

運用類神經網路於飛機機翼結構件設計成本預測

鄧世剛¹ 金 憲² 葉宗翰^{3*}

¹國防大學理工學院動力暨系統工程學系

²大葉大學工業工程與科技管理學系

³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(BPN)針對飛機研發階段結構件設計成本進行預測，並以飛機機翼結構作為案例，同時與統計反應曲面法(RSM)進行預測績效比較。案例探討分為個別結構件以及混合式結構件預測案例。案例一係將四種主要結構件，分別以 100 筆訓練樣本建立預測模型並使用 50 筆測試樣本驗證預測模型。案例二係模擬實際飛機結構件資料庫，以混合四種結構件資料進行訓練和測試。最終案例結果驗證倒傳遞類神經網路之可行性以及準確之預測能力。

關鍵詞：飛機結構，統計參數預測法，倒傳遞類神經網路，反應曲面法

Using Artificial Neural Networks to Airframe Wing Structural Design Cost Estimation

S. Deng¹, Hsiang Chin², and Tsung-Han Yeh^{3*}

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

²*Department of Industrial and Technology Management, Da-Yeh University*

³*Graduate School of National Defense Science, Chung-Cheng Institute of Technology, National Defense University*

ABSTRACT

This research using the back-propagation neural network (BPN) method to estimate a project design cost of airframe wing structure, and compared the estimation performance with response surface methodology (RSM) adopted by cost estimation software in the market. There are two case studies in this research, the first case using the main structure parts of Wing-Box separately, each part has 100 training samples to create estimation models, then used another 50 test sample to verify the estimation models. In the second case, we simulated a real wing-box structural cost database. Training and testing cost estimation model with mixed structure samples data of all four different parts. Finally, the test results shows BPN can get much better prediction than traditional RSM and verifies the feasibility and accuracy prediction ability of the BPN.

Keywords: airframe structure, statistical parametric estimation, back-propagation neural network, response surface methodology

一、前言

成本對於專案規劃以及產品研發等領域都是極為重要的，航太產業亦是如此[1]。現行成本預測方法可分為人為主觀判斷以及統計回歸分析法。人為判斷意造成與實際成本落差甚大，而統計回歸分析法在面對快速變動的社會因素並無法即時更新預測模型。許多學者提出運用類神經網路(Artificial Neural Networks, ANN)的人工智能學習機制取代傳統統計回歸分析法並且獲得良好預測績效。本研究將運用倒傳遞類神經網路(Back-propagation Neural Networks, BPN)於飛機結構件設計成本預測，並驗證其可行性，同時比較傳統統計參數預測方法中的反應曲面法(Response Surface Methodology, RSM)進行預測績效比較，最終驗證倒傳遞類神經網路(BPN)之可行性以及較反應曲面法(RSM)能達到更好之預測績效，以提供飛機產業一有效的成本預測方法。

傳統專案成本規劃方法可分為從上而下(Top-Down)與從下而上(Bottom-Up)兩種方法[2]，前者係由高階主管訂定預算再由上至下劃分至各階層，而後者係由各階層主管預估概略預算，再由下至上統整，但此兩種模式都係以經驗人為進行成本預測，時常因估測不夠準確而使專案最終難以執行成功。有效的控管成本必須分析各單位運作實際所需之成本，彙整後訂定一個預算門檻，而專案必須在預算門檻內達到目標，因此有按成本設計(Design to Cost, DTC)的成本規劃概念提出。

過去航太產業皆以按產品性能設計(Design to Performance)為主軸，但長久下來發現花費龐大的費用，因此如何有效控管成本成為重要課題，專案成功與否除了績效與時程之外，成本也是重要的考量因素。根據美國國防部文件 DoD5000.28 對按成本設計(DTC)定義為一種管理概念，即是在發展過程中要確定嚴格的成本目標，並且通過在使用能力、性能、成本以及進度之間進行權衡，對系統採購、使用及支援等成本予以控制，以確保能達到既定的目標。過去產業界多以產品規格作為專案主要目標，係以產品規格去決定成本多寡，此生產概念因為沒有

成本限制考量所以經常造成浪費。因應近年來因應全球產業趨勢，皆以成本為優先考量下進行生產作業，所以必須以按成本設計(DTC)的管理概念執行。以專案管理角度解釋 DTC 即是在專案編列的設計成本限制內完成所應達到之設計工作，必須按成本設計方能同時兼顧績效與成本。執行按成本設計成功案例可以美國為例，美國太空總署 NASA 的 Mars Pathfinder-Rover 計畫執行時提出新的政策，即在有限控管的成本下完成所規劃的任務，推行此政策之效益使得 NASA 在 1976 年的 Viking-Mars Lander 計畫所耗費 30 億美元降為新計劃的 1.75 億美元，總共節省了 94% 成本[2]。依上述案例可得知目前全球產業趨勢已經由傳統按產品性能設計(Design to Performance)的生產概念轉變為按成本設計(DTC)為考量下進行規劃並完成既定任務。

二、成本預測法

成本預測方法依據 Layer[4] 文章中提及預測方法分為定性法(Qualitative)與定量法(Quantitative)，定性預測方法中包括專家經驗判斷等方法，此仍以傳統專案成本規劃中從上而下(Top-Down)與從下而上(Bottom-Up)兩種方法主觀決定成本為主軸。定量預測方法包括統計參數預測方法(Statistical Parametric Estimation)以及類神經網路(Artificial Neural Networks, ANN)等預測方法。

2.1 統計參數預測法

統計參數預測法中最廣泛被使用的是統計學中的迴歸分析法[5]，其理論是藉由實驗數據中影響反應值的獨立變數($x_1, x_2, \dots, x_i$)以及反應變數的誤差(ε)對所欲得到之反應值(Y)進行預測，透過最小平方法可配適一階迴歸預測模型。

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \times X_1 + \hat{\beta}_2 \times X_2 + \dots + \hat{\beta}_i \times X_i + \varepsilon$$

對於處理一般簡單的預測問題運用一階迴歸預測模型即可達到良好成效。隨著預測問題複雜度增加，若只使用變數本身作為

參數進行預測反應值可能得到較差的預測成效，意即預測模型參數之解釋能力較差。因此必須將變數之平方項以及變數間交互作用納入考量以建立二階預測模式，此模式又可稱為反應曲面法(RSM)[6]。反應曲面法係統計參數回歸預測法中二階回歸預測模型，模型組成包括一次變數項、二次變數項以及各變數間交互作用項，如下式所示。

$$\hat{Y} = \hat{\beta}_0 + \sum_{i=1}^n \hat{\beta}_i \hat{X}_i + \sum_{i=1}^n \hat{\beta}_{ii} \hat{X}_i^2 + \sum_{i < j} \hat{\beta}_{ij} \hat{X}_i \hat{X}_j + \varepsilon$$

統計回歸預測模型在面對參數固定且變動不大的情況下可達到良好的預測效果。以飛機製造產業為例，其預測模型通常會受到通貨膨脹、技術成長、產量產能變化等社會環境影響而失去原有的準確性，必須經常修改迴歸分析參數才能確保預測精確度，而修改回歸預測模型造成時間以及成本的浪費，因此傳統統計回歸分析已無法因應社會上的變動因素。

現今國外已陸續發展出適應於各種產業的成本預測軟體，較具代表性的有以下幾種[5]：

- (1)ACEIT(Automated Cost Estimating Integrated Tools)，主要用於生命週期成本之估算以及分析。
- (2)PRICE H，主要用於電子、機電及結構組裝之成本、資源與硬體計畫之成本估算。
- (3)SEER H，主要是提供工時與材料資訊，包括研發與生產、操作使用與後勤支援階段。
- (4)COCOMO-II (Construct Cost Model-II)，此預測模型主要係針對產品開發專案整體成本進行分配與規劃。

上述成本預測軟體已被廣泛使用於全球各產業，但這些成本預測軟體主要核心預測機制仍係使用統計參數迴歸分析法為主。

2.2 倒傳遞類神經網路

為了改善傳統統計回歸預測模型的不足，以至許多學者運用人工智慧中的類神經網路(ANN)來取代傳統的統計回歸分析法，類神經網路之優勢包括可處理高維度非線性問題；不受參數數量限制；使用歷史資料進行函數逼近，並透過學習機制建構一個準

確之預測模型。類神經網路中最具代表性且被廣泛運用的為倒傳遞類神經網路(BPN)，此網路概念是藉由歷史資料進行網路訓練，在訓練過程中不斷得進行誤差遞回，更新並調整參數，以達到誤差最小化，最終建立預測模式[7][8]。圖 1 為一個通用之倒傳遞類神經網路架構。倒傳遞類神經網路運算過程可分為前向傳遞階段、誤差計算階段以及誤差遞迴階段，倒傳遞類神經網路運作流程內容說明如下：




圖 1. 通用之 BPN 網路架構。

- (1)前向傳遞階段(forward pass):式(1)係將輸入層每個單元(x_i)透過權重(v_{ji})以及傳遞函數(f)計算至隱藏層單元(y_j)；式(2)係將隱藏層每個單元(y_j)透過權重(w_{kj})以及活化函數(f)計算至輸出層單元(O_k)。

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

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

- (2)誤差計算階段(error computation): 定義誤差函數並計算網路輸出值與期望值之間的誤差，式(3)中為 d_k 期望輸出值。

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

- (3)誤差遞迴階段(error back-propagation): 至此階段若誤差未滿足終止條件則使用梯度下降法(gradient descent)更新單元傳遞

權重， η 為梯度下降係數。式(4)係更新從隱藏層至輸出層之權重；式(5)係更新連結輸入層至隱藏層間的權重，重覆此過程達到中止條件，即網路輸出值與期望輸出間誤差最小化。

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

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

2.3 倒傳遞神經網路參數設定

欲建置倒傳遞類神經網路預測模型必須決定許多網路參數，包括隱藏層層數、隱藏層神經元數量，傳遞函數，訓練函數以及訓練誤差目標值等，適當的參數選取能提高預測模型之預測績效[7][9]。本研究將比較不同訓練函數以及不同隱藏層神經元數量的情況下之訓練績效。

- (1)傳遞函數：倒傳遞類神經網路中的傳遞函數，本研究於輸入層至隱藏層使用雙曲正切 S 型傳遞函數；隱藏層至輸出層使用線性傳遞函數。
- (2)隱藏層層數與神經元數：設定隱藏層用意在於可進行非線性映射，本研究於倒傳遞類神經網路中設定為 1 層隱藏層。隱藏層神經元數可依據經驗公式進行設計，其中 n 為隱藏層神經元數； n_{input} 為輸入神經元數； n_{output} 為輸出神經元數； a 為 1~10 常數。以本研究為例，包含三個輸入與一個輸出，則隱藏層神經元數可在 3~12 之間找尋最適者。

$$n = \sqrt{n_{input} + n_{output}} + a \quad (6)$$

- (3)訓練函數：標準的倒傳遞類神經網路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。針對傳統倒傳遞類神經網路存在的一些不足，發展出許多改進的訓練函數，本研究使用以下 7 種改良式訓練函數，包括最速下降倒傳遞法(Steepest descent back-propagation, SDBP)；動量倒傳遞法(Momentum back-propagation, MOBP)；變動學習率倒

傳遞法 (Variable learning rate back-propagation, VLBP)；彈性倒傳遞法(Resilient back-propagation, RPROP)；共軛梯度倒傳遞法(Conjugate gradient back-propagation, CGBP)；擬牛頓法(Quasi-Newton algorithms)以及 Levenberg-Marquardt 訓練函數等七種訓練函數。

倒傳遞神經網路參數選擇依據過去應用於成本預測相關文獻彙整顯示皆以試誤法找尋最佳網路參數[10-14]，因此本研究將嘗試在各種使用不同訓練函數以及隱藏層神經元數的情況下，找尋對問題本身最適之訓練函數以及隱藏層神經元數組合進行預測模型建立。

2.4 倒傳遞類神經網路架構於成本預測應用綜整

近年來倒傳遞類神經網路(BPN)已被廣泛運用在各領域的成本預測方面，如 Cavalieri 與 Maccarrone[10]使用參數預測法以及類神經網路於車輛產業產品成本預測；Verlinden 等人[11]使用多元回歸與類神經網路法於薄片金屬構件之成本預測；Greese 與 Li[12]運用類神經網路針對木造橋樑專案成本預測並與傳統參數預測法進行比較；Zhang 與 Fuh[13]運用倒傳遞類神經網路於產品包裝離型系統開發所需之成本預估；Murat 與 Zeynep[14]運用類神經網路於強化混凝土架構建築結構系統早期設計階段成本預估。上述係使用類神經網路於成本預測問題之研究綜整，其最終預測績效皆優於傳統迴歸分析法，但類神經網路建構預測模型時必須決定適當的網路參數組合以提高預測模型準確度。

三、飛機機翼結構案例探討

飛機全壽期成本可分為概念設計(Conceptual design)、初步設計(Preliminary design)、細部設計(Detailed design)、製造與裝配(Manufacturing and acquisitions)、運作與支援(Operation and support)、除役(Disposal)等階段。在規劃飛機全壽期成本時，必須依

據成本分解結構 (Costs Breakdown Structure, CBS) 來進行, 以時間階段劃分飛機全壽命成本可分為研發費用、生產費用以及使用維修等費用。以飛機各次系統劃分可分為飛機機體、動力系統、武器系統、電子系統等費用, 其中研發費用又可分為設計費用、材料費用、測試費用、設備費用等[3]。本研究在案例探討部分將針對飛機機體研發階段中的飛機機翼主要結構件設計成本進行探討。

3.1 案例定義與設定

案例探討部份, 本研究假設欲規劃執行一個軍用飛機機翼專案所需之結構設計成本。結構件設計成本可透過設計工時乘上單位工時成本(單位: 美元)進行計算, 因此預測目標為結構件設計工時(單位: 小時), 影響預測目標的特徵參數為結構件尺寸(單位: 英吋), 包括結構件長度、寬度以及厚度, 本研究假設每單位工時成本為 60 美元。

$$\text{設計工時} = f(\text{長度}, \text{寬度}, \text{厚度}) \quad (10)$$

$$\text{設計成本} = \text{設計工時} * \text{單位工時成本} \quad (11)$$

飛機機體結構大致可分為機身 (Fuselage)、機翼 (Wing) 以及尾翼 (Empennage) 等部份, 其中機翼部份主要組件為 Wing-Box, Wing-Box 結構如圖 2 所示。Wing-Box 所需之主要結構件包括 Spars、Ribs、Skins 以及 Stringers 等, 本研究假設各主要結構件均使用鋁合金材質並透過銑床製程進行生產。

本研究假設各種 Wing-Box 主要結構件尺寸範圍並透過隨機模擬產生各結構件樣本 150 筆資料。結構件 Spars 尺寸範圍: 長度 15~50 英吋、寬度 2~10 英吋、厚度 2~10 英吋, 各主要結構件尺寸範圍如表 1 所示。




圖 2. Wing-Box 結構圖[16]。

表 1. 各主要結構件尺寸範圍(單位: 英吋)

主要結構件	長度	寬度	厚度
Spars	15~50	2~10	2~10
Ribs	10~25	5~10	2~5
Skins	30~50	30~50	0.1~1
Stringers	10~30	2~10	2~10

確定各種 Wing-Box 結構件設計數據範圍後, 本研究使用兩種類型之案例驗證 BPN 之可行性以及預測準確性:

- (1) 個別結構件預測案例: 此案例係將各種主要結構件分別建立設計工時預測模型, 並比較 BPN 與 RSM 之預測績效。
- (2) 混合式結構件預測案例: 此案例係為了模擬實際飛機產業結構件資料庫之狀況。因傳統統計方法對於異質資料無法建立準確之預測模型, 本研究僅使用 BPN 於混合式結構件預測案例, 最後假設一個 Wing-Box 專案所需之結構件資料透過 BPN 預測模型所需之設計成本。

3.2 倒傳遞神經網路系統設定

本研究在使用倒傳遞類神經網路(BPN)建立預測模型時可分為訓練階段以及測試階段進行說明, 本案例使用之 BPN 網路架構如圖 3 所示:




圖 3. 本案例使用之 BPN 網路架構圖。

(1) BPN 訓練階段: 網路參數設定如下所示:

- 輸入項 (X_1, X_2, X_3) 分別為結構件長度、寬度以及厚度。
- 隱藏層層數設定為 1 層。
- 輸出項 (Y) 為結構件設計工時。
- 隱藏層神經元數: 本研究將在 3 至 12 個中選取較適者。
- 傳遞函數: 輸入層至隱藏層間為雙曲正切 S 型函數; 隱藏層至輸出層為線性傳遞函數。

- 訓練函數：本研究將比較 SDBP、MOBP、VLBP、RPROP、CGBP、QN 以及 LM 等七種訓練函數，選用收斂與績效最佳者作為預測模型訓練函數。
- 訓練終止條件設定為(MSE=0.001)。
- 訓練最大迭代次數設定為 5000 次。

(2)BPN 測試階段：將測試資料代入訓練階段完成之預測模型，可得到預測值並與實際值比較計算誤差，透過預測效益評量準則評斷(MSE 以及 MAPE)此預測模型之預測能力。

3.3 預測效益評量準則

預測效益評量準則主要功能是将預測值與實際值進行比對，以證實模式之可行性，本研究藉此評量倒傳遞類神經網路(BPN)預測模式以及反應曲面法(RSM)之預測模式。本研究選用均方誤差(Mean Squared Error, MSE)(12)以及平均絕對誤差(Mean Absolute Percentage Error, MAPE)(13)統計評量值進行評估[15]，MSE 和 MAPE 即用來衡量真實質與預測值之間的差異程度，當 MSE 與 MAPE 值愈小時，代表預測值愈接近實際值。以下列出此兩種統計評量值之計算公式其中 n 為樣本數； s_i 為實際值； $\hat{s}_i$ 為預測值。

$$MSE = \frac{1}{n} \sum_{i=1}^n (s_i - \hat{s}_i)^2 \quad (12)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{s_i - \hat{s}_i}{s_i} \right| \times 100\% \quad (13)$$

3.4 案例 1：個別結構件預測案例

在個別結構件預測案例中，將各主要結構件 Spars、Ribs、Skins 以及 Stringers 隨機產生之資料集 150 筆，隨機抽取 100 筆作為訓練樣本，另外 50 筆作為測試樣本。接著進行 BPN 以及 RSM 預測模型建立，以下說明兩種方法建立訓練模型相關設定以及訓練階段預測績效評比。

3.4.1 案例 1：BPN 訓練階段

在 BPN 訓練階段，目標係能找尋出最佳參數組合能達到訓練誤差最低。本研究將 7

種訓練函數與 10 種隱藏層單元數的進行組合搭配，分別使用 Spars、Ribs、Skins 以及 Stringers 等四種主要結構件建立訓練模型並進行評估。透過訓練結果顯示，各主要結構件在使用 LM 訓練函數時較能滿足訓練誤差門檻並且在與各種隱藏層神經元數組合訓練誤差皆較為穩定，而其餘 6 種訓練函數皆無法在最大迭代次數內達到訓練誤差終止條件。

結構件 Spars 訓練過程中，在使用 LM 訓練函數的情況下，當使用隱藏層神經元數為 8、9、11 以及 12 個神經元時皆能達到訓練誤差門檻，而 8 個神經元訓練誤差 0.000992813 為 4 種組合中最低者，因此選用參數組合作為之後測試階段使用，訓練階段收斂圖如圖 4 所示。結構件 Ribs 訓練過程中，最低訓練誤差參數組合係在隱藏層神經元數為 12 個神經元時，訓練誤差為 0.0009941，訓練階段收斂圖如圖 5 所示。結構件 Skins 訓練過程中，最低訓練誤差參數組合係在隱藏層神經元數為 9 個神經元時，訓練誤差為 0.0009997，訓練階段收斂圖如圖 6 所示。結構件 Stringers 訓練過程中，最低訓練誤差參數組合係在隱藏層神經元數為 9 個神經元時，訓練誤差為 0.00098811，訓練階段收斂圖如圖 7 所示。表 2 為各主要結構件訓練階段最佳參數組合彙整。

表 2. 各結構件於 BPN 訓練階段誤差綜整

結構件	訓練函數	神經元數	MSE
Spars	LM 法	8	0.000992813
Ribs		12	0.0009689
Skins		9	0.0009997
Stringers		9	0.00098811




圖 4. 結構件 Spars 訓練階段收斂圖。




圖 5. 結構件 Ribs 訓練階段收斂圖。




圖 6. 結構件 Skins 訓練階段收斂圖。




圖 7. 結構件 Stringers 訓練階段收斂圖。

3.4.2 案例 1：RSM 訓練階段

各主要結構件使用 RSM 建立之預測模型以及相關設定如下所示：

(1)結構件 Spars 之最佳 RSM 預測模型：

$$Y=20.3191-0.561228*X_1-3.02565*X_2-3.49289*X_3+0.0280891*X_3^2+0.0869425*X_1*X_2+0.$$

$0950531*X_1*X_3+0.491295*X_2*X_3$ ，訓練階段誤差 MSE 為 0.5585。

(2)結構件 Ribs 之最佳 RSM 預測模型：

$$Y=8.69705-0.414735*X_1-1.20485*X_2-2.27327*X_3+0.000332035*X_1^2+0.0100852*X_2^2+0.053293*X_1*X_2+0.112439*X_1*X_3+0.297925*X_2*X_3$$
，訓練階段誤差 MSE 為 0.0124。

(3)結構件 Skins 之最佳 RSM 預測模型：

$$Y=9.70496-0.233876*X_1-0.250973*X_2-16.4489*X_3+0.000366731*X_1^2+0.000610947*X_2^2+0.319591*X_3^3+0.00510595*X_1*X_2+0.40221*X_1*X_3+0.400476*X_2*X_3$$
，訓練階段誤差 MSE 為 0.0062。

(4)結構件 Stringers 之最佳 RSM 預測模型：

$$Y=9.84336-0.635895*X_1-1.50943*X_2-1.50451*X_3+0.00317328*X_1^2-0.0144221*X_2^2+0.0914116*X_1*X_2+0.0843171*X_1*X_3+0.277063*X_2*X_3$$
，訓練階段誤差 MSE 為 0.1046。

3.4.3 案例 1：測試階段

測試階段係使用上階段訓練完成之預測模型，將各結構件 50 筆測試資料輸入訓練階段建構之預測模型可得到模型預測值，再與實際值間之差距進行誤差計算即可得到預測績效。

在 BPN 測試階段係使用訓練階段最佳參數組合建置預測模型，RSM 則係使用訓練階段求得之二階回歸模型。兩種方法訓練後之測試結果如表 3 所示，透過結果顯示使用 BPN 能達到比 RSM 更準確之預測能力。

結構件 Spars 測試階段使用 BPN 預測模型 MSE 為 0.00234，MAPE 為 0.38451%；透過 RSM 預測模型測試之結果 MSE 為 0.1866，MAPE 為 3.6558%，兩方法績效指標絕對差額 MSE 為 0.1826，MAPE 為 3.27129%。其中在結構件 Spars 與 Stringers 透過 BPN 測試誤差百分比優於 RSM 約 2.8%~3.2%，此結果顯示 Spars 與 Stringers 結構件尺寸範圍較廣且資料分佈較為分散，以至於 RSM 無法達到較好之準確度。相對於較不受資料範圍之影響，BPN 在預測模型參數選取時，目標係不斷修正調整將誤差最小化，此優勢係統計參數預測法不及機器學習之主因。

在個別結構件預測案例之測試過結果驗證了使用 BPN 預測模型於飛機結構件設計成本係可行的，並且預測績效較傳統反應曲面法(RSM)為佳。本研究將進一步探討在混合式結構件資料的情況下，BPN 預測模型之可行性以及預測績效。

表 3. 個別結構件訓練之測試結果比較

結構件	預測績效	BPN	RSM	差值
Spars	MSE	0.00234	0.1866	0.18426
	MAPE(%)	0.38451	3.6558	3.27129
Ribs	MSE	0.003429	0.021	0.01757
	MAPE(%)	0.43314	1.1123	0.67916
Skins	MSE	0.004606	0.0067	0.00209
	MAPE(%)	0.53707	0.5612	0.02413
Stringers	MSE	0.004209	0.3006	0.29639
	MAPE(%)	0.51153	3.37	2.85847

3.5 案例 2：混合式結構件預測案例

在實際飛機產業資料庫中，各結構件資料呈現混合狀態，因此本研究進行混合式結構件設計工時預測。訓練樣本為 100 筆，此樣本係從 Spars 結構件、Ribs 結構件、Skins 結構件以及 Stringers 結構件訓練樣本中分別隨機抽取 25 筆樣本所組成。測試樣本為 40 筆，係從 Spars 結構件、Ribs 結構件、Skins 結構件以及 Stringers 結構件測試樣本分別隨機抽取 10 筆資料所組成。而在此案例中本研究僅使用 BPN 建置預測模型，其原因係二階回歸預測模型在面對資料屬性與分佈差異甚大時無法建置準確的預測模型。

3.5.1 案例 2：訓練階段

在混合式結構漸 BPN 訓練階段，基本參數設定與上階段各別結構件相同，訓練函數以及隱藏層神經元數仍需要透過進行不同參數組合以選取一組最適參數作為建置測試階段預測模型之依據。透過訓練結果顯示，LM 訓練函數在最大訓練迭代次數內達到訓練誤差門檻，且在各種神經元數皆能維持穩定之訓練誤差，因此選用 LM 訓練函數。而在使用 LM 訓練函數的情況下，訓練誤差最低係使用 7 個神經元數時 MSE 為 0.000998568，訓練階段誤差收斂圖如圖 8 所示。因此選用 LM 訓練函數以及 7 個隱藏層神經元數為最佳參數組合。




圖 8. 混合式結構件訓練階段收斂圖。

3.5.2 案例 2：測試階段

在測試階段，將混合結構件測試資料 40 筆透用上階段建立之 BPN 預測模型可得到模型預測值，並與實際值間之差距可得到預測績效。訓練後測試結果 MSE 為 0.14106；MAPE 為 1.1145%，依據測試結果顯示 BPN 在面對實際資料庫中混合的結構件資料仍能準確得預測每種結構件之設計工時，換言之 BPN 預測模型能符合實際飛機產業情境。

3.6 Wing-Box 專案設計成本預測

完成建構各結構件之設計工時預測模型後，假設進行規劃一個 Wing-Box 專案設計成本預測，假設此專案共需要 100 個主要結構件，其中包括 35 個 Spars、35 個 Ribs、15 個 Skins 以及 15 個 Stringers。

將 Wing-Box 所需之結構件資料集輸入上階段建構之 BPN 預測模型，可得到各結構件設計工時之預測值，再乘上單位時間成本 (60 美元) 可得設計成本。編號 1 的 Spars 結構件設計工時預測值為 48.358 小時；設計成本預測值為 2901.48 美元。最終可得知進行規畫一個 Wing-Box 專案可能需要之設計成本為 72969.58 美元，可提供給專案成本規劃作為參考依據。

四、結論

在基於按成本設計(DTC)的概念下執行專案規劃，不論過去採用從上而下(Top-Down)或從下而上(Bottom-Up)的人為

主觀成本預測模式，都因預測方法較粗略以及造成與實際成本誤差甚大，最終使專案難以成功，所以準確的專案成本預測將成為未來執行 DTC 的趨勢。

過去廣泛運用於專案規劃的統計參數預測方法，在面對全球環境快速變遷的情況下並無法快速反應並且更新成本預測模型，因此本研究使用倒傳遞類神經網路(BPN)透過訓練測試以及調整參數的機制建立成本預測模型並且與傳統統計參數預測法中的反應曲面法(RSM)進行比較，結論如下：

- (1)本研究驗證倒傳遞類神經網路(BPN)運用於飛機設計成本預測之可行性，並且預測模型之測試結果優於現行成本估測軟體採用之反應曲面法(RSM)。藉由飛機機翼主要結構件進行設計成本預測模型建構，透過預測績效可得知 BPN 在每種主要結構件預測結果皆優於 RSM，其主要原因在於機器學習方法主要優勢在於可不斷調整參數並且達到誤差最小化；而傳統統計參數預測建構之預測模型缺乏調整之彈性。
- (2)本研究使用混合式結構件預測案例模擬現實飛機產業資料庫之情況，透過訓練與測試結果可得知 BPN 在面對異質混合式資料集仍能達到均方誤差 MSE 為 0.14106 與平均絕對誤差 MAPE 為 1.1145%的準確程度。
- (3)本研究最終假設規劃一個 Wing-Box 專案所需之設計成本，透過 BPN 混合式結構件預測模型可得到 Wing-Box 可能所需之設計成本總和，以提供專案規劃者作為參考。

在未來研究發展方面，由於飛機具備多式樣及少數量之特性，本研究將進行在「少量訓練樣本」的情況下，驗證機器學習方法建置之預測模型仍能達到良好預測績效。此方向亦為了驗證在未來面對全球環境變遷時，若影響成本之因素有所改變，能透過較少之樣本數就能建構良好預測能力之成本預測模型。

參考文獻

- [1] Bode, J., "Decision support with neural networks in the management of research

and development: Concepts and application to cost estimation," *Information & Management*, Vol. 34, pp. 33-40, 1997.

- [2] Mantel, S. J., Meredith, J. R., Shafer, S. M., and Sutton, M. M., Project Management in Practice 2nd Edition, Wiley, 2005.
- [3] Roskam, J., Airplane Design Part VIII : Arplane cost estimation : Design, Development, Manufacturing and Operation, DAR corporation, 2002.
- [4] Layer, A., Brinke, E. T., Houten, F. V., Kals, H., and Haasis, S., "Recent and Future trends in cost estimation," *Computer Integrated Manufacturing*, Vol. 15, No. 6, pp. 499-510, 2002.
- [5] International Society of Parametric Analysis (ISPA), Parametric Estimating Handbook 4th Edition, 2008.
- [6] Montgomery, D. C., Design and Analysis of Experiments 5th Edition, Wiley, 2001.
- [7] Haykin, S., Neural Networks – A Comprehensive Foundation 2nd Edition, Prentice Hall, 1999.
- [8] Lippmann, R. P., "An Introduction to Computing with Neural Nets," *IEEE ASSP MAGAZINE*, pp. 4-22, 1987.
- [9] Hagan, T., Demuth, H., and Beale, M., Neural Network Design, MA:PWS Publishing, 1996.
- [10] Cavalieri, S., Maccarrone, P. and Pinto, R., "Parametric vs. neural network model for the estimation of production costs: A case study in the automotive industry," *International Journal of Production Economics*, Vol. 91, pp. 165-177, 2004.
- [11] Verlinden, B., Duflou, J.R., Collin, P. and Cattrysse, D., "Cost estimation for sheet metal parts using multiple regression and artificial neural networks: A case study," *International Journal of Production Economics*, Vol. 111, pp. 484-492, 2008.
- [12] Greese, R. C., and Li, L., "Cost Estimation of Timber Bridges Using Neural Network," *Cost Engineering*, Vol. 37, No. 5, pp. 17-22, 1993.
- [13] Zhang, Y. F., and Fuh, J. Y. H., "A Neural

- Network Approach for Early Cost Estimation of Packaging Products,” Computer & Industrial Engineering, Vol. 34, No. 3, pp. 433-450, 1998.
- [14] Murat, H., and Zeynep, S., “A neural network approach for early cost estimation of structural systems of buildings,” International Journal of Project Management, Vol. 22, pp. 295-602, 2004.
- [15] Lewis, C. D., Industrial and Business Forecasting Methods : a practical guide to exponential smoothing and curve fitting, 1982.
- [16] Niu, M. C. Y., Airframe Structural Design : Practical Design Information and Data on Aircraft Structures, Hong Kong : Conmilit Press, 1988.
- [17] Raymer, D. P., Aircraft Design : A conceptual Approach, AIAA, 1992.