

類神經網路與田口法於引擎故障聲訊辨識之應用

林筱增*、高志中**、潘冠呈***、葉懷仁****

摘 要

隨著現代科技進步，今日汽車引擎之故障檢修皆以電腦診斷方式進行，惟此方式對於因機件異常所產生的噪音聲訊卻無法判斷。本論文旨在以類神經網路結合田口法來建構一套有效率的引擎故障聲訊辨識系統，以期在一般引擎故障檢修範圍之外，能夠及早發現其它的機件異常現象，以協助維修人員正確辨識故障來源。

本研究係以倒傳遞類神經網路結合田口法為研究架構，透過類神經網路學習來辨識引擎在不同狀況下所產生之故障聲訊。在聲訊正規化部分，採用 OTA 及 TPM 兩種不同正規化處理方式。建構類神經網路模式時選擇其輸入層單元數、隱藏層單元數、學習速率及學習循環次數等四項控制因子，並採用田口法直交表的配置，在不同水準條件下進行實驗，配合訊雜比、變異數分析及 F 檢定之計算，分析控制因子對網路辨識率的影響程度，以獲得最佳的參數組合。研究結果顯示引擎故障聲訊最佳辨識率為 77.1%。

關鍵字：類神經網路、田口法、引擎噪音

* 美和技術學院資訊管理系副教授兼系主任

** 和春技術學院資訊管理系助理教授

*** 國防部海軍總部計畫處上尉研究發展官

**** 國立旗山高級農工職業學校教師

壹、前言

引擎為車輛動力之來源，若發生故障，將直接影響其正常運作，如能及早發現異狀立即檢修，不僅可防範未然，更可增加車輛使用壽命。隨著電子科技的進步，新式噴射引擎的燃料及點火等系統皆由電子控制單元(ECU, Electric Control Unit)控制，並由電腦診斷器對引擎進行故障監控；而傳統之故障監控係由各種電子感知器與回授線路連接，若引擎發生異狀時則由 ECU 處理，並以警示燈號或警告聲告知駕駛者。雖然目前噴射引擎之故障現象可由電腦診斷器加以分析判斷，但對於機件異常現象所產生的噪音等聲訊卻無法處理，此時一般只能藉由熟練的技師憑經驗診斷或利用傳統式聽診器來判斷其故障原因，唯這些方法主要取決於經驗累積，且很難加以系統化。因此本研究旨在建構一種引擎故障聲訊診斷方式，未來可協助及早發現引擎異狀並及時檢修。

一、研究動機與目的

今日由於資訊發達，電腦科技進步一日千里，若能利用聲訊儀器等監測辨識方式，透過電腦軟體建構一套完備而有效率的故障診斷系統，將可迅速的協助駕駛者及早發現故障徵候；而在引擎檢測的過程中，亦可協助維修技工迅速針對故障原因加以維修，不但可將許多故障防範於未然，更可節省人力並大幅減少維修時間。

本研究旨在以類神經網路結合田口法進行引擎故障聲訊之辨識。透過收錄的各種引擎聲訊，藉由在類神經網路訓練過程中，針對影響故障聲訊辨識率之參數如：輸入層單元數、隱藏層單元數、學習速率及學習循環次數等，以田口法的直交表進行有系統的實驗規劃，分析各參數對辨識率之影響，以決定較佳的學習參數組合，進而達到引擎聲訊最佳辨識效果。另外在影響辨識效果的原因中，聲訊的正規化為一非常重要因素，本文嘗試比較不同的正規化法對聲訊辨識系統之影響，以有效提昇引擎故障聲訊辨識率。

貳、文獻回顧

國內運用類神經網路之研究相當多，如曹大鵬（1996）將類神經網路應用於馬達聲訊辨識，以監督式學習演算法進行電機故障狀況訓練及辨識；同年陳建源（1996）提出以感應電動馬達產生噪音做為監測訊號，並應用倒傳遞類神經網路做故障狀況的辨識研究，此研究係模擬實際工廠大型電動機之運轉情形，以達到良好的故障辨識能力；黃信豪（1996）則利用訊號處理與式樣辨識技術做為機器故障偵測之工具。

洪振益（2000）等人將類神經網路應用於小型軸流風扇葉片之設計。莊凱斌（2001）則結合聲音辨識與影像處理的監視系統，並應用倒傳遞類神經網路進行撞擊聲音種類之辨識，模擬系統在發生撞擊事件時，建立完整的影像畫面

記錄檔，藉以釐清交通事故責任歸屬之研究；同年邱垂霖（2001）針對迴轉機轉子於固定轉速下進行檢測，經由倒傳遞類神經網路來辨識轉子運轉之正常或不平衡、對中心不準等異常狀態，並模擬實際工廠大型工具機運轉之狀況。晉鳳山（2002）則針對傳統倒傳遞類神經網路之運算方式加以改良。

國外對於將類神經網路應用於車輛噪音之相關研究相當多。Marko（1989）等人應用類神經網路來檢查汽車引擎的故障，其做法係根據汽車感知器輸出的電壓值做為分析參數，以辨識汽缸不點火或燃料噴油嘴之故障；Marko（1990）再利用一實際可訓練之分類工具來診斷與辨識汽車動力系統之故障。Arai（1991）將類神經網路應用於空氣壓縮機汽門聲音的故障診斷；Lowe（1997）將類神經網路應用在預測引擎最佳的混合汽比和點火正時的時間，使引擎能在維持在最佳狀態運轉，以並作為引擎校正之依據。

Shayler（2000）應用類神經網路研究汽車引擎是否維持在正常的運轉狀態，此研究係將類神經網路應用在對汽車引擎做最佳化的設計及檢測上；Schwarte 與 Isermann（2002）則運用類神經網路來模擬未知物理模式結構之複雜流體及其熱力特性，研究中並利用一柴油引擎及快速控制原型系統驗證偵錯運算法則。

而近年來田口法除了運用於品質工程以及產品製程改良等領域外，更有逐漸與最佳化理論、控制器設計、類神經網路、遺傳基因演算及模糊灰色等理論相結合的趨勢。綜觀文獻回顧，吾人發現田口法與倒傳遞類神經網路方法之結合實屬具體可行，雖然從 2000 年就有一些相關研究，唯數量及應用範圍仍相當有限，而應用於汽車故障聲訊之辨識實屬首創。對於這種以聲訊辨識故障的觀念並非侷限於車輛，所有操作時會產生聲訊的各種交通或運輸工具，例如航空器、船舶之故障監測與辨識等均適用，未來發展的潛力未可限量。

參、理論分析

一、類神經網路

類神經網路(Artificial Neural Network)是指一種模仿生物神經網路的資訊處理系統，它使用大量相連的人工神經元來模仿生物神經元的能力，並模擬生物神經元的運算方式，將其結果藉由網路傳遞至其它人工神經元。透過不同的網路學習方式，類神經網路可將其系統輸入與輸出所組成的資料建立系統模型，並利用系統模式的輸入和輸出關係，應用於預測、辨識和分類等問題。

生物神經網路是由許多神經元(Neuron)所組成，各神經元間透過神經節與神經樹互相連接，神經細胞可以接收來自其他神經細胞傳送過來的脈波訊號，如接收訊號夠強並超過某一特定閾值(Threshold)，便促使神經元產生反應，並產生一個新的脈波訊號，最後此訊號透過神經軸，傳送到其他神經元的神經節與神經樹，而成為其他神經元的輸入訊號，生物神經元模型如圖 1。每一個神

經元主要包含了神經核(Soma)、神經軸(Axon)、神經樹(Dendrite)及神經節(Synapse)。

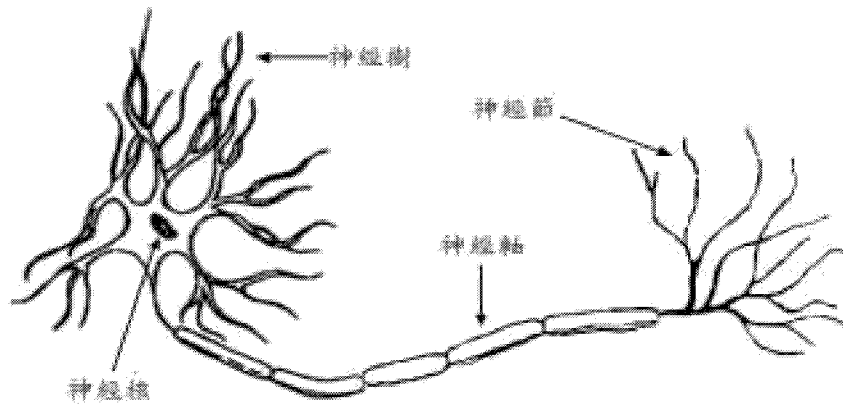


圖 1 生物神經元模型

類神經網路是由許多人工神經元(Artificial Neuron)所組成，人工神經元又稱處理單元。每一個處理單元皆有 n 個輸入(X_1, X_2, \dots, X_n)及一個輸出(Y_j)，而輸入端都先經過加權值 W_{ij} 的運算，興奮的神經節具有正的加權值，抑制的神經節則具有負的加權值，輸出值 Y_j 是輸入值加權乘積和再經由轉換函數轉換的結果。

類神經網路組成的基本單位為「處理單元」或稱「人工神經元」，處理單元再組成「層」，層再進一步組成「網路」。其中「層」是由若干具有相同作用的處理單元所組成，而網路是由若干具有不同作用的層所集合連結而成。基本上類神經網路係以輸入層、隱藏層與輸出層的三層網路結構相互連結而成（如圖 2 所示）。其中隱藏層可視其實際需要適當的增加層數，但亦有不使用隱藏層的網路。

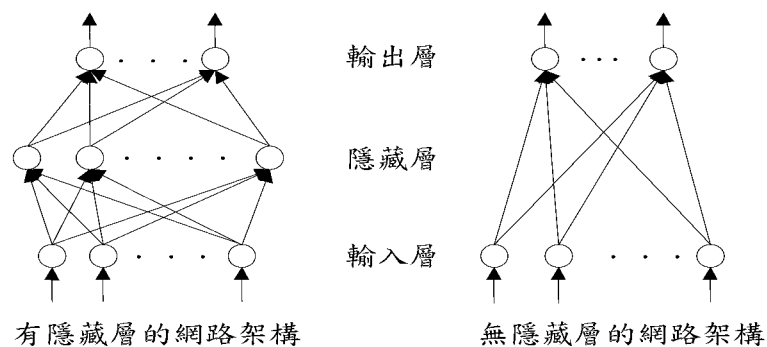


圖 2 類神經網路的架構

人腦可藉由外界的刺激調整本身的行為，而調整的對象即為神經鍵；同樣地類神經網路也能利用所獲得的資訊來調整本身的性能，換言之就是藉著改變連接權重的方式來表示對輸入的反應，此過程稱為學習。一般吾人將輸入資料分為訓練範例與測試範例兩類，訓練範例是類神經網路學習過程所使用的範例，而測試範例的目的則在於評估類神經網路訓練後的結果，若無法達到目標輸出值的要求，則類神經網路須重新評估再訓練。當所有的訓練範例皆輸入網路執行一次時，稱為完成一個學習循環。一個網路可以將訓練範例反覆學習若干次循環，直達收斂為止。

二、倒傳遞類神經網路

倒傳遞類神經網路(BPN, Back Propagation Neural Networks)，是目前類神經網路學習模式中最具代表性、應用最普遍的模式之一。倒傳遞類神經網路之基本原理係利用最陡坡降法(The Gradient Steepest Descent Method)，以網路的輸出誤差反覆調整網路的連接加權值；換言之，吾人希望在學習過程中，網路的輸出值與所預設的目標值能夠愈接近。而修正網路加權值的方法，則是將網路的輸出值與目標值間的誤差，依一定比例回傳誤差值，用以修正網路加權值，故此類網路一般被稱為「倒傳遞類神經網路」。以下將介紹倒傳遞類神經網路的基本結構及演算的方法與過程。

傳遞類神經網路的基本結構如圖 3 所示，其中包含：

- (一)、輸入層：表示網路的輸入向量，其單元數目依實際問題特性而定。
- (二)、隱藏層：表示輸入與輸出單元間的交互影響，其單元數目之決定並無標準方法可遵循，通常須以試驗方式決定其最佳數目。
- (三)、輸出層：表示網路的輸出向量，為網路經層層運算後所得到的向量，其單元數目一般也視問題特性而定。




圖 3 倒傳遞類神經網路基本結構

三、田口法

1951 年田口玄一博士(Dr. Taguchi Genichi)提出使用直交表(Orthogonal Array)的實驗設計方法，並率領研究團隊積極開發各種類型的直交表點線圖應用技巧以及解析方法。由於此方法具備：實驗結果之重現性很高、配置實驗的彈性較大且配置容易、所需實驗次數可顯著降低以及其解析方法較簡便等諸多

優點，很快就在日本迅速推廣應用，歐美則是在 1980 年代初期開始接受並廣泛運用此方法，並統稱為田口法(Taguchi's Method)。

本研究主要結合田口法以及類神經網路，以建構一種可有效找出引擎聲訊之最佳辨識方法。傳統的類神經網路在多個實驗因子及水準交互影響之下，較難以有系統及有效率的進行網路學習並找出最佳參數組合，因此藉由田口直交表之配置及變異數分析，以期透過田口實驗規劃更有效率地找到最佳的參數水準組合。

田口實驗計畫法主要係應用直交表來執行各項實驗分析，首先須選定實驗變數因子、決定各變數的水準、並將實驗結果經變異數分析求得各變數對目標函數的影響程度。在運算過程中，吾人可以根據問題的特性選擇適當的直交表，以供規劃實驗矩陣之用。各種直交表各有名稱，由其名稱可知該表橫列及直列之數目以及各直交表之水準數目。例如 $L_4(2^3)$ 直交表有四個橫列，三個兩水準之直行。

在類神經網路的訓練過程中，吾人選擇輸入層單元數、隱藏層單元數、學習速率及學習循環次數等四個主要參數作為實驗因子，每個因子均設定在三個不同水準，對於實驗因子之水準，吾人選定之標準如下：

- (一)、輸入層單元數：相對於網路輸出層單元數為 4（引擎聲訊之型式共分 4 類），故將輸入層單元數設定為 4、6、8。
- (二)、隱藏層單元數：隱藏層單元數可由下列公式獲得：

$$\text{隱藏層單元數} = (\text{輸入層單元數} + \text{輸出層單元數}) / 2 \quad (1)$$

或

$$\text{隱藏層單元數} = (\text{輸入層單元數} + \text{輸出層單元數})^{1/2} \quad (2)$$

故將隱藏層單元數設定為 4、6、8。

- (三)、學習速率：學習速率太大或太小均不利於網路的收斂，依據經驗一般在 0.01 到 1.0 之間大都可得到良好的收斂性，故吾人將學習速率設定為 0.05、0.1 及 0.5。
- (四)、學習循環次數：網路的學習循環次數雖然不宜太少，但如果太多而超過某一限度，則反而會造成過度訓練之現象，不利於網路的收斂，故將學習循環次數設定為 1000、2000 及 3000。

對於實際類神經網路運算而言，當選定實驗因子及設定水準後，吾人必須探討各因子對網路訓練結果的影響。若依本實驗設定的因子及水準數目，理論上必須執行 34、或 81 次的測試，方可求出其最佳參數組合。而當實驗涉及的因子及水準數再增加時，則所需的運算次數將更為可觀，除了缺乏效率之外，更對於因子與水準之最佳組合無任何掌握。此時可採用田口法直交表的方式進

行實驗因子與其水準的配置，藉由分析代表性的實驗之結果，可找出各因子對網路訓練的影響程度及重要性，進而調整實驗因子以求出最佳的組合參數。由於本研究有四個重要控制因子，而每個因子有三個水準，故選擇 $L_9(3^4)$ 直交表（如表 1 所示）。

表 1 田口實驗 $L_9(3^4)$ 直交表

實驗因子 實驗編號	輸入層單元數	隱藏層單元數	學習速率	學習循環次數
1	1	1	1	1
2	1	2	2	2
3	1	3	3	3
4	2	1	2	3
5	2	2	3	1
6	2	3	1	2
7	3	1	3	2
8	3	2	1	3
9	3	3	2	1

四、訊號雜訊比計算

在通訊工程常以電訊的輸出訊號(Signal)與雜訊(Noise)之比作為品質指標。因此田口博士借用此定義一訊號雜訊比(Signal to Noise Ratio)，或簡稱 S/N 比，作為衡量產品品質的一種指標。田口有效的利用直交表及 S/N 比的觀念，再加入參數設計求得一最佳參數水準。品質特性依理想機能的特性而會有不同的品質計量方式，而其 S/N 比的計算方式亦不同，以下列出常見的幾種形態：

- (一)、望小特性：對於實驗數值，如磨耗量、有害成份及噪音的音壓等，一般希望其值愈小愈好，因此這種非負值而其值愈小愈好的特性稱為望小特性。
- (二)、望大特性：在實驗中有些數值需要越大越好，例如拉力強度、黏著強度等，吾人希望其平均值越大，這種非負值而其值愈大愈好的特性稱為望大特性。
- (三)、望目特性：有時實驗希望品質特性能夠達到設定的目標，例如尺寸大小希望愈接近目標值愈好，這種希望能將結果維持在特定目標值的特性稱為望目特性。

由於本研究目的在尋找汽車故障聲訊的最佳辨識效果，辨識率當然是愈高愈好，且其最大值為 1，對於這種求其值愈大愈好的望大特性，依據田口品質計量法則，可定義如下的 S/N 比：

$$\eta = -10 \log \frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \quad (3)$$

其中

η ：為由實驗觀察值計算所得之S/N比（單位為dB）

n ：為各實驗條件重複的次數

y_i ：表示第 i 個實驗所計算出來之辨識率

五、變異數分析

田口法中的變異數分析係將總變異數區分為原因變異與誤差變異，再根據誤差基本常態基礎來檢定各因素是否在其水準之間有顯著差別之統計分析方法。首先須計算類神經網路參數變異數與誤差變異數，然後將各參數變異數除以誤差變異數，求得 F 值，再進行 F 檢定以判定各參數對網路訓練結果之影響。

田口法中係以因子效果表來區分各因子水準平均值效果的大小，進而決定各因子水準對變異數的影響程度，以預估最佳因子水準條件組合。

肆、實驗步驟及演算方法

一、引擎聲訊之收錄與處理

原始實驗主要以 GRAS 1/2 英吋壓電式麥克風(Prepolarized Free Field Microphone ,Type 40AE)，主要用來接收引擎聲訊，並以 SONY 數位攝影機(Digital 8DCR-TRV410)收錄音訊（使用範圍設定 16bits 單音、取樣頻率定為 48kHz），最後以 HP-3650A 動態訊號分析儀對收錄的聲訊輸入進行頻譜分析。

根據一般與聲訊相關之引擎故障狀況，選定三種故障設定狀況與正常狀況做比較，所設定故障分別為第三缸不點火、第三個汽門間隙過大以及風扇皮帶過鬆。實驗時將引擎設定在 1200rpm 之轉速，針對各種故障狀況收錄音訊，經上述相關資料分析處理並進行各種不同正規化處理，代入類神經網路執行訓練及辨識，最後再以田口法直交表進行實驗規劃，並透過變異數分析求出最佳參數水準組合。

引擎聲訊在經過電腦處理之前，在時域上為連續性的類比訊號，而經過 A/D 轉換器將聲訊數位化後，便以不連續性的數位形式儲存，以便處理和分析，這些訊號只在固定的時間軸刻度上有值，此稱為取樣點，兩個取樣點之時間間隔稱為取樣週期。本實驗取音框的長度為 0.8 秒來做頻譜分析，取樣頻率為 2kHz，頻率間隔為 1.25Hz，取樣點數為 1600 點。

由於引擎聲音訊號是相當龐大的，很難直接加以分析及辨識，因此將聲音訊號切成數個音框來做分析，此種過程稱之為「框化」。此外擷取音框與音框之間最好重疊至少 1/3 的音框長度，以維持聲音訊號的連續性。聲訊在截取音框時，其數位信號長度很難絕對剛好等於信號週期的整倍數，使得前一個週期波形的最後值與下一個週期得最初值之間的差異，若以波形全體來看會有失真發生。因音框隨機截取信號所造成的波形間斷每次都會不同，使得旁瓣成分的變動範圍太大，這樣的信號並不適合做分析，因此為了消除音框起點與終點接觸部分的不連續，越接近音框的兩端將相乘以可以減小權重的視窗函數。常用

的視窗函數有漢尼視窗(Hanning Window)及漢明視窗(Hamming Window)，在本實驗中則採用漢尼視窗，因為其對最大旁瓣帶能階降的 dB 值較漢明視窗為低。週期訊號函數可用傅立葉轉換函數來表示，運用傅立葉轉換之方法可將所有的數位訊號由時域轉換到頻域，來簡化處理訊號的資料量和計算處理的時間。

因實驗時收錄引擎聲訊之距離不同，使得接收音量大小有異，因此訊號由時域轉換到頻域時其頻寬之能量大小便產生差異，為了將聲訊能量調整至同一基準來做比較，吾人採用統計學中的正規化方式。其做法是先將頻譜分析儀獲得之數位訊號經電腦轉換，再利用 *MATLAB* 程式做正規化處理。正規化一般可定義為：

$$N_k = \frac{X_k}{\mu_k} \quad (4)$$

其中 X_k 是第 k 個振幅大小， μ_k 為第 k 個雜訊估計平均值。假設 Ω_k 集合為一組能被估算出 μ_k 的集合，則 Ω_k 定義為：

$$\Omega_k = (k-M, k-M+1, \dots, k+M-1, k+M) \quad (5)$$

其中 $k=2M+1$ ，為集合內的頻率成分數量。接著我們可以用最簡單的方式直接求其樣本平均值 μ_k ：

$$\mu_k = \sum_{i \in \Omega_k} \frac{X_i}{K} \quad (6)$$

假設 Ω_k 集合中僅包含雜訊，那麼估計出來的 μ_k 就是最佳的線性估計值，但若 Ω_k 的集合中出現了信號，那麼估計出來的 μ_k 就不是最佳的，其偏差值會隨著信號的增加而上升。因此在本研究中探討二種常使用的正規化方法：依序截取中值法(OTA, Order Truncate Average)及二次運算均值法(TPM, Two-Pass Mean)。

二、OTA 正規化

OTA 正規化是由 Wolcin 在 1978 年所提出，運用 OTA 正規化可將各種聲訊中的部分寬頻雜訊分量消除，僅留下窄頻雜訊，使得聲訊更容易加以辨認。OTA 正規化計算過程由下列步驟組成：

- (一)、將 Ω_k 集合中的 k 個頻率成分，依序排列為 $\{Y_1, Y_2, \dots, Y_k\}$ ，其中 Y_1 為最小、 Y_k 為最大。
- (二)、求出取樣的中間值(Median) Y_m ，剔除振幅值大於 rY_m 的頻率成份，且設定 L 為剔除後剩餘的成份數量。

(三)、根據 L 的數量求出逐次框取的平均值

$$\mu_k = \sum_{i=1}^L \frac{Y_i}{L}, Y_i = 1,2,3 \dots L \quad (7)$$

(四)、最後計算正規化後的新頻率成份值

$$N_k = \frac{X_k}{\mu_k} \quad (8)$$

通常可將 Ω_k 集合的成員數設定為 33，而 rY_m 為剔除變異值的閾值 (Threshold)，定義為：

$$\begin{aligned} rY_m &= \{MM+(2 \times SGMM)\} Y_m \\ &= \frac{1}{2} \left\{ (\pi/\ln 2)^{1/2} + 2[(4-\pi)/(4M\ln 2)]^{1/2} \right\} Y_m \end{aligned} \quad (9)$$

其中 MM (Mean to Median Ratio)為 Ω_k 集合中平均值與中間數的比值， $SGMM$ (Sigma to Median Ratio)為標準差與中間數的比值。

三、TPM 正規化

OTA 正規化雖可將聲訊中部分的寬頻雜訊分量消除，僅留下窄頻雜訊，使得聲訊更容易加以辨認，然而為比較不同正規化對辨識率之影響，因此本文另採用 TPM 正規化方式。TPM 正規化的主要步驟如下：

(一)、先利用下式求出各振幅之局部一階均值

$$\overline{X}_k = \sum_{i \in \Omega_k} \frac{X_i}{K} \quad (10)$$

(二)、將各振幅之值與 \overline{X}_k 比較

$$Y_i = \begin{cases} X_k & \text{if } X_k < T = r\overline{X}_k \\ \overline{X}_k & \text{if } X_k > T = r\overline{X}_k \end{cases} \quad (11)$$

利用下式可求出噪音平均估計值 μ_k

$$\mu_k = \sum_{i \in \Omega_k} \frac{Y_i}{K} \quad (12)$$

(三)、最後再計算正規化後的新頻率成份值

$$N_k = \frac{X_k}{\mu_k} \quad (13)$$

通常可將 Ω_k 集合的成員數設定為 33，而 $r \overline{X}_k$ 為剔除變異值的閾值 (Threshold)，定義為：

$$\begin{aligned} r \overline{X}_k &= \{1 + (C \times SGMG)\} \overline{X}_k \\ &= \{1 + C[(4/\pi) - 1]^{1/2} / \sqrt{M}\} \overline{X}_k \end{aligned} \quad (14)$$

其中 $SGMG$ (Sigma to Mean Ratio)為標準差與平均值的比值， C 值通常設定為 2。

四、類神經網路輸入參數之正規化

類神經網路的輸入參數值若太大，易使處理單元的轉換函數迅速飽和，而使處理單元失去作用。為避免此一問題，輸入資料須經正規化處理，使其介於轉換函數近似線性的區間[-0.5,+0.5]，而使處理單元能正常發揮其運算能力。類神經網路輸入參數之正規化做法為：

$$Y' = \frac{y - mean}{range} \quad (15)$$

其中

Y' ：新的輸入參數

y ：原輸入參數

$mean$ ：其個數之平均值

$range$ ：原輸入參數個數最大值與最小值之差

五、田口實驗規劃

引擎聲訊經由類神經網路特徵參數正規化後，由於每筆由 1600 個特徵參數所組成的特徵向量資料過於龐大，因此須運用統計學之標準差方式，也就是在每筆含有 1600 個特徵參數中擷取標準差最大的前 4、6、8 項，以組成類神經網路的輸入向量，最後依田口實驗規劃之直交表（如表 2 所示）代入類神經網路中進行引擎聲訊之訓練及辨識。

表 2 田口實驗規劃之直交表

實驗因子 實驗編號	輸入層單元數 A	隱藏層單元數 B	學習速率 C	學習循環次數 D
1	4	4	0.05	1000
2	4	6	0.1	2000
3	4	8	0.5	3000
4	6	4	0.1	3000
5	6	6	0.5	1000
6	6	8	0.05	2000
7	8	4	0.5	2000
8	8	6	0.05	3000
9	8	8	0.1	1000

伍、結果與討論

本節將分別說明引擎聲訊經 OTA 及 TPM 正規化處理，並利用田口直交表配置所進行之實驗結果。由實驗結果可求出 S/N 比，再進行變異數分析與 F 檢定，並找出各實驗因子對辨識率的影響程度，藉以調整實驗因子之數值，以求出網路學習最佳參數組合。

為確認並比較類神經網路結合田口法之效果，在進行田口直交表實驗之前，吾人首先對控制因子進行隨機取樣並輸入類神經網路作訓練，由結果可知所獲得之辨識率約在 35%~58% 之範圍內，其中採用 OTA 正規化之最佳辨識率為 58.3%、採用 TPM 正規化之最佳辨識率為 56.3%，由上述的實驗可初步了解不同水準之控制因子對類神經網路辨識率之影響甚鉅，可作為進行田口實驗之組合時對控制因子水準選定之基本依據。

一、OTA 正規化結合類神經網路與田口法之結果

由 OTA 正規化結合類神經網路與田口法所得的網路辨識率，可得最佳參數組合為 A3B2C1D3(辨識率為 66.7%)。接著由變異數分析及 F 檢定的結果，可知因子 A (輸入層單元數) 為影響類神經網路辨識率的最重要因素，故再針對此因子進行改善。

另 A 因子利用各個水準所得辨識率之 S/N 比隨著輸入層單元數數目的增加而增加，因此可知輸入層單元數呈現越大越好之趨勢，故將輸入層單元數數目由 8 調整至 10，再帶入最佳參數組合中做類神經網路訓練，最後可得 OTA 正規化之最佳辨識率為 68.8%。

二、TPM 正規化結合類神經網路與田口法之結果

由 TPM 正規化結合類神經網路與田口法所得的網路辨識率，可得最佳參數組合為 A3B2C2D3(辨識率為 60.4%)。接著由變異數分析及 F 檢定的結果，可知因子 A 為影響類神經網路辨識率的最重要因素，故再針對此因子進行改善。

另 A 因子利用各個水準所得辨識率之 S/N 比隨著輸入層單元數數目的增加而增加，因此可知輸入層單元數呈現越大越好之趨勢，因此將輸入層單元數數目由 8 調整至 10，再帶入最佳參數組合中進行類神經網路訓練，最後可得 TPM 正規化之最佳辨識率為 66.7%。最後可將類神經網路結合各種實驗方法所得之辨識率整理如表 3。

表 3 類神經網路結合各種實驗方法所得之辨識率

實驗方式 正規化方式	隨機選擇 因子組合	田口實驗規劃	田口實驗規劃及 變異數分析
OTA	58.3%	66.7%	68.8%
TPM	56.3%	60.4%	66.7%

由類神經網路所得辨識率，吾人發現在測試範例的總錯率曲線中，其最佳辨識率一般並非落在最終循環次數時，而是通常在其之前就已達到最低點，故在此吾將辨識率分為最佳辨識率及最終辨識率，可歸納出採用 OTA 及 TPM 正規化之最佳辨識率分別為 77.1% 及 72.9%。

陸、結論與建議

本研究在單純以隨機方式選擇各種因子組合，並輸入類神經網路訓練結果可得最佳辨識率為 58.3% (OTA 正規化) 以及 56.3% (TPM 正規化)；接著運用類神經網路配合田口直交表的方式進行實驗，以最佳參數組合所得之辨識率為 66.7% (OTA 正規化) 以及 60.4% (TPM 正規化)，其辨識率較前述隨機選擇因子組合之最佳辨識率分別提昇了 8.4% 以及 4.1%。

若再將類神經網路配合田口法的實驗結果，透過變異數及 F 檢定的分析，發現輸入層單元數為影響辨識率最重要的因素。再針對輸入層單元數進行改善後，可得最佳參數組合之辨識率為 68.8% (OTA 正規化) 與 66.7% (TPM 正規化)。由此可證明以類神經網路結合田口法並配合變異數分析及 F 檢定的確可有系統的分析控制因子對訓練效果的影響，進而針對重要的控制因子調整其控制水準，其最後之辨識率較隨機選擇因子組合之最佳辨識率皆分別提昇了約 10%。

本研究中所採用的 OTA 及 TPM 聲訊正規化的方式，由類神經網路訓練的結果可發現，採用 OTA 正規化所得之辨識率較採用 TPM 正規化之辨識率稍佳，惟其差距僅 2.1%，影響並不顯著。本研究證實以類神經網路結合田口法之實驗，確能有系統且快速的找到最佳參數組合，並可大幅減少實驗時間；而利用田口的變異數分析，更可找出影響辨識效果之最重要因子（即輸入層單元數），接著再針對輸入層單元數進行調整後，可改善類神經網路之辨識效果。

田口法雖然可有系統快速地找到最佳辨識率之控制因子組合，惟本研究之最佳辨識率仍有提昇的空間。未來應更廣泛地將訓練範例數量、測試範例數量等其它控制因子一併納入考量，再逐步將研究範圍縮減到最重要的幾個因子，以有效提昇辨識率。此外，由於所使用之類神經網路應用程式之限制，因此在網路訓練過程中，對於參數之設定有諸多限制，進而影響了可實驗之範圍，所以若能針對引擎聲訊及類神經網路之特性自行開發適當的應用程式，將可獲得更佳的類神經網路學習效果。在實驗方面，若能使用更精密之儀器進行實驗，將可獲得更精確、完善之數據，並有利於辨識率之提昇。

柒、參考文獻

1. 邱垂霖 (2001)。以聲音訊號為特徵輸入之類神經診斷系統。國立臺北科技大學機電整合研究所碩士論文，未出版，台北。

2. 洪振益、林博正、湯恩溶（2000）。類神經網路應用於小型軸流風扇葉片設計。《機械月刊》，第二十六卷，第十二期，390-399。
3. 陳建源（1996）。類神經網路應用於感應機聲訊之辨識。國立中山大學電機工程研究所碩士論文，未出版，高雄。
4. 黃信豪（1996）。機器故障偵測利用訊號處理與式樣辨識技術。《雲林工專學報》，第十五卷，151-160。
5. 曹大鵬（1996）。類神經網路在馬達聲訊辨識上之應用。《國科會研究計畫報告》，NSC86-2213-E-110-014。
6. 莊凱斌（2001）。以倒傳遞類神經網路進行聲音辨識之監視系統。國立臺灣科技大學電機工程研究所碩士論文，未出版，台北。
7. 晉鳳山（2002）。改良式倒傳遞類神經網路之研究。《測驗統計簡訊》，第四十七卷，28-34。
8. 葉怡成（2001）。類神經網路模式應用與實作。台北：儒林圖書。
9. Arai, K., Shimodaira, H., Sakaguchi, Y., and Nakano, K. (1991). Application of Neural Computation to Sound Analysis for Valve Diagnosis," *IJCNN*, 91 I, 177-182.
10. Lowe, D., and Zapart, K. (1997). *Validation of Neural Networks In Automotive Engine Calibration*, Pro.IEE Int Conf. Artificial Neural Network, No.440, 221-226.
11. Marko, K. A., Feldkamp, L. A., and Puskorius, G. V. (1990). Automotive Diagnostics Using Trainable Classifiers: Statistical Testing and Paradigm Selection, *IJCNN*, 90 I, 33-38.
12. Marko, K. A., James, J., Dossdall, J., and Murphy, J. (1989). Automotive Control System Diagnosis Using Neural Nets for Rapid Pattern Classification of Large Data Sets, *IJCNN*, 89 II, 13-16.
13. Schwarte and Iserman, R. (2002). *Neural Network Applications for Model Based Fault Detection with Parity Equations*, 15th Triennial World Congress, Barcelona, Spain.
14. Shayler, P. J., Goodman, M., and Ma, T. (2000). The exploitation of neural networks in automotive engine management systems, *Engineering Applications of Artificial Intelligence*, 147-157.

An Application of Artificial Neural Network and Taguchi's Method on Engine Fault Noise Recognition

Hsiao-Tseng Lin^{*}, Chih-Chung Kao^{**}, Kuan-Chung Pan^{***}, Hui-Zen Yie^{****}

Abstract

Due to the improvement of modern technology, the detecting of vehicle engine's faults can be achieved by computer. However, computer can't detect the noise resulting from the abnormalities of mechanical parts. The objective of this research is to combine artificial neural network and Taguchi's method to construct an engine fault recognition system. It is expected to detect the abnormalities of engine before it breakdowns, and to assist mechanical technicians to identify the origin of the problem.

This research, constructed by artificial neural network and Taguchi's method, is to identify different engine fault noises by network learning process. For noise signal normalization, OTA and TPA methods are used. In the construction of artificial neural network model, number of input layer, number of hidden layer, learning rate and learning cycle number are chosen as control factors. Taguchi's orthogonal array is then used to conduct the calculations in different levels. Signal to noise ratio, analysis of variance, and F-test are applied to analyze the effect of different control factors on the engine fault recognition rate, and to accomplish optimum combination for relevant control factors. The best fault recognition rate achieved in this work is 77.1%.

Keywords: Neutral Network, Taguchi's Method, Engine Noise

^{*} Associate professor and Chair, The Department of Information Management, Meiho Institute Of Technology

^{**} Assistant professor, The Department of Information Management, Fortune Institute Of Technology

^{***} Lieutenant, Navy General Headquarters, Department of Defense

^{****} Teacher, National Cishan Agricultural and Industrial Vocational Senior High School

