

適應式影像還原—以計算智慧為方法

李俊賢*

國立中央大學資訊管理學系

陳玟玢

國立中央大學資訊管理學系

摘要

影像訊號進行傳輸或轉換的過程中經常會受到其它訊號的干擾，導致影像失真之情形發生。為解決此問題，本研究針對灰階影像失真之問題提出一計算智慧之方法，以 Takagi-Sugeno 類神經模糊系統為架構，結合粒子群最佳化演算法 (PSO) 與遞迴最小平方估計法 (RLSE) 建構出複合學習演算法，並且應用於適應性雜訊消除的問題，最終目標在於使受干擾之影像能夠儘量還原接近原始影像。此外，本研究中亦針對類神經模糊系統之模糊規則數目之增減對於系統效能是否有顯著的影響作探討。本研究以灰階影像的雜訊消除進行實驗，將所提出的複合學習演算法與標準的粒子群演算法進行比較，實驗結果顯示本研究所提出之方法優於標準的粒子群演算法。

關鍵詞：類神經模糊系統 (NFS)、粒子群演算法 (PSO)、遞迴最小平方估計法 (RLSE)、雜訊消除、計算智慧

* 本文通訊作者。電子郵件信箱：jamesli@mgt.ncu.edu.tw
2010/03/22 投稿；2011/11/30 修訂；2012/01/16 接受

Adaptive Image Restoration — A Computational Intelligence Approach

Chunshien Li*

Department of Information Management, National Central University

Wen-Wen Chen

Department of Information Management, National Central University

Abstract

Image signal may be interfered by some unknown mechanisms during transmission or transformation, resulting in image corruption that useful information or details in the image can be lost more or less. In the paper, we propose a computational intelligence approach with the famous adaptive noise canceling framework to the problem of gray-level image restoration. The approach is based on the theory of Takagi-Sugeno neuro-fuzzy system (NFS) and the proposed PSO-RLSE hybrid learning method which includes the famous particle swarm optimization (PSO) and the well-known recursive least squares estimator (RLSE) algorithm. With the NFS-based image restoration system, the research target is to restore gray-level images from their corrupted versions as possible as can be. In the study, we investigated different sizes of rule base to see the influence by the amount of fuzzy If-Then rules to the restoration performance, and we also compared the proposed PSO-RLSE learning method to the PSO learning method for restoration performance. Several results are shown in the paper. Through the experimental results, the proposed PSO-RLSE method outperforms the PSO method, in terms of restoration performance and learning convergence.

Keywords: Neuro-fuzzy system (NFS), Particle swarm optimization (PSO), Recursive least squares estimator (RLSE), Noise canceling, Computational intelligence

* Corresponding author. Email: jamesli@mgt.ncu.edu.tw
2010/03/22 received; 2011/11/30 revised; 2012/01/16 accepted

壹、研究背景

科技的發展使得人們對資訊的需求日益漸增，資訊之間的傳遞與交換已經變得非常頻繁。資訊流通的方式會根據使用者的需求及應用的領域而有不同，大約可分為有線通訊、無線通訊與混合式通訊等機制。近年來隨著資訊交流活動的大幅增加，資料、聲音、影像與視訊等訊號在商業活動與資訊管理環境中流通量日益增加。資訊訊號進入通訊環境就有可能受到雜訊污染，使得接收方接受到污染的或不正確的資訊。當資訊訊號經由不同的流通模式進行，其受到許多因素干擾乃屬必然之事，尤其，現今無線通訊技術的快速發展及應用普及，更是如此。本論文所發展之適應式技術具有多種商業運用價值之潛能，例如，手機通訊，心電圖訊號，腦波訊號，胎兒產檢訊號，礦物探測，衛星通訊，移動載具間之通訊，演講或演唱訊號，飛航塔台通訊，醫學影像，超音波影像等等。以手機通訊為例，資訊訊號曝露在基地台的電子電路及大氣的環境中；當訊號在這樣的電氣環境及無線環境中流動時，各種動態侵擾因子自難免之，例如，訊號會因為通訊媒介而造成訊號的衰減；通訊設備在使用時所產生的熱噪與雜訊；通訊的過程中訊號受到其它電子訊號或是電磁波之干擾；大氣背景輻射之干擾；水氣之干擾等，使得訊號在流通過程中產生訊號污損的情況。隨著科技的積極發展，愈來愈多資訊之間的交換是透過此種相關方式來進行，因此，資訊訊號受到干擾的情況將更加普遍。有鑑於此，如何在許多雜訊干擾的環境中對失真的訊號進行雜訊之清除或訊號復原，在資訊交換日增的資訊管理與商業活動環境中有其研究探討之必要。

雖然資訊的快速且大量流動已是現代科技高度發展的資訊社會上常見的運作方式，但是資訊在流通過程中遭受到各種非固定形式的雜訊干擾造成資訊失真之情況會引起通訊率下降及資訊失誤等問題而延誤商機。因此，在解決非固定性雜訊的相關研究中，其研究的方向主要是著重於濾波器的設計及參數設定與調整，雜訊消除的方式是透過機器學習調整相關的參數以達成雜訊消除之目的（Mastin 1985; Jin et al. 2003; Afonso & Joshi 2005）。在濾波器中的參數調整，常會因面對不同的雜訊而有所彈性改變。自從 1965 年 Zadeh 提出模糊理論發展至今，相關之研究應用已十分多元化，舉凡企業應用、工業控制、消費產品等都可窺見其蹤影。本研究將以 Takagi-Sugeno 型態之模糊系統（Zadeh 1973; Takagi & Sugeno 1983; 1985）結合類神經網路建構出類神經模糊系統（Jang et al. 1996）之架構，並運用模糊邏輯推理程序以達到智慧型處理之效果（Chen 2006; Lee 1990）。目前文獻中關於類神經網路及模糊系統最常使用的機器學習方法可以分為 gradient-based 與 gradient-free 兩種方式，前者以回傳法（backpropagation）為主，後者以基因演算法等隨機性最佳化方法較為普遍。回傳法會受到初始條件的影響且比較

容易落入局部最佳解；基因演算法雖然可以取得全域最佳解，但其計算量龐大且需要其基因池中有足夠的基因多樣性，否則容易陷入局部最佳解。在本研究中，我們利用粒子群最佳化演算法（particle swarm optimization; PSO）（Kennedy & Eberhart 1995; Shi & Eberhart 1998; Duan et al. 2006; Kennedy 2007）進行系統的自我學習。基因演算法必須透過選擇、交配、取代與突變，而 PSO 搜尋最佳解是以粒子群之個別搜尋及群體合作搜尋之方式尋找最佳解，在運算的複雜度上大幅降低。透過 PSO 的最佳化能力使得類神經模糊系統成為擁有自我學習能力的智慧型系統。當系統中的參數經由不斷的學習與調整後，其影像適應性雜訊消除將符合期待的效果，並且減少還原後之影像較原始影像之灰階或深或淺的情形發生。換言之，本論文提出之方法將復原影像的灰階值控制在與原圖較接近的範圍之內（Lee et al. 1997）。然而，當系統面對非線性的問題時，較難達到應有預期的效果。當 PSO 面臨求解問題的維度過大時，會發生求解效果無法滿足預期、計算時間過長或是收斂過於緩慢之情況。為解決上述問題，本研究加入遞迴最小平方估計法（recursive least squares estimator; RLSE）（Astrom & Wittenmark 1984; Goodwin & Sin 1984; Strobach 1990）形成複合學習演算法（Jang 1991; 1993）作為效能提昇之方法，利用 PSO 與 RLSE 結合的複合學習演算法訓練類神經模糊系統，並在經過函數求解模擬測試過之後，將此複合學習架構應於用於影像之適應性雜訊消除。

本文之架構敘述如下，第貳節說明本研究的理論與演算法；第參節說明實驗設計及實驗結果；第肆節針對實驗結果進行討論；第伍節為本論文之結論。

貳、研究理論與方法

一、理論基礎

（一）模糊集合（fuzzy set）

在傳統集合中，只具有「屬於」或「不屬於」這兩種關係，如同電腦世界裡「0」與「1」的二元概念，但此種描述方法並不適合真實世界的狀況。舉例來說，現在有「冷」和「熱」兩種集合，而溫度就是裡面的元素，如果使用傳統集合的概念，就會出現攝氏25度屬於「冷」，但攝氏26度馬上變成屬於「熱」的情況出現；然而對於人的感受來說，冷和熱的界線是漸近的，因此這種方法並不符合現實情形。導入模糊集合（fuzzy set）的概念（Takagi & Sugeno 1985; Zadeh 1965）之後，即可改變此情形。相對於傳統集合，模糊集合（簡稱為模糊集）最大的不同就是允許元素和模糊集之間的關係擁有不同歸屬程度，透過「歸屬度」的概念來判斷元素屬於模糊集的程度多寡。以上述例子為例，攝氏25度可能在「冷」的模糊集中歸屬度為0.6，在「熱」的模糊集中歸屬度為0.4，經過相關計

算，即可得出攝氏25度屬於哪個模糊集。模糊理論自從1960年代Zadeh提出發展至今，其應用已擴展到許多層面，影像處理亦是其中之一（Lee et al. 1997; Kuo et al. 2000）。模糊推論系統使用IF-Then規則的形式，對於不同的狀況進行分析與決策，但其效能的優劣深受系統之自由參數（free parameters）的影響。一個模糊邏輯系統大致上可分為模糊化介面（fuzzification interface）、知識庫（knowledge base）、模糊推論（fuzzy inference）、解模糊化介面（defuzzification interface）等四大部分，模糊推論系統基本架構如圖1。

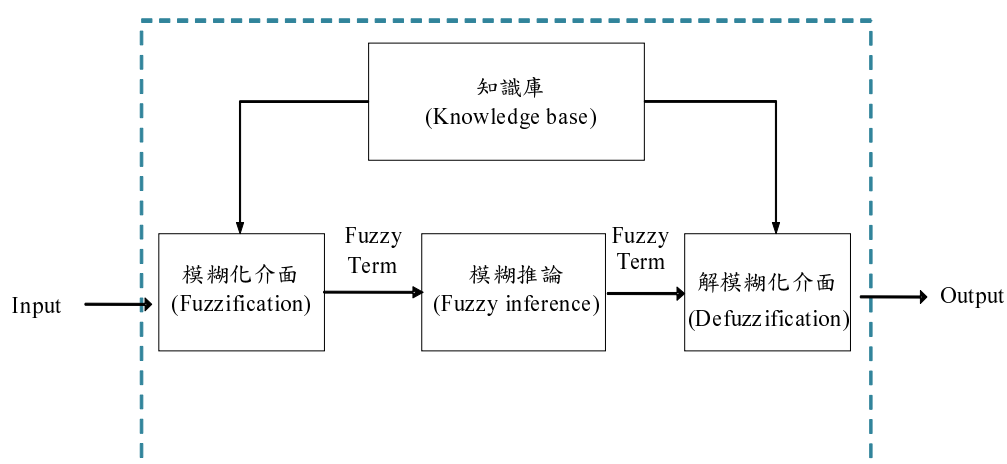


圖 1：模糊推論系統基本架構圖

（二）模糊系統運作流程

1. 模糊化介面（fuzzification interface）：模糊化介面會將輸入的變數進行對應，且轉化成模糊描述之方式。
2. 知識庫（knowledge base）：知識庫包含資料庫（data base）和模糊規則庫（fuzzy rule base）。資料庫提供系統所需的資料與法則定義，讓模糊規則和模糊資料可以具體化。在模糊規則庫中，則定義多條的模糊規則作為決策使用。
3. 模糊推論（fuzzy inference）：決策邏輯為整個模糊系統的核心所在，具有模擬人類決策的能力，經由推論過程作出適當的決策。
4. 解模糊化介面（defuzzification interface）：與模糊化介面的運作相反，它是將輸出轉換到其相對應的論域，並由推論出來的結果產生實際的輸出數值。

(三) 類神經模糊系統 (neuro-fuzzy system; NFS)

本研究以模糊理論為基礎，建置一個類神經模糊系統 (neuro-fuzzy system; NFS) 用於影像雜訊消除之問題，NFS 結合模糊推論系統與類神經網路 (Jang et al. 1996; Watrous 1991) 兩者的優點。類神經網路 (NN) 雖具有自我學習 (self-learning) 能力，但卻無法像模糊推論系統有透明決策過程而導致不易了解其運作意涵。因此，結合兩者不僅可進行模糊推論也可具有自我學習能力，使類神經模糊系統能夠經過學習的過程取得更好的參數配置。模糊類神經系統使用多條 IF-Then 規則來進行推論，其架構可以分為模糊集層、規則層、正規化層、規則結論層、與輸出層。

假設此 NFS 系統有 K 條 Takagi-Sugeno (T-S) 類型之模糊規則，而每一條 T-S 模糊規則可以表示如下：

$$R^i: \text{IF } x_1 \text{ is } A_1^i(h_1) \text{ and } \dots \text{ and } x_M \text{ is } A_M^i(h_M) \\ \text{THEN } h_y^i = a_0^i + a_1^i h_1 + a_2^i h_2 + \dots + a_M^i h_M \quad (1)$$

$i=1,2,\dots,K$, 其中 (x_j, h_j) 為第 j 個輸入語意變數 (linguistic variable) 及其數值變數 (base variable); A_j^i 為第 i 條規則之第 j 個模糊集; $\{a_k^i, k = 0, 1, 2, \dots, M\}$ 表示第 i 條規則之後鑑部參數 (consequent parameters); h_y^i 為第 i 條規則之公稱輸出 (nominal output)。類神經模糊系統之架構表示於圖 2。

本研究將以高斯歸屬函數 (gaussian membership function) 設計模糊集，定義如下：

$$\text{gaussian}(h, c, s) = e^{-\frac{(h-c)^2}{2s^2}} \quad (2)$$

其中 h 為輸入數值變數 (input base variable), s 為高斯歸屬函數的延展度 (spread), c 為高斯歸屬函數之中心位置 (mean)。圖 3 為高斯歸屬函數示意圖。以下分別說明類神經模糊推論系統中各層之計算：

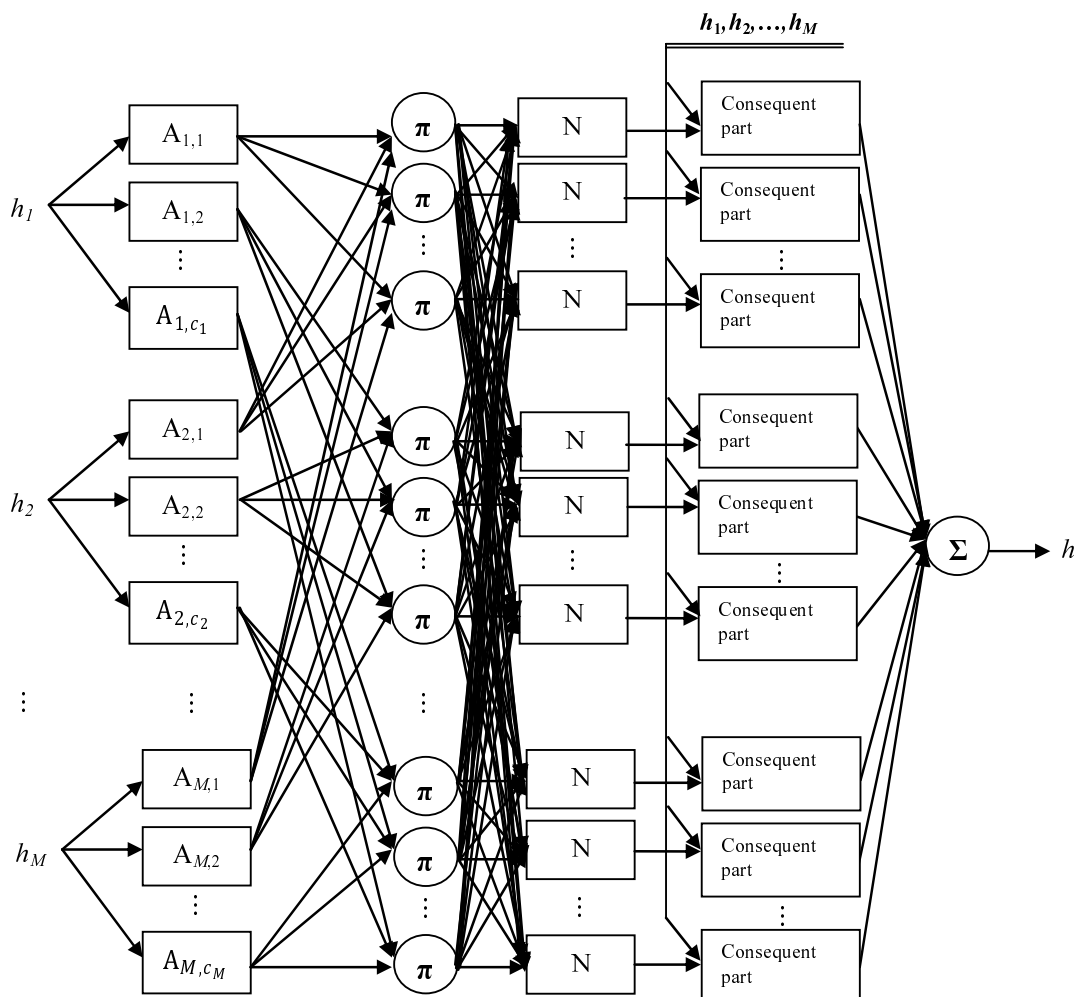
1. 第一層：模糊集層

該層負責計算輸入 $\{h_j, j = 1, 2, \dots, M\}$ 於各個模糊集的歸屬程度，定義如下：

$$\mu_j^i(h_j) = \text{第 } j \text{ 個輸入於第 } i \text{ 條規則的第 } j \text{ 個模糊集之歸屬程度} \quad (3)$$

2. 第二層：規則層

第二層稱為規則層，將各個輸入與需要對應的模糊集進行分配以產生模糊規則，每一條規則都有一啟動強度 (firing strength)，啟動強度是由第一層



$A_{j,k}$ 代表第 j 個 input 之第 k 個模糊集； π 代表相乘積之運算； N 代表正規化之運算； Σ 代表總和之運算。

圖 2：類神經模糊系統運作圖

各個對應模糊集的歸屬程度計算而來。假設在時間 t 時，輸入為 $\{h_j(t), j = 1, 2, \dots, M\}$ ，每一條模糊規則之啟動強度計算如下：

$$\beta^i(t) = \prod_{j=1}^M (\mu_j^i(h_j(t))) \tag{4}$$

$i=1,2,\dots,K$ ，其中 Π 代表 product 之運算 (fuzzy-and 運算)。




圖 3：高斯歸屬函數示意圖

3. 第三層：正規化層

第三層進行模糊規則啟動強度之正規化的工作，計算如下：

$$\lambda^i(t) = \frac{\beta^i(t)}{\sum_{i=1}^K \beta^i(t)} \quad (5)$$

$i=1,2,\dots,K$ 。

4. 第四層：規則結論層

第四層使用第三層所得的結果與後鑑部進行運算，計算每條規則之推論結果，表示如下：

$$\hat{h}_y^i(t) = \lambda^i(t) \times (a_0^i + \sum_{j=1}^M a_j^i h_j(t)) \quad (6)$$

5. 第五層：輸出層

第五層負責將第四層所得結果進行加總並且輸出，加總結果即是此系統的輸出，計算如下：

$$\hat{h}_y(t) = \sum_{i=1}^K \hat{h}_y^i(t) = \sum_{i=1}^K \lambda^i(t) \times (a_0^i + \sum_{j=1}^M a_j^i h_j(t)) \quad (7)$$

上述五層即為 NFS 之架構。為了使 NFS 能夠具有自我調整系統參數之能力，我們提出一複合學習演算法作為參數調整的機制，使 NFS 能夠進行自由參數的調整與更新。

二、複合學習演算法


模糊類神經系統中需要調整的參數數量會隨著模糊規則數量的增加而增加，因此，若只利用粒子群最佳化演算法進行參數的調整，將會使得求解問題的維度過大而降低系統的學習成效，較難達到預期。基於上述問題，本研究以分而擊之（divide-and-conquer）的觀念提出複合式學習方法來進行 NFS 參數的調整與更新。NFS 的自由參數可區分成前鑑部與後鑑部兩組自由參數。前鑑部參數集結每個模糊集的參數，由於本研究中所選擇的模糊集類型為高斯模糊集，因此需要調整的參數為模糊集的中心位置與延展度；後鑑部參數集結每條規則之結論部分中的參數。本研究所提出的複合學習演算法針對前鑑部參數（premise parameters）是利用粒子群最佳化演算法（PSO）進行調整並且計算出每條規則之啟動強度，後鑑部參數（consequent parameters）則利用遞迴最小平方估計法（recursive least squares estimator; RLSE）更新（Li & Chiang 2010）。粒子群最佳化演算法與遞迴最小平方估計法分別說明如下。

（一）粒子群最佳化演算法（particle swarm optimization; PSO）

粒子群最佳化演算法是由學者 Eberhart 與 Kennedy（1995）所提出，此演算法的概念是源自於觀察鳥群覓食的行為得來。鳥群在進行覓食時，除了會受到本身的飛行經驗影響外，同時也受到整個群體的飛行趨勢所影響，藉由本身與群體的飛行經驗能夠帶領鳥群朝向食物方位移動。圖 4 為鳥群搜尋食物時位置移動的飛行示意圖，目標（target）為欲求解問題之最佳解，在粒子群演算法中，每隻鳥可視為一個粒子，粒子的位置則代表目前求解問題之候選解（candidate solution），各個粒子都會藉由移動速度來改變目前位置而逐漸往最佳解方向移動。在每次尋找最佳解的移動過程中，粒子會記錄本身目前最好的解（*Pbest*），且由於粒子亦會也會受到目前群體中的全群最佳解（*Gbest*）影響。所以粒子除了依自身最佳解移動之外，基於考慮到全群最佳解之影響，粒子也會逐漸往最佳解之方向移動。在粒子移動的迭代過程中，粒子會透過適應值（fitness）來評估粒子目前的優劣程度。計算適應值的方式是透過適應值函數（fitness function）求出，適應值函數的設計會根據求解問題類型而有所不同。粒子群演算法由(8)及(9)式表示，PSO 之操作流程於圖 5 說明。

$$\begin{aligned} V_i(k+1) = & w \times V_i(k) + c_1 \times rand_1 \times (Pbest_i(k) - L_i(k)) \\ & + c_2 \times rand_2 \times (Gbest(k) - L_i(k)) \end{aligned} \quad (8)$$

$$L_i(k+1) = L_i(k) + V_i(k+1) \quad (9)$$



左圖為鳥群初始位置，右圖為經過一段時間覓食飛行之後的位置。

圖 4：鳥群粒子移動示意圖

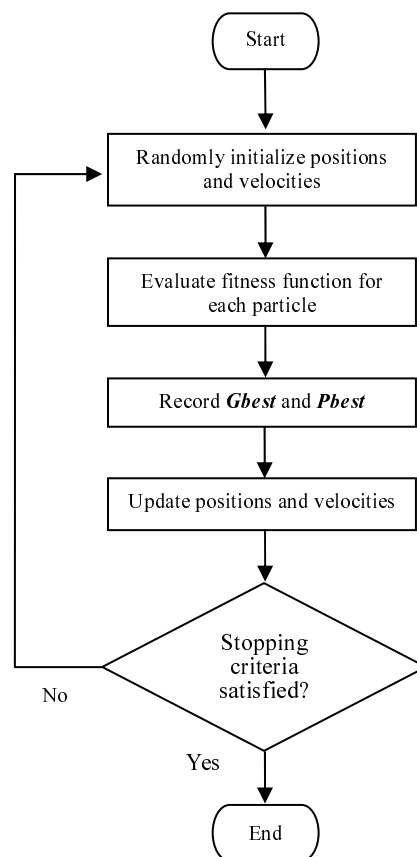


圖 5：粒子群演算法之流程圖

其中

k ：迭代指標 (iteration index)；

$Pbest_i(k)$ ：第 k 次迭代時粒子 i 的最佳解；

$Gbest(k)$ ：第 k 次迭代時所有 $Pbest_i(k)$ 中的最佳解 (整群的最佳解)；

$V_i(k)$ ：第 k 次迭代時粒子 i 的速度；

$L_i(k)$ ：第 k 次迭代時的粒子 i 的位置；

w ：慣性權重；

c_1, c_2 ：加速常數；

$rand_1, rand_2$ ：為 0 至 1 之間的隨機亂數。

(二) 遞迴最小平方估計法 (recursive least squares estimator; RLSE)

遞迴最小平方估計法 (RLSE) 是由最小平方估計法 (least squares estimator; LSE) 衍伸而來。以最小平方估計法之矩陣的型態來表示，模糊系統的第五層可敘述成 $AZ + \varepsilon = B$ 之型態，其中 A 為第三層計算後之結果與輸入變數的乘積， Z 為後鑑部參數向量， ε 為誤差， B 為此線性系統之期望輸出。本研究所設計之類神經模糊系統的輸入變數個數為 2 個，且 NFS 採 T-S 模糊規則設計，因此結論部份的自由參數數量為模糊規則數量的 3 倍。若 NFS 中包含 K 條規則及 Q 筆資料，則 A 為 $Q \times 3K$ 的矩陣， B 為 $Q \times 1$ 之向量， Z 為 $3K \times 1$ 之向量。因此後鑑部自由參數在遞迴最小平方估計法中可用一向量 Z 表示，如下所示：

$$Z = (A^T A)^{-1} A^T B \quad (10)$$

由於矩陣相乘之計算量比較大，且無法確定 $A^T A$ 是否存在可逆矩陣，因此本研究利用遞迴最小平方估計法 (RLSE) 進行計算，其公式為：

$$S_{i+1} = S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}} \quad (11)$$

$$Z_{i+1} = Z_i + S_{i+1} a_{i+1} (y_{i+1}^T - a_{i+1}^T Z_i) \quad (12)$$

$i=0, 1, \dots, Q-1$ ，其中 Q 為訓練資料之數量。 Z_i 為第 i 次之估計結果， y_i 為第 i 個訓練資料之目標值 (target)， a_i 為 A 的第 i 行。初始時，令 Z_0 為一零向量， S_0 為 αI ， α 為極大正值 ($\alpha = 10^9$)， I 為單位矩陣。

三、適應性雜訊消除

本研究的雜訊消除架構 (如圖 6) 是源自於學者 Widrow、Glover 與 McCool (1975) 所提出之適應性雜訊清除 (adaptive noise cancelling; ANC) 概念，利用

ANC 構架結合本研究所提出的 NFS 與 PSO-RLSE 學習演算法進行雜訊之消除。此 ANC 架構假設污染訊號是由原始訊號線性結合攻擊雜訊所產生。雜訊消除概念說明如下，首先 $s(k)$ 代表時間 k 時之原始訊號，原始訊號意指未受任何雜訊污染的訊號，換言之，即為本研究之原始影像； $n(k)$ 為原始雜訊 (original noise)，原始雜訊是未受到任何的轉移函數 (或機制) 轉換的。假設原始雜訊在環境中為高斯隨機分佈，當 $n(k)$ 經過轉移函數 $f(\cdot)$ 轉換之後產生攻擊雜訊 (attacking noise)，記為 $d(k)$ ，攻擊雜訊在訊號傳輸時將會影響原始訊號； $y(k)$ 表示受到攻擊雜訊干擾後的訊號，即為接收者實際接收到的訊號 (已遭到污染的訊號)。基於適應性雜訊清除，本研究利用 PSO-RLSE 複合學習演算法對 NFS 進行訓練以近似雜訊轉移函數，產生模擬攻擊雜訊 (simulated attacking noise)，記為 $d'(k)$ ，接著從受污染影像 $y(k)$ 中將攻擊雜訊 $d(k)$ 清除，得到之訊號 $s'(k)$ 即為復原影像之訊號。我們應該區別原始雜訊 $n(k)$ 及攻擊雜訊 $d(k)$ 之不同，後者經過了雜訊轉移函數的作用。

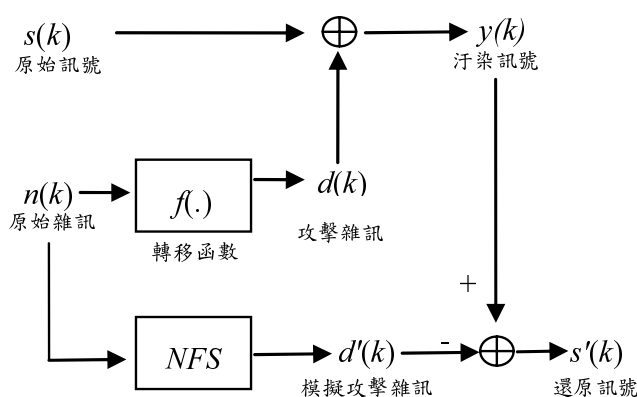


圖 6：雜訊攻擊與清除架構

參、實驗設計與結果

一、系統設計

本研究將以 NFS 與適應性雜訊清除 (ANC) 為架構，並結合 PSO-RLSE 複合學習演算法來調整 NFS 中的系統參數，使 NFS 之輸出能夠逼近真實的攻擊雜訊。在 NFS 設計方面，NFS 之輸入為 t 和 $t+1$ 時間下之原始雜訊，輸出為模擬攻擊雜訊，實驗中影像大小為 280×280 之灰階影像。在理想的狀態下，若將 78400 個像素全部當作系統的訓練資料，則 NFS 系統理論上具有較佳的訓練結果，但由於訓練筆數龐大且計算時間長，因此本研究取影像的前 1000 個像素作為 NFS 訓練用，此 1000 筆訓練資料已包含雜訊分佈之相關信息，足以作為 NFS 訓練以近似雜訊轉移函數之用。NFS 設定如下：

1. NFS 輸入： t 與 $t+1$ 時間下之原始雜訊；
2. NFS 輸出：模擬攻擊雜訊；
3. 模糊規則成形方式：Grid-type partition；
4. 模糊規則型態：Takagi-Sugeno (T-S) If-Then rules；
5. 訓練資料筆數：1000 筆；
6. 訓練資料取得方法：已污染影像前 1000 筆之像素。

為了探討影像復原效能，我們分三部份實驗分別進行，NFS 的模糊規則數量及設計方式如表 1 所示。在本研究中，學習演算法透過成本函數 (cost function) 作為系統參數調整之依據，我們使用均方誤差 (mean square error; MSE) 設計成本函數。成本值愈小，表示其對應之 NFS 系統的訓練結果愈佳。MSE 表示如下：

$$\text{MSE} = \frac{1}{Q} \sum_{k=1}^Q (y(k) - d'(k))^2 \quad (13)$$

其中 Q 為訓練資料筆數， $y(k)$ 為第 k 個污染像素訊號， $d'(k)$ 為第 k 個 NFS 之輸出。訓練終止條件為滿足所設定的迭代數。NFS 訓練完成後，進行影像之還原。

表 1：模糊集數目與模糊規則數量之設計

	Fuzzy set 數目		
	第一個 input (h_1)	2	3
第二個 input (h_2)	2	2	3
模糊規則數量	4	6	9

二、PSO-RLSE 複合學習演算法之設計

本研究中我們透過 PSO-RLSE 複合學習法調整 NFS 中的自由參數，並且與傳統的 PSO 比較效能。本研究使用 T-S 模糊規則，其後鑑部表示如下：

$$h_y^i = a_0^i + a_1^i h_1 + a_2^i h_2 + \dots + a_M^i h_M \quad (14)$$

其中 $\{a_0^i, a_1^i, \dots, a_M^i\}$ 為後鑑部自由參數， $\{h_1, h_2, \dots, h_M\}$ 為 NFS 系統輸入。在 PSO-RLSE 中，我們利用粒子群演算法調整前鑑部參數，後鑑部參數則是透過 RLSE 更新。學習群演算法之參數設定如下：

1. 粒子移動範圍：-10000000~10000000；
2. 粒子速度範圍：-10000000~10000000；
3. 迭代數：2000 代 (PSO)；1000 代 (PSO-RLSE)；
4. 粒子數：100；
5. 加速常數 (c_1 與 c_2)：根據相關研究 (Eberhart & Shi 1998; Zheng et al. 2003) 指出，當加速常數值為 2 時，其演算法之效果較佳，本研究中將兩者設定為 2；
6. 慣性權重 (w)：根據學者於研究中提出 (Shi & Eberhart 1998)，其值為 0.94 逐漸遞減至 0.4；
7. 演算法終止條件：滿足設定之迭代數。

三、實驗結果

本研究假設污染影像是由原始影像線性結合攻擊雜訊所產生。攻擊雜訊是原始雜訊經過轉移函數轉換之後產生的。因此，本研究期望 NFS 學習完成後，其輸出將能夠盡量接近攻擊雜訊。本研究所使用的影像皆為灰階影像，雜訊轉移函數包含線性與非線性轉移函數，且原始雜訊屬於高斯分佈。實驗分三部份分別進行，各部份說明如下。

(一) 在第一部份實驗方面，我們用 9 條模糊規則之 NFS 及一種非線性轉移函數與另一種線性轉移函數進行實驗。

首先，我們使用式(15)的非線性轉移函數來進行 PSO-RLSE 與 PSO 的效能比較。

$$\text{轉移函數：} f(n) = n|\sin n| + \frac{n}{2} \quad (15)$$

其中 n 是原始雜訊。圖 7 與 8 分別為原始影像及受污染影像。圖 9 是利用 PSO 學習演算法之復原影像，圖 10 是 PSO-RLSE 之復原影像，復原後的影像即可利用肉眼區分其效果。圖 11 為使用 PSO 之 NFS 輸出訊號 (模擬攻擊雜訊之訊號)，圖 12 為使用 PSO-RLSE 之模擬攻擊雜訊。



圖 7：原始影像




圖 8：雜訊攻擊後之影像




圖 9：PSO 之復原影像
(9 條模糊規則)




圖 10：PSO-RLSE 之復原影像
(9 條模糊規則)




圖 11：模擬攻擊雜訊與實際攻擊雜訊
(78400 像素中取前 500 個像素
畫出)，兩者有些接近，但還
不如理想 (PSO 方法)

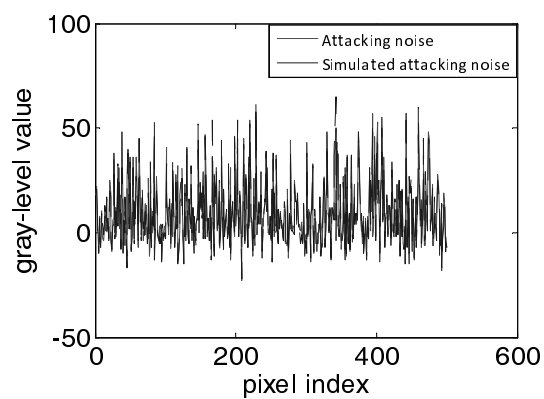


圖 12：模擬攻擊雜訊與實際攻擊雜訊
(78400 像素中取前 500 個像素
畫出)，兩者很靠近 (PSO-
RLSE 方法)

圖 13 及 14 分別為 PSO 與 PSO-RLSE 與原始影像的前 500 個像素值。表 2 為 PSO 與 PSO-RLSE 兩者的 MSE 之效能比較，由表 2 可得知 PSO-RLSE 複合學習演算法與 PSO 兩者之 MSE 的明顯差異。根據實驗結果顯示，在相同的粒子數、加速常數、慣性權重與模糊規則數條件之下，本研究所提出的 PSO-RLSE 複合學習演算法之影像復原結果優於傳統的 PSO 演算法。




圖 13：還原和原始影像像素值，為使圖形清楚呈現，78400 像素中只取前 500 個畫出 (PSO 方法)

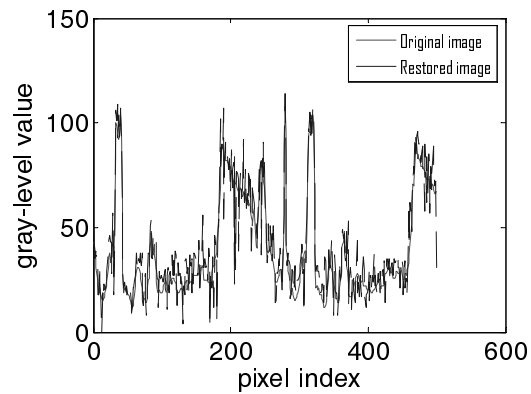


圖 14：還原和原始影像像素值 (78400 像素中取前 500 個像素畫出)，兩者之像素訊號曲線已相當靠近 (PSO-RLSE 方法)

表 2：PSO 演算法與 PSO-RLSE 複合學習演算法之效能比較

方法	MSE	規則數	迭代次數
PSO	79.820	9	2000
PSO-RLSE	8.1601	9	1000

第一部份之線性轉移函數實驗方面，我們使用式(16)之線性轉移函數來進行 PSO-RLSE 與 PSO 的比較，並且顯示兩者之學習曲線 (learning curves)。

$$\text{轉移函數：} f(n) = 10 \times n - 5 \quad (16)$$

其中 n 是原始雜訊。圖 15 與 16 分別為原始影像及受污染影像。圖 17 為利用 PSO 學習演算法之復原影像，圖 18 為 PSO-RLSE 之復原影像。圖 19 為利用 PSO 學習演算法之學習曲線，圖 20 為利用 PSO-RLSE 學習演算法之學習曲線。圖 21 為使用 PSO 之攻擊雜訊訊號，圖 22 為使用 PSO-RLSE 之攻擊雜訊訊號，圖 23

及 24 分別為 PSO 與 PSO-RLSE 與原始影像的前 500 個像素值。表 3 為 PSO 與 PSO-RLSE 兩者的 MSE 之效能比較。根據表 3 之 MSE 效能，在相同的粒子數、加速常數、慣性權重與模糊規則數量條件之下，本研究所提出的 PSO-RLSE 複合學習演算法之影像復原結果優於傳統的 PSO 演算法。



圖 15：原始影像




圖 16：雜訊攻擊後之影像




圖 17：PSO 之復原影像（9 條模糊規則）


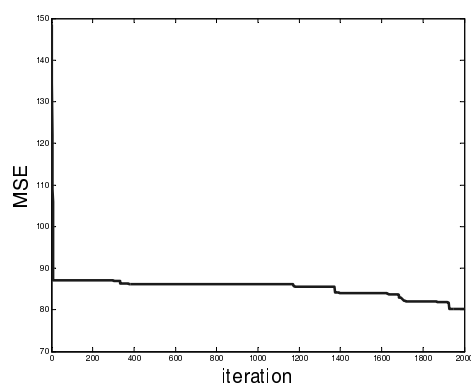
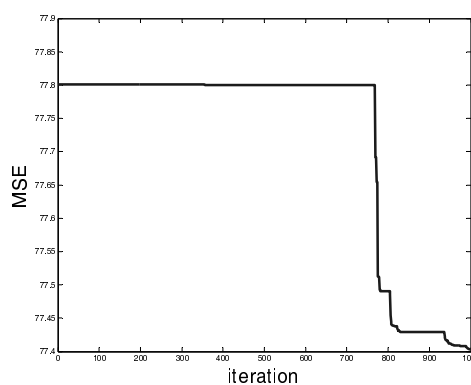


圖 18：PSO-RLSE 之復原影像（9 條模糊規則）

圖 19：PSO 之學習曲線
（9 條模糊規則）圖 20：PSO-RLSE 之學習曲線
（9 條模糊規則）

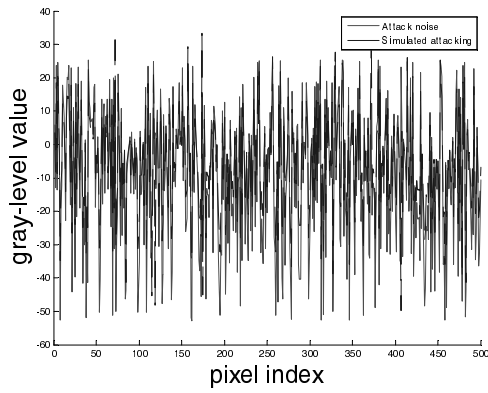


圖 21：模擬攻擊雜訊與實際攻擊雜訊（78400 像素中取前 500 個像素畫出），兩者有些接近，但還不如理想（PSO 方法）

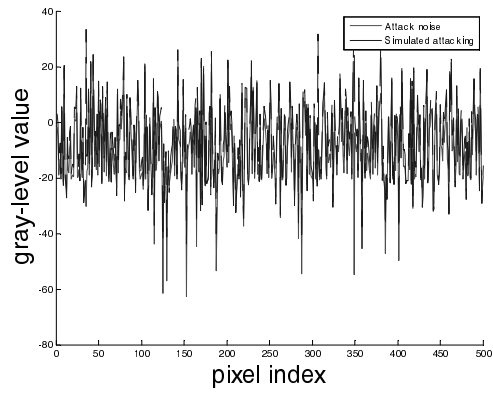


圖 22：模擬攻擊雜訊與實際攻擊雜訊（78400 像素中取前 500 個像素畫出），兩者很靠近（PSO-RLSE 方法）

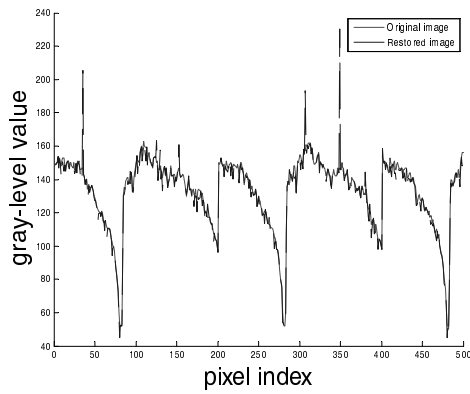


圖 23：原始和還原影像，為使圖形清楚呈現，78400 像素中只取前 500 個畫出（PSO 方法）

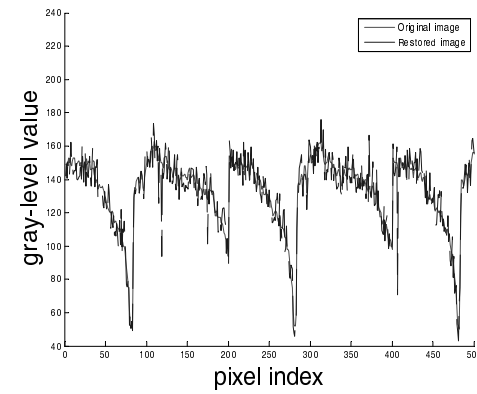


圖 24：原始影像和還原影像（78400 像素中取前 500 個像素畫出）（PSO-RLSE 方法）

表 3：PSO 演算法與 PSO-RLSE 複合學習演算法之效能比較

方法	MSE	規則數	迭代次數
PSO	80.137	9	2000
PSO-RLSE	77.403	9	1000

(二) 第二部份實驗中，我們以 PSO-RLSE 與兩種線性轉移函數來探討不同的模糊規則數量於影像復原之效能。在此實驗中我們使用線性轉移函數式(16)及(17)。首先，我們進行線性轉移函數式(17)之實驗。

$$\text{轉移函數：} f(n) = \frac{3}{4}n + 10 \quad (17)$$

其中 n 是原始雜訊。圖 25 與圖 26 分別為原始影像及受汙染影像。圖 27、28 與 29 分別為 4 條、6 條及 9 條模糊規則數量下之復原圖。在 4 條模糊規則數下，NFS 輸出（模擬攻擊雜訊）與實際的攻擊雜訊，原始與復原影像之像素值及原始與復原像素值之間的差異分別列在圖 30、31 及 32。在系統自由參數調整方面，自由參數數量為 20，系統前鑑部與後鑑部參數調整結果分別在表 4 及表 5 中列舉。



圖 25：原始影像



圖 26：雜訊攻擊後之影像



圖 27：4 條模糊規則之復原影像



圖 28：6 條模糊規則之復原影像



圖 29：9 條模糊規則之復原影像




圖 30：NFS 使用 4 條規則之模擬攻擊與實際攻擊雜訊（78400 像素中取前 500 個像素畫出）

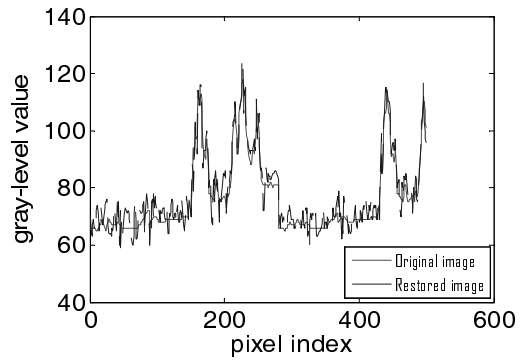


圖 31：NFS 使用 4 條規則之還原影像和原始影像像素值（78400 像素中取前 500 個像素畫出）




圖 32：原始影像與復原影像間之差異（4 條規則）

表 4：前鑑部參數（4 條規則）

Input	Fuzzy set	c	s
h_1	$\text{gaussian}(h_1, c, s)$	675891.269	-5417.694
	$\text{gaussian}(h_1, c, s)$	-9407692.544	-251878.0316
h_2	$\text{gaussian}(h_2, c, s)$	3684251.0458	2803301.2458
	$\text{gaussian}(h_2, c, s)$	-8686842.787	-1098582.211

表 5：後鑑部參數（4 條規則）

Rule	a_0	a_1	a_2
R^1	-6.4502×10^3	5.9696×10^2	-1.9729×10^2
R^2	6.4081×10^7	3.7071×10^{10}	1.2384×10^3
R^3	2.3523×10^{-1}	-2.8542×10^{-1}	3.2155×10^2
R^4	-3.6529×10^4	6.2354×10^7	-7.1252×10^2

在 6 條模糊規則數下，NFS 輸出與實際的攻擊雜訊，原始與復原影像之像素值及原始與復原像素值之間的差異分別列在圖 33、34 及 35。系統前鑑部與後鑑部參數調整結果分別在表 6 及 7 中列舉。在 9 條模糊規則數下，NFS 輸出與實際的攻擊雜訊，原始與復原影像之像素值及原始與復原像素值之間的差異分別列在圖 36、37 及 38。系統前鑑部與後鑑部參數調整結果分別在表 8 及 9 中列舉。




圖 33：NFS 使用 6 條規則之模擬攻擊雜訊與實際攻擊雜訊（78400 像素中取前 500 個像素畫出）。




圖 34：NFS 使用 6 條規則之復原影像和原始影像像素值（78400 像素中取前 500 個像素畫出）




圖 35：原始影像與復原影像間之差異（6 條規則）

表 6：前鑑部參數（6 條規則）

Input	Fuzzy set	c	s
h_1	gaussian(h_1, c, s)	-8856468.644	-1096094.821
	gaussian(h_1, c, s)	565971.2098	-119955.4135
h_2	gaussian(h_2, c, s)	7154083.8344	6752523.4887
	gaussian(h_2, c, s)	10000000	332064.1987
	gaussian(h_2, c, s)	-6133159.127	-1467910.655

表 7：後鑑部參數（6 條規則）

Rule	a_0	a_1	a_2
R^1	1.2944×10^{-7}	-8.9067×10^{-11}	-9.7131×10^{-9}
R^2	-3.2291×10^{-3}	-2.5849×10^{-8}	-2.506×10^{-3}
R^3	-2.3285×10^{-1}	2.5368×10^{-4}	-2.7334×10^5
R^4	1.0573×10^{-2}	-2.4766×10^5	1.1575
R^5	6.5368×10^7	-2.1582×10^3	-1.1469×10^6
R^6	-2.9681×10^3	-7.0242×10^3	-5.6345×10^{-6}




圖 36：NFS 使用 9 條規則之模擬
攻擊雜訊與實際攻擊雜訊
(78400 像素中取前 500 個
像素畫出)

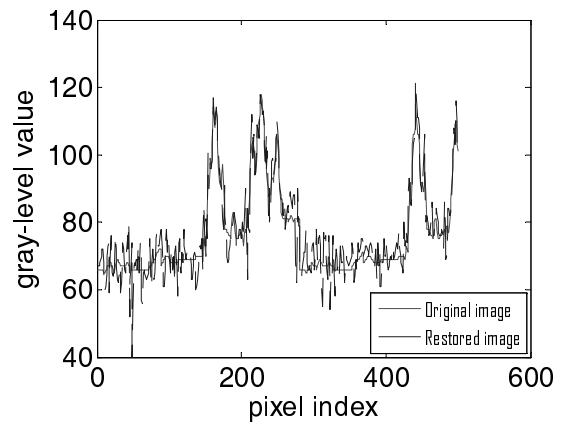


圖 37：NFS 使用 9 條規則之復原
影像和原始影像像素值
(78400 像素中取前 500 個
像素畫出)




圖 38：原始影像與復原影像間之差異（9 條規則）

表 8：前鑑部參數（9 條規則）

Input	Fuzzy set	c	s
h_1	$\text{gaussian}(h_1, c, s)$	5869026.580	-1764157.881
	$\text{gaussian}(h_1, c, s)$	-8766299.102	9868450.346
	$\text{gaussian}(h_1, c, s)$	5528640.024	-10000000
h_2	$\text{gaussian}(h_2, c, s)$	-3257299.023	-2238840.006
	$\text{gaussian}(h_2, c, s)$	10000000	-7250860.781
	$\text{gaussian}(h_2, c, s)$	3172763.268	9942803.614

表 9：後鑑部參數（9 條規則）

Rule	a_0	a_1	a_2
R^1	-5.5583×10^8	-3.0398×10^6	-4.3459×10^6
R^2	1.9395×10^7	2.7747×10^{10}	-2.7802×10^7
R^3	1.3115×10^{-2}	-2.0670×10^{-3}	1.4275×10^6
R^4	-1.9764×10^5	5.7308×10^6	-5.6806×10^3
R^5	-1.4390×10^5	-5.0556×10^6	1.1688×10^5
R^6	-5.1460×10^4	-1.0438×10^5	2.6417×10^4
R^7	2.2303×10^5	2.7500×10^4	-1.2859×10^6
R^8	2.1728×10^8	-1.6253×10^6	-3.1840×10^3
R^9	2.4546×10^3	-1.9673×10^4	-2.9104×10^2

根據實驗結果顯示，不同的模糊規則數量對於復原的品質較無顯著的差異。如表 10 所示，使用 4 條、6 條及 9 條模糊規則之 MSE 分別為 1.7674×10^{-2} 、 1.8016×10^{-2} 及 1.8291×10^{-2} 。在線性轉移函數式(16)之實驗，4 條、6 條及 9 條模糊規則數量下之復原效能列於表 11。

表 10：線性轉移函數（式 17）於不同規則數之效能比較

方法	模糊規則數	MSE
PSO-RLSE	4	1.7674×10^{-2}
PSO-RLSE	6	1.8016×10^{-2}
PSO-RLSE	9	1.8291×10^{-2}

表 11：線性轉移函數（式 16）於不同規則數之效能比較

方法	模糊規則數	MSE
PSO-RLSE	4	8.7175×10^1
PSO-RLSE	6	8.5020×10^1
PSO-RLSE	9	8.7984×10^1

（三）在第三部份實驗中，我們以 PSO-RLSE 與二個非線性轉移函數來探討不同的模糊規則數量對影像復原之效能。此實驗中，第一個非線性轉移函數式（15）列出如下。

$$\text{轉移函數：} f(n) = n|\sin n| + \frac{n}{2}$$

其中 n 是原始雜訊。圖 39 與圖 40 分別為原始影像及受污染影像。圖 41、42 與 43 分別為 4 條、6 條及 9 條模糊規則數量下之復原圖。在 4 條模糊規則數量下，NFS 輸出（模擬攻擊雜訊）與實際攻擊雜訊，原始與復原影像之像素值及原始與復原像素值之間的差異分別列在圖 44、45 及 46。NFS 系統前鑑部與後鑑部參數調整結果分別在表 12 及 13 中列舉。



圖 39：原始影像




圖 40：雜訊攻擊後之影像



圖 41：4 條模糊規則之復原影像



圖 42：6 條模糊規則之復原影像



圖 43：9 條模糊規則之復原影像




圖 44：NFS 使用 4 條規則之模擬攻擊雜訊與實際攻擊雜訊（78400 像素中取前 500 個像素畫出）




圖 45：NFS 使用 4 條規則之復原影像和原始影像像素值（78400 像素中取前 500 個像素畫出）




圖 46：原始影像與復原影像間之差異（4 條規則）

表 12：前鑑部參數（4 條規則）

Input	Fuzzy set	c	s
h_1	gaussian(h_1, c, s)	413122292.678	-1000000000
	gaussian(h_1, c, s)	508008261.676	780586798.286
h_2	gaussian(h_2, c, s)	952698764.879	43353351.5044
	gaussian(h_2, c, s)	-989589394.411	-9408293.4696

表 13：後鑑部參數（4 條規則）

Rule	a_0	a_1	a_2
R^1	5.7263×10^3	5.8429×10^2	4.3375×10^3
R^2	5.0462×10^3	5.1486×10^2	3.8221×10^2
R^3	-1.335	3.6123×10^1	3.0687×10^{-1}
R^4	4.6093×10^{-4}	4.9540×10^2	-1.489

在 6 條模糊規則數量下，NFS 輸出與實際攻擊雜訊，原始與復原影像之像素值及原始與復原像素值之間的差異分別列在圖 47、48 及 49。NFS 系統前鑑部與後鑑

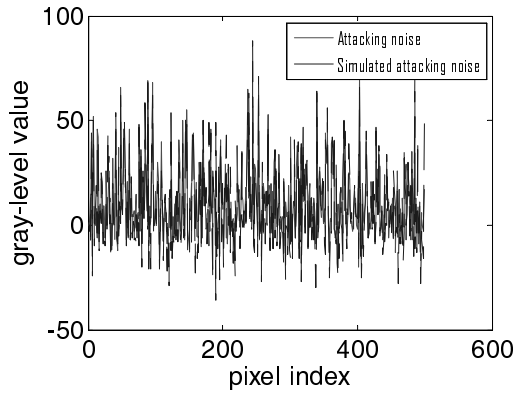


圖 47：NFS 使用 6 條規則之模擬攻擊雜訊與實際攻擊雜訊（78400 像素中取前 500 個像素畫出）




圖 48：NFS 使用 6 條規則之復原影像和原始影像像素值（78400 像素中取前 500 個像素畫出）




圖 49：原始影像與復原影像間之差異（6 條規則）

部參數調整結果分別在表 14 及 15 中列舉。在 9 條模糊規則數量下，NFS 輸出與實際攻擊雜訊，原始與復原影像之像素值及原始與復原像素值之間的差異分別列在圖 50，51 及 52。根據實驗結果，如表 16 所示，使用 4 條、6 條及 9 條模糊規則之 MSE 分別為 8.3375、8.16018 及 8.51278，6 條模糊規則對於影像復原品質稍微較佳，但無明顯差異。

表 14：前鑑部參數（6 條規則）

Input	Fuzzy set	c	s
h_1	gaussian(h_1, c, s)	3813637.6386	34138.6097
	gaussian(h_1, c, s)	6518094.584	296780.3311
h_2	gaussian(h_2, c, s)	-10000000	-6730377.361
	gaussian(h_2, c, s)	-733843.4178	10000000
	gaussian(h_2, c, s)	9999901.9728	4149455.8124

表 15：後鑑部參數（6 條規則）

Rule	a_0	a_1	a_2
R^1	2.4964×10^3	2.8281×10^1	1.9503×10^3
R^2	7.5081×10^3	8.5056×10^2	-5.8656×10^2
R^3	4.6741×10^1	5.2031×10^2	3.2236×10^2
R^4	-1.8921	7.6178×10^2	4.1203×10^1
R^5	8.5947	7.2652×10^1	9.8213×10^{-1}
R^6	3.6652×10^2	6.8955×10^{-1}	-5.0328×10^{-1}


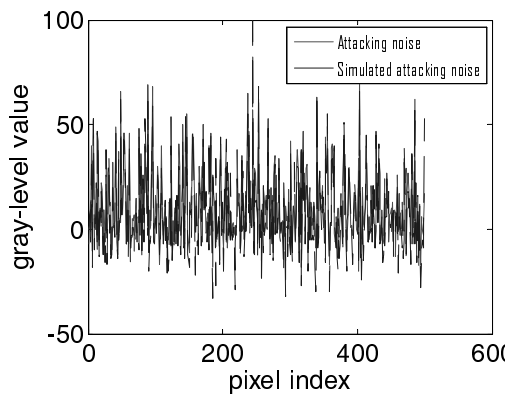


圖 50：NFS 使用 9 條規則之模擬攻擊與 圖 51：NFS 使用 9 條規則之復原影像和
 實際攻擊雜訊（78400 像素中取
 前 500 個像素畫出）

原始影像像素值（78400 像素中
 取前 500 個像素畫出）




圖 52：原始影像與復原影像間之差異（9 條規則）

表 16：非線性轉移函數（式 15）於不同規則數之效能比較

方法	模糊規則數	MSE
PSO-RLSE	4	8.3375
PSO-RLSE	6	8.16018
PSO-RLSE	9	8.51278

第二個非線性轉移函數設計如式(18)，列出如下。

$$\text{轉移函數：} f(n) = 10 \times n + 5 \times \cos(2 \times \pi \times n + 1.5) - 10 \quad (18)$$

圖 53 與 54 分別為原始影像及受汙染影像。圖 55、56 與 57 分別為 4 條、6 條及 9 條模糊規則數量下之復原圖。根據實驗結果，如表 17 所示，9 條模糊規則對於影像復原品質較佳，但差異不大。



圖 53：原始影像




圖 54：雜訊攻擊後之影像




圖 55：4 條模糊規則之
復原影像



圖 56：6 條模糊規則之
復原影像




圖 57：9 條模糊規則
之復原影像

表 17：非線性轉移函數（式 18）於不同規則數之效能比較

方法	模糊規則數	MSE
PSO-RLSE	4	8.8795×10^1
PSO-RLSE	6	9.2093×10^1
PSO-RLSE	9	8.7068×10^1

肆、分析與討論

在本論文研究中，我們以 NFS 及 PSO 與 PSO-RLSE 學習演算法為基礎，實施了三種不同實驗，以探討本研究方法在影像復原的性能表現。在第一部份實驗，我們以相同粒子群參數及模糊規則數為基礎，利用不同的學習迭代數比較 PSO-RLSE 複合學習演算法與 PSO 演算法之間的效能差異，其中 PSO 演算法之迭代數為 2000 次，PSO-RLSE 複合學習演算法之迭代數為 1000 次。影像復原結果如圖 9 與 10 所示，我們利用肉眼即可辨識出圖 9 中尚存在許多未清除之雜訊，顯示 PSO 之復原效能遠不及 PSO-RLSE 於 1000 次迭代後之效能。根據表 2 與圖 19 及 20 學習曲線，說明 PSO-RLSE 複合學習演算法之效能優於 PSO 演算法，原因在於 PSO 演算法對所有 NFS 自由參數調整時，PSO 演算法面臨參數維度較大而比較容易造成陷入局部最佳解之困境。PSO-RLSE 因採用分而擊之的學習策略，因此有較佳的表現。

在第二部份的線性轉移函數實驗中，分別以 4、6 及 9 條模糊規則進行影像復原。由表 10 與 11 的實驗結果得知，在線性轉移函數問題下，NFS 之模糊規則數量的增減對影像恢復之性能並無明顯的影響。在第三部份的非線性轉移函數實驗，分別以 4、6 及 9 條模糊規則進行影像復原。根據表 16 與 17 顯示，復原結果與 NFS 之模糊規則數量的增減並無絕顯著關係及影響。在實驗結果方面，表 16 中顯示 NFS 於 6 條模糊規則條件下時的復原結果稍微優於其它兩者，而在表

17 中顯示 NFS 於 9 條模糊規則條件下時的復原結果稍微優於其它兩者，其性能表現並無明顯差異。換言之，NFS 對模糊規則之數量具有一定程度的包容性。在未來的研究上，本研究結果可進一步延伸，利用分群演算法幫助使用者決定適當的模糊數量作為系統運作之用。

伍、結論與未來研究

本研究應用類神經模糊系統 (NFS) 於影像雜訊消除的議題上，並且提出 PSO-RLSE 複合學習演算法作為調整 NFS 自由參數的機制。在本研究中，我們利用 PSO 演算法調整 NFS 之前鑑部參數，而後鑑部參數則是透過 RLSE 進行更新。當 NFS 學習完成後，其輸出可作為模擬攻擊雜訊之用，清除 (或仰制) 影像雜訊。我們以 PSO-RLSE 複合學習演算法與 PSO 演算法進行效能比較，根據實驗結果顯示，PSO-RLSE 學習演算法明顯優於 PSO 演算法。在模糊規則數目對影像復原之影響方面，我們透過不同的模糊規則數量來進行復原研究，實驗結果顯示，影像復原效能與模糊規則數量之間並無存在明顯的關係，NFS 對模糊規則數量的需求具有某種程度的包容性存在。因此，若企圖增加模糊規則數量來提昇影像復原效果，並不能保證復原效果的提昇，反而因模糊規則數量增多造成求解問題維度增大，使得 NFS 計算時間與系統負載上升。本研究所提出之智慧型系統研究方法在灰階影像復原問題上已有相當的成果，未來可延伸於彩色影像及音訊雜訊清除的研究領域。

參考文獻

- Afonso, M. and Joshi, S.D. (2005), 'A wavelet based scheme for adaptive noise cancelling from images', *Proceedings of the 28th General Assembly of the International Union of Radio Science*, pp.1-4.
- Astrom, K.J. and Wittenmark, B. (1984), *Computer Controller Systems: Theory and Design*, Prentice-Hall, Englewood Cliffs, NJ.
- Chen, Y.C. (2006), *FLS (Fuzzy Logic System)*, EE, FCU.
- Duan, Y., Gao, Y. and Li, J. (2006), 'A new adaptive particle swarm optimization algorithm with dynamically changing inertia weight', *Intelligent Information Management Systems and Technologies*, Vol. 2, No. 2, pp. 245-255.
- Eberhart, R.C. and Kennedy, J. (1995), 'A new optimizer using particle swarm theory', *Proceeding of Sixth International Symposium on Micro Machine and Human Science*, pp. 39-43.
- Eberhart, R.C. and Shi, Y. (1998), 'Comparison between Genetic Algorithms and

- Particle Swarm Optimization', *EP '98 Proceedings of the 7th International Conference on Evolutionary Programming VII*, pp. 611-616.
- Goodwin, C. and Sin, K.S. (1984), *Adaptive Filtering Prediction and Control*, Prentice-Hall, Englewood Cliffs, NJ.
- Jang, J.S.R. (1991), 'Fuzzy modeling using generalized neural networks and kalman filter algorithm', *Proceedings of Ninth National Conference on Artificial Intelligence*, pp. 762-767.
- Jang, J.S.R. (1993), 'ANFIS: adaptive-network-based fuzzy inference system', *IEEE Transactions on System, Man and Cybernetics*, Vol. 23, No. 3, pp. 665-685.
- Jang, J.S.R., Sun, C.T. and Mizutani, E. (1996), *Neuro-Fuzzy and Soft Computing*, Prentice Hall, USA.
- Jin, F., Fieguth, P., Winger, L. and Jernigan, E. (2003), 'Adaptive wiener filtering of noisy images and image sequences', *IEEE International Conference on Image Processing*, Vol. 2, pp. 349-52.
- Kennedy, J. and Eberhart, R.C. (1995), 'Particle swarm optimization', *IEEE International Conference on Neural Networks*, pp. 1942-1948.
- Kennedy, J. (2007), 'Some issues and practices for particle swarms', *IEEE Swarm Intelligence Symposium*, pp. 162-169.
- Kuo, Y.H., Lee, C.S. and Chen, C.L. (2000), 'High-stability awfm filter for signal restoration and its hardware design', *Fuzzy Sets and Systems*, Vol. 114, No. 2, pp. 185-202.
- Lee, C.C. (1990), 'Fuzzy logic in control systems: fuzzy logic controller, part I, part II', *IEEE Transactions on System, Man and Cybernetics*, Vol. 20, pp. 404-435.
- Lee, C.S., Kuo, Y.H. and Yu, P.T. (1997), 'Weighted fuzzy mean filters for image processing', *Fuzzy Sets and Systems*, Vol. 89, pp. 157-180.
- Li, C. and Chiang, T.W. (2010), 'Complex neuro-fuzzy self-learning approach to function approximation', *Lecture Notes in Artificial Intelligence*, Vol. 5991, pp. 289-299.
- Mastin, A. (1985), 'Adaptive filters for digital image noise smoothing: an evaluation', *IPPR Conference on Computer Vision, Graphics, and Image Processing*, Vol. 31, pp. 103-121.
- Shi, Y. and Eberhart, R.C. (1998), 'A modified particle swarm optimizer', *IEEE World Congress on Computational Intelligence*, pp. 69-73.
- Strobach, P. (1990), *Linear Prediction Theory: A Mathematical Basis for Adaptive Systems*, Springer-Verlag, New York.

- Takagi, T. and Sugeno, M. (1983), 'Derivation of fuzzy control rules from human operator's control actions', *Proceedings of IFAC Symposium Fuzzy Information, Knowledge Representation and Decision Analysis*, pp. 55-60.
- Takagi, T. and Sugeno, M. (1985), 'Fuzzy identification of systems and its applications to modeling and control', *IEEE Transactions on System, Man and Cybernetics*, Vol. 15, pp. 116-132.
- Watrous, R.L. (1991), 'Learning algorithms for connectionist network: applied gradient methods of nonlinear optimization', *Proceedings IEEE International Conference on Neural Networks*, pp. 619-627.
- Widrow, B., Glover, J.R. and McCool, J.M. (1975), 'Adaptive noise canceling: principles and application', *Proceedings of the IEEE*, Vol. 63, pp. 1692-1730.
- Zadeh, L.A. (1965), 'Fuzzy sets', *Information and Control*, pp. 338-353.
- Zadeh, L.A. (1973), 'Outline of a new approach to the analysis of complex systems and decision processes', *IEEE Transactions on System, Man and Cybernetics*, Vol. 3, pp. 28-44.
- Zheng, Y., Ma, L., Zhang, L. and Qian, J. (2003), 'Empirical study of particle swarm optimizer with an increasing inertia weight', *Evolutionary Computation 2003 (CEC 2003)*, Canberra, Australia, December 8-12, pp. 221-226.