

以遺傳神經網路建構台灣股市買賣決策系統之研究

連立川

台灣科技大學營建工程學系

葉怡成

中華大學資訊管理學系

摘要

本研究採用台灣大盤股價指數及成交值所轉換的18個價量技術指標做為輸入參數，以期末資金最大化做為適應度函數，應用遺傳演算法(Genetic Algorithms)建構買賣決策類神經網路(Neural Networks)。研究結果顯示，本研究所比較之四種交易策略：遺傳神經網路策略(Genetic Neural Networks, GNN)、遺傳邏輯規則策略(Genetic Logic Rule, GLR)、單一遺傳邏輯規則策略(Single Genetic Logic Rule)及買入持有策略，在測試範例期間的平均年獲利率分別是10.27%、2.02%、-0.05%與-7.2%。另外由GNN、GLR及SGLR的風險評估得知，其高於買入持有策略的機率分別是91.77%、80.51%及79.39%。因此，GNN是一個穩定且有效的台灣股市交易策略。

關鍵字：股票市場、技術指標、遺傳演算法、類神經網路



Building Trading System for Taiwan Stock Market Using Genetic Neural Networks

Li-Chuan Lien

Department of Construction Engineering, National Taiwan University of Science and
Technology

I-Cheng Yeh

Department of Information Management, Chung Hua University

Abstract

This paper used 18 kinds of price and volume technical indices transferred from the Taiwan stock price index as the input parameters, the maximization of the final capital as the fitness function, the genetic algorithms as the optimization tool to construct the trading system based on neural networks. The results showed that the four kinds of trading strategies, the Genetic Neural Networks strategy(GNN), the Genetic Logic Rule strategy(GLR), the Single Genetic Logic Rule(SGLR), and the buy and hold strategy, in test period produced the average year profit rate respectively are 10.27%, 2.02%, -0.05%, and -7.2 . Moreover, compared the risk assessment of the GNN, GLR and SGLR strategies, the probability of average year profit rate higher than the buy and hold strategy rate respectively are 91.77%, 90.51%, and 79.39. Therefore, the GNN trading system is a not only effective but also stable Taiwan stock market of trading system.

Key words: Stock market, technical index, genetic algorithms, neural networks



壹、導論

股票市場瞬息萬變，相關資訊流通速度快速，投資者如何在這難以預測的市場中取得良好的績效，獲得較佳的報酬，是投資者所深切盼望的。然而股市之所以難以預測大致可歸咎下列因素：(一)股市受隨機事件影響甚鉅、(二)分析師或投資者本身能力不足。有學者將這兩種影響因素分為政治面、金融財稅面、經貿面、國際面、消息面、和技術面六構面，這六個構面在股價預測研究上因觀點不同而產生三種理論學派：(一)基本分析學派、(二)技術分析學派及(三)市場效率假說學派。

基本分析學派相信分析未來經濟發展、各產業之間的動態關係以及公司產業業績等因素，能夠決定股價未來真實價值(江吉雄 2001)。技術分析學派依據過去的歷史股價以及交易量而繪製成圖表或轉換為公式，因為他們相信股價的技術圖表可以充分反應投資人的心態及行為，所以可以透過圖表來預測股價未來走勢。至於市場效率學派又分為三種層次：(一)弱勢、(二)半強勢及(三)強勢(林耀堂 2001)。弱勢主張股票市場中，所有能夠影響股價的資訊都已經及時且充分反映到股價，故投資者無法由過去歷史股價預測市場。半強勢主張股價呈現隨機狀態，因此投資人無法透過現有的公開資訊預測市場。而強勢主張「市場行為將涵蓋一切」的現象，認為即使採用基本分析及技術分析同樣無法掌握市場脈動。

隨著科技的發達，也使得人們解決問題的方式不在只是單憑過去的經驗，尤其是瞬息萬變的股票市場，過去與未來之間或許有潛在的關聯存在，然而單憑個人的記憶來判斷，不但不易掌握出其中的關聯性，更易流於主觀，所以多數的企業與專家都會藉由電腦來做為投資決策的輔助工具，因此各種預測方法不斷地出現，例如：統計方法(李惠妍 2003)、時間序列分析(Yim 2002)、類神經網路(Neural Networks; NN)(李惠妍 2003; Tan 1993; Glaria 1996; Cheh 1999; Yim 2002)、遺傳演算法(Genetic Algorithms; GA)(陶宏德 1995; 邱昭彰 1998; 林耀堂 2001; 許智明 2003; 王衍智 2004; Allen 1999; Korcazk 2002; Jiang 2003)、甚至是演算法的彼此結合(劉克一 2000; 周慶華 2000; 林建成 2001; 李建輝 2002; Phua 2001; Armano 2002; Kwon 2003)……等，這些系統將更具有理性客觀的研判，以減少人為的錯誤。

技術分析的實用性以及參考價值往往讓許多投資人潛心研究，但是由於技術指標的多樣性及不一致性，往往讓投資者在面對抉擇時猶豫不定，導致錯失買賣的最佳時機。許多股價預測研究，其技術指標採用常用特定日期的技術指標，如日線、週線、月線、季線、半年線等，然而採用常用特定日期的技術指標是否真正具備預測能力呢？還是另有更具備的獲利能力的技術指標或組合是尚未發現的呢(陶宏德 1995)？有鑑於此，本研究試圖利用遺傳演算法的最佳化能力及類神經網路的模型構成能力，配合台灣大盤加權指數的技術指標，建構最佳的買賣決策模型以及最佳的買賣決策時機，以幫助於投資者在面對大盤的走勢時，能夠有買賣決策之依據。

本研究與其它文獻不同處分述如下：

1. 強化學習的機制：以往研究常以最小化股價漲跌預測誤差作為目標，本研究是以最大化交易獲利為目標。
2. 新式指標的使用：本研究採用之指標不同於常見之技術指標，雖同樣考慮台灣大盤股價及成交值的混合變動情況，但設計上較傾向把價量數據用時間數列的觀點來處理。
3. 重要指標的優選：以往研究常以固定的技術指標為輸入變數，本研究是以GA優化選擇最佳的技術指標做為輸入變數。
4. 最佳門檻的決定：以往研究常以固定門檻值決定買入及賣出時機，本研究是以GA優化門檻值決定買入及賣出時機。
5. 風險評估的考量：以往研究常以最佳的模擬結果展示其系統的效能，本研究是以30次模擬結果展示系統的效能，以分析系統的可靠度。

貳、文獻回顧

國內、外學者早已在財務領域研究當中加入人工智慧的方法，企圖以科學的角度自動產生可信的決策。人工智慧在買賣決策上的應用大致可以區分成三大領域：類神經網路、遺傳演算法、遺傳演算法及類神經網路彼此結合。以下將介紹這三大領域的研究成果：

一、類神經網路在買賣決策的應用

類神經網路是一種模仿生物神經網路的資訊處理系統，配合電腦的高速計算能力、記憶能力、學習與容錯能力，因此適合解決複雜的分類或預測等問題。倒傳遞類神經網路係現今應用最普遍且最具代表性之類神經網路學習模式，已發表之相關應用為數數千個以上。其基本觀念係運用最陡坡降法(Gradient Steepest Descent Method)之觀念，將誤差函數最小化。倒傳遞網路的演算法架構可參考文獻(葉怡成 2002)。在類神經網路理論與應用的蓬勃發展下，其技術日趨成熟，應用也日漸廣泛，包括工業控制、商業決策和辨識系統等各方面的應用都有不錯的表現。其所能解決的問題包括了診斷分類、預測、聚類、雜訊過濾、資料擷取與最佳化問題等(劉克一 2000)。這裡要探討的是買賣決策上的相關研究，基於類神經網路文獻整理如表1所示。



表 1：「基於類神經網路」文獻回顧

文 獻	研究內容
李惠妍 (2003)	以民國89年12月21日至91年12月18日台灣加權股價指數日資料作為樣本，運用類神經網路及統計方法中的迴歸分析，來預測台股指數期貨的隔日收盤指數，以尋找出最適宜的預測模式。結果顯示：在使用了11種不同的技術指標，包括MA、RSI、KD、MACD、DMI、BIAS、W%R、PSY、VR、AR、BR指標，在三種不同模式的預測績效比較方面，迴歸分析績效最好MAE為72.866，其次是改良式類神經網路MAE為72.878，而預測績效最差的是倒傳遞類神經網路MAE為73.441。
Tan (1993)	以264週資料為樣本，其中165週為訓練期，99週為試驗期，以類神經網路作為金融交易系統，進行NYSE-stock兩年的虛擬交易。輸入資料包含前五週的最高價、最低價、收盤價與四個技術指標共35個輸入項，以預測下一週的收盤價，結果顯示，類神經網路訓練區間漲跌預測方向正確率88%，測試區間漲跌預測方向正確率為83%。
Glaria (1996)	以聖地牙哥股市240天日交易資料做為樣本，以前十天的指數與成交量為輸入資料，並以類神經網路預測聖地牙哥股市隔天收盤指數。結果顯示，類神經網路在上漲區間漲跌預測方向正確率63.3%，下跌區間漲跌預測方向正確率達74.7%。
Cheh (1999)	以紐約證交所上市公司非金融與服務業中1448家企業為樣本，並以公司規模、負債比率、現金比率、銷貨成長率、盈餘分配率、本益比、股息、q ratio(股票市值/總資產)與企業遭併購比率等為輸入變數。以類神經網路預測可能遭併購的企業，作為投資組合的標的，以取得股票上漲的獲利。結果顯示，採用六年的資料為實驗數據，其漲跌預測方向正確率超過70%，其投資績效勝過大盤的買入持有策略。
Yim (2002)	以民國83年7月30日至民國87年6月30日，共988日資料做為樣本，比較類神經網路與傳統時間序列模型在預測巴西股價指數的能力。結果顯示，類神經網路優於ARIMA-GARCH模型。

二、遺傳演算法在股市投資的應用

遺傳演算法，或稱基因演算法，是近年來快速發展且極具潛力的最佳化方法之一。它有獨特的搜尋技巧，能跳離局部最佳值，以趨近整體最佳值。此方法最初是由Holland於1975年發展出來，並出版Adaptation in Natural and Artificial System一書。到了1989年其弟子Goldberg又出版遺傳演算法專書Genetic Algorithms in Search, Optimization and Machine Learning，更使的學術界普遍了解到此種極為強健的最佳化技術(葉怡成2005)。其概念源自於達爾文「物競天擇，適者生存」的想法，仿效自然界生物生存競爭，個體結合之後，所產生的後代會繼承雙方特性，較能適應環境的個體，將獲得較高

的存活機會，並繼續繁衍優秀的後代。其原理可參考文獻(雷英杰 2005)。這幾年遺傳演算法在財務上的實際應用日漸受重視，其相關文獻整理如表2所示。

表 2：「基於遺傳演算法」文獻回顧

文 獻	研究內容
陶宏德 (1995)	以民國78年1月5日至民國85年4月15日台灣加權股價指數日資料作為樣本，將知識庫中的規則模組語法加以定義，再藉由遺傳演算法的搜尋機制，從資料庫中擷取影響投資決策的技術分析指標，求得最佳的交易策略知識。研究的結果指出，以遺傳演算法來建構交易系統知識庫，可以有效的將關鍵的規則集納入。結果顯示，由此產生的規則集，在其年獲利率可達24.16%且在風險管理的控制上，也有優異的表現。
邱昭彰 (1998)	以民國84年1月起至85年8月31日台灣加權股價指數日資料作為樣本，並使用MA、RSI、BIAS、PSY四種指標，找出技術指標與常數值域的組合，最大化訓練期間之報酬率，並計算測試期間的報酬率。結果顯示，遺傳演算法所產生之每筆買入報酬率平均為3.7%及每筆賣出報酬率平均為-0.7%，其報酬率高於傳統上若指標高於某一常數則買入3.3%，但低於某一常數則賣出的策略之報酬率1.0%。
林耀堂 (2001)	以民國87年10月至民國88年4月的台積電股價日資料作為樣本，企圖將所有技術指標納入，再以演化的力量來作選擇，甚至允許以組合或分解的方式，產生前所未有的新技術指標，改善以往技術指標挑選在質和量方面不足的問題。透過世代的演化，產生最終代表多單進場、空單進場、多單出場、空單出場的4條交易規則。研究採用移動視窗的訓練方式，以適應環境的變遷。在適應函數分別以「獲利追求導向」及「風險趨避導向」為原則的設計下，由遺傳程式規劃所產生之擇時交易策略，在以大多頭市場為測試期間的平均總投資報酬率56.98%，皆能略高或貼近於買入持有策略總報酬率55.62%。而其中在風險趨避導向設計下所產生之交易策略，不僅能夠同時兼顧到風險的考量，同時也能夠達到總報酬率達55.33%。
許智明 (2003)	以民國84年1月1日至民國91年12月31日的台灣加權股價指數日資料作為樣本，利用遺傳演算法搜尋最佳之技術指標，然後以實證期加以驗證最佳技術指標之交易法則是否能有效預測大盤漲跌，獲取利潤。結果顯示，在搜尋期間，所搜尋到的六條最佳交易法則的績效明顯優於同期間五年的買進並持有策略的績效，證明遺傳演算法的確能有效搜尋最佳解。結果顯示，僅一條交易法則劣於買進並持有策略的年獲利率-2.67%，其餘五條交易法則皆能打敗買進並持有策略，且最高能夠獲得年獲利率8.61%，證明其交易法則是具備獲利能力的。從實證結果得知技術分析仍然是具備參考價值，而且投資人不應該將常用的技術指標視為最佳的交易法則。

表 2：「基於遺傳演算法」文獻回顧(續)

文 獻	研究 內容
連立川 (2006)	以民國78年7月11至93年7月2日台灣加權股價指數日資料作為樣本，並以所轉換的18種價量技術指標做為輸入參數，以期末資金最大化做為適應度函數，應用遺傳演算法的最佳化能力建構台灣大盤加權指數的買賣決策規則。研究結果顯示，所比較之三種交易策略：雙向GA買賣決策策略、單一雙向GA買賣決策策略及買入持有策略，在測試範例期間的平均年獲利率分別是10.72%、6.30%與-7.2%。
Allen (1999)	以標準500普爾指數(SP500)在西元1928至西元1998年的資料做為研究樣本，以移動平均線、最高價、最低價以及成交量為輸入變數，並運用遺傳規劃的方法來產生技術性的買進、賣出時點決策交易法則。結果顯示：(一)考慮0.25%為其交易成本，其整體績效不如買進並持有策略。(二)由於研究僅以移動平均指標及日資料做為輸入變數，因此，若再加入其它的技術指標，應該是能夠增加整體績效。
Allen (1999)	以標準500普爾指數(SP500)在西元1928至西元1998年的資料做為研究樣本，以移動平均線、最高價、最低價以及成交量為輸入變數，並運用遺傳規劃的方法來產生技術性的買進、賣出時點決策交易法則。結果顯示：(一)考慮0.25%為其交易成本，其整體績效不如買進並持有策略。(二)由於研究僅以移動平均指標及日資料做為輸入變數，因此，若再加入其它的技術指標，應該是能夠增加整體績效。
Korczak (2002)	以西元1997年1月2日至1999年11月10日之法國股市為研究樣本，研究由CAC40指數中，挑選出24支股票，並以四種技術指標結合遺傳演算法進行報酬率最大化的優化。其中訓練期為261天，測試期為7天。結果顯示，遺傳演算法所產生的策略大部分較買入持有策略之報酬率來的高。
Jiang (2003)	以西元1990年1月1日至2002年8月30日共2205筆交易資料的Microsoft、Intel Dell及Oracle為研究樣本。以移動平均指標所轉換之四種技術指標，並結合遺傳演算法進行報酬率最大化的優化。其中2000筆資料為訓練期，後1305筆資料作測試期。結果顯示，遺傳演算法所產生之報酬率明顯高於買入持有策略。

三、遺傳演算法及類神經網路彼此結合在財務的應用

遺傳演算法是以群體的概念同時搜尋空間上多個點而不是單一個點，因此基本上能夠避免最陡坡降法陷入局部最佳解的問題，同時也可以較快獲得整體最佳解。將遺傳演算法整合於類神經網路中，可改善類神經網路局部最佳解的缺點。相關文獻如表3所示。

表 3：「基於結合類神經網路與遺傳演算法」文獻回顧

文 獻	研究內容
劉克一 (2000)	以民國85年1月4日至民國88年12月28日摩根成份股來做為研究樣本。使用股票的技術指標作為類神經網路輸入變數，而輸出則是決定該股票的買入或賣出，以遺傳演算法演化類神經網路的權重。結果顯示，以台灣加權股價指數為例，其買入持有報酬率為-43.91%，但遺傳演算法能有效和穩定的設計類神經網路使其報酬率達14.68%。
周慶華 (2000)	以民國87年10月1日至民國89年12月31日新加坡交易所摩根台股指數期貨與期貨指數資料做為樣本。選擇領先期貨開盤的期貨指數及前一日期貨與期貨之收盤指數當作輸入層之輸入變數，建構遺傳演算法與類神經網路模式針對期貨開盤指數進行預測。結果顯示，整合遺傳演算法與類神經網路之預測模式對期貨開盤指數漲跌方向預測之正確率達80.46%。
林建成 (2001)	以民國86年1月至民國90年6月台灣加權股價指數日資料作為樣本，結合遺傳演算法與倒傳遞類神經網路來預測未來走勢。採以有限記憶的調適學習模式，分成三個區段，建立時間序列之移動窗戶。以開盤價、收盤價、最高價、最低價、成交量及一般股市投資人常用之技術分析指標做為輸入變數。並建立多元迴歸估計式，比較兩者的預測績效。結果顯示，在整體的預測績效上，遺傳演算類神經網路模式平均報酬率為348.6%，顯然優於多元迴歸模式報酬率為97.6%。
李建輝 (2002)	以民國90年1月1日至民國90年12月31日台灣加權股價指數日資料作為樣本，利用遺傳演算法所建構的類神經網路，以預測臺灣期貨交易所之台股指數期貨為對象，實驗分別採前三天之期貨指數漲跌幅為輸入變數及以五種技術指標為輸入變數，預測未來每日期貨指數之漲跌幅。與傳統操作策略(順向操作、逆向操作、迴歸操作及買進持有策略)作比較。結果顯示，不管有無考慮技術指標，遺傳演化類神經網路所預測出的平均每月準確率及平均每月報酬率分別為54.32%及12.51%，其績效均優於迴歸策略；且有考慮技術指標之遺傳演化類神經網路所預測出之平均每月準確率及平均每月報酬率分別為62.42%及59.62%，較不考慮技術指標之遺傳演化類神經網路者為優。
Phua (2001)	以民國87年9月至民國89年1月新加坡海峽指數(STI)日資料作為樣本，以開盤價、收盤價、最高價、最低價、成交量以及國外其他市場大盤指數等為指標，並以遺傳演算法做為類神經網路設定參數的搜尋工具。研究預測隔天股市上漲或下跌，其準確率高達81%。
Armano (2002)	使用西元1992年2月5日至西元2000年8月20日共2000筆義大利證券市場指數日資料做為樣本，並進行模擬交易。研究使用股價移動平均值、平均變動率、RSI、上升與下降趨勢線等技術指標作為輸入項目，並預測股票指數。結果顯示，遺傳演化類神經網路系統優於買入持有策略。

表 3：「基於結合類神經網路與遺傳演算法」文獻回顧(續)

文 獻	研究 內容
Kwon (2003)	研究以西元1992年至西元2001年NYSE及NASDAQ共36家公司股價作為樣本，64個日資料轉換的技術指標作為輸入變數，並以遺傳演算法優化類神經網路權值，輸出變數為各家公司隔天股價的漲幅，以移動視窗的概念，並以二年期間作為訓練範例，三年期間作為驗證範例，最後四年期間作為測試範例。結果顯示，遺傳演化類神經網路的方法，確實能夠達到良好之獲利情況。

參、研究方法

一、股價資料收集

好的交易策略應來自歷經多頭與空頭市場的歸納，要證明交易策略的優劣也應歷經多頭與空頭市場的考驗。台灣股市在民國78年至93年間歷經七次多頭與七次空頭市場(見圖1)，是合適的資料來源。因此本研究共收集78/7/11~93/7/2台灣股市大盤股價指數4083筆資料，每筆資料包含當日收盤價、開盤價、最高價、最低價以及成交值。此外，為正確評估產生之系統的普遍性，本研究將數據依時序分成二部分：前段為訓練範例；後段為測試範例。GA只對訓練範例進行最佳化，所產生的買賣決策系統再應用在測試範例。因此，所得之評估將具有普遍性。本研究以78/7/11~89/6/27共3083筆約12年的資料做為訓練範例，89/6/28~93/7/2共1000筆約5年的資料做為測試範例，如圖1所示。從圖中能夠發現，訓練階段及測試階段皆經過多次大多頭及大空頭時期，因此資料具有代表性。




圖 1：訓練及測試範例歷史資料期間

二、技術指標計算

本研究採用之指標不同於常見之技術指標，雖同樣考慮台灣大盤股價及成交值的混合變動情況，但設計上較傾向把價、量資訊用時間數列的觀點來處理。本研究所使用的技術指標包括趨向指標(Durbin Watson; DW)、相對強弱指標(Relative Strength Indicator; RSI)、價量指標(Price Volume Indicator; PVI)、價量變化指標(Price Volume Change; PVC)、移動平均價指標(Moving Average Indicator; MAI)及移動平均量指標(Moving Volume Indicator; MVI)六種代表性指標，各種指標的計算方式如公式 (1) ~ (6) 所示。其中RSI、MAI及DW純粹是「價」方面的指標，MVI純粹是「量」方面的指標，而PVI及PVC為「價」與「量」結合的指標。

$$DW_{n=5,10,20} = \frac{\sum_{t=1}^n (\Delta C_t - \Delta C_{t-1})^2}{\sum_{t=1}^n (\Delta C_t)^2} \dots\dots\dots(1)$$

$$RSI_{n=5,10,20} = \frac{\sum_{t=1}^n \text{Max}(\Delta C_t, 0)}{\sum_{t=1}^n |\Delta C_t|} \dots\dots\dots(2)$$

$$PVI_{n=5,10,15} = \frac{\sum_{t=1}^n \Delta C_t \times V_t}{\sum_{t=1}^n |\Delta C_t| \times V_t} \dots\dots\dots(3)$$

$$PVC_{n=5,10,20} = \frac{\sum_{t=1}^n \Delta C_t \times \Delta V_t}{\sum_{t=1}^n |\Delta C_t \times \Delta V_t|} \dots\dots\dots(4)$$

$$MAI_{m,n=(5,10),(5,20),(10,20)} = \frac{MA_m}{MA_n} \dots\dots\dots(5)$$

$$MVI_{m,n=(5,10),(5,20),(10,20)} = \frac{MV_m}{MV_n} \dots\dots\dots(6)$$

其中 C_t =第 t 日收盤價； $\Delta C_t=C_t-C_{t-1}$ ； V_t =第 t 日成交值； $\Delta V_t=V_t-V_{t-1}$ ； MA_m = m 日收盤價的移動平均， MA_n = n 日收盤價的移動平均； MV_m = m 日成交值的移動平均， MV_n = n 日成交值的移動平均，其中 MA_m 、 MA_n 、 MV_m 、 MV_n 如公式 (7) ~ (10) 所示。

$$MA_m = \frac{\sum_{t=1}^m C_t}{m} \dots\dots\dots(7)$$



$$MA_n = \frac{\sum_{t=1}^n C_t}{n} \dots\dots\dots(8)$$

$$MV_m = \frac{\sum_{t=1}^m V_t}{m} \dots\dots\dots(9)$$

$$MV_n = \frac{\sum_{t=1}^n V_t}{n} \dots\dots\dots(10)$$

由於每種指標值域的範圍不一，為求正規化，再進行值域-1.0~1.0的轉換，其轉換公式如公式 (11) 所示。

$$V_{new} = \frac{V_{old} - V_{min}}{V_{max} - V_{min}} (D_{max} - D_{min}) + D_{min} \dots\dots\dots(11)$$

其中 V_{old} 為正規化前的技術指標； V_{min} 為該技術指標之最小值； V_{max} 為該技術指標之最大值； D_{max} 為該技術指標正規化後值域中最大值，本研究設為1.0； D_{min} 為該技術指標正規化後值域中最小值，本研究設為-1.0； V_{new} 為正規化後的技術指標。

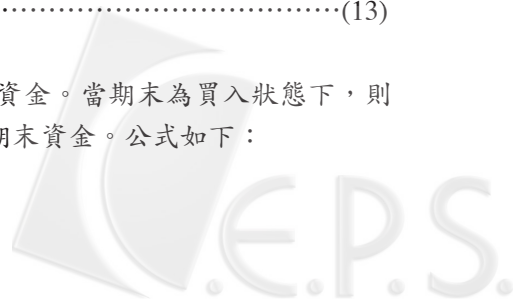
三、買賣決策規則及適應度函數定義

國內證券金融市場於民國87年7月21日正式推出台灣發行量加權指數期貨契約，為台灣的金融業自由化及國際化，建立一新里程碑，提供了投資者新投資商品和避險工具，也提供投機客及套利者，以少量資金賺取較大利潤的機會。尤其近幾年來期貨交易熱度愈來愈沸騰，期貨市場的發展潛力愈來愈不可忽視(李惠妍 2003)。因此，本研究提出買賣期貨的雙向買賣決策規則。所謂雙向買賣決策規則是指投資者不僅考量買入點至賣出點的獲利績效，另外也同時考量賣出點至買入點時後的獲利績效。此外，由於本研究的目的是以發展能提升投資台灣股市績效的交易策略，因此其交易成本參考真實個股之交易成本定義，諸如買入之手續費為0.1425%，如公式 (12) 所示，而賣出之手續費為0.1425%，此外賣出需再付給0.3%交易稅，如公式 (13) 所示。

$$\text{買入持有股票} = \frac{\text{持有資金}}{\text{當日股價}} \times 99.8575\% \dots\dots\dots(12)$$

$$\text{賣出持有資金} = \text{持有股票} \times \text{當日股價} \times 99.5575\% \dots\dots\dots(13)$$

本研究所採用之買賣決策規則的適應度函數為期末資金。當期末為買入狀態下，則需轉換為期末資金；若期末為賣出狀態下，則直接等於期末資金。公式如下：



$$\text{期末} \begin{cases} \text{買入狀態} & \text{資金} = \text{持有股數} \times \text{期末股價} \cdots \cdots (14) \\ \text{賣出狀態} & \text{資金} = \text{資金持有} \cdots \cdots (15) \end{cases}$$

四、決策規則之評估方式

評估買賣決策規則優劣的常用基準為年獲利率：

$$\text{年獲利率} = \left(\sqrt[n]{\frac{M_e}{M_s}} - 1 \right) \times 100\% \cdots \cdots (16)$$

但上述基準在交易期間是處於多頭市場時，「買入持有策略」會有不錯的績效，以致一般的交易策略不易擊敗之；反之，處於空頭市場時，會有低劣的績效，以致一般的交易策略易於擊敗之。因此本文提出「相對獲利指標」：

$$\text{相對獲利指標} = \frac{\sqrt[n]{\frac{M_e}{M_s}}}{\sqrt[n]{\frac{C_e}{C_s}}} \cdots \cdots (17)$$

其中n等於總交易年數； M_s 等於期初資金； M_e 等於期末資金； C_s 等於期初收盤價； C_e 等於期末收盤價。


由公式 (17) 可知，買入持有策略之相對獲利係數為1.00。若買賣決策產生之相對獲利指數大於1.00，則優於買入持有策略；反之，則反。由於相對獲利指標有考慮交易期間是處於多頭或空頭市場，因此是較佳的比較基準。

用來評估決策規則產生之買入及賣出之時機適當與否可用成功率來表示，本研究所給定之「買入成功」定義為，當系統決定買入後，而在系統決定賣出時，股價上漲，稱為買入成功；而「賣出成功」定義為，當系統決定賣出後，而在系統決定買入時，股價下跌，則稱為賣出成功。其成功率公式如 (18)~(20) 式所示。

$$\text{買入成功率} = \frac{\text{買入成功次數}}{\text{買入交易次數}} \cdots \cdots (18)$$

$$\text{賣出成功率} = \frac{\text{賣出成功次數}}{\text{賣出交易次數}} \cdots \cdots (19)$$

$$\text{總交易成功率} = \frac{\text{買入成功次數} + \text{賣出成功次數}}{\text{買入交易次數} + \text{賣出交易次數}} \cdots \cdots (20)$$



五、目標函數及演算法參數設定

本研究以最大化「期末資金」為遺傳神經網路所要優化的目標函數。在GA參數的設定原則方面，在參考許多文獻(雷英杰 2005; Jiang 2004; Kwon 2004; Armano 2003; Korczak 2002)後，歸納得：(一)交配後產生之個體數50~200個；(二)交配率設定為0.4~0.99；(三)突變率設定為0.0001~0.1。本研究經過嘗試錯誤的過程後採用以下參數：(一)交配後產生之個體數設定為100個；(二)交配率設定為0.9；(三)突變率設定為0.001；(四)使用保存精英策略，即最佳個體無條件複製到下一世代的族群之中。在收斂條件方面，設定至少200個世代，否則直到目標函數明顯不再改善時停止遺傳神經網路的演化過程。

肆、遺傳神經網路(Genetic Neuron Network; GNN)

一、模型建構

本研究是以標準的類神經網路模型架構，但輸出變數是買賣決策指標，此值愈大，代表愈該買入；反之愈小，代表愈該賣出。由於此輸出變數並無目標值，因此傳統的最陡坡降法無法使用，在此改以遺傳演算法來決定網路的連結權值，目標函數也由傳統的誤差均方和改為前述「期末資金」。遺傳演算法以最大化此一目標函數為原則決定最佳的連結權值，其GA搜尋的權值範圍為-10~10之間的數值。在輸入層的部分，由於使用大量的變數做為輸入層較易使神經網路發生過度配適(overfitting)問題，而只用少量重要的變數做為輸入層反而可使神經網路不易發生過度配適問題，使其在測試範例的表現較為強健(葉怡成 2002)，因此本研究以GA優選18個指標中的6個指標做為輸入變數，其中18個指標的編碼如表4所示。

表 4：18個技術指標的編碼方式

編碼	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
技術指標	DW(5)	DW(10)	DW(20)	RSI(5)	RSI(10)	RSI(20)	PVI(5)	PVI(10)	PVI(20)	PVC(5)	PVC(10)	PVC(20)	MAI(5,10)	MAI(5,20)	MAI(10,20)	MVI(5,10)	MVI(5,20)	MVI(10,20)

本研究隱藏層設定為一層且節點設定為6個，其中輸入層與隱藏層節點的關係如公式(21)所示。

$$\text{net}_k = \sum_{i=1}^{N_{\text{inp}}} W_{ik} \times x_i + \theta_k \dots\dots\dots (21)$$

其中 net_k 是隱藏層節點的加權乘積的值； W_{ik} 是隱藏層節點與輸出層之間的權值； x 是尺度化後的輸入變數；是 θ_k 隱藏層的偏權值。

轉換函數通常有值域在(0,1)的sigmoid函數與值域在(-1,+1)的tanh函數二種。一般而言，採用何者對神經網路的效能影響甚微(葉怡成 2002)。本研究採用tanh函數：

$$f(\text{net}_k) = \tanh(\text{net}_k) \dots\dots\dots(22)$$

神經網路輸出層與隱藏層節點的關係如公式 (23) 所示。

$$\text{net}_j = \sum_{k=1}^{N_{\text{hid}}} W_{kj} \times f(\text{net}_k) + \theta_j \dots\dots\dots(23)$$

其中 W_{kj} 是隱藏層節點與輸出層之間的權值； θ_j 是輸出層的偏權值。

此外輸出層最後進行-1.0~1.0之間的轉換，其公式如公式 (11) 所示。最後再由GA優化決定最佳之「買入門檻值」及最佳之「賣出門檻值」，即當神經網路的輸出層之「買賣決策指標」大於「買入門檻值」，進行買入動作；當「買賣決策指標」小於「賣出門檻值」，進行賣出動作。

本研究所使用之遺傳神經網路(Genetic Neuron Network; GNN)之流程圖如圖2所示。

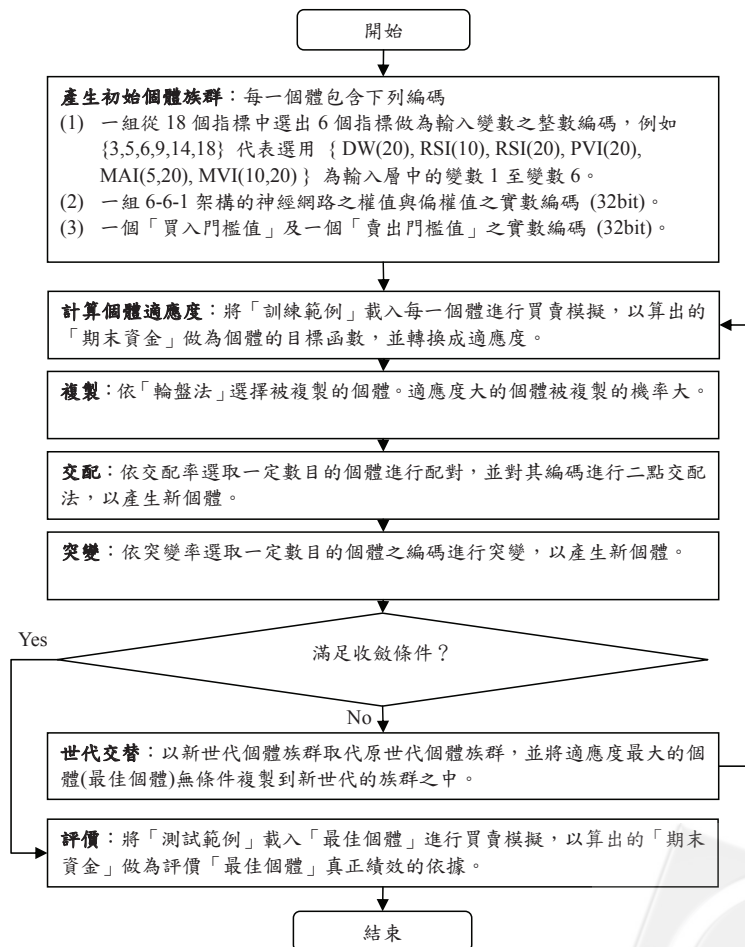


圖 2：遺傳神經網路流程圖

二、結果

表5為GNN在輸入層最後優選的六個指標變數，分別是MVI(10, 20)、PVC(10)、PVC(20)、PVI(20)、DW(5)及DW(20)。GA最後決定之最佳買入及賣出時機為當輸出值等於或大於0.482時，將進行買入，當輸出值等於或小於0.145時，將進行賣出。圖3a及圖3b分別是GNN最佳買賣決策下的訓練範例買入及賣出交易點與資金變動圖，其中白色三角點為買入點，黑色菱形點為賣出點。圖4a及圖4b分別是最佳買賣決策下的測試範例買入及賣出交易點與資金變動圖。

表 5：GNN優化後所使用的六個指標

使用指標	編碼	指標名稱
一	18	MVI(10,20)
二	11	PVC(10)
三	12	PVC(20)
四	9	PVI(20)
五	1	DW(5)
六	3	DW(20)



圖 3a：GNN在訓練範例產生之買入及賣出交易點




圖 3b：GNN在訓練範例之資金變動圖




圖 4a：GNN在測試範例產生之買入及賣出交易點




圖 4b：GNN在測試範例之資金變動圖

三、獲利能力與交易風險之比較

為比較GNN之績效，除了「買入持有」策略，本文另外以四種策略作績效比較：

- (1) 實務上常用之「月線之RSI正操作策略」、「月線之RSI逆操作策略」。前者是基於「跌多必漲，漲多必跌」的理念，以月線之RSI小於30%為買入點，大於70%為賣出點；後者是基於「趨勢明朗，追高殺低」的理念，以月線之RSI大於70%為買入點，小於30%為賣出點。傳統的技术分析比較傾向主張前者。
- (2) 文獻中(連立川&葉怡成 2005)已發表且同樣基於遺傳演算的「遺傳演化邏輯規則(Genetic Logic Rule; GLR)」、「單一遺傳演化邏輯規則(Single Genetic Logic Rule; SGLR)」。所謂GLR是以GA優化產生的邏輯規則交易策略，買入與賣出規則都有三個條件。SGLR是以GA優化產生的單一邏輯規則交易策略，即僅考慮單一技術指標下以GA優化產生的交易策略，買入與賣出規則都只有一個條件。

將上述方法套用本研究之數據，結果如圖5及圖6分別是GLR及SGLR所產生之最佳買入及賣出時機；圖7及圖8為傳統以月線之RSI的正操作及逆操作決策規則。

買入規則			賣出規則		
IF	DW(5) > 0.23		IF	RSI(5) > 80%	
AND	PVI(20) > 0.50		AND	PVC(20) > 0.10	
AND	RSI(10) > 65%		AND	RSI(20) ≤ 49%	
THEN	進行買入動作		THEN	進行賣出動作	

圖 5：GLR

買入規則		賣出規則	
IF	RSI(5) > 45%	IF	MVI(10,20) > 0.09
THEN	進行買入動作	THEN	進行賣出動作

圖 6：SGLR

買入規則		賣出規則		買入規則		賣出規則	
IF	RSI(20) ≤ 30.0%	IF	RSI(20) > 70.0%	IF	RSI(20) > 70.0%	IF	RSI(20) ≤ 30.0%
THEN	進行買入動作	THEN	進行賣出動作	THEN	進行買入動作	THEN	進行賣出動作

圖 7：月線之RSI正操作買賣決策規則

圖 8：月線之RSI逆操作買賣決策規則

表6及表7分別為GNN及其它五種決策下，訓練範例及測試範例的評估結果。由表可知，無論在訓練範例期間或測試範例期間GNN均優於其它五種買賣決策。此外值得注意的是雖然傳統的技術分析比較傾向主張「月線之RSI正操作策略」，但本實證研究卻發現「月線之RSI逆操作策略」的績效遠比前者為佳。

表 6：各種策略在訓練範例期間之比較

		GNN	GLR	SGLR	RSI 正操作策略	RSI 逆操作策略	買入 持有策略
獲利 分析	期初資金	1,000,000	1,000,000	1,000,000	1,000,000	1,000,000	1,000,000
	期末資金	207,201,259	177,229,566	65,019,121	245,967	4,772,522	1,016,734
	年獲利率	55.97%	53.95%	41.61%	-11.0%	13.9%	0.1%
	相對獲利係數	1.56	1.54	1.41	0.89	1.14	1.00
成功 率 分析	買入交易次數	50	19	55	31	31	NA
	買入成功次數	38	17	26	20	13	NA
	買入成功率	76.0%	89.5%	47.3%	64.5%	41.9%	NA
	賣出交易次數	49	18	54	31	30	NA
	賣出成功次數	26	12	29	18	11	NA
	賣出成功率	53.1%	66.7%	53.7%	58.1%	36.7%	NA
	總交易次數	99	37	109	61	61	NA
	總成功次數	64	29	55	38	24	NA
	總成功率	64.6%	78.4%	50.5%	61.3%	39.3%	NA

表 7：各種策略在測試範例期間之比較

		GNN	GLR	SGLR	RSI 正操作策略	RSI 逆操作策略	買入 持有策略
獲利 分析	期初資金	1,000,000	1,000,000	1,000,000	1,000,000	1,000,000	1,000,000
	期末資金	2,869,306	1,449,641	122,4286	528,599	1,302,040	686,909
	年獲利率	23.47%	7.71%	4.13%	-12.0%	5.4%	-7.2%
	相對獲利係數	1.33	1.16	1.12	0.95	1.14	1.00
成功 率 分析	買入交易次數	15	8	23	8	8	NA
	買入成功次數	10	5	12	4	3	NA
	買入成功率	66.7%	62.5%	52.2%	50.0%	37.5%	NA
	賣出交易次數	14	7	22	8	7	NA
	賣出成功次數	10	3	10	6	4	NA
	賣出成功率	71.4%	42.9%	45.5%	75.0%	57.1%	NA
	總交易次數	29	15	45	16	15	NA
	總成功次數	20	8	22	10	7	NA
	總成功率	69.0%	53.3%	48.9%	62.5%	46.7%	NA

由以上結果分析可知，結合技術指標及GA確實能夠從歷史資料中搜尋出合理的買賣決策規則，但GA的優化具有隨機性，因此，若訓練範例每次所產生的決策規則在測試範例中都能具備良好獲利效果，才足以確認所產生的決策規則具備穩定性。表8至表10分別是GNN與GLR及SGLR在30次執行中產生的結果之統計分析。由表8至表10可看出在測試範例中，GNN在獲利能力方面遠優於GLR與SGLR；但在成功率方面，差異並不大。

表 8：30個代表組的GNN效益統計

		年獲利率	相對獲利係數	總成功率
訓練範例	最大值	86.22%	1.86	67.50%
	最小值	40.58%	1.40	50.55%
	平均值	58.80%	1.59	57.06%
	標準差	10.86%	0.11	4.52%
測試範例	最大值	30.09%	1.40	70.59%
	最小值	-17.82%	0.89	31.58%
	平均值	10.27%	1.19	51.47%
	標準差	12.57%	0.14	7.86%

表 9：30個代表組的GLR效益統計

		年獲利率	相對獲利係數	總成功率
訓練範例	最大值	58.93%	1.59	80.00%
	最小值	23.99%	1.24	40.14%
	平均值	36.65%	1.36	55.46%
	標準差	9.91%	0.10	8.30%
測試範例	最大值	30.12%	1.30	81.82%
	最小值	-11.83%	0.90	38.00%
	平均值	2.02%	1.08	51.04%
	標準差	10.76%	0.11	9.90%

表 10：30個代表組的SGLR效益統計

		年獲利率	相對獲利係數	總成功率
訓練範例	最大值	41.61%	1.41	71.43%
	最小值	6.57%	1.06	47.85%
	平均值	38.61%	1.38	52.51%
	標準差	6.34%	0.06	5.44%
測試範例	最大值	17.15%	1.26	71.43%
	最小值	-24.08%	0.82	28.57%
	平均值	-0.05%	1.08	47.26%
	標準差	8.67%	0.09	7.67%

圖9是GNN、GLR、SGLR在執行30次結果及RSI正操作策略、RSI逆操作策略、買入持有策略的訓練範例及測試範例的相對獲利係數散佈圖。從圖可知，無論在訓練範例期間或測試範例期間，GNN均優於其它五種買賣決策策略。此外，由圖可知，大致上在訓練範例期間表現較佳的策略，在測試範例也有較佳的表現，可見這些策略具有一定的普遍性。不過GNN、GLR與SGLR三者有嚴重的過度學習現象，即在訓練範例表現佳，但在測試範例表現遜於訓練範例之現象。




圖 9：各種策略訓練範例及測試範例相對獲利係數關係圖

表11為GNN、GLR及SGLR三種方法的檢定分析，由表可知，GNN、GLR及SGLR的年獲利率高於買入持有的機率分別為91.77%、80.51%及79.39%，GNN明顯高於另二種方法，雖然GNN在測試範例的年獲利率之最小值微幅低於GLR，但其檢定分析證明GNN仍然顯著優於GLR。

表11：三種模型重新訓練後與買入持有策略的檢定分析

比較項目	買入持有大於三種模型的機率
GNN	$P(\mu > x) = \Phi\left(\frac{\mu - x}{\sigma}\right) = \Phi\left(\frac{10.27 - (-7.2)}{12.57}\right) = 0.9177$
GLR	$P(\mu > x) = \Phi\left(\frac{\mu - x}{\sigma}\right) = \Phi\left(\frac{2.02 - (-7.2)}{10.76}\right) = 0.8051$
SGLR	$P(\mu > x) = \Phi\left(\frac{\mu - x}{\sigma}\right) = \Phi\left(\frac{-0.05 - (-7.2)}{8.67}\right) = 0.7939$
其中x等於買入持有策略年平均獲利率-7.2%、 μ 為三種模型的年平均獲利率、 σ 為三種模型的年平均獲利率標準差。	

伍、結論與建議

本研究的重要結論如下：

- 一、由獲利能力之比較可知，結合遺傳演算與神經網路的「遺傳神經網路」(GNN)在台灣大盤加權指數上能夠有良好的獲利，年獲利率在測試期間平均達10.27%，遠高於買入持有策略的-7.2%，也顯著高於其它四種實務上與文獻上的交易策略。
- 二、由於遺傳演算法具有隨機性，本研究重覆訓練、測試過程，建構30個GNN, GLR, 與SGLR決策模式，結果顯示，GNN的風險性明顯低於GLR及SGLR這二種方法，顯示GNN是一個穩健的方法。
- 三、由檢定分析可知，GNN的年獲利大於買入持有策略的機率是91.77%，這在學術上提供一個評估「效率市場假說」的個案研究。
- 四、傳統的技術分析比較傾向主張「月線之RSI正操作策略」，但本實證研究卻發現「月線之RSI逆操作策略」的績效遠比前者為佳。這在實務上提供一個反思傳統技術分析觀念的實例。

本文的研究限制如下：

- 一、本研究以股價指數為買賣標的，雖然股價指數是台股股價的加權結果，但實務上並不能做為直接買賣的標的。
- 二、本研究以臺灣股價指數為研究標的，由於各國證券市場結構的特性不同，因此本研究的結論並不一定適用於其他市場。
- 三、本研究以民國78年至93年間的台灣股市為範圍，雖然在此期間歷經七次多頭與七次空頭市場，可充份代表不同市場環境。但如果台灣股市在未來產生相當大的結構性變化，如投資人的組成、交易成本、交易限制、漲跌幅限制等，則本研究的結論並不一定適用於當時的市場結構。
- 四、本研究採用雙向買賣決策規則，它不僅考量買入點至賣出點的獲利績效，另外也同時考量賣出點至買入點時後的獲利績效，但在實務上這種操作有一定的難度。
- 五、本研究雖在技術指標的考量上包含了純粹是「價」的指標、純粹是「量」的指標與「價量」結合的指標，但這些指標都是人為設計的，而非經過演算法優化設計的，因此並不是最理想的技術指標。

對於未來研究，有二個方向：

- 一、由於市場上各類股、個股的特性不同，因此本研究未來將朝向針對各種類股及个股，預期發展適合的買賣決策。
- 二、由於各國證券市場結構的特性不同，因此本研究未來也將朝向針對不同經濟發達程度的國家之股票市場進行實證研究，以探討本文方法在不同市場的適用性，並探討效率市場假說在不同經濟發達程度市場的正确性。

參考文獻

1. 江吉雄，民90，遺傳演算法於股市選股與擇時策略之研究，國立中央大學碩士論文。
2. 林耀堂，民90，遺傳程式規劃於股市擇時交易策略之應用，國立中央大學碩士論文。
3. 李惠妍，民92，類神經網路與迴歸模式在台股指數期貨預測之研究，國立成功大學碩士論文。
4. 劉克一，民89，以遺傳演算法演化類神經網路在股價預測上的應用，真理大學碩士論文。
5. 邱昭彰、李安邦，1998『遺傳演算法在發展股市投資專家知識規則之研究』，資管評論，第八期：21-38頁。
6. 陶宏德，民84，應用遺傳演算法達成知識之最適化—以臺灣股市技術分析指標為例，交通大學碩士論文。
7. 許智明，民92，運用遺傳演算法搜尋最佳化技術指標之台灣股市實證研究，雲林科技大學碩士論文。
8. 周慶華，民89，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，輔仁大學碩士論文。
9. 李建輝，民91，遺傳演化類神經網路在預測台股指數期貨的應用，東吳大學碩士論文。
10. 林建成，民90，遺傳演化類神經網路於台灣股市預測與交易策略之研究，東吳大學碩士論文。
11. 葉怡成，2005，資料探勘—方法應用與實作，未出版。
12. 雷英杰、張善文、李續武、周創明，2005，MATLAB遺傳算法工具箱及應用，西安電子科技大學出版社。
13. 葉怡成，2002，應用類神經網路，儒林圖書有限公司。
14. 連立川、葉怡成、江宗原、楊豐銘，2006『遺傳演算法建構台灣股市期貨買賣決策規則之研究』，資管評論，第十四期：47-61頁。
15. Yim, J. "A comparison of neural networks with time series models for forecasting returns on a stock market index," *Lecture Notes in Computer Science* 2002, pp:25-35
16. Cheh, J. J., Weinberg, R. S. and Yook, K. C. "An application of an artificial neural network investment system to predict takeover targets," *Journal of Applied Business Research* (15) 1999, pp:33-45
17. Glaria, B. A., et al. "Stock market indices in Santiago de Chile: forecasting using neural networks," *IEEE International Conference on Neural Networks* (4) 1996, pp:2172 -2175
18. Tan, C. N. W. "Trading a NYSE-stock with a simple artificial neural network-based financial trading system," *First New Zealand International Two-Stream Conference on Artificial Neural Networks and Expert Systems* 1993, pp:24-26

19. Allen, F. and Karjalainen, R. "Using genetic algorithms to find technical trading rules," *Journal of Financial Economics* (51) 1999, pp:245-271
20. Phua, H. P. K., Ming, D., and Lin, W. "Neural network with genetically evolution algorithms for stocks prediction," *Asia-Pacific Journal of Operation Research* (18:1) 2001, pp:103-108
21. Armano, Giuliano, et al. "Stock market prediction by a mixture of genetic-neural experts," *International Journal of Pattern Recognition and Artificial Intelligence* (16) 2002, pp:501-526
22. Kwon, Y. K. and Moon, B. R. "Daily Stock Prediction Using Neuro-Genetic Hybrids," *Genetic and evolutionary computation conference* 2003, pp:2203-2214
23. Korcazk J. and Roger P. "Stock timing using genetic algorithm," *Applied Stochastic Models in Business and Industry* (18) 2002, pp:121-134
24. Jiang R., and Szeto K. Y. "Extraction of Investment strategies based on Moving Averages: A Genetic Algorithm Approach," *IEEE 0-7803-7654-4* 2003, pp:403-410

