然而現有資料收集設備皆無法完全克服車型誤判之情形。若在交通變異較大之情況下，此誤差是否會影響車流特性之解析值得探討。再者，國內高速公路全面建置電子收費系統(Electronic Toll Collection, ETC)至今，近年來亦能提供即時旅行時間資訊。此一資訊雖非為真實旅行時間，然而卻能反映歷史車流之特性。相同的，納入此變數是否有助提升旅行時間預測模式之預測能力，亦值得探究。此外累計雨量的往回追朔期需多長(1 小時、2 小時或 3 小時)？平均速度對旅行時間預測模式之影響程度為何？星期屬性以何種

編碼方式才能有較佳解析能力等問題，將於本計畫研究成果中呈現。

2.確實掌握車流變異，提升模式適用層面

當道路發生非重現性擁擠時，其對車流造成之變異與重現性擁擠下之特性有所不同，也較難以掌握。然而建構高速公路連續型旅行時間預測模式，勢必面臨非重現性擁擠發生下所產生之車流變異情形。若能針對各個時間間隔所反映之車流特性予以分門別類，以提高群內車流特性之同質性，則能達到掌握車流變異之目的。再者為提高模式預測能力，本計畫藉由混合專家概念，依據同質性之各群建置預測模式，以達到提高模式預測能力之目的，並進而提升模式適用層面。

3.有效縮減輸入變數，降低設備維護壓力

一個穩健之預測模式，除具備準確預測能力以符合管理者與使用者需求外，更尤甚者，應進一步減少模式輸入變數，才能使模式於使用上具有較高之落實度。此乃因為就設備維護而言，再完整的設計與維護流程，亦無法避免不可抗力因素所造成之故障與維修等問題。有鑒於此，本研究針對探索出之關鍵變數組合與編碼方式，利用 CART 模式，依據其分類規則選取重要變數，以達縮減輸入變數之目的。

1.4 研究範圍

本研究係針對台灣地區國道 1 號楊梅收費站與泰山收費站間北上方向，蒐集 2009 年 9 月 16 日至 10 月 16 日間，每五分鐘之相關資料。本研究路段範圍為單向三車道之高速公路，另外由圖 1 可知，本研究路段範圍內共包含 8 個交流道(含 2 個系統交流道，分別為平鎮與機場系統交流道)，研究路段範圍長達 36.1 公里(佔國道 1 號高速公路全長的 9.7%)。依照台灣區國道高速公路局(Taiwan Area National Freeway Bureau, MOTC) 2009 年 9 月與 10 月之統計資料顯示，本研究路段範圍內之每日平均交通量為 336,895 車次(楊梅收費站 111,938 車次/每日與泰山收費站 224,957 車次/每日)，約佔整體國道 1 號高速公路平均每日交通量之 23.5%。由上述可知，本研究路段範圍為台灣國道 1 號高速公路中車流量最大且車流特性較為複雜之路段。

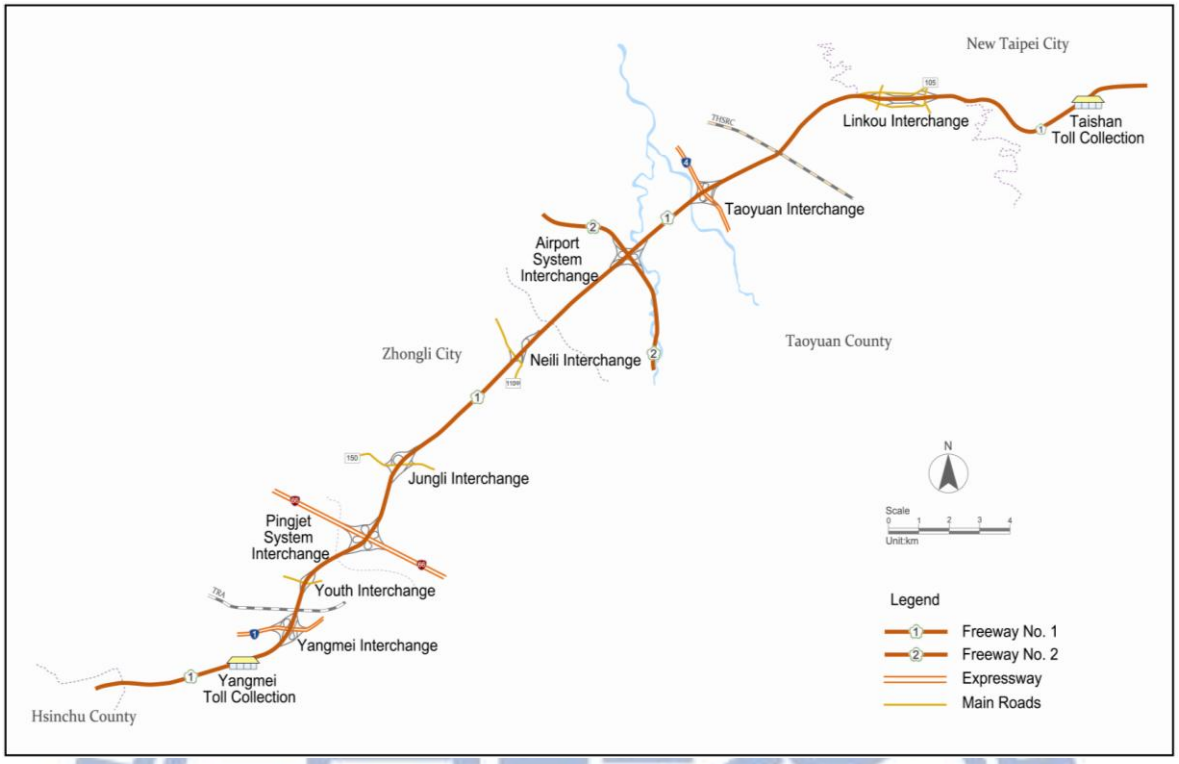

圖 1 研究範圍

1.5 研究流程

本計畫之研究流程如圖 2 所示。首先確立研究範圍與目的，並據此進行文獻蒐集與評析。透過文獻評析結果了解以往針對旅行時間預測議題之研究成果與有待解決之處。經由上述兩步驟確立研究範圍與內容後，後續針對資料進行蒐集與分析。包含資料穩定度判斷、遺漏值填補、旅行時間計算與旅行時間特性分析等。本研究將資料蒐集結果作為預測模式之輸入變數。本研究共發展 3 種旅行時間預測方法，分別為類神經為基之預測方法(Neural Network Based Method, NNBM)、混合專家概念為基之預測方法(Mixture of Experts Based Method, MEBM)、整合分群分類為基之預測方法(Integrated Clustering-Classification Method, ICCM)等 3 個預測架構。在建立預測架構後即針對個別架構之實證結果進行說明與分析。最後，將研究成果進行最後結論與建議。

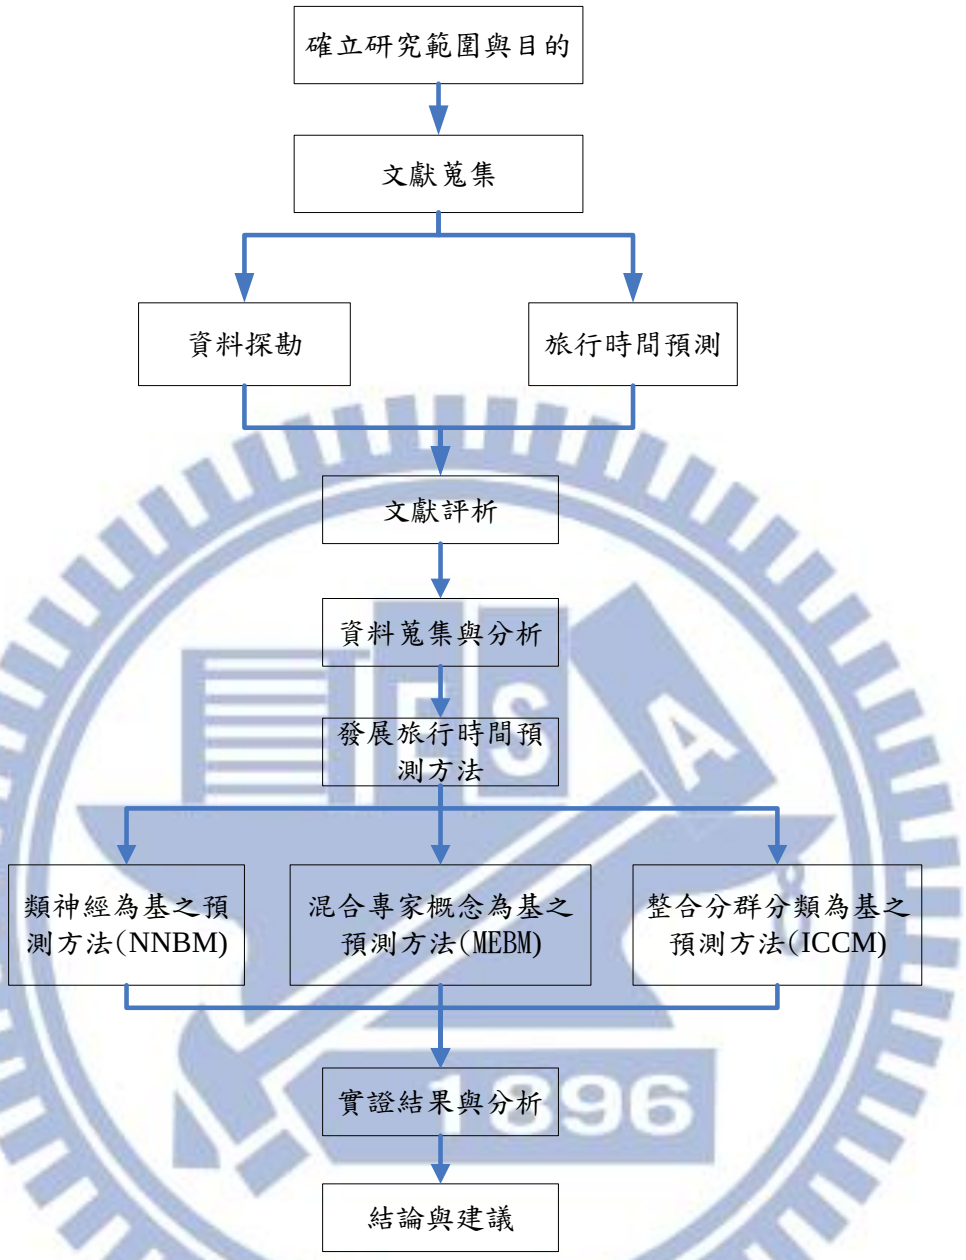

圖 2 研究流程

1.6 論文組織

有關本研究之研究背景與動機說明於第一章，且於第一章同時說明了本研究之目的、研究範圍與整體研究架構。透過確定研究範圍與架構後隨即進行變數選取、旅行時間預測等文獻回顧並且說明於第二章。經由本章節進一步確定本研究所採用方法之適切性。另外於第三章分別針對本研究之研究方法進行說明，並涵蓋類神經為基之預測方法(即

NNBM)、混合專家概念為基之預測方法(即 MEBM)、整合分群分類為基之測方法(即ICCM)等三個預測架構。本章節說明各預測架構之進行步驟與相關方法。經確立方法與預測架構後，則進一步針對資料前處理之內容與研究範圍內之交通特性說明於第四章。本研究經由資料前處理後，則進入旅行時間預測之程序。經由系統性程序所建構之預測模式，綜整其預測結果說明於第五章。最後，第六章總結本研究之結論與建議。

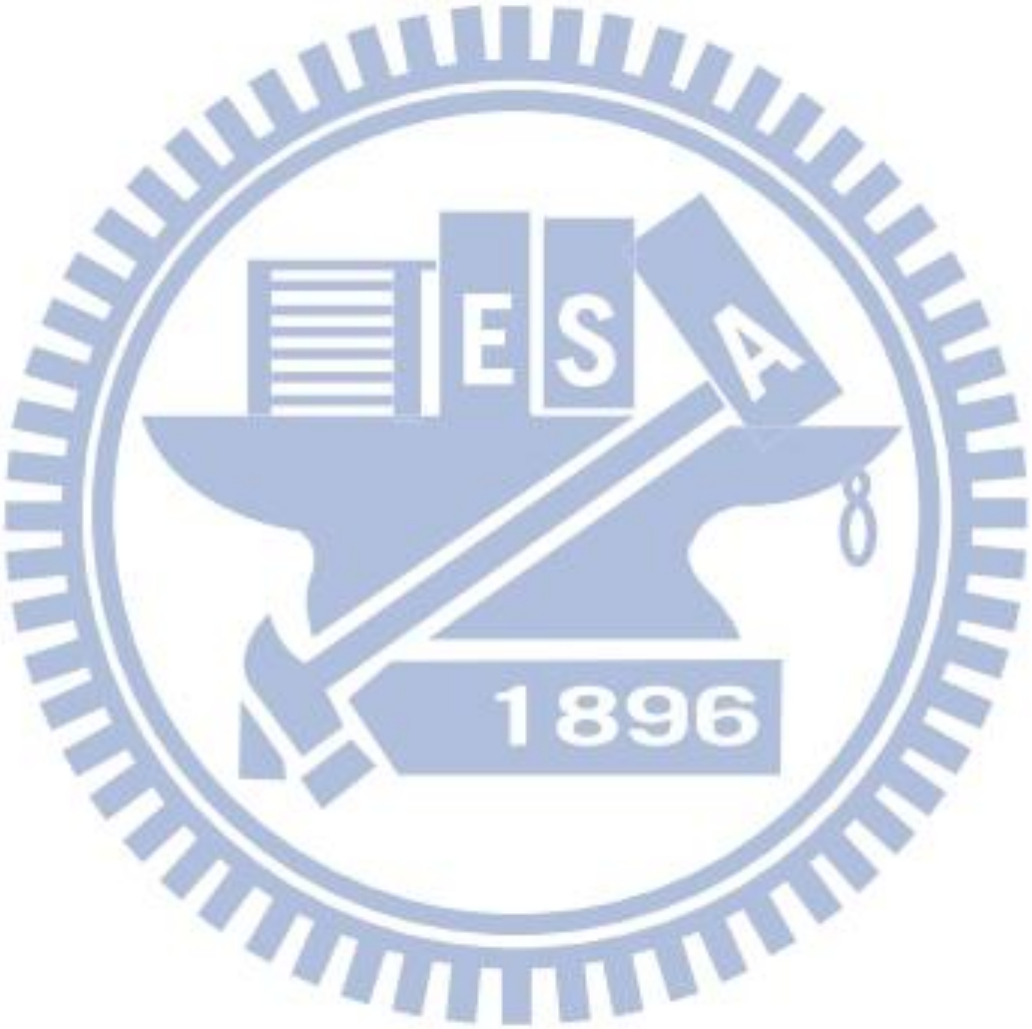

第二章 文獻回顧

由於國內外於高速公路旅行時間預測之研究上，顯少針對分群(Clustering)結合混合式專家(Mixture of Experts)概念及輸入變數縮減等議題進行探討。因此以下主要針對資料探勘技術與旅行時間預測方法相關文獻進行說明。

2.1 資料探勘

2.1.1 資料探勘簡介

在處理海量資料之過程中，為迅速處理大量資料，探掘資料背後之未知資訊並且避免了統計方法上針對屬性間之嚴格定義，因此資料探勘技術逐漸被重視。資料探勘技術係以統計學與電腦科學為基礎，在大型資料庫中挖掘資訊並形成規則，此過程又稱為知識挖掘(Peacock, 1998)。資料探勘技術乃透過自動或半自動方式於海量資料中探勘具有價值之知識。其所建構出之理論架構係屬於探索導向，經由實證資料推導而來，非屬於理論建構與假設導向(Berry and Linoff, 1997)。Berry and Linoff (1997)之研究指出，資料探勘具備分類、群集化、預測、推估、關聯分組(購物籃分析)與描述等 6 種功能，茲將各項功能之內涵與適用技術彙整如表 1 所示。再者，各項技術適用之任務如表 2 所示。本研究係採用資料探勘中群集化、分類與預測等功能，經由系統性分析架構進行高速公路旅行時間預測。

表 1 資料探勘功能與相關技術

功能	內涵	相關技術
分類	依照各樣本之屬性，經由模式學習建立分類準則。透過該模式可針對新樣本進行分類。	決策樹、基因演算法
群集化	群集化事先並沒有明確定義之類別，透過模式將同質性較高之樣本劃分為同一群體。個群體所代表之意義需透過事後針對各群特性加以分析得知。	*K*-means PAM
預測	所謂預測係透過即時或是過去之觀察值推估未來值。	類神經、迴歸分析、時間序列、基因演算法
推估	推估係用於處理連續性之數值，此較分類不同。透過現有屬性可進一步推估未知的連續變數。	類神經、迴歸分析、相關分析
關聯分組(購物籃分析)	用以了解何種事件同事發生，又稱為購物籃分析。以商場消費行為而言，即可藉由關聯法則了解消費者購物行為進而決定展售方式。	關聯法則
描述	在複雜資料庫中透過簡單描述說明其內容與關係。	-

資料來源：Berry and Linoff (1997)

表 2 相關資料探勘技術適合之任務

技術	分類	集群化	預測	推估	關聯分組(購物籃分析)	描述
統計方法	*	*	*	*	*	*
類神經網路	*	*	*	*		
決策樹	*	*	*			*
集群分析		*				
連結分析	*		*		*	
購物籃分析		*	*		*	*
基因演算法	*		*			

資料來源：Berry and Linoff (1997)

2.1.2 分群技術

所謂分群是針對資料屬性，透過一定原則將相似性之樣本集群化，以群內差異最小，群間差異最大為分群目標。因此分群之主要目的，即將未知資料依照其相似度類成不同群體，此技術亦可用於預測樣本特性(Chacko, 1998)。再者，分群技術係屬於資料挖掘技術一種，包含可採用非監督式方法呈現真實數據分布情形(Zhang *et al.*, 2007)。Wedel and Kamakura (2000)研究指出，非重疊法(nonoverlapping methods)是最早的分群方法，在此方法中每個樣本只被允許屬於某個群體。此方法又可區分為分層法(hierarchical)與非分層法(nonhierarchical)兩種。透過分層法進行分群時，當樣本已被分為特定群體時就不再改變。另外非分層法則有別與此限制，在分群過程中可將原有分群打散而形成新的群體。*K*-means 為非分層法中最常被使用之方法。以下針對分層法、非分層法與兩階段方法進行說明如後。

1.分層法

分層法總共包含兩種方式，分別是凝聚法與分離法。凝聚分層法一開始將每個樣本視為單獨群體，並依據"距離"最近者結合成同一個群體。重覆此步驟減少群體數。兩個樣本一旦被劃分為同一個群體，則往後步驟就不再更動。一般而言，可透過加權平均連結法、單一連結法(最近法)、完全連結法(最遠法)、未加權中心距離法(中心法)及華德法(最小變異法)等計算兩個群體間之距離。另外分離分層法有別於凝聚分離法，一開始即將所有樣本視為同一群，之後足見增加分群個數。此方法較少被採用。

2.非分層法

非分層法在分群過程中，係將原有群體打散並重新形成群體。*K*-means 為非分層法之主要代表方法。此方法一開始先決定分群個數，並計算某樣本至各群體重心之歐幾里德距離，並以距離最近者作為該樣本劃分為某群體之原則。重複上述步驟直至所有樣本皆已被劃分完成。

3.二階段法

二階段分群法係結合分層與非分層等兩種方法。首先利用分層法得到群數與

起始點，其次採用非分層法進行各樣本之分群。華德法為一般最常被使用於第一階段分群之方法，透過華德法先決定群組個數。第二階段再以 *k*-means 進行分群。

考量本研究之分群群數為固定值，且為避免分層法一旦樣本被分群後便不再改變之缺點，因此本研究採用非分層法進行分群，MacQueen 於 1967 年提出 *k*-means 演算法，此演算法屬於無監督是學習法。發展至今已常被用於處理分群問題。*k*-means 演算步驟如下。

1.先設定所需要之集群數目 K

2.選定 K 個觀察值做為種子，此即為各群體初始之質量中心。

3.選擇某一樣本，並計算該樣本至所有種子之距離，並以最小距離點作為該樣本歸屬某群體之指標。重覆至所有樣本皆完成分群。

4.計算每個群體內所有樣本之平均值，此平均值即為新的質量中心。

5.比較新舊質量中心是否相同，若相同則停止，若否則繼續上述 2~4 步驟直至新舊質量中心相同為止。

2.1.3 分類技術

在統計有母數分析方法上，可透過羅吉斯迴歸(logistic regression)與鑑別分析(discriminant analysis)等兩種方法進行分類。就邏吉斯迴歸而言，須避免自變數共線性、殘差項自我相關且資料須符合常態分配等相關假設前提。Myung and Han (2001)指出羅吉斯迴歸與一般迴歸模式不同之處在於，羅吉斯迴歸之反應變數為類別屬性，而一般迴歸模式之反應變數為連續屬性。此外，鑑別分析方法則強調變數間須符合線性資料型態。由於資料探勘技術省去傳統統計方法須滿足許多假設條件之前提，因此更適用於建構非線性模式。

在資料探勘方法中，以決策樹(decision tree)方法最常被使用於分類問題。決策樹係屬於監督是學習方法之一種，透過遞迴分割方式產生樹狀結構，並以”if, then”之方式呈現決策規則(McSherry, 1999)。透過決策樹圖形化之呈現方式，可提高使用性，且經由決

策數模型，使用者透過蒐集到之各項屬性，經由決策規則可達成預測應變數之目的(Yada, 2011)。然而 Duda *et al.* (2001)研究指出，若規則過多(即決策樹樹狀過大)，則會產生模型過度配適問題，此將造成模型預測能力不佳。此時應透過剪枝(tree pruning)步驟避免過度配適問題。總計有兩中剪枝方法，分別為先剪枝(prepruning)與後剪枝(postpruning)等兩種方式。

目前常見的決策樹分類方法有分類迴歸數(classification and regression, CART)(Breiman et al., 1984)、C4.5(Quinlan, 1993)、ID3(Interactive Dichotomiser 3)(Quinlan, 1979)、CHAID(chi-squared automatic interaction detection)(Kass, 1980)等方法。CART (Classification and Regression Trees)演算方法主要建立一個二元決策樹，係以每個節點的動態臨界值作為條件判斷式，藉由單一輸入的變數函數，在每個節點分隔資料建立決策樹。CART 之分割規則係採用 Gini Ratio 作為衡量指標。若分散的指標程度很高，則表示分佈許多類別，相反的，若指標程度越低，則代表單一類別居多。此外，CART 演算法係依據整體的誤差率作為修剪決策樹之指標。因此第一步需先算出節點誤差率(node error rate, ε)，如式(1)所示。X_i表示節點中分類錯誤的資料數。$\sum_{i=1} X_i$表示節點中資料總數。

$$\varepsilon = \frac{X_i}{\sum_{i=1} X_i} \qquad (1)$$

CART 演算法是先計算決策樹最底層節點的上一層節點錯誤率，錯誤率越低則修剪優先順序越高並從錯誤率最低的優先修剪，之後再計算整體的錯誤率。因此修剪方向係從最底層的樹葉往上修剪，如果整體錯誤率大於使用者定義的錯誤率則停止修剪動作。

C4.5 與 CART 兩者最大不同點在於節點分之數目。CART 在每一個節點固定產生兩個分支，然而 C4.5 則在每個節點產生不同分之數目，且分之數目將決定類別的個數。C4.5 的前身則為 ID3。

CHAID(Chi-Square Automatic Interaction Detector)演算以卡方檢定(Chi-Square Test)判別二個變數是否需要合併，若能產生最大類別差異的預測變數，則將成為節點的分隔變數。經由計算節點中類別之 P 值(P-Value)來決定決策樹是否繼續生長。因此不需像

C4.5 或 CART 要再做決策樹修剪的動作。CHAID 與 CART、C4.5 之差異有二，其一在於，CHAID 只限於處理類別變數。其二在於修剪的部分，CART、C4.5 是先過度套用資料訓練之後再修剪。但 CHAID 則是在過度套用之前即停止支點蔓生擴大。

表 3 各種決策術演算法特性說明

演算法	分割規則	修剪樹規則	適合資料屬性	特性	備註
CART	Gini Index	Entire Error Rate	類別與連續型資料	二元樹	Briemen(1984)
C4.5	Gain Ratio	Predicted Error Rate	類別資料	多元樹	Quinian(1993)
ID3	Entropy Gain Ratio	Predicted Error Rate	類別資料	多元樹	Quinian(1979)
CHAID	Chi-Square Test	No Pruning	類別型資料	多元樹	Kass(1980)

由表 3 可知，CART 適用於連續與類別之資料屬性，相較於 C4.5 與 CHAID 而言較具彈性。另外 ID3、C4.5 與 CHAID 等方法皆屬於多元樹，應用於本研究中可能發生車流特性分類在同一個階層上，因此本研究採用 CART 作為主要研究方法。

2.1.4 類神經網路

類神經網路(artificial neural network)或稱「人工類神經網路」，是一種模仿生物神經網路的資訊處理系統。類神經網路屬於一種計算系統，使用大量簡單相連的人工神經元(artificial neuron)以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，從外界環境或其它人工神經元取得資訊，經過簡單的運算，將結果輸出至外界環境或其它人工神經元(葉怡成，2003)。

類神經網路中的人工神經細胞(artificial neuron)又稱類神經元、人工神經元或處理單元(processing element)。每個處理單元以扇形輸出，作為其它處理單元之輸入值，如圖 3 所示。處理單元輸出(output)和輸入(input)值的關係式，一般以輸入值的加權乘積和函數表示，如式(2)。介於處理單元間的訊號傳遞路徑稱為「連結(connection)」，每個連結上有一數值加權值w_{ij}，用以表示第 i 個處理單元對第 j 個處理單元之影響度，而函數中其它符號分別代表神經元的各個部分。

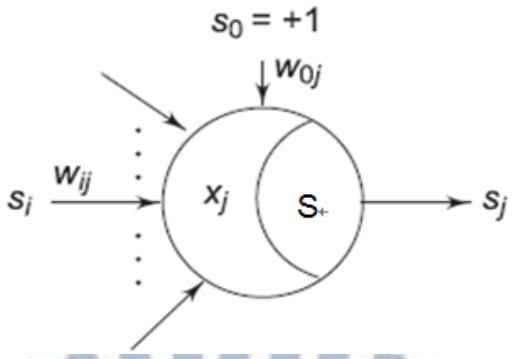

圖 3 人工神經元模型
資料來源：Kumar (2005)

$$s_j = s\left[\sum_{i=1}^{n} w_{ij} s_i + \theta_j\right] \quad (2)$$

其中，s_j為模仿生物神經元模型的輸出訊號(output signal)；s為模仿生物神經元模型的轉換函數(transfer function)，或稱啟動函數(activation function)，是用來將其它處理單元的輸入值加權乘積轉換成處理單元輸出值的函數。常用的有二元(binary)、線性(linear)、雙曲(sigmoidal)和高斯(Gaussian)函數等，其中雙曲函數(sigmoidal)為最常用的轉換方式(Zhang *et al.*, 1998)。各項函數之型式與圖形如表 4 所示。而由許多個人工神經元連結而成之類神經網路共有多層，每層又包含許多處理單元，且每層處理單元間都有連結與相鄰層的處理單元相連接，可構成各式各樣的網路模式(network model)，或稱網路典範(network paradigm)。

1. **輸入層(input layer)**：處理單元用以輸入外在環境的訊息。
2. **輸出層(output layer)**：處理單元用以輸出訊息給外在環境。
3. **隱藏層(hidden layer)**：其具有提供類神經網路表現處理單元間的交互作用，與問題的內在結構的能力。

表 4 神經元轉換函數

二元轉換函數 (Binary Signal Function)	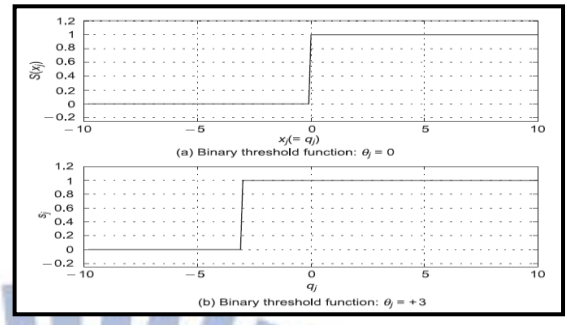
$S(x_j) = \begin{cases} 1 & x_j \geq 0 \\ 0 & x_j < 0 \end{cases}$	
線性轉換函數 (Linear Signal Function)	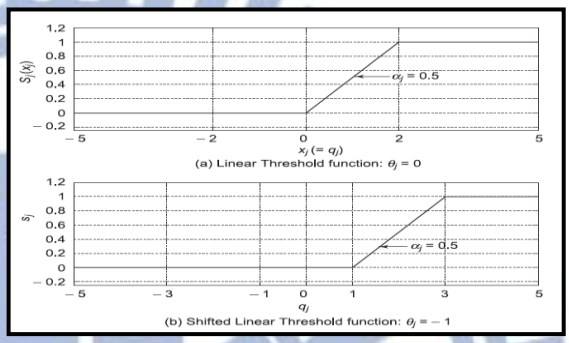
$S_j(x_j) = \begin{cases} 0 & x_j \leq 0 \\ \alpha_j x_j & 0 < x_j < x_m \\ 1 & x_j \geq x_m \end{cases}$	
雙曲轉換函數 (Sigmoidal Signal Function)	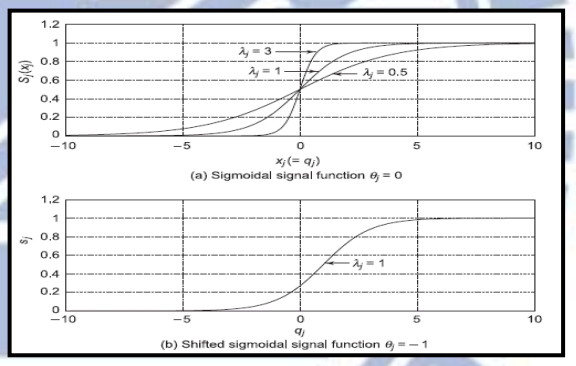
$S_j(x_j) = \dfrac{1}{1+e^{-\lambda_j x_j}}$	
高斯轉換函數 (Gaussian Signal Function)	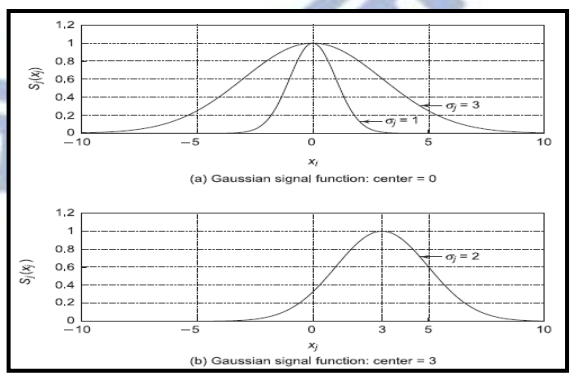
$S_j(x_j) = \exp\left(-\dfrac{x_j - c_j^{\,2}}{2\sigma_j^{\,2}}\right)$	

資料來源：Kumar (2005)

w_{ij}為模仿生物神經元模型的神經節強度，又稱**連結權重(synaptic weights)**；

s_i為模仿生物神經元模型的**輸入訊號(input signals)**；

θ_j為模仿生物神經元模型的**閥值(threshold)**。

類神經網路模式若依據其學習型態可分為以下三類：

1. 監督(Supervised Learning)與非監督式學習(Unsupervised Learning)網路

監督式學習的訓練過程中有實際值可做比對，能讓神經網路架構的每筆輸入值所求之輸出值，可根據相對應的實際值進行誤差修正。藉由不斷地學習可使整個神經網路架構更符合輸入與輸出間的對應關係；反之，非監督式神經網路在訓練過程中並沒有實際輸出值可供比對，權重的修改僅回應網路的輸入，並未描述輸入值間分布關係。詳細的網路學習架構如圖 4 所示。

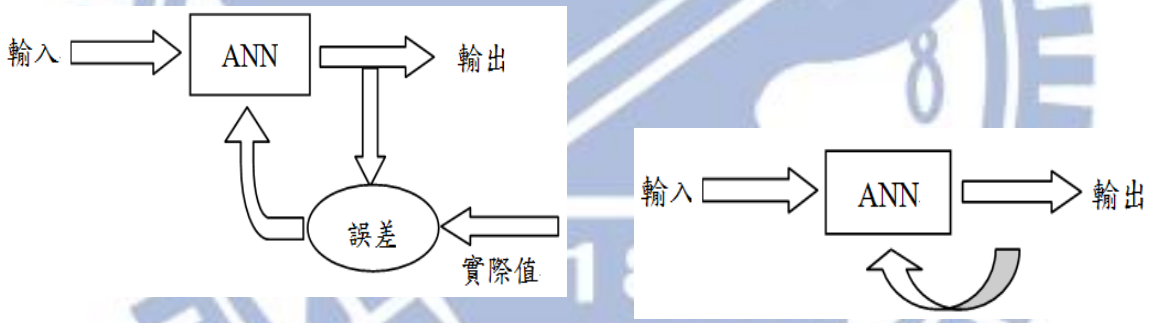

圖 4 監督式和非監督式學習網路

資料來源：Kumar (2005)

2. 競爭與非競爭式學習

競爭式學習本質上屬一種自組織(Self-Organization)的學習方式，它基本理念是假設在輸出神經元間存在某種形態的競爭，在競爭的群體之中只有一個神經元會被激發成活化狀態(Active State)，其餘神經元則會被抑制成休止狀態（Inactive State）；當競爭完成後，只有獲勝的神經元才會進行調整(即學習)，落敗神經元則保持不變。

3. 聯想式學習網路(Associative learning network)

當輸入的資料有雜訊或不完整時，可以從訓練資料去學習內在的記憶規則，以將不完整之變數值推論至完整。

此外，類神經網路架構的資訊傳遞方式又可分為以下兩種：

1. 前饋式神經網路(Feed-Forward Neural Network，FNN)：

FNN 是類神經網路中最常使用的一種形式(Zurada, 1992)。其神經元結構屬向前傳導的連結方式，網路的操作方式也是由輸入層、隱藏層及輸出層依序輸入及輸出，在架構上較為單純，且網路中並無循環(loops)發生。圖 5 為 FNN 的基本結構，雖然圖中僅有一個隱藏層，然而實際的網路模式中可有多於一層的隱藏層。在輸入層及每個隱藏層，都有一偏誤(bias)神經元，可藉此偏誤神經元提高網路的自由度並更新訓練的權重，亦可幫助權重收斂至可接受的解(Freeman and Skapura, 1991)。

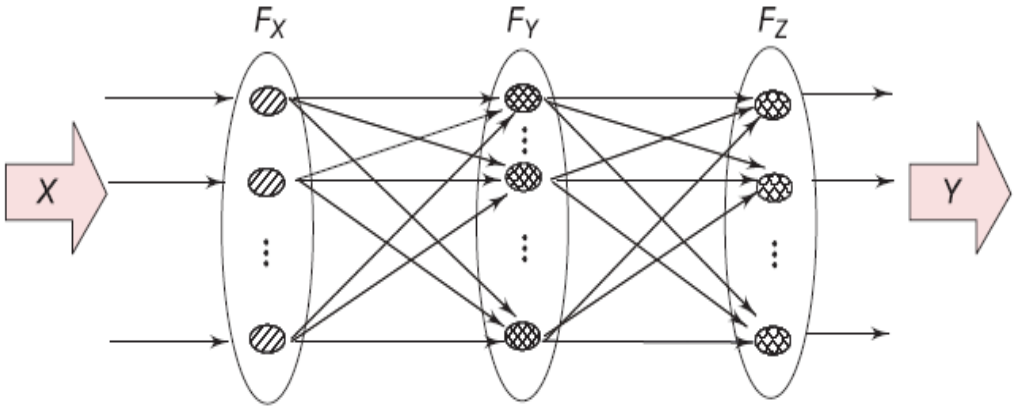

圖 5 前饋式神經網路
資料來源：Kumar (2005)

2. 反饋式神經網路(Feed-Back or Recurrent Neural Network, RNN)：

操作上較為複雜，且在網路中有循環的發生。意指架構中的隱藏層或輸出層皆可能回饋至前一層的神經元，甚至是更前面的神經元。故反饋式神經網路的輸入及輸出將會有多個方向，如圖 6 所示。

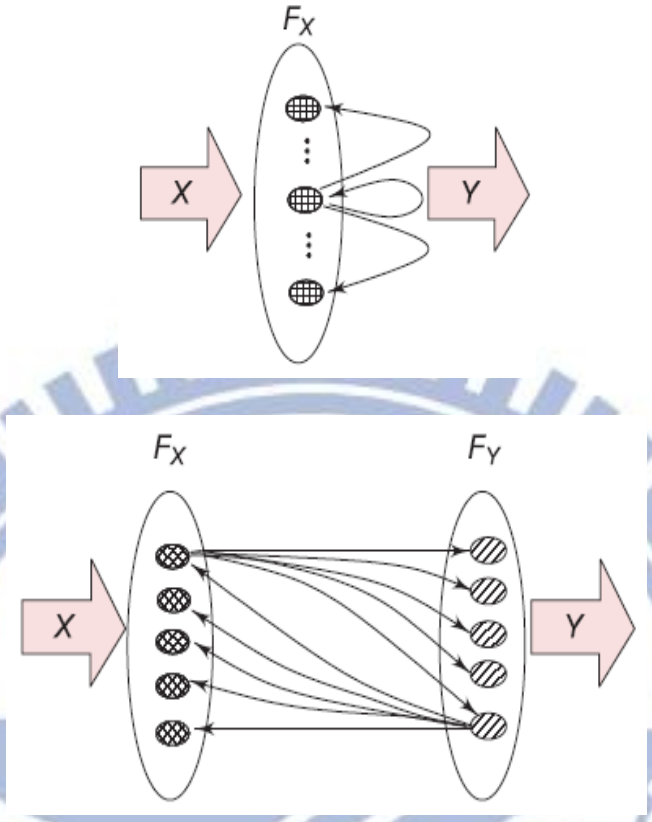

圖 6 反饋式神經網路
資料來源：Kumar (2005)

近年來，類神經網路的相關研究的發展極為迅速，表 5 列出類神經網路資訊處理系統的特性，即為類神經網路目前被廣泛應用的優勢所在(Kumar, 2005)。而其應用範圍擴展至各個領域，不只在社會科學上已成為非常普遍使用的分析工具，許多的議題也都使用類神經網路進行分析，包括了工業工程、科學技術、社會科學和商業與金融等，整理如表 6 所示。

表 5 類神經網路特性

高速計算能力	類神經網路對於資訊之處理方式本質上屬於平行處理的架構，使處理速度更加快速。
高容記憶能力	類神經網路將資料庫及規則分散於連結各神經元的權重，連結不同處理單元間的權重或鏈結強度來記憶，靠著多重分散式聯想記憶，大量減少資料儲存空間並降低資料存取時間。
學習能力 (learning)	模擬生物神經網路學習模式，透過修正和改變連結強度反應環境的變化，並累積每次獲得的經驗以求得正確的反應輸出，大幅降低輸入值與輸出值間的誤差大小。
容錯能力 (tolerance)	類神經網路在訓練後，由於是分散式的記憶模式，故當部分鏈結損壞亦不會影響整個網路功能，仍可獲得合理輸出。
歸納能力	可依據本身的網路架構，將以前不曾見過或不完整的輸入加以歸納分類，不需要有明確的輸出作參考。

資料來源：王偉丞(2010)

表 6 類神經網路應用範圍

應用領域	**工作類型**	**範例**
工業與工程	最適化問題求解	排程、VLSI設計、資源配置、廢水處理最適化
	決策諮詢	自來水廠水質處理操作、材料選用
	故障診斷	飛機、汽車引擎診斷、電子電路診斷、衛星通訊廣播故障診斷
	資料分析	探測訊號分析
	製程監控	化工、鋼鐵製程監控
商業與金融	商業決策	期貨交易決策、債券分級、信用卡盜用判斷、貸款審核、保單審核
	商業預測	股價預測、利率預測、市場預測
	商業分析	財務分析、稅務稽查
科學與資訊	包括資料庫聯想搜尋、電腦輔助教學、電腦音樂、專家系統等、醫學疾病診斷、醫學影像診斷、氣象預測、化學儀器分析解釋、複雜現象映射與模式化、感測資料分類、軍事目標追蹤、犯罪行為聚類分析及性向測驗分析等。	

資料來源：葉怡成(2003)

2.1.5 重要變數選擇

旅行時間之研究主要可透過模擬或估計等兩種方法。若以估計方式進行旅行時間預測，則選取重要變數以反映車流特性，是為提高模式預測及估計能力之重要關鍵。Chang (2005)的研究指出，影響車流特性之因素主要可區分為幾何變數(geometric variables)、交通特性(traffic characteristics)、環境因素(environmental factors)等三大類別，其中幾何變數(geometric variables)主要包含曲度(degree of horizontal curve)與坡度(vertical grade)等變數。交通特性之變數(traffic characteristics)主要包含每日平均交通量(Average Daily Traffic, ADT)、大型車流量佔比(Trucks percentage)、公車流量佔比(Bus percentage)、尖峰小時因素(Peak Hour Factor, PHF)等變數。環境因素(Environmental Factors)則主要考量降雨天數。該研究結果顯示，雨量與公車流量佔比(Bus percentage)為解釋肇事行為之重要變數。Wei *et al.* (2007)則採用交通資料、時間、空間與幾何特性等屬性分析肇事持續時間，並獲得良好之研究成果。其中交通資料主要透過雙線圈偵測器(Dual-Loop VD)蒐集速度與流量等資料。由於本研究主要針對每 5 分鐘之旅行時間進行預測，雖然幾何特性與空間等屬性為分析車流特性之重要變數，然而此變數於短時間連續型預測模式中之變異不大，因此本研究針對交通資料、時間與環境因素等類別進行資料蒐集。

資料蒐集方式可區分為點與空間等 2 種蒐集方式。就點的資料收集方式，主要技術為感應線圈、微波、紅外線與雷達等四種方式，透過上述技術可蒐集空間平均速度(space-mean-speed)、車種、流量等交通參數。其中台灣又以感應線圈之蒐集方式最廣為使用。Yeon *et al.* (2008) 研究指出，以雙線圈車輛偵測器蒐集流量、平均現點速率(average spot speed)等進行均質狀態之旅行時間預測，可獲得良好之推估效果。Yuan *et al.* (2003)指出，不同時點下之速度、佔有率、流量等變數，亦為辨析車流特性之重要因素。一般而言，由於車流多以車隊方式運行，因此縱使對車型有誤判情形發生，但對平均現點速率之影響較低。因此，為避免感應線圈所蒐集之資料產生不一致之誤差，本研究以雙線圈所蒐集之平均現點速率，做為預測模式之重要輸入變數。

再者，以空間角度進行資料收集方式而言，主要透過自動車輛偵測系統(Automatic Vehicle Identification, AVI) (Dion *et al.*, 2006; Tam *et al.*, 2010)與探測車技術(probe vehicle

technology) (Liu *et al.*, 2009)等方式進行均質狀態下之旅行時間預測，且透過此系統所獲得研究範圍內之真實旅行時間，可確保模式發展之可靠度。亦因 AVI 系統於資料擷取過程中，無需克服全球衛星定位系統(Global Positioning System, GPS)定位所產生之誤差與資料回傳時間延遲等問題，因此相較於探測車技術而言，具有準確度與即時性皆較高之優點。由於AVI系統之建置費用較高，因此以往之研究範圍較有侷限性且樣本數亦較少。台灣自 2006 年完成電子收費(Electronic Toll Collection, ETC)系統建置至今，其建置範圍涵蓋整體中山高速公路。至 2009 年 10 月底，其使用率已達 36.48%，且 10 月份共有 16,247,908 筆扣款記錄，扣款成功率為 99.9984%。因此透過 ETC 系統，不僅可蒐集大範圍之旅行時間資料，亦可大幅增加樣本數，更能確保樣本之代表性。本研究即透過此 ETC 系統，蒐集原始資料並計算真實旅行時間(Actual Travel Time, ATT)以作為模式訓練之目標(target)。

Chang and Chen (2005)研究指出，公車流量佔比為分析肇事行為之重要變數，即表示大型車流量大小為影響車流特性之重要變數。本研究路段為台灣新竹科學園區、中壢工業區、桃園國際機場、松山國際機場、台北港、基隆港等重要經濟發展地區之主要聯絡道路，因此本路段之車流特性受複雜經濟活動所影響。其中大型車數量除反映經濟活動狀況外，基於台灣中山高速公路大型車與小型車之限速不同，且大型車之爬坡與變換車道等性能皆不及小型車等因素之影響，造成大型車流量越大，對整體車流運行效率之影響越大。有鑒於此，本研究透過雙線圈偵測器蒐集大型車流量資料並做為預測模式之輸入變數。另外，一般而言，我們認為假日與非假日亦呈現不同之交通特性。因此，星期(day of week)之不同編碼方式亦為掌握車流特性之重要變數。綜合以上所述，雨量、星期、時間、速度與大型車流量等為影響車流特性之重要變數。

2.2 旅行時間預測

許多研究針對旅行時間預測議題已發展不同預測模式。大致上可歸類線性回歸(linear regression)、時間序列(time-series modes)，人工智慧(Artificial intelligence)等方式。一般研究內容主要可分為預測間隔與研究範圍等兩大部分進行說明。所謂預測間隔是指

預測時間之長短，例如預測未來 5 分鐘、10 分鐘。Sun *et al.* (2003)研究指出，預測間隔越長則預測誤差越大。相關研究建議預測間隔應介於 5-30 分鐘之間(Abdulhai *et al.*, 1999; Kirby *et al.*, 1997; Vythoulkas, 1993)。

在資料驅動(data-driven)方法中，特別致力於如何使模式能於線上即時使用。相關研究提出一簡單且可靠架構整合多種模組包含資料蒐集(data collection)、資料處理(data processing)、確認模型(pattern identification)與建立預測模式(prediction module) 等步驟(van Lint, 2006; van Lint *et al.*, 2005; Yu *et al.*, 2008) 。以資料驅動方式所建立之預測模型，在處理即時交通資料上能獲得良好準確度(Chien and Kuchipudi, 2003; Fei *et al.* 2011; van Lint, 2006; Park *et al.* 1999; Zhang and Rice, 2003)。以 data-driven 方法預測旅行時間係透過歷史資料進而預測現況交通狀況，無須詳細描述路網內之動態交通狀態。因此，研究人員可透過路側設施所蒐集之資料，直接或間接的預測旅行時間。以往可透過自動車輛辨識(Automatic Vehicle Identification, AVI)系統或是收費系統(toll collection system, TCS)進行旅行時間之計算。另外，車輛偵測器(vehicle detectors, VDs)為應用最廣泛之資料蒐集設備。一般透過該設備蒐集流量、佔有率、速度等資料間接預測旅行時間。然而透過系統收集資料無法避免資料遺漏或者不正確等問題，因此研究者往往需要針對資料進行前處理，確保資料正確性後再進行模式建構的程序。

van Hinsbergen and van Lint (2008)以貝氏理論為基礎進行多元線性模型之整合。Fei *et al.* (2011)發展貝氏動態線性模型(dynamic linear model, DLM)建立一穩健預測模式並且可針對事件發生下之情形進行旅行時間預測。此外，由於類神經網路(Neural Networks, NNs)適用於處理複雜與非線性等交通特性之優勢，因此已被廣泛應用在交通領域上。類神經網路係屬於非參數型模型(non-parametric models)，該模式透過歷史資料進行模式訓練後再以該模式預測旅行時間。近幾十年來，相關研究主要透過線性迴歸(Linear Regression)、ARIMA(Auto-regressive Integrated Moving Average Model)、卡門濾波(Kalman Filter)、MLP 等方法進行旅行時間預測。以下針對各個方法之研究成果說明如後。

2.2.1 線性迴歸

Kwon *et al.* (2000)以逐步迴歸方法建立線性迴歸模型，並針對旅行時間進行預測。該研究發現，現況交通資料對於預測短期旅行時間較有幫助。歷史資料則對預測長期旅行時間較有幫助。該研究係透過探偵車(probe-vehicles)蒐集旅行時間資訊並作為預測目標，並以車輛偵測器資料與星期等變數作為自變數。該模型應用於 I-880N&S。該研究顯示每日每一時段之變化對旅行時間預測能力有非常顯著影響。該研究指出，該研究所建立之模型有助於預測未來 20 分鐘旅行時間。平均而言 MAPE 值為 14.1%(11%~16.6%)。作者指出該模式最大之限制在於預測時間短且適用範圍較小。

相關研究(Zhang and Rice, 2003; Rice and van Zwet, 2004)以簡單線性迴歸進行旅行時間預測。該研究建立現況交通資訊與未來旅行時間之線性關係。Zhang and Rice (2003)依據不同出發時間建立不同迴歸係數，並且透過現況旅行時間進行未來旅行時間之預測。其中現況旅行時間係透過車輛偵測器所蒐集之速度資料推估而得。該研究被應用於 I-880N 與 I-405N 等地區。該模式在 I-880N 進行測試時，在預測未來 30 分鐘之旅行時間時，具有較低之 MAPE 值(11%)。該研究顯示，相較於離峰時段，尖峰時段具有較高之 RMSE 值。該研究成果與主成分分析法(principal component analysis)及最鄰近法(nearest neighbor method)做比較後發現，該研究建立之線性模式具有較高預測能力。該研究者認為可透過大量資料蒐集與車流特性區分進行參數校估。然而實際應用上需耗費許多時間。

Sun *et al.* (2003)以局部線性迴歸模式(local linear regression model)進行旅行時間預測。該研究以 US-290E 之 2.5 公里作為研究範圍。該研究並未假設現況交通資訊與未來之估計值屬於線性關係。相關研究((Vanajakshi, 2004; Wu *et al.*, 2004)亦整合線性模型中的支持向量機(Support Vector Machines, SVM)進行旅行時間預測。Wu *et al.* (2004)透過 SVM 針對上午尖峰時段進行旅行時間預測並且以 RMSE 做為模式之評估績效值。Danech-Pajouh and Aron (1991)採用類似研究方法，透過分群方式針對各群建立現行迴歸預測模型。該研究指出，透過將車流特性分類之方式可提高預測準確度。為增加模式於複雜真實世界之實用性，van Hinsbergen and van Lint (2008) 發展了貝氏架構(Bayesian

framework)並結合兩種線性迴歸模型(linear model and locally weighted model)。Fei *et al*. (2011)建立 ADLM 模型(adaptive dynamic linear model)並進一步處理非重現性擁擠下之旅時間預測。貝氏模型主要是認為旅行時間與平均歷史旅行時間、旅行時間之變異及模式誤差項等三者間屬於線性關係。該研究顯示透過 ADLM 模型之預測能力高於自迴歸模型(auto-regressive model)，尤其在非重現性擁擠的情況下更有甚之。

2.2.2 ARIMA

就交通工程領域而言，相關研究(Ahmed and Cook, 1979; Levin and Tsao, 1980; Ahmed, 1983)以 ARMIA 模式針對隨機交通狀況進行預測。Oda (1990)以自迴歸(Auto-regression, AR)模型預測旅行時間。該研究針對 16 號公路(Route-16)進行 4 天共 3 個時段的預測。該研究誤差最大的時段為中午與晚上尖峰。Saito and Watanabe (1995)使用 VD 資料進行未來 60 分鐘旅行時間之預測。該研究以 30 分鐘內所蒐集到的資料建立 AR 模式，且平均誤差小於 3 分鐘。並透過可變訊息標誌(Variable Message Signs, VMS)與廣播等方式進行旅行時間資訊之發布。van der Voort *et al*. (1996)建立 KARIMA 模型針對交通特性進行預測。該模型混和自組織映射圖(self-organizing map, SOM)與 ARIMA 等兩種模式。該研究依據樣本之日期特性進行分群。該研究針對法國高速公路進行 30 分鐘與 60 分鐘之旅行時間預測。90%樣本之預測誤差介於-15~+15%之間。Chen *et al*. (2001)採用相似概念進行研究。該研究以 3 個車輛偵測器所蒐集之流量、佔有率與速度等屬性進行分群。該研究所採用之整合架構(SOM/ARIMA)其 MAPE 值為 11.4%，相較於 ARIMA 模式之 MAPE 值為 14.6%有較佳之表現。相較於歷史平均法而言，ARIMA 模式對於旅行時間之預測有較佳之表現(Smith and Demetsky ,1997)。然而與歷史平均法比較之同時，ARIMA 模式仍有超過 10~20%之樣本預測能力偏低。因此 ARIMA 之對旅行時間之預測能力仍低於類神經模型。因此該研究認為不適合透過 ARIMA 模型進行旅行時間預測。

2.2.3 卡門濾波

歷年來卡門濾波(Kalman Filter)模型以廣泛被使用於流量預測(Okutani and Stephanedes, 1984; Whittaker *et al.*, 1997)與旅行時間預測(Chen and Grant-Muller, 2001;

Chen and Chien, 2001; Chien and Kuchipudi, 2003; Chien *et al.*, 2003; Kuchipudi and Chien, 2003; Vythoulkas, 1993; Yang, 2005; Yasui *et al.*, 1995)等領域。卡門濾波係屬於時間序列方法，透過不斷更新現況資料進行未來事件之預測。因此本技術假設狀態向量與觀察向量存在一定關係，透過轉換方程式(first order Markov process)則能建立狀態向量。該狀態向量建立在過去與現在之最佳估計向量上(Kalman, 1960)。Park *et al.* (1999)以卡門濾波模型進行旅行時間預測。該研究蒐集 AVI 資料，並預測 5~25 分鐘之旅行時間，且應用範圍為 US-290 公路。該研究之平均準確度(accuracy)為 16.1%該研究指出卡門濾波模型相較於歷史平均法與指數平滑法具備較佳之預測能力，然而類神經模型卻比卡門濾波模型具備較佳預測能力。Chen and Chien (2001)使用 AVI 資料並同時於路徑與路段之問題中提升了預測準確度。Chien and Kuchipudi (2003)則採用時間變數進而提升了路徑與路段問題之預測準確度(路徑之 MARE 為 1.1~7.3%。路段之 MARE 為 2.1~9.2%)。就旅行時間預測之議題，以往研究透過狀態轉換模型(state-transition models)進行預測。主要採用歷史旅行時間或相近狀態之旅行時間等時間序列之方法。因此，透過非線性轉換方程式將相似交通狀態之旅行時間以離散的線性函數呈現。通常以卡門濾波(Kalman filter)模型進行旅行時預測(Chen and Chien, 2001; Chien and Kuchipudi, 2003; Nanthawichit *et al.*, 2003; Yang, 2005)。雖然透過即時或者歷史資料建立之模型相較於簡單模型較具預測能力。然而卡門濾波中的高斯噪音(Gaussian noise)並非皆能與研究範圍內之資料一致(Ye and Zhang, 2010)。另外，相鄰時點之旅行時間在非線性車流特性中具有非線性之特性(Chen and Rakha, 2014)。再者，由於卡門濾波模型受限於若干 Markov 之限制，因此相關研究針對不同議題發展不同混和模型。相關研究結合類神經模型針對交通流量進行預測((van Hinsbergen *et al.*, 2012; van Lint and Djukic, 2012)。

2.2.4 MLP

近幾十年來 ANN 已經被廣泛使用於流量、速度(Ishak *et al.*, 2003; Ishak *et al.*, 2004; Xiao *et al.*, 2004)與旅行時間(Dia, 2001; Vanajakshi *et al.*, 2004; Wei *et al.*, 2007)等不同議題上。另外，Karlaftis and Vlahogianni (2011)研究指出，ANN 模式相較於統計模式而言，

由於無須先確定變數間之因果關係與符合一定統計分配之要求，因此使得 ANN 模式相較於統計模式而言應用上更有其彈性。Smith and Demetsky (1997)以類神經網路針對弗吉尼亞洲之公路(Telegraph road in Virginia)進行旅行時間預測。該研究之平均誤差為 7.54%，其預測能力相較於 ARIMA 與歷史平均法而言更為準確。Huisken and van Berkum (2003) 進一步比較 MLP、DTTE(dynamic travel time estimation)、STTE(static travel time estimation)等三個模型。該研究共收集 43 個變數包含來自 21 處車輛偵測器之資料。最後作者將輸入變數縮減至 12 個。經研究發現 MLP 相較於 DTTE 與 STTE 等模型具有較低之誤差值(MARE=4.61%)。相關研究(Park and Rilett, 1999; Park et al., 1999; Rilett and Park, 2001)更結合 AVI 資料建立 MLP 模型。Park and Rilett (1999)蒐集 US-290 公路 7 處 AVI 資料進行旅行時間預測。該研究顯示預測範圍越常亦或預測時間時間長度越長則誤差越大(MAPE 值越大)。該研究亦指出變數選擇對於類神經模型預測能力有重要性影響。Innamaa (2005)針對芬蘭 4 號公路(Road-4)蒐集車輛偵測器與 4 處 AVI 資料建立 MLP 預測模型。該研究針對研究範圍切分不同區段長度(9.1~28.1 km)，並針對各區段進行旅行時間預測。該研究顯示，隨著研究範圍越長，則誤差值(MAE)由 0.3 分鐘增加至 1.1 分鐘。

2.3 小結

有關旅行時間相關研究內容與模式績效值彙整如表表 7 旅行時間預測相關文獻研究內容與表 8 所示。由上述分析可知，以往研究多集中於在現有設備下提升預測能力，並未針對利用虛擬變數提升模式預測能力；發展能同時適用於事件發生下之預測模式；透過預測架構探掘關鍵變數等 3 個議題進行研究。

就面對含非重現行擁擠特性下之複雜車流特性而言，Yildirimoglu and Geroliminis (2013)研究指出，透過簡單的歷史資料平均法去預測未來旅行時間將發生很大的誤差。此乃因未考量車流隨機變動之特性，尤其在擁擠發生下(例如：等候線情形、需求不確定等等)。若進一步研究每天旅行時間之變異情形，則採用歷史平均法進行估計之誤差越大。由於一般估計模式未能於模式中充分反映研究範圍內之動態擁塞情形，因此應用於擁擠狀況

時會低估旅行時間。由於 ANN 模式相較於統計模式而言，無須先確定變數間之因果關係與符合一定統計分配之要求，因此使得 ANN 模式相較於統計模式而言應用上更有其彈性。此外，由以往研究結果可知，ANN 之多層感知與推演能力，針對複雜、非線性與難以預測之議題，具有較高度穩健性與預測能力。因此，本研究係以多層感知機作為含非重現性擁擠狀態下旅行時間之預測工具。

再者，相關研究雖然透過 AVI 收集探針車資料，並以此建立旅行時間預測模式，由 Chien and Kuchipudi (2003)之研究指出，探測車之佔有比例對提升旅行時間預測能力有關鍵性之影響。然而以往研究受限於經費與時間影響，無法全面性建置 AVI 系統並且取得大量真實旅行時間樣本，僅能透過資料填補(邱孟佑，2010)或推估等方式獲得預測目標(真實旅行時間)。因此唯有進一步克服真實旅行時間樣本取得與樣本數不足等問題，才能建立穩健之預測模式。此外，本研究參照以往研究共收集雨量、星期、時間、速度與大型車流量等影響車流特性之重要變數外，更預計收集 ETC 原始資料所推得之歷史旅行時間(Historical Travel Time, HTT)，並以真實旅行時間(Actual Travel Time, ATT)做為訓練目標。

最後，本研究為解決 1.在現有設備下提升預測能力。2.發展遺漏值填補方式，並且找出重要偵測器與關鍵變數。3.發展同時適用非重現性擁擠之高預測能力模式。4.自動辨別交通特性並且發展高準確度之預測模式等 4 大議題，並考量研究範圍之交通特性。本研究共結合 *K*-means、CART、ANN 等 3 種資料探勘方法，發展 3 種預測架構並以此建立一適用於非重現性擁擠下之旅行時間預測模式。

表 7 旅行時間預測相關文獻研究內容

作者	模式	變數	資料蒐集方式	研究地區	備註
Kwon *et al.* (2000)	Linear regression	流量、佔有率(30s)、旅行時間	VDs、probe vehicle	I-880N&S(10km, 19VDs)	Linear regression with step wise variable selection
Zhang and Rice (2003)		速度(30s)、旅行時間(I-880N) 流量、佔有率(I-405N)	VDs	I-880N(10km, 18VDs)	
Rice and van Zwet (2004)		流量、佔有率(30s)。整理成 5 min 資料	VDs	I-405N(32km)	
Sun *et al.* (2003)		速度(5min)	VDs	US-290E(2.5km)	Local linear regression
Wu *et al*. (2004)		速度(3min)	VDs	Taipei-Chungli(45km) Taipei-Taichung(178km)	Linear regression with SVM
Fei *et al*. (2011)		流量、佔有率、速度(1min)。整理成 5 min 資料	VDs	I-66E(11.26km)	ADLM
Oda (1990)	ARIMA	流量、佔有率(5 min)	VDs	National Route 16(7km)	AR
Ishak and AI-Deek (2002)		速度(30sec)	VDs	I-4(62.5km)	Non-linear time series

表 7(續) 旅行時間預測相關文獻研究內容

作者	模式	變數	資料蒐集方式	研究地區	備註
Park and Rilett (1999)	Kalman filter	旅行時間(5min)	AVI	US-290E(27.6km)	Kalman filter
Chien and Kuchipudi (2003)		旅行時間(5 min)	AVI	US-290E(27.6km)	Kalman filter(Path-based and Link-based)
Kuchipudi and Chien (2003)		旅行時間(5 min)	AVI	Eastbound NYST(17km)	Kalman filter(hybrid model)
Dougherty and Cobbet (1997)	ANN	流量、佔有率、速度(1 mim)。整理成 5 min。	VDs	A3 and A13	MLP-single hidden layer
Huisken and van Berkum (2003)		流量、速度(1 mim)	VDs	A13(11.4 km)	
Park and Rilett (1999)		旅行時間(5 min)	AVI	US 290 (27.6 km)	
Innamaa (2005)		流量、速度(1 min)、旅行時間	VDs AVI	Road-4 (28 km)	
Park *et al*. (1999)		旅行時間(5 min)	AVI	US-290E(27.6 km)	SNN-single hidden layer
Dia (2001)		流量、速度	VDs	Pacific highway(1.5 km)	TLRN
Van Lint *et al*. (2005)		流量、速度(60s)	VDs	A13S (8.5 km)	SSNN-one hidden layer and one context layer
Van Lint (2008)		流量、速度(60s)	VDs	A13S (7 km)	Delayed censored EFK SSNN

表 8 旅行時間預測相關文獻研究績效

作者	模式	預測時間長度	研究時段	績效指標	績效值
Kwon *et al.* (2000)	Linear regression	20 min	Morning peak(05:00-10:00) Evening peak(14:00-19:00)	Root-MSPE MAPPE	116.7s(95~149s) 14.1%(11~16.6%)
Zhang and Rice (2003)		30 min(I-880N) 90 min(I-405N)	Morning peak(05:00-10:00)	MAPE	11% 14%
Rice and van Zwet (2004)		60 min	All-day(05:00~21:00)	RMSE	Less than 10 min
Sun *et al.* (2003)		25 min	Morning peak(06:00-10:00)	RME	11.38%
Wu *et al*. (2004)		10 min	Morning peak(07:00-10:00)	RMSE	6.79%
Fei *et al*. (2011)		5 min	Morning peak(05:00-11:00) Evening peak(14:00-20:00)	MAPE	2~14%
Oda (1990)	ARIMA	P(P>=2)	Morning peak(07:00-9:00)	Difference	5~6%
Ishak and AI-Deek (2002)		5 min	Morning and afternoon peak and off-peak (06:00~19:00)	Average error	3 min
Park and Rilett (1999)	Kalman filter	5 min	Morning peak(06:00-10:00)	MAPE	6.2%
Chien and Kuchipudi (2003)		5 min	Morning and afternoon peak and off-peak (06:30~09:30)	MARE	1.1~7.3%(Path-based) 2.1~9.2%(Link-based)
Kuchipudi and Chien (2003)		5~15 min(peak) 30 min(off-peak)	All day	MARE	4.8~11.73%werjkl;’

表 8(續) 旅行時間預測相關文獻研究績效

作者	模式	預測時間長度	研究時段	績效指標	績效值
Dougherty and Cobbet (1997)	ANN	15 min	All day (06:00~19:30) for typical week day	RMSEP	0.22~0.24(flow) 0.21~0.23(occ)
Huisken and van Berkum (2003)		NA	NA(1996/11/11~1997/2/23)	MARE	4.61%
Park and Rilett (1999)		5 min	Morning peak(06:00-10:00)	MAPE	7.4(NN_M1)
Innamaa (2005)		4 min	All day	MARE	6.0%
Park *et al*. (1999)		5 min	Morning peak(06:00-10:00)	MARE	7.2%
Dia (2001)		5s	Collected over a 5 h period on 2 days in April 1995	Average percent error	7%
Van Lint *et al*. (2005)		NA	NA	MRE	1.6%
Van Lint (2008)		NA	Evening peak (14:00~20:00)	RMSE	100s(SSNN)

第三章 旅行時間預測方法發展

本研究建立類神經為基之預測方法(Neural Network Based Method, NNBM)、混合專家概念為基之預測方法(Mixture of Experts Based Method, MEBM)、整合分群分類為基之預測方法(Integrated Clustering-Classification Method, ICCM)等 3 個預測架構。以下針對 3 個預測架構之輸入與產出關係說明於 3.1 節。另外依序針對 NNBM、MEBM 與 ICCM 等 3 個預測架構細部內容分別說明於 3.2~3.4 節。

3.1 旅行時間預測方法架構

本研究所建構之 3 個預測架構如圖 7 所示。首先經由文獻回顧蒐集可解析車流特性之變數，包含速度、雨量(rainfall)、星期(day of week)、時間(Time)、大型車流量等，以及透過電子收費系統(Electronic Toll Collection, ETC)原始資料計算而得知真實旅行時間(Actual Travel Time, ATT)與歷史旅行時間(Historical Travel Time, HTT)。經由 NNBM 模型後獲得重要變數組合、168 種組合之預測模式與重要變數組合下之預測模型績效值等產出。經 NNBM 獲得重要變數組合後，即將此成果作為 MEBM 與 ICCM 之輸入變數。此外，經由 MEBM 模型可進一步獲得分群模式、分類模式、混和專家系統模型與混和專家系統模型績效值等產出。其中，分群模式與分類模式亦作為 ICCM 之研究基礎，並且透過 ICMM 可獲得關鍵變數、整合分群分類預測模型與整合分群分類預測模型等產出。最後針對 NNBM、MEBM 與 ICCM 等 3 個模型之績效值進行比較分析。

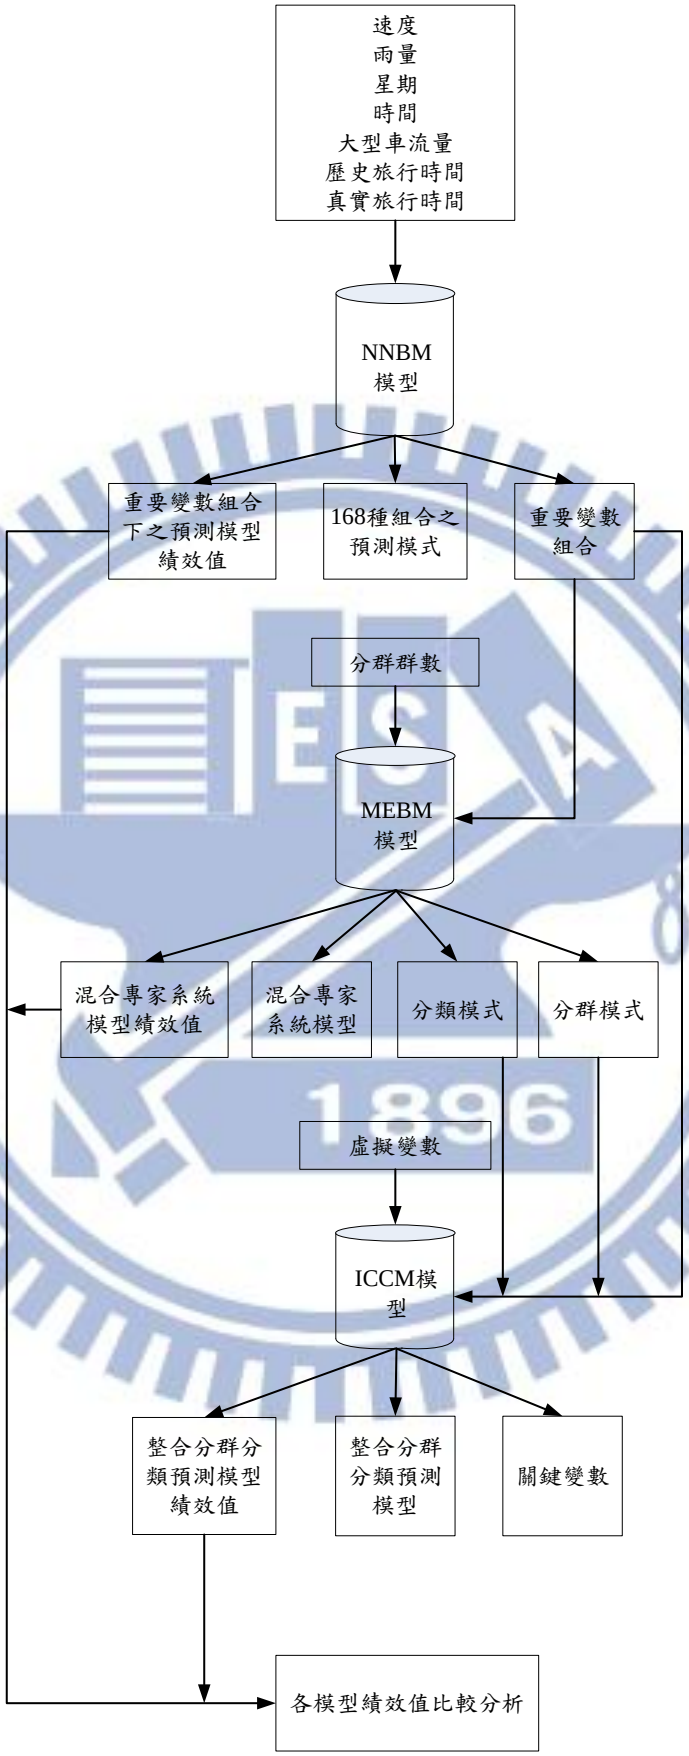

圖 7 旅行時間預測方法架構

3.2 方法一

透過類神經網路建構非線性的模式，進而免除多元線性迴歸(Multi-factor line regression method)及 ARIMA 建構模式時必須設立許多假設條件的缺點(Rumelhart *et al.*, 1986)。因而 1992 到 1998 年間，將類神經網路應用於商業相關問題的研究中，約有 78％使用 BPN 進行分析 (Vellido *et al.*, 1999)。

Rumelhart *et al.* (1986)發表 BPN 演算法，並提出了反饋學習法則(Propagation Learning Rule)。倒傳遞學習法以最小均方法(Least Mean Square, LMS)訓練其網路權重值(Kumar, 2005)，將輸入值由輸入層投入類神經網路，經隱藏層進行訊息傳遞與強化，最後由輸出層輸出預測值，再經由網路學習過程使誤差函數最小化。LMS 於 1960 年由 Widrow 和 Hoff 二位學者所發展，也稱作 Widrow-Hoff 學習法 (Kumar, 2005)。再者，其演算原理主要依據最陡坡降法(Gradient Steepest Descent Method) (Kumar, 2005)，透過演算法重複計算步驟，目的將誤差函數予以最小化。

BPN 之架構為多層前饋式(Multilayer Feed Forward)，採取監督式(Supervised Learning)的學習模式，故亦稱之多層感知機(Multi-Layer Perceptron, MLP)。其將訓練樣本輸入網路中並同時傳遞網路輸出結果，讓網路學習輸入與輸出變數中的對映規則；若網路輸出值($\overline{X}(k)$)和預先設定的輸出值($X(k)$)有偏差時，網路會調整各節點之間的權重(w_{ih}^{k}, w_{hj}^{k})，降低網路輸出值與期望輸出值的差距。倒傳遞類神經網路主要由「輸入層」(Input Layer)、「隱藏層」(Hidden Layer)及「輸出層」(Output Layer)所組成，其中「輸入層」是用來輸入外在環境變數，即本研究所蒐集之 VD、星期、時間、雨量、ETC、虛擬變數等屬性。而「隱藏層」是表示輸入節點間的交互影響，「輸出層」則是將訊息傳送到外在環境，即為本研究路段旅行時間預測值($\overline{X}(k)$)，兩者皆使用非線性函數作為其轉換函數，雙曲線函數(Sigmoid Function)為隱藏層較常使用之轉換函數，本研究之網路模式架構如圖 8 所示。

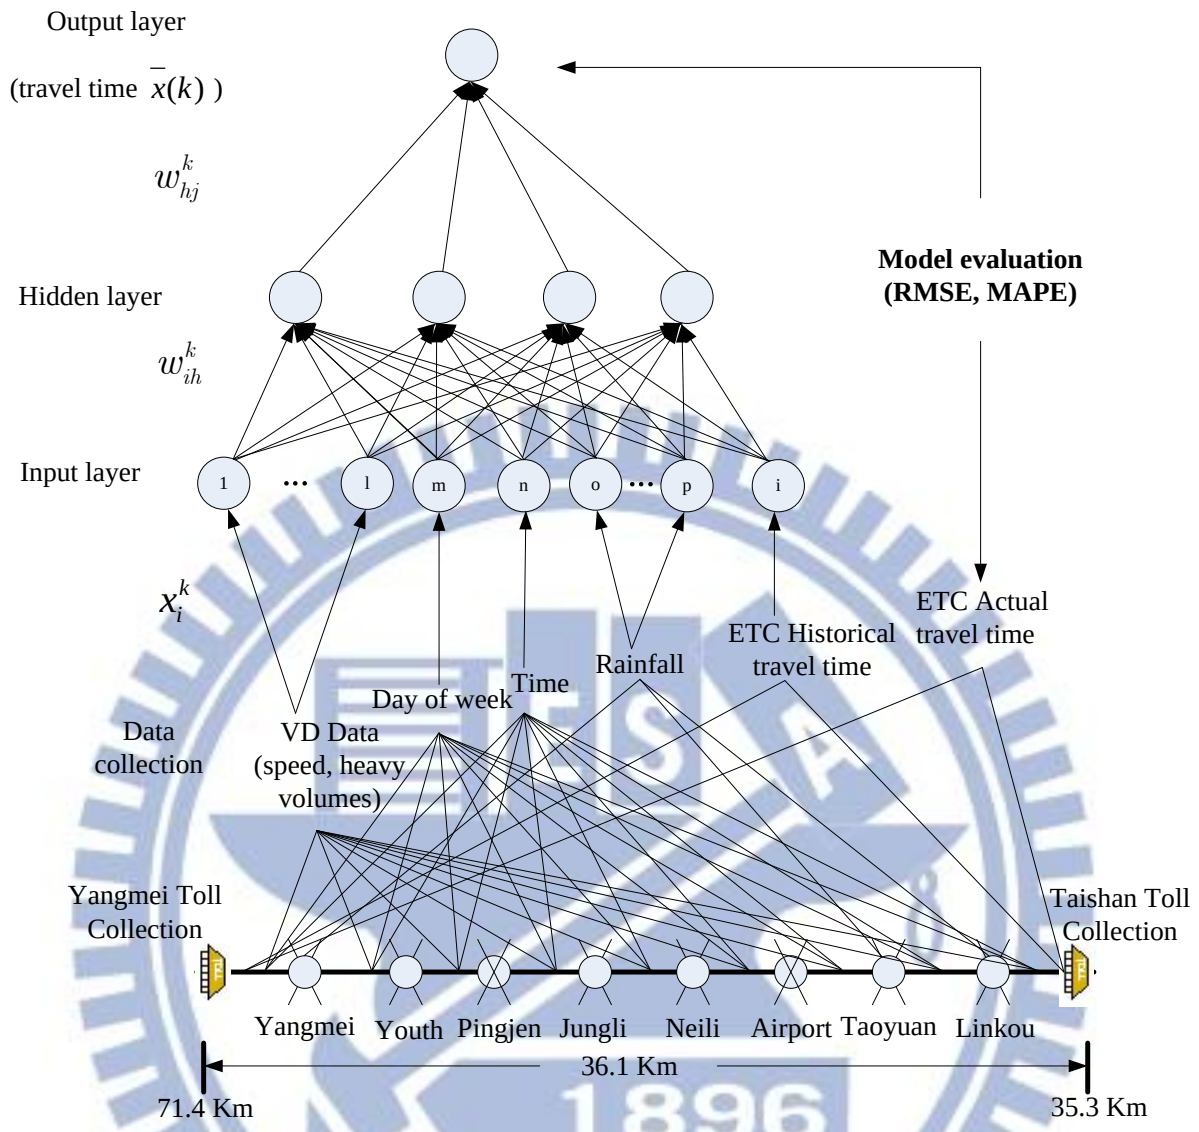

圖 8 倒傳遞神經網路架構

NNBM 之預測架構，主要針對 VD、ETC、雨量、時間、星期等屬性進行資料蒐集，並且由資料蒐集結果，選擇穩定度較高之雙線圈偵測器所蒐集之交通參數作為 VD 屬性輸入變數，藉此避免資料過度填補造成模式預測結果背離實際車流狀況。基於遺漏值(Missing data)為蒐集各屬性原始資料過程中，可能會遭遇之問題。因此，經由適當填補技術，除了可以反映實際車流特性外，亦可提高連續型預測模式之適用度。另外，本研究針對 ETC 原始資料計算 HTT 與 ATT。其中，有關連續旅次與旅行時間之演算邏輯，係整合 Southwest Research Institute (SwRI, 1998)與 Transmit (Mouskos *et al.*, 1998)所提出之 AVI algorithms 進行計算。最後，經由資料蒐集、整理與計算等步驟後，即針對現有

屬性設計不同實驗組合，以了解不同變數組合對旅行時間預測模式之影響。圖 9 為 NNBM 旅行時間預測流程。

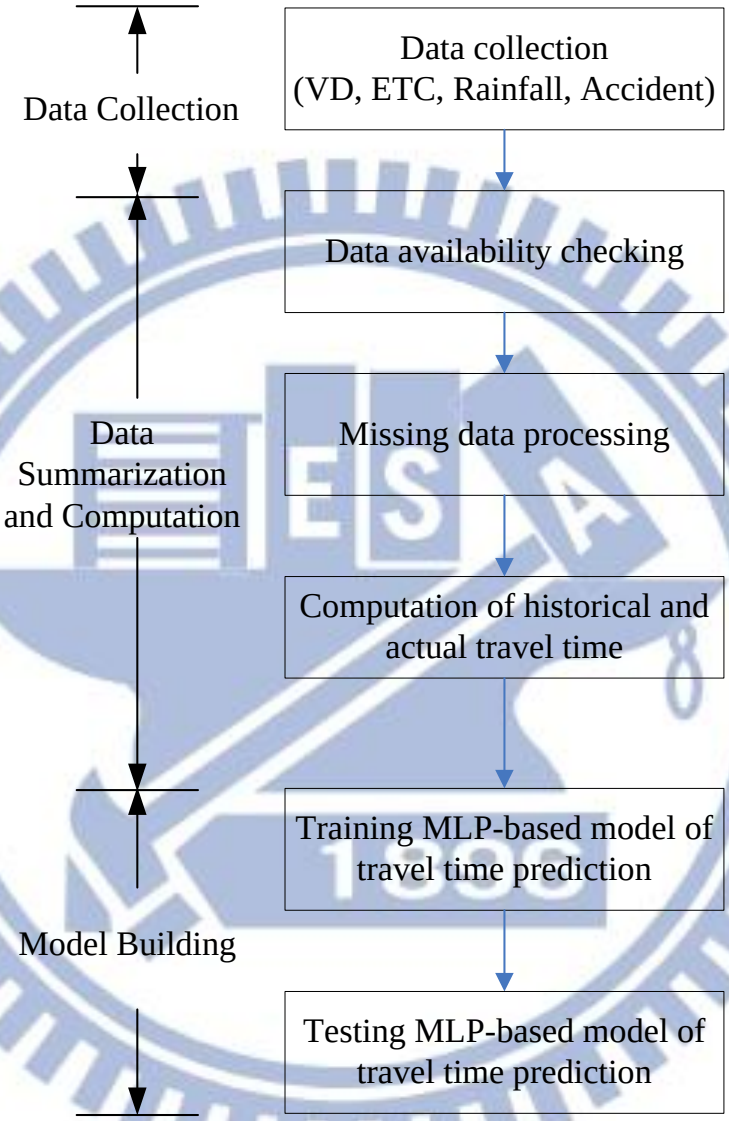

圖 9 NNBM 旅行時間預測流程

3.3 方法二

有關 MEBM 之預測步驟如圖 10 所示。首先須針對資料進行分群數目進行設定。鑑於一般車流特性多有上、下午尖峰之特性。再者經由本研究現況旅行時間尖離峰之觀察，由於包含非重現行擁擠之情形，因此具有 1~3 個尖峰不等，由此可知，在 3 個尖峰特性

下即具備 4 個離峰時段。再者，通常交通管理單位會將深夜離峰之特性與一般離峰情形進行區分。因此，針對複雜車流地區將其交通情形區分為 8 個特性並分別依據其特性研擬相對應之管理策略為一常見方式。本研究亦將研究範圍內之車流特性設定為 8 個群體。俟決定分群數目後以 *K*-means 建立分群模式，並將各群分群結果以隨機方式區分為訓練組與驗測組。資料比例為 7：3。另外，為能區別驗測組內各樣本分屬於哪一個群體，因此本研究進一步以 CART 建立預測模型。再者，本研究共設計兩種混合專家模式進行旅行時間預測，最後針對測試結果進行分析與結論。

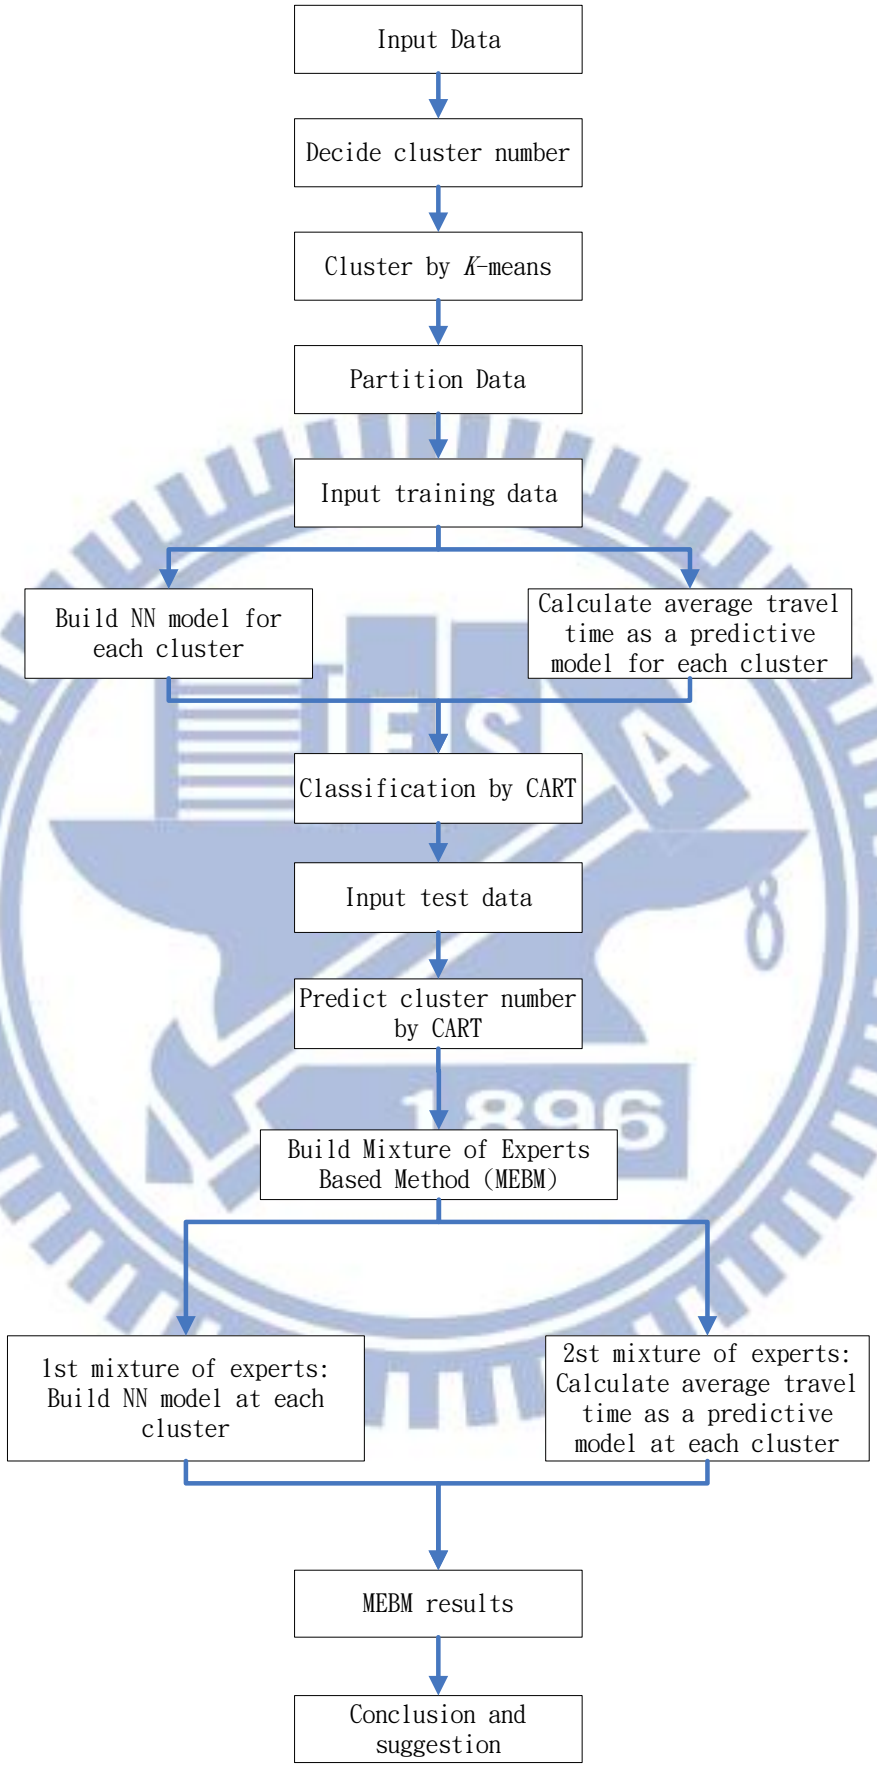

圖 10 MEBM 旅行時間預測流程

Step 1：Input data

依據 van Hinsbergen *et al.* (2007)之研究，就短時間交通預測方法而言，ANN 被歸類為非參數型的統計方法(nonparametric statistical methods)。透過 ANN 建立預測模式之過程中，尋找重要且關鍵之輸入變數，為建立準確預測模式之重要關鍵。有關 MEBM 模式中之輸入變數，首先透過 NNBM 決定重要變數，並將該變數作為輸入變數。輸入變數共包含現點速率、大型車流量、雨量、星期、時間等。

Step 2：cluster by *K*-means

MEBM 之概念主要針對各群建立適宜於該群之預測模式。本研究採用資料探勘中 *K*-means 之方法進行分群。Prototype-based 分群技術可建立具有一個階層的資料分割，常見的包括 *K*-Means、*K*-medoid。*K*-means 使用一群資料點的平均作為代表，常應用於連續 n 維空間的物件上。*K*-medoid 則使用一群資料點的中心點作為代表（必須是實際的點）(Tan *et al.*, 2006)。基本 *K*-Means 演算法說明如下(Tan *et al.*, 2006)：

首先需選擇 K 個初始中心（其中 K 為使用者要分群的群數），每個點都會被分配到最近的群中心，分配至群中心的資料點形成一群集，各群集的中心再依據所分配到的資料點進行更新，直到群集不再變動或群中心不再變動為止。但在實際應用中，通常會使用較弱的條件作為結束條件，例如直到只有 1%的資料點會改變群集。

基本 *K*-Means 演算法表示如下(Tan et al., 2006)：

基本 *K*-means 演算法
Select K points as initial centroids
Repeat
From K clusters by assigning each point to its closest centroid
Re-compute the centroid of each cluster
Until Centroids do not change

基本演算法中個步驟細節分述如下(Tan *et al.*, 2006)：

1.選擇初始中心點

對中心做隨機初始化時，不同 *K*-means 會產生不同的誤差平方和 (sum of the

squared error, SEE)。一般方法是隨機選擇初始中心點，但通常會造成群集相當粗糙

2.分配資料點至最接近群中心

為分配資料點至最近之群中心，必須以一個臨近值測量 (proximity measure) 的表示法以證明特定的資料是滿足接近的概念。歐基理德距離 (Euclidean distance) 常被用於歐基理德空間中的資料點；餘弦相似度則較適用於文件。一特定類型資料亦有其他臨近值測量方式能滿足，例如：曼哈頓距離亦能適用於歐基理德空間、Jaccard 亦常用於文件型資料。

3.中心與目標函數

上述演算法中第 4 行為「重新計算每一個群集的中心，因為中心是依據資料與分群目標的鄰近值測量而得，因此可能會變動；而分群的目標一般由目標函數表示，此函數將依據資料點與其他點或其他群中心的鄰近距離。

(1)在歐氏空間中的資料

若鄰近值測量方法為歐基理德距離，則用以測量分群品質的目標函數為誤差平方和 (SEE)，即為分散程度來衡量。其公式如下：

$$\mathrm{SSE} = \sum_{i=1}^{K} \sum_{x \in C_i} \mathrm{dist}(C_i, X)^2$$

演算法中，將會計算每個資料點的誤差，並計算誤差平方和， 演算中將會選擇具有較小誤差平方和的分群。但在演算法過程中，僅能保證會找到 SSE 的區域最小值， 而無法針對最佳化 SSE 以選擇特定中心點與群集，可能會出現僅有部分最佳化 (suboptimal)分群的結果。

(2) 文件資料

目的是要最大化群集中文件與群集中心的相似度，此數量代表群集的內聚力 (cohesion)，其公式如下：

$$\mathrm{cohension} = \sum_{i=1}^{K} \sum_{X \in C_i} \mathrm{cosine}(X_i, C_i)$$

Step 3： classification by CART

決策樹歸納法的基本演算法為貪心演算法(Greedy Algorithm)，它是從上到下遞迴的(Top-Down Recursive)且採用各個擊破方式(Divide-and-Conqure)以建構決策樹(Han and Kamber, 2001)。本研究主要採用 TreeGrowth 演算法。TreeGrowth 演算法的輸入包含訓練資料與屬性集合，運作流程為遞迴的選擇最佳屬性來切割資料，並擴展樹的葉節點，直到滿足停止條件(Tan *et al.*, 2006)。以下針對 TreeGrowth 演算法各程序進行說明(Tan *et al.*, 2006)：

(1)The creatNode ()

為決策樹建立新的節點，決策樹的節點可為測試條件(Test Condition)，以node, test_cond表示之，或者為類別標籤，以node, label表示之。

(2)The find_best_split ()

決定應該選擇那個屬性作為切割訓練資料的測試條件。測試條件的選取乃依據使用哪種非純性(Impurity)的衡量指標來評估切割的優良性。

(3)The Classify ()

決定類別標籤(Class Label) 歸類於哪個葉節點。對於每個葉節點 t，令P(i|t)表示該節點上類別(Class) 為 i 的訓練資料所佔的比例。在多數的情況下，都將葉節點歸類到具有多數訓練資料的類別，計算方式如下式所示：

$$\text{Leaf.label} = \underset{i}{\text{argmax}}\, P(i|t)$$

其中，運算符號argmax為返回極大化P(i|t)的參數值 i。P(i|t)除了決定葉節點類別標籤所需之資訊外，也可用來估計分配到葉節點t的資料，屬於類別 i 之機率。

(4)The stopping_cond ()

藉由檢查所有的資料是否屬於同一個類別標籤或者具有相同的屬性值，決定是否停止決策樹的增長。另一種停止遞迴函數的方法為檢查訓練資料是否小於某個最小閥值。

由於決策樹演算法的關鍵在於如何挑選合適的屬性，作為測試節點來將資料作分類。而衡量決策樹分割的適合性，主要為節點非純性之計算，目前已被廣泛使用的衡量指標有熵(Entropy)、吉尼係數(Gini Index)與卡方統計量(X^2Statistics)(Tan *et al.*, 2006)。本研究主要應用 CART 的決策樹分析方法(Breiman *et al.*, 1984)。當決策樹產生之後，可自決策樹探勘出分類規則，呈現所得之分類知識。分類規則係以 IF-THEN 形式表示之，建立方式為從決策樹之根節點到葉節點(Leaf Node)的每一條路徑，便代表一條分類規則。沿著路徑上的每個屬性-數值(Attribute-Value Pair)形成規則之前半部(IF 部分)的一個連接項，葉節點會包含類別之預測，並形成規則後半部(THEN 部分)(Han and Kamber, 2001)。

Step 4：Build Mixture of Experts Based Model (MEBM)

本研究建立兩種混合專家模式，第一種混合專家系統係針對各群分別建立預測模式，總計建立 8 個類神經預測模型。第二種混合專家系統則以各群平均旅行時間做為該群之預測結果。經由上述步驟完整建構分群、分類與混合專家系統等模式。隨後針對測試資料進行驗測，以此模擬實際應用下模式之預測能力。

3.4 方法三

為建構一同時適用於非重現性擁擠下之旅行時間預測模式，且在現有設備下提升預測能力並獲得關鍵地點之影響變數，以供管理單位於設備維運時，有一明確之管理目標，則必須重視下列關鍵問題(1)如何收集重要變數以反映車流特性。(2)如何避免增加興建設備成本。(3)如何於複雜與非線性之車流特性中，找出關鍵偵測設備與相關變數。(4)如何於複雜與非線性之車流特性中建立一準確預測模式。為解決上述問題，本研究發展整合分群分類為基之預測方法(Integrated Clustering-Classification Method, ICCM)，結合 *K*-means、CART 與 ANN 模式，並透過圖 11 之預測流程達成上述目標。以下針對相關步驟說明如後。

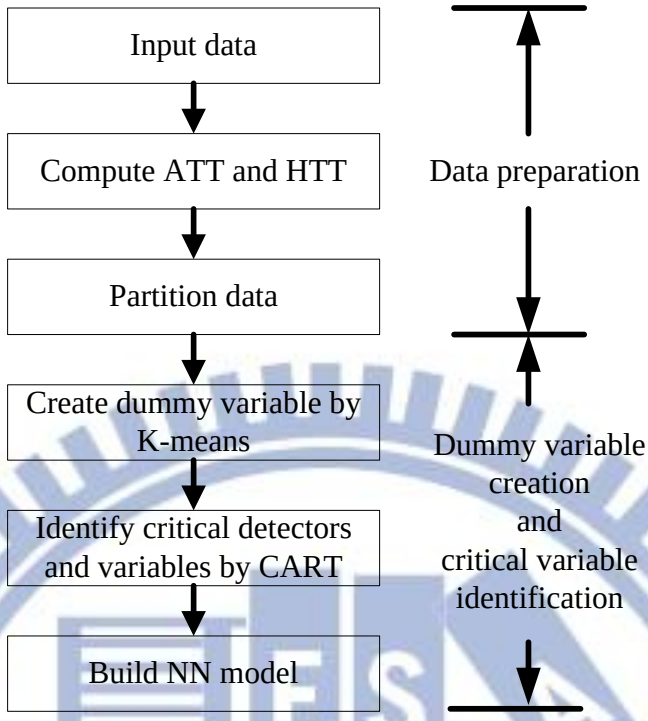

圖 11 ICCM 旅行時間預測流程

Step 1: Input data

首先透過 NNBM 決定重要變數，並將該變數作為輸入變數。輸入變數共包含現點速率、大型車流量、雨量、星期、時間等。另外透過蒐集 ETC 車輛之 ID 與扣款時間等原始資料進行 ATT 與 HTT 之計算。此外，本研究提出創新架構，結合 *K*-means 與 CART 等模式進一步決定虛擬變數，並且探勘重要偵測器與關鍵變數(critical variables)。相關預測程序將於下列步驟中進行說明。

Step 2: Compute ATT and HTT

本研究蒐集高速公路用路人經過 ETC 系統之扣款時間，經由 Southwest Research Institute (SwRI, 1998)與 Transmit (Mouskos *et al.*, 1998)所發展之演算法，即可算得 HTT 與 ATT。Southwest Research Institute (SwRI, 1998) 針對 AVI 系統計算旅行時間之方式，共發展出 TransGuide and TranStar 等兩種演算法。此兩種模式皆以滾動平均演算邏輯(rolling average algorithm)概念自動計算符合門檻值下之旅行時間。式(3)為 SwRI

algorithm 計算旅行時間Ctt_{ABt}之集合

$$Ctt_{ABt} = \{t_{Bi} - t_{Ai} | t - t_r \le t_{Bi} \le t \; and \; Btt_{ABt}(1 - l_{th}) \le t_{Bi} - t_{Ai} \le Btt_{ABt}(1 + l_{th})\} \quad (3)$$

式(3)用以估算車輛通過 2 個 AVI readers 間之旅行時間，即上游 A 點t_{Ai}與下游 B 點t_{Bi}。然而為避免不正常旅次(彎繞、停車)之資料影響旅行時間之估計。當車輛i通過 AB 路段之旅行時間($t_{Bi} - t_{Ai}$)超過門檻值(link threshold parameter, l_{th})時，則不將該旅次之資料列入計算。TransGuide and TranStar 等兩種 algorithms 皆將門檻值l_{th}設為 0.2，即當車輛 i 之旅行時間，低於或超過前一次平均旅行間Btt_{ABt}之 20%時，則視為不正常旅次，因此不列入計算。另外，TransGuide algorithm 將觀測時窗t_r設為 2 分鐘，即只計算 2 分鐘內所有旅次旅行時間之平均(如式 4 所示)。然而，TranStar algorithm 則有別於 TransGuide algorithm 固定時窗之概念，只要 AVI readers 獲得新旅行時間樣本，則同步更新旅行時間集合並計算平均旅行時間(Dion, 2006)。

$$Ott_{ABt} = \frac{\sum_{i=1}^{|Ctt_{ABt}|}(t_{Bi} - t_{Ai})}{|Ctt_{ABt}|} \quad (4)$$

Transmit algorithm 之計算邏輯與 TransGuide and TranStar 等兩種 algorithms 計算方式非常類似。主要不同點在於，Transmit algorithm 並非採用滾動平均演算邏輯概念計算符合限制條件下之旅行時間，而是固定計算 15 分鐘內之旅行時間。即於每個固定時間間隔 s，蒐集兩個 AVI readers 之旅行時間樣本 ns，且上限為 200 個樣本，並以式(5)計算該時間間隔內之旅行時間Ott_{ABS} (Mouskos *et al.*, 1998)。

$$Ott_{ABS} = \frac{\sum_{i=1}^{|n_s|}(t_{Bi} - t_{Ai})}{|n_s|} \quad (5)$$

另外，由每 15 分鐘計算一次之旅行時間資料庫，再透過式(6)可進一步推估真實旅行時間(Actual Travel Time, ATT) Att''_{ABS}。

$$Att''_{ABS} = \alpha * Htt_{ABS} + (1 - \alpha)Att''_{ABS-1} \quad (6)$$

即S期之歷史旅行時間Htt_{ABS}與$S-1$期所算得之真實旅行時間Att''_{ABS-1}，經平滑參數

α調整後，即可推估S期之真實旅行時間Att''_{ABS}。然而，為了避免因事件所引發之非重現性擁擠特性影響歷史資料庫所代表之正常車流狀況，因此該旅行時間之歷史資料庫，不包含事件發生後之旅行時間資料。由此可知，Transmit algorithm 適用範圍侷限於無事件發生時，且車流狀況變化較為穩定，另外，現況旅行時間與歷史資料成線性變化之地區。不可否認的，雖然歷史旅行時間資料可反映若干車流狀況，然而，由於事件發生具有隨機性，且複雜之交通狀況難以用線性方程式準確反應其特性。因此本研究除透過 AVI 之旅行時間演算法，計算 ETC 資料庫內之 HTT 與 ATT 旅行時間，並融合 ETC 歷史旅行時間外，亦透過 ANN 模型，針對複雜且非線性交通特性，發展一穩健之預測模式。

研究當時 ETC 系統主要採用固定費率而非里程計費，且因系統營運之初，僅紀錄車輛於收費站之扣款時間與金額，致使營運初期無法計算路段旅行時間。由於旅行時間資訊對用路人與管理者而言，皆屬一重要且有參考價值之資訊。因此現皆段 ETC 系統於車輛第一次扣款時即給予一組 identity (ID) number，且旅行時間樣本之取樣邏輯與 SwRI algorithms 相同。當該車輛之旅行時間超過該路段前一次時間間隔平均旅行間門檻值時，則判斷為非連續旅次，並給予另一組 ID。本研究蒐集 ETC 車輛通過楊梅收費站北上至林口收費站之扣款時間與車輛 ID。總計蒐集 1,679,868 筆有效樣本資料，並透過 Transmit algorithm 計算每 5 分鐘之 HTT 與 ATT，且 t 時點內並無針對樣本數做限定(及鬆弛 200 個樣本為上限之限制)。有關 AB 路段於 t 時點之歷史旅行時間(HTT_{ABt})計算方式如式(7)所示。

$$HTT_{ABt} = \{t_{Bi} - t_{Ai} | t - t_r \le t_{Bi} \le t \text{ and } Btt_{ABt}(1-0.4) \le t_{Bi} - t_{Ai} \le Btt_{ABt}(1+0.4)\} \quad (7)$$

於式(7)中可知，所謂歷史旅行時間(HTT_{ABt})之計算方式，係以車輛 i 通過 B 點之時間(t_{Bi})做為判斷標準，並蒐集某 5 分鐘內通過 B 點之所有車輛數作為樣本，並以 B 點 t 時點內之車輛 ID 做為比對樣本，進一步比對通過 A 點之所有車輛 ID 號碼，具備相同 ID 號碼者則擷取 i 車通過 A 點之時間(t_{Ai})資料。透過上游 A 點與下游 B 點之時間差即可計算出該路段之歷史旅行時間(HTT_{ABt})。由式(7)中亦可得知，本研究所設定之門檻值為 0.4(40%)。此門檻值為高速公路局依照實際經驗所決定之數值。雖然 HTT 並無法代

表該路段 ATT，然而 HTT 仍反映該路段之車流特性。因此本研究亦將HTT_{ABt}作為 ICCM 預測模式之輸入變數。

有關 AB 路段於 t 時點之真實旅行時間(ATT_{ABt})計算方式如式(8)所示。

$$ATT_{ABt} = \{t_{Bi} - t_{Ai} | t - t_r \le t_{Ai} \le t \text{ and } Btt_{ABt}(1 - 0.4) \le t_{Bi} - t_{Ai} \le Btt_{ABt}(1 + 0.4)\} \quad (8)$$

於式(8)中可知，所謂真實旅行時間(ATT_{ABt})之計算方式，係以車輛 i 通過 A 點之時間(t_{Ai})做為判斷標準，並蒐集某 5 分鐘內通過 A 點之所有車輛數作為樣本，並以 A 點 t 時點內之車輛 ID 做為比對樣本，進一步比對通過 B 點之所有車輛 ID 號碼，具備相同 ID 號碼者則擷取 i 車通過 B 點之時間(t_{Bi})資料。透過上游 A 點與下游 B 點之時間差即可計算出該路段之真實旅行時間(ATT_{ABt})。另外有關連續旅次之判斷，其門檻值之設定與式(7)相同，接設定為 0.4(40%)。舉例而言，當 t-1 時刻於 AB 路段之平均旅行時間為 30 分鐘，則 i 車輛於 t 時刻在 AB 路段之旅行時間必須大於等於 18 分鐘或小於等於 42 分鐘才會被視為是連續旅次，並納入平均旅行時間之計算樣本。在本研究中，HTT_{ABt}與ATT_{ABt}之門檻值採用高速公路局之校估值皆設定為 0.4，然而在不同地區須對此門檻值做重新校估，以符合該地區之實際狀況。最後，本研究將算得之真實旅行時間(ATT_{ABt})作為預測模式之目標值。由於本研究之預測目標為真實旅行時間且蒐集百萬筆資料而得，因此本研究之旅行時間預測結果可反映該路段之實際狀況並具備實用性。

Step 3: Partition data

經由步驟 2 之後，隨即以 7：3 之比例將資料區分為訓練組與驗測試組並以此建立預測模式。然而若直接以隨機方式資料以 7：3 方式劃分為訓練組與驗測試組則不適用於包含非重現行擁擠之狀況。此乃因非重現性擁擠之資料存在資料不平衡問題，因此若直接以隨機方式進行資料劃分，則相關資料有可能太過集中於訓練組或驗測組。此將造成建構模式時會發生過度學習或者學習偏誤之情形。為解決此問題，首先將所有樣本資料透過 *K*-means 進行分群，再針對各群以隨機方式將樣本以 7：3 之比例劃分為訓練組

與驗測試組。此方式可確保不同交通狀態皆以 7:3 之比例隨機分配至訓練組與驗測組。藉由避免資料不平衡造成預測模式之偏誤，可進一步確保本研究所建構之旅行時間預測模式符合實際車流狀況。

Step 4: Create dummy variable by *K*-means

透過上述資料處裡過程後，隨即進入本研究所欲克服之問題之一，即在現有設備下提升模式預測能力。毋庸置疑的，提高對車流特性掌握能力與提升旅行時間預測能力有明顯正向關係。一般而言，當車流處於重現性擁擠情況下，會產生週期性之尖、離峰時間。因此，當 t 時刻之交通狀況被判定屬於尖峰或離峰狀態時，則管理者可以準確地預估交通狀況與明確地使用有效的管理策略。此外，以往旅行時間之研究不論是透過模式推導、系統模擬、參數校估與非線性模式之構建等，皆在提升對車流特性解析能力上做努力。由此可知，辨別 t 時刻之車流狀況屬於何種交通特性，將有助於提升預測模式之準確性。再者，蒐集越充分與完整之交通資料越能反映交通特性，例如，每十公里設置一個車輛偵測器與每一公里設置一個車輛偵測器，後者對車流之解析能力較強。然而，增加設備數量所衍伸之建置費用、維護成本等，卻對管理單位造成嚴重之負擔。因此，長久以來，增加設備與提升對車流特性之掌握能力兩者間，已成為一個困難的取捨問題。

面對此困難問題，本研究提出一個方法，以避免增加硬體投資成本並同時提升對車流特性之掌握程度，且期能增進模式預測能力。本研究透過分群技術創造虛擬變數以達到上述目標。由於分群結果即反映該樣本特性。因此，本研究透過 *K*-means 方法針對訓練組進行分群，且於輸入變數中增加一虛擬變數，以代表該筆資料之分群代號，並以此建構旅行時間預測模式。其次，為模擬該預測模式於即時資料更新下之實際應用情形。首先，針對訓練組之分群結果進行分類模式之構建。其次，透過上述建構之 CART 模式，針對驗測組中所有樣本進行分類，以判別該樣本屬於何種集群編號(例如，第 1 群、第 2 群等)。再者，於輸入變數中之虛擬變數欄位標註分群編號。最後，利用經由訓練組所建構之旅行時間預測模式，針對驗測組內之樣本所代表之交通狀況進行旅行時間預測。

上述訓練組係模擬歷史資料，驗測組則模擬即時資料之應用情形。綜合以上所述，有關虛擬變數產生過程如圖 12 所示。

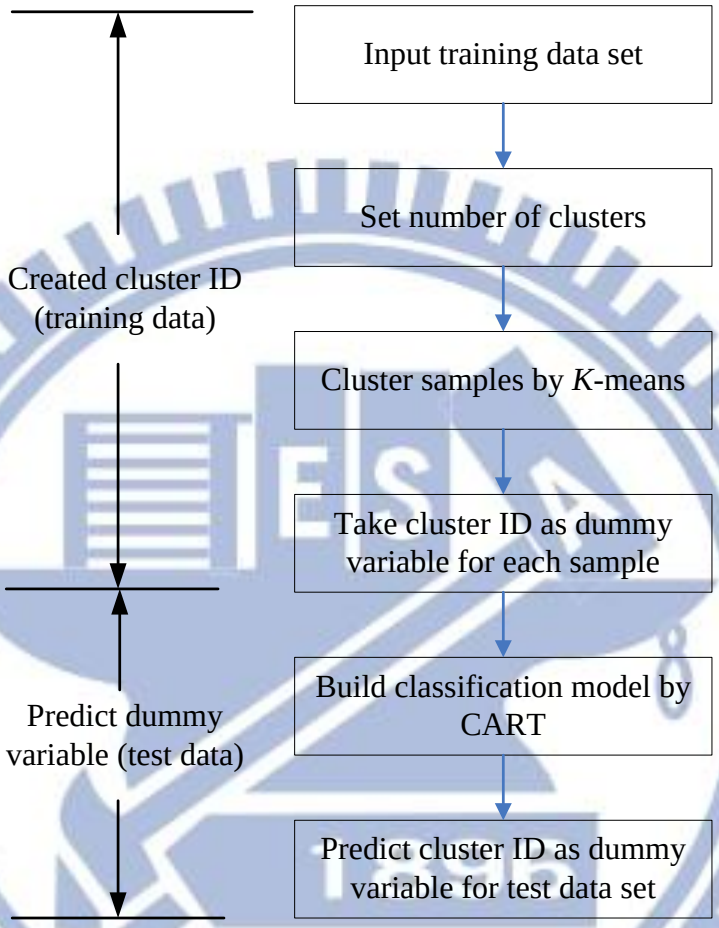

圖 12 創造虛擬變數之流程

Step 5: Identify critical detectors and variables by CART

本研究另一個研究重點，即在非線性車流特性中，找出解析車流特性之關鍵偵測器與變數。使管理單位在獲得明確維運目標之同時，亦能降低硬體設備之投資成本與提高模式應用時機。相較於用人工調查而言，透過設備收集資料雖然具備長時間蒐集與誤差較易控制優點，然而卻無法避免資料遺漏的問題。因此，為確實掌握車流車性，有許多學者(Zhong *et al.*, 2004; Raj and Stern, 2005; Cerisara *et al.*, 2007; Demange *et al.*, 2009; Lederman and Wynter, 2011)針對遺漏值處理進行研究。然而，就高速公路旅行時間預測

而言，以往研究較少針對關鍵地點與關鍵影響變數兩個問題進行探討。舉例而言，若能得知 A 偵測點之雨量資料、B 偵測點之現點速度、C 偵測點之大型車流量等不同偵測點之變數，為解析研究範圍內車流特性之關鍵變數，且運用此關鍵變數進行旅行時間預測並能同時維持預測準確度，則管理者不僅可明確地掌握重點維運目標，亦可針對特定偵測點之特定變數發展遺漏值填補方式。此外，亦同時具備減少設備投資、降低維運成本與提升模式應用時機效益。

有鑑於此，本研究透過整合資料探勘之決策樹方法與旅行時間預測模式達成上述目標。一般而言，CART 產生的分類規則決定新受測樣本之分類情形。因此，出現於每條規則之變數即代表判別樣本特性之關鍵變數。因此，本研究先以 CART 萃取出關鍵變數，再以該特定地點之特定變數作為旅行時間預測模式之輸入變數以此建構預測模式。最後以 test data set 驗證僅採用關鍵變數所建構之預測模式之預測能力。以此解決現階段管理單位所關切之問題，同時提升模式適用範圍。

本研究萃取關鍵變數之演算過程，係透過(1)蒐集現況重要變數資料後，建立歷史資料即為本研究中之訓練組；(2)以 *K*-means 針對訓練組進行分群；(3)將訓練組內各樣本之分群編號設定為預測目標；(4)以 CART 建構分類模式；(5)將出現於決策樹內之變數視為關鍵變數，並以此關鍵變數構建 ANN 旅行時間預測模式。藉由此預測模式即可針對現況資料進行即時預測，並運用於資訊發布或交通管理上。上述演算步驟如圖 13 所示。

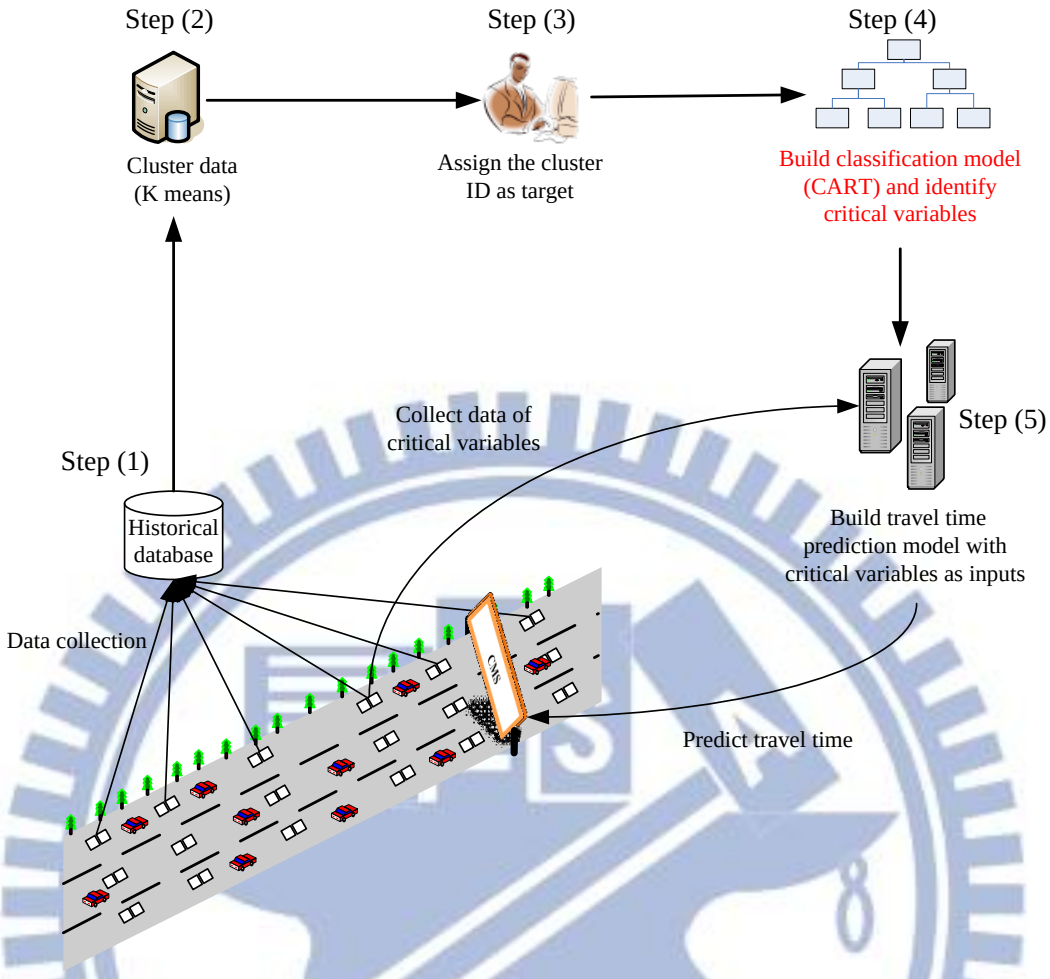

圖 13 關鍵變數萃取與旅行時間預測模式構建之過程

Step 6：Experimentation

經由上述資料分析、虛擬變數之新增及關鍵變數之萃取步驟後，隨即針對不同變數組合進行實驗設計與績效分析。為了解在含非重現性擁擠之交通特性下，歷史旅行時間、虛擬變數、關鍵變數對模式預測能力之影響程度。本研究共設計 6 種實驗組合，並以 ANN 之三層架構建構預測模式。再者，每一實驗組合皆以訓練組建構最佳 ANN 預測模式，之後再以此最佳預測模式透過驗測組之樣本模擬未來實際應用情形。本研究以 MAPE 值做為績效指標並以此進行結果分析。針對每一實驗組合最佳 ANN 預測模式之決定方式，係經由反覆測試不同隱藏層單元數，並以 RMSE 做為績效指標。當測試結果具有最小 RMSE 時，則該模式即視為該實驗組合之最佳預測模式。

本研究以 SAS Enterprise Miner 5.3 版，構建 input-hidden-output 架構為 3 層之 BPN

模型。另外，基於隱藏層單元個數為影響模式預測能力之重要參數。因此，在共同參數設定下，本研究針對不同隱藏層單元數進行測試，其中選定 RMSE 值最低者，作為該實驗組合之最佳預測模式。最後，以驗測組進行測試分析。

第四章 資料分析

經由上述章節確定研究範圍與研究架構後，則針對資料進行蒐集與分析。本章針對資料蒐集情形、雨量資料、VD 穩定度、遺漏值填補等內容說明於 4.1 節內之各小節。此外，由於本研究範圍涵蓋事件發生下之樣本，因此進一步針對研究期間內之肇事資料與非重現性擁擠特性等內容說明於 4.2 節內之各小節。

4.1 資料前處理

4.1.1 資料蒐集

若要提升複雜車流特性地區之旅行時間預測能力，則蒐集重要變數以有效解析車流特性，同時確保資料來源可靠度，即成為必須面對且解決之課題。由許多旅行時間預測研究發現，現點速度、雨量、HTT、星期與時間等屬性(Yuan *et al.*, 2003; Chang, 2005; Wei *et al.*, 2007; Yeon *et al.*, 2008; Fei *et al.*, 2011)皆為提升旅行時間預測模式能力之重要變數。

中山高速公路為台灣西岸主要城際運輸走廊，全線共長 373 公里，並有 20 個收費站。本研究主要針對該高速公路楊梅收費站與泰山收費站間北上方向，蒐集 2009 年 9 月 16 日至 10 月 16 日間 VD、ETC、肇事與雨量等資料。由圖 14 可知，本研究範圍內共包含 6 個交流道與 2 個系統交流道，研究範圍長達 36.1 公里。另外依照台灣區國道高速公路局 2009 年 9 月至 10 月之統計資料顯示，楊梅收費站與泰山收費站於此兩個月內之平均每日交通量分別為 111,938 與 224,957 輛，大約佔整體中山高速公路平均每日交通量之 23.5%。由此可知，本研究範圍係為台灣中山高速公路中最繁忙之路段。

本研究透過台灣區國道高速公路局交通控制中心資料庫，蒐集雙線圈偵測器每 5 分鐘之速度與大型車流量等資料(共計 22 個 VDs)，並蒐集 ETC 使用者之原始扣款時間；雨量資料來自於中央氣象局資料庫(共計 3 處雨量偵測器資料)，另外，事故之資料則來自於國道高速公路警察局肇事資料庫。上述三個資料庫係由台灣政府單位所建置，並長期蒐集最完整與即時之資料，以供資訊發布、管理與研究使用。

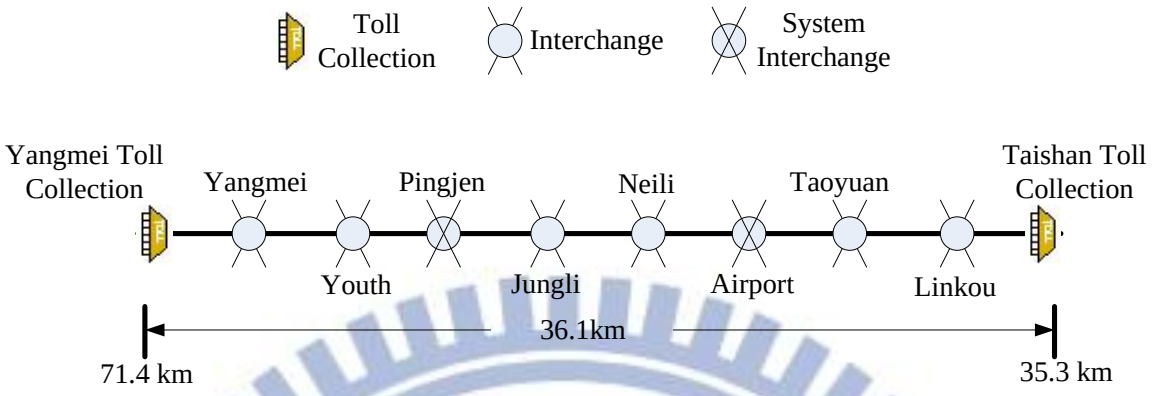

圖 14 研究範圍示意圖

4.1.2 雨量資料

Konstantopoulos *et al.* (2010)指出，下雨不僅影響駕駛者視線，亦會提高行車風險並為影響肇事發生之重要變數。由於雨量多寡不僅影響駕駛行為，更為影響交通特性之重要因素。因此於研究旅行時間之議題上，針對下雨天數與下雨量皆較高之地區，雨量大小為一重要且必須考量之變數。台灣是海島型氣候國家，致使降雨天數與降雨量皆有較高之趨勢。本研究範圍位於台灣北部地區，依據中央氣象局統計全球 55 個主要城市之降雨資料顯示，台北市每年平均下雨量超過 0.1 毫米之天數為 168 天。僅較雅加達 187 天，奧斯陸 174 天，斯德哥爾摩 173 天等三個城市低，然而年降雨量 2325 毫米卻位居全球 55 個主要城市之冠。鑑此，本研究蒐集楊梅、桃園、林口等 3 處之雨量偵測器資料，作為建構旅行時間預測模式之變數。由於現有雨量統計資料係以 10 分鐘作為基本單位，為能針對 5 分鐘旅行時間進行預測，本研究以算術平均之方式，將雨量資料之基本單位整理成 5 分鐘，並以此進行模式構建。

4.1.3 VD 穩定度

本研究蒐集研究範圍內所有雙線圈 VD 資料，共計 22 處。然而資料可信度是建構模式最重要且基本之要求。透過選定穩定度高之 VD，除可進一步確保資料可信度外，亦可提高模式之適用性。本研究針對 VD 所蒐集之資料，當連續遺漏超過 2 小時以上者，

則視為不穩定之 VD，且不作為建構模式之變數。最後共計選定 11 處穩定度較高之 VD 作為建構模式之用。本研究各區段 VD 之蒐集與採用數量如圖 15 所示。

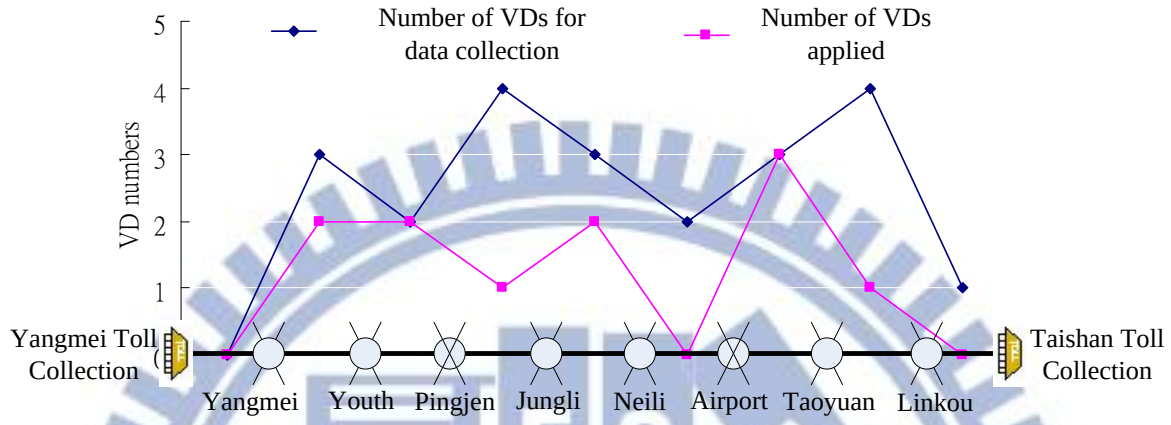

圖 15 各區段 VD 之蒐集與採用數量

4.1.4 遺漏值填補

以自動化設備蒐集資料之方式，雖具有長時間蒐集、大範圍調查與誤差較小且具一致性等優點，然而由於例行檢修、施工、電纜失竊、天候及許多不可抗力等因素，造成系統故障與穩定度不佳等情形發生，進而難以避免產生資料遺漏問題。由邱孟佑(2010)之研究指出，以時窗之概念可將遺漏值之發生情形歸納為三種情況。(1)隨機單一時窗遺漏值，(2)數個時窗發生短暫遺漏值，或(3)單一偵測器在一段期間內持續數個時窗遺漏值。Little and Rubin (1987)提出 4 種遺漏值填補方式，(1) 忽略處理，即不採用該筆資料。(2) 加權處理，依據自變數給予不同權重，其中權重可來自於專家判斷。(3) 模式處理。(4) 插補處理，透過依時性關係進行資料填補。此外，就填補方法而言，Fernandez *et al.*(2008) 提出 3 種填補方法，分別為 (1) ARIMA 時間序列，(2)歷史時窗均值及(3) 往前滾動平均等 3 種方法。Van Lint *et al.* (2003) 則採用移動平均法進行填補且獲得良好補值效果。

由於 ETC 資料、現點速率與大型車流量等資料之特性與對本研究預測模式之必要性不同，因此本研究針對 3 種資料之遺漏值採用不同填補方式。本研究彙整遺漏值之填

補方式可以透過下列 3 種方式：1.以原資料蒐集點不同日期相同時段之歷史資料進行填補，且以距離較近之日期或相同特性者具有較優先之填補順序。2.相同蒐集地點，透過算數平均、簡單加權、指數平滑等方式，依據 t-n 時刻之資料進行 t 時刻之填補。3.以前後蒐集點之資料進行填補，且通常以距離較短、屬於相同群組者，其填補優先順序較高。本研究採用第 3 種方式並以迴歸模式進行現點速度之填補。

由於台灣 ETC 系統於某 t 時刻內有下列原因產生資料遺漏的問題：(1)設備檢修，(2)旅行時間超過 40%之門檻值而判斷為非連續旅次，或(3)無 ETC 車輛通過收費站而導致沒有旅次等情形發生時，即會沒有旅行時間樣本。基於本研究以 ETC 實際旅行時間做為模式訓練(training)、校估(validation)與測試(test)之目標，且 HTT 亦為一重要變數。為避免資料填補之誤差而造成模式訓練結果與實際狀況不符，因此當 ATT 與 HTT 有資料遺漏情形時，則採用 Little and Rubin (1987)提出之第 1 種遺漏值填補方式，直接刪除該 t 時刻之樣本。

另外，當 VD 蒐集資料過程中發生遺漏值時，可歸納成三種情況且需要依照個別情況進行填補。Case 1，單時窗遺漏，即 t-1 時段有值，然 t 時段發生遺漏情形。Case 2，多時窗遺漏且前後 VD 皆未發生遺漏情形，即 t-1 與 t 時段皆發生遺漏情形，然而前後 VD 皆未發生遺漏情形。Case 3，多時窗發生遺漏值且前後有 VD 發生遺漏值，即 t-1 與 t 時段皆發生遺漏值，且前後有 VD 亦發生遺漏值。值得注意的是，本研究針對大型車之填補方式，係以需要填補之 VD 前半小時內，行駛速度與本次填補速度最相近之該時刻，所測得之大型車流量進行填補。此乃考量不同觀測點 VD 偵測品質不一致及車種組成特性不同等因素之影響，因此由同一觀測點之歷史資料進行填補不失為反映該觀測點車流特性之有效方法。綜合以上所述，本研究針對上述三種情境，將其填補步驟說明如下，並將填補流程繪製如圖 16 所示。

Step1：判斷是否為 Case 1。若是，則進入 Step 2。若否，則進入 Step 4。

Step2：搜尋$VD_j(t-1)$時刻之速度$Speed_j(t-1)$與大型車流量$HVV_j(t-1)$。

Step3：$VD_j(t)$時刻之速度 Speedj(t)等於$VD_j(t-1)$時刻之速度 $Speed_j(t)$。VDj t 時刻之大型車流量$HVV_j(t)$等於$VD_j(t-1)$時刻之大型車流量$HVV_j(t-1)$，並

進入 Step 17。

Step4：判斷是否為 Case 2。若是，則進入 Step 5。若否，則進入 Step 12。

Step5：紀錄 t 時刻有值之VD_j，即$\{VD_j(t) > 0\}$。

Step6：選擇相同群組 K 且有值之 VD 做為填補對象，$\{VD_j^k > 0\}$。

Step7：VD_j與VD_m距離較近者，有優先之填補順序，(i.e., min distance (VD_j, VD_m))。

Step8：以選定之VD_m與VD_j前一小時之速度資料建立線性迴歸式(Linear Regression Model, LRM)。依 LRM 模式填補VD_j於 t 時刻之速度，$Speed_j(t)$，$Speed_j(t) = a + b \times speed_m(t)$。

Step9：尋找VD_j於 t 時刻前半小時內與 t 時刻之速度$Speed_j(t)$相差最小者，$\min\{|Speed_j(t) - Speed_j(t-i)|\}, i = 1,2,\ldots,6$並以該時刻之大型車流量填補 t 時刻之大型車流量。填補大型車流量，$HVV_j(t) = HVV_j(t-i)$。

Step10：如果為 case 2 則進入 step 11，若否則進入 step 15。

Step11：連續填補時間是否超過 2 小時。若是，則停止填補並刪除後續連續遺漏值。若否，則重複 Steps 5-9 直至完成遺漏值填補，並進入 Step 17。

Step12：進入 Case 3。紀錄 t 時刻有值之VD_j，即$\{VD_j(t) > 0\}$。

Step13：判斷相同群組 K 之 VD 於 t 時刻是否有值，$VD_j^k > 0$?。若是，則選擇相同群組 k 且有值之 VD 做為填補對象。若否，則不同群組η且有值之 VD 做為填補對象，$\{VD_j^k > 0\}$，$\eta \neq$ K。

Step14：重複 Steps 7-9。

Step15：判斷 t 時刻內所有發生 Missing Data 之 VD 是否皆完成填補。若是，則進入 Step 16。若否，則填補下個 VD 並重複 Steps 13-14。

Step16：連續填補時間是否超過 2 小時。若是，則停止填補並刪除後續連續遺漏值。若否，則重複 Steps 12-13 直至完成遺漏值填補，並進入 Step 17。

Step17：判斷是否完成最後一筆資料之填補。若是，則完成資料填補之作業。若否，則回到 Step 1。

綜合以上所述，若 VD 之資料遺失情形不符合上述填補情況，則刪除該筆樣本。另

外若某 t 時刻之資料被視為異常值，則刪除該筆資料。有關速度之異常值判斷，基於本研究路段行駛速度超過每小時 120 公里者，才進行違規取締。因此當速度高於每小時 120 公里者，則視為異常值。基於本研究以 ATT 做為模式訓練與驗測模式之預測目標，且 HTT 亦為一重要變數。為避免資料填補之誤差而造成模式訓練結果與實際狀況不符，因此當 ATT 與 HTT 有遺漏資料情形時，則刪除該 t 時刻之樣本。經上述資料前處理步驟後，總計採用 7,908 筆樣本進行模式構建，並以 7：3 之比例將樣本區分為訓練組與測試組。

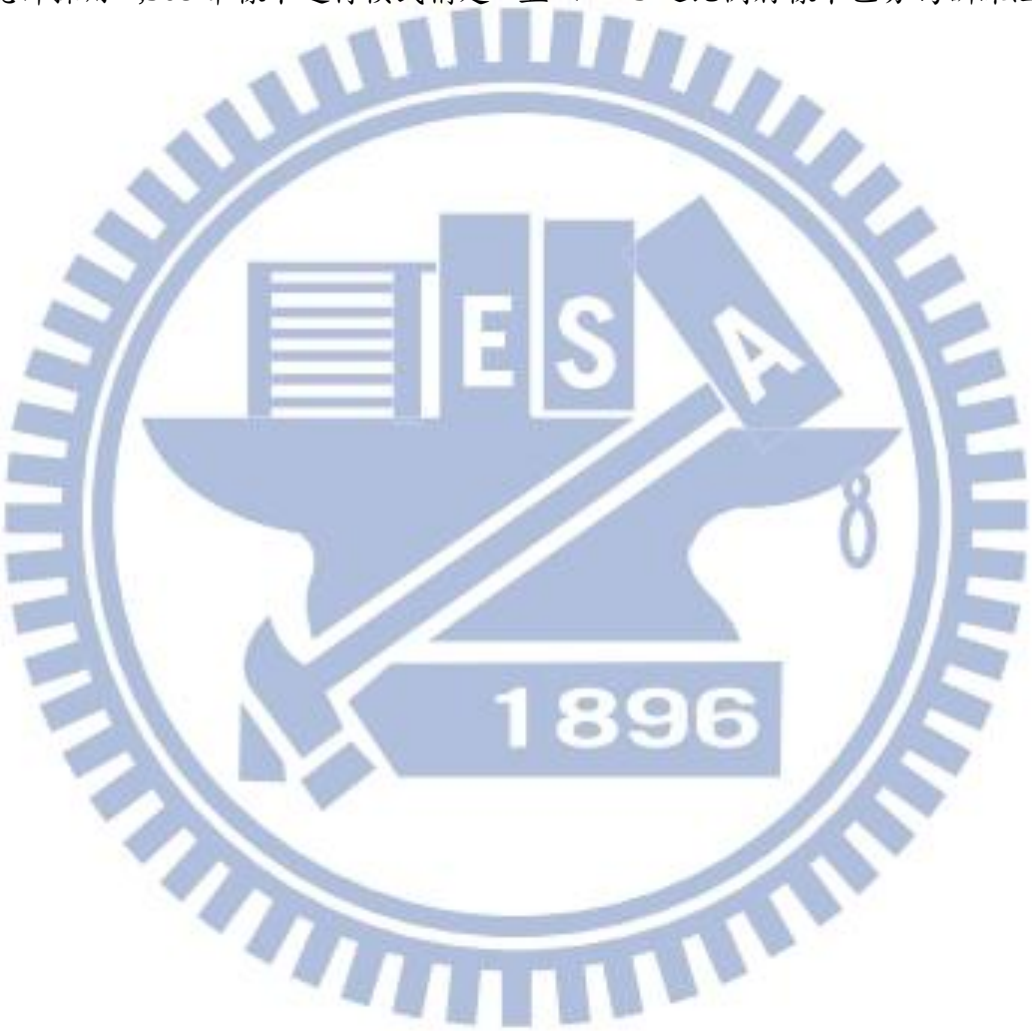

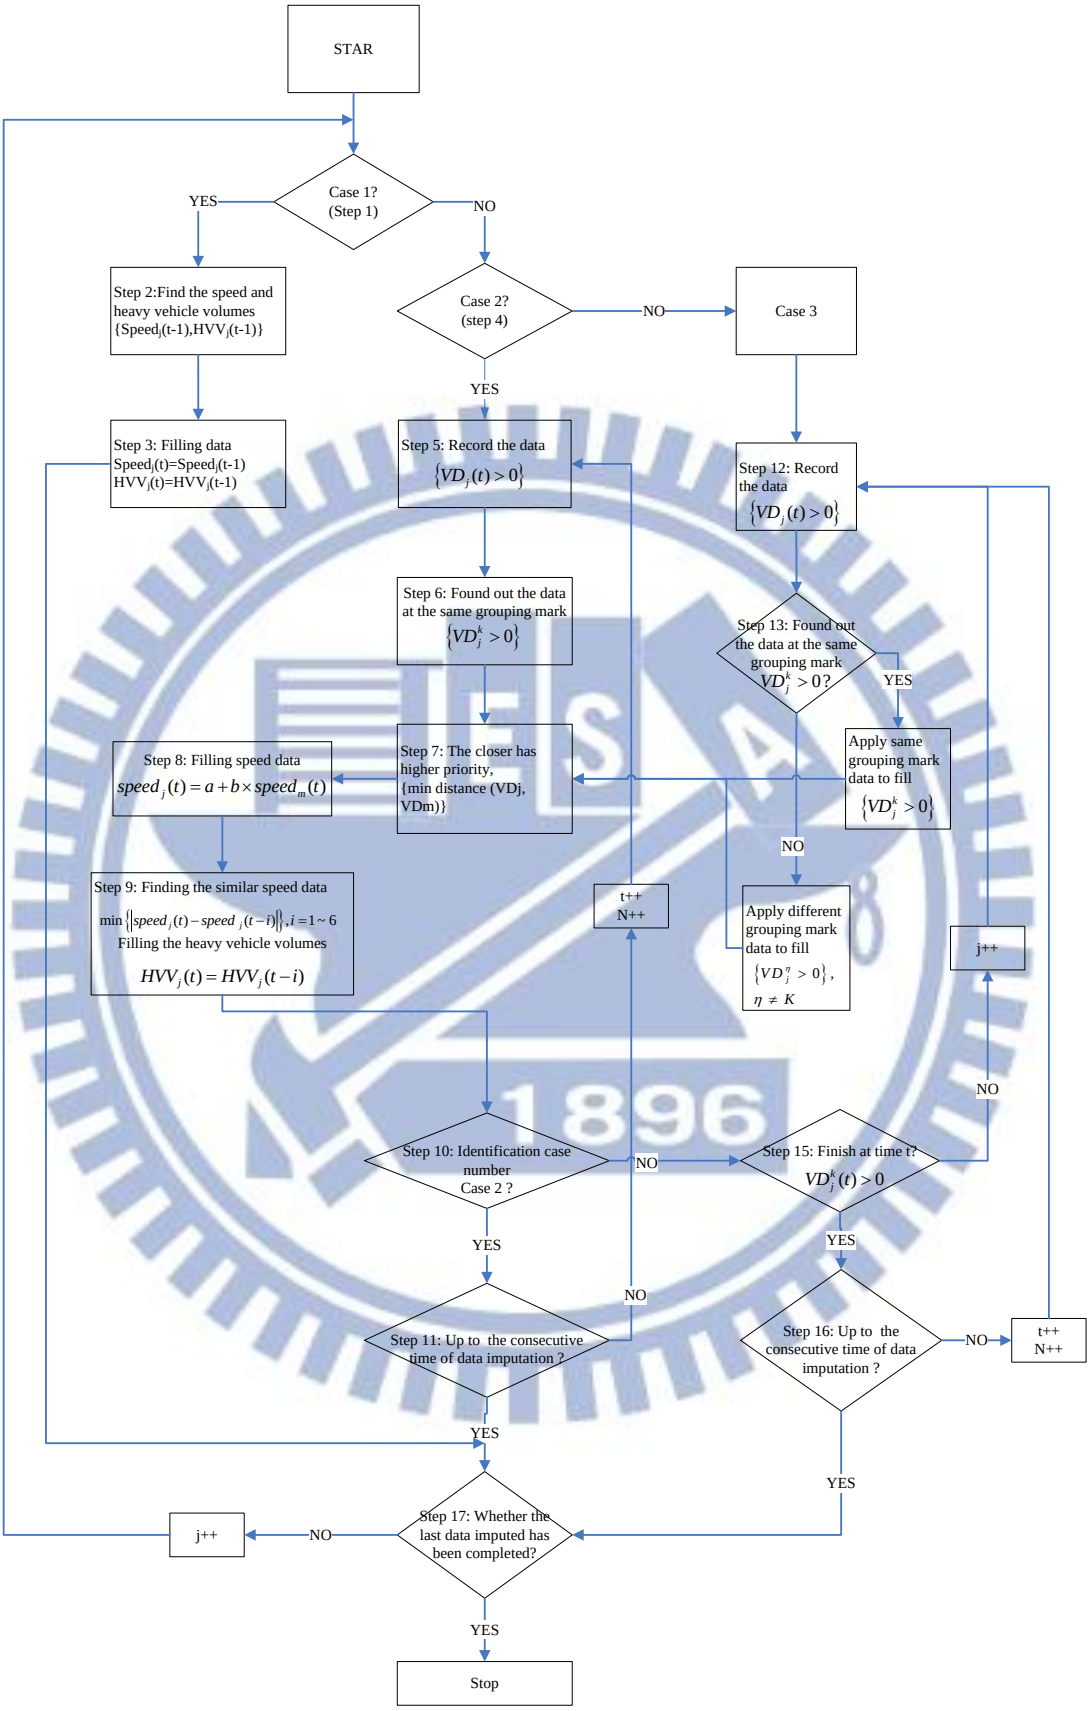
STAR
Case 1?
(Step 1)
YES
NO
Step 2:Find the speed and heavy vehicle volumes {Speed$_j$(t-1),HVV$_j$(t-1)}
Case 2?
(step 4)
NO
Case 3
YES
Step 3: Filling data
Speed$_j$(t)=Speed$_j$(t-1)
HVV$_j$(t)=HVV$_j$(t-1)
Step 5: Record the data
$\{VD_j(t)>0\}$
Step 12: Record the data
$\{VD_j(t)>0\}$
Step 6: Found out the data at the same grouping mark
$\{VD_j^k>0\}$
Step 13: Found out the data at the same grouping mark
$VD_j^k>0$?
YES
Step 8: Filling speed data
$speed_j(t)=a+b\times speed_m(t)$
Step 7: The closer has higher priority, {min distance (VDj, VDm)}
Apply same grouping mark data to fill
$\{VD_j^k>0\}$
NO
Step 9: Finding the similar speed data
$\min\{|speed_j(t)-speed_j(t-i)|\}, i=1\sim 6$
Filling the heavy vehicle volumes
$HVV_j(t)=HVV_j(t-i)$
t++
N++
Apply different grouping mark data to fill
$\{VD_j^\eta>0\}$, $\eta\neq K$
j++
NO
Step 10: Identification case number
Case 2 ?
NO
Step 15: Finish at time t?
$VD_j^k(t)>0$
YES
YES
NO
Step 11: Up to the consecutive time of data imputation ?
Step 16: Up to the consecutive time of data imputation ?
NO
t++
N++
YES
YES
Step 17: Whether the last data imputed has been completed?
j++
NO
YES
Stop

圖 16 遺漏值填補流程

4.2 交通特性分析

4.2.1 事件資料分析

由於事故發生具有隨機性，並且評估事件對車流衝擊程度之相關重要變數，例如，事故發生時間、封閉車道數、事故排除時間等，基於受限通報機制，進而無法獲得準確與即時之資料。因此，如何利用相關即時資訊，發展一即時穩健之旅行時間預測模式，並同時確保預測能力以符合管理者與使用者需求，即為本研究欲克服之重點。總計在本研究時間範圍內共計發生 76 次事件，車損部分共計 176 輛車，且有 6 個人受傷(如表 9 所示)。由統計結果得知，有 96.1%之事件屬於無人傷亡且僅發生車損。另外，值得注意的是，桃園交流道-林口交流道之路段，事件次數雖較中壢交流道-內壢交流道低，然而卻有較高之車損車輛數。由此可知，該路段事件發生後對車流之衝擊程度較大。

表 9 研究範圍內各路段事故次數、受傷人數與碰撞車輛統計

Segment		Number of accidents	Number of injuries	Number of crashed cars
Origin	Destination			
Yangmei Toll Collection	Yangmei	0	0	0
Yangmei	Youth	5	0	10
Youth	Pingjen	9	0	21
Pingjen	Jungli	11	0	23
Jungli	Neili	12	3	24
Neili	Airport	6	0	16
Airport	Taoyuan	8	3	18
Taoyuan	Linkou	10	0	28
Linkou	Taishan Toll Collection	15	0	36

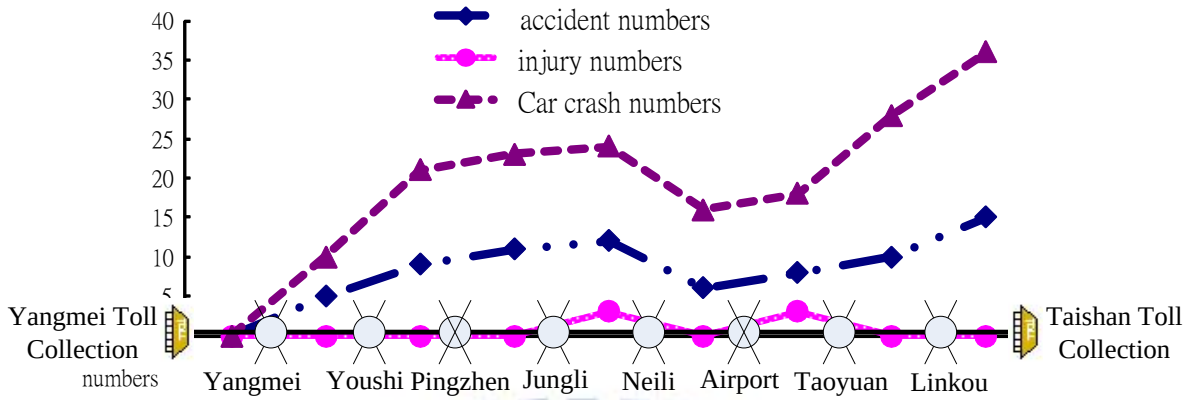

圖 17 事故資料統計

4.2.2 非重現性特性分析

圖 18 為研究路段範圍內每天每 5 分鐘之旅行時間分布圖。由圖 18~25 可知，本研究路段每日約有 1~3 個尖峰時段，且每個尖峰時段持續之長短、開始及結束時間點及尖峰時段內之旅行時間長短皆未盡相同。由圖 18 可知，整體而言，上午尖峰約介於 7~10 點，中午尖峰約介於 1~3 點，下午尖峰約介於 5~9 點。另外，一般而言，我們習慣將星期六與星期日視為假日；星期 2~4 視為非假日，並認為歸納為同屬於假日或非假日之不同日期，其車流狀況有一致之特性。然而由圖 20~22 之上午時段可知，9 月 16 日(星期三)上午並無明顯尖峰，然而 9 月 22 日(星期二)之上午尖峰時間則落於 7：20~11：00。另外，由圖 24~25 可知，就例假日上午尖峰而言，9 月 20 日(星期日) 上午並無明顯尖峰，然而 9 月 26 日(星期六)上午尖峰時間則落於 11：00~13：30。由此可知，不論是平常日或例假日，於本研究範圍內之路段，其尖離鋒時段之變化皆有不同，且不同日期之尖峰個數、尖峰時段長度與開始及結束時間點等變化差異甚大。上述尖離峰特性可於圖 18 中，旅行時間曲面所呈現之起伏與扭轉情況清楚得知。

長路段、高流量、進出口匝道多及降雨頻繁之地區，由於干擾車流順暢行駛之因素較多，致使其車流特性相對較為複雜。並且，於交通特性較為複雜之地區，除容易引發肇事外，亦因肇事與雨量等屬於難以預測之外在因素，導致車流特性變異甚大。圖 26~29 為星期二旅行時間、肇事與雨量綜合圖。當未發生降雨與肇事時，由圖 26(a)10 月 13 日之旅行時間分布情形可知，本研究路段上午尖峰時段約介於 7：00~8：20。然當有降雨

發生時，其尖峰時間皆有延長之情形。以 9 月 29 為例，因上午 5：25~6：40 之漸歇性降雨(如圖 27(b)所示)，使得當日上午尖峰時段改為 7：20~8：50。再者 10 月 6 日上午 7：15~8：50 的漸歇性降雨，亦造成當日上午尖峰時段改為 7：00~9：30。通用汽車(General Motors, GM)第 5 代跟車模式即反應出，當駕駛人受到外在駕駛環境衝擊而改變其加減速行為時，將對整體車流產生往後衝擊現象，且其衝擊程度會經過一段時間後趨於穩定。為了解不同累積降雨量變數(ex: 5 min, 1 hour, 2 hour…etc.)對車流特性之解釋能力，本研究透過實驗設計方式加以探討之。

另外，就本路段星期二下午時段之車流特性而言，在未有肇事發生下，其下午尖峰並不明顯。然而當有肇事發生時，本研究路段之旅行時間確有明顯增加之趨勢。以 9 月 29 日為例，當 15：10~18：45 陸續有肇事發生時(如圖 27(c)所示)，本路段於 16：30~18：45 間隨即形成一尖峰時段(如圖 27(a)所示)。另外， 9 月 22 日上午 10：40~11：27 發生三輛車之肇事，致使上午尖峰時段由 7：15 持續至 11：25。由此可知，肇事與雨量的發生確為非重現性擁擠產生之重要因素之一。由於肇事發生具有隨機性，並且評估肇事對車流衝擊程度之相關重要變數，例如，肇事發生時間、封閉車道數、事故排除時間等，基於受限通報機制，進而無法立即獲得即時資訊。因此，如何在不增加設備，以現有即時資訊發展一含非重現行擁擠下之穩健即時旅行時間預測模式，並同時確保預測能力以符合管理者與使用者需求，即為本研究另一個欲克服之重點。

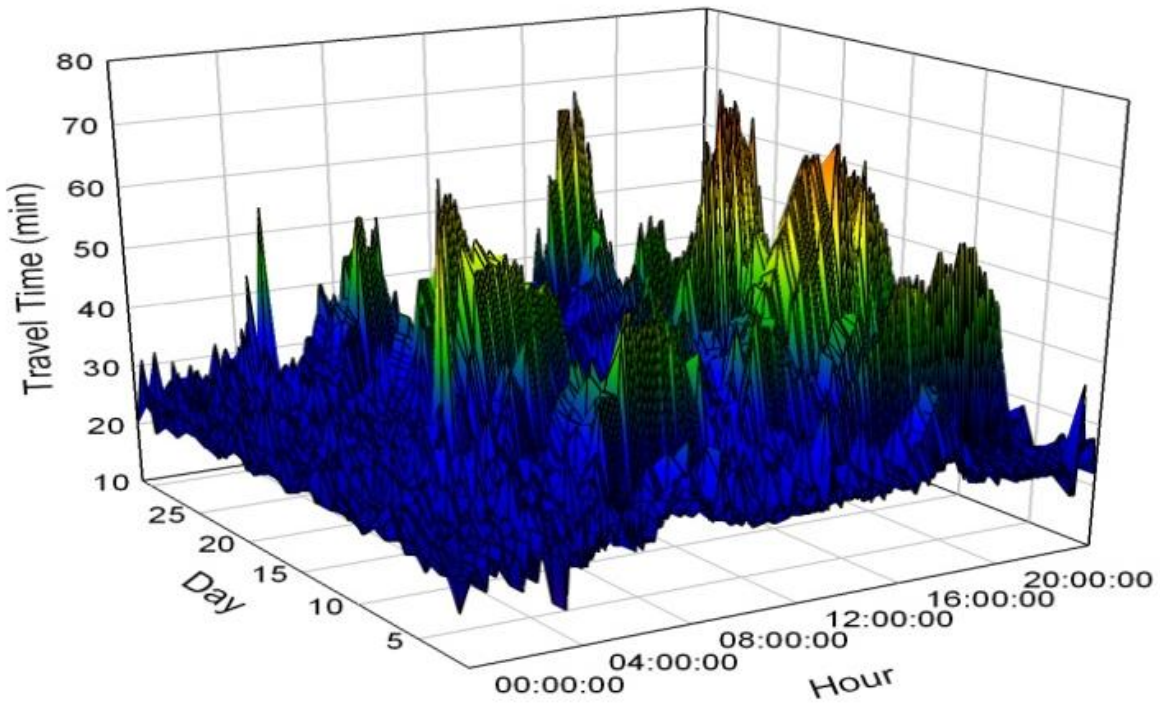

圖 18 所有天數之旅行時間

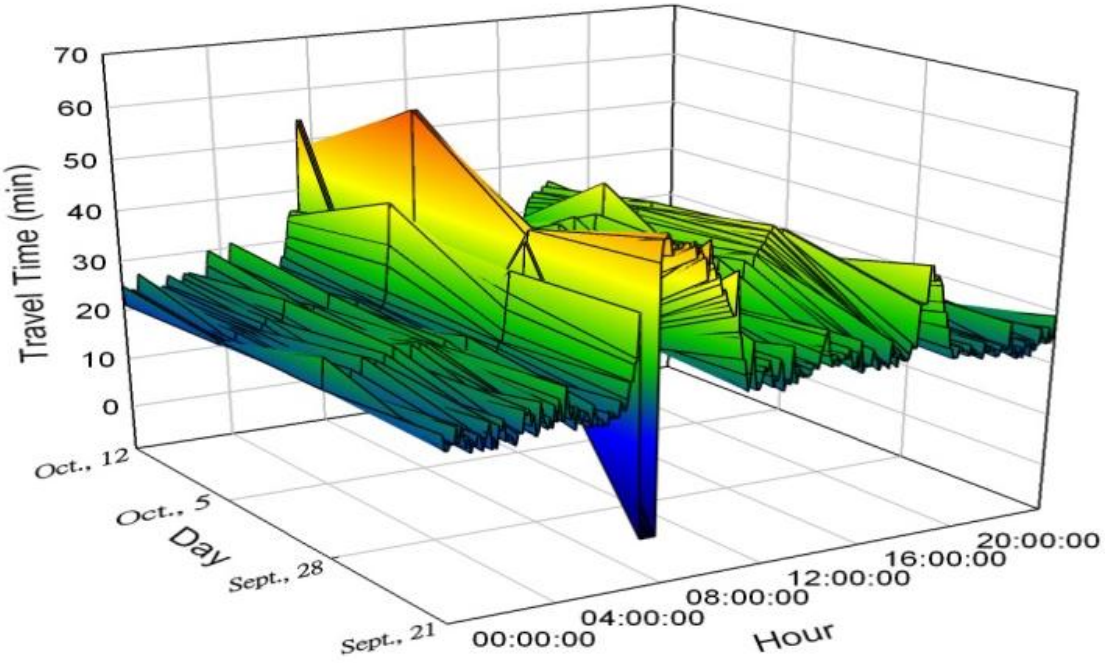

圖 19 星期 1 之旅行時間

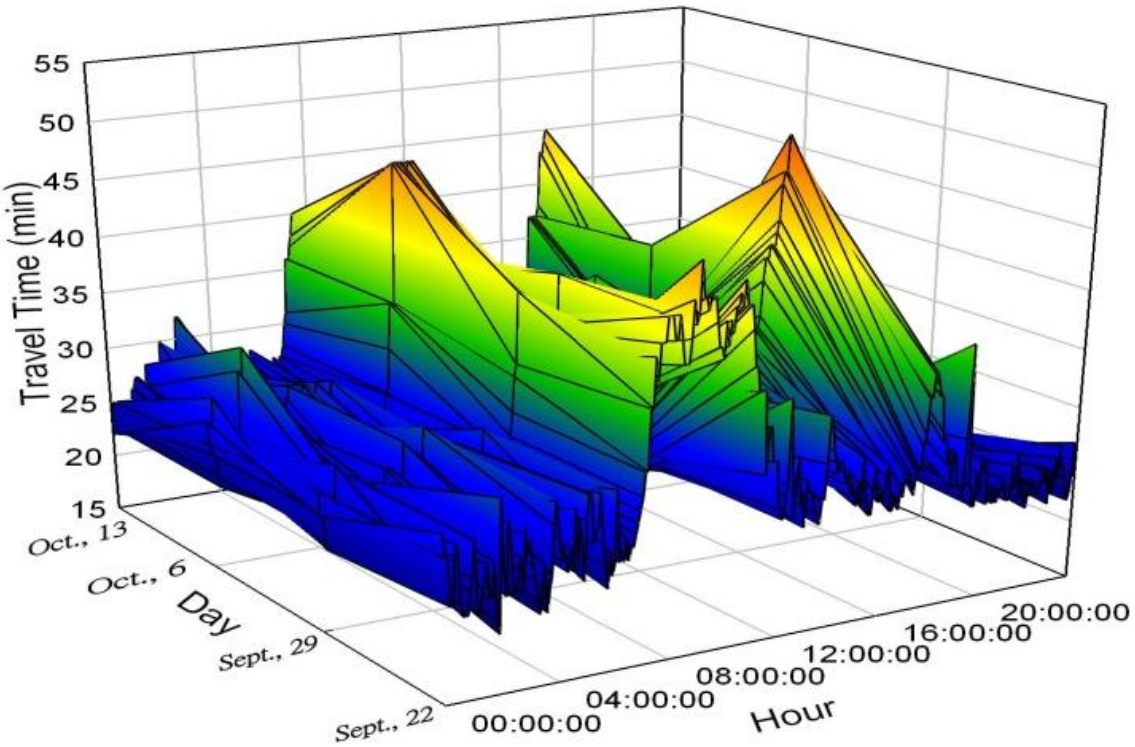

圖 20 星期 2 之旅行時間

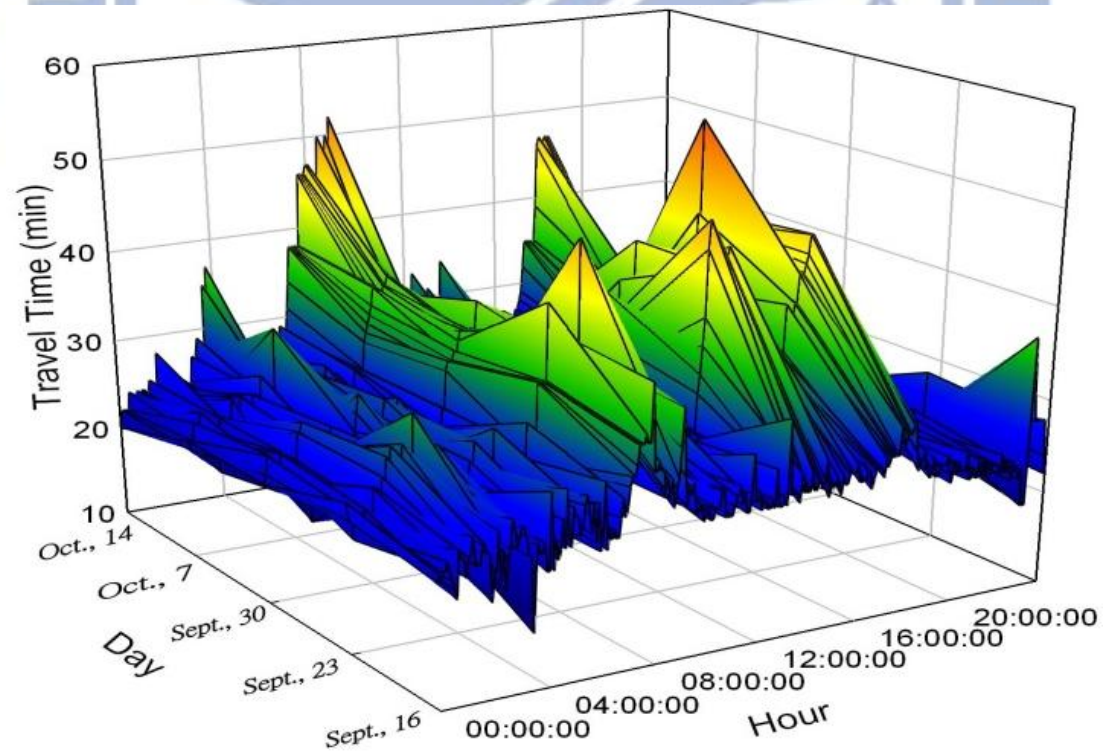

圖 21 星期 3 之旅行時間

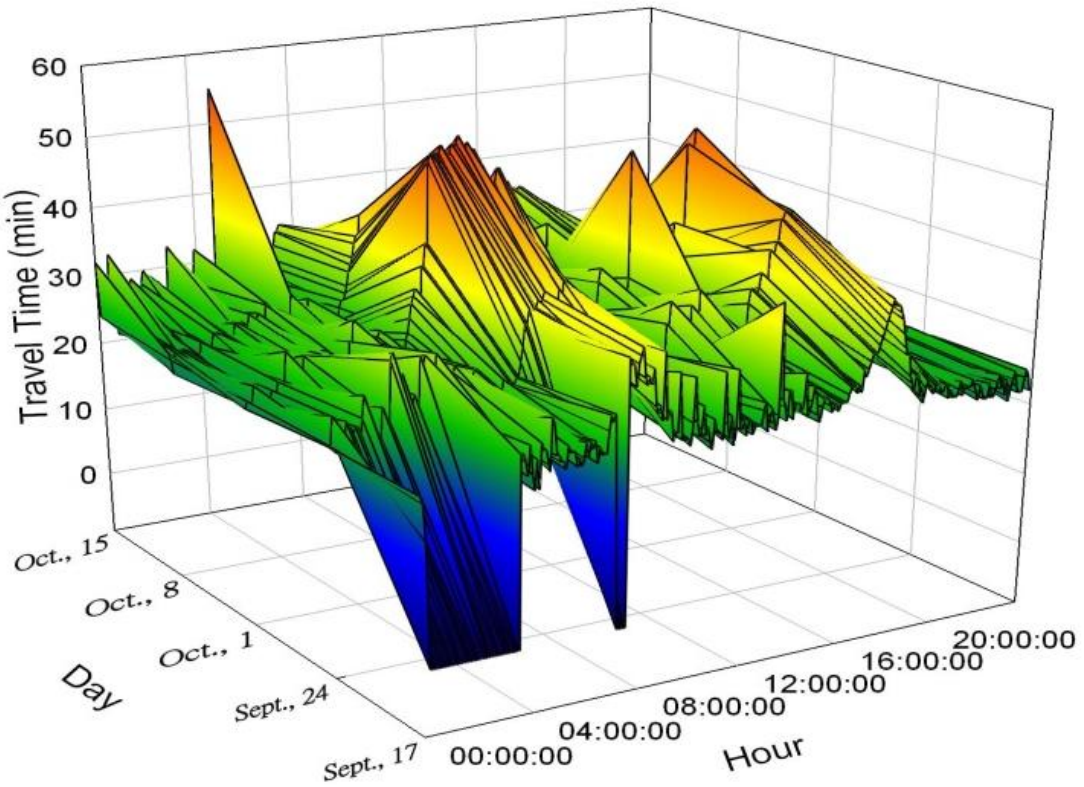

圖 22 星期 4 之旅行時間

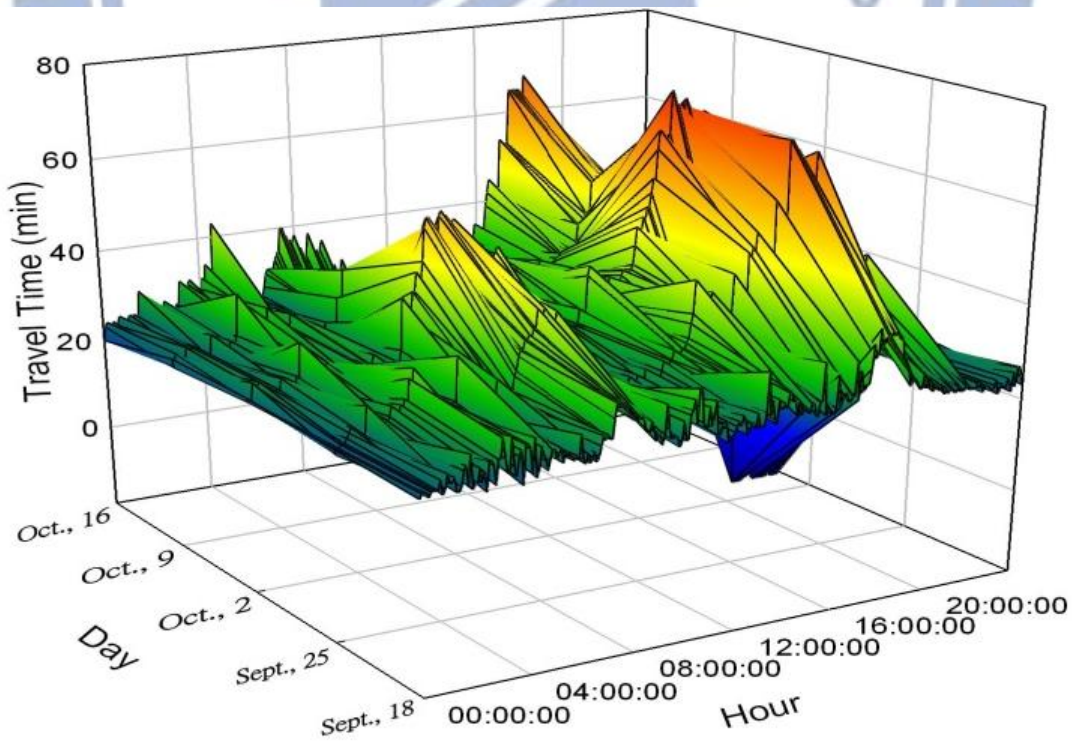

圖 23 星期 5 之旅行時間

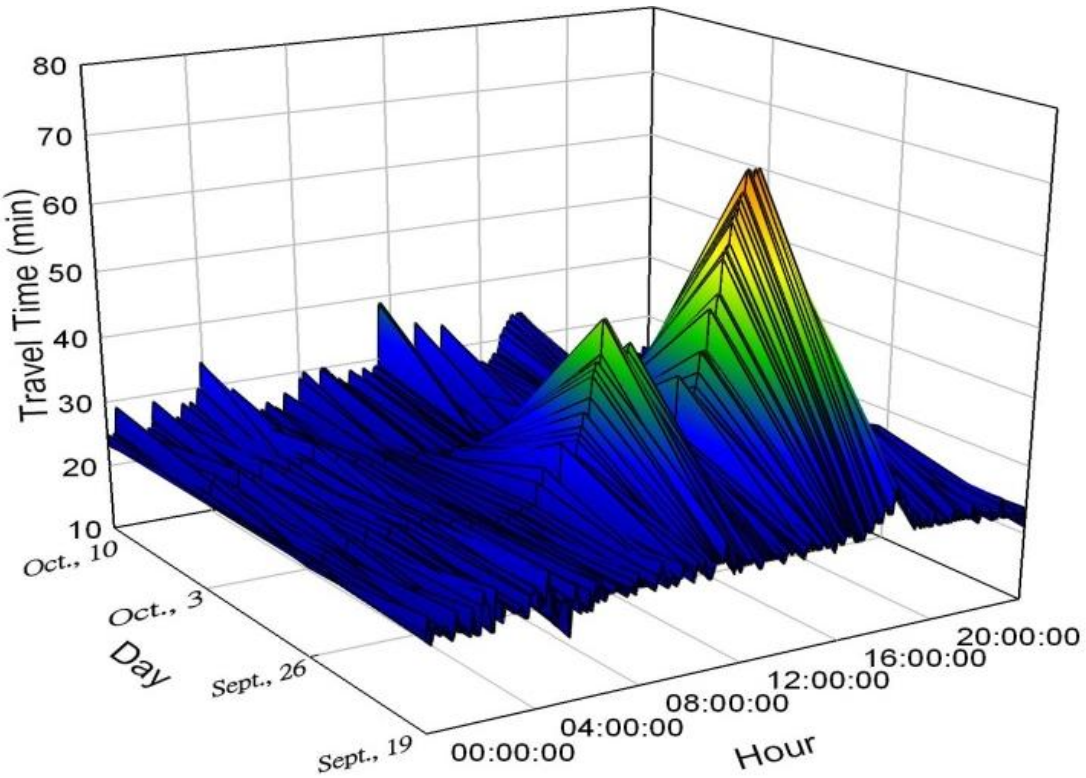

圖 24 星期 6 之旅行時間

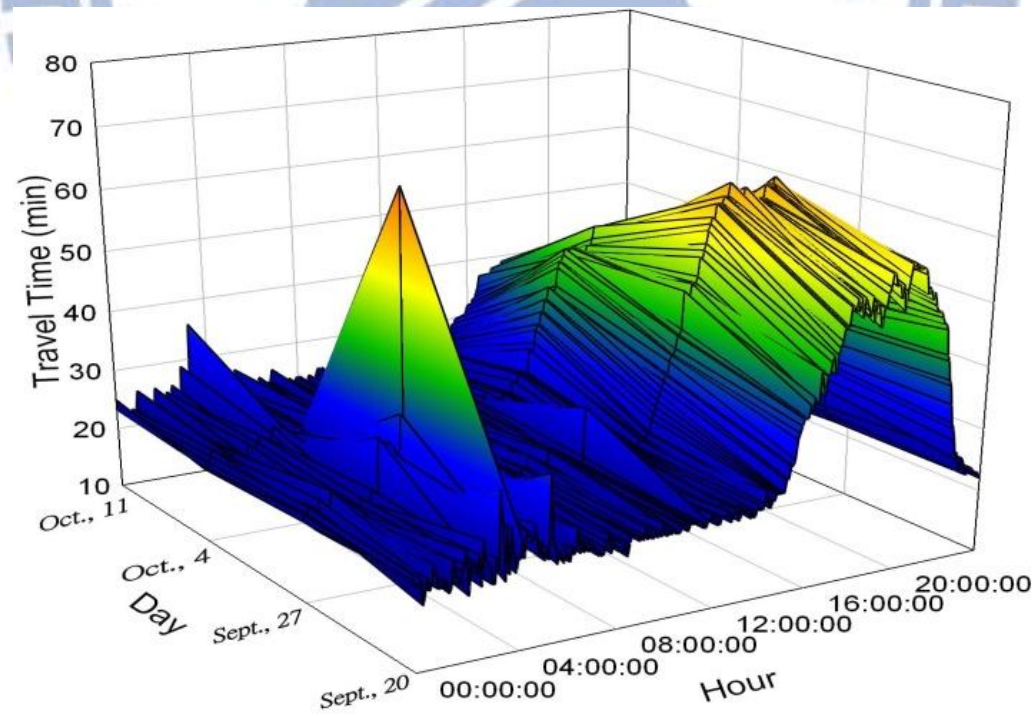

圖 25 星期日之旅行時間

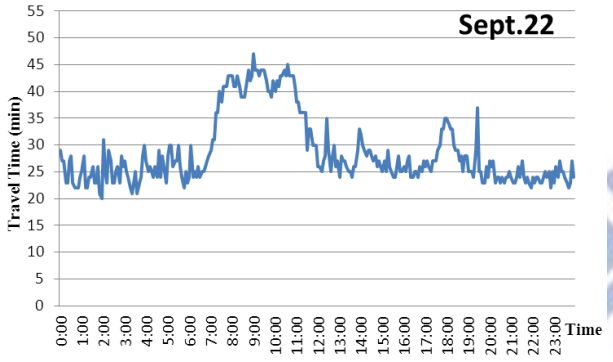

A 旅行時間

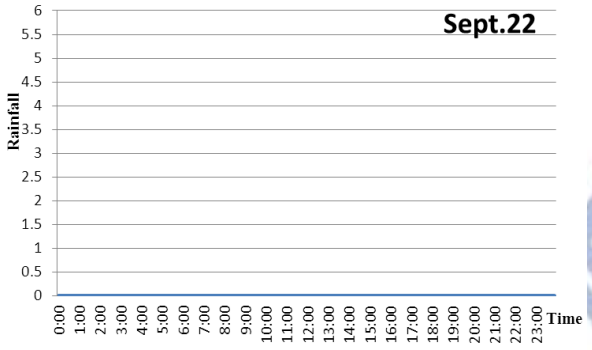

B 雨量

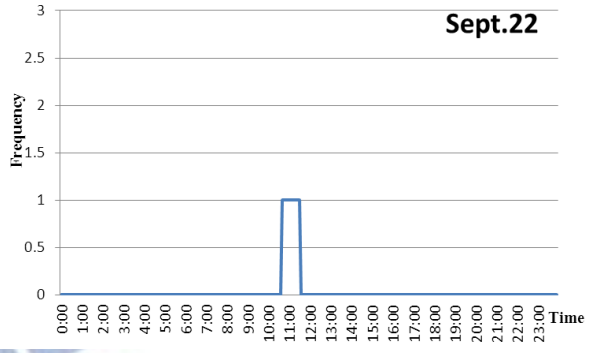

C 肇事車輛數與持續時間

圖 26 9 月 22 日(二)旅行時間、肇事與雨量綜合圖

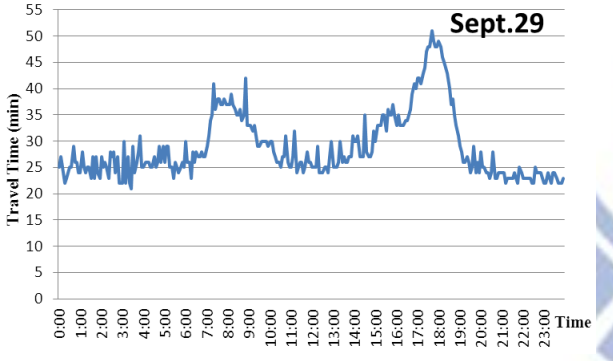

A 旅行時間

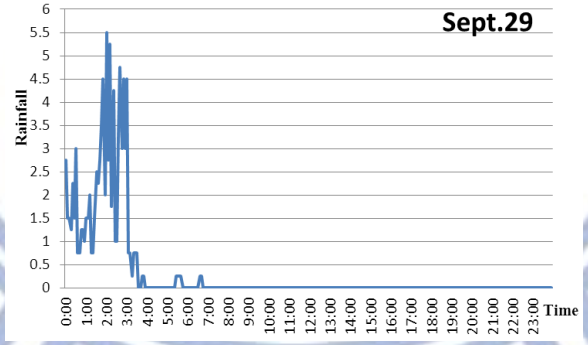

B 雨量

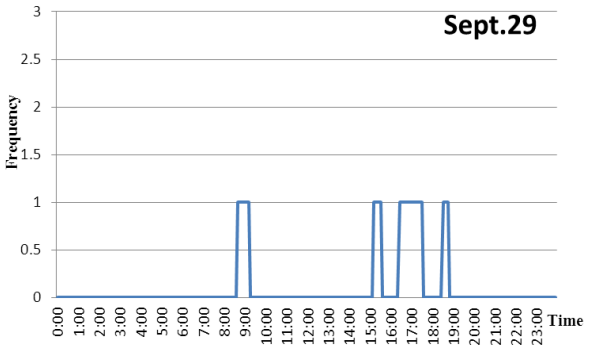

C 肇事車輛數與持續時間

圖 27 9 月 29 日(二)旅行時間、肇事與雨量綜合圖

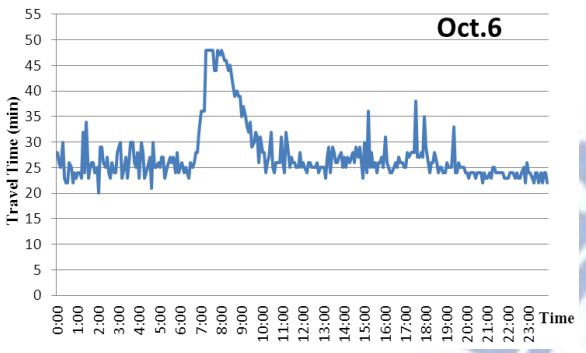

A 旅行時間

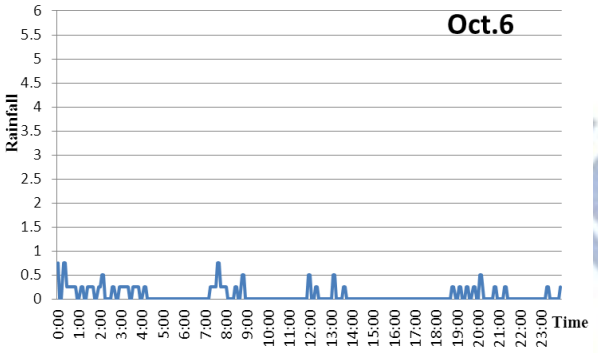

B 雨量

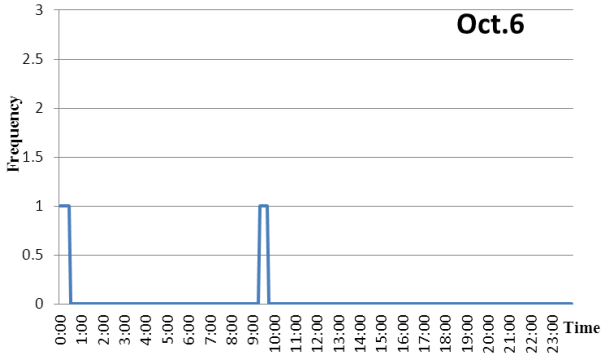

C 肇事車輛數與持續時間

圖 28 10 月 6 日(二)旅行時間、肇事與雨量綜合圖

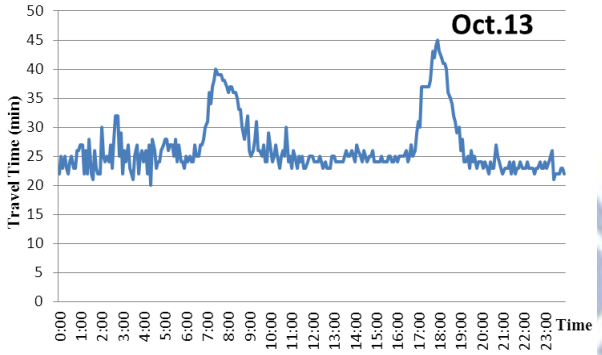

A 旅行時間

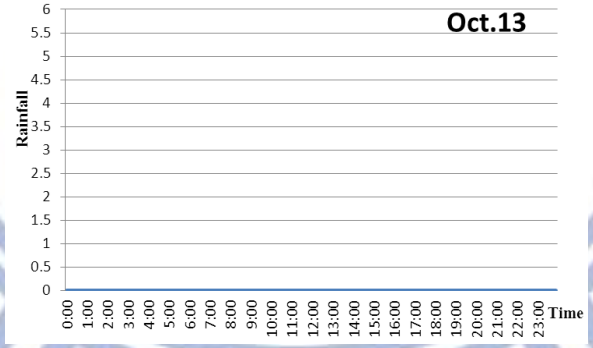

B 雨量

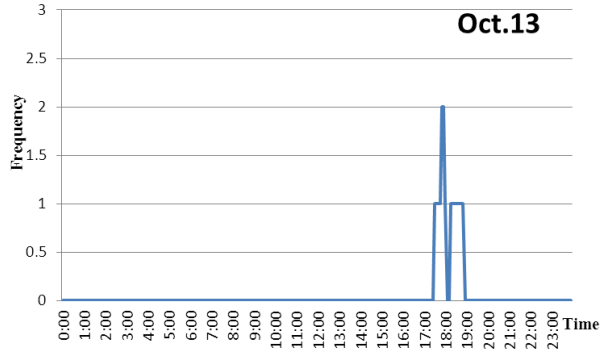

C 肇事車輛數與持續時間

圖 29 10 月 13 日(二)旅行時間、肇事與雨量綜合圖

第五章 實證結果與分析

經由確立研究架構、預測方法與資料蒐集等步驟後，即針對 NNBM、MEBM 與 ICCM 等 3 種模型進行預測模式之建構。本章即針對 NNBM、MEBM 與 ICCM 等 3 種模型之實驗設計方式與實驗結果分別進行說明於 5.1~5.3 各小節。最後，針對各模式之預測績效進行比較分析於 5.4 節。

5.1 NNBM 結果與分析

5.1.1 實驗設計

有關 NNBM 之實驗設計，本研究針對雨量設計 7 種組合。針對車輛偵測器所蒐集之資料(速度、大型車) 設計 3 種組合。星期變數之編碼方式設計 2 種組合。ETC 資料設計 2 種組合。時間變數設計 2 種組合。上述各項輸入變數之組合內容如表 10 所示，總計共包含 168 種實驗組合。本研究針對每一實驗組合建置最佳 ANN 預測模式。以往研究主要經由精進各種模式以提升旅行時間預測能力。然而對變數本身是否有顯著影響旅行時間預測能力卻鮮少探討。就管理單位而言，了解變數對旅行時間預測之影響，為影響設備投入之重要關鍵，且可進一步獲得系統維運之目標。有鑑於此，本研究針對 168 種實驗組合之預測結果，透過統計檢定方式獲得各變數對預測模式之實質影響力，並以此研究成果作為 MEBM 與 ICCM 等模式之輸入變數。表 11 為各項參數值設定說明。

本研究以 SAS Enterprise Miner Version 5.3 建構旅行時間預測模式。各項參數之設定如表 3 所示。就 ANN 模式而言，隱藏層內之單元數為影響模式預測能力之重要因子。因此，本研究針對每一實驗組合，測試不同隱藏層單元數，並以誤差均方根(Root Mean Square Error , RMSE)與平均絕對誤差百分比(Mean Absolute Percentage Error, MAPE)值作為該組合內最好架構之判斷依據，且各實驗組合依其最後測試時所得最佳架構之 RMSE 與 MAPE 值進行組合間特性分析。RMSE 為一非線性之判斷準則，可有效了解某固定時段 t 下，於樣本數為 M 時，其預測結果($\bar{x}(k)$)與實際值($x(k)$)之誤差，此指標具有相對值之概念，其計算方式如式(9)所示。

$$\mathrm{RMSE} = \sqrt{\frac{1}{M}\sum_{k=1}^{M}(x(k) - \bar{x}(k))^2} \quad (9)$$

MAPE 乃由 Lewis 於 1982 年提出，因該值不受實際值與預測值單位之影響，因此能客觀獲得實際值與預測值間之相對差異。當 MAPE<10%屬於 Highly accurate forecasting；10%<MAPE<20%屬於 Good forecasting；20%<MAPE<50%屬於 Reasonable forecasting；MAPE>50%屬於 Inaccurate forecasting，其計算方式如式(10)所示。

$$\mathrm{MAPE} = \frac{1}{M}\sum_{k=1}^{M}\left|\frac{x(k)-\bar{x}(k)}{x(k)}\right| \times 100\% \quad (10)$$

由 MAPE 與 RMSE 之計算方式可知，值越小表示預測效果越佳。

表 10 NNBM 輸入變數

Factors	Experiment number	Input Variables	Descriptions
Rainfall	1.1	5-min.	5-min. cumulative rainfall as input variable-
	1.2	5-min., 1-hour	5-min., 1-hour cumulative rainfall as input variables -
	1.3	5-min., 1-hour, 2-hour	5-min., 1-hour, 2-hour cumulative rainfall as input variables
	1.4	5-min., 1-hour, 2-hour, 3-hour	5-min., 1-hour, 2-hour, 3-hour cumulative rainfall as input variables
	1.5	5-min., 1-hour, 2-hour, 3-hour, 4hour	5-min., 1-hour, 2-hour, 3-hour, 4-hour cumulative rainfall as input variables
	1.6	5-min., 1-hour, 2-hour, 3-hour, 4-hour, 5-hour	5-min., 1-hour, 2-hour, 3-hour, 4-hour, 5-hour cumulative rainfall as input variables
	1.7	5-min., 1-hour, 2-hour, 3-hour, 4-hour, 5-hour, 6-hour	5-min., 1-hour, 2-hour, 3-hour, 4-hour, 5-hour, 6-hour cumulative rainfall as input variables
VD data	2.1	Speed and heavy vehicle volume	Data of 10 VDs
	2.2	Speed	Data of 10 VDs
	2.3	Speed	Data of 11 VDs
Day of week	3.1	Divided into three categories	1: Saturday, Sunday 2: Monday, Friday 3: Tuesday, Wednesday, Thursday
	3.2	Divided into seven categories	1: Monday, 2: Tuesday, 3: Wednesday, 4: Thursday 5: Friday, 6: Saturday, 7: Sunday
ETC data	4.1	Used	Historical travel time as input variable
	4.2	Unused	Historical travel time not used as input variable
Time	5.1	Unused	Variable not used
	5.2	Used	1: AM, 2: PM

表 11 NNBM 參數設定

Property	Value
Train options	
Maximum iterations	1000
Maximum Time	4 Hours
Training Technique	Default
Preliminary Training options	
Preliminary Training	Yes
Maximum iterations	10
Maximum Time	1 Hours
Number of Runs	5
Convergence Criteria	
Uses Defaults	Yes
Score	
Hidden Units	No
Residuals	Yes
Standardization	No

5.1.2 實驗結果

(一) 雨量變數分析

由於雨量會影響駕駛者視線進而直接影響駕駛者行為與間接影響交通特性，因此雨量變數對於解析路段車流特性有重要影響。然而如果透過迴歸等統計方法了解雨量對旅行時間預測之影響，將無法避免自變數間共線性問題。依據 DeTienne *et al.* (2003)之研究顯示，ANN 模式相較於統計方法可處理多重共線性(multicollinearity)問題。有鑑於此，本研究依據雨量變數設計 7 種組合(如表 10 所示)。Experiment 1.1 包含 5 分鐘累計雨量變數。Experiment 1.2 則增加前 1 小時累計雨量當變數。以此類推，Experiment 1.7 即包含 7 個累計雨量變數，分別為 5 分鐘、1 小時、2 小時、3 小時、4 小時、5 小時、6 小時(如表 10 所示) ，並分別測試由 VD 資料、時間、星期、ETC 資料等變數所構成之 24 種實驗組合(VD 共 3 種組合、時間共 2 種組合、星期共 2 種組合、ETC 共 2 種組合)。

由表 4 可知，就 MAPE 值而言，Experiment 1.1 之績效值並非最佳。一般而言，ANN

之輸入變數越多且皆為重要變數的話，對提升模式預測能力有正面幫助。然而，就實際測試結果可知，Experiment 1.7 並非具有最佳預測能力。為進一步了解各項組合於變異數與平均數是否有顯著不同。本研究先以 F test 分析各項組合之變異數是否有明顯差異，之後透過 t test 分析各項組合平均數是否有明顯差異。分析結果如表 12 所示。雖然 7 個實驗組合在 MAPE 與 MAPE>20%之樣本數此兩項指標之表現並沒有明顯差異。然而在 RMSE 與 MAPE>50%之樣本數此兩項指標之表現呈現明顯差異(如表 13 與表 16 所示)。由研究結果顯示，增加累計雨量變數不僅無法改善旅行時間預測模式之預測能力，而且更會增加 MAPE>50%之樣本數。由於 MAPE>50%已歸為不準確預測(Inaccurate forecasting)結果，因此增加此樣本數將降低用路人對旅行時間預測系統之接受度，更會對政策推展造成很大阻力。再者，減少模式之輸入變數不僅可提高模式之適用性，亦可降低前端資料蒐集設備之投入成本。綜合以上所述，採用 5 分鐘累計雨量作為輸入變數(Experiment 1.1)即可建立高度準確預測(Highly accurate forecasting)模式，且降低預測模式之輸入構面。

表 12 雨量變數於 24 種實驗組合之平均績效值

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 1.1	3.03(.11)	6.78(.22)	4.05(.43)	0.05(.03)
Experiment 1.2	3.04(.11)	6.80(.20)	4.06(.43)	0.05(.03)
Experiment 1.3	3.05(.11)	6.78(.22)	4.05(.51)	0.05(.02)
Experiment 1.4	3.03(.12)	6.78(.19)	4.05(.42)	0.06(.03)
Experiment 1.5	3.00(.11)	6.78(.21)	3.94(.46)	0.05(.02)
Experiment 1.6	2.98(.10)	6.73(.19)	3.98(.45)	0.07(.03)
Experiment 1.7	2.98(.09)	6.73(.17)	3.94(.41)	0.06(.03)

註: (.)表示標準差

表 13 雨量變數各組合於 RMSE 之 t 檢定

Experiment	Experiment 1.1	Experiment 1.2	Experiment 1.3	Experiment 1.4	Experiment 1.5	Experiment 1.6	Experiment 1.7
Experiment 1.1	-	-0.27(2.02)*	-0.40(2.02)	0.26(2.02)*	1.06 (2.02)	1.74(2.02)	1.80(2.02)
Experiment 1.2	-	-	-0.12(2.02)	0.53(2.02)*	1.34(2.02)	**2.02(2.02)**	**2.08(2.02)**
Experiment 1.3	-	-	-	0.65(2.02)*	1.49(2.02)	**2.18(2.02)**	**2.26(2.02)**
Experiment 1.4	-	-	-	-	0.76(2.02)	1.42(2.02)	1.46(2.02)
Experiment 1.5	-	-	-	-	-	0.68(2.02)	0.70(2.02)
Experiment 1.6	-	-	-	-	-	-	0.00(2.02)
Experiment 1.7	-	-	-	-	-	-	-

註: 1. (.)表 t value 雙尾檢定的值

2. ()*表 F 檢定下有顯著差異

3. _ 表 t 檢定下有顯著差異

表 14 雨量變數各組合於 MAPE 之 t 檢定

Experiment	Experiment 1.1	Experiment 1.2	Experiment 1.3	Experiment 1.4	Experiment 1.5	Experiment 1.6	Experiment 1.7
Experiment 1.1	-	-0.41(2.02)	-0.04(2.02)	0.06(2.02)	-0.05(2.02)	0.64(2.02)	0.69(2.02)
Experiment 1.2	-	-	0.38(2.02)*	0.52(2.02)	0.37(2.02)*	1.12(2.02)	1.20(2.02)
Experiment 1.3	-	-	-	0.11(2.02)	-0.01(2.02)	0.69(2.02)	0.75(2.02)
Experiment 1.4	-	-	-	-	-0.12(2.02)*	0.63(2.02)*	0.69(2.02)
Experiment 1.5	-	-	-	-	-	0.71(2.02)	0.77(2.02)
Experiment 1.6	-	-	-	-	-	-	0.04(2.02)
Experiment 1.7	-	-	-	-	-	-	-

註: 1. (.)表 t value 雙尾檢定的值

2. ()*表 F 檢定下有顯著差異

3. _ 表 t 檢定下有顯著差異

表 15 雨量變數 MAPE>20%樣本數之 t 檢定

Experiment	Experiment 1.1	Experiment 1.2	Experiment 1.3	Experiment 1.4	Experiment 1.5	Experiment 1.6	Experiment 1.7
Experiment 1.1	-	-0.03(2.02)*	-0.08(2.02)*	0.09(2.02)	0.96(2.02)*	0.57(2.02)*	1.05(2.02)
Experiment 1.2	-	-	-0.05(2.02)*	0.12(2.02)	0.98(2.02)*	0.59(2.02)*	1.07(2.02)
Experiment 1.3	-	-	-	0.16(2.02)	0.96(2.02)	0.60(2.02)	1.03(2.02)
Experiment 1.4	-	-	-	-	0.89(2.02)*	0.49(2.02)*	0.98(2.02)
Experiment 1.5	-	-	-	-	-	-0.39(2.02)	0.01(2.02)
Experiment 1.6	-	-	-	-	-	-	0.43(2.02)
Experiment 1.7	-	-	-	-	-	-	-

註: 1. (.)表 t value 雙尾檢定的值

2. ()*表 F 檢定下有顯著差異

3. _ 表 t 檢定下有顯著差異

表 16 雨量變數 MAPE>50%樣本數之 t 檢定

Experiment	Experiment 1.1	Experiment 1.2	Experiment 1.3	Experiment 1.4	Experiment 1.5	Experiment 1.6	Experiment 1.7
Experiment 1.1	-	-0.86(2.02)*	-0.84(2.02)*	-1.61(2.02)*	-1.01(2.02)	**-2.81(2.02)***	-1.93(2.02)
Experiment 1.2	-	-	0.25(2.02)*	-0.64(2.02)	0.00(2.02)	-1.82(2.02)	-0.89(2.02)
Experiment 1.3	-	-	-	-1.11(2.02)	-0.32(2.02)*	**-2.54(2.02)**	-1.49(2.02)
Experiment 1.4	-	-	-	-	0.75(2.02)	-1.29(2.02)*	-0.24(2.02)
Experiment 1.5	-	-	-	-	-	-2.11(2.02)*	-1.07(2.02)*
Experiment 1.6	-	-	-	-	-	-	1.12(2.02)
Experiment 1.7	-	-	-	-	-	-	-

註: 1. (.)表 t value 雙尾檢定的值

2. ()*表 F 檢定下有顯著差異

3. _ 表 t 檢定下有顯著差異

(二) VD 資料分析

Experiment 2 係針對 VD 所蒐集到之速度與大型車流量等資料設計不同變數組合(如表 10 所示)，並且比較其預測績效。Experiment 2.1 係以 10 處 VD 之速度與大型車流量作為輸入變數。Experiment 2.2 則僅以 10 處 VD 之速度作為輸入變數。Experiment 2.3 則以 11 處 VD 之速度作為輸入變數，並分別測試由雨量、時間、星期、ETC 資料等變數所構成之 56 種實驗組合(雨量共 7 種組合、時間共 2 種組合、星期共 2 種組合、ETC 共 2 種組合)。由表 17 各項績效指標之統計結果可知，當 VD 屬性以速度與大型車流量當作輸入變數時(Experiment 2.1)，相較於其他實驗組合而言，其各項績效值表現結果最差，並且有較大之標準差。然而，有趣的是，當 VD 屬性僅採用速度當輸入變數，且變數個數由 10 個增至 11 個，則能提升預測預測績效。再者透過表 18 之統計檢定結果可知，VD 屬性之不同實驗組合彼此之各項績效指標皆有顯著性差異。由研究結果可知，在採用 10 個 VD 資料之前提下，僅以速度作為輸入變數之預測模式，其 MAPE 與 RMSE 之表現皆比以速度及大型車流量作為輸入變數之預測模式其表現結果較佳。再者，採用 11 處 VD 所蒐集到之速度資料作為輸入變數(Experiment 2.3) 之預測模式，其 RMSE 與 MAPE 之績效亦優於採用 10 處 VD 所蒐集到之速度資料作為輸入變數(Experiment 2.2) 之預測模式。由此可知，VD 所蒐集之速度為提升模式預測能力之重要變數。另外，將大型車流量當作輸入變數，對提升模式預測能力較無幫助。更重要的是，為能提升與確保使用者對旅行時間資訊之信賴，應極力降低 Reasonable forecasting 或 Inaccurate forecasting 之樣本數。對此， Experiment 2.3 之預測模式平均僅有 3.67%之樣本會有此情形發生，皆較其他 2 種組合低。此對建構一穩健且適用長時期使用之預測模式而言，是一重要參考指標。

表 17 VD 變數於 56 種實驗組合之平均績效值

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 2.1	3.09(.10)	6.90(.19)	4.32(.41)	0.06(.03)
Experiment 2.2	3.02(.10)	6.77(.18)	4.05(.39)	0.05(.03)
Experiment 2.3	2.93(.07)	6.63(.11)	3.67(.23)	0.05(.02)

註: (.)表示標準差

表 18 VD 變數各項績效指標之 t 檢定

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 2.1 VS Experiment 2.2	**3.79(1.98)**	**3.77(1.98)**	**3.67(1.98)**	0.52(1.98)
Experiment 2.1 VS Experiment 2.3	**9.25(1.98)***	**9.10(1.98)***	**10.30(1.98)***	1.16(1.98)*
Experiment 2.2 VS Experiment 2.3	**5.18(1.98)***	**4.82(1.98)***	**6.12(1.98)***	0.65(1.98)*

註: 1. (.)表 t value 雙尾檢定的值

2. ()*表 F 檢定下有顯著差異

3. _ 表 t 檢定下有顯著差異

(三) 星期(the day of the week)變數分析

為了解星期 2~4 之平常日與星期六~日之例假日，於本研究路段內是否呈現同質之車流狀況。Experiment 3 係用以比較星期屬性不同編碼方式之預測績效。Experiment 3.1 係將星期六與星期日編碼為 1；星期一與星期五編碼為 2；星期 2~4 編碼為 3。Experiment 3.2 則將所有星期彼此之間皆視為非均質，因此將星期 1~日依序編為 1~7，並分別測試由雨量、VD、時間、ETC 等屬性所構成之 84 種實驗組合(雨量共 7 種組合、VD 共 3 種組合、時間共 2 種組合、ETC 共 2 種組合)。由表 19 各項績效指標之統計結果可知，Experiment 3.1 於各項績效指標之平均表現能力較 Experiment 3.2 差，且 MAPE 之變異數卻有較大之情形。此研究結果顯示 Experiment 3.1 所構建之預測模式，其表現較不穩定。然而，由表 20 之統計檢定結果可知，星期屬性之不同編碼方式，在 MAPE 大於 50% 之樣本百分比上有明顯差異。一般而言，在長距離、高流量與交流道密集之高速公路路段，由於連接多個重要經濟發展地區與扮演主要城際運輸之角色，使其有較複雜之旅次特性，因此其車流特性較難以平常日或例假日加以區分。在本研究範圍內，就星期屬性於各項績效指標之平均表現而言，Experiment 3.2 有較佳之表現。因此，一般將星期以平常日與例假日之區分方式(即 Experiment 3.1)，較無法有效解析具有非重現性擁擠特性下之車流特性。

表 19 星期變數於 84 種實驗組合之平均績效值

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 3.1	3.02(.11)	6.78(.20)	4.03(.44)	0.06(.03)
Experiment 3.2	3.01(.11)	6.75(.19)	3.99(.44)	0.05(.02)

註: (.)表示標準差

表 20 星期變數各項績效指標之 t 檢定

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 3.1 VS Experiment 3.2	0.81(1.97)*	0.90(1.97)	0.57(1.97)	1.42(1.97)*

註: 1. (.)表 t value 雙尾檢定的值

2. ()*表 F 檢定下有顯著差異

3. _ 表 t 檢定下有顯著差異

(四) ETC 變數分析

Experiment 4 比較以 ETC 原始資料所推得之歷史旅行時間資料作為輸入變數及不以 ETC 歷史旅行時間資料作為輸入變數之預測績效。其中 Experiment 4.1 係以 ETC 原始資料所推得之歷史旅行時間資料作為輸入變數。Experiment 4.2 則不以 ETC 歷史旅行時間資料作為輸入變數(如表 10 所示)，並分別測試由雨量、VD、時間、星期等屬性所構成之 84 種實驗組合(雨量 7 共種組合、VD 共 3 種組合、時間共 2 種組合、星期共 2 種組合)。由表 21 各項績效指標之統計結果可知，包含 ETC 歷史旅行時間資訊(Experiment 4.1)之實驗組合，其各項績效值表現結果皆優於不採用 ETC 歷史旅行時間資訊(Experiment 4.2)之實驗組合，且變異數亦較低。再者，透過統計檢定結果可知(如表 22 所示)，除了 MAPE>50%之績效值不顯著外，RMSE、MAPE、MAPE>20%等績效值皆有統計上顯著差異。由此可知，以 ETC 歷史旅行時間資訊作為旅行時間預測模式之輸入變數，不僅對提高模式之預測能力(MAPE 較低)有明顯幫助，並且由於該模式於各項績效指標之變異數較低，因此能建構一穩健之預測模式。再者，重要的是能有效減少 MAPE>20%之樣本數。此就提升用路者接受度而言，係為一重要衡量指標。

表 21 ETC 變數於 84 種實驗組合之平均績效值

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 4.1	2.94(.06)	6.64(.12)	3.79(.29)	0.06(.03)
Experiment 4.2	3.09(.10)	6.90(.18)	4.23(.46)	0.05(.03)

註: (.)表示標準差

表 22 ETC 變數各項績效指標之 t 檢定

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 4.1 VS Experiment 4.2	**-11.71(1.97)**	**-11.10(1.97)**	**-7.36(1.97)**	1.42(1.97)

註: 1. (.)表 t value 雙尾檢定的值
2. ()*表 F 檢定下有顯著差異
3. _ 表 t 檢定下有顯著差異

(五) 時間變數分析

Experiment 5 係比較不以時間作為輸入變數及以時間作為輸入變數之預測績效。其中 Experiment 5.1 係不以時間作為輸入變數。Experiment 5.2 則以時間作為輸入變數，並以 0~12 時編碼為 1；12~24 時編碼為 2(如表 10 所示)，並分別測試由雨量、VD、星期、ETC 等屬性所構成之 84 種實驗組合(雨量共 7 種組合、VD 共 3 種組合、星期共 2 種組合、ETC 共 2 種組合)。由表 23 各項績效指標之統計結果可知，Experiment 5.1 於各項績效指標之平均表現能力較 Experiment 5.2 差且變異數較大。另外，經統計檢定結果可知(如表 24 所示)，採用時間屬性與否，對旅行時間預測模式之績效表現而言，除 RMSE

外，皆有統計上明顯差異。因此，旅行時間預測模式納入時間屬性確能改善模式之預測能力。

表 23 時間變數於 84 種實驗組合之平均績效值

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 5.1	3.02(.11)	6.80(.20)	4.11(.46)	0.06(.03)
Experiment 5.2	3.00(.10)	6.73(.19)	3.92(.40)	0.05(.03)

註: (.)表示標準差

表 24 時間變數各項績效指標之 t 檢定

Experiment	RMSE	MAPE (%)	Percentage of samples of MAPE>20% (%)	Percentage of samples of MAPE>50% (%)
Experiment 5.1 VS Experiment 5.2	-1.54(1.97)*	**-2.42(1.97)***	**-2.88(1.97)***	**-2.88(1.97)***

註: 1. (.)表 t value 雙尾檢定的值
2. ()*表 F 檢定下有顯著差異
3. _ 表 t 檢定下有顯著差異

5.2 MEBM 結果與分析

5.2.1 實驗設計

本研究共設計 6 種實驗情境如表 25 所示。情境 1 係以 11 個 VD 的現點速度資料、三個 VD 的 5 分鐘雨量資料、星期、時間等作為輸入變數，並且直接建立類神經預測模式。情境 2 則在情境 1 之基礎上增加 ETC 的歷史旅行時間作為輸入變數，並且直接建立類神經預測模式。情境 3 係以情境 1 之輸入變數當基礎，然而預測方式係採用混合專

家系統之概念構建預測模式，即於各群建立各自類神經預測模式。情境 4 則以情境 2 之輸入變數當基礎，然而預測方式係採用混合專家系統之概念構建預測模式，即於各群建立各自類神經預測模式。情境 5 則以情境 1 之輸入變數當基礎，然而預測方式係採用混合專家系統之概念構建預測模式，即於各群計算該群平均旅行時間當作是預測值。情境 6 則以情境 2 之輸入變數當基礎，然而預測方式係採用混合專家系統之概念構建預測模式，即於各群計算該群平均旅行時間當作是預測值。

表 25 MEBM 實驗情境設計

情境	變數組成	預測模式
1	11 個 VD 的現點速度資料、三個 VD 的 5 分鐘雨量資料、星期、時間(Time)	直接建立類神經預測模式
2	在情境 1 上增加 HTT 資料	直接建立類神經預測模式
3	11 個 VD 的現點速度資料、三個 VD 的 5 分鐘雨量資料、星期、時間(Time)	第一種專家模式(各群建立自有類神經預測模式)
4	在情境 1 上增加 HTT 資料	第一種專家模式(各群建立自有類神經預測模式)
5	11 個 VD 的現點速度資料、三個 VD 的 5 分鐘雨量資料、星期、時間(Time)	第二種專家模式(以各群平均旅行時間做為預測值)
6	在情境 1 上增加 HTT 資料	第二種專家模式(以各群平均旅行時間做為預測值)

5.2.2 實驗結果

各種情境之測試結果如表 26 所示。由研究成果顯示，除情境 5 之預測能力屬於 Good forecasting 之外，其餘情境之預測能力皆屬於 Highly accurate forecasting。經研究結果發現，加入 ETC 歷史旅行時間資料作為輸入變數之模式，具備較佳的預測能力。就混合專家系統之設計而言，加入 ETC 歷史旅行時間資料之預測模型(情境 4、6)較直接預測之模型(情境 2)預測能力較差。探究其原因，由於分群過後各群樣本數減少且各群組之異常值(肇事或下雨)有被放大效果，因此造成模式有過度學習的可能。然而當樣本數越大時，依據 NNBM 之研究成果可知，增加 ETC 歷史旅行時間資訊有助於建立更準確之預測模式。此外，第一種混合專家系統確實能提升模式預測能力，此趨勢由情境 1、3、5 之預測結果可得知。當採用第一種混合專家系統進行預測時，不僅增加模式之預測能

力，同時也降低 MAPE 值大於 20%之樣本數。此對提升民眾信任度有實質影響。由兩種混合專家系統之測試可知，針對個別群體建立類神經預測模式之作法較具預測能力。由此可知，較具學習力之預測模式有助於提升預測準確度。此亦反應出面對一複雜交通狀況而言，透過簡單模型並無法提升模式預測能力。此驗證了 Yildirimoglu and Geroliminis (2013)提出的觀點。

表 26 MEBM 實驗結果彙整

情境	MAPE	MAPE 大於 20%之樣本百分比
1	6.68%	3.74%
2	6.41%	2.99%
3	6.47%	3.12%
4	7.76%	6.63%
5	12.42%	20.53%
6	8.80%	9.26%

表 27 為第一種混合專家類型各群預測能力分析。由表中可清楚得知，第一種混合專家類型在肇事下之平均預測能力其 MAPE 值為 9.9%。在雨天之平均預測能力其 MAPE 值為 8.5%。因此由本研究可知，經由本研究之預測架構，可建立一高度預測能力之模式且同時適用於雨天與肇事發生下之情境。另外由研究中得知，隨著資料量越大，樣本數越多，則本研究所提出之預測步驟與模型越能提升預測能力。管理單位無須針對肇事或雨量額外建立新的預測模式。由於肇事或雨量發生時，依據現有通報機制，難以準確掌握實際發生時間點與影響範圍，尤其肇事之正確時間點、受影響車道數、預計排除時間等等皆非第一時間可獲得。然而當事件發生時，用路人對旅行時間預測之需求更勝。因此，發展一適用於事件發生下之預測模式且能克服現有通報機制不足之處，則能有效擴大模式適用時機。

表 27 第一種混合專家類型各群預測能力

群組編號	群組特性	肇事發生下之旅行時間預測能力	雨天發生下之旅行時間預測能力
1	星期 3、5 的下半天	肇事資料 10 筆，平均 MAPE10.6%	6 筆下雨資料，平均 MAPE 為 8.1%
2	星期 2、4、日之下半天	16 筆肇事資料，平均 MAPE12.1%	7 筆下雨天資料，平均 MAPE 為 3.44%
3	星期 2、3、日上半天	9 筆肇事，平均 MAPE11.3%	8 筆下雨資料，平均 MAPE8.2%
4	星期 3~5 的上半天	6 筆肇事資料，有 3 筆誤差超過 10%。平均 MAPE10%	4 筆下雨資料，2 筆誤差超過 10%，平均 MAPE10.1%
5	星期一下半天	6 筆肇事，平均 MAPE13.3%	20 筆下雨資料，平均 MAPE11.0%
6	星期一上半天	1 筆肇事資料，MAPE10.7%	9 筆下雨資料，MAPE6.6%
7	星期六上半天	6 筆肇事資料，平均 MAPE3.1%	1 筆下雨資料，平均 MAPE5.6%
8	星期六下半天	3 筆肇事，平均 MAPE7.7%	-
平均預測能力		9.9%	8.5%

5.3 ICCM 結果與分析

5.3.1 實驗設計

本研究經由 ICCM 探討如何在現有硬體設備下，甚至在精簡設備下，能提供一穩健與準確模式以預測高速公路含非重現性擁擠旅行時間。因此，本研究共設計 6 種情境進行分析。Scenario 1 係以 11 個車輛偵測器所蒐集之現點速度、3 個不同地點之雨量偵測器資料、星期與時間作為輸入變數，並透過 ANN 建立旅行時間預測模式。Scenario 2 相較於 Scenario 1 而言，新增 ETC 所計算得之歷史旅行時間作為輸入變數。Scenario 3 則於 Scenario 1 之輸入變數中，新增透過 *K*-means 分群產生之虛擬變數，即群集代碼 (cluster ID)。Scenario 4 之輸入變數係於 Scenario 2 之變數組合再加上 Scenario 3 所採用之群集代碼。Scenario 5 則於 Scenario3 之情境下將群集代碼設為分類模式之類別目標，並進行決策樹分析。再者，將出現於決策樹中之變數視為關鍵變數，且僅用該關鍵變數作為輸入變數，並以此建構 ANN 預測模式，過程如 Section 2 的 Step 5 所示。Scenario 6 之輸入變數與 Scenario 5 相似，主要差異點在於 Scenario 6 係在 Scenario 4 之情境下進行

決策樹分析以產生關鍵變數。

由上述可知， Scenario 5 與 Scenario 6 皆是透過決策樹決定關鍵變數。經研究發現，Scenario 5 與 Scenario 6 之決策樹分析結果分別如圖 30 與圖 31 所示。雖然決策樹形狀不同，然而卻具有相同關鍵變數出現於決策樹中。總計萃取出之共同關鍵變數共有三個，其分別為時間、星期與位於 51.6 公里之 VD 所蒐集到之現點速度，即 speed 5160。有關 6 種情境之設計內容彙整如表 28 所示。

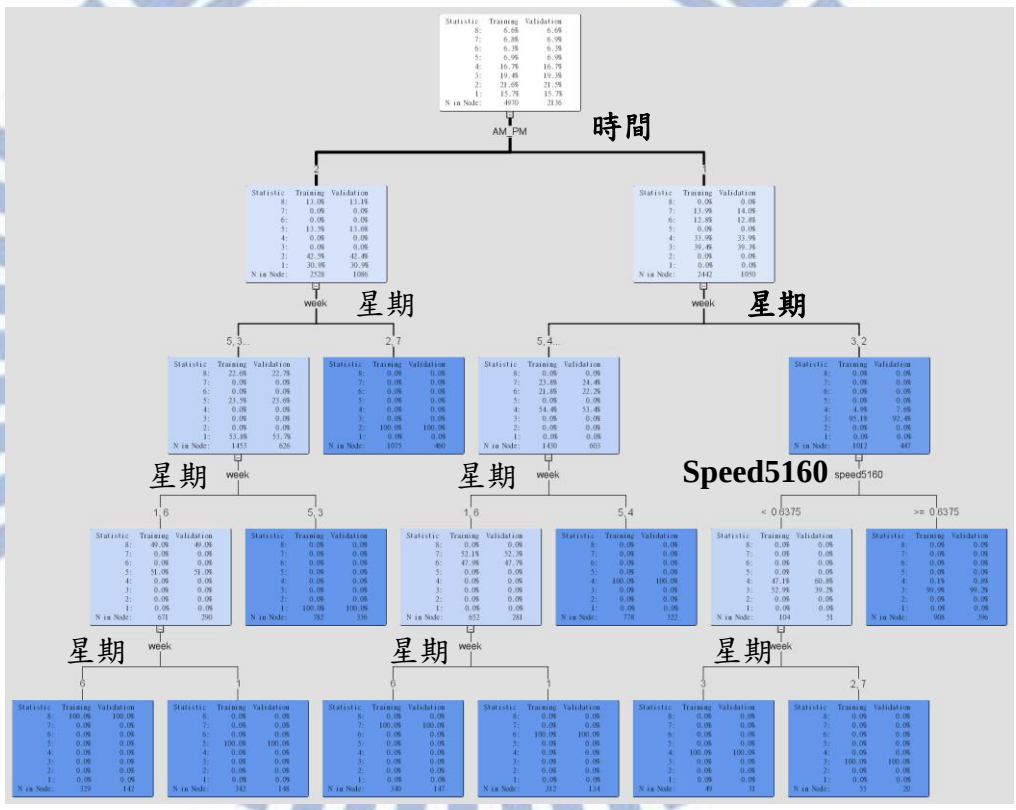

圖 30 Scenario 5 之決策樹

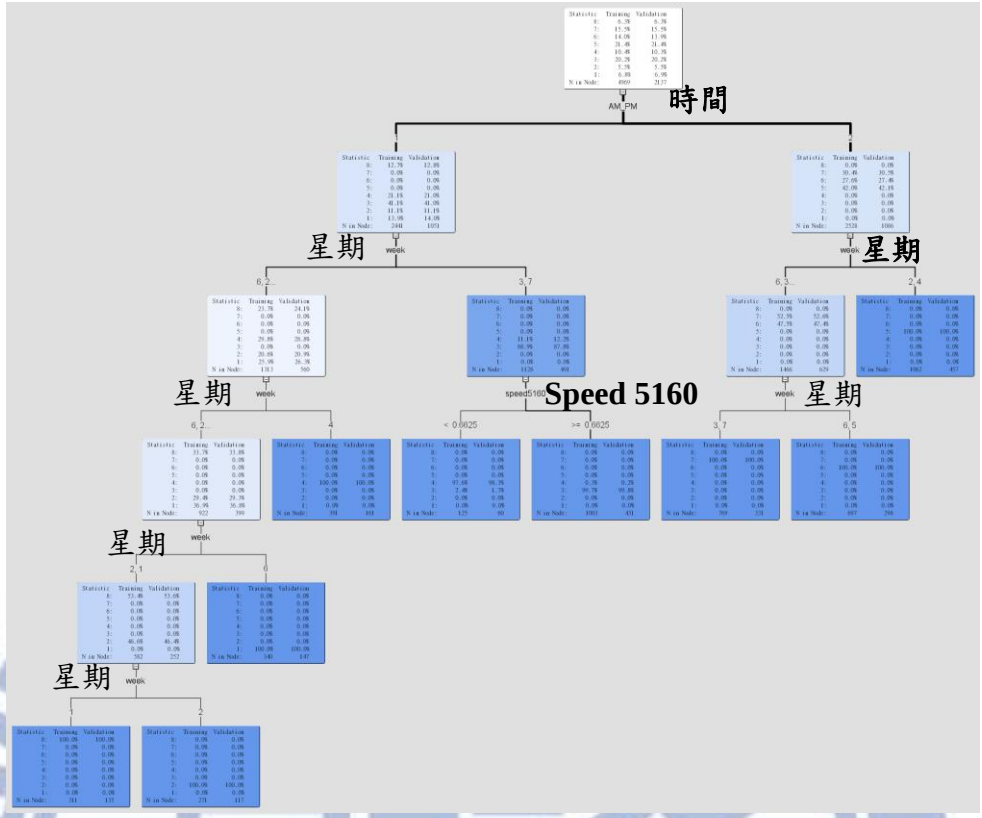

圖 31 Scenario 6 之決策樹

表 28 ICCM 實驗情境設計

Scenario	Description of input variables
1	Spot speeds collected by 11 VDs, rainfalls from three detectors, the day of the week, and time (AM or PM)
2	The input variables of S1, and HTT calculated from ETC
3	The input variables of S1, and the dummy variable (i.e., cluster ID)
4	The input variables of S2, and the dummy variable (i.e., cluster ID)
5	The important variables identified by CART with the variables in Scenario 3
6	The important variables identified by CART with the variables in Scenario 4

5.3.2 實驗結果

判別每筆樣本之分群結果並以此新增一虛擬變數為 Scenario 3 及 Scenario 4 與其他實驗組合最大相異點。為獲得驗測組每筆樣本之分群編號，本研究先以 *K*-means 對訓練組所有樣本進行分群，之後再以 CART 方法建立分類模式，則驗測組內之每筆樣本便可

透過該分類模式判別其分群編號。本研究亦將研究範圍內之車流特性設定為 8 個群體。此外，為避免分群結果受資料單位影響。因此，本研究首先以$\delta_{ij} = \frac{\varepsilon_j - \varphi_{ij}}{\varepsilon_j}$之方式針對原始資料進行標準化後，再進行分群與分類之步驟。其中，δ_{ij}表示樣本 i 於第 j 個變數之標準化結果。φ_{ij}表示樣本 i 於第 j 個變數之原始值。ε_j表示在第 j 個變數中，所有樣本 i 最大值再加上 20%之值，$\varepsilon_j = \max\{\varphi_i\} \times 1.2$。為建構一穩健之分類模型，本研究針對訓練組之資料，以隨機方式將資料以 7:3 之比例，區分為訓練階段(Training Stage)與驗證階段(Validation Stage)。表 29 與表 30 即為 Scenario 3 and Scenario 4 在訓練組資料標準化過程後之分類結果。由決策樹分類結果可知，透過訓練組資料所建構之分類模式，不論是 Scenario 3 或 Scenario 4 其訓練階段與驗證階段之判中率皆在 99.85%以上。由此可知，透過本研究所建構之分類模式，不僅可有效判別樣本之分群特性，亦可避免因分類不準確造成預測模式之偏誤，進而可準確分析虛擬變數對模式預測能力所造成之影響。

表 29 Scenario 3 於 CART 分類模式之判中率

Actual class	Predicted class	Training Stage(%)	Validation Stage(%)
1	1	15.7344	15.7303
2	2	21.6298	21.5356
3	3	19.3561	19.3352
4	3	0.0201	0.1403
4	4	16.6398	16.5262
5	5	6.8813	6.9288
6	6	6.2777	6.2734
7	7	6.8410	6.8820
8	8	6.6197	6.6479
判中率		99.9798	99.8594

表 30 Scenario 4 於 CART 分類模式之判中率

Actual class	Predicted class	Training Stage (%)	Validation Stage (%)
1	1	6.8424	6.8788
2	2	5.4538	5.4750
3	3	20.1248	20.1217
4	3	0.0604	0.0468
3	4	0.0604	0.0468
4	4	10.3240	10.2948
5	5	21.3725	21.3851
6	6	14.0270	13.9448
7	7	15.4760	15.4890
8	8	6.2588	6.3173
判中率		99.8793	99.9065

經本研究結果發現(如表 31 所示)，6 種實驗組合之 MAPE 值介於 6%~9%之間。由此可知，本研究所建構之預測模式，皆屬於具有 Highly accurate prediction 能力之模式。再者，由 Scenario 1 之 MAPE 值(6.68%) 高於 Scenario 3 之 MAPE 值(6.49%)，及 S2 之 MAPE 值(6.41%)接近於 Scenario 4 之 MAPE 值(6.47%)可知，不論在有 ETC 系統之建置環境下，抑或只有最常見的 VD 偵測器環境中，以分群編號作為虛擬變數並以此作為輸入變數，對提升模式預測能力有正向幫助。再者，Scenario 3 之 MAPE 大於 20%的樣本百分比(3.74%)相較於 Scenario 1(2.62%)低。Scenario 4 之 MAPE 大於 20%的樣本百分比(2.99%)相較於 S2(2.74%)低。由此可知，增加虛擬變數可有效降低 MAPE 大於 20%之樣本數。因此，不論是否建置 AVI 或 ETC 系統之地區，透過本研究所提出之方法產生虛擬變數，皆能有助於提升模式預能力。尤其在以 VD 蒐集交通資訊之地區，設立虛擬變數對模式預測能力之提升更為顯著，且對減少 MAPE 大於 20%之樣本數亦有明顯降低情形。

此外，若僅透過關鍵變數建立預測模式(Scenario 5 與 Scenario 6)，會導致 MAPE 大於 20%之樣本數相較於其他情境增加 2 到 4 倍之多。由於預測模式包含越多重要變數能增加對交通特性之解析能力，進而提升模式預測能力。因此，就省略許多重要變數之 Scenario 5 與 Scenario 6 而言，造成此結果是可以預期的。但是，透過 Scenario 5 and

Scenario 6 之測試結果，本研究萃取出三個關鍵變數，分別為星期、時間、51.6 公里處之 VD 所測得之現點速度(即 Speed5160)。由於樣本 i 之星期與時間兩個關鍵變數可透過 VD 設備獲得。因此，就管理單位之角度而言，管理單位能準確掌握資料蒐集系統之重點維護對象為 51.6K 之 VD 所蒐集之現點速度。由於本研究共蒐集 11 處現點速度與 3 處雨量偵測器資料作為模式輸入變數。由此可知，透過 Scenario 5 and Scenario 6 之研究步驟，不僅降低 92.9%之設備維運壓力(14 個重變數中，僅有 1 個為關鍵變數)，亦確實獲得特定偵測器之關鍵變數資訊。再者，相較於以往，管理單位可透過本研究成果進行系統維護、校估與發展資料填補動作。此外，在 Scenario 5 與 Scenario 6 下所建構之模式，相較於其他實驗組合而言，雖然 MAPE 值僅 8.94%。然而，Lewis(1982)對 MAPE 值之研究分類，此旅行時間預測模式仍屬於高預測能力之模式。因此，此模式具備最廣泛之適用層面。由此可知，當資料蒐集系統因為不可抗力因素而導致故障發生時，透過上述之重要變數，仍可維持一定之預測品質。最後，經關鍵變數之萃取結果發現，時間為一關鍵變數。此研究結果與 Fei *et al.* (2011)研究結果相同，證實上下半天之車流特性於含非重現行擁擠情況下確有不同。因此，將其資料分開討論，抑或以變數設定方式區別車流特性，實有助於提升模式預測能力。

表 31 ICCM 實驗結果彙整

Statement	MAPE(%)	The percentage of MAPE>20%
Applying speed, rainfall, the day of the week, Time to be the input data **(S1)**	6.68	3.74
Applying speed, rainfall, the day of the week, Time**, HTT** to be the input data **(S2)**	6.41	2.99
Applying speed, rainfall, the day of the week, Time**, dummy variable** to be the input data (**S3)**	6.49	2.62
Applying speed, rainfall, the day of the week, Time**, HTT, dummy variable** to be the input data **(S4)**	6.47	2.74
Applying **critical variables** speed5160, the day of the week, Time to be the input data **(S5 and S6)**	8.94	10.22

5.4 比較分析與討論

經由本研究所提出之 NNBM 研究發現，當預測模式之輸入變數包含 HTT 時，有較佳之預測能力。此乃因旅行時間資料所呈現出之特性屬於線的交通資料，有別於以往透過 VD 擷取點的資料，因此有助於反應路段內整體交通狀況，進而提升模式預測能力。

此外，大型車流量雖為影響車流特性之重要指標，然而透過感應線圈針對車型進行判斷時，無法避免誤判情形。再者由於車流運行多以車隊方式前進，因此即使對車型產生誤判，然而，對平均車速之計算結果影響較小。基於上述原因，致使車型之統計資料相較於行駛速度而言產生較大之誤差。此將造成以大型車當輸入變數時，無法提高對車流特性解釋力，進而降低模式之預測能力。

一般針對車流特性分析，習慣區分為平常日與例假日並以此進行分析，然此歸類方式較不適用於本研究路段。此乃因在長距離、高流量與交流道密集之高速公路路段，由於連接多個重要經濟發展地區與扮演主要城際運輸之角色，在複雜經濟因素影響下，使得不同旅次目的之分布特性較為複雜。亦造成本研究路段內，以往認為同屬於平常日或例假日之車流特性並未呈現均質之原因。

DeTienne *et al.* (2003)與 Karlaftis *et al.* (2011)在研究中指出，類神經網路針對變數共線性之處理能力優於統計方法。再者，由於類神經網路在模式的學習過程中，針對共線性較高之變數，會傾向選擇其中一個變數給於較高之學習權重。然而，若增加之變數超過類神經學習能力，則反而會降低預測能力。由本研究針對累計雨量之變數設計 7 種不同實驗組合之研究結果，即反應類神經網路之學習特性。

本研究所提出之 MEBM 模式可知，在第二種混合專家系統下(以各分群之平均值做為預測值)，透過 ETC 資料進行分群之結果(情境 6)可獲得較佳預測結果，且 MAPE 大於 20%之樣本百分比雖然增加將近 10%，然而亦比情境 5 增加之幅度低(20%)。由此可知，ETC 資料確有助於解析車流特性。然而若研究範圍未建置 ETC 系統或者 AVI 系統，則應透過第一種混合專家系統之架構進行預測，且模式預測能力優於直接建模式預測(情境 3 VS 情境 1)。最重要的是能同時降低 MAPE 大於 20%之樣本百分比。

經由本研究所提出之 ICCM 研究發現，透過產生虛擬變數與萃取關鍵變數之方法，能夠提升高速公路含非重現行擁擠的旅行時間預測績效。經研究結果發現，增加虛擬變數為輸入變數確實能在不增加設備建置下，仍可提升模式預測能力，且降低 MAPE 大於 20%之樣本。此對提升民眾對於旅行時間預測接受度有實質上之幫助。再者，本研究證實經由 ICCM 之關鍵變數萃取方法，不僅能同時維持高準確性的預測能力，亦能大幅降低設備維運成本以符合管理單位之需求。

綜合以上所述，茲將本研究所建構之 3 種預測架構績效值彙整如表 32 所示。在已建構 ETC 之地區，以速度、雨量、星期、時間、HTT、虛擬變數等作為輸入變數並且透過 ICCM 架構進行預測，則其 MAPE 值大於 20%之樣本百分比最低，且 MAPE 值與 NNBM 下之預測結果接近(6.47% VS 6.41%)。由此可知，在建置 ETC 系統之地區可透過 ICCM 模型進行預測可獲的最佳預測結果。若該地區未建置 ETC 系統，則以速度、雨量、星期、時間、虛擬變數等作為輸入變數並且透過 ICCM 架構進行預測，則其 MAPE 值大於 20%之樣本百分比最低，其次為第一種 MEBM 架構。

表 32 3 種預測架構績效值

預測架構	輸入變數	MAPE	MAPE 大於 20%之樣本百分比
NNBM	速度、雨量、星期、時間	6.68%	3.74%
	速度、雨量、星期、時間、HTT	6.41%	2.99%
第一種 MEBM	速度、雨量、星期、時間	6.47%	3.12%
	速度、雨量、星期、時間、HTT	7.76%	6.63%
第二種 MEBM	速度、雨量、星期、時間	12.42%	20.53%
	速度、雨量、星期、時間、HTT	8.80%	9.26%
ICCM	速度、雨量、星期、時間、虛擬變數	6.49%	2.62%
	速度、雨量、星期、時間、HTT、虛擬變數	6.47%	2.74%
	星期、時間、speed5160	8.94%	10.22%

第六章 結論與建議

本章主要針對研究之總成果說明於 6.1 節並針對後續研究建議說明於 6.2 節。

6.1 結論

預測高速公路含非重現行擁擠下之旅行時間是非常困難之課題。再者，解決 1.)在現有設備下提升模式預測能力與 2.)獲得關鍵地點之關鍵變數，以減少設備維運成本與同時維持預測準確度問題，一直被管理單位與研究單位所重視及努力之目標。本研究蒐集並整理百萬筆 ETC 原始資料，進而得以針對真實旅行時間進行預測。另外，透過國道 1 號高速公路楊梅收費站到泰山收費站北上路段之實證分析發現，以整合 *K*-means、CART 與 ANN 等資料探勘技術實能建構一穩健模式以預測高速公路含非重現行擁擠之情況下的旅行時間。

本研究 NNBM 之貢獻在於探討雨量、VD、星期、ETC、時間等屬性對建構高速公路於含非重現性擁擠下之旅行時間預測模式之影響。由研究結果發現，在雨量屬性中納入 5 分鐘累計雨量變數時，由於能減少模式構面與降低 Inaccurate forecasting 之預測結果，且同樣維持較佳 MAPE 與 RMSE，因此較能建構一穩健預測模式。另外，就 VD 所蒐集之輸入變數而言，採用大型車流量作為輸入變數，無助於提升模式預測能力。再者，僅採用速度當輸入變數不僅能降低 RMSE 與 MAPE 值，若再增加一處 VD 之速度當輸入變數，則能有助於降低 Reasonable forecasting 或 Inaccurate forecasting 之樣本數，並降低 MAPE 值。有關星期屬性部份，將所有星期彼此之間皆視為非均質，而進行 1~7 之編碼方式，其 RMSE 與 MAPE 之表現度較好。因此，將星期屬性區分為平常日與例假日之方式於本研究路段較不適用。再者，採用 ETC 歷史旅行時間資料可產生一穩定且預測準確度高之預測模式。最後，考量時間變數將有助提升模式之預測能力。

綜合以上所述，本研究所構建出之穩健模式，其輸入變數包含 ETC 歷史旅行時間資料，VD 變數採用 11 個 VD 之速度資料，星期變數以 1~7 方式進行編碼，雨量變數採用 1 個累計雨量變數(5 分鐘累計雨量)，時間變數以上、下午編碼時，其 MAPE 值為 6.47%，

屬於 Highly accurate forecasting model，另外，屬於 Reasonable forecasting 之樣本數僅佔 3.50%。

本研究 MEBM 之貢獻在於，本研究所提出之預測程序確能建構一 Highly accurate forecasting 預測模式。由 6 項情境之測試可知。第一種類型之混合專家系統確能提升預測能力且同時降低 MAPE 值大於 20%之樣本數。當採用第一種混合專家系統進行預測時，不僅增加模式之預測能力，同時也降低 MAPE 值大於 20%之樣本數。此對提升民眾信任度有實質影響。由兩種混合專家系統之測試可知，針對個別群體建立類神經預測模式之作法較具預測能力。由此可知，較具學習力之預測模式有助於提升預測準確度。此研究成果與 Yildirimoglu and Geroliminis (2013)之建議相同。第一種混合專家類型在肇事下之平均 MAPE 值為 9.9%。在雨天之平均 MAPE 值為 8.5%。因此由本研究可知，經由本研究之預測架構，可建立一高度預測能力之模式且同時適用於雨天與肇事發生下之情境。

本研究 ICCM 之貢獻在於，透過本研究所提出之虛擬變數產生與關鍵變數萃取方法，能夠提升高速公路含非重現行擁擠的旅行時間預測績效。經研究結果發現，根據本研究之實驗結果，透過增加虛擬變數為輸入變數確實能在不增加設備建置下，仍可提升模式預測能力，且降低 MAPE 大於 20%之樣本。此對提升民眾對於旅行時間預測接受度有實質上之幫助。再者，本研究證實透過研究中所提出之關鍵變數萃取方法，不僅能同時維持高準確性的預測能力，亦能大幅降低設備維運成本以符合管理單位之需求。

本研究提出整合多種資料探勘方法進行含非重現性旅行時間預測步驟。本研究成果能應用於事件與非事件下之旅行時間預測，並且提供高速公路管理單位使用。透過本研究之分析架構可探掘影響高速公路旅行時間預測之關鍵變數與關鍵資料蒐集設備點，進而降低管理單位之維運成本。相關政府部門透過本研究可針對關鍵變數發展更精確之遺漏值填補方式。另外以往管理單位無法得知主要設備維護地點，然而透過本研究所提出之步驟，能有效解決此問題。透過本研究可使管理單位得知眾多資料蒐集設備中，何者為關鍵設備。因此管理單位即可針對該設備列為重點維護目標。本研究亦分析有無 ETC 資料下對預測模式之影響。研究成果同時適用於未建置 ETC 系統地區，因此本研究成

果可提供不同地區使用。

降低 MAPE 值大於 20%之樣本百分比，為一個需要持續克服的議題。雖然本研究已證實透過本研究提出之方法可降低 MAPE>20%之樣本數且具有良好改善成效，然而該指標之改善對民眾滿意度之影響甚巨，因此，值得未來做更進一步之研究。例如，於雙向六車道且為平衡設置之高速公路上，以某一特定方向為例(outbound or inbound)，若旅行時間資訊每五分鐘更新一次，旅行時間預測模式連續運作 30 天，且每五分鐘內通過每個資訊可變標誌(Changeable Message Sign, CMS)地區之車輛數以 600 PCU(三個車道總和)作計算。另外，每輛車以 2 個乘客做計算，則每個 CMS 於一個月內總共有 10,368,000 人次接收旅行時間資訊。此時就算只減少 MAPE 值大於 20%之樣本數達 0.1%，則每月能降低 10,368 人次對預測模式之負面觀感。若高速公路沿途設置 N 個 CMS，且雙向(two bounds)同時設置，則其影響還須乘上 2N 倍(10,368×2N 人次)。因此，降低 MAPE 值大於 20%之樣本數為重要關鍵議題。

6.2 未來研究方向與建議

本研究為確保所建構出之預測模式能預測真實旅行時間，因此，當真實旅行時間發生遺漏時，則刪除該樣本且不進行填補。歷史旅行時間發生遺漏下之填補方式與真實旅行時間相同。然而經由研究發現，將歷史旅行時間作為模式之輸入變數時，對模式預測能力有提升作用。再者，透過 ETC 蒐集旅行時間資訊，總計有 3 種因素造成遺漏值情形。有鑑於此，未來研究應針對歷史旅行時間之填補方式做進一步研究。藉此可確保預測模式之應用。

本研究針對連續旅次之門檻值係採用高公局實務操作之數值(l_{th} =0.4)。現況由於科技之進展已可透過手機通話進行定位。經由手機發話時間與地點等資訊，可確認該高速公路旅次是否為連續旅次。此可更準確獲得在不同事件發生下之連續旅次門檻值。因此後續研究可精進此定位技術，並重新校估高速公路連續旅次之門檻值。再者，亦可進一步針對事件等級與車流狀況等兩個構面之各別組合，分別校估連續旅次之門檻值，藉此準確掌握車流變異情形。因此，未來高速公路局應依據現況特性建立一交通狀態辨識模

型(例如：利用 CART 進行交通狀態之辨別)。再依該交通狀態選擇相對應之連續旅次判斷門檻值，並以此建立連續旅次之資料庫。

採用本研究所提出之虛擬變數，確實能在不增加設備下進一步提升模式預測能力。此對管理單位有實質助益。由於經由事件發生之類型與當下交通狀態(例如：速度)等兩個構面之各別組合，可對照出不同交通狀態類型。若能辨別 t 時點下之交通狀態屬於何種類型，則有助於提升對車流特性之解析。此外，就 t 時點下之交通樣本而言，事件發生下之樣本係屬於異常值，因此整體而言具有資料不平衡之特性。如何提升資料不平衡下之辨識度，即為未來研究重點。Freund and Schapire (1996)之研究證實，ensemble 方法經常比任何單一分類模型要來得準確。該研究針對 22 個基準問題(benchmark)進行測試，其中一個問題的執行結果差不多，4 個問題的結果比較差，但其它問題的表現結果都有明顯的改進。由於 ensemble 之 boosting 模式適於處理分類不平衡之問題。因此透過 ensemble 架構預測 t 時刻下是否發生事件或是判別事件型態，並設定一虛擬變數反映事件型態且以此作為預測模式之輸入變數，預期能提升在事件發生下之旅行時間預測模式之準確度。因此，建議未來相關研究可朝此方向進行專研。

參考文獻

Abdulhai, B., Porwal, H., & Recker, W., (1999), "Short term freeway traffic flow prediction using genetically-optimized time-delay-based neural networks" California PATHWorking Paper: UCB-ITS-PWP- 99-1. Berkeley, CA: Institute of Transportation Studies, University of California.

Ahmed, M. S., and Cook, A. R., (1979), "Analysis of freeway traffic time-series data by using Box-Jenkins techniques" Transportation Research Record, Vol. 722, pp. 1–9.

Ahmed, S. A., (1983), "Stochastic processes in freeway traffic Part I. Robust prediction models" Traffic Engineering & Control, Vol. 24, issue 6, pp.309–310.

Berry, J.A., and Linoff, G., (1997), "Data Mining Techniques: For Marketing, Sales, and Customer Support" New York: John Wiley and Sons, Inc.

Breiman, L., Friedman, J., Olsen, R., and Stone, C., (1984), "Classification and Regression Trees" Monterey: Wadsworth and Books.

Cerisara, C., Demange, S., and Haton, J.P., (2007), "On noise masking for automatic missing data speech recognition: a survey and discussion" Computer Speech & Language, Vol. 21, issue 3, pp.443–457.

Chacko, I., (1998), "S-P chart and instructional decisions in the classroom" International Journal of Mathematical Education in Science and Technology, Vol. 29, pp.445-450.

Chang, L. Y., (2005), "Analysis of freeway accident frequencies: negative binomial regression versus artificial neural network" Safety Science, Vol. 43, issue 8, pp.541–557.

Chang, L. Y., and Chen, W. C., (2005), "Data mining of tree-based models to analyze freeway accident frequency" Journal of Safety Research, Vol. 36, issue 4, pp.365 – 375.

Chen, H., and Rakha, H.A., (2014), "Real-time travel time prediction using particle filtering with a non-explicit state-transition model" Transportation Research Part C, Vol. 43, Part 1, pp.112–126.

Chen, M., and Chien, S. I., (2001), "Dynamic freeway travel-time prediction with probe vehicle data, link based versus path based" Transportation Research Record, Vol. 1768, pp.157–161.

Chen, H., Grant-Muller, S., Mussone, L., and Montgomery, F., (2001), "A study of hybrid neural network approaches and the effects of missing data on traffic forecasting" Neural Computing & Applications, Vol. 10, issue 3, pp. 277–286.

Chien, S. I. J., and Kuchipudi, C. M., (2003), "Dynamic travel time prediction with real-time and historic data" Journal of Transportation Engineering, Vol. 129, issue 6, pp.608–616.

Chien, S. I., Liu, X., and Ozbay, K., (2003), "Predicting travel times for the South Jersey real-timemotorist information system" Transportation Research Record: Journal of the Transportation Research Board, Vol. 1855, issue 1, pp.32–40.

Chin, S.M., Franzese, O., Greene, D.L., Hwang, H.L., and Gibson, R.C., (2004), "Temporary

loss of highway capacity and impacts on performance: Phase 2" Report No. ORLNL/TM-2004/209, Oak Ridge National Laboratory.

ChuL, Y., OhJ, S., and ReckerW., (2005), "Adaptive Kalman filter based freeway travel time estimation" Paper Presented at the 84th TRB Annual Meeting, Washington DC, January.

Chung, Y., (2010), "Development of an accident duration prediction model on the Korean Freeway Systems" Accident Analysis and Prevention, Vol. 42, issue 1, pp.282-289.

Danech-Pajouh, M., and Aron, M., (1991), "ATHENA: A method for short-term inter-urban motorway traffic forecasting" Recherche Transports Se´curite´, Vol. 6, pp. 11–16.

Demange, S., Cerisara, C., and Haton, J.P., (2009), "Missing data mask estimation with frequency and temporal dependencies" Comput.Speech &Language. Vol. 23, issue 1, pp.25–41.

Der Voort, M. V., Dougherty, M., and Watson, S., (1996), "Combining Kohonen maps with ARIMA time series models to forecast traffic flow" Transportation Research Part C. Vol. 4, issue 5, pp.307–318.

DeTienne, K.B., Detienne, D.H., and Joshi, S.A., (2003), "Neural networks as statistical tools for business researchers" Organizational Research Methods. Vol. 6, issue 2, pp.236–265.

Dharia, A., and Adeli , H., (2003), "Neural network model for rapid forecasting of freeway link travel time" Enginnering Application of Artificial Intelligence, Vol. 16, issue 7, pp.607–613.

Dia, H., (2001), "An object-oriented neural network approach to short-term traffic forecasting" European Journal of Operational Research, Vol. 131,issue 2, pp.253–261.

Dion, F., and Rakha, H., (2006), "Estimating dynamic roadway travel times using automatic vehicle identification data for low sampling rates" Transportation Research Part B, Vol. 40, issue 9, pp.745–766.

Duda, R.O., Hart, P.E., and Stork, D.G., (2001), "Pattern classification" New York: Wiley.

Elhenawy, M., Chen, H., and Rakha, H. A., (2014), "Dynamic travel time prediction using data clustering and genetic programming" Transportation Research Part C, Vol. 42, pp.82–98.

Fei, X., Lu, C.C., and Liu, K., (2011), "A Bayesian dynamic linear model approach for real-time short term freeway travel time prediction" Transportation Research Part C, Vol. 19, issue 6, pp.1306–1318.

Freeman, J. A., and Skapura, D. M., (1991), "Neural Networks: Algorithms applications, and Programming Techniques" Addison-Wesley, Reading, M.A.

Freund, Y., and Schapire, R., (1995) "A Decision-Theoretic eneralization of On-Line Learning and an Application to Boosting" European Conference on Computational Learning Theory.

Gevrey, M., Dimopoulos, I., and Lek, S., (2003), "Review and comparison of methods to study the contribution of variables in artificial neural network models" Ecological Modelling, Vol. 160, issue 3, pp.249–264.

Golob, T.F., Recker, W.W., and Alvarez, V.M., (2004), “Freeway safety as a function of traffic flow” Accident Analysis Prevention, Vol. 36, issue 6, pp.933–946.

Hall, Randolph W., (2002), “Incident dispatching, clearance and delay” Transportation Research Part A, Vol. 36, pp.1-16.

Hamed, M. S., and Cook, A. R., (1979), “Analysis of freeway traffic time-series data by using Box–Jenkins techniques” Transportation Research Record, Vol. 722, pp.1–9.

Hamed, M. M., Al-Masaeid, H. R., and Said, Z. M., (1995), “Short-term prediction of traffic volume in urban arterials” Journal of Transportation Engineering, Vol. 121, No. 3, pp.249–254.

Huisken, G., and van Berkum, E. C., (2003), “A comparative analysis of short-range travel-time prediction methods” In 82nd Transportation Research Board Annual Meeting, Washington, DC.

Innamaa, S., (2005), “Short-term prediction of travel time using neural networks on an interurban highway” Transportation, Vol. 32, pp.649–669.

International Energy Agency Statistics. CO2 Emission from Fuel Combustion. IEA Publications, 9, rue de la Federation, 75739 Paris Cedex 15 Printed in Luxembourg by Imprimerie Centrale, October 2011.

Ishak, S., and Alecsandru, C., (2004), “Optimizing traffic prediction performance of neural networks under various topological input, and traffic condition settings” Journal of Transportation Engineering, Vol. 130, No. 4, pp.452–465.

Ishak, S., Koth, P., and Alecsandru, C., (2003), “Optimization of dynamic neural network performance for short-term traffic prediction” Transportation Research Record. Vol. 1836, pp.45–56.

Joumard, R., Jost, P., Hickman, J., and Hassel, D., (1995), “Hot passenger car emissions modelling as a function of instantaneous speed and acceleration” Science of The Total Environment, Vol. 169, issues 1-3, pp.167–174.

Kalman, R. E., (1960), “A new approach to linear filtering and prediction problems” Journal of Basic Engineering, Vol. 82, issue 1, pp.35–45.

Karlaftis, M.G., and Vlahogianni, E.I., (2011), “Statistical methods versus neural networks in transportation research: Differences, similarities and some insights” Transportation Research Part C, Vol. 19, No. 3, pp.387-399.

Kass, G., (1980), “An exploratory technique for investigating large quantities of categorical data” Applied Statistics, Vol. 19, issue 2, pp.119-127.

Kirby, H.R., Watson, S.M., and Dougherty, M.S., (1997), “Should we use neural networks or statistical models for short-term motorway traffic forecasting?” International Journal of Forecasting, Vol. 13, No. 1, pp.43–50.

Kuchipudi, C. M., and Chien, S. I,. (2003), “Development of a hybrid model for dynamic travel-time prediction” Transportation Research Record: Journal of the Transportation Research Board, Vol. 1855, issue 1, pp. 22–31.

Kumar, S., (2005), “Neural Networks: A Classroom Approach” McGraw-Hill Education.

Kwon, J.Y., Coifman, B., and Bickel, P., (2000), “Day-to-day travel-time trends and travel-time prediction from loop detector data” Transportation Research Record. Vol. 1717, pp.120–129.

Konstantopoulos, P., Chapman, P., and Crundall, D., (2010), “Driver's visual attention as a function of driving experience and visibility. Using a driving simulator to explore drivers’ eye movements in day, night and rain driving” Accident Analysis Prevention, Vol 42. issue 3, pp.827-834.

Lam, W.H.K., Chan, K. S., Tam, M. L., and Shi, J. W. Z., (2005), “Short-term travel time forecasts for transport information system in Hong Kong” Journal of Advanced Transportation, Vol. 39, issue 3, pp.289–306.

Lee, S., and Fambro, D., (1999), “Application of subset autoregressive integrated moving average model for short-term freeway traffic volume forecasting” Transportation Research Record, Vol. 1678, pp.179–188.

Lederman, R., and Wynter, L., (2011), “Real-time traffic estimation using data expansion” Transportation Research Part C, Vol. 45, issue 7, pp.1062–1079.

Levin, M., and Tsao, Y. D., (1980), “On forecasting freeway occupancies and volumes (abridgment)” Transportation Research Record, Vol. 773, pp. 47–49.

Li, C.S., and Chen, M.M., (2013), “Identifying important variables for predicting travel time of freeway with non-recurrent congestion with neural networks” Neural Computing and Applications, Vol. 23, issue 6, pp.1611-1629.

Li, C.S., and Chen, M.M., (2014), “A data mining based approach for travel time prediction in freeway with non-recurrent congestion” Neurocomputing, Vol. 133, pp.74-83.

Li, R., and Rose, G., (2011), “Incorporating uncertainty in to short-term travel time predictions” Transportation Research Part C, Vol. 19, pp.1006–1018.

Liu, Henry X., and Ma, W., (2009), “A virtual vehicle probe model for time-dependent travel time estimation on signalized arterials” Transportation Research Part C, Vol. 17, No. 1, pp.11-26.

MacQueen J.B., (1967), “Some Method for classification and analysis of Multivariate Observations, Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability” Berkeley, University of California Press, 1, pp.281-297.

Manoel, C. N., Jeong, T. S., Jeong, M. K., and Lee, D. H., (2009), “Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions” Expert Systems with Applications. Vol. 36, pp.6164–6173.

Mazloumi, E., Ros, G., Currie, G., and Moridpour, S., (2011), “Prediction intervals to account for uncertainties in neural network predictions : methodology and application in bus travel time prediction” Engineering Applications of Artificial Intelligence, Vol. 24, issue 3, pp.534–542.

McSherry, D., (1999), “Strategic induction of decision trees” Knowledge-Based Systems, Vol.

12, pp.169-175.

Myung, S., and Han, S., (2001), “Knowledge-based parametric design of mechanical products based on configuration design method” Expert Systems witj Applications, Vol. 21, issue 2, pp.99-107.

Nanthawichit, C., Nakatsuji, T., and Suzuki, H., (2003), “Application of probe-vehicle data for real-time traffic-state estimation and short-term travel-time prediction on a freeway” Transportation Research Record, Vol. 2987, pp.49–59.

Nihan, N.L., (1980), “Use of the box and Jenkins time series technique in traffic forecasting” Transportation, Vol. 9, pp.125–143.

Nikovski, D., Nishiuma, N., Goto, Y., and Kumazawa, H., (2005), “Univariate short-term prediction of road travel times” In: 8th International IEEE Conference on Intelligent Transportation Systems, Vienna, Austria.

Oda, T., (1990), “An algorithm for prediction of travel-time using vehicle sensor data” IEEE 3rd Conference on Road Traffic Control, London, UK. IET (pp. 40–44).

Okutani, I., and Stephanedes, Y. J., (1984), “Dynamic prediction of traffic volume through Kalman filtering theory” Transportation Research Part B: Methodological, Vol. 18, issue 1, pp.1–11.

Park, B., Messer, C. J., and Urbanik, T. II, (1998), “Short-term traffic volume forecasting using radial basis function neural network” Transportation Research Record, Vol. 1651, pp.39–47.

Park, D.J., and Rilett, L.R., (1998), “Forecasting multiple-period freeway link travel times using modular neural networks” Transportation Research Record, Vol. 1617, pp.163–170.

Park, D. J., Rilett, L., and Han, G., (1999), “Spectral basis neural networks for realtime travel time forecasting” Journal of Transportation Engineering, Vol. 125, issue 6, pp.515-523.

Park, D., and Rilett, L. R., (1999), “Forecasting freeway link travel-times with a multilayer feed forward neural network” Computer-Aided Civil and Infrastructure Engineering, Vol. 14, issue 5, pp. 357–367.

Park, D., Rilett, L. R., and Han, G., (1999), “Spectral basis neural networks for real-time travel-time forecasting” Journal of Transportation Engineering, Vol. 125, issue 6, pp.515–523.

Park, T., and Lee, S., (2004), “A Bayesian approach for estimating link travel time on urban arterial road network” Computation Scinece and Its Applications, Vol. 3043, pp.1017–1025.

Peacock, P.R., (1998), “Data mining in marketing: Part 1” Marketing Management, Vol. 6, issue 4, pp.8-18.

Petty, K.F., Bickel, P., Ostland, M., Rice, J., Schoenberg, F., Jiang, J., and Ritov, Y., (1998), “Accurate estimation of travel time from Single-Loop detectors” Transportation Research Part A, Vol. 32, issue 1, pp.1–18.

Quinlan, J.R., (1979), “Dicovering rules by induction from large collections of examples” In

Michie, D. (ED.), Expert Systems in the Micro Electronic Age. Edinburgh: University Press.

Quinlan, J.R., (1993), "C4.5: Programs for Machine Learning" San Mateo: Morgan Kaufmann.

Raj, B., and Stern, R.M., (2005), "Missing-feature approaches in speech recognition" IEEE Signal Processing Magazine, Vol. 22, issue 5, pp.101–106.

Rice, J., and van Zwet, E., (2004), "A simple and effective method for predicting travel-times on freeways" Intelligent Transportation Systems, IEEE Transactions, Vol. 5, issue 3, pp.200–207.

Rilett, L. R., and Park, D., (2001), "Direct forecasting of freeway corridor travel-times using spectral basis neural networks" Transportation Research Record: Journal of the Transportation Research Board, Vol. 1752, issue 1, pp.140–147.

Rumelhart, D. E., Hinton, G. E. and Williams, R. J., (1986), "Learning internal representation by error propagation" Parallel Distributed Processing, Vol. 1, pp.318-362.

Saito, M., and Watanabe, T., (1995), "Prediction and dissemination system for travel-time utilizing vehicle detectors" Proceedings of the 2nd world congress on Intelligent Transport Systems, Yokohama, Japan.

Santosh, T. V., Srivastava, A., Sanyasi Rao, V. V. S., Ghosh, A. K., and Kushwaha, H. S., (2009) "Diagnostic system for identification of accident scenarios in nuclear power plants using artificial neural networks" Reliability Engineering and System Safety, Vol. 94, issue 3, pp.759–762.

Smith, B. L., and Demetsky, M. J., (1997), "Traffic flow forecasting: Comparison of modeling approaches" Journal of Transportation Engineering, Vol. 123, issue 4, pp.261–266.

Skabardonis, A., Varaiya, P., and Petty, K.F., (2003), "Measuring recurrent and nonrecurrent traffic congestion" Transportation Research Record, Vol. 1856, pp.118–124.

Soriguera, F., Rosas, D., and Robuste, F., (2010), "Travel time measurement in closed toll highways" Transportation Research Part B, Vol. 44, issue 10, pp.1242-1267.

Sun, H., Liu, H. X., Xiao, H., He, R. R.,& Ran, B., (2003), "Short term traffic forecasting using the local linear regression model" In 82nd Annual Meeting of the Transportation Research Board,Washington, DC.

Stathopoulos, A., and Karlaftis, M. G., (2003), "A multivariate state space approach for urban traffic flow modeling and prediction" Transportation Research Part C, vol. 11, issue 2, pp.121-135.

SwRI, (1998), "Automatic vehicle identification model deployment initiative—system design document" Report prepared for TransGuide, Texas Department of Transportation, Southwest Research Institute, San Antonio, TX.

Tam, M. L., and Lam, William H.K., (2010), "Application of automatic vehicle identification technology for real-time journey time estimation" Information Fusion, Vol. 12, issue 1, pp.11-19.

Vanajakshi, L. D., (2004), “Estimation and prediction of travel-time from loop detector data for intelligent transportation systems applications (Doctoral dissertation)” Texas A&M University.

Vanajakshi, L., and Rilett, L. R., (2004), “A comparison of the performance of artificial neural networks and support vector machines for the prediction of traffic speed” In IEEE intelligent vehicles symposium.

VanArem, B., VanDerVlist, M.J.M., Muste, M.R., and Smulders, S.A., (1977), “Travel time estimation in the GERDIEN project” International Journal of Forecasting, Vol. 13, issue 1, pp.73–85.

Vanderschuren, M., (2008), “Safety improvements through intelligent transport systems: a South African case study based on microscopic simulation modelling” Accident Analysis Prevention, Vol. 40, issue 2, pp.807–817.

van der Voort, M., Dougherty, M., and Watson, S., (1996), “Combining Kohonen maps with ARIMA time series models to forecast traffic flow” Transportation Research Part C: Emerging Technologies, Vol. 4, issue 5, pp. 307–318.

van Hinsbergen, C. P., Schreiter, T., Zuurbier, F. S., van Lint, J. W. C., and van Zuylen, H. J., (2012), “Localized extended kalman filter for scalable real-time traffic state estimation” Intelligent Transportation Systems, IEEE Transactions, Vol. 13, issue 1, pp.385–394.

van Hinsbergen, C. P. I.,and van Lint, J.W., (2008), “Bayesian combination of travel time prediction models” Transportation Research Record: Journal of the Transportation Research Board, Vol. 2064, issue 1, pp. 73–80.

van Lint, H., and Djukic, T., (2012), “Applications of Kalman filtering in traffic management and control” In P. Mirchandani (Ed.), Informs tutorials in operations research (Vol. 9, pp. 59–91). Hanover, MD: INFORMS.

van Lint, J. W. C., Hoogendoorn, S. P., and Van Zuylen, H. J., (2002) “Freeway travel time prediction with state-space neural networks—Modeling state-space dynamics with recurrent neural networks” Traosportation Research Record, Vol. 1811, pp.30-39.

Van Lint, J.W.C., Hoogendoorn, S.P., and Van Zuylen, H.J., (2005) “Accurate travel time prediction with state-space neural networks under missing data” Transportation Research Part C, Vol. 13, pp.347–369.

van Lint, J. W., (2006), “Reliable real-time framework for short-term freeway travel-time prediction” Journal of Transportation Engineering, Vol. 132, issue 12, pp.921–932.

Van Lint, J.W.C., (2008), “Online Learning Solutions for Freeway Travel Time Prediction” IEEE Transactions On Intelligent Transportation Systems, Vol. 9, issue 1, pp.38-47.

Vythoulkas, P. C., (1993), “Alternative approaches to short term traffic forecasting for use in driver information systems” In International Symposium on the Theory of Traffic Flow and Transportation. Transportation and traffic theory, Berkeley, CA.

Wang, Y., and Papageorgiou, M., (2005), “Real-time freeway traffic state estimation based on extended Kalman filter: ageneral approach” Transportation Research Part B,Vol. 39, issue

2, pp.141–167.

Wedel, M., and Kamakura, W.A., (2000), "Market Segmentation-Conceptual and Methodological Foundations" Dordrecht: Kluwer.

Wei, C. H., and Lee, Y., (2007), "Sequential forecast of incident duration using Artificial Neural Network models" Accident Analysis and Prevention, Vol.39, pp.944–954.

Whittaker, J., Garside, S., and Lindveld, K., (1997), "Tracking and predicting a network traffic process" International Journal of Forecasting, Vol. 13, issue 1, pp. 51–61.

Wu, C. H., Wei, C. C., Su, D. C., Chan, M. H., and Ho, J. M., (2004), "Travel time prediction with support vector regression" In IEEE Transactions on Intelligent Transportation Systems, Vol. 5, issue 4, pp.276-281.

Xiao, H., Sun, H., Ran, B., and Oh, Y., (2004), "Special factor adjustment model using fuzzy-neural network in traffic prediction" Transportation Research Record, Vol. 1879, pp.17–23.

Yada, K., (2001), "String analysis technique for shopping path in a supermarket' Journal of Intelligent Information System, Vol. 36, issue 3, pp.385-402.

Yang, J. S., (2005), "Travel time prediction using the GPS test vehicle and Kalman filtering techniques" In American Control Conference, 2005. Proceedings of the 2005, Portland, OR. IEEE (pp. 2128–2133).

Yasui, K., Ikenoue, K., and Takeuchi, H., (1995), "Use of AVI information linked up with detector output in travel time prediction and OD flow estimation" In Steps Forward. Intelligent Transport Systems World Congress (Vol. 1).

Yeon, J., Elefteriadou, L., and Lawphongpanich, S., (2008), "Travel time estimation on a freeway using Discrete Time Markov Chains" Transportation Research Part B, Vol. 42, pp.325–338.

Yildirimoglu, M., and Geroliminis, N., (2013), "Experienced travel time prediction for congested freeways" Transportation Research Part B, Vol. 53, pp.45–63.

Yu, J., Chang, G. L., Ho, H.W., and Liu, Y., (2008), "Variation based online travel time prediction using clustered neural networks" In Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on. Beijing, China. IEEE (pp. 85–90)

Yuan, F., and Cheu, R. L., (2003), "Incident detection using support vector machines" Transportation Research Part C, Vol. 11, pp.309–328.

Zhang, X., and Rice, J. A., (2003), "Short-term travel time prediction" Transportation Research Part C, Vol. 11, pp.187-210.

Zhang, K., Cui, L., Wang, H., and Sui, Q., (2007), "An Improvement of Matrix-based Clustering Method for Grouping Learners in E-Learning" 11th International Conference on Computer Supported Cooperative Work in Design.

Zhang, G., Patuwo, B. E., and Hu, M. Y., (1998), "Forecasting with artificial neural networks: The state of the art" International Journal of Forecasting, Vol. 14, pp.35-62.

Zhong, M., Lingras, P., and Sharma, S., (2004), "Estimation of missing traffic counts using

factor, genetic, neural, and regression techniques" Transportation Research Part C, Vol. 12, pp.139–166.

Zhong, M., Sharma, S., and Lingras, P., (2005), "Refining genetically designed models for improved traffic prediction on rural roads" Transportation Planning and Technology, Vol. 28, pp.213–236.

Zurada, J. M., (1992), "Introduction to Artificial Neural Systems" West Publishing Company, St. Paul, MN.

http://www.cwb.gov.tw/V6/index.htm

http://www.freeway.gov.tw/traffic_density.aspx

http://www.freeway.gov.tw/UserFiles/File/2009 年 990203.pdf

邱孟佑 (2010),「以交通狀態為基礎之旅行時間預測」,國立交通大學交通運輸研究所博士論文。

王偉丞 (2010),「生鮮產品貨架壽命管理暨銷售指派」,國立交通大學交通運輸研究所碩士論文

葉怡成 (2003),「類神經網路模式應用與實作 八版」,儒林圖書有限公司,台北市。