

# 回饋式類神經網路知識發掘應用 於最適投資組合資金配置

Knowledge Discovery from Recurrent Neural Network for Optimal Portfolio Capital Allocation

黃國棟 *Kuo-Dong Huang*

許中川 *Chung-Chian Hsu*

黃金生 *Chin-Sheng Huang*

國立雲林科技大學

National Yunlin University of Science and Technology

90 年 7 月 24 日收稿、90 年 12 月 21 日第一次修改、91 年 11 月 13 日接受刊登

## 摘要

投資人在複雜的投資環境中進行投資，無疑是希望能夠賺取更多的報酬來增加自己的財富；近年來，雖然有不少國內外學者試圖從龐大的股市資料中，運用各種資料探勘的技術預測市場走勢，提供投資人做為投資決策參考的依據；但是，在眾多研究者以各種理論或方法解釋市場表現的研究中，少有研究討論到投資組合資金配置這個重要議題，而且在以類神經網路進行股市預測的研究議題中，大多只是針對未來的指數或個股的走勢進行預測而已，未能針對資料庫知識發掘流程的最後一個階段，知識的呈現、表達與轉譯等步驟進行更深一層的研究，致使從資料庫中所擷取的資訊非常有限；而本研究主要是提出一完整的「財務資料庫知識發掘模型」，針對財務資料庫中的歷史資料，進行前置處理、建立最適投資組合評估模型、回饋式類神經網路預測等步驟，提供投資人一個兼具風險與報酬考量的最適投資組合資金配置策略，之後再以法則萃取演算法，探勘類神經網路結構中的黑盒，使財務資料庫中所隱含的資訊與知識能夠外顯化，提供使用者較佳的投資決策支援環境。最後，本研究以雛型系統開發與實際的財金資料庫資料，驗證此架構的可行性。

關鍵字：資料庫知識發掘、資料探勘、回饋式類神經網路、法則萃取、資金配置

## Abstract

The investors made decisions for investment on sophisticated investment environment. Undoubtedly, the investors hope earn more returns to increase their wealth. In recent years, many researchers try to use data mining or other relates techniques trying to discovery patterns from huge financial database to support investors to make decision. However, most of these researchers just explain market performance with theories or methods. The important issues of portfolio capital allocation are addressed relatively few. Moreover, a lot of researches which used artificial neural network for stocks prediction focused on prediction for marketing index or stock price. But, past researches after didn't present or translate the patterns explicitly, which are mined from databases. Therefore, this research mainly proposed a complete "financial database knowledge discovery model" to help investors make investment decision. First, we process financial database, build optimal portfolio analysis model and use recurrent neural network to form optimal portfolio capital allocation strategy. Second, we use a rule extraction algorithm to mine unknown rules from the neural network. The intention to mine the unknown rules from the black box of neural network is that finding implicit information or relate knowledge from financial database. The discovered knowledge or information from database will become useful information, which can help investors to make decision and provide investors optimal investment decision supports. Finally, the feasibility of this method is evaluated by developing a prototype system and testing with real financial data.

**Keywords:** Knowledge Discovery in Databases、Data Mining、Recurrent Neural Network、Rule Extraction、Capital Allocation

## 壹、緒論

在自由化與全球化的投資市場中，投資人除了擁有更多的機會去尋找獲利

的空間外，也必須面臨更多的投資風險；因此，在任何一筆交易皆會影響個人財富增減的情況之下，投資人若未能及時掌握、提昇投資的技能，將很容易被投資過程所產生的財富重整洪流所淘汰。然而，到目前為止雖然有許多國內外學者嘗試以各種理論及方法，分析和解釋股市的表現；但是，在陳稼興&張應華[民 88]的研究中卻指出，目前財務研究的領域上，雖然已經有許多學者利用投資組合的策略，來幫助投資人達到趨避風險的目的。可是，現在仍然缺乏好的理論與模型來處理投資組合資金配置這個重要的議題。

近年來，雖然許多學者嘗試以各種理論及方法，分析和解釋股市的表現，其中又以利用歷史股價資料和人工智慧演算法預測股票加權指數或各股股價等議題最引人注目[Tkacz, 2001][Gavrilov et al., 2000]；但是，根據資料庫知識發掘學者 Fayyad[1996a][1996b]與 Han[2001]的看法，在資料庫知識發掘的過程中，除了利用資料探勘的技術，發掘或預測隱含於資料庫中的模式或趨勢外，尚包含對探勘所得到的模式或趨勢，進行知識表達與呈現的步驟。而這些以人工智慧進行股價指數預測的研究議題中，大多只有針對資料庫內的資料進行趨勢的分析與預測而已，而未能對資料庫知識發掘流程中，最後一個知識的呈現與表達的步驟進行更深入的研究，甚為可惜；因此，本研究本研究主要是提出一個「財務資料庫知識發掘模型」，支援使用者透過歷史的財務資料庫、回饋式類神經網路與法則萃取演算法，進行資料庫知識探勘，俾提供投資人一個同時擁有報酬與風險投資組合策略，並且同時對在預測模型中，已訓練完成的回饋式類神經網路進行法則的萃取與探勘，讓投資人在進行投資決策時，有更多、更充分的資訊來支援其決策。

本篇論文後續內容結構如下：第二節文獻探討、第三節財務資料庫知識發掘模型、第四節實驗分析與結果、最後一節是結論及未來研究方向。

## 貳、文獻探討

財務管理與資料探勘結合的應用是近年來熱門的研究領域之一，相關的議題包含資料探勘技術、人工智慧、財務分析、股市預測、風險、績效評估等議題。本篇研究主要是經由財務資料庫中，所儲存的資料經過分析、預測與探勘等步驟，所形成的知識，作為投資人在進行投資組合資金配置時，決策輔助的工具；因此，本節針對與本篇研究相關的議題，包含投資組合理論、資料探勘與資料庫知識發掘、智慧型系統、智慧型系統在財務管理應用等文獻進行探討。

## 一、投資組合理論

投資人在投資理財的過程中，除了可以獲得報酬之外，尚必須承擔投資的風險；因此，為了確保投資的報酬與降低投資風險，投資人可以利用「不要把所有雞蛋放在同一個籃子裡」的風險分散觀念，進行所謂的多元化投資組合策略，將有限的資金同時投資於多種資產，根據各資產之間不同的報酬與風險特性截長補短，藉以分散投資於單一資產所帶來的非系統風險[Alexander et al., 1995] [Elton & Martin, 1995]。而關於投資組合的理論主要可分為傳統投資組合理論與現代投資組合理論；傳統投資組合理論分析的重點在於，除了考慮證券的風險與報酬外，尚包含投資人的需求偏好及投資人本身的限制條件。例如個人或家庭的財務狀況、承受風險的意願、個人處理投資的知識或技能等；由於這些評估因子不易被量化，而且以常識法則為依據的分析方法過於主觀，所以出現了所謂的現代投資組合理論，學者們試圖以客觀的方法改善傳統投資組合理論的缺點，以量化的數據取代定性的變數因子，在效率前緣(efficient frontier)之下，求得效率投組合[Elton & Martin, 1995]。

由於本研究主要是針對現代投資理論進行投資策略之研究，因此整理關於現代投資組合理論中，較相關的研究。其中，1952年，馬可維茲(Harry M. Markowitz)首創以數學模式來分析投資組合，提出平均數—變異數投資組合模式(Mean-Variance portfolio model)，為現代投資組合理論之濫觴；馬氏利用各投資項目之間的相關程度 $\sigma_{ij}$  或  $\rho_{ij}$  來說明如何降低投資的風險，達到多元化投資組合的目的；之後，夏普(William F. Sharpe)提出了馬可維茲模型的簡化方法—單一指數模式(Single index model)或稱「對角線模式」(Diagonal model)，他假設不同的證券報酬間的相互關係均可以藉由某些基本的因素，加以解釋，因此在加入市場因素( $R_m$ )及隨機因素( $\varepsilon_i$ )後，將平均數—變異數投資組合模式中的二次規劃法 $\delta$  展開式加以簡化，從而決定各投資項目比重 $w_i$  的效率前緣，可是這兩種在財務投資領域中，最普遍被應用的投資組合分析模式，皆存在只能以線性求解投資組合，以及計算程序或參數過於複雜等問題[Elton & Martin, 1995]。

關於投資組合績效的評估不僅是投資管理程序中的最後一個階段，它更是一種連續的過程，一種回饋與控制的機制，能夠使得投資管理程序更有效率；對投資人而言，除了能夠藉由績效的評估，瞭解投資過程的優劣，亦可以利用投資組合的績效來調整個人投資限制、投資目標與投資的資金等[Alexander et al., 民 84]。而在投資組合績效評估中，最常用的三種指標，簡介如下[Elton & Martin,

1995] :

- 1.Sharpe Ratio : 報酬/標準差，即計算每承受一單位總風險，投資組合會有多少的報酬，是市場上最常見的衡量指標，適用於投資組合內之資產皆為風險性資產。
- 2.Treynor measure : 報酬/ $\beta$ ，即計算每承受一單位系統風險，投資組合會有多少的報酬。適用於投資組合非常龐大，且有多位基金經理人在操盤時，因為此時非系統性風險已被充分的分散，故衡量績效時只要考慮系統性風險即可。
- 3.Jensen measure : 以投資組合報酬和市場報酬作迴歸，取其截距項，當此一截距為正，表投資組合績效比市場佳。較適用於投資組合中有風險性資產、且有無風險性資產。

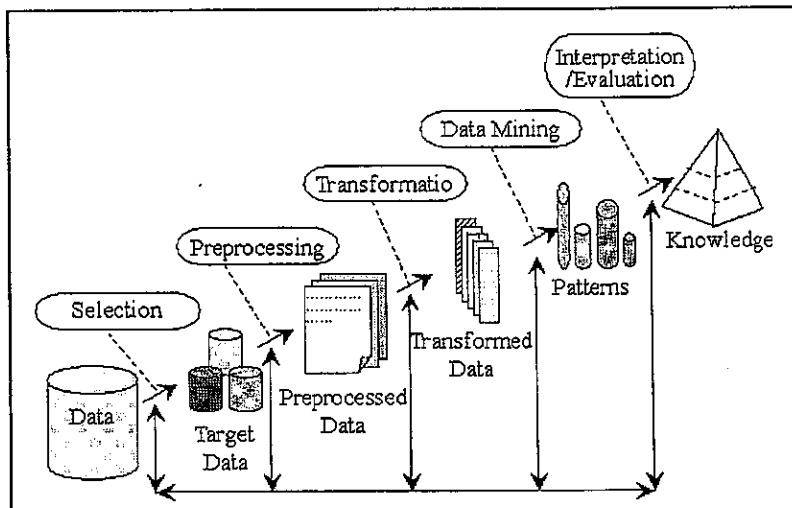
## 二、資料探勘與資料庫知識發掘

由於資訊科技的成熟與普及，使得資料的產生與收集呈現了爆炸性的發展；因此，自從 80 年代末，即開始有學者利用資訊技術，探索資料庫中所隱含的模式或規則，找出實用而且具有價值的資訊，輔助人們進行各項決策的制定，而這些研究議題則包含了資料探勘（Data Mining, DM）與資料庫知識發掘（Knowledge Discovery in Databases, KDD）。根據 Fayyad [1996c] 與 Han [2001] 的定義，資料探勘與資料庫知識發掘，同樣都是指利用資訊技術，從資料庫中找出隱含的趨勢或資訊；但是，資料探勘著重於如何由資料庫之中，萃取出各種隱含的模式；而資料庫知識發掘的流程，除了探索資料庫中所隱含的模式或規則外，還包含評價資料探勘技術所找到的模式或規則等步驟，甚至說明、解釋這些模式，藉此決定哪一些模式能夠成為知識；所以，它們兩者之間的差異在於資料庫知識發掘是一探索資料庫隱含資訊的整體流程，而資料探勘則是這一探索流程中的特定步驟，而資料庫知識發掘的流程（如圖 1 所示），主要可分為：資料選取、前置處理、資料探勘、轉譯探勘結果等五大步驟 [Fayyad 1996a] [Fayyad 1996b] [Piatetsky-Shapiro, 1991]：

## 三、智慧型系統

Brachman et. Al [1996]，在 Mining Business Database 的研究中指出，資料探勘與資料庫知識發掘一般較常使用的工具，除了統計的方法外，尚包含了智慧型系統—類神經網路、決策樹、遺傳演算法與範例庫等；而本研究在利用財

務資料庫，進行回饋式類神經網路知識發掘的過程，即是使用智慧型系統來作為資料探勘的工具；因此，本小節中，除了將對智慧型系統作定義外，亦將對本研究所應用的類神經網路及法則萃取技術作更詳盡的探討。



[資料來源：Fayyad 1996b]

圖1 資料庫知識探索處理過程

根據 Goonatilake et. al [1995]的定義，「智慧型系統」是利用資訊設備，從大量的資料中擷取出相關的資訊，幫助使用者做決策的資訊系統，這些系統通常是以類神經網路、基因遺傳演算法、模糊系統等人工智慧的技術建置而成。而由於在證券市場中進行財務資料庫進行知識的發掘與探索的過程中，證券價格的變動十分快速，且影響價格變動的因素多如牛毛，其所產生出來的資料或資訊相當繁雜且龐大，因此，本研究在智慧型系統的應用上，選擇具有學習、非線性、無模式估計及良好歸納推演能力的類神經網路，作為投資組合資金配置的預測工具。

雖然類神經網路較數學統計方法較適合解決高度複雜的預測問題[Odom, 1990]，且已被證實在股價預測上擁有不錯的效果[Kimoto and Asakawa, 1990] [Wuthrich et al., 1998]；可是，在 Fu[1999]的研究中卻指出類神經網路存在了兩個重要的議題：(1) 如何表達 (2) 如何萃取神經網路知識；因為類神經網路，它的神經元運算過程本身即是一個黑盒（black box）架構；而 Berry et al.[1997]亦指出「就算資料探勘的目標是預測性，其所使用的模型是否具備足夠的解釋

來支持預測的結果，仍是非常重要的議題」；因此，近年來有不少的研究，即在探討如何將類神經網路的黑盒知識透明化，其中 Craven & Shavlik[1996]在研究中，指出類神經網路法則萃取的重要性包含下列兩點：

- 1.增加信賴度：讓使用者能夠瞭解學習系統是如何進行決策的過程，增加使用者對系統效能的信賴度。
- 2.發現輸入資料的關聯與特性：將結果以人類所能理解的方式呈現，將可能獲得原有學習機制中無法呈現或表達的規則或特性。

另外，在 Setiono & Liu[1996]的研究中亦指出，當訓練的資料由類神經網路輸入層到隱藏層時就已產生了規則，每個隱藏層亦將對各自收集的資料，保留輸入層與隱讓該隱藏層觸發的資料，所以，每一個隱藏層都可視為一個類別（Class），而法則萃取則是在探討各類別間可能讓輸出觸發的各種權值組合；Omlin & Giles[1996]認為，一個訓練完成的神經網路週期狀態神經元輸出將會形成類聚，而這些類聚都是經過學習才形成同一群組，所以法則萃取是去搜尋狀態神經元輸出空間裡的類聚。

關於法則萃取演算法，最常見的演算法包含了 BIO-RE、Subset、MofN、Partial-RE 及 Full-RE 等（如表 1），其各種演算法都具有其應用的上的特性，如 BIO-RE 演算法即能夠有效的表達具有二元值輸出入的神經網路法則、Subset 能夠表達結點上、下層之簡子集合的關聯；因此在上列這些演算法中，並無明顯的優劣之分，而是要適才適用的選出一個適合應用領域的方法，才能夠使法則萃取達到最佳的效果[Taha & Ghosh,1999]。

表1 法則萃取技術比較表

	BIO-RE	Partial-RE	Full-RE	Subset	MofN
Provides certainty factors	No	Yes	Yes	No	No
May need a default rule	Yes	Yes	No	Yes	Yes
Binary inputs	Yes	Yes	Yes	Yes	Yes
Normalized inputs	No	Yes	Yes	No	No
Continuous inputs	No	No	Yes	No	No
Complexity	Very Low	Low	Med	Med	High
Additional overheads	No	No	No	No	Yes

[資料來源：Taha & Ghosh,1999]

#### 四、智慧型系統與財務管理相關研究

類神經網路在許多應用領域已經被證明為一個相當不錯的方法，其中，在財務投資方面的研究，即有：投資選股、信用風險預測、股票評價、股價漲跌與投資時機預測、投資決策支援與投資組合策略等的應用。其中，與本研究較相關的研究有：Moody et. al[1997]提出 Differential Sharpe Ratio 投資組合最佳化模型，以投資財富效用的概念及回饋神經網路的增強式學習功能，建構一個投資人何時進行買進、賣出的交易策略；陳稼興& 張應華[民 88]，結合類神經網路、遺傳演算法和模糊理論，運用柔性計算技術建構一套股票交易決策支援系統，提供投資者選股、擇時、資金配置等功能，幫助投資者解決複雜的股票交易決策問題；苑守慈& 官美蘭[民 88]認為股市預測系統除了提供準確的預測服務外，尚必須提供加值的服務，方能提高投資人使用的意願，因此，他們使用類神經網路法則萃取及與知識庫神經網路的整合，萃取前向式神經網路的規則，融入個人化或專家的認知知識，使預測系統達到個人化、透明化的功能。

雖然以類神經網路為基礎的股市預測系統的研究十分眾多，而且預測結果上皆有不錯的績效[Kimoto and Asakawa, 1990] [Wuthrich et al., 1998]；但是，在大部份的股價預測研究中，大多只是對大盤或個股的價格進行預測；可是，對投資者而言，除必須對價格趨勢有所了解外，還要有一個有效的投資策略來提供決策支援；因此，本論文有別於先前所介紹的類神經網路結合財務預測的研究，除了利用在時間序列上具有增強式學習特性的回饋式類神經網路求解最佳的資金配置權數，提供最適投資策略外，亦嘗試針對回饋式類神經網路中的黑盒架構，進行探勘，萃取出具有價值的資訊，使資料庫知識探勘的過程，除了可以提供投資人最適的投資資金配策略外，亦能夠透過知識的萃取過程，讓使用者獲得隱藏於資料庫中的寶貴知識，進而提高系統的可信度及使用者的使用意願。

#### 參、財務資料庫知識發掘模型

由文獻探討中，我們可以發現到目前為止，以智慧型系統所建立的財務資料庫探勘研究，大多著重於個股或大盤指數的預測，然而雖有少數的論文對投資決策的問題進行討論；但是並無一套從資料收集、分析、預測與探勘到知識呈現的完整的財務資料庫知識探勘模型。因此，在本節中，將提出一完整的財務資料庫知識探勘架構，利用回饋式類神經網路與法則萃取等技術，從資料庫

中萃取高價值、有用的資訊與知識，輔助投資人建構最佳的投資組合資金配置策略。本節內容主要包含：一、財務資料庫知識探勘架構：簡述財務資料庫知識探勘架構的各個步驟；二、前置處理：介紹探勘流程的前置處理；三、投資組合評估模型：闡述投資組合的建構方法；四、回饋式類神經網路：詳述回饋式類神經網路的預測架構；五、法則萃取：說明類神經網路法則萃取與知識的探勘流程。

## 一、財務資料庫知識探勘架構

投資人在詭譎多變的證券市場中投資，無疑是希望能夠以最小的風險獲取最大的報酬；因此，本研究提出的財務資料庫知識探勘模型（如圖 2），即針對財務資料庫中的歷史資料，進行前置處理、建立最適投資組合評估模型、回饋式類神經網路預測等步驟，形成最適投資組合資金配置策略後，再根據已訓練完成的回饋式類神經網路架構進行法則萃取，探勘類神經網路的黑盒結構，使資料庫中所隱含的模式及回饋式類神經網路學習完成的知識能夠外顯化，並且回饋給使用者。

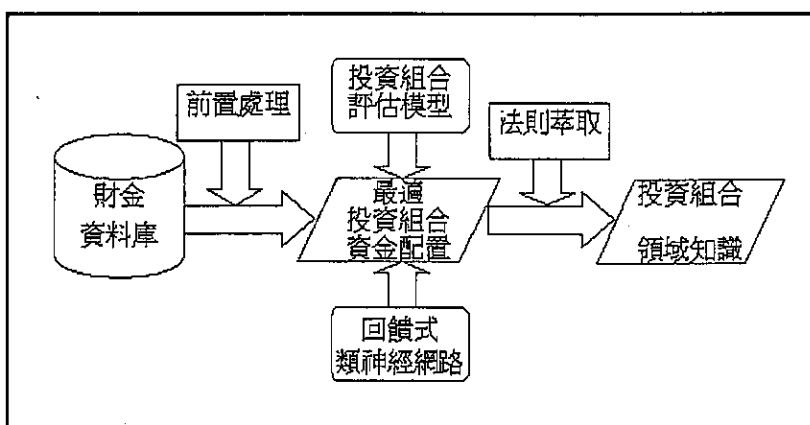


圖2 財務資料庫知識發掘模型

## 二、前置處理

前置處理為資料探勘與資料庫知識發掘中的一項重要的前置步驟[Han 1993]，其主要是針對目標資料進行篩選、過濾的步驟，將無關、不正確或格式不符的資料予以排除或修正，避免原始資料中的雜訊影響資料探勘準確度。

而在本研究中，則是將前置處理分為：資料處理、資料正規化與補充領域知識等三個步驟（如圖 3）：

1. 資料處理：對原始資料庫表格中的資料，進行整合及過慮的步驟，主要包含的項目有：資料欄位格式的轉換、缺值、錯誤資料的刪除，以避免資料的偏誤，影響資料探勘的品質。
2. 資料正規化：透過數值資料的正規化，可以降低同一屬性資料最大與最小值之間的差距，提昇探勘後所得到的資訊品質；同時，藉由資料的正規化，可避免太大或太小的資料值所產生的運算過程過於複雜的問題。
3. 補充領域知識：當原始探勘資料不夠豐富時，可加入額外探勘分析目標相關的背景知識，或稱為領域知識[許中川, 民 86]，使目標資料能夠藉由各研究的專業領域知識，讓探勘資料更具多樣化，並且提昇資料探勘的資訊價值；在本研究中，即透過財務管理背景知識，計算各投資項目的技術指標，作為類神經網路預測模型輸入的一部份，以提昇資料探勘的績效。

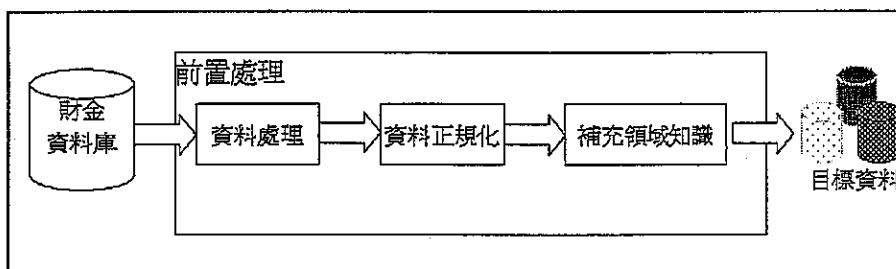


圖3 前置處理步驟

### 三、投資組合評估模型

報酬與風險為一體兩面，高投資報酬必然會伴隨著高風險；但是本研究中，所建構的「最適投資組合」資金配置策略，除了考量投資報酬外，還同時將分析投資過程所產生的風險。即建立一折衷的方式，定義「最適投資組合」必須要滿足投資效用最大化—讓投資人獲得單位風險之下的最大報酬。在風險和報酬的衡量上，我們是採取 Markowitz 於 1952 年，所提出的以證券報酬的變異數  $\sigma^2$  來表示投資組合的風險，以報酬加權平均數  $\mu$  代表投資組合的期望報酬：

但是，Markowitz 當初所提出的評估方法，並未導入交易成本的概念，無法滿足證券交易時，所必須付證交稅與手續費等現況；因此，在經過修正後，其數學表示式如公式(1)所示。

$$S = \frac{\mu_p}{\sigma_p^2} = \frac{\sum_{i=1}^n (w_i^t \mu_i^t - |w_i^t - w_i^{t-1}| \times P_i^t C)}{\sum_{i=1}^n w_i^t \sigma_i^{t2} + 2 \sum_{i=1}^n \sum_{i>j} w_i^t w_j^t \sigma_{ij}^t} \quad (1)$$

$$\text{s.t. } \sum_{i=1}^n w_i^t \leq 1 \quad \text{and} \quad w_i^t \geq 0$$

式中：

$\mu_p$ ：投資組合的期望報酬

$\sigma_p^2$ ：投資組合的總風險

$w_i^t$ ：證券  $i$  在時間點  $t$  的投資比率

$w_j^t$ ：證券  $j$  在時間點  $t$  的投資比率

$\mu_i^t$ ：證券  $i$  在時間點  $t$  的期望報酬

$\sigma_i^{t2}$ ：證券  $i$  在時間點  $t$  的變異數

$\sigma_{ij}^t$ ：證券  $i$ 、 $j$  在時間點  $t$  的共變異數

$P_i^t$ ：證券  $i$  的價格在  $t$  時間點的價格

$C$ ：交易成本率

$n$ ：投資項目個數

#### 四、回饋式神經網路

雖然求解 (1) 式的最適投資組合最大化，可以利用作業研究 (Operations Research, OR) 中的二次規劃或是單體法等方式求解最適投資組合，但從文獻探討中可以發現，雖然用變異數估計投資組合的風險，最為大家所接採納，但若將其以二次規劃或其他方法運算時，因為其在共變數的估計個數將達到  $C_2^n$ ，在加上其他的變數 ( $\mu$ 、 $\sigma$ ) 時，其運算的時間複雜度將十分可觀；因此，本研究將借重類神經網路在模擬非線性及高度的學習與預測能力，求解最適的資

金配置權數。

在類神經網路架構的選擇上，由於證券資料是一具有時間序列特性的資料；因此對於一般常見的前向式神經網路架構，對時間序列資料處理問題，只能對輸入資料作空間訊息資料的處理（例如：在預測  $t$  期資料時，同時輸入  $t-1$ 、 $t-2$ 、 $t-3$ ……、 $t-n$  期的資料），無法滿足本研究的需求；因此，本研究使用回饋式神經網路架構，透過網路之間各處理單元的回饋式連結，表達時間序列資料中前後的關聯及其相互的影響狀態，以達到學習最佳化與增強式學習（reinforcement learning）的效果。在回饋式神經網路架構，主要可分為全回饋式神經網路（fully recurrent neural）和部份回饋式神經網路（partial recurrent network）或稱為限制回饋神經網路（limited recurrent networks），本研究中主要採用部份回饋式神經網路中的 Jordan's 回饋式架構，它結合了前向式與回饋式的神經網路架構；其主要的優點在於除了可以利用前向式神經網路的倒傳遞演算法進行自我的學習與錯誤修正外，亦能夠透過神經元之間的連結架構，表達時間序列的前後關連，達到時間序列最佳化的學習與預測效果[Bigus, 1996]。

關於回饋式類神經網路輸出入設計；如：圖 4 所示，其中，類神經網路的輸入層－主要包含：市場資訊、歷史報酬與回饋輸入  $F(MI_{1 \dots M}, R_{1 \dots N}, W_{1 \dots N}^{t-1})$  三個部分，主要內容說明如下：

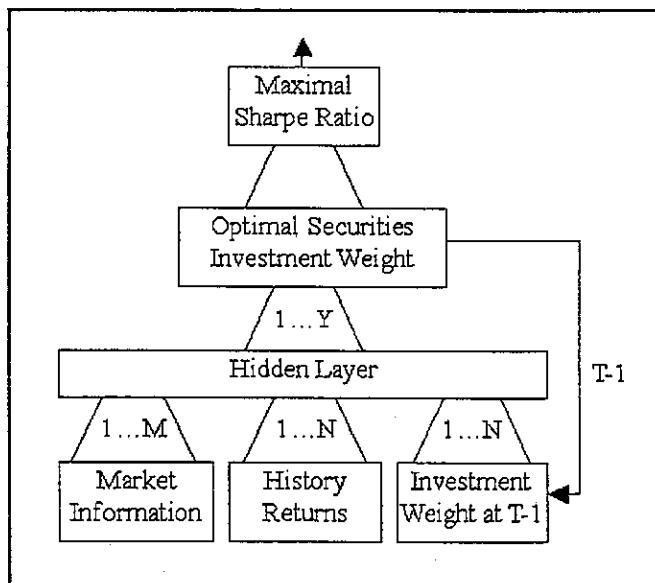


圖 4 回饋式類神經網路預測架構圖

1. 市場變數  $MI_{1,...,M}$ ：為有效預測市場趨勢，本研究使用技術指標領域知識作為市場資訊的輸入變數，使預測模型能夠更有效的掌握市場的脈動，近而提昇預測的準確性。
2. 歷史報酬  $R_{1,...,N}$ ：在資金配置過程中，報酬是一重要的決策因素，在神經網路中，我們使用歷史報酬作為網路輸入，是為了使投資報酬能夠達到最佳化。
3. 神經網路的回饋輸入  $W_{1,...,N}^{t-1}$ ：前一期的回饋輸入則是希望網路能夠在資金分配預測過程中，能夠根據時間序列前後的狀況進行調整，達到快速收斂、快速學習的目的。

在研究過程中，本研究的目的使投資項目透過投資權數的調整，使各期的最適投資組合的衡量指標達到最大化；因此，在類神經網路訓練過程中的目標函數  $O(w_i)$ ，我們是採取最陡坡降法（Gradient Steepest Descent Method）的概念，修正最適投資組合向量，使 Sharpe ratio 達到最大化。其運算的步驟為：

1. 個別證券投資權數的貢獻度：以個別證券投資比率  $w_i$  對最適投資組合的衡量指標  $-S$  作偏微分；如（2）式，可獲得到個別證券投資權數  $w_i$  的增減，對衡量指標  $-S$  產生的變動量。
2. 投資權數正規化：因為投資組合的權數加總必須小於等於 1，所以本研究利用 softmax 函數；如（3）式，對（2）式所求得之個別證券投資權數的貢獻度進行正規化，使各期的投資比率變動量  $\Delta w_i$  能夠針對個別證券貢獻度的高低，得到一明顯的比值。
3. 目標函數：根據前一期的投資權數  $w_i^{t-1}$ ，加上經由（2）式及（3）式所得到之投資權數變化的貢獻度  $\Delta w_i$ ；如（4）式，可得每一期類神經網路在建構最適投資組合目標函數投資權數  $w_i^t$ 。

$$\nabla S = \left[ \frac{\partial S}{\partial w_1} \quad \frac{\partial S}{\partial w_2} \quad \dots \quad \frac{\partial S}{\partial w_N} \right] \quad (2)$$

其中：

$$\frac{\partial S}{\partial w_i} = \frac{\partial \mu_p}{\partial w_i} \sigma_p^{-2} + \frac{\partial \sigma_p^{-2}}{\partial w_i} \mu_p$$

$$\Delta W = [\Delta w_1 \quad \Delta w_2 \dots \Delta w_n] = softmax(\nabla S) \quad (3)$$

$$w_i^t = w_i^{t-1} + \Delta w_i \quad (4)$$

關於類神經網路學習的演算法，本研究是採用具有高度學習功能、平行運算能力及具有容錯性的倒傳遞神經網路（Back-Propagation Neural network, BPN）的學習演算法，它的網路錯誤修正的原理是採用的是「坡降法」（gradient descent）的觀念，將表達網路實際輸出與目標輸出之差異的誤差函數最小化，並透過加權值的不斷調整，來達成網路訓練與預測的目的。

## 五、法則萃取

由文獻探討中得知，類神經網路除了擁有非線性學習的能力外，神經元資料值亦會根據其連結權重形成類聚，所以，此時若將神經元之間的連結關係，以結構化的語法表示，將能夠使類神經網路的黑盒處理流程透明化，進而找出推論的知識規則。

在類神經網路推論法則的萃取的研究中，雖然幾乎所有的萃取演算法都是以前向式類神經網路架構探討輸出入神經元之間的推論關係，但是，在本研究中所使用的 Jordan's 回饋式神經網路架構，本質上是一個前向式網路架構的改良型，所以本研究在對類神經網路法則萃取時，乃採用前向式網路法則萃取的方法。因為財金資料是屬於具有連續型、正規畫的數值資料，而在較適合的法則萃取演算法中只有 Partial-RE 和 Full-RE 兩種，而且 Full-RE 在法則推論的過程，可以明確的計算各輸入範圍的發生機率，加上它在類神經網路法則的結構表示上非常完整，因為本研究在法則萃取的演算法中，採用 Full-RE 演算法作為知識探索的技術。

Full-RE 法則萃取演算法，主要的推論流程可分為下列三個步驟：

1. 計算群聚範圍：Full-RE 法則萃取演算法在對資料值進行群聚分析時，採用 Chi-2 演算法，它是透過兩個階段的群聚確認：(1) 對資料值進行初步的界限範圍的判定、(2) 進行深入的範圍確認，以達到群聚的分類目的。這兩個階段所使用的概念相似，主要過程如下[Liu & Setiono, 1995]：

(1) 計算卡方  $\chi^2$  值：根據神經網路中每一個神經元（屬性節點）在訓練期間所輸入的資料值，予以排序、分群，再根據 (5) 式，計算每一群組的卡方值  $\chi^2$  值。

(2) 合併：當卡方值  $\chi^2$  低於信賴程度（confidence level），則將該一群組與臨界的群組合併，再重回程序 (1)，從新計算界限範圍，直到所有

群組的卡方值  $\chi^2$  大於信賴程度為止。

$$\chi^2 = \sum_{i=1}^2 \sum_{j=1}^k \frac{(A_{ij} - E_{ij})^2}{E_{ij}} \quad (5)$$

式中：

$k$ ：分類結點個數

$A_{ij}$ ：屬性資料值出現的次數

$E_{ij}$ ：屬性期望出現次數

2. 萃取法則：此步驟主要的目的是以法則呈現類神經網路的知識結構，其方法為：利用權重與輸入值的相乘求出引發的出值；如(6)式，判定推論法則是否成立，而當此一輸出值大於神經元觸發的門檻值時，則可將其視為法則的形成，並且可以利用 IF  $X_i$  OP  $V_i$  THEN *consequent* 的結構化語法表示法則的關聯。

$$\sum_{i=1}^n w_{ij} \times X_i \geq \lambda_j \quad (6)$$

式中：

$w_{ij}$ ：節點  $i$  到  $j$  的連結權重

$X_i$ ：輸入結點的範圍

$\lambda_j$ ：節點  $j$  的門檻值

2. 計算法則相對準確率 (Certainty Factors, CF)：由於在萃取法則的過程中，必須針對每一神經元屬性的群聚範圍，計算其法則是否成立，所以勢必會產生法則多大的現象，而此一步驟則是依據神經元連結的轉換函數；如：(7)式即為當轉換函數為 sigmoid 時計算相對準度的公式，而使用者亦可以依據個人的需求，自己定義門檻值，達到法則篩選的目的。

$$CF = \frac{1}{1 + \exp\left(\sum_{i=1}^n w_{ji} \times X_i - \lambda_j\right)} \quad (7)$$

## 肆、雛型開發與評估

### 一、實驗環境與資料來源

本研究雛型系統開發與實驗環境為 IBM Netfinity 5100 系列 Pentium III-733 雙 CPU PC Server，512 MB RAM，作業平台為 Windows 2000 Advanced Server，開發工具則是使用 Math Work 公司的 MatLab 5.3 R11。

實驗資料採自台灣經濟新報財金資料庫（Taiwan Economic Journal Data Bank, TEJ）中，民國 76 年 1 月 1 日到 89 年 12 月 31 日共 14 年，台灣加權股價指數中，水泥、礦業、金融、食品類、紡織、造紙類、塑膠化工、機電、營建等八大類股的指數資料，合計共 3959 筆（各年度的資料分佈如：表 2 年度資料分佈表）；資料內容則包含：交易日期、開盤價、收盤價、最高價、最低價、報酬率、成交量、成交值、成交筆數、週轉率、流通在外股數等。

表2 年度資料分佈表

年度	資料筆數	年度	資料筆數
76	288	83	286
77	289	84	286
78	287	85	288
79	281	86	286
80	286	87	271
81	284	88	266
82	290	89	271
合計		3959	

### 二、前置處理

為使資料庫中的資料能夠達到正確性與完整性，作為最適投資組合預測的依據，本研究針對資料庫的內容，進行下列前置處理：

1. 資料處理：將歷史資料庫中，錯誤或缺值的資料，予以修正或剔除；在

台灣的股市交易中，具有漲跌幅 7%的限制，因此若指數資料連續兩天的相差大於 7%，即可判定此為錯誤資料；在此階段，本研究遇到錯誤或缺值的資料，則是最近三天的資料，求其算數平均數予以修正。

## 2. 資料正規化：資料的正規化主要包含兩個步驟：

- (1) 將類股資料中，股票股利、股票分割與減資這三種無實質經濟意義的事件予以正規化<sup>1</sup>，使資料能夠保持一致性。
- (2) 在研究期間，歷年的加權指數最高與最低差距超過 7000 點以上，因此，本研究在前置處理資料正規化步驟中，將所有類股的指數資料予以正規化，使其介於 0 與 1 之間，以降低運算的複雜度。

3. 領域知識：因為在財務管理研究領域中，技術指標領域知識計算的方法不下 30 種以上，本研究在領域知識的指標選擇上，排除「圖形解析」類型技術分析方法，主要在於圖形解析必須依靠線型交叉點或長期走勢的分析，才能獲得較明確的市場預測，而採用「指標型」的技術分析的優點則是，利用指標公式計算所得的市場指標值，即具有市場預測的能力。本篇論文所應用的技術指標包含：

- (1) 相對強弱指標 (Relative Strength Index, RSI)
- (2) 乖離率 (BIAS)
- (3) 心理線 (Psychological Line) :
- (4) 量強弱指標 (Volume Ratio, VR)

## 三、實驗流程

在利用類神經網路進行最適投資組合資金配置權數的預測過程中，本研究將經過前置處理後 76 年至 88 年的類股資料，依年度分為 13 組神經網路訓練的範例資料，分別訓練 13 組類神經網路之後，再根據以前 13 組已訓練完成的類神經網路分別預測次年，即 77 年至 89 年度的最適投資組合的類股資金配置權數<sup>w<sub>i</sub></sup>。也就是利用 76 年的資料當訓練資料，預測 77 年的投資組合。利用 77 年的資料當訓練資料，預測 78 年的投資組合。依此類推。

---

<sup>1</sup> 調整後股價=原始股價× 調整因子  
調整因子=當日之後所有“調整係數”累乘  
調整係數=除權參考價／(除權前收盤價-現金股息)

因為類神經網路在學習預測過程中，隱藏層單元個數、隱藏層數和學習速率的多寡皆會影響學習的績效；所以，本研究在隱藏層單元個數上，採用一般最常使用的兩種方法，(1) 輸入與輸出層單元個數的平均值、(2) 輸入與輸出層單元個數的幾合平均數兩種方式，分別建立前向式與回饋式神經網路預測模型；隱藏層數設定為 1；學習速率則是採 0.5；而傳遞函數，則因為在資金配置的過程，有不能買空賣空的限制，投資權數必須介於 0 與 1 之間，所以採用 Log Sigmoid；根據以上的參數準則，在實驗過程中，本研究共建立 Portfolio1~Portfolio4 投資組合 4 組的預測模型，其各組的參數設定如表 3 所示。其中 Portfolio1~Portfolio4 輸出單元個數八，為八大類股個別的投資權數。Portfolio1 及 Portfolio2 輸入單位個數 40，分別為八大類股的前一天的類股指數、相對強弱指標、乖離率、心理線及量強弱指標等共 40 個輸入。Portfolio3 及 Portfolio4 輸入單位個數 48，分別為八大類股前一天的類股指數、相對強弱指標、乖離率、心理線、量強弱指標及類神經網路前一次的輸出等共 48 個輸入。

表3 類神經網路參數設定值

參數名稱 代號	Portfolio1	Portfolio2	Portfolio3	Portfolio4
網路架構	前向式		回饋式	
輸入單元個數	40		48	
輸出單元個數		8		
隱藏層單元個數 <sup>2</sup>	24	18	28	20
隱藏層數		1		
學習速率		0.5		
網路傳遞函數	Log Sigmoid			

<sup>2</sup> Portfolio1 隱藏層單元個數=(輸入單元個數+輸出層單元個數)/2=(40+8)/2=24Portfolio2 隱藏層單元個數=(輸入單元個數× 輸出層單元個數)<sup>1/2</sup>=(40× 8)<sup>1/2</sup>=17.89≈18

Portfolio3 隱藏層單元個數=(輸入單元個數+輸出層單元個數)/2=(48+8)/2=28

Portfolio4 隱藏層單元個數=(輸入單元個數× 輸出層單元個數)<sup>1/2</sup>=(48× 8)<sup>1/2</sup>=19.60≈20

## 四、實驗結果與評估

### (一) 類神經網路訓練績效

本研究利用 Portfolio1~Portfolio4 四組類神經網路模型，對 76 到 88 年的 13 組年度資料，分別帶入各類神經網路模型，各進行 300 回的學習範例訓練，每一年度資料用來預測隔年的投資組合。並以類神經網路在訓練過程所產生的均方差 (Mean Squared Error, MSE)；如 (8) 式，測量類神經網路的收斂績效，當均方差的值越小，表示神經網路學習過程中，神經元所觸發的輸出值，與目標值的誤差越小。而在類神經網路績效評估的過程中，本研究根據表 4，各組神經網路預測模型所產生的均方差，進行假設檢定，假設：

$$H1_A : \mu_{\text{Portfolio}1}(\text{mse}) - \mu(\text{mse})_{\text{Portfolio}3} \geq 0$$

$$H1_B : \mu_{\text{Portfolio}2}(\text{mse}) - \mu(\text{mse})_{\text{Portfolio}4} \geq 0$$

經過成對 (matching) 樣本 t 檢定後， $H1_A$  t 值等於 14.43， $H1_B$  t 值等於 4.28，在顯著水準  $\alpha=5\%$ ，自由度等於 13 之下，皆高於  $t_{0.05}(13)$  的 1.1771，所以拒  $H1_A$  與  $H1_B$ ，結果顯示本研究利用 Jordan's 回饋式類神經網路所建構的 Portfolio3 與 Portfolio4 兩組投資組合分析模型，所得到的均方差明顯低於 Portfolio1 與 Portfolio2 兩組前向式的神經網路預測模型；即在投資組合時間序列的分析過程中，使用回饋式神經網路模擬的結果，在收斂速度比較上，確實較前向式架構佳，此一研究結果和 Bigus[1996] 和 Onat[1998] 所提出的在回饋式類神經網路中，在時間序列中，擁有較佳的增強式學習效果的結論是一致的。

$$MSE = \sqrt{\frac{\sum_{p=1}^M \sum_{j=1}^N (T_j^p - Y_j^p)^2}{M \times N}} \quad (8)$$

式中：

$T_j^p$ ：第  $p$  個學習範例中第  $j$  個輸出單元之目標輸出值

$Y_j^p$ ：第  $p$  個學習範例中第  $j$  個輸出單元之推論輸出值

$M$ ：範例數目

$N$ ：輸出層單元數目

表4 類神經網路收斂績效表

年度	Portfolio1	Portfolio2	Portfolio3	Portfolio4
76	0.0671	0.0556	0.0221	0.0270
77	0.0729	0.0440	0.0266	0.0357
78	0.0567	0.1048	0.0149	0.0207
79	0.0633	0.1418	0.0167	0.0234
80	0.0854	0.0627	0.0202	0.0271
81	0.0665	0.0789	0.0261	0.0332
82	0.0651	0.1029	0.0295	0.0368
83	0.0796	0.0713	0.0221	0.0377
84	0.0598	0.2380	0.0259	0.0307
85	0.0692	0.1024	0.0375	0.0319
86	0.0516	0.0663	0.0192	0.0217
87	0.0488	0.0692	0.0194	0.0248
88	0.0766	0.0557	0.0249	0.0345
平均	0.0664	0.0918	0.0235	0.0296

## (二)投資績效評比

在投資績效的評估過程中，本研究利用 Portfolio1~ Portfolio4 在 76 年到 88 年所分別訓練的 13 組類神經網路模型，個別預測 77 到 89 年各年度的資金配置權數與類股指數平均報酬<sup>3</sup>、市場大盤買入持有策略和一般開放型基金前 50% 的投資報酬進行比較（如表 5）；並且假設：

$$H2_A : \mu(\text{returns})_{\text{加權指數}} - \mu(\text{returns})_{\text{Portfolio3}} \geq 0$$

$$H2_B : \mu(\text{returns})_{\text{買入持有策略}} - \mu(\text{returns})_{\text{Portfolio3}} \geq 0$$

$$H2_C : \mu(\text{returns})_{\text{開放型基金前 50\%}} - \mu(\text{returns})_{\text{Portfolio3}} \geq 0$$

$$H2_D : \mu(\text{returns})_{\text{Portfolio1}} - \mu(\text{returns})_{\text{Portfolio3}} \geq 0$$

3 類股指數平均報酬=針對研究對象八大類股，分別投資 1/8 單位資金的投資組合報酬  
 Portfolio1~4 =市場大盤買入持有策略=台灣加權股價指數的年度報酬

$$H2_E : \mu(\text{returns})_{\text{加權指數}} - \mu(\text{returns})_{\text{Portfolio4}} \geq 0$$

$$H2_F : \mu(\text{returns})_{\text{買入持有策略}} - \mu(\text{returns})_{\text{Portfolio4}} \geq 0$$

$$H2_G : \mu(\text{returns})_{\text{開放型基金前 50\%}} - \mu(\text{returns})_{\text{Portfolio4}} \geq 0$$

$$H2_H : \mu(\text{returns})_{\text{Portfolio2}} - \mu(\text{returns})_{\text{Portfolio4}} \geq 0$$

在顯著水準  $\alpha=5\%$ ，自由度等於 13 之下，結果如表 6 所示，因為 H2 中所有假設的 t 值皆大於  $t_{0.05}(13)$  的 1.1771，所以拒 H2 中所有的假設，即表示本研究中所建構的 Portfolio3 與 Portfolio4 兩組最適投資組合分析預測模型，所得的平均投資報酬，顯著高於加權股價指數平均報酬、市場買入持有策略、一般開放型基金前 50% 投資報酬及 Portfolio1 與 Portfolio2。

表5 投資績效比較表

年度	加權指數 平均報酬	買入持有 策略	開放型基 金前 50%	Portfolio 1	Portfolio 2	Portfolio 3	Portfolio 4
77	71.74	118.78	76.15	95.22	86.52	101.24	103.51
78	75.74	88.00	82.94	109.72	104.93	117.20	109.92
79	-63.67	-52.93	-41.63	-32.00	-40.04	-20.71	-23.38
80	27.72	1.56	22.78	45.18	32.46	62.07	57.26
81	-26.97	-26.60	-9.39	-3.71	-7.12	7.59	4.34
82	54.51	79.76	54.61	83.50	69.69	90.90	84.30
83	20.52	17.36	26.72	34.61	39.73	61.64	63.07
84	-30.00	-27.38	-18.20	-12.15	-10.34	9.88	6.34
85	29.78	34.02	40.01	52.09	52.23	57.64	53.08
86	15.18	18.08	60.08	76.24	67.70	95.32	99.07
87	-29.31	-21.60	-1.47	13.45	9.86	29.12	28.04
88	3.63	31.63	58.92	56.86	61.14	92.02	84.31
89	-43.09	-43.91	-35.63	-14.66	-17.20	4.62	7.78
平均	8.14	16.67	24.30	38.80	34.58	54.50	52.13

表6 H2 t 檢定結果

檢定	H2 <sub>A</sub>	H2 <sub>B</sub>	H2 <sub>C</sub>	H2 <sub>D</sub>	H2 <sub>E</sub>	H2 <sub>F</sub>	H2 <sub>G</sub>	H2 <sub>G</sub>
t 值	8.97	5.65	13.84	6.38	8.21	5.15	10.90	7.52

## 二、回饋式類神經網路知識萃取績效

根據類神經網路輸出的各類股投資權重，本研究在進行法則萃取前，先將權重值的變化以公式（9）表示，因此法則萃取的結果為對八大類股投資權重的增減量。此一作法主要的目的在於可以提供一個更明確的投資訊息，讓使用者可以獲得一個在何種狀況下，該增加或減少投資標的多少權重。

在回饋式類神經網路法則萃取的過程中，本研究將 Portfolio3 與 Portfolio4 兩組回饋式類神經網路模型，所分別訓練完成的 13 組預測模型，利用（9）式，計算各組學習範例資料的輸出向量所對映的投資策略。然後，再將各買賣策略依 0.005 的組距分組，統計各組神經網路與各類股投資權數買賣策略出現的權數；由於利用（9）式所求得各年度類股投資權數的平均約介於正負 0.2~0.3 之間，礙於版面限制的情況下，本論文只舉出以 Portfolio3 民國 77 水泥窯業與 Portfolio3 民國 89 年金融業類神經網路回饋輸入所對映於投資策略  $D_t^i$  介於-0.02~0.02 出現次數的統計表（如表 7、表 8 所示）；之後，再根據 Chi-2 演算法和（5）式，計算各組預測模型輸入變數的群聚範圍，當  $\chi^2$  值小於 50% 信賴區間值時，則將該組與鄰近組別合併，直到所有區間值大於信賴區間值時，即可將每一群組界限視為一組群聚（如表 8 民國 77 年水泥窯業 6 日 RSI 輸入變數投資策略群聚統計表 9、表 10 民國 89 年金融業回輸入變數投資策略群聚統計表）。

$$D_t^i = W_t^i - W_{t-1}^i \quad (9)$$

式中：

$D_t^i$ ：第  $i$  種類股在  $t$  時間的買賣策略

$W_t^i$ ：第  $i$  種類股在  $t$  時間的投資權數

$W_{t-1}^i$ ：第  $i$  種類股在  $t-1$  時間的投資權數

表7 Portfolio3 民國 77 年水泥窯業 6 日 RSI 投資策略統計表

買賣策略 RSI%	- 0.02	- 0.015	- 0.01	- 0.005	0 0	+- 0.005	+- 0.01	+- 0.015	+- 0.02
0 < RSI ≤ 0.02	1		1			2		1	
0.02 < RSI ≤ 0.04			1						
...	...	...	...	...	...	...	...	...	...
0.46 < RSI ≤ 0.48				2	1				
0.48 < RSI ≤ 0.50			2	1	1	1		2	
0.5 < RSI ≤ 0.52		1		3			1	1	1
0.52 < RSI ≤ 0.54	1				2				1
0.54 < RSI ≤ 0.56		1	3		2	1		1	
...	...	...	...	...	...	...	...	...	...
0.96 < RSI ≤ 0.98							1		
0.98 < RSI ≤ 1	1								

表8 Portfolio3 民國 89 年金融業類神經網路回饋輸入投資策略統計表

買賣策略 $O_{t-1}^2$	- 0.02	- 0.015	- 0.01	- 0.005	0 0	+- 0.005	+- 0.01	+- 0.015	+- 0.02
0 < $O_{t-1}^2 \leq 0.02$					1				3
0.02 < $O_{t-1}^2 \leq 0.04$					1	1		2	
...	...	...	...	...	...	...	...	...	...
0.10 < $O_{t-1}^2 \leq 0.12$	1				1	1	3		
0.12 < $O_{t-1}^2 \leq 0.14$		2				1		1	1
0.14 < $O_{t-1}^2 \leq 0.16$			1	3	3		1		1
0.16 < $O_{t-1}^2 \leq 0.18$			2		1	2		1	2
0.18 < $O_{t-1}^2 \leq 0.20$	1	1			1	2		3	
...	...	...	...	...	...	...	...	...	...
0.96 < $O_{t-1}^2 \leq 0.98$									
0.98 < $O_{t-1}^2 \leq 1$									

表9 Portfolio3 民國 77 年水泥窯業 6 日 RSI 輸入變數投資策略群聚統計表

買賣策略 RSI%	- 0.02	- 0.015	- 0.01	- 0.005	0	+- 0.005	+- 0.01	+- 0.015	+- 0.02	$\chi^2$
0 < RSI ≤ 0.06	1		2	1	3	2		6	1	6.282
0.06 < RSI ≤ 0.18	1		5		1		2	4	1	5.289
...	...	...	...	...	...	...	...	...	...	...
0.26 < RSI ≤ 0.34	1		5	3		4		1		5.936
0.34 < RSI ≤ 0.40		2		2	4		3	1	1	5.912
0.40 < RSI ≤ 0.48	2		1	6	1	1	2		1	8.281
0.48 < RSI ≤ 0.52		1	2	4	1	1	1	3	1	5.370
0.52 < RSI ≤ 0.60	5	2	3	1	6	1	1	2	1	6.381
...	...	...	...	...	...	...	...	...	...	...
0.80 < RSI ≤ 0.88		4		1			3	2		6.016
0.88 < RSI ≤ 1	1	3	4		1		2		4	5.173

表10 Portfolio3 民國 89 年金融業類神經網路回饋輸入變數

投資策略群聚統計表

買賣策略 $O_{t-1}^2$	- 0.02	- 0.015	- 0.01	- 0.005	0	+- 0.005	+- 0.01	+- 0.015	+- 0.02	$\chi^2$
0 < $O_{t-1}^2 \leq 0.12$	1	1		1	4	1	4	3	5	6.128
0.12 < $O_{t-1}^2 \leq 0.18$		2	3	3	4	3	1	2	4	5.597
0.18 < $O_{t-1}^2 \leq 0.22$	1	1	5		1	2	3	6		7.712
0.22 < $O_{t-1}^2 \leq 0.24$		2		3	1	4	1		1	5.912
0.24 < $O_{t-1}^2 \leq 0.30$		1	3	2		5		1	2	5.736
0.30 < $O_{t-1}^2 \leq 0.34$	4	1		2		5		1	1	6.584
0.34 < $O_{t-1}^2 \leq 0.38$	2	1	3		1		4	1	1	5.718
...	...	...	...	...	...	...	...	...	...	...
0.48 < $O_{t-1}^2 \leq 0.64$	1	5		1	2	1		4		6.222
0.64 < $O_{t-1}^2 \leq 1$	4	1	2	1		1		3	1	5.164

根據以上各組類神經網路輸入變數的群聚界限，再代入（6）式，求得各輸入群組的觸發值後，當觸發值大於神經傳遞的閾值時，即可將此群聚與其對應的投資策略以 If.....Then 的方式表達，而最後，再根據（7）式，計算各法則的相對準確度，在經過相對精確度大於 50%的門檻值限制後，本研究在各年度的類股最適投資組合資配置權數的知識發掘過程中，平均各類股在每個年度約可獲得 45 條類似下列的投資組合決策分析準則，供其作為投資組合決策分析的依據。

1. 民國 77 年 portfolio3, CF= 67.82%, If  $-2.5\% < RET^I \leq -1.3\% \& 26\% < RSI^I \leq 34\% \& -4.5\% < BAIS^I \leq -3.9\% \& 16.7\% < PSY^I \leq 33.3\% \& 93\% < VR^I \leq 157\% \& 10.4\% < O^I_{n,i} \leq 15.8\% \dots \& 1.8\% < RET^S \leq 2.9\% \& 24\% < RSI^S \leq 30\% \& 3.7\% < BAIS^S \leq -2.8\% \& 16.7\% < PSY^S \leq 33.3\% \& 75\% < VR^S \leq 184\% \& 13.1\% < O^S_{n,i} \leq 19.1\%$  Then  $D^I = +0.025$
2. 民國 89 年 portfolio4, CF= 71.10%, If  $1.5\% < RET^I \leq -3.1\% \& 42\% < RSI^I \leq 50\% \& 5.3\% < BAIS^I \leq 8\% \& 16.7\% < PSY^I \leq 33.3\% \& 180\% < VR^I \leq 327\% \& 7.3\% < O^I_{n,i} \leq 14.2\% \dots \& -5.1\% < RET^S \leq -2.7\% \& 41\% < RSI^S \leq 58\% \& 3.6\% < BAIS^S \leq 4.5\% \& 33.3\% < PSY^S \leq 50\% \& 278\% < VR^S \leq 396\% \& 19.2\% < O^S_{n,i} \leq 23.1\%$  Then  $D^S = -0.005$

根據以上過程所建構的投資組合分析法則中，主要的目的在於獲得一個較佳的資金分配組合，並且從已訓練的神經網路中，獲取一些投資組合配置的相關知識。因此在績效評估過程中，採用：(1) 資金配置報酬績效、(2) 資金配置相關係數比較作為法則萃取的績效評比，其結果如下：

1. 資金配置報酬績效：本研究在回饋式類神經網路法則萃取投資績效的評估階段，將 77 到 89 年各年度的加權股價指數的平均報酬、市場買入持有策略和一般開放型基金前 50% 的投資報酬、Portfolio3、Portfolio4 和法則萃取的投資報酬進行比較（如表 11），在假設：

$$H3_A : \mu(\text{returns})_{\text{加權指數}} - \mu(\text{returns})_{\text{Portfolio3 法則萃取}} \geq 0$$

$$H3_B : \mu(\text{returns})_{\text{買入持有策略}} - \mu(\text{returns})_{\text{Portfolio3 法則萃取}} \geq 0$$

$$H3_C : \mu(\text{returns})_{\text{開放型基金前 50\%}} - \mu(\text{returns})_{\text{Portfolio3 法則萃取}} \geq 0$$

$$H3_D : \mu(\text{returns})_{\text{Portfolio3}} - \mu(\text{returns})_{\text{Portfolio3 法則萃取}} \geq 0$$

$$H3_E : \mu(\text{returns})_{\text{加權指數}} - \mu(\text{returns})_{\text{Portfolio4 法則萃取}} \geq 0$$

$$H3_F : \mu(\text{returns})_{\text{買入持有策略}} - \mu(\text{returns})_{\text{Portfolio4 法則萃取}} \geq 0$$

$$H3_G : \mu(\text{returns})_{\text{開放型基金前 50\%}} - \mu(\text{returns})_{\text{Portfolio4 法則萃取}} \geq 0$$

$$H3_H : \mu(\text{returns})_{\text{Portfolio4}} - \mu(\text{returns})_{\text{Portfolio4 法則萃取}} \geq 0$$

在顯著水準  $\alpha=5\%$ ，自由度等於 13 之下，結果如：

表 12 所示，在  $H3$  的假設檢定中，只有  $H3_D$  與  $H3_H$  的  $t$  值小於  $t_{0.05}(13)$  的 1.1771，所以拒絕  $H3_A$ 、 $H3_B$ 、 $H3_C$ 、 $H3_E$ 、 $H3_F$ 、 $H3_G$ ，接受  $H3_D$  與  $H3_H$  假設，即表示，本研究針對回饋式類神經網路進行法則萃取所得的投資報酬，結果雖然分別低於 Portfolio3、Portfolio4 兩組回饋式神經網路預測模型，但是仍然顯著高於加權股價指數的平均報酬、市場買入持有策略與一般開放型基金前 50%

2. 資金配置相關係數：在法則萃取過程中，本研究利用 Portfolio3、Portfolio4 和法則萃取過後對各類股的投資權數，進行相關係數比較；如 (10) 式，比較類股在各年度投資權數的差異性，由表 13 與

表 14 中，吾人由 Portfolio3 與 Portfolio4 的法則萃取相關係數表中得知，兩組回饋式神經網路在經過法則萃取前後的相關係數平均分別為 0.8958 與 0.9095，顯示透過法則萃取所獲得的最適投資組合資金配置的權數，兩者的相關性十分顯著。

$$\rho_{XY} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (10)$$

式中：

X：回饋式類神經網路的預測類股投資權數

Y：回饋式類神經網路法則萃取分析類股投資權數

表11 回饋式類神經網路法則萃取投資績效比較表

年度	加權指數 平均報酬	買入持有 策略	開放型 基金前 50%	Portfolio 3	Portfolio 3 法則萃取	Portfolio 4	Portfolio 4 法則萃取
77	71.74	118.78	76.15	101.24	93.15	103.51	94.58
78	75.74	88.00	82.94	117.20	104.86	109.92	100.49
79	-63.67	-52.93	-41.63	-20.71	-26.73	-23.38	-33.27

80	27.72	1.56	22.78	62.07	57.40	57.26	49.65
81	-26.97	-26.60	-9.39	7.59	2.16	4.34	-3.43
82	54.51	79.76	54.61	90.90	80.57	84.30	75.62
83	20.52	17.36	26.72	61.64	53.31	63.07	57.98
84	-30.00	-27.38	-18.20	9.88	1.37	6.34	-3.24
85	29.78	34.02	40.01	57.64	52.21	53.08	46.63
86	15.18	18.08	60.08	95.32	90.58	99.07	90.36
87	-29.31	-21.60	-1.47	29.12	23.92	28.04	20.84
88	3.63	31.63	58.92	92.02	83.39	84.31	76.87
89	-43.09	-43.91	-35.63	4.62	-3.58	7.78	-0.42
平均	8.14	16.67	24.30	54.50	47.12	52.13	44.05

表12 H3 t 檢定結果

檢定	H3 <sub>A</sub>	H3 <sub>B</sub>	H3 <sub>C</sub>	H3 <sub>D</sub>	H3 <sub>E</sub>	H3 <sub>F</sub>	H3 <sub>G</sub>	H3 <sub>G</sub>
t 值	7.41	4.36	11.06	-11.28	6.67	3.92	7.55	-21.53

表13 Portfolio 3 與法則萃取投資策略相關係數表

類股 年度	水泥	塑膠	機電	營建	食品	紡織	金融	造紙
77	0.9404	0.9120	0.9250	0.8996	0.9134	0.9451	0.8949	0.9387
78	0.8582	0.8810	0.9024	0.9412	0.9441	0.8746	0.9108	0.8934
79	0.8512	0.9208	0.9346	0.8803	0.9277	0.9400	0.7994	0.9031
80	0.8936	0.9098	0.7802	0.9011	0.8588	0.9247	0.9242	0.9544
81	0.9466	0.8627	0.8844	0.8995	0.9049	0.9479	0.9280	0.8945
82	0.9305	0.8810	0.8574	0.9437	0.9441	0.8980	0.9410	0.8274
83	0.8974	0.9496	0.9362	0.9372	0.9118	0.9130	0.9179	0.9002
84	0.9399	0.9118	0.9349	0.9273	0.8988	0.9458	0.8646	0.9266
85	0.9133	0.8213	0.9276	0.9526	0.9503	0.8573	0.9488	0.9397
86	0.9122	0.9224	0.9418	0.9276	0.9260	0.8710	0.9030	0.8901
87	0.9436	0.9028	0.8509	0.9405	0.9395	0.8573	0.9394	0.9231
88	0.9127	0.9171	0.8784	0.9334	0.9387	0.9383	0.9301	0.8944
89	0.9489	0.9250	0.8710	0.9239	0.9237	0.9354	0.8416	0.8921
平均	0.9145	0.9013	0.8942	0.9237	0.9217	0.9114	0.9034	0.9060

表14 Portfolio4 與法則萃取投資策略相關係數表

類股 年度	水泥	塑膠	機電	營建	食品	紡織	金融	造紙
77	0.9521	0.8688	0.8791	0.9124	0.9120	0.8064	0.8578	0.8668
78	0.8724	0.8585	0.9332	0.9139	0.8994	0.9177	0.9045	0.9071
79	0.8879	0.9325	0.9142	0.8952	0.8981	0.8506	0.8803	0.8738
80	0.8523	0.9476	0.8508	0.9371	0.9491	0.9288	0.8661	0.9314
81	0.9193	0.9464	0.8927	0.8015	0.9070	0.8358	0.9066	0.8835
82	0.9520	0.9535	0.8815	0.9522	0.8989	0.8901	0.9545	0.9238
83	0.9034	0.8963	0.9391	0.9155	0.8552	0.9290	0.8873	0.8855
84	0.9498	0.8861	0.9044	0.9061	0.8181	0.8990	0.8784	0.8911
85	0.9066	0.9039	0.8569	0.8593	0.9043	0.8819	0.8548	0.8716
86	0.8655	0.8653	0.9074	0.9059	0.8761	0.9001	0.8298	0.9324
87	0.8904	0.8762	0.8746	0.9491	0.8205	0.9213	0.8948	0.8946
88	0.8990	0.8823	0.8981	0.9360	0.8861	0.9408	0.9070	0.9042
89	0.9453	0.9398	0.8944	0.8677	0.9392	0.8515	0.8745	0.8576
平均	0.9074	0.9044	0.8943	0.9040	0.8895	0.8887	0.8843	0.8941

## 伍、結論與未來研究方向

從文獻探討中得知，以往針對財務資料庫進行資料探勘與預測的研究中，大多著重於大盤或個股指數的預測，鮮有學者討論投資組合資金配置的問題，而且在眾多以類神經網路進行股市資料探勘的研究中，探勘所得的資訊大多局限於股價何時會漲、會跌的訊息預測，未能針對類神經網路的黑盒特性，進行知識萃取與表達；以至於這些研究皆只進行資料庫知識發掘流程中，資料探勘的步驟，致使探勘所得到隱含於資料庫裡的資訊與知識十分有限；而本研究主要是彌補以往研究的不足的部份，提出一個完整的財務資料知識探勘模型，利用財務資料庫中的歷史交易資料，進行前置處理、建立最適投資組合評估模型、回饋式類神經網路預測等步驟，預測最適投資組合資金配置權數，之後再根據已訓練完成的 Jordan's 回饋式類神經網路架構進行法則萃取，探索類神經

網路的黑盒結構，讓使用者能夠獲得更多實用而且具有價值的資訊。

本研究除了提出一財務資料庫知識發掘模型外，在離型系統開發與實證的過程中，以民國 78 年到 89 年間共 14 年八大類股指數資料，進行最適投資組合資金配置的模擬、建構與驗證，得到下列結果：

1. 類神經網路架構與預測績效：研究中，根據實驗階段所建構的 Profolio1~Portfolio4 四組類神經網路模型，與收斂績效比較假設檢定的結果，顯示以回饋式網路架構所建構的 Portfolio3 與 Portfolio4 兩組預測模型，收斂結果均小於利用前向式網路架構所建立的 Portfolio1 與 Portfolio2 兩組模型；其主要原因在於證券的交易資料具有時間序列的特性，而以回饋式網路架構所建立的預測模型，較能表達時間序列中，前後資料的關聯，以致於在財務資料探勘中，能夠擁有較佳的預測效果。
2. 投資績效的評比：本研究將 Portfolio1~Portfolio4 四組類神經網路模型所建構的投資組合資金配置權數，與加權股價指數的平均報酬、市場買入持有策略和一般開放型基金前 50% 的投資報酬進行比較。經由假設檢定的結果顯示，本研究所建構的 Portfolio3 與 Portfolio4 兩組回饋式類神經網路獲得的投資報酬，皆顯著高於加權股價指數平均報酬、市場買入持有策略和一般開放型基金前 50% 投資報酬與前向式網路架構預測結果，表示以本研究模型所建構的資金配置投資策略，確實擁有較佳的投資決策支援能力。
3. 類神經網路知識萃取績效：本研究所使用的 Full-RE 萃取演算法，以往的研究皆應用於前向式類神經網路架構的資訊擷取，我們所使用的 Jordan's 的回饋式網路的模型是屬前向式與全回饋式網路的混合架構，它仍然具有前向式的架構的特性與優點。研究發現，使用 Full-Re 演算法，萃取 Jordan's 部份回饋式類神經網路法則的結果，在和未進行萃取前投資權數相關係數比較的結果顯示，雖然本研究對 Jordan's 回饋式網路架構的知識擷取績效，無法像 Taha & Ghosh[1996]對向前式類神經網路法則萃取過程中，達到 93.33% 及 97.33% 高度的萃取績效，但本研究對法則萃取前後相關係數仍達到 9 成左右，顯示以 Full-Re 演算法對部份回饋式網路的法則萃取，乃具有一定的準確度。另外，在法則萃取前後報酬的比較上，雖然法則萃取後的投資報酬低於原有預測結果，但是仍顯著高於市場報酬與一般共同基金前 50% 的投資報酬。而從以上兩項分析的結果，可以得知，在本研究中對 Jordan's 部份回饋式類神經網路知識萃取的結果，

顯示法則萃取雖然會因為投資權數的些微變化，而無法達到法則萃取前的投資績效，但是它卻能夠以結構化 If...Then 方式表達類神經網路中的黑盒推論法則，使其分析判斷的經驗知識能夠外顯化及透明化。

本研究已經進行部份的實證工作，證實以回饋式類神經網路法則萃取的資料庫知識探勘方法，確實能夠將資料庫中所隱含的知識表達於結構化的語法中，並且提供最適化的資金配置投資策略；但是囿於研究時間及人力之限制，本研究尚有幾項改善的空間。以下提出後續研究建議。

- 1.個人化的投資策略：由於本研究採用的投資組合分析模型是遵循現代化投資組合理論的分析方法，而該理論分析流程並無考量個別投資人的偏好或限制條件（例如個人的風險態度即可分為保守型、穩健型、積極型）；因此，建議後續研究者可以將投資人對資產的偏好轉換成投資組合資金配置的限制條件，以滿足個人化投資的需求，或是可以進行有無個人化限制條件之下投資效率的比較。
- 2.增加或改變類神經網路的輸入變數或學習參數：本研究在預測最適投資組合資金配置的過程中，雖然只採用少數幾個較具代表性技術指標，但是分析市場上的趨勢的方法十分眾多，包含了基本面、消息面、技術面……等因子，因此，在未來的研究工作上，可考慮加入更多更有意義的類神經網路輸入變數，並評量預測的準確度；另外，由於類學神網路的學習參數亦會影響預測的品質，本研究因礙於研究時間與人力的限制，只採用一般較常見的參數設定方法。在未來的研究上，使用不同的類神經網路參數值，觀察能否得到更好的績效。
- 3.結合其他智慧型系統的應用：類神經網路結合遺傳演算法或是模糊理論的應用，有研究顯示比單獨使用一種演算法，擁有更多的優點。因此，在未來的研究上，可以多種演算法的結合應用。例如以遺傳演算法進行投資選股，利用回饋式神經網路和法則萃取作為預測及知識分析的工具。

## 參考文獻

- 苑守慈、官美蘭，2001，透明化與個人化之股市預測分析，資訊管理學報，6(2)：211-239。
- 許中川、洪鈺鋒，1997，資料庫知識發掘前置處理與欄位拆解，第三屆國際資訊管理研究暨實務研討會論文集，362-369。

- 陳稼興、張應華，2001，應用柔性計算技術於股票交易決策支援模型之建構，第五屆資訊管理研究暨實務研討會，33-41。
- Alexander, Sharpe and Bailey, 1995, *投資學*, 謝劍平、蔡祖銘 編譯, 華泰書局。
- Berry, M. and G. S. Linoff, 1997, Data mining techniques: for marketing, sales, and customer support, John Wiley & Sons INC.
- Bigus, Joseph P., 1996, Data mining with neural networks, McGraw-Hill.
- Brachman, R. J., T. Khabaza, W. Kloesgen, G. P. Shapiro and E. Simoudis, 1996, Mining business database, *Communications of the ACM*, 39(11):42-48.
- Craven, Mark W. and Jude W. Shavlik, 1996, Extracting tree-structured representations of trained networks, *Advances in Neural Information Processing System*, 1(8). MIT Press, Cambridge, MA.
- Elton, E. J. and J. G., 1995, *Martin modern portfolio theory and investment analysis*, 5th Edition, John Wiley & Sons INC.
- Fayyad, U., G. Piatetsky-Shapiro and P. Smyth, 1996, From data mining to knowledge discovery: an overview, 1996a, *Advances in Knowledge Discovery and Data Mining*, 1-36. California: AAAI/MIT Press.
- Fayyad, U., G. Piatetsky-Shapiro and P. Smyth, 1996b, The KDD process for extracting useful knowledge from volumes of data, *Communications of the ACM*, 39(11): 27-34.
- Fischer, Donald E. and Ronald J. Jordan, 1995, *Security analysis and portfolio management*, 6th Edition, Prentic Hall.
- Fu, LiMin, 1999, Knowledge discovery based on neural networks, *Communication of The ACM*, 42(11):47-50.
- Gavrilov, M., D. Anguelov, P. Indyk and R. Motwani, 2000, Mining the stock market: which measure is best? , *Proceedings of International Conference on Knowledge Discovery and Data Mining*, 487-496.
- Goonatilake, S. and P. Treleaven, 1995, *Intelligent systems for finance and business*, John Widly & Sons Ltd.
- Han, Jiawei and Micheline Kamber, 2001, *Data mining concepts and techniques*, Morgan Kaufmann Publishers.
- Kimoto, T. and K. Asakawa, 1990, Stock market prediction system with modular neural networks, *IEEE International Joint Conference on Neural Networks*, 1-6.
- Moody, J. and L. Wu, 1997, Optimization of trading systems and portfolios, *Proceedings of the IEEE/IAFE Computational Intelligence for Financial Engineering*, 300-307.
- Odom M.D. and R. Sharda ,1990, A neural network model for bankruptcy prediction, *International Joint Conference on Neural Networks*, 2:163 -168
- Omlin, Christian W. and C. Lee Giles, 1996, Rule revision with recurrent neural networks, *IEEE Transactions on Knowledge and data engineering*, 8(1).
- Piatetsky-Shapiro, G. and W. J. Frawley, 1991, Knowledge discovery in databases,

California, AAAI/MIT Press.

Setiono, Rudy and Huan Liu, 1996, Symbolic representation of neural networks,  
*Computer*, 29(3):71-77.

Taha, I. A. and J. Ghosh, 1999, Symbolic interpretation of artificial neural networks,  
*IEEE Transactions on Knowledge and Data Engineering*, 11(3):448-463.

Tkacz, G., 2001, Neural network forecasting of canadian GDP growth, *International Journal of Forecasting*, 17(1):57-69.

Wuthrich, B., V. Cho, S. Leung, D. Permutilleke, K. Sankaran and J. Zhang, 1998,  
Daily stock market forecast from textual web data, *IEEE International Conference on Systems, Man, and Cybernetics*, 3:2720-2725.