



(19)中華民國智慧財產局

(12)發明說明書公告本 (11)證書號數：TW I560634 B

(45)公告日：中華民國 105(2016)年 12 月 01 日

(21)申請案號：100116808

(22)申請日：中華民國 100(2011)年 05 月 13 日

(51)Int. Cl. : G06Q40/04 (2012.01)

G06F17/15 (2006.01)

(71)申請人：國立臺灣科技大學（中華民國）NATIONAL TAIWAN UNIVERSITY OF SCIENCE
AND TECHNOLOGY (TW)
臺北市大安區基隆路 4 段 43 號

(72)發明人：張兆鴻 CHANG, CHAO HUNG (TW)；徐演政 HSU, YEN TSENG (TW)；葉治宏
YEH, JE ROME (TW)；葉柏麟 YEH, PO LIN (TW)；林玉堂 LIN, YU TUNG (TW)

(74)代理人：林育雅

(56)參考文獻：

TW 200947225A	US 20060150216A1
WO 2002088903A2	

審查人員：洪奕璿

申請專利範圍項數：7 項 圖式數：6 共 24 頁

(54)名稱

多指標選擇權交易模型產生方法

GENERATING METHOD FOR TRANSACTION MODES WITH INDICATORS FOR OPTION

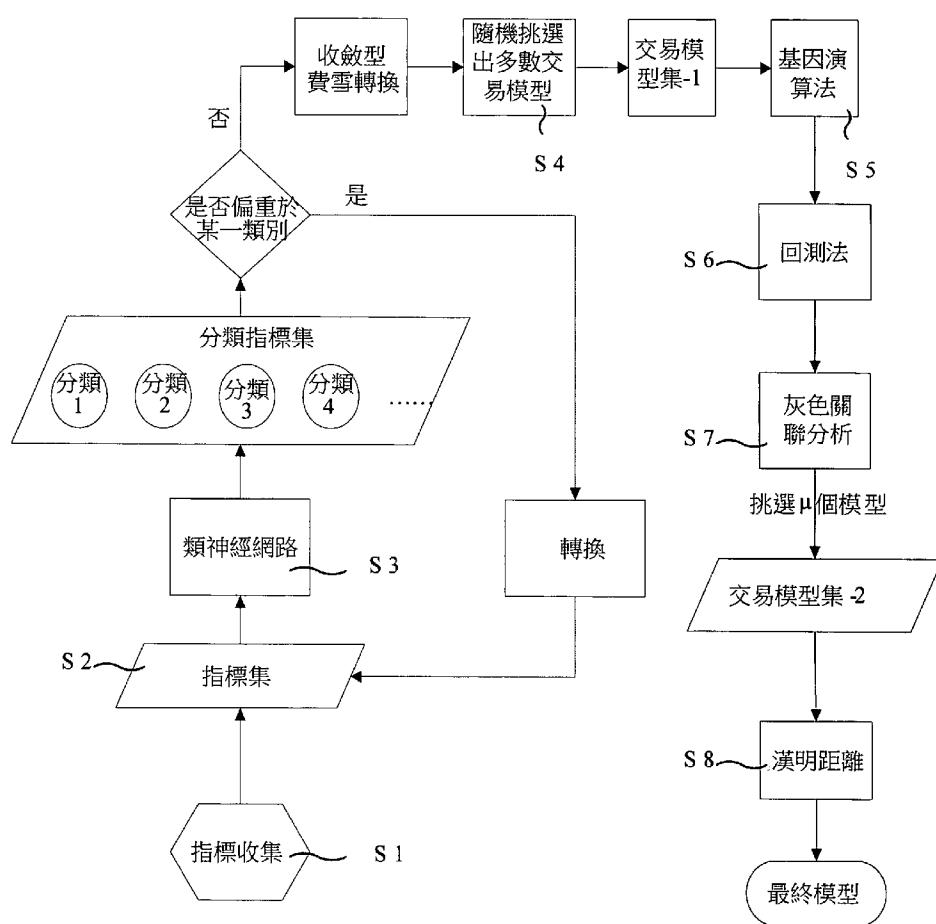
(57)摘要

一種多指標選擇權交易模型產生方法是先收集股票市場的不同類股之數個技術指標，每一技術指標均具有日期參數；再建立儲存該等技術指標之一指標集；再利用類神經網路來將該等技術指標加以辨識及分類；再隨機挑選出數個交易模型，其中每一交易模型內的技術指標不能屬於同一分類；接著決定每一技術指標之該日期參數；然後踢除部分該等交易模型；再自另一部份該等交易模型中，挑選數個最終交易模型；最後，決定每一最終交易模型的權重。本發明之主要目的為利用人工智慧技術，來提供投資者能夠在選擇權市場擁有一個作為買賣參考的程式交易模型。

The invention is to provide a generating method for transaction modes with indicators for option. The method comprises: (S1) collecting a variety of indicators from the financial market; (S2) establishing an indicator pool saved with the indicators; (S3) distinguishing and classifying the indicators by Neural Network; (S4) determining a plurality of transaction modes, the indicator of each transaction mode in an independent classification; (S5) determining a date parameter for each indicator; (S6) deleting a part of the transaction modes; (S7) determining a plurality of final transaction modes from another transaction modes; and (S8) determining a weighting of each final transaction mode.

指定代表圖：

符號簡單說明：
 (S1)~(S8) · · · 步驟



圖一

公告本

發明專利說明書

(本說明書格式、順序，請勿任意更動，※記號部分請勿填寫)

※申請案號：(09116808)

※申請日：100.5.13

※IPC分類：G06Q 40/42 202.01

一、發明名稱：(中文/英文)

G06F 19/5 (2006.01)

多指標選擇權交易模型產生方法 / GENERATING METHOD FOR TRANSACTION MODES WITH INDICATORS FOR OPTION

二、中文發明摘要：

一種多指標選擇權交易模型產生方法是先收集股票市場的不同類股之數個技術指標，每一技術指標均具有日期參數；再建立儲存該等技術指標之一指標集；再利用類神經網路來將該等技術指標加以辨識及分類；再隨機挑選出數個交易模型，其中每一交易模型內的技術指標不能屬於同一分類；接著決定每一技術指標之該日期參數；然後踢除部分該等交易模型；再自另一部份該等交易模型中，挑選數個最終交易模型；最後，決定每一最終交易模型的權重。本發明之主要目的為利用人工智慧技術，來提供投資者能夠在選擇權市場擁有一個作為買賣參考的程式交易模型。

三、英文發明摘要：

The invention is to provide a generating method for transaction modes with indicators for option. The method comprises: (S1) collecting a variety of indicators from the financial market; (S2) establishing an indicator pool saved with the indicators; (S3) distinguishing and classifying the indicators by Neural Network; (S4) determining a plurality of transaction modes, the indicator of each transaction mode in an independent classification; (S5) determining a date parameter for each indicator; (S6) deleting a part of the transaction modes; (S7) determining a plurality of final transaction modes from another transaction modes; and (S8) determining a

weighting of each final transaction mode.

四、指定代表圖：

(一)本案指定代表圖為：圖（一）。

(二)本代表圖之元件符號簡單說明：

(S1)~(S8)：步驟

五、本案若有化學式時，請揭示最能顯示發明特徵的化學式：

「無」

六、發明說明：

【發明所屬之技術領域】

本發明係與一種運用人工智慧技術來建立多指標選擇權交易模型的多指標選擇權交易模型產生方法有關。

【先前技術】

近年來台灣的金融市場蓬勃發展，其中以選擇權市場更具代表性。在選擇權市場中，投資者只需維持一定金額的保證金，便有機會利用高度財務槓桿獲取驚人的利潤，同時選擇權也提供了避險的功能，因而吸引國外投入大量資金進入台灣的市場進行避險，使得台灣金融市場更顯活絡與健全。

對於股票市場的分析，一般分為基本分析以及技術分析兩種方式。其中基本分析所需考慮的因素很多，包括：國內外的政治局勢、政府對股市的政策、經濟發展、金融概況、股票上市公司的整體分析、營運績效以及股市資金流動的情況等，所以很難從基本面中找出影響市場動向的因子及其規則性，也因此技術分析能夠廣為大眾所採用。技術分析為運用統計科學及數學的方式，依據歷史的股價與成交量等資訊衍生而來的線性指標來歸納出某些特性，進而預測市場未來可能的發展方向。

隨著電腦技術的發達，程式交易系統成為近年來新興的交易方式，利用電腦化的交易工具、技術分析工具、基本分析模型、商品價格波動特性及週期或是其他邏輯思考訊息等，化作程式碼產生一個交易模型，做為研判趨勢以及進出場的依據。交易者只要依其訊號進行買進或是賣出的動作，而不以自身的看法進行操作，因此排除投資人因為盤勢所產生的情緒化反應，而做出不合理的追高殺低動作，另外也可透過一致化的交

易規則，免除不必要的操作，是以電腦下單逐漸取代了以往的人為敲單，因此不論在國內外，程式交易所占的比重也越來越高，越來越受到重視。

由於近年來投資活動蓬勃發展，各種新的技術分析方法或指標不斷的被提出並被廣泛地使用，投資人若是只使用一種技術分析方法，勢必無法準確地預測各市場之趨勢，但若同時使用多項技術分析方法，則在各技術分析方法所顯示的買賣訊號相互矛盾時，投資人又將遭遇盲點而不知所措。同時，技術指標間的結合往往不是一加一等於二的簡單呈現，有些確實可能能夠相輔相成，但是時常也會有互扯後腿的狀況，因此如何整合多項技術指標訊息，也成為本技術領域所迫切面臨之課題，亦即是許多投資者所關切的重點。

【發明內容】

習知交易模型多為選擇一到兩個技術指標，在使用市場常用的參數之後便作為交易訊號之參考，但因參數後續調整不便以及少數參考指標所造成的偏頗，將此作為市場買賣之依據很容易導致資金上的損失。有鑑於此，本發明之一範疇在於提供一種多指標選擇權交易模型產生方法。本發明係與一種運用人工智慧技術，來建立多指標選擇權交易模型的交易模型產生器有關，因其具有多指標、多模型的特性，因此也能夠配合選擇權常用的複式交易策略。更明確地說，本發明從指標開始往上建構，指標到模型，模型再到最終交易模型，過程中利用各種人工智慧技術搭配，以完成一個不論在穩定度、可信度以及適應度各方面，皆能有不錯表現且適用於選擇權市場的交易模型，其中人工智慧技術包括了類神經網路、基因演算法、灰色

關聯度分析。

本發明之主要目的為利用人工智慧技術，來提供投資者能夠在選擇權市場擁有一個作為買賣參考的程式交易模型，而不用再隨波逐流或是舉棋不定並造成損失，進而幫助投資大眾增加獲利，打敗市場。

本發明之次一目的為提供學術上各種技術進入交易市場的一個應用方式，以達到學術與實際應用能夠相輔相成之結果。

根據一具體實施例，本發明之一種多指標選擇權交易模型產生方法，包含有以下步驟：步驟(S1)收集股票市場的不同類股之數個技術指標，每一技術指標均具有日期參數；步驟(S2)建立儲存該等數個技術指標之一指標集；步驟(S3)利用類神經網路來將該等數個技術指標加以辨識及分類；步驟(S4)隨機挑選出數個交易模型，其中每一交易模型內的技術指標不能屬於同一分類；步驟(S5)決定每一技術指標之該日期參數；步驟(S6)踢除部分該等數個交易模型；步驟(S7)自另一部份的該等數個交易模型挑選中數個最終交易模型；以及步驟(S8)決定每一最終交易模型的權重。

關於本發明之優點與精神可以藉由以下的發明詳述及所附圖式得到進一步的瞭解。

【實施方式】

請參考圖一至圖六，本發明首先要做的便是收集股票市場的不同類股之數個技術指標，每一技術指標具有日期參數，如步驟(S1)。

接著，建立一個儲存各式各樣指標的指標集（Indicator pool），如步驟(S2)，此指標集所儲存的數個技術指標，將成為後續建立調整型權重多指標選擇權交易模型的基本元件，因此其之種類與數量自然是越多越好，但是為了平衡其種類分布狀況以避免在基礎模型建立之時，出現模型類型偏重的問題，因此採用了人工智慧技術中的類神經網路這種技術來作為辨識以及分類之目的，如步驟(S3)。在本實施例中，該等數個技術指標包含大盤指數、成交量、融資或融券。當然熟習此技術者當知在其他實施例中，此等數個技術指標也可以包含上櫃指數、成交量、融資或融券。

自從 1943 年 McCulloch 和 Pitts 就提出了基本計算類神經元的運算模式，但此類神經元模式並沒有廣泛地被採用，因為當時的模式沒有學習的能力。直到 1949 年由 Hebb 所提出的學習方式後，才能解釋某些心理學上的實驗結果；也因而其係被稱為 Hebbian 學習法則。此後神經網路係被較成功地應用在實務上，有 Rosenblatt 利用認知器(perceptron)來從事文字辨識的工作，以及 Widrow 與 Hoff 共同提出的適應線性元件(adaptive linear element)，其係被廣泛地應用在適應訊號處理上。本發明所使用到的類神經網路為可以處理連續信號的 ART-2 。 ART-2 為非監督式學習網路(Unsupervised Learning Network)之一種。非監督式的類神經網路在缺乏期望輸出值的情況下，能夠自行發掘出資料中的那些特徵是重要的或是可忽略的，以便將資料作“群聚”(clustering)的處理，其之理論詳述如下：

ART-2 設計的基本思想是採用競爭學習和自穩學習機制。ART-2 系統分為 F1 與 F2 層，F1 層有 W、X、U、V 、

P、Q 及 R 七個子層。當信號 S 從 F1 層輸入，經由 F1 層的處理之後，通過由下往上的連接權重 b_{ij} 的加權組合，以作為 F2 的輸入訊號。當訊號輸入時 F2 層中的各節點之間會相互競爭，並產生優勝單元，之後透過 t_{ji} 再將訊號傳回 F1 層。在 F1 層計算 t_{ji} 與輸入模式的匹配程度並與警戒值進行比較。如果匹配值大於警戒值，則修改 b_{ij} 與 t_{ji} 之權重值；若匹配程度小於警戒值，則向 F2 層發出重置訊號以抑制優勝單元，F2 再重新尋找其他優勝單元；如果 F2 層所有單元都已被抑制，則產生新的處理單元，並設定權值。

本發明經由以下的 ART-2 流程，最後將會得到經過分類的 Classified 指標集：

F1 層之特徵值為：

$$u_i = \frac{v_i}{e + \|V\|} \quad (1)$$

$$w_i = s_i + au_i \quad (2)$$

$$p_i = u_i + dt_{ji} \quad (3)$$

$$x_i = \frac{w_i}{e + \|w\|} \quad (4)$$

$$q_i = \frac{p_i}{e + \|p\|} \quad (5)$$

$$v_i = f(x_i) + bf_x \quad (6)$$

$$f(x) = \begin{cases} x & \text{if } x \geq 0 \\ x & \text{if } x < 0 \end{cases} \quad (7)$$

步驟 1. 參數與權值初始化：a、b、c、d、e、 α 、 ρ

其中 $a = b$ ； c 與 d 須滿足 $\frac{cd}{1-d} \leq 1$ 而 α 為學習率； ρ 為警戒值，權值初始為， $t_{0i} = 0$ ， $b_{i0} = \frac{1}{(1-d)\sqrt{n}}$

，其中 n 為範例之屬性個數。

步驟 2. 每輸入一個指標訓練範例則將步驟 3 至 12 執行數次學習循環。

步驟 3. 更改 F1 層之特徵值： $u_i = 0$; $p_i = 0$; $q_i = 0$;
 $w_i = s_i$; $x_i = \frac{s_i}{e + \|s\|}$; $v_i = f(x_i)$

步驟 4. 再次更改 F1 層之特徵值，計算 (1) 至 (6) 。

步驟 5. 計算 F2 層之特徵值：

$$y_j = \sum b_{ij} p_i \quad (8)$$

步驟 6. 當重置值為真，執行步驟 7 至 8 。

步驟 7. 找出 F2 層中特徵值最大之單元 J 。

步驟 8. 警戒值測試：

計算 (1) 與 (3) 以及

$$r_i = \frac{u_i + cp_i}{e + \|u\| + c\|p\|} \quad (9)$$

若 $\|r\| < p - e$ 則 $y_J = -1$ 且抑制單 J 元，返回步驟 5。

若 $\|r\| \geq p - e$ 則計算 (2) 、 (4) 、 (5) 、 (6) 並繼續執行

步驟 9。

步驟 9. 反覆執行步驟 10 至 12 。

步驟 10. 更改單元 J 之權重值：

$$t_{Ji} = adu_i + [1 + ad(d-1)]t_{Ji} \quad (10)$$

$$b_{iJ} = adu_i + [1 + ad(d-1)]b_{iJ} \quad (11)$$

步驟 11. 更改 F1 層之特徵值，計算 (1) 至 (6) 。

步驟 12. 測試是否達到更改權值之次數。

步驟 13. 測試是否達到學習循環之次數。

經過 ART-2 的分類之後將會產生 Classified 指標集，而在 Classified 指標集裡，本發明更採用了費雪轉換式(Fisher Transform)以作為改善指標性能的方法。高斯機率分布函數 (Gaussian Probability Distribution Function)普遍係被用來模擬股市資料，但事實上股市資料鮮少呈現如圖二的一般分布狀態，這也是許多技術指標無法如預期成功模擬的原因之一。

為了解決此問題，我們使用了收斂型費雪轉換式將各種機率分布曲線轉換為近似高斯分布，其轉換公式如下所示：

$$\text{Inverse Fisher Transform (IFT)} : \quad x = \left[\frac{e^{2y} - 1}{e^{2y} + 1} \right] \quad (12)$$

選擇權買賣價或是各類指標的值在作為輸入的時候，必須先經過正規化至 +1 與 -1 之間，其輸出結果如圖三所示：當輸入值接近平均值的時候，輸出將會趨近於零；反之當輸入值接近極值(+1 或 -1)的時候，輸出將會被大幅強化。如此一來，原本頻繁出現的雜訊將可濾掉，指標的高峰轉折將會成為相對的少數事件，而能將真正的線型轉折處突顯出來，並對於何時買或賣，給予更明確的指示。

完成指標的蒐集、分類以及強化之後，以兩至四個指標為一組，隨機的挑選出來成為數個交易模型，每個模型內的指標不能屬於同一分類，如步驟(S4)。這是因為每個指標都有其表現突出的地方，可能是上漲、下跌或是盤整波段會績效特別

好，然而其在其他區段卻可能是令人失望的。經過分類之後，同一類指標的表現優異與失敗處可能都互相相同，如果再將同種類的指標組成模型，則會侷限於某些區段而不能適應股市瞬息萬變的起伏，且出現重複的相似模型。

接著，步驟(S5)決定每一技術指標之該日期參數。在每個模型中，各指標都有其各自的日期參數，而每個指標在模型中所占的比重，也就是買、賣、平倉或是不動作的決定權強度，係以權重參數來代表，本發明採用了基因演算法來決定這些參數，其之流程圖如圖四所示。將上述所有參數視為一染色體(Chromosome)來表示，而適存性函數(Fitness Function)則以模型經過績效評估之後的總獲利(Total Net Profit, TNP)、勝率(Percent profitable, PP)、獲利因子(Profit Factor, PF)以及在場比率(Duty Ratio, DR)等參數，依照下式作為適存性函數(Fitness Function)：

$$f(x) = \frac{TNP \times PP \times PF}{DR} \quad (13)$$

並依據結果來評估其之適存性。雖然基因演算法只能求出最佳近似解，但實際上我們也不需要真正的最佳解，因為過度的最佳化有可能產生過適(overfitting)現象，且這些參數在本發明之後的過程中將會逐漸減弱它的影響性，所以只需求出最佳近似解即可。

即使採用了基因演算法來求出最佳的參數解，仍可能有些模型的績效就是差強人意，不論這是因為組成的指標之間相性不合或是其他任何原因，這樣的該等數個交易模型部分自然該被剔除，因此需要一個評估過程來決定此階段所產生的模型是

否該被剔除，本發明使用一回測法來決定模型的去留，如步驟(S6)。該方法為設定一個固定長度的 Far-Data 區間以及 Near-Data 區間，Far-Data 區間為過去的歷史時間區間；Near-Data 區間為靠近現在的時間區間，從過去的某一個時間點開始計算 Far-Data 與 Near-Data 區間的績效，隨著時間不斷的前進，Far-Data 以及 Near-Data 區間也會隨著推進直到現在的時間點，每次的 Near-Data 區間與 Far-Data 區間所產生的績效，以式(13)計算出兩個區間各自的得分，並以 Near-Data × 60% + Far-Data × 40%的比率計算出最後得分，當某一模型處於後 20%一段時間之後便將之淘汰，整體流程如圖五所示：

在建立了一定數量的模型之後，同樣的也必須避免產生同質性太高的模型，但事實上各個優良模型之間，因為大部分該賺錢、該賠錢的地方都會重覆到，所以在經過基因演算法的最佳化以及回測評估之後，數個模型都會有一定程度上的相似，因此本發明採用灰色系統理論中的灰關聯分析，來挑選自另一部份該等數個交易模型挑選數個最終交易模型，如步驟(S7)，因此組成最終交易模型的模型。

在灰關聯分析中，灰關聯度定義為兩個序列間的關聯程度。在計算灰關聯度時，如果只選取一個序列 $x_0(k)$ 做為參考序列時，稱之為『局部性(Localized)灰關聯測度』。如果所有的序列中，任一序列 $x_i(k)$ 均可為參考序列時，則稱之為『整體性(Globalized)灰關聯測度』。在本實施例中，該灰色關聯分析係基於數列間距離之灰色關聯度、數列間斜率之灰色關聯度、數列間面積之灰色關聯度或其結合之灰色關聯度。

由於本發明是以某個模型的歷史已實現與未實現獲利曲線，做為參考序列來對其他模型作關聯度計算，故其將使用「局

部性灰關聯測度」方法來計算二者之間的關聯度。

首先計 $x_i(k)$ 算和 $x_0(k)$ 兩點之間的絕對距離 $\Delta_{0,i}(k)$ ，其中 $i = 1, \dots, m$. $k = 1, \dots, n \in N$ ，然後求出比較序列 x_i 對參考序列 x_0 在所有點 k 的距離灰關聯係數(Distance Grey Relational Coefficient) $\xi_{0,i}(k)$ ，最後再根據平均法求出序列 x_i 對序列 x_0 之距離灰色關聯度 $\gamma^{0,i}$ 。

$$\xi_{0,i}(k) = \frac{\Delta_{\min} + \zeta \Delta_{\max}}{\Delta_{0,i}(k) + \zeta \Delta_{\max}} \quad (14)$$

$$\gamma^{0,i} = \gamma(x_0, x_i) = \frac{1}{n} \sum_{k=1}^n \xi_{0,i}(k) \quad (15)$$

其中

$$\Delta_{0,i}(k) = |x_0(k) - x_i(k)| \quad (16)$$

$$\Delta_{\max} = \max_i \max_k \Delta_{0,i}(k) \quad (17)$$

$$\Delta_{\min} = \min_i \min_k \Delta_{0,i}(k) \quad (18)$$

$$i = 1, 2, \dots, m \quad k = 1, 2, \dots, n$$

其之流程圖係如圖六所示。灰色關聯係數 ξ 是介於 0~1 之間的實數。將每個模型對其它模型的已實現與未實現獲利曲線的兩個灰關聯度加總可以得到 $\gamma_{sum}(j)$ ， $j = 1, 2, \dots, m$ ，最後選出適當數量的前幾個 γ_{sum} 值最小的模型來組成最終交易模型。

當使用多模型也就是更多的指標來作決策的時候，少數服從數個並不是一個很好的方法，因為在瞬息萬變的股票市場中，每個模型都有自己所擅長的區段，單純的投票系統無法將個別的特性展現出來，因此本發明採用了權重投票系統來解決此問題。所謂的權重投票系統即組成最終交易模型的每個模

型，對於買賣的投票方式將不再是簡單的投買、賣或平倉一票 — 即齊頭式的平等，而是加上根據此模型到目前為止的表現而換算出的投票份量，表現好的模型自然擁有更高的決定權，但是相對的也需考慮到這樣的機制最後可能產生「一模獨大」的情形，因此本發明採用漢明距離(Hamming distance)來決定每一最終交易模型的權重，如步驟(S8)。

令論域為 U , $U(k) = \{u_1(k), u_2(k), u_3(k)\}, k = 1, 2, \dots, \mu$, u_1 代表各個模型當日累計勝率的集合； u_2 代表當日累計獲利點數； u_3 代表當日累計連續勝負次數。當日累計獲利點數以及當日累計連續勝負次數都需先正規化至 0 與 1 之間，其式如下：

$$u_2(k) = \frac{u_2(k)}{\max[u_2(k)]}, k = 1, 2, \dots, \mu \quad (19)$$

$$u_3(k) = \frac{ConL(k)}{ConW(k) \times \lambda}, k = 1, 2, \dots, \mu \quad (20)$$

此處 $ConL(k)$ 代表當日累計連輸次數； $ConW(k)$ 代表當日累計連贏次數，每一次成功(賺錢)的交易將會使當日累計連贏次數加 1 ，反之亦然； μ 代表模型的數量； λ 為一個調整參數，目的為使 $u_3(k)$ 的數值保持在 0 與 1 之間。

很清楚的，累計勝率與累計獲利點數都是越高越好，因此為了避免「一模獨大」的情況，而加入了累計連續勝負次數的考量，由 (20) 可以看出當一個模型累計連贏次數越來越高時，反而會使其權重逐漸下降；同時再加入一個計數器去紀錄每個模型的累計連續獲得最大權重的次數，只要超過一定的閾值便將其權重降低。事實上累計連續勝負次數以及累計連續獲得最大權重次數的設計，也代表一個模型不可能在千變萬化的市場中永遠是贏家。

假設最佳的模糊集 $A = \frac{1}{u_1} + \frac{1}{u_2} + \frac{1}{u_3}$ ，則每日 $U(k)$ 與 A 的漢明

距離即為每個模型的每日權重，接著將此權重乘上其所屬模型的當日操作訊號(買、賣或平倉)，再進行加總，所得的加總值即為最終交易模型當日的原始操作訊號，最後再以下列方式作出買賣判斷。

$$\text{買點} : \Sigma \geq \mu \times \sigma_{(Buy)}$$

$$\text{賣點} : \Sigma \geq -\mu \times \sigma_{(Sell)}$$

平倉或等待：其它

此處 Σ 為最終交易模型當日的原始操作訊號； μ 代表模型的數量； $\sigma_{(Buy)}$ 及 $\sigma_{(Sell)}$ 為門檻調整參數，可以決定最終交易模型對於買賣的敏感度。

藉由以上較佳具體實施例之詳述，係希望能更加清楚描述本發明之特徵與精神，而並非以上述所揭露的較佳具體實施例來對本發明之範疇加以限制。相反地，其目的是希望能涵蓋各種改變及具相等性的安排於本發明所欲申請之專利範圍的範疇內。因此，本發明所申請之專利範圍的範疇應根據上述的說明作最寬廣的解釋，以致使使其涵蓋所有可能的改變以及具相等性的安排。

【圖式簡單說明】

圖一繪示根據本發明之較佳具體實施例之流程圖。

圖二繪示一般高斯機率分布圖。

圖三繪示正規化後之近似高斯分布圖。

圖四繪示基因演算法之流程圖。

圖五繪示整體流程圖。

圖六繪示灰關聯分析流程圖。

【主要元件符號說明】

(S1)~(S8)：步驟

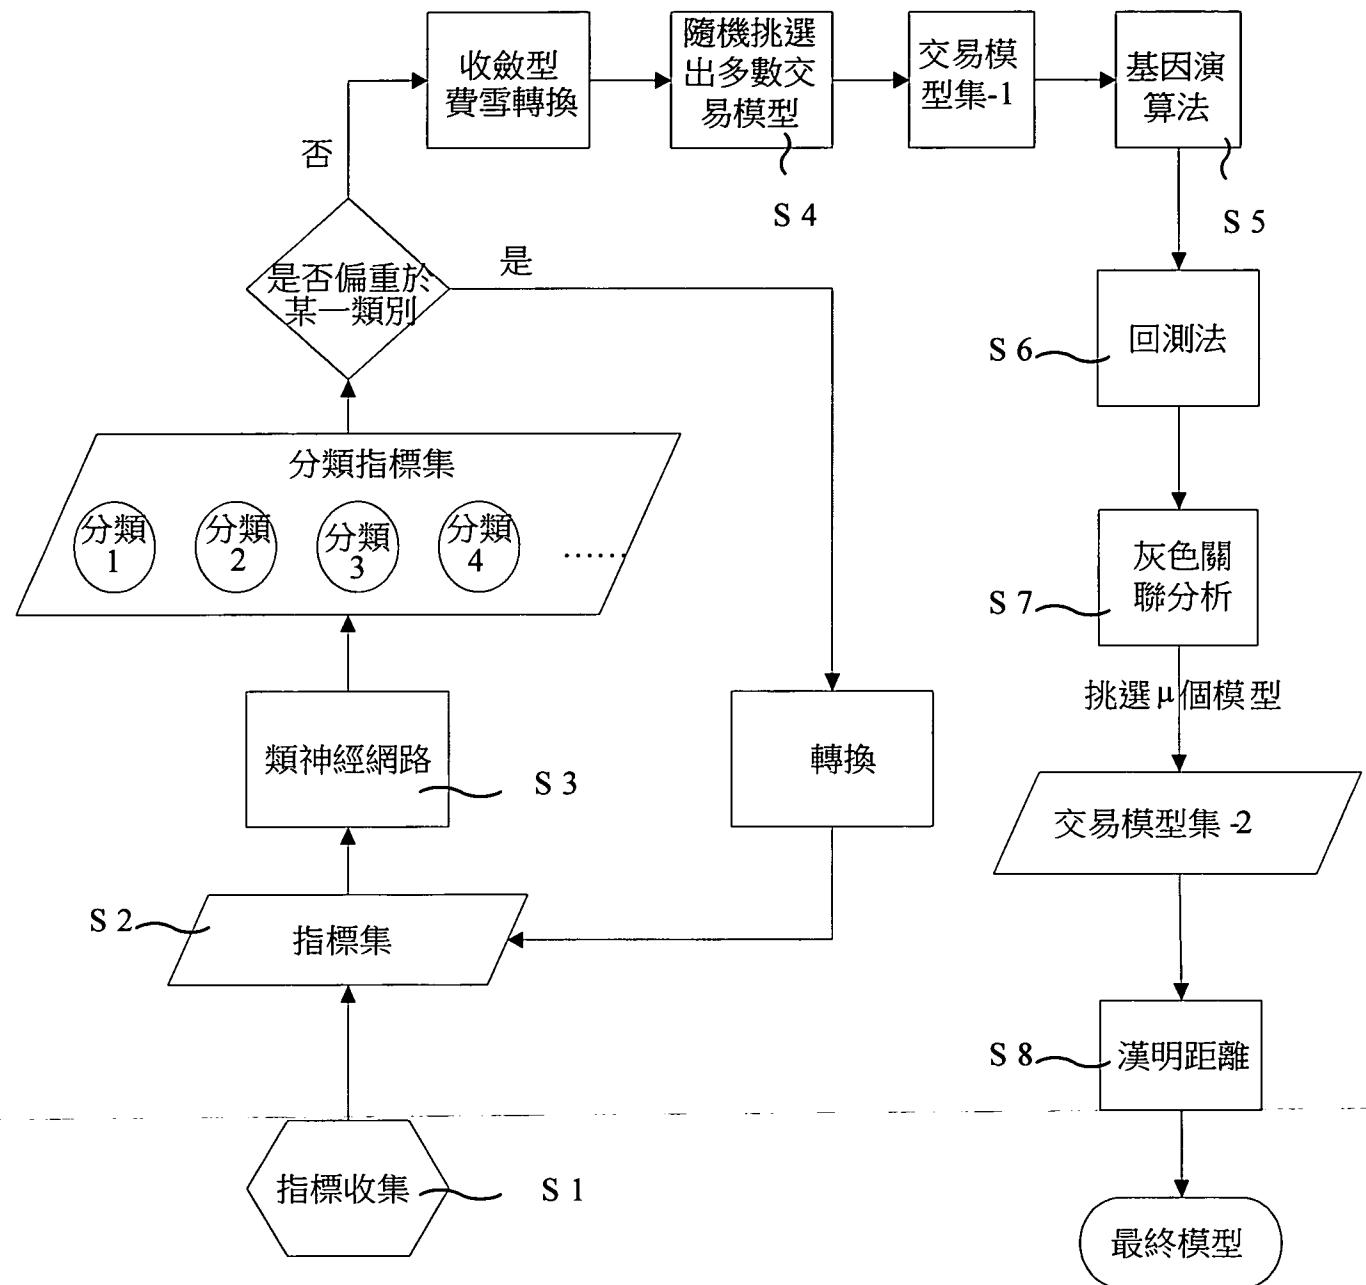
Far-Data：歷史的時間區間

Near-Data：現在的時間區間

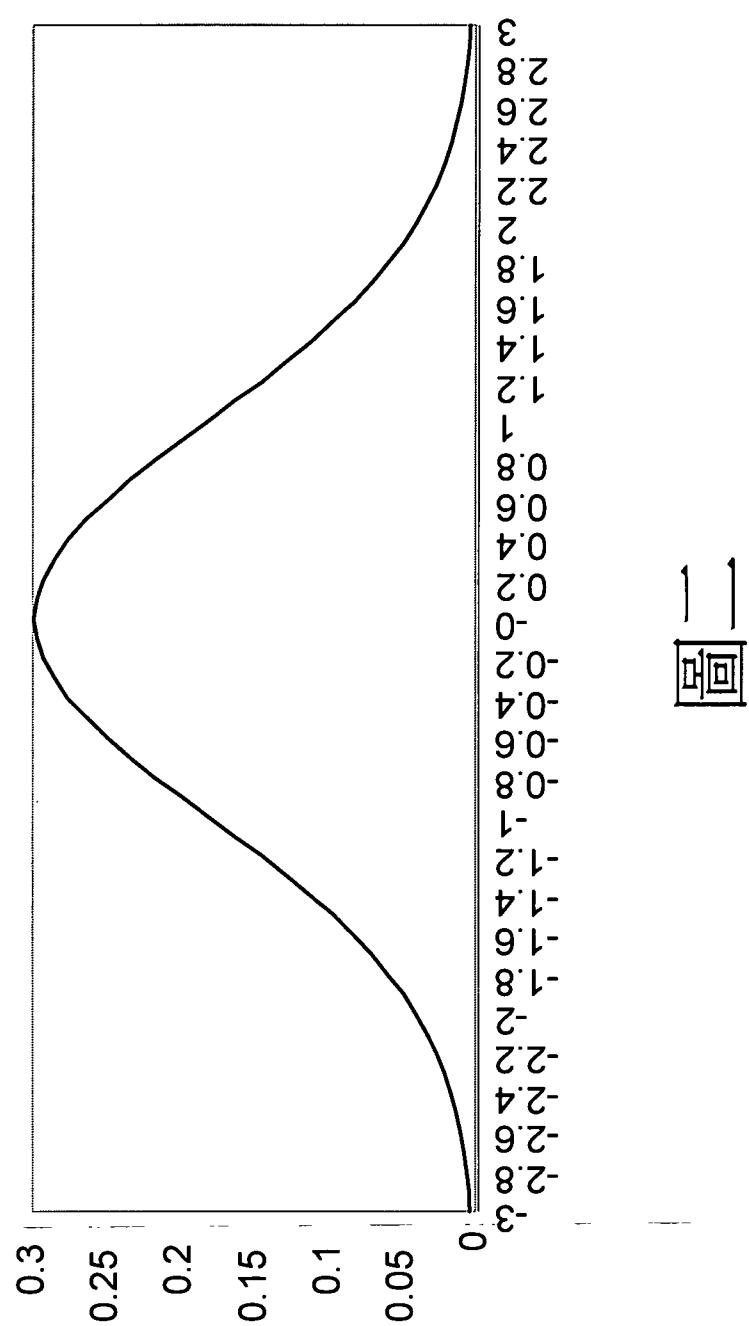
七、申請專利範圍：

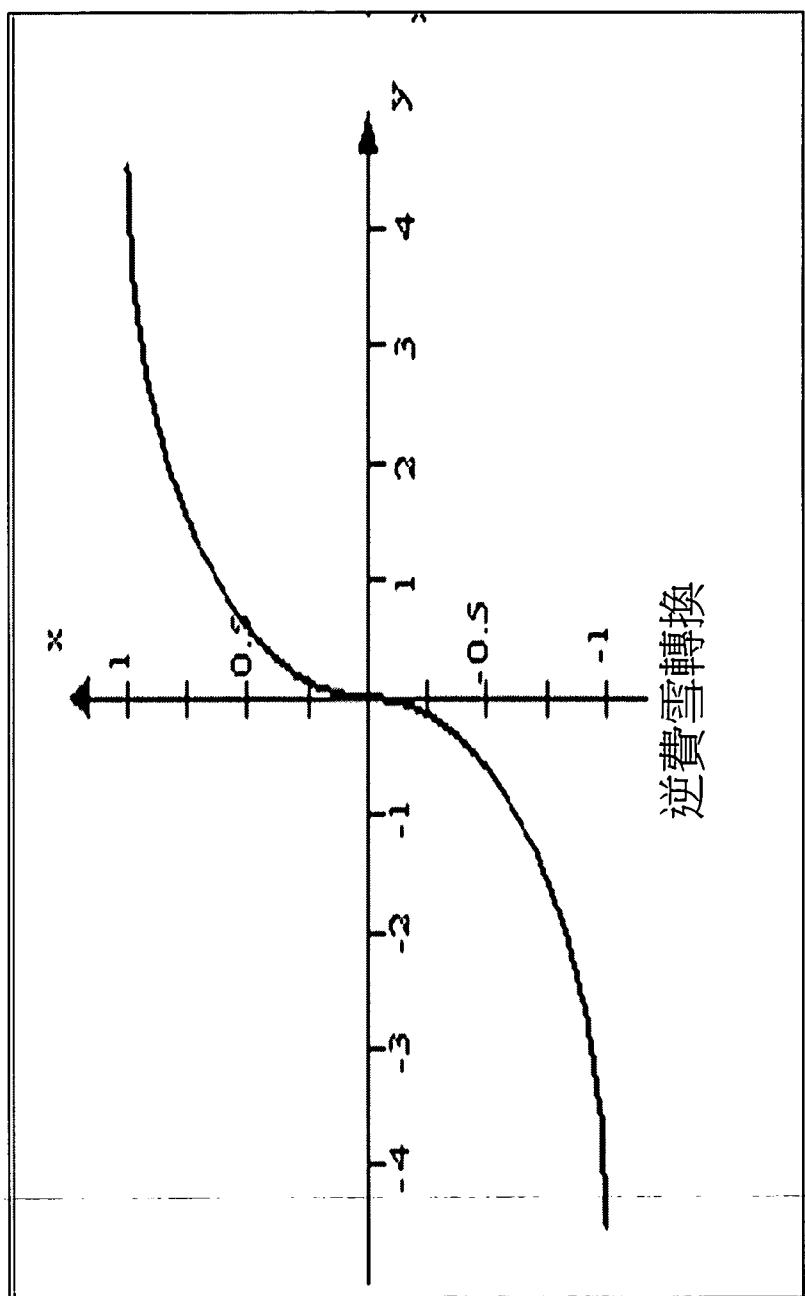
1. 一種多指標選擇權交易模型產生方法，包含有以下步驟：
 - (S1) 收集股票市場的複數個技術指標；
 - (S3) 利用一ART-2類神經網路演算法來辨識及分類該複數個技術指標；
 - (S4) 隨機地自該複數個技術指標中挑選出複數個技術指標來組成複數個交易模型，每個該交易模型包含有複數個技術指標，每個該交易模型所包含之該複數個技術指標所屬之分類均為相異；
 - (S5) 利用基因演算法以一預設之適存性函數來計算該複數技術指標之一日期參數及一權重參數，該權重參數係指該複數個技術指標在該交易模型中所占的比重；
 - (S6) 利用一回測法，根據該複數個交易模型之歷史績效剔除部份之該複數個交易模型；
 - (S7) 利用一灰關聯分析法分析各個未被剔除之該複數個交易模型，並根據該複數個交易模型之一獲利曲線之間的關連性來選擇複數個最終交易模型；以及
 - (S8) 根據該複數個最終交易模型之一累計勝率來決定每一最終交易模型的權重以組成該多指標選擇權交易模型。
2. 如申請專利範圍第1項所述之多指標選擇權交易模型產生方法，其中該類神經網路係為非監督式學習網路。
3. 如申請專利範圍第1項所述之多指標選擇權交易模型產生方法，其中該等數個技術指標係包含大盤指數、成交量、融資及融券之一者或其組合。
4. 如申請專利範圍第1項所述之多指標選擇權交易模型產生方法，其中該等數個技術指標係包含上櫃指數、成交量、融資及融券之一者或其組合。

5. 如申請專利範圍第1至4項中任一項所述之多指標選擇權交易模型產生方法，其中該(S8)步驟係利用漢明距離來決定每一最終交易模型的權重。
6. 如申請專利範圍第1項所述之多指標選擇權交易模型產生方法，其中該灰色關聯分析係基於數列間距離之灰色關聯度、數列間斜率之灰色關聯度、數列間面積之灰色關聯度或其結合之灰色關聯度來進行。
7. 如申請專利範圍第1至4項中任一項所述之多指標選擇權交易模型產生方法，其中該權重乘上每一最終交易模型的當日操作訊號，再進行加總所得總值，即為當日的原始操作訊號。

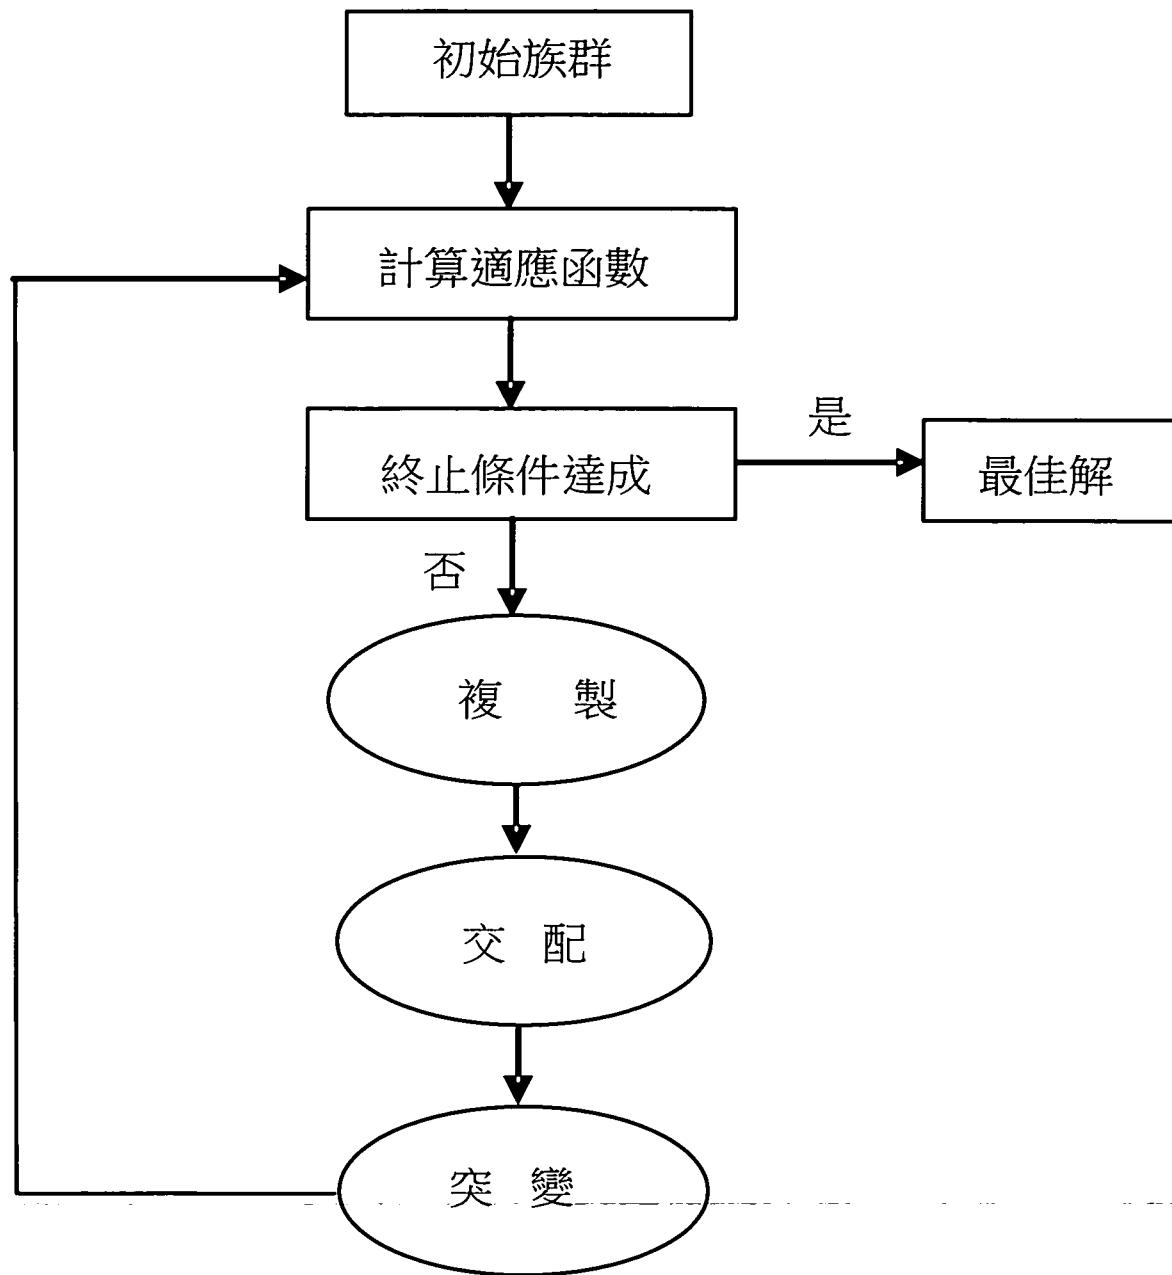


圖一

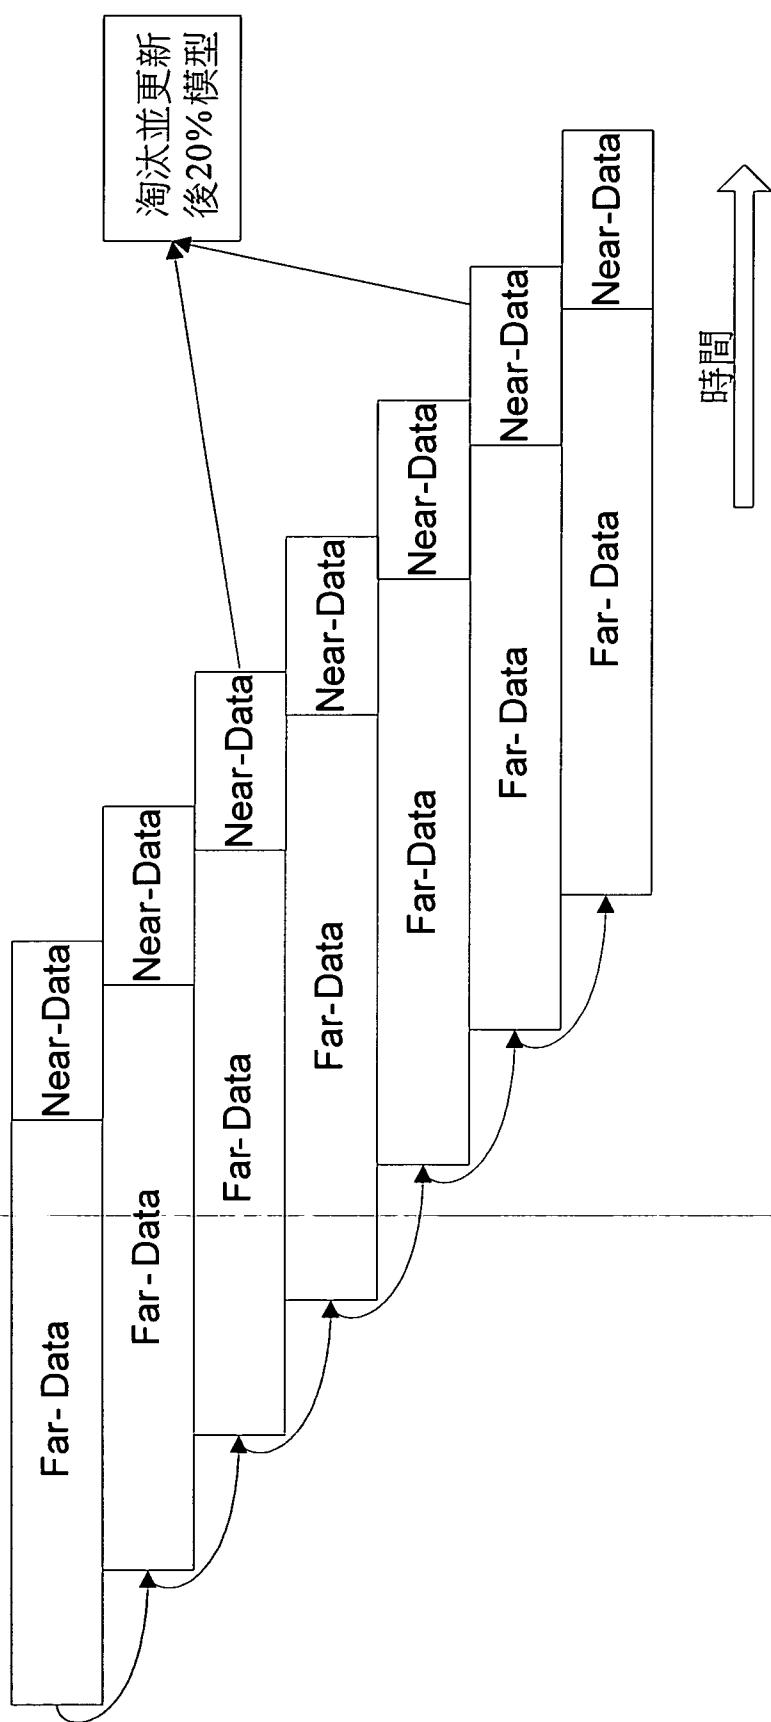




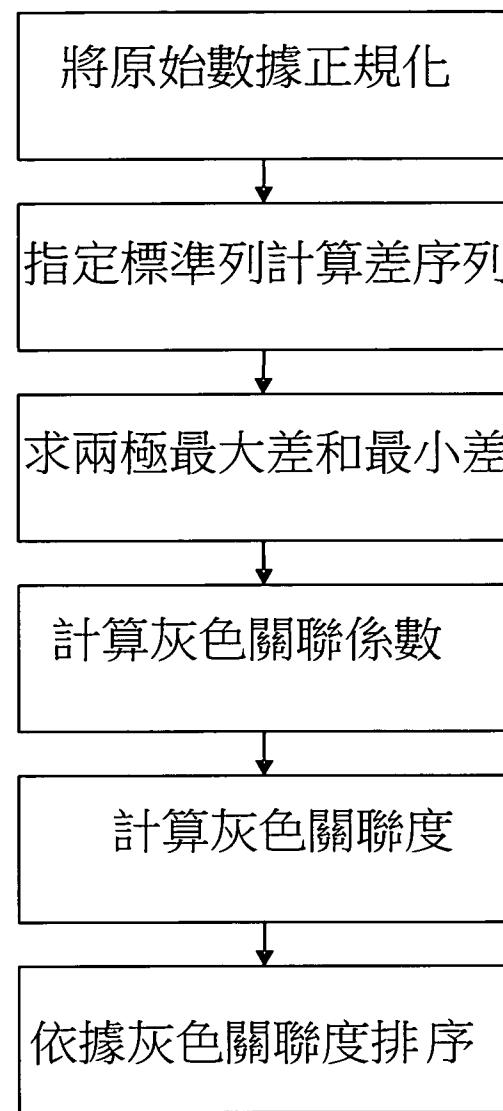
圖二



圖四



圖五



圖六