

逢甲大學
交通工程與管理學系碩士班
碩士論文

高速公路短期交通資訊之灰預測模型

**GREY PREDICTION MODELS FOR FREEWAY
SHORT-TERM TRAFFIC INFORMATION**

指導教授:邱裕鈞

研 究 生:邱妍菁

中 華 民 國 九 十 五 年 六 月 三 十 日

誌謝

本篇論文定稿之際，研究所生涯緩緩落幕，回首修業期間酸甜苦辣，點滴在心頭，然曲終將散，熱淚盈眶，踏上新的里程碑，昂首闊步，無限感激銘記在我心。

首先感謝指導教授邱裕鈞老師對學生之論文悉心指導，克盡傳道之責，竭力授業，不吝解惑，引領我進入學術研究之大千世界。感謝馮正民教授與魏健宏教授，兩位口試委員對學生論文之細心審閱，提出寶貴的意見與輔證，使本篇論文得以更加完整。

感謝顏秀吉老師在修業期間之諄諄教誨，讓學生窺見學術與實務並駕齊驅之磅礴氣勢，增廣見聞，您苦口婆心告誡處事之道，使我精進不已。感謝林良泰老師、艾嘉銘老師在論文最後關頭，給予神來之筆的指導與協助，以及台大黃宏仁學長不吝批判，皆令我精益求精，「論文是一輩子的事！」學生將深深烙印心坎。

感謝高速公路局中區交控中心劉大偉主任、陳基銘先生、陳孟佑領班之支持鼓勵，感謝交通工程師白豐源、簡任甫、卓嘉良、李翰宗，提供研究資料協助，電腦工程師張勝至，給於電腦資訊輔佐，還有王世傑學姐、郭熹、明志、秋竹、志憲、种翰、志傑、國雄大哥、定洲兄等人之鼎力支持。

感謝蘇怡如傳授 ARIMA 心法、陳炯男之防毒軟體、徐書彥之程式設計、黃彥斐、郭耀彰、郭芳吟、蔡佩真、李夢盈、蔡瑞美姐等人之精神支柱。

感謝我的同窗摯友劉欣憲、陳怡霖在研究路上之相互扶持，感謝鵬升、欣翰、昱彰、仁維、梅舜、堂展、姿雁、智淮、耿禎、雅博、志豪、宗勳、家勝、智超、芋頌、聖奇、尚輯、韻珏、庭銀、雅雯等人在生活上之陪伴。

感謝含辛茹苦的父母親，邱文進先生與陳純女士，感謝您的養育與栽培，感謝我摯愛的親人瀚宇、昱棋大哥、小妹妍華、表妹怡文做我永遠的後盾。

僅以本文獻給一路扶持我的家人、師長、朋友們。

邱妍菁 僅誌於

逢甲大學交通工程與管理學系碩士班

中華民國九十五年七月

摘要

交通資訊是交通控制實施及交通資訊提供之重要依據，如何取得即時且正確之交通資訊實為 ITS 服務系統能不能成功運作的重要因素。然蒐集交通資訊之偵測器佈設位置未必符合實際實施交通控制之處（如匝道儀控），因此有必要進行交通相關資訊之預測，以作為交通控制之基礎。此外，旅行者資訊系統（行前或途中）所提供之”即時”資訊，其實距用路人真正使用該道路之實際時間，可能會相隔一段時間。因此，適當長度之交通資訊預測確有其必要性。

然由於交通資訊會因交通組成、方向分佈、車道分佈、道路分類、道路服務性質，路線設計、交通管制方式、道路容量等因素有所影響，要加以精確預測並不容易。因此，已有許多研究利用時間序列分析、迴歸分析、類神經網路、狀態空間方法、混沌理論等方法探討此一課題。而灰預測模型之績效在許多領域之應用上已獲驗證，且由於其校估時所需樣本數甚少，而參數計算又簡單容易，應用上極具彈性。而且透過滾動學習方式(RGM)隨時更新模式更可進一步提昇預測績效。基此，本文乃利用滾動灰預測模型進行短期交通資訊之預測。

本文主要構建兩種動態交通資訊預測模式，分別為單元數列預測模式 $RGM(1,1)$ 及多元預測模式 $RGM(1,N)$ ，其中， $RGM(1,1)$ 主要是以偵測器所蒐集之歷史時間序列資料，對未來時階進行預測， $RGM(1,N)$ 則是應用相關資訊進行交通資訊預測，以同一偵測器之交通量、速度、佔有率資料、觀測路段上下游偵測器資料、歷史資料等構建模式。模式之資料單位為 20 秒一筆，本研究分別加以彙整成 1 分鐘及 5 分鐘進行預測，探討不同單位長度資料之預測結果，同時進行不同滾動時階（4~8 階）及不同預測長度（1~5 筆）下，模型預測績效之表現，最後，應用時間序列模式（ARIMA）與人工類神經網路模式（ANN）作為模式績效驗證之對照模式。

本研究蒐集國道 1 號中部路段車輛偵測器所蒐集之交通資訊主要包括交通量、平均速度及佔有率資料，以資料之 70% 作為訓練組，30% 作為驗證組，並以平均絕對百分誤差（MAPE）作為模式績效評估指標。預測結果顯示， $RGM(1,1)$ 中，一分鐘單位資料-滾動時階 4 模式，在交通量之預測結果，其 $MAPE=17.51\%$ ，平均速度之 $MAPE=3.46\%$ ，佔有率之 $MAPE=9.81\%$ ，顯示 $RGM(1,1)$ 明顯優於 ARIMA 模式（交通量 $MAPE=42.77\%$ ，平均速度

MAPE=11.51%，佔有率 MAPE=33.88%)；在 RGM (1,N) 方面，交通量 RGM (1,6) 之 MAPE=5.44%，平均速度為 0.05%，佔有率為 4.44%，顯示 RGM (1,N) 模式明顯優於 ANN 模式（交通量 MAPE=15.34%，平均速度 MAPE=7.54%，佔有率 MAPE=16.73%）及 RGM(1,1)模式。藉此得證灰色預測準確度優於時間序列模式及類神經網路預測模式。

關鍵詞：短期交通資訊，灰預測模式，人工類神經網路，ARIMA



ABSTRACT

The real-time traffic information detected by traffic devices might be outdated to implement dynamic traffic management and real-time traffic responsive control, because of the time lag caused by the transitions and calculations of these information or because of the significant distances between these traffic detection devices and traffic control points. Traffic control operators have to recognize how these information will evolve in the near future. Thus, an accuracy and efficiency short-term traffic forecast model is extremely essential to traffic control. Although numerous short-term traffics forecasting models have been proposed and validated, some of them are too complex in field application or others do not excellently perform. In contrast, the grey prediction model has overwhelming advantages of high accuracy, easy calculation and few calibrated samples required, therefore, this study aims to develop rolling grey prediction models (RGM) to forecast the short-term traffics.

Two RGM models are developed, RGM(1,1) and RGM (1,N). RGM(1,1) only considers the historical time-series data of a specific traffic information detected by a specific vehicle detector (VD). RGM(1,N) further considers the other related information, such as volume, speed and occupancy detected by neighbored VDs. For investigating and validating the accuracy and applicability of proposed models, three time horizons of short-term traffic data of 20-seconds, 1-minute and 5-minutes are collected. For comparison, two commonly used short-term traffic forecast models, statistical time-series model (ARIMA) and artificial neural network (ANN), are also developed and compared.

All traffic datasets, including three major traffics: volume, occupancy and speed, are collected from national No.1 freeway in Taiwan. Each of them is further divided into two subsets for training (70%) and validation (30%), respectively. The accuracies in term of mean absolute percent error (MAPE) of different numbers of rolling intervals (4-8interval) and forecast periods (1-5period) of the proposed model are also compared. The results show that, taking four rolling intervals and one forecast period RGM(1,1) model on 1-minute traffics for instance, it can predict volume with MAPE =17.51%, speed with MAPE=3.46%, and occupancy with MAPE=9.81%, which are

significantly better than those of ARIMA (42.77% for volume, 11.51% for speed and 33.88% for occupancy). Furthermore, the RGM(1,6) can accurately predict volume with MAPE =5.44%, speed with MAPE=0.05% and occupancy with MAPE=4.44%, which are still remarkably better than those of ANN (15.34% for volume, 7.54% for speed and 16.73% for occupancy) and those of RGM(1,1). Obviously, the performances and applicabilities of proposed RGM models are validated.

Key Words: Short-term traffics, grey prediction model, artificial neural network, ARIMA.



目錄

誌謝	I
摘要	II
英文摘要	IV
目錄	VI
圖目錄	IX
表目錄	X
第一章 緒論	1
1.1 研究動機與背景	1
1.2 研究目的	2
1.3 研究範圍	3
1.4 研究內容與流程	3
第二章 文獻回顧	7
2.1 灰色理論與灰預測模型	7
2.1.1 農業產銷	9
2.1.2 交通運輸	10
2.1.3 環境工程	12
2.2 交通量預測方法	13
2.2.1 平滑常數的應用	13
2.2.2 資料之數據特性	14
2.2.3 其他預測方法	14
2.2.4 交通量預測方法之應用	15
2.3 綜合評析	19
第三章 研究方法	23
3.1 單元數列預測模式	23
3.1.1 GM(1,1)模式	23

3.1.2 RGM(1,1)模式	25
3.2 多元預測模式	26
3.2.1 GM(1,N)模式	26
3.2.2 RGM(1,N)模型	28
3.3 對照模式	30
3.3.1 ARIMA模式	30
3.3.2 類神經網路	34
第四章 單元數列模式構建與驗證	38
4.1 資料蒐集與樣本描述	38
4.2 灰預測模型	42
4.2.1 交通量	43
4.2.2 平均速度	46
4.2.3 佔有率	50
4.3 ARIMA模型	55
4.3.1 交通量	55
4.3.2 平均速度	58
4.3.3 佔有率	60
4.4 小結	62
第五章 多元預測模式構建與驗證	64
5.1 灰關聯分析	64
5.1.1 交通量灰關聯分析	65
5.1.2 平均速度灰關聯分析	66
5.1.3 佔有率灰關聯分析	67
5.2 RGM (1,N) 模式	69
5.2.1 交通量預測模式	70
5.2.2 平均速度預測模式	72
5.2.3 佔有率預測模式	73
5.3 類神經網路模式	75
5.3.1 交通量預測模式	75

5.3.2 平均速度預測模式	79
5.3.3 佔有率預測模式	81
5.4 小結	84
第六章 結論建議	86
6.1 結論	86
6.2 建議	89
參考文獻	91
(一) 中文部分	91
(二) 英文部分	93



圖目錄

圖 1.1 研究流程圖	6
圖 2.1 灰預測類型總覽	21
圖 3.1 三層之類神經網路架構圖	34
圖 4.1 RGM(1,1)灰預測系統	42
圖 4.2 滾動時階 4 之誤差率與交通量變異係數之各日分佈型態	45
圖 4.3 滾動時階 4 之D2 交通量預測值與實際值之分佈情形	45
圖 4.4 滾動時階 4 之誤差率與平均速度變異係數之各日分佈型態	49
圖 4.5 滾動時階 4 之D3 平均速度預測值與實際值之分佈情形	49
圖 4.6 滾動時階 4 之誤差率與佔有率標準差間之關係	53
圖 4.7 滾動時階 4 之D3 佔有率預測值與實際值之分佈情形	53
圖 4.8 交通量之ACF圖	57
圖 4.9 交通量之PACF圖	57
圖 4.10 平均速度之ACF圖	59
圖 4.11 平均速度之PACF圖	59
圖 4.12 佔有率之ACF圖	61
圖 4.13 佔有率PACF圖	61
圖 5.1 RGM (1,N) 灰預測系統	69
圖 5.2 交通量類神經網路預測模式架構圖	76
圖 5.3 平均速度類神經網路預測模式架構圖	79
圖 5.4 佔有率預測類神經網路模式架構圖	82

表目錄

表 2.1 傳統上的預測方法及其限制	8
表 2.2 交通量預測方法之應用文獻彙整表	18
表 2.3 交通量預測方法之優缺點比較表	19
表 2.4 灰預測模式與對照模式之特性分析	22
表 3.1 MAPE & RMSPE之預測能力等級	33
表 4.1 一分鐘交通量資料基本統計分析	39
表 4.2 一分鐘平均速度資料基本統計分析表	39
表 4.3 一分鐘佔有率資料基本統計分析表	40
表 4.4 五分鐘交通量資料基本統計分析	40
表 4.5 五分鐘平均速度資料基本統計分析表	41
表 4.6 五分鐘佔有率資料基本統計分析表	41
表 4.7 不同滾動時階之交通量平均預測誤差	44
表 4.8 不同滾動時階之交通量平均預測誤差	44
表 4.9 不同預測長度之交通量平均預測誤差	46
表 4.10 不同預測長度之交通量平均預測誤差	46
表 4.11 不同滾動時階之平均速度平均預測誤差	47
表 4.12 不同滾動時階之平均速度平均預測誤差	48
表 4.13 不同預測長度之平均速度平均預測誤差	50
表 4.14 不同預測長度之平均速度平均預測誤差	50
表 4.15 不同滾動時階之佔有率平均預測誤差	51
表 4.16 不同滾動時階之佔有率平均預測誤差	52
表 4.17 不同預測長度之平均佔有率平均預測誤差	54
表 4.18 不同預測長度之平均佔有率平均預測誤差	54
表 4.19 RGM(1,1)與ARIMA之交通量預測結果（一分鐘單位）	57
表 4.20 RGM(1,1)與ARIMA之交通量預測結果（五分鐘單位）	57
表 4.21 RGM(1,1)與ARIMA之平均速度預測結果（一分鐘單位）	59
表 4.22 RGM(1,1)與ARIMA之平均速度預測結果（五分鐘單位）	59
表 4.23 RGM(1,1)與ARIMA之佔有率預測結果（一分鐘單位）	61
表 4.24 RGM(1,1)與ARIMA之佔有率預測結果（五分鐘單位）	61

表 5.1 交通量預測變數灰關聯序列表	66
表 5.2 交通量預測變數灰關聯係數表	66
表 5.3 平均速度預測變數灰關聯序列表	67
表 5.4 平均速度預測變數灰關聯係數表	67
表 5.5 佔有率預測變數灰關聯序列表	68
表 5.6 佔有率預測變數灰關聯係數表	68
表 5.7 交通量RGM (1,N) 模式之預測精確度彙整表	71
表 5.8 平均速度RGM (1,N) 模式之預測精確度彙整表	73
表 5.9 佔有率RGM (1,N) 模式之預測精確度彙整表	75
表 5.10 交通量類神經網路訓練模式相關參數設定表	77
表 5.11 交通量類神經網路預測模式之訓練結果	78
表 5.12 交通量驗證資料於類神經網路預測模式之預測結果表	78
表 5.13 平均速度類神經網路訓練模式相關參數設定表	80
表 5.14 平均速度類神經網路預測模式之訓練結果	81
表 5.15 平均速度驗證資料於類神經網路預測模式預測結果表	81
表 5.16 佔有率類神經網路訓練模式相關參數設定表	83
表 5.17 佔有率類神經網路預測模式之訓練結果	84
表 5.18 佔有率驗證資料於類神經網路預測模式預測結果表	84
表 5.19 一分鐘單位資料之最佳模式預測準確度比較表	85

第一章 緒論

1.1 研究動機與背景

藉由交通量資料，可以了解道路使用情況與車流分佈狀態，以作為調整路網、裝設交通管制設施以及改善或新建道路系統的依據。而交通資訊會因時間、交通組成、方向分佈、車道分佈、道路分類、道路服務性質、路線設計、交通管制方式、道路容量等因素有所影響。同時交通流量具備相互比較的基本尺度，在研究、規劃、設計交通工程和執行交通管理時皆用交通流量作為根據，所以計量交通對任何路段或交通設施的設計都非常重要。

「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)」乃是智慧型運輸系統 (Intelligent Transportation System; ITS) 之發展核心，藉由交通量變化之模式可依各種交通預測進行匝道儀控、號誌管制等相關策略，而即時交通資訊亦可透過交通量變化模式，分析交通擁擠區域、意外事故地點、旅行時間等重要之道路狀況訊息。交通量準確的預測可準確推估動態旅行時間，將可即時提供用路人選擇其適當之行駛路徑、出發時間等，以避開交通擁擠路段，並以最短之旅行時間到達其目的地。

如何取得即時且正確之交通資訊實為該服務系統能不能成功運作的重要因素。然大部份交通資訊係透過偵測器加以蒐集，惟偵測器佈設位置未必符合實際實施交通控制之處（如匝道儀控），因此有必要進行交通相關資訊之預測，以作為交通控制之基礎。此外，旅行者資訊系統（行前或途中）所提供之”即時”資訊，其實距用路人真正使用該道路之實際時間，可能會相隔一段時間。因此，適當長度之交通資訊預測確有其必要性。

在交通量預測，以基年時間長短來區分，基年較長者，通用應用於中、長程的交通工程設計與運輸規劃方案；而基年較短者，除了可作為交通資訊的提供與研擬即時的交通控制策略外，也可

應用於反應無法預期的車流事件。過去的交通量可經由調查而得知，對於未來的交通量則需以預測方法來求得。由於交通量具有隨時間與空間而變化的動態特性，若能找出一套能有效地預測交通量變化之模式，交控單位即可依各種交通預測適時修正控制策略並作出最適之反應。

對於交通量有許多不同的預估方法，如：時間序列分析模式、迴歸分析、類神經網路、狀態空間方法、灰色理論...等。而由短期交通資訊的特性來看，我們所能收集或掌握的樣本資料有限，同時也不確定其分佈型態，無法以時間序列分析或迴歸分析這種需要有一定要求樣本數量的統計方法來作，而灰色理論是利用「生成技術」來使預測結果更為準確。本研究試著去驗證灰預測在短期交通量的適用性、準確性。能夠準確預測交通量，就能使潛在危險性降至最低，並同時作一個積極有效的預防措施。而灰預測模型之績效在許多領域之應用上已獲驗證，且由於其校估時所需樣本數甚少，而參數計算又簡單容易，應用上極具彈性。灰預測參數的精確度，可利用殘差檢驗、平均誤差平方值、平均誤差絕對值、平均誤差百分比絕對值等指標來檢驗，而且透過滾動學習（rolling-trained）方式隨時更新模式更可進一步提昇預測績效；灰預測它所需最少樣本數只要 4 筆以上即可，且數學計算又簡單容易。因此，本研究以灰預測模型作為研究探討的主題。

1.2 研究目的

本研究即是嘗試以灰預測方法建立一個國內高速公路之短期交通資訊灰預測模式，主要之研究目的即藉由高速公路主線路段之車輛偵測器資料，以灰預測方法建立交通資訊灰預測模式，可供未來國內實務上應用之參考，研究目的條列如下：

1. 將蒐集完成之偵測器資料，以 $GM(1,1)$ 模型及滾動模型（ $RGM(1,1)$ ）分別建構高速公路短期交通資訊（交通量、平均速度及佔有率）之預測模型。
2. 分析探討不同滾動週期、滾動時階以及模式中分類變數與

灰預測參數的精確度之關係。

3. 由於傳統時間序列 ARIMA 預測模型，其所使用之資料特性與 GM(1,1)相同，皆為單純的時間序列資料，且 ARIMA 模型在統計學上是已確立的方法，因此本研究以 ARIMA 模型作為比較模式，藉以了解灰預測模式之預測績效。
4. 選擇預測績效較佳之單元模式，進一步以多階模型 (GM(1,N)) 進行分析，加入同一偵測器資料 (交通量、速度、佔有率) 三者間之關連變數、上下游偵測器資料、有無事件等分類變數，建立滾動多階灰預測模型 (RGM(1,N))。
5. 多變數預測模式以迴歸分析及類神經網路 (ANN) 最具代表性，由於 ANN 之預測績效表現較佳，因此本研究以 ANN 模型作為 GM(1,N)之比較模式，藉以了解多元模式之預測績效。

1.3 研究範圍

本研究透過佈設於高速公路路段之車輛偵測器，蒐集交通量基礎資料，構建灰預測模式，以國道一號中部路段，南起斗南北至竹南，沿線佈設之環路線圈偵測器所測得之全日交通量、平均速度及佔有率等數據資料為研究對象。資料的格式是分車道分車種統計，在埋設偵測器路段分為三個車道，車種則分為小車、大車及聯結車，資料數據包含交通量、速度、佔有率等，將資料予以彙整 (交通量為加總資料，速度及佔有率則是平均資料)，將每 20 秒一筆之資料分別彙整成 1 分鐘、5 分鐘一筆，故以 1 分鐘為單位之資料，每支偵測器全日資料共計有 1440 筆；以 5 分鐘為單位之資料，每支偵測器全日資料共計有 288 筆。資料蒐集期間於民國 94 年 1 月 1 日起，至民國 94 年 9 月 30 日止。

1.4 研究內容與流程

本研究之研究流程首先要確立研究之目的與研究範圍，回顧以往相關之文獻最為研究參考之用，文獻回顧分為二個部份，一為灰色理論與灰預測模型之相關研究，另一為短期交通量之預測

之研究方法回顧。綜合文獻回顧之心得，建構 $GM(1,1)$ 與滾動之灰預測模型 $RGM(1,N)$ ，滾動模式是利用 $GM(1,1)$ 模式進行滾動設計，並以實際資料倒入模式中驗證其精確度，探討不同預測長度與滾動時階之差異性，將相同資料套用於 ARIMA 模式並進行比較分析，最後評估灰預測模式之實驗績效，證明其預測結果優於 ARIMA 模式，最後以 $RGM(1,N)$ 模式，以灰關聯方法分析關聯變數並進行預測，找出最佳多階灰預測模式，藉以提出相關建議供後續研究之參考。本研究之研究內容如下：

■ 第一章 緒論

說明提供一個準確的即時交通資訊並進而準確地預估用路人之旅行時間，未來將更加迫切需要，而灰預測模型之績效在許多領域之應用上已獲驗證，且由於其校估時所需樣本數甚少，而參數計算又簡單容易，應用上極具彈性。而且透過滾動學習（rolling-trained）方式隨時更新模式更可進一步提昇預測績效；灰預測它所需最少樣本數只要 4 筆以上即可，且數學計算又簡單容易，故以灰預測模型作為研究探討的主題。

■ 第二章 文獻回顧

回顧過去灰色理論在各領域中應用與研究結果，了解灰色理論之研究方法，分析灰預測模型之預測績效以作為本研究之參考依據。回顧國內外研究學者應用相關之研究方法進行短期交通量預測，包括傳統統計方法、時間序列分析、混沌理論及類神經網路等，最後整合相關文獻以選定一適合模式與灰預測模式進行精確度驗證。

■ 第三章 研究方法

研究方法針對灰色理論中之灰預測方法進行探討，包括基礎之單元模式，即灰預測模型 $GM(1,1)$ 與具滾動特性的 $RGM(1,1)$ 模式之建構方法，並研究多元預測模式，即多階灰預測模型 $GM(1,N)$ ，先利用灰關聯方法分析 $GM(1,N)$ 模式中關聯變數之相關係數，決定選擇變數之優先順序，再以滾動設計構建多階灰預測模型 $RGM(1,N)$ 。基於模式之績效驗證，本研究選定 ARIMA 模式及類神經網路作為績效驗證對照模式。

■ 第四章 單元數列模式構建與驗證

根據前章之灰預測基礎模型，利用蒐集研究範圍內高速公路之環路線圈偵測器資料進行模式實證，分別以 1 分鐘、5 分鐘為單位構建 $GM(1,1)$ 及滾動 $RGM(1,1)$ 模式，分析兩種模式之預測績效結果，探討滾動 $RGM(1,1)$ 模式中，不同滾動週期與不同預測長度之預測精確度，依據驗證結果選出最佳模式，並以相同資料應用 ARIMA 模式進行測試，比較兩模式之驗證績效，證明最佳模式之績效明顯優於 ARIMA 模式。

■ 第五章 多元預測模式構建與驗證

因車流、速度與密度關係 (Q-K-V)，其中一者，可利用其他兩者資料，透過 Q-K-V 關係圖加以預測，本研究將依據前章之最佳預測模式進一步構建 $GM(1,N)$ 模式，應用同一偵測器之交通量、速度、佔有率資料，以整合方式同時進行預測，其變數包括三者間之關連變數、上下游偵測器資料等。 $GM(1,N)$ 模式構建初期，先以灰關聯方法分析模式中變數與預測準確度之相關係數，找出影響預測準確值之數個主因變數，最後以滾動設計構建 $RGM(1,N)$ 模式，在 $RGM(1,N)$ 模式中找出最佳多階灰預測模式，並以類神經網路作為績效驗證對照模式。

■ 第六章 結論與建議

根據本研究過程中發現之問題與研究結果，進行歸納分析，提出具體之研究結論與未來後續研究之建議。

本研究之研究流程圖如圖 1.1 所示。

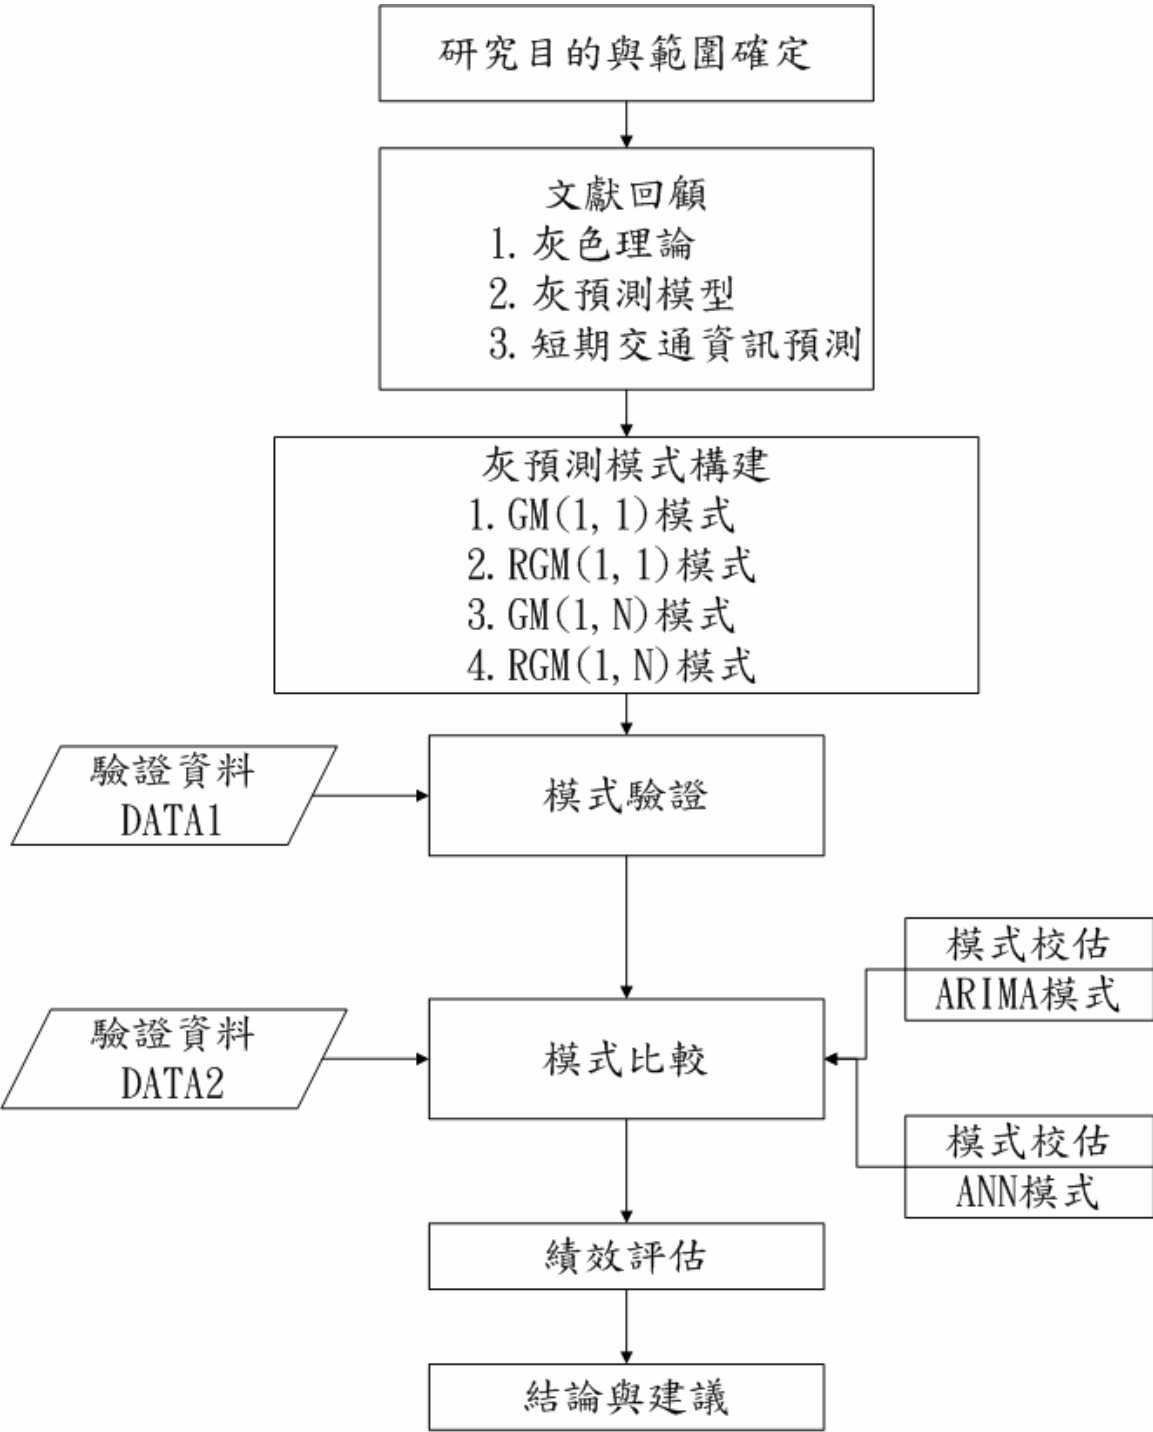


圖1.1 研究流程圖

圖 1.1 研究流程圖

第二章 文獻回顧

本研究之文獻回顧分為二個部份，一為灰色理論與灰預測模型之相關研究，另一為交通量之預測之研究方法回顧，詳述如后。

2.1 灰色理論與灰預測模型

灰色系統理論為一種將事物分為灰、白、黑三種的思想模式。白色思維為事物的規律性具唯一性與確定性；黑色思維強調事物的規律相當模糊且不確定，發生的情形具偶發性；對事物規律不具完全瞭解的情形下，如何從少數對事物已知的白色思維中尋找事物的規律，即一種白因白果、白因灰果、灰因白果關係思維，即為灰色理論的精髓。【17、23】

在系統理論的發展歷史上，1945 年控制論學 N.Wiener 的 Closed Box 與 1953 年 W.R Ashby 的 Block Box 都是用來定義內部結構及特性，參數全部未知，只好以對象外部及直接的直觀的因果關係及輸入輸出關係來研究這類事物。【18】而在鄧聚龍提出灰色系統理論前，乃是以系統外部特徵去研究，並未利用系統內部之白訊息。1982 年鄧聚龍提出灰色系統理論分析(grey system theory)，該理論主要是針對系統模型之不明確性，資訊之不完整性之下，進行關於系統的關連分析 (relational analysis)、模型建構 (constructing a model)、藉預測 (prediction) 及決策 (decision) 之方法來探討及瞭解系統【4】。

所謂灰色系統理論的定義是：系統模型之不明確及資訊之不完整性之下，進行關於系統預測分析。灰預測 (Grey Prediction) 是以 GM(1,1)模型為基礎對現有數據所進行的預測方法，實際上則是找出某一數列中間各個元素之未來動態狀況，主要的優點為所需的數據不用太多及數學基礎相當的簡單【1】。一般在對系統作分析時，均以已有之數據，利用統計與機率之方法加以分析，以求達到評估、預測及決策之目的。但統計之方法需要大量之數據，而事實上，大量之數據之獲得是相當不容易的，故而大多數之系統中所能得到的之訊息是相當有限的，也就是所謂之貧訊息，而灰色分析正是針對此種貧訊息之條件下對系統作分析而設

立的【4】。鄧聚龍【21】亦指出當數據太少時，不能成為有規律的分佈，概率統計不能研究；此外，數據太少也無法獲得經驗，模糊理論也不適合，或者在統計結果與經驗處置都不理想時，可利用灰色系統。

由此可知，灰色理論在理論基礎方面，利用朦朧集（hazy set），在一確定命題下，用不斷補充內部資源的方式，將不明確的狀態逐漸變成明確；在數據特性方面，其處理問題只需少量數據（最少 4 筆）且強調現實資訊，現實資訊必是少量的，而少量數據不可能構成某種分佈，故灰色系統理論允許數據為任意分佈型態；在運算方式方面，以生成方式（grey generating）方式，即指數運算，目的在使分析提供可比數據，並為建模提供合理的數據基礎，使樣本呈現一致性；在思維方面，以資訊覆蓋（information cover）為依據，不同於統計的歷史規律資料【23】。

灰預測方法是在找出某一數列中間各個元素之未來動態狀況，在表 2.1 中列出了傳統上做預測的方法及灰色預測的特點。

表 2.1 傳統上的預測方法及其限制

數學的方式	所需最少之數據	數據之型態	數據之間隔	準備時間	數學需求
簡單指數型	5 至 10 個	等間距	短間隔	短	基本
Holt's 指數型	10 至 15 個	同趨勢	短或中間隔	短	稍高
Winter's 指數型	至少 5 個以上	同趨勢且具規律性	短或中間隔	短	中等
迴歸分析法	10 或 20 個以上	同趨勢且具規律性	短或中間隔	短	中等
Causal 迴歸法	10 個以上	可各種型態相互混合	短、中及長間距	長	高等

時間序壓縮法	2 個峰值以上	同趨勢、具規律性且可自我調整	短或中間隔	短(稍長)	基本
Box Jenkins 法	50 個以上	等間距	短、中及長間距	長	高等
灰色預測法	4 個	等間距及非等間距	短、中及長間距	短	基本

資料來源：張偉哲、溫坤豐、張廷政，2000【18】

1982 年鄧聚龍提出灰色系統理論分析(grey system theory)後，經由各界學者積極研究努力下，今已被廣泛應用於各個領域並得到有效的論證與預測，本研究列舉農業產銷、交通運輸、以及環境工程之相關文獻進行回顧。

2.1.1 農業產銷

1. 黃光宇 (2004) 對澎湖箱網養殖產量進行灰色模式 $GM(1,N)$ 建模固定以平均背景值方式組成 $Z^{(0)}(K)$ 可以得到適正結果。利用 $GM(1,N)$ 灰模式，將相關因素及各構面都納入系統中考量，推估產量預測方程式求解市場簡化期望最佳產量目標，以解決決策數據上的限制。然而，對於離散數列所隱含規律變化，有時對澎湖生產數量產量進行預測，無法由平均背景值的建模方式充分顯現，所以會形成 $GM(1,N)$ 模式的誤差，但是仍為可以接受範圍，誤差值為 10.57%【13】。
2. 黃仲達 (2003) 以灰預測來進行已少量數據預測來年國內農產銷售量，經過實務驗證的結果，灰預測在預測精確度、模型的等級評定及使用的樣本數等多方面的整體表現優於時間序列分析及統計的線性迴歸分析。從實證中兩產品的預測準確度來看，可以推論數值越大，越能偵測到產品銷售量走勢變化，使得預測值越精確。在預測方法比較上，研究發現較

多的歷史觀察值並無法提供給模式一個穩定的衰退比例，所以，時間上距離預測值越遠的歷史觀察值，對於預測模式無太大的助益，這也就是導致迴歸預測能力發揮不如灰預測的主要原因。移動平均法之預測能力未達水準的主要原因在於，年銷售量資料具有趨勢性，造成對資料走勢中「異常觀測值」的反應不靈敏，同時也因為觀察值日數太少，導致誤差的穩定度較差。單一指數平滑法中之平滑常數通常界於 0.2 到 0.3，當 α 值越大，越適合有趨勢的預測，亦越能反應出最近的觀測結果。Winter 指數平滑模式同時具有趨勢性及季節性。研究認為「突發事件的異常數據」，乃是影響灰預測方法之預測準確度最大的因素【16】。

2.1.2 交通運輸

1. Wang et al.(2004)應用灰關聯分析對航空站進行績效評估，主要討論有關於台灣地區主要航空站營運績效之評定與比較，並著力於四大重點去衡量，1.航空站，2.旅客，3.航空公司，4.防火服務。而其中為了克服小樣本數量的限制，選擇用灰關聯分析來分類初始的評估指標，同時選擇最能代表性的指標【53】。
2. 曹文建（2003）以灰預測 GM(1,1)、GM(1,N)針對航空運輸需求製造業及運輸倉儲關連產業產值預測與迴歸預測模型進行比較，研究結果顯示，GM (1, 1)模型達 90% 以上的精確度，優於迴歸預測模型，研究認為預測模型之優劣並無絕對，端視研究對象以及研究特性來選去適合之預測模型【23】。
3. 吳嘉斌（2003）在物流運輸之應用領域中，以灰色理論來做為研究基礎，對未來物流中心的運量做預測與設計配送路線的車輛途程問題(Vehicle Routing Problem, VRP)首先是根據歷史資料來預測未來需求，建構出灰色預測之 GM 模式，對現有數據進行預測，以求得數列中各數據元素之未來動態發展狀況；再來是根據需求點的屬性，綜合各項實際影響路線規劃因素，以評估指標進行區分；最後以此類指標，建構白化權函數檢視新提出之灰聚類方法在第三者物流(The Third Party

Logistics, 3PL)應用上的適用性與發展潛力，並進行初步路線建構【3】。

4. 李家儂 (2003) 主目的建立都會區尺度之大眾運輸導向發展規劃模式。其模式之輸入資料及輸出結果均為灰數，以符合實際所面臨的資訊不明確與規劃彈性的需求。此研究建構的是灰色多目標土地使用規劃模式，其所設計之 Grey TOPSIS 方法，經過簡例與實例測試分析之使用經驗，以提供未來其他相關研究在求解灰色多目標規劃模式時應用【2】。
5. 劉素妙 (2002) 表示在航空公司機隊管理中，不能像以往一樣只考慮機型選擇、機隊與航空線間的指派，應該考慮到機隊購置汰換時程之影響因素。故以航空公司機隊採購/汰換的最佳流程之觀點來作深入探討。從航空公司營運及機隊更新決策成本，並配合機隊飛機使用率，以解析性方法推導航空公司直接與間接營運成本及機型選擇、汰換決策函數。因為經濟景氣會有個循環週期，其會影響航空公司旅客需求，故應用灰色理論之拓撲預測 (Grey Topological Forecasting) (鄧聚龍，1986)。以旅客流量配合景氣循環波形歷史資料來推測未來可能旅客需求量及經濟景氣波動下之變化率【26】。
6. 侯洸廷 (2002) 藉由現地調查鋪面狀況，計算鋪面損壞指標值，以灰預測方法求得預測破壞指數，並與迴歸預測進行比較，目的在得到一個適用於鋪面評估之預測模型，為一精確度高且不需要大量數據即可建立預測之模型。研究結果顯示，在所有未維修路段之各種預測模型之預測誤差平均值比較上，以一次累加生成模式 1.26% 最為準確，證明灰預測模型在預測「鋪面損壞指標」有很好的成果【9】。
7. 謝明聰 (2001) 民國 90 年之前，由於國內航空運輸量已進乎飽和，致使各終端管制區域(Terminal Control Area)及主要機場於尖峰時段產生嚴重之容量不足現象，為紓解嚴重的空中交通擁塞現象，便透過灰色決策來有效解決空中交通阻塞問題。以 FCFS (First Come First Serve) 為大原則，配合著灰色決策理論來建立一個新的航機到場排序工具期能達成高效率的

飛航班機進場。所謂的灰色決策就是在對付同一事件的多種決策中挑選一個效果最好的對策來對付事件的發生。灰色決策分為三大部分：目標效果測度、多目標決策、綜合多目標決策效果測度。此研究所運用的灰色系統理論，就是針對到場航空器所提供的各項飛航參數以灰色決策理論來決定其落地先後順序，以求達到比較與參考的目的【25】。

8. 陳仕倫 (2000) 利用不同的系統分析方法及灰色系統理論分析，來對飛行安全的系統進行分析，以求達到比較與參考的目的。主要是在信息不完整的條件下，找到處理灰元的方法且使灰變白，使白度增加。故可以在資訊之不完整下，應用於社會、經濟、交通、人文等各類系統中。本篇利用飛安事件為例，找尋灰關聯度與灰預測值兩者之間的關係，發現灰關聯度低的因子，其灰預測值誤差越大【11】。
9. Hsu and Chang(1999)提出以灰色理論應用於航線網絡中，決定出最佳的方法，來提高對旅客的服務水準，降低航空公司營運的成本。而灰色理論能有效的使用最少的資料就可以解出結果以決定出航空公司航線的規劃，而在建立灰模式之後，也能確實的執行出來所要的結果【35】。

2.1.3 環境工程

1. 溫修慧 (2004) 利用 $GM(1,N)$ 模型及 $GM(0,N)$ 模型、 $GM(1,2)$ 模型針對焚化廠之環境背景因子進行建模預測，依「預防及減輕開發行為對環境不良影響對策摘要表」之施工期間影響程度進行量化，以探討預測各焚化廠環境因子之間影響程度，嘗試將同一類別之環評案件做橫向比較。研究結果顯示，以 $GM(1,N)$ 模型綜合分析，環境因子在地形、地質與土壤等、陸域動植物、空氣品質、水域動植物、水文及水質及廢棄物等方面，其平均殘差值分別為 9%、16%、12.5%、28.5%、9.5%、19%，與環境影響評估對策摘要表評估之影響程度相當符合。另焚化廠背景因子以 $GM(1,N)$ 模型對環境因子影響分析部分，結果顯示設計處理量(公噸/日)影響性最為顯著。因僅針對一項背景因子作建模比較，獲得結果均會較以 $GM(1,N)$ 模型

將所有背景因子一同進行建模預測有更佳之預測效果【19】。

2. 周裕然、鍾秉勳、歐陽橋暉等 (2004) 以好氧—缺氧—好氧 (OAO) 生物除氮程序之水質數據進行灰關連分析、模式建構與水質預測，於進行灰建模前，均以各獨立之好氧、缺氧生物反應槽為控制體積 (control volume)，針對每一槽體做局部性灰關聯分析，尋求操作參數與水質參數間之關聯性，再以灰關聯性較高之各項控制因子建立 GM(1,N) 水質預測模式，以預測 SRT=15 天、HRT=10 小時、Q1:Q2=0.8:0.2 操作時之各項放流水營養鹽濃度，獲致氧—缺氧—好氧 (OAO) 生物除氮程序之水質預測模型。研究結果得知，以 GM(1,N) 理論預測都市污水處理廠處理水回收特性時，預測 COD、PO₄ 濃度可獲致較準確的結果。GM(1,N) 水質預測模式於預測 OAO 生物除氮程序放流水水質時，預測值與實測值變化趨勢具一致性，顯示 GM(1,N) 水質測驗模式可描述本程序硝化、脫硝、磷代謝及 COD 等生化反應，且預測處理水 COD、PO₄ 濃度可獲致較準確的結果。故水質預測模型可作為程序動態控制策略擬定之參考依據【8】。

2.2 交通量預測方法

回顧以往有關交通量預測之文獻可以發現，常見的交通量預測方法包括 UTCS 預測模式、簡單指數平滑法、CHOW 應變平滑法、Trigg&Leach 應變平滑法、歷史平均法、無母數迴歸法、人工智慧之類神經網路、Kalman 濾波法、時間序列之 ARIMA 模式、混沌理論等等，茲分述如下。

2.2.1 平滑常數的應用

1. 簡單指數平滑法
2. CHOW 應變平滑法
3. Trigg&Leach 應變平滑法

上述模式皆以某些較平滑的中間值作為預測之依據，模式預測步驟先利用前期之流量資料來計算平滑值，進而預測下一時階之流量，CHOW 應變平滑法利用大小平滑常數之效力來減少以單

一固定平滑常數進行預測產生之誤差，Trigg & Leach 將平滑常數值設計為可以隨各期預測誤差而不斷更新改變，可排除選擇最佳平滑常數值 α 之缺點【5】。

2.2.2 資料之數據特性

1. 以歷史流量資料為主進行預測，如 Okutani and Stephanedes (1984) 卡門濾波法(Kalman filtering method)【46】、歷史平均法。

Smith and Demetsky(1997)中提出歷史平均法 (historical average)【51】，依據交通量有固定循環的週期性變化特性，利用過去平均交通量以預測未來交通量，此法的缺點是未能即時有效的反應突發事件動態交通狀況之改變。

2. 以當日流量資料為主進行預測，如周義華（民 70）之第三代 UTCS (Urban traffic control system) 交通量預測模式【7】；黃泰林（民 77）對於車流量預測模式進行簡單指數平滑法、CHOW 應變平滑法、Trigg & Leach 應變平滑法【14】。
3. 綜合歷史和當日流量進行預測，如周義華（民 70）之第二代 UTCS (Urban traffic control system) 交通量預測模式【7】；Box Jenkins(1970)時間序列之 ARIMA 模式；林煙祥（民 88）類神經網路於高速公路交通量預測之研究【5】。

於上述各種模式之預測步驟中可發現，利用前一期之車流量資料計算平滑值或修正係數，將近期的車流量給予較大的加權，顯示當期的車流量容易受上一期流量之影響。【6】

2.2.3 其他預測方法

1. 人工類神經網路

人工類神經網路近幾年漸漸獲得注意，多用在交通流量模式、交通號誌控制及運輸規劃等領域。在交通量預測方面，Florio and Mussone(1996)、Dougherty and Cobbett(1997)、Mohet al.(1995)及 Smith and Demetsky(1997)等構建高速公路或市內道路的交通量預測模式，使用倒傳遞 (back-propagation) 網路法，包含輸入

層 (input layer)、隱藏層 (hidden layer) 學習出近似數學函數，研究結果顯示模式預測效果良好。【6】

林煙祥 (民 88) 利用歷史交通特性資料，進行模式訓練，將當期的車流量容易受上一期流量之影響視為一輸入變數，對未來時段進行即時預測，結果顯示，當車流不穩定時，預測之結果，落後實際流量變化趨勢一個時段，但整體流量變動趨勢仍能正確掌握，不致偏離過大。就預測正確性而言，若以預測誤差標準為 02，一般日與例假日全日交通量預測模式，其預測能力分別為 80% 和 85%。【5】

2. 無母數迴歸與混沌理論

Davis and Nihan (1991) 及 Smith and Demetsky (1997) 提出無母數迴歸法 (nonparametric regression method) 預測高速公路短期交通量，嘗試找出與預測時期狀態相似之群組，界定其臨界點，將所有觀察值取其平均而得。而藍武王、陳郁文 (民 87) 以混沌理論為基礎，使用模糊局部重建法 (local reconstruction) 之技術構建模式，以台北市區的每五分鐘道路交通量為例進行預測，對於非線性變化之車流量有相當之參考價值。【27】

林尚儀 (民 90) 應用相空間局部近似法 (PSLA) 預測具混沌特性的車流量變化，以各路段交通量觀察值與預測值間之相關係數作為預測評估準則之初步指標，預測結果顯示，以均方百分誤差 RMSPE 分析，越長時間尺度交通量預測效果明顯較佳，五分鐘流量預測之 RMSPE 約為 40%，十及十五分鐘流量之預測大約都能在 10%-40% 內。【6】

2.2.4 交通量預測方法之應用

1. Chen and Grant-Muller (2001) 利用類神經網路進行短期交通流量的預測，以尖峰流量時之時間數列、時序資料進行預測，使發生事故之危險性降至最低，作一個積極有效的預防措施【30】。
2. Dougherty and Watson (1996) 應用 Kohonen self-organizing map 將交通量資料做最初步的分類，並將每個各地分類資料轉到

- ARIMA 模式。從以上這兩種方式中的一系列事物，進行聯合、合併其行為模式，配合著演算法模型，來進行著預估交通流量，使其整個路網能更具流暢性、方便性、安全性【33】。
3. Vemuri et al. (1998) 由於造成高速公路上的交通延遲量原因通常是高速公路上的建築物區域，所以為了研究出交通延遲量及正確的旅行時間，A.T.Vemuri and M.M. Polycarpou 便使用 On-Line Approximators(網上逼近)的方法來推估出一套有系統方法的模數，再以現有的相關資料倒入，以推測出未來的交通延遲量及正確的旅行時間【52】。
 4. Kirby et al. (1997) 提出在法國的高速公路交通上，可以用兩種模式來預測出短期交通量的結果來比較，一種是 neural networks(類神經網路)，另一種則是 statistical models(統計方法)，而在此所使用的統計方法是傳統的 ARIMA(時間序列預測模式)。透過兩種方法的使用，就可得知那種方法對於短期交通量能做出較為準確的預測結果【40】。
 5. Dougherty and Cobbett (1997)認為在荷蘭的三個城市中可以透過 neural networks(類神經網路)來做出短期交通預測中的交通量、速率和佔有率。最後所得到的結果發現在城市交通內用 neural networks(類神經網路)來預測是有效的，不只是可以產生出網路的大小，而且還能解釋整個神經網路模型【32】。
 6. Arem et al. (1997) 指出道路交通擁塞目前為全球性的議題，而其中可解決之道是動態交通管理(dynamic traffic management, DTM)，而裡頭所包含的交通流量管理、運具與交通需求所建立的數據，均來自於現有與近期預測交通形勢。而 DTM 的主要關鍵因素為全路網範圍的短期交通預測。本文章討論統計學(nonlinear regression、ARIMA)應用於運輸上的短期交通預測【29】。
 7. Smith et al. (2002) 討論統計上母數與無母數資料在交通量預測上的分別。在運行的路網模式下，單一點短期交通量預測代表一個重要需求預測關鍵。季節性的時間序列預測模式(ARIMA)為典型母數模式去處理時間序列，無母數迴歸模式也

同時適用單一點短期交通量預測。本研究試著去找尋檢查無母數迴歸理論基礎並解答無母數迴歸問題有關於增進預測產生方法處理週期性之時間序列預測在單一間隔交通量預測績效【47】。

8. Stathopoulos et al. (2003) 探討多變量狀態空間方法應用於都市交通量預測。近年來，由於都市交通擁塞問題愈來愈嚴重，為有效解決此問題，故智慧型運輸系統(intelligent transportation systems, ITS)應孕而生。ITS之所以能成功運行，主要是它能提供準確的即時交通資訊及短期交通預測的參數，如交通量、旅行時間與搭載率...等。而此多變量時間序列狀態空間方法是以 3 分鐘為一單位去作測量衡量，除了產生的結果能清楚表示不同模式指標適用於不同的時間區間外，也能顯現出此方法的使用能增進單變量時間序列在預測上的準確性【48】。
9. 林尚儀 (2001)藉由混沌理論的觀念，對混沌車流之短期交通量預測課題作一深入探討。短期間道路上實際車流狀況是一個非常複雜的系統，呈現巨幅的不連續變化現象，屬於非線性的系統。其影響因子，舉凡有交通量、車種組成、駕駛人行為、道路幾何條件、天候因素等。交通量會隨著時間而變化，且具有混沌現象，以往認為十分複雜、乍看之下雜亂無章的現象，背後卻可能存有一種簡單的秩序。基於此，以混沌理論為基礎，利用相空間局部近似法來建立短期交通量變化預測模式，並以實例驗證模式之預測準確度與可信度【6】。

表 2.2 交通量預測方法之應用文獻彙整表

作者	使用理論	應用範圍
Chen and Grant-Muller (2001)	時間序列 neural networks	高速公路路網之尖峰流量
Dougherty and Watson (1996)	HYBRID 定理 KARIMA 定理	高速公路短期交通量
Vemuri et al. (1998)	On-Line Approximators	高速公路上交通延遲量 正確的旅行時間
Kirby et al. (1997)	neural networks ARIMA	高速公路短期交通量
Dougherty and Cobbett (1997)	neural networks	城市內交通量、速率 和佔有率
Arem et al. (1997)	nonlinear regression ARIMA	交通流量、運具與交通 需求
Smith et al. (2002)	nonparametric resression ARIMA	單一間隔交通量
Stathopoulos et al. (2003)	multivariate state space approach	都市交通量
林尚儀 (2001)	混沌理論 相空間局部近似法	短期交通量預測
Chen and Grant-Muller (2001)	時間序列 neural networks	高速公路路網之尖峰流量
Dougherty and Watson (1996)	HYBRID 定理 KARIMA 定理	高速公路短期交通量

2.3 綜合評析

將上述各主要預測模式之優缺點進行一綜合性之比較，如表 2.3 所示。

表 2.3 交通量預測方法之優缺點比較表

模式	優點	缺點
歷史平均法	<ol style="list-style-type: none"> 1. 易於實行預測 2. 預測的速度快 	未能及時反應突發意外事件
灰預測	<ol style="list-style-type: none"> 1. 適合處理極少且有限的數據之問題（至少 4 筆） 2. 數據型態可以為等間距及非等間距 3. 數學運算簡易 	突發的數據異常，會影響預測準確度
ARIMA	<ol style="list-style-type: none"> 1. 單純的時間序列應用 2. 在統計上是已確立的方法 	若序列中有遺漏資料則須加以處理
類神經網路	<ol style="list-style-type: none"> 1. 適合用在複雜、非線性關係 2. 不需定義模式的函數形式 	<ol style="list-style-type: none"> 1. 黑盒子作業 (black box) 2. 樣本訓練過程複雜 3. 可能會過度訓練，及記憶訓練資料而忽略整體關係
第三代 UTCS	<ol style="list-style-type: none"> 1. 不需大量的歷史交通量 2. 可用於交通量變化不定型之地點 	交通量之變化產生急劇之變動時，則其預測之誤差值較大
指數平滑法	<ol style="list-style-type: none"> 1. 單純的資料序列應用 2. 易於實行預測 	<ol style="list-style-type: none"> 1. 預測值受平滑常數值 α 影響 2. 當期的車流量容易上一期流量之影響

無母數迴歸	<ol style="list-style-type: none"> 1. 不需基礎關係的假設 2. 型態認知的應用 	<ol style="list-style-type: none"> 1. 尋找並辨認鄰點具複雜性 2. 鄰點個數如何決定
相空間模式	<ol style="list-style-type: none"> 1. 可反應出混沌內部動態行為 2. 預測過程簡潔且短期預測效果良好 	僅適用於混沌時間序列之預測，才具理論基礎

資料來源：林尚儀（民 90）、本研究整理

灰色預測僅需一個光滑離散函數便可進行建模預測，其對數據量的要求並不嚴苛，因此只需要少量數據便可進行模式構建，這增加了灰色預測理論的實用性，對於訊息不完整或資料數據過少的系統環境，灰色預測理論也就發揮了它的強健性（林家傑、張士行，2000），在上述的文獻中，對於交通量預測模式之探討可發現，每種預測模式皆有其適用之特性與應用之限制，其中面臨交通量之變化產生急劇之變動時，周義華第三代 UTCS、林煙祥之類神經網路、Smith and Demetsky 之歷史平均法等，皆會產生預測之誤差值較大的現象；灰色預測模式亦是如此，然在多數灰預測模式與其他常用之預測模式之研究應用上比較可發現，在資料限制、計算簡易性、應用範圍方面，灰預測模式確實較一般常使用之迴歸模式等預測模式具有預測之優勢。然而灰色預測並非全然沒有限制，故多位學者進一步提出修正，如林建德等（1997）提出雙向差分推導背景值關係式，許巧鶯、溫裕弘（1998）以二階馬爾可夫鍊修正灰預測殘差模式等，其目的都在降低殘差，提升預測精確度。

灰色預測理論認為任何環境系統皆屬於一個能量系統，可以用指數函數表達，而在系統中獲得的數據大都呈現離散狀態的情況下，系統可以簡單的灰微分方程式表示其動態模型 $GM(n, h)$ ，即為 n 階 h 個變數的灰色動態模型。在灰預測類型方面，可歸納如下圖 2.1。【22】

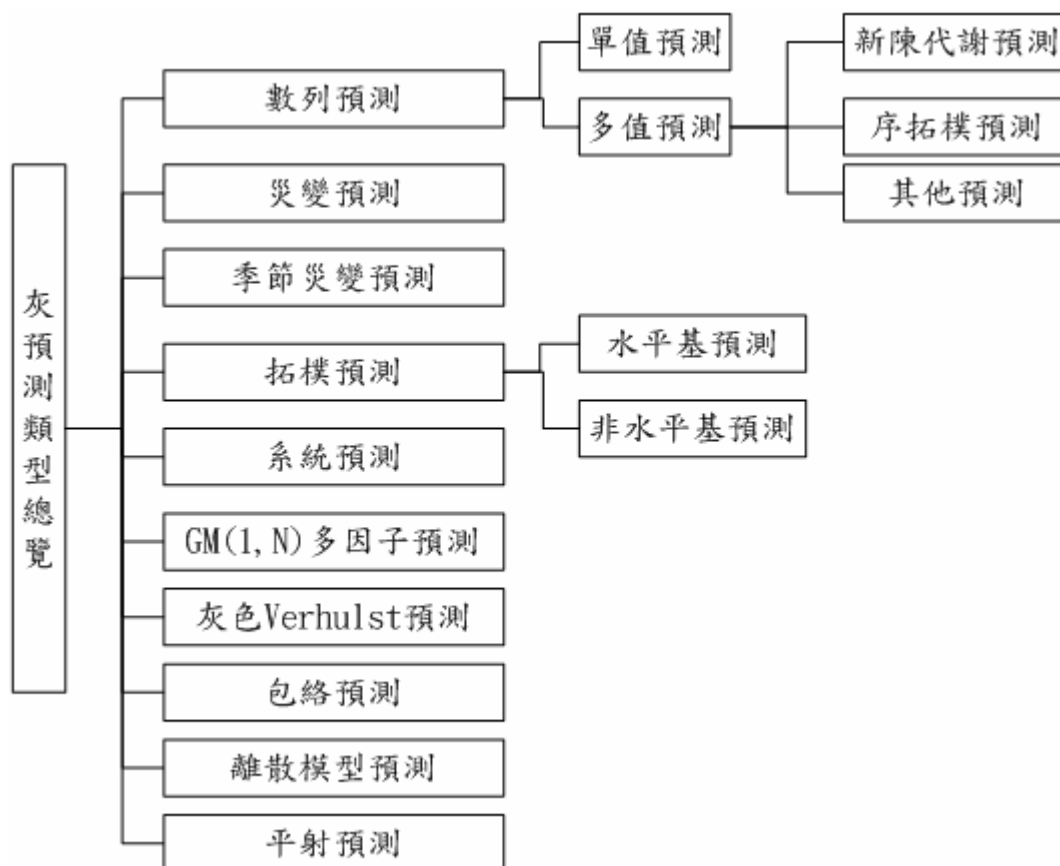


圖 2.1 灰預測類型總覽

資料來源：鄧聚龍、郭洪，1996，灰預測原理與應用，台北：全華科技圖書，頁 1-40。

圖 2.1 中所示之灰預測類型中，災變預測所指的是針對所給定數列中出現過大或過小之異常值所進行預測，而季節災變預測則是當災變發生在每年特定的時區，而對這些災變事件的時間分佈進行預測，而數列預測、系統預測、GM(1,N)多因素預測則是最常為研究應用之灰預測模型。許巧鶯、溫裕弘(1997)進一步說明灰色系統理論係以GM(1,1)模式為基礎，一般分為數列預測與系統預測兩類模式，其中數列預測以GM(1,1)為主體，為簡單時間數列模式；系統預測則結合GM(1,1)與GM(1,N)模式，對系統中多個變數進行預測，以瞭解變數彼此間之關係。

目前國內學者將灰預測應用於短期交通量預測之研究尚屬缺乏，基於此，本研究將以灰預測方法之單元預測GM(1,1)為主

體，對高速公路路段交通量進行簡單時間數列模式預測，並以多元預測 GM(1,N) 模式，對系統中各種流量、密度及速率間的關係，藉由微觀 (microscopic) 的分析，找出變數彼此間之關係，以期有較佳的預測效果。在對照模式選擇上，由於傳統時間序列 ARIMA 預測模型，其所使用之資料特性與 GM(1,1) 相同，皆為單純的時間序列資料，且 ARIMA 模型在統計學上是已確立的方法，而多變數預測模式以迴歸分析及類神經網路 (ANN) 最具代表性，而 ANN 之預測績效表現較佳，因此選定 ARIMA 模式及 ANN 模型作為對照模式，藉以了解灰預測模式之預測績效。茲將三種模式之特性與差異以表陳述，如表 2.4 所示。

表 2.4 灰預測模式與對照模式之特性分析

比較之項目及差異性	灰預測模式	ARIMA 模式	ANN 模式
本質內涵	1. 數列預測 GM(1,1)-對行為特徵值大小的發展變化進行預測。 2. 系統預測 GM(1,N)-將某一系統各種因素的動態關係找出，對系統特徵值預測。	利用特徵值之歷史資料預測該變數未來的變化趨勢。	建立數入變數與輸出變數之對應關係，過網路學習方式預測輸出值
數學基礎	灰朦朧集合	自我迴歸、移動平均概念。	以激發函數進行正規化數值，權重值運算。
數學運算方式	累加生成法	統計方法	黑箱運算
數據分佈	任意分佈	連續性	任意分佈
模式型式	1. GM(1,1)數列預測 2. GM(1,N)多元預測	數列預測	多元預測
短期交通資訊預測之適用性	本研究驗證。	文獻顯示適用。	文獻顯示適用。

第三章 研究方法

依據前章文獻評析結果，本研究選定用以預測交通量之方法為灰預測模式，並細分為單元數列預測模式與多元預測模式兩類，單元數列預測模式用以預測具時間序列特性之交通量、平均速度及佔有率等資料，多元預測模式則是針對系統中各種流量、密度及速率間的關係，藉由微觀（microscopic）的分析，找出變數彼此間之關係；本研究之研究方法主要分為三個部分，分別為單元數列預測模式、多元預測模式以及用以對照驗證之用之 ARIMA 模式與類神經網路，茲分述如后。

3.1 單元數列預測模式

3.1.1 GM(1,1)模式

灰預測模型 (Grey Forecasting Model, Grey Model, GM)，詳細說就是將離散不規則的原始數據轉換成具指數規律的累加生成數，據此建立微分方程式，並由樣本數值產生微分方程組求解係數，據以進行預測。GM(1,1)屬於單元數列之預測，即依據數列資料的發展變化進行下一時階之數值預測，因此又稱為 GM(1,1)模式。

灰預測理論包括於灰色系統理論之中，其建構模式為假設 GM 模式為一階線性常微分方程式，透過對生成數據進行一階微分方程式求解，建立 GM 模式，再以累減生成還原，即為灰色預測模式。

根據灰色系統理論的定義，GM(h,N)模型的灰微分方程式定義為：

$$\sum_{i=0}^h a_i \frac{d^{(i)} x_1^{(1)}}{dt^{(i)}} = \sum_{j=2}^N b_j x_j^{(1)}(k) \quad (1)$$

其中： a_i 和 b_j 為係數； $a_0 = 1$ ； $x_1^{(1)}(k)$ 為標準序列； $x_j^{(1)}(k)$ 為比較序列；

$$x^{(1)} = \left(\sum_{k=1}^1 x^{(0)}(k), \sum_{k=1}^2 x^{(0)}(k), \dots, \sum_{k=1}^n x^{(0)}(k) \right) \quad (2)$$

代入 $h=1$ 及 $N=2$ ，可以得到 GM(1,1)模型的灰微分方程式為：

$$\frac{dx_1^{(1)}}{dt} + a_1 x_1^{(1)} = b_2 \quad (3)$$

根據 GM 模型的推導：

$$\frac{dx_1^{(1)}}{dt} \text{ 可轉化成前後項的差, } \frac{dx_1^{(1)}}{dt} \rightarrow x_1^{(1)}(k+1) - x_1^{(1)}(k)。$$

而經由逆累加運算(IAGO)，得知 $x_1^{(1)}(k+1) - x_1^{(1)}(k) = x_1^{(0)}(k+1)$ 。

再由背景值 $x_1^{(1)}(t)$ 的定義, $x_1^{(1)}(t) \rightarrow 0.5x_1^{(1)}(k) + 0.5x_1^{(1)}(k-1) = z_1^{(1)}(k)$ 。

綜合上述，得出 GM(1,1)模型的灰差分方程式為：

$$X_1^{(0)}(t) + a_1 z_1^{(1)}(k) = b_2 \quad (4)$$

亦即具有一個及一階變量的灰色模型即稱為 GM(1,1)模型。

而 $\frac{dx_1^{(1)}}{dt} + a_1 x_1^{(1)} = b_2$ 稱為源模型，從數學觀點而言是利用序列建立近似的微分方程式。將源模型簡化得出 (5) 式，第一項 $(X^{(0)}(1))e^{-ak}$ 為初值項，而 $\frac{b}{a}(1-e^{-ak})$ 為數項，在 $k+1$ 時，則稱為預測值。

$$\hat{X}^{(1)}(k+1) = (X^{(0)}(1))e^{-ak} + \frac{b}{a}(1-e^{-ak}) \quad (5)$$

GM(1,1)參數的求法，對於 GM(1,1)模型而言，首先要計算 GM(1,1)參數 a 及參數 b 的大小。根據最小平方法，令

$$Y_N = \begin{bmatrix} X_1^{(0)}(2) \\ X_1^{(0)}(3) \\ \vdots \\ X_1^{(0)}(n) \end{bmatrix}, \quad B = \begin{bmatrix} -Z_1^{(1)}(2) & X_2^{(1)}(2) & \dots & X_N^{(1)}(2) \\ -Z_1^{(1)}(3) & X_2^{(1)}(3) & \dots & X_N^{(1)}(3) \\ \vdots & \vdots & \dots & \vdots \\ -Z_1^{(1)}(n) & X_2^{(1)}(n) & \dots & X_N^{(1)}(n) \end{bmatrix}, \quad \hat{a} = \begin{bmatrix} a \\ b_2 \\ \vdots \\ b_N \end{bmatrix}$$

求解，得出：

$$\hat{a} = (B^T B)^{-1} B^T Y_N$$

GM(1,1)模型的誤差定義為：

$$e(k) = \left| \frac{x^{(0)}(k) - \hat{x}^{(0)}(k)}{x^{(0)}(k)} \right| \times 100\% \quad (6)$$

3.1.2 RGM(1,1)模式

GM(1,1)滾動模型是利用同一序列前面幾個數據(通常以第四點開始)建立 GM(1,1)模型後,再預測下一個數據(第五點的數據)的值後,再向後移一點(第五點),同樣建立 GM(1,1)模型,依此類推的做到原始數據的最後一點為止,主要是檢驗 GM(1,1)模型的精確度,此一方式稱為滾動檢驗(rolling check)又稱為 RGM(1,1)模式。分析步驟為:

令原始序列:

$$X^{(0)} = (X^{(0)}(1), X^{(0)}(2), X^{(0)}(3), \dots, X^{(0)}(n)), n \geq 4 \quad (7)$$

取其部份原始序列,稱為子序列:

$$X^{(0)}(i;k) = (X^{(0)}(i), X^{(0)}(i+1), X^{(0)}(i+2), \dots, X^{(0)}(k)) \quad (8)$$

當 $i=1$ 時,亦即:

$$X^{(0)}(1;k) = (X^{(0)}(1), X^{(0)}(2), X^{(0)}(3), \dots, X^{(0)}(k)) \quad (9)$$

(9) 稱為正規子序列,此時我們利用 $X^{(0)}(i;k)$ 建立 GM(1,1)模型,然後利用 $\frac{dx^{(1)}}{dt} + a x^{(1)} = b$ 白化方成模型得到 $\hat{X}^{(1)}(k+1)$ 項之後,再利用 (IAGO) 還原做誤差分析。

在灰色理論中滾動檢驗所使用的符號定義為:

$$\hat{GM}_p \bullet AGO: x^{(0)}(i;k) \rightarrow (a, b) \quad (10)$$

$$\hat{GM}_m \bullet AGO: x^{(0)}(i;k) \rightarrow x^{(0)}(k) + aZ^{(1)}(k) = b \quad (11)$$

$$IAGO \bullet AGO: x^{(0)}(i;k) \rightarrow \hat{x}^{(0)}(k+1) \quad (12)$$

當 $i=1, k=4, 5, 6, \dots, n-1$ 時,利用傳統的誤差公式得到誤差的大小為:

$$e(k+1) = \left| \frac{x^{(0)}(k+1) - \hat{x}^{(0)}(k+1)}{x^{(0)}(k+1)} \right| \times 100\%, k+1 \leq n \quad (13)$$

GM(1,1)的滾動檢驗誤差為：

$$e = \frac{1}{n-4} \sum_{k=4}^{n-1} e(k+1)\% \quad (14)$$

GM(1,1)的滾動檢驗精度為：

$$\varepsilon = (1 - e)\% \quad (15)$$

3.2 多元預測模式

3.2.1 GM(1,N)模式

GM(1,N)模型表示：一階微分，輸入變數為 N 個，如果在序列

$$X_i^{(0)}(k) \quad i = 1, 2, 3, \dots, N \quad \text{中} \quad ,$$

$X_1^{(0)}(k)$ 為系統的主要行為，而

$X_i^{(0)}(k) \ i=2,3,4,...N$ 為影響主行為之因子，則可利用 GM(1,N) 模型做分析，首先建立原始序列

$$\begin{aligned} X_1^{(0)} &= \{X_1^{(0)}(1), X_1^{(0)}(2), X_1^{(0)}(3), \dots, X_1^{(0)}(k)\} \\ X_2^{(0)} &= \{X_2^{(0)}(1), X_2^{(0)}(2), X_2^{(0)}(3), \dots, X_2^{(0)}(k)\} \\ X_3^{(0)} &= \{X_3^{(0)}(1), X_3^{(0)}(2), X_3^{(0)}(3), \dots, X_3^{(0)}(k)\} \\ &\vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \\ X_N^{(0)} &= \{X_N^{(0)}(1), X_N^{(0)}(2), X_N^{(0)}(3), \dots, X_N^{(0)}(k)\} \\ k &= 1, 2, 3, \dots, n \end{aligned}$$

建立 AGO 序列（累加生成序列）

$$\begin{aligned} X_1^{(1)} &= \{X_1^{(1)}(1), X_1^{(1)}(2), X_1^{(1)}(3), \dots, X_1^{(1)}(k)\} \\ X_2^{(1)} &= \{X_2^{(1)}(1), X_2^{(1)}(2), X_2^{(1)}(3), \dots, X_2^{(1)}(k)\} \\ X_3^{(1)} &= \{X_3^{(1)}(1), X_3^{(1)}(2), X_3^{(1)}(3), \dots, X_3^{(1)}(k)\} \\ &\vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \\ X_N^{(1)} &= \{X_N^{(1)}(1), X_N^{(1)}(2), X_N^{(1)}(3), \dots, X_N^{(1)}(k)\} \\ k &= 1, 2, 3, \dots, n \end{aligned}$$

寫出標準式

仿照 GM(1,1)的型式，將 AGO 後之數是組合成

$$X_1^{(0)}(k) + aZ_1^{(1)}(k) = \sum_{i=2}^N b_i x_i^{(1)}(k) \quad (16)$$

其中

$$Z_1^{(1)}(k) = 0.5X_1^{(1)}(k) + 0.5X_1^{(1)}(k-1) \quad k=2,3,\dots,n \quad (17)$$

求解

利用 (17) 式，並帶入各生成後的數值，可以得到：

$$X_1^{(0)}(2) + aZ_1^{(1)}(2) = b_2 x_2^{(1)}(2) + \dots + b_N x_N^{(1)}(2)$$

$$X_1^{(0)}(3) + aZ_1^{(1)}(3) = b_2 x_2^{(1)}(3) + \dots + b_N x_N^{(1)}(3)$$

$$\dots\dots\dots$$

$$X_1^{(0)}(n) + aZ_1^{(1)}(n) = b_2 x_2^{(1)}(n) + \dots + b_N x_N^{(1)}(n)$$

再將上列之方程組轉乘矩陣的型式：

$$\begin{bmatrix} X_1^{(0)}(2) \\ X_1^{(0)}(3) \\ \vdots \\ X_1^{(0)}(n) \end{bmatrix} = \begin{bmatrix} -Z_1^{(1)}(2) & X_2^{(1)}(2) & \dots & X_N^{(1)}(2) \\ -Z_1^{(1)}(3) & X_2^{(1)}(3) & \dots & X_N^{(1)}(3) \\ \vdots & \vdots & \ddots & \vdots \\ -Z_1^{(1)}(n) & X_2^{(1)}(n) & \dots & X_N^{(1)}(n) \end{bmatrix} * \begin{bmatrix} a \\ b_2 \\ \vdots \\ b_N \end{bmatrix}$$

根據最小平方法，令

$$Y_N = \begin{bmatrix} X_1^{(0)}(2) \\ X_1^{(0)}(3) \\ \vdots \\ X_1^{(0)}(n) \end{bmatrix}, \quad B = \begin{bmatrix} -Z_1^{(1)}(2) & X_2^{(1)}(2) & \dots & X_N^{(1)}(2) \\ -Z_1^{(1)}(3) & X_2^{(1)}(3) & \dots & X_N^{(1)}(3) \\ \vdots & \vdots & \ddots & \vdots \\ -Z_1^{(1)}(n) & X_2^{(1)}(n) & \dots & X_N^{(1)}(n) \end{bmatrix}, \quad \hat{a} = \begin{bmatrix} a \\ b_2 \\ \vdots \\ b_N \end{bmatrix}$$

求解，得出：

$$\hat{a} = (B^T B)^{-1} B^T Y_N$$

GM(1,N)模型的誤差定義為：

$$e(k) = \left| \frac{x^{(0)}(k) - \hat{x}^{(0)}(k)}{x^{(0)}(k)} \right| \times 100\% \quad (18)$$

3.2.2 RGM(1,N)模型

利用同一序列前面幾個數據（通常以第四點開始）建立 GM(1,1)模型後，再預測下一個數據（第五點的數據）的值後，再向後移一點（第五點），同樣建立 GM(1,1)模型，依此類推的做到原始數據的最後一點為止。

GM(1,N)模型表示：一階微分，輸入變數為 N 個，如果在序列

$$X_i^{(0)}(k) \quad i=1,2,3,\dots,N \text{ 中，}$$

$X_1^{(0)}(k)$ 為系統的主要行為，而

$X_i^{(0)}(k) \quad i=2,3,4,\dots,N$ 為影響主行為之因子，則可利用 GM(1,N) 模型做分析，首先建立原始序列

$$X_1^{(0)} = \{X_1^{(0)}(1), X_1^{(0)}(2), X_1^{(0)}(3), \dots, X_1^{(0)}(k)\}$$

$$X_2^{(0)} = \{X_2^{(0)}(1), X_2^{(0)}(2), X_2^{(0)}(3), \dots, X_2^{(0)}(k)\}$$

$$X_3^{(0)} = \{X_3^{(0)}(1), X_3^{(0)}(2), X_3^{(0)}(3), \dots, X_3^{(0)}(k)\}$$

$$\dots\dots\dots$$

$$X_N^{(0)} = \{X_N^{(0)}(1), X_N^{(0)}(2), X_N^{(0)}(3), \dots, X_N^{(0)}(k)\}$$

$$k \geq 4, \dots, n$$

建立 AGO 序列（累加生成序列）

$$X_1^{(1)} = \{X_1^{(1)}(1), X_1^{(1)}(2), \dots, X_1^{(1)}(k)\}$$

$$X_2^{(1)} = \{X_2^{(1)}(1), X_2^{(1)}(2), \dots, X_2^{(1)}(k)\}$$

$$X_3^{(1)} = \{X_3^{(1)}(1), X_3^{(1)}(2), \dots, X_3^{(1)}(k)\}$$

$$\dots\dots\dots$$

$$X_N^{(1)} = \{X_N^{(1)}(1), X_N^{(1)}(2), \dots, X_N^{(1)}(k)\}$$

$$k \geq 4, \dots, n$$

寫出標準式

仿照 GM(1,1)的型式，將 AGO 後之數是組合成

$$X_1^{(0)}(k) + aZ_1^{(1)}(k) = \sum_{i=2}^N b_i x_i^{(1)}(k) \quad (19)$$

其中

$$Z_1^{(1)}(k) = 0.5X_1^{(1)}(k) + 0.5X_1^{(1)}(k-1) \quad k=2,3,\dots,n \quad (20)$$

求解

利用 (20) 式，並帶入各生成後的數值，可以得到：

$$X_1^{(0)}(2) + aZ_1^{(1)}(2) = b_2x_2^{(1)}(2) + \dots + b_Nx_N^{(1)}(2)$$

$$X_1^{(0)}(3) + aZ_1^{(1)}(3) = b_2x_2^{(1)}(3) + \dots + b_Nx_N^{(1)}(3)$$

.....

$$X_1^{(0)}(n) + aZ_1^{(1)}(n) = b_2x_2^{(1)}(n) + \dots + b_Nx_N^{(1)}(n)$$

再將上列之方程組轉乘矩陣的型式：

$$\begin{bmatrix} X_1^{(0)}(2) \\ X_1^{(0)}(3) \\ \vdots \\ X_1^{(0)}(n) \end{bmatrix} = \begin{bmatrix} -Z_1^{(1)}(2) & X_2^{(1)}(2) & \dots & X_N^{(1)}(2) \\ -Z_1^{(1)}(3) & X_2^{(1)}(3) & \dots & X_N^{(1)}(3) \\ \vdots & \vdots & \ddots & \vdots \\ -Z_1^{(1)}(n) & X_2^{(1)}(n) & \dots & X_N^{(1)}(n) \end{bmatrix} * \begin{bmatrix} a \\ b_2 \\ \vdots \\ b_N \end{bmatrix}$$

根據最小平方法，令

$$Y_N = \begin{bmatrix} X_1^{(0)}(2) \\ X_1^{(0)}(3) \\ \vdots \\ X_1^{(0)}(n) \end{bmatrix}, \quad B = \begin{bmatrix} -Z_1^{(1)}(2) & X_2^{(1)}(2) & \dots & X_N^{(1)}(2) \\ -Z_1^{(1)}(3) & X_2^{(1)}(3) & \dots & X_N^{(1)}(3) \\ \vdots & \vdots & \ddots & \vdots \\ -Z_1^{(1)}(n) & X_2^{(1)}(n) & \dots & X_N^{(1)}(n) \end{bmatrix}, \quad \hat{a} = \begin{bmatrix} a \\ b_2 \\ \vdots \\ b_N \end{bmatrix}$$

求解，得出：

$$\hat{a} = (B^T B)^{-1} B^T Y_N$$

在灰色理論中滾動檢驗所使用的符號定義為：

$$\hat{GM}_p \bullet AGO: x^{(0)}(i; k) \rightarrow (a, b) \quad (21)$$

$$\left(\begin{array}{ccc} \hat{GM}_m \bullet AGO: x^{(0)}(i; k) \rightarrow x^{(0)}(k) + aZ^{(1)}(k) = b \\ 2 \qquad \qquad \qquad 2 \end{array} \right)$$

$$\left(\begin{array}{ccc} IAGO \bullet AGO: x^{(0)}(i; k) \rightarrow \hat{x}^{(0)}(k+1) \\ 2 \qquad \qquad \qquad 3 \end{array} \right)$$

當 $i=1, k=4, 5, 6, \dots, n-1$ 時，利用傳統的誤差公式得到誤差的大小為：

$$e(k+1) = \left| \frac{x^{(0)}(k+1) - \hat{x}^{(0)}(k+1)}{x^{(0)}(k+1)} \right| \times 100\% \quad , k+1 \leq n \quad (24)$$

GM(1,N)的滾動檢驗誤差為：

$$e = \frac{1}{n-4} \sum_{k=4}^{n-1} e(k+1)\% \quad (25)$$

3.3 對照模式

3.3.1 ARIMA 模式

時間序列分析旨在利用變數之歷史資料預測該變數之未來變化趨勢，不需要考量其他外生變數，應用上相當簡易。時間序列分析有許多模式，包括成長率模式、簡單移動平均模式（simple moving average model）、指數平滑模式（exponential smoothing model）、簡單線性迴歸模式（以變數序列為因變數、時間為自變數），以及 Box-Jenkins 模式等。其中，以 Box-Jenkins 模式之理論最為嚴謹，應用也最廣泛，其依變數序列之特性，又可分為自我迴歸模式、移動平均模式、混合自我迴歸移動平均模式，以及整合自我迴歸移動平均模式等四種。本研究將同時建立時間序列之交通資訊預測模式，以供作比較預測精確度之用。

時間數列（Time series）係指以時間順序型態出現之一連串觀測值之集合，即對某動態系統（Dynamic system）隨時間連續觀察所產生有順序的觀測值集合（林文茂，1992）。一時間序列通常以 (X_t) 表示，即在時間為 t_1, t_2, \dots, t_n 時，其觀測值為 $X^{t_1}, X^{t_2}, \dots, X^{t_n}$ 。整合性自我迴歸平均移動模式 ARIMA（Autoregressive Integrated Moving Average Model）是由 Box-Jenkins 在 1970 年提出，分析的目的是找出可精確代表一時間數列之過去和未來模型之模式，即實際值等於模型加上誤差值。

在自我迴歸平均移動模型（ARMA Model）中，不但考量到自變數本身的時間序列影響，也同時考慮誤差項的時間序列影響，設定的基本模型如下：

$$X_t = \alpha + \sum_{i=1}^p \theta_i X_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + u_t \quad X_t \text{ ARMA}(p, q) \quad (26)$$

如果當資料使用 ARMA 模式還是無法適當的解釋時，我們可以對資料取差分 ($\Delta X_t = X_t - X_{t-1}$)，再重新以 ARMA 模型進行配適，直到找出合適的差分後 ARMA 模式為止，這個方法就是自我迴歸整合移動平均模型。如果資料經過 d 次差分之後，我們可以用 ARMA(p, q) 來解釋資料時，表示模型為 ARIMA(p, d, q)。例如，以 ARIMA($1, 1, 1$) 模型為例，當原始的資料經過一階差分後成為 ΔX_t 後，轉換後資料符合 ARMA($1, 1$) 模型，則表示此一差分後模式為 ARIMA($1, 1, 1$) 的資料型態。

在研究時間序列模型的建構上，主要有兩個步驟，資料檢定與時間序列模型的架構，分別說明如下。

1. 資料檢定

Ljung-Box Q Test

為了處理序列資料中所存在的自我相關問題，我們可以透過 Ljung-Box (1978) 的統計量，來檢定判斷序列資料是否存在著自我相關性。

$$Q^* = T \times (T+2) \times \sum_{k=1}^m \frac{\hat{\tau}_k^2}{T-k} \sim \chi_m^2 \quad (27)$$

其中 T ：樣本個數， k ：自我相關滯後期數。其虛無假設為：

$$H_0 : \tau_1 = 0, \tau_2 = 0, \dots, \tau_m = 0$$

$$H_1 : \tau_1 \neq 0 \cup \tau_2 \neq 0 \cup \dots \cup \tau_m \neq 0$$

如果檢定之後的結果顯著，則代表序列資料的自我相關係數並不完全為 0，則必須進一步修正資料存在的自我相關性問題。

2. 單根檢定 (Unit Root Test)

是用來檢定序列資料是否符合定態隨機過程，一般常用的檢定方法有 Phillips-Perron tests (1988) 和 Dicky and Fuller (1979) 所提出的增強式單根檢定 (Augmented Dicky Fuller test ; ADF-test)。檢定序列資料是否存在單根，若檢定結果指出序列資料存在單根時，代表序列資料並非為一定態隨機序列。而轉換資料成為定態隨機序列最常用的方式是對序列資料進行階次差分。經過 N 階次轉換的序列資料成為定態隨機序列後，才能使我們所

推演、估計的時間序列模型具有一致性與不偏性的性質。

3. 架構時間序列模型 (Construct the model)

(1) 推定自我相關係數

建立時間序列模型時，須先計算序列資料的不同滯後期數的自我相關係數 (Autocorrelation Coefficient Function ; ACF) 與偏自我相關係數 (Partial Autocorrelation Coefficient ; PACF) 來判斷適宜的 ARMA 模型階次。

$$\text{ACF: } \rho_k = \frac{\text{Cov}(X_t, X_{t-k})}{\sigma_{X_t} \sigma_{X_{t-k}}} = \frac{\gamma_k}{\gamma_0} \quad (28)$$

$$\text{PACF: } \Theta_{kk} = \frac{\text{Cov}(X_t, X_{t-k} | X_{t-1}, X_{t-2}, \dots, X_{t-k+1})}{\sigma_{X_t} \sigma_{X_{t-k}}} \quad (29)$$

(2) ARM 模型階數的決定

當我們決定了幾個適宜的時間序列模型時，可以藉由資訊準則 (Information Criteria) 的計算，來決定最適合的時間序列模型階次，研究上最常用的資訊準則有三種，分別為 AIC (Akaike's Information Criteria)、SBIC (Schwarz's Bayeaian Information Criteria) 與 HQIC (Hannan-Quinn Information Criteria)，計算公式如下。

$$\text{AIC} = \ln(\hat{\sigma}^2) + \frac{2k}{T} \quad (30)$$

$$\text{SBIC} = \ln(\hat{\sigma}^2) + \frac{k}{T} \ln T \quad (31)$$

$$\text{HQIC} = \ln(\hat{\sigma}^2) + \frac{2k}{T} \ln(\ln(T)) \quad (32)$$

(3) 認定、估計與偵測

進行樣本資料時間序列分析時，可透過是由 Box-Jenkins 在 1970 年提出之 Box-Jenkins Methods，來分析 ARIMA 中階次的高低，模式建立使用三個反覆步驟：

a. 模式認定 (Identification)：利用 ACF、PACF 來找出

定態序列下 ARIMA (p,d,q) 中的 p 與 q 的階次。

- b. 估計 (Estimation)：使用最小平方方法和最大概似法估計模式中之參數。
- c. 偵測 (Diagnosis)：檢查模型中的誤差項值 (ε_t) 是否存在著序列相關特性，使用 ACF、PACF 判定模式是否適當，若判定適當則使用此模式，否則須重複辨認模式和估計參數之步驟。

最後確認預測之合理性，使用圖形簡單的統計量和信賴區間來決定預測之適當性、追蹤模式表現並偵測失去控制的狀況。

4. 模型績效評估

預測能力之優劣通常要看預測值誤差之大小來評估預測之精確度，常用來預測精確度的統計量有 1. 平均絕對百分誤差 MAPE (Mean Absoute Percentage Error) 和 2. 根均方百分誤差 RMSPE (Root Mean Square Percentage Error) 兩種方法，MAPE 因方法計算簡單其使用範圍較廣泛。依據 Delurgio 區分，依 MAPE 及 RMSPE 之大小，將模式預測能力分成四個等級 (Delurgio, 2000)。如表 3.1。

表 3.1 MAPE & RMSPE 之預測能力等級

MAPE & RMSPE	預測能力
<10%	高精確度
10~20%	良好的預測
20~50%	合理的預測
>50%	不正確的預測

3.3.2 類神經網路

倒傳遞網路是目前類神經網路學習模式中最具有代表性，應用最普遍的網路模式。Werbos 於 1974 年在其博士論文中提出了隱藏層的學習演算法，這是已知最早的倒傳遞類神經網路模式。倒傳遞類神經網路架構如圖 3.1 所示，包括：




圖 3.1 三層之類神經網路架構圖

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

在檢驗 ANN 學習與測試績效，研究者須事先進行範例的製

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

倒傳遞網路有幾個重要參數，包括：

(1) 隱藏層處理單元

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

(2) 隱藏層層數

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

(3) 學習速率

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

倒傳遞網路之演算法以 3 層之 BPN 網路結構為例，其學法則分為三階段：學習範例之前推 (forward)、誤差之回饋 (feedback) 以及權重之調整。前推階段係將所有範例之輸入變數值 (x_i) 輸入網路，計算網路之輸出值 (y_j)。回饋階段則計算各輸出值 (y_j) 與

對應範例原輸出變數值(t_j)之誤差(δ_j)。調整階段，則依據誤差大小進行權重之調整。其演算法如下(Fausett, 1994)：

步驟零：設定權重之起始值。

步驟一：若不符停止條件，執行步驟二至十。

步驟二：輸入一個訓練範例，執行步驟三至八，直到所有範例均輸入後，跳至步驟九。

前推階段

步驟三：輸入層各節點($X_i, i=1, 2, \dots, n$)接收輸入資料。

步驟四：每一個隱藏層節點彙整輸入層各節點所傳來之資料，即： $z_in_j = v_{oj} + \sum_{i=1}^n x_i v_{ij}$ ，

再利用激發函數加以轉換，成為：

$$z_j = f(z_in_j)。$$

其中， v_{oj} 為隱藏層第 j 個節點的誤差項。

步驟五：每一個輸出層節點彙整隱藏層各節點所傳來之資料，即： $y_in_k = w_{ok} + \sum_{j=1}^p z_j w_{jk}$ ，

再利用激發函數加以轉換，成為：

$$y_k = f(y_in_k)。$$

其中， w_{oj} 為輸出層第 k 個節點的誤差項。

回饋階段

步驟六：計算每一個輸出層節點與其對應原範例輸出值之誤差，即： $\delta_k = (t_k - y_k)f'(y_in_k)$ 。

並據以計算輸出層權重調整幅度，即：

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

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

步驟七：計算每一個隱藏層節點彙整輸出層傳回之誤差，即： $\delta_in_j = \sum_{k=1}^m \delta_k w_{jk}$ ，乘以其激發函數之偏微分，即：

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

並據以計算隱藏層權重調整幅度，即：

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

調整階段

步驟八：更新輸出層之權重，即：

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

以及隱藏層之權重，即：

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

步驟九：計算能量函數 El 值， $l=l+1$ 。

步驟十：測試停止條件。停止條件通常設為：

$$(El - El-1) \leq \varepsilon。$$

ε 為設定之極小值。

訓練完成後，進行預測時，其運作步驟如下：

步驟零：設定權重值（以訓練所得之權重值設定之）。

步驟一：輸入預測案例之輸入變數值，設其為輸入層各節點值： x_i 。

步驟二：計算隱藏層各節點值：
 $z_{in_j} = v_{0j} + \sum_{i=1}^{n-1} x_i v_{ij}$ ， $z_j = f(z_{in_j})$ 。

步驟三：計算輸出層各節點值：
 $y_{in_k} = w_{ok} + \sum_{j=1}^{n-1} z_j w_{jk}$ ， $y_k = f(y_{in_k})$ 。

第四章 單元數列模式構建與驗證

根據前章之灰預測基礎模型，利用蒐集研究範圍內高速公路之環路線圈偵測器資料進行模式實證，分別以 1 分鐘、5 分鐘為單位構建 GM (1,1) 及滾態 RGM (1,1) 模式，分析兩種模式之預測績效結果，探討滾態 RGM (1,1) 模式中，不同滾動週期與不同預測長度之預測精確度，依據驗證結果選出最佳模式，並以相同資料應用 ARIMA 模式進行測試，比較兩模式之驗證績效，證明最佳模式之績效明顯優於 ARIMA 模式。

4.1 資料蒐集與樣本描述

資料來源為國道 1 號北上路段 208km+200m 處之環路線圈偵測器所測得之全日交通量、平均速度及佔有率等數據。資料的格式是分車道分車種統計，在埋設偵測器路段分為三個車道，車種則分為小車、大車及聯結車。本研究將三車道之數據予以彙整（交通量為加總資料，速度及佔有率則是平均資料）。本文進一步將每 20 秒一筆之資料彙整成 1 分鐘一筆及 5 分鐘一筆資料，故 1 分鐘一筆資料之全日資料共計有 1440 筆，5 分鐘一筆資料之全日資料共計有 288 筆。本研究共蒐集民國 94 年 9 月共 30 日資料，挑選與高速公路局 94 年交通統計報告之平均日交通量相符之週間五天，為 9 月 5 日～9 日共計 5 日之樣本資料，即星期一至星期五，（以下分別以 D1, D2,..., D5 稱之）。將樣本資料進行敘述統計分析（如表 4.1～4.6），顯示交通量之變異係數較大，且隨彙整時間單位越大，變異係數越大，由於交通量資料為加總數據，不同於平均速度與佔有率為平均資料，因此會隨彙整時間單位越長，數據越大，因此每單位的數據間變異程度較大，而數據變異係數較大是否會對預測結果產生影響，下小節將進行分析。

表 4.1 一分鐘交通量資料基本統計分析

資料特性	資料日期				
	D1	D2	D3	D4	D5
平均數	33.17	31.17	22.22	28.66	32.18
標準差	19.96	17.54	20.19	18.25	16.61
變異係數	398.57	367.32	397.60	369.05	385.88
峰度	-0.23	-0.46	-1.06	-0.57	-1.09
偏態	0.69	0.59	0.33	0.76	0.35
範圍	95	82	72	73	69
最小值	0	0	0	5	4
最大值	95	77	72	78	73

表 4.2 一分鐘平均速度資料基本統計分析表

資料特性	資料日期				
	D1	D2	D3	D4	D5
平均數	94.92	93.61	92.91	95.71	95.78
標準差	8.48	5.26	4.54	4.66	4.14
變異係數	68.92	48.94	26.59	31.72	37.15
峰度	88.43	11.39	2.32	10.79	4.85
偏態	-8.05	2.86	0.79	1.43	0.67
範圍	112.13	42.18	35.21	55.25	46.75
最小值	0.00	81.00	82.29	81.00	75.50
最大值	112.13	136.25	117.50	136.25	122.25

表 4.3 一分鐘佔有率資料基本統計分析表

資料特性	資料日期				
	D1	D2	D3	D4	D5
平均數	3.24	3.07	3.49	3.20	3.51
標準差	1.56	1.42	1.35	1.37	1.30
變異係數	2.42	1.93	1.82	1.86	1.98
峰度	0.62	0.37	0.24	-0.20	-0.50
偏態	0.86	0.34	0.50	0.66	0.29
範圍	8.75	8.75	8.00	6.50	6.25
最小值	0	0	1	1	1
最大值	8.75	8.75	9.00	7.50	7.25

表 4.4 五分鐘交通量資料基本統計分析

資料特性	資料日期				
	D1	D2	D3	D4	D5
平均數	165.84	119.22	111.10	143.31	160.89
標準差	9.98	10.07	12.79	16.85	14.43
變異係數	99.51	101.49	163.64	283.96	266.32
峰度	0.58	-0.05	-0.67	-0.19	0.07
偏態	0.70	-0.56	0.38	0.96	0.29
範圍	367	339	312	308	266
最小值	364	296	173	182	168
最大值	416	416	312	360	320

表 4.5 五分鐘平均速度資料基本統計分析表

資料特性	資料日期				
	D1	D2	D3	D4	D5
平均數	94.92	99.57	92.91	95.71	95.78
標準差	4.33	4.04	3.17	2.28	2.23
變異係數	18.71	5.15	10.03	5.19	4.97
峰度	14.37	1.45	1.00	0.29	2.02
偏態	-3.26	0.67	0.50	0.39	0.89
範圍	28.86	14.09	16.73	13.28	13.62
最小值	72.16	72.16	85.83	89.49	91.28
最大值	101.02	115.25	102.57	102.77	104.89

表 4.6 五分鐘佔有率資料基本統計分析表

資料特性	資料日期				
	D1	D2	D3	D4	D5
平均數	3.24	3.07	3.49	3.20	3.51
標準差	1.83	1.74	1.65	1.76	1.82
變異係數	3.78	3.16	2.72	3.28	3.67
峰度	0.45	0.42	-0.42	-0.14	-0.79
偏態	0.77	0.41	-0.09	0.82	0.26
範圍	5.9	5.2	4.05	4.7	4.15
最小值	1.35	2.05	1.6	1.55	1.65
最大值	7.25	7.25	5.65	6.25	5.8

4.2 灰預測模型

依據連續 5 日樣本資料，以灰預測模型進行預測分析，GM(1,1) 模型是將資料直接輸入模式中分析，依輸入的筆數不同分析預測一筆、二筆、三筆至五筆等之預測績效，由於預測時只校估一次參數，應此稱為靜態模式。滾動模型則於分析時自動剔除先前筆數資料，只保留近期筆數資料進行預測，透過滾動始終使用最近期之歷史資料，滾動模型分為 4、5、6、7、8 等 5 種時階，每滾動一次便執行參數校估一次，因此又稱為 RGM(1,1) 模式（即每 4、5、...、8 筆資料校估參數一次，再進行預測），探討不同滾動學習時階之模式預測精確度變化。

交通量、平均速度及佔有率之時間序列數值，可建立 RGM(1,1) 一階單變數的灰色模型，以最少 4 筆連續時間之交通資訊之預測為例，其系統如圖 4.1 所示。輸入資料最少需要 4 筆，亦可以到數十筆，預測第 1 筆之結果與真實資料相減結果百分比即為預測之誤差，亦可以預測後續更多筆數，但其預測績效需加以檢視。在灰預測的模式中 $\otimes A = \otimes A + \alpha(\otimes A - \otimes A)$, $\alpha \in [0,1]$ ，使用 α 作為權重值，由於 α 值的調整可以降低預測誤差結果，通常以試誤法調整權重值，以求達到模式最佳化，而一般均採等權重方式將 α 設定為 0.5 進行模式績效預測，本研究以權重方式將 α 設定為 0.5，分別針對交通量、平均速度，以及佔有率等三項交通資訊進行預測模型之建構、驗證與比較。




圖 4.1 RGM(1,1)灰預測系統

4.2.1 交通量

將 5 日之樣本資料，以一分鐘及五分鐘為單位，分別建構不同滾動時階之 RGM(1,1)模型及不滾動之 GM(1,1)模型，結果如表 4.7、4.8 所示。其中，以滾動時階為 4 的 RGM(1,1)模型，一分鐘單位資料，全日 1440 筆資料，共需滾動 1436 次；五分鐘單位資料，全日 288 筆資料，共需滾動預測 284 次，而平均誤差率是將此 1436 次及 284 次預測值與實際值間之比較平均而得。以此類推，滾動時階為 5 的 RGM(1,1)模型，一分鐘單位資料，需滾動 1435 次，五分鐘單位資料，需滾動 283 次、滾動時階為 6 則需滾動 1434 次及 282 次。至於 GM(1,1)則利用之前一分鐘單位資料 1439 筆與五分鐘單位資料 287 筆校估參數後，預測下一筆。

由表 4.7 知，一分鐘單位資料，以 5 日之平均預測誤差而言，滾動時階為 4 時，平均預測誤差為 12.38%、滾動時階 5 為 16.12%、滾動時階 6 為 18.06%、滾動時階 7 為 19.17%、滾動時階 8 為 20.13%，顯示滾動時階愈長，預測績效反而愈差。此與傳統統計模型，資料樣本愈多愈精確之特性明顯不同。而 GM(1,1)模型（不滾動）之預測誤差則高達 42.30%，誤差極為嚴重，顯示滾動機制之重要性。表 4.8，五分鐘單位資料之平均預測誤差顯示，滾動時階為 4 時，平均預測誤差為 5.94%、滾動時階 5 為 7.30%、滾動時階 6 為 8.0%、滾動時階 7 為 8.52%、滾動時階 8 為 8.90%，GM(1,1)模型（不滾動）之預測誤差為 35.22%，預測結果明顯優於一分鐘單位資料，就模式特性而言，顯示資料單位愈大，預測精確度愈高，就滾動時階而言，同樣顯示滾動時階愈長，預測績效有愈差之趨勢。

此外，以同一滾動時階模型而言（以表 4.7 滾動時階 4 為例），以 D2 之預測誤差最低，僅 10.66%，D1 之預測誤差最大，達 14.43%。若進一步觀察各日之預測誤差與與各日交通量變化情形（以變異係數表之）間之關係，可繪製成圖，如圖 4.2 所示。由圖知，平均預測誤差率與交通量變異程度之分佈型態大致相同，顯示資料標準差愈大，預測之誤差也愈大，也愈難加以精確地預測。其全日之交通量預測值與實際值之分佈情形如圖 4.3 所示。

表 4.7 不同滾動時階之交通量平均預測誤差

資料日期	RGM(1,1)之滾動時階					不滾動
	4	5	6	7	8	GM(1,1)
D1	14.43%	18.94%	21.27%	22.38%	23.82%	35.83%
D2	10.66%	14.57%	16.50%	17.86%	18.78%	44.33%
D3	12.77%	16.18%	17.77%	18.64%	19.42%	37.01%
D4	11.24%	14.45%	16.39%	17.16%	17.89%	43.23%
D5	12.81%	16.45%	18.39%	19.80%	20.76%	51.13%
平均	12.38%	16.12%	18.06%	19.17%	20.13%	42.30%

(資料單位：1 分鐘一筆，預測長度 = 1 筆)

表 4.8 不同滾動時階之交通量平均預測誤差

資料日期	RGM(1,1)之滾動時階					不滾動
	4	5	6	7	8	GM(1,1)
D1	6.69%	7.77%	8.60%	9.16%	9.57%	36.18%
D2	5.49%	7.19%	7.49%	7.85%	8.18%	44.54%
D3	5.07%	6.31%	6.89%	7.40%	7.76%	26.82%
D4	5.63%	7.42%	8.23%	8.72%	9.07%	30.74%
D5	6.80%	7.81%	8.82%	9.46%	9.89%	37.80%
平均	5.94%	7.30%	8.00%	8.52%	8.90%	35.22%

(資料單位：5 分鐘一筆，預測長度 = 1 筆)

由交通量平均預測誤差結果得知靜態 GM(1,1)模型 (即不滾動) 之預測誤差則高達 42.30% (一分鐘單位資料)，五分鐘單位資料之預測誤差亦高達 35.22%，誤差極為嚴重，顯示靜態之 GM(1,1)模型在長期預測績效並不理想，透過滾動機制，將預測筆數減少至 4 筆時，能凸顯灰預測之績效，就滾動時階之平均預測誤差來看，一分鐘單位資料預測誤差為 12.38%，五分鐘單位資料誤差為 5.94%，顯示滾動灰預測模式在短期交通量上有良好之預測能力。




圖 4.2 滾動時階 4 之誤差率與交通量變異係數之各日分佈型態




圖 4.3 滾動時階 4 之 D2 交通量預測值與實際值之分佈情形

為了解 RGM(1,1)在不同預測長度之績效表現，本文以(D2)一分鐘及五分鐘單位資料分別利用不同滾動時階之 RGM(1,1)模型，預測之後 5~25 分鐘之資料（即預測後 1~5 筆），結果如表 4.9、4.10 所示。由表知，以各滾動時階之平均誤差而言，具有預測長度愈長，誤差率有愈高之趨勢。而滾動時階之預測績效排序在不同預測長度仍維持以時階愈短愈好之特性。

表 4.9 不同預測長度之交通量平均預測誤差

預測長度	RGM(1,1)之滾動時階					平均誤差
	4	5	6	7	8	
1 筆	12.38%	16.12%	18.06%	19.17%	20.13%	17.17%
2 筆	13.04%	17.25%	18.57%	20.68%	20.79%	18.07%
3 筆	14.47%	18.40%	19.72%	21.43%	22.19%	19.24%
4 筆	15.63%	19.45%	20.51%	22.89%	23.81%	20.46%
5 筆	17.51%	21.38%	21.94%	23.24%	24.47%	21.71%

（資料單位：1 分鐘一筆，預測長度 = 1 筆）

表 4.10 不同預測長度之交通量平均預測誤差

預測長度	RGM(1,1)之滾動時階					平均誤差
	4	5	6	7	8	
1 筆	5.94%	7.30%	8.00%	8.52%	8.90%	7.73%
2 筆	6.11%	8.29%	8.61%	8.96%	9.82%	8.36%
3 筆	6.52%	8.76%	9.22%	9.64%	10.73%	8.97%
4 筆	7.68%	9.46%	9.93%	10.05%	11.23%	9.67%
5 筆	8.31%	9.97%	10.21%	10.72%	11.84%	10.21%

（資料單位：5 分鐘一筆，預測長度 = 1 筆）

4.2.2 平均速度

以相同 5 日之樣本資料分別建構平均速度在不同滾動時階之 RGM(1,1)模型及不滾動之 GM(1,1)模型，一分鐘單位資料及五分鐘單位資料預測結果分別如表 4.11、4.12 所示。由表 4.11 知，一分鐘單位資料，以 5 日之平均預測誤差而言，滾動時階為 4 時，

平均預測誤差為 1.74%、滾動時階 5 為 2.20%、滾動時階 6 為 2.48%、滾動時階 7 為 2.61%、滾動時階 8 為 2.73%%，顯示滾動時階愈長，預測績效反而愈差，不過，各滾動時階之預測誤差相距不大，均在 0.5%以下，顯示以 RGM(1,1)預測平均速度較預測交通量之績效更好。而 GM(1,1)模型（不滾動）之預測誤差為 3.48%，準確率已較預測交通量時大幅改善。表 4.12，五分鐘單位資料之平均預測誤差顯示，滾動時階為 4 時，平均預測誤差為 0.83%、滾動時階 5 為 1.03%、滾動時階 6 為 1.13%、滾動時階 7 為 1.20%、滾動時階 8 為 1.24%，GM(1,1)模型（不滾動）之預測誤差為 1.67%，預測結果明顯優於一分鐘單位資料，顯示資料單位愈大，預測精確度愈高，但預測誤差差距不大，僅在 1%左右。

此外，以同一滾動時階模型而言（以表 4.11 滾動時階 4 為例），以 D3 之預測誤差最低，僅 1.42%。D1 之預測誤差最大，為 2.23%，但與 D3 相較差距不大。若進一步觀察各日之預測誤差與與各日平均速度變化情形（以變異係數表之）間之關係，可繪製成圖，如圖 4.4 所示。由圖知，平均預測誤差率與平均速度變異程度之分佈型態也大致相同，顯示資料標準差愈大，預測之誤差有愈大之趨勢。其全日之平均速度預測值與實際值之分佈情形如圖 4.5 所示。

表 4.11 不同滾動時階之平均速度平均預測誤差

資料日期	RGM(1,1)之滾動時階					不滾動
	4	5	6	7	8	GM(1,1)
D1	2.23%	2.78%	3.15%	3.22%	3.35%	4.87%
D2	1.79%	2.26%	2.51%	2.66%	2.87%	3.28%
D3	1.42%	1.80%	2.02%	2.12%	2.20%	2.88%
D4	1.60%	2.06%	2.34%	2.49%	2.60%	3.17%
D5	1.64%	2.11%	2.37%	2.55%	2.65%	3.17%
平均	1.74%	2.20%	2.48%	2.61%	2.73%	3.48%

（資料單位：1 分鐘一筆，預測長度＝1 筆）

表 4.12 不同滾動時階之平均速度平均預測誤差

資料日期	RGM(1,1)之滾動時階					不滾動
	4	5	6	7	8	GM(1,1)
D1	0.91%	1.13%	1.23%	1.30%	1.32%	1.71%
D2	0.86%	1.00%	1.10%	1.15%	1.18%	1.61%
D3	0.79%	0.95%	1.06%	1.14%	1.20%	1.55%
D4	0.68%	0.90%	1.01%	1.08%	1.15%	1.67%
D5	0.92%	1.15%	1.26%	1.34%	1.36%	1.79%
平均	0.83%	1.03%	1.13%	1.20%	1.24%	1.67%

(資料單位：5 分鐘一筆，預測長度＝1 筆)






圖 4.4 滾動時階 4 之誤差率與平均速度變異係數之各日分佈型態




圖 4.5 滾動時階 4 之 D3 平均速度預測值與實際值之分佈情形

在 RGM(1,1)不同預測長度之績效表現方面(D1)，平均速度預測之後 5~25 分鐘之資料（即預測後 1~5 筆），結果如表 4.13、4.14 所示。由表知，以各滾動時階之平均誤差而言，具有預測長度愈長，誤差率有愈高之趨勢，不過，誤差率增加幅度不大，以表 4.13 為例，預測後 1 筆之平均誤差為 2.35%，預測後 5 筆之平均誤差為 4.20%，僅增加約 2%；表 4.14 預測後 1 筆之平均誤差為 1.09%，預測後 5 筆之平均誤差為 2.78%，只增加了 1.69%，顯示 RGM(1,1)預測平均速度方面具有穩定的預測精確度。

表 4.13 不同預測長度之平均速度平均預測誤差

預測長度	RGM(1,1)之滾動時階					平均誤差
	4	5	6	7	8	
1 筆	1.74%	2.20%	2.48%	2.61%	2.73%	2.35%
2 筆	2.11%	2.66%	2.94%	3.26%	3.34%	2.86%
3 筆	2.36%	3.12%	3.48%	3.53%	3.61%	3.22%
4 筆	2.71%	3.86%	3.87%	3.95%	4.04%	3.69%
5 筆	3.46%	4.23%	4.34%	4.42%	4.53%	4.20%

（資料單位：1 分鐘一筆，預測長度 = 1 筆）

表 4.14 不同預測長度之平均速度平均預測誤差

預測長度	RGM(1,1)之滾動時階					平均誤差
	4	5	6	7	8	
1 筆	0.83%	1.03%	1.13%	1.20%	1.24%	1.09%
2 筆	0.96%	1.23%	1.31%	1.39%	1.44%	1.27%
3 筆	1.22%	1.37%	1.45%	1.49%	1.53%	1.41%
4 筆	1.35%	1.46%	1.76%	2.01%	2.11%	1.74%
5 筆	2.49%	2.66%	2.83%	2.94%	2.98%	2.78%

（資料單位：5 分鐘一筆，預測長度 = 1 筆）

4.2.3 佔有率

以相同 5 日之樣本資料分別建構平均佔有率在不同滾動時階之 RGM(1,1)模型及不滾動之 GM(1,1)模型，一分鐘單位資料及五

分鐘單位資料預測結果分別如表 4.15、4.16 所示。由表 4.15 知，一分鐘單位資料，以 5 日之平均預測誤差而言，滾動時階為 4 時，平均預測誤差為 6.18%、滾動時階 5 為 7.46%、滾動時階 6 為 8.39%、滾動時階 7 為 8.60%、滾動時階 8 為 8.98%，顯示滾動時階愈長，預測績效反而愈差，不過，各滾動時階之預測誤差相距不大，顯示以 RGM(1,1)預測平均佔有率之績效優於預測交通量但劣於預測平均速度。而 GM(1,1)模型（不滾動）之預測誤差為 17.49%。表 4.16，五分鐘單位資料之平均預測誤差顯示，滾動時階為 4 時，平均預測誤差為 12.41%、滾動時階 5 為 15.75%、滾動時階 6 為 17.73%、滾動時階 7 為 18.88%、滾動時階 8 為 19.80%，GM(1,1)模型（不滾動）之預測誤差為 28.32%，預測結果一分鐘單位資料預測誤差明顯優於五分鐘單位資料，顯示平均佔有率資料，具有資料單位愈大，預測精確度愈低之特性。

此外，各滾動時階模型在各全日佔有率之預測績效之排序也不盡相同。以同一滾動時階模型而言（以表 4.15 滾動時階 4 為例），以 D3 之預測誤差最低，誤差 4.91%。D5 之預測誤差最大，為 7.41%，但彼此差距不大。若進一步觀察各日之預測誤差與各日平均佔有率變化情形（以變異係數表之）間之關係，可繪製成圖，如圖 4.6 所示。由圖知(圖 4.7)，平均預測誤差率與佔有率變異程度之分佈型態顯示資料標準差愈大，預測之誤差有愈大之趨勢似乎具反向關係。

表 4.15 不同滾動時階之佔有率平均預測誤差

資料日期	RGM(1,1)之滾動時階					不滾動
	4	5	6	7	8	GM(1,1)
D1	7.15%	8.29%	9.33%	9.68%	10.15%	18.84%
D2	5.34%	7.01%	7.55%	7.94%	8.27%	18.42%
D3	4.91%	6.27%	6.76%	7.39%	7.83%	12.27%
D4	6.07%	7.27%	8.84%	8.15%	8.32%	19.10%
D5	7.41%	8.45%	9.50%	9.85%	10.32%	18.84%
平均	6.18%	7.46%	8.39%	8.60%	8.98%	17.49%

（資料單位：1 分鐘一筆，預測長度＝1 筆）

表 4.16 不同滾動時階之佔有率平均預測誤差

資料日期	RGM(1,1)之滾動時階					不滾動
	4	5	6	7	8	GM(1,1)
D1	12.38%	15.92%	17.60%	18.89%	19.68%	23.60%
D2	12.08%	16.08%	17.73%	19.13%	20.33%	29.62%
D3	13.58%	16.50%	18.41%	19.29%	20.34%	26.57%
D4	10.71%	13.32%	15.35%	16.30%	16.82%	26.03%
D5	13.28%	16.94%	19.54%	20.76%	21.82%	35.78%
平均	12.41%	15.75%	17.73%	18.88%	19.80%	28.32%

(資料單位：5 分鐘一筆，預測長度＝1 筆)






圖 4.6 滾動時階 4 之誤差率與佔有率標準差間之關係




圖 4.7 滾動時階 4 之 D3 佔有率預測值與實際值之分佈情形

平均佔有率在 RGM(1,1) 不同預測長度之績效表現方面 (D1)，平均佔有率預測之後 5~25 分鐘之資料（即預測後 1~5 筆），結果如表 4.17、4.18 所示。由表知，以各滾動時階之平均誤差而言，具有預測長度愈長，誤差率有愈高之趨勢。以表 4.17 為例，預測後 1 筆之平均誤差為 6.18%，預測後 5 筆之平均誤差增加至 9.81%；表 4.18 預測後 1 筆之平均誤差為 12.41%，預測後 5 筆之平均誤差增加至為 16.87%。

表 4.17 不同預測長度之平均佔有率平均預測誤差

預測長度	RGM(1,1)之滾動時階					平均誤差
	4	5	6	7	8	
1 筆	6.18%	7.46%	8.39%	8.60%	8.98%	7.92%
2 筆	6.96%	8.46%	9.59%	9.75%	9.86%	8.92%
3 筆	7.83%	9.51%	10.61%	10.77%	10.98%	9.94%
4 筆	8.69%	10.62%	11.73%	11.80%	11.87%	10.94%
5 筆	9.81%	12.03%	12.54%	13.08%	13.76%	12.24%

（資料單位：1 分鐘一筆，預測長度 = 1 筆）

表 4.18 不同預測長度之平均佔有率平均預測誤差

預測長度	RGM(1,1)之滾動時階					平均誤差
	4	5	6	7	8	
1 筆	12.41%	15.75%	17.73%	18.88%	19.80%	16.91%
2 筆	13.22%	16.21%	18.15%	19.28%	20.76%	17.52%
3 筆	14.51%	17.43%	19.38%	20.65%	21.11%	18.62%
4 筆	15.47%	18.17%	20.19%	21.43%	22.52%	19.56%
5 筆	16.87%	19.02%	20.89%	22.21%	23.62%	20.52%

（資料單位：5 分鐘一筆，預測長度 = 1 筆）

由以上各小節之比較分析可知，RGM(1,1)模型明顯優於不滾動之 GM(1,1)模型，且 RGM(1,1)模型具有滾動時階愈少、預測長度愈短，其準確度愈高之特性。不過，GM(1,1)模型於交通量預測方面則明顯表現不佳，一分鐘及五分鐘單位資料上之誤差率為 42.30%、35.22%，但在平均速度及佔有率預測方面，也具有不錯

的預測績效，平均速度為 3.48%、1.67%，佔有率為 17.49%、28.32%。

而原始資料單位的使用，交通量及平均速度預測結果顯示，資料單位愈大，其預測精確度愈準確，其中，以滾動時階為 4 之模型，其預測結果最佳，一分鐘單位資料分析結果，預測後 1 筆交通量之誤差率為 12.38%，平均速度為 1.74%，五分鐘單位資料其預測後 1 筆交通量之誤差率為 5.94%，平均速度為 0.83%。而在平均佔有率方面，原始資料則為單位愈小預測準確度愈高，一分鐘資料分析結果，誤差率為 6.18%，五分鐘資料誤差率為 12.41%。

就預測長度而言，滾動時階為 4 之模型不論在一分鐘或五分鐘單位資料上，其預測後 5 筆交通資訊之誤差率，交通量分別為 17.51%、8.31%，平均速度為 3.46%、2.49%，佔有率為 9.81%、16.87%。以 MAPE 績效指標等級分析（表 3.1）而言，RGM(1,1) 模型屬於高精確度的預測模式。

4.3 ARIMA 模型

為進一步比較本文所建立之 RGM(1,1)模型之績效，本節另利用同樣之交通資訊資料，建立時間序列分析之 ARIMA 模型，並將其預測績效與 RGM(1,1)(以滾動時階為 4 之模型為代表)比較。ARIMA 模型是運用 SPSS 軟體繪製 ACF 圖形，分析其是否為一平穩序列，若否則進行一次差分，接著以 AIC 圖、SBIC 圖決定最佳之(p, d, q)，在對 AR(p)、MA(q)進行參數校估，最後進行預測分析誤差率。以下即針對交通量、平均速度，以及佔有率等三項交通資訊分別進行比較分析。

4.3.1 交通量

上節所述 RGM(1,1)之交通量預測最佳模式為 RGM(1,1)滾動時階 4 模式，將其一分鐘資料及五分鐘單位資料分別以 SPSS 軟體建立 ARIMA 模型。以 D2 之交通量資料為例，由 ACF 圖顯示該序列資料為非平穩型序列，故先對原始序列進行一次差分，再繪製其 ACF 與 PACF 圖，結果如圖 4.9、4.10 所示。顯示一次差

分後之序列已呈穩定。再以 AIC 圖及 SBIC 圖決定最佳之 (p, d, q) 參數數值，本文將其設定為 $(2, 1, 1)$ 。表 4.19、4.20 為一分鐘及五分鐘單位資料之 ARIMA 模式，其在不同預測長度下之預測績效，由表知 ARIMA 模式顯示預測長度愈長，其預測績效具有明顯惡化之現象；進一步與滾動時階為 4 之 RGM(1,1)模型之預測結果比較可知，滾動時階 4 之 RGM(1,1)模型其交通量之預測精確度明顯優於 ARIMA 模型，而且兩種方法誤差比率之差距，更隨著預測長度增長，而明顯增加。顯示，ARIMA 在預測長度延長時，其預測績效無法維持。



表 4.19 RGM(1,1)與 ARIMA 之交通量預測結果（一分鐘單位）

預測長度	RGM(1,1)	ARIMA	誤差比率差距
1	12.38%	24.59%	12.21%
2	13.04%	29.32%	16.28%
3	14.47%	37.43%	22.96%
4	15.63%	38.88%	23.25%
5	17.51%	42.77%	25.26%

表 4.20 RGM(1,1)與 ARIMA 之交通量預測結果（五分鐘單位）

預測長度	RGM(1,1)	ARIMA	誤差比率差距
1	5.94%	11.70%	5.76%
2	6.11%	17.28%	11.17%
3	6.52%	30.41%	23.89%
4	7.68%	37.46%	29.78%
5	8.31%	48.15%	39.84%




圖 4.8 交通量之 ACF 圖




圖 4.9 交通量之 PACF 圖

4.3.2 平均速度

上節所述 RGM(1,1)之平均速度預測最佳模式為 RGM(1,1)滾動時階 4 模式，同樣依兩種單位資料分別建立 ARIMA 模型。以 D3 之平均速度資料為例，對原始序列進行一次差分後，再繪製其 ACF 與 PACF 圖，結果如圖 4.11、4.12 所示，顯示一次差分後之序列已呈穩定。再以 AIC 圖及 SBIC 圖決定最佳之(p, d, q)參數數值，本文將其設定為(2, 1, 1)。表 4.21、4.22 為一分鐘及五分鐘單位資料之 ARIMA 模式，其在不同預測長度下之預測績效，由表 4.21 知 ARIMA 模式其預測後 1 筆之誤差值為 2.97%，後 2 筆之誤差值為 3.02%，後 3 筆之誤差值為 5.72%，後 4 筆之誤差值為 11.03%，後 5 筆之誤差值為 11.51%，預測後 3 筆之誤差值仍趨於穩定，但至預測後 4 筆時，誤差值開始增大，進一步與滾動時階為 4 之 RGM(1,1)模型之預測結果比較可知，預測後 4 筆時，誤差比率差距達 8.32%，顯示滾動時階 4 之 RGM(1,1)模型其平均速度之預測精確度優於 ARIMA 模型，不過，ARIMA 在平均速度預測之表現較交通量預測準確，當預測長度延長時，兩種方法誤差比率之差距較小。由表 4.22 可知，五分鐘單位資料之 ARIMA 模式，預測後 2 筆之誤差值仍趨於穩定，誤差值為 3.02%，但至預測後 3 筆時，誤差值開始增大，預測後 5 筆時誤差值已達 24.08%，兩種方法誤差比率達 21.59%，顯示 ARIMA 之平均速度預測模式中，一分鐘單位模式優於五分鐘單位模式。

表 4.21 RGM(1,1)與 ARIMA 之平均速度預測結果

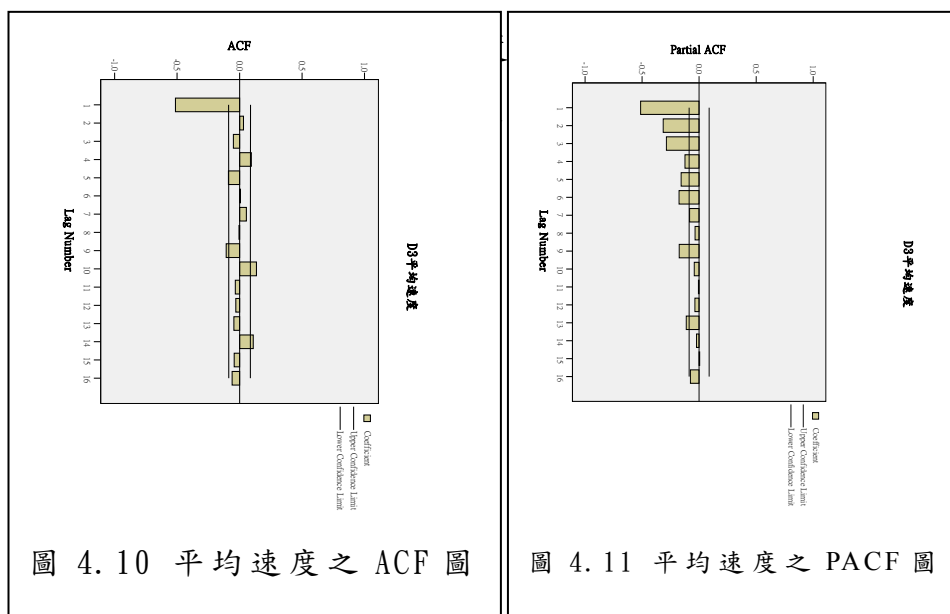
預測長度	RGM(1,1)	ARIMA	誤差比率差距
1	1.74%	2.97%	1.23%
2	2.11%	3.02%	0.91%
3	2.36%	5.72%	3.36%
4	2.71%	11.03%	8.32%
5	3.46%	11.51%	8.05%

(一分鐘單位)

表 4.22 RGM(1,1)與 ARIMA 之平均速度預測結果

預測長度	RGM(1,1)	ARIMA	誤差比率差距
1	0.83%	3.41%	2.58%
2	0.96%	4.88%	3.92%
3	1.22%	10.53%	9.31%
4	1.35%	14.30%	12.95%
5	2.49%	24.08%	21.59%

(五分鐘單位)



4.3.3 佔有率

上節所述 RGM(1,1)之佔有率預測最佳模式為 RGM(1,1)滾動時階 4 模式，同樣依兩種單位資料分別建立 ARIMA 模型。以 D3 之佔有率資料為例，對原始序列進行一次差分後，再繪製其 ACF 與 PACF 圖(圖 4.13、4.14)，顯示一次差分後之序列已呈穩定。再以 AIC 圖及 SBIC 圖決定最佳之(p, d, q)參數數值為(1, 1, 1)。表 4.23、4.24 為一分鐘及五分鐘單位資料之 ARIMA 模式，其在不同預測長度下之預測績效，由表知 ARIMA 模式之預測長度愈長，其預測績效有明顯惡化之現象；進一步與 RGM(1,1)模型比較可知，RGM(1,1)模型之預測精確度明顯優於 ARIMA 模型，而且兩種方法誤差比率差距，隨著預測長度增長而明顯增加。顯示，ARIMA 在預測長度延長時，其預測績效無法維持。

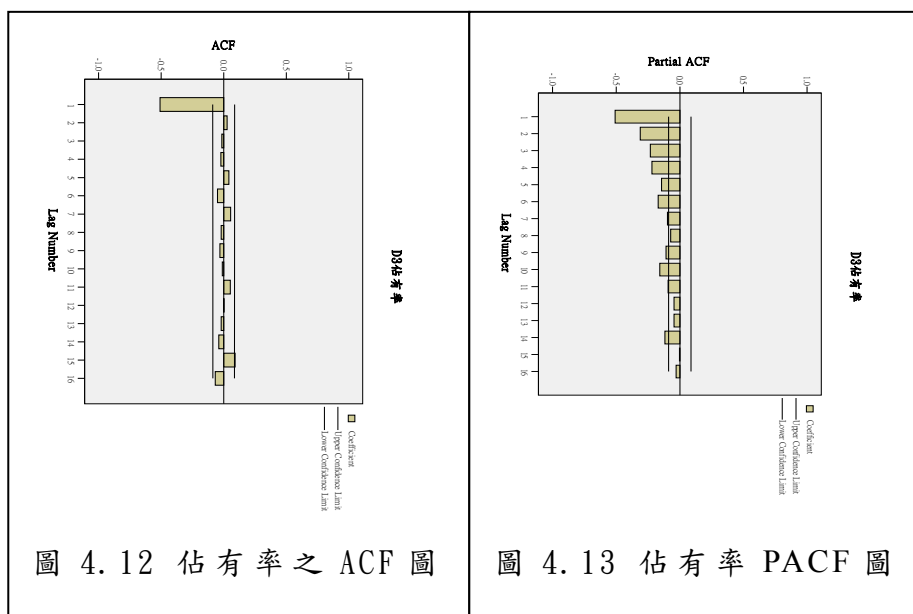


表 4.23 RGM(1,1)與 ARIMA 之佔有率預測結果(一分鐘單位)

預測長度	RGM(1,1)	ARIMA	誤差比率差距
1	6.18%	14.13%	7.95%
2	6.96%	17.39%	10.43%
3	7.83%	24.22%	16.39%
4	8.69%	29.46%	20.77%
5	9.81%	33.88%	24.07%

表 4.24 RGM(1,1)與 ARIMA 之佔有率預測結果(五分鐘單位)

預測長度	RGM(1,1)	ARIMA	誤差比率差距
1	12.41%	28.63%	23.24%
2	13.22%	33.10%	26.50%
3	14.51%	48.37%	36.33%
4	15.47%	50.85%	41.57%
5	16.87%	61.57%	45.99%



4.4 小結

本文利用滾動灰預測模型 (RGM(1,1)) 建構高速公路短期交通資訊 (交通量、平均速度及佔有率) 之預測模型, 探討不同單位長度資料 (一分鐘一筆及五分鐘一筆) 之預測結果, 並與 ARIMA 模型進行比較分析, 藉以驗證本模型之準確率。此外, 也同時進行不同滾動時階 (4~8 階) 及不同預測長度 (1~5 筆) 下, RGM(1,1) 模型預測績效之檢討。結果顯示:

從資料單位來看, 將不同滾動時階 (4~8 階) 預測後一筆之誤差值取其平均, 交通量一分鐘單位之誤差值為 17.17%, 五分鐘單位之誤差值為 7.73%; 平均速度一分鐘單位之誤差值為 2.35%, 五分鐘單位之誤差值為 1.09%, 顯示交通量、平均速度預測模型以五分鐘單位資料預測績效較佳, 而佔有率一分鐘單位之誤差值為 7.92%, 五分鐘單位之誤差值為 16.91%, 則以一分鐘單位資料預測績效較佳。

就資料本身特性而言, 高速公路主線屬於封閉式道路, 又有其速限規定, 因此, 正常狀況下, 通過偵測器之車輛速度均維持在時速 80~90 之區間, 因而平均速度容易進行預測, 且預測準確度亦較其他二者精確。而單位時間越大佔有率預測誤差越大之趨勢, 係因一分鐘單位資料之變異數小於五分鐘單位資料之變異數, 因此變異數大小影響其預測精確度, 佔有率採以較小的單為時間進行佔有率之預測績效較佳。

就滾動時階而言, RGM(1,1) 模型具有滾動時階愈少, 預測長度愈短, 其準確度愈高之趨勢。以表現最佳之 4 個滾動時階模型為例, 其預測後 1 筆五分鐘單位資料交通量之誤差率為 5.94%, 平均速度為 0.83%, 一分鐘單位資料佔有率為 6.18%。顯示在 RGM(1,1) 在短期交通資訊 (交通量、平均速度及佔有率) 之預測上具有相當之準確度。

在預測長度方面, 若延長預測長度達後 5 筆時, 則五分鐘單位資料交通量之誤差率增為 8.31%, 平均速度為 2.49%, 一分鐘單位資料佔有率為 9.81%。不過, 與 ARIMA 模型之績效比較結果顯示, RGM(1,1) 模型之表現明顯優於 ARIMA 模型, 而且具有預

測長度愈長，表現差距愈大之趨勢。顯示在短期交通資訊之預測上，RGM(1,1)模型優於 ARIMA 模型。



第五章 多元預測模式構建與驗證

RGM(1,1) 模式就本身資料序列進行預測，其預測精確度具有不錯的水準，且具有單位時間越長、滾動時階越短，預測精確度越高的趨勢。若考慮整體環境中，有許多因素會影響預測序列資料的變化，本研究將依據前章之最佳預測模式-一分鐘單位資料，滾動時階 4 之 RGM(1,1) 進一步構建多元預測模式-RGM(1,N) 模式，探討其預測精確度。

本研究依據前章之最佳預測模式-一分鐘單位資料，滾動時階 4 之 RGM(1,1) 進一步構建 GM(1,N) 模式，應用同一偵測器之交通量、速度、佔有率資料，以整合方式同時進行預測，其變數包括三者間之關連變數、上下游偵測器資料、前一日、前一週歷史資料等。GM(1,N) 模式構建初期，先以灰關聯方法分析模式中變數與預測準確度之相關係數，找出影響預測準確值之主因變數，最後以滾動設計構建 RGM(1,N) 模式，在 RGM(1,N) 模式中找出最佳多階灰預測模式，並以類神經網路作為績效驗證對照模式。

5.1 灰關聯分析

RGM(1,N) 模式即探討多個變數對預測結果的影響，依據車流理論觀點，車流、速度與密度關係 (Q-V-K)，其中一者，可利用其他兩者資料，透過 Q-V-K 關係圖加以估計求得，因此可利用車流、速度與密度關係 (Q-V-K) 進行多元預測；考慮路段上、下游交通組成可能會影響觀測點偵測器偵測結果，例如上游路段發生事故，會造成觀測路段流量減少，或下游路段發生事故造成車流迴堵，使得觀測路段平均速度降低等情形，故觀測點上下游偵測器資料亦可列為影響變數，而歷史資料能反應路段過去的路況資訊，例如週間的交通組成，可利用前一星期該日資料預測未來狀況，或重大節日交通量預測可利用歷年重大節日之該日資料預測未來狀況，因此路段之歷史資料也可作為一影響變數。

在灰關聯分析方法中，本研究僅以以 $x_0^{(0)}(t)$ 為參考序列，其他的序列為比較序列時，又稱為「局部灰關聯」，在灰關聯係數中，辨識係數 (ζ) 之功能主要是作背景值和比較序列之間的對比，數值的大小可以根據實際的需要作適當之調整，一般而言，辨識係數的數值取 $\zeta=0.5$ ，但是為了加大結果的差異性，可以依據實際的需要作調整，本研究以 $\zeta=0\sim1$ 進行實驗，結果發現 ζ 數值的改變只會影響相對數值的大小，不會影響灰關聯度的排序，因此，本研究以 $\zeta=0.5$ 進行灰關聯分析，對各比較序列之關聯度進行排序。

本研究以簡單灰關聯方法進行變數間之關聯分析，對各個變數採等權重值，亦即是各個因子對系統之重要程度完全相同進行分析。依據前章之最佳預測模式-一分鐘單位資料，滾動時階 4 之 RGM (1,1) 進一步構建 GM (1,N) 模式，應用同一偵測器之交通量、速度、佔有率資料，以整合方式同時進行預測，其變數包括三者間之關連變數、上下游偵測器資料、前一日、前一週歷史資料等。在 GM (1,N) 模式構建初期，相關變數之挑選需有一套應用準則，依據文獻中楊川明【28】考慮多項因素會影響預測模式之精確度變化，先以灰關聯方法分析模式中變數與預測準確度之相關係數，找出影響預測準確值之主因變數。以下依交通量、平均速度及佔有率三個模式分別進行分析。

5.1.1 交通量灰關聯分析

在第四章中，選取五日之資料樣本以第二天（即 Day-2）之資料表現最佳，故以滾動時階 4 之 RGM (1,1) 模式 Day-2 之交通量原始序列資料作為灰關聯分析之參考數列即 $x_0^{(0)}(t)$ ，比較數列依序為同一偵測器之平均速度資料 ($x_1^{(0)}(t)$)，同一偵測器之佔有率資料 ($x_2^{(0)}(t)$)，觀測路段上游前一支偵測器之交通量資料 ($x_3^{(0)}(t)$)，觀測路段下游後一支偵測器之交通量資料 ($x_4^{(0)}(t)$)，前一日同一偵測器之交通量資料 ($x_5^{(0)}(t)$)，前一週同一偵測器之交通量資料 ($x_6^{(0)}(t)$) 等六項。序列長度為 1440 筆，其序列資料如表 5.1 所示。

表 5.1 交通量預測變數灰關聯序列表

關聯序列	t=1	t=2	t=3	t=...	t=1440
考序列 $=x_0^{(0)}(t)$	31	21	27	...	30
較序列 1 $=x_1^{(0)}(t)$	99.77	103.89	96.89	...	99.67
較序列 2 $=x_2^{(0)}(t)$	4.33	3	3.33	...	4
較序列 3 $=x_3^{(0)}(t)$	26	17	28	...	35
較序列 4 $=x_4^{(0)}(t)$	31	33	16	...	43
較序列 5 $=x_5^{(0)}(t)$	24	21	32	...	29
較序列 6 $=x_6^{(0)}(t)$	20	23	17	...	27

以辨識係數 $\zeta=0.5$ ，等權重進行灰關聯分析，得出各比較序列與參考序列之關聯度大小排序依序為序列 4>序列 3>序列 6>序列 5>序列 1>序列 2，即下游後一支偵測器之交通量資料關連度最高，上游前一支偵測器之交通量資料次之，各比較序列之灰關聯係數如表 5.2 所示。此關連度分析結果將作為構建 GM(1,N) 模式，變數選取優先順序的依據。

表 5.2 交通量預測變數灰關聯係數表

較序列						
關聯係數	839	804	8073	8176	8245	8476

5.1.2 平均速度灰關聯分析

以滾動時階 4 之 RGM(1,1) 模式 Day-3 之平均速度原始序列資料作為灰關聯分析之參考數列即 $x_0^{(0)}(t)$ ，比較數列依序為同一偵測器之交通量資料 ($x_1^{(0)}(t)$)，同一偵測器之佔有率資料 ($x_2^{(0)}(t)$)，觀測路段上游前一支偵測器之平均速度資料 ($x_3^{(0)}(t)$)，觀測路段下游後一支偵測器之平均速度資料 ($x_4^{(0)}(t)$)，前一日同一偵測器之平均速度資料 ($x_5^{(0)}(t)$)，前一週同一偵測器之平均速度資料

($x_6^{(0)}(t)$) 等六項。序列長度為 1440 筆，其序列資料如表 5.3 所示。

表 5.3 平均速度預測變數灰關聯序列表

關聯序列	t=1	t=2	t=3	t=...	t=1440
考序列 $x_0^{(0)}(t)$	99.78	103.89	96.89	...	99.67
較序列 1= $x_1^{(0)}(t)$	31	21	27	...	30
較序列 2= $x_2^{(0)}(t)$	4.33	3.00	3.33	...	4.00
較序列 3= $x_3^{(0)}(t)$	01.11	98.78	93.67	...	98.67
較序列 4= $x_4^{(0)}(t)$	01.22	99.44	99.22	...	97.33
較序列 5= $x_5^{(0)}(t)$	99.44	103.78	02.56	...	01.89
較序列 6= $x_6^{(0)}(t)$	57.56	76.56	44.11	...	66.44

以辨識係數 $\zeta=0.5$ ，等權重進行灰關聯分析，得出各比較序列與參考序列之關聯度大小排序依序為序列 5>序列 4>序列 3>序列 6>序列 1>序列 2，即前一日同一偵測器之平均速度資料關連度最高，下游後一支偵測器之平均速度資料次之，各比較序列之灰關聯係數如表 5.4 所示。此關連度分析結果將作為構建 GM(1,N) 模式，變數選取優先順序的依據。

表 5.4 平均速度預測變數灰關聯係數表

較序列						
關聯係數	432	424	420	427	624	874

5.1.3 佔有率灰關聯分析

以滾動時階 4 之 RGM(1,1) 模式 Day-3 之佔有率原始序列資料作為灰關聯分析之參考數列即 $x_0^{(0)}(t)$ ，比較數列依序為同一偵測器之交通量資料($x_1^{(0)}(t)$)，同一偵測器之平均速度資料($x_2^{(0)}(t)$)，觀測路段上游前一支偵測器之佔有率資料($x_3^{(0)}(t)$)，觀測路段下

游後一支偵測器之佔有率資料 ($x_4^{(0)}(t)$)，前一日同一偵測器之佔有率資料 ($x_5^{(0)}(t)$)，前一週同一偵測器之佔有率資料 ($x_6^{(0)}(t)$) 等六項。序列長度為 1440 筆，其序列資料如表 5.5 所示。

表 5.5 佔有率預測變數灰關聯序列表

關聯序列	t=1	t=2	t=3	t=...	t=1440
考序列 = $x_0^{(0)}(t)$	4.33	3.00	3.33	...	4.00
較序列 1 = $x_1^{(0)}(t)$	31	21	27	...	30
較序列 2 = $x_2^{(0)}(t)$	99.78	103.89	96.89	...	99.67
較序列 3 = $x_3^{(0)}(t)$	3.33	2.67	3.00	...	4.33
較序列 4 = $x_4^{(0)}(t)$	3.67	4.67	2.33	...	5.67
較序列 5 = $x_5^{(0)}(t)$	3.00	2.67	3.67	...	3.67
較序列 6 = $x_6^{(0)}(t)$	2.33	3.67	2.00	...	3.00

以辨識係數 $\zeta=0.5$ ，等權重進行灰關聯分析，得出各比較序列與參考序列之關聯度大小排序依序為序列 3>序列 4>序列 5>序列 6>序列 1>序列 2，即上游前一支偵測器之佔有率資料關連度最高，下游後一支偵測器之佔有率資料次之，與交通量與平均速度分析比較，顯示歷史資料與參考序列有較高之關連度，各比較序列之灰關聯係數如表 5.6 所示。此關連度分析結果將作為構建 GM (1,N) 模式，變數選取優先順序的依據。

表 5.6 佔有率預測變數灰關聯係數表

較序列						
關聯係數	137	420	870	803	792	757

5.2 RGM (1,N) 模式

以交通量、平均速度及佔有率資料分別建立具滾動特性之 RGM (1,N) 模式。首先將全部因子帶入建立 RGM (1,6) 模式，計算預測精確度，再依據灰關聯分析之模式中變數之關聯性排序，剔除相關係數最低之因子，依序建立 RGM (1,5)、RGM (1,4) ... RGM (1,1) 等模式，在 RGM (1,N) 模式中找出預測精確度最高之最佳多階灰預測模式。

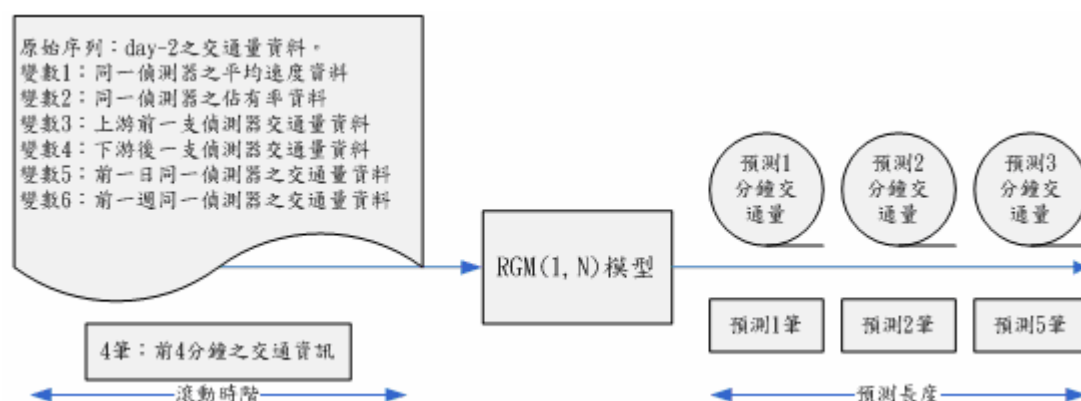


圖 5.1 RGM (1,N) 灰預測系統

5.2.1 交通量預測模式

建立 GM (1,N) 模式首先選定原始序列，原始序列包含下列 7 項：

1. 參考序列：路段觀測之偵測器交通量資料。
2. 比較序列 1：同一偵測器之平均速度資料。
3. 比較序列 2：同一偵測器之佔有率資料。
4. 比較序列 3：上游前一支偵測器交通量資料。
5. 比較序列 4：下游後一支偵測器交通量資料。
6. 比較序列 5：前一日同一偵測器之交通量資料。
7. 比較序列 6：前一週同一偵測器之交通量資料。

將原始序列進行累加生成，進行參數運算，在 RGM (1,6) 模式中得出 rolling1 之參數為：

a	32.5311		
b1	3.8554	b1/a	0.1185
b2	-82.3037	b2/a	-2.53
b3	10.0816	b3/a	0.3099
b4	3.9197	b4/a	0.1204
b5	8.9398	b5/a	0.2748
b6	1.3131	b6/a	0.0403

帶入微分方程式可得：

$$\frac{dx_0^{(1)}}{dt} + aX_0^{(1)} = b_1X_1^{(1)} - b_2X_2^{(1)} - b_3X_3^{(1)} - b_4X_4^{(1)} - b_5X_5^{(1)} - b_6X_6^{(1)} \quad (33)$$

微分方程的函數為：

$$\begin{aligned} \hat{X}_0^{(1)}(t) = & (X_0^{(0)}(1) - \frac{b_1}{a}X_1^{(1)}(t) - \frac{b_2}{a}X_2^{(1)}(t) - \frac{b_3}{a}X_3^{(1)}(t) - \frac{b_4}{a}X_4^{(1)}(t) - \frac{b_5}{a}X_5^{(1)}(t) - \frac{b_6}{a}X_6^{(1)}(t))e^{-at} \\ & + \frac{b_1}{a}X_1^{(1)}(t) + \frac{b_2}{a}X_2^{(1)}(t) + \frac{b_3}{a}X_3^{(1)}(t) + \frac{b_4}{a}X_4^{(1)}(t) + \frac{b_5}{a}X_5^{(1)}(t) + \frac{b_6}{a}X_6^{(1)}(t) \end{aligned} \quad (34)$$

計算預測值

$$\hat{X}_0^{(0)}(t) = \hat{X}_0^{(1)}(t) - \hat{X}_0^{(1)}(t-1) \quad (35)$$

RGM (1,6) 模式序列總計 rolling1436 次，將 1436 筆預測資料以平均百分誤差 (MAPE) 計算精確度，取其平均值得出交通量 RGM (1,6) 模式預測精確度為 94.56%。剔除關聯性最低之比較序列 2 (同一偵測器之佔有率資料)，建立 RGM (1,5) 模式，得出預測精確度，由表 5.7 知，交通量 RGM (1,6) 模式之預測績效屬於高精確度之預測模式，預測準確度高達 94.56%，明顯優於單元預測模式 RGM (1,1) 之預測精確度 89.34% (預測誤差 10.66%)；而在多元預測模式中發現，預測準確度有隨輸入變數減少而遞減的趨勢，至 RGM(1,3) 模式時，預測準確度明顯下滑僅只有 61.27%。

表 5.7 交通量 RGM (1,N) 模式之預測精確度彙整表

RGM(1,N)	預測準確度%
RGM(1,6)	94.56%
RGM(1,5)	74.84%
RGM(1,4)	86.14%
RGM(1,3)	61.27%
RGM(1,2)	62.32%
RGM(1,1)	60.80%

本研究嘗試以資料之原始序列做為參考序列，且僅以灰關聯度最高之序列作為比較序列，建立多元預測模式之 RGM(1,1) 模式，企圖與單元預測模式之 RGM(1,1) 模式進行比較，結果發現多元預測模式之 RGM(1,1) 預測結果相當不理想，預測準確度為 60.80%，而單元之 RGM(1,1) 準確度為 89.34%，其差異如此懸殊之原因為，單元之 RGM(1,1) 模式是以自身資料以滾動方式進行下一時階之交通資訊預測，藉由資料持續更新，模式參數持續修正，以達到準確的預測，而多元預測模式是在探討多個變數對預測結果的影響，即探討外在變數對自身資料之影響程度，若只考慮一項外在因素與資料原始序列進行多元預測，在進行參數求解時，參數值僅只有 b_1/a 一項，會對預測值產生絕對影響，微分方程函數計算累加之預測值時， b_1/a 會對預測值產生絕對影響，造成預測值與原始值差距大。因此，建構多元預測模式應考慮兩種以上

之變數，至於是否具有變數個數越多預測準確度越高之特性，值得後續研究進一步探討。

5.2.2 平均速度預測模式

建立 GM (1,N) 模式首先選定原始序列，原始序列包含下列 7 項：

1. 參考序列：路段觀測之偵測器平均速度資料。
2. 比較序列 1：同一偵測器之交通量資料。
3. 比較序列 2：同一偵測器之佔有率資料。
4. 比較序列 3：上游前一支偵測器平均速度資料。
5. 比較序列 4：下游後一支偵測器平均速度資料。
6. 比較序列 5：前一日同一偵測器之平均速度資料。
7. 比較序列 6：前一週同一偵測器之平均速度資料。

將原始序列進行累加生成，進行參數運算，在 RGM (1,6) 模式中得出 rolling1 之參數為：

a	-0.4838		
b1	-11.8544	b1/a	24.5026
b2	76.5381	b2/a	-158.202
b3	-1.6007	b3/a	3.3085
b4	0.0797	b4/a	-0.1647
b5	0.8635	b5/a	-1.7848
b6	1.3386	b6/a	-2.7668

帶入微分方程式可得：

$$\frac{dx_0^{(1)}}{dt} + aX_0^{(1)} = b_1X_1^{(1)} - b_2X_2^{(1)} - b_3X_3^{(1)} - b_4X_4^{(1)} - b_5X_5^{(1)} - b_6X_6^{(1)}$$

微分方程的函數為：

$$\begin{aligned} \hat{X}_0^{(1)}(t) = & (X_0^{(0)}(1) - \frac{b_1}{a}X_1^{(1)}(t) - \frac{b_2}{a}X_2^{(1)}(t) - \frac{b_3}{a}X_3^{(1)}(t) - \frac{b_4}{a}X_4^{(1)}(t) - \frac{b_5}{a}X_5^{(1)}(t) - \frac{b_6}{a}X_6^{(1)}(t))e^{-at} \\ & + \frac{b_1}{a}X_1^{(1)}(t) + \frac{b_2}{a}X_2^{(1)}(t) + \frac{b_3}{a}X_3^{(1)}(t) + \frac{b_4}{a}X_4^{(1)}(t) + \frac{b_5}{a}X_5^{(1)}(t) + \frac{b_6}{a}X_6^{(1)}(t) \end{aligned}$$

計算預測值

$$\hat{X}_0^{(0)}(t) = \hat{X}_0^{(1)}(t) - \hat{X}_0^{(1)}(t-1)$$

RGM(1,6) 模式序列總計 rolling1436 次，將 1436 筆預測資料以平均百分誤差 (MAPE) 計算精確度，取其平均值得出平均速度 RGM(1,6) 模式預測精確度為 99.95%。剔除關聯性最低之比較序列 2 (同一偵測器之佔有率資料)，建立 RGM(1,5) 模式，得出預測精確度，由表 5.8 知，平均速度 RGM(1,6) 模式之預測績效屬於高精確度之預測模式，預測準確度高達 99.95%，優於單元預測模式 RGM(1,1) 之預測精確度 98.58% (預測誤差 1.42%)；而在多元預測模式中發現，預測準確度有隨輸入變數減少而遞減的趨勢，但差距不大。

表 5.8 平均速度 RGM(1,N) 模式之預測精確度彙整表

RGM(1,N)	確度 %
RGM(1,6)	95%
RGM(1,5)	25%
RGM(1,4)	95%
RGM(1,3)	87%
RGM(1,2)	27%
RGM(1,1)	33%

5.2.3 佔有率預測模式

建立 GM(1,N) 模式首先選定原始序列，原始序列包含下列 7 項：

1. 參考序列：路段觀測之偵測器佔有率資料。
2. 比較序列 1：同一偵測器之交通量資料。
3. 比較序列 2：同一偵測器之平均速度資料。
4. 比較序列 3：上游前一支偵測器佔有率資料。
5. 比較序列 4：下游後一支偵測器佔有率資料。
6. 比較序列 5：前一日同一偵測器之佔有率資料。
7. 比較序列 6：前一週同一偵測器之佔有率資料。

將原始序列進行累加生成，進行參數運算，在 RGM (1,6) 模式中得出 rolling1 之參數為：

a	2985.325		
b1	764.911	b1/a	0.2562
b2	-11.8323	b2/a	-0.0039
b3	264.676	b3/a	0.0886
b4	-1332.94	b4/a	-0.4465
b5	-2503.52	b5/a	-0.8386
b6	508.8029	b6/a	0.1704

帶入微分方程式可得：

$$\frac{dx_0^{(1)}}{dt} + aX_0^{(1)} = b_1X_1^{(1)} - b_2X_2^{(1)} - b_3X_3^{(1)} - b_4X_4^{(1)} - b_5X_5^{(1)} - b_6X_6^{(1)}$$

微分方程的函數為：

$$\begin{aligned} \hat{X}_0^{(1)}(t) = & (X_0^{(0)}(1) - \frac{b_1}{a}X_1^{(1)}(t) - \frac{b_2}{a}X_2^{(1)}(t) - \frac{b_3}{a}X_3^{(1)}(t) - \frac{b_4}{a}X_4^{(1)}(t) - \frac{b_5}{a}X_5^{(1)}(t) - \frac{b_6}{a}X_6^{(1)}(t))e^{-at} \\ & + \frac{b_1}{a}X_1^{(1)}(t) + \frac{b_2}{a}X_2^{(1)}(t) + \frac{b_3}{a}X_3^{(1)}(t) + \frac{b_4}{a}X_4^{(1)}(t) + \frac{b_5}{a}X_5^{(1)}(t) + \frac{b_6}{a}X_6^{(1)}(t) \end{aligned}$$

計算預測值

$$\hat{X}_0^{(0)}(t) = \hat{X}_0^{(1)}(t) - \hat{X}_0^{(1)}(t-1)$$

RGM (1,6) 模式序列總計 rolling1436 次，將 1436 筆預測資料以平均百分誤差 (MAPE) 計算精確度，取其平均值得出佔有率 RGM (1,6) 模式預測精確度為 95.56%。剔除關聯性最低之比較序列 2 (同一偵測器之佔有率資料)，建立 RGM (1,5) 模式，得出預測精確度，由表 5.9 知，佔有率 RGM (1,5) 模式之預測績效屬於高精確度之預測模式，預測準確度高達 98.95%，優於單元預測模式 RGM (1,1) 之預測精確度 95.09% (預測誤差 4.91%)；而在多元預測模式中發現，準確度不具有隨著輸入變數減少而遞減的趨勢，而是呈現不規則的組合，RGM(1,6) 之預測準確度 95.56% 低於 RGM(1,5)，RGM(1,3) 次之為 93.96%，預測準確率最低為 RGM(1,1) 75.11%。

表 5.9 佔有率 RGM (1,N) 模式之預測精確度彙整表

RGM(1,N)	確度 %
RGM(1,6)	56%
RGM(1,5)	95%
RGM(1,4)	18%
RGM(1,3)	96%
RGM(1,2)	79%
RGM(1,1)	11%

5.3 類神經網路模式

為進一步驗證本文所建立 RGM(1,N)模式之績效，本節另利用同樣的交通資訊資料，建立時間序列分析之類神經網路 (ANN) 模式，並將其預測績效與交通量 RGM(1,6)、平均速度 RGM(1,6) 及佔有率 RGM(1,5)模式比較。ANN 模式是運用 NeuroSolutions 軟體進行模式訓練及驗證。以下即針對交通量、平均速度，以及佔有率等三項交通資訊分別進行比較分析。

5.3.1 交通量預測模式

類神經網路架構中，輸入層 (Input Layer) 的作用是接受外界的輸入訊號，然後經由連結鏈將訊號傳到網路內部的隱藏層 (Hidden Layer)。這些隱藏層是類神經網路運作的主要層次，其結構及數目決定了類神經網路的功能及能力。經由隱藏層的運算後，訊號傳至輸出層 (Output Layer) 上，得到類神經網路對外界輸入訊號所產生的反應訊號。本研究欲建立的交通資訊預測模式，其輸入層採用交通量 RGM(1,6)之六個變數，圖 5.2 為交通量類神經網路預測模式架構圖，其中隱藏層、轉換函數以及激發函數必須以試誤法的方式來決定其節點數與函數型態，輸出層為預測觀測路段之交通量。

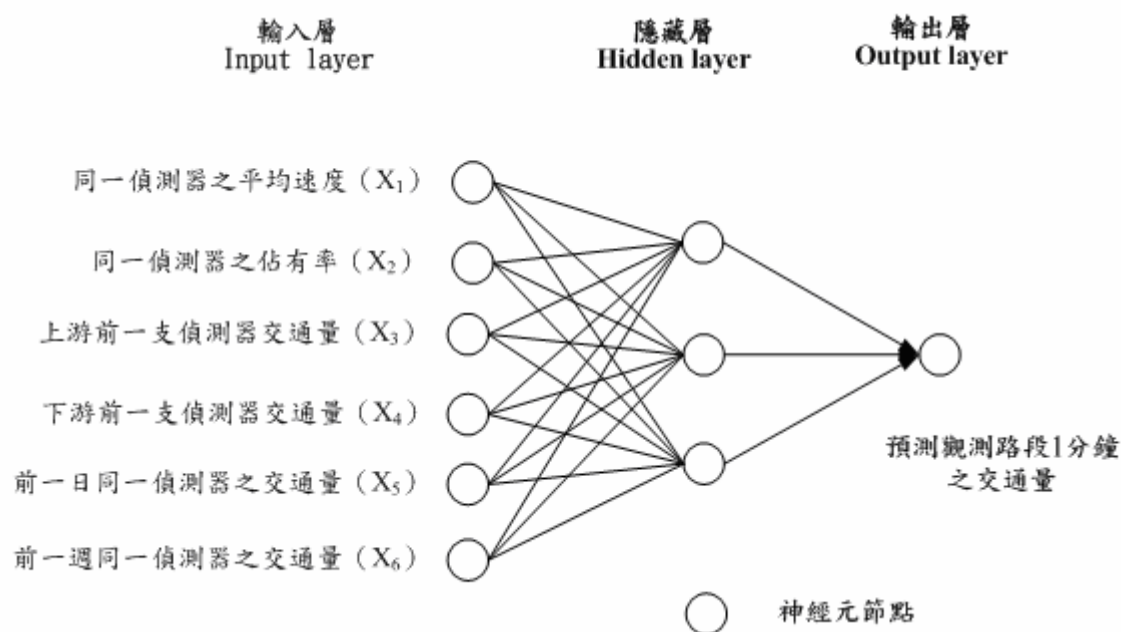


圖 5.2 交通量類神經網路預測模式架構圖

本研究在進行模式之構建與驗證前，先將一天之交通量資料 1440 筆分為模式訓練組與模式驗證組。故在資料中抽取約 70%（即 1000 筆）作為訓練組即將資料之 70% 當成訓練類神經網路模式之資料筆數，藉此建立預測模式。資料之 30% 作為模式驗證組，待預測模式建立後，以 30%（即 440 筆）資料倒入模式中，探討其預測準確度。其中輸入層與隱藏層之轉換函數一般採用正切雙彎曲轉換函數（Sigmoid threshold transfer function），隱藏層與輸出層之間之轉移函數為線性轉換函數（Linear transfer function）。訓練類神經網路之前，首先要進行網路訓練模式的設定，參考過去相關類神經網路研究之文獻資料，本研究之隱藏層設定為一層，隱藏層節點數一般以（輸入變數個數 + 輸出變數個數）除以 2 決定，因此本研究嘗試以 3、4、5、6 個節點數進行探討，其他相關設定值如表 5.10 所示。

表 5.10 交通量類神經網路訓練模式相關參數設定表

網路相關 參數設定	變數輸入 模式設定值
隱藏層數	1層
隱藏層節點數	分別嘗試3、4、5、6個節點數
輸出層節點數	1個
隱藏層轉換函數	正切雙彎曲轉換函數
輸出層轉換函數	線性轉換函數
學習演算法	擬牛頓演算法
設定訓練次數	3000次
設定績效目標	10^{-6}

註：正切雙彎曲轉換函數： $a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$ ，線性轉換函數： $a = n$ ；

n 為各數入變數之值， a 為轉換後之值，通常前推網路之隱藏層內採用正切雙彎曲轉換函數，可允許網路學習到輸入向量與輸出向量間之非線性與線性關係，而線性之輸出層轉換函數，則可以讓網路產生範圍在-1到+1以外的數值。

首先抽取 70%之原始資料進行模式之訓練與學習，並將模式訓練後所得的預測結果與實際結果進行迴歸分析，來了解所訓練資料之實際值與訓練後預測值的相關性為何，另外也分別將模式訓練後所得的預測結果與實際資料進行平均絕對百分誤差（MAPE）之精確度計算。

模式訓練後，透過迴歸分析後我們可以得到預測結果與實際

結果之相關係數是以 4 個隱藏層節點之模式所得 0.897 最大，如表 5-11 所示，且訓練結果之預測精確度是以 4 個隱藏層節點之模式所得 86.75% 最高，由結果看來類神經網路模式的隱藏層節點數為 3 個時，預測精確度 85.22%，在 5 個與 6 個節點時其預測精確度彼此之間差異不大，僅有 0.75% 之差距，就預測績效的觀點來看，4 個隱藏層節點即可達到最佳預測結果，因此在類神經網路模式以 4 個隱藏層節點為最佳訓練模型，如表 5.11 所示。

表 5.11 交通量類神經網路預測模式之訓練結果

隱藏層節點數	相關係數	預測精確度
3個隱藏層節點	0.848	85.22%
4個隱藏層節點	0.897	86.75%
5個隱藏層節點	0.831	84.82%
6個隱藏層節點	0.842	84.07%

進一步將 30% 之原始資料（驗證組資料），輸入訓練完成之類神經網路模式以進行交通量預測，驗證資料於類神經網路模式之預測結果顯示，4 個隱藏層節點模式驗證資料之預測精確度較訓練模式降低了 2.09%，比較其他節點數模式之相關係數與預測精確度，仍以 4 個隱藏層節點之模式表現最佳，其相關係數為 0.847，預測精確度為 84.66%，如表 5.12 所示。

表 5.12 交通量驗證資料於類神經網路預測模式之預測結果表

隱藏層節點數	相關係數	預測精確度
3個隱藏層節點	0.783	82.12%
4個隱藏層節點	0.847	84.66%
5個隱藏層節點	0.802	83.18%
6個隱藏層節點	0.769	82.63%

5.3.2 平均速度預測模式

在平均速度之類神經網路預測模式中，輸出層採用平均速度 RGM(1,6) 之六個變數，其模式架構圖如圖 5-3。同樣在原始資料中抽取約 70%（即 1000 筆）作為訓練組，即將資料之 70% 當成訓練類神經網路模式之資料筆數，藉此建立預測模式，待預測模式建立後，以 30%（即 440 筆）驗證組資料倒入模式中，探討其預測準確度，圖 5.3 為平均速度類神經網路預測模式架構圖

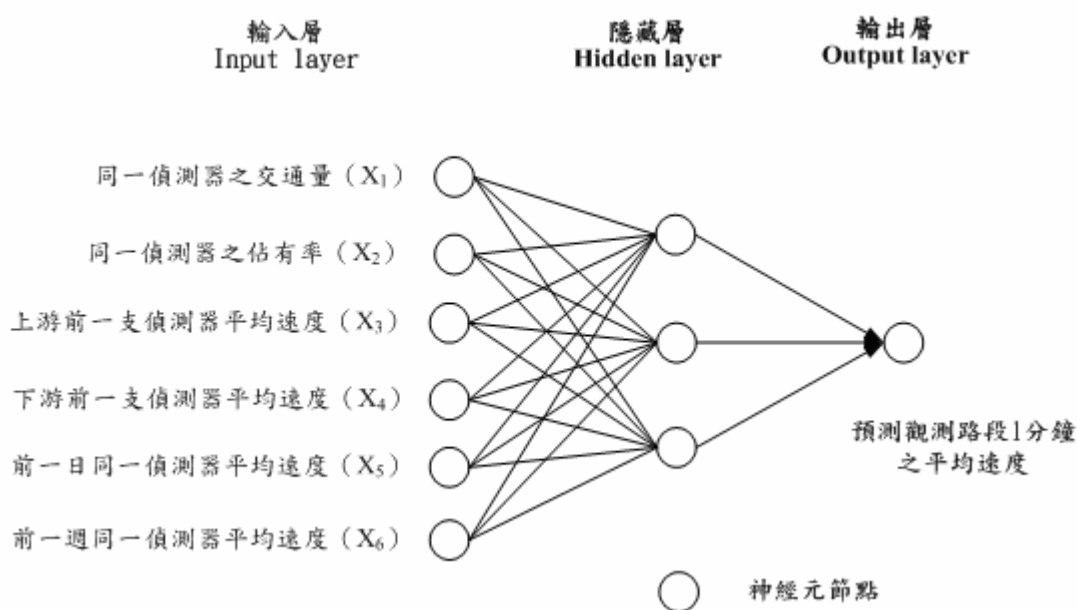


圖 5.3 平均速度類神經網路預測模式架構圖

其中輸入層與隱藏層之轉換函數一般採用正切雙彎曲轉換函數（Sigmoid threshold transfer function），隱藏層與輸出層之間的轉移函數為線性轉換函數（Linear transfer function）。訓練類神經網路之前，首先要進行網路訓練模式的設定，參考過去相關類神經網路研究之文獻資料，本研究之隱藏層設定為一層，隱藏層節點數一般以（輸入變數個數+輸出變數個數）除以 2 決定，因此本研究嘗試以 3、4、5、6 個節點數進行探討，各設定值如表 5.13 所示。

表 5.13 平均速度類神經網路訓練模式相關參數設定表

網路相關 參數設定	變數輸入 模式設定值
隱藏層數	1層
隱藏層節點數	分別嘗試3、4、5、6個節點數
輸出層節點數	1個
隱藏層轉換函數	正切雙彎曲轉換函數
輸出層轉換函數	線性轉換函數
學習演算法	擬牛頓演算法
設定訓練次數	3000次
設定績效目標	10^{-6}

在模式訓練完成後，透過迴歸分析後我們可以得到預測結果與實際結果之相關係數是以 3 個隱藏層節點之模式所得 0.937 最大，如表 5.14 所示，且訓練結果之預測精確度是以 3 個隱藏層節點之模式所得 92.46%最高，由結果看來平均速度類神經網路模式的預測精確度有隨隱藏層節點數增加而遞減的趨勢，隱藏層為 4 個節點時，預測精確度 90.23%，在 5 個節點時，預測精確度 88.17%，為 6 個節點時，預測精確度 87.29%，因此在類神經網路模式以 3 個隱藏層節點為最佳訓練模型，如表 5.14 所示。

表 5.14 平均速度類神經網路預測模式之訓練結果

隱藏層節點數	相關係數	預測精確度
3個隱藏層節點	0.937	92.46%
4個隱藏層節點	0.902	90.23%
5個隱藏層節點	0.886	88.17%
6個隱藏層節點	0.857	87.29%

進一步將 30% 之原始資料（驗證組資料），輸入訓練完成之類神經網路模式以進行平均速度預測，驗證資料於類神經網路模式之預測結果顯示，平均速度預測模式明顯優於交通量預測模式，在平均速度預測模式中，3 個隱藏層節點模式驗證資料之預測精確度較訓練模式僅降低了 0.69%，差距甚小，其相關係數與預測精確度仍以 3 個隱藏層節點之模式表現最佳，其相關係數為 0.908，預測精確度為 91.77%，如表 5.15 所示。

表 5.15 平均速度驗證資料於類神經網路預測模式預測結果表

隱藏層節點數	相關係數	預測精確度
3個隱藏層節點	0.908	91.77%
4個隱藏層節點	0.891	89.67%
5個隱藏層節點	0.875	86.54%
6個隱藏層節點	0.854	85.28%

5.3.3 佔有率預測模式

在佔有率之類神經網路預測模式中，輸出層採用佔有率 RGM(1,5) 之五個變數，其模式架構圖如圖 5.4。同樣在原始資料中抽取約 70%（即 1000 筆）作為訓練組，即將資料之 70% 當成訓練類神經網路模式之資料筆數，藉此建立預測模式，待預測模式建立後，以 30%（即 440 筆）驗證組資料倒入模式中，探討其預測準確度。

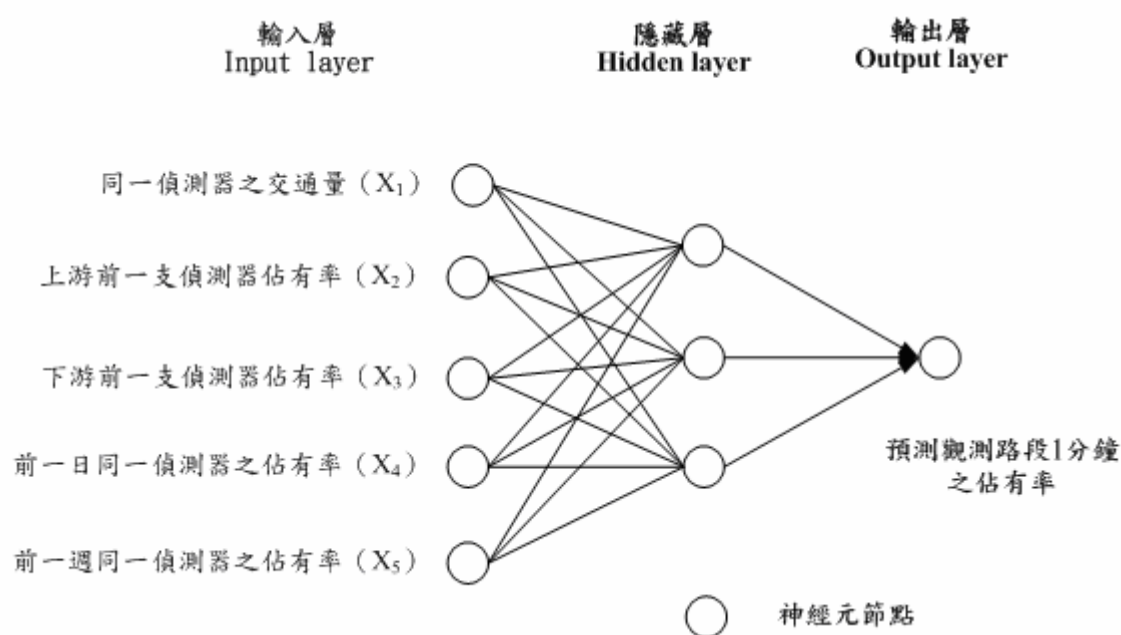


圖 5.4 佔有率預測類神經網路模式架構圖

其中輸入層與隱藏層之轉換函數一般採用正切雙彎曲轉換函數 (Sigmoid threshold transfer function)，隱藏層與輸出層之間之轉移函數為線性轉換函數 (Linear transfer function)。訓練類神經網路之前，首先要進行網路訓練模式的設定，參考過去相關類神經網路研究之文獻資料，本研究之隱藏層設定為一層，隱藏層節點數一般以 (輸入變數個數 + 輸出變數個數) 除以 2 決定，在佔有率模式中輸入變數為 5 個，輸出變數為 1 個，因此本研究嘗試以 3、4、5 個三種節點數進行探討，各設定如表 5.16 所示。

表 5.16 佔有率類神經網路訓練模式相關參數設定表

網路相關 參數設定	變數輸入 模式設定值
隱藏層數	1層
隱藏層節點數	分別嘗試3、4、5個節點數
輸出層節點數	1個
隱藏層轉換函數	正切雙彎曲轉換函數
輸出層轉換函數	線性轉換函數
學習演算法	擬牛頓演算法
設定訓練次數	3000次
設定績效目標	10^{-6}

將資料中抽取 70% 先進行各模式之訓練與學習，並將各模式訓練後所得的預測結果與實際結果進行迴歸分析，來了解所訓練資料之實際值與訓練後預測值的相關性為何，另外也分別將各模式訓練後所得的預測結果與實際資料進行平均絕對百分誤差（MAPE）之精確度計算。

模式訓練後，透過迴歸分析後我們可以得到預測結果與實際結果之相關係數是以 3 個隱藏層節點之模式所得 0.867 最大，如表 5.17 所示，且訓練結果之預測精確度是以 3 個隱藏層節點之模式所得 86.92% 最高，由結果顯示，佔有率模式之預測績效優於交通量預測模式，但低於平均速度預測模式，在佔有率模式中，其預測精確度有隨隱藏層節點數增加而遞減的趨勢，如表 5.17 所示。

表 5.17 佔有率類神經網路預測模式之訓練結果

隱藏層節點數	相關係數	預測精確度
3個隱藏層節點	0.867	86.92%
4個隱藏層節點	0.823	84.64%
5個隱藏層節點	0.746	80.26%

將資料中 30% 作為驗證組資料（沒有以類神經網路訓練與學習的資料），輸入訓練完成之類神經網路模式以進行佔有率預測，驗證資料於類神經網路模式之預測結果顯示，驗證資料之預測精確度較訓練模式降低了 3.65%，其相關係數與預測精確度仍以 3 個隱藏層節點之模式表現最佳，其相關係數為 0.839，預測精確度為 83.27%，如表 5.18 所示。

表 5.18 佔有率驗證資料於類神經網路預測模式預測結果表

隱藏層節點數	相關係數	預測精確度
3個隱藏層節點	0.839	83.27%
4個隱藏層節點	0.803	81.52%
5個隱藏層節點	0.731	78.63%

5.4 小結

依據本文第四章之 RGM (1,1) 模式，其就本身資料序列進行預測結果顯示，其預測精確度具有不錯的水準，且具有單位時間越長、滾動時階越短，預測精確度越高的趨勢。此章節係考慮整體環境中，有許多因素會影響預測序列資料的變化，即以 RGM (1,1) 最佳預測模式-五分鐘單位資料，滾動時階 4 之模式，進一步構建多元預測模式-RGM (1,N) 模式，探討其預測精確度；應用同一偵測器之交通量、速度、佔有率資料，以整合方式同時進行預測，其變數包括三者間之關連變數、上下游偵測器資料、前一日、前一週歷史資料等。GM (1,N) 模式構建初期，先以灰關聯方法分析模式中變數與預測準確度之相關係數，找出影響預測準確值之主因變數，最後以滾動設計構建 RGM (1,N) 模式，

在 RGM (1,N) 模式中找出最佳多階灰預測模式，並以類神經網路作為績效驗證對照模式，研究結果顯示如后。

就多元預測模式 RGM (1,N) 而言，在資料單位一分鐘一筆之預測結果中，交通量以 RGM (1,6) 表現最佳，預測後一筆之準確度為 94.56%，平均速度以 RGM (1,6) 表現最佳，預測後一筆之準確度高達 99.95%，佔有率以 RGM (1,5) 表現最佳，預測後一筆之準確度為 95.56%。與單元預測模式 RGM (1,1) 及類神經網路預測模式之結果比較，不論在交通量、平均速度及佔有率上，RGM (1,N) 之預測準確度皆優於前二者。顯示 RGM (1,N) 在短期交通資訊（交通量、平均速度及佔有率）之預測上具有相當之準確度。將三種預測模式依據交通資訊類別分類，比較各模式中表現最佳模式之預測準確度，如表 5.19 所示。

表 5.19 一分鐘單位資料之最佳模式預測準確度比較表

交通資訊類別	最佳模式預測準確度 (%)					
	單元預測模式 RGM (1,1)		多元預測模式 RGM (1,N)		神經網路預測模式 ANN	
	模式類型	準確度	模式類型	準確度	模式類型	準確度
通量	ling-4	34%	GM (1,6)	56%	de-4	66%
均速度	ling-4	58%	GM (1,6)	95%	de-3	77%
有率	ling-4	09%	GM (1,5)	56%	de-3	27%

第六章 結論建議

本研究主旨是以灰預測方法建立一個國內高速公路之短期交通資訊灰預測模式，主要之研究目的為藉由高速公路主線路段之車輛偵測器資料，以灰預測方法建立動態交通資訊預測模式，可供未來國內實務上應用之參考，本研究之結論建議分述如下。

6.1 結論

1. 蒐集民國 94 年 1 月 1 日起，至民國 94 年 9 月 30 日止，佈設於國道一號高速公路中部路段之車輛偵測器資料，其數據包含交通量、平均速度、以及佔有率，將資料以 EXCEL 軟體予以彙整，彙整之方式交通量為加總資料（加總三個車道之小車、大車及聯結車），速度及佔有率則是平均資料，將每 20 秒一筆之資料分別彙整成 1 分鐘一筆（全日 1440 筆）、5 分鐘一筆（全日 288 筆），作為模式之訓練驗證資料。
2. 挑選連續 5 日之資料作為實驗樣本，以單元預測模式（即一階灰預測模式）進行分析，其中又分為靜態分析 GM(1,1)與動態分析 RGM(1,1)，探討不同預測長度與不同滾動學習時階對於預測精確度之變化。研究結果以資料單位來看，將不同滾動時階（4~8 階）預測後一筆之誤差值取其平均，顯示交通量、平均速度預測模式以五分鐘單位資料預測績效較佳，預測誤差值分別為交通量 7.73%，平均速度 1.09%；佔有率則以一分鐘單位資料預測績效較佳，預測誤差值為 7.92%。就滾動時階而言，RGM(1,1)模型具有滾動時階愈少，預測長度愈短，其預測準確度愈高之趨勢。以表現最佳之 4 個滾動時階模式為例，其預測後 1 筆五分鐘單位資料交通量之誤差值為 5.94%，平均速度為 0.83%，一分鐘單位資料佔有率之誤差值為 6.18%。顯示在 RGM(1,1)在短期交通資訊（交通量、平均速度及佔有率）之預測上具有相當之準確度。
3. 利用不同預測長度（預測一筆~五筆）分析 RGM(1,1)與比較模式 ARIMA 之預測精確度，結果發現若延長預測長度達到後 5 筆時，則五分鐘單位資料交通量之誤差值增為 8.31%，平均速度為 2.49%，一分鐘單位資料佔有率為 9.81%。但與 ARIMA

模式之預測績效比較結果，顯示 RGM(1,1)模型之表現明顯優於 ARIMA 模式，而且具有預測長度愈長，表現差距愈大之趨勢。證明在短期交通資訊之預測上，RGM(1,1)模型優於 ARIMA 模型。

4. 應用一分鐘單位資料，滾動時階 4 之 RGM (1,1) 模式，進一步構建多元預測模式（即多階灰預測模式）GM (1,N) 模式，應用同一樣本資料，以整合方式同時進行預測，蒐集同一偵測器之三項交通資訊、觀測路段之上下游偵測器資料、以及觀測路段偵測器之前一日、前一週歷史資料等，作為模式之訓練驗證資料。
5. GM (1,N) 模式構建初期，先以灰關聯方法分析模式中變數與預測準確度之相關係數，找出影響預測準確值之主因變數並將變數與預測序列關連度進行排序，交通量灰關聯分析其關聯度大小排序依序為序列 4>序列 3>序列 6>序列 5>序列 1>序列 2，即下游後一支偵測器之交通量資料關連度最高，上游前一支偵測器之交通量資料次之，平均速度灰關聯分析之關聯度大小排序依序為序列 5>序列 4>序列 3>序列 6>序列 1>序列 2，即前一日同一偵測器之平均速度資料關連度最高，下游後一支偵測器之平均速度資料次之，佔有率灰關聯分析之關聯度大小排序依序為序列 3>序列 4>序列 5>序列 6>序列 1>序列 2，即上游前一支偵測器之佔有率資料關連度最高，下游後一支偵測器之佔有率資料次之。
6. 以交通量、平均速度及佔有率資料分別建立具滾動特性之 RGM (1,N) 模式，以實驗資料進行訓練驗證，在 RGM (1,N) 模式中找出最佳多階灰預測模式，並同時構建類神經網路預測模式作為績效驗證之對照模式。就多元預測模式 RGM(1,N) 而言，在資料單位一分鐘一筆之預測結果中，交通量以 RGM (1,6) 表現最佳，預測後一筆之準確度為 94.56%，平均速度以 RGM (1,6) 表現最佳，預測後一筆之準確度高達 99.95%，佔有率以 RGM (1,5) 表現最佳，預測後一筆之準確度為 95.56%，而類神經網路預測模式中，交通量 4 個隱藏層節點之模式預測準確度為 84.66%，平均速度 3 個隱藏層節點之模式預測準確度為 91.77%，佔有率 3 個隱藏層節點之模式預測

準確度為 83.27%，顯示 RGM (1,N) 之預測準確度優於類神經網路預測模式。

7. 綜合本研究應用之預測方法，包括 GM (1,1)、RGM (1,1)、RGM (1,N)、ARIMA 模式 ANN 模式等，由於不同之預測方法應用在不同之資料上會產生不同之預測效果，若以預測準確度挑選預測方法，應視其應用之資料來源限制進行選擇，就長期預測而言，簡單序列之預測方法，ARIMA 模式優於靜態 GM (1,1)；就短期交通資訊預測而言，簡單數列預測透過滾動模式可增加預測精確度，簡單數列預測以 RGM (1,1) 表最佳，且因灰預測具有滾動時階越短，預測績效越高之趨勢因此建議以滾動時階 4 模式進行預測；就多元預測模式而言，ANN 模式需要大量資料進行訓練，其預測精確度在 80% 以上，屬於良好的預測模式，而 RGM (1,N) 模式亦可適用於大量資料之預測，惟在資料數據少時，ANN 模式不能使用，可應用 RGM (1,N) 進行多元模式預測，其中以滾動時階 4 之 RGM (1,6) 在交通量、平均速度及佔有率上皆有良好的預測績效。

6.2 建議

對於未來應用灰預測方法進行相關交通資訊預測研究課題，提出以下建議，可供相關單位及後續研究者作為參考。

1. 灰預測模式中，因透過累加生成建立微分方程式，並由樣本數值產生微分方程組求解係數，據以進行預測，若遇著序列中連續長串為零之數列則微分方程運算會產生錯誤，本研究嘗試以偵測器原始資料單位每 20 秒一筆進行交通資訊預測，礙於資料中過多長串為零之資料，無法有效之預測，後續研究可在模式中設定資料為零時之特定參數，發展更完美之預測模式。
2. 在多元預測模式中，本研究嘗試以資料之原始序列做為參考序列，且僅以灰關聯度最高之序列作為比較序列，建立多元預測模式之 RGM(1,1) 模式，企圖與單元預測模式之 RGM(1,1) 模式進行比較，結果發現多元預測模式之 RGM(1,1) 預測結果相當不理想，預測準確度為 60.80%，而單元之 RGM(1,1) 準確度為 89.34%，其差異如此懸殊之原因為，單元之 RGM(1,1) 模式是以自身資料以滾動方式進行下一時階之交通資訊預測，藉由資料持續更新，模式參數持續修正，以達到準確的預測，而多元預測模式是在探討多個變數對預測結果的影響，即探討外在變數對自身資料之影響程度，若只考慮一項外在因素與資料原始序列進行多元預測，在進行參數求解時，參數值僅只有 a 一項，會對預測值產生絕對影響，微分方程函數(34 式)計算累加之預測值時， a 會對預測值產生絕對影響，造成預測值與原始值差距大。因此，建構多元預測模式應考慮兩種以上之變數，至於是否具有變數個數越多預測準確度越高之特性，值得後續研究進一步探討。
3. 本研究蒐集之交通資訊來源是由高速公路局中區交控中心提供，惟偵測器資料因傳輸過程或遭遇大雨雷擊等原因，造成偵測器資料精確度下降，時有缺漏情形，面臨資料缺漏問題，建議後續研究可以針對以偵測器資料精確度加以檢核，並當偵測資料已被判定為錯誤，且無法透過模式加以調校時，為能在極短時間內即尋得替代交通資訊填補缺漏值。

4. 本研究以灰預測方法進行短期交通資訊預測，並與 ARIMA 模式及類神經網路預測模式進行比較，近年來相關對於交通量預測方法仍持續發展中，建議後續研究可以綜合方式探討預測能力，此外，高速公路路網已逐步形成，未來研究亦可拓展其研究範圍，考量路網交互影響下建構預測模式。



參考文獻

(一) 中文部分

- 【1】 江金山、吳佩玲，「灰色理論入門」等編著，民 87 年。
- 【2】 李家儂 (2003)，「都會區大眾運輸導向發展之規劃模式」，國文臺北大學都市計劃研究所碩士論文。
- 【3】 吳嘉斌 (2003)，「植基於灰色理論之物流中心運量預測與途程規劃研究」，實踐大學企業管理研究所碩士學位論文。
- 【4】 吳漢雄、鄧聚龍、溫坤豐，1996，灰色分析入門，台北：高立出版社。
- 【5】 林祥煙 (1998)，「類神經網路於高速公路交通量預測之研究」，中央大學土木工程研究所碩士論文。
- 【6】 林尚儀 (2001)，「混沌車流短期交通量變化之預測-相空間局部近似法(PSLA)之應用」，國立交通大學交通運輸研究所碩士論文。
- 【7】 周義華，「UTCS 交通量預測模式之比較分析」，運輸計畫季刊，Vol.10，No. 2，167-175 頁，民國七十年。
- 【8】 周裕然、鍾秉勳、歐陽橋暉等(2004)，「應用灰建模 GM(1,N) 理論於都市污水處理回收特性預測」，第九屆灰色系統理論與應用研討會論文集。
- 【9】 侯洸廷 (2002)，「灰預測理論於鋪面評估之應用」，國立成功大學土木工程研究所碩士論文。
- 【10】 許巧鶯、溫裕弘 (1997)，「台灣地區國際航空客運量之預測-灰色預測模式之應用」，運輸計畫第 26 卷第 3 期。
- 【11】 陳仕倫 (2000)，「飛安事故之灰預測與灰關聯分析」，淡江大學航空太空工程學系碩士論文。
- 【12】 陳齊邦 (2004)，「高速公路動態旅行時間與旅次起氣推估之研究」，淡江大學運輸管理學系運輸科學碩士班碩士論文。
- 【13】 黃光宇 (2004)，「澎湖箱網養殖系統灰色 GM (1,N) 建模與產量預測」，嶺東技術學院 資管系，2004 年第九屆灰色系統理論與應用研討會。
- 【14】 黃泰林 (民 77)，「電腦化交通號誌控制系統中流量預測模式之比較及其實證研究」，國立成功大學交通管理科學研究

所碩士論文。

- 【15】黃守琮 (2005),「運用偵探車與偵測器資料融合估計車輛旅行時間之研究」,淡江大學運輸管理學系運輸科學碩士班碩士論文。
- 【16】黃仲達 (2003),「灰色理論在農產銷售預測及其銷售關係探討之應用」,國文嘉義大學運輸與物流工程研究所碩士論文。
- 【17】張偉哲、陳朝光,2000,灰色系統理論與發展應用,中華民國資訊學會通訊 31:23-29。
- 【18】張偉哲、溫坤豐、張廷政,2000,灰關聯模型方法與應用,台北:高立出版社。
- 【19】溫修慧 (2004),「以灰色理論評定焚化場環境影響評估各項環境因子影響程度之研究」,朝陽科技大學環境工程與管理系碩士論文。
- 【20】蔡逢哲、柯俊宏 (2004),”以多種 GM 模型應用於產能預測之研究-以台南投資市場為例”,中央大學機械工程研究所,2004 年第九屆灰色系統理論與應用研討會。
- 【21】鄧聚龍,2000,灰色系統理論與應用,台北:高立出版社。
- 【22】鄧聚龍、郭洪,1996,灰預測原理與應用,台北:全華科技圖書,頁 1-40。
- 【23】曹文建 (2003),「灰色系統理論應用於空港型關聯產業成長因素與預測之研究」,逢甲大學土地管理學系碩士論文。
- 【24】魏健宏、林士傑、李穎 (2003),「高速公路客運車輛旅行時間預測之實證評析」,運輸計劃季刊。
- 【25】謝明聰 (2001),「灰色決策於空中交通管理之應用」,淡江大學航空太空工程學系碩士論文。
- 【26】劉素妙 (2002),「航空公司機隊規劃之航機採購/汰換時程之研究」,國立交通大學運輸科技與管理學系碩士論文。
- 【27】藍武王、陳郁文 (民 87),「應用模糊推論於混沌短期交通量預測為例」,模糊系統學刊,第 4 卷,第 1 期,頁 73-80。
- 【28】楊川明 (2004),「發展適用於產業產值之灰預測模式」,南華大學碩士論文。

(二) 英文部分

- 【29】Arem, B.V., Kirby, H.R., Martie J.M. Vlist, V.D. and Whittaker, J.C. (1997) "Recent advances and applications in the field of short-term traffic forecasting", International Journal of Forecasting, Vol.13, pp.1-12.
- 【30】Chen, M. and Chien, S. I. J., "Dynamic Freeway Travel Time Prediction Using Probe Vehicle Data: Link-Based vs. Path-Based," 80th Annual Meeting of Transportation Research Board, 2001.
- 【31】Chen, H. and Grant-Muller, S. (2001) "Use of sequential learning for short-term traffic flow forecasting", Transportation Research Part C, Vol.9, pp319-336.
- 【32】Dougherty, M.S. and Cobbett, M.R. (1997) "Short-term inter-urban traffic forecasts using neural networks", International Journal of Forecasting, Vol.13, pp.21~31.
- 【33】Dougherty, M. and Watson, S. (1996) "Combining Kohonen maps with ARIMA time series model to forecast traffic flow", Transportation Research Part C, Vol.4, pp307-318.
- 【34】Grol, R. V. et al., "On-line Traffic Condition Forecasting Using On-line Measurements and a Historical Database," Proceeding of the 7th Word Congress on Intelligent Transportation Systems, 2001.
- 【35】Hsu, C.I. and Chang, Y.H. (2000) "Application of grey theory and multiobjective programming towards airline network design", European Journal of Operational Research, Vol.127, pp.44-68.
- 【36】Iwasaki, M., "Classification of Historical Mean Speed Patterns on a Motorway for Prediction of Near-Future Traffic Flow States," Proceeding of the 4th Word Congress on Intelligent Transportation Systems, 1997.
- 【37】Jayakrishnan, R., Wei K.T. and Chen, A. (1995) "A dynamic traffic assignment model with traffic-flow relationships", Transportation Research Part C, Vol.3, pp51-72.
- 【38】Jarjees, G. "Methods for Predicting Bus Travel Time Using a Signpost Position Systems," Proceeding of the 4th Word Congress on Intelligent Transportation Systems, 1997.
- 【39】Jiang, G. and Zhang, R., "Travel-Time Prediction for Urban Arterial Road:A Case on China," Proceedings of the IEEE

- International Vehicle Electronics Conference, 2001.
- 【40】 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, pp.43~50.
- 【41】 Lee, Y. I., "Development of a Link Travel Time Prediction Algorithm for Urban Expressway," Proceeding of the 5th World Congress on Intelligent Transportation Systems, 1998.
- 【42】 Maruyama, M., "Travel Time Measurement Using the Automated Vehicle Location System," Proceeding of the 7th World Congress on Intelligent Transportation Systems, 2000.
- 【43】 Matsumura, S., "Experimental Verification of Travel Time Prediction Method," Proceeding of the 5th World Congress on Intelligent Transportation Systems, 1998.
- 【44】 Oda T., "An Algorithm for Prediction of Travel Time Using Vehicle Sensor Data," Proceedings of the IEEE 3th International Conference on Road Traffic Control, London, 1990, pp.40-44.
- 【45】 Ohba Y., Koyama T. and Shimada S., "Online-learning Type of Traveling Time Prediction Model in Expressway," Proceedings of the IEEE International Vehicle Electronics Conference, 1998.
- 【46】 Okutani, I. and Y. J. Stephanedes (1984), "Transportation Research B, Vol.18, No.1, pp.1-11.
- 【47】 Smith, B.L., Billy M.W. and Oswald, R.K. (2002) "Comparison of parametric and nonparametric models for traffic flow forecasting", Transportation Research Part C, Vol.10, pp303-321.
- 【48】 Stathopoulos, A., Karlaftis, M.G. (2003) "A multivariate state space approach for urban traffic flow modeling and prediction", Transportation Research Part C, Vol.11, pp121-135.
- 【49】 Sun, X. and Yang, Z., "Integrated Forecasting Method of Real-time Dynamic Travel Time of Road Segment Based on Discrete Time," Proceedings of the IEEE International Vehicle Electronics Conference, 2001.
- 【50】 Suzuki, H., et al., "Dynamic Estimation of Origin-Destination Travel Time and Flow on a Long Freeway Corridor Neural Kalman Filter," Transportation Research

Record 1739, 2000.

- 【51】 Smith, B.L.and M.J.Demetsky (1997), "Traffic Flow Forecasting: Comparison of Modeling Approaches," Journal of Transportation Engineering, Vol.123, No. 4, pp.261-266.
- 【52】 Vemuri, A.T., Polycarpou, M.M. and Pant, P.D. (1998) "Short-term forecasting of traffic delays in highway construction zones using on-line approximators" Mathematical and Computer Modelling, Vol.27, pp.311-322.
- 【53】 Wang, R.T., Ho, C.T., Feng, C.M., Yan, Y.K. (2004) "A comparative analysis of the operational performance of Taiwan's major airports", Journal of Air Transport Management, Vol.10, pp.353-360.



作者簡歷



姓名：邱妍菁

籍貫：台灣台中市

生日：民國七十年一月六日

學歷：民國 95 年逢甲大學交通工程與管理學系研究所畢業

民國 92 年逢甲大學交通工程與管理學系畢業

民國 88 年嘉義市宏仁女子中學畢業

戶籍地址：台中縣大里市仁愛路 190 巷 31 弄 8 號

聯絡電話：0920080717

