

# 以知識規則與類神經網路之整合對台灣加權股價指數收盤

## 走勢預測之行為研究

學生：洪安裕

指導教授：陳安斌、林富松

國立交通大學管理科學系碩士班

### 摘 要

試圖在股市或是衍生性金融商品中投資獲利者不可不重視大盤趨勢的變化，然而影響指數的因素極為廣泛，對於如此大量且複雜的資訊，實非一般投資人可以輕易掌握的。近年來，拜資訊科技快速發展之賜，人工智慧應用於財務金融領域變得可行，它的優點是可以只利用少量且不足的資訊，針對非結構化的問題於複雜的空間中求得有效解。

本研究使用：1.非現貨交易時段之指數資訊；2.股市與期貨的原始交易資料變數；3.國際股市的漲跌變化；4.技術分析指標等四大類輸入資料變數，利用類神經網路工具建構台灣加權指數當日收盤漲跌預測模型與隔  $n$  日收盤漲跌預測模型，然後與同一段時間之內採取多元迴歸模式進行優劣比較，進一步選取最適之預測模型，並依據預測結果建立台股期貨當沖買賣交易策略。

在資料樣本方面，訓練期資料期間為 2002 年 5 月 1 日至 2004 年 7 月 31 日共計 492 個交易日；測試期資料期間為 2004 年 8 月 1 日至 2004 年 10 月 31 日共計 52 個交易日。實證結果發現類神經網路模型預測當日收盤漲跌的 MSE 為 0.0999，RMSE 為 0.3161，預測方向準確率為 73.0769%；而多元迴歸模型的 MSE 為 0.1685，RMSE 為 0.4105，預測方向準確率為 65.3846%。依據預測結果所建立之台股期貨交易策略，扣除交易成本而計算實證測試期的報酬，在 52 個日交易天數中，有高達 287 點的指數期貨報酬的和 262.8205% 的年報酬率。

本研究成果為：1.使用四大類輸入變數，較能完整掌握影響台股指數之因素；2.縮短模型預測天數，可用於短線交易。並將此類神經網路模型的預測績效與傳統多元迴歸模式相比較，實證結果顯示類神經網路模型不論是在預測收盤漲跌點數或是漲跌方向上，其預測能力皆優於多元迴歸模型。

關鍵字：類神經網路、多元迴歸、台股加權股價指數

# **A Behavioral Study of Combining Knowledge Rules and Neural Networks to Forecast the Intraday Trend of TAIEX**

Student: An-Yu Hung

Advisor: Dr. An-Pin Chen

Dr. Fu-Sung Lin

Department of Management Science  
National Chiao Tung University

## **Abstract**

For those who try to profit from the stock or the derivative market, the fluctuation of the benchmark can never be left behind. The factors that could affect such movements may not be easy to probe into. Thanks to the contemporary technology. Nowadays, with the applications of artificial intelligence in the financial field, such movements in the both stock and derivative market are converted into insight from foresight.

This study makes use of the followings: 1. the index information from the non-trading period; 2. the raw data from the both stock and future markets; 3: the fluctuation in the international stock market; 4: the technical analysis. These four changing factors will be exported into the neural network with the purposes of predicting the daily closing price and the closing price in n days. These will be compared to the multiple regression model. Non-dominated model will be picked among these three and suitable trading strategies will be developed accordingly.

As far as the data sample is concerned, the data of training period is from 2002/5/1 to 2004/7/31, which sums up to 492 trading days; while the data of testing period is from 2004/8/1 to 2004/10/31, which sums up to 52 trading days. The results show that the MSE of neural network is 0.0999 and the RMSE of neural network is 0.3161. The accuracy is 73.0769%. While the MSE of multiple regression is 0.1685 and the RMSE of multiple regression is 0.4105. The accuracy is 65.3846%. The TAIEX futures transaction strategy is constructed according to the forecasting results. After subtracting the transaction fee in 52 trading days, the profits are as high as 287 points at TAIEX futures and the annual return is 262.8205%.

This study reveals a couple findings: One is that when incorporating four changing factors stated above, one could possibly get hold of momentum from TAIEX; second is that by shortening the forecasting periods, intraday transactions will be enabled. Lastly, according to the experiment results, the neural network performs better in every presumed spectrum such as up-or downward movement in the stock market or the closing points in TAIEX.

Keywords: Artificial Neural Networks, Multiple Regression, TAIEX

## 誌 謝

經過兩年碩士班生涯的專業訓練與師長們的盡心指導，安裕終於順利完成此篇，心中充滿著無限的感激與喜悅。

首先，安裕要感謝兩位熱心的指導教授，交大資訊管理所陳安斌所長與管理科學所林富松博士一年來耐心地教導與指引，讓安裕對財金領域之人工智慧應用有更深入之認識與了解，並獲得研究所需之相關知識，此外，也感謝寶碩財務科技公司給安裕實習之機會，讓安裕藉由實習的過程，得到撰寫碩士論文所需之資料，並了解實務界操作金融之作法與理念，讓安裕可更加完善、快速的解決撰寫期間所遭遇問題，如期完成本篇碩士論文。論文口試時，承蒙徐怡老師與何淑熏老師仔細地審閱與指導，使本篇論文益臻完善。謹此對各位師長致上由衷感謝。

安裕也要感謝父母親、家人不斷地關懷與支持，你們的關心是安裕研究所生涯中最大的精神支柱。

洪安裕 謹致於

交大博愛校區管理科學系碩士班

中華民國九十四年六月

# 目 錄

摘 要 .....	I
Abstract .....	II
誌 謝 .....	III
目 錄 .....	IV
圖目錄 .....	V
表目錄 .....	VI
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 研究對象與範圍.....	4
1.4 研究流程.....	8
第二章 文獻探討 .....	10
2.1 國際股市股價波動之傳導效果.....	10
2.2 股價指數期貨與現貨市場之連動關係.....	13
2.3 技術分析理論.....	17
2.4 類神經網路於財務金融領域之相關應用.....	22
第三章 研究方法 .....	28
3.1 研究架構.....	28
3.2 類神經網路原理及架構.....	32
3.3 倒傳遞類神經網路模式.....	36
3.4 交易策略.....	40
第四章 實證研究分析 .....	42
4.1 當日收盤漲跌預測模型分析.....	43
4.2 隔n日收盤漲跌預測模型分析.....	50
4.3 多元迴歸預測模型分析.....	65
4.4 不同模型預測結果之比較.....	69
4.5 交易報酬分析.....	71
第五章 結論與建議 .....	74
5.1 結論.....	74
5.2 研究貢獻.....	76
5.3 後續研究建議.....	77
參考文獻 .....	79

## 圖目錄

圖 1-1	研究流程圖 .....	9
圖 3-1	研究架構圖 .....	31
圖 3-2	人工神經元之模型 .....	34
圖 3-3	倒傳遞類神經網路架構 .....	37
圖 4-1	資料樣本區間之劃分說明 .....	42
圖 4-2	訓練期資料之性能績效測試 .....	47
圖 4-3	預測當日收盤漲跌之散佈圖 .....	48
圖 4-4	預測當日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	49
圖 4-5	預測隔 1 日收盤漲跌之散佈圖 .....	51
圖 4-6	預測隔 1 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	52
圖 4-7	預測隔 2 日收盤漲跌之散佈圖 .....	54
圖 4-8	預測隔 2 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	54
圖 4-9	預測隔 3 日收盤漲跌之散佈圖 .....	56
圖 4-10	預測隔 3 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	56
圖 4-11	預測隔 4 日收盤漲跌之散佈圖 .....	58
圖 4-12	預測隔 4 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	58
圖 4-13	預測隔 5 日收盤漲跌之散佈圖 .....	60
圖 4-14	預測隔 5 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	60
圖 4-15	預測隔 10 日收盤漲跌之散佈圖 .....	62
圖 4-16	預測隔 10 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	62
圖 4-17	預測隔 20 日收盤漲跌之散佈圖 .....	64
圖 4-18	預測隔 20 日收盤漲跌之目標輸出值與推論輸出值走勢圖 .....	64
圖 4-19	迴歸分析預測模式之散佈圖 .....	68
圖 4-20	迴歸分析預測模式之目標輸出值與推論輸出值走勢圖 .....	68
圖 4-21	投組淨值與大盤走勢比較圖 .....	73
圖 4-22	日報酬率變動圖 .....	73

## 表目錄

表 1-1	台灣證券交易所股價指數期貨契約規格	6
表 3-1	台灣指數期貨相關交易成本	41
表 4-1	預測現貨當日收盤漲跌點數之輸入、輸出變數表	44
表 4-2	不同隱藏層處理單元數目之MSE與RMSE	46
表 4-3	倒傳遞類神經網路參數之設定	46
表 4-4	訓練期與測試期資料之MSE與RMSE	48
表 4-5	預測當日收盤漲跌方向之結果	50
表 4-6	預測隔 1 日之MSE與RMSE	51
表 4-7	預測隔 1 日收盤漲跌方向之結果	53
表 4-8	預測隔 2 日之MSE與RMSE	53
表 4-9	預測隔 2 日收盤漲跌方向之結果	55
表 4-10	預測隔 3 日之MSE與RMSE	55
表 4-11	預測隔 3 日收盤漲跌方向之結果	57
表 4-12	預測隔 4 日之MSE與RMSE	57
表 4-13	預測隔 4 日收盤漲跌方向之結果	59
表 4-14	預測隔 5 日之MSE與RMSE	59
表 4-15	預測隔 5 日收盤漲跌方向之結果	61
表 4-16	預測隔 10 日之MSE與RMSE	61
表 4-17	預測隔 10 日收盤漲跌方向之結果	63
表 4-18	預測隔 20 日之MSE與RMSE	63
表 4-19	預測隔 20 日收盤漲跌方向之結果	65
表 4-20	迴歸預測模式之 $\beta$ 估計表	66
表 4-21	迴歸分析預測模式之變異數分析表	67
表 4-22	迴歸分析預測模式之MSE與RMSE	68
表 4-23	迴歸分析預測模式預測漲跌方向之結果	69
表 4-24	不同模型測試期間之MSE與RMSE	70
表 4-25	不同模型預測漲跌方向之準確率	70
表 4-26	交易報酬統計表	72
表 4-27	獲利與損失比較表	72
表 4-28	交易報酬分析表	72

# 第一章 緒論


## 1.1 研究背景與動機

近年來全球各國利率不斷走低，以銀行定存利率扣除通貨膨脹所得出的實質利率，有時甚至呈現負利率，可見以往儲蓄理財的方式已漸不適用，亦即身處低利率時代，人們究竟可如何進行財富管理已漸漸成為一項重要的課題。此外，隨著台灣經濟的發展、國民所得的提高以及台灣金融投資市場的蓬勃發展，市面上可供選擇的金融商品琳瑯滿目，舉凡債券、基金、股票、期貨和選擇權等都是目前極為熱門的投資標的物，民眾除可以定存或是購買債券等較為保守的方式來進行投資外，較為積極者亦通常會選擇將資金投入於股市或其他相關之衍生性金融商品中，而在此趨勢下，無論是專業的投資經理人或是一般的投資散戶，皆期待可透過有效、迅速的效掌握台灣加權指數的漲跌趨勢，來規避投資風險進而獲得超額報酬，換言之，如何有效投資理財已是深處低利時代下的民眾不可不接觸、因應的課題。

試圖在股市或是衍生性金融商品中投資獲利者不可不重視其指數與股價的趨勢，然而影響指數與股價的因素極為廣泛，舉凡總體經濟、產業發展、國際股匯市、政治面、公司基本面、技術面、心理面、籌碼面，甚至消息面都可能造成指數和股價的大幅波動。對於如此大量且複雜的資訊，實非單一專家或是個別投資散戶可在短時間內加以整理分析，進而完全掌握的，此外，對大多數投資人來說，雖可閱讀屬於落後資訊的財務報表，但若期待再藉由即時了解影響財務狀況變動的所有因素來增加報酬率卻有一定的難度，然而，這些因素卻皆是影響金融市場交易狀況的重要因素，所以本論文試圖透過技術分析、台灣加權指數與期貨

指數之原始交易資料的變數探討、國際股市的漲跌變化和股價行為的研究，進而建立一套有效率且準確的預測模型，除可做為投資人於投資決策時的輔助系統，協助其迅速、有效率的掌握台灣加權指數的漲跌趨勢以獲取超額報酬。

八〇年代末期以來，拜資訊科技突飛猛進與電腦技術快速發展之賜，除了使電腦原本的運作效率大幅提高之外，許多需藉由電腦快速運算才得以進行的研究也變得可行，而在財務金融的相關領域中，許多運用人工智慧工具的研究與發展也正快速的增加中，此外，許多學者與研究也持續的積極探討人工智慧應用於此領域的可行性。人工智慧的優點便是可以只利用少量且不足的資訊，針對非結構化的問題於複雜的空間中求得有效解，然而，其輸入的資訊必須具備有效性，才可透過人工智慧的方式進行準確的預測、創造超額報酬。



在目前市面上許多的人工智慧模型中，類神經網路是解決非結構化問題最適切的方式之一。類神經網路是一種計算系統，包括軟體和硬體，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，過程中透過大量的平行運算處理，快速擷取現行資訊，並從過去樣本資料中學習型態辨認的能力，而達到知識累積與知識呈現的目的（Turban，1995）。因此，發展類神經網路系統做為股市交易投資決策的輔助工具，實為一項可行、有意義且具有挑戰性的研究方向。而其在財務金融領域的應用，除已有部分學者專家利用股市之價量關係或是技術指標，以預測其未來價格之走向外，亦有人根據總體經濟面的變化，以類神經網路來研判未來股市的走向（陳安斌，2002）。

綜合過去應用類神經網路於財務金融領域之相關文獻可以發現：(1) 以往用於預測股票或是期貨市場走勢之研究大多以技術分析指標、基本分析之經濟指



標、原始交易資料變數或是結合技術分析指標和基本分析之經濟指標為主，然而影響股市漲跌波動並非單一因素，此外，基本分析的影響通常較為長期，而技術分析則又有落後指標的疑慮。(2) 過往的研究通常是以預測隔  $n$  日或是隔月等長期趨勢為主，然而隨著預測天數的增長，其影響因素也愈多，此將間接影響預測的準確性。因此，本研究希望透過輸入變數選取的多樣化與縮短預測天數兩種方式，來增進模型預測的準確性。

本研究在選取輸入變數上進行改善，首先，由於考量台灣股市為一淺碟市場，深受國際股市與國際重大事件的影響，因此本研究將國際股市的傳導效果納入變數中；其次，由於期貨市場與現貨市場通常具備一定的連動關係，因此本研究試圖將期貨與現貨的價差納入其中；再者，由於現貨市場於前一日收盤後，若有影響股市波動的事件發生，會傾向於當日領先開盤的期貨市場先行反應，因此本研究亦將非現貨交易時段的指數資訊納入考量的重點；最後則是技術分析指標可視為將過去的股價變化做為分析指標的依據，並藉以預測未來股價變化趨勢的能力，因此本研究亦納入進行分析。而在模型預測天數方面，由於考量隔夜效應與其它非預期因素增多所造成的影響，而導致預測準確率的下降，因此本研究嘗試利用類神經網路建構一較短天期的預測模型，以提供投資人短線交易的投資決策輔助工具。

## 1.2 研究目的

近年來利用類神經網路等電腦人工智慧的方法來預測指數或是股價漲跌趨勢相關研究的論文不勝枚舉，但是大多皆以技術指標、基本分析或是總體經濟指標為主要輸入因子，然而影響股市的漲跌趨勢並非單一因素，諸如國際股市對於台股的傳導效果和期貨與現貨的連動關係，因此本研究試圖加入更多有效的輸入

變數，以提高模型預測的準確度；此外，台股為淺碟市場，深受國際股市、政治事件與各種消息面的影響，諸如美國 911 恐怖攻擊、台灣 319 槍擊案、西班牙馬德里火車爆炸事件等，這些因素皆會使得台股短期內變得不理性與更加不可預期，而導致投資人蒙受多餘的損失與風險，因此本研究擬利用類神經網路工具建構較短天期的預測模型，提供投資人短線交易的輔助工具，以規避不必要的隔夜風險。

本研究即是利用類神經網路工具建構台灣加權指數當日收盤漲跌預測模型與隔  $n$  日收盤漲跌預測模型，然後與同一段時間之內採取多元迴歸模式進行優劣比較，再取三者中預測績效最佳者，並以台股指數期貨為投資標的，擬定短線之買賣交易策略，以買賣動作開始至平倉時，計算扣除期貨交易手續費和交易稅後的報酬，期望達到風險極小化、報酬極大化的目標。



### 1.3 研究對象與範圍

本研究主要是以台灣加權股價指數為研究對象，選取所有台灣地區上市的公司，以加權計算的方法，來衡量台灣股票市場表現，其選取的標的物包含金融類股、電子類股以及所有各產業類股，其有較不受單一產業因素與該產業之榮枯興衰而影響，且其平時成交量較大，亦較不易受單一法人或個別大戶所左右，而使本研究之結果可較不受外在因素所干擾。在台灣證券交易所目前編算的股價指數中，以發行股數加權來計算之指數計有 26 種，包括發行量加權股價指數，未含金融股發行量加權股價指數，未含電子股發行量加權股價指數，22 種產業分類股價指數，以及與英國富時 (FTSE) 共同編製的台灣 50 指數；另外，以算術平均方式計算的有綜合股價平均數以及工業指數平均數兩種 (台灣證券交易所)。「發行量加權股價指數」計算方式係以民國五十五年之股票市場市值為基期(設定為

100 點)，除特別股、全額交割股及上市未滿一個月之股票外，其餘皆包含在其採樣中。臺灣發行量加權股價指數是以各上市股票之發行量為權數計算指數值，換句話說，股本較大的股票對指數的影響會大於股本較小的股票，其計算公式如下（台灣期貨交易所）：

$$\frac{\text{計算期之各股市價} \times \text{各股上市股數}}{\text{基數之各股市價} \times \text{各股上市股數}} \times 100$$

本研究資料來源為寶碩財務科技財經資料庫，選擇 2002 年 5 月 1 日至 2004 年 10 月 31 日共 544 個交易日之資料為實證研究之時間序列資料，其中訓練期資料期間為 2002 年 5 月 1 日至 2004 年 7 月 31 日共 492 個交易日，測試期資料期間為 2004 年 8 月 1 日至 2004 年 10 月 31 日共 52 個交易日。由於考量少數交易天數之資料有所遺漏，以及研究中同時考量美國道瓊（DJ）指數、那斯達克（NASDAQ）指數和韓國漢城指數，所以只要其中之一因為休市或其他因素造成資料缺漏，便將此交易天數予以刪除不計。

本研究共計有 22 個輸入資料，可分為 4 大類：

1. 非現貨交易時段之指數資訊：前一交易日之現貨收盤指數變化率、前一交易日之期貨收盤指數變化率、8：45~8：50 之期貨開盤指數變化率。
2. 股市與期貨的原始交易資料變數探討：9：00~9：05 現貨開盤指數變化率、9：00~9：05 台股期貨與現貨之價差、9：00~9：05 摩根台股期貨與現貨之價差、9：10~9：15 現貨之總委買與總委賣張數、9：10~9：15 現貨之均買與均賣張數、9：10~9：15 現貨之成交量。
3. 國際股市的漲跌變化：韓股開盤指數變化率、美股道瓊（DJ）與那斯達克（NASDAQ）收盤指數變化率。
4. 技術分析指標：前一交易日之（5MA-10MA）、（5MA-20MA）、

(10MA-20MA)、(20MA-60MA)、(K-D)、(DIF-MACD)、(5 均量-22 均量)、(5 均量變化率)。

文中以類神經網路工具來建構台灣加權股價指數的收盤漲跌預測模型，再透過以其為標的物的衍生性金融商品—台股指數期貨為交易對象，以買賣動作開始至平倉時，計算扣除期貨交易手續費和交易稅後的報酬。表 1-1 列出台股指數期貨的契約規格之相關資訊。

表 1-1 台灣證券交易所股價指數期貨契約規格

項目	內容
交易標的	臺灣證券交易所發行量加權股價指數
中文簡稱	臺股期貨
英文代碼	TX
交易時間	臺灣證券交易所正常營業日上午 8：45～下午 1：45
契約價值	臺股期貨指數乘上新臺幣 200 元
契約到期交割月份	自交易當月起連續二個月份，另加上三、六、九、十二月中三個接續季月，總共五個月份的契約在市場交易
每日結算價	每日結算價原則上為當日收盤時段之成交價，若收盤時段無成交價，則依「臺灣證券交易所加權指數期貨契約交易規則」訂定之
每日漲跌幅	最大漲跌幅限制為前一營業日結算價上下 7%
升降單位	指數 1 點（相當於新臺幣 200 元）
最後交易日	各契約的最後交易日為各該契約交割月份第三個星期三，其次一營業日為新契約的開始交易日
最後結算	最後交易日之次一營業日

日	
最後結算價	以最後結算日依臺灣證券交易所本指數各成分股當日交易時間開始後十五分鐘內之平均價計算之指數訂之。前述平均價係採每筆成交價之成交量加權平均。但當日市場交易時間開始後十五分鐘內仍無成交價者，以當日市價升降幅度之基準價替代之
交割方式	以現金交割，交易人於最後結算日依最後結算價之差額，以淨額進行現金之交付或收受
稅率	稅率千分之 0.25 (單邊)
部位限制	<ul style="list-style-type: none"> <li>● 交易人於任何時間持有之各月份契約未平倉部位總和限制如下： <ol style="list-style-type: none"> <li>1. 自然人三百個契約</li> <li>2. 法人機構一千個契約</li> <li>3. 法人機構基於避險需求得向本公司申請豁免部位限制</li> <li>4. 期貨自營商之持有部位不在此限</li> </ol> </li> </ul>
保證金	<ul style="list-style-type: none"> <li>● 期貨商向交易人收取之交易保證金及保證金追繳標準，不得低於本公司公告之原始保證金及維持保證金水準</li> <li>● 本公司公告之原始保證金及維持保證金，以「臺灣期貨交易所結算保證金收取方式及標準」計算之結算保證金為基準，按本公司訂定之成數加成計算之</li> </ul>

資料來源：台灣期貨交易所

## 1.4 研究流程

本研究共分為五個章節，各章的內容分別摘要如下：

第一章 緒論：說明本研究的研究背景與動機、研究目的、研究對象與範圍、研究流程。

第二章 文獻探討：依序說明國際股市股價波動之傳導效果、股價指數期貨與現貨市場之連動關係、技術分析理論、類神經網路於財務金融領域之相關應用，匯總整理國內外相關文獻，並進行探討與比較。

第三章 研究方法：說明研究架構、類神經網路原理及架構、倒傳遞類神經網路模式，及如何運用漲跌方向預測模型建構交易策略。

第四章 實證研究分析：分別說明當日收盤漲跌預測模型分析、隔 n 日收盤漲跌預測模型分析、多元迴歸預測模型分析，並比較不同模型預測績效結果與交易報酬分析。

第五章 結論與建議：整理與歸納本研究之結論，並建議後續研究方向。

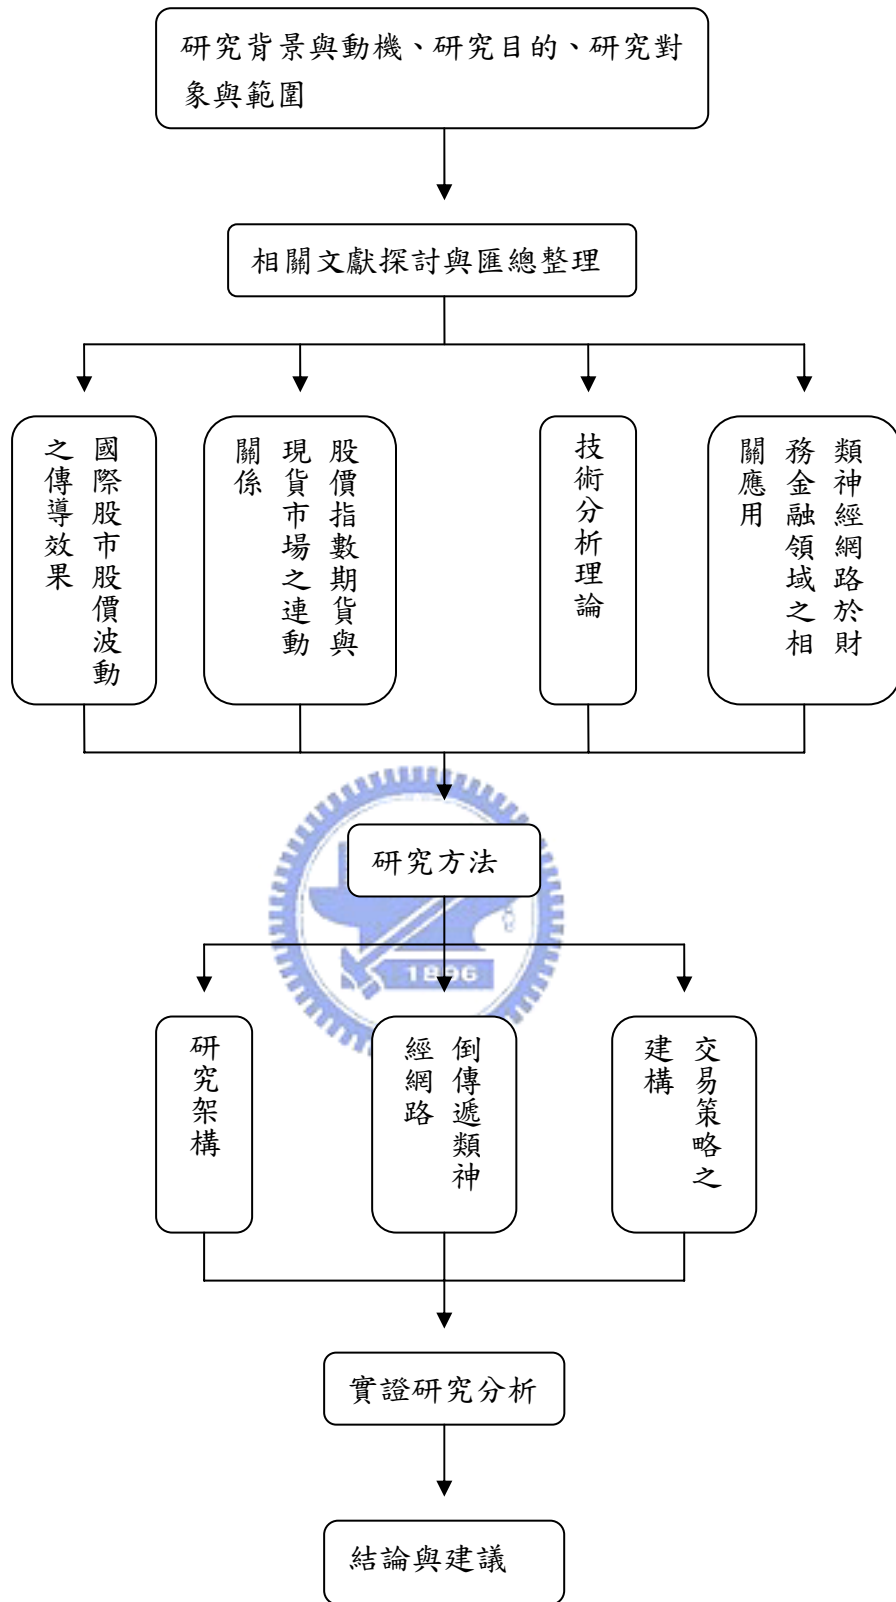


圖 1-1 研究流程圖

## 第二章 文獻探討

本章針對相關參考文獻分為 4 個部分加以探討：第一節為國際股市股價波動之傳導效果、第二節為股價指數期貨與現貨市場之連動關係、第三節為技術分析理論、第四節為類神經網路於財務金融領域之相關應用。

### 2.1 國際股市股價波動之傳導效果

Eun and Shim (1989)以 VAR 模型評估九個國際股票市場的訊息傳遞機制，以了解國際股市間是否存在一定程度的相關性，總體來說存在著大量的多邊互動關係。其中美國股市之突發事件會迅速傳遞至其他國際股票市場，然而卻沒有任一個國外市場可以明顯解釋美國股市的波動，顯示美國股市是全球最具影響力的市場。而且，市場對於突發事件之衝擊多在兩天內反應完成，顯示國際資本市場為效率市場。

King and Wadhvani (1990)的研究中利用蔓延模型 (Contagion Model) 來評估紐約、東京和倫敦三個國家股市間的相對互動關係，其基本假設認為理性的投資人應該會依據其他市場股價的變化，來預測與評估哪些相關的資訊對於股票基本面的影響，以及哪些公開資訊對於其他股價變動的衝擊。研究結果發現當某一國家股市的波動性提高時，對於其他國家股市的傳遞效果也會因此提高，因而使得各國股市間的關係更加增強，而且某一股市的錯誤也會蔓延至其他股市。

Jeon and Furstenberg (1990)以 VAR 模型來評估東京、法蘭克福、倫敦和紐約股市間的互動關係，研究結果顯示自從 1987 年國際股市大崩盤以來，各國的股



價指數呈現共變異性增加的狀況，且前一交易時段的股市對於下一時段即將交易的股市的影響力亦大幅增加。因此可推論蔓延效果與其他因素增強了報酬波動性的傳遞效果，且紐約股市的影響力相對於東京股市來說是減弱的，可知在崩盤後國際股市間的互動性是增加的。

Lin *et al.* (1994)的研究中利用總合衝擊模型 (Aggregate Shock Model) 與資訊萃取模型 (Signal Extraction Model)，探討開盤至收盤的日間報酬和收盤至隔日開盤的隔夜報酬對於紐約與東京股市間報酬和波動性的外溢效果。研究結果顯示國外股市的日間報酬顯著影響國內股市的隔夜報酬，也就是國外股市前一日的漲跌會影響國內股市今日的開盤高低，亦顯示紐約與東京股市存在雙邊互動關係；但是國外股市的日間報酬對於國內股市的日間報酬則無明顯的外溢效果，也就是資訊的反應具有效率性。



Wei *et al.* (1995)的研究中利用 GARCH 模型分析已開發國家股市對於新興市場股市短期報酬波動性的外溢效果，研究結果顯示 NYSE 相較於東京股市對於台灣和香港股市具有較顯著的影響，而且台灣股市對於成熟市場的敏感度比香港股市來得高，其因素可能為台灣的產業結構與美國較為相似。

Su and Wu (1998)探討國際股市報酬的短期動態關係，研究結果顯示紐約、東京、倫敦和香港等四個國際股市間存在明顯的動態關係，且在 1987 年後其關連性有顯著的增加，同時亦存在報酬領先與落後的不對稱關係，也就是大市場報酬有領先小市場報酬的現象。

Chou *et al.* (1999)分析台灣股票市場的價格和波動度與美國市場的連結程度，檢視先進國家股市 (例如美國) 的短期波動度和價格是否對於新興市場 (例如台灣) 有外溢效果。研究中使用 ARCH 和 M-GARCH 模型。結果顯示美國股

市對於台灣股市有大量的外溢效果，尤其是使用收盤到開盤的隔夜報酬最為顯著，如果是使用開盤到收盤的日間報酬則外溢效果不明顯。

Pan and Hsueh (1998)檢視美國 S&P500 和日本 Nikkei 225 股票指數期貨市場的報酬率和波動度的傳遞效果，藉由使用兩階段的 GARCH 模型，實證發現在同一時期中，美國與日本股市不論在報酬率和波動度皆存在同向的外溢效果，且美國股市相較於其他因子對於日本股市報酬率的影響多達 4 倍之多。最後，東京股市的報酬率和波動度對於芝加哥股市並沒有延遲的外溢效果，然而，美國股市的波動度對於日本股市則有明顯的外溢效果。

Fung *et al.* (2001)檢視美國與日本資本市場的資訊傳遞效果，結果顯示美國市場在價格資訊的傳遞上扮演領導的角色。至於在波動度的外溢效果方面，其他國際市場（例如 Nikkei 指數期貨）亦扮演相似的角色，有時甚至比美國市場來得更重要（例如新加坡的歐洲-美元期貨和日本的美元-日圓外匯期貨）。

Tse (1998)藉由使用日本的歐洲-日圓期貨和芝加哥的歐洲-美元期貨來檢視日本和美國的資訊傳遞效果，結果顯示在東京（芝加哥）的投資人會使用昨晚在芝加哥（東京）所揭露的訊息。研究中使用雙變數的 EGARCH-t 模型，實證結果發現並無明顯的波動度外溢效果，推論會於開盤價迅速反應國外的訊息，也就是國內資本市場會有效率地反應國外的資訊。

柯忠昇（2002）以 GARCH(1,1)-MA(1)模型，對台灣加權股價指數與美國道瓊工業指數、S&P 500 指數、NASDAQ-100 指數等四種股價指數現貨與期貨市場，進行模型配置。實證結果發現，以上四種指數現貨與期貨市場的價格以 GARCH(1,1)-MA(1)模型配置均可成功收斂，且價格過程中有強烈的記憶效果，亦即下一期的價格深受前一期價格變動的影響，符合財務理論所說的波動性叢聚

現象。研究第二部分針對兩地的股市與期貨市場，以相同的 GARCH 模型進行外溢效果分析。實證結論為：在平均數外溢模型中，美國三大指數期貨與現貨價格變動均會對台灣市場產生正向波及效果，其中以 NASDAQ-100 市場影響最為顯著，其次為 S&P 500，最弱者為道瓊工業指數。

朱正修 (2004) 研究旨在探討國內股市與國際股市間之連動性，利用統計方法-複迴歸分析、時間序列分析與類神經網路方法-倒傳遞網路，針對所收集到的 14 個國家(含 16 種股市)，各 297 筆週交易記錄進行分析；經實證結果顯示，在相關性方面，就美洲地區而言，台股與美國那斯達科技類股連動性最強；在亞洲方面，台股與南韓漢城綜合指數連動性最強；就歐洲而言，德國法蘭克福商銀指數與台股連動性較高。而在預測模式的報酬率方面，改良式倒傳遞網路模式最好，複迴歸模式次之；經由本研究顯示，台股與國際股市間是有相關的，且台股之趨勢是可以藉國際股市變動來預測的。



## 2.2 股價指數期貨與現貨市場之連動關係

Kawaller *et al.* (1987) 使用 Granger 因果關係檢定法，並利用輸入分鐘資料來檢驗美國 S & P500 指數期貨和現貨的日內 (intraday) 價格變動關係，研究中使用三階段最小平方迴歸法來評估 S & P500 指數期貨到期日和到期日前的領先與落後關係。研究結果顯示指數期貨的價格變動持續地領先現貨大約有 20-45 分鐘，但是相反的，現貨對於指數期貨則沒有領先的關係。

Finnerty and Park (1987) 的研究利用簡單迴歸分析探討 MMI (Major Market Index) 和 MMMI (Maxi Major Market Index) 兩個指數間的領先與落後關係，其輸入資料為 1984 年 8 月 23 日至 1986 年 8 月 15 日的指數現貨與期貨的每分鐘資

料。實證研究結果發現在 MMI 指數方面，此研究期間的最後 16 個月中有 13 個月期貨是領先現貨的；而在 MMMI 指數方面，此研究期間的最後 7 個月中期貨均是領先現貨的。

Stoll and Whaley (1990)認為在效率市場的假設下，指數現貨和指數期貨市場的報酬應該是具有絕對的相關性。研究中資料實證期間為 S&P 500 指數期貨和現貨取 1982 年 4 月 21 日至 1987 年 3 月 31 日的日內 5 分鐘資料，MM 指數期貨和現貨取 1984 年 7 月 23 日至 1987 年 3 月 31 日的日內 5 分鐘資料，結果發現指數期貨具有領先指數現貨的關係，平均而言大約快了 5 分鐘；如果把存在於股價指數報酬當中的非同步交易和買賣價差效果去除後，指數期貨甚至領先現貨 10 分鐘或更多，這項研究支持期貨具有價格發現的功能。

Chan (1992)針對 MMI(Major Market cash Index)指數、MMI(Major Market Index Futures)指數期貨和 S&P 500 期貨日內報酬率的領先落後關係來作研究。實證結果發現有強烈的證據顯示期貨有領先現貨的現象，但是對於現貨是否領先期貨則沒有明顯的證據，如此不對稱的領先落後關係普遍存在於期貨與現貨間（包括每 5 分鐘才交易一次的狀況）。實證結果也指出當大部分股票往某一方向一起移動時，期貨領先現貨的情況更加明顯，也就是說期貨市場是造成股票往某一方向一起移動(market-wide information)的主要訊息來源。

Martikainen and Puttonen (1994)的研究使用 Granger 因果關係檢定法探討國際股市的資訊如何反映在芬蘭的股價指數現貨與期貨市場上，其輸入資料是芬蘭股價指數 1988 年 5 月 2 日至 1990 年 3 月 31 日期間的 FOX(Finnish Options Index) 股價指數現貨與期貨和 FTAWI (Financial Times Acturaies World Index) 股價指數的日資料。研究結果顯示若只考慮現貨市場，芬蘭股市不受國際股市的影響；但是若將芬蘭的新興股價指數期貨市場納入考慮後，則芬蘭股市便會受到國際股市

的影響。同時亦發現股價指數期貨有領先股價指數現貨的關係，且若將期貨的報酬率分為正報酬和負報酬，則發現期貨領先現貨的狀況更加明顯。

Martikainen *et al.* (1995)的研究使用雙向 Granger 因果關係檢定法探討股價指數期貨與現貨之間的關係，其輸入資料是 1989 年至 1990 年兩年的 FOX (Finnish Options Index) 股價指數期貨與現貨的收盤價和 22 檔成分股的價格。研究結果顯示期貨市場的價格變動對於成分股報酬率的預測能力優於現貨市場的價格變動，而且期貨市場的報酬率對於個股具有預測能力，也就是說期貨市場具有領先現貨市場的現象，且並不是因為非同步交易導致期貨市場的報酬率領先現貨市場。

Pizzi *et al.* (1998)的研究採用 Engle-Granger 兩階段共積法 (Cointegration) 探討期貨與現貨之間的關係，其輸入資料是 3 月和 6 月的 S&P 500 股價指數現貨和期貨。研究結果顯示變數間具有共積關係，證明市場滿足具有效率性的必要條件，且 3 月和 6 月的期貨市場至少領先現貨市場 20 分鐘。

Min and Najand (1999)研究韓國現貨和期貨市場報酬率與波動度的可能領先落後關係，利用韓國期貨市場新建立的日內資料，發現期貨市場領先現貨市場長達 30 分鐘左右，這樣的結果與先前對於美國和其他國家期貨市場的研究是一致的。然而對於現貨與期貨市場波動度的關係中，卻發現它並不像報酬率那般，它的領先與落後關係是雙向的，也就是它是相互獨立的，同時也發現成交量對於現貨與期貨市場的波動度改變方面是有解釋能力的。

何怡滿和康信鴻 (2001) 使用 GARCH 模型來檢測 SIMEX 摩根臺指期貨、TAIFEX 臺指期貨與 TSE 臺指現貨三市場之間的領先/落後關係。以五分鐘的日內報酬資料分別探討三市場之間的報酬率、報酬率波動性與報酬率殘差的領先/

落後關係。研究結果如下：1.SIMEX 摩根臺指期貨、TAIFEX 臺指期貨與 TSE 臺指現貨兩兩之間的報酬有雙向的領先/落後關係。2.TAIFEX 臺指期貨報酬波動與 TSE 臺指現貨報酬波動具有同時性，沒有領先/落後的關係存在。3.SIMEX 摩根臺指期貨報酬波動與 TSE 臺指現貨報酬波動有雙向的領先落後關係。4.TAIFEX 臺指期貨報酬波動領先 SIMEX 摩根臺指期貨報酬波動 10 分鐘。5.報酬率殘差的領先/落後結果同報酬率之結果。

郭煒翎(1998)以摩根臺灣股價指數期貨與現貨從民國 86 年 3 月 1 日至 87 年 2 月 27 日總共 282 組樣本之日資料，以及從民國 86 年 10 月 30 日至 87 年 2 月 27 日總共 3000 組樣本之每五分鐘資料，分別進行期貨與現貨的領先與落後關係之研究。整體而言，不論是日資料或是每五分鐘資料，期貨與現貨報酬率之間的領先與落後關係較明顯，而期貨與現貨波動之間的領先與落後關係較不明顯；而且，領先與落後的關係並非單向的，換言之，隨著研究資料期間的不同，或是隨著區分子期的標準不同，期貨與現貨間之領先與落後關係可能會互換，有時甚至會存在有既領先又落後的雙向關係。

姜德宣(1999)研究 1998/7/21 剛上市的台指期貨(TAIFEX)與現貨的 Granger 因果關係，資料來源出自於臺灣期貨交易所 1998/10/13~1999/4/13 的每 5 分鐘報價。檢定結果為：1. 整體而言，短期中 SPOT 領先 TAIFEX 5~10 分鐘，長期中兩者具有回饋關係；2. 空頭走勢時，短期中 SPOT 領先 TAIFEX 5~10 分鐘，長期中兩者為獨立；3. 多頭走勢時，短期中 TAIFEX 領先 SPOT 15~30 分鐘，長期中兩者具有回饋關係。

## 2.3 技術分析理論

技術分析理論的基礎起源於 1884 年查里斯·道氏 (Charles H. Dow) 所提出的道氏理論 (Dow Theory)，道氏理論選取了當時的美國工業股價平均數與鐵路股價平均數等指數，來針對市場的波動進行分析、解釋並預測股價未來的走向，以作為一般景氣動向的指標，也就是藉由研判過去市場中的趨勢變化，用來預測未來市場趨勢的方向。

技術分析認為股價從原始均衡價格至新的均衡價格，需要一段時間慢慢調整，此乃因為每個投資人取得資訊的時間快慢先後不同，以及對於股價的解釋能力有所差異所致，因此當股價未來的趨勢產生後，將會持續一段時間，故能根據成交量、成交價以及價格趨勢等歷史資訊來預測短期股票價格的變化 (謝劍平，2003)。技術分析是用過去的股價變化做為分析的依據，並透過統計分析、各種圖表、技術指標等來研究股票期貨市場的行為，並藉以預測未來股價變化趨勢的方法。技術分析的相關理論是建立在三個前提假設之下：1. 現在的價格是反應所有訊息的結果；2. 價格會依循趨勢而變動；3. 歷史會一再重演，因此它認為經由掌握過去股價變化的趨勢，便能預測未來股價的變動方向，進而決定最佳的買賣時點。目前技術分析已普遍成為股票期貨買賣時的參考工具，若只採用一種技術分析指標，並不能夠很正確地預測未來股價的走向，但是若同時使用多種技術指標，則容易因為技術指標的買賣訊號相異時導致無所適從。因此，本研究便藉由結合類神經網路的方法，根據歷史訓練期資料的學習，以期達到有效的股價趨勢預測能力。

技術分析主要的理論架構大致可以區分成兩大類：(1) 指標類的技術分析：價的指標、量的指標；(2) 型態類的技術分析：道氏理論、K 線理論、波浪理論、

趨勢線理論、移動平均線理論等。簡言之，技術分析理論便是藉由價、量、趨勢來預測未來股價的走向。本研究使用類神經網路模式作為預測工具，輸入變數的選擇上包括技術分析指標、加權與期貨指數的原始交易資料變數探討、國際股市的漲跌變化和股價行為模式等，以期達到最佳的預測效果，茲將所選取的變數關於技術分析者說明如下：

1. 價的部分：指數變化率、期貨與現貨的正逆價差。
2. 量的部分：成交量。
3. 移動平均線（Moving Average, MA）：

移動平均線即是應用統計學移動平均的原理與時間序列分析的概念，求得平滑的曲線，它代表不同期間投資人的平均持股成本，它的好處是可以將極端值的影響降低，盡量消除短期的變動，看出股價的相對長期趨勢，進而掌握股價的真正走向。在台灣股市較常使用的移動平均線包括：5 日（週線）、10 日、20 日（月線）、60 日（季線）、120 日（半年線）、240 日（年線），一般移動平均有算數移動平均數、加權移動平均數和指數平滑移動平均數三種，本文所採用的是算數移動平均數，計算公式如下：

$$n \text{ 日 MA} = \frac{n \text{ 日收盤價之和}}{n} \quad (2-1 \text{ 式})$$

葛蘭碧（Granville J.）1960 年提出 200 日移動平均線為主的八大買賣法則，乃是運用指數或是股價向上突破與向下跌破移動平均線的關係，作為買賣時機的研判。進一步更有人發現，當短天期的移動平均線向上穿越長天期的移動平均線，即所謂的黃金交叉，代表多頭買進的時機；當短天期的移動平均線向下跌破長天期的移動平均線，即所謂的死亡交叉，代表空頭賣出的時機，且天數愈長的移動平均線交叉更具有指標性意義。



#### 4. 隨機指標 KD (Stochastic Index KD) :

雷恩 (George Lane) 在 1957 年首先提出隨機指標 KD 的公式，之後在 1986 年有人提出修正的公式。它是一種非常實用的屬於價的技術指標，其理論基礎是當股價上漲時，當日收盤價總是朝向當日價格波動的最高價接近；反之，當股價下跌時，當日收盤價總是朝向當日價格波動的最低價接近。

KD 值是先計算出第 t 天的收盤價與 n 天內最低價之差距，佔 n 天內最高價與 n 天內最低價之差距的百分比，先求出初估隨機值 (Raw Stochastic Value, RSV)，再求出 RSV 的 3 日指數平滑移動平均線 (Exponential Moving Average, EMA)，分別計算快速隨機指標 (K 值) 與慢速隨機指標 (D 值)，其公式如下所示：

$$RSV_t = \frac{\text{第 } t \text{ 天收盤價} - \text{n 天內最低價}}{\text{n 天內最高價} - \text{n 天內最低價}} \quad (2-2 \text{ 式})$$

$$K_t = RSV_t \times \frac{1}{3} + K_{t-1} \times \frac{2}{3} \quad (2-3 \text{ 式})$$

$$D_t = K_t \times \frac{1}{3} + D_{t-1} \times \frac{2}{3} \quad (2-4 \text{ 式})$$

K、D 值均界於 0~100 之間，利用 K 值與 D 值的交叉點可以研判短期股市的買進或賣出時機。一般實務上，均以 9 天 KD 值為判斷短線行情的買賣訊號，當 K 值向上突破 D 值時，代表買進訊號；反之，當 K 值向下跌破 D 值時，代表賣出訊號。KD 值超過 80 以上時，代表超買區；而 KD 值低於 20 以下時，則代表超賣區。當 K 值傾斜角度趨於平緩時是警告訊號，表示行情可能回軟或是止跌。當股價走勢創新高價或是創新低價時，而 KD 值未能創新高或創新低，即呈現牛市或熊市背離現象，代表股價有反轉的可能。

5. 指數平滑異同移動平均線 MACD (Moving Average Convergence and Divergence, MACD) :

艾培爾 (Gerald Appel) 和希斯勒 (W. Fredrick Hitschler) 兩人於 1979 年在「股市交易系統」(Stock Market Trading System) 一書中提出此一理論，它是根據移動平均線的優點所研發出來的另一種技術分析工具，其原理是應用中期與長期的兩條平滑移動平均線 (EMA)，來計算兩者之間的離差值 (DIF)，再根據 DIF 的狀況作為研判股價走勢的基礎，是一項研判股市中長期走勢的有效工具。計算過程如下所示：

I. 計算需求指數 (Demand Index, DI) :

$$DI = \frac{\text{最高價} + \text{最低價} + 2 \times \text{收盤價}}{4} \quad (2-5 \text{ 式})$$

II. 計算 12 日及 26 日的 EMA :

$$EMA_t = EMA_{t-1} + \alpha (DI_t - EMA_{t-1}) \quad (2-6 \text{ 式})$$

其中， $EMA_t$ 、 $EMA_{t-1}$  分別代表第  $t$  日及第  $t-1$  日的指數平滑移動平均值。

$$EMA_t = EMA_{t-1} + \alpha (C_t - EMA_{t-1}) \quad (2-7 \text{ 式})$$

其中， $C_t$  表當天收盤價

$\alpha$  表平滑常數 (smoothing constant)

$$\alpha = \frac{2}{1+n}, \quad n \text{ 表移動平均天數。}$$

III. 計算離差值 (Difference, DIF) :

$$DIF = 12 \text{ 日 EMA} - 26 \text{ 日 EMA} \quad (2-8 \text{ 式})$$

IV. 計算 DIF 的 9 日指數平滑移動平均值，即所謂的 MACD :

$$MACD_t = MACD_{t-1} + \alpha (DIF_t - MACD_{t-1}) \quad (2-9 \text{ 式})$$

DIF - MACD 即是柱狀圖。

MACD 判斷買賣的主要原則包括：(1) DIF 值與 MACD 值在 0 軸之上

代表多頭市場，若兩者均在 0 軸之下代表空頭市場；(2) DIF 值向上突破 MACD 或是 0 軸時，代表買進訊號；反之，當 DIF 值向下跌破 MACD 或是 0 軸時，代表賣出訊號；(3) DIF 在 0 軸之上，向上突破 MACD，買進；向下跌破 MACD，先獲利賣出，若拉回 0 軸不破時再買進；(4) DIF 在 0 軸之下，向下跌破 MACD，賣出；向上突破 MACD，可低接買進，若拉上 0 軸無法突破時再賣出。

#### 6. 平均成交量：

平均成交量（即成交量的移動平均線）是測量股市行情變化的溫度計，成交量的增減速度可用以研判多空雙方買賣氣勢的強弱，量價關係的假設條件為：(1) 量比價先行；(2) 量價背離是一個反轉訊號；(3) 股價上漲的必要條件為量能持續擴大。通常短天期的平均成交量向上突破長天期的平均成交量，代表近期買氣旺盛，股價具有上漲動能，為買進訊號；反之，則代表人氣衰退，為賣出訊號。

#### 7. 委買委賣、均買均賣：

從均買均賣張數的大小變化可以瞭解主力或是大戶的動向，研判大盤屬於主力盤或是散戶盤。委買張數大於委賣張數代表多方買氣較為旺盛，若配合均買張數持續擴大，代表大戶或是主力站在買方，如此多方容易取得主導權；反之，若委賣張數大於委買張數，且均賣張數持續增加，代表大戶或是主力站在賣方，此時空方容易取得主導權（杜金龍，2002）。

Brock, Lakonishok and Lebaron (1992)使用兩種技術指標來預測道瓊工業指數的走勢：1.移動平均線(Moving average)法，其中又分為變動移動平均(VMA)

和固定移動平均 (FMA) 兩種；2. 區間突破 (Trading range break) 法，樣本區間為 1897 年至 1986 年的道瓊工業指數。實證結果顯示其投資報酬率優於買進持有策略。

Pruitt and White (1988) 結合三種技術指標：累積成交量 (Cumulative Volume)、相對強勢 (Relative Strength) 和移動平均線 (Moving Average)，組合成一複雜之 CRISMA 指標，並建構其投資策略，其研究期間為 1976 年至 1985 年，所選用的投資標的為芝加哥大學電腦檔案 CRSP 的 204 種股票。實證結果顯示，在交易成本為 0%、0.5%、1% 及 2% 的情況下，CRISMA 的交易策略可獲得超額報酬。

洪志豪 (1999) 的研究使用 4 種技術分析指標：隨機指標 (KD)、指數平滑異同移動平均線 (MACD)、相對強弱指標 (RSI) 和威廉指標，並分別相互搭配使用，其研究期間為 1995 年至 1998 年，所選用的研究標的為台灣加權股價指數、類股指數和 7 家上市公司股票。實證結果顯示，此 4 種技術分析指標的優劣順序為：威廉指標、MACD 指標、KD 指標和 RSI 指標，雖然單獨使用此 4 種指標的投資績效皆無法優於市場表現，但是若將 KD 指標與威廉指標搭配、MACD 指標與威廉指標搭配，則可以獲得良好的投資績效。

## 2.4 類神經網路於財務金融領域之相關應用

人工神經網路 (Artificial Neural Network, ANN) 又稱為類神經網路，類神經網路之研究起源於 McCulloch 和 Pitts (1943) 兩人所提出之結合神經生理學與邏輯數學的神經網路模型。它使用大量簡單的相連人工神經元 (Neurons)，來模仿生物神經網路的能力，它非常適宜解決非結構化的問題，加上隨著電腦運算速度大

幅提昇，目前類神經網路的學習速度也日益加快，使得其應用能力愈來愈廣，本節將其運用於財務金融相關領域之文獻稍作整理：

Lapends and Farber (1987)以倒傳遞類神經網路演算法為模型工具，針對美國 S&P500 股價指數進行預測工作，實證研究結果發現利用類神經網路所建構的模型，其預測能力相較於傳統統計方法的移動平均法來得好。

Kimoto and Asakawa (1990)以倒傳遞類神經網路預測未來一個月東京股價指數 (Tokyo Stock Exchange Prices Indexes, TOPIX) 之最佳漲跌與買賣時機，其輸入為成交量、利率、乖離率曲線、外幣匯率、道瓊指數平均值等結合技術指標與經濟指標之變數，輸出則為一個買賣時機指標。此系統模擬範圍從 1987 年 1 月至 1989 年 9 月共 33 個月，實證結果發現利用此模型所獲得之報酬率為 98%，相較於同一時期買入持有策略所獲得之報酬率為 67%，此模型可提高 46% 的投資效益。



Baba and Kozaki (1992)以修正式的倒傳遞類神經網路演算法結合隨機最佳化法 (random optimization method) 來進行日本股票市場之預測，其輸入變數高達 15 種之多，例如有收盤價、今日股價變動、周轉率、銀行利率、股東權益變化、道瓊指數變化、匯率變化等，並使用一個輸出變數，當其值趨近 1 時表示股價趨漲，當其值趨近 0 時表示股價趨跌，其目標輸出變數 T 採「公式後定法」。簡言之，如果預測日後一個月之最高股價比預測日當日的股價高於或低於多少% 時，便有一目標輸出變數 T 與之對應，則可知其漲勢或跌勢，其實證結果有高達 75% 的準確率，且所提出之混合式演算法也能加快其網路模式之收斂速度。

類神經網路模型除了可用於股票市場的預測之外，針對其他標的物市場的預測亦有不錯的貢獻，Grudnitski and Osburn (1993)利用倒傳遞類神經網路分別針對

S&P500 股價指數和黃金期貨每月的價格變動來進行預測，實證研究結果發現此模型對於次月的 S&P500 股價指數和黃金期貨每月的價格變動分別有高達 75% 和 61% 的準確率。

Glaria *et al.* (1996) 使用前十日的指數與成交量當作輸入變數，建構類神經網路模型來預測聖地牙哥股市的隔天指數，研究中選擇的資料樣本為聖地牙哥股市的 240 日交易資料，實證研究結果發現此模型在上漲區間的準確率為 63.3%，在下跌區間的準確率為 74.7%。

Tan (1993) 利用類神經網路來建構金融交易系統，其輸入變數包含前五週的最高價、收盤價、最低價與四個技術指標，總計共 35 個輸入因子，用來預測下一週的收盤價，以此來進行 NYSE-stock 兩年的虛擬買賣交易。研究中以五年共計 264 週的資料為其樣本區間，其中又分前面的 165 週為訓練期資料，後面的 99 週為測試期資料，更限定當預測下一週的上漲或下跌幅度超過 5% 才進行買賣交易，實證研究結果發現此模型在訓練期的準確率高達 88%，而在測試期的準確率則為 83%。

類神經網路不僅可用於股價指數與期貨的預測外，應用於上市公司經營績效與盈餘的預測亦有不錯的表現。George S. (1992) 使用成長率、預期獲利、預期損失、策略規劃、長短期樂觀指數..... 等 9 項基本面指標為輸入變數，建構類神經網路模型來預測企業未來的經營績效。研究中分別選取 Fortune500 所列出的 5 大產業中獲利最高的 58 家公司當作訓練樣本，並且以 Business Week "Top 1000" 所列出的 10 大產業中市值最高的 40 家公司當作測試樣本，然後將其分為獲利較高與獲利較低的兩組，分別測試模型預測的準確性，並進一步與 Multiple Discriminating Analysis (MDA) 的方法進行預測績效比較，結果發現類神經網路的預測準確率高達 77%，明顯優於 MDA 的 65%。

Lawrence *et al.* (1993)的研究中使用 Boltzmann Machine (BM)以圖形分類模擬退火演算法來訓練類神經網路，其輸入變數為生產毛利、生產純利、現金流量、設備產能、總資產負債比等 5 項產業基本面指標，建構類神經網路模型來預測加拿大 120 家上市公司下半年度的盈餘，研究使用 6 年的資料當作樣本區間，預測其盈餘表現並作為選股的依據，實證研究結果顯示本模型的準確率高達 71.7%。

John *et al.* (1999)的研究中使用公司規模、負債比率、現金比率、銷售成長率、盈餘分配率、本益比、股息、q ratio(股票市值/總資產)與企業被併購比率等多項公司基本面指標作為輸入變數，建構類神經網路模型來預測即將可能被併購的企業，以此組成一投資組合 (portfolio) 以獲取將來股價上漲的資本利得。研究中使用紐約證交所非金融業與服務業中的 1448 家上市公司作為實驗樣本 (當中有 173 家為已被併購的案例)，並選取 6 年的資料當作樣本區間，其預測的準確率高達 70%，且其投資績效明顯優於大盤的漲幅。

Casas (2001)的研究中使用指數、P/E ratio、成交量等作為輸入變數，並選取美國股票市場、債券市場與現金市場等 3 類資產作為資產配置的標的，建構類神經網路模型組成資產配置的投資策略，並且每月進行一次的資產重新配置，然後與 S&P500 指數的 buy-and-hold 投資策略進行比較，經過一年的實證研究後發現類神經網路的績效優於 buy-and-hold 策略的績效，且其預測準確率高達 92%。

除了單一類神經網路預測工具外，有些學者亦加入其他人工智慧方法，結合類神經網路模型來進行預測。Bergerson and Wunsch (1991)結合倒傳遞類神經網路與專家系統來進行期貨交易，使用美國 S&P 500 從 1989/01/04 至 1991/01/25 共 25 個月的資料為研究範圍，以技術指標為輸入變數，以買賣時點為輸出變數，其中以技術指標做為買賣時點的判定涉及樣本辨識能力，所以可利用類神經網路

來解決；其中也需要根據風險與資金部位來做為資金管理準則的判定，也就是停損點的決定，這可以使用專家系統來解決，依此系統在模擬交易的 25 個月內報酬率可以達到 660%。

Paul (2001)結合基因演算法與類神經網路來預測新加坡股市海峽時報指數 (STI)，研究中使用每日開盤價、最高價、收盤價、最低價、成交量、Dow Johns Industrial average (DJIA)指數、NASDAQ (IXIC)指數、Heng Seng Index (HIS)指數與 Nikkei 225 (N225)indices 指數等作為輸入變數，且將連續 15 日的資料同時輸入，用以預測隔 1~5 日的指數漲跌，模型採用 feed forward neural network with back propagation algorithm 演算法，並透過基因演算法來最佳化類神經網路的架構與參數。實證研究結果發現連續 13~15 日的輸入資料較為適配，此模型的預測準確率高達 81%，但是對於趨勢反轉點的預測效果並不好。

Kamijo and Tanigawa (1990)利用類神經網路來辨識日本的股價 K 線圖 (Candlestick Chart)，資料實證期間為 1987 年至 1989 年的股市週資料，希望能夠透過辨識股價三角形 K 線圖而進一步找出股價變動的趨勢。研究中使用 3 年的三角形 K 線圖的最高價和最低價當作類神經網路的輸入變數，經過 15 組訓練範例的實證學習後，再用來預測 16 個測試資料，發現股價三角形 K 線圖的辨識能力高達 93.8%。

周慶華 (2001) 的研究探討新加坡交易所摩根台股指數非現貨交易時段之期貨交易資訊內涵，首先選擇領先現貨開盤的期貨指數及前一日現貨與期貨之收盤指數當作輸入層之輸入變數，以建構倒傳遞類神經網路模式，來針對現貨開盤指數進行預測。以 1998/10/01 至 2000/12/31 現貨與期貨指數 5 分鐘日內資料為實證之時間序列資料，實証結果顯示以整合基因演算法與類神經網路之預測模式，相較於單純使用倒傳遞類神經網路之預測模式及對開盤持中性看法的隨機漫步模式



有較好之預測能力，且對現貨開盤指數漲跌方向預測之正確率達80.46%，顯示利用適當之模型可以得到非現貨交易時段之期貨交易價格蘊含訊息，並可做為預測現貨開盤指數之參考。

詹錦宏和袁澤峻（1999）的研究探討影響股票市場的總體經濟因素，譬如：匯率、物價、利率及通貨膨脹率等指標，以期能正確掌握未來股票市場趨勢。而景氣循環更是影響企業經營的重要因素，因此本研究嘗試利用類神經網路與景氣循環來預測股價指數之上漲或下跌。由各次預測結果得知，景氣循環法比移動模擬法有較高預測正確率。

李建輝（2002）的研究利用人工智慧的方法，結合遺傳演算法所建構的類神經網路，以預測台灣期貨交易所之臺股指數期貨為對象，比較在傳統操作策略（順向操作、逆向操作、迴歸操作及買進持有策略）與遺傳演化類神經網路之優劣。實驗結果顯示：1.遺傳演化類神經網路所預測出的報酬率會優於本研究之所有傳統策略；2.從傳統策略而言，買進持有策略在長期間會比在短期間優於順、逆向策略，是因為每日進出會有較高之價格變動風險；另一方面，以技術指標為輸入變數在迴歸策略下不能預測出好的報酬率，表示該指標不是有效指標；3.就遺傳演化類神經網路而言，短期間影響準確率及投資報酬率之指標以技術指標較為有效，而適應性較為無效；但長期間則否，以適應性較為有效，而技術指標較為無效。

## 第三章 研究方法

本章研究方法分為 4 個部分加以探討：第一節為研究架構、第二節為類神經網路原理及架構、第三節為倒傳遞類神經網路模式、及第四節說明如何運用漲跌方向預測模型建構交易策略。

### 3.1 研究架構

本研究架構分為：文獻探討、定義研究問題、選取輸入變數、資料蒐集與整理、資料分析與轉換、建立類神經網路模型—預測當日收盤漲跌、預測隔 n 日收盤漲跌、建立多元迴歸模型、評估 MSE、RMSE 與方向準確率、交易策略之擬定與報酬率分析、結論與建議等十個步驟，如圖 3-1 所示。研究架構說明大致如下：

- 一、選取輸入變數：整合包括技術分析指標、加權與期貨指數的原始交易資料變數探討、國際股市的漲跌變化和非現貨交易時段資訊等，作為類神經網路的輸入變數。
- 二、建立模型：蒐集取得變數，建立台灣加權指數之當日收盤漲跌預測模型、隔 n 日收盤漲跌預測模型和多元迴歸模型。
- 三、網路模式之建構：以 Neural Solutions 4.0 來做為實證研究之工具，建構一最佳之類神經網路模式，並利用 SPSS 建構多元迴歸模型以進行優劣比較。
- 四、交易策略之研擬：根據所建立之漲跌方向預測模型，以台股指數期貨為交易標的，並模擬該交易策略之報酬。

為了使倒傳遞網路模型能夠有較好的預測能力，最重要的便是輸入變數的選取，根據國內外對於預測指數漲跌方向的相關文獻與實務的經驗，本研究主要選取 4 大部分的輸入變數，(1) 由於國際股市股價波動具有傳導效果，綜合相關文獻所得，本研究選取與台股指數具有高度相關之國際股市做為輸入變數，包括美股道瓊、那斯達克與韓股等；(2) 股價指數期貨與現貨市場具有一定連動關係，因此台股指數期貨、摩根台股指數期貨與台股指數現貨的正逆價差也納入選取標準；(3) 觀察國內金融市場之開收盤時間可知，期貨市場之收盤時間較現貨市場晚 15 分鐘，而隔日又提早現貨市場 15 分鐘開盤，加上期貨市場一般皆有領先現貨市場的狀況，因此每日現貨市場收盤後到隔日現貨市場開盤時，若有相關資料應會提前反應於期貨市場，所以非現貨交易時段之指數資訊也是重點輸入變數；(4) 技術分析方面，Brock, Lakonishok and Lebaron (1992) 的研究中發現移動平均線 (MA) 具有預測指數的功能，Ratner and Leal (1999) 的研究發現利用移動平均線可準確預測報酬序列的變化，因此選取移動平均線作為輸入變數，且短天期移動平均線與長天期移動平均線的交叉代表買賣點的轉折；Pruitt and White (1988) 的研究結合累積成交量、移動平均線與相對強勢建構一 CRISMA 指標和洪志豪 (1999) 的研究結合 KD 指標、MACD 指標等 4 種技術分析指標，得知多種技術分析指標的搭配使用可提高投資績效，因此選取 KD 指標、MACD 指標、移動平均線和平均成交量作為輸入變數並相互搭配使用，其中平均成交量具有與移動平均線相似的意義。

蒐集完主要影響股市漲跌趨勢的國內外相關文獻後，整理相關領域知識，並結合專家知識規則，以選取影響台股漲跌變化的適當輸入變數，建構類神經網路預測模型。Brock *et al.* (1992) 利用 90 年來的道瓊工業指數資料與選取 26 種技術分析法則，其中分成兩大類：移動平均線法則與區間突破法則，實證發現其績效明顯超越長期持有策略；杜金龍 (2002) 利用短天期與中長天期兩條移動平均線

的交叉確認股價是處於多頭或是空頭走勢中，當短天期 MA 由下向上突破中長天期 MA 時，稱為黃金交叉，為買進時機；當短天期 MA 由上向下跌破中長天期 MA 時，稱為死亡交叉，為賣出時機。杜金龍（2002）利用 KD 指標的交叉研判股市的買賣點，當 K 值由下向上突破 D 值代表買進訊號；當 K 值由上向下跌破 D 值代表賣出訊號。MACD 指標的交叉亦可研判買賣訊號，當 DIF 值由下向上突破 MACD 值時適合買進；當 DIF 值由上向下跌破 MACD 值時適合賣出。Blume *et al.* (1994)從市場結構的觀點認為成交量與價格資訊可以提高技術分析的績效；Suliram *et al.* (1999)的 5 大類技術分析法則亦包含有關成交量的資訊；杜金龍（2002）利用短天期與長天期兩條平均成交量的交叉研判股市的買賣點，當短天期平均成交量由下向上突破長天期平均成交量為買進時機；當短天期平均成交量由上向下跌破長天期平均成交量為賣出時機；亦以平均成交量的遞增或遞減研判推動股價漲跌原動力的強弱。



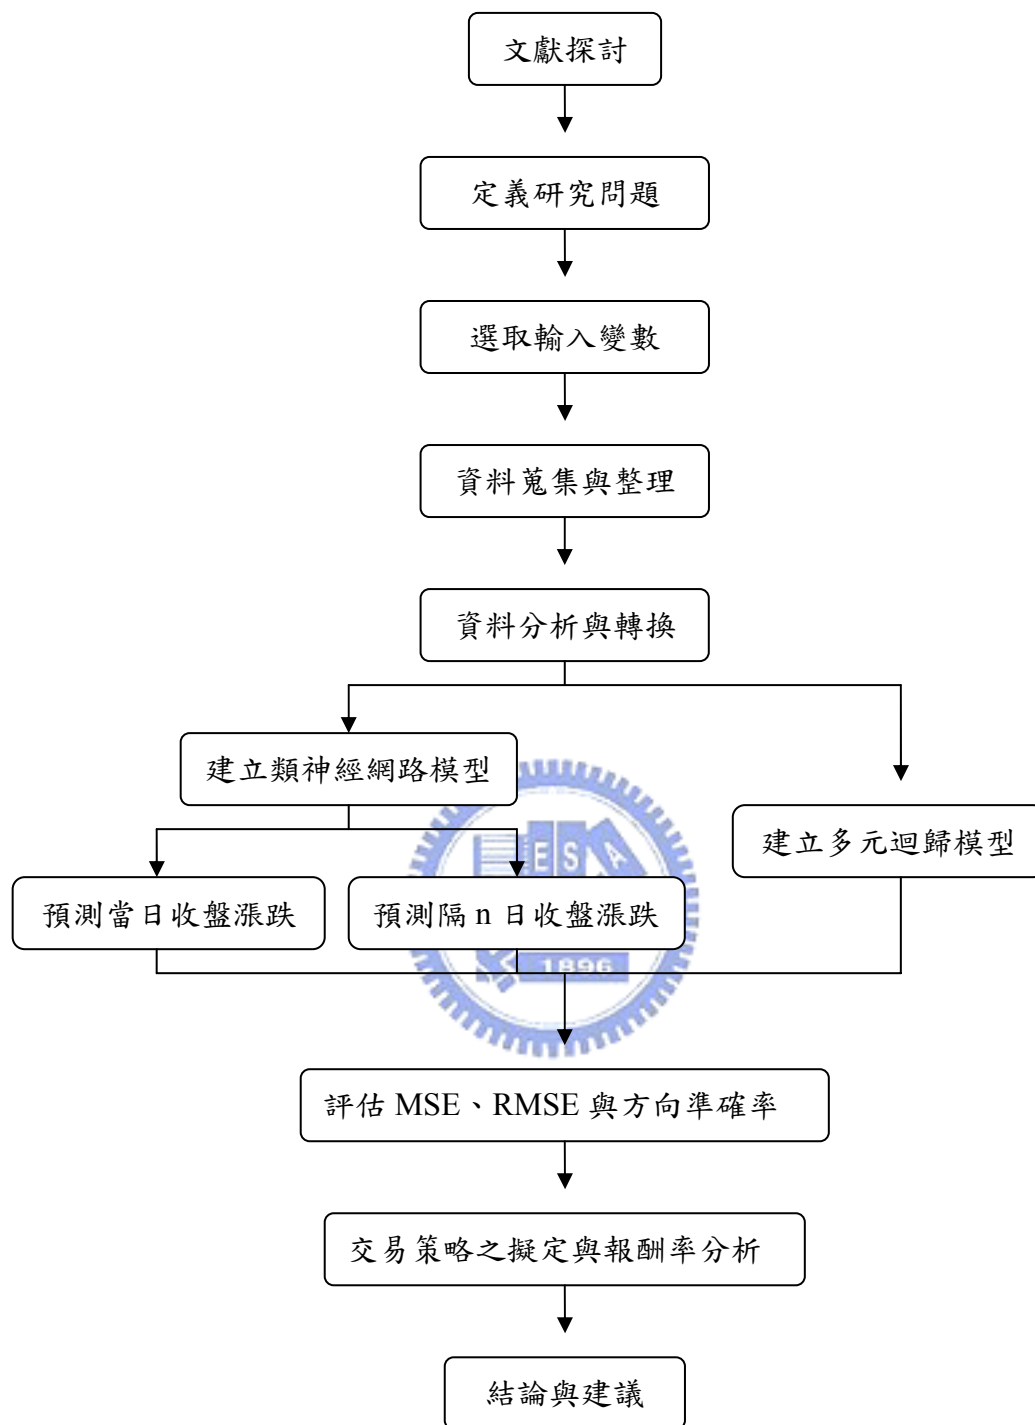


圖 3-1 研究架構圖

蒐集完資料後，先將所有訓練期和測試期的資料利用最大最小對映法轉換成介於  $(-1, 1)$  的值，訓練期數據集 (Training set) 是用來建構和取得類神經網路模式的權重，測試期數據集 (Testing set) 是用來衡量此一模式的一般化能力，

其數目大約是訓練期數據集的 10~30% 左右，至於交叉驗證數據集 (Cross Validation set) 則是用來評估此模式的實際績效。

本研究採用倒傳遞類神經網路模式中的多層感知機 (Multi-layer Perceptrons)，使用 22 個輸入變數、1 個隱藏層、11 個 Processing Elements、1 個輸出層，類神經網路軟體則是 NeuroDimension 公司所設計開發的 Neural Solutions Version 4.0。其他相關參數則是：隱藏層學習速率  $\eta=1.0$ 、輸出層學習速率  $\eta=1.0$ 、慣性量 (Momentum) = 0.7、轉換函數為雙曲線正切函數，在類神經網路的學習過程中，採用批次 (Batch) 學習一個訓練範例的方式，直到學習完所有的訓練範例後，才完成一次的學習週期 (Epoch)。

### 3.2 類神經網路原理及架構



生物神經網路是由巨量的神經細胞 (神經元) (neuron) 所組成，神經細胞的形狀與一般的細胞有很大的不同，它包括：(1) 神經核 (soma)：神經細胞中呈核狀的處理機構；(2) 軸索 (神經軸) (axon)：神經細胞中呈軸索狀的輸送機構；(3) 樹突 (神經樹) (dendrites)：神經細胞中呈樹枝狀的輸出入機構；(4) 突觸 (神經節) (synapse)：神經樹上呈點狀的連結機構。當一個神經元被輸入的訊號所激發時，神經元會產生一串脈衝列 (pulse) 沿著軸索傳遞，若是激發是在興奮突觸 (excitatory synapse)，則會增加脈衝列的速率 (pulse rate)；若是激發是在抑制突觸 (inhibitory synapse)，則會減少脈衝列的速率。因此，脈衝列的速率是同時取決於輸入脈衝列的速率，以及神經節的強度 (strength)。而神經節的強度可視為神經網路儲存資訊之所在，神經網路的學習即在調整神經節的強度 (葉怡成，2002)。

基於想發展出一套人工智慧系統能夠執行智慧化的任務就像人類的大腦那般，就在這樣的動機之下，藉由觀察單一生物神經細胞或是神經元所獲得的靈感，便發展出了類神經網路。類神經網路之所以和人類的大腦相似有以下兩個原因：(1) 類神經網路是透過學習而獲得知識；(2) 類神經網路的知識是儲存在神經元間的連結加權值強度 (connection strengths) 中，就如同我們已知的神經節權值 (synapse weights) (NeuroDimension Incorporated)。

類神經網路 (artificial neural network) 是一種強而有力，且能夠捕捉和呈現複雜的輸入和輸出資料間相對關係的資訊處理模型。它是一種模擬生物神經網路對於外界資訊所做的接收、儲存、學習、反應等一系列動作的一種數學運算網路。它可以利用一組或多組範例，當作系統輸入與系統輸出的資料來建立系統模型，透過學習輸入與輸出資料間的關係而取得適當的連結加權值，之後便可輸入資料後透過網路運算而得到相對應的輸出資訊，屬於平行分散式的處理計算模式，因此這樣的系統模型便可用於樣式辨認、推估、預測、決策和診斷。它能夠藉由輸入資料中學習線性和非線性的關係，而傳統的線性模型則無法處理資料中包含有非線性的特徵。

類神經網路中是由許多個人工神經元 (artificial neuron) 又稱為處理單元 (processing element, PE) 所組成，它就相當於一個個的神經元，每一個處理單元接受輸入訊號後，以類似扇狀的方式送出訊號，成為下一層中許多處理單元的輸入訊號，其關係式可用下列函數表示：
$$Y_j = f\left(\sum_i W_{ij}X_i - \theta_j\right)$$
，下圖為人工神經元之模型。

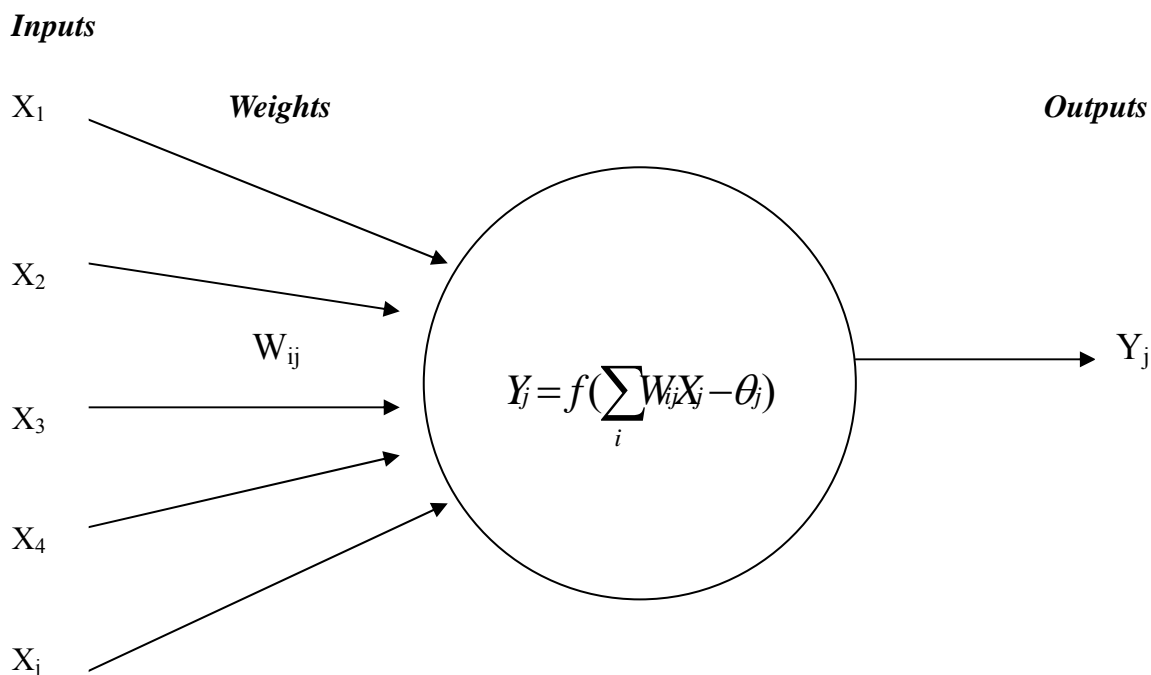


圖 3-2 人工神經元之模型



其中，

$X_j$ ：輸入訊號 (inputs)，模擬生物神經元所接收到的訊號，輸入資料須先利用最大最小對映法來前處理 (pre-processing) 至  $-1 \sim 1$  之間。

最大最小對映法 
$$X_{new} = \frac{X_{old} - X_{min}}{X_{max} - X_{min}} (D_{max} - D_{min}) + D_{min} \quad \circ$$

$W_{ij}$ ：連結加權值 (weights)，模擬生物神經元中突觸的強度，為第  $j$  個輸入值與第  $i$  個神經元之間的連結加權值，類神經網路的學習基本上即是透過不斷地調整連結加權值以減少誤差。

$\theta_j$ ：偏權值或閾值 (bias)，模擬生物神經元之閾值。

$\sum_i$ ：結合函數 (combination function)，將所有的輸入訊號 ( $X_j$ ) 與連結加權值 ( $W_{ij}$ ) 相乘後加總合併成一個單一的值，函數有一內定的閾值，若函數值 ( $Y_j$ ) 越接近此閾值，則對輸出訊號有較強烈的影響。

$f(\ )$ ：轉換函數 (transfer function)，其目的是將加權輸入 ( $W_{ij}X_j$ ) 和偏權值 ( $\theta_j$ )



的總和轉換成處理單元的輸出。最常見的轉換函數為雙彎曲函數 (Sigmoid function) 和雙曲線正切函數 (Hyperbolic Tangent function)。

雙彎曲函數  $f(x) = \frac{1}{1 + e^{-x}}$ ，當  $X \rightarrow \pm\infty$  時，函數值域介於  $(0, 1)$  之間。

雙曲線正切函數  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ ，當  $X \rightarrow \pm\infty$  時，函數值域介於  $(-1, 1)$  之間。

$Y_j$ ：輸出訊號 (outputs)，模擬生物神經元的輸出訊號，類神經網路結果的輸出，可成為某一特定問題之解；也可能輸出至其他處理單元，成為該處理單元輸入訊號的一部份。

類神經網路的基本架構可分成三個層次：1.處理單元 (Processing Element, PE) — 為類神經網路組成的基本單元；2.層 (Layer) — 若干個具相同作用的處理單元集成“層”，層具有三種作用為正規化輸出、競爭化輸出、競爭化學習；3.網路 (Network) — 若干個具不同作用的層集成網路，網路具有學習過程和回想過程兩種作用。截至目前為止，許多學者針對欲解決問題的不同，提出許多不同型式的類神經網路模型，每一種類神經網路的演算法並不相同。若將其作概略的分類，類神經網路的分類通常使用兩種方式：(1) 依學習策略分類：監督式學習 (supervised learning)、無監督式學習 (unsupervised learning)、聯想式學習 (associate learning)、最適化應用 (optimization application)；(2) 依網路架構分類：前向式架構 (forward)、回饋式架構 (feedback)。依葉怡成 (2003) 的網路分類，分別詳述如下：

#### (1) 依學習策略分類：

- ◆ 監督式學習網路 (Supervised learning network)：從問題領域中取得訓練範例 (有輸入變數和輸出變數)，並從中學習輸入變數和輸出變數間的內在對映規則，以應用於新的案例 (只有輸入變數)。

- ◆ 無監督式學習網路 (Unsupervised learning network): 從問題領域中取得訓練範例 (只有輸入變數), 並從中學習範例的內在聚類規則, 以應用於新的案例 (只有輸入變數)。
- ◆ 聯想式學習網路 (Associate learning network): 從問題領域中取得訓練範例 (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)。
- ◆ 最適化應用網路 (Optimization application network)

## (2) 依網路架構分類:

- ◆ 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者, 稱為前向式架構。
- ◆ 回饋式架構 (feedback): 從輸出層回饋到輸入層, 或者層內各處理單元間有連結者, 或者神經元不分層排列, 只有一層, 各神經元均可相互連結者, 稱為回饋式架構。

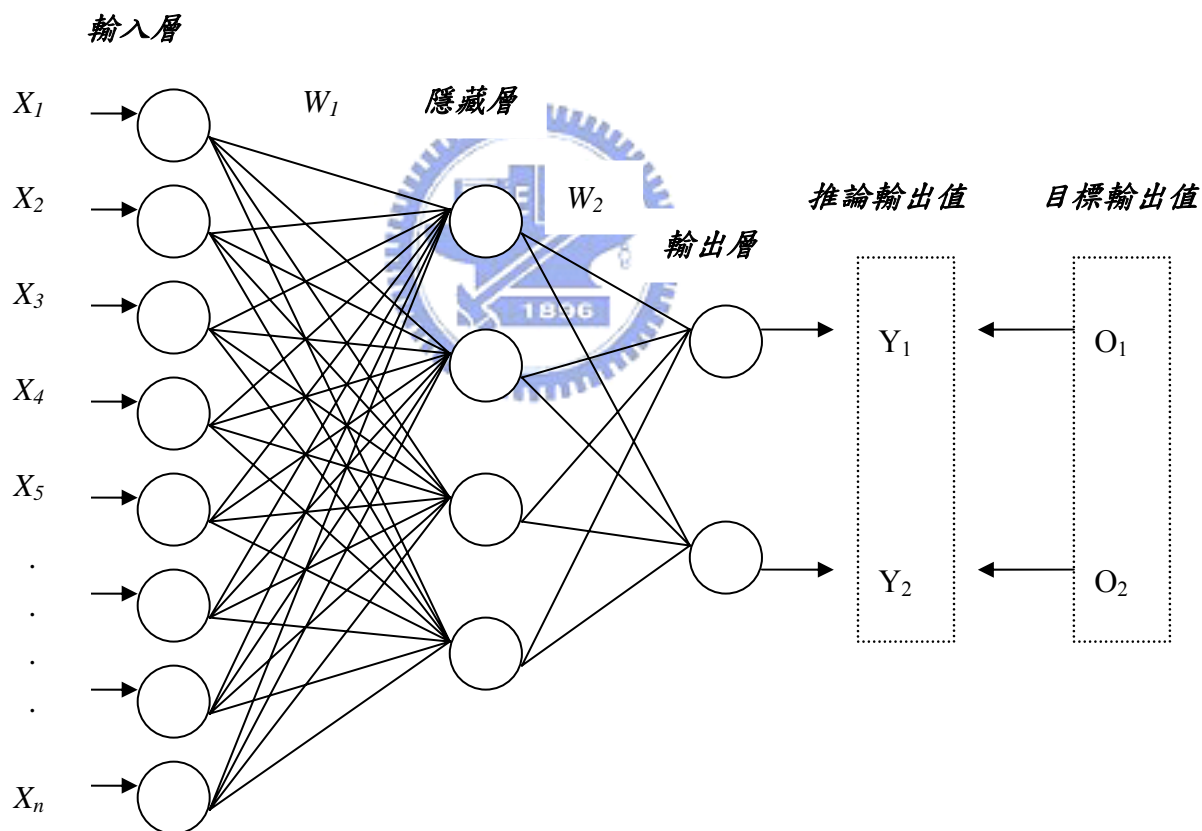
### 3.3 倒傳遞類神經網路模式

監督式學習網路 (Supervised learning network) 是目前應用最為普遍的類神經網路模式, 而其中又以倒傳遞類神經網路 (Back-propagation Network) 為其中最具有代表性的, 也是應用最為廣泛的, 所以本研究採用倒傳遞類神經網路。其發展始於 1957 年 Rosenblatt 提出多層感知機 (Multi-layer Perceptrons), 1974 年韋伯斯 (P. Werbos) 學者提出了隱藏層的學習演算法, 這是目前已知最早具有倒傳遞類神經網路概念的想法, 而直到 1985 年 Rumelhart、Hinton 和 Williams 三位學者共同提出的倒傳遞類神經相關論文, 才使得此一領域重新受到重視。

倒傳遞類神經網路的基本原理是利用最陡坡降法 (the gradient steepest descent method) 的觀念，將推論輸出值與目標輸出值相減後的誤差值以回饋方式修正網路的連結加權值和閾值，將誤差函數予以最小化，使網路能夠擷取一最適的權重，進而使推論輸出值能夠盡量逼近目標輸出值。

(1) 網路架構：

倒傳遞類神經網路通常是由三大部分所組成，包括輸入層、隱藏層和輸出層，分別詳述如下：



訊息向前傳遞，每一層只接受前一層的輸出當輸入

← 推論值與目標值的誤差向後傳遞，調整連結加權值和閾值

圖 3-3 倒傳遞類神經網路架構

- ◆ 輸入層：用以輸入外在環境的資訊，通常處理單元 (processing element) 的數目多寡依所欲處理的問題而定。在這裡是使用線性轉換函數，也就是  $f(x) = x$ 。
- ◆ 隱藏層：隱藏層的存在提供類神經網路表現處理單元間的交互影響，與問題的內在結構的能力。通常一個類神經網路可以有數層的隱藏層，也可以只有一層或是沒有隱藏層，不過須注意的是開始決定隱藏層數目時，必須先使用沒有隱藏層的結構作測試，如果其結果比有隱藏層的為佳，則可能需考慮此一問題或許不適合使用倒傳遞類神經網路，而只需使用一般的線性模型。通常是使用非線性轉換函數。Zhang *et al.* (1998) 提出具有一層隱藏層的類神經網路就能達到模型所需要的精確度，且經驗顯示隱藏層在 1~2 層時會有最好的結果。
- ◆ 輸出層：用以輸出資訊給外在環境，通常處理單元 (processing element) 的數目多寡依所欲處理的問題而定。通常是使用非線性轉換函數。

## (2) 網路演算法：

倒傳遞類神經網路是屬於一種監督式的學習演算法，應用訓練範例的一組輸入值和一組目標輸出值，來修正網路的連結加權值 (權重) 與閾值，而達到網路學習的目的。在修正網路的連結加權值過程中，使網路誤差函數達到最小，也就是使推論輸出值趨近於目標輸出值，如此一來，網路已從訓練範例中學習到隱含在其中的內隱知識。整個演算法大致可分成兩部分：1. 學習過程，2. 回想過程；訓練範例不斷重複上述兩步驟，直到所有訓練範例皆輸入完畢為止，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，直到收斂為止 (葉怡成，2002)。

### (3) 網路模式的績效評估標準：

1. 收斂測試—推論輸出值與目標輸出值的收斂程度可用誤差均方根 (Root Mean Square Error, RMSE) 來衡量，公式如下：

$$RMSE = \sqrt{\frac{\sum_k \sum_{i=1}^N (O_i^k - Y_i^k)^2}{M \times N}} \quad (3-1 \text{ 式})$$

其中， $O_i^k$  = 輸出層第 k 個範例的第 i 個輸出單元之目標輸出值

$Y_i^k$  = 輸出層第 k 個範例的第 i 個輸出單元之推論輸出值

M = 範例數目

N = 輸出層處理單元數目


2. 驗證測試—在監督式學習類神經網路學習完成後，其結果可以用散佈圖來做驗證測試。散佈圖：對於應用於預測問題的倒傳遞網路，因其輸出層處理單元的推論輸出值與目標輸出值均為實數，因此可用散佈圖來做驗證測試。其定義為橫軸為輸出層處理單元的目標輸出值，縱軸為輸出層處理單元的推論輸出值，將各範例的結果點繪在圖上形成散佈圖，如果散佈圖上的點均在圖的對角線上代表結果良好。

### (4) 倒傳遞網路的優缺點：

1. 優點：
  - A. 輸出值為連續值，適用於樣本辨識、分類問題、函數合成、資料壓縮、專家系統等，應用範圍廣。
  - B. 學習精度高，可處理複雜的樣本辨識和高度非線性的函數合成問題。
  - C. 回想速度快。
2. 缺點：
  - A. 學習速度慢。
  - B. 有局部最小值困擾。

- C. 網路架構與網路動態的決定尚缺乏非常系統化的方法。
3. 可能遇到的問題：
- A. 局部最小值 (local minimum)。
  - B. 處理單元飽和。
  - C. 減緩現象和跳出現象。
  - D. 暫時不穩定。
  - E. 執行時間太長。
  - F. 嘗試各種網路架構、網路動態皆無法收斂。

### 3.4 交易策略



本研究除了利用類神經網路來建構台灣加權股價指數當日或隔  $n$  日收盤漲跌預測模型外，更進一步希望建構一交易策略來模擬實際利用測試期數據集 (Testing set) 的預測結果以進行交易所產生的報酬。本文中利用台指期貨做為買賣的交易標的，進行短線的買賣交易，以賺取買低賣高或高賣低買的價差。而關於買賣時機的部分，由於本研究所採用的輸入變數有一部份需採用每日 9:15 左右的資料，加上考量模型運算所需的時間，因此本研究設定每日的 9:20 為模擬交易時點：

1. 若類神經網路模型預測台灣加權股價指數當日或隔  $n$  日收盤相對於當日開盤價格為高 (上漲)，則利用 9:20 的第一筆交易做為買進，並於當日或隔  $n$  日 13:45 收盤時利用最後一筆交易進行賣出平倉。
2. 若類神經網路模型預測台灣加權股價指數當日或隔  $n$  日收盤相對於當日開盤價格為低 (下跌)，則利用 9:20 的第一筆交易做為賣出，並於當日或隔  $n$  日 13:45 收盤時利用最後一筆交易進行買進平倉。

3. 本研究之交易採每次一口期貨為限，至平倉動作完成後，始進行下一次交易。

期貨交易與一般各種商品或是證券交易相同，皆有交易成本必須予以考慮，根據期交所的相關規定可知，台指期貨的交易成本大致可以分成兩大部分，一部份屬於期交稅，為買進、賣出時按契約總值各課千分之 0.25，如果以指數 6000 點來計算為  $6000 \times 200 \times \frac{0.25}{1000} = 300$ ，也就是買進與賣出時各課 300 元，完成一次交易（買進與賣出）共需課 600 元；另一部份為交易手續費，此部分由交易人與期貨商自行議定，目前一般市場的行情為單邊 150~250 元不等，完全視投資人的交易狀況而定，本研究採單邊手續費 200 元，也就是完成一次交易（買進與賣出）共需手續費 400 元。綜合以上所需之相關成本，本研究完成一次交易共需交易成本 1000 元，相關資訊整理於下表。

表 3-1 台灣指數期貨相關交易成本

期貨交易稅	買進、賣出時按契約總值各課千分之 0.25
交易手續費	由交易人與期貨商自行議定，本研究採單邊交易手續費 200 元

## 第四章 實證研究分析

本研究之設計是以非現貨交易時段之指數資訊、股市與期貨原始交易資料變數、國際股市的漲跌變化、技術分析指標等四大類數據做為輸入變數，利用倒傳遞類神經網路來建構台灣加權指數當日收盤漲跌預測模型與隔  $n$  日收盤漲跌預測模型，然後與同一段時間之內採取多元迴歸模式進行優劣比較，並依據預測結果建立台股期貨買賣交易策略以檢視模型的獲利報酬率。

在資料樣本方面，本研究資料來源為寶碩財務科技財經資料庫，選擇 2002 年 5 月 1 日至 2004 年 10 月 31 日共計 30 個月，刪除資料缺漏與相關國際股市休市等因素即 544 個交易日之資料為實證研究之時間序列資料，其中訓練期資料期間為 2002 年 5 月 1 日至 2004 年 7 月 31 日共計 27 個月即 492 個交易日，測試期資料期間為 2004 年 8 月 1 日至 2004 年 10 月 31 日共計 3 個月即 52 個交易日，資料樣本區間之劃分說明如下圖所示。

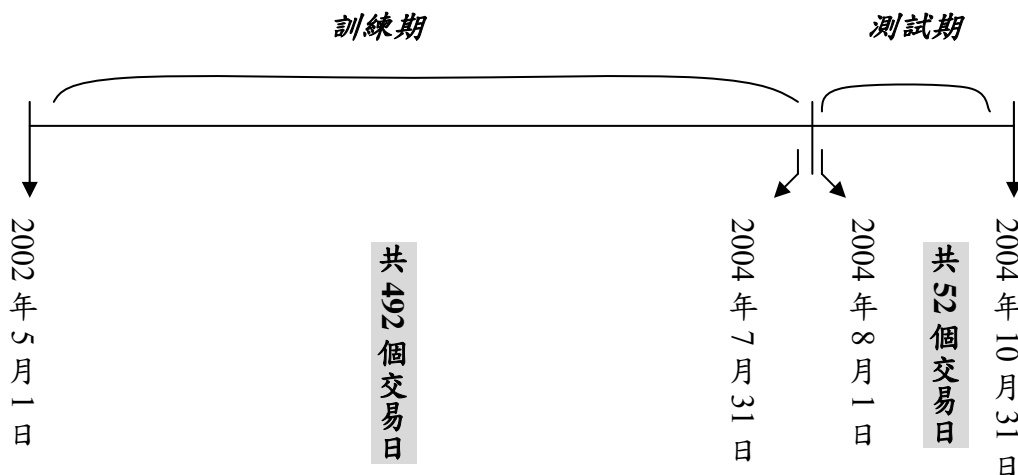


圖 4-1 資料樣本區間之劃分說明



在本章中，將利用類神經網路建構當日收盤漲跌預測模型、隔 n 日收盤漲跌預測模型與多元迴歸分析模型，分別求取其預測績效，並採用誤差均方根 (RMSE) 與驗證測試做為比較的基準，以瞭解此三種模型的預測績效之優劣順序，其說明如下：

### 1. 誤差均方根 (Root of Mean Square Error, RMSE)：

誤差均方根為衡量推論輸出值與目標輸出值的收斂程度，其值愈小代表其推論輸出值愈接近目標輸出值，RMSE 公式如下：

$$RMSE = \sqrt{\frac{\sum_k \sum_{i=1}^N (O_i^k - Y_i^k)^2}{M \times N}} \quad (4-1 \text{ 式})$$

### 2. 驗證測試：

可利用散佈圖來作驗證測試，其定義為橫軸為輸出層處理單元的目標輸出值，縱軸為輸出層處理單元的推論輸出值，將各範例的結果點繪在圖上形成散佈圖，如果散佈圖上的點均在圖的對角線上代表結果良好。

## 4.1 當日收盤漲跌預測模型分析

本研究利用 Neural Solutions Version 4.0 類神經網路軟體，並採用倒傳遞類神經網路模式中的多層感知機 (MLP) 做為網路預測模式，茲將模型建構、倒傳遞類神經網路參數選擇、實證結果分析詳細說明如下：

### (1) 模型建構說明：

以非現貨交易時段之指數資訊、股市與期貨原始交易資料變數、國際股市的漲跌變化、技術分析指標等四大類數據做為輸入變數，以建立倒傳遞類神經網路

預測模式，而輸出變數則為台股指數當日收盤漲跌點數，茲將輸入變數與輸出變數整理如下表所示。

表 4-1 預測現貨當日收盤漲跌點數之輸入、輸出變數表

輸入變數	輸出變數
<p>X1：前一交易日之現貨收盤指數變化率</p> <p>X2：前一交易日之期貨收盤指數變化率</p> <p>X3：今日 8：45～8：50 之期貨開盤指數變化率</p> <p>X4：今日韓股開盤指數變化率</p> <p>X5：前一交易日之美股道瓊（DJ）收盤指數變化率</p> <p>X6：前一交易日之美股那斯達克（NASDAQ）收盤指數變化率</p> <p>X7：今日 9：00～9：05 之現貨開盤指數變化率</p> <p>X8：今日 9：00～9：05 台股期貨與現貨之價差</p> <p>X9：今日 9：00～9：05 摩根台股期貨與現貨之價差</p> <p>X10：今日 9：10～9：15 現貨之總委買張數</p> <p>X11：今日 9：10～9：15 現貨之總委賣張數</p> <p>X12：今日 9：10～9：15 現貨之均買張數</p> <p>X13：今日 9：10～9：15 現貨之均賣張數</p> <p>X14：今日 9：10～9：15 現貨之成交量</p> <p>X15：前一交易日之（5MA-10MA）</p> <p>X16：前一交易日之（5MA-20MA）</p> <p>X17：前一交易日之（10MA-20MA）</p> <p>X18：前一交易日之（20MA-60MA）</p> <p>X19：前一交易日之（K 值-D 值）</p> <p>X20：前一交易日之（DIF 值-MACD 值）</p>	<p>Y：今日現貨收盤之漲跌點數</p>

X21：前一交易日之（5均量-22均量）	
X22：前一交易日之5均量變化率	

由於考量不同輸入變數間值域差距太大，為了避免小值域變數的重要性無法顯現出來，導致大值域的變數控制整個網路學習過程，因而影響學習效果。例如一輸入單元的值域介於 -0.1~0.1，而另一輸入單元的值域介於 -1000~1000，則前者將很難與後者相抗衡，所以必須先將所有輸入單元的變數值域作轉換，本研究將所有訓練期與測試期的輸入變數和輸出變數採取最大最小對映法映射至同一區間範圍內，且由於轉換函數為雙曲線正切函數，因此將值域對映到（-1.0, 1.0）上。

## （2）倒傳遞類神經網路參數選擇：

關於倒傳遞類神經網路參數選擇上，最主要包含了隱藏層層數、隱藏層處理單元數目、學習速率和慣性量之決定。在隱藏層層數方面，根據過去的研究發現通常隱藏層的數目為1層或2層時具有最好的收斂效果，並足以反應輸入單元間的交互作用關係，更多的隱藏層只會減緩網路收斂速度，且非線性程度較低的問題可取1層隱藏層即可，因此本研究將隱藏層之層數設定為1層。

在隱藏層處理單元數目方面，目前並沒有明確的公式或法則可以依循，不過根據過去研究和相關書籍可以發現，較常採用的方法大約可以分成下列幾種：葉怡成（2002）建議可採用 1.平均法—（輸入層處理單元數+輸出層處理單元數）÷2；2.總和法—（輸入層處理單元數+輸出層處理單元數）；3.加倍法—（輸入層處理單元數+輸出層處理單元數）×2，而 Masters（1993）亦建議可採用  $\frac{\sqrt{n \times m}}{2} \leq$  隱藏層處理單元數目  $\leq \sqrt{n \times m}$ （n 表輸入層處理單元數，m 表輸出層處理單元數），因此本研究即針對這些方式來進行測試以找出最佳之網路參數。

表 4-2 不同隱藏層處理單元數目之 MSE 與 RMSE

網路型態	訓練期之 MSE	訓練期之 RMSE
22-3-1	0.1655	0.4068
22-4-1	0.1532	0.3914
22-10-1	0.1167	0.3417
22-11-1	0.0961	0.3101
22-12-1	0.1082	0.3289
22-23-1	0.1329	0.3645
22-46-1	0.1156	0.3401

另外，在學習速率和慣性量方面，則依照 Neural Solutions Version 4.0 類神經網路軟體所預設的建議值，隱藏層之學習速率  $\eta = 1.0$ ，輸出層之學習速率  $\eta = 0.1$ ，慣性量採用 0.7，而轉換函數則採用雙曲線正切函數，學習過程則採用批次 (Batch) 學習，其他相關倒傳遞類神經網路參數之選擇設定茲整理於下表 4-3 中：

表 4-3 倒傳遞類神經網路參數之設定

參數	設定值
輸入層處理單元數目	22
隱藏層層數	1
隱藏層處理單元數目	11
輸出層處理單元數目	1
學習循環數目	1000
隱藏層轉換函數	TanhAxon
隱藏層學習速率	1.0

輸出層轉換函數	TanhAxon
輸出層學習速率	0.1
慣性量	0.7
學習過程	Batch

### (3) 實證結果分析：

本研究以收斂測試—誤差均方根（Root of Mean Square Error, RMSE）和驗證測試—散佈圖為模式的評估標準，當 RMSE 值愈小，散佈圖上的點均在圖的對角線上，或是相關係數的絕對值愈大，代表此模型的預測績效愈佳。

#### 1. 收斂測試：

首先，類神經網路模型先進行訓練期資料之性能績效（Active Performance）測試，其值愈小愈好，由下圖 4-2 可知此網路模型之收斂情況良好，因此可進一步利用此權重進行測試期資料之預測工作。




圖 4-2 訓練期資料之性能績效測試

當網路型態為 22-11-1 時，其訓練期之 MSE 為 0.0961，RMSE 為 0.3101，之後將測試期資料輸入模型中進行預測的工作，結果其測試期之 MSE 為 0.0999，亦即 RMSE 為 0.3161，如下表 4-4 所示。

表 4-4 訓練期與測試期資料之 MSE 與 RMSE

網路型態	訓練期之 MSE	訓練期之 RMSE	測試期之 MSE	測試期之 RMSE
22-11-1	0.0961	0.3101	0.0999	0.3161

2. 驗證測試：

應用於倒傳遞類神經網路之預測問題可用散佈圖來作驗證測試，由下圖 4-3 可知，利用推論輸出值來追蹤目標輸出值的結果良好，散佈圖上的點除了少數幾個偏離值外，大致均在圖的對角線上，此外，其相關係數亦達到  $R=0.7066$ ，在統計學上已屬於高度相關，因此，此模型的配適良好。




圖 4-3 預測當日收盤漲跌之散佈圖

由下圖 4-4 可知，測試期資料之推論輸出值與目標輸出值的走勢圖中，除了少數幾個交易日差異較大外，其餘對於預測當日收盤漲跌點數與漲跌方向均有不錯的配適。




圖 4-4 預測當日收盤漲跌之目標輸出值與推論輸出值走勢圖

除了計算收盤漲跌點數之目標輸出值與推論輸出值的 MSE、RMSE 和利用散佈圖進行驗證測試後，進一步亦想了解本模型對於預測大盤漲跌方向的相關資訊，下表 4-5 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測當日收盤漲跌方向的準確率高達 73.0769%，不管是預測上漲或是下跌，其正確的次數均高於錯誤的次數，如此對於開盤 9:20 分鐘時，欲決定期貨作多或是作空方向提供不錯的指引，亦提高研判大盤走向的準確性與交易的報酬率。

表 4-5 預測當日收盤漲跌方向之結果

實際上漲天數：23 實際下跌天數：29		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	16	7
	下跌	7	22
預測方向準確率：73.0769%			

#### 4.2 隔 n 日收盤漲跌預測模型分析

本節嘗試利用前一節中所建立之倒傳遞類神經網路預測模式為基礎，採用相同的資料樣本區間、22 個輸入變數、隱藏層層數、隱藏層處理單元數目、學習速率、慣性量和轉換函數等，僅是在輸出變數方面有所修正，改採隔 1、2、3、4、5、10、20 日之大盤收盤漲跌點數為輸出變數，重新建構類神經網路預測模式，用以預測台股指數隔 1、2、3、4、5、10、20 日之收盤漲跌點數與漲跌方向，求取其預測績效並進行相關比較，並與預測當日收盤漲跌模型進行比較，以期在相同的輸入變數條件下，驗證本模型是否依然受到隔夜效應（Overnight Effect）的影響。

與前一節相同，採用收斂測試與驗證測試做為比較的基準，分為四大類：(1) 測試期之 MSE 與 RMSE；(2) 散佈圖與相關係數；(3) 目標輸出值與推論輸出值之走勢圖；(4) 收盤漲跌方向之準確率，進行比較以瞭解此模型預測隔 1、2、3、4、5、10、20 日績效之優劣順序。



### (1) 預測隔 1 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 1 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 1 日收盤漲跌之 MSE 為 0.2665，亦即 RMSE 為 0.5162，如下表 4-6 所示。

表 4-6 預測隔 1 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 1 日	0.2665	0.5162

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-5 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R = -0.1721$ ，僅屬於低度相關，因此，預測隔 1 日收盤的模型配適狀況不甚佳。




圖 4-5 預測隔 1 日收盤漲跌之散佈圖

由下圖 4-6 可知，預測隔 1 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，不論是在預測漲跌點數或是漲跌方向，結果皆不甚理想。




圖 4-6 預測隔 1 日收盤漲跌之目標輸出值與推論輸出值走勢圖

下表 4-7 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 1 日收盤漲跌方向的準確率僅有 51.9231%。

表 4-7 預測隔 1 日收盤漲跌方向之結果

實際上漲天數：22 實際下跌天數：30		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	8	14
	下跌	11	19
預測方向準確率：51.9231%			

(2) 預測隔 2 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 2 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 2 日收盤漲跌之 MSE 為 0.2837，亦即 RMSE 為 0.5327，如下表 4-8 所示。



表 4-8 預測隔 2 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 2 日	0.2837	0.5327

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-7 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R=0.0129$ ，僅屬於低度相關，因此，預測隔 2 日收盤的模型配適狀況不甚佳。




圖 4-7 預測隔 2 日收盤漲跌之散佈圖

由下圖 4-8 可知，預測隔 2 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，不論是在預測漲跌點數或是漲跌方向，結果皆不甚理想。




圖 4-8 預測隔 2 日收盤漲跌之目標輸出值與推論輸出值走勢圖

下表 4-9 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 2 日收盤漲跌方向的準確率僅有 53.8462%。

表 4-9 預測隔 2 日收盤漲跌方向之結果

實際上漲天數：22 實際下跌天數：30		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	12	10
	下跌	14	16
預測方向準確率：53.8462%			

### (3) 預測隔 3 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 3 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 3 日收盤漲跌之 MSE 為 0.4072，亦即 RMSE 為 0.6381，如下表 4-10 所示。

表 4-10 預測隔 3 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 3 日	0.4072	0.6381

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-9 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R = -0.1207$ ，僅屬於低度相關，因此，預測隔 3 日收盤的模型配適狀況不甚佳。




圖 4-9 預測隔 3 日收盤漲跌之散佈圖

由下圖 4-10 可知，預測隔 3 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，對於預測漲跌點數結果不甚理想，僅有當盤勢上漲時，預測漲跌方向的成績不錯。




圖 4-10 預測隔 3 日收盤漲跌之目標輸出值與推論輸出值走勢圖

下表 4-11 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 3 日收盤漲跌方向的準確率僅有 46.1538%。

表 4-11 預測隔 3 日收盤漲跌方向之結果

實際上漲天數：24 實際下跌天數：28		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	21	3
	下跌	25	3
預測方向準確率：46.1538%			

#### (4) 預測隔 4 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 4 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 4 日收盤漲跌之 MSE 為 0.3322，亦即 RMSE 為 0.5764，如下表 4-12 所示。

表 4-12 預測隔 4 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 4 日	0.3322	0.5764

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-11 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R = -0.1674$ ，僅屬於低度相關，因此，預測隔 4 日收盤的模型配適狀況不甚佳。




圖 4-11 預測隔 4 日收盤漲跌之散佈圖

由下圖 4-12 可知，預測隔 4 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，不論是在預測漲跌點數或是漲跌方向，結果皆不甚理想。




圖 4-12 預測隔 4 日收盤漲跌之目標輸出值與推論輸出值走勢圖



下表 4-13 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 4 日收盤漲跌方向的準確率僅有 36.5385%。

表 4-13 預測隔 4 日收盤漲跌方向之結果

實際上漲天數：23 實際下跌天數：29		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	9	14
	下跌	19	10
預測方向準確率：36.5385%			

#### (5) 預測隔 5 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 5 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 5 日收盤漲跌之 MSE 為 0.2784，亦即 RMSE 為 0.5276，如下表 4-14 所示。

表 4-14 預測隔 5 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 5 日	0.2784	0.5276

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-13 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R=0.0578$ ，僅屬於低度相關，因此，預測隔 5 日收盤的模型配適狀況不甚佳。




圖 4-13 預測隔 5 日收盤漲跌之散佈圖

由下圖 4-14 可知，預測隔 5 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，不論是在預測漲跌點數或是漲跌方向，結果皆不甚理想。




圖 4-14 預測隔 5 日收盤漲跌之目標輸出值與推論輸出值走勢圖

下表 4-15 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 5 日收盤漲跌方向的準確率僅有 44.2308%。

表 4-15 預測隔 5 日收盤漲跌方向之結果

實際上漲天數：22 實際下跌天數：30		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	16	6
	下跌	23	7
預測方向準確率：44.2308%			

#### (6) 預測隔 10 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 10 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 10 日收盤漲跌之 MSE 為 0.2544，亦即 RMSE 為 0.5044，如下表 4-16 所示。

表 4-16 預測隔 10 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 10 日	0.2544	0.5044

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-15 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R=0.0627$ ，僅屬於低度相關，因此，預測隔 10 日收盤的模型配適狀況不甚佳。




圖 4-15 預測隔 10 日收盤漲跌之散佈圖

由下圖 4-16 可知，預測隔 10 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，不論是在預測漲跌點數或是漲跌方向，結果皆不甚理想。




圖 4-16 預測隔 10 日收盤漲跌之目標輸出值與推論輸出值走勢圖

下表 4-17 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 10 日收盤漲跌方向的準確率僅有 55.7692%。

表 4-17 預測隔 10 日收盤漲跌方向之結果

實際上漲天數：23 實際下跌天數：29		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	16	7
	下跌	16	13
預測方向準確率：55.7692%			

#### (7) 預測隔 20 日收盤漲跌

在收斂測試方面，當類神經網路預測天數為隔 20 日時，將測試期資料輸入模型中進行預測的工作，結果預測隔 20 日收盤漲跌之 MSE 為 0.2703，亦即 RMSE 為 0.5199，如下表 4-18 所示。

表 4-18 預測隔 20 日之 MSE 與 RMSE

預測天數	測試期之 MSE	測試期之 RMSE
隔 20 日	0.2703	0.5199

在驗證測試方面，則利用散佈圖和相關係數來追蹤推論輸出值與目標輸出值的配適狀況，由下圖 4-17 可知，散佈圖上的點只有大約一半是在其對角線上，而其相關係數則為  $R=0.0217$ ，僅屬於低度相關，因此，預測隔 20 日收盤的模型配適狀況不甚佳。

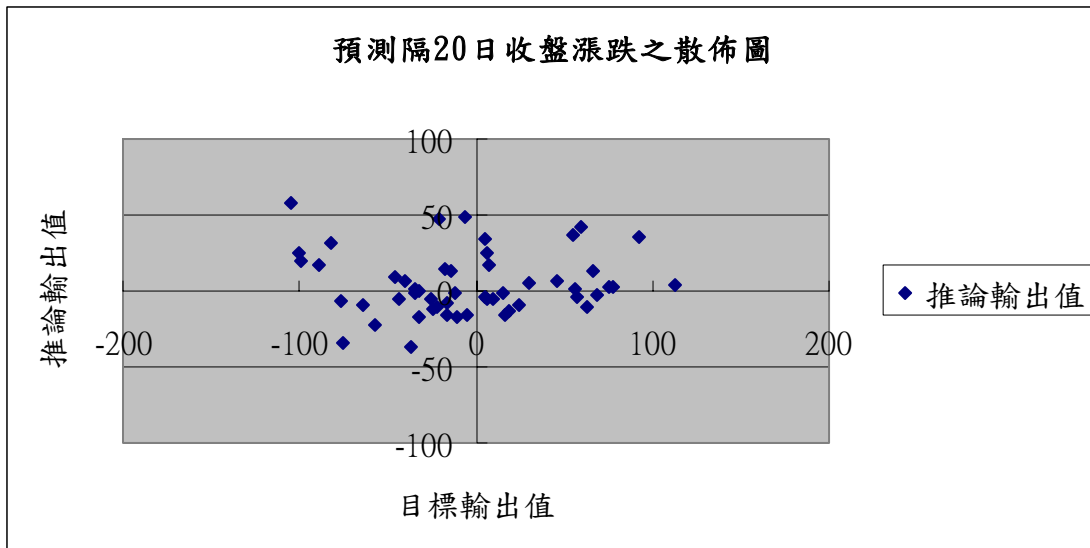


圖 4-17 預測隔 20 日收盤漲跌之散佈圖

由下圖 4-18 可知，預測隔 20 日收盤漲跌之測試期資料中，推論輸出值並不具備有預測目標輸出值的功能，不論是在預測漲跌點數或是漲跌方向，結果皆不甚理想。




圖 4-18 預測隔 20 日收盤漲跌之目標輸出值與推論輸出值走勢圖

下表 4-19 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知本模型對於預測隔 20 日收盤漲跌方向的準確率僅有 55.7692%。

表 4-19 預測隔 20 日收盤漲跌方向之結果

實際上漲天數：23 實際下跌天數：29		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	13	10
	下跌	13	16
預測方向準確率：55.7692%			



### 4.3 多元迴歸預測模型分析

許多統計方法希望能夠找出變數之間的關係，以期藉由其他變數來預測一個或多個變數，根據某個已知變數的值，來預測另一個變數的平均值的方法，稱作迴歸(Regression)，最早於 19 世紀末由法蘭西斯·高登(Francis Galton, 1822-1911)所提出。迴歸分析 (Regression Analysis) 可以說是應用統計分析中極為重要的一項工具，它可以用於資料分析、預測及建構模式。

#### (1) 模式建構：

利用本章第一節表 4-1 中所提出的 22 個輸入變數作為自變數，其輸出變數作為應變數，建立迴歸分析模式如下：

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_{22} X_{22i} + \varepsilon \quad (4-2 \text{ 式})$$

其中， $\beta_i$ 為迴歸係數， $X_i$ 為自變數， $Y$ 為應變數。

$$\varepsilon_i \sim \text{iid } N(0, \sigma^2) \quad i=1,2,3,\dots,492$$

在資料樣本區間方面，其中訓練期資料期間為 2002 年 5 月 1 日至 2004 年 7 月 31 日共計 492 個交易日，測試期資料期間為 2004 年 8 月 1 日至 2004 年 10 月 31 日共計 52 個交易日。

由於迴歸分析模式的自變數資料，乃是採用與類神經網路訓練期相同的資料，其 22 個輸入變數中，有一部份皆取自台股指數原始資料或是所衍生計算求得的技术分析指標，因此變數間必定存在共線性的問題。所以先透過逐步迴歸分析來篩選變數，得出 7 個較重要的變數，分別是今日韓股開盤指數變化率 ( $X_4$ )、前一交易日之美股NASDAQ收盤指數變化率 ( $X_6$ )、今日期貨開盤指數變化率 ( $X_3$ )、今日現貨之總委買張數 ( $X_{10}$ )、今日現貨之總委賣張數 ( $X_{11}$ )、前一交易日之 5MA-20MA ( $X_{16}$ )、前一交易日之 5 均量變化率 ( $X_{22}$ )，並分別求出其  $\beta$  估計值，茲將其結果整理於下表 4-20 中。自變數為現貨當日收盤漲跌點數。

表 4-20 迴歸預測模式之  $\beta$  估計表

變數名稱	$\beta$ 估計值	標準差	t 值	p 值
常數 ( $\beta_0$ )	-9.940	8.862	-1.122	0.263
今日韓股開盤指數變化率 ( $X_4$ )	570.369	186.365	3.060	0.002
前一交易日之美股NASDAQ收盤 指數變化率 ( $X_6$ )	-792.743	199.704	-3.970	0.000
今日期貨開盤指數變化率 ( $X_3$ )	8959.599	1190.572	7.525	0.000
今日現貨之總委買張數 ( $X_{10}$ )	0.0002683	0.000	5.314	0.000
今日現貨之總委賣張數 ( $X_{11}$ )	-0.0002644	0.000	-5.923	0.000



前一交易日之 5MA-20MA ( $X_{16}$ )	-0.04831	0.019	-2.584	0.010
前一交易日之 5 均量變化率( $X_{22}$ )	99.088	41.294	2.400	0.017

由上表 4-20 中可知，此 7 個自變數的 p 值皆小於 0.05，具有顯著性，並可得台股指數當日收盤漲跌點數之迴歸預測模式如下：

$$Y = -9.940 + 570.369X_4 - 792.743X_6 + 8959.599X_3 + 0.0002683X_{10} - 0.0002644X_{11} - 0.04831X_{16} + 99.088X_{22}$$

此模型的 $R^2=0.187434$ ，Adjusted  $R^2$ （校正複判定係數）=0.175682，可以解釋為Y的變異僅有不到 2 成是來自於X的變化，而其相關係數R也只有 0.4329，相較於類神經網路的 0.7066 明顯偏低。可知個別的自變數X對於應變數Y具有顯著性，然而將多個變數納入考慮時，卻無法充分解釋Y的變異，此點更充分說明自變數與應變數間存在非線性的關係，因此一般的線性迴歸分析可能無法充分解釋其變異，而須佐以非線性的類神經網路模型。變異數分析表（ANOVA）如下表 4-21 所述：

表 4-21 迴歸分析預測模式之變異數分析表

	自由度	平方和 (SS)	均方和 (MS)	F	p 值
迴歸 (Regression)	7	426706.4	60958.06	15.94916	$6.81 \times 10^{-19}$
殘差 (Error)	484	1849859	3822.022		
總和 (Total)	491	2276565			

## (2) 實證結果分析

測試期資料期間為 2004 年 8 月 1 日至 2004 年 10 月 31 日共計 52 個交易日，將其帶入此迴歸預測模型中，可得推論輸出值，再與目標輸出值作比較，計算得出其測試期之 MSE 為 0.1685，RMSE 為 0.4105，如下表 4-22 所示。

表 4-22 迴歸分析預測模式之 MSE 與 RMSE

Model	測試期之 MSE	測試期之 RMSE
迴歸預測模式	0.1685	0.4105

由下圖 4-19 可知，散佈圖上的點大約有 3/4 分佈在其對角線上，不過其相關係數 R 僅有 0.4329，屬於中度相關，其適配狀況尚可。




圖 4-19 迴歸分析預測模式之散佈圖




圖 4-20 迴歸分析預測模式之目標輸出值與推論輸出值走勢圖

由上圖 4-20 可知，迴歸分析預測模式之推論輸出值與目標輸出值的走勢圖中，對於預測當日收盤漲跌點數方面有數個交易日差異較大，而在預測漲跌方向上則有不錯的配適。

下表 4-23 中統計當模型預測收盤上漲或下跌時，而實際收盤時上漲或下跌的次數，可知迴歸分析預測模式對於預測當日收盤漲跌方向的準確率為 65.3846%，低於類神經網路預測模式，但其在下跌方向的預測有不錯的結果。

表 4-23 迴歸分析預測模式預測漲跌方向之結果

實際上漲天數：23 實際下跌天數：29		預測漲跌方向	
		上漲	下跌
實際漲跌方向	上漲	9	14
	下跌	4	25
預測方向準確率：65.3846%			

#### 4.4 不同模型預測結果之比較

本節將探討不同模型的預測結果，主要針對當日收盤漲跌預測模型、隔 n 日收盤漲跌預測模型與多元迴歸預測模型三者進行比較，選擇其測試期間之 MSE 與 RMSE 愈小者，且預測收盤漲跌方向準確率愈高者，即是本研究最佳之模型，並以其建立台股期貨當沖買賣交易策略，進一步檢視模型的獲利報酬率。

表 4-24 不同模型測試期間之 MSE 與 RMSE

Model	測試期之 MSE	測試期之 RMSE
預測當日收盤漲跌 (類神經)	0.0999	0.3161
預測隔 1 日收盤漲跌 (類神經)	0.2665	0.5162
預測隔 2 日收盤漲跌 (類神經)	0.2837	0.5327
預測隔 3 日收盤漲跌 (類神經)	0.4072	0.6381
預測隔 4 日收盤漲跌 (類神經)	0.3322	0.5764
預測隔 5 日收盤漲跌 (類神經)	0.2784	0.5276
預測隔 10 日收盤漲跌 (類神經)	0.2544	0.5044
預測隔 20 日收盤漲跌 (類神經)	0.2703	0.5199
迴歸分析預測模型	0.1685	0.4105

由上表 4-24 可知，類神經網路預測當日收盤漲跌模型的 MSE 與 RMSE 最小，迴歸分析預測模型次之，而同樣以類神經預測隔 n 日收盤漲跌的模型效果皆不佳，因此可知以類神經網路建立之當日收盤漲跌預測模型為最適之預測模型。

上面所計算之 MSE 與 RMSE，主要用以比較預測漲跌點數的績效，若要了解模型所預測之收盤漲跌方向與實際收盤漲跌方向是否一致，則需比較其預測方向準確率的高低，茲將相關數據整理於下表 4-25 中。

表 4-25 不同模型預測漲跌方向之準確率

Model	預測方向準確率
預測當日收盤漲跌 (類神經)	73.0769%
預測隔 1 日收盤漲跌 (類神經)	51.9231%
預測隔 2 日收盤漲跌 (類神經)	53.8462%

預測隔 3 日收盤漲跌 (類神經)	46.1538%
預測隔 4 日收盤漲跌 (類神經)	36.5385%
預測隔 5 日收盤漲跌 (類神經)	44.2308%
預測隔 10 日收盤漲跌 (類神經)	55.7692%
預測隔 20 日收盤漲跌 (類神經)	55.7692%
迴歸分析預測模型	65.3846%

由上表 4-25 可知，以類神經網路預測當日收盤漲跌方向的準確率最高，迴歸分析預測模型次之，因此可知依然是以類神經網路建立之當日收盤漲跌預測模型為最適之預測模型。

#### 4.5 交易報酬分析



由前一節的模型預測結果相關比較可知，經由類神經網路所建構之當日收盤漲跌預測模型為最適的預測模型，所以本研究以此模型建立台股期貨當沖買賣交易策略，並計算在實證測試期內（2004 年 8 月 1 日至 2004 年 10 月 31 日，共計 52 個交易日）的報酬率。每次交易以一口台指期貨為限，利用每日 9：20 的開盤價作為買進或賣出價格，並利用當日 13：45 的收盤價作為賣出沖銷或買進回補的價格，交易以當日沖銷為主，不進行隔日留倉動作。交易起始日的投組淨值為一口期貨保證金 105,000 元，每次交易扣除相關成本 1000 元，也就是期貨指數 5 點，茲將相關損益報酬分析整理於下表 4-26、表 4-27、表 4-28 與下圖 4-21、圖 4-22 中。

表 4-26 交易報酬統計表

實證測試期	獲利點數	損失點數	交易成本	淨獲利
2004/08/01~2004/10/31	1131 點	584 點	52×5=260 點	287 點

表 4-27 獲利與損失比較表

最大獲利點數	最大損失點數	平均獲利點數	平均損失點數
147	92	37.7	26.55

表 4-28 交易報酬分析表

日期	投組淨值	日報酬率變動 $\ln(S_i/S_{i-1})$	日報酬標準差	年化波動率	日報酬率	年報酬率	Sharp Ratio
	105000						
2004/8/2	106000	0.009478744	0.064897	102.6119%	1.0513%	262.8205%	2.5418
2004/8/3	101000	-0.048318577					
2004/8/4	101600	0.005923018					
2004/8/5	130000	0.246490915					
2004/8/6	125200	-0.037621992					
2004/8/9	140600	0.116006521					
2004/8/10	140400	-0.001423488					
2004/8/11	128600	-0.08778868					
2004/8/12	122000	-0.052685767					
2004/8/13	131200	0.072701832					
2004/8/16	131400	0.00152323					
2004/8/17	133600	0.016604155					
...	...	...					
...	...	...					
2004/10/21	164400	-0.034671734					
2004/10/22	168400	0.024039619					
2004/10/26	173400	0.029258963					
2004/10/27	178400	0.028427156					
2004/10/28	168600	-0.056499175					
2004/10/29	162400	-0.037466618					




圖 4-21 投組淨值與大盤走勢比較圖




圖 4-22 日報酬率變動圖

## 第五章 結論與建議

### 5.1 結論

本研究嘗試考慮非現貨交易時段之指數資訊、股市與期貨的原始交易資料變數、國際股市的漲跌變化與技術分析指標等四大類輸入資料變數，來建構倒傳遞類神經網路模型，用以預測台灣加權股價指數當日收盤的漲跌點數與漲跌方向，輔以搭配多元迴歸模式和預測隔  $n$  日收盤漲跌模型進行比較，進一步選取最適宜之預測模型，並依據預測結果建立台指期貨當沖買賣交易策略。本節根據相關實證研究結果分析，提出以下結論：

1. 以倒傳遞類神經網路所建構之預測模式優於多元迴歸模式：

本研究以類神經網路來建構預測當日收盤漲跌的方式，並於同一時段內，以相同變數資料進行多元迴歸模式的比較，其結果發現類神經網路模型的 MSE 為 0.0999，RMSE 為 0.3161，由散佈圖中可知，推論輸出值追蹤目標輸出值的結果良好，相關係數  $R=0.7066$ ，預測方向準確率為 73.0769%；而多元迴歸模型的 MSE 為 0.1685，RMSE 為 0.4105，相關係數  $R=0.4329$ ，預測方向準確率為 65.3846%。可知類神經網路模型不論是在預測收盤漲跌點數或是漲跌方向上，其預測能力皆優於多元迴歸模型。

2. 本研究輸入變數與輸出變數間具有非線性關係，適合使用類神經網路模型：

從逐步迴歸分析中所篩選出的 7 個輸入變數，皆與輸出變數間呈現顯著性，而其相關係數  $R$  卻只有 0.4329，可知若同時將多個變數納入考慮，卻無法充分



解釋輸出變數的變異，則可推論輸入變數與輸出變數間存在非線性的關係，故不適用一般的線性迴歸分析，因而應改採用具有分析非線性特徵的類神經網路模型。

3. 隔夜效應 (Overnight Effect) 的因素影響模型的預測能力：

利用相同輸入變數所建構之預測當日收盤漲跌模型與預測隔  $n$  日收盤漲跌模型的比較可知，預測隔  $n$  日收盤漲跌模型的 MSE 和 RMSE 皆高於預測當日收盤漲跌模型，且預測方向準確率皆較低，所以不論是在預測收盤漲跌點數與漲跌方向上，其預測能力皆因為隔夜效應而下滑。

4. 逐步迴歸分析所篩選出的 7 個輸入變數，分別隸屬於本研究所規劃的 4 大類輸入資料中，進一步支持影響股市變動的因素是多因子的：

由於先前利用類神經網路預測股市所做的研究中，大致將輸入變數的焦點單純集中在基本分析之經濟指標、原始交易資料變數或是技術分析指標上，缺乏多因子的考量，然而影響股市變動的因素是多方面的，統計的逐步迴歸分析可佐證此一觀點，表示本研究所考慮的 4 大類輸入資料皆是影響股市變動的重要因素。

5. 本研究預測當日收盤漲跌方向的準確率高達 73.0769%，代表預測模型已有效掌握大盤漲跌的趨勢：

技術分析指標中 MA (移動平均線) 具有掌握股市變動趨勢的功能，本研究高達 73.0769% 的預測方向準確率，也印證技術分析指標具有舉足輕重的影響，而非技術分析指標無用論。

6. 本研究所使用的輸入變數中，有 11 個輸入變數是屬於技術分析領域的範疇，而經由逐步迴歸分析所篩選的變數中，亦有 4 個是屬於此範疇，推論技術分析指標對於模型的預測能力具有極大的貢獻。

7. 經由模型所建構的台指期貨當沖買賣交易策略，可獲得高達 262.8205% 的年報酬率：

扣除交易成本而計算實證測試期的報酬，在 52 個日交易天數中，有高達 287 點的指數期貨報酬和 262.8205% 的年報酬率，投組淨值呈現穩定的成長，日報酬率變動亦大致在  $\pm 10\%$  以內，因此本模型的報酬績效良好。

## 5.2 研究貢獻

本節將說明本研究在類神經網路之建構與實務投資上之貢獻：

1. 本研究模型使用 4 大類輸入變數，有別於以往相關研究只是單純考慮基本面因素或是技術分析指標，且影響股市漲跌趨勢並非單一因素，如此可更完整且全面性地掌握股市收盤走勢，以提供投資人決策的輔助工具。
2. 由預測當日收盤漲跌模型與預測隔 n 日收盤漲跌模型的相關績效比較中可知，預測當日收盤模型的準確性高於預測隔 n 日收盤模型，此可推論預測隔 n 日收盤模型的準確性受限於隔夜效應、國際股市波動與政治事件等因素影響，因此有效縮短預測天數可提高模型預測的準確性。
3. 本研究所建構之模型可於每日早上 9:20 預測當日收盤漲跌點數與漲跌方向，如此便可提供投資人做多或是放空的參考依據，更可在已知預測收盤點數下，若台指期貨與現貨出現大幅且不正常的價差，可進一步進行套利交易。
4. 藉由類神經網路預測當日收盤漲跌與當沖交易策略的執行，本研究的交易年

報酬率高達 262.8205%且 Sharp Ratio 為 2.541816，亦即在承擔每一單位風險，可獲得 2.5418 單位的超額報酬下，可知此預測模型具有高報酬低風險的特性。

### 5.3 後續研究建議

本研究為類神經網路模型針對台灣加權指數當日收盤漲跌的預測，後續相關的研究亦有不少可供改進的空間，茲整理以下幾點建議可供後續研究考慮與努力的方向：

#### 1. 輸入變數資料的改變：

本研究輸入變數包含 4 大類輸入資料，雖包含有長天期的移動平均線，可作為研判一段時間的漲跌趨勢，不過尚有一部份是屬於極短線的盤中資訊，因此本模型對於預測當日收盤漲跌有很高的準確率，但是若要預測隔  $n$  日收盤漲跌，則容易受到隔夜效應的影響，因此建議後續研究可嘗試採用更多適合預測波段漲跌趨勢的指標，以求解決與突破本模型無法有效預測隔  $n$  日收盤漲跌的疏漏。

#### 2. 資料樣本區間的移動：

本研究僅採用固定資料樣本區間的輸入輸出資料，來作為訓練期與測試期的資料來源，不過隨著時空環境的改變，有可能先前的訓練期資料已無法有效掌握與追蹤後續測試期資料的變動，因此後續研究可考慮採用 Window Horizon 的方式，每隔一段時間來動態改變資料樣本區間的選取。

#### 3. 輸出變數資料的改變：

本研究所採用的輸出變數為當日現貨收盤之漲跌點數，若嘗試使用下一個

30 分鐘或 60 分鐘的收盤漲跌點數，如此模型可更適用於極短線的當沖操作。

#### 4. 預測標的的改變：

本研究模型為針對大盤漲跌點數的預測，交易策略則採用台指期貨為交易對象，若配合台灣期貨交易所的其他期貨工具，例如金融指數期貨與電子指數期貨，與陸續推出的利率期貨等等，本研究建議後續研究可針對金融指數現貨或電子指數現貨來作為預測的標的物，期可進一步搭配操作多種期貨商品，以及利用不同種類指數的漲跌趨勢，來進行指數期貨套利的交易。

#### 5. 其他人工智慧方法的使用：

近年來人工智慧的發展進步神速且日新月異，本研究僅針對倒傳遞類神經網路之模型來作為大盤指數的漲跌預測，後續研究可進一步利用基因演算法或是分類源系統之模型來建構預測相關指數的工具。



## 參考文獻

### 一、中文部分

1. 郭煒翎，「摩根臺灣股價指數期貨與現貨間之領先與落後關係」，中正大學企業管理學系碩士論文，1998。
2. 姜德宣，「台股指數期貨(TAIFEX)與現貨之因果關係研究」，台灣大學商學研究所碩士論文，1999。
3. 洪志豪，「技術指標KD、MACD、RSI 與WMS%R之操作績效實證」，台灣大學國際企業學研究所碩士論文，1999。
4. 詹錦宏、袁澤峻，「景氣循環與股價指數之預測—類神經網路之應用」，證交資料，第 449 期，1999。
5. 周慶華，「整合基因演算法及類神經網路於現貨開盤指數之預測—以新加坡交易所摩根台股指數期貨為例」，輔仁大學金融研究所碩士論文，2001。
6. 何怡滿、康信鴻，「以GARCH模型探討SIMEX摩根台股指數期貨、TAIFEX台股指數期貨與TSE臺指期貨之領先/落後關係」，中華管理評論，Vol. 4，No. 2，pp. 1-12，Mar. 2001。
7. 陳安斌，財務金融資訊管理與投資決策，寶基資訊股份有限公司出版，2002。
8. 葉怡成，應用類神經網路，儒林出版社，2002。
9. 杜金龍，技術指標在臺灣股市應用的訣竅，財訊出版社，2002。
10. 柯忠昇，「台灣與美國主要股價指數現貨與期貨市場外溢效果之研究」，台灣大學商學研究所碩士論文，2002。
11. 李建輝，「遺傳演化類神經網路在預測台股指數期貨的應用」，東吳大學經濟研究所碩士論文，2002。
12. 葉怡成，類神經網路模式應用與實作，儒林出版社，2003。

13. 謝劍平，現代投資學—分析與管理，智勝文化事業有限公司出版，2003。
14. 朱正修，「台灣股市與國際股市連動性之研究」，成功大學統計學系碩士論文，2004。



## 二、英文部分

1. Baba, N. and Kozaki, M., “An Intelligent Forecasting System of Stock Price Using Neural Networks,” IEEE International Joint Conference on Neural Networks, Vol. 1, pp. 371-377, 1992.
2. Bergerson, K. and Wunsch, D. C., “A Commodity Trading Model based on a Neural Network-Expert System Hybrid,” IEEE International Joint Conference on Neural Networks, Vol. 1, pp. 289-293, 1991.
3. Brock, W., Lakonishok J. and Lebaron B., “Simple Technical Trading Rules and the Stochastic Properties of Stock Returns,” Journal of Finance, Vol. 47, No. 5, pp. 1731-1764, Dec. 1992.
4. Casas, C.A., “Tactical asset allocation: an artificial neural network based model.” Neural Networks, International Joint Conference on, Vol. 3, pp. 1811-1816, 15-19 July 2001.
5. Chan, Kalok, “A Further Analysis of the Lead-Lag Relationship between the Cash Market and Stock Index Futures Market,” Review of Financial studies, Vol. 5, Iss. 1, pp. 123-152, 1992.
6. Cheh, John J. Weinberg, Randy S. Yook and Ken C., “An application of artificial neural network investment system to predict takeover targets.” Article. Feature article Journal of Applied Business Research, Vol. 15, pp. 33-45, Fall 1999.
7. Chou, R. Y., Lin, J. L. and Wu, C. S., “Modeling the Taiwan Stock Market and International Linkages,” Pacific Economic Review, Vol. 4, Iss. 3, pp. 305, Oct. 1999.
8. Eun, C. S. and Shim, S., “International Transmission of Stock Market Movements,” Journal of Financial and Quantitative Analysis, Vol. 24, No. 2, pp. 241-256, June 1989.

9. Finnerty, J. F. and Park, H. Y., "Stock Index Futures: Does the Tail Wag the Dog? A Technical Notes" Financial Analysts Journal, Vol. 43, pp. 57-61, 1987.
10. Fung, H. G., Leung, W. K. and Xu, X. E., "Information Role of U.S. Futures Trading in a Global Financial Market," Journal of Futures Markets, Vol. 21, Iss. 11, pp. 1071-1090, Sep. 2001.
11. George S., Jr. and Yoon, Young., "Applying Artificial Neural Networks to Investment Analysis." Financial Analysts Journal, Charlottesville, Vol. 48, pp. 78, Sep./Oct. 1992.
12. Glaria Bengoechea, A., *et al.*, "Stock market indices in Santiago de Chile: forecasting using neural networks." Neural Networks, IEEE International Conference on, Vol. 4, pp. 2172-2175, 3-6 June 1996.
13. Grudnitski, G. and Osbum, L., "Forecasting S&P and Gold Futures Prices: An Application of Neural Networks," The Journal of Finance, Vol. 5, pp. 1155-1176, 1993.
14. Jeon, B. N. and Von Furstenberg, G. M., "Growing International Co-movement in Stock Price Indexes," Quarterly Review of Economics and Business, Vol. 30, No. 3, pp. 15-30, Autumn 1990.
15. Kamijo, K. and Tanigawa, T., "Stock Price Pattern Recognition: A Recurrent Neural Network Approach," IEEE International Joint Conference on Neural Networks, Vol. 1, pp. 215-221, June 1990.
16. Kawaller, I. G., Kock, P. D. and Koch, T. W., "The Temporal Price Relationship Between S&P 500 Futures and the S&P 500 Index," The Journal of Finance, Vol. 42, Iss. 5, pp. 1309-1329, 1987.
17. Kimoto, T. and Asakawa, K., "Stock Market Prediction System with Modular Neural Networks," IEEE International Joint Conference on Neural Networks, Vol. 1, pp. 1-6, 1990.



18. King, M. A. and Wadhvani, S., "Transmission of Volatility between Stock Markets," The Review of Financial Studies, Vol. 3, pp. 5-33, 1990.
19. Kryzanowski, Lawrence, *et al.*, "Using artificial neural networks to pick stocks." Financial Analysts Journal, Charlottesville, Vol. 49, Iss. 4, pp. 21, Jul./Aug. 1993.
20. Lapends, A. and Farber, R., "Nonlinear Signal Processing Using Neural Networks: Prediction and System Modeling," Los Alamos National Laboratory Report, 1987.
21. Lin, W. L., Engle, R. F., and Ito, T., "Do Bulls and Bears Move across Borders? International Transmission of Stock Returns and Volatility," The Review of Financial Studies, Vol. 3, pp. 507-508, 1994.
22. Martikainen, T., Perttunen, J. and Puttonen, V., "On the Dynamics of Stock Index Futures and Individual Stock Returns," Journal of Business Finance and Accounting, Vol. 22, pp. 87-100, 1995.
23. Martikainen, T. and Puttonen, V., "A Note on the Predictability of Finnish Stock Market Returns: Evidence from Stock Index Futures Markets," European Journal of Operational Research, Vol. 73, pp. 27-32, 1994.
24. Min, J. H. and Najand, M., "A Further Investigation of the Lead-Lag Relationship between the Spot Market and Stock Index Futures: Early Evidence from Korea," Journal of Futures Markets, Vol. 19, Iss. 2, pp. 217-232, Mar. 1999.
25. Pan, M. S. and Hsueh, L. P., "Transmission of Stock Returns and Volatility between the U.S. and Japan: Evidence from Stock Index Futures Markets," Asia-Pacific Financial Markets, Vol. 5, No. 3, pp. 211-225, Jan. 1998.
26. Paul Kang Hoh Phua, *et al.*, "Neural network with genetically evolved algorithms for stocks prediction," Asia-Pacific Journal of Operational Research, Singapore, Vol. 18, Iss. 1, pp. 103, May 2001.

27. Pizzi, M. A., Economopoulos, A., and O'Neill, H. M., "An Examination of the Relationship Between Stock Index Cash and Futures Market: A Cointegration Approach," Journal of Futures Markets, Vol. 18, pp. 297-305, 1998.
28. Pruitt, Stephen W. and White, Richard E., "The CRISMA Trading System: Who Says Technical Analysis Can't Beat the Market?" Journal of Portfolio Management, pp. 55-58, Sep. 1988.
29. Stoll, H. R. and Whaley, R.E., "The Dynamics of Stock Index and Stock Index Futures Returns," Journal of Financial and Quantitative Analysis, Vol. 25, No. 4, pp. 441-468, Dec. 1990.
30. Su, Y. C. and Wu, C., "Dynamic Relations Among International Stock Markets," International Review of Economics and Finance, Vol. 7, No. 1, pp. 63-84, 1998.
31. Tan, C.N.W., "Trading a NYSE-stock with a simple artificial neural network-based financial trading system." Artificial Neural Networks and Expert Systems, First New Zealand International Two-Stream Conference on, pp. 24-26, Nov. 1993.
32. Tse, Y., "International Transmission of Information: Evidence from the Euroyen and Eurodollar Futures Markets," Journal of International Money and Finance, Vol. 17, Iss. 6, pp. 909-929, Dec. 1998.
33. Wei, K. C. J., Liu, Y. J., Yang, C. C., and Chaung, G. S., "Volatility and Price Change Spillover Effects Across the Developed and Emerging Markets," Pacific-Basin Finance Journal, Vol. 3, pp. 113-136, 1995.
34. Zhang, G., Patuwo, B. E., and Hu, M. Y., "Forecasting with Artificial Neural Networks: The State of the Art." International Journal of Forecasting, Vol. 14, pp.35-62, 1998.