

倒傳遞類神經網路用於裝備故障診斷-以某防空火砲為例

鄧世剛¹ 林聖義^{2*}

¹國防大學理工學院動力暨系統工程學系

²國防大學理工學院國防科學研究所

摘 要

本研究運用倒傳遞類神經網路(Back-Propagation Neural Network, BPN)，建立國軍某防空火砲故障診斷模型，過程中並針對單一輸出、多輸出等兩種網路結構進行探討，分別進行訓練函數、隱藏層神經元數等相關參數選擇，據以進行後續模型訓練與測試。實驗結果顯示，BPN 用於防空火砲故障診斷具有相當優異的診斷準確率，且多輸出網路架構比單一輸出網路架構更適用於故障診斷問題。

關鍵詞：倒傳遞類神經網路，故障診斷，防空火砲

Fault Diagnosis Based on Back-Propagation Neural Network – A Case Study of Anti-air Gun

S. Deng¹ and Seng-Yi Lin^{2*}

¹ Department of Power Vehicle and Systems Engineering, Chung-Cheng Institute of Technology, National Defense University

² School of Defense Science, Chung-Cheng Institute of Technology, National Defense University

ABSTRACT

We use the Back-Propagation Neural Network (BPN) algorithm to deal with the fault diagnosis problem, and present a case study of anti-air gun in this research. The Neural Network technique can be used to solve complex and nonlinear problems, and can be apply to establish the fault diagnosis models for different equipments rapidly. We construct two different structures of networks (single output and multiple outputs) to perform the BPN fault diagnosis systems, and discuss the efficiency of faults detection about these two models. The result shows that the performance of anti-air fault diagnosis system based on BPN is good, and the structure of network with multiple outputs is more suitable for fault diagnosis problems.

Keywords: back-propagation neural network, fault diagnosis, Anti-air Gun

一、前言

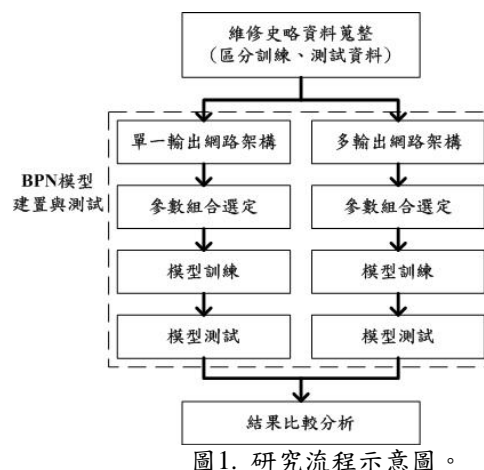
當裝備失去既定功能時，找出故障原因(元件)並加以檢修(更換)，是恢復裝備妥善正常的不二途徑，而如何快速找出故障原因(即所謂故障診斷)就成了裝備修護領域上一個相當重要課題。故障診斷主要目的，就是依據裝備操作時可獲得的各種資訊，來推斷出特定的故障位置或者故障發生時間[1]。其方法大致上可分為二類，即傳統故障診斷方法與智能診斷技術。傳統診斷方法係仰賴修護人員的專業知識及經驗，借助三用電表及示波器等簡單儀器執行修護，採用邏輯推理的方式，尋求故障的因果關係，此過程不僅耗時費力，更仰賴修護人員的素質。一般而言，技術人員須經長時間培養而成，然而技術純熟後卻因陞遷、離職或退休等情況，致使所累積的經驗及知識流失，造成後續裝備維修資源運用上的損失。

為降低人為因素對裝備修護的影響，促成了智能診斷技術成為現今故障診斷系統發展主流。Weiner等學者[2]使用案例推理儲存故障管理的經驗，協助操作人員在發現新故障時，從中擷取相似現象加以比較；Yang等學者[3]利用案例推導結合派屈網路(Petri nets)技術，用於馬達故障診斷；Kramer[4]使用模糊推論的方法，建構一個以規則庫為基礎的專家系統，應用於化學工廠的故障診斷，獲得良好的診斷效果；Chen等學者[5]以及Assaf等學者[6]則是運用決策樹分析方法，產生故障判斷依循規則，據以執行故障診斷；Bose等學者[7]將資料採礦技術運用於軟體故障診斷，而Hou等學者[8]則是將資料採礦技術用於空調設備故障診斷。上述智能診斷方法都比較偏向故障規則分析歸納與管理，雖然都有不錯的成效，但當遇到系統規則庫擴充時，規則間容易會有相互矛盾現象的產生，而不容易管理[9]，而且所能診斷的故障現象，僅限於規則庫中所列，若遭遇未曾發生的故障，即無法予以診斷，缺乏學習與預測的能力[10]。此外，此類專家系統無法隨著維修資料變異快速變更或調整，因此無法快速運用到不同裝備。

類神經網路技術透過學習訓練的過程對資料特性產生相當程度的記憶，面對未知的資料時，則進行回想推論的動作，所以此種智

能故障診斷並不是針對故障規則進行分類歸納，不會產生前述規則衝突或不易管理的問題；且神經網路針對不同類型資料形態，經過適當網路架構規畫與參數選擇後，就能很容易地建置故障診斷模型，所以可以快速運用在不同裝備；此外，類神經網路技術具有處理高度非線性問題的能力，適合處理大型、複雜的問題，近年來已被廣泛地運用在故障診斷問題。例如，Li 等學者[11]應用於馬達轉子故障偵測；Vemuri 等學者[12]運用在機器人系統故障診斷；而 Lu 等學者[13]則是運用在引擎故障診斷；Patan [1, pp.141-182]在 2008 年編彙神經網路技術應用於故障診斷問題專書，詳細介紹不同類型故障診斷問題以及各種適用之神經網路技術，並列舉在工業領域上的成功應用，例如應用在製糖工廠、液體分餾過程以及直流馬達檢測等。

本文則是以某防空火炮裝備為實例，運用倒傳遞類神經網路(Back-Propagation Neural Network, BPN)進行裝備故障診斷，研究重點是故障位置推斷(不包含故障時間訊息)，研究目的是當診斷模型建立後，我們只要輸入一組量測資料值，即可快速有效地判斷相對應的故障類別。我們除驗證BPN故障診斷模型用於防空火炮裝備可行性，研究中並探討兩種不同的BPN網路架構(單一輸出與多輸出)，分別找出最適合的參數設定，個別建立最佳BPN故障診斷模型並測試，最後針對此兩種網路架構模型效能加以比較分析(研究流程簡述如圖1)。經實驗結果顯示，BPN用於防空火炮故障診斷具有相當優異的診斷準確率，且多輸出BPN網路架構花費時間短、診斷準確率高，比單輸出BPN網路架構更適合用在故障診斷問題。



二、倒傳遞類神經網路

2.1 倒傳遞類神經網路(BPN)

倒傳遞類神經網路(BPN)學習算法係屬於監督式學習多層式網路，網路架構包括輸入層(Input Layer)、隱藏層(Hidden Layer)以及輸出層(Output Layer)，BPN 運算目的是在使誤差函數最小化，運算時會重覆執行前向傳遞、誤差計算以及誤差遞迴等步驟，直到滿足收斂停止條件前(BPN 架構示意圖如圖 2)。BPN 運算流程說明如下 [14-16]：

(一)輸入層每個神經元(x_i)乘上權重(v_{ji})，加總後透過傳遞函數(f)計算，得到每一個隱藏層神經元輸出(y_i)。

$$y_i = f(\text{net}_j = \sum_{i=1}^M v_{ji} x_i) \quad (1)$$

(二)每一個隱藏層神經元輸出(y_i)乘上權重(w_{kj})，加總後透過傳遞函數(f)計算，得到輸出層神經元輸出(O_k)。

$$O_k = f(\text{net}_k = \sum_{j=1}^N w_{kj} y_j) \quad (2)$$

(三)定義誤差函數(E)(如 Eq.3)，BPN 演算法主要目的即在使誤差函數最小化。另此階段並計算網路輸出值(O_k)與期望值(d_k)之間的誤差，若尚未滿足終止條件則準備進行誤差遞迴。

$$E = \frac{1}{2} \sum_{k=1}^L (d_k - O_k)^2 \quad (3)$$

(四)利用梯度下降法，調整更新隱藏層至輸出層之權重(w_{kj}) (如 Eq.4)，其中 η 稱為學習速率。

$$w_{kj} = w_{kj} + \Delta w_{kj} = w_{kj} - \eta \frac{\partial E}{\partial w_{kj}} \quad (4)$$

(五)調整更新輸入層至隱藏層間的權重(v_{ji})。

$$v_{ji} = v_{ji} + \Delta v_{ji} = v_{ji} - \eta \frac{\partial E}{\partial v_{ji}} \quad (5)$$

(六)不斷重覆計算步驟(一)至(五)，直到使誤差函數最小化或滿足停止條件。




圖 2. BPN 網路架構。

2.2 BPN 運算參數選擇與設定

建置 BPN 模型時有許多參數必須決定，而參數選擇合適與否，直接影響到模型的效能。針對 BPN 相關參數設定選擇簡述如下：

(一)隱藏層層數與神經元數量選擇：目的在決定處理問題時非線性映射的維度。

(二)傳遞函數選擇：BPN 常用的傳遞函數有三種，一是可將數值調整至 1 與 0 之間的對數型 sigmoid 函數；一是可將數值調整至 1 與 -1 之間的雙曲正切 sigmoid 函數；最後一種則是可輸出任意值的線性傳遞函數(如圖 3 所示)。

(三)學習停止條件：包含 MSE 目標值、迭代次數、最小允許坡降梯度等。

(四)學習速率：可決定學習速度與收斂狀況。

(五)連結權重與偏權值得初始值設定。

(六)訓練函數：標準 BPN 訓練函數是梯度下降法，其權重值更新是沿著誤差性能函數的負梯度方向進行。隨著處理問題的多樣性與複雜性以及 BPN 本身存在的缺點(例如學習慢、易陷入局部最小值等)，已陸續發展出許多改進的訓練函數，本研究共列出 7 種改良過的訓練函數[17]，準備依序進行實驗，並從實驗結果挑選出最適合的訓練函數。簡述如下：

1. 最陡坡降 BP 算法(Steepest Descent Back-Propagation, SDBP)：此訓練函數係使用透過梯度下降與學習率計算下一個迭代之更新值 $x(k+1)$ 。

$$x(k+1) = x(k) - \alpha \cdot g(k) \quad (6)$$

$x(k)$ 代表第 k 次迭代各網路層間的連結向量或偏移值向量； $g(k)$ 代表梯度向量，負號表示呈現反向梯度，意即梯度的最速下降方向； α 為一學習速率常數。

2. 動量 BP 算法 (MOmentum Back Propagation, MOBP)：以梯度下降法為基礎，並且導入動量因子，此因子會影響網路計算誤差時修正幅度。
3. 變動學習率 BP 算法 (Variable Learning rate Back-Propagation, VLBP)：此訓練函數係以最速下降倒傳遞法為基礎，在訓練過程中學習率會隨之變動，使網路計算沿著誤差終止條件進行修正。
4. 彈性 BP 算法 (Resilient back PROPagation, RPROP)：此訓練函數目的在於去除梯度幅度對權重值更新之不利影響，權重值更新取決於與幅度無關聯性的修正值。
5. 共軛梯度 BP 算法 (Conjugate Gradient Back-Propagation, CGBP)：此算法係沿著共軛方向進行更新網路權重，在每一次迭代進行時調整權重值長度 (即步長大小)，使網路函數可沿此方向來達到誤差最小化。此類算法中較具代表性為比例共軛梯度 (Scaled Conjugate Gradient Back-Propagation, SCGBP) 算法。
6. 擬牛頓法 (Quasi-Newton Algorithms)：牛頓法係以二階泰勒級數為基礎之快速最佳化訓練函數。

$$x(k+1) = x(k) - A^{-1}(k) \cdot g(k) \quad (7)$$

其中 $A(k)$ 為海森 (Hessian) 矩陣，即誤差性能函數在目前權重值與偏移值的二次微分，海森矩陣計算複雜並耗時較高，所以此算法較費時。其中應用較成功的為 BFGS (Broyden, Fletcher, Goldfarb, and Shanno) 修正算法。

7. Levenberg-Marquardt (LM) 算法：LM 算法與擬牛頓法概念相近，差別在運算時避免計算海森矩陣，而將海森矩陣逼近來使用，以節省運算時間。




圖 3. BPN 常用傳遞函數。

三、裝備簡介與維修資料蒐整

本文所選定之故障診斷裝備為某低空防禦火炮，它與雷達車、地對空飛彈共同組成一套低空防禦系統，擔任守護機場低空防衛的重責大任。此型火炮配屬乙部電源機採電動操作，裝備區分為上、下架二大部分，下架包含拖曳輪組及液壓系統，提供火炮機動能力與射擊放列、姿態變換；上架則包含伺服系統、裝填系統與機砲，是火炮進行目標追隨、進彈、射擊的重要元件 (功能方塊圖如圖 4)。當火炮接收雷達車送來的攻擊目標資訊後，本身工作流程依序為 (1) 電源機啟動、送電 (2) 火炮送電 (3) 液壓系統放列 (4) 裝填系統送彈 (5) 伺服系統進行目標追隨 (6) 火炮射擊等，當某一個步驟無法正常工作時，火炮即無法完成既定射擊任務。上述各工作階段發生故障狀況時，會導致裝備部分檢測點電壓值或燈號顯示異常，傳統故障檢修係仰賴修護人員依據所量測到的數據進行故障判斷，人員經驗、素質影響修護成效甚巨，因此要建立一套人工智能診斷系統，當故障發生時只需要將各量測點數據輸入，即可快速準確地進行故障原因判斷，排除人為因素並能夠更快速的完成故障排除，恢復裝備妥善。

依據操作維修經驗並參考維修史略，針對較常發生故障狀況的 (1) 電源機啟動、送電 (2) 火炮送電 (3) 液壓系統放列 (4) 裝填系統送彈 (5) 伺服系統進行目標追隨等五個工作階段，共計歸納出「交流發電機」等 19 類常見故障原因 (如表 1)，作為本研究故障診斷標的。為能有效判別上述 19 類故障，並找出相關的檢測點共 20 個 (如表 2)，可量測得電壓值或顯示燈號狀態，藉由一組資料 (20 個量測值) 可以對應到 19 類常見故障中的某一類。

本文蒐整近五年來維修史略資料，參考比對裝備維修手冊，將錯誤或記載不齊全之資料刪除後，針對上述 19 類故障獲得維修資料共計

240筆，每一筆資料維度為 20×1 ，並對應到某一類的故障。為了因應後續單一輸出與多輸出兩種網路結構模型實驗使用，在輸出值部分需預先處理。單一輸出部分，直觀地用數值1至19來表示，維度是 1×1 ；多輸出部分，則用二進位表示法來涵蓋19類故障，維度是 5×1 ，例如[00001]代表第1類，而[10011]代表第19類(兩種網路結構輸出對應值詳如表3)。本研究除探討用BPN建立防空火砲裝備故障診斷模型可行性外，另一個重點即是要探討比較兩種網路結構診斷模型效能，分別是20-X-1(單輸出)網路結構以及20-X-5(多輸出)網路結構，其中X代表待決定之隱藏層神經元數量。

資料蒐整最後階段，就是將資料分為訓練用以及測試驗證用。然而在學習過程中，為了保證BPN識別故障類型的可靠性和有效性，被選擇用來學習的資料必須包含故障狀況所有變化[18]。基於上述學習原理，在能涵蓋所有故障變化前提下，隨機選出訓練資料200筆，用來當成訓練資料建立BPN故障診斷模型；而剩餘未參與訓練的40筆資料，則用來測試驗證模型的故障診斷能力。

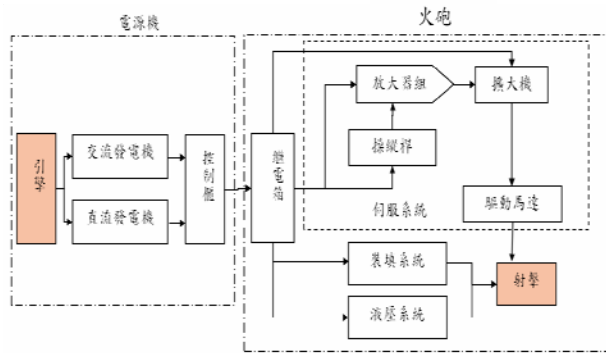


圖4. 防空火砲功能方塊圖。

表1. 19類故障名稱

編號	故障元件(原因)	編號	故障元件(原因)
F1	電源機交流發電機	F11	A9 放大器
F2	電源機直流發電機	F12	操縱桿(迴旋)
F3	電源機控制櫃	F13	A1 放大器
F4	火砲繼電箱	F14	B1 放大器
F5	火砲主控箱	F15	M1 磁力擴大機
F6	火砲主電纜箱	F16	操縱桿(俯仰)
F7	自動裝彈機繼電器	F17	A2 放大器

F8	自動裝彈機電動馬達	F18	B2 放大器
F9	液壓馬達控制器	F19	M2 磁力擴大機
F10	液壓馬達		

表2. 各檢測點正常顯示範圍

檢測點代號	名稱	正常值
TP1	AC Voltage Gate	110VAC \pm 10V
TP2	DC Voltage Gate	220VDC \pm 20V
TP3	PSU Output Point	220VDC \pm 20V
TP4	Gun Input Point	220VDC \pm 20V
TP5	Psu Ready	亮燈
TP6	Psu On	亮燈
TP7	Gun On	亮燈
TP8	Gun Ready	亮燈
TP9	Operation meter	400HZ \pm 10%
TP10	Electronic Motor Input	220VDC \pm 20V
TP11	Hydraulic Motor Input	220VDC \pm 20V
TP12	Amplifier Voltage Gate	280VDC \pm 30V
TP13	Joystick 1 Output	\pm 15V
TP14	Amplifier A1 Output	\pm 30V
TP15	Amplifier B1 Output	\pm 60V
TP16	Metadyne 1	\pm 300V
TP17	Joystick 2 Output	\pm 15V
TP18	Amplifier A2 Output	\pm 30V
TP19	Amplifier B2 Output	\pm 60V
TP20	Metadyne 2	\pm 300V

表3. 輸出值預處理

編號	單輸出	多輸出	編號	單輸出	多輸出
F1	1	00001	F11	11	01011
F2	2	00010	F12	12	01100
F3	3	00011	F13	13	01101
F4	4	00100	F14	14	01110
F5	5	00101	F15	15	01111
F6	6	00110	F16	16	10000
F7	7	00111	F17	17	10001
F8	8	01000	F18	18	10010
F9	9	01001	F19	19	10011
F10	10	01010			

四、建置 BPN 故障診斷模型

4.1 參數選擇

在前一章已說明建構 BPN 模型所需選定的參數，而參數選擇實是模型建置成功與否最大關鍵，每一項參數選定對模型效能都有相當大影響，需謹慎考量評估。在開始為兩種網路結構 20-X-1 以及 20-X-5 選擇參數前，先將眾多參數分成兩大類，一是依據原理、經驗、資料特性以及輸出要求等，即可推論決定的一般參數如隱藏層層數、傳遞函數以及停止條件等，另一類是需靠實驗結果來決定，如訓練函數以及隱藏層神經元數量等兩種參數。以下依序針對各參數選定進行探討。

4.1.1 一般參數選擇

- (一) 隱藏層層數：對一般問題而言，若隱藏層神經元數量可調整，那麼三層 BPN 網路架構(單隱藏層)已可進行任意的非線性映射[19]。所以我們在 20-X-1 以及 20-X-5 等兩種網路架構都使用單隱藏層，置重點於後續隱藏層神經元數量調整選擇。
- (二) 傳遞函數：由於輸入資料範圍相當大，為了方便將範圍縮小到 1 與 0 之間，所以隱藏層傳遞函數選擇對數型 sigmoid 函數，至於輸出層傳遞函數則因網路結構有所不同，20-X-1 結構因只為有一個輸出，為使其輸出能任意逼近數值 1 至 19，所以選擇線性傳遞函數；20-X-5 結構有 5 個輸出，範圍在 0 至 1 之間，所以選用對數型 sigmoid 函數。
- (三) 學習停止條件：為避免產生過度訓練情形，本研究並用三種學習停止條件，相關參數訂定說明如下：
 - (1) MSE 目標值：不論是 20-X-1 或者 20-X-5 網路架構，我們針對輸出值會先進行四捨五入運算後，才能得到輸出類別結果。舉例來說，20-X-1 網路輸出 13.2213 即判定為第 13 類，輸出 2.9985 即判定為第 3 類；20-X-5 網路輸出值[0.0024, 0.0031, 0.0145, 0.0069, 0.9877]即判定為[0 0 0 0 1](第 1 類)。由於使用四捨五入運算，因此輸出值小數點後第 2 位數影響已相當小，因

此本文 MSE 目標值在合理範圍內選定為 0.05。

- (2) 迭代次數：為訂定合理迭代次數，本研究嘗試做了一些先期試驗，發現 20-X-5 網路架構大約都在迭代 1000 次內即可達到 MSE 小於 0.05 條件，而 20-X-1 網路架構大約要 10000 次才可達到前述條件。為便於觀察比較兩種網路結構收斂情形，迭代次數均定為 5000 次。
- (3) 坡降梯度值：訓練過程中，當坡降梯度值小於 10^{-6} 時，不論是否達到前述兩條件訓練皆終止。
- (四) 學習速率：初始設定為 0.01，後續隨使用的訓練函數不同而調整。
- (五) 權重向量與偏權值初始值均設定為 0。

4.1.2 訓練函數選擇實驗

首先依照一般經驗將隱藏層神經元數量暫訂為輸入維度的兩倍 0，因此兩種網路結構分別是 20-40-1 以及 20-40-5，依序使用不同訓練函數進行訓練並測試(試驗結果如附錄 1 以及附錄 2)。從實驗數據可以明顯看出，不論哪種網路結構，表現最佳的訓練函數都是比例共軛梯度算法 (Scaled Conjugate Gradient Back-Propagation, SCGBP)，因此將其選定為本研究兩種網路結構模型所要用的訓練函數，並進行後續實驗。

4.1.3 隱藏層神經元數量選擇實驗

訓練函數選定後接著進行神經元數量選擇實驗，運用網路增長以及網路刪減原理，以經驗數量 40 為中心依序增長與刪減，實驗範圍在 35 至 46 之間，每種神經元數量進行 3 次實驗，20-X-1 網路結構實驗結果如附錄 3，可看出最適合的神經元數量為 41，因此後續模型訓練測試時即使用 20-41-1 網路結構；20-X-5 網路結構實驗結果如附錄 4，可看出最適合的神經元數量為 40，因此後續模型訓練測試時即使用 20-40-5 網路結構。

4.1.4 參數選擇小結

研究至此已完成兩種網路結構所有參數選定，在進入下一階段模型訓練驗證前，先將所有參數設定做一綜整(如表 4)。實驗結果中出現一些值得探討的現象，綜述討論如下：

- (一) 大部分參數可以依據原理、經驗、資料特性以及輸出要求等，即可推論決定，例如隱藏層層數；而有些參數則需靠重複實驗來獲得，例如訓練函數。
- (二) 不論何種網路結構，使用不同訓練函數產生的結果差異相當大。在不同案例資料下，最適訓練函數的選擇，取決於很多因素，例如資料複雜性、訓練樣本數量、誤差目標、網路用途等，所以需要花時間重複實驗才能得到最適結果，不宜貿然選用。
- (三) 在訓練函數選擇實驗中，兩種網路結構都可發現使用 RPROP 算法是最節省時間的，但診斷準確率並不理想；兩種網路結構使用 LM 算法都花費相當多時間，這是因為此算法要求精度較高(計算海森矩陣逼近值)，所以遇到像本案例問題較複雜時，自然會花費大量計算時間；SCGBP 算法的時間花費與診斷準確率，不論在單輸出、多輸出網路結構，皆有相當不錯表現。有些訓練函數坡降梯度很快到達停止條件(例如 20-40-1 網路結構使用 MOBP 算法)，但訓練誤差卻無法收斂，此類算法則不適用於本案例。
- (四) 從隱藏層神經元實驗結果可看出，兩種網路結構隨著神經元數量從 35 增長至 46，不論是 MSE 值、迭代次數、花費時間或診斷準確率，皆無法歸納出明顯的收斂趨勢，各種數量神經元實驗結果差異不大。關於此現象我們可以就學理上來探究其原因，因為隱藏層神經元數量，代表著問題處理時所映射的維度，而本案例輸入層維度已相當高(20 個神經元)，而不論 20×35 的維度或者 20×46 的維度，基本上都足以處理本案例訓練資料，這也就是實驗結果無法歸納出明顯收斂趨勢的主因。另一方面，也間接驗證了前述使用的經驗法則——隱藏層神經元數量定為輸入層神經元數量的 2 倍(即 40 個)，確實也適用於本案例。

表 4. 兩種網路結構參數設定表

參數名稱	網路結構	
	參數內容	
隱藏層數量	20-X-1 網路	20-X-5 網路
隱藏層傳遞函數	1	1
輸出層傳遞函數	對數型 sigmoid	對數型 sigmoid
MSE 目標值	線性	對數型 sigmoid
迭代次數	0.05	0.05
坡降梯度下限	5000	5000
學習速率初始設定	10^{-6}	10^{-6}
初始連結權重	0.01	0.01
初始偏權值	0	0
訓練函數	0	0
隱藏層神經元數量	SCGBP	SCGBP
	41	40

4.2 模型訓練與測試

依據選定的參數，開始進行模型訓練與測試。為客觀地觀察 BPN 模型在同樣輸入參數以及相同的訓練、測試資料條件下，其訓練結果以及預測準確率變異，在此規劃兩種網路架構分別進行 10 次實驗。20-41-1 網路實驗結果如表 5，20-40-5 實驗結果如表 6。從實驗數據可初步看出，20-40-5 所建立的故障診斷模型，不論在花費時間以及故障診斷準確率上，都具有比較優異的表現。

表 5. 20-41-1 網路訓練與測試實驗結果

實驗項次	1	2	3	4	5
迭代次數	5000	5000	5000	5000	5000
花費時間	76 秒	76 秒	75 秒	75 秒	75 秒
MSE	0.0733	0.0738	0.0743	0.0823	0.0943
準確率	92.5%	92.5%	90%	82.5%	90%

實驗項次	6	7	8	9	10
迭代次數	5000	5000	5000	5000	5000
花費時間	76 秒	76 秒	75 秒	73 秒	76 秒
MSE	0.0806	0.0818	0.0986	0.0737	0.0884
準確率	90%	87.5%	97.5%	82.5%	85%

平均迭代次數	5000
平均花費時間	75.3 秒
平均 MSE	0.0821
準確率平均值	89.00%
準確率標準差	4.74%

表 6. 20-40-5 網路訓練與測試實驗結果

實驗項次	1	2	3	4	5
迭代次數	270	283	538	397	584
花費時間	6 秒	6 秒	10 秒	8 秒	10 秒
MSE	0.0499	0.0499	0.0499	0.0499	0.0499
準確率	97.5%	92.5%	95%	97.5%	90%
實驗項次	6	7	8	9	10
迭代次數	380	415	286	604	267
花費時間	7 秒	8 秒	6 秒	10 秒	5 秒
MSE	0.0499	0.0499	0.0499	0.0499	0.0499
準確率	90%	90%	95%	90%	95%
平均迭代次數	402.4				
平均花費時間	7.6 秒				
平均 MSE	0.0499				
準確率平均值	93.25%				
準確率標準差	3.13%				

4.3 結果比較與分析

從表 5 與表 6 實驗結果可明顯看出，在相同的訓練、測試資料條件下，20-40-5 網路結構模型平均預測準確率較高(93.25%)且變異較小(3.13%)，明顯優於 20-41-1 網路結構模型(89.00%，4.74%)。此外，20-40-5 網路結構模型平均僅需花費時間 7.6 秒，平均迭代 402.4 次，即可達到 MSE=0.05 收斂條件，相較於 20-41-1 網路結構模型迭代 5000 次，平均花費時間 75.3 秒，仍無法達到 MSE=0.05 收斂條件，可看出 20-40-5 網路結構模型學習收斂效率遠優於 20-41-1 網路結構模型。整體而言，就本案例故障診斷，運用多輸出網路結構(20-40-5)整體效能優於單輸出網路結構(20-41-1)。

五、結論

本文利用防空火炮維修資料，成功地用 BPN 建立高效能的故障診斷模型，過程中並探討多輸出網路結構(20-40-5)與單輸出網路結構(20-41-1)在故障診斷的適用性。綜述研究結論如下：

- (一) 以 BPN 建立防空火炮故障診斷模型，經驗證具有相當高的診斷準確率。
- (二) 多輸出網路結構(20-40-5)故障診斷模型，其診斷準確率較高，且模型建置花費時間較短，整體而言效能優於單輸出網路結構(20-41-1)。

- (三) 參數的選擇，關係到模型訓練成敗，需謹慎為之。部分參數可以依據原理、經驗、資料特性以及輸出要求等即可推論決定，而有些參數則需靠重複實驗來獲得，例如本案例中，經實驗選出的最適訓練函數為 SCGBP 訓練函數。
- (四) 單隱藏層 BPN 網路已足夠處理本案例問題；至於隱藏層神經元數量，常用的經驗法則(輸入層神經元數量的兩倍)亦適用於本案例。
- (五) 研究過程中，依序進行資料蒐整、網路結構選定、參數選擇、訓練與測試等步驟，此一流程極適合推展至不同裝備建立 BPN 故障診斷模型使用。

參考文獻

- [1] Patan, K., Artificial Neural Networks for the Modeling and Fault Diagnosis of Technical Processes, Springer, Chap. 1, pp. 8, 2008.
- [2] Weiner, A.J., David, A.T., and Christine, M.M., "Applying Case-Based Reasoning to Aid Fault Management in Supervisory Control", IEEE International Conference on Systems, Vol. 5, pp. 4213-4218, 1995.
- [3] Yang, B.S., Jeong, S.K., and Oh, Y.M., "Case-based reasoning system with Petri nets for induction motor fault diagnosis," Expert Systems with Applications Vol. 27, pp.301-311, 2004.
- [4] Kramer, M.A., "Malfunction Diagnosis Using Quantitative Models with Non-Boolean Reasoning in Expert Systems," American Institute of Chemical Engineers Journal, Vol. 33, No.1, pp. 130-140, 1987.
- [5] Chen, M., Alice, X.Z., Lloyd, J., Jordan, M., and Brewer, E., "Failure Diagnosis Using Decision Trees", Proceedings of the International Conference on Autonomic Computing, IEEE, 2004.
- [6] Assaf, T., and Dugan, J.B., "Diagnostic Expert Systems from Dynamic Fault Trees," RAMS, IEEE, pp.444-450, 2004.
- [7] Jagadeesh, R.P., and Srinivasan, S.H., "Data Mining Approaches to Software Fault Diagnosis," Proceedings of the 15th International Workshop on Research Issues in Data Engineering: Stream Data Mining

- and Applications, IEEE, 2005.
- [8] Hou, Z., Lian, Z., Yao, Y., and Yuan, X., "Data mining based sensor fault diagnosis and validation for building air conditioning system," *Energy Conversion and Management* Vol. 47, pp.2479-2490, 2006.
- [9] Thomas, F.P., Klein, J., and Dhurjati, P.S., "Diagnostic Model Processor: Using Deep Knowledge for Process Fault Diagnosis," *American Institute of Chemical Engineers Journal*, Vol. 36, No. 4, pp. 565-575, 1990.
- [10] Surma, J., and Braunschweig, B., "Case-Based Retrieval in Process Engineering: Supporting Design by Reusing Flowsheets," *Engineering Applications of Artificial Intelligence*, Vol. 9, No. 4, pp. 385-391, 1996.
- [11] Li, B., Chow, M.Y., Tipsuwan, Y., and Hung, J.C., "Neural Network Based Motor Rolling Bearing Fault Diagnosis," *IEEE Transactions on Industrial Electronics*, VOL. 47, NO. 5, pp.1060-1069, 2000.
- [12] Vemuri, A.T., and Polycarpou, M.M., "Neural Network Based Robust Fault Diagnosis in Robotic Systems," *IEEE Transactions on Neural Networks*, VOL. 8, NO. 6, pp.1410-1420, 1997.
- [13] Lu, P.J., Zhang, M.C., Hsu, T.C., and Zhang, J., "An Evaluation of Engine Faults Diagnostics Using Artificial Neural Networks." *Transactions of the ASME* Vol. 123, pp.340-346, 2001.
- [14] Haykin, S., Neural Networks – A Comprehensive Foundation 2nd Edition, Prentice Hall, Chap. 4, pp.178-274, 1999.
- [15] Lippmann, R.P., "An Introduction to Computing with Neural Nets". *IEEE ASSP Magazine*, pp. 4-22, 1987.
- [16] Hagan, T., Demuth, H., and Beale, M., Neural Network Design, PWS Publishing Company, Chap.11, pp.1-26, 1996.
- [17] 周開利、康耀紅，神經網路模型及其MATLAB仿真程序設計，清華大學出版社(北京)，第5章，第70-83頁，2006。
- [18] 葛哲學、孫志強，神經網路理論與MATLAB R2007實現，電子工業出版社(北京)，第1章，第8頁，2008。
- [19] 楊淑瑩，模式識別與智能計算—MATLAB技術實現，電子工業出版社

(北京)，第6章，第148頁，2008。

附錄1 20-40-1 BPN 網路結構 訓練函數選擇實驗結果

函數名稱	SDBP	MOBP	VLBP	RPROP
迭代次數 (max 5000)	5000	466	5000	5000
花費時間	42 秒	6 秒	54 秒	53 秒
MSE (Goal = 0.05)	29.8744	29.8744	6.3956	0.0903448
收斂狀況	差	無法收斂	差	收斂，未達目標
測試準確率				82.5%

函數名稱	SCGBP	Quasi-Newton BFGS	LM
迭代次數 (max 5000)	5000	10	5000
花費時間	74 秒	15 秒	4387 秒
MSE (Goal = 0.05)	0.0781858	29.8744	0.0991224
收斂狀況	收斂，未達目標	無法收斂	收斂，未達目標
測試準確率(%)	90%		75%

附錄2 20-40-5 BPN 網路結構 訓練函數選擇實驗結果

函數名稱	SDBP	MOBP	VLBP	RPROP
迭代次數 (max 5000)	5000	5000	5000	27
花費時間	55 秒	53 秒	52 秒	2 秒
MSE (Goal = 0.05)	0.114848	0.960237	0.16565	0.0499668
收斂狀況	收斂，未達目標	收斂，未達目標	收斂，未達目標	收斂，達目標
測試準確率	62.5%	57.5%	45%	82.5%

函數名稱	SCGBP	Quasi-Newton BFGS	LM
迭代次數 (max 5000)	610	5000	5000
花費時間	11 秒	26955 秒	6443 秒
MSE (Goal = 0.05)	0.0499979	0.124262	0.0983443
收斂狀況	收斂，達目標	收斂，未達目標	收斂，未達目標
測試準確率(%)	92.5%	62.5%	65%

附錄 3 20-X-1 隱藏層神經元數量選擇實驗 (使用 SCG-BP 訓練函數)

神經元數	35			36			37		
迭代次數	5000	5000	5000	5000	5000	5000	5000	5000	5000
花費時間	70 秒	71 秒	72 秒	70 秒	73 秒	71 秒	72 秒	71 秒	73 秒
MSE	0.0910	0.0789	0.0696	0.0792	0.0776	0.0692	0.0799	0.0655	0.0743
準確率	87.5%	85%	82.5%	85%	85%	82.5%	85%	87.5%	87.5%
平均時間	71 秒			71.33 秒			72 秒		
平均 MSE	0.0798			0.0753			0.0732		
平均準確率	85%			84.16%			86.66%		
神經元數	38			39			40		
迭代次數	5000	5000	5000	5000	5000	5000	5000	5000	5000
花費時間	73 秒	72 秒	72 秒	75 秒	77 秒	77 秒	76 秒	78 秒	74 秒
MSE	0.0766	0.0949	0.0772	0.0871	0.0735	0.0766	0.0776	0.0822	0.0867
準確率	82.5%	85%	85%	87.5%	82.5%	87.5%	87.5%	90%	85%
平均時間	72.33 秒			76.33 秒			76 秒		
平均 MSE	0.0829			0.0791			0.0822		
平均準確率	84.17%			85.83%			87.5%		
神經元數	41			42			43		
迭代次數	5000	5000	5000	5000	5000	5000	5000	5000	5000
花費時間	76 秒	76 秒	75 秒	77 秒	78 秒	75 秒	79 秒	78 秒	78 秒
MSE	0.0733	0.0738	0.0743	0.0756	0.0706	0.0939	0.0693	0.0729	0.0709
準確率	92.5%	92.5%	90%	90%	85%	90%	85%	85%	87.5%
平均時間	75.67 秒			76.67 秒			78.33 秒		
平均 MSE	0.0738			0.0800			0.0710		
平均準確率	91.67%			88.33%			85.83%		
神經元數	44			45			46		
迭代次數	5000	5000	5000	5000	5000	5000	5000	5000	5000
花費時間	78 秒	78 秒	77 秒	78 秒	79 秒	77 秒	79 秒	79 秒	79 秒
MSE	0.0694	0.0695	0.0744	0.0720	0.0839	0.0815	0.0659	0.0776	0.0757
準確率	90%	85%	85%	90%	87.5%	87.5%	87.5%	87.5%	87.5%
平均時間	77.67 秒			78 秒			79 秒		
平均 MSE	0.0711			0.0791			0.0731		
平均準確率	86.67%			88.33%			87.5%		

附錄4 20-X-5 隱藏層神經元數量選擇實驗 (使用 SCG-BP 訓練函數)

神經元數	35			36			37		
迭代次數	398	268	406	333	858	269	621	492	585
花費時間	7 秒	5 秒	7 秒	6 秒	14 秒	5 秒	11 秒	9 秒	10 秒
MSE	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499
準確率	92.5%	92.5%	95%	97.5%	95%	87.5%	95%	90%	97.5%
平均次數	357			486			566		
平均時間	6.33 秒			8.33 秒			10.00 秒		
平均準確率	93.33%			93.33%			94.17%		
神經元數	38			39			40		
迭代次數	257	350	263	208	317	280	270	283	538
花費時間	5 秒	7 秒	5 秒	5 秒	6 秒	6 秒	6 秒	6 秒	10 秒
MSE	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499
準確率	92.5%	90%	90%	87.5%	90%	85%	97.5%	92.5%	95%
平均次數	290			268			363		
平均時間	5.67 秒			5.67 秒			7.3 秒		
平均準確率	90.83%			87.5%			95.00%		
神經元數	41			42			43		
迭代次數	367	593	351	201	231	461	461	476	381
花費時間	7 秒	11 秒	7 秒	5 秒	5 秒	9 秒	9 秒	9 秒	7 秒
MSE	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499
準確率	92.5%	97.5%	92.5%	90%	92.5%	90%	87.5%	90%	97.5%
平均次數	497			297			439		
平均時間	8.33 秒			6.33 秒			8.33 秒		
平均準確率	94.17%			90.83%			91.67%		
神經元數	44			45			46		
迭代次數	260	542	330	217	267	454	367	211	231
花費時間	6 秒	10 秒	7 秒	5 秒	6 秒	9 秒	7 秒	5 秒	5 秒
MSE	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499	0.0499
準確率	95%	95%	90%	90%	90%	92.5%	95%	90%	90%
平均次數	377			312			269		
平均時間	7.67 秒			6.67 秒			5.67 秒		
平均準確率	93.33%			90.83%			91.67%		