

RRPG91040209 (63.P)

交通部中央氣象局
地震測報中心
九十一年度委託研究計畫成果報告

計畫編號

MOTC-CWB-91-E-12

應用小波神經網路於橋樑實測地震反應之 損壞偵測

洪士林 黃炯憲 黎明璟 溫俊明
國立交通大學土木工程系

張智峯 陳承俊
中央氣象局地震測報中心

摘 要

本計畫為國家地震研究中心羅俊雄主任所提“橋梁強震觀測資料之收集整理、分析”總計畫之子計畫之一。計畫中擬配合中央氣象局在全省各地橋梁裝設地震反應監測系統所量測資料，透過小波神經網路來偵測橋梁是否在歷年地震中損壞，並做為將來長期監測或健康診斷之基本資料。本研究中建構了利用小波神經網路進行結構系統損壞偵測之架構。利用結構物於小地震之反應訓練小波神經網路，將未損壞結構系統參數儲存於小波網路中；然後將結構於不同地震下之實測地震反應饋入網路來算出結構之地震反應，藉由比較實測與網路求得的地震反應之差異來判別結構是否損壞。此方法首先印證於一五層樓鋼構於國家地震工程研究中心振動台試驗數據，而後應用於處理台北市東西向快速道路高架橋 P155~P158 之地震反應資料。

This project is a sub-project of the main project “Collection and Analysis of Bridge Responses to Earthquakes” led by C. H. Loh, director of National Center of Research on Earthquake Engineering. The aim of this work is to apply a wavelet neural network to detect the damage of bridges from their dynamic responses to earthquakes. The detecting results can be used for bridge’s health monitoring in long term. This study establishes the procedure of structure damage detection using a wavelet neural network. A record of dynamic responses of a structure to small earthquake is first employed to train a wavelet neural network; the structural parameters of the structure, therefore, are derived and stored in the network. By comparing the differences of the dynamic response of the structure between measured in site and computed via the wavelet neural network, the damage of the structure can be detected. The methodology is first verified in successfully processing the measured responses of a five-story steel frame under shaking table tests undertaken by National Center for Research on Earthquake Engineering in Taiwan. The proposed procedure is finally applied to process the measured earthquake responses of a unit of elevated bridge in the east-to-west express high way in Taipei.

壹、前言

結構材料之退化或是強烈外力如大地震之侵襲後，便有可能使結構物遭受到損壞。結構中的破壞位置及損壞程度通常是由有經驗的工程師藉由其肉眼與經驗來檢查及判斷。然而，隨著科技日益進步、人口日漸增多、土地利用日趨密集，結構物的建築也趨向大型與複雜，因此結構的行為與潛在的破壞機制變得複雜而不易預測。而如何安全（非破壞性）、有效、可靠地評估結構損壞(包括破壞是否產生、破壞位置及損壞程度)，以提供人們生命、財產更大的保障，乃是一件刻不容緩的工作。

近年來，許多創新的感應器技術陸續地被發展出來，並應用在建築或土木結構之監測上。藉由感應器適當的佈置，量測結構在震動下的結構反應資料，吾人便可依據這些量測的資料的分析結果，評估結構是否發生破壞，或更進一步地瞭解這些破壞的一些特性。然由於大型土木工程結構物如橋樑、大樓等等的現場監測由於經濟因素，不可能在結構的每一個自由度上皆放置感應器，再加上噪音等周圍環境因素的影響，因此資料通常不太精確也不完整，所以大型、複雜結構的損壞偵測及損壞桿件的識別是一件非常具有挑戰性的工作。傳統的結構識別、結構損壞偵測方法可分別以靜態或動態的方法來進行，但是這些演算法都非常複雜，而且不適用於量測資料不精確和不完整的問題上。

1.1、文獻回顧

土木工程結構損壞偵測的方法可概分為局部損壞偵測與整體損壞偵測兩種方法。局部損壞偵測方法包括利用 X 光線照相術、電磁鐵、磁鐵、聽覺、超音波等方法。然而，不幸地，這些方法並無法提供整體結構的情況資料，也無法提供任何不可預知的潛在破壞機制的資料。

在整體損壞偵測方面，傳統的結構識別、結構損壞偵測方法可分別以靜態 (Sanyayi 與 Onipede [1]) 或動態 (Yao [2]) 的方法來進行。首先建立結構的數學模式，之後利用這個數學模式來發展、建立結構反應之改變與桿件損壞狀況之間的關係。但是這些演算法都非常複雜，並且對於線性及非線性結構系統的處理過程和選用的數學模式有極大的不同。此外，這些數學模式的建立是直接處理的方式，即已知原因 (桿件損壞狀況)，進而推導結果 (結構反應)。然而，從損壞的結構反應來識別桿件的損壞是一個逆向的過程，即原因 (桿件損壞狀況) 必須由結果 (結構反應) 來識別。對於一個逆向的問題，通常不只有唯一解，特別是當資料不足時。因此使用傳統的結構損壞偵測方法來評估遭受未知程度損壞之複雜結構的損壞程度是非常困難的。

由於類神經網路強大的學習能力，及其對於部分不精確資料的高容錯性，在過去的二十年間，類神經網路（ANN）被廣泛地應用在許多的領域之中。無論是在模式識別（pattern recognition）、訊號處理（signal processing）、控制、以及複雜的映射（mapping）等問題上，類神經網路已成為了一種強有力的應用工具。因此，對於常須考慮非線性行為的大型、複雜結構物而言，類神經網路對於結構損壞的偵測工作是一個非常強大、有用的工具。而於最近幾年更進一步地被應用在結構的破壞偵測評估或是結構健康診斷上。如 Ghaboussi 等人[3]、Wu 等人[4]、Elkordy 等人[5]、Szewczy Hajela[6]、Masri 等人[7][8]、Hung 和 Kao[9]、Huang 等人[10]。這些學者的研究均證實類神經網路在結構損壞偵測之可行性。

小波轉換（Wavelet Transform）改善了傅立葉轉換（Fourier Transformation）只能觀察到頻率域資料的特性，其二維（時間和頻率）分析的功能使得信號在時間和頻率域內的變化能同時被偵測到，而且，它對雜訊的容忍度高，因此非常適合應用於結構損壞偵測。近年來小波分解（wavelet decomposition）[11][12][13]脫穎而出成為函數近似的一個功能強大的新工具。不僅如此，Zhang 和 Benveniste[14]率先提出了一個新穎的方法，結合了小波分解和類神經網路，稱之為小波神經網路（wavelet neural network, 小波神經網路），亦可簡稱為小波網路。之後，便有許多研究延伸到如何改善小波神經網路的網路結構[15][16]、初始化過程[17]、參數採納法則[18]、和學習演算法[19][20]。同時，將小波神經網路應用於函數近似也在許多的科學和工程領域中被研究[21][22][23]。小波神經網路（Wavelet Neural Network）是根據類神經網路（Artificial Neural Network）架構所發展出來的，由小波轉換取代類神經網路中神經元（Neuron）的轉換函數（Transfer Function）而建構出小波元（Wavelon）。對於實際之大維度（Dimension）問題，由於可得到的資料很少，若應用小波轉換，則需要大量的小波來分解（Decompose）及合成（Synthesis）訊號。小波神經網路的訓練採用類似於類神經網路常用的 BP（Back-Propagation）學習演算法，根據工程問題的輸入與輸出訊號自動調整小波元中的參數，因此可大量減少分解及重建訊號所需的小波數目，並快速而有效地分解及重建訊號。因此本計畫將應用小波神經網路來發展以實測之地震反應資料偵測橋樑損壞的方法，這個計畫的研究成果可提供工程界參考，做為將來結構健康診斷之基本資料。

1.2、研究方法

本研究中，提出了一套基於小波神經網路所架構的系統識別模式，並將其應用於結構破壞偵測之上。為考量實際工程上之應用，本研究僅使用結構加速度反應資料作為網路訓練之用，以結構未破壞時的結構反應資料所訓練的小波神經網路，可用來模擬在其他地震作用下的結構反應。當網路模擬反應與實際量測反應

之間有明顯的差異時，便可進一步指出該識別模式所識別之結構可能有破壞情形之發生。診斷之策略為：首先以小地震資料訓練小波神經網路，假設小地震下的結構為未破壞前的結構，於是依據小地震資料所架構的網路以及儲存於網路中的參數可表示該識別系統的動力特徵，一旦結構遭受損害導致動力特徵變化，則該網路架構將無法適切的描述破壞後的結構行為（因該網路架構僅能描述未破壞前的結構行為）。

為驗證診斷策略的可行性，本研究將首先以一於國家地震工程研究中心進行的五層樓實驗鋼構架實驗資料，來架構適當的小波神經網路，繼而驗證損壞偵測的程序。該實驗中以多種不同強度下的 Kobe 地震作為震動台輸入力源，進而量測五層鋼構架各樓層之結構反應。本研究破壞診斷策略驗證的步驟概述如下：

1. 利用此五層鋼構於小地震時（20% Kobe 地震）實驗資料訓練小波神經網路。
2. 根據網路收斂情形，選擇適當的網路架構。
3. 由訓練完成的網路來代表此鋼構之結構動力特徵。
4. 以不同地震下的結構反應資料輸入於所訓練的小波網路，根據小波網路的輸出表現，對照觀測試驗體（五層鋼構架）於不同地震下的結構行為，以驗證所提方法之可行性。

而後，將本研究所提之方法應用在台北市東西向快速道路高架橋 P155~P158 段上，利用兩筆不同的實測地震反應，進行該橋的損壞偵測工作。一個於 1999 年 9 月 21 日發生之地震量測資料，文中稱之為 921 地震；另一個則於 2001 年 6 月 14 日發生，文中稱之為 614 地震。

1.3、報告內容安排

本報告的內容安排如下，接續本章之後；第二章將首先對小波理論的概念做一些簡單的介紹，以使讀者能夠瞭解小波理論的原理；第三章的內容則述及本研究所提之小波神經網路與演算法則，內容將討論到有關如何建立小波神經網路之架構、小波神經網路學習演算法、及如何訓練網路；而後於第四章內驗證所提模式，國家地震工程研究中心之五層鋼構架之振動台實驗數據，將被用作為驗證之案例。第五章將所提模式進一步應用至橋梁實測地震反應上，將利用臺北市東西向快速道路高架橋所遭受到之兩次地震作用下，所測得的 921 及 614 地震資料進行橋梁之損壞偵測。最後之章節則將針對研究所得成果，做出合理結論以及提出相關之建議。

貳、小波理論

小波轉換是藉由一組正則基底 (Orthonormal Basis)，將一維時間域的信號轉換到二維的時間和頻率域信號的方法。這組正則基底是由一個母波函數經過不同的脹縮 (Dilation) 和平移 (Translation) 之後的小波所組成的。關於在 $L^2(\mathbb{R})$ 的 radial 小波的理论如下：

我們說一個函數 $f: \mathbb{R}^d \rightarrow \mathbb{R}$ 是 radial，假如存在一個函數 $g: \mathbb{R} \rightarrow \mathbb{R}$ 使得 $\forall x \in \mathbb{R}^d, f(x) = g(\|x\|)$ ，其中 $\|x\|$ 是 x 的歐幾里德模數。假如一個函數 $\psi(x) \in \mathbb{R}^d$ 是 radial，則他的傅立葉轉換 $\hat{\psi}(x)$ 也是 radial。

令

$$\hat{\psi}(x) = \eta(\|x\|) \quad (2.1)$$

其中 $\eta: \mathbb{R} \rightarrow \mathbb{R}$ 是一單一變數函數。函數 ψ 若符合下式條件，則可成為一小波函數：

$$C_\psi = (2\pi)^d \int_0^\infty \frac{|\eta(\xi)|}{\xi} d\xi < \infty \quad (2.2)$$

若 ψ 滿足條件式 (2.2)，則任一函數 $f \in L^2(\mathbb{R}^d)$ 其 (連續) 小波轉換定義為：

$$w(a, t) = \int_{\mathbb{R}^d} f(x) a^{-\frac{d}{2}} \psi\left(\frac{x-t}{a}\right) dx \quad (2.3)$$

而此函數可由反小波轉換重建：

$$f(x) = \frac{1}{C_\psi} \int_0^\infty a^{-(d+1)} \int_{\mathbb{R}^d} w(a, t) a^{-\frac{d}{2}} \psi\left(\frac{x-t}{a}\right) dt da \quad (2.4)$$

其中， $a \in \mathbb{R}_+$ 和 $t \in \mathbb{R}^d$ 各稱為脹縮和平移參數。連續小波轉換和其反小波轉換並不能直接可以在電腦上實行的，故以下介紹一些方法將他離散化。

a. 小波基底

將反小波轉換 (2.4) 離散化為：

$$f(x) = \sum_i w_i a_i^{-\frac{d}{2}} \psi\left(\frac{x-t_i}{a_i}\right) \quad (2.5)$$

將重建公式離散化需要滿足一些條件，這與傅立葉轉換中的採樣理論有關。對於小波轉換，一些解是已知的。第一個是尋找一些可數的家族 (a_i, t_i) ，以致於對應

的脹縮和平移後的小波家族

$$\{a_i^{-\frac{d}{2}}\psi\left(\frac{x-t_i}{a_i}\right): i \in Z\} \quad (2.6)$$

組成了某個函數空間（典型來說， $L^2(R^d)$ ）的正則基底。通常，家族（2.6）具有以下雙標示規則點陣（a double regular lattice）

$$\{(a_n, t_m) = (\alpha^n, m\beta\alpha^n): n \in Z, m \in Z^d\} \quad (2.7)$$

其中純量參數 α 和 β 定義了離散化的脹縮和平移的步幅（一般取 $\alpha = 2, \beta = 1$ ）。

b. 小波框架

另一個方法是使用非正交的小波家族—小波框架。假如我們只要求(2.6)組成框架而非某個函數空間的基底，則我們在 ψ 的選擇上會有更多自由。以較不嚴格的說法來說，框架就是一個有贅餘度的基底。以下是在一般西爾伯特空間（Hilbert Space）中的框架的正式定義：

我們稱在一個西爾伯特空間中的數列 $\{\psi_k: k \in Z\}$ 為框架，假如存在兩個常數 $A > 0$ 和 $B < \infty$ 使得對於所有 $f \in H$ 滿足下式

$$A\|f\|^2 \leq \sum_{k \in Z} |\langle f, \psi_k \rangle|^2 \leq B\|f\|^2 \quad (2.8)$$

在框架的條件下， f 可經由 $\langle f, \psi_k \rangle$ 復原， $k \in Z$ 。因此假如一個家族（2.6）組成了一個框架，則離散的重建公式（2.5）是成立的。雖然藉由放鬆正交條件，在選擇小波函數時多了更多自由，但是由於正則小波而產生的快速演算法便不見了。

參、小波神經網路

小波神經網路係連結了類神經網路和小波分解理論而成概念，是藉由引入小波轉換理論來建構出來的新穎網路結構。小波轉換和小波分解近年來被發現是訊號分析的一種有力的工具，並且被應用到許多研究領域上[24][25][26][27]。由小波理論中得知，在 L^2 空間中的函數可以由他們在小波函數家族所展開的空間的投影來表示。這個動作時常被稱為小波分解。選擇小波函數通常是選擇在時間和頻率域都有最緊密的涵蓋者，以使他們具有在時間頻率域的區域性質。

小波被視為由參數化非線性函數所組成的家族，任一函數 $f(x)$ 可由式 (2.5) 來近似。然如何來決定 (2.5) 的參數 w_i, a_i, t_i ，這個問題非常類似於類神經網路訓練，事實上，式 (2.5) 可被視為一個單層隱藏層神經網路，此網路以 ψ 作為隱藏神經元(hidden neurons)的激發函數，在輸出層有一個線性神經元。一般來說，使用類似於 BP (Backpropagation learning algorithm) 的訓練演算法 (此法通常使用於訓練類神經網路)，以估計小波網路中的參數。當輸入輸出資料最契合且將訓練誤差最小化時，小波網路之權值便可被決定。

3.1、類神經網路

類神經網路 (Artificial Neural Network, ANN) 是一廣泛使用的函數近似法。其中，結合多層感知器 (MLP) 和誤差倒傳遞學習演算法 (BP) 的網路模式大概是目前最常被使用的神經網路。圖 3.1 是一典型的 MLP 結構，基本上包含一個輸入層、一個輸入層、和一個以上的隱藏層。BP 是一個簡單且實用的 ANN 學習演算法，然其缺點是學習過程時常停在區域最小值或收斂的太慢。The radial basis(RBF)網路，是一種具單層隱藏層的類神經網路。從函數近似的觀點來說，RBF 網路是藉由一個緊密涵蓋的基底函數家族來表示函數。基底函數的區域性使得 RBF 網路更加適於學習具有區域變化和不連續的函數。更甚者，RBF 網路可以表示在基底函數所展開的空間中的任何函數。

圖 3.2 表示了一個 RBF 網路結構，此結構也被稱為 $(1+1/2)$ 層網路。假如 $\sigma(\cdot)$ 是一個 discriminatory 函數，則

$$f(x) = \sum_{i=1}^N w_i \sigma(a_i^T x + b_i) \quad (2.9)$$

其中 $w_i, b_i \in R, a_i \in R^n$

在定義於 $[0,1]^n$ 的連續函數空間中是緊密的。換句話說，已知定義於 $[0,1]^n$ 的任何

連續函數 f 和任意 $\varepsilon > 0$ ，存在一個方程式 (2.9) 的和 $g(x)$ ，對所有 $x \in [0,1]^n$ ，滿足 $|g(x) - f(x)| < \varepsilon$ 。

3.2、建立小波神經網路

本研究採用 Zhang[13][16]所提出的方式建立小波神經網路，以下就如何決定網路架構、建立網路、及如何初始化網路提出說明。小波網路結合了小波分解 (2.4) 和神經網路結構 (圖 3.2)，其架構如圖 3.3 所示。在圖 3.3 中，平移、脹縮和小波的組合置於同一排，本文中稱此為一個小波元(Wavelon)。假如欲被近似的函數含有部分的線性性質存在，為了更精確去近似此函數，可加入一個平行於網路 (2.5) 的額外的線性組合，以利網路將此線性性質考慮進去。故將 (2.5) 修正後，產生下式：

$$f(x) = \sum_i w_i a_i^{-\frac{d}{2}} \psi\left(\frac{x-t_i}{a_i}\right) + c^T x + b \quad (3.1)$$

式 (3.1) 的另一種表示法為

$$f(x) = \sum_{i=1}^N u_i \psi(a_i \times (x - t_i)) + c^T x + b \quad (3.2)$$

於圖 3.3 已顯示了如 (3.2) 中所含的線性組合項。

圖 3.4 展示如何利用 WNN 近似任一函數的演算法則。首先，決定以下的工作參數：

- (1) 網路結構參數--例如小波母波函數與小波元數目。在多種存在的母波函數中，本研究所採用之母波為

$$\psi(x) = (x^T x - n) \times e^{-\frac{1}{2}x^T x}, x \in R^n \quad (3.3)$$

選擇這個小波的優點是因為它是 radial、平滑且集中在時間和頻率域上。圖 3.5 顯示這個小波的圖形，當 $n=1$ 時。

在 ANN 中的隱藏層的數目和神經元 (節點) 的數目常以非系統化的試誤法決定的。然而，隱藏層數目明顯地影響 ANN 的學習效率與預測結果。如同 ANN 中的隱藏層和神經元的數目一樣，WNN 中小波元的數目的決定也是很重要的。有別於傳統類神經網路 (ANN)，WNN 可以使用一個系統化的方式決定網路參數。網路中的小波元數目的選擇可以依賴統計學中的標準模型順序的適當型態來決定。本研

究以 Akaike's 終極預測誤差理論 (FPEC) 來協助決定小波網路中之小波數目。誤差理論 (FPEC) 定義如下

$$J_{FPR}(\hat{f}) = \frac{1+n_p/N}{1-n_p/N} \frac{1}{2N} \sum_{k=1}^N (\hat{f}(x_k) - y_k)^2 \quad (3.4)$$

其中參數 n_p 是在估計式中的數目， $(x_k, y_k) \in O_1^N$ 代表第 k 個訓練資料，而 N 是訓練資料的樣本長度。對於 WNN 而言，因為純量脹縮參數被使用於初始化，每個小波在 (3.2) 會有一個脹縮， d 個平移和一個線性參數。此外，此網路有 $d+1$ 個直接線性連接 (direct linear connection)。因此，初始化小波網路的參數數目如下：

$$n_p = M(d+2) + d + 1 \quad (3.5)$$

其中 M 是網路中的小波數目， d 是輸入維度。其實 $J_{FPE}(\hat{f})$ 只是估計式的平方誤差 (MSE) 的平均值乘以懲罰因子。當使用利用正交性所做的逐步搜尋時，在每一個小波被選擇後， $J_{FPE}(\hat{f})$ 就會被計算出，當選擇的小波的參數數目大於或等於訓練資料的樣本長度 N ，或當所有在函式庫中的小波已被選擇時，這個過程就會停止。最後，小波數目 M 係將 $J_{FPE}(\hat{f})$ 最小化得到。

- (2) 小波初始化參數--例如尺度層數 (scale levels) 和每個小波元應包含的輸入型態的最小數目。掃描的尺度層數的數目和每個小波元應該包含的輸入型態的最小數目，可以經由下列經驗法則決定：

$$\min_nbw = 2 + nb \text{ var} \quad (3.6)$$

$$\text{levels} = 4 \quad (3.7)$$

其中 \min_nbw 是每個小波元應包含的輸入型態的最小數目

$nb \text{ var}$ 是輸入變數的數目

levels 是初始化期間所掃描的尺度層數數目

- (3) 訓練參數--例如訓練代數的最大值和結束條件。

再根據初始參數，網路中的小波是基於樣本的輸入輸出資料來選擇，在回歸選擇小波之後，網路中的小波元 (一開始是經由 (3.2) 中的 a_i 和 t_i 建立) 即被建立。再者，網路中的權值 ((3.2) 中的 u_i) 是經由假牛頓 (Quasi-Newton) 演算法計算。在迭帶訓練和調整 (3.2) 的參數 a_i 、 t_i 和 u_i 後，量測輸出值和預測輸出值的差應達到最小值，則 WNN 便建立完成，且可以模擬工程行為。

3.3、學習演算法

由於 BP 神經網路通常需要大量的學習時間，而且其網路收斂速度非常倚靠學習率的選擇。因此，本研究採用較有效率的演算法--假牛頓法 (Quasi-Newton's method)。此方法利用一個矩陣去近似 Hessian 或其反矩陣，而不需要計算二次導數，這樣計算變的較快也較容易。目前常用的兩個近似法分別為 one step secant(OSS) 法 (也稱為 Davidson-Fletcher-Powell (DFP)) 和 Broyden-Fletcher-Goldfarb-Shanno (BFGS) 法。本研究係採用 OSS 法來訓練小波神經網路。

OSS 法並不會儲存完整的 Hessian 矩陣，假設在每一迭代中，前一個 Hessian 矩陣是一個單位矩陣。因此，複雜的矩陣運算簡化成較簡單的向量運算。OSS 法的主要演算過程圖示於圖 3.6 與 3.7 中。於 OSS 法中，每次迭代只需求出梯度向量 g_{k+1} ，新的搜尋方向 p_{k+1} 則可由下式獲得：

$$p_{k+1} = -g_{k+1} + A_k s_k + B_k y_k \quad (3.8)$$

其中 $y_k = g_{k+1} - g_k$

而純量 A_k 和 B_k 是由前次定義的向量 s_k, g_{k+1} 和 y_k 的乘積而得

$$A_k = -\left(1 + \frac{y_k^T y_k}{s_k^T y_k}\right) \frac{s_k^T g_{k+1}}{s_k^T y_k} + \frac{y_k^T g_{k+1}}{s_k^T y_k}; \quad B_k = -\frac{s_k^T g_{k+1}}{s_k^T y_k} \quad (3.9)$$

每一迭代中取得需尋方向 p_{k+1} 後，接著須沿著此方向決定搜尋步幅 λ_{\min} (一維最小化)。一維搜尋是基於拋物線近似法求得；假設 E_0 為第 k 次迭帶之系統誤差值，沿著 p_{k+1} 方向求得 E 滿足 $E'_0 \times E'_\lambda < 0$ ；若不滿足則增加學習率 λ ($\lambda \leftarrow \lambda \times 1.1$) 至滿足上述條件為止。再由在初始點的 E_0 值和 E'_0 值和在該點的 E_λ 值可決定一拋物線如下：

$$P(x) = E_0 + E'_0 x + \left[\frac{E_\lambda - E_0 - \lambda E'_0}{\lambda^2}\right] x^2 \quad (3.10)$$

則搜尋步幅 λ_{\min} 可由下式求得：

$$\lambda_{\min} = \frac{-E'_0}{2\left[\frac{E_\lambda - E_0 - \lambda E'_0}{\lambda^2}\right]} \leq \frac{1}{2(1 - G_{devr})} \lambda \quad (3.11)$$

肆、結構損壞偵測驗證

4.1、結構系統概述

為驗證本研究所提基於小波神經網路架構之系統識別模式，以及結構診斷策略之可行性，本節將首先以小波神經網路處理振動台試驗之測量反應資料。所用之數據為國家地震工程研究中心所提供。如圖 4.1 所示，此試驗之主體為一 3 公尺長、2 公尺寬、6.5 公尺高的五層鋼構架。該構架於各樓層皆放置了鉛塊，使其各樓層之質量達到約 3664 公斤。該結構之動態試驗中，以不同強度的 Kobe 地震（強度由 8% 變動至 60%）作為於振動台之輸入地表加速度，在振動台之振動下，記錄各不同地震下的位移、速度、加速度反應歷時資料[28]。此外，在靠近一樓樓版的柱子上，安裝了一些應變計以觀察該柱變形過程。實驗時的採樣頻率為 1000 Hz，然而為考量實際應用上的一般採樣頻率，且減少資料之維度 (dimension) 而不失去原動力反應的特徵，因此將原資料透過低通 (lowpass) FIR 濾波器之處理後，獲得採樣頻率為 100 Hz 的地震反應資料。

值得一提地是，由該實驗的應變計紀錄結果發現[28]，在地震強度小於 52% 的振動情形下，結構的反應仍在線性範圍內，而同時根據 Huang 針對不同地震下的模態識別結果[10]亦可知，在地震強度小於 52% 之內所識別的模態參數並無明顯變化。而在地震強度 60% 的振動時，根據應變計資料與目測檢查的結果顯示，靠近一樓樓層的柱子已發生降伏的現象，同時識別之模態參數亦與其他地震下所獲得之結果有所差異。

4.2、基於小波神經網路所架構的系統識別模式

4.2.1、系統識別模式

系統識別的方法允許工程師基於測量資料建立一個動力系統的數學模型。其識別過程主要在調整一個已知數學模型的係數，直到該模型的計算輸出值與實際測量到的輸出值相合為止。傳統上大部分的所採用的模型是由微分方程式所建立的數學模型，例如 ARX 模型、ARMAX 模型、以及線性狀態空間模型。

最近，黑盒子 (black-box) 非線性模型，例如類神經網路，模糊模型等等，已經大量被使用。然而，對於真實的結構系統而言，無論以何種方式建立系統之數學模型，都無法與真實系統之間完全符合，我們可以做的便是以更為精確的方法去近似真實的系統。因此，在本報告中，將討論使用小波神經網路架構系統識

別模型的能力，而後進一步研究將其應用至結構損壞檢測之可行性。

我們將利用小波神經網路從事一多重輸入單一輸出 (MISO) 系統的動力模擬。在本研究中，訓練集合包含了三個長度為 n 的數列：兩個輸入數列 $\begin{Bmatrix} u_a(n) \\ u_b(n) \end{Bmatrix}$ 和一個測量的輸出數列 $\{y_p(n)\}$ 。這三個數列轉換為系統在時間 t 的輸入輸出，分別為 $u(t), y(t)$ 。

根據一些系統識別[29][30]的書，系統輸入與輸出之間最基本的關係，可用線性微分方程式來加以描述：

$$y(t) + a_1 y(t-1) + a_2 y(t-2) + \dots + a_{n_a} y(t-n_a) = b_1 u(t-n_k) + \dots + b_{n_b} u(t-n_k-n_b+1) \quad (4.1)$$

n_a 等於極點 (poles) 的數目， $n_b - 1$ 是零點 (zeros) 的數目， n_k 是系統的延遲時間 (pure time-delay)。(4.1) 也可以表示為

$$y(t) = f(y(t-1), \dots, y(t-n_a), u(t-n_k), \dots, u(t-n_k-n_b+1)) \quad (4.2)$$

這個方程式以延遲輸入輸出的函數展開來描述系統。從微分方程式導出，一些研究指出許多種離散時間非線性系統可以由 NARMAX 模型表示。在一個我們想要的精確度之內近似一個系統的能力，在於適當選擇已知函數的集合。多項式函數的集合在連續空間中是緊密的，他為函數提供了完備性 (completeness) 以模擬非線性系統。由於小波函數近似的能力，他便參與在 NARMAX 模型中。

一具有 r 個輸入和 m 個輸出的非線性離散時間系統的 NARMAX 模型可表示如下：

$$y(t) = f(y(t-1), \dots, y(t-n_y), u(t-1), \dots, u(t-n_u), e(t-1), \dots, u(t-n_e)) + e(t) \quad (4.3)$$

其中

$$\begin{aligned} y(t) &= [y_1(t) \quad y_2(t) \quad \dots \quad y_m(t)]^T \\ u(t) &= [u_1(t) \quad u_2(t) \quad \dots \quad u_r(t)]^T \\ e(t) &= [e_1(t) \quad e_2(t) \quad \dots \quad e_m(t)]^T \end{aligned} \quad (4.4)$$

各是系統的輸出、輸入和噪音向量， $e(t)$ 是一個零平均 (zero-mean) 獨立數列， $f(\cdot)$ 表示非線性函數向量 (vector-value)。

在此，我們延伸小波神經網路 (3.1) 的使用到近似由以下模型控制的非線性系統：

$$y(t) = f(y(t-1), \dots, y(t-n_y), u(t-1), \dots, u(t-n_u)) \quad (4.5)$$

上式中忽略了 (4.4) 中的雜訊，結構反應的測量的資料必須由重新採樣和經過濾波處理。

4.2.2、小波神經網路識別模型架構與測試

在五層鋼構架案例驗證中，小波神經網路之輸入與輸出變數設計如圖 4.2 所示。一、三樓的反應資訊將作為小波神經網路之輸入變數，而二樓之反應資訊將作為網路之輸出變數。不使用所有自由度而僅採用此三自由度之反應資訊原因如下：真實結構之自由度眾多，一般上僅能測量少數我們所關切的自由度之反應；由報告[28]中指出，靠近一樓樓層的柱子在 60% Kobe 地震力振動下已發生降伏的現象，在降伏發生處附近所測量到的反應資料，較能夠明顯反應出降伏情況的發生。雖然整個系統是動力系統，但在 (4.5) 中的非線性對應 f 是靜態的。因為這個模型基於過去的資料給予系統預測輸出，這個過程會導致預測輸出的誤差累積。我們提出了一個回饋 (feedback) 預測網路，如圖 4.3。在訓練時，使用原本測得的資料作為輸入輸出資料。在訓練後，則使用預測輸出和原本測量得的資料為過去時間輸入資料來預測下一次時間的輸出。圖 4.4 為小波神經網路訓練時的靜態網路。

關於小波神經網路的訓練資料，此處採用了 20% Kobe 地震力振動下的結構反應資料。在此地震下，該五層鋼架結構之行為呈線性。另外，亦只取結構長向 (3m 之方向) 之地震反應記錄來作分析。其輸入地震與結構加速度反應歷時圖如圖 4.5 所示。整個 20% Kobe 地震下的歷時反應資料將作為訓練小波神經網路的學習案例。

本研究中，使用小波神經網路做系統識別的工作有幾下幾點：

1. 估計動力模型參數，亦即在 (4.5) 中的階數 n_y, n_u 。
2. 決定小波神經網路參數，例如小波元的數目，被掃描的尺度層數的數目，每個小波元應包含的輸入型態的最小數目和最大代數。
3. 估計預測結構反應的適合度 (fitting)，並證明小波神經網路模型的預測品質。

本研究中，預測品質的測量是由正規化平方誤差之均方根 (RMSE) 定義：

$$RMSE(\hat{y}) = \frac{\sqrt{\sum (y - \hat{y})^2}}{\sqrt{\sum (\hat{y} - \bar{y})^2}} \quad (4.6)$$

其中 y 是真實的量測值， \hat{y} 是預測輸出， \bar{y} 是預測輸出的平均值。RMSE 愈小則表示預測能力愈好。

4. 根據前面步驟所決定的參數模擬在不同輸入外力下結構的動力行為。

在本例的小波神經網路訓練階段中，一至三樓在過去時間的加速度反應為小波神經網路的輸入值，而二樓現在的加速度反應則為網路之輸出值。而在小波神經網路的預測階段，過去時間所測量一、三樓加速度反應以及前時刻由網路預測所得二樓加速度反應，成為網路之輸入值，透過網路之計算來預測下一時刻的二樓加速度反應。因此對應於 4.1 節中之敘述， $u_u(n), u_b(n)$ 在此例中即為一、三樓的加速度反應，而 $y_p(n)$ 則是二樓的加速度反應。

首先我們試著去決定適於描述結構行為的動力模型階數，在(4.5)中的 n_y, n_u 。我們假設 n_y 等於 n_u ，對大部分的情況而言，這個假設是合理的。圖 4.6 是選擇許多不同模型階數 (model order) 的測試結果。初始化和訓練所花的計算時間與由 RMSE 所表示的預測精度，都是選擇模型階數的考慮因素。圖 4.7 說明了階數 10 可以滿足這兩個條件。接下來便要決定網路參數。被掃描的尺度層數的數目和每個小波元要包含的型態的最小數目，由在章節 3.2 所提到的經驗法則來決定。小波元的數目則由 Akaike's FPEC 預測，預測結果如圖 4.8 所示。結果顯示，小波元的數目只需要一個，就足以做本系統之動態模擬。選擇最大代數的測試結果如圖 4.9，顯示訓練代數在 20 次後，小波神經網路便會收斂。但由於要節省計算時間，我們只選擇 10 次作為訓練代數。

待小波網路經訓練完畢之後，再以同地震加以驗證其表現，並繪其結構反應歷時於圖 4.10。由圖 4.10 中可看出網路的預測反應與真實反應之間極為吻合。顯示了這樣的小波神經網路架構已能夠相當準確的描述此系統的動力行為。

4.3、小波神經網路於五層鋼構架的破壞診斷

利用前小節所訓練完成的小波神經網路，分別就不同地震下的結構反應作分析，這些地震資料包括：32%、40%、52%、以及 60% Kobe 地震下的結構反應資料，將其歷時圖分別繪於圖 4.11~4.14 中。依據本報告所提之診斷策略，在結構尚未有破壞情況發生時（地震強度小於 52% 之 Kobe 地震），小波神經網路將能夠適切的描述結構的動力行為，亦即網路之計算輸出反應與實際測量反應之間將極為吻合（RMSE 值將很小）；而在結構發生破壞時（60% 之 Kobe 地震振動下），原網路架構將不足以描述破壞結構之動力行為，而導致網路之計算輸出反應與實際測量反應之間明顯差異（RMSE 值大幅增加）。

根據分析的結果（圖 4.15）顯示，以 20% Kobe 地震資料訓練之小波神經網路能夠準確的預測 20%、32%、40%、以及 52% Kobe 地震資料，其 RMSE 值皆在 0.07 之內，同時與訓練資料（20% Kobe 地震資料）之 RMSE 差異亦在 0.03 之

內。但是對於 60% Kobe 地震資料之預測上，確有明顯的誤差存在，其 RMSE 超過 0.2，與訓練資料之 RMSE 差異亦超過了 0.17。

因此，由本節驗證的過程與結果可證明：

1. 小波神經網路所架構的系統識別模式可精確地進行系統的動態模擬。
2. 所提的小波神經網路結構檢測策略可進行結構破壞發生之診斷。

伍、應用至橋樑實測地震反應之損壞偵測

5.1、橋樑與測站資料概述

在本節中，我們將藉由前節的經驗，重新架構一個用於橋樑地震反應的動力模型，來模擬真實的系統。此結構為台北市東西向快速道路高架橋，其為一種特殊型態的鋼橋，採用高架橋與地下街共構的方式。該橋西起環河北路與鄭州路口，由鄭州路經華山車站北側至金山街，延續鐵路縱貫線至光復南路後，再沿鐵路局北機場與公賣局菸廠交界，跨基隆路至永吉路，長約 6.4 公里。位於華山車站附近，林森北路至金山街段橋墩 P155 到 P158，安裝有強震儀。如圖 5.1 所示，橋梁各跨度皆為 33 公尺，橋長 99 公尺，橋寬為 26 公尺，橋高為橋面至設計地面之高度，為 13 公尺，橋面為 22 公分厚的 RC 橋面板，以及 5 公分厚的 AC 鋪面。橋梁之結構型式為三孔連續立體剛構鋼梁橋。上部結構為 4 支箱型梁（如圖 5.2），梁寬 2.8 公尺，梁高約 1.2~1.8 公尺。於中間連續部分由中間連續部分由 4 支主梁與橋墩帽梁形成立體剛構；於銜接兩側橋梁處（即伸縮縫處），上、下部結構分離，以橋墩柱上方之可動支承支持連接 4 支主梁的箱型端橫梁。每座橋墩為 2 根外徑 2 公尺、柱距 12 公尺的圓形鋼柱所構成（如圖 5.3）。墩柱貫穿高架橋下方之雙層 RC 地下停車場（覆土深約 4 公尺，每層高 4.3 公尺）而至停車場之基礎板，並埋置錨碇螺栓及錨碇構架以傳遞柱底之力量至基礎版。

如圖 5.1 所示，該段橋梁共裝設了 29 個頻道的強震儀（16 個位於地下一層，13 個位於上部結構），文中每個頻道稱之為一個測站，分別可紀錄橋梁軸向（x 向）、側向（y 向）、及垂向（z 向）之歷時反應。位於地下一層可紀錄 x 向反應之測站有 4 個，y 向有 4 個，而 z 向共有 8 個，每根墩柱附近皆有一個測站記錄 z 向之反應，以瞭解墩柱是否產生上下晃動的情形。位於上部結構可紀錄 x 向反應之測站有 4 個，y 向有 6 個，z 向有 3 個。

所獲得的該橋地震資料有兩筆，一為 1999 年 9 月 21 日之 921 主震，一為 2001 年 6 月 14 日之 614 地震。兩筆地震之採樣頻率皆為 197 Hz，因此每筆資料之間約間隔 0.005 秒。

5.2、橋樑之小波神經網路動力模型

依據現有地震資料，我們設計了四種不同的測站組合，分別建立四種小波神經網路之動力模型。此組合列於表 5.1 中，其中編號 1 該列表示小波網路設計是從已測得的測站 CH1 與測站 CH17 之反應來識別測站 CH11 的平均加速度，其識

別軸向為 x 方向，其餘可依此類推。圖 5.4 至 5.7 分別為 921 地震時，四種設計組合下各測站所紀錄之歷時反應。而圖 5.8 至 5.11 分別為 614 地震時，於同地點所紀錄之歷時反應。

本節中小波神經網路之架構將基於 921 地震資料，亦即利用 921 地震資料進行小波神經網路的訓練過程。

參照表 5.1，在本例的小波神經網路訓練階段中，測站 CH1、CH11、CH17 在過去時間的加速度反應為小波神經網路的輸入值，而測站 CH11 現在時刻的加速度反應則為網路之輸出值。而在小波神經網路的預測階段，過去時間所測量 CH1、CH17 之加速度反應以及前時刻由網路預測所得測站 CH11 之加速度反應，成為網路之輸入值，透過網路之計算來預測下一時刻的測站 CH11 加速度反應。於是對應於 4.1 節中之敘述， $u_u(n), u_b(n)$ 即為測站 CH1、CH17 的加速度反應，而 $y_p(n)$ 則是測站 CH11 的加速度反應。表 5.1 中其他組合的資料處理以此類推。

首先需提醒的是，小波神經網路架構時所採用的資料為 921 地震下的反應資料，而所採用的訊號為各測站記錄歷時中第 2001 到 6000 點（約為 10 秒到 30 秒間）的數據。與第四章驗證時相同，首先決定適於描述結構行為的動力模型階數 n_y 及 n_u 。同樣假設 n_y 等於 n_u 。經由比較小波神經網路初始化與訓練所花時間以及測試後 RMSE 的結果，選擇一適當的模型階數 $n_y = n_u = 15$ 。接著關於網路參數如被掃描的尺度層數的數目和每個小波元要包含的型態的最小數目，由在章節 3.2 中所提到的經驗法則來決定。小波元的數目則由 Akaike's FPEC 決定。結果顯示，在本例中，小波元的數目只需要一個就已足夠。而訓練之疊代數在設定為 50 次後，預測誤差將會收斂。以上之參數設定經測試後發現皆可適用於表 5.1 所列之四種組合之下。

5.3、橋樑之損害診斷

根據以上獲得的小波神經網路參數，分別針對四種測站組合下的 921 地震資料加以預測。獲得結果如下：使用測站 CH1、CH11、CH17 的資料（即表 5.1 測站組合編號 1）所得的網路計算誤差之 RMSE 值為 0.1291；使用測站 CH2、CH12、CH18 的資料（即測站組合編號 2）所得的網路計算誤差之 RMSE 值為 0.0797；使用測站 CH18、CH20、CH25 的資料（即測站組合編號 3）所得的網路計算誤差之 RMSE 值為 0.0955；使用測站 CH10、CH20、CH25 的資料（即測站組合編號 4）所得的網路計算誤差之 RMSE 值為 0.0799。其網路計算輸出反應與實際測量反應之結果如圖 5.12~5.15 所示。

接著以同樣的小波網路，分別針對四種測站組合下的 614 地震資料加以預

測。獲得結果如下：使用測站組合編號 1 的資料所得的網路計算誤差之 RMSE 值為 0.3108；使用測站組合編號 2 的資料所得的網路計算誤差之 RMSE 值為 0.1018；使用測站組合編號 3 的資料所得的網路計算誤差之 RMSE 值為 0.1287；使用測站組合編號 4 的資料所得的網路計算誤差之 RMSE 值為 0.1104。其網路計算輸出反應與實際測量反應之結果如圖 5.16~5.19 所示。

根據反應歷時圖來看（圖 5.12~5.19），所架構的小波神經網路對於無論是 921 地震或是 614 地震資料，皆有能力加以預測，其誤差精度雖無法達到第四章之驗證案例的水準，然而對於整個歷時反應之趨勢仍能掌握的相當準確。再就 RMSE 值來討論，921 地震下的 RMSE 皆低於 614 地震下者，主要原因在於小波神經網路是由 921 地震資料（約 10 秒到 30 秒之間的數據）所架構且訓練的。進一步由小波神經網路對 921 地震資料之 RMSE 值來看，除測站組合編號 1（識別方向為 x 向）之 RMSE 較大之外，其餘之 RMSE 值皆小於 0.1，探究此差異性其可能之原因為，921 地震下測站 CH1 之記錄顯示有明顯的高頻反應，而高頻反應對於小波神經網路之預測有負面之影響。而由小波神經網路對 921 地震資料之 RMSE 值來看，同樣地，測站組合編號 1 之 RMSE 明顯異於其他三者，尤其是其 RMSE 值大幅增加至 0.3108，而其他三者之 RMSE 雖有增加，但其幅度並不大。於是再就其地震記錄來觀看，可發現除了測站 CH1 仍有高頻反應之外，連 CH11 及 CH17 皆有這樣的情況，因此更增加了小波神經網路預測的困難度。614 地震之記錄除了以上所說的幾個測站有高頻反應之外，尚有測站 CH18 及 CH25 也有此現象。因此，在此高頻反應來源為何尚未釐清之前，考量小波神經網路對於測站組合編號 2~4（識別方向皆為 y 向）之系統反應良好的預測以及其 RMSE 值未有明顯變化的情形之下，該橋樑於兩次地震之後，應無太大之改變，亦即該橋應無破壞發生之虞。

陸、結論

在本報告之中，我們提出了以小波神經網路架構系統之動力模型，並應用到結構工程的問題以證明其模擬地震下之結構行為的可行性。此外，本報告亦提出了基於小波神經網路之動力模型，所進行的結構破壞診斷策略。

本文中首先於第四章中以國家地震工程研究中心之五層樓鋼構架，於不同強度之 Kobe 地震下的振動台實驗記錄來加以驗證所提模式與策略。其結果顯示，以 20% Kobe 地震資料所建立的小波神經網路動力模型，能夠有效的模擬該地震下的系統反應，網路之計算輸出反應與實際測量反應之間相當的吻合，證明小波神經網路所架構的系統識別模式可精確地描述系統的動力行為。同時，以 20% Kobe 地震資料所建立的小波神經網路動力模型，對於結構未損壞下不同地震力資料（小於 52% 之 Kobe 地震），該網路模型可以準確的描述，但對於受損結構之動力行為（60% 之 Kobe 地震）則否，亦說明了所提的結構檢測策略在結構破壞診斷上的可行性。根據驗證的過程所獲得之建模經驗以及結果，提出以下幾點建議與結論：

1. 小波神經網路之成功有賴於架構小波網路時，工作參數的適當選擇。根據筆者經驗，模型之階數在經過初步設為兩倍之結構系統自由度後（如五層鋼架之驗證案例中，設為 $2 \times 5 = 10$ ），即可獲得不錯的預測結果，而增減模型階數與預測誤差之間並無明顯關聯，同時差異性亦不大。因此，模型階數之選擇重點在於「合適」而非「最佳」。
2. 小波神經網路初始化完成後，網路即可達到相當之精度。因此學習的時間（或疊代次數）遠較一般之類神經網路為低。
3. 架構系統動力模型的小波神經網路節點數不多，也不需要太多的訓練疊代數，以致於計算時間並不需要太多。
4. 使用小波神經網路進行系統之動態模擬可以達到相當顯著的效果。同時，預測結構行為的 RMSE 可以明顯的指出原來結構的變化並且可以用於估計結構的破壞。根據過去動力反應去預測下一個反應的 RMSE 有明顯變化時，暗示了結構行為在外力作用下已經被改變。

最後，本研究進一步將所提小波神經網路系統動力模型與結構破壞檢測策略應用於橋樑實測反應之損壞檢測上。裝設有強震儀之一段位於橋墩柱編號 P155~P158 之間。本研究使用之地表加速度資料有兩筆，一為 1999 年 9 月 21 日之 921 主震記錄，另一為 2001 年 6 月 14 日之地震記錄。根據本研究於橋樑應用上的結果，茲列出以下結論以及尚可進一步研究之建議。

1. 以小波神經網路所架構的橋樑動力模型，能夠適切的描述橋樑實測的動力行

為。

2. 由各測站的歷時資料發現，有些測站有非常多的高頻反應，在本研究中，並未對數據進行濾波程序。而高頻反應對於網路之效能有負面之影響，導致在預測誤差上，無法達到與驗證案例相同之程度。若於橋樑應用中將資料經過濾波後，網路之效能將可獲得改善，但資料經濾波後是否會造成資料上的失真，亦有待進一步的研究。
3. 在應用於橋樑的過程中發現，由於地震資料僅有兩筆，因此若欲以本文所提診斷策略進行診斷會略顯薄弱。因此透過較多的測站組合來加以改善。但於測站之安排上，由於箱型梁上之測站不夠多，導致能夠利用的測站組合較少（僅四組）。針對本橋樑破壞診斷結果上有所薄弱的情況之下，可能的解決之道有二：一為持續獲得其他地震之記錄；二為增加箱型梁上之測站。

柒、參考文獻

1. Sanyayei, M. and Onipede, O., 'Damage assessment of structures using static test data', *Jn*, **29**, pp.1174-1179, 1991.
2. Yao, J. T. P., *Safety and reliability of existing structure*. Pitman, 1985.
3. Ghaboussi, J., Garrett, J. H., and Wu, X., 'Knowledge-based modeling of material behavior with neural networks', *J. Engrg. Mech.*, **117**(1), pp.132-153, 1991.
4. Wu, X., Ghaboussi, J. and Garrett, J.H., Jr., 'Use of neural networks in detection of structural damage', *Computers and Structures*, **42**(4), pp.649-659, 1992.
5. M. F. Elkordy, K. C. Chang, and G. C. Lee, 'Neural networks trained by analytically simulated damage states', *Journal of Computing in Civil Engineering, ASCE*, **7**(2), pp.130-145, 1993.
6. Szewczyk, Z. P. and Hajela, P., 'Damage detection in structures based on feature-sensitive neural networks', *Journal of Computing in Civil Engineering, ASCE*, **8**(2), pp.163-178, 1994.
7. Masri, S. F., Nakamura, M., Chassiakos, A. G., and Caughey, T. K., 'A neural network approach to the detection of changes in structural parameters', *J. Engrg. Mech.*, ASCE, **122**(5), pp.350-360, 1996.
8. Masri, S. F., Smyth, A. W., Chassiakos, A. G., Caughey, T. K., and Hunter, N. F., 'Application of neural networks for detection of changes in nonlinear systems', *J. Engrg. Mech.*, ASCE, **126**(7), pp.666-676, 2000.

9. Hung, S. L. and Kao, C. Y., 'Structural damage detection using the optimal weights of the approximating artificial neural networks', *Earthquake Engineering and Structural Dynamics*, **31(2)**, pp.217-234, 2002.
10. Huang, C. S., Hung, S. L., Wen, C. M., Tu, T. T., 'A neural network approach for structural identification and diagnosis of a building from seismic response data' *Earthquake Engineering and Structural Dynamics*, **32(2)**, pp.187-206, 2003.(Not published yet)
11. C. K. Chui, 'An introduction to wavelets', Academic Press, INC., 1992
12. 'Scanning the special issue on wavelets', The Proceedings of the IEEE, Vol.84, No.4, 1996.
13. Raghuvver M. Rao and Ajit S. Bopardikar, 'Wavelet Transform: introduction to theory and applications', Addison Wesley Longman, Inc., 1998.
14. Qinghua Zhang and Albert Benveniste, 'Wavelet Networks', IEEE Transactions of Neural Networks, Vol. 3, No. 6, pp.889-898, 1992.
15. Qian, Jun, and Shao, Huihe, 'Novel Algorithm of Wavelet Network Structural Design', Journal of Shanghai Jiaotong University, Vol. 33, No.4, pp 422-424, 1999.
16. Jun Zhang, Gilbert G. Walter, Yubo Miao, and Wan Ngai Wayne Lee, 'Wavelet Neural Networks for Function Learning', IEEE Transactions on Signal Processing, Vol.43, No. 6, pp1485-1497, 1995.
17. Qinghua Zhang, 'Using wavelet network in nonparametric estimation', IEEE Transactions on Neural Networks, Vol.8, No.2, pp.227-236, 1997.
18. G. P. Liu, S. A. Billings, V. Kadiramanathan, 'Nonlinear system identification using wavelet networks', UKACC international Conference on Control '98, IEE, 1998.
19. Y. Oussar, I. Rivals, L. Personnaz, G. Dreyfus, 'Training wavelet networks for nonlinear dynamic input-output modeling', Neurocomputing, 20, pp.173-188, 1998.
20. I. Ciuca, J. A. Ware, 'Wavelet networks as an alternative to neural networks', The 6th International Conference on Emerging Technologies and Factory Automation Proceedings, pp.353-358, 1997.
21. Lu, Baiquan; Li, Tianduo, 'Approach of Fault Detection Based on Wavelet Network', Transactions of China Electrotechnical Society v12 n4 97 p 34-36.
22. Yu-Min Cheng, Bor-Sen Chen, and Fu-Yuan Shiau, 'Adaptive Wavelet Network Control Design for Nonlinear', Proceedings of the National Science Council, Republic of China, Part A: Physical Science and Engineering v 22 n 6 Nov 1998 Natl Sci Counc Taipei Taiwan p 783-799.
23. Y. Harkouss, E. Ngoya, J. Rousset, D. Argollo, 'Accurate radial wavelet neural-network model for efficient CAD modelling of microstrip discontinuities', IEE Proceedings - Microwaves, Antennas and Propagation, Vol. 147, Issue 4, pp.277 -

283, 2000.

24. Grafov BM, Grafova IB, 'Discrete Laplace transformation as a wavelet tool to analyse the electrochemical random time series', *Journal of Electro Analytical Chemistry*, 502: (1-2), pp.47-50, Apr 6, 2001.
25. Jang WY, Ryou JR, Lee C, Sohn K, 'Error-resilient zero-tree wavelet image coding technique over noisy channels', *Optical Engineering*, 40: (5), pp.861-867, May 2001.
26. Zhao W, Song YH, Chen WR, 'Improved GPS travelling wave fault locator for power cables by using wavelet analysis', *International Journal of Electrical Power & Energy Systems*, 23: (5), pp.403-411, Jun 2001.
27. Guler I, Hardalac F, Muldur S, 'Determination of aorta failure with the application of FFT, AR and wavelet methods to Doppler technique', *Computers in Biology and Medicine*, 31: (4), pp.229-238, Jul 2001.
28. S. C. Yeh, C. P. Cheng and C. H. Loh, 'Shaking table tests on scaled down five-story steel structures', *NCREE Report No. NCREE-99-002, National Center for Research on Earthquake Engineering*, R.O.C., 1999. (in Chinese)
29. Lennart Ljung and Torkel Glad, 'Modeling of dynamic systems', PTR Prentice Hall, Englewood Cliffs, N.J., 1994.
30. Jer-Nan Juang, 'Applied system identification' PTR Prentice Hall, Englewood Cliffs, N.J., 1994.

表5.1、用於橋樑之WNN系統動態模擬的四種測站組合描述

測站組合編號	選用測站	測站加速度方向	系統輸入	系統輸出
1	CH1, CH11, CH17	X	CH1, CH17	CH1
2	CH2, CH12, CH18	Y	CH2, CH18	CH12
3	CH12, CH20, CH25	Y	CH12, CH25	CH20
4	CH18, CH20, CH25	Y	CH18, CH25	CH20

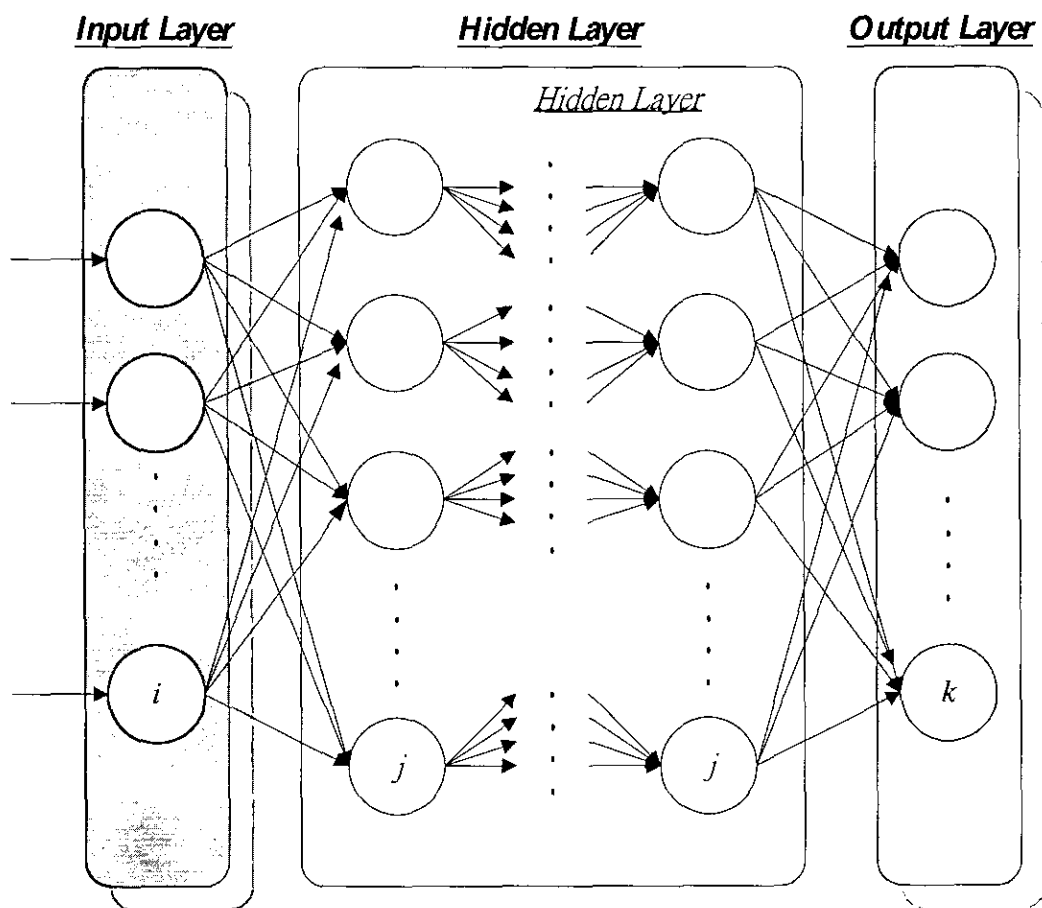


圖 3.1 一典型的 MLP 網路結構

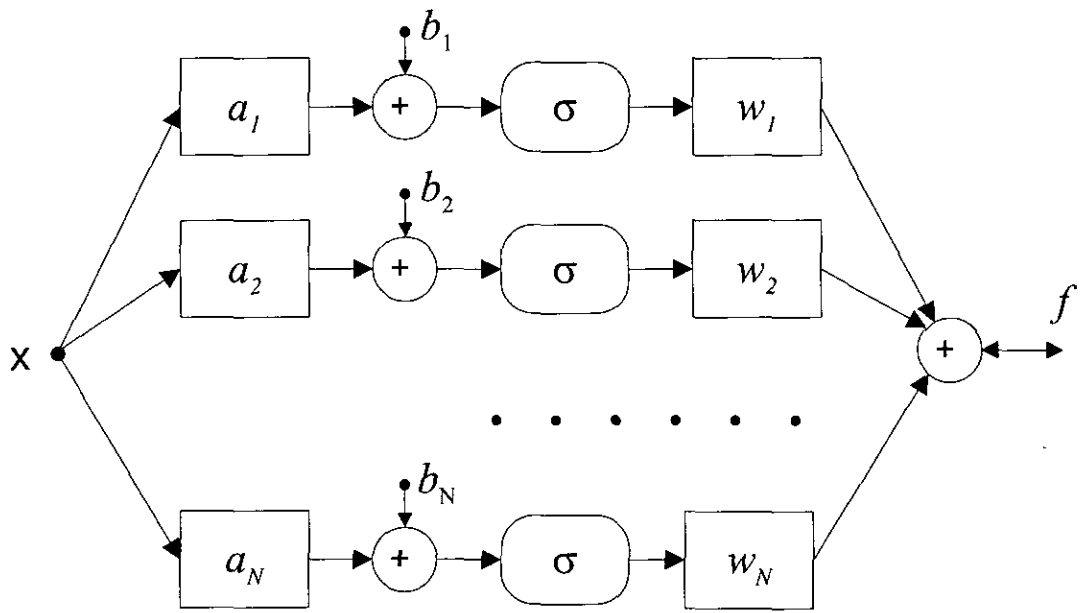


圖 3.2. RBF 網路架構

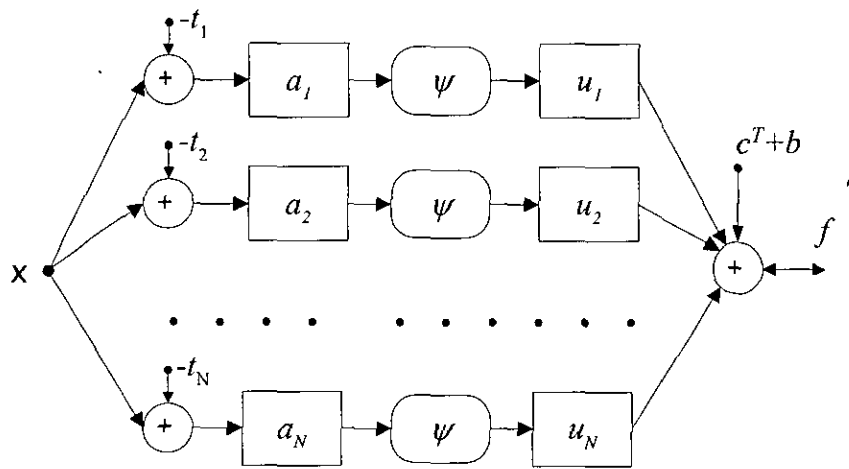


圖 3.3 小波神經網路架構

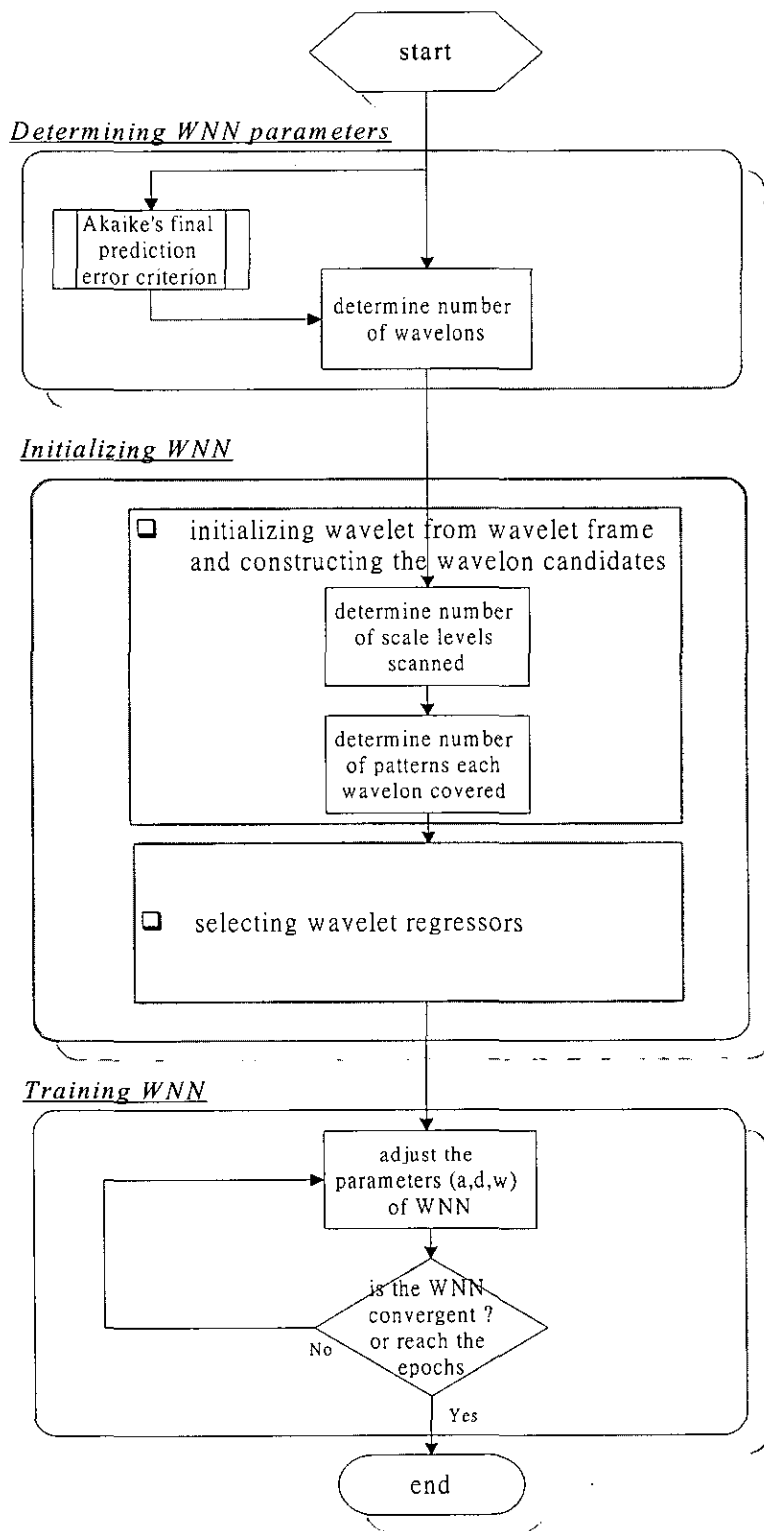


圖 3.4 WNN 演算法則




圖 3.5 本研究所採用之母波函數

```

procedure oss_minimize
begin
  begin_or_restart
  Initialize the learning rate  $\varepsilon := 10^{-5}$ 
  Initialize the average learning rate  $\bar{\varepsilon} := 10^{-5}$ 
  Set  $w_{curr} :=$  random initial weights
  Iterations:=1
  while convergence_criterion_is_not_satisfied do
    begin
      if iteration_is_a_multiple_of_N then
        begin_or_restart
        iterations:=iterations+1
         $\vec{d} :=$  find_search_direction (see eq.3.3)
        if fast_line_search( $\vec{d}$ ) = FALSE then
          begin_or_restart
        end
      end
      procedure begin_or_restart
      begin
        Find the current energy value.
         $\bar{\varepsilon} := \varepsilon$ 
         $\vec{d} := -\vec{g}$ 
        fast_line_search( $\vec{d}$ )
      end
    end

function fast_line_search( $\vec{d}$ )
comment
  Search for a new weight vector starting from the current configuration  $\vec{w}_{curr}$  and
  moving along direction  $\vec{d}$ .  $d_1$  is the directional derivative of  $E$  along  $\vec{d}$ .  $G_{decr}$  is
  a constant equal to 0.5, used to multiply the directional derivative. The constant
  MAX_TRIALS is equal to 10 and can be adjusted by user defined.  $L_{incr}$  is a
  constant equal to 1.1.  $L_{decr}$  is a constant equal to 0.5.
begin
   $d_1 = \vec{g} \cdot \vec{d}$ 
  If  $\vec{d}$  is not a descent direction ( $\vec{d} > 0$ ), reset it to the negative gradient  $-\vec{g}$ :
  if  $d_1 > 0$  then
    begin
       $\vec{d} := -\vec{g}$ ;  $d_1 = \vec{g} \cdot \vec{d}$ 
    end
  end

```

圖 3.6 OSS 小波神經網路學習演算法 (I)

```

Save the value of  $E$  and gradient corresponding to  $w_{curr}$  :
 $E_{saved} := E$ 
 $\varepsilon := L_{incr} \cdot \varepsilon$ 
ok := FALSE; trials:= 0
repeat
  begin
    trials:=trials + 1
     $w := w_{curr} + \varepsilon \cdot d$ 
     $E := E(w)$ 
    if  $E < (E_{saved} + G_{decr} \cdot d_1 \cdot \varepsilon)$  then
      ok := TRUE
    else
      begin
         $\varepsilon_{qual} := \text{parabola\_minimizer}(E_{saved}, d_1, f)$ 
         $w := w_{curr} + \varepsilon_{qual} \cdot d$ 
         $E := E(w)$ 
        if  $E < (E_{saved} + G_{decr} \cdot d_1 \cdot \varepsilon_{qual})$  then
          begin
            ok := TRUE
             $\varepsilon := \varepsilon_{qual}$ 
          end
        else
           $\varepsilon := L_{decr} \cdot \varepsilon$ 
        end
      end
    end
  end
until ok = TRUE or trials > MAX_TRIALS
if ok = TRUE then
  begin
     $\underline{p} := \varepsilon \cdot \underline{d}$ 
     $\underline{w}_{curr} := w$ 
     $\underline{g} := \nabla_w E(w)$  (Only the backward pass of backpropagation is needed at this point.)
     $\varepsilon := 0.9 \cdot \varepsilon + 0.1 \cdot \varepsilon$ 
  end
fast_line_search := ok;
end

```

圖 3.7 OSS 小波神經網路學習演算法 (II)





圖 4.1 國家地震工程研究中心之五層樓鋼構架模型

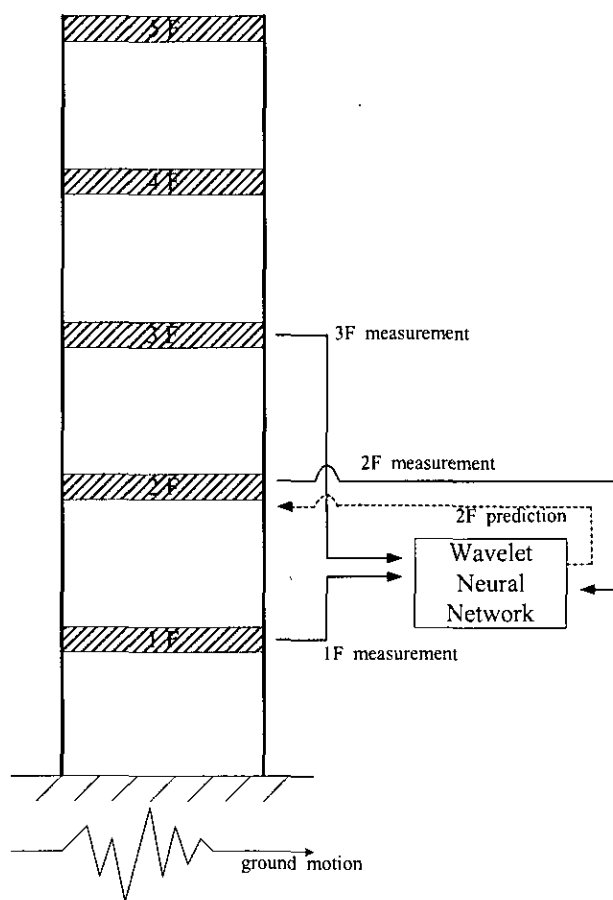


圖 4.2 小波神經網路之輸入與輸出變數安排




圖 4.3 回饋預測網路




圖 4.4 靜態訓練網路



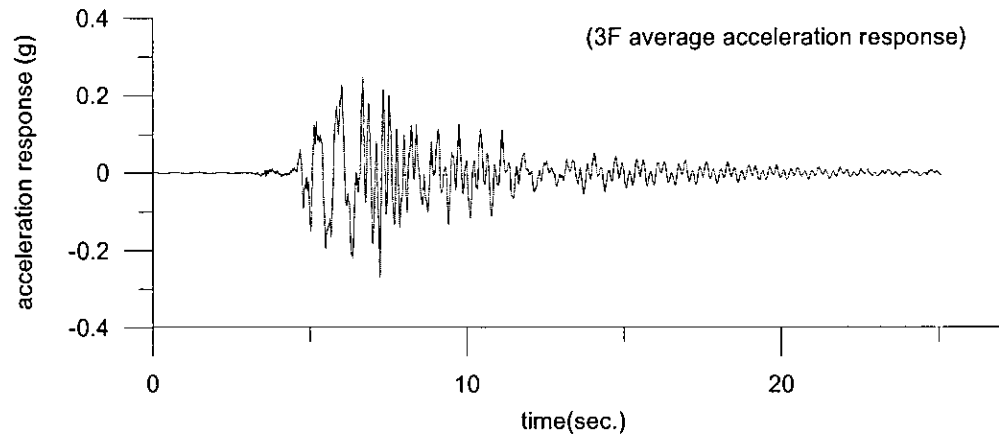


圖 4.5 在 Kobe 20% 外力下結構的 1~3 樓之加速度歷時圖





圖 4.6 動力模型階數測試


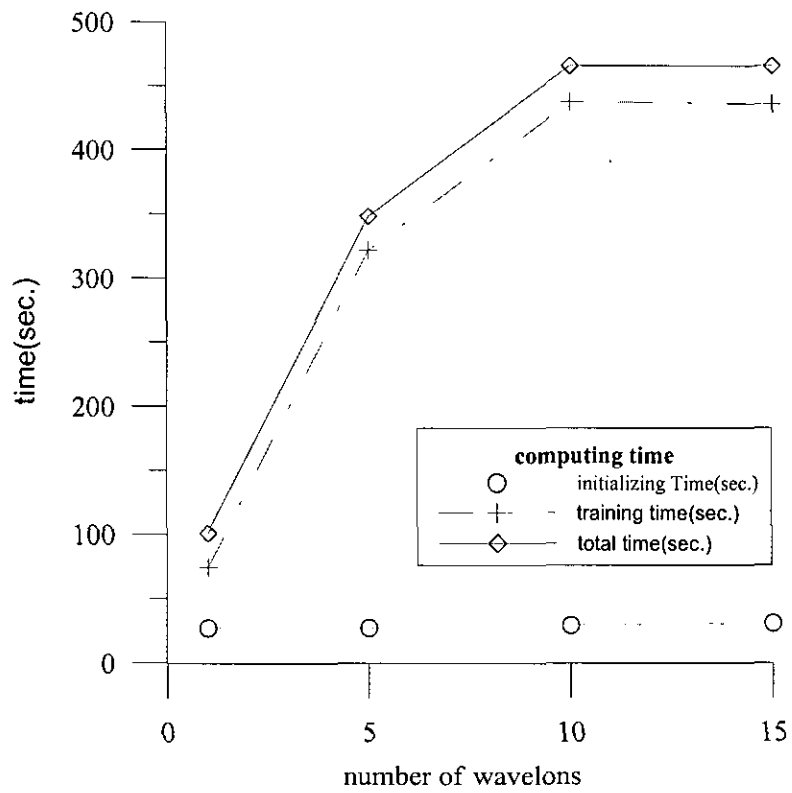


圖 4.7 小波元數目測試

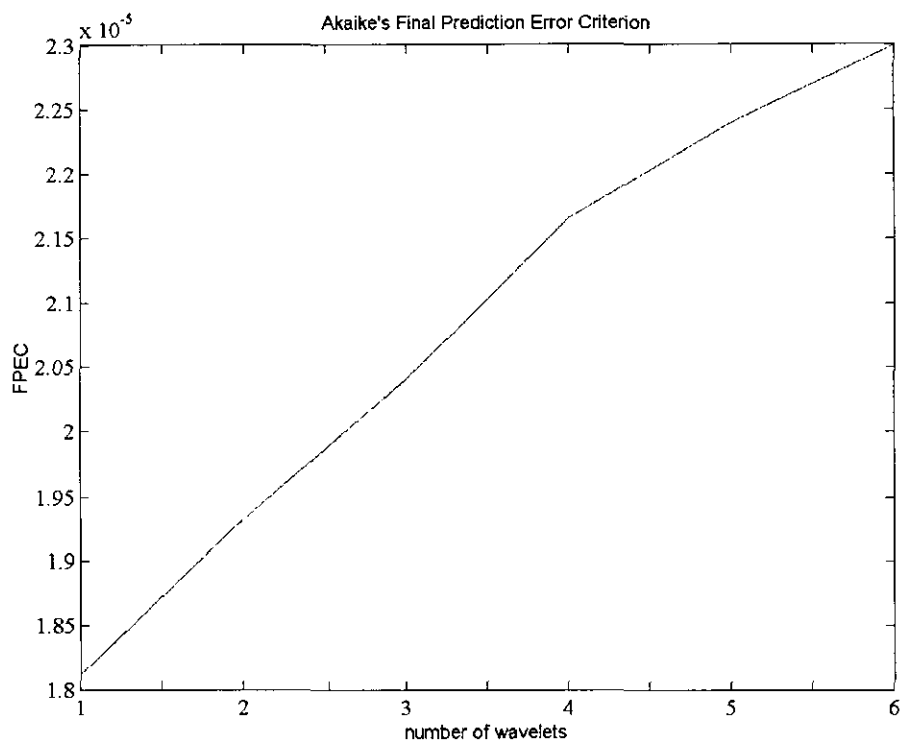


圖 4.8 利用 Akaike's FPEC 預測小波元數目.





圖 4.9 訓練數測試

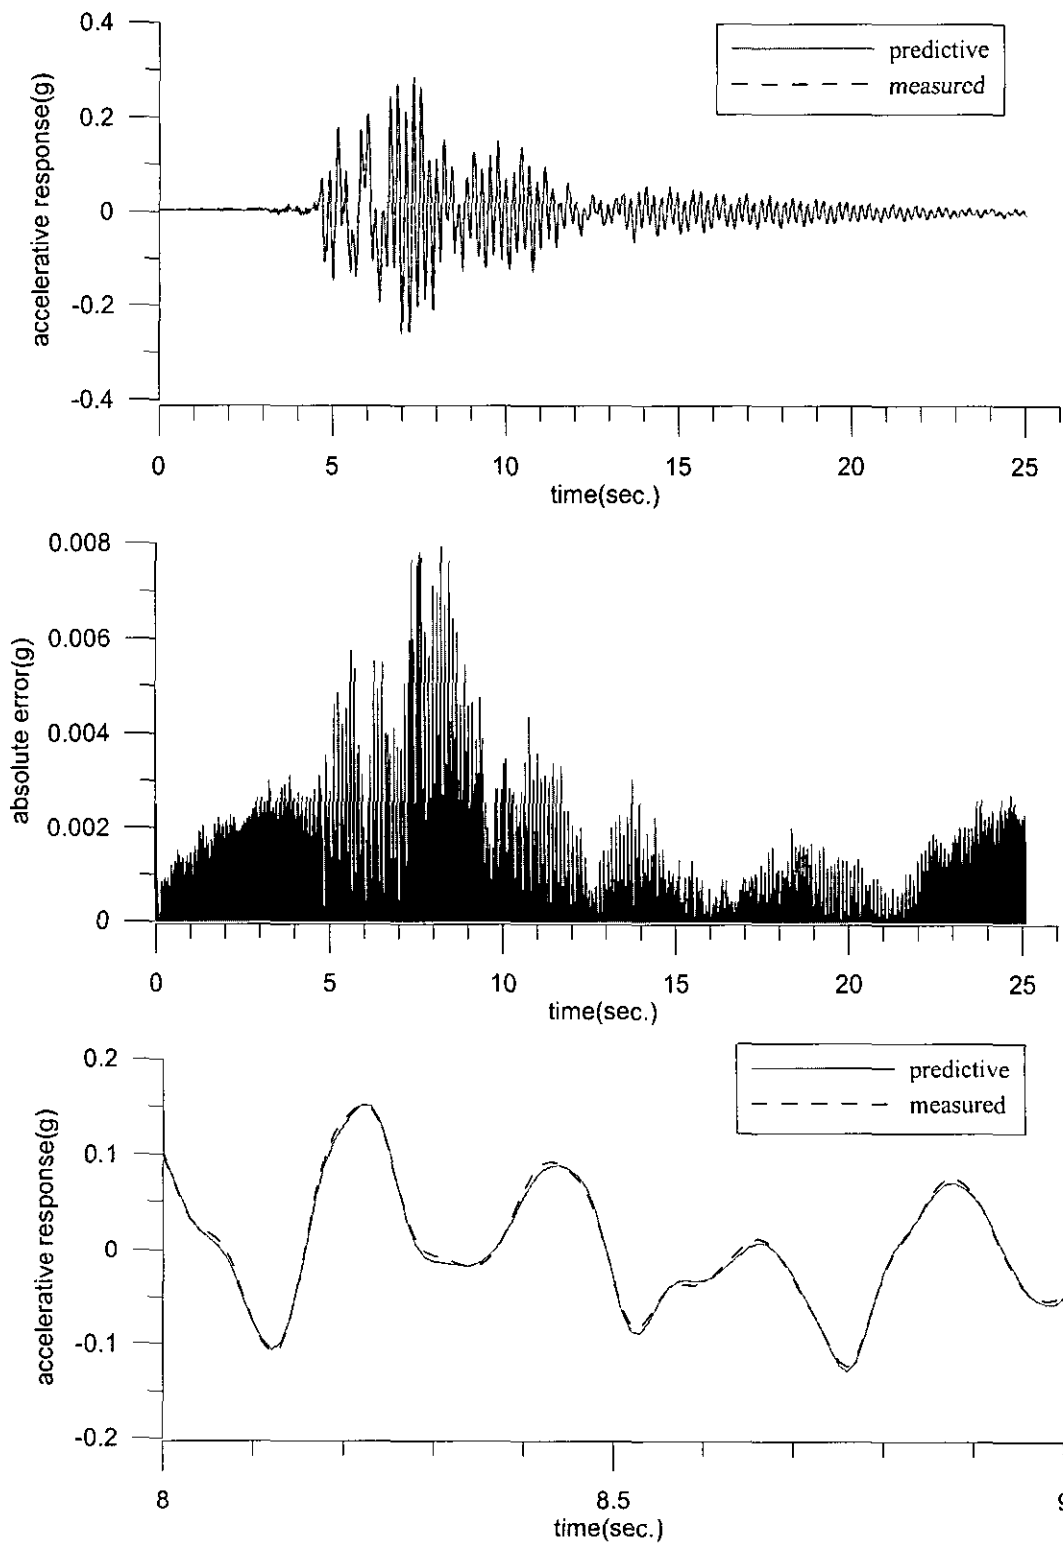


圖 4.10 WNN 動態模擬結果 (以 Kobe 20% 訓練，預測 Kobe 20% 下的反應)

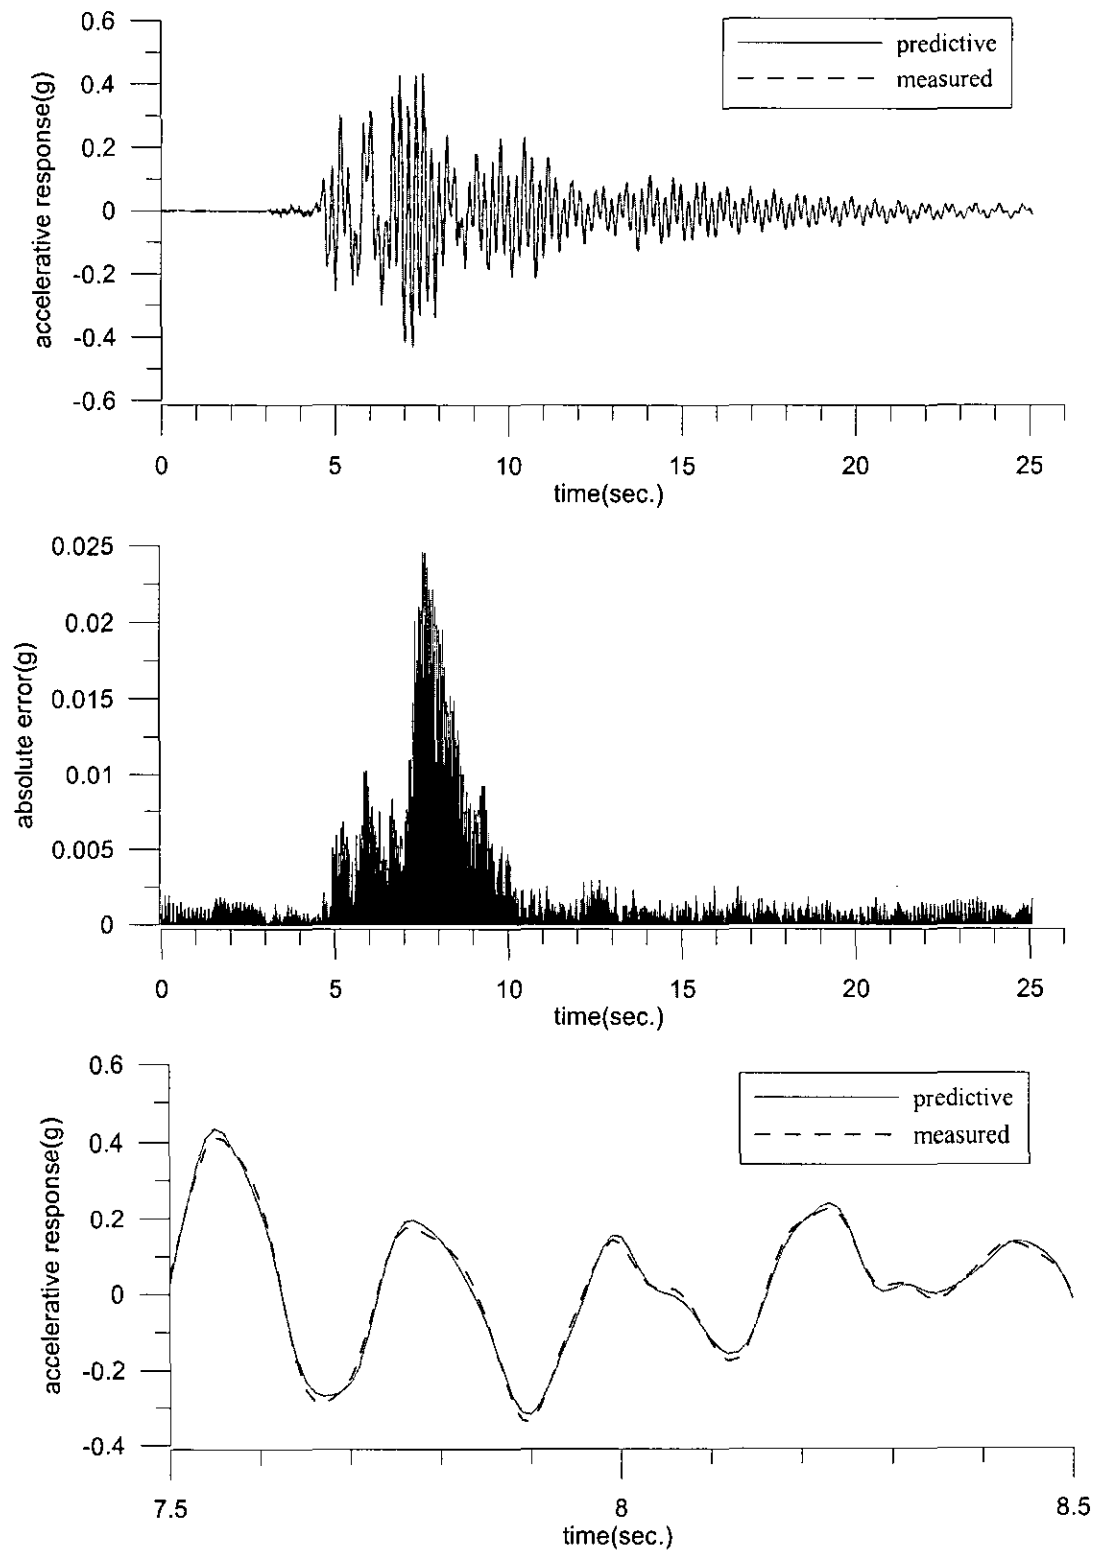


圖 4.11 WNN 動態模擬結果 (以 Kobe 20% 訓練，預測 Kobe 32% 下的反應)

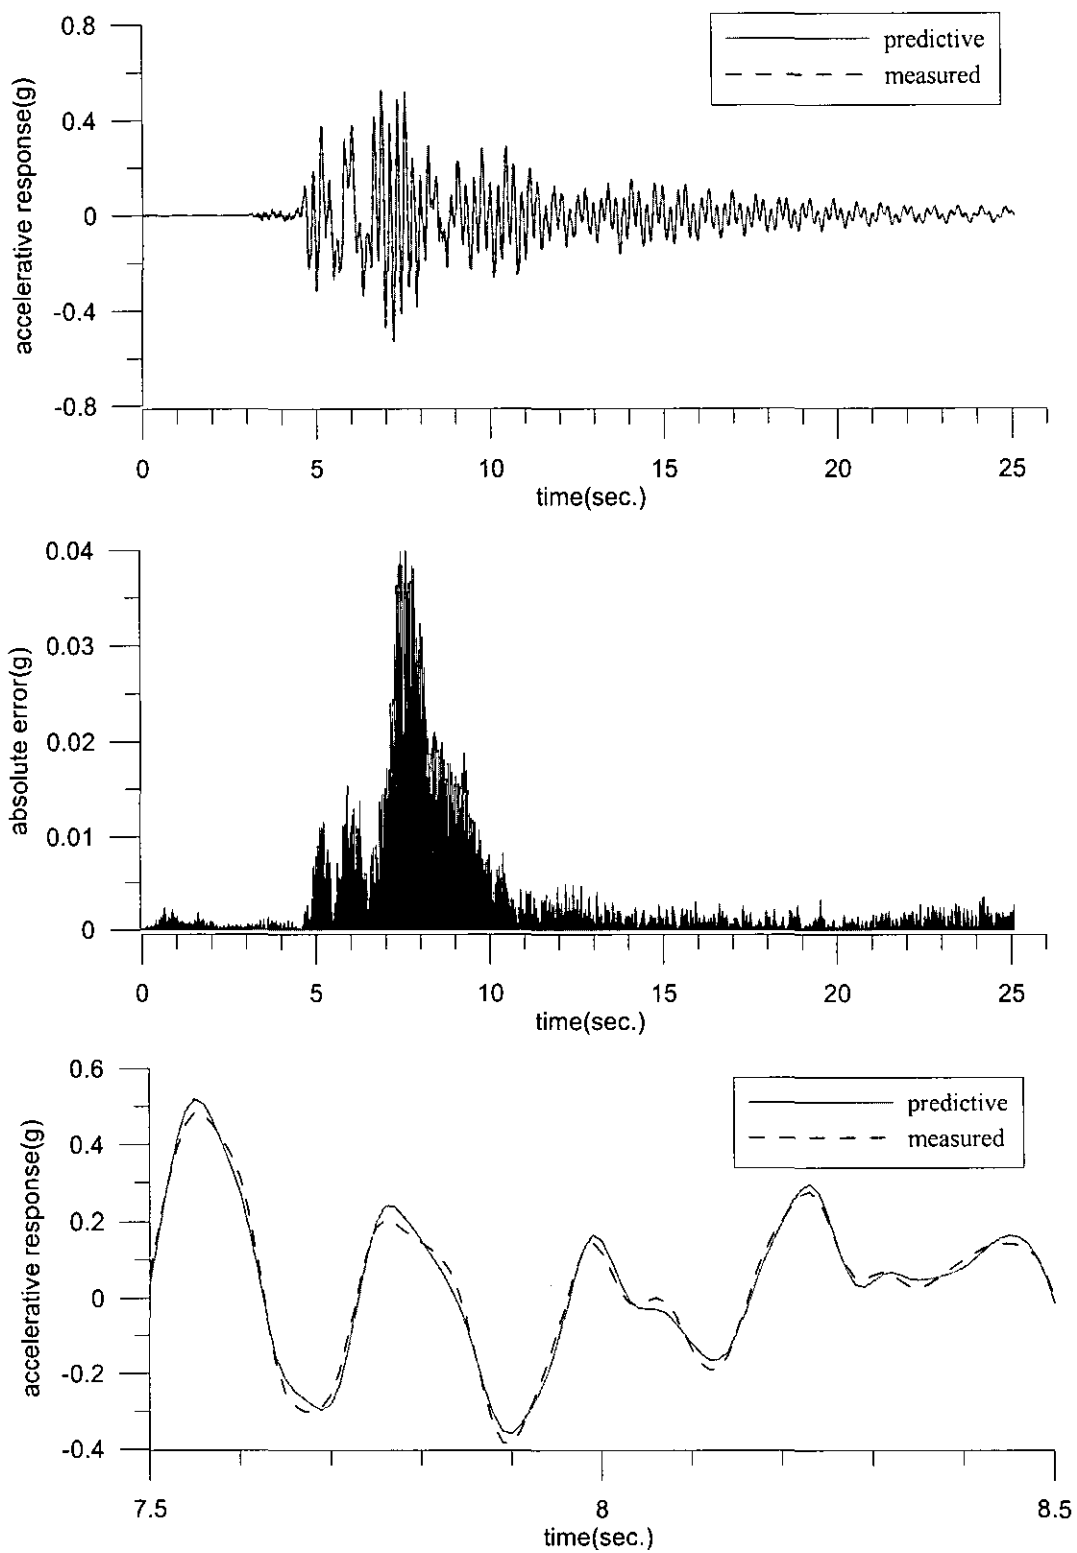


圖 4.12 WNN 動態模擬結果 (以 Kobe 20% 訓練，預測 Kobe 40% 下的反應)

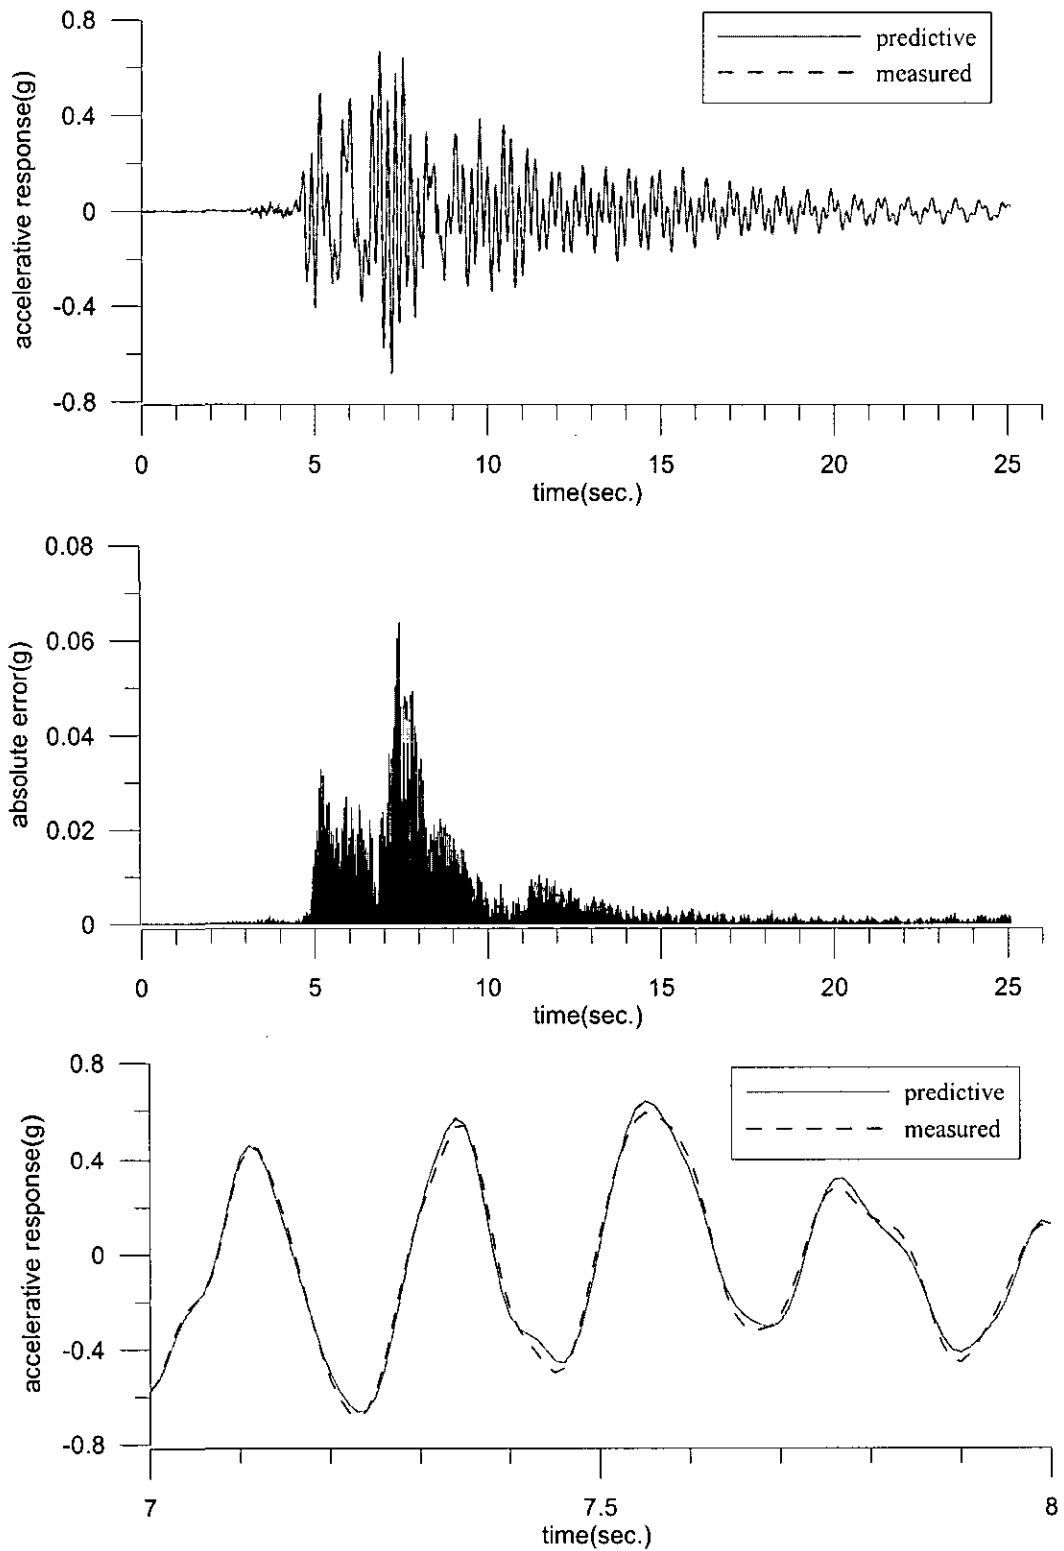


圖 4.13 WNN 動態模擬結果 (以 Kobe 20%訓練，預測 Kobe 52%下的反應)

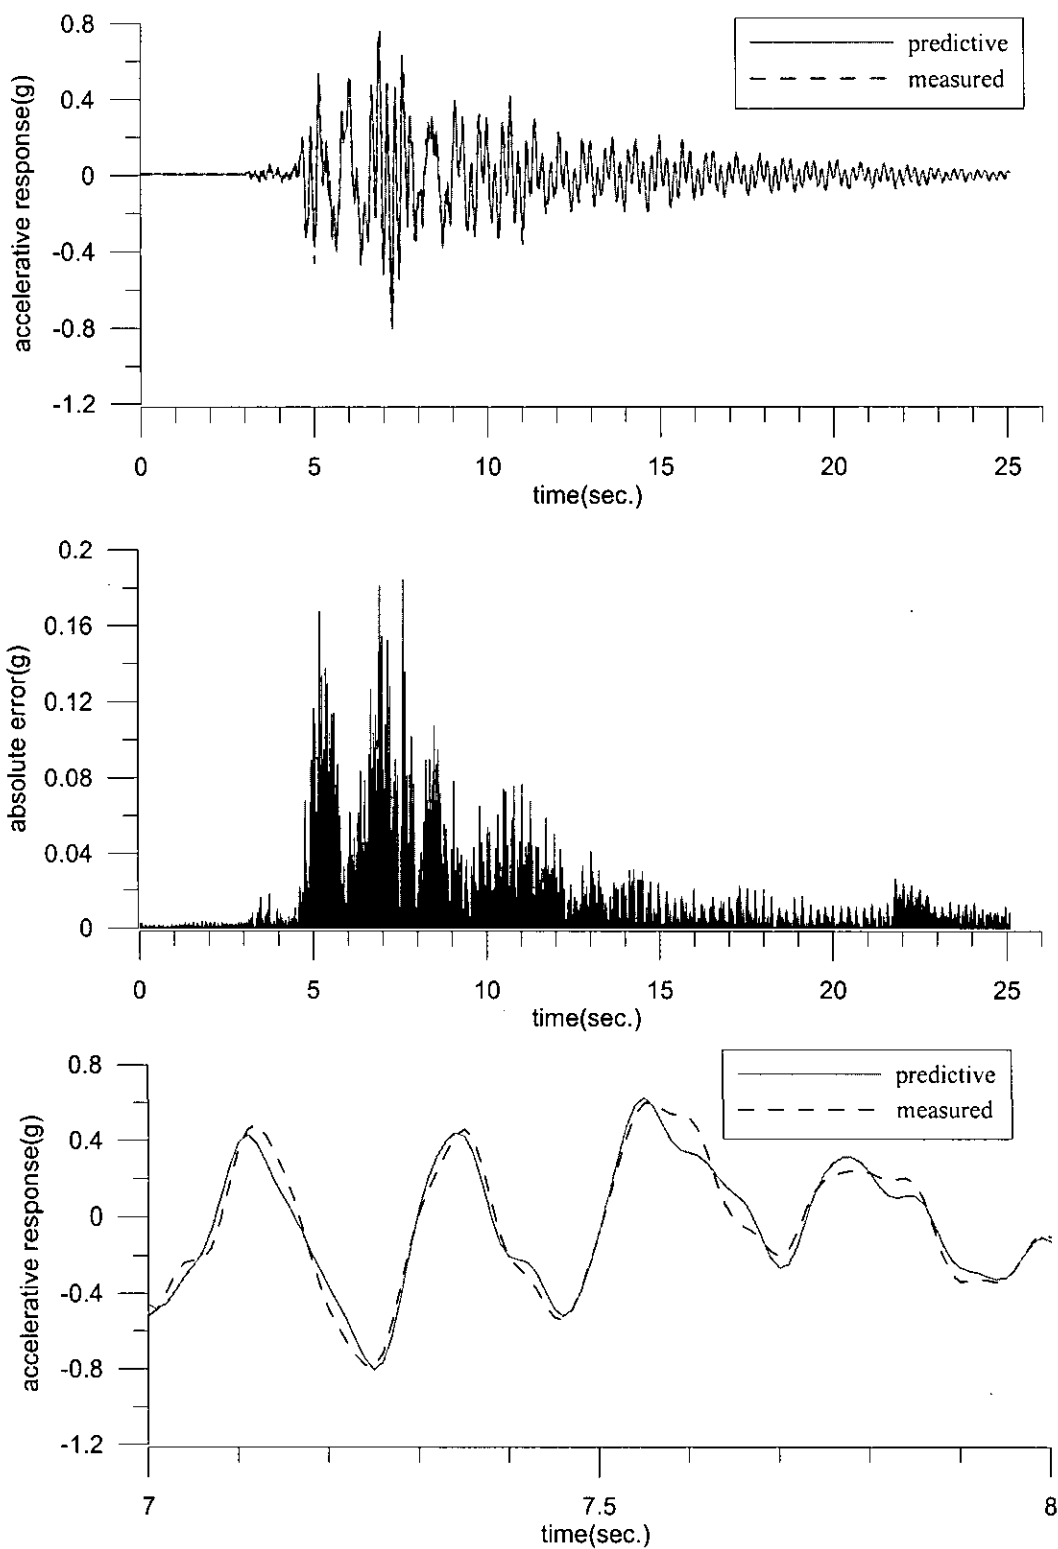


圖 4.14 WNN 動態模擬結果 (以 Kobe 20% 訓練，預測 Kobe 60% 下的反應)






圖 4.15 以 Kobe Ns20%訓練之 WNN 對不同外力反應做系統識別結果



(a) 平面圖



(b) 立面圖

圖 5.1、台北市東西向快速道路高架橋儀器及觀測屋配置圖
(由中央氣象局提供)






圖 5.2、台北市東西向快速道路高架橋 P155~P158 段



P155 橋墩

P156 橋墩

(a)P155 及 P156 橋墩斷面圖



P158 橋墩

P157 橋墩

(b)P157 及 P158 橋墩斷面圖

圖 5.3、P155~P158 橋墩斷面圖
(由中央氣象局提供)




圖 5.4、測站組合編號 1 之加速度反應歷時記錄 (921 地震)




圖 5.5 測站組合編號 2 之加速度反應歷時記錄 (921 地震)




圖 5.6 測站組合編號 3 之加速度反應歷時記錄 (921 地震)




圖 5.7 測站組合編號 4 之加速度反應歷時記錄 (921 地震)




圖 5.8 測站組合編號 1 之加速度反應歷時記錄 (614 地震)




圖 5.9 測站組合編號 2 之加速度反應歷時記錄(614 地震)




圖 5.10 測站組合編號 3 之加速度反應歷時記錄 (614 地震)




圖 5.11 測站組合編號 4 之加速度反應歷時記錄 (614 地震)




圖 5.12 WNN 動態模擬 921 地震資料結果 (測站組合編號 1)




圖 5.13 WNN 動態模擬 921 地震資料結果 (測站組合編號 2)




圖 5.14 WNN 動態模擬 921 地震資料結果 (測站組合編號 3)




圖 5.15 WNN 動態模擬 921 地震資料結果 (測站組合編號 4)




圖 5.16 WNN 動態模擬 614 地震資料結果 (測站組合編號 1)




圖 5.17 WNN 動態模擬 614 地震資料結果 (測站組合編號 2)




圖 5.18 WNN 動態模擬 614 地震資料結果 (測站組合編號 3)




圖 5.19 WNN 動態模擬 614 地震資料結果 (測站組合編號 4)