

國立交通大學  
運輸科技與管理學系碩士班

碩士論文

貨運需求預測：  
指數平滑與 ARIMA 相關模式之比較

Freight Transportation Demand Forecasting:  
Comparison of Exponential Smoothing-based and  
ARIMA-based Models

研究生：陳怡文

指導教授：韓復華 教授

中華民國九十九年九月

貨運需求預測：指數平滑與 ARIMA 相關模式之比較

Freight Transportation Demand Forecasting:  
Comparison of Exponential Smoothing-based and ARIMA-based Models

研究生：陳怡文

Student : I-Wen Chen

指導教授：韓復華

Advisors : Anthony Fu-Wha Han

國立交通大學  
運輸科技與管理學系  
碩士論文



Submitted to Department of Transportation Technology and Management

College of Management

National Chiao Tung University

in partial Fulfillment of the Requirements

for the Degree of Master in

Transportation Technology and Management

September 2010

Hsinchu, Taiwan, Republic of China

中華民國 九十九 年 九 月

# 貨運需求預測：指數平滑與 ARIMA 相關模式之比較

學生：陳怡文

指導教授：韓復華 教授

國立交通大學運輸科技與管理學系碩士班

## 摘 要

貨運需求預測(Freight Transportation Demand Forecasting)是第三方物流業者要進行貨物運送前對貨物運送需求所做出的預測模式，再經由預估之運量進行貨物運送車輛派遣、車輛路線規劃、人員安排等的作業流程規劃。根據本研究之個案台灣 H 貨運公司所提供之資料顯示，台灣運輸業者的運輸成本占營收比的 20~25%，運輸成本占總營運成本相當大的比例。因此準確的預測貨運需求量將有助於在車輛與人力方面做出最有效率的安排。

本研究採用三年之每日各站所發貨量資料進行模式之建立與預測。模式以指數平滑模式(Exponential Smoothing Method, ESM)與自我迴歸移動平均整合模式(Autoregressive Integrated Moving Average method, ARIMA)為基礎之四種時間序列預測模式進行貨運量需求量預測，包括：傳統 ESM、抑制趨勢多重日期屬性指數平滑模式(Damped Trend Multi-Calendar exponential smoothing, DTMC)、傳統 ARIMA 模式與多重季節性自我迴歸移動平均整合模式(Multi-Seasonal Autoregressive Integrated Moving Average, MSARIMA)。

最後以五股、新竹、台中、永康與鳳山五個營業站所之資料進行測試，預測結果顯示當資料變異係數在 40% 以上時，ARIMA 模式之預測效果較佳；當資料變異係數在 40% 以下時，MSARIMA 與 DTMC 模式之預測效果較佳，其預測效果與 Lewis (1982) 提出之 MAPE 小於 10% 為預測效果極佳之標準接近。

**關鍵詞：**貨物運送、需求預測、時間序列、指數平滑、ARIMA

# Freight Transportation Demand Forecasting: Comparison of Exponential Smoothing-based and ARIMA-based Models

Student: I-Wen Chen

Advisor: Anthony Fu-Wha Han

Department of Transportation Technology and Management  
National Chiao Tung University

## Abstract

Freight transportation demand forecasting is an important issue for third party companies that influences vehicle dispatching, vehicle route planning and crew scheduling. According to the information of H transportation company, the delivery cost is about 20% to 25% of all operation cost for the forwarder of Taiwan. Therefore, a good demand forecasting can save the delivery and personnel cost.

Conventional models for freight demand forecasting are commonly based on exponential smoothing method (ESM) and Autoregressive Integrated Moving Average method (ARIMA). In addition to ESM and ARIMA, we also considered damped trend multi-calendar exponential smoothing (DTMC) and multi-seasonal autoregressive integrated moving average (MSARIMA).

A three-year data set, 2007/2 to 2010/1, of daily freight demand from five depots, Wugu, Hsinchu, Taichung, Yongkang and Fongshan, were collected from H transportation company for our study. The results showed that the conventional ARIMA provides better forecast. We also found that the MSARIMA and DTMC would perform best when the coefficient of variation of demand is lower than 40%. In particular, the average absolute percentage error (MAPE) of MSARIMA forecast is only 10.64%, which is close to the applicable criterion of 10% MAPE as proposed by Lewis (1982).

**Keywords:** freight transportation  
demand forecasting  
time series  
exponential smoothing  
ARIMA

## 誌 謝

經過了兩年的時間，終於完成了論文，從一開始著手到最後的完成，所有的過程只有自己走才能瞭解。論文能夠順利完成，首先要感謝恩師 韓復華教授兩年來嚴謹的教學態度以及耐心細心的指導，不論是在學業或平常待人接物上的教誨，都使我有更深的體會與警惕，在此致上由衷的感謝，謝謝老師。

口試期間，承蒙系上 任維廉教授與 黃家耀助理教授細心閱讀並不吝指教與斧正，提供許多寶貴意見讓本論文更佳完善。

一開始到新竹念書，對於環境非常的陌生，從一開始在新竹市區迷路到現在對於新竹的環境已經大部分的瞭解。在交大的這兩年能夠順利完成論文有許多人需要感謝，包括了系上的老師、系辦助理、系上所有其他的同學以及 Han Lab 的大家。Lab 的大學長威哥；每天都要問今天吃什麼並且說不給我問問題但最後還是給我問的俊德；很照顧關心我們的陳董；常會提醒我們注意的學勳；常常幫我買便當與飲料又帶我們去吃好吃的東西而且教我很多特別才藝的小朱；幫我解決電腦問題的阿保；看不下去都會來幫我解決問題的忠傑；一直在抓頭髮的鴻祥；站在同一陣線的好夥伴小胖；同為 Lab 沒勢力要自立自強的二人組好姊妹婷尹；謝謝學長姐們常常教我很多東西，不管是在學業上或是在生活上都給予我很多的幫助與叮嚀。另外，一起娛樂一起歡笑的好姊妹雪花，是助理也是學長講話犀利的阿春，還有不是我們 Lab 但是資歷卻比我深還常請我們吃東西的承正，一開始帶我認識交大再度成為學長的丕哥，很感謝助理及學長在我在學校期間的照顧。一起努力有時候一起熬夜不會欺負我的少能，一起做報告的程鴻，謝謝你們一起渡過這學習的兩年。以及在 Lab 為我們處理事務的致傑與禮瑛。還有與我一起上課一起討論論文的運管好同學們，謝謝你們。感謝所有在新竹陪伴我的好朋友們，讓我這兩年有很好的回憶。

除了在新竹的好朋友之外，還有許多的好朋友與我一起分享這兩年的快樂與辛苦，認識十年以上的好朋友們我親愛的國中同學群；高中一年級二年級還有社團的好姊妹們；大學四年一起玩樂與讀書的好同學們；謝謝你們大家常常要接我的電話，聽我說很多的事，因為有你們的陪伴我才可以又重回信心再繼續努力去做我該做的事。另外要特別感謝晏羽，謝謝你陪我一起渡過我碩班的每個時刻，要再一起很開心渡過很多時間喔！

最後要謝謝默默支持我的家人們，我的阿公、阿嬤、爸、媽和妹，謝謝你們讓我只要專心念書不用擔心其他的事情，很愛我們家歡樂的氣氛，還要謝謝我的兩位表哥在新竹的照顧，家人是最好的！

要謝謝的人真的很多，謝謝你們，我愛你們！

陳怡文 謹誌

于 交大網路實驗室 2010.09

# 貨運需求預測：指數平滑與 ARIMA 相關模式之比較

## 目 錄

摘 要.....	i
Abstract.....	ii
誌 謝.....	iii
目 錄.....	iv
圖目錄.....	vi
表目錄.....	viii
第一章 緒論.....	1
1.1 研究動機與目的.....	1
1.2 研究內容與範圍.....	2
1.3 研究方法與流程.....	3
第二章 文獻回顧.....	5
2.1 需求預測相關文獻回顧.....	5
2.1.1 貨運需求預測回顧.....	7
2.1.2 其他方面預測回顧.....	9
2.2 時間序列模式.....	11
2.2.1 指數平滑模式.....	11
2.2.2 抑制趨勢多重日期屬性指數平滑模式.....	14
2.2.3 自我迴歸移動平均整合模式.....	14
2.3 小結.....	20
第三章 應用個案簡介.....	21
3.1 個案背景簡介.....	21
3.2 資料來源.....	22
3.3 資料處理.....	23
第四章 模式構建與實證分析.....	30
4.1 指數平滑相關模式.....	30
4.1.1 指數平滑模式.....	30

4.1.2 抑制趨勢多重日期屬性指數平滑模式.....	36
4.2 ARIMA 相關模式 .....	41
4.2.1 自我迴歸移動平均整合模式.....	41
4.2.2 多重季節性自我迴歸移動平均整合模式.....	47
4.3 結果比較與分析.....	52
第五章 結論與建議.....	54
5.1 結論.....	54
5.2 建議.....	54
參考文獻.....	56





## 圖目錄

圖 1.1 研究流程圖.....	4
圖 3.1 H 貨運公司貨物寄送流程圖.....	21
圖 3.2 五股營業站所 96/02-97/01 資料修補前後比較圖.....	25
圖 3.3 五股營業站所 97/02-98/01 資料修補前後比較圖.....	25
圖 3.4 五股營業站所 98/02-99/01 資料圖.....	25
圖 3.5 新竹營業站所 96/02-97/01 資料修補前後比較圖.....	26
圖 3.6 新竹營業站所 97/02-98/01 資料修補前後比較圖.....	26
圖 3.7 新竹營業站所 98/02-99/01 資料圖.....	26
圖 3.8 台中營業站所 96/02-97/01 資料修補前後比較圖.....	27
圖 3.9 台中營業站所 97/02-98/01 資料修補前後比較圖.....	27
圖 3.10 台中營業站所 98/02-99/01 資料修補前後比較圖.....	27
圖 3.11 永康營業站所 96/02-97/01 資料修補前後比較圖.....	28
圖 3.12 永康營業站所 97/02-98/01 資料修補前後比較圖.....	28
圖 3.13 永康竹營業站所 98/02-99/01 資料圖.....	28
圖 3.14 鳳山營業站所 96/02-97/01 資料修補前後比較圖.....	29
圖 3.15 鳳山營業站所 97/02-98/01 資料修補前後比較圖.....	29
圖 3.16 鳳山營業站所 98/02-99/01 資料圖.....	29
圖 4.1 指數平滑模式流程圖.....	33
圖 4.2 ESM 五股營業站所預測比較圖.....	35
圖 4.3 ESM 新竹營業站所預測比較圖.....	35
圖 4.4 ESM 台中營業站所預測比較圖.....	35
圖 4.5 ESM 永康營業站所預測比較圖.....	36
圖 4.6 ESM 鳳山營業站所預測比較圖.....	36
圖 4.7 新竹農曆年前後貨運量圖.....	37
圖 4.8 DTMC 指數平滑模式之執行流程.....	38
圖 4.9 DTMC 五股營業站所預測比較圖.....	39
圖 4.10 DTMC 新竹營業站所預測比較圖.....	39
圖 4.11 DTMC 台中營業站所預測比較圖.....	40
圖 4.12 DTMC 永康營業站所預測比較圖.....	40
圖 4.13 DTMC 鳳山營業站所預測比較圖.....	40
圖 4.14 ARIMA 執行流程圖.....	41
圖 4.15 新竹營業站所原始序列之 ACF.....	42



圖 4.16 新竹營業站所原始序列之 PACF.....	42
圖 4.17 新竹一次季節性差分後之 ACF.....	43
圖 4.18 新竹一次季節性差分後之 PACF.....	43
圖 4.19 ARIMA 五股營業站所預測比較圖 .....	46
圖 4.20 ARIMA 新竹營業站所預測比較圖 .....	46
圖 4.21 ARIMA 台中營業站所預測比較圖 .....	46
圖 4.22 ARIMA 永康營業站所預測比較圖 .....	47
圖 4.23 ARIMA 鳳山營業站所預測比較圖 .....	47
圖 4.24 MSARIMA 模式之執行流程圖 .....	48
圖 4.25 MSARIMA 五股營業站所預測比較圖 .....	50
圖 4.26 MSARIMA 新竹營業站所預測比較圖 .....	50
圖 4.27 MSARIMA 台中營業站所預測比較圖 .....	51
圖 4.28 MSARIMA 永康營業站所預測比較圖 .....	51
圖 4.29 MSARIMA 鳳山營業站所預測比較圖 .....	51



## 表目錄

表 2.1 貨運需求預測文獻整理.....	8
表 2.2 其他方面預測文獻整理.....	10
表 2.3 判斷 ARIMA 模式之準則 .....	18
表 3.1 五營業站所訓練階段與測試階段之平均數、變異數與變異係數.....	23
表 3.2 H 貨運公司異常值天數統計表(單位：天).....	24
表 3.3 五營業站所訓練階段資料修補前後之平均數、標準差與變異係數.....	24
表 4.1 MAPE 優劣程度 .....	30
表 4.2 以指數平滑模式預測五營業站所之各項參數值與 MAPE .....	31
表 4.3 以回溯指數平滑模式預測五營業站所之各項參數值與 MAPE .....	32
表 4.4 五營業站所多次回溯之參數與 MAPE .....	34
表 4.5 五營業站所回溯之測試階段 MAPE 改善率 .....	34
表 4.6 DTMC 指數平滑模式之參數值與 MAPE.....	39
表 4.7 新竹一次季節性差分後之 ADF 單根檢定.....	44
表 4.8 新竹 ARIMA(1,0,1)(0,1,1) <sub>6</sub> 之參數估計值.....	44
表 4.9 新竹 ARIMA(1,0,1)(0,1,1) <sub>6</sub> 之白噪音檢定.....	44
表 4.10 新竹 ARIMA(1,0,1)(1,1,1) <sub>6</sub> 之參數估計值.....	45
表 4.11 新竹 ARIMA(1,0,1)(1,1,1) <sub>6</sub> 之白噪音檢定.....	45
表 4.12 ARIMA 模式之參數 .....	45
表 4.13 ARIMA 模式之 MAPE .....	45
表 4.14 MSARIMA 模式之參數值 .....	48
表 4.15 MSARIMA 模式之模式與 MAPE .....	49
表 4.16 五營業站所五模式 MAPE 比較(單位：%) .....	52
表 4.17 資料變異係數大於 40% 之營業站所預測效果比較(單位：%) .....	53
表 4.18 資料變異係數小於 40% 之營業站所預測效果比較(單位：%) .....	53

# 第一章 緒論

## 1.1 研究動機與目的

近年來全球商業的競爭趨勢改變，已由企業對企業的競爭轉變為供應鏈(supply chain)對供應鏈的競爭時代。許多的大企業多著重在發揮其核心的優勢領域，因此將其與運輸、倉儲等相關的物流功能外包(outsource)給專業的物流服務提供者(Logistics Service Provider，LSP)。而由於這些 LSP 業者為買賣以外的第三方，因此其所提供的專業物流服務型態被稱為第三方物流(Third Party Logistics，3PL)。

物流中心的作業內容繁瑣，包含路線規劃、車輛頻次、人員調派等，這些車輛設備費用與人員薪資等占物流業者經營成本中一定的比例，所以傳統上物流中心被視為成本中心(Cost Center)。因此若能有效的經營管理物流中心，將內部作業成本降低，則物流中心將可由以成本為導向轉變成為以利潤為導向的利潤中心(Profit Center)。

物流中心配送作業的重點是，如何有效的使用車輛在最經濟的配送路線上將所有的貨物在最短的時間內送達客戶的手中。貨物的運送流程為：寄貨人在集貨時間內將要運送的貨物交于物流業者，物流業者將所有貨物集中至各地的營業所，再經由長途運輸到達目的地營業所，然後各營業所再將貨物轉送至收貨人所在地。貨物的長途運輸時間在深夜凌晨的六、七個小時，貨物需在隔日的配送作業時間前到達目的地營業所，才可在預計時間內將貨物交到收貨人手中。假若貨物的運送是由台北到高雄，則貨物運送的行車時間可能就需五至六個小時，而長途運輸的六、七個小時內還包括了貨物的裝載與卸貨時間，時間可說是相當緊湊，因此若能準確預估貨運量則可提前進行車輛的安排與路線的規劃，縮短整體的運送時間。

貨運需求預測(Freight Transportation Demand Forecasting)則是第三方物流業者本身要進行貨物運送前對貨物運送需求所做出的預測模式，再經由所預估的運量進行貨物運送車輛派遣、車輛路線規劃、人員安排等的作業流程規劃。因此若能準確的預測貨運需求將有助於在車輛與人力方面做出最有效率的安排，避免造成車輛與人力派遣的不足或是過剩的現象。目前台灣的運輸預測研究大多為旅運需求預測，而貨運需求預測的部分則較為少見，因此本研究之目的為準確預測陸運每日貨運量以利車輛安排。

## 1.2 研究內容與範圍

本研究以 H 貨運公司為研究對象，H 貨運公司目前並未針對貨運量進行需求預測，僅在重大節日前貨運量的推估，例如農曆新年、端午、中秋台灣的三大重大節慶前才會進行特別根據歷史經驗推估貨運量。

H 貨運公司所提供之貨運量資料為 H 貨運公司各營業站所間每日之貨物交互件數表，其內容為每日各營業站所的發貨量與到貨量資料，資料時間由民國 96 年 2 月到民國 99 年 3 月。由於資料之完整性問題，本研究以農曆年之日期作為資料分割依據，採用完整三年之資料進行模式之建立與預測，採用資料之時間為民國 96 年 2 月 3 日到民國 99 年 1 月 29 日。

由於營業站所對營業站所間的貨運量較小，不易觀察貨運量特性，在預測時選用某營業站所之每日發貨量做預測，因為總體資料會較各起終點之資料偏差小。因此再進行預測之前，先將起終點資料進行加總轉換成某營業站所之每日發貨量資料。由於 H 貨運公司之營業站所的營業時間為每周一到周六，周日不營業，因此每週之天數為 6 天。

貨運量的變化並非僅受星期的影響，當遇到連續假期時也會有高峰的出現，每日的貨運量預測通常以星期的周期性變化為主要的考量，但若從整年度的資料來看，連續假日前的貨運量高峰的影響亦不小，若可同時考量多種季節性因子則可減少預測誤差，因此本研究將納入多重季節因子模式作為預測模型。

本研究總共採用以指數平滑模式與自我迴歸移動平均整合模式為基礎之五種時間序列預測模式進行貨運量需求預測，其主要研究內容如下：

1. 探討與回顧貨運求相關文獻與各類型之預測方法。
2. 藉由 H 貨運公司之個案資料分析瞭解目前 H 貨運公司各營業站所之每日貨運量的週期及其變化性。
3. 建立以指數平滑為基礎之時間序列預測模式並進行預測。
4. 建立以 ARIMA 模式為基礎之時間序列預測模式並進行預測。
5. 計算並比較以指數平滑為基礎之時間序列預測模式與以 ARIMA 模式為基礎時間序列預測模式之預測誤差。
6. 針對本研究的結果與遭遇問題進行整理，以提供進一步的修改或後續研究之參考。

### 1.3 研究方法與流程

本研究採用時間序列中最常見之兩種預測模型：以指數平滑模式為基礎之指數平滑模式(Exponential Smoothing Method, ESM) 抑制趨勢多重日期屬性指數平滑模式(Damped Trend Multi-Calendar exponential smoothing, DTMC)進行 H 貨運公司之貨運量推估。傳統之指數平滑模式僅能考慮單一周期性之變化，但貨運需求量並非只受單一季節性的影響，例如除星期變化的影響外，也會受到農曆新年或其他假日的影響，整年的貨量並非都在同一水平之下，因此本研究也將可同時考慮多重季節性因子之 DTMC 模式納入研究。而另一也可考慮以自我迴歸移動平均整合為基礎之模式，其中包括自我迴歸移動平均整合模式(Autoregressive Integrated Moving Average method, ARIMA)以及多重季節性自我迴歸移動平均整合模式(Multi-Seasonal Autoregressive Integrated Moving Average method, MSARIMA)。

各種時間序列預測模型各有其優點與其缺點，需視當次預測之目的再決定將使用何種模型作為預測模式，因此本研究將比較各種時間序列預測模型之預測結果。

本研究之流程與步驟，如圖 1.1 所示，並分述如下：

1. 確定研究問題及內容  
透過研究背景瞭解目前物流業之運作情形，發現問題進而引起研究之動機，接著確定研究之內容，建立研究之目的。
2. 相關文獻回顧  
回顧各種貨運相關文獻以及各種預測方法，整理各方法之文獻，再根據研究內容選擇適合之預測模型。
3. 資料蒐集與整理  
瞭解本研究之研究對象 H 貨運公司之背景，蒐集數年 H 貨運公司每日貨運量作為預測之歷史資料。根據 H 公司所提供之每日貨運量歷史資料研究其每日貨運量的週期性變化與日期屬性與節慶特性下所產生的運量變化情形，並且將貨運量資料整理為可預測之形式。
4. 以指數平滑為基礎之時間序列模式建立與預測  
以指數平滑為基礎之時間序列分為二種模式：指數平滑模式(Exponential Smoothing Method, ESM)以及抑制趨勢多重日期屬性指數平滑模式(Damped Trend Multi-Calendar exponential smoothing, DTMC)，建立上述二種模式之模型，利用歷史資料找出最佳之參數組合以及係數做為預測之模型，再利用最適模型進行貨運量預測。
5. 以 ARIMA 為基礎之時間序列模式建立與預測  
以 ARIMA 為基礎之時間序列模式分為兩種：自我迴歸移動平均整合模式

(Autoregressive Integrated Moving Average method, ARIMA)以及多重季節性自我迴歸移動平均整合模式(Multi-Seasonal Autoregressive Integrated Moving Average method, MSARIMA)。建立上述兩種模式之模型，找出最適之參數組合與係數作為預測模型之用，最後再進行預測，以期達到更好之貨運量預測效果。

6. 預測貨運量與結果分析

比較以指數平滑為基礎之時間序列模式與以 ARIMA 為基礎之時間序列模式之預測效果，並分析不同模型所產生不同效果之原因。

7. 結論與建議

根據預測結果對 H 貨運公司提出方便實務使用之預測模式，探討預測模式之發展方向。

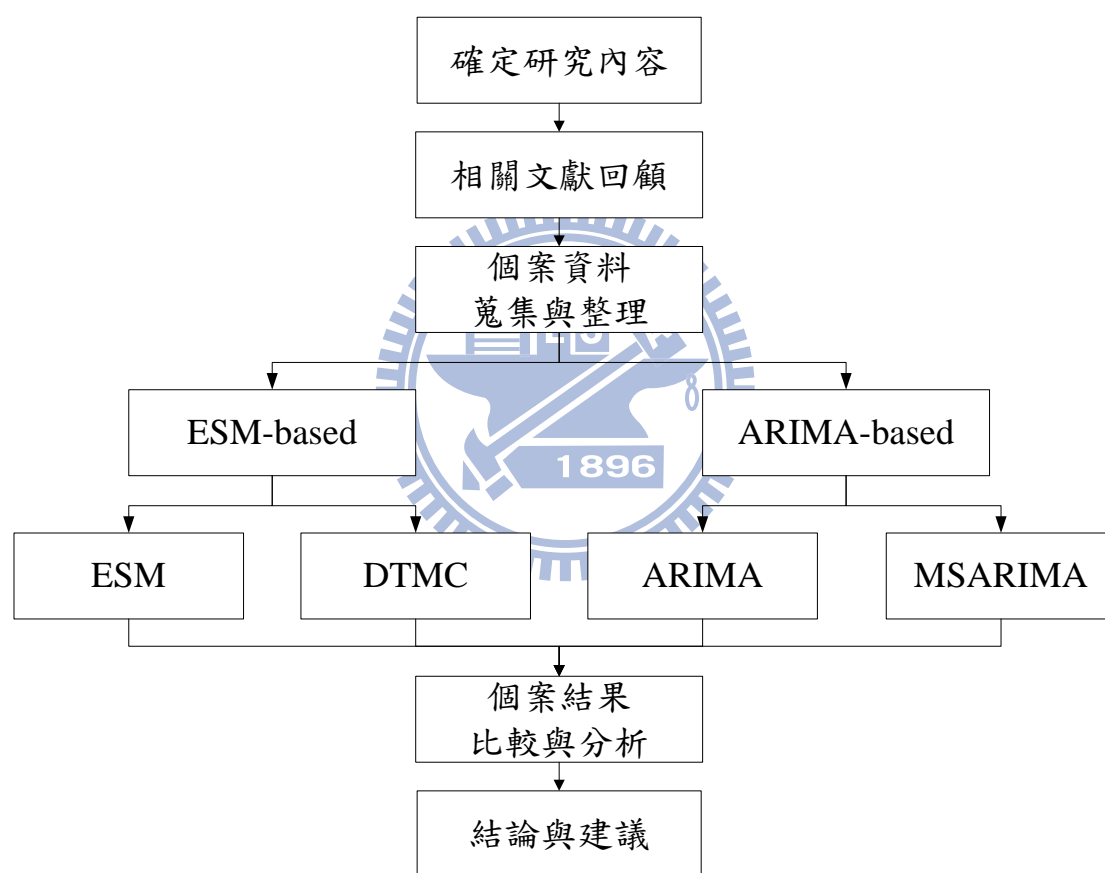


圖 1.1 研究流程圖



## 第二章 文獻回顧

本章將回顧統計相關預測方法、貨運需求預測以及旅運需求預測之相關文獻，最後以小結說明文獻與本研究相關處。

### 2.1 需求預測相關文獻回顧

于宗先[17]於其「經濟預測」一書中對預測的定義為：「預測乃對未被觀察的(或未知的)事象的一種說明。所為位被觀察的(或未知的)事象不僅指未來的事象，也指已發生的事象。如果所涉及的包括這兩種事象，則稱為廣義的預測(Prediction)；如果涉及的僅是未來的事象，即稱為狹義的預測(Forecasting)。」

預測的正確性與預期期間有著密不可分的關係，預測期間的長短因各種企業性質與目的而有所不同，林聰明、吳水丕[24]將預測期間分為三種時期：

1. 短期預測(Short-Term Forecasting)：涵蓋期間通常在三個月以內，較適用於公司中低階層的管理單位，如材料的訂購量等。由於計畫人員需經常修正短期預測的結果以期達到長期預測的要求，故短期預測相當重要。
2. 中期預測(Medium-Term Forecasting)：涵蓋期間通常為三個月到兩年，較適用於公司內部各種資源的分配，如生產與存貨預算等。
3. 長期預測(Long-Term Forecasting)：涵蓋期間通常為兩年以上，最適用於高階層之策略性計畫基礎，如產品的發展等。

預測方法的分類有很多種，根據林聰明、吳水丕[24]將預測方法分為三類：

1. 定性分析法(Qualitative methods)：使用定性資料，如專家意見，及某些記載事象的特殊資料，有時候並不考慮過去。當新產品要引進市場，缺乏可用資料時，最適用定性分析法，通常使用判斷和評等技巧把定性資料轉換成定量的評估，因此在估計過程中如何保持邏輯、不偏差及有系統的分法來對所有的情報加以客觀的判斷最為重要。定性分析法有：德爾菲法(Delphi method)、市場研究法(Market Research)、小組意見法(Panel Consensus)、想像預測法(Visionary Forecast)及歷史類比法(Historical Analogy)等。
2. 時間序列分析法 (Time Series Analysis)：完全著重於過去的型態和型態的改變，且完全依靠歷史資料來預測未來。當產品有幾年的資料可供利用且趨勢穩定時，可利用此種分法加以預測，利用事象本身的歷史關係，時間序列分析法所強調的論點是：未來是過去的延伸。由於未來是現有型態的延伸，所



以此方法的短期預測較長期精準。指數平滑法(Exponential Smoothing)與移動平均法(Moving Average)類似，皆是根據歷史資料去估算預測值，而指數平滑法較近期的資料加權較重，以反應近期的資料型態，指數平滑法所需保留資料較少，且計算容易，為成本相當低的一種預測方式，因此應用相當廣泛。自我迴歸移動平均整合模式(Autoregressive Integrated Moving Average method, ARIMA)為目前時間序列分析法中非常廣泛使用的一種方法，雖然其方法較精確，但其所需花費的時間與成本相對高出許多。

3. 因果分析法(Causal methods)：對於系統元素間相互的關係使用高度精確和詳細的資料，且對特殊元素能加以有效的考慮，且著重於過去的資料。當歷史資料可利用且足於分析以明確說明被預測事象的相關因素和其他因素(如相關企業、經濟力量和社會經濟因素等)時，可使用此類型方法。

除了上述三類預測方法外，還有另外兩種預測方法為近年來較常見的：

1. 類神經網路(Artificial neural network)：類神經網路定義為：「類神經網路是一種計算系統，包括軟體與硬體，它使用大量簡單的相連人工神經元來模仿生物類神經網路的能力。人工神經元是生物神經元的簡單模擬，他從外界環境或者其它人工神經元取得資訊，並加以非常簡單的運算，並輸出其結果到外界環境或者其它人工神經元。」一個類神經網路是由許多人工神經元與其連結所組成，且可組成各種網路模式，其中以倒傳遞網路(Back-Propagation Network, BPN)應用最為普遍，葉怡成[32]。
2. 灰色預測(Grey Prediction)：灰色系統理論(Grey System Theory)為鄧聚龍於1982年所提出，其主要在研究數據少而導致的不確定。其將一切隨機變量視為一定範圍內變化之灰色量及與時間相關之灰過程。對灰色量之處理並非藉由尋找統計規律，而是將原始數據經過處理後，尋找其內在之規律性，再將處理過後之數列轉化為微分方程，建立灰色模型再進行預測。

運輸需求根據運送來源可分為貨運需求(freight transportation demand)與旅運需求(tourism transportation demand)兩種，前者為貨物的運送需求，後者為旅客的運送需求。貨運需求之文獻相較於旅運需求文獻較少，因此除貨運需求外，本研究亦回顧與貨運需求預測息息相關之旅運需求預測文獻，2.1.1 節與 2.1.2 節將分別回顧貨運需求文獻與旅運需求文獻。

### 2.1.1 貨運需求預測回顧

以下將回顧貨運需求之文獻，並將下列文獻整理成表 2.2：

Garrido and Mahnassani [8]利用空間時間多項概率模型預測兩市場的貨運選擇機率，再根據此一機率換算得知可能之貨運需求量。

Godfrey and Powell [9]藉由 Brown 的單一季節指數平滑模式發展出抑制趨勢多重日期屬性指數平滑模式(Damped Trend Multi-Calendar exponential smoothing, DTMC)，其模式可同時考量多種季節因子，另外在加上控制圖(control chart)控制異常的貨運量變化。個案使用 25 個城市之每日發貨量資料，多重季節因子包括星期(day of week)、月份(month of year)、月循環(week of month)以及季末(end of quarter)。將 DTMC 模式之預測結果與自我迴歸移動平均整合模式(AutoRegressive Integrated Moving Average method, ARIMA)作比較，結果最適之 DTMC 模式有 84 %的程式預測誤差優於 ARIMA 模式。

Fite, Talyor and Usher [4]預測載重車輛公司之未來貨運量，以逐步線性迴歸作為預測工具，並使用許多與貨運量相關之經濟變數。其使用不同範圍之資料作預測，預測平均誤差約在 6.86%~24.70% 不等。

Kulshreshtha, Nag and Kulshreshtha [12]利用多元共整合向量自我迴歸模式預測印度鐵路之年貨運量，其使用 35 年之資料進行預測。此研究為長期之預測，且其貨運量受 GDP、價格與噸公里數之影響。

吳嘉斌[26]以物流中心的運量作為資料，資料區分為件數與重量兩種數據，使用灰色預測模式進行預測，再經過季節性調整後，件數與重量的預測誤差分別為 5.89%與 6.16%。

Celik[3]以三種類神經網路模式預測美國之貨運量，並與 Box-Cox 迴歸模式進行比較。其結果發現，三種類神經模式之預測效果皆優於 Box-Cox 迴歸模式，類神經網路中效果最佳模式較 Box-Cox 迴歸模式平均改善 80%。

林佳慧[22]以模糊最小平方方法與區間估計法對中正國際機場與高雄國際機場之進出口與轉口貨運量進行預測，其結果發現模糊最小平方方法做適合用於航空貨運預測。

蘇承正[35]利用灰色理論預測經濟發展後之中國大陸對亞洲各航空站之影響，利用灰色關連度分析影響各航空站客貨運之最大因素，再進行預測，預測誤差落於誤差百分比 28.41%~11.1% 不等。

林東慶[23]以灰色理論與類神經網路預測航空客、貨運之變化，以美國與大

陸機場做比較。灰色理論較無法對劇烈變動作出有效預測，但在穩定的成長趨勢下則可抓住其脈動，因此灰色理論之長期預測效果較好。而類神經網路對於非線性模式有良好的學習能力，只要經過訓練即可準確預測，因此短期來說類神經網路預測效果較佳。

李書賢[27]以灰色預測、ARIMA、線性迴歸趨勢進行個別廠商之出貨預測，再將個別廠商之出貨預測進行加總而成為貨運需求預測，期預測效果則以灰色預測之效果最好。

陳俊男[28]以 ARIMA、X-11 分解法、指數平滑法及倒傳遞神經網路 4 種預測方法最為預測模型，預測台灣三大國際港：基隆港、台中港與高雄港之各項貨運量，各模型之預測結果依各項預測量有所不同，若以進出口貨運量來說則是以倒傳遞神經網路之預測效果最佳。

廖孟媛[33]以桃園機場航空貨運量月資料為時間序列，使用相成季節性自我迴歸移動平均整合模式進行貨運量預測，模型建立之資料比數有 120 筆，預測筆數為 48 筆，共計四年，其預測誤差各年之預測誤差皆在 5% 以下。

表 2.1 貨運需求預測文獻整理

資料型態	年代	作者	方法	比較結果
日	2000	Godfrey and Powell [9]	DTMC、ARIMA	DTMC 優於 ARIMA
年或月	2000	Garrido & Mahnassani [8]	空間時間多項概 率模型	無進行方法比較
	2001	Fite, Taylor and Usher [5]	逐步線性迴歸	平均誤差 6.86%~24.70% 不等
	2001	Kulshreshtha Nag, Kulshrestha [12]	多元共整合向量 自我迴歸模式	無進行方法比較
	2003	吳嘉斌[26]	灰色理論	件數與重量的預測誤差 分別為 5.89%與 6.16%
	2004	Celik [3]	類神經網路、 Box-Cox 迴歸模 式	類神經網路效果較佳
	2005	林佳慧[22]	模糊最小平方 法、區間估計法	模糊最小平方方法較佳
2005	蘇承正[35]	灰色理論	誤差百分比約 28.41%~11.1% 不等	

	2007	林東慶[23]	灰色理論、類神經網路	長期灰色理論較佳；短期類神經網路較佳
	2008	李書賢[27]	灰色理論、ARIMA、線性迴歸趨勢	修正灰色理論預測模式較佳
	2008	陳俊男 [28]	ARIMA、X-11 分解法、指數平滑模式、倒傳遞神經網路	ARIMA、X-11 分解法與倒傳遞神經網路表現較佳
	2009	廖孟媛 [33]	SARIMA	相對誤差在 5% 以下

資料來源：本研究整理

## 2.1.2 其他方面預測回顧

以下將回顧旅運需求之文獻，並將下列文獻整理成表 2.3：

游智元[30]使用自我迴歸移動平均整合模式、指數平滑模式與其根據經驗將兩模式結合產生指數平滑結合自我迴歸移動平均整合模式三種方法對台灣鐵路自強號列車之四列車次進行每日之旅運量預測。除直接利用一般資料進行預測外，另加入 Box-Cox 轉換再分別以上述三種模式進行預測，並比較三種不同資料更新方式所產生的誤差結果。結果顯示當使用指數平滑結合自我迴歸移動平均整合模式並將資料經 Box-Cox 轉換後再以逐月更新資料之預測效果最佳。

蔡宗憲[34]使用台鐵 1008 班次民國 88 年及民國 89 年之每日高雄到北部各區之旅運需求記錄以類神經網路進行運量預測，並比較隨機模式、去季節隨機模式、移動平均模式、指數平滑模式以及綜合模式之預測結果。結果發現總合模式之預測績效優於個別模式；個別模式中類神經模式之預測績效優於其他模式，但與指數平滑模式相近；另外亦發現不適當的變數會導致類神經網路模式之預測績效惡化。

Goh and Law[10]以十種時間序列預測模式預測位於世界各地之十地到香港的旅運量。十種時間序列模式包括兩種 Naïve 模式、兩種移動平均模式、三種指數平滑模式與三種自我迴歸移動平均整合模式。比較模式精確度的指標則有六種。十種模型之平均絕對百分誤差(Mean Absolute Percentage Error, MAPE)在 6%~18%之間，其中表現最好的兩種模式皆屬自我迴歸移動平均整合之變化模式，一為一般常見之相成季節性自我迴歸移動平均整合模式，平均絕對百分誤差為 10.39%；另一模式則為干預分析之季節性自我迴歸移動平均整合模式(SARIMA



model with intervention)，此為多變量自我迴歸移動平均整合模式之延伸，其平均絕對百分誤差為 6.46%。

Cho[4]以指數平滑模式、自我迴歸移動平均整合模式以及類神經網路模式對六個地區至香港旅遊之每月旅運量進行預測，模式精確度指標使用均方根誤差(Root Mean Square Error, RMSE)及平均絕對百分誤差兩種。其結果顯示類神經網路於預測五筆序列資料為三種方法中最好，誤差最小，另一筆資料則為指數平滑法之表現最佳。但若仔細觀察其資料原始圖形趨勢則可發現，類神經網路預測效果最佳乃是因為序列資料中有大趨勢的變化，旅運量因受外在因素而驟減；指數平滑法表現預測效果較佳之歷史資料則呈現穩定變化的狀態，而指數平滑模式又是加重歷史資料作為預測基準，因此此時指數平滑模式所產生之預測效果較他者佳。自我迴歸移動平均整合模式之預測效果皆較只是平滑模式差。因此可推論，當資料變化較大時使用類神經網路模式預測較佳，若資料變化較穩定則使用指數平滑模式預測較佳。

表 2.2 其他方面預測文獻整理

資料型態	年代	作者	方法	比較結果
日	2006	游智元[30]	ESM、ARIMA 與 ESM 及 ARIMA 結合模式	ESM 及 ARIMA 結合模式較佳。
	2006	蔡宗憲、李治綱、魏健宏[34]	隨機模式、去季節化隨機模式、移動平均模式、ESM、類神經網路與綜合 ESM 與類神經模式	類神經網路與 Holt-Winters ESM 相近優於其他模式；綜合 ESM 與類神經模式效果最佳。
月	2002	Goh and Law [10]	Naïve 模式、移動平均模式、ESM 與 ARIMA	ARIMA 模式最佳。
	2003	Cho [4]	ESM、ARIMA、類神經網路	類神經網路最佳。

資料來源：本研究整理

## 2.2 時間序列模式

### 2.2.1 指數平滑模式

指數平滑法(Exponential Smoothing)為時間序列分析的一種，為 Brown 所取。平滑(smoothing)含有平均的意思，過去的時間序列資料存在著某些基本型態且在短期內假設其不會改變，因此可將過去資料加以平均，使不規則變動降到最低做為下一期的預測基礎。數學公式中，不管使用多大的平滑常數 $\alpha$  ( $0 < \alpha < 1$ )，過去資料的加權將呈現如指數(exponential)函數般的曲線，因此命名。由於指數平滑法較為簡單，所需保留資料較少，計算方便，成本相對較便宜，且能夠提供較佳的短期預測精準度，為最便宜且應用廣泛的一種預測方法，因此指數平滑法的發展更為迅速，。

模式中之各項數值說明如下：

$\hat{X}_t$ ： $t$  期之預測值

$\hat{X}_{t-m}(m)$ ： $t+m$  期之預測值

$X_t$ ： $t$  期之實際值

$S_t$ ： $t$  期之平滑基準線估計值(smoothed baseline estimate)

$T_t$ ： $t$  期之平滑趨勢估計值(smoothed trend estimate)

$I_t$ ： $t$  期之平滑季節因子估計值

$\alpha$ ：平滑基準線參數(smoothing parameter for baseline) ( $0 < \alpha < 1$ )

$\gamma$ ：平滑趨勢參數(smoothing parameter for baseline) ( $0 < \gamma < 1$ )

$\delta$ ：平滑季節因子參數(smoothing parameter for seasonal/calendar) ( $0 < \delta < 1$ )

$e_t$ ： $t$  期的誤差， $e_t = \hat{X}_{t-m}(m) - X_t$

$m$ ： $m$  期後之預測

$P$ ：一個季節性循環有  $p$  期

Brown 所設計的簡單指數平滑模式(Single exponential Smoothing model)，此模式是由 Holt 與 Brown 所發展，其公式為：

$$\hat{X}_t = S_t \tag{2.1}$$

$$S_t = \alpha X_t + (1 - \alpha) S_{t-1} \tag{2.2}$$

若將式(2.2)中之  $S_{t-1}$  持續替換為實際值，則可推得式(2.3)：

$$S_t = \sum_{i=0}^{\infty} \alpha(1-\alpha)^i X_{t-i+1} \quad (2.3)$$

由式(2.3)可看出，簡單平滑模式即是過去的歷史值依照時間長短給與不同的權重值進行加權，而距離現在越近之歷史資料權重較重才能有效反應近期之需求型態。在簡單平滑模式中，平滑基準線估計值(smoothed baseline estimate)即為預測值。

當需求水準隨著時間改變呈現上升、平穩或下降時，即產生了趨勢需求型態。Holt[11]與 Winters[19]分別使用兩個獨立的參數於基準線(baseline)與趨勢(trend)，一般稱為 Holt-Winters 線性趨勢指數平滑 Holt-Winters Linear Trend Exponential Smoothing)，其公式為：

$$\hat{X}_t(m) = S_t + mT_t \quad (2.4)$$

$$S_t = S_{t-1} + T_{t-1} + \alpha e_t \quad (2.5)$$

$$T_t = T_{t-1} + \alpha \gamma e_t \quad (2.6)$$

另一種趨勢需求型態為 Brown[2]所發展，此模式同一個參數於於基準線(baseline)與趨勢(trend)，一般稱為 Brown's 線性趨勢指數平滑(Brown's Linear Trend Exponential Smoothing)，其公式為：

$$\hat{X}_t(m) = S_t + mT_t \quad (2.4)$$

$$S_t = S_{t-1} + T_{t-1} + \alpha(2-\alpha)e_t \quad (2.7)$$

$$T_t = T_{t-1} + \alpha^2 e_t \quad (2.8)$$

上述之兩種趨勢型態為藉由參數各數做區分，若依據趨勢的型態則可分為水平(constant level)、線性趨勢(linear trend)、指數趨勢(exponential trend)及抑制趨勢(damped trend)四種：水平趨勢即為簡單平滑模式；線性趨勢則如上述之兩種；指數趨勢之趨勢變化則較明顯；抑制趨勢較平緩，在長期預測顯著較線性趨勢好，Gardner and McKenzie[7]。

除趨勢外，預測之需求項目也受季節(seasonal)因素的影響，在一段時間內需求呈現規律的變化，在趨勢與季節性同時影響下產生兩種季節性型態：相加式季節性(additive seasonality)與相乘式季節性(multiplicative seasonality)，若在加上不受季節性影響之模式，則總共有三種季節型態：非季節性(nonseasonal)、相加式季節性(additive seasonality)與相乘式季節性(multiplicative seasonality)。相加式季節性與相乘式季節性的不同在於相加式季節性的季節因素不因趨勢的增加而加廣，但相乘式季節性的季節因素則會受趨勢的增加而加廣，林聰明、吳水丕[24]。



季節性模型中，Holt-Winters 模式為中指數平滑最常使用的模型，其公式為：

$$\hat{X}_t(m) = (S_t + mT_t)I_{t-p+(m \bmod p)} \quad (2.9)$$

$$S_t = S_{t-1} + T_{t-1} + \alpha e_t / I_{t-p} \quad (2.10)$$

$$T_t = T_{t-1} + \alpha \gamma e_t / I_{t-p} \quad (2.11)$$

$$I_t = I_{t-p} + \delta(1-\alpha)e_t / S_t \quad (2.12)$$

而抑制趨勢的季節性模型若使用 Holt-Winters 模式則會包含四個參數，因此為減化參數，抑制趨勢季節模型則以 Brown 型式為代表，Gardner[6]：

$$\hat{X}_t(m) = (S_t + \sum_{i=1}^{(m)} \phi^i T_t)I_{t-p+(m \bmod p)} \quad (2.9)$$

$$S_t = S_{t-1} + \phi T_{t-1} + \alpha(2-\alpha)e_t / I_{t-p} \quad (2.13)$$

$$T_t = \phi T_{t-1} + \alpha(\alpha - \phi + 1)e_t / I_{t-p} \quad (2.14)$$

$$I_t = I_{t-p} + \delta[1-\alpha(2-\alpha)]e_t / S_t \quad (2.15)$$

指數平滑模式在使用時須先初始化，例如當  $t=1$  時，計算  $t$  期的平滑值須用到  $t=0$  期的平滑基準線估計值，因此須先給定  $S_0$ ，針對初始化的問題 Ledolter and Abraham [13]整理歸納出四種方式：

1. Makridakis and Wheelwright [16]建議使用  $S_0 = X_1$ 。
2. Brown[2]與 Montgomery and Johnson [17]使用所有歷史觀察值之算數平均數作為第 0 期平滑值之初始值。
3. Browerman and O'Connell [1]則較偏好使用前六個觀察值之平均。
4. 回溯(backforecast)：回溯的方法則是先初始化  $S_{t+1}^* = X_t$ ，然後再利用式(2.2)

即可推得  $S_1^*$ ，而  $S_0 = S_1^*$ 。

$$S_t^* = \alpha X_t + (1-\alpha)S_{t+1}^* \quad (2.16)$$

## 2.2.2 抑制趨勢多重日期屬性指數平滑模式

指數平滑模式發展至今已包含最基本的基準線平滑再加入不同趨勢，而後又再加入季節性以配合周期性的變化。不過季節性的變化皆是單一周期性，但實際的情形來看同樣為月底，若當月又為季末則其貨運量又或有所不同，同一天的貨運量可能同時受數種季節性的影響，因此 Godfrey & Powell [9]即發展出 DTMC 指數平滑模式(Damped Trend Multi-Calendar exponential smoothing, DTMC)，根據 Brown 抑制趨勢修改而成的，其特色為可同時考慮多個季節因子，有別於傳統的模式只能考慮單一季節因子，可達到最佳的預測效果。

$$\hat{X}_t(m) = (S_t + \sum_{i=1}^{(m)} \phi^i T_t) \prod_{j \in J} I_t^m(j) \quad (2.17)$$

$$S_t = S_{t-1} + \phi T_{t-1} + \alpha(2 - \alpha)e_t / I_{t-1} \quad (2.18)$$

$$T_t = \phi T_{t-1} + \alpha(\alpha - \phi + 1)e_t / I_{t-1} \quad (2.19)$$

$$\prod_{j \in J} I_t^m(j) = \exp\left(\sum_{j \in J} \alpha_{j,t} \cdot y_j(t+m)\right) \quad (2.20)$$

$$\alpha_{j,t} = \alpha_{j,t-1} + \frac{1}{|\hat{J}|} \cdot \ln \left[ 1 + \delta [1 - \alpha(2 - \alpha)] \left( \frac{e_t}{S_t I_{t-1}^m} \right) \right] \quad \text{for all } j \in \hat{J} \quad (2.21)$$

其中，

$y_j(t)$ ：若日期屬性  $j$  在  $t$  期是存在的，則  $y_j(t) = 1$ ；否則  $y_j(t) = 0$

$\alpha_{j,t}$ ：季節因子係數

$|\hat{J}|$ ：日期屬性的個數

## 2.2.3 自我迴歸移動平均整合模式

自我迴歸移動平均整合模式 (AutoRegressive Integrated Moving Average, ARIMA)於 1970 年由 Box 與 Jenkins 兩位學者所提出，因此也稱為 Box-Jenkins 預測模式，是目前最常被使用的時間序列模型之一。自我迴歸(Autoregressive)與移動平均(Moving Average)兩種方法混合成 ARMA 模式，但序列並非一定為平穩，因此又演變成 ARIMA 模式。

### 1. 自我迴歸(Autoregressive)

$p$  階自我迴歸模型， $p \in \{1, 2, \dots\}$ ，簡稱為 AR( $p$ )，其定義為：

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + a_t \quad (2.22)$$

其中  $X_t$  為  $t$  期的實際值， $\{\varphi_1, \varphi_2, \dots, \varphi_p\}$  為自我迴歸參數， $a_t$  為誤差項，

每個誤差項為成常態分配彼此獨立的隨機變數，平均值為 0，標準差為  $\sigma_a^2$ 。

一般 ARIMA 模式常會以後移運算元， $B$ ，來表示，其定義為  $BX_t = X_{t-1}$ ，

$B^2 X_t = X_{t-2}$ ， $B^k X_t = B^k X_{t-k}$ ， $\forall k \in \{1, 2, \dots\}$ ，因此上式又可表示為：

$$X_t = (\varphi_1 B + \varphi_2 B^2 + \dots + \varphi_p B^p) X_t + a_t \quad (2.23)$$

經過移項後可得：

$$(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) X_t = a_t \quad (2.24)$$

$\varphi_p(B)$  為 AR(p) 之運算元， $\varphi_p(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$ ，因此上式又可

表示為：

$$\varphi_p(B) X_t = a_t \quad (2.25)$$

## 2. 移動平均(Moving Average)

$q$  階移動平均模型， $q \in \{1, 2, \dots\}$ ，簡稱為 MA(q)，其定義為：

$$X_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.26)$$

其中  $\{\theta_1, \theta_2, \dots, \theta_q\}$  為移動平均參數，上式利用後移運算元又可寫成：

$$X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (2.27)$$

$\theta_q(B)$  為 MA(q) 之運算元， $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ ，因此上式又可表

示為：

$$X_t = \theta_q(B) a_t \quad (2.28)$$

## 3. 混合自我迴歸與移動平均過程

(p,q) 階混合自我迴歸移動平均過程， $p, q \in \{1, 2, \dots\}$ ，簡稱為 ARMA(p,q)，其定義為：

$$X_t = \varphi_1 X_{t-1} + \dots + \varphi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.29)$$

上式經過移項後可改寫為：

$$(1 - \phi_1 B - \dots - \phi_p B^p) X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (2.30)$$

又可寫為：

$$\phi_p(B) X_t = \theta_q(B) a_t \quad (2.31)$$

#### 4. 自我迴歸移動平均模式

一般ARIMA模型需在乎穩的條件下才能進行模式的估計與預測。若觀察值在一固定水準或區域間上下跳動則稱此數列為平穩(stationary)，反之則為非平穩(nonstationary)。若資料屬於非平穩的狀態，則使用差分處理，得到一個新的時間序列。

判斷是否需要進行差分首先必須計算自我相關函數(Autocorrelation Function, ACF)與偏自我相關函數(Partial Autocorrelation Function, PACF)。

一組之  $\{\rho_j\}_{j=0}^{\infty}$  被稱為ACF，自我相關係數被定義為

$$\rho_j = \frac{\text{Cov}(X_i, X_{i+j})}{\sqrt{\text{Var}(X_i) \cdot \text{Var}(X_{i+j})}} = \frac{\gamma_j}{\gamma_0} \quad (2.32)$$

一組之  $\{\phi_{kk}\}_{k=1}^{\infty}$  被稱為PACF，偏自我相關係數被定義為

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \vdots & \vdots & \vdots & & 1 & \rho_1 \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}} \quad (2.33)$$

若ACF與PACF呈極緩慢消失則為非平穩，需進行差分直至ACF呈現很快消失為止。差分運算元， $\nabla$ ，被定義為： $\nabla X_t = X_t - X_{t-1} = X_t - B X_t = (1 - B) X_t$ ， $\nabla = 1 - B$ ， $\nabla^2 = (1 - B)^2$ ， $\nabla^d = (1 - B)^d$ ， $\forall d \in \{1, 2, \dots\}$ 。

(p,d,q)階自我迴歸移動平均模式，簡稱ARIMA(p,d,q)，其定義為：

$$\varphi_p(B)\nabla^d X_t = c + \theta_q(B)a_t \quad (2.34)$$

其中d表示d階差分，常數項c表示差分後的平穩序列 $(1-B)^d X_t$ 之平均值。

許多季節性時間序列資料之間的相依性來自連續不同週期中相同期數的數個觀測值或同一週期內相連其數之數個觀測值兩方面，因此形成相乘季節性模型。

相乘季節性自我迴歸移動平均模型，簡稱ARIMA(p,d,q)(P,D,Q)<sub>s</sub>，其定義如下：

$$\varphi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D X_t = \theta_q(B)\Theta_q(B^s)a_t \quad (2.35)$$

其中 $\Phi_p(B^s) = 1 - \varphi_s B^s - \varphi_{2s} B^{2s} - \dots - \varphi_{ps} B^{ps}$ ， $\nabla^D = (1 - B^s)^D$ ， $\forall D \in \{1, 2, \dots\}$ ，

$\Theta_q(B^s) = 1 - \theta_s B^s - \theta_{2s} B^{2s} - \dots - \theta_{qs} B^{qs}$ 。

ARIMA模式之操作流程包括三個步驟：模型鑑定(Identification)、模型估計(Estimation)以及模型偵測(Diagnostic Check)。以下將分別敘述每個步驟之細節：

#### 1. 模型鑑定(Identification)

當有一組時間序列資料時，首先需鑑定序列為何種ARIMA模式，也就是需決定p,d,q,P,D,Q。若要使用統計方法檢定序列是否為平穩則可使用單根檢定 Augmented Dickey-Fuller(ADF)。利用單根檢定檢驗某一時間序列是否需差分p次使達平穩，其三種表示形式如下：

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \quad (2.36)$$

$$X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \quad (2.37)$$

$$X_t = \mu + \delta \cdot t + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \quad (2.38)$$

又可轉換成：

$$X_t = \rho X_{t-1} + \zeta_1 \Delta X_{t-1} + \zeta_2 \Delta X_{t-2} + \dots + \zeta_{t-p+1} \Delta X_{t-p+1} + a_t \quad (2.39)$$

$$X_t = \alpha + \rho X_{t-1} + \zeta_1 \Delta X_{t-1} + \zeta_2 \Delta X_{t-2} + \dots + \zeta_{t-p+1} \Delta X_{t-p+1} + a_t \quad (2.40)$$

$$X_t = \alpha + \delta \cdot t + \rho X_{t-1} + \zeta_1 \Delta X_{t-1} + \zeta_2 \Delta X_{t-2} + \dots + \zeta_{t-p+1} \Delta X_{t-p+1} + a_t \quad (2.41)$$

其中  $\rho = \phi_1 + \phi_2 + \dots + \phi_p$  ,  $\zeta_j = -(\phi_{j+1} + \phi_{j+2} + \dots + \phi_p)$  ,  $j = 1, 2, \dots, p-1$  ,  $a_t$  屬於白噪音。

單根檢定即是在檢定  $X_t$  的所有  $p$  個落後期數的係數和是否為一，也就是虛無假設為  $\rho = 1$ ，若接受虛無假設則表示有單根，為非定態需要進行差分；若拒絕虛無假設表示序列為定態。接著以表 2.4 判斷 ARIMA 之模式。

表 2.3 判斷 ARIMA 模式之準則

項目	準則	SAC 與 PAC 之情形	ARIMA 模式
非季節性	1	SAC 在落後期 1,2,...,q 時呈現凸出 (spikes) 且在 q 落後期截斷(cuts off)；SPAC 呈現漸漸消失(dies down)	$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$
	2	SAC 呈漸漸消失；SPAC 在落後期 1,2,...,q 時呈現凸出且在 p 落後期截斷	$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$
	3	SAC 在落後期 1,2,...,q 時呈現凸出且在 q 落後期截斷；SPAC 在落後期 1,2,...,q 時呈現凸出且在 p 落後期截斷	$\theta_q(B)$ 或 $\phi_p(B)$ 若 SAC 截斷較 SPAC 突然則選 $\theta_q(B)$ ； 若 SPAC 截斷較 SAC 突然則選 $\phi_p(B)$ ； 若兩者截斷程度相同則選擇表現較佳者，通常為 $\theta_q(B)$
	4	SAC 與 SPAC 都呈現極小相關	無非季節性因子
	5	SAC 與 SPAC 都呈漸漸消失	同時為 $\theta_q(B)$ 與 $\phi_p(B)$
季節性	6	SAC 在落後期 $L, 2L, \dots, QL$ 時突出且在落後期 $QL$ 截斷；SPAC 呈漸漸消失	$\theta_Q(B^L) = (1 - \theta_L B^L - \theta_{2L} B^{2L} - \dots - \theta_{QL} B^{QL})$
	7	SAC 呈漸漸消失；SPAC 在落後期	$\phi_P(B^L) = (1 - \phi_P B^P - \phi_{2P} B^{2P} - \dots - \phi_{LP} B^{LP})$

	L,2L,...,PL 時呈現凸出且在 PL 落後期截斷	
8	SAC 在落後期 L,2L,...,QL 時呈現凸出且在 QL 落後期截斷；SPAC 在落後期 L,2L,...,PL 時呈現凸出且在 PL 落後期截斷	$\theta_Q(B^L)$ 或 $\phi_p(B^L)$ 若在季節落後期 SAC 截斷較 SPAC 突然則選 $\theta_Q(B^L)$ ；若在季節落後期 SPAC 截斷較 SAC 突然則選 $\phi_p(B^L)$ ；若兩者截斷程度相同則選擇表現較佳者，通常為 $\theta_Q(B^L)$
9	SAC 與 SPAC 在所有季節落後期都呈現極小相關	無季節性因子
10	SAC 與 SPAC 在所有季節落後期都呈漸漸消失	同時為 $\theta_Q(B^L)$ 與 $\phi_p(B^L)$

參考資料：Bowerman & O'Connell [1]與本研究修改

## 2. 模型估計(Estimation)

暫定 ARIMA 模式後需進行 ARIMA 模式中參數的估計，參數的估計方法有許多種，本研究使用最大概似估計法進行參數估計。

## 3. 模型偵測(Diagnostic Check)

要確認暫定 ARIMA 模式是否適合則需透過白噪音檢定。一個適合的 ARIMA 模式其所產生之殘差項應為獨立的，因此採用 Ljung-Box 的方法進行檢定，肖枝洪、郭明月[21]，其假設如下：

$$H_0: \rho_1 = \rho_2 = \dots = \rho_m = 0, \quad \forall m \geq 1$$

$$H_1: \rho_k \neq 0, \quad \forall m \geq 1, k \leq m$$

其檢定統計量為 LB(Ljung-Box)統計量：

$$LB = N(N+2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{N-k} \sim \chi^2(m), \quad \forall m > 0 \quad (2.42)$$

其中 N 序列的觀測期數，m 為指定的落後期數。


若無法通過白噪音檢定則表示暫定之 ARIMA 模式為不適合之模式，因此需再進行調整，直至通過白噪音檢定為止，此時通過檢定之 ARIMA 模式



為適當之模式，才可用來進行預測。

### 2.3 小結

根據上述文獻可歸納出下列項目：(1)大部分的預測多為年資料預測或月資料預測，其預測目的以長期規劃為主；本研究欲預測之目標為每日貨運量，預測結果為營運決策所需。(2)文獻中為日資料預測之方法以時間序列中的 ESM 與 ARIMA 為主，雖也有使用類神經模式，但蔡宗憲等人(2006)指出，類神經較適合於趨勢有度幅度變動時使用，若長期需是屬較穩定之狀態，則 ESM 之預測效果較佳。(3) Godfrey and Powell (2000)改良傳統 ESM 為可同時考量多重季節性之 DTMC 模式，其結果顯示 DTMC 模式之預測效果優於 ARIMA 模式。(4)因此本研究以時間序列預測方法為預測方法，最常見之模式為 ESM 與 ARIMA，並使用 DTMC 模式與 ESM 結合 ARIMA 模式同時進行預測並比較期預測結果。



### 第三章 應用個案簡介

#### 3.1 個案背景簡介

根據公路法規定，將貨物運輸服務業分為汽車貨運業、汽車路線貨運業與汽車貨櫃業三種，而本研究之個案 H 貨運公司屬汽車路線貨運業，其經營方式為零擔貨運。零擔(Less-than-truckload)為一批貨物在一定數量限制之內非專用一貨車而與他批貨物合裝運送者，林繼國、陳其華[25]，莊賢凱[29]。

H 貨運公司之營業站所遍及全台，每日的貨運件數大約在 20 到 30 萬件之間，最高之每日貨運量件數可高達 40 萬件。貨物配送有時間的限制，需於每日早上七點前達成全部貨件到站及分配區域，少部分偏遠區域之時間限制有些微不同，運送過乘除講求理會效率外，貨件的安全性也是 H 貨運公司的使命之一。H 貨運公司的營業時間為每週一至周六，周日營業站所則不營業，但近期周日也開始營業收貨。

H 貨運公司之貨物寄送流程可分為六個步驟：

1. 集貨：寄貨人與 H 貨運公司聯絡，H 貨運公司向寄貨人收取寄貨件並運送至集貨站營業所。
2. 卸集貨：貨物經運送至集貨站營業所後將貨物卸下。
3. 裝載：處理人員將貨物依預配送地點分別裝載至長途運輸車輛上。
4. 卸到著：貨物經長途運輸到達配達站所營業所後，將貨物卸於配達站。
5. 持出：貨物到達配達站後，再換由送貨車將貨物運送出。
6. 完成配送：當貨物交至收貨人收中即完成配送。

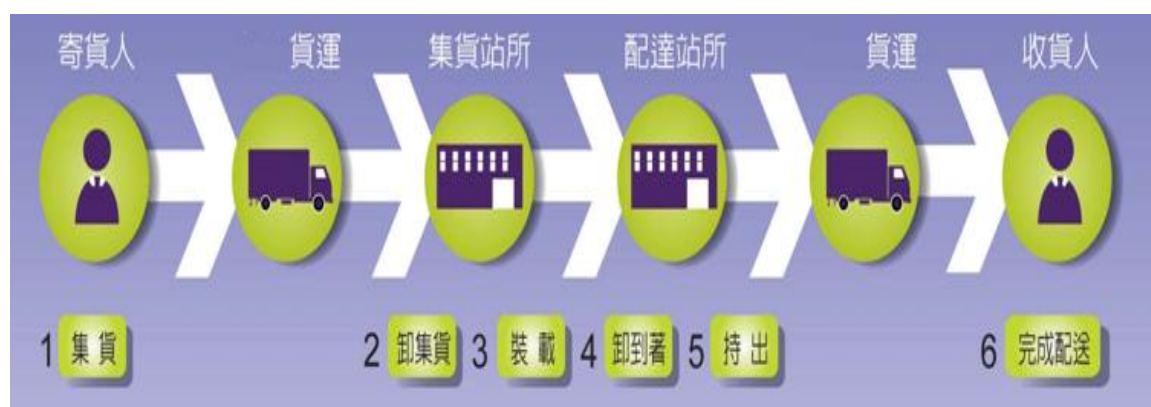


圖 3.1 H 貨運公司貨物寄送流程圖

資料來源：H 貨運公司

貨物在交由集貨站後，需再進行車輛路線的排班才能順利將貨物運送到收件人手中。H 貨運公司之長途運輸全部委託外包車商進行貨物運送，H 貨運公司之運務中心僅進行營業所間的協調與規劃，執行的部分則是由外包車商公司負責安排司機與車輛，其排班步驟如下：

1. 依照貨量或時間決定點到點的班次。
2. 車廂平衡原則。
3. 依路線或時間或站所作業決定行駛順序。
4. 依時間或里程組合成一動力車班次。
5. 交由外包車商安排人車行駛。

根據 H 貨運公司所提供的資料顯示，台灣運輸業者的運輸成本占營收比的 20~25%，運輸成本占總營運成本相當大的比例。車輛排班的第一個步驟為依照貨量決定班次，根據每日之貨量決定所需的車輛數並安排路線，這些安排皆需要時間才能完成，但若能在事前對貨運量進行預測，則可以貨量之預測值預先進行車輛數以及路線的安排，再根據當日之貨量進行些微的調整，如此可減少排班所需的時間。且若事先可以對貨運量進行預測則可以預測之貨量作為依據與外包車商簽約，降低與外包車商承租車輛之成本，相當於運輸成本的降低，也同時表示總營運成本降低。



### 3.2 資料來源

H 貨運公司所提供之各營業站所間每日之貨物交互件數表，其內容為每日各營業站所之發貨量與到貨量資料。由於各營業所對營業所之間的貨量甚小較無法正確掌握貨量之變化情形，因此本研究將各營業站所之貨量進行加總，採用各營業站所之每日發貨量資料進行模型的建立與預測。

H 貨運公司之交互件數表單位為件，只要符合下述限制之貨件即為一件，其在包裝限制如下：

1. 單位體積：需小於 5 才。
2. 單位長度：貨件單邊長不可超過 150 公分。
3. 單邊重量：不可超過 25 公斤。

#### 才積計算說明

1. 才積計算： $(\text{最大長} \times \text{最大寬} \times \text{最大高}) / 27000$ ，其長寬高之單位皆為公分，若無法整除則為條件進位至整數位。
2. 膨鬆貨件依體積換算才數；沉重貨件依重量換算才數(1 才=10 公斤)。

貨運公司所提供的運量資料時間由民國 96 年 2 月到民國 99 年 3 月，總計

38 個月，本研究之預測模式考慮農曆年節的影響，為了保值資料完整性，本研究以農曆年日期作為資料的切割依據，採用之資料由民國 96 年 2 月 3 日到民國 99 年 1 月 29 日，完整農曆三年之資料進行模式之建立與預測。預測模型的建立需再將所得之歷史資料進行分類：訓練階段(training period)與測試階段(testing period)。本研究預測 H 貨運公司五股、新竹、台中、永康與鳳山五個營業站所之每日發貨量，單位為貨運量之件數，訓練階段為民國 96 年 2 月 3 日到民國 98 年 1 月 9 日，共 606 天，測試階段為民國 98 年 1 月 10 日到民國 99 年 1 月 29 日，共 330 天。每週之營業天數為 6 天。H 貨運公司五個營業站所之歷史資料進行各預測模型之建立與預測，五營業站所分別為台灣各地區之營業所貨運量之首，各營業站所之平均數、標準差與變異係數列於表 3.1。

表 3.1 五營業站所訓練階段與測試階段之平均數、變異數與變異係數

項目	訓練階段			測試階段		
	平均數	標準差	變異係數	平均數	標準差	變異係數
五股	23675.51	10376.36	43.83%	18941.53	8656.32	45.70%
新竹	3699.03	1624.30	43.91%	3689.36	1540.84	41.76%
台中	11428.3	4996.83	43.72%	12601.26	4846.56	38.46%
永康	7303.44	2799.86	38.34%	8171.76	3028.26	37.06%
鳳山	5205.62	2094.78	40.24%	5662.44	2246.38	39.67%

由於各站所之平均貨運量有所不同，因此若單從標準差來判斷貨量的分布情形有失合理之處，因此另計算變異係數(coefficient of variation, C.V.)，變異係數為一相對差異之指標，沒有單位，適用於兩群體單位不同或是單位相同但平均數差距較大時使用。

$$C.V. = \frac{\sigma}{\mu} \times 100\% \quad (3.1)$$

由表 3.1 可看出，除五股外其餘四營業站所之貨量平均數在測試階段皆高於訓練階段，表示貨量有成長之情形；由變異細數來看貨量的離散情形則可看出五個站所之變異係數在訓練階段皆高於測試階段。變異最大的站所為五股，最小者為永康。

### 3.3 資料處理

若資料有缺少或異常時需將資料先處理過後才可進行預測，資料異常包括颱風天(A 類)與國定假日 H 貨運公司不營業天(B 類)，部分國定假日 H 貨運公司雖有營業但一般公司行號未營業與補上班日(C 類)，資料也屬異常情形，另外資料

有超過上下兩個標準差則為離群值(outlier) (D 類)，若使用原始資料進行貨運量預測模型的建立則可能會再訓練階段接受錯誤的訊息，且模型會依此錯誤訊息進行測試階段的預測，如此非依照正常情形的預測則會造成很大的誤差，因此在面對上述之情形時需進行資料的缺補與修補。

資料的缺補與修補的部分本研究將貨運量缺失或需修補之日以同一星期之上下兩期正常貨運量值平均處理缺失或需修補日之貨運量。使用同一星期上下兩期正常貨運量之平均值係因貨運量之變化情形仍受星期變化影響最大，因此採同一星期上下兩期正常貨運量之平均則較符合正常之狀況。表 3.2 整理個案異常值處理天數。預測模式之測試階段使用處理過後之資料，但在測試階段計算預測誤差時則使用原始之資料相比，扣除異常值不列入誤差計算，表 3.3 為訓練階段資料處理前後五營業站所貨運量之平均數、標準差與變異係數。

表 3.2 H 貨運公司異常值天數統計表(單位：天)

項目	訓練階段(共 606 天)					測試階段(共 330 天)				
	A	B	C	D	總數	A	B	C	D	總數
五股	5	22	17	0	34	2	8	12	0	22
新竹	5	22	17	0	34	2	8	12	0	22
台中	5	22	17	2	36	2	8	12	0	22
永康	5	22	17	0	34	2	8	12	0	22
鳳山	5	22	17	0	34	2	8	12	0	22

表 3.3 五營業站所訓練階段資料修補前後之平均數、標準差與變異係數

項目	資料修補前			資料修補後		
	平均數	標準差	變異係數	平均數	標準差	變異係數
五股	23675.51	10376.36	43.83%	24912.92	9280.35	37.25%
新竹	3699.03	1624.30	43.91%	3897.80	1450.11	37.20%
台中	11428.3	4996.83	43.72%	12115.14	4387.95	36.22%
永康	7303.44	2799.86	38.34%	7698.54	2366.25	30.74%
鳳山	5205.62	2094.78	40.24%	5498.03	1823.54	33.17%

### 五股(96/02-97/01)




圖 3.2 五股營業站所 96/02-97/01 資料修補前後比較圖

### 五股(97/02-98/01)




圖 3.3 五股營業站所 97/02-98/01 資料修補前後比較圖

### 五股(98/02-99/01)




圖 3.4 五股營業站所 98/02-99/01 資料圖



### 新竹(96/02-97/01)




圖 3.5 新竹營業站所 96/02-97/01 資料修補前後比較圖

### 新竹(97/02-98/01)




圖 3.6 新竹營業站所 97/02-98/01 資料修補前後比較圖

### 新竹(98/02-99/01)




圖 3.7 新竹營業站所 98/02-99/01 資料圖



### 台中(96/02-97/01)




圖 3.8 台中營業站所 96/02-97/01 資料修補前後比較圖

### 台中(97/02-98/01)




圖 3.9 台中營業站所 97/02-98/01 資料修補前後比較圖

### 台中(98/02-99/01)




圖 3.10 台中營業站所 98/02-99/01 資料修補前後比較圖

### 永康(96/02-97/01)

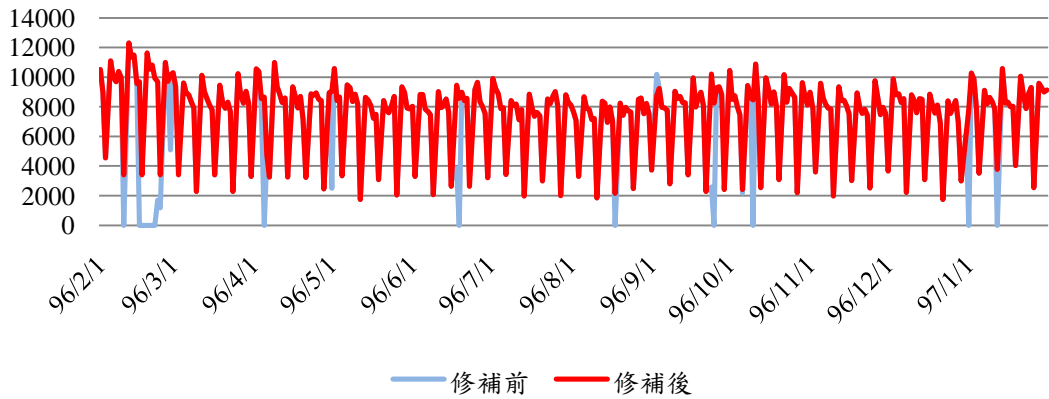


圖 3.11 永康營業站所 96/02-97/01 資料修補前後比較圖

### 永康(97/02-98/01)




圖 3.12 永康營業站所 97/02-98/01 資料修補前後比較圖

### 永康(98/02-99/01)




圖 3.13 永康竹營業站所 98/02-99/01 資料圖

### 鳳山(96/02-97/01)




圖 3.14 鳳山營業站所 96/02-97/01 資料修補前後比較圖

### 鳳山(97/02-98/01)




圖 3.15 鳳山營業站所 97/02-98/01 資料修補前後比較圖

### 鳳山(98/02-99/01)




圖 3.16 鳳山營業站所 98/02-99/01 資料圖

## 第四章 模式構建與實證分析

本節將分別介紹本研究所使用之 ESM 相關模式與 ARIMA 相關模式，分別為傳統 ESM、DTMC 模式、傳統 ARIMA 與 MSARIMA，並將本研究個案運用於各預測模式，最後將各預測結果進行綜合比較分析。

預測誤差為預測模型所得之預測值與實際值之間的差，此可作為評估一預測模型成功與否的量度。常見的預測模型精確度分析方法很多，而本研究採用平均絕對百分誤差(Mean Absolute Percentage Error, MAPE)指標作為檢測預測模型的可信度，當此值越接近 0 時，表示其誤差越小、預測效果越好，Lewis [14]將 MAPE 分為四個等級來判斷模式之優劣程度。其定義如下：

$$MAPE = \frac{\sum \left| \left( X_t - \hat{X}_t \right) / X_t \right|}{n} \times 100 \quad (4.1)$$

其中，

$X_t$  :  $t$  期的實際值

$\hat{X}_t$  :  $t$  期的預測值

$n$  : 總期數

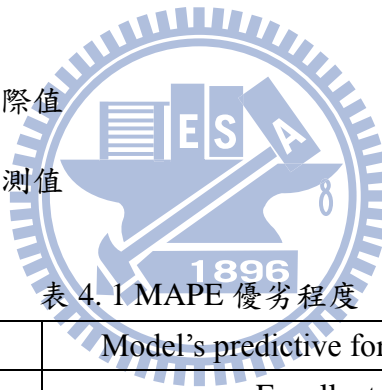


表 4.1 MAPE 優劣程度

MAPE(%)	Model's predictive for the MAPE
<10	Excellent
10-20	Good
20-50	Reasonable
>50	Incorrect

資料來源：Lewis [14]

### 4.1 指數平滑相關模式

#### 4.1.1 指數平滑模式

指數平滑模式(Exponential Smoothing Method, ESM)本研究以 Matlab 軟體 r2009a 版本進行模式撰寫，模式則採用 Brown 之抑制趨勢(Brown's Damped Trend)型式，且由於只使用歷史資料作預測，並不適用較長期的預測，因此採用一期(one-step ahead)後預測， $m=1$ ，Godfrey and Powell [9]。

Brown's 抑制趨勢模型一期後之預測公式：

$$\hat{X}_t = (S_t + \phi T_t) I_{t-p+1} \quad (4.2)$$

$$S_t = S_{t-1} + \phi T_{t-1} + \alpha(2 - \alpha)e_t / I_{t-p} \quad (4.3)$$

$$T_t = \phi T_{t-1} + \alpha(\alpha - \phi + 1)e_t / I_{t-p} \quad (4.4)$$

$$I_t = I_{t-p} + \delta[1 - \alpha(2 - \alpha)]e_t / S_t \quad (4.5)$$

指數平滑模是在使用時須先給定初始值，初始值給定本研究採用 Makridakis and Wheelwright [16]的方法，以  $S_0 = X_1$ 、 $T_0 = 0$  及  $I_0 = I_1 = I_2 = I_3 = I_4 = I_5 = 1$  分別作為第零期之平滑基準線、平滑趨勢及前六期季節因子之初始值，接著利用格子搜尋法(Grid Search) 作為搜尋最佳參數  $\alpha$ 、 $\delta$  與  $\phi$  之方法，依據 Godfrey and Powell[9]的建議，使用  $0.02 < \alpha < 0.2$ 、 $0.03 < \delta < 0.2$  與  $0.0 < \phi < 1.0$ ，而每次跳動的範圍分別為 0.005、0.01 與 0.05，依照所有  $\alpha$ 、 $\delta$  與  $\phi$  的組合分別計算出各組之均方誤差(Mean Square Error, MSE)，也就是殘差的平方和。總共有  $37 \times 18 \times 21 = 13986$  個組合，MSE 最小之  $\alpha$ 、 $\delta$  與  $\phi$  組合即為最佳參數組合，並利用最小參數組合計算第 T 期之平滑基準線、平滑趨勢與季節因子。此階段為訓練階段的預測，由民國 96 年 2 月 1 日預測到民國 98 年 1 月 31 日。接著再利用最佳參數組合做為預測模式之參數進行測試階段的預測時間為由民國 98 年 2 月到民國 99 年 1 月，並計算 MAPE。當在計算測試階段的 MAPE 時，以原始資料進行預測誤差的計算，而不以處理過後之資料計算誤差，但資料異常之部分則忽略，不列入 MAPE 的計算中。H 貨運公司之五營業站所利用指數平滑模型所得之最佳模式各項參數值與誤差列於表 4.2。

表 4.2 以指數平滑模式預測五營業站所之各項參數值與 MAPE

項目	$\alpha$	$\phi$	$\delta$	Training MAPE	Testing MAPE
五股	0.02	0	0.2	18.84%	15.38%
新竹	0.03	0.3	0.2	13.43%	18.38%
台中	0.085	0.15	0.2	20.75%	15.76%
永康	0.035	0.2	0.2	10.4%	8.75%
鳳山	0.045	0.15	0.2	13.21%	14.74%

初始值之給定除利用第一期之值代替外，另有回溯之方式，本研究接著計算初始值採用回溯方式之指數平滑模式之預測誤差。回溯之原理即以後期推回前期。

Brown's 抑制趨勢模型一期後之預測回溯公式如式(4.6)-(4.9)所示。

$$\hat{X}_t = (S_t + \phi T_t) I_{t+p-1} \quad (4.6)$$

$$S_t = S_{t+1} + \phi T_{t+1} + \alpha(2 - \alpha)e_t / I_{t+p} \quad (4.7)$$

$$T_t = \phi T_{t+1} + \alpha(\alpha - \phi + 1)e_t / I_{t+p} \quad (4.8)$$

$$I_t = I_{t+p} + \delta[1 - \alpha(2 - \alpha)]e_t / S_t \quad (4.9)$$

初始值之初次給定同樣先以  $S_0 = X_1$ 、 $T_0 = 0$  及  $I_0 = I_1 = I_2 = I_3 = I_4 = I_5 = 1$  分別作為第零期之平滑基準線、平滑趨勢及前六期季節因子之初始值，接著進行回溯，利用最小參數組合計算得之  $S_T$ 、 $T_T$ 、 $I_{T-5}$ 、 $I_{T-4}$ 、 $I_{T-3}$ 、 $I_{T-2}$ 、 $I_{T-1}$  與  $I_T$  同樣利用格子搜尋法找出最佳參數組合。此過程同樣為訓練階段的預測，但時間則是由民國 98 年 1 月 31 日往回預測到民國 96 年 2 月 1 日。重複上述步驟即為回溯。最後再根據最佳參數組合計算  $S_0$ 、 $T_0$ 、 $I_0$ 、 $I_1$ 、 $I_2$ 、 $I_3$ 、 $I_4$  與  $I_5$  同樣利用格子搜尋法找出最佳參數組合，利用最後所得之最佳參數組合進行測試階段的預測，並計算 MAPE。表 4.2 分別記錄一次回溯與二次回溯之各項參數值與 MAPE，其回溯之指數平滑模式執行如圖 4.1 所示。

表 4.3 以回溯指數平滑模式預測五營業站所之各項參數值與 MAPE

項目	一次回溯				
	$\alpha$	$\phi$	$\delta$	Testing MAPE	Testing MAPE
五股	0.025	0.05	0.14	18.22%	14.61%
新竹	0.04	0.1	0.07	10.62%	17.13%
台中	0.12	0.1	0.08	17.84%	11.23%
永康	0.065	0	0.07	9.13%	7.84%
鳳山	0.065	0.1	0.15	11.83%	13.66%
項目	二次回溯				
	$\alpha$	$\phi$	$\delta$	Testing MAPE	Testing MAPE
五股	0.025	0.05	0.14	18.22%	14.61%
新竹	0.045	0	0.05	10.58%	16.98%
台中	0.12	0.1	0.08	17.83%	11.23%
永康	0.065	0	0.06	9.13%	7.83%
鳳山	0.065	0.1	0.15	11.83%	13.66%

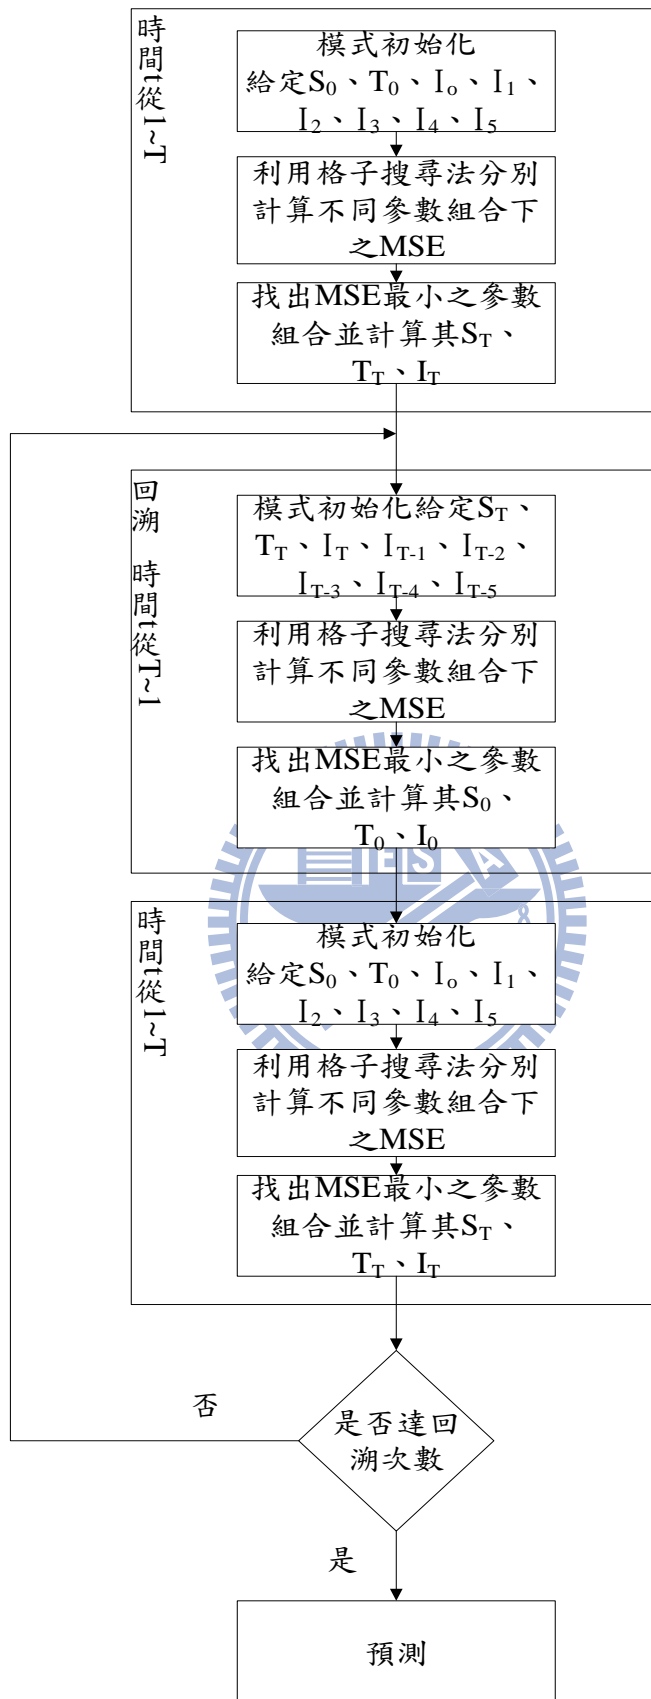


圖 4.1 指數平滑模式流程圖

資料來源：本研究整理



為了比較回溯次數之差異，將零次回溯、一次回溯與二次回溯之各項參數與預測誤差重新整理如表 4.4。

表 4.4 五營業站所多次回溯之參數與 MAPE

項目		五股	新竹	台中	永康	鳳山
零次回溯	$\alpha$	0.03	0.085	0.17	0.08	0.085
	$\phi$	0.15	0.5	0	0.4	0.35
	$\delta$	0.2	0.2	0.18	0.35	0.2
	Training MAPE	20.01%	12.14%	18.69%	10.30%	12.91%
	Testing MAPE	14.73%	21.27%	15.41%	8.75%	16.24%
一次回溯	$\alpha$	0.025	0.045	0.13	0.06	0.07
	$\phi$	0	0	0.05	0.05	0.05
	$\delta$	0.12	0.03	0.03	0.03	0.14
	Training MAPE	18.63%	10.63%	18.19%	9.15%	12.01%
	Testing MAPE	14.71%	15.58%	13.76%	8.08%	13.77%
二次回溯	$\alpha$	0.025	0.04	0.125	0.065	0.07
	$\phi$	0	0.1	0.1	0	0.05
	$\delta$	0.12	0.03	0.03	0.03	0.14
	Training MAPE	18.63%	10.66%	18.21%	9.14%	12.01%
	Testing MAPE	14.71%	15.37%	13.75%	8.06%	13.77%

表 4.5 五營業站所回溯之測試階段 MAPE 改善率

項目	五股	新竹	台中	永康	鳳山	平均
零次回溯	-	-	-	-	-	-
一次回溯	0.02%	5.69%	1.65%	0.67%	2.47%	2.10%
二次回溯	0%	0.21%	0.01%	0.02%	0%	0.05%

由表 4.4 可以看出，傳統之指數平滑模式直接給定初始值所得到之 MAPE 會較有進行回溯所得之 MAPE 來的大。表 4.5 則計算多回溯一次 MAPE 的改善率，指數平滑模式之初始值經過一次回溯後再進行預測所得之 MAPE 皆較沒有經過回溯所得之 MAPE 來的小，其平均改善 2.10%。若進行第二次的回溯，則第二次回溯較第一次回溯的 MAPE 改善效果則不如一次回溯來的好，五營業站所中僅三營業站所有些微的改善，其餘兩站所則沒有改善，平均改善率為 0.05%。

### 五股




圖 4.2 ESM 五股營業站所預測比較圖

### 新竹




圖 4.3 ESM 新竹營業站所預測比較圖

### 台中




圖 4.4 ESM 台中營業站所預測比較圖

## 永康




圖 4.5 ESM 永康營業站所預測比較圖

## 鳳山




圖 4.6 ESM 鳳山營業站所預測比較圖

### 4.1.2 抑制趨勢多重日期屬性指數平滑模式

以 Matlab 軟體 r2009a 版本進行抑制趨勢多重日期屬性指數平滑模式 (Damped Trend Multi-Calendar exponential smoothing, DTMC) 的撰寫，使用回溯搜尋較佳之初始值，採一期後預測。一期後之預測模式如式(4.10)-(4.13)所示。

$$\hat{X}_t(1) = (S_t + T_t) \prod_{j \in J} I_t^1(j) \quad (4.10)$$

$$S_t = S_{t-1} + \phi T_{t-1} + \alpha(2 - \alpha)e_t / I_{t-1} \quad (4.11)$$

$$T_t = \phi T_{t-1} + \alpha(\alpha - \phi + 1)e_t / I_{t-1} \quad (4.12)$$

$$\prod_{j \in J} I_t^1(j) = \exp\left(\sum_{j \in J} \alpha_{j,t} \cdot y_j(t+1)\right) \quad (4.13)$$

本研究採用之多重季節性因素為常見之星期變化(day of week)與台灣農曆年的季節性影響。每年農曆年前，許多公司會在過年前將貨物全數送出或是賀年禮品的寄送而造成農曆年前貨運公司之貨運量突然的暴增，DTMC 模式即為可同時考慮多重季節性之影響且季節性可為非固定周期性變化，非固定周期性變化是指不一定像星期變化為每 6 天一循環。因此為探討農曆年對貨運量的影響，如圖 4.7 所示，將農曆年之季節性因素分為 4 種因子：過年前兩周、過年期間、過年後兩周以及其他平日。在使用 DTMC 模式時，需注意每日之特性洽為每種季節因素之一種因子。本研究考慮兩種季節因素之影響，總共有 10 個季節因子，星期變化的影響包含 6 種因子，分別為星期一到星期六與前述之農曆年 4 種因子。




圖 4.7 新竹農曆年前後貨運量圖

季節性因子之更新只有當期為顯性之因子才會進行更新，否則維持與前期相同。例如當  $t$  期時有  $j$  季節因子之特性， $\alpha_{j,t}$  才會更新更新之公式為式(2.21)，若

否則  $\alpha_{j,t} = \alpha_{j,t-1}$ 。

$$\alpha_{j,t} = \alpha_{j,t-1} + \frac{1}{|\hat{J}|} \cdot \ln \left[ 1 + \delta [1 - \alpha(2 - \alpha)] \left( \frac{e_t}{S_t I_{t-1}^1} \right) \right] \quad \text{for all } j \in \hat{J} \quad (2.21)$$

模式初始化需給定  $S_0 = X_1$ 、 $T_0 = 0$  及  $\alpha_{j,0} = 0$ ， $j$  為季節因子個數。DTMC 指數平滑模式之執行流程與指數平滑模式相似，如圖 4.8 所示。

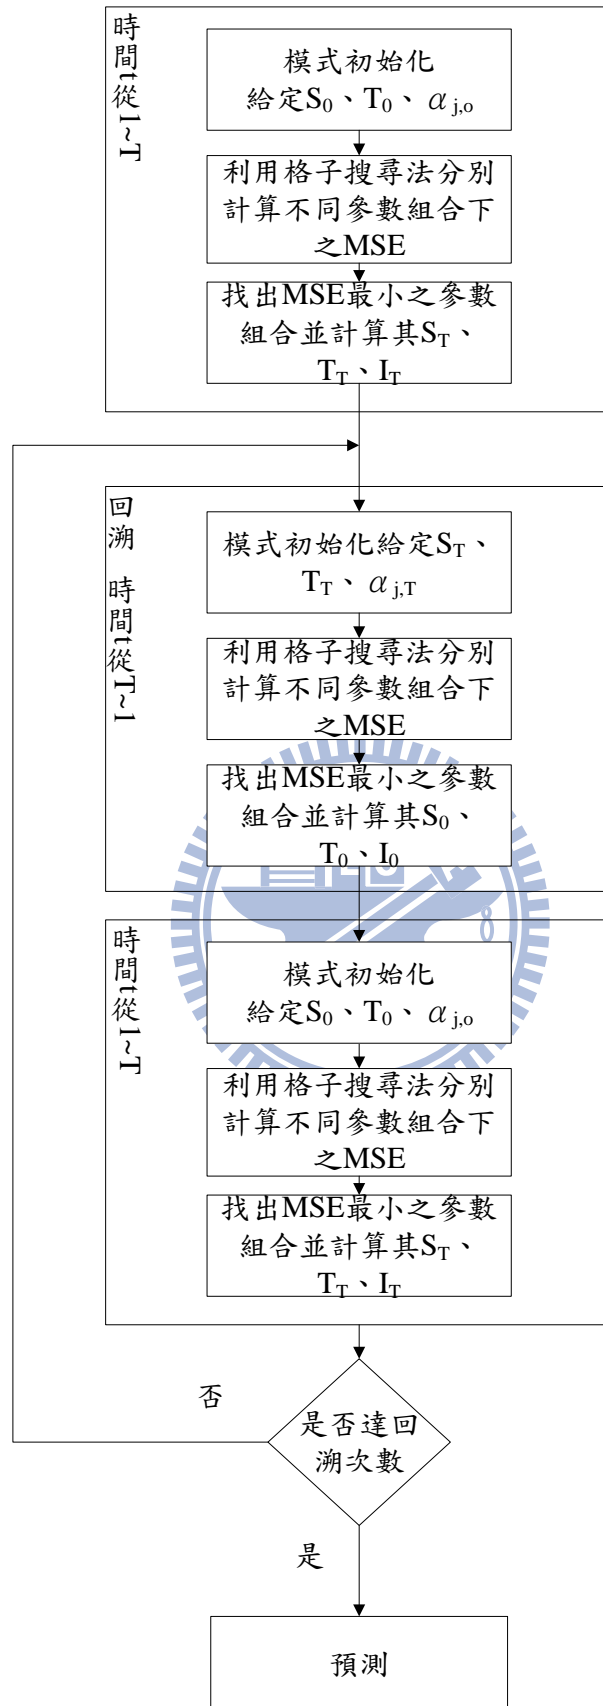


圖 4.8 DTMC 指數平滑模式之執行流程

資料來源：本研究整理

根據執行流程，分別建立 H 貨運公司五股、新竹、台中、永康與鳳山五個營業站所之 DTMC 指數平滑模式，並且分別進行測試階段之貨運量預測。五營業站所之參數與 MAPE 記錄於表 4.6。

表 4.6 DTMC 指數平滑模式之參數值與 MAPE

項目	$\alpha$	$\psi$	$\delta$	Training MAPE	Testing MAPE
五股	0.02	0	0.11	19.41%	20.06%
新竹	0.02	0	0.03	10.47%	14.14%
台中	0.1	0.15	0.03	18.27%	13.30%
永康	0.05	0.05	0.03	9.08%	8.07%
鳳山	0.02	0	0.19	11.81%	12.68%

### 五股




圖 4.9 DTMC 五股營業站所預測比較圖

### 新竹




圖 4.10 DTMC 新竹營業站所預測比較圖



## 台中

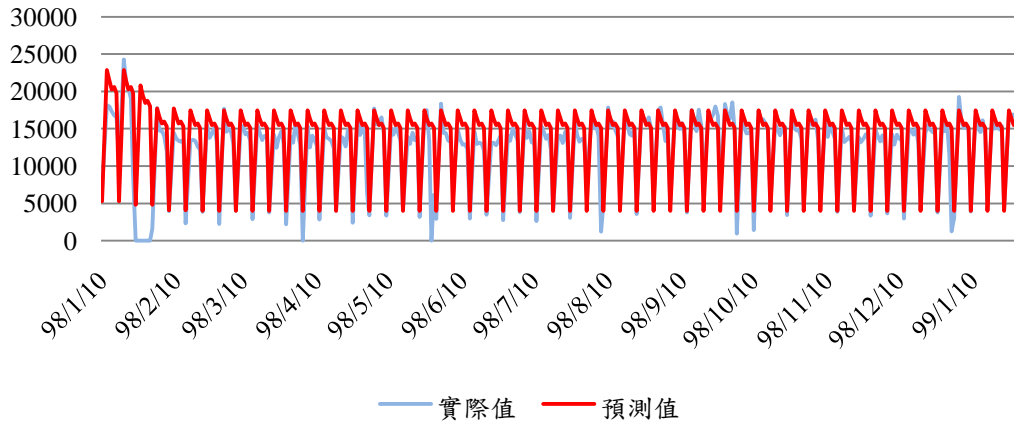


圖 4. 11 DTMC 台中營業站所預測比較圖

## 永康




圖 4. 12 DTMC 永康營業站所預測比較圖

## 鳳山




圖 4. 13 DTMC 鳳山營業站所預測比較圖

## 4.2 ARIMA 相關模式

### 4.2.1 自我迴歸移動平均整合模式

整個自我迴歸移動平均整合模式(AutoRegressive Integrated Moving Average method, ARIMA)的流程大致上分為三個階段，模型鑑定、模型估計與模型偵測，其詳細的步驟已於 2.2.3 節說明過，整個 ARIMA 的執行流程可參考圖 4.3。本研究之 ARIMA 模式以 SAS 軟體 9.2 版本執行。

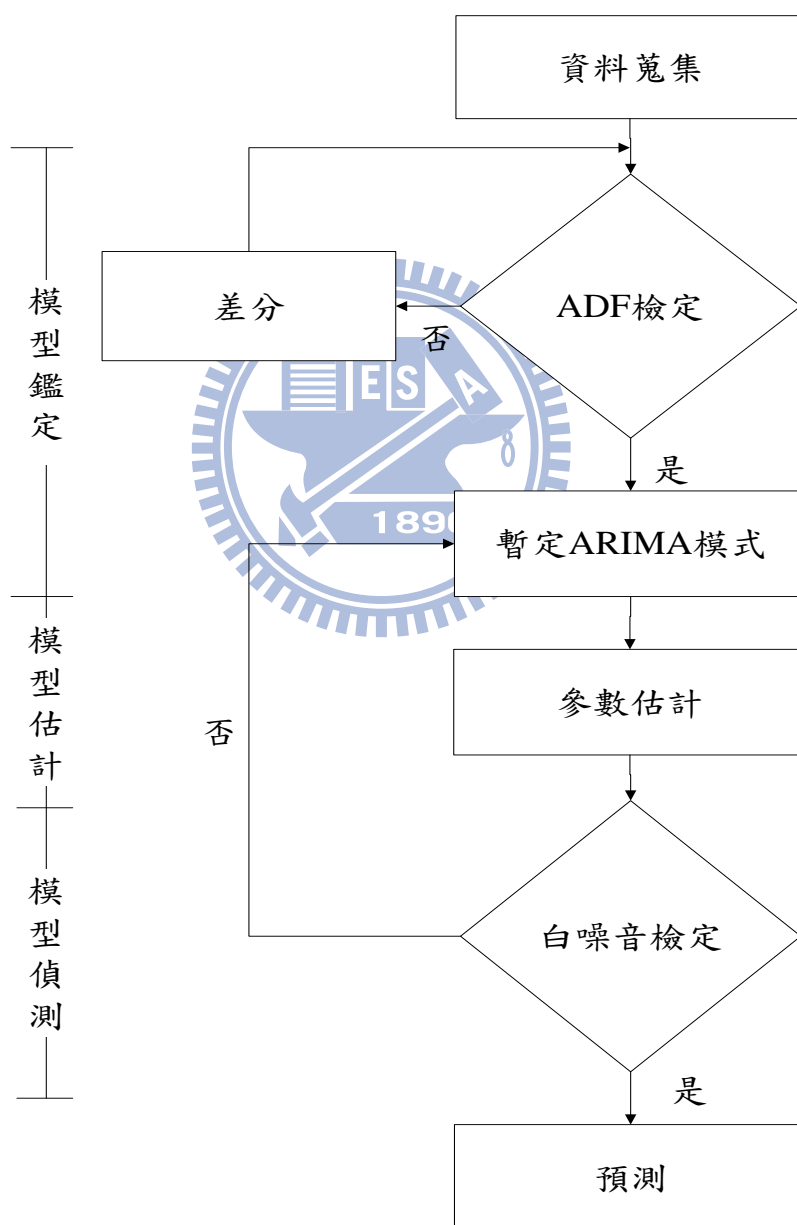


圖 4.14 ARIMA 執行流程圖

參考資料：葉小蓁[31]與本研究整理

本研究以新竹營業站所之序列為例，說明 ARIMA 模式之執行流程。首先判斷序列是否定態需先繪製原始序列之自我相關函數 ACF 與偏自我相關函數 PACF 圖形，此部分所說之原始序列為原始資料經過資料修補之後之序列。非平穩之時間序列之 AC 直不會隨著落後期數的增加而快速消失。觀察新竹原始序列之 ACF 圖，ACF 值並為隨著落後期數的增加而快速消失，因此判斷新竹原始序列為非平穩序列，需進行差分使序列達平穩後才可進行模式建立。新竹序列 6 期為一個週期，而 ACF 中 AC 值凸出之落後期數為 6、12、18 與 24，需進行季節性差分， $D=1$ 。




圖 4.15 新竹營業站所原始序列之 ACF




圖 4.16 新竹營業站所原始序列之 PACF

經過一次季節性差分過後，需重新繪製 ACF 與 PACF 之圖形，再重新判斷經過一次季節性差分過後之序列是否為平穩之序列。新竹序列經過一次季節性差分過後之 ACF 與 PACF 圖形如圖 4.6 與圖 4.7 所示。由圖 4.6 可以看出，經過一次季節性差分後，新竹序列之 AC 值呈快速消失，因此判斷此經過差分後之序列為平穩序列。並且也由單根檢定 Augmented Dickey-Fuller(ADF)來檢定此差分過後之序列是否平穩，單根檢定 ADF 表 4.7 中之所有 p 值皆小於 0.05，應拒絕虛無假設，表示次序列沒有單根，為平穩序列，可以此序列進行 ARIMA 模式建立。




圖 4.17 新竹一次季節性差分後之 ACF




圖 4.18 新竹一次季節性差分後之 PACF

表 4.7 新竹一次季節性差分後之 ADF 單根檢定

Augmented Dickey-Fuller Unit Root Tests							
Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	0	-526.444	0.0001	-21.40	<.0001		
	1	-447.431	0.0001	-14.95	<.0001		
Single Mean	0	-526.499	0.0001	-21.39	<.0001	228.72	0.0010
	1	-447.600	0.0001	-14.94	<.0001	111.66	0.0010
Trend	0	-527.028	0.0001	-21.39	<.0001	228.69	0.0010
	1	-448.820	0.0001	-14.96	<.0001	111.85	0.0010

根據表 2.4 的 ARIMA 模式判斷準則與新竹序列一次差分後之 SACF 與 SPACF 圖判斷，暫定模式為 ARIMA(1,0,1)(0,1,1)<sub>6</sub>。暫定 ARIMA 模式後，需進行模式參數估計，本研究選用最大概似估計法(Maximum Likelihood Estimate, MLE)，各項參數估計值列於表 4.8，其中 p 值皆小於 0.05 表示參數皆為有效估計。最後需進行白噪音檢定，檢定殘差間是否獨立。白噪音之檢定結果列於表 4.9，其中在落後期數 6 時之 p 值小於 0.05，表示殘差間為非獨立，此暫定模式並非合理之模式，因此需重新尋找 ARIMA 模式，直至模式通過白噪音檢定為止。

表 4.8 新竹 ARIMA(1,0,1)(0,1,1)<sub>6</sub> 之參數估計值

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.75276	0.05509	13.66	<.0001	1
MA2,1	0.93447	0.01829	51.08	<.0001	6
AR1,1	0.91667	0.03607	25.41	<.0001	1

表 4.9 新竹 ARIMA(1,0,1)(0,1,1)<sub>6</sub> 之白噪音檢定

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	12.82	3	0.0050	-0.039	0.035	0.010	0.013	-0.067	0.1127
12	19.26	9	0.0231	-0.078	0.043	0.032	0.004	-0.040	0.007
18	21.29	15	0.1279	0.005	-0.035	-0.002	0.009	0.003	-0.044
24	32.97	21	0.0465	0.102	-0.080	-0.012	0.027	-0.009	0.033

經過重新搜尋之暫定模式為 ARIMA(1,0,1)(1,1,1)<sub>6</sub>，此模式之各項參數估計值與白噪音檢定列於表 4.10 與表 4.11，各項參數估計值之 p 值皆小於 0.05 且白噪音檢定之各落後期數之 p 值也都小於 0.05，通過白噪音檢定，因此以此 ARIMA(1,0,1)(1,1,1)<sub>6</sub> 模式為新竹營業站所之預測模式，進行測試階段之貨運量預測，並計算其平均絕對誤差百分比 MAPE。

表 4. 10 新竹 ARIMA(1,0,1)(1,1,1)<sub>6</sub> 之參數估計值

Maximum Likelihood Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.71861	0.06816	10.54	<.0001	1
MA2,1	0.97854	0.02155	45.41	<.0001	6
AR1,1	0.88496	0.04902	18.05	<.0001	1
AR2,1	0.163126	0.04529	360	0.0003	6

表 4. 11 新竹 ARIMA(1,0,1)(1,1,1)<sub>6</sub> 之白噪音檢定

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	1.91	2	0.3851	-0.020	0.025	0.012	0.013	-0.043	-0.003
12	7.70	8	0.4635	-0.062	0.052	0.044	0.004	-0.018	0.026
18	8.78	14	0.8451	0.010	-0.025	0.004	0.007	0.020	-0.024
24	21.86	20	0.3481	0.107	-0.0703	-0.013	0.022	-0.009	0.061

根據上述之執行流程，分別建立 H 貨運公司五股、新竹、台中、永康與鳳山五個營業站所之 ARIMA 模式，並且分別進行測試階段之貨運量預測。五營業站所之模式皆通過 ADF 單根檢定與白噪音檢定，其參數記錄於表 4.12 模式與 MAPE 記錄於表 4.13。

表 4. 12 ARIMA 模式之參數

項目	$\varphi_1$	$\varphi_2$	$\varphi_6$	$\theta_1$	$\theta_6$	$\theta_{12}$
五股	0.76965	-	0.16906	0.55392	0.90212	-
新竹	0.88496	-	0.16312	0.71861	0.97854	-
台中	0.32373	0.09582	0.99986	0.81807	-	0.99907
永康	0.88758	-	-	0.62941	0.91238	-
鳳山	0.89253	-	-	0.59875	0.93084	-

表 4. 13 ARIMA 模式之 MAPE

項目	模式	Training MAPE	Testing MAPE
五股	(1,0,1)(1,1,1) <sub>6</sub>	18.20%	14.74%
新竹	(1,0,1)(1,1,1) <sub>6</sub>	10.69%	13.51%
台中	(2,1,1)(1,1,2) <sub>6</sub>	16.77%	17.04%
永康	(1,0,1)(0,1,1) <sub>6</sub>	8.96%	8.17%
鳳山	(1,0,1)(0,1,1) <sub>6</sub>	11.51%	10.28%



### 五股




圖 4. 19 ARIMA 五股營業站所預測比較圖

### 新竹




圖 4. 20 ARIMA 新竹營業站所預測比較圖

### 台中




圖 4. 21 ARIMA 台中營業站所預測比較圖

## 永康




圖 4. 22 ARIMA 永康營業站所預測比較圖

## 鳳山




圖 4. 23 ARIMA 鳳山營業站所預測比較圖

### 4.2.2 多重季節性自我迴歸移動平均整合模式

多重季節性自我迴歸移動平均整合模式(Multi-Seasonal AutoRegressive Integrated Moving Average method, MSARIMA)為本研究依據貨運量特性，將資料以季節特性進行拆解，再分別進行各區段預測之模式。由於貨運量並非僅受單一季節性之影響可能同時受到多種季節性之影響，而一般之 ARIMA 模式又無法同時考量多種季節性因素之影響，因此本研究將資料依照季節特性拆解，再分別以 ARIMA 模式分別進行最佳模式建立及進行貨運量預測。ARIMA 模式之部分則以 SAS 軟體 9.2 版本進行模式之建立與預測。其模式之執行流程如圖 4.9 所示。

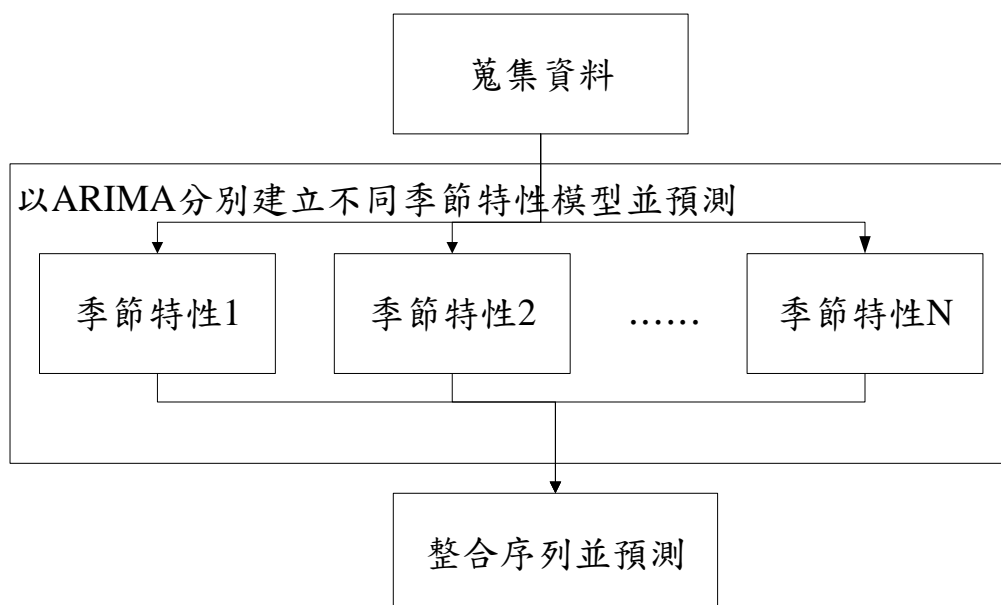


圖 4. 24 MSARIMA 模式之執行流程圖

資料來源：本研究整理

根據執行流程，首先將資料切成三份，分別為農曆年前兩周、農曆年後兩周與其他平常日。將此三個序列分別以 ARIMA 模式建立模型與預測，最後再將序列整合，計算 MAPE。ARIMA 模式中原本就可以設定固定周期性之影響，此個案應用中即為星期的變化，而將資料拆解分開預測又有考慮到農曆年季節因素之影響，如此方式即可達到同時考慮兩種季節性因素的影響。

本研究之多重季節性為考慮星期變化與農曆年對貨運量之影響，原始之 ARIMA 可以對星期的變化進行預測，而模型拆解的部分即是將資料拆解為農曆年前兩周、農曆年後兩周與其他平常日三個部份，並將每年所屬之季節特性合成一序列，例如將民國 97 年之農曆年前兩周資料與民國 98 年農曆年前兩周資料合為一序列，若資料串接之部分為星期不連續，則當作資料缺失，以前後期之資料作平均替代。重複此方式皆資料一季節特性整理完成。

H 貨運公司五股、新竹、台中、永康與鳳山五個營業站所之 MSARIMA 模式 testing period 之貨運量預測之參數值記錄於表 4.14，MAPE 記錄於表 4.15。

表 4. 14 MSARIMA 模式之參數值

營業站	項目	$\phi_1$	$\phi_3$	$\phi_6$	$\phi_{12}$
五股	過年前兩周	-	-	0.79555	-
	過年後兩周	-	-	0.90798	-
	其他日	0.71840	-	0.13768	-
新竹	過年前兩周	-0.56560	-	0.75889	-
	過年後兩周	-	-	0.95147	0.14424
	其他日	0.77453	-	0.13679	-

台中	過年前兩周	-0.55241	-	0.67523	-
	過年後兩周	-	-	0.97012	-
	其他日	0.86439	-0.12044	-0.98862	-
永康	過年前兩周	-0.51584	-	0.70572	-
	過年後兩周	-	-	-	0.95401
	其他日	0.81317	-	-	-
鳳山	過年前兩周	-	-	0.60843	-
	過年後兩周	-0.61685	-	0.90571	-
	其他日	0.80954	-	-	-
營業站	項目	$\theta_1$	$\theta_2$	$\theta_6$	$\theta_{12}$
五股	過年前兩周	-	-	-	-
	過年後兩周	0.96111	-	-	-
	其他日	0.49948	-	0.90062	-
新竹	過年前兩周	-	-	-	-
	過年後兩周	0.73122	-	-	-
	其他日	0.65711	0.97206	-	-
台中	過年前兩周	-	-	-	-
	過年後兩周	0.74814	-	-	-
	其他日	0.40437	-	-	0.95645
永康	過年前兩周	-	-	-	-
	過年後兩周	0.54909	-	-	-
	其他日	0.58010	-	0.92910	-
鳳山	過年前兩周	-	-	-	-
	過年後兩周	-	-	-	-
	其他日	0.55004	-	0.96843	-

表 4. 15 MSARIMA 模式之模式與 MAPE

營業站	項目	模式	Training MAPE	Testing MAPE
五股	過年前兩周	$(0,1,0)(1,0,0)_6$	20.55%	18.87%
	過年後兩周	$(0,1,1)(1,0,0)_6$		
	其他日	$(1,0,1)(1,1,1)_6$		
新竹	過年前兩周	$(1,1,0)(1,0,0)_6$	12.43%	13.90%
	過年後兩周	$(0,1,1)(2,0,0)_6$		
	其他日	$(1,0,1)(1,1,1)_6$		
台中	過年前兩周	$(1,1,0)(1,0,0)_6$	18.57%	10.77%
	過年後兩周	$(0,1,1)(1,0,0)_6$		
	其他日	$(3,0,1)(1,1,2)_6$		

永康	過年前兩周	$(1,1,0)(1,0,0)_6$	10.90%	9.64%
	過年後兩周	$(0,1,1)(2,0,0)_6$		
	其他日	$(1,0,1)(0,1,1)_6$		
鳳山	過年前兩周	$(0,1,0)(1,0,0)_6$	12.60%	10.96%
	過年後兩周	$(1,1,0)(1,0,0)_6$		
	其他日	$(1,0,1)(0,1,1)_6$		

### 五股




圖 4. 25 MSARIMA 五股營業站所預測比較圖

### 新竹






圖 4. 26 MSARIMA 新竹營業站所預測比較圖


## 台中



## 永康



## 鳳山





### 4.3 結果比較與分析

將 4.1 與 4.2 節中五個模型指數平滑模式 ESM、自我迴歸移動平均整合模式 ARIMA、指數平滑結合自我迴歸移動平均整合模式 ES-ARIMA 抑制趨勢多重日 DTMC 與多重季節性自我迴歸移動平均整合模式 MSARIMA 之預測誤差 MAPE 整理為表 4.16，其中 ESM 模式之 MAPE 為二次回溯後之 MAPE。

表 4.16 五營業站所五模式 MAPE 比較(單位：%)

項目	變異係數	ESM-BASED		ARIMA-BASED	
		ESM	DTMC	ARIMA	MSARIMA
五股	45.70%	14.71	20.06	<b>14.74</b>	18.87
新竹	41.76%	15.37	14.14	<b>13.51</b>	13.90
台中	38.46%	13.75	13.30	17.04	<b>10.77</b>
永康	37.06%	<b>8.06</b>	8.07	8.17	9.64
鳳山	39.67%	13.77	<b>12.68</b>	<b>10.28</b>	10.96
平均		13.13	13.65	<b>12.75</b>	12.83
變異數		<b>2.61</b>	3.83	3.16	3.33

註：粗黑體表示該營業站所中預測效果最佳之模式與總模式平均或變異最小之模式。

首先在變異係數對與 MAPE 之關係，不論時那一個模式，變異係數與各模式之預測誤差皆成正比，除新竹營業站所在 ESM 時有例外，此資料之變異程度與誤差成正比之情形為在預測前即可得知的，而結果也更應證了這一部分。

接著比較以指數平滑為基礎之模式，除永康與五股營業站所外，其餘三個營業站所之 DTMC 預測模式皆較 ESM 預測誤差來的小，若從整體平均資料來看，DTMC 模式之預測誤差也較 ESM 之預測誤差小，此部分則可說明 DTMC 模式同時考慮多重季節性模式之預測效果較傳統之 ESM 更可表現貨運量之變化，但其預測效果變異較大。

於 ARIMA 為基礎之模式比較上，傳統之 ARIMA 之預測效果較 MSARIMA 之預測效果來的好，僅台中營業站所除外，台中營業站所之貨運量預測效果以 MSARIMA 之預測效果最佳。但 ARIMA 與 MSARIMA 之誤差差距甚小。

由表 10 可發現，資料變異係數相對較大之五股營業站所在 DTMC 模式與 MSARIMA 模式之預測誤差 MAPE 有明顯高於其他模式之情形，且高出之比例非常明顯，因此本研究另外比較資料變異係數在 40% 以下之各營業站所與各模式的預測效果，表 4.17 及表 4.18 分別為資料變異係數大於 40% 與小於 40% 之營業站所之預測效果比較表。

表 4.17 資料變異係數大於 40% 之營業站所預測效果比較(單位：%)

項目	變異係數	ESM-BASED		ARIMA-BASED	
		ESM	DTMC	ARIMA	MSARIMA
五股	45.70%	14.71	20.06	<b>14.74</b>	18.87
新竹	41.76%	15.37	14.14	<b>13.51</b>	13.90
平均		15.04	17.1	<b>14.13</b>	16.39
標準差		<b>0.33</b>	2.96	0.62	2.49

註：粗黑體表示該營業站所中預測效果最佳之模式與總模式平均或變異最小之模式。

表 4.18 資料變異係數小於 40% 之營業站所預測效果比較(單位：%)

項目	變異係數	ESM-BASED		ARIMA-BASED	
		ESM	DTMC	ARIMA	MSARIMA
台中	38.46%	13.75	13.30	17.04	<b>10.77</b>
永康	37.06%	<b>8.06</b>	8.07	8.17	9.64
鳳山	39.67%	13.77	12.68	<b>10.28</b>	10.96
平均		11.86	11.35	11.83	<b>10.46</b>
標準差		2.69	2.33	3.78	<b>0.58</b>

註：粗黑體表示該營業站所中預測效果最佳之模式與總模式平均或變異最小之模式。

若僅考慮資料變異係數在 40% 以下之營業站所，則可發現 MSARIMA 模式之整理 MAPE 平均最低，僅 10.46%，且預測效果為四模式中最穩定者；而預測效果次佳者為 DTMC 模式。只考慮單一季節性之 ESM 與 ARIMA 模式之預測效果與穩定性為四模式中相對較差。

整體來說，若資料變異係數在 40% 以上者，本研究推薦使用 ARIMA 模式做為最佳之預測模式，因其預測誤差最小，且相較其他模式預測效果較穩定；若資料變異係數在 40% 以下者，本研究推薦使用可同時考慮多重季節性之 MSARIMA 與 DTMC 模式，其不論是在整體平均或是預測效果較好之營業站所個數都很極佳的表現，且其預測誤差與 Lewis [14] 所提之 MAPE 小於 10% 之預測為極佳之預測。

## 第五章 結論與建議

本研究採用時間序列作為貨運預測方法，分別為以指數平滑為基礎之模式：ESM 及 DTMC 模式。另外為以 ARIMA 模式為基礎之模式：ARIMA 及 MSARIMA，以 H 貨運公司五股、新竹、台中、永康與鳳山營業站所之每日貨運量資料建立模式並進行預測，作後以 MAPE 做為衡量模式預測精準度之指標。

### 5.1 結論

本研究完成之重要結果如下：

1. 本研究採用之四種預測模式之預測誤差 MAPE 在 8%~20% 之間，平均誤差在 12%~14% 左右。整體來說，ARIMA-based 之模式較 ESM-based 之模式預測效果佳。
2. 傳統 ARIMA 模式之預測效果較其他預測模式佳且穩定。
3. 本研究將台灣農曆年節對貨運量之影響納入 DTMC 模式中，使一模式可同時考慮多重季節性之變化，且其預測效果較傳統之 ESM 模式佳。ESM 相關模式以回溯之方式搜尋模式初始值可降低預測誤差。
4. 若不考慮資料的變異情形，則以 ARIMA 模式之預測效果最佳，且其模型預測之穩定性最佳；MSARIMA 模式之預測效果略差於 ARIMA 模式，模式預測穩定性次佳。
5. 資料變異係數在 40% 以下時，MSARIMA 模式之預測效果為所有模式中最佳者，因其模式可同時考慮多重季節性，模式之穩定性也為四種模式中最穩定者。而 DTMC 模式之預測效果與穩定性皆僅次於 MSARIMA 模式。

### 5.2 建議

本研究除得到上述結論外，另列出 3 點建議以供未來研究之參考：

1. 本研究所蒐集到之每日貨運量資料僅三年，以兩年之資料建立預測模式，一年之資料作為預測比較。雖然三年的資料以足夠建立單一季節性星期變化之影響，但若要考慮多重季節性如農曆年節之影響，因為其周期為一年左右，兩年之資料稍嫌不足，若未來可蒐集到更長時間之歷史資料，將更有助於比較模式之預測效果。
2. 本研究在考量多重季節性因素之影響時僅考量星期變化與農曆年節變化兩種，未來可在加入其他季節性變化之影響，例如其他國定假日及連續假日對每日貨運量之影響。

3. 本研究所得資料為貨運件數，若要根據貨運量而進行運送車輛的派遣，則貨運量資訊稍顯不足，不知道貨物件數的大小，無法估計所需之車輛數，因此建議未來研究可預測貨物之才積數，如此可估計所有貨量之體積，進而在計算所需之派遣車輛數。



## 參考文獻

1. Bowerman, B. L. and O'Connell, R. T., Time series and Forecasting: An Applied Approach, North Scituate, MA: Duxbury Press, 1979.
2. Brown, R. G., Smoothing, Forecasting and Prediction, Englewood Cliffs, N.J.: Prentice-Hall, 1963.
3. Celik, H. M., "Modeling freight distribution using artificial neural networks," Journal of Transport Geography, Vol. 12, NO. 2, pp. 141-148, 2004.
4. Cho. V., "A comparison of three different approaches to tourist arrival forecasting," Tourism Management, Vol. 24, pp. 323-330, 2003.
5. Fite. J. T., Taylor, G. D., Usher, J. S., English, J. R., Roberts, J. N., "Forecasting freight demand using economic indices," International Journal of Physical Distribution & Logistics Management, Vol. 32, No. 4, pp. 299-308, 2001.
6. Gardner Jr., E.S. "Exponential smoothing: the state of the art", Journal of Forecasting, Vol. 4, No.1, pp.1-28, 1985.
7. Gardner. Jr., E.S., McKenzie, E., "Seasonal exponential smoothing with damped trends.", Management Science, Vol. 35, No.3, pp.372-376, 1989.
8. Garrido, R.A., Mahmassani, H.S., "Forecasting freight transportation demand with the space-time multinomial probit model," Transportation Research Part B, Vol. 34, No. 5, pp. 403-418, 2000.
9. Godfrey. G. A., Powell, W. B. "Adaptive estimation of daily demands with complex calendar effects for freight transportation", Transportation Research Part B, Vol. 34, No. 6, pp. 451-469, 2000.
10. Goh. C., Law, R., "Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention," Tourism Management, Vol. 23, pp. 499-510, 2002.
11. Holt, C.C., Modigliana, F. Muth, J. F., Simon, H. A., Planning Production, Inventories, and Work Force. Prentice-Hall, Englewood Cliffs, NJ, 1960 .
12. Kulshreshtha, M., Nag, B., Kulshreshtha, M., "A multivariate cointegrating vector auto regressive model of freight transport demand: evidence from Indian railways," Transportation Research Part A, Vol. 35, pp. 29-45, 2001.

13. Ledolter, J., Abraham, B., "Some comments on the initialization of exponential smoothing." Journal of Forecasting, Vol. 3, pp.79-84, 1984.
14. Lewis, C.D., Industrial and Business Forecasting Method, London, Butterworth Scientific Publishers, 1982.
15. Lucas, J.M., Saccucci, M.S. "Exponentially weighted moving average control schemes: properties and enhancements with discussion" Technometrics, Vol. 32, No.1, pp. 1-30, 1990.
16. Makridakis, S. and Wheelwright, S. C., Forecasting: Methods and Applications, New York: Wiley, 1978.
17. Montgomery, D. C. and Johnson, L.A. Forecasting and Time Series Analysis, New York: McGraw-Hill.
18. Roberts, S.W. "Control chart tests based on geometric moving averages", Technometrics, Vol. 42, No.1, pp.97-101, 2000.
19. Winters, P.R., "Forecasting sales by exponentially weight moving averages.", Management Science, Vol. 6, pp.324-342, 1960.
20. 于宗先，經濟預測，台北，大中國圖書公司，民國 61 年。
21. 肖枝洪、郭明月，時間序列分析與 SAS 應用，武漢大學出版社，民國 98 年。
22. 林佳慧，「台灣國際航空貨運量之預測」，國立高雄第一科技大學運籌管理系，碩士論文，民國 94 年。
23. 林東慶，「以灰色理論和類神經網路預測航空客、貨運量之變化」，國立成功大學民用航空所，碩士論文，民國 96 年。
24. 林聰明、吳水丕，指數平滑法之選擇與應用，初版，華泰書局，民國 70 年。
25. 林繼國、陳其華，「台灣地區公路汽車貨物運輸業種分類之研究」，中華民國運輸年會第 17 屆論文研討會，民國 91 年。
26. 吳嘉斌，「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，碩士論文，民國 92 年。
27. 李書賢，「供應鏈協同運輸管理之出貨預測與貨運需求預測模式研究」，淡江大學運輸管理學系運輸科學碩士班，碩士論文，民國 97 年。
28. 陳俊男，「台灣地區國際商港營運量預測模式之探討」，逢甲大學交通工程與管理學系碩士在職專班，碩士論文，民國 97 年。



29. 莊賀凱，「派車專家-車輛途程分析系統應用於零擔貨運業」，南台科技大學工業管理研究所，碩士論文，民國 94 年。
30. 游智元，「時間序列方法於台鐵短期旅運需求預測之研究」，國立成功大學交通管理科學研究所，碩士論文，民國 95 年。
31. 葉小蓁，時間序列分析與應用，三版，台大法律學院圖書文具部，台北，民國 95 年。
32. 葉怡成，類神經網路模式應用與實作，八版，儒林圖書有限公司，台北，民國 93 年。
33. 廖孟媛，「季節性 ARIMA 模式在桃園機場貨運量預測之研究」，2009 航空產業創新發展學術研討會，民國 98 年。
34. 蔡宗憲、李治綱、魏健宏，「短期列車旅運需求之類神經網路預測模式建構與評估」，運輸計畫季刊第 35 卷第 4 期，民國 95 年。
35. 蘇承正，「中國大陸經濟發展對亞洲航空站運量之分析與預測」，國立交通大學運輸科技與管理學系，碩士論文，民國 94 年。

