



# 非線性後鑑部之 模糊類神經網路簡介

Introduction to Fuzzy Neural Network  
with Nonlinear Consequent

陳政宏


國立交通大學  
電機與控制學系

謝伯璜

工研院機械所  
智慧系統工程技術組  
智慧系統技術部

張俊隆

工研院機械所  
智慧系統工程技術組  
智慧系統技術部  
經理



## 關鍵詞

- 模糊類神經網路 Fuzzy Neural Network
- 自我建構法則機制 self-constructing rule
- 倒傳遞學習演算法 backpropagation algorithm
- 系統判別 system identification
- 圖形辨識 pattern recognition
- 水槽溫度控制 temperature system control problem

## 摘要

本文提出一非線性後鑑部之模糊類神經網路 (Fuzzy Neural Network with Nonlinear Consequent, FNNNC)。所提出來的網路架構是利用函數鏈結神經網路(functional link neural network, FLNN)當作模糊法則的後鑑部，此函數鏈結神經網路使用函數擴展功能，具有正交多項式和線性獨立的特性。

因此，所建議的後鑑部是輸入變數的非線性組合。此外，本研究也提出包括架構學習及參數學習之線上學習演算法。架構學習是透過熵量測(entropy measure)決定適當的模糊法則數，參數學習是利用梯度陡降法調整模糊法則的歸屬函數形狀和後鑑部相對應的權重值。最後，非線性後鑑部之模糊類神經網路將應用在判別、辨識及控制問題上，以證明所提出的模糊類神經網路之效能。

This study presents a fuzzy neural network with nonlinear consequent. The proposed model uses a functional link neural network (FLNN) to the consequent part of the fuzzy rules. This study uses orthogonal polynomials and linearly independent functions in a functional expansion of the FLNN. Thus, the consequent part of the proposed model is a nonlinear combination of input variables. An online learning algorithm, which consists of structure learning and parameter learning, is also presented. The structure learning depends on the



entropy measure to determine the number of fuzzy rules. The parameter learning, based on the gradient descent method, can adjust the shape of the membership function and the corresponding weights of the FLNN. Finally, the proposed model is applied in various simulations. Results of this study demonstrate the effectiveness of the proposed model.

---

## 前言

---

對於一般物理及數學現象的描述，通常是透過數學模型，再加以數學運算式子來說明。但是對於過於複雜的系統而言，想要以基本的物理意義透過單純的數學模型來完全表示卻不是那麼的容易。因此，實驗變成為了推算與了解系統的另一方式，透過實驗測試與數據的收集，可以了解系統的特性，且更可以透過對數據的分析，進一步的反求出物理系統的參數及資料間的函數相關性。而這一門廣被運用的學問，稱為系統識別(system identification)。相對於控制方面，運用系統識別方法常被用來模擬並控制複雜的程序，但是對於許多高維度非線性的程序而言，運用傳統的控制策略及控制方法有時候並不能提供令人滿意的效果。因此，對於複雜而無法使用傳統控制器以達控制效果的程序，必須還是要以人工手動操作，以補控制器之不足。但是對於工業化的現代而言，為了有效的降低成本，工廠自動化成為了企業的主要訴求之一，這顯然跟良好控制是相違背的。因此，如何以控制器取代之工廠中的資深操作員或工程師(稱為專家)的操作且能提供跟有經驗的專家控制相同的控制效能，是工廠自動化和控制的共同目標。

所以，若可以將專家控制行為模擬並由控制器學習，已表現出和專家一樣的控制動作行為，即可以達到自動化和控制效果的雙面要求。為了達到此

目標，必須先將程序的動態以輸入和輸出的資料建模(modeling)，再根據所得到的數學模型建立起控制系統。如此說來系統識別在控制系統設計過程中扮演著相當重要的角色。近年來，模糊類神經網路[1-3]已經成爲一熱門的研究題目，並且應用在預測、控制、辨識、決策等領域上。其重要的相關議題包括：設計一精確的模糊類神經網路及設計一效率高的學習演算法。模糊類神經網路是利用類神經網路低層次的學習和計算權值導入模糊系統，並且利用模糊系統提供高層次的人類思考和推論模式導入類神經網路架構。因此，它結合類神經網路的學習能力及模糊邏輯系統的人類思考推論模式等二個的優點。

模糊類神經網路的兩種典型類別分別是：Mamdani-type 模糊類神經網路[4-5]與 TSK-type 模糊類神經網路[6-7]。Mamdani-type 模糊類神經網路是分割輸入空間，再將推論部指定到那些空間，因此所需的法則個數相對的會比較多；相對的，TSK-type 模糊類神經網路所使用的法則個數會比Mamdani-type 模糊類神經網路更少，它是將Mamdani-type 模糊類神經網路推論部之模糊集合以一線性函數的方法取代。許多文獻[6-7]證實 TSK-type 模糊類神經網路於網路架構與學習效率方面皆比Mamdani-type 模糊類神經網路優秀。在傳統的 TSK-type 模糊類神經網路中，它的推論部是以輸入訊號的線性組合函數完成，而其網路輸出具有局部近似目標輸出的功能。不幸地，傳統的 TSK-type 模糊類神經網路的推論部無法提供完全的映射能力。NARA[8]和CANFIS[9]利用多層類神經網路當作模糊法則的後鑑部，藉由類神經網路是非線性函數的特性使得模糊類神經網路的推論部能使網路輸出更具體且更逼近目標輸出。不過，多層類神經網路有收斂過度緩慢及計算量過度龐大等不利條件。因此，本研究是利用函數鏈結神經網路當作模糊法則的後鑑部，因而提出一非線性後鑑部之模糊類神經網



路，主要是爲了改善函數逼近準確性。所建議的非線性後鑑部之模糊類神經網路其後鑑部是輸入變數的非線性組合，這是不同於其他目前存在的模糊類神經網路。所使用的函數鏈結神經網路是一單層的神經網路，它是藉由函數擴展的特性可產生非線性的決策邊界。且函數鏈結神經網路有方便被使用、收斂速度快及較少的計算量等特性。每一個模糊法則的後鑑部對應於一函數鏈結神經網路輸出。而函數鏈結神經網路有正交多項式和線性獨立的能力。

傳統的模糊系統是由一連串的「若~則~(If~Then~)」模糊法則組合而成。而模糊法則的選擇常常依賴適合的決策知識。很明顯地，要由專家從一個複雜系統中，對所有輸入—輸出的資料找出適合模糊系統使用的法則是困難的。爲了應付這困難點，在模糊類神經網路領域中，有很多學者正在研究由數值資料中自動產生模糊法則「若~則~(If~Then~)」的方法。一般來說，這些方法是包含二個學習的階段，分別爲結構上的學習階段和參數上的學習階段。以傳統來說，這二個階段都是依序相繼地，結構的學習階段是決定模糊法則的結構，而參數學習階段是在調整每個法則的參數(像是歸屬函數的形狀和位置)。這些學習演算法又分爲離線(off-line)學習[10-11]及線上(on-line)學習[4, 7]，所謂的離線學習是將所蒐集到的資料先完成結構學習，再進行參數學習，若有新資料進來，必須重新再學習。相對地，線上學習即是根據新進來的資料，同時完成結構及參數學習。我們提出一線上學習演算法，此演算法包括架構學習和參數學習。架構學習主要是決定所使用的模糊法則數，以讓輸入空間做適當的模糊分割，而剛開始我們的架構是沒有任何法則，亦是沒有任何節點的。模糊法則是藉由熵量測自動從訓練資料產生的。參數學習是透過倒傳遞演算法調整網路架構中所有參數，主要是爲了減少網路的輸出誤差。

## 一個非線性後鑑部之模糊類神經網路架構

### 一、函數鏈結神經網路

函數鏈結神經網路(FLNN)最初是由Patra等人[12]提出，藉由基本函數近似定理，隨機線性組合輸入信號，擴展輸入信號空間，成功地將多層感知機中的隱藏層省略掉，並簡化多層感知機的架構，使FLNN結構具有比多層感知機結構更快的收斂速度及較少的計算負荷。作者同時也證明FLNN的性能優於多層感知機。FLNN的函數近似採用三角函數多項式去擴展輸入信號空間的維度，也成功地應用在非線性動態系統的識別與非線性通道等化。FLNN是將輸入信號  $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_n]^T$  經函數展開成  $\Phi = [\phi_1(x) \ \phi_2(x) \ \dots \ \phi_N(x)]^T$ ， $N$ 個線性獨立的函數，將  $n$ 維信號空間映對至  $N$ 維信號空間，即  $R^n \rightarrow R^N$ ， $n < N$ ；它的理論基礎在[12]中討論與分析，其主要的目的是將原先在低維度信號空間線性不可分離之問題轉換到高維度信號空間，藉以形成線性可分離之問題，以便還原正確信號。此映對函數有多種選擇，譬如：Legendre、Chebyshev多項式和三角函數  $\sin(x)$  或  $\cos(x)$ ，其中以具有  $N$ 次部分和的Fourier級數爲最佳近似函數。因此，三角基底函數 (trigonometric polynomial basis functions) 可由  $\{1, x_1, \sin(\pi x_1), \cos(\pi x_1), \dots, x_2, \sin(\pi x_2), \cos(\pi x_2), \dots\}$  組成，若輸入信號有超過2個以上的變數，其外積項(outer product terms)加上三角基底函數當做函數擴展(function expansion)  $\Phi(X)$ ，會有較佳之收斂效果。Patra等人[12]證實在如此函數擴展選擇下，利用倒傳遞學習演算法，FLNN應用在非線性動態系統識別上，其映對準確度比多層感知機好很多。FLNN的結構如圖一所示， $S = \mathbf{W}\Phi$ ，此處  $S = [s_1, s_2, \dots, s_m]^T$ ， $\mathbf{W}$  是  $(m \times M)$  維的加權矩陣， $S$  再經非線性函數  $\rho(\cdot) = \tanh(\cdot)$  產生  $\hat{\mathbf{Y}} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_m]^T$ ，此處



更完整的內容

請參考紙本【機械工業雜誌】316期・98年7月號

每期220元・一年12期2200元

劃撥帳號：07188562 工業技術研究院機械所

訂書專線：03-591-9342

傳真訂購：03-582-2011