

東 海 大 學

工業工程與經營資訊研究所

碩士論文

台灣液晶顯示器面板產業
需求預測模式之研究

研 究 生：莊秉欣
指 導 教 授：洪堯勳 博士

中 華 民 國 九 十 八 年 六 月

台灣液晶顯示器面板產業需求預測模式之研究

學生：莊秉欣

指導教授：洪堯勳博士

東海大學工業工程與經營資訊研究所

摘要

平面顯示器為台灣第二個兆元產業，其中位居關鍵地位的就是 TFT-LCD 面板生產，目前主要面板生產以台灣及韓國為最大生產國，兩國合計產值比重均已超過七成以上，而液晶顯示器面板產業之特性為市場需求不確定性大、產品生命週期短，再加上受到金融風暴的衝擊，使需求更加不確定，因此準確的需求預測顯得格外重要，準確的需求預測不僅可以降低因過度生產所造成之存貨成本，也可降低由生產不足所產生之缺貨成本。

過去，需求預測往往被視為不具生產力之工作，或是以質化方法進行直觀評估，而學者研究也顯示若是以量化研究來進行需求預測會有較佳的結果，且在預測的領域之中，大多研究多採取方法之間的比較，如此有可能遺漏重要之訊息，因此本研究擬採用組合方法對於需求量進行量化之研究。

本研究採用 2001 年 1 月至 2009 年 1 月之台灣液晶顯示器面板之銷售量進行預測，組合時間序列 ARIMA 預測法以及灰色預測法兩者，再將組合預測值之誤差投入倒傳遞類神經網路之中，並針對液晶顯示器面板主要銷售對象為全球市場，加入面板出口價格、美國景氣領先指標、歐元地區景氣領先指標、OECD 領先指標、G7 領先指標以及韓元兌台幣匯率等六項投入變數當作參考指標，於類神經網路進行學習預測，來對時間序列以及灰色預測方法組合的預測值進行修正。

實證結果顯示，組合預測模型對於單一預測模型比較之下確實有較佳之預測績效，並且可以藉由類神經網路對於資料之變動性進行修正，因此，本研究之研究成果驗證出組合方法確實可以將兩種各有優勢的預測方法截長補短，達到更佳的預測效果，而本研究之結果也可提供國內液晶顯示器面板廠商之產能規劃的參考。

關鍵字詞：TFT-LCD 面板產業、需求預測、時間序列、灰色預測、倒傳遞類神經網路

Applying Combination Forecasting Method for Taiwan LCD Panel Industry Demand Forecast

Student: Ping-Hsin Chuang

Advisor: Prof. Jau-Shin Hon

Department of Industrial Engineering and Enterprise Information
Tunghai University

ABSTRACT

The flat panel display industry is the second trillion industry in Taiwan. TFT-LCD panel production is in a key position of flat panel display industry. At present, the main panel production is Taiwan and South Korea. Proportion of the total output value of the two countries have move than 70%. The LCD panel industry characterized by uncertainty in market demand, and short product life cycle. In addition, the impact of financial turmoil made the demand more uncertainty. Therefore it is particularly important in accurate demand forecasts. Accurate demand forecasting can not only reduce inventory costs cause by excessive product, but also can reduce the cost out of stock cause by inadequate production.

In the past, the demand forecasts are often seen as nonproductive work or use qualitative methods to assess demand. Scholars study to quantify the demand forecast study results will be better. Most research on the comparison between different forecast ways. So there may be missing an important message. Therefore this study proposed combination of methods used to quantify the demand for research.

In this study, We use Taiwan's LCD Panel sales volume from January 2001 to January 2009. Combination of time-series ARIMA forecasting method and the grey prediction method. Then mix the predictive error into the back-propagation neural network, and joined the panel export prices, the U. S. leading indicator of the economy, a leading indicator of the euro area economy, OECD leading indicator, G7 leading indicator and the NT dollar exchange rate won, the six input variables as a reference indicator for neural network to learning and prediction. The predictive value of the combined method will be amended.

The results shows us, combined forecasting method is better then single forecasting method by neural network to be amended. Combined forecasting method can capture the advantages of single method. The results of this study may also provide the manufacturers of LCD panels of the reference capacity planning.

Keywords: TFT-LCD Panel Industry 、 Demand Forecast 、 Time Series 、 Gray Prediction 、 Back-Propagation Neural Network

誌謝

研究所兩年期間，由衷感謝指導教授洪堯勳博士悉心指導，並在研究領域上給予發揮自由與支持，使得學生論文得以順利完成。並感謝蕭子怡教授、陳建良教授與陳文典教授，百忙之中協助學生完成論文口試，並給予建議與指正，使論文得以趨於完備。感謝工工系老師們教導學生在工工領域專業知識技術的學習及謹密的思考邏輯能力。

在研究所兩年生涯中，最難忘的莫過於一起奮戰的戰友，宏均、宣傑，在這兩年中我們的默契可說是無人能敵，還有半個戰力的彥章，少了你研究室就少了很多歡笑，加上學弟學妹的加入，明修、穎志、卓漢和婉蓉，大家一起在研究室歡笑，就像個大家庭一樣，也要感謝大彥智，小彥志以及佳欣學姐，在我們還是小碩一的時候細心的指導我們，謝謝大家，謝謝EDA 這個溫馨的大家庭。

還要感謝經常來串門子的 QRG 研究團隊二人組，孝尚以及義清，還有人因三兄弟，阿達、金漢還有雨揚，大家總是開開心心的聊天、打球還有開彥章玩笑，彥章有一半是屬於你們的，大家記得要保持聯絡阿。

感謝親愛的秀容，妳的包容以及支持是我繼續念下去的原動力，雖然我們分隔兩地，每次見面都要隔一兩個禮拜，妳卻從來沒有抱怨過，在我壓力最大的時候，也是妳一路支持著我，跟妳在一起是最幸福的事，今後也要一直走下去喔。

感謝親愛的老媽以及老姐，沒有你們經濟上的支持，我沒辦法達到今天的境界，雖然我上研究所之後也早出晚歸，雖然我很少陪你們，不過每天仍然會回到溫暖的家。

套句彥章哥的話 ~ 謝謝各位鄉親父老! 謝謝! ~

秉欣 謹誌於

東海大學工業工程與經營資訊研究所

價值鏈創新與管理研究室

目錄

摘要.....	I
目錄.....	IV
圖目錄.....	VI
表目錄.....	VII
表目錄.....	VII
第一章 緒論.....	1
1.1 研究背景與動機.....	1
1.2 研究目的.....	3
1.3 研究限制.....	4
1.4 研究架構與流程.....	4
第二章 文獻探討.....	6
2.1 影響 LCD 需求量之因素分析.....	6
2.2 需求預測.....	7
2.3 量化預測方法.....	9
2.3.1 趨勢性預測.....	10
2.3.2 修正性預測方法.....	11
2.3.3 預測方法於 TFT-LCD 相關研究.....	13
2.4 組合預測探討.....	14
第三章 研究方法.....	15
3.1 研究操作概念.....	15
3.2 研究樣本期間與資料蒐集.....	15
3.3 時間序列分析.....	16
3.3.1 定態序列.....	16
3.3.2 單根檢定.....	16
3.3.3 自我迴歸整合移動平均 (ARIMA) 模型.....	17
3.4 灰色預測分析.....	20
3.4.1 灰預測模型驗證.....	20
3.4.2 灰預測建模.....	20
3.5 組合方法.....	22
3.6 類神經網路.....	24
3.6.1 類神經網路簡介.....	24
3.6.2 類神經網路原理及架構.....	24
3.6.3 類神經網路之運作.....	27
3.6.4 倒傳遞類神經網路.....	28
3.7 預測績效之評估指標.....	33
第四章 實證分析與結果.....	35
4.1 時間序列模型建構與分析.....	35
4.1.1 單根檢定.....	35

4.1.2 序列資料特性檢定.....	36
4.2 灰色預測模型建構與分析	39
4.2.1 滾動模型驗證.....	39
4.3 組合模型建構與分析	41
4.4 倒傳遞類神經模型建構與分析	42
4.5 模型之驗證與比較	45
4.6 大尺寸及中小尺寸之應用	46
第五章 結論與建議.....	49
5.1 研究結論.....	49
5.2 未來研究建議.....	50
參考文獻.....	51

圖目錄

圖 1.1 TFT-LCD 產業關聯圖.....	1
圖 1.2 全球顯示器面板業產值之各國市占率概況.....	2
圖 1.3 研究流程圖.....	5
圖 2.1 韓元兌台幣之匯率轉換圖.....	7
圖 3.1 本研究之操作架構圖.....	15
圖 3.2 人工神經元模型.....	25
圖 3.3 倒傳遞類神經網路架構.....	28
圖 4.1 原始數據序列圖.....	36
圖 4.2 時間序列一階差分序列圖.....	36
圖 4.3 取自然對數後時間序列一階差分序列圖.....	37
圖 4.4 殘差自我相關圖.....	38
圖 4.5 殘差常態性檢驗圖.....	38
圖 4.6 倒傳遞類神經網路運作流程圖.....	42
圖 4.7 倒傳遞類神經網路架構圖.....	44
圖 4.8 倒傳遞類神經網路訓練結果圖.....	44
圖 4.9 不同預測方式比較圖.....	45

表目錄

表 2.1 時間序列及灰色預測比較表.....	10
表 3.1 類神經網路模式分類表.....	27
表 4.1 原始時間序列單根檢定表.....	35
表 4.2 一階差分後時間序列單根檢定表.....	36
表 4.3 時間序列模型配適表.....	37
表 4.4 灰色預測滾動建模驗證表.....	39
表 4.5 不同預測方法之預測誤差整理表.....	41
表 4.6 類神經網路訓練參數設定表.....	43
表 4.7 組合預測方法與單一預測方法之績效評比表.....	45
表 4.8 中小尺寸面板之時間序列模型配適表.....	46
表 4.9 中小尺寸面板之灰色預測滾動建模驗證表.....	46
表 4.10 中小尺寸面板之不同預測方法預測誤差整理表.....	47
表 4.11 中小尺寸面板之組合預測與單一方法之預測績效比較表.....	47
表 4.12 大尺寸面板之時間序列模型之配適表.....	48
表 4.13 大尺寸面板之灰色預測滾動建模驗證表.....	48
表 4.14 大尺寸面板之不同預測方法預測誤差整理表.....	48
表 4.15 大寸面板之組合預測與單一方法之預測績效比較表.....	48

第一章 緒論

1.1 研究背景與動機

平面顯示器為台灣第二個兆元產業，其中位居關鍵地位的就是 TFT-LCD 面板之生產，台灣平面顯示器產值規模在 2008 年總產值為 1 兆 4,844 億新台幣，而主要營收來自於 TFT-LCD 的產值，約 1 兆 4,376 億新台幣，占整個平面顯示器產業高達 96% 以上(陳沛霖 2008)，而 TFT-LCD 產業結構可分為上、中、下游三個層次。上游包括設備、材料及零組件三大類，中游則屬面板 (Panel) 之製造與模組 (Module) 組裝，下游則應用於筆記型電腦、液晶監視器、液晶電視及 IA 資訊產品等，如圖 1.1 所示，而隸屬於中游部分的面板 (Panel) 製造業為整體供應鏈之關鍵產業。

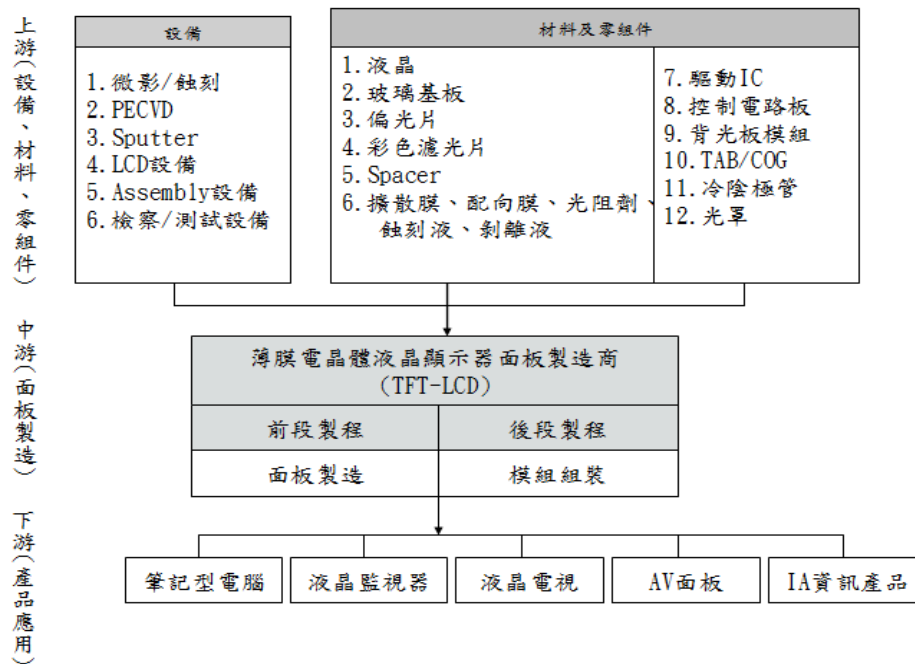


圖 1.1 TFT-LCD 產業關聯圖(資料來源:PIDA 2004)

目前主要面板生產以台灣及韓國為最大生產國，兩國合計產值比重已超過七成以上(圖 1.2)。政府也自 2002 年開始將薄膜電晶體液晶顯示器 (Thin Film Transistor-Liquid Crystal Display) 產業列為發展重點，因此可以見得 TFT-LCD 面板製造產業已成為代表台灣高科技的指標性產業。

台灣為 LCD 面板的製造大國，對於今天如 TFT-LCD 這種的高科技產業，市場需求不確定性大、產品生命週期短的特性，準確的需求預測顯得

格外重要。台灣的面板產業主要以代工為主，缺乏品牌可以消耗自身產能，所有產能利用率皆視訂單多寡而定，所以在產能調配、產能規劃方面更突顯銷售預測的重要性，且在現今競爭如此激烈的面板市場中，減少一分成本即為增加一分利潤，且因2008下半年金融風暴席捲全球，受到金融風暴的衝擊，全球消費力道急凍，導致各面板廠商紛紛調降產能利用率，以降低產能供給，同時產品價格大幅下降，期望透過降價以刺激需求。無奈金融風暴問題持續擴大，各國企業相繼傳出倒閉、關廠、裁員及無薪假等事件，迫使消費者消費力道更加縮手，導致各終端需求相當疲弱，使需求更加不確定，對於各面板廠之產能規劃無疑是一項考驗，因此，若能藉由需求預測更準確的預測出市場需求，即能提供非常有價值的參考依據，建構更準確的產能規劃。

Wemmerlov(1987)認為，需求預測誤差不僅影響各批量訂購方式之績效，並可導致缺貨及存貨過多的現象，Luis & Richard(2007)也提到，從供應鏈的角度來看，有較準確的需求預測模式，可以降低整體供應鏈之存貨成本，因此準確的需求預測不僅可以降低因過度生產所造成之存貨成本，也可降低由生產不足所產生之缺貨成本，郭秀敏(2004)也提到，合理可靠的需求預測資訊可幫助物料部門進行有效的存貨控制，幫助生管部門妥善進行排程工作以增加設備利用率；幫助決策者進行正確的判斷並提供適當的決策成為生產計劃的基礎，最後達到整體成本減少的目的。因此本研究期望能建立較準確的需求預測模式，且可以根據實際終端需求、大環境的影響隨時調整，能符合如金融風暴之下不確定性高的市場需求，提供進行產能規劃的參考，降低廠商之存貨、缺貨成本。




圖 1.2 全球顯示器面板業產值之各國市占率概況

(資料來源：經濟部 ITIS 計畫、工研院 IEK，台灣經濟研究院整理)

李智明(2004)認為，企業實際上值行需求預測時，往往將其視為不具生產力之工作，因此在做預測時過於草率，甚至預算也不足，造成需求預測執行上不切實際。且在進行需求預測時，通常以定性方法之歷史推演法，根據以往的需求數據進行類推，或是以管理者之經驗進行需求量判斷，Frederick et. al(2004)認為，採用計量模型進行需求預測通常較定性方法得到較佳的結果，且 Bates & Granger(1969)認為，傳統之預測方式多採用方法之間之比較，如此有可能會遺漏某些重要之訊息，在進行預測時，以不同之權重將不同方法加以組合會得到較佳之結果，因此本研究擬建構一量化預測方式，並採用不同預測方法之組合來針對需求量進行預測。

1.2 研究目的

需求預測的研究可分為值化研究以及量化研究兩種範圍，而在量化研究的範圍中，多以單一方法來進行預測，或以多種方法進行預測並比較各方法間之優劣，然而，近年來，許多文獻也提出利用不同方法進行組合預測，可以得到較單一方法準確的效果，因此，本研究即採用組合預測的模式，結合誤差的修正，來進行實證的探討。

本研究之研究目的如下：

1. 找出 TFT-LCD 之銷售數字，以及影響其銷售數字之變數，嘗試量化預測方法組合時間序列(ARIMA)以及灰色預測(Grey)兩種可以預測趨勢的技術，來預估銷售數字的趨勢性。
2. 再進一步針對組合方法所預測出之數值與真實數值之差異以及影響需求量之因素來建立類神經網路的非線性模型，來進行誤差的修正。
3. 針對本研究所建構之組合預測模式，與個別獨立預測方法對於預測準確度進行績效比較。
4. 而本研究之實證結果可提供面板廠在進行銷售預測，或是產能規劃時一個參考標的。

1.3 研究限制

本研究之研究限制分述如下：

1. 建立預測模型實以過去資料進行模型之建立與驗證，對於未來不可預測之變數，其預測能力有限，而本研究僅針對大環境之景氣變動狀況來對面板產業之需求量進行修正，而不考慮其餘不可預測之變數。
2. 本研究之樣本數採取2001年1月至2009年1月之銷售量數字，數據資料較少，實由於TFT-LCD於2001年始發展至今，時間上較其他產業短。

1.4 研究架構與流程

本研究共分為五個章節，各章節內容如下：

第一章 緒論

說明研究背景與動機、研究目的、研究限制、研究架構與流程。

第二章 理論基礎與文獻探討

對於影響台灣TFT-LCD面板需求量之因素進行研究，並針對各種需求預測方法，於產業上之應用方式進行文獻之探討。

第三章 研究方法

定義本研究之研究範圍以及資料來源，並對本研究所建立之模型其各部分方法提供理論依據，詳述建立組合預測模型之整體流程以及架構。

第四章 實證結果與分析

針對本研究所建立之預測模型，進行樣本內建模以及樣本外驗證步驟，並進行單一預測方法以及本研究之組合預測方法之預測績效比較。

第五章 結論與建議

說明與分析本研究之實證結論，並對後續之研究提出建議及方向。

本研究之研究流程如圖1.3所示：

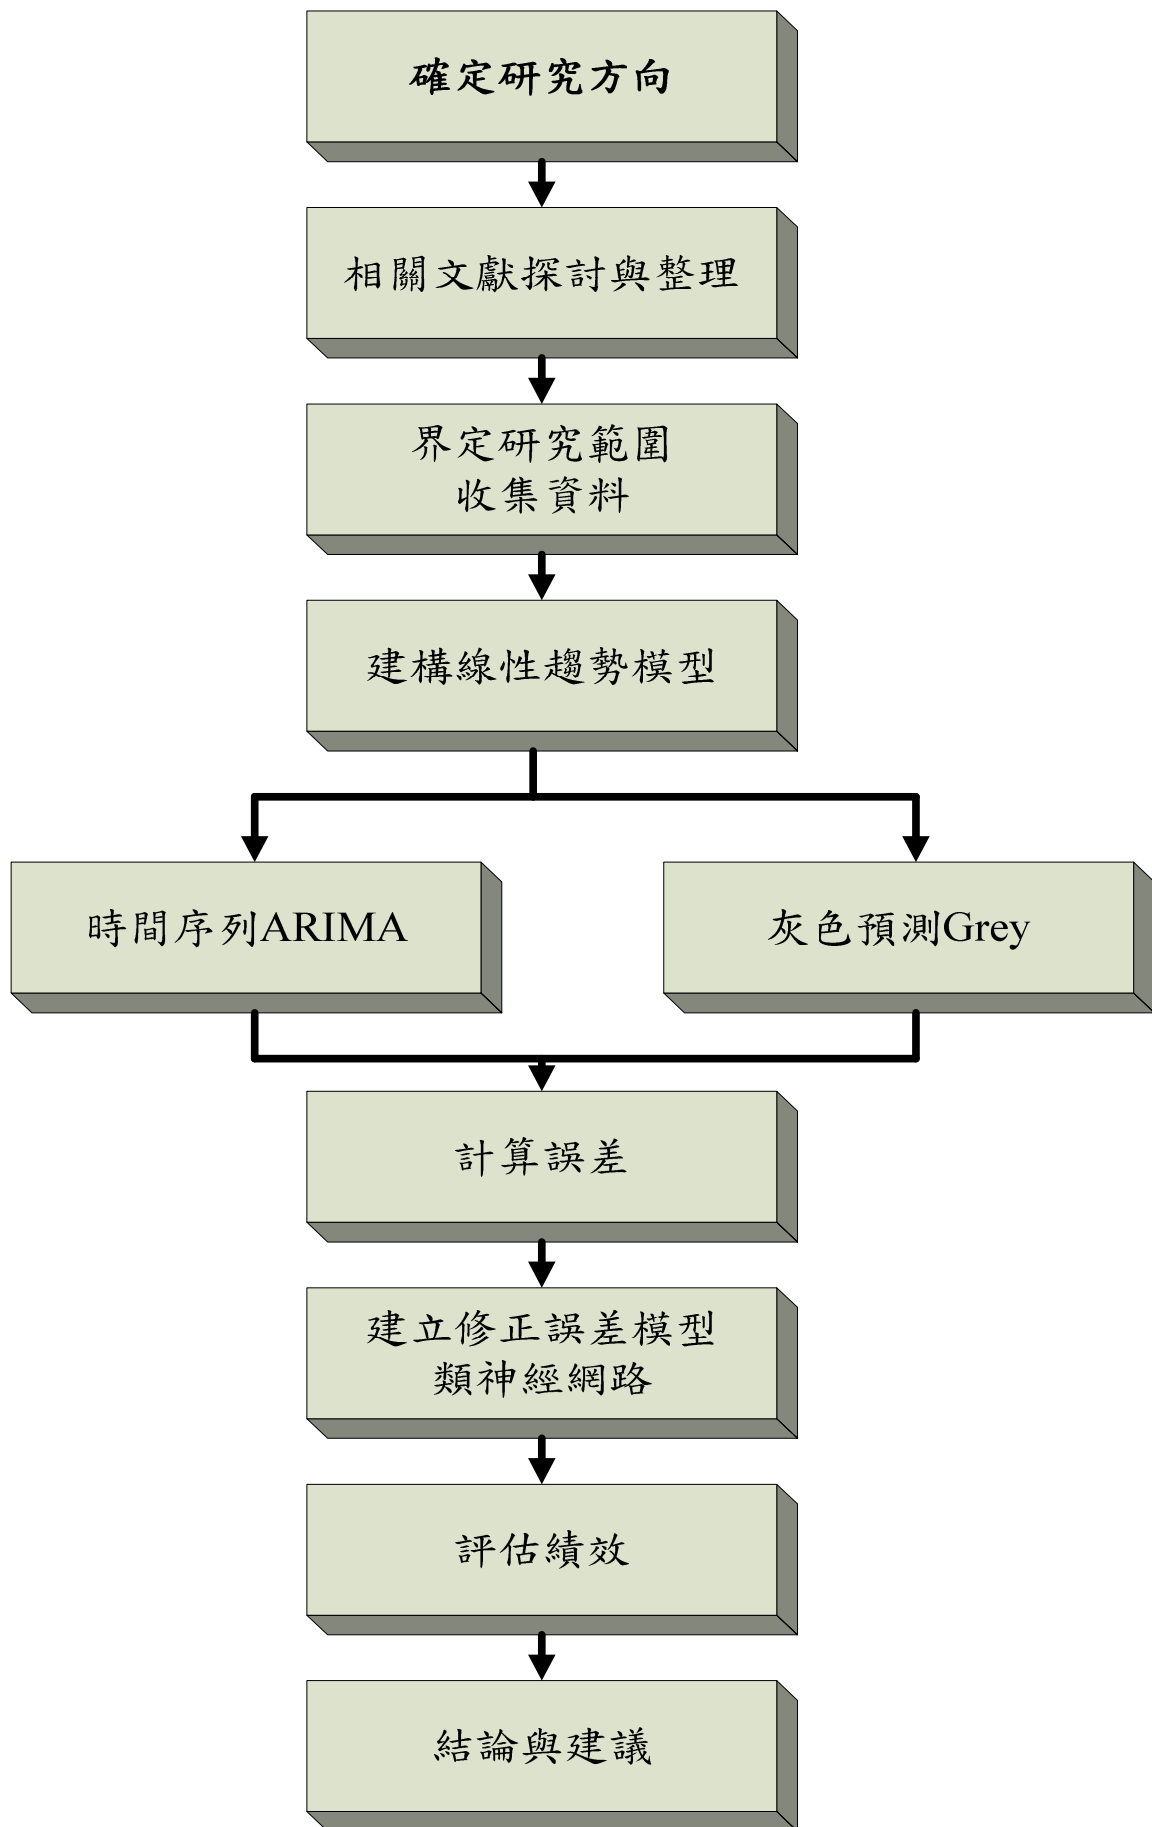


圖1.3 研究流程圖(資料來源:本研究整理)

第二章 文獻探討

本章首先列舉各學者針對 TFT-LCD 面板產業之供需研究，針對影響 TFT-LCD 面板產業之需求因素進行探討，再進一步探討需求預測之各種不同方法，並探討本研究擬採用之預測方法之適用性，提出組合預測之合理依據，作為本研究建構組合預測模型之基礎。

2.1 影響 LCD 需求量之因素分析

曾俊洲(2009)指出，歐美地區為全球顯示器面板下游終端產品主要消費地區，其主要產品包括桌上型電腦、筆記型電腦、液晶電視、手機、數位相機、遊戲機產品等，陳赫廷(2006)對於台灣大尺寸 TFT-LCD 面板產業出口供需進行探討，指出影響 TFT-LCD 面板產業之出口供需因素為面板價格、美國 GDP、歐元 GDP，顯示出對於面板產業之需求量，主要以地區之因素為主，而在全球需求地區之中，又以歐美地區最具有代表性，且根據第一銀行之解釋，國內生產毛額 GDP 可以反映一國經濟總產出規模的變化，是各國經濟景氣的具體象徵，而基於資料齊一性之考量，本研究即採用代表景氣象徵之景氣領先指標，針對主要銷售歐美地區，採取美國景氣領先指標以及歐元地區景氣領先指標，以及面板之出口價格，作為本研究之銷售地區因素之投入變數。

而根據台灣經濟研究院於 2009 年對於全球金融風暴對我國顯示器面板產業影響的報告中指出，面板價格一直是顯示器面板產業的重要觀察指標，並可以根據此指標進一步研判景氣趨勢，因此在全球金融風暴的影響下，全球一片不景氣，對顯示器面板的需求也大幅降低，由此我們可以說 TFT-LCD 面板需求量可以說是與全球整體的景氣是有連帶關係的，施正宏(2004)也驗證出以總體經濟指標對電子類股資料進行預測，較單純利用財務資料為準確，因此可以知道總體經濟指標對於高科技產業為具有代表性之因素，因此本研究將具有代表全球整體景氣之指標納入投入變數之中，如 OECD(經濟合作發展組織)領先指標以及 G7(7 大工業國)領先指標來做為影響 TFT-LCD 面板需求量之全球景氣因子。

曾俊洲(2009)提到，台灣與韓國為主要面板生產國，自 2008 年以來，隨著韓元大幅貶值，而帶動該國出口競爭力相對強大，雖然台灣在 2009 年 1~2 月亦出現明顯貶值現象，但其幅度明顯不如韓國，出口競爭力以韓國較為

優勢，可以知道匯率轉換為兩國競爭力之比較之代表因子，因此本研究採用韓元兌台幣之匯率值作為影響面板銷售量之競爭力因子。

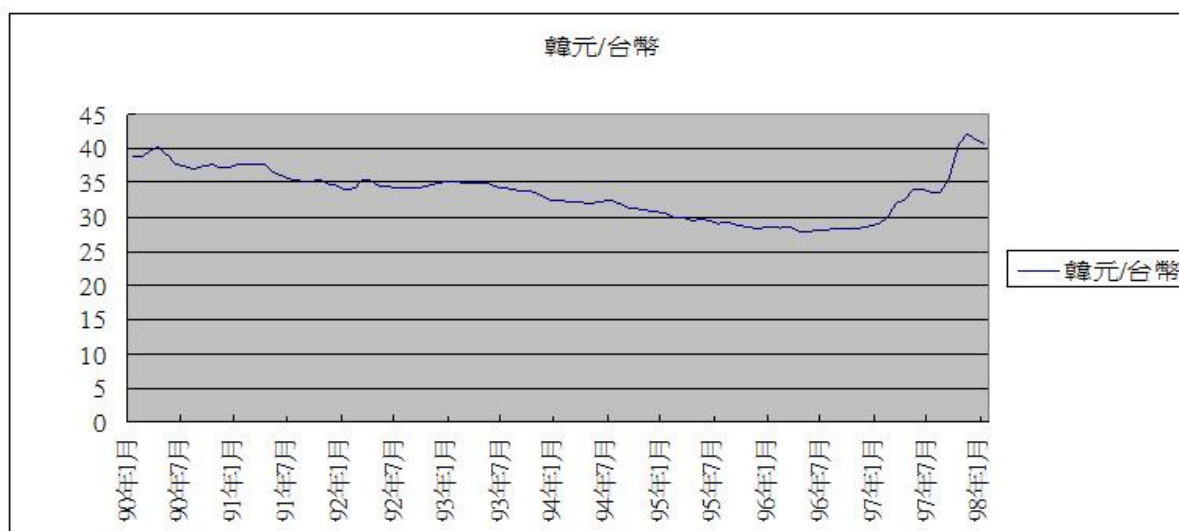


圖 2.1 韓元兌台幣之匯率轉換圖 (資料來源:本研究整理)

2.2 需求預測

企業在進行商業行為之前，均必須要對市場進行某種程度的推測，如需求預測、銷售預測、生產預測或價格預測等的預測行為，其中以需求預測為最首要執行之預測步驟，需求預測是對於某個特定社會領域，有關某種產品的需求數量的預測。包括了生產同樣產品的全部企業，也就是生產同種產品所有企業的立場出發進行預測，知道需求預測值之後，才可進一步根據市場佔有率推斷個別企業之銷售量預測數字。(春日井博 1988)

Charu & Janis(2005)認為在供應鏈中，需求預測是非常重要的一環，若是需求預測不準確，容易產生長鞭效應的影響，導致成本大幅增加。李智明(2004)認為正確預測並滿足顧客需求，為企業生存之根本，若是需求預測能力不佳，可能導致公司營運計畫不實及財務報表失真的情形。Frederick et.al(2004)認為需求預測分析可以提供兩個主要管理目的，為可預先洞悉需求以達到有效之運用，以及有助於對銷售及獲利報酬之預測。

一般的需求預測通常可以分為定性方法以及定量方法兩種，張盛鴻等(2000)認為定性方法為使用非數學之方式，依賴判斷、直覺及主觀性的評價。在這方面的主要技術有市場研究(觀察)、德爾菲法(專家意見)、歷史的推論及管理的估計(猜測)，其分述如下：

1. 市場研究(Market Research):此法對於實際市場之假設做有系統的、正式的，且有意義的檢定程序。
2. 德爾菲法(Delphi Method):以一系列之問卷調查一組專家意見，在每次訪問後，將分析結果連同下一次之問卷一起分送受訪專家，直到大多數的專家看法接近一致。由於受訪專家是採取匿名的，因此可以不受其他人的身分、地位所影響，評自己的知識與看法來判斷。
3. 歷史類比法(Historical Analogy):本法是對於欲引人注意的新產品，根據與其類似的舊產品的歷史資料，以相似的方式作比較分析，進而做為新產品的預測。
4. 管理的估計:通常由高級決策人員招集決策管理人員，包括銷售、生產、採購、財務及研究發展部門主管共同集會討論預測，由成員發言表示其考慮之因素，說明其影響，並提出個人的預測數值，最後由招集人綜合所有人的預測值平均之。

而定量的技術為使用數學的方式取得預測資訊，常用的有時間序列法以及迴歸分析法。其分述如下：

1. 時間序列分析:時間序列是以過去的資料為主，假設未來的情形與過去情勢相類似，因此若有因素改變情形時，必須參照判斷予以修正，預測才能正確，而時間數列是指一個固定間隔為基礎，經過一段時間之時間序列的觀察結果
2. 迴歸分析法:本法利用迴歸找出自變數與應變數之關係，例如，利用最小平方法之技術估計出銷售額與其他經濟的、競爭性的及內在的變數之間的關係，本法主要是建立於統計性的分析，故每種關係都應加以合理的檢定。

張盛鴻等(2000)指出數學性的技術通常能較專家修正的預測有比較好

的結果，然而一些數學性的技術需要相當的歷史資料的數量，但通常這些資料可能無法獲得。當缺乏實體的資料時，主觀性的管理判斷就變成一個比較好的選擇

James and Jens(1995)也指出需求預測的目標通常是較無結構性、以及需求不確定性高，屬於高度複雜性的市場，定性的銷售預測通常較缺乏數字化的依據，容易導致預測不準確

Frederick et.al(2004)認為以計量模型進行需求預測有三項優點，

1. 以量化數字評估需求量時，具有客觀性，較能防止管理階層任意更改政策所產生之不客觀行為。
2. 以量化預測建立需求預測模式時，可以預測經濟狀況變化的方向以及強度，藉此可提供企業在策略規劃上之參考。
3. 可以根據所建立之量化預測模型所做的預測數字，與實際值進行比較，藉此修正預測模型，如此可使需求預測更具有彈性。

因此本研究即針對量化型預測進行文獻探討

2.3 量化預測方法

隨著電腦科技的發展，在經濟、社會、人口、環保、經營規劃與管理控制等領域的應用，愈來愈受到重視，而應用在預測技術更是不可或缺的決策過程，因為電腦科技的快速演算，使得學者在進行量化型的預測研究時，得以快速的進行估算，建立預測模型，因此量化預測技術得以快速發展，而時間序列以及灰色預測模式在需求預測領域已廣泛的使用，均得到不錯的預測成果，且因時間序列在數據的需求量上較多，所需要較高的知識以進行預測，其預測範圍適合中、長期之預測，而灰色預測僅需少量之數據即可進行預測，且用法簡單，不需太高深的知識，適合於短期之預測範圍，因此本研究擬採用各有優缺點之兩者進行組合預測模式之建立。

表 2.1 時間序列及灰色預測比較表

數學方式	所需最少數據	準備時間	知識需求	適合預測範圍
時間序列	50 個以上	長	高等程度	中、長期
灰色預測	4 個	短	基本數學	短期

(資料來源 吳漢雄、鄧聚龍、溫坤禮 1996、鄭美幸等 2002)

2.3.1 趨勢性預測

1. 時間序列

在時間序列應用於預測方面已有多位學者驗證其預測有效性較傳統之迴歸預測方法較為優良。如呂珊茹等(2006)以機車 HC 氣體排放量為實證數據，驗證迴歸分析以及時間序列模式，研究結果顯示，時間序列模式的預測效果較迴歸分析優良，陳執中(2006)應用迴歸分析、時間序列分析及類神經網路三種預測方法，以台股加權指數為研究目標，目的為預測台股加權指數之隔月收盤價，其研究結果顯示，時間序列 ARIMA 模式的預測效果最好，其預測誤差皆小於其他模式。

而時間序列預測方法也有多位學者驗證出其預測績效具有可參考之預測趨勢性，黃黎平(2005)應用時間序列於銷售量的預測中，提出影響銷售量的三個主要因素為

- (1) 長期趨勢變動的影響
- (2) 季節循環變動趨勢的影響
- (3) 隨機變動的影響

並根據某公司的歷年銷售量數據為實證，研究結果顯示時間序列模式對於趨勢性的數據有一定的代表性。曹銳勤(2004)以國內 30 家上市銀行為研究對象，不考慮其他經濟因素的影響下，利用集群分析、時間序列 ARIMA 模式對所規劃集群的銀行股價做預測分析，以決定投資者的投資

標的，其研究結果顯示，ARIMA 模式所得之誤差值比雙重指數平滑模式所得的誤差小，且可以準確的預測股價未來的趨勢，對於決定投資標的的選擇有很大的幫助。

2.灰色預測

灰色理論目前已在各種不同領域廣為使用，其中灰色預測也有許多學者驗證出其預測績效較傳統之預測方法為佳，洪麗珠(2006)比較灰色預測以及計量經濟理論中之迴歸分析方法，以台灣地區居民前往大陸地區旅遊之旅客市場為實證，研究結果得到，灰色預測僅需要單一變數而且使用少量的數據即可達到與迴歸分析相同的預測效果，足以證明灰色預測在某些領域可以取代計量經濟模型。羅志明等(2006)藉由台灣 TFT-LCD 之出口值，比較灰色理論 GM(1,1)模型、迴歸分析、指數平滑法三種方法之預測績效，其研究結果顯示，灰色理論的 GM(1,1)灰色預測模型較其他方法對於預測 TFT-LCD 之出口值是比較適合的。

且灰色預測在實際執行預測時，也有學者提出具有可預測趨勢性之性質，吳漢雄、鄧聚龍、溫坤禮(1996)認為，灰色預測中之數列預測是對原始數據做其未來發展的趨勢研究，由於原始數據中僅包含各因子對系統之現有影響，但對系統於未來發展時之各種新變數及新影響是無法掌握的。呂柏賢(2000)以灰色理論方法，結合古典時間序列分解法，建構以灰色理論為背景的需求預測模式。並以生鮮果汁產品的銷售量為建模數據，發現在使用灰色理論預測數據的趨勢時，有不錯的預測準確度。但數據呈週期性變動時，灰色預測效果則不理想

由於時間序列及灰色預測均具有較傳統預測方式佳且可預測資料趨勢性之功能，因此本研究擬採用兩者進行組合方法建立並執行預測。

2.3.2 修正性預測方法

類神經網路是以模擬人類大腦神經元之方式，並以不同之演算法來進行數據的推演，其特性為非線性之學習能力，應用其功能已有多位學者驗證類神經網路的預測功能較傳統之預測方式為佳，鄭佳欣(2008)以多元迴歸模型、時間序列模型以及倒傳遞類神經模型，藉由 KD 技術指標建立投入變數來對人民幣匯率進行預測，其研究結果顯示，在人民匯率預測範圍中，

倒傳遞類神經之預測績效優於其餘兩者，且證明 KD 技術指標應用於匯率預測之中是確實可行。龔旭陽等(2005)利用倒傳遞類神經網路、多元迴歸以及多變量不安定指數法來對南投縣境內 181 條土石流潛勢溪流進行預測，以土石流發生學理及歷史資料分析提出八項土石流災害發生因子為投入變數，其研究結果顯示，倒傳遞類神經所分析的結果最佳且誤判最小。

類神經網路的最大特性即為其具有適應性學習能力，多位學者亦驗證出類神經網路之學習能力的有效性，張斐章、張麗秋(2005)認為類神經網路最主要的特性為擁有三項功能，學習、回想及歸納推演，分別概述如下：

1. 學習(learning):

類神經網路可藉由學習的方式，隨外在環境的變化來改變它的行為模式，類神經網路的學習過程可藉由建立神經元間之連結模式、修正連結神經元間之權重以及調整神經元活化函數中之門檻值來達成

2. 回想過程(recall):

當類神經網路接受到一個輸入刺激，進而依據網路架構產生一個輸出值時，我們便稱這一個過程為回想過程，在前饋式網路中，回想過程即為一對一映射方式，得到一個輸入刺激即對應到一個輸出，而在回饋式網路中，因前期輸入刺激會反覆的回饋，因此輸入和輸出的關係不斷被修正與調整，故為一動態系統，常用於描述非線性動態系統的行為。

3. 歸納推演過程(generalization):

歸納推演法是從一個系統中局部觀察描述出其整體特性的過程，能夠讓我們找出所有可以適用於全部類別物件的重要因子，而非僅將記憶中的特殊事件運用於個別物件。

本研究即應用類神經網路的適應性學習能力，擬藉由影響 TFT-LCD 面板需求量之因素為投入變數，對時間序列以及灰色預測所建立組合預測模型之預測誤差進行預測，來達到修正誤差的功能。

2.3.3 預測方法於 TFT-LCD 相關研究

本研究針對所採用之三種不同預測方法，不僅提出其優於傳統以及具有預測趨勢性和學習修正性之特性，更進一步探討此三種預測方法於 TFT-LCD 產業之應用，以模型之預測績效適用性以及產業應用之適用性來對本研究所使用之預測方法進行評估。

陳淑真等(2008)針對某 TFT-LCD 公司進行整合 ARIMA 需求預測與存補貨政策，進行模擬供應鏈存或模型之比較與分析，結果顯示 ARIMA 需求預測模式有正面的效益，羅志明等(2008)應用灰色預測理論、迴歸分析、指數平滑法來預測台灣 TFT-LCD 出口值，其結果顯示灰色預測之績效相對其餘方法是較好的。王瓊敏(2000)針對 LCD 面板及 DRAM 價格變動情形以灰色預測、時間數列等預測方式建立價格預測模式，並比較各預測模式間優缺點及準確性，其結果顯示，灰預測可以解釋線性關係，而在預測 TFT-LCD 時可使用時間序列模式。黃惠民等(2008)以國內某面板製造公司為例，倒傳遞類神經、移動平均、迴歸預測等方法對該公司營業額進行預測，其結果顯示倒傳遞類神經以及複迴歸模型所得預測較佳

因此，本研究即根據所討論之模型預測績效適用性以及產業應用之適用性，以時間序列模式、灰色預測方式對 TFT-LCD 產業面板需求量進行組合預測，並以倒傳遞類神經網路，加入影響面板產業需求之因素，對其需求量進行誤差修正。

2.4 組合預測探討

組合預測模式最早由J. M. Bates及Granger C.W.J.於1969年提出，因為傳統的預測通常為將不同預測方法對相同預測目標做預測再進行方法間之比較，之後取預測績效較佳者進行預測，績效不佳者即捨棄，對於單一方法預測的情形J. M. Bates及Granger C.W.J. 提出有可能為以下兩點

1. 績效好的預測模型已經包含了變數以及所有資訊，而其他的模型並沒有考慮到。
2. 績效不好的預測模型有可能對於變數之間的關係有不一樣的解釋。

直接捨棄績效不好的模型可能會造成將某些重要的影響變數排除的影響，因為預測績效不佳即有可能為此模型包含著影響的變數，而造成預測績效不佳，因此J. M. Bates及Granger C.W.J建議對於不同模型，應配合適當的線性組合權重進行組合，所得到的預測誤差將小於個別模型的預測誤差。(Bates & Granger 1969)

黎鑑輝(2007)也指出組合預測法係結合不同預測方法的優點來提升預測的可信度，有助於彌補使用單一預測法的缺點，一般而言，組合方法可獲得更精準的預測結果。

由J. M. Bates及Granger C.W.J. 所提出之觀點，本研究擬採用組合預測之方法，結合時間序列以及灰色預測兩種不同之預測模式，以期能達到互補其優缺點的功用，並加入誤差修正之類神經網路模形，以期能涵蓋可能之影響變數，進而達到預測績效的提升。

第三章 研究方法

本章針對本研究之研究設計與操作加以闡述，首先說明整體組合架構之模式，接著再針對本研究所使用之三種不同預測方法進一步解說，最後再說明不同模型的預測績效衡量標準。

3.1 研究操作概念

本研究嘗試以組合建模的方式來對於台灣 TFT-LCD 產業之銷售量進行預測，並擬進一步採用倒傳遞類神經的方式進行誤差之修正，本研究之數據處理架構如下圖 3.1 所示

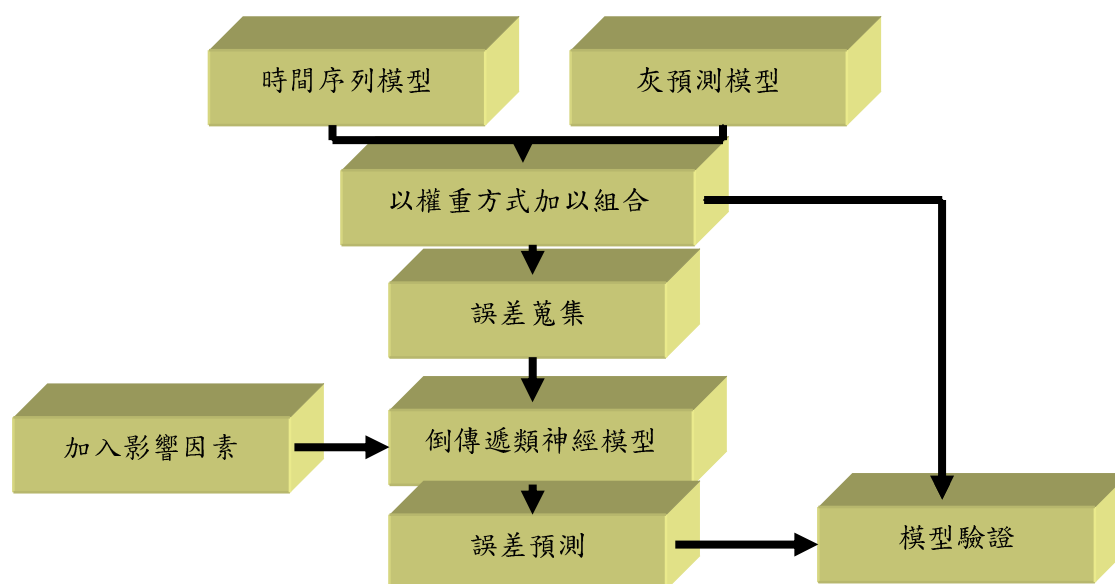


圖3.1 本研究之操作架構圖 (資料來源：本研究整理)

3.2 研究樣本期間與資料蒐集

本研究之樣本採用台灣 TFT-LCD 產業 2001 年 1 月至 2009 年 1 月期間之銷售量資料，並蒐集同一時段之影響 TFT-LCD 需求量因素，如銷售地區因素，分為面板出口價格、美國景氣領先指標以及歐元地區景氣領先指標，以及全球景氣因素，如 OECD 領先指標和 G7 領先指標，並加入競爭因素，以韓元兌台幣匯率表示。

3.3 時間序列分析

依時間過程所得變數的觀察值稱為時間序列(time series)，而對時間序列之研究，稱為時間序列分析。時間序列模型便是以分析序列變數過去資料與現在關係，來預測變數未來的變動趨勢。因此，本節介紹在建立實證模型前，處理時間序列資料所需的相關檢定，來配適一良好之ARIMA (Autoregressive Integrated Moving Average Models) 模式。

3.3.1 定態序列

採時間序列進行計量分析前，應先檢定變數是否呈現定態(stationary)。所謂定態係指一時間序列資料產生過程為一隨機過程(stochastic process)，但此一隨機過程之機率分配不隨時間而改變。若一時間數列為定態，其變數具有相同的期望值與變異數，亦即該數列存在一均值，受到衝擊事件影響僅是短暫，隨時間便會逐漸消逝，整個序列再度回到長期的均衡。

根據Granger and Newbold(1974)研究發現，若對非定態變數數列進行傳統的迴歸分析，可能產生判定係數很高，且變數之t統計量非常顯著，但Durbin-Watson檢定值卻很低的假性迴歸(spurious regression)現象，導致估計結果產生偏差。由於許多研究發現，大多經濟或財務的時間序列資料變數，都具有非定態性質。因此，採用時間序列變數進行研究時，檢定變數是否為定態，成為必備的先驗步驟。

3.3.2 單根檢定

單根檢定(Unit Root Test)主要是用來檢定序列是否為定態，即檢測樣本是否存在單根。若一序列經過d次差分始達定態，則稱此序列為一整合級次為d的序列，表示為I(d)(integrated of order d)。一般而言，單根檢定方法中，以Dickey-Fulle檢定法與Augmented Dickey-Fuller檢定法最廣為使用。但由於DF檢定法係假設殘差符合白噪音¹性質，而迴歸殘差項卻可能存在序列相關的現象，造成DF值不正確，檢定範圍受到限制，使得DF檢定的檢定力不足(楊奕農, 2007)。而為解決此問題，Said and Dickey(1984)提出當殘差項非

¹白噪音(white noise)之定義如下：

(1)誤差項之期望值為零，即 $E(\varepsilon_t) = 0$, for all t

(2)誤差項之變異數為一固定常數，即 $\text{var}(\varepsilon_t) = \sigma^2$, for all t,且

(3)誤差項之自我共變數為零，即 $\text{cov}(y_t, y_{t-k}) = \text{cov}(y_{t-j}, y_{t-k-j}) = 0$, for all j, k, j ≠ k

白噪音時，將誤差項序列相關的可能性考慮進來之修正模型，即將解釋變數加入被解釋變數的落後項，視其為額外的解釋變數後再進行檢定，即為 ADF 單根檢定。而 Engle and Granger(1987) 亦建議使用 ADF 檢定法來檢測單根問題，故本研究採用 ADF 檢定法來進行單根檢定。

一般而言，ADF 檢定法有以下三種模型：

1. 無截距項與時間趨勢項

$$\Delta Y_t = \gamma_{t-1} + \sum_{i=2}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (3.3.1)$$

2. 有截距項與無時間趨勢項

$$\Delta Y_t = \alpha_0 + \gamma_{t-1} + \sum_{i=2}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (3.3.2)$$

3. 有截距項與時間趨勢項

$$\Delta Y_t = \alpha_0 + \alpha_1 T + \gamma_{t-1} + \sum_{i=2}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (3.3.3)$$

式中 Δ 表示差分， $\Delta Y_t = Y_t - Y_{t-1}$ 服從白噪音， $\varepsilon_t \sim N(0, \sigma^2)$ ， α_0 為截距項， T 為時間趨勢(trend)， P 為使殘差項 ε_t 符合白噪音的最適落後期數。此三種模型之虛無假設為 $H_0: \gamma = 0$ (即 Y_t 序列存在單根)，若檢定結果 γ 顯著異於 0，即拒絕單根存在，表示該序列為定態；若所得結果為非定態序列，須經由差分處理反覆檢定，直到 γ 顯著異於 0，成為定態序列結果。

3.3.3 自我迴歸整合移動平均(ARIMA)模型

自我迴歸移動平均(Autoregressive Integrated Moving Average, ARIMA) 係由 Box and Jenkins(1970) 提出，其主要由兩部分所組成，分別為自我迴歸(AutoRegressive, AR)模型與移動平均(Moving Average, MA)模型。

1. 自我迴歸(AR)模型

AR 模型指依變數(y_t)除了受誤差項(ε_t)影響外，亦受該變數前 p 期值 (y_{t-1}, y_{t-2}, \dots) 所影響，以 AR(p) 表示，模型如下：

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-i} + \varepsilon_t \quad (3.3.4)$$

其中 a_0 表示截距項， y_t 為第 t 期實際值， a_i 代表 y_{t-i} 估計參數， ε_t 為白噪音

2. 移動平均(MA)模型

MA 模型指依變數(y_t)與過去 q 期隨機干擾項($\varepsilon_{t-1}, \varepsilon_{t-2}, \dots$) 有關係，以 MA(q) 表示，模型如下：

$$y_t = a_0 + \sum_{i=1}^q b_i \varepsilon_{t-i} + \varepsilon_t \quad (3.3.5)$$

其中 a_0 表示截距項， b_i 代表 ε_{t-i} 估計參數， ε_t 為白噪音

3. 自我迴歸移動平均(ARMA)模型

若一變數(y_t)同時與變數之前期(y_{t-1}, y_{t-2}, \dots)及誤差項之前期($\varepsilon_{t-1}, \varepsilon_{t-2}, \dots$)相關，則稱此模型為ARMA(p,q)模型。

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-i} + \varepsilon_t + \sum_{i=1}^q b_i \varepsilon_{t-i} \quad (3.3.6)$$

其中 a_0 表示截距項， a_i 與 b_i 代表估計參數， ε_t 為白噪音。

4. 自我迴歸整合移動平均(ARIMA)模型

若一變數(y_t)同時與變數之前期($y_{t-1}, y_{t-2}, y_{t-3}, \dots$)及誤差項之前期($\varepsilon_{t-1}, \varepsilon_{t-2}, \varepsilon_{t-3}, \dots$)相關的話，則稱此模型為ARMA(p,q)模型。若有一資料為非定性資料，ARMA模型無法配適時，可利用取差分方式進行配適，此模型即為ARIMA模型，若取d次差分後可用ARMA(p,q)配適，則稱此模型為ARIMA(p,d,q)，其模型如下：

$$\Delta^d y_t = a_0 + \sum_{i=1}^p a_i \Delta^d y_{t-i} + e_t + \sum_{i=1}^q b_i e_{t-i} \quad (3.3.7)$$

其中 d 表示差分次數， a_0 表示截距項， a_i 與 b_i 代表估計參數， e_t 為白噪音。

任一時間序列可以不同型態出現，一般可根據Box and Jenkins(1976)發展之自我相關函數(Autocorrelation Function, ACF)來判斷移動平均過程MA之階數q，及偏自我相關函數(Partial Autocorrelation Function, PACF)來判斷自我迴歸過程AR之階數p。對於各種可能之模型配適，再以Akaike(1974)年提出的AIC值(Akaike's Information Criterion)，或是Schwartz(1978)提出的SBC值(Schwartz's Bayesian Information Criterion)來決定最適模型。若AIC和SBC值愈小，則代表模型的配適度越佳，計算方式分別如下所示。

$$AIC = T \ln(SSE) + 2k \quad (3.3.8)$$

$$SBC = T \ln(SSE) + k \ln(T) \quad (3.3.9)$$

其中， T 是樣本總數， $\ln(SSE)$ 是SSE(殘差平方和)取自然對數， $\ln(T)$ 是樣本總數取自然對數， k 是待估參數總數。

此兩種模型選擇準則何者較佳，並沒有一致的定論。一般而言，根據

模型的簡約性(parsimony)原則，參數較少的模型就是較好的模型(楊奕農, 2007)，而SBC準則較AIC準則嚴格，當樣本資料愈大時，SBC愈能選擇出正確的模型，而同情況下AIC傾向選出落後期較長的模型(Enders, 2004)，因此當AIC準則與SBC準則相抵觸時，則以SBC準則為優先考量。

而模型配適後為了解估計模型是否合適，須檢定模型之殘差項是否存在序列相關，以及檢定模型之殘差是否符合「常態分配」。評估殘差項是否存在序列相關之標準以Ljung and Box(1978)提出的Ljung-Box Q統計量檢定殘差項是否存在m階序列相關，其虛無假設為 H_0 ：無m階序列相關，Ljung-Box Q統計量為：

$$Q = T(T+2) \sum_{i=1}^m \frac{\rho(i)^2}{(T-i)} \sim \chi^2(m) \quad (3.3.10)$$

其中， T 為樣本數， $\rho(i)$ 為殘差第 i 階自我相關係數， m 為落後期數；若 $Q > \chi^2(m)$ ，則拒絕無 m 階序列相關之虛無假設，表示模型配適不適當，須重新認定及估計；若 $Q < \chi^2(m)$ ，則表示模型配適適當。而評估殘差項是否符合「常態分配」之標準為Jarque-Bera統計量，其虛無假設 H_0 ：被檢定之變數為常態分配，則Jarque-Bera統計量為：

$$JB = \frac{T-n}{6} \left(S^2 + \frac{1}{4}(K-3)^2 \right) \quad (3.3.11)$$

其中， S 為偏態係數(skewness)， K 為峰態係數(kurtosis)， n 為待估參數， T 為樣本數，若是無法拒絕虛無假設，則我們可以設定此模型之殘差符合常態分配。

因此，本研究擬採用時間序列分析法，建構TFT-LCD銷售量之ARIMA模型以進行本研究建構之預測架構之初步預測，並使用所建構出之時間序列模型做獨立預測，和本研究所建構之預測架構進行分析比較。

3.4 灰色預測分析

灰色分析是由鄧聚龍教授於1982年所提出，主要是針對系統模型之不明確性，資訊之不完整性之下，進行關於系統的關聯分析(Relational Analysis)、模型建構(Constructing A Model)，藉由預測(Prediction)及決策(Decision)來探討及了解系統，在我們探討許多領域時，經常會遇到訊息不明確的情形，如果以「黑色」表示訊息完全缺乏，而以「白色」表示訊息完全確知，對系統完全了解，因此訊息不完全之系統即為「灰色系統」，而灰色預測即是應用了灰色系統之相關理論，如累加生成、累減生成及灰差分方程之方式建立灰色預測模型，並藉由滾動驗證之方式來驗證模型的精確度，本節即陸續介紹灰色預測之相關步驟。

3.4.1 灰預測模型驗證

本研究在建立之灰色預測模型之前即採用滾動建模之方式驗證其精確度，滾動建模(Rolling Checking)是利用同一序列前面幾個數據(通常以前四點開始)建立GM(1,1)模型後，預測下一點數據後，再向後移一點(捨棄第一點，由第二點開始)，同樣建立GM(1,1)模型，依此類推做到原始數據最後一點為止。我們定義每次滾動所做預測之誤差公式為：

$$e(k+1) = \frac{x^{(0)}(k+1) - \hat{x}^{(0)}(k+1)}{x^{(0)}(k+1)} \times 100\% \quad (3.4.1)$$

而GM(1,1)模型的滾動檢驗平均誤差定義為：

$$e = \frac{1}{n-4} \left(\sum_{k=4}^{n-1} \|e(k+1)\| \right) \times 100\% \quad (3.4.2)$$

因此可以得到GM(1,1)的滾動檢驗平均精度為：

$$\varepsilon = (1 - e) \times 100\% \quad (3.4.3)$$

3.4.2 灰預測建模

灰色預測(Grey Prediction)為灰色理論中之一部分，是以GM(1,1)模型為基礎，對現有數據進行的預測方法，優點為數據不需太多，且應用數學基礎簡單，具有廣泛適用性(龔昶元等2006)，應用灰色生成的方式來建立模型，灰色生成為補充訊息之數據處理，這是一種就數找數的規律方法，利用此種方式，在雜亂無章的數據中，設法將其被掩蓋的規律及特徵浮現出來，也就是我們可以利用灰色生成的方式降低數據中的隨機性，並提升其規律性(溫坤禮等2002)，使用生成過的數據建立一組灰差分方程與灰擬微

分方程之模式，建立一階微分、一個變量之GM(1,1)模式來進行預測，其步驟簡述如下：

步驟一、建立原始數據序列

假設 $x^{(0)}$ 為一原始數列，即

$$x^{(0)} = (x^{(0)}(1), x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)) \quad (3.4.4)$$

其中 $x^{(0)}(i)$ 表示原始數列中第 i 個數

步驟二、建立累加生成AGO數據序列

定義 $x^{(1)}$ 為 $x^{(0)}$ 的一次累加生成，則可以得到

$$x^{(1)} = \left(\sum_{k=1}^1 x^{(0)}(k), \sum_{k=1}^2 x^{(0)}(k), \dots, \sum_{k=1}^n x^{(0)}(k) \right) \quad (3.4.5)$$

步驟三、求出背景值 $z^{(1)}(k)$

背景值為GM(1,1)之源模型

$x^{(0)}(k) + az^{(1)}(k) = b$ 中之 $z^{(1)}(k)$ 項

其定義為：

$$z^{(1)}(k) = 0.5x^{(1)}(k) + 0.5x^{(1)}(k-1) \quad (3.4.6)$$

步驟四、求得待定係數 a 、 b

由源模型 $x^{(0)}(k) + az^{(1)}(k) = b$ ，對所有 $k = 2, 3, \dots, n$ ，代入數列可得

$$\begin{aligned} x^{(0)}(2) + az^{(1)}(2) &= b \\ x^{(0)}(3) + az^{(1)}(3) &= b \\ x^{(0)}(4) + az^{(1)}(4) &= b \\ &\dots \\ x^{(0)}(n) + az^{(1)}(n) &= b \end{aligned} \quad (3.4.7)$$

化成矩陣型式，

$$\begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \dots \\ x^{(0)}(n) \end{bmatrix} = \begin{bmatrix} -z^{(1)}(2), & 1 \\ -z^{(1)}(3), & 1 \\ \dots & \dots \\ -z^{(1)}(n), & 1 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} \quad (3.4.9)$$

其中

$$Y_n = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \dots \\ x^{(0)}(n) \end{bmatrix}, \quad B = \begin{bmatrix} -z^{(1)}(2), & 1 \\ -z^{(1)}(3), & 1 \\ \dots & \dots \\ -z^{(1)}(n), & 1 \end{bmatrix} \quad (3.4.10)$$

根據最小平方法可求得待定係數

$$\begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_n \quad (3.4.11)$$

步驟五、根據灰微分方程導出 $x^{(0)}$ 之響應式

由灰微分方程

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b \quad (3.4.12)$$

透過常微分方程求解方法，可得到 $x^{(1)}$ 之響應式為：

$$x^{(1)}(k+1) = \left[x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} + \frac{b}{a} \quad (3.4.13)$$

步驟六、還原響應式，得到預測模型進行預測

由累減生成還原響應式

$$\begin{aligned} x^{(0)}(k+1) &= x^{(1)}(k+1) - x^{(1)}(k) \\ x^{(0)}(k+1) &= (1 - e^{-a}) \left[x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} \end{aligned} \quad (3.4.14)$$

本研究經過模型建立初期之滾動驗證模型可得知預測準確率最高之 n 筆數據，再由資料最後一筆開始往前取 n 筆數據開始進行建模，並根據所求得之響應式執行驗證端之預測。

3.5 組合方法

本研究之組合方式是將兩種不同的預測模型，藉由線性組合的方式，分別給予不同的權重予以加權，本節主要敘述為線性組合之演算方式，其計算如下：

令兩種模型預測之第 i 組數據表示為 $Q_{Time}(i)$ 以及 $Q_{Grey}(i)$ ，

目標線性模式為：

$$Q_{combin} = (\omega_{Time} \times Q_{Time}) + (\omega_{Grey} \times Q_{Grey}) \quad (3.5.1)$$

其中 ω_{Time} 、 ω_{Grey} 表示兩種預測方法個別的組合權重

則個別預測誤差可以表示為：

$$\begin{aligned} \varepsilon_{Time} &= Q_{Act} - Q_{Time} \\ \varepsilon_{Grey} &= Q_{Act} - Q_{Grey} \end{aligned} \quad (3.5.2)$$

而組合預測誤差可表示為：

$$\varepsilon_{combin} = Q_{Act} - Q_{Combin} \quad (3.5.3)$$

且可藉由使總誤差平方和最小之方式，來求得各別組合權重，其演算如下：

$$\min Z = \sum_{i=1}^n (Q_{act}(i) - Q_{com}(i))^2 \quad (3.5.4)$$

將(3.5.1)式帶入(3.5.4)式可得到

$$Z = \sum_{i=1}^n [\omega_{Time} (Q_{Act}(i) - Q_{Time}(i)) + \omega_{Grey} (Q_{Act}(i) - Q_{Grey}(i))]^2 \quad (3.5.5)$$

因此，將(3.5.2)兩式代入(3.5.5)式即可得：

$$Z = \sum_{i=1}^n [(\omega_{Time} \times \varepsilon_{Time}(i)) + (\omega_{Grey} \times \varepsilon_{Grey}(i))]^2 \quad (3.5.6)$$

經過化簡可以得到：

$$Z = \omega_{Time}^2 \times \left(\sum_{i=1}^n (\varepsilon_{Time}(i))^2 \right) + 2 \cdot \omega_{Time} \cdot \omega_{Grey} \times \left(\sum_{i=1}^n \varepsilon_{Time}(i) \times \varepsilon_{Grey}(i) \right) + \omega_{Grey}^2 \times \left(\sum_{i=1}^n (\varepsilon_{Grey}(i))^2 \right) \quad (3.5.7)$$

上式即可建立非線性方程式模型：

$$\begin{cases} \min Z \\ s.t. \\ \omega_{Time} + \omega_{Grey} = 1 \\ \omega_{Time} \geq 0 \\ \omega_{Grey} \geq 0 \end{cases} \quad (3.5.8)$$

對此非線性方程式求解，即可求得必須的權重 ω_{Time} 、 ω_{Grey} ，並以此權重來對驗證端進行預測驗證。

3.6 類神經網路

3.6.1 類神經網路簡介

「類神經」一詞最早起源於1943年，由McCulloch and Pitts於「A Logical Calculus of Ideas Imminent in Nervous Activity」中提出神經元數學模型(MP model)，但此模型採用固定的鍵結值(synaptic weights)與閾值(threshold)，故不具學習能力。之後，1949年Hebb提出神經元間的鍵結值發生改變將導致學習效果的產生。使得MP模型與Hebb學習法則對後來的類神經網路發展建立了基礎。到了1957年，Frank Rosenblatt提出感知機(Perceptron)，為第一種類神經網路模型。由具有可調整鍵結值及閾值的單一類神經元所組成，主要用於理論研究與樣本識別。但1969年Minsky and Papert於「Perceptron」書中，以數學證明當時類神經網路模型的學習能力極受限制，甚至連最簡單的「互斥或」(exclusive or, XOR)問題都無法解決，而使類神經網路的發展陷入低潮。直到1980年代中期後，隨著霍普菲爾網路(Hopfield neural network)的提出，類神經網路的研究才再次熱門起來。1986年Rumelhart and McClelland等人提出倒傳遞網路網路(BPN)與通用差距法則(generalized delta rule)，此種類神經網路克服了XOR的問題。並且以理論證明此種演算法的收斂性，此種模型已成為目前應用最廣的網路。至今為止，類神經網路仍然有新的架構與理論不斷被提出，配合電腦運算速度的增加，使得類神經網路的功能更為強大，運用層面也更為廣泛。

3.6.2 類神經網路原理及架構

類神經網路(Artificial Neural Network, ANN)，又稱人工神經網路，是指模仿生物神經網路的資訊處理系統。根據DARPA Neural Network Study (1988)定義，類神經網路為「一種由許多簡單的處理單元以平行方式運作所構成的神經網路」。葉怡成(2006)較精確定義為「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神經網路的能力。人工神經元是生物神經元的簡單模擬，它從外界環境或者其他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他人工神經元」。

類神經網路與傳統統計方法或專家系統不同之處，在於其不需事先設定出特定的函數形式，資料也不需限定在某種特定的統計分配假設，是一種

能透過學習來處理多變數時間非線性關係的工具。類神經網路便是藉由模擬人類大腦神經的運作方式，透過不斷的學習與錯誤修正，創建與訓練出符合實際問題的類神經網路架構，以映射出輸入與輸出間關係的數學式，來達到正確預測的目的。

類神經網路的基本架構可分三個層次：處理單元(processing element, PE)、層(layer)、網路(network)所構成。一個類神經網路是由許多的人工神經元，又稱處理單元所組成。介於處理單元間的訊號傳遞路徑稱為連結(connection)。每一個連結都有對應的加權值 W_{ij} (weight)，用以代表處理單元 i 對處理單元 j 的影響強度，其運作方式如圖3.2所示。每一個處理單元接受輸入訊號後，以扇狀方式送出訊號，成為下一層處理單元的輸入訊號，處理單元的輸出值與輸入值之關係式，一般可用下列函數表示：

$$Y_j = f(\sum W_{ij} X_i - \theta_j) \quad (3.6.1)$$

其中， Y_j ：輸出變數，模仿生物神經元的輸出訊號。

X_i ：輸入變數，模仿生物神經元的輸入訊號

W_{ij} ：連結加權值(weight)，模仿生物神經元的神經節強度。

θ_j ：模仿生物神經元的模型的閾值(bias)，又稱偏權值。即輸入訊號的加權乘積必須大於此門檻值，才会有訊號傳送至下個神經元。

Σ ：集成函數(summation function)，此部分是將每一個輸入(X_i)與加權值(W_{ij})相乘後做加總。

f ：轉換函數(transfer function)，用以將從其他處理單元輸入的輸入值之加權乘積和($W_{ij} X_i$)和偏權值 θ_j 的總合轉換成處理單元輸出值的數學公式。




圖 3.2 人工神經元模型(資料來源：葉怡成, 2006)

至目前為止，許多學者針對不同問題的解決，提出許多不同類神經網路模型，每一種類神經網路的演算法並不相同。而類神經網路通常依照學習方策略與網路架構二種方式進行分類，分別詳述如下(葉怡成, 2006)：

1. 依學習策略分類

- (1) 監督式學習(Supervised Learning)：從問題領域中取得訓練範例(有輸入變數與輸出變數)，並從中學習輸入變數與輸出變數的內在對映規則，以應用於新的案例(只有輸入變數值，而需推論輸出變數值的應用)。分類應用(如疾病診斷)與預測應用(如經濟預測)屬之。
- (2) 無監督式學習(Unsupervised Learning)：從問題中取得訓練範例(只有輸入變數值)，並從中學習範例的內在集群規則，以應用於新的案例(只有輸入變數值，而需推論它與那些訓練範例屬同一集群的應用)。無監督式學習可作為監督式應用的前端處理。
- (3) 聯想式學習(Associate Learning)：從問題中取得訓練範例(狀態變數值)，並從中學習範例的內在記憶規則，以應用於新的案例(只有不完整的狀態變數值，而需推論其完整的狀態變數值的應用)。資料擷取應用與雜訊過濾應用屬之。
- (4) 最適化應用(Optimization Learning)：類神經網路除了「學習」應用外，還有一類特殊應用即最適化應用—對一個問題決定其設計變數值，使其在能滿足設計限制下，使設計目標達到最佳狀態應用。設計應用與排程應用屬之。此類應用的網路架構大都與聯想式學習網路架構相似。

2. 依網路架構分類

- (1) 前向式架構(forward)：神經元分層排列，形成輸入層、隱藏層(若干層)、輸出層。每一層只接受前一層的輸出作為輸入，稱前向式架構。
- (2) 回饋式架構(feedback)：從輸出層回饋到輸入層，或是層內各處理單元間有連結者，或是當神經元不分層排列，只有一層，各神經元間均可以相互連結，稱回饋式架構。依據學習策略與網路架構的區分，茲將類神經網路的十四種模式分類，整理如表3.1所示(葉怡成, 2006)。

表 3.1 類神經網路模式分類表

學習策略 \ 網路架構	前向式架構	回饋式架構
監督式學習	認知機 倒傳遞網路(BPN) 機率神經網路(PNN) 學習向量化網路(LVQ) 反傳遞網路(CPN)	波茲曼機(BM) 時空樣本識別網路(STPR) 新認知機(也可作無監督學習)
無監督式學習	自組織映射圖(SOM)	自適應共振理論(ART)
聯想式學習		霍普菲爾網路(HNN) 雙向聯想記憶網路(BAM)
最適化應用		*霍普菲爾-坦克網路(HTN) *退火神經網路(ANN)

*屬解最適化問題的網路，不屬上述任一種學習模式

(資料來源：葉怡成, 2006)

3.6.3 類神經網路之運作

類神經網路如何學習而具有功能，便要瞭解網路如何透過訓練，來調整並決定加權值 W_{ij} 和偏權值 θ_j 。基本上，類神經網路的運作分成兩個過程(羅華強, 2005)：

1. 訓練過程—目的在決定網路的加權值與偏權值。
2. 模擬過程—目的在決定網路的預測輸出值或驗證網路的準確度。

在訓練過程中，網路遵循所謂的學習規則(Learning Rule)，當然，各種類型的網路各有所不同。而學習規則目的在修正網路的加權值與偏權值。訓練過程一般採用所謂的訓練演算法(Training Algorithm)，同樣的，不同類型網路也各有其不同的訓練演算法。

類神經網路在運作時會將所需訓練的資料，或稱訓練數據集(Training Data Set)分成兩類：

1. 訓練數據集—目的在修改網路的加權值與偏權值。
2. 測試數據集—目的在驗證網路的準確度。

總之，類神經網路運作就是透過訓練，不斷的調整節點之間的加權值與偏權值，使網路所計算的輸出為目標輸出，其運作目的就是要讓網路能映射出正確的輸入—輸出關係模式。

3.6.4 倒傳遞類神經網路

倒傳遞類神經網路為目前類神經網路學習模式中最具代表性，應用最普遍的模式，屬於監督式學習網路，適用於分類、診斷、預測和雜訊過濾等應用。

典型的倒傳遞類神經網路基本原理是利用最陡坡降法(the gradient steepest descent method)的觀念，採用錯誤更正學習法則的倒傳遞演算法(back propagation algorithm)，而「倒傳遞」就是指非線性多層網路內計算梯度的方法，將錯誤的訊號以回饋方式修正網路的連結權重與閾值，使誤差函數最小化，而將推論的輸出值能夠最接近目標輸出值，以達到網路學習的目的。目前，倒傳遞演算法基於其他不同標準的最佳化技巧，而有了許多變化的演算法，例如共軛梯度法(Conjugate Gradient)和牛頓法等，另外，類神經網路工具箱被視為一個已知能運作良好並已建立好步驟的套裝軟體，亦已提供了大多數變化的演算法。

1. 倒傳遞網路之架構

倒傳遞類神經網路架構為多層感知機(multilayer perceptrons)，輸入信號以前饋(feedforward)方式，每一層只接受前一層的輸出作為輸入。主要由輸入層、隱藏層和輸出層所構成。其架構如圖3.3所示：

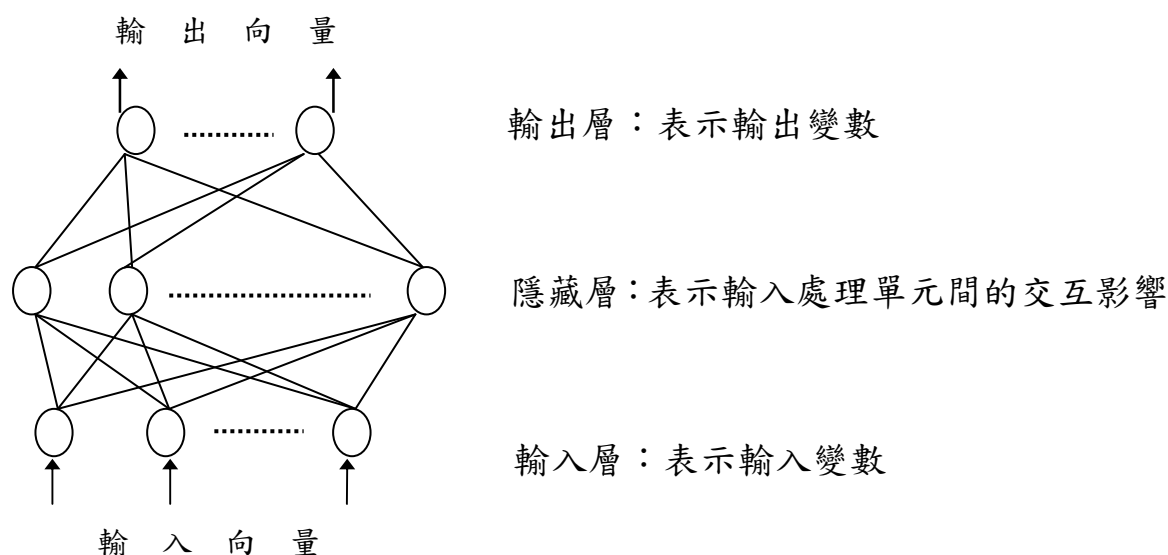


圖 3.3 倒傳遞類神經網路架構

(資料來源：葉怡成, 2006)

- (1) 輸入層：用以表現網路的輸入變數，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：用以表現網路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決定，經常需以試驗方式決定最佳的數目。使用非線性轉換函數。在網路中隱藏層的數目可以不只一層，也可以沒有隱藏層。
- (3) 輸出層：用以表現網路的輸出變數，其處理單元數目依問題而定，常使用非線性轉換函數。

2. 倒傳遞網路之學習演算法

以下將簡單說明在倒傳遞網路的學習過程中，網路如何利用一輸入向量 X 與一目標輸出向量 T ，來修正網路加權值 W ，而達到學習的目的。

在倒傳遞網路中，第 n 層的第 j 個單位輸出值為 $n-1$ 層單位輸出值計算之淨輸入值 (net_j^n) 的非線性函數：

$$A_j^n = f(net_j^n) \quad (3.6.2)$$

$$\text{其中， } net_j^n \text{ 為集成函數 } = \sum_i W_{ij} A_i^{n-1} - \theta_j \quad (3.6.3)$$

W_{ij} 為第 $n-1$ 層第 i 個處理單元與第 n 層第 j 個處理單元間之連結加權值， θ_j 為偏權值(即閾值)。

因為倒傳遞網路目的在降低目標輸出值與推論輸出值之差距，一般以下列誤差函數來表示學習的品質：

$$E = \frac{1}{2} \sum_j (T_j - A_j)^2 \quad (3.6.4)$$

其中， T_j 為輸出層的目標輸出值

A_j 為輸出層的推論輸出值

而監督式學習網路的學習過程在使上述誤差函數最小化，通常使用最陡坡降法，即每當輸入一個訓練範例，網路即小幅調整加權值大小：

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E(n)}{\partial W_{ij}(n)} \quad (3.6.5)$$

其中， η 為學習速率，控制以最陡坡降法最小化誤差函數的步幅。

而 $\frac{\partial E}{\partial W_{ij}}$ 可用微積分的連鎖律(chain rule)表示為：

$$\frac{\partial E}{\partial W_{ij}} = \left(\frac{\partial E}{\partial net_j^n} \right) \left(\frac{\partial net_j^n}{\partial W_{ij}} \right) \quad (3.6.6)$$

第①項第②項

將(3.6.3)代入(3.6.6)第②項得

$$\frac{\partial net_j^n}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} (\sum_i W_{ij} A_i^{n-1} - \theta_j) = A_i^{n-1} \quad (3.6.7)$$

為簡明定義

$$\text{令 } \frac{\partial E}{\partial net_k^n} = -\delta_j^n \quad (3.6.8)$$

將(3.6.7)(3.6.8)代入(3.6.6)，則

$$\frac{\partial E}{\partial W_{ij}} = -\delta_j^n \cdot A_i^{n-1} \quad (3.6.9)$$

其中， A_i^{n-1} 為 W_{ij} 所連結之較低層處理單元之輸出值

δ_j^n 為 W_{ij} 所連結較上層處理單元之差距量

再將(3.6.9)代入(3.6.5)，可得

$$\Delta W_{ij} = \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (3.6.10)$$

此式即為倒傳遞演算法之關鍵公式。

根據上式來調整新的連結加權值 $W_{ij}(n+1)$ 為：

$$W_{ij}(n+1) = W_{ij}(n) + \Delta W_{ij}(n) = W_{ij}(n) + \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (3.6.11)$$

若 W_{ij} 連接的為輸出層，則

$$\begin{aligned} \delta_j^n &= -\frac{\partial E}{\partial net_j^n} = -\frac{\partial E}{\partial A_j^n} \cdot \frac{\partial A_j^n}{\partial net_j^n} \\ &= -\frac{\partial}{\partial A_j^n} \left[(1/2) \sum_j (T_j - A_j)^2 \right] \cdot \frac{\partial f(net_j^n)}{\partial net_j^n} \\ &= (T_j - A_j)^2 \cdot f'(net_j^n) \end{aligned} \quad (3.6.12)$$

若 W_{ij} 連接的為隱藏層，則

$$\begin{aligned} \delta_j^n &= -\frac{\partial E}{\partial net_j^n} = -\frac{\partial E}{\partial A_j^n} \cdot \frac{\partial A_j^n}{\partial net_j^n} = -\frac{\partial E}{\partial A_j^n} \cdot f'(net_j^n) \\ \frac{\partial E}{\partial A_j^n} &= \sum_k \frac{\partial E}{\partial net_k^n} \cdot \frac{\partial net_k^n}{\partial A_j^n} = \sum_k \frac{\partial E}{\partial net_k^n} \cdot W_{kj} = -\sum_k \delta_k^{n+1} \cdot W_{kj} \\ \delta_j^n &= \left[\sum_k \delta_k^{n+1} \cdot W_{kj} \right] \cdot f'(net_j^n) \end{aligned} \quad (3.6.13)$$

如果轉換函數使用雙彎曲函數(sigmoid function)，則

$$f(\text{net}_j) = \frac{1}{1 + e^{-\text{net}_j}} \quad (3.6.14)$$

$$\text{則 } f'(\text{net}_j) = f(\text{net}_j) \cdot [1 - f(\text{net}_j)] \quad (3.6.15)$$

若 W_{ij} 連接的為輸出層，則

$$\delta_j^n = (T_j - A_j^n) \cdot A_j^n (1 - A_j^n) \quad (3.6.16)$$

若 W_{ij} 連接的為隱藏層，則

$$\delta_j^n = \left[\sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot H_j^n \cdot (1 - H_j^n) \quad (3.6.17)$$

其中， Y = 輸出層處理單元輸出值

H = 隱藏層處理單元輸出值

同理可證，

$$\Delta \theta_j = -\eta \cdot \delta_j^n \quad (3.6.18)$$

此學習過程通常以一次一個訓練範例進行，直到所有訓練範例皆輸入學習完畢，稱為一個學習循環(learning cycle)。一個網路可以將訓練範例反覆學習數個學習循環，直到網路收斂為止。當網路收斂後將結果輸出，則完成訓練過程，便可利用此一模型進行驗證、測試之過程，最後用來進行預測。

3. 倒傳遞網路常見重要參數設定

(1) 隱藏層層數

通常隱藏層之數目為一到二層時，有最好的收斂性質，太多或太少層其收斂結果則較差。若沒有隱藏層則不能反應此問題輸入變數間的交互作用，因而有較大的誤差；而更多的隱藏層，反而使網路過度複雜，使得修正網路加權值時更易掉入一誤差函數的局部最小值，而無法收斂。

(2) 隱藏層處理單元數目

通常隱藏層處理單元之數目越多收斂越慢，但可達到更小的誤差值。如果數目太少，不足以反映輸入變數間的交互作用，因而有較大的誤差。但超過一定數目後，對降低「訓練範例」誤差幾乎沒有幫助，徒增執行時間。一般而言，隱藏層處理單元數目的選取原則如下：

$$\text{公式一:}(\text{輸入層單元數}+\text{輸出層單元數})/2 \quad (3.6.19)$$

$$\text{公式二:}(\text{輸入層單元數}\times\text{輸出層單元數})^{1/2} \quad (3.6.20)$$

(3) 學習速率

學習速率太大或太小對網路的收斂性質均不利。較大的學習速率雖然可較快逼近函數最小值，但過大的學習速率將導致網路加權值修正過量，造成數值振盪而難以達到收斂。依據經驗取學習速率的值取在0.5或0.1到1.0間，大都可以得到良好的收斂性。

(4) 慣性項

通常可在學習公式加上一個慣性項，即加上某比例的上次加權值改變量，以改善收斂過程中振盪的現象及加速收斂。因此(3.6.10)(3.6.18)可改寫成

$$\Delta W_{ij}^m = \eta \cdot \delta_j^n \cdot A_i^{n-1} + \alpha \cdot \Delta W_{ij}^{m-1} \quad (3.6.21)$$

$$\Delta \theta_j^m = -\eta \cdot \delta_j^n + \alpha \cdot \Delta \theta_j^{m-1} \quad (3.6.22)$$

其中， ΔW_{ij}^m = 加權值 ΔW_{ij} 第 m 次改變量，其餘類推。

α = 慣性因子，控制慣性項之比例， $0 \leq \alpha \leq 1$ ，建議值0.5。

(5) 轉換函數

轉換函數的主要目的是將作用函數輸出值，轉換成處理單元的輸出，倒傳遞網路常用的非線性轉換函數有二：

a. 雙彎曲函數(sigmoid function)

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.6.23)$$

當自變數趨於正負無限大時，其函數值趨於常數，值域在[0,1]之間。

b. 正切雙彎曲函數(Hyperbolic tangent function)

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.6.24)$$

當自變數趨於正負無限大時，其函數值趨於常數，值域在[-1,1]之間。

綜觀上述探討，發現類神經網路不須事先建立模型，可直接藉由訓練的過程來找出輸入變數與輸出變數之間的關係，並且能夠處理變數間非線性複雜問題。因此本研究即採用類神經網路進行誤差之修正。

3.7 預測績效之評估指標

預測準確性係指衡量模型所得預測值與實際值間之誤差大小，藉以評估模型配適的好壞。本研究採用均方誤差(Mean Square Error, MSE)、均方根誤差(Root Mean Square Error, RMSE)、Theil's U(又稱Theil's Inequality Coefficient)及絕對平均誤差百分比(Mean Absolute Percent Error, MAPE)，來檢測模型預測值的準確性。各評估指標計算公式，茲說明如下：

1. 均方誤差(Mean Square Error, MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2 \quad (3.7.1)$$

其中， A_t 代表實際值， F_t 代表預測值， n 為期數。

MSE為預測誤差值平方和之平均，其特色為大的預測誤差會較小的預測誤差以不成比例地方式顯現，而MSE值愈小表示愈接近實際。

2. 均方根誤差(Root Mean Square Error, RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2} \quad (3.7.2)$$

RMSE為MSE之平方根，可將均方誤差放大之誤差經由平方根後，回歸至正常之誤差，如此可得到較為精確的比較基礎。

3. Theil's U(Theil's Inequality Coefficient)

$$U = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (F_t - A_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (F_t)^2 + \frac{1}{n} \sum_{t=1}^n (A_t)^2}} \quad (3.7.3)$$

其中 F_t 為第 t 期之預測值； A_t 為第 t 期之實際值； n 為期數。

Theil's U的分子稱為根均方誤差(RMSE)，係衡量模擬變數與它的時間路徑之偏離。Theil's U除上分母係為了使Theil's U值總是介於0與1之間，如果 $U=0$ ，對所有的 t ，則 $F_t=A_t$ 即有一個完美的配適，如果 $U=1$ ，模型的預測績效則相當不佳。Theil's U 衡量相對之誤差，其目的為求算每個預測誤差值達到最小，而非以預測差平均概念來衡量，因此當Theil's U值越小，表示其預測誤差和越小，預測能力越佳。

4. 絕對平均誤差百分比(Mean Absolute Percent Error, MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{F_t - A_t}{A_t} \right| \quad (3.7.4)$$

其中， A_t 代表實際值， F_t 代表預測值， n 為期數。

MAPE是以實際值為分母之相對數值，所代表為百分比，不受實際值與預測值的單位或大小之影響而產生比較基礎不穩固問題，能夠客觀的獲得估計值與評估值間之差異程度。若MAPE值越小，表示預測誤差越小，模型預測能力越佳。學者Makridakis(1993)指出平均絕對誤差百分比具有整合不同衡量指標的最佳特質，建議評估不同模型預測能力應以MAPE為準則，能提供決策者作為判斷依據。

第四章 實證分析與結果

本研究以台灣液晶顯示器面板銷售量為實證樣本，將蒐集之資料分為樣本內以及樣本外兩組，以樣本內資料進行時間序列以及灰色預測建模，並根據組合預測方法將兩者以權重組合，並對樣本外資料進行預測，而組合後之模型的誤差值則當作類神經網路的應變數進行倒傳遞類神經網路之預測，並導入影響需求量之因素為自變數，再對樣本外資料進行誤差項之預測，最後整合組合預測以及倒傳遞類神經網路之誤差預測，進行誤差修正，進而得到最後之預測值，並比較單一方法與本研究之組合方法之預測績效。

4.1 時間序列模型建構與分析

4.1.1 單根檢定

許多經濟或財務資料具有非定態的性質。當迴歸式的解釋變數為時間序列資料且為非定態，若直接進行傳統迴歸分析很容易造成解釋變數與被解釋變數間有顯著相關之假性迴歸結果(Granger and Newbold, 1974)，但實際上並非如此，因而產生錯誤研判。因此，在進行實證研究前，必須先作單根檢定，以確認變數資料是否為定態序列，據此再以時間序列模型進行分析與預測，其結果才有意義。

本研究利用統計軟體Eviews 5進行ADF單根檢定法，檢定本研究之樣本內資料是否存在單根，即為非定態數列，其檢定結果如下表4.1，顯示不同類型的ADF單根檢定皆無法拒絕存在單根的虛無假設，因此資料為非定態數列，必須採取差分方法以達到定態數列，如下表4.2皆顯示經過差分之後數列都拒絕存在單根之虛無假設，因此數列可藉由一階插分後轉為定態數列。本研究即採用一階插分之數列進行後續相關檢定程序。

表 4.1 原始時間序列單根檢定表

ADF單根檢定類型	t-statistic	P-Value	臨界值(1%)
無截距項及趨勢項	2.206370	0.9930	-2.599934
有截距項但無趨勢項	1.371909	0.9988	-3.531592
有截距項及趨勢項	-0.564872	0.9778	-4.100935

*為10%顯著水準；**為5%顯著水準；***為1%顯著水準

(資料來源：本研究整理)

表 4.2 一階差分後時間序列單根檢定表

ADF單根檢定類型	t-statistic	P-value	臨界值(1%)
無截距項及趨勢項	-6.991214***	0.0000	-2.597939
有截距項但無趨勢項	-7.570463***	0.0000	-3.525618
有截距項及趨勢項	-7.906603***	0.0000	-4.092547

*為10%顯著水準；**為5%顯著水準；***為1%顯著水準

(資料來源：本研究整理)

4.1.2 序列資料特性檢定

黃台心(2005)提到，對於某些近似指數成長的經濟變數，常會取自然對數轉換，經過轉換後會以近似線性方式成長，且本研究之資料之原始數據即呈現指數成長趨勢，如圖4.1，且根據經過一階差分後之數據的分布圖形可以看出，數列的特性具有變異數不穩定情況，如圖4.2，因此必須對數列進行對數轉換，如圖4.3。




圖 4.1 原始數據序列圖(資料來源：本研究整理)




圖 4.2 時間序列一階差分序列圖(資料來源：本研究整理)




圖 4.3 取自然對數後時間序列一階差分序列圖

(資料來源：本研究整理)

模型配適(AIC、SBC)

根據Box-Jenkins建立ARIMA模型步驟，進行模型的配適，而在選取模型準則上則採用AIC與SBC兩準則來選取可能最適模型，若AIC與SBC準則發生衝突，則以SBC準則為優先考量，而本研究根據所配適出之模式選出可能之ARIMA模式，在進一步進行可能模式殘差之估計。

表 4.3 時間序列模型配適表

ARIMA (p,d,q)	(1,1,1)	(1,1,2)	(1,1,3)	(2,1,1)	(2,1,2)	(2,1,3)	(3,1,1)	(3,1,2)	(3,1,3)
AIC	-126.40	-123.07	-121.36	-123.3	-123.34	-130.53	-122.37	-130.54	-128.79
SBC	-117.29	-111.69	-107.71	-111.92	-109.68	-114.59	-108.711	-114.61	-110.58

(資料來源：本研究整理)

本研究利用gretl軟體進行ARIMA模型的配適，其結果整理如表4.3所示，利用AIC與SBC值之最小值作標準來判斷，結果顯示，ARIMA(3,1,2)與ARIMA(1,1,1)模型較佳，而本研究採用SBC值最小為模型選取標準，故選用ARIMA(1,1,1)模型做為可能最適模式，以進行後續檢定與分析。

自我相關檢定與常態性檢定檢定

判斷序列為ARIMA(1,1,1)型態後，即以此模型對其均數迴歸方程式之殘差項是否符合白噪音，即以Q統計量檢定殘差項是否具有自我相關的現象，以及以Jarque-Bera統計量檢定殘差項是否符合常態分配。本研究以gretl軟體進行檢定。結果發現，Q檢定量顯示殘差已無自我相關，如圖4.4所示，且J-B檢定顯示殘差以符合常態分配，如圖4.5所示

殘差自我相關檢定

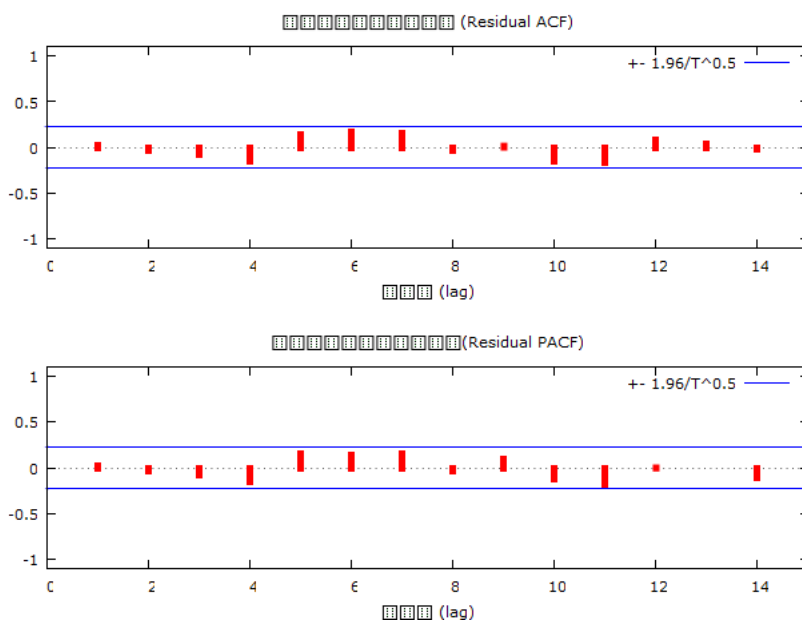


圖 4.4 殘差自我相關圖(資料來源：本研究整理)

殘差常態性檢定




圖4.5 殘差常態性檢驗圖(資料來源：本研究整理)

4.2 灰色預測模型建構與分析

4.2.1 滾動模型驗證

本研究根據所擷取之資料，以灰色建模方式建立預測模型，首先以樣本內資料投入灰色預測中，以滾動驗證模式來驗證以多少筆數據進行預測會得到較佳的結果，由於灰色預測的特性為以少量的資料，最少為四筆資料即可以進行預測，且得到不錯的結果，因此本研究即根據此，驗證四筆~十五筆資料，計算其建模預測精度，以得到最佳的建模資料數目，其結果如下表4.4所示，以11筆的資料建立模型所得到的預測精度最佳，因此本研究即採用11筆數據來對樣本外資料進行預測。

表 4.4 灰色預測滾動建模驗證表

筆數	4	5	6	7	8	9	10	11	12	13	14	15
精度 (%)	90.8	90.34	90.07	89.99	90.4	90.89	91.39	91.6	91.39	90.78	90.3	89.66

(資料來源：本研究整理)

而對於樣本外資料的預測，本研究即採用11筆的樣本數來進行下一筆的預測，接著在加入新的一筆的樣本，並將第一筆樣本捨棄，以新的11筆樣本進行預測，以此逐步預測到最後一筆數據，在此以預測前兩筆數據為例加以說明。

首先以樣本內之最後11筆數據來建立灰色預測模型，先將11筆數據累加生成，得到累加序列，

$$x^{(0)} = (26118, 26640, 25654, 22624, \dots, 26710, 23319, 29831)$$

$$x^{(1)} = (26118, 52758, 78412, 101036, \dots, 231959, 255278, 285109)$$

再由生成之累加數列求出個別之背景值

$$z^{(1)} = (\dots, 39438, 65585, 89724, \dots, 218604, 243618.5, 270193.5)$$

根據灰色預測之源模型求得待定係數 a 、 b

$$\begin{bmatrix} 26640 \\ 25654 \\ \dots \\ 29831 \end{bmatrix} = \begin{bmatrix} -39438, 1 \\ -65585, 1 \\ \dots \\ -270193.5, 1 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix}$$

以最小平方法求解可得到代定係數

$$a = -0.0119198056, b = 24074.0245908639$$

求得待定係數，並帶入由灰色差分計算出之響應式，並根據累減生成還原響應式，即可得到預測模型進行預測

$$x^{(0)}(k+1) = (1 - e^{-0.0119198056}) \left[x^{(0)}(1) - \frac{24074.0245908639}{-0.0119198056} \right] e^{(0.0119198056)(k)}$$

而所得到的預測值為 $x^{(0)}(12) = 27636.7459$

進行下一期之預測時，即加入最新一筆數據以及移除第一筆數據，因此原始數列即變更為

$$x^{(0)} = (26640, 25654, 22624, \dots, 26710, 23319, 29831, 25580)$$

進行預測後得到 $x^{(0)}(13) = 27656.3464$ ，以此類推進行剩餘之樣本外預測直到最後一筆資料為止。

4.3 組合模型建構與分析

J. M. Bates及Granger C.W.J認為，對於不同模型，應配合適當的線性組合權重進行組合，可得到較佳的結果，因此本研究採用針對兩種不同模型給予不同的權重方式加以組合，以期可以達到較小的預測誤差，而權重決定之方式即採用個別預測方法之預測誤差平方和，並建立非線性組合方程式，以求得適合個別模型的權重。

根據式3.5.6所敘述之非線性方程，本研究整理上述兩種預測方法在建模時所進行的樣本內預測驗證所得到的誤差平方和以及個別誤差相乘，如下表所示，因灰色預測採取11點建模的方式，因此所得數據為從第12筆開始到第73筆共62筆數據，故時間序列模式之預測誤差為配合資料之齊一性，亦採取最後62筆資料之預測誤差數據

表 4.5 不同預測方法之預測誤差整理表

預測方法	時間序列模式 (誤差平方)	灰色預測 (誤差平方)	兩種模式誤差相乘
總和	130819565.8	177120984.5	117463513.4

(資料來源：本研究整理)

以此三項數據代入式3.6.7並求解，即可得到權重大小，

$$\begin{cases} \min Z \\ s.t. \\ \omega_{Time} + \omega_{Grey} = 1 \\ \omega_{Time} \geq 0 \\ \omega_{Grey} \geq 0 \end{cases}$$

本研究使用Lingo 11軟體，對於其可求解非線性方程式之功能，來進行本研究之求解過程，經過求解之後所得到之個別權重分別為

$$\omega_{Time} = 0.8170743$$

$$\omega_{Grey} = 0.1829257$$

再根據此權重對於樣本內資料進行兩種預測模型之整合，可以針對樣本內資料得到一組全新之組合預測值，比較此組合預測值與真實值所得之誤差，即做為接下來倒傳遞類神經網路之應變數項，進行誤差之修正。

4.4 倒傳遞類神經模型建構與分析

類神經網路最主要的特性為擁有三項功能，學習、回想及歸納推演，藉此三項特性來改變它的行為模式及修正輸入與輸出的關係，因此本研究採用倒傳遞類神經網路模式，以影響液晶顯示器面板需求之因素為自變數，而組合預測之預測誤差為應變數，來預測樣本外資料可能的誤差值，以期能對本研究所建立之組合預測模型進行誤差的修正。

倒傳遞類神經網路之運作方式如下圖所示

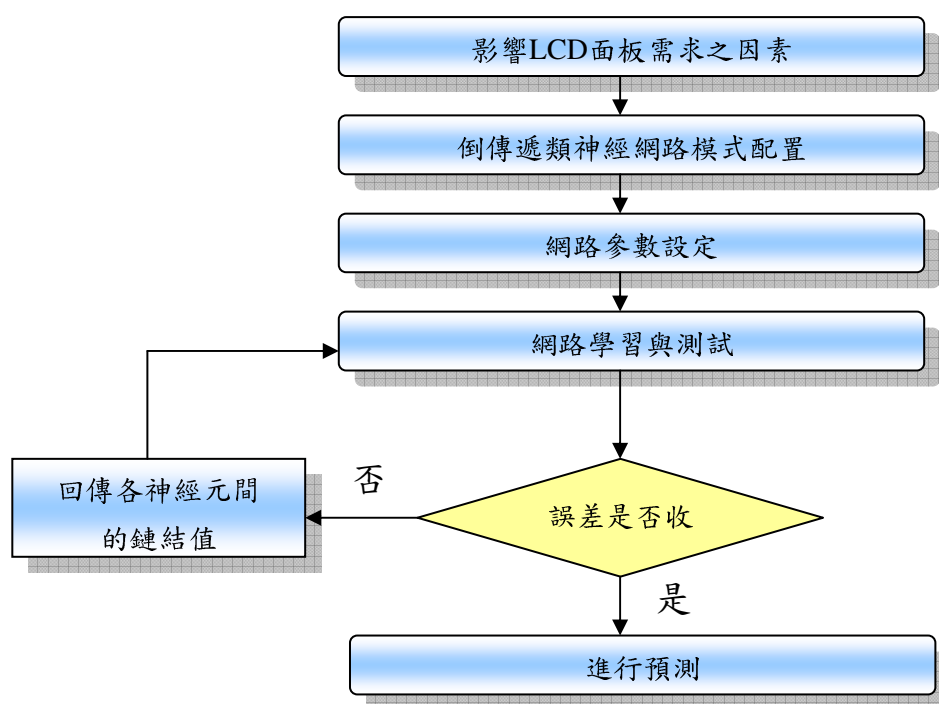


圖4.6 倒傳遞類神經網路運作流程圖(資料來源：本研究整理)

1. 模型輸出入變數的決定

本研究所採用之輸入變數為影響液晶顯示器面板需求之因素，如面板出口價格、美國景氣領先指標、歐元地區景氣領先指標、OECD領先指標、G7領先指標以及韓元兌台幣匯率等六項變數，而輸出變數為組合預測模型之樣本內誤差。

2. 選取隱藏層層數與神經元數目

通常隱藏層之數目為一層到二層時有最好的收斂性質，故本研究採取一層隱藏層之網路架構。而在隱藏層神經元數目方面，則採用一般算

數平均數法求得，即得 $(6+1)/2=3.5$ 個，本研究乃設定為4個神經元數目。

參數設定

本研究採用MATLAB 7.0應用軟體提供之Neural Network Toolbox模組進行倒傳遞類神經網路預測模型之建構與訓練。在BPN網路模型隱藏層與輸出層內之轉換函數皆採用正切雙彎曲函數，允許輸入變數與輸出變數間的非線性關係，並使網路輸出產生範圍在-1和1之間，因此在輸出變數上本研究必須先對其進行正規化動作，使其範圍落在-1和1之間。其在MATLAB7.0之Neural Network Toolbox模組中所使用的指令為tansig。而在訓練演算法方面，由於典型的倒傳遞訓練演算法容易收斂至局部最小值(Local Minima)且權值更新速率慢，學習時間長，另外，可能造成發散結果(趙景明、梁淑芳, 2006)。然而，目前類神經網路軟體工具箱已提供了許多高速率的演算法，因此本研究採用模組所提供快速訓練演算法Levenberg-Marquardt法，直接進行倒傳遞網路模型訓練，在Neural Network Toolbox模組中所使用的指令為trainlm，其訓練參數說明如表4.6所示。

表 4.6 類神經網路訓練參數設定表

訓練參數	內定值	描述
net.trainParam.epochs	1000	設定訓練的最大循環次數。
net.trainParam.goal	0	設定性能目標
net.trainParam.max_fail	5	設定最大驗證數據失敗次數
net.trainParam.mem_reduc	1	用於降低記憶體需求量的係數
net.trainParam.min_grad	1e-10	設定最小性能梯度
net.trainParam.mu	0.001	設定動量 μ 的初始值
net.trainParam.mu_dec	0.1	設定動量 μ 的減少係數
net.trainParam.mu_inc	10	設定動量 μ 的增加係數
net.trainParam.mu_max	1e-10	設定動量 μ 的最大值
net.trainParam.show	25	設定每隔多少訓練循環數目就顯示
net.trainParam.time	Inf	設定最大的訓練所需時間，單位為秒

(資料來源：本研究整理)

本研究直接利用MATLAB7.0應用軟體之Neural Network Toolbox模組進行倒傳遞類神經網路模型建構。依上述建構流程，配置之倒傳遞類神經網路模型包括輸入層、單層隱藏層和輸出層。其中，設定輸入層共6個處理單元(即八個輸入變數)、單層隱藏層共4個處理單元，和輸出層為1個處理單元(即一個輸出變數)。而在隱藏層與輸出層部分皆設定為非線性正切雙彎曲函數(MATLAB 7.0所使用的指令為tansig)來計算該層神經元的輸出。而本研究配置之倒傳遞類神經網路架構如圖4.7所示：

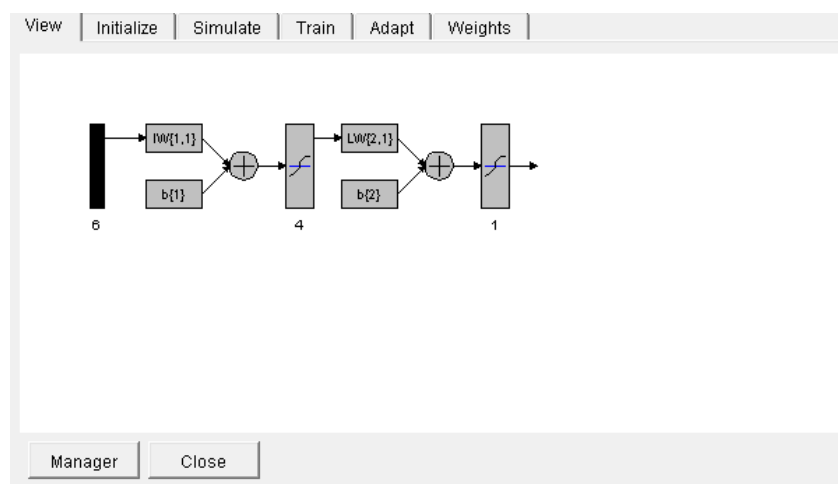


圖4.7 倒傳遞類神經網路架構圖(資料來源：本研究整理)

本研究進一步利用模組中快速訓練演算法Levenberg-Marquardt訓練法進行資料之訓練，其各網路參數設定如上述介紹，而經過1000次訓練結果可顯示訓練誤差已達收斂效果，如圖4.8所示，顯示本研究配置之倒傳遞類神經網路模型建構得宜。

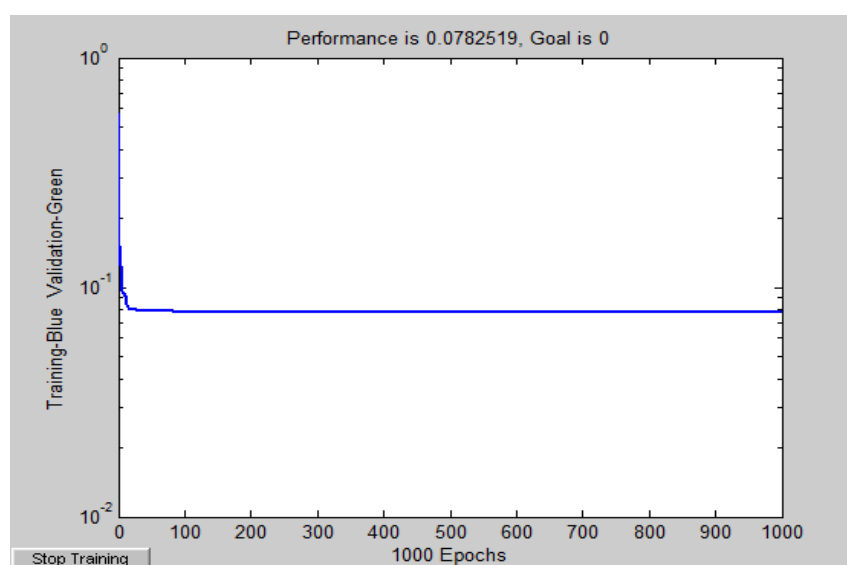


圖4.8 倒傳遞類神經網路訓練結果圖(資料來源：本研究整理)

因此本研究即採用此模型對於樣本外之資料(2007/2至2009/1共24筆)進行其誤差之預測。

4.5 模型之驗證與比較

本研究採用組合預測之模式，以不同的權重結合時間序列(ARIMA)模型以及灰色預測模型，並以類神經網路進行其誤差的預測，藉此建立誤差修正模式，所採用的樣本內資料為2001年1月至2007年1月共73筆資料進行組合預測之建模以及倒傳遞類神經網路之誤差預測建模，並在誤差修正後，對樣本外資料2007年2月至2009年1月進行驗證，驗證方式則採用MSE值、RMSE值、Theil's U值以及MAPE值進行比較，整理如表4.7所示。

表 4.7 組合預測方法與單一預測方法之績效評比表

	MSE	RMSE	Theil's U	MAPE
時間序列模型	46133155.05	6792.13921	0.0783	0.134839
灰色預測模型	99308924.1	9965.3863	0.11472	0.2047
組合預測模型	41319975.85	6428.061594	0.074671	0.132732

(資料來源：本研究整理)

由上表4.7可以得知，組合預測模型所得之預測準確度皆高於單一方法之預測模式，其次為時間序列模式，而以灰色預測模式之預測準確度較為不佳，而以下圖 所示，組合預測確實有較單一預測方法較為貼近真實值之數列分布。




圖4.9 不同預測方式比較圖(資料來源：本研究整理)

4.6 大尺寸及中小尺寸之應用

在液晶顯示器面板之應用上，主要可以分為大尺寸面板以及中小尺寸面板兩種不同之領域，主要是以10寸為分界，大於等於10寸之面板稱為大尺寸面板，而小於10寸以下之面板則稱為中小尺寸面板，本研究也根據上述之分類，對此兩類別分別以相同之樣本數，對本研究所建構之組合預測模式之適用性進行探討

4.6.1 中小尺寸面板

針對中小尺寸面板之需求量探討，其時間序列預測模式建構如下表4.8，是以ARIMA(1,1,1)模式較為適切，因此本研究即針對中小尺寸面板之需求以時間序列ARIMA(1,1,1)進行預測，而在灰色預測建模方面，中小尺寸面板在樣本內資料建模以四筆之資料建模其精確度較為優良，因此本研究在灰色預測建模上即採用四筆資料建模，而所得之兩種預測方法之誤差平方以及兩種方法之誤差相乘整理如表4.10，並將其投入所建構之非線性方程式中，可求出兩者之權重分別為 $\omega_{Time} = 0.8271507$ ， $\omega_{Grey} = 0.1728493$ ，再以此權重所組合之組合預測計算誤差並投入倒傳遞類神經網路學習預測樣本外誤差，所得之預測績效整理如表4.11，可以得到組合預測之績效比其餘兩者單一方法較為優良。

表 4.8 中小尺寸面板之時間序列模型配適表

ARIMA (p,d,q)	(1,1,1)	(1,1,2)	(1,1,3)	(2,1,1)	(2,1,2)	(2,1,3)	(3,1,1)	(3,1,2)	(3,1,3)
AIC	1.27	2.54	3.53	2.33	3.98	5.36	3.58	5.57	2.67
SBC	10.37	13.92	17.19	13.71	17.64	21.3	17.24	21.5	20.89

(資料來源：本研究整理)

表 4.9 中小尺寸面板之灰色預測滾動建模驗證表

筆數	4	5	6	7	8	9	10	11	12	13	14	15
精度 (%)	78.79	78.47	76.34	75.18	74.98	75.64	75.81	75.59	75.17	74.28	74.16	74.00

(資料來源：本研究整理)

表 4.10 中小尺寸面板之不同預測方法預測誤差整理表

預測方法	時間序列模式 (誤差平方)	灰色預測 (誤差平方)	兩種模式誤差相乘
總和	112298296.3	227496553.3	81865931.1

(資料來源：本研究整理)

所得權重如下：

$$\omega_{Time} = 0.8271507$$

$$\omega_{Grey} = 0.1728493$$

表 4.11 中小尺寸面板之組合預測與單一方法之預測績效比較表

	MSE	RMSE	Theil's U	MAPE
時間序列模型	44893117.03	6700.23261	0.10441	0.199469244
灰色預測模型	49248791.34	7017.74831	0.11259432	0.1788161
組合預測模型	29906103.7	5468.64734	0.08737173	0.156457436

(資料來源：本研究整理)

4.6.2 大尺寸面板

在大尺寸面板之需求量方面，本研究亦建構時間序列模型以及灰色預測模型，在時間序列模型中以ARIMA(1,1,1)較為適配，如表4.12，而灰色預測模型之滾動建模驗證中顯示以四筆數據進型建模所得之準確度最高，如表4.13，因此針對大尺寸面板本研究即採用ARIMA(1,1,1)以及灰色四筆建模方式進行預測，而在建立組合預測模型上，在經過非線性規劃模型計算出權重後發現，灰色預測之誤差遠大於時間序列模型之誤差，因此權重上顯示為 $\omega_{Time} = 1$ ， $\omega_{Grey} = 0$ ，表示大尺寸面板的需求預測上，以時間序列模式進行預測即可達到誤差最小之效果，因此本研究即採用時間序列模式搭配倒傳遞類神經網路進行誤差修正模式進行預測，並與單一方法進行預測績效比較，其結果顯示，針對大尺寸面板方面，雖只使用時間序列以及倒傳遞類神經之組合方式，但是仍可以降低誤差，提升預測準確度，其組合預測模式之準確度驗證皆優於單一方法

表 4.12 大尺寸面板之時間序列模型之配適表

ARIMA (p,d,q)	(1,1,1)	(1,1,2)	(1,1,3)	(2,1,1)	(2,1,2)	(2,1,3)	(3,1,1)	(3,1,2)	(3,1,3)
AIC	-113.04	-111.325	-109.45	-108.47	-109.86	-110.32	-108.72	-110.32	-108.69
SBC	-103.93	-99.94	-95.79	-97.09	-95.52	-94.39	-95.06	-94.39	-90.47

(資料來源：本研究整理)

表 4.13 大尺寸面板之灰色預測滾動建模驗證表

筆數	4	5	6	7	8	9	10	11	12	13	14	15
精度 (%)	90.43	90.22	89.99	90.17	89.95	89.66	89.45	89.07	88.55	88.15	87.92	87.19

(資料來源：本研究整理)

表 4.14 大尺寸面板之不同預測方法預測誤差整理表

預測方法	時間序列模式 (誤差平方)	灰色預測 (誤差平方)	兩種模式誤差相乘
總和	32772041.2	54589040.32	35297150.8

(資料來源：本研究整理)

所得權重如下：

$$\omega_{Time} = 1$$

$$\omega_{Grey} = 0$$

表 4.15 大尺寸面板之組合預測與單一方法之預測績效比較表

	MSE	RMSE	Theil's U	MAPE
時間序列模型	2371501.52	1539.968	0.060464	0.10007
灰色預測模型	2664810.255	1632.424	0.064896	0.11554901
組合預測模型	1788038.657	1337.175627	0.05	0.090554059

(資料來源：本研究整理)

第五章 結論與建議

5.1 研究結論

目前全球液晶顯示器面板生產主要以台灣和韓國為主，且政府也對面板產業非常重視，可謂液晶顯示器面板產業目前已是台灣具有代表性之高科技產業，而需求不確定性高為高科技產業之一大特點，若是需求預測無法提供一個好的參考價值，勢必會造成存貨、缺貨成本之增加，而自2008年以來，全球金融風暴爆發，面板銷費主要出口國之歐美地區之需求疲弱，因此造成需求之更加不確定，加上台灣之主要競爭國，韓國，刻意讓韓元維持弱勢刺激出口成長，造成我國之面板產業之競爭壓力，因此建立一個準確且可以依據各種情勢進行修正之需求預測模型即突顯其重要性。

在需求預測的領域之中，主要可以分為定性以及定量方法兩種，定性方法如專家預測法、德爾菲法等，大都透過訪談專家進行未來趨勢的預測，往往缺乏數學模式之驗證，容易流於不客觀。而定量方法即根據歷史數據進行數學模式之建立，較為客觀，且若是將不同之預測方法以不同權重進行組合，通常都可以得到較單一方法優良的結果，因此本研究透過量化方法之時間序列以及灰色預測模型進行組合，並以類神經網路來進行誤差修正，以期能更適切台灣之液晶顯示器面板產業。

本研究即採用2001年1月至2009年1月之液晶顯示器面板之銷售量進行分析，分為樣本內資料以及樣本外資料，根據樣本內資料，投入時間序列模型以及灰色預測模型進行預測，以不同之權重加已組合，形成一組新的預測值，並與實際值比較計算誤差，做為類神經網路之預測標的，並把影響液晶顯示器面板之六項因素投入類神經網路中進行學習、預測，根據建立之模型進行樣本外資料誤差之預測，並與組合預測方法之樣本外預測值進行相加達到誤差修正的效果。

經過實際數據驗證本研究所建立之預測模式之後，所得到之結論可以整理如下：

1. 本研究採取2001年1月至2009年1月之面板銷售量進行實證分析，根據績效評判準則MSE、RMSE、Theil's U以及MAPE值都顯示，組合預測模式合併誤差修正模式之預測績效確實優於單一預測方法。

2. 在中小尺寸面板之應用上，經由組合預測所得到的結果均顯示組合預測之績效較為優良，並可得到較整體產業誤差較小之結果。
3. 在大尺寸面板之應用上，灰色預測之準確度過小，導致誤差過大，因此建議採用時間序列模式加上類神經網路進行誤差修正即可得到優於單一預測方法之預測績效

5.2 未來研究建議

本研究所建立之預測模式，雖於液晶顯示器面板產業之資料範圍內驗證得到不錯的績效，但對於未來之研究仍有許多需要改進以及不同領域之研究方向可以考慮，本研究整理如下：

1. 本研究僅針對台灣液晶顯示器面板之需求量進行組合預測之模型驗證，未來研究可進一步針對全球液晶顯示器面板之需求，亦或是單一液晶顯示器面板公司之需求進行預測。
2. 本研究針對台灣液晶顯示器面板產業進行組合預測之適用性探討，未來研究可將類似組合預測模型，針對不同性質、不同領域之產業進行驗證比較。
3. 本研究僅採用時間序列、灰色預測以及倒傳遞類神經模式進行預測，未來研究者可根據本研究之預測模式，以不同之預測方法來進行預測驗證。
4. 本研究在進行組合預測為採用時間序列以及灰色預測，緊接著在以類神經網路進行誤差之修正，未來之研究可嘗試不同之組合方式，以期獲得更佳之預測績效。

參考文獻

一、中文部分：

- 王瓊敏，2000。電腦關鍵零組件之價格預測模式，國立中央大學工業管理研究所碩士論文。
- 吳漢雄、鄧聚龍、溫坤禮，1996，灰色分析入門，高立出版社。
- 呂柏賢，2000。灰色需求預測模式之研究—以易腐性商品為例，東海大學工業工程研究所碩士論文。
- 呂珊茹、林啟文、洪士賢、林國顯，2006。機車HC排放之迴歸與時間序列分析-以南投縣為例，科學與工程技術期刊，第二卷第二期，29-35。
- 李智明，2004。單期季節性商品之需求預測投資預算-使用貝氏估計法，交大管理學報，第二十四卷第二期，37-60。
- 邢治宇，2008。基於迴歸方法與灰色模式的能源消費預測比較之研究，石油季刊，第四十四卷第二期，83-94。
- 周鵬程，2002。類神經網路入門，初版，全華圖書。
- 林茂文，2006。時間數列分析與預測:管理與財經之應用，三版，華泰文化。
- 春日井博，1988，需求預測入門，書泉出版社。
- 施正宏，2004。結合總體經濟指標及個股財報資料以預測個股漲跌-以台灣電子類股為例，中原大學資訊管理學系碩士論文。
- 洪麗珠，2006。灰色預測與計量經濟模式預測比較研究，管理科學與統計決策，第三卷第四期，66-79。
- 張盛鴻等譯，2000。生產計畫與管理，二版二刷。，高立出版。譯自Fogarty Blackstone Hoffmann 1991.Production & Inventory Management 2/e.
- 張斐章、張麗秋，2005，類神經網路，初版，東華書局。
- 曹銳勤，2004。股票投資規劃與分析-以上市銀行股票為例，玄奘管理學報，第一卷第二期，1-16。
- 郭秀敏，2004。模糊倒傳遞網路於印刷電路板生產預測之應用，元智大學工業工程與管理學系研究所碩士論文。
- 陳杏圓、王焜潔，2007。人工智慧，初版，高立圖書。
- 陳沛霖，2009。2008年台灣平面顯示器產業回顧，光連雙月刊，第七十九期，33-37。
- 陳執中，2006。台股加權指數隔月收盤價預測之研究。國立成功大學統計學系碩士論文。
- 陳淑真、陳雅慧、王樹人、黃喬次，2009。整合ARIMA需求預測與存補貨政策之RFID-Enabled供應鏈效益模擬，建國科大學報，第二十八卷第二期，81-98。
- 陳赫廷，2006。台灣大尺寸TFT-LCD面板產業出口供需探討，國立成功大學國際企業研究所碩士論文。
- 陳耀茂，2004。時間序列分析的SPSS使用手冊，初版，鼎茂圖書。

- 曾俊洲，2009。金融風暴引發亞洲顯示器面板產業之消長，台經月刊，第三十二卷第四期。
- 黃台心，2006。計量經濟學，初版二刷，雙葉書廊。
- 黃惠民、黃文昌、王孔政，2008。公司營運業績有效預測模型-X公司案例，先進工程學刊，第三卷第三期，225-234。
- 黃黎平、樂娟，2005。時間序列在銷售量預測中的應用分析，商場現代化，x卷四四五期，67-68。
- 楊奕農，2006。時間序列分析經濟與財務上之應用，初版三刷，雙葉書廊。
- 溫坤禮、張簡士琨、葉鎮愷、王建文、林慧珊，2007。MATLAB在灰色系統理論的應用，初版，全華圖書。
- 溫坤禮、黃宜豐、陳繁雄、李元秉、連志峰、賴家瑞，2002。灰預測原理與應用，初版，全華圖書。
- 葉怡成，2003。類神經網路模式應用與實作，八版，儒林圖書。
- 鄭佳欣，2008。隨機指標(KD)於匯率預測有效性之研究，東海大學工業工程研究所碩士論文。
- 鄭美幸、詹志明，2002。灰色理論與時間序列模形在匯率預測機效上之比較，台灣金融財務季刊，第三卷第二期。
- 鄭淑梅，2007。市場銷售的灰色預測方法，荊門職業技術學院學報，第二十二卷第六期，65-68。
- 黎鑑輝，2007。機車市場銷售預測實證研究，長庚大學企業管理研究所在職專班碩士論文。
- 羅志明、詹宗學、黃營芳，2006。應用灰色預測理論、迴歸分析、指數平滑法於預測台灣TFT-LCD出口值，工程科技與教育學刊，第五卷第一期，120-140。
- 羅華強，2005。類神經網路:MATLAB的應用，二版，高立圖書。
- 龔旭陽、顧浩翔、林靖祐、蔡光榮，2005。土石流災害數值預測模式之分析與研究，交大管理學報，第二十五卷第二期，109-140

二、英文部分：

- Bates J. M., Granger C. W. J., 1969. The Combination of Forecasts., *Operational Research Quarterly*, 20, pp.451-468.
- Charu Chandra and Janis Grabis, 2005. Application of Multi-Steps Forecasting for Restraining the Bullwhip effect and Improving Inventory Performance Under Autoregressive Demand, *European Journal of Operational Research*, 166, pp.337-350.
- Fang-Mei Tseng, Hsiao-Cheng Yu, and Gwo-Hsiung Tzeng, 2001. Applied Hybrid Grey Model to Forecast Seasonal Time Series, *Technological Forecasting and Social Change*, 67, pp.291-302.
- Frederick H. deB, Harris, James R., McGuigan & R. Charles Moyer, 2004. *Managerial Economics: Application, Strategy, and Tactics*.
- G. Peter Zhang, 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, *Neurocomputing*, 50, pp.159-175.
- Granger, C. and Newbold, P., 1974. Spurious regression in econometrics. *Journal of Econometrics*, 2(2), pp.111-120.
- James T. Luxhoj, Jens O. Riis, Brian Stensballe, 1995. A Hybrid Econometric-Neural Network Modeling Approach for Sales Forecasting. *Int. J. Production Economics*, 43, pp.175-192.
- Jully Jeunet, 2006. Demand Forecast Accuracy and Performance of Inventory Policies Under Multi-Level Rolling Schedule Environments, *Int. J. Production Economics*, 103, pp.401-419.
- Kevin K. F., 2007. Tourism Forecasting: To Combine or Not to Combine?, *Tourism Management*, 28, pp.1068-1078.
- Li-Chang Hsu, 2003. Applying the Grey Prediction Model to The Global Integrated Circuit Industry, *Technological Forecasting & Social Change*, 70, pp.563-574.
- Luis Aburto, Richard Weber, 2007. Improved supply chain management based on hybrid demand forecasts, *Applied Soft Computing*, pp.136-144.
- Mingzhi Mao, and E. C. Chirwa, 2006. Application of Grey Model GM(1,1) to Vehicle Fatality Risk Estimation, *Technological Forecasting & Social Change*, 73, pp.588-605.
- Ralf Becker, and Adam E. Clements, 2008. Are Combination Forecasts of S&P 500 Volatility Statistically Superior, *International Journal of Forecasting*, 24, pp.122-133.
- Wemmerlov U, 1989. The Behavior of Lot-Sizing Procedures in the Presence of Forecast Errors, *Journal of Operations Management*, 8, pp.37-48.
- Ye Yao, Zhiwei Lian, Zhijian Hou, Weiwei Liu, 2006. An Innovative Air-Conditioning Load Forecasting Model Based on RBF Neural Network and Combined Residual Error Correction, *International Journal of Refrigeration*, 29, pp.528-538.
- Ye-Qun Chen, Xiao-Jun Chen, Xian-Xi Huang and Xue-Rui Tan, 2008. Application and Selection of Grey Model in The Medical Management, *Journal of Grey System*, 11(4), pp.193-198.
- Zhi-Jie Zhou, Chang-Hua Hu., 2008. An Effective Hybrid Approach Based on Grey and ARMA for Forecasting Gyro Drift. *Chaos, Solitons and Fractals*. 35, pp.525-529.