

ELIMINACIÓN DE RUIDO DE SEÑALES ACÚSTICAS USANDO DESCOMPOSICIÓN DE VALORES SINGULARES Y ANÁLISIS DE COMPONENTES PRINCIPALES

Nicolás Ponso^a, Leonardo Molisani^a, Adriana Zapico^{a,b}, Juan C. del Real^c y Yolanda Ballesteros^c

^a Grupo de Acústica y Vibraciones (GAV), Universidad Nacional de Río Cuarto, Ruta Nac. N° 36 Km 601, 5800 Río Cuarto, Argentina, e-mail: nponso@ing.unrc.edu.ar, lmolisani@ing.unrc.edu.ar, adrianazapico@gmail.com

^b Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Av. Rivadavia 1917 CP C1033AAJ Ciudad de Buenos Aires, Argentina

^c Universidad Pontificia Comillas de Madrid, Alberto Aguilera, 23, 28015 Madrid, España

Palabras Clave: Eliminación de ruido, Redes Neuronales, Nivel de Presión Sonora, Diagnostico de Fallas.

Resumen. Este trabajo se ocupa de la eliminación de contenido no correlacionado en mediciones de funciones de Nivel de Presión Sonora (NPS) de vigas de aluminio pegadas por las técnicas de Descomposición de Valores Singulares (DVS) y por Análisis de Componentes Principales (ACP). La técnica ACP se utiliza con el objetivo de una aplicación posterior de detección de daño estructural. Se utiliza un sistema de adquisición de datos para mediciones de señales experimentales de Nivel de Presión Sonora (NPS) de vigas de aleación de aluminio, las cuales están contaminadas con ruido o contenido no correlacionado. El ruido procede del entorno así como de dispositivos electrónicos. En el enfoque DVS, los datos de cada función de NPS se dividen en un subespacio de la señal original y un subespacio de ruido. Al reducir la contribución del ruido en los vectores singulares y utilizarlos en la reconstrucción de los NPS, se logra una mejora significativa en la separación de la señal medida en datos no contaminados y ruido. En el enfoque ACP, utilizando múltiples mediciones de NPS y por medio de una transformación ortogonal, los datos son convertidos en un conjunto de datos no correlacionados y comprimidos significativamente para su utilización como entrada a una Red Neuronal Artificial (RNA) empleada como herramienta de detección y clasificación de fallas. La RNA posee conexiones hacia delante con algoritmo de entrenamiento Backpropagation a la Levenberg-Marquardt para clasificar las vigas según el daño simulado a través de distintos porcentajes de pegado.

1 INTRODUCTION

El uso de sonido en el diagnóstico de fallas data de la antigüedad ya que golpeando un objeto se puede distinguir cuándo el objeto presenta una falla. En general, la evaluación no destructiva es utilizada para detectar y localizar defectos usando señales con una longitud de onda menor o igual que el defecto a ser detectado. Los métodos convencionales de diagnósticos de fallas en general no son globales, es decir requieren numerosas mediciones en pequeñas secciones, incrementando la dificultad y el costo de las mediciones y por ende del diagnóstico de fallas. En este trabajo utilizaremos diagnóstico global no destructivo de fallas, con lo cual a través de una única evaluación global es posible establecer el nivel de daño de las vigas bajo estudio.

Las fallas en las estructuras metálicas causan pequeños cambios en las frecuencias naturales de vibrar. Experiencias previas muestran que pequeños cambios en la resonancia producen variaciones en las propiedades dinámicas de la estructura. En otros trabajos de la literatura pública se han utilizado Funciones de Respuesta en Frecuencia (FRF) para diagnosticar fallas en vigas de acero, en vigas de aluminio y en vigas de material compuesto en ensayos globales (A. Zapico y L. Molisani, 2009a; A. Zapico y L. Molisani, 2009b; A. Zapico, L. Molisani et al., 2010; N. Mohamad, et al, 2010; A. Zapico, L. Molisani et al., 2011a). En este esfuerzo, debido a las dimensiones de las vigas y su relativo poco peso frente a un acelerómetro, se emplean funciones de Nivel de Presión Sonora (NPS) medidas con micrófono, evitándose así el efecto de masa agregada que modifica la dinámica de las vigas bajo estudio y disminuyéndose drásticamente el costo de equipamiento necesario para la medición (A. Zapico, L. Molisani et al., 2011b; A. Zapico, L. Molisani et al., 2011c)

Una de las fuentes de error inevitables que puede reducir la calidad los NPS medidos es el ruido. Es difícil y generalmente costoso realizar mediciones libres de ruido. La fiabilidad y el éxito de muchas aplicaciones que usan NPS o FRF medidas dependen del ruido presente en los datos provenientes de mediciones. Por lo tanto, es necesario eliminar o minimizar contaminantes en los NPS medidos (D.J. Ewins, 2000; K.G. McConnell, 1995; C.R. Pickrel, 1996; S.O. Fahey y A.L. Wicks, 2000) antes de que se utilicen para otras aplicaciones. Este trabajo presenta técnicas de filtrado para la eliminación de ruido de los NPS medidos en vigas de referencia de aluminio EN AW 6082. Se emplea una Ventana Exponencial en la señal en el dominio del tiempo, para la Descomposición de Valores Singulares y el Análisis de Componentes Principales; este último además de aportar en la eliminación de ruido, permite la compresión de los datos de los NPS para ser utilizados como entrada a una red neuronal (Bishop, 1995). La Red Neuronal Artificial es utilizada como un método de estimación de fallas globales analizando los datos acústicos reducidos a sus proyecciones sobre sus componentes principales. Las fallas en la unión adhesiva se simuló mediante diferentes porcentajes de superficie adherida, considerando el 25%, el 50%, el 75 % de adhesión para simular fallas y el 100% para simular la unión de la viga totalmente adherida o sana.

En la próxima Sección se describe el equipamiento de medición empleado y los especímenes de vigas sobre los que se obtuvieron los NPS. En la Sección 3 introduciremos los conceptos básicos de Niveles de Presión Sonora. En la Sección 4 se presentan los métodos aplicados de reducción de ruido y compresión de datos DVS y ACP. En la Sección 5 se presenta una aplicación a detección de fallas, donde la red neuronal se utiliza para clasificar los daños de las vigas. Finalmente en Sección 6, resumiremos algunas conclusiones.

2 EQUIPAMIENTO DE MEDICIÓN

El equipo necesario consta tan sólo de una computadora personal con el software

desarrollado por el Grupo de Acústica y Vibraciones (GAV) de la Facultad de Ingeniería de la UNRC, para la extracción de parámetros modales, un Soporte Universal de Cuerdas diseñado por el mismo grupo, un micrófono, y una varilla metálica con la que se carga la estructura en forma impulsiva. El micrófono se dispone cercano a la viga y recoge la medida de presión sonora emitida por la estructura al vibrar. La [Figura 1](#) muestra una imagen del equipo empleado.

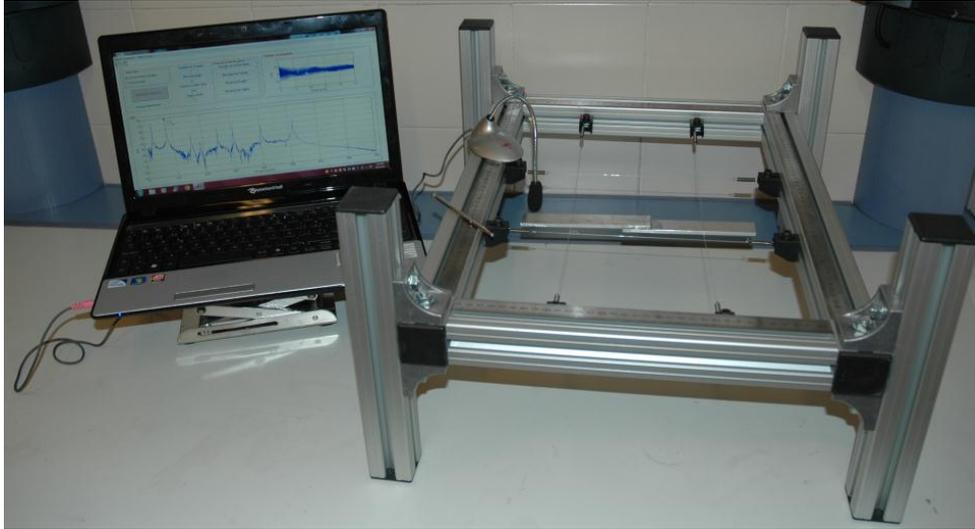


Figura 1: Soporte universal de cuerdas y sistema para medir la presión sonora.

Las vigas ensayadas son de aleación de aluminio EN AW 6082 adheridas en su superficie de solapamiento con adhesivo acrílico, [Figura 2](#). Las fallas se simulan experimentalmente en la unión de dos vigas de aluminio. Dicha unión se realiza con adhesivo acrílico tenaz bicomponente RT Loctite Speedbond H4800 y la superficie de la unión que se solapa está totalmente adherida para simular la viga en perfectas condiciones o está sólo parcialmente adherida con un 25%, 50% o un 75% de su superficie para simular diferente tipo de daño.



Figura 2: Viga de aluminio EN AW 6082 pegada.

Las vigas tienen una dimensión de 225 mm de largo, 25 mm de ancho y 6 mm de espesor. El área de solapamiento donde se lleva a cabo la unión de las vigas tiene 30 mm de longitud y 25 mm de ancho, el espesor del pegamento es de 0.5 mm, ver [Figura 3](#). La condición de apoyo para realizar los ensayos de las vigas es libre-libre. Este tipo de apoyo permite evitar la interacción propia de la viga con la dinámica del área de contacto con el entorno o apoyo. Entre los efectos adversos del área de contacto o apoyo se encuentra el bloqueo de modos de vibrar de la estructura, lo cual fue evitado mediante el uso del soporte universal de cuerdas.

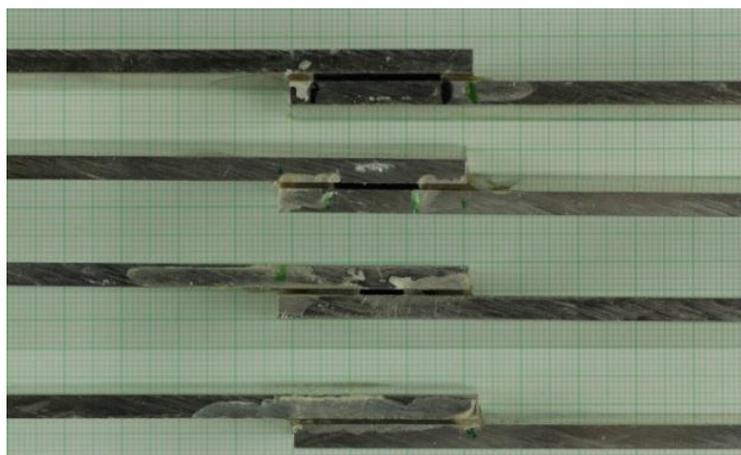


Figura 3: Vigas de aluminio EN AW 6082 total y parcialmente adheridas.

3 NIVELES DE PRESIÓN SONORA

Durante el proceso de adquisición, la señal acústica proveniente de la estructura radiante es captada por un micrófono y a partir de esta se determina el Nivel de Presión Sonora, el cual es definido por:

$$L_p = 10 \log_{10} \left(\frac{P_{rms}^2}{P_{ref}^2} \right) \quad (1)$$

Siendo P_{rms} la raíz cuadrática media de la presión acústica y P_{ref} la presión de referencia de $20 \mu Pa$.

La carga aplicada a la estructura es de tipo impulsiva y puntual para minimizar la influencia del entorno sobre la estructura.

Debido a que no se cuenta con la posibilidad de medir la intensidad del golpe impulsivo, no es posible obtener unicidad en los diferentes ensayos medidos. Entonces fue necesario que los datos se normalizaran con respecto al valor máximo obtenido en una medición sobre la viga sana, como se resolvió en los trabajos previos (A. Zapico, L. Molisani et al., 2011b; A. Zapico, L. Molisani et al., 2011c). La normalización se lleva a cabo mediante:

$$\bar{L}_p^{(i)}(\omega) = \frac{L_p^{(i)}(\omega)}{\max_{\omega} [L_p^{(1)}(\omega)]} \quad (2)$$

4 REDUCCIÓN DE RUIDO Y COMPRESIÓN DE DATOS

El hecho de que los NPS estudiados surgen de funciones de respuesta al impulso, permitió explorar el uso de una Ventana Exponencial aplicada a la señal. Esto permitió reducir la cantidad de puntos adquiridos haciendo que la respuesta tienda a amplitud cero, eliminando la parte de la señal baja en proporción de señal-ruido que contaminan la curva de NPS debido a la presencia de contenido no correlacionado, Figura 4. Esta reducción de datos en la respuesta al impulso reduce el tiempo de procesamiento para la etapa siguiente de ACP. La Figura 5 muestra el efecto reducción de ruido obtenido.

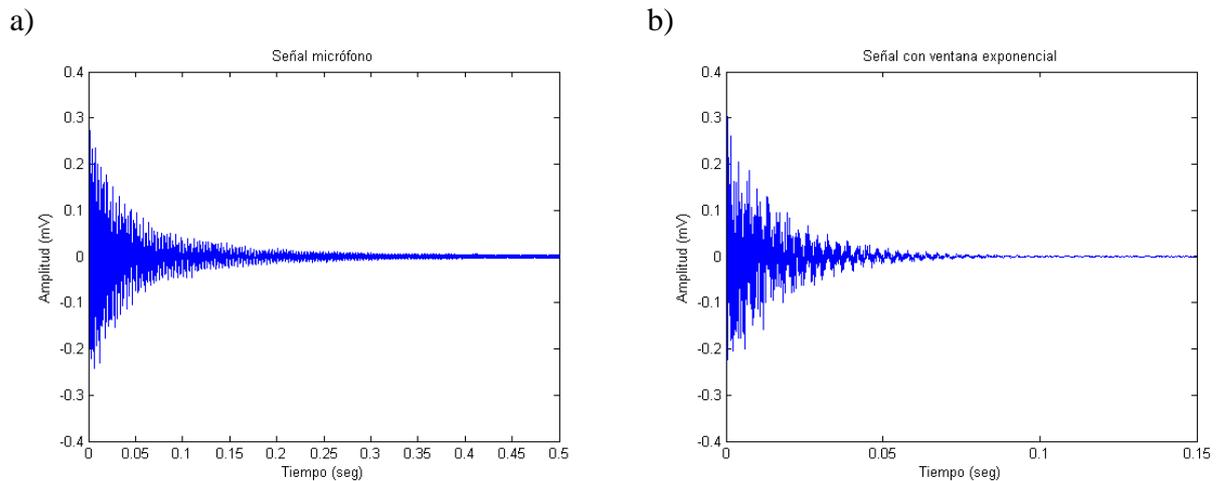


Figura 4: a) Señal original del micrófono. b) Señal con ventana exponencial.

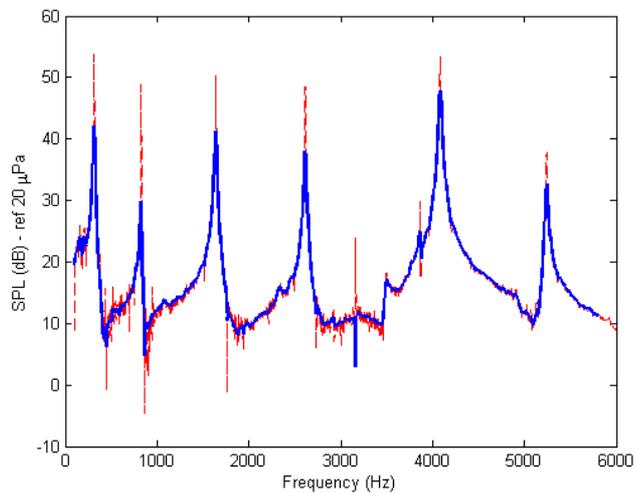


Figura 5: Nivel de Presión Sonora con ventana exponencial.

El efecto de adición de amortiguamiento de la ventana exponencial es claro; esta técnica resulta útil a fin de reducir la cantidad de datos adquiridos sin información útil y eliminar contenido de ruido. Sin embargo, presenta desventajas frente a la necesidad de inspección de cada ensayo para determinar el período de tiempo conveniente para amortiguar la señal de respuesta al impulso hasta amplitud cero. Otra desventaja se manifiesta con la necesidad de extracción de parámetros modales en el caso de utilizar FRFs.

4.1 Descomposición de Valores Singulares (DVS)

Varias técnicas, basadas en la Descomposición de Valores Singulares (DVS), se han desarrollado para reducir la vulnerabilidad de aplicaciones respecto a FRF ruidosas como, estimaciones de parámetros modales (J.N. Juang y R.S. Pappa, 1986; K. Liu, 1996; R.J. Allemang y D.L. Brown, 1998), acoplamiento/modificación estructural donde se requiere la inversión de matrices (W.M. To, D.J. Ewins, 1995), actualización de modelos donde parámetros del mismo se ajustan utilizando datos de FRF (M.I. Friswell, y J.E.T. Penny, 1990). En este trabajo, la técnica de DVS aplicada a NPS medidos permite la eliminación de ruido sin la necesidad de identificación del sistema original o la determinación de un modelo.

Teoría y aplicación a la eliminación de ruido en funciones de NPS

La base de la teórica de DVS presentada en este trabajo, surge del teorema de Eckart y Young, quienes en 1936 aportaron la derivación de un procedimiento para encontrar la mejor aproximación de rango inferior de una matriz dada (D.W. Tufts, R. Kumerasan y I. Kirsteins 1982). K.Y. Sanliturk y O. Cakar (2005) presentaron un procedimiento para la eliminación de ruido en FRF medidas empleando la técnica de DVS. Aquí se extiende la aplicación a funciones de NPS medidas experimentalmente.

Considerando un vector de señal de N puntos $\{s\} = \{s_0, s_1, s_2, \dots, s_{N-1}\}$ y asumiendo que el ruido es aditivo, entonces $\{s\} = \{\bar{s}\} + \{\text{ruido}\}$, donde $\{\bar{s}\}$ representa la componente de la señal y $\{\text{ruido}\}$ representa la componente de contenido no correlacionado.

Se puede construir la matriz de Hankel de dimensiones $m \times n$ utilizando el vector de señal $\{s\}$ como:

$$[S] = \begin{bmatrix} s_0 & s_1 & \dots & s_{M-1} \\ s_1 & s_2 & \dots & s_M \\ \vdots & \vdots & \ddots & \vdots \\ s_{L-1} & s_L & \dots & s_{N-1} \end{bmatrix} \quad (3)$$

Donde $M + L = N + 1$ y $L \geq M$.

Partiendo de una función de NPS medida de L puntos de frecuencia ω , denotada por $h(\omega) = \{h_1, h_2, h_3, \dots, h_L\}$. Los datos del NPS pueden ser incorporados en una matriz de Hankel como:

$$[H]_{m \times n} = \begin{bmatrix} h_1 & h_2 & \dots & h_n \\ h_2 & h_3 & \dots & h_{n+1} \\ \vdots & \vdots & \ddots & \vdots \\ h_m & h_{m+1} & \dots & h_L \end{bmatrix} \quad (4)$$

Donde $m + n - 1 = L$ y $A_{ij} = h_{i+j-1}$.

La descomposición en DVS de la matriz $[H]$ viene dada por:

$$[H]_{m \times n} = [U]_{m \times m} [\Sigma]_{m \times n} [V]_{n \times n}^T \quad (5)$$

Donde el superíndice T denota transpuesta y siendo $[U]$ y $[V]$ matrices ortogonales. $[\Sigma]$ es una matriz diagonal que contiene los denominados valores singulares σ_i de $[H]$. Los valores singulares σ_i son arreglados en orden decreciente $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_R$ y la matriz $[H]$ será singular si uno o más de sus valores singulares son cero, o próxima a la singularidad si uno o más de sus valores singulares se encuentran por debajo de un umbral ε . El número de valores singulares distintos de cero o mayores al umbral ε determinará el rango r de la matriz, lo que se utilizará como herramienta para el proceso de eliminación de ruido, separando los datos significativos de los ruidosos de las funciones de NPS. Entonces:

$$\begin{aligned} \sigma_i &> \varepsilon & i = 1, \dots, r \\ \sigma_i &\leq \varepsilon & i = r + 1, \dots, R \end{aligned} \quad (6)$$

El rango de la matriz que contiene los datos de ensayo indica el número de características independientes en los datos. Se puede decir que la limitación en el rango r de la matriz $[H]$ se debe a la presencia de ruido y otros errores en los datos, entonces expresando a $[H]$ como:

$$[H] = [\bar{H}] + [NS] = [U_r \quad U_0] \begin{bmatrix} \Sigma_r & 0 \\ 0 & \Sigma_0 \end{bmatrix} \begin{bmatrix} V_r^T \\ V_0^T \end{bmatrix} \quad (7)$$

Siendo $[\bar{H}]$ la matriz de datos no contaminados y $[NS]$ la matriz de ruido. En Σ_r se

encuentran los valores singulares significativos que representan al subespacio de los datos no contaminados y en Σ_0 se encuentran los valores singulares que están por debajo de un umbral dado que representan al subespacio del ruido.

Para separar los datos significativos del ruido en el NPS medido, en primer lugar, r se determina mediante un examen cuidadoso de los valores relativos de los valores singulares. Luego, los valores singulares para $i > r$ son igualados a cero y por último, la Ec. 8 determina una matriz libre de ruido $[\bar{H}]$ utilizando sólo las primeras r columnas de $[U]$, $[\Sigma]$ y $[V]$.

$$[\bar{H}] = [U_r][\Sigma_r][V_r]^T \quad (8)$$

Una manera de determinar el rango ‘efectivo’ de $[H]$ es graficar los valores singulares normalizados respecto del mayor de ellos y elegir el rango apropiado cuando estos se aproximan a una asíntota. Como resultado del procedimiento anterior se puede reconstruir un vector de datos no contaminados a partir de la matriz $[\bar{H}]$. Esto se realiza mediante la Ec. 9:

$$\bar{h}_i = \frac{1}{k-l+1} \sum_{j=l}^k \bar{H}_{i-j+1,j} \quad (9)$$

Siendo $l = \max(1, i - m + 1)$ y $k = \min(n, i)$.

Para una descripción más profunda del método, ver [K.Y. Sanliturk y O. Cakar \(2005\)](#).

La determinación de los valores singulares necesarios para la reconstrucción se realiza mediante la descomposición DVS graficando los valores singulares normalizados, seleccionando los primeros r valores dominantes y descartando los demás. Para esto es necesario cierta inspección a fin de determinar el número de columnas necesario para conformar la matriz de Hankel; si se selecciona una matriz de Hankel cuadrada el procedimiento será más eficiente en cuanto a filtrado de ruido, sin embargo, el costo computacional puede ser elevado para aplicaciones prácticas, dependiendo de la cantidad de líneas espectrales de la función de NPS empleada. Generalmente, seleccionando que el número de columnas de la matriz de Hankel sea un orden de magnitud mayor al doble de los modos que se observan en la FRF se obtienen resultados satisfactorios, [K.Y. Sanliturk y O. Cakar \(2005\)](#).

Un aspecto relevante del método es que este presenta un mejor desempeño si se utiliza una señal medida en el dominio del tiempo, salvando la desventaja de emplear mayor cantidad de puntos, el beneficio se hace presente a la hora de extraer el rango r o la cantidad de valores singulares para la reconstrucción de la señal filtrada, ya que gráficamente los valores singulares normalizados se aproximan a una asíntota de manera más visible.

En este apartado, aplicando el procedimiento descrito anteriormente a la respuesta al impulso medida en presión efectiva de 8000 puntos, se grafican los valores singulares normalizados a fin de determinar el rango efectivo para reconstruir la función de NPS filtrada. La [Figura 6](#) muestra los valores singulares normalizados para una descomposición de una señal de presión efectiva particular, a partir de la cual luego del proceso de DVS se reconstruye la función de Nivel de Presión Sonora; se observa que para los primeros pocos Valores Singulares, la magnitud normalizada decrece rápidamente, por lo que los Valores Singulares posteriores se asocian a contenido no correlacionado a la señal de respuesta al impulso.

La matriz de Hankel para este caso fue determinada cuadrada a fin de poder reconstruir la señal completa.

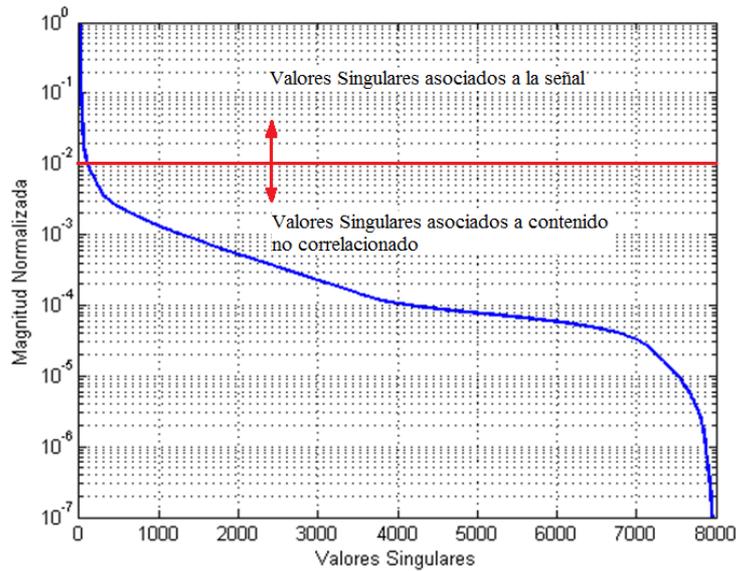


Figura 6: Valores Singulares normalizados.

Seleccionando los primeros 16 valores singulares para la reconstrucción del NPS, la [Figura 7](#) muestra el nivel de filtrado obtenido.

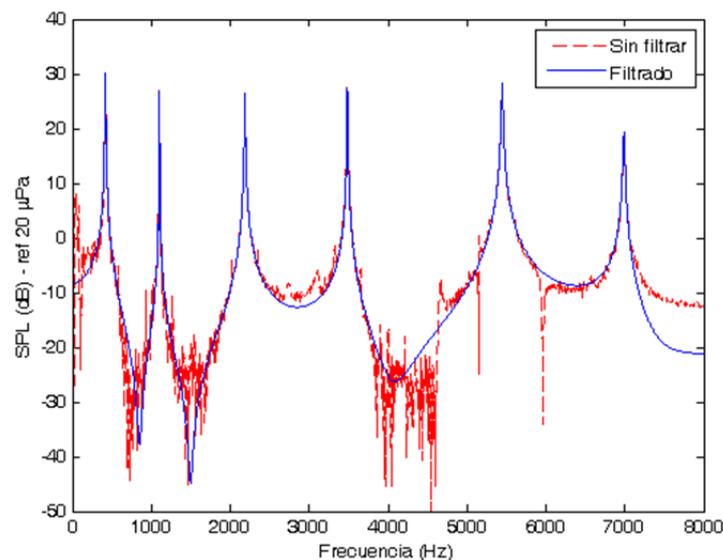


Figura 7: Nivel de Presión Sonora medido y reconstruido con 16 Valores singulares

Puede verse que el contenido de ruido presente en el NPS luego del proceso de filtrado por DVS es prácticamente despreciable comparado con el original, lo que indica que la descomposición DVS es una herramienta muy útil para aplicaciones que requieren funciones de NPS, o bien FRF, de bajo contenido de ruido, como también para la extracción de parámetros modales.

4.2 Análisis de Componentes Principales (ACP)

La aplicación de la técnica de Análisis De Componentes Principales (ACP) surge en este

trabajo como una extensión de los trabajos previos realizados donde se emplea una Red Neuronal Artificial (RNA) como herramienta de detección y clasificación de fallas en vigas globales (A. Zapico y L. Molisani, 2009a; A. Zapico y L. Molisani, 2009b; A. Zapico, L. Molisani et al., 2010; A. Zapico, L. Molisani et al., 2011b; A. Zapico, L. Molisani et al., 2011c). La factibilidad de entrenar una RNA como medio de detección y clasificación ya ha sido demostrada en numerosos trabajos, aunque un obstáculo sigue estando presente, el tamaño de las funciones espectrales utilizadas, FRF o NPS, que determinaban el tamaño o complejidad de la RNA necesaria.

El uso de todas las líneas espectrales disponibles en las mediciones hace que la cantidad de neuronas de entrada sea muy grande y por ende la cantidad de conexiones entre todas las neuronas de la red, volviendo impráctico al procedimiento. La selección de líneas espectrales ha arrojado buenos resultados en los trabajos anteriores, pero este trabajo pretende presentar un método eficaz para lograr la reducción de los datos de las funciones de NPS empleando ACP para la aplicación de RNA en la detección de fallas en estructuras.

C. Zang y M. Imregun (2001), presentan un método eficiente y preciso de reducción de datos de FRF para la aplicación de redes neuronales para la detección de daño estructural. Aquí se extiende la aplicación a funciones de NPS medidas experimentalmente.

Teoría y aplicación a la compresión de funciones de NPS

La técnica de ACP fue desarrollada por I. T. Jolliffe (1986) y Bishop (1995). Es una técnica lineal de compresión de datos y su aplicación a la dinámica estructural se debe a T. K. Hasselman y M. C. Anderson (1998).

En ACP, el conjunto original de datos en un espacio K dimensional, se transforma en un nuevo set de datos no correlacionados llamados componentes principales, en un espacio P dimensional, de modo que $P < K$.

Utilizando los datos disponibles de NPS medidos de N puntos de frecuencia ω , para una estructura de referencia, se conforma una matriz de respuesta $H = [h_{ij}(\omega)]$ que tiene M filas correspondientes a los NPS cada una con puntos de frecuencia N . Dado que se supone que todos los datos de las NPS son igualmente importantes en la descripción de las características subyacentes de las señales de referencia, se realiza una normalización. En esta, cada columna de $[H]$ se ajusta para que tenga una media de cero restando la media de cada columna.

Entonces un elemento h_{ij} de la matriz $[H(\omega)]_{M \times N}$ puede ser expresado como:

$$\tilde{h}_{ij}(\omega) = h_{ij}(\omega) - \bar{H}_j \quad (10)$$

Siendo la media de cada columna \bar{H}_j :

$$\bar{H}_j = \frac{1}{M} \sum_{i=1}^M h_{ij}(\omega) \quad (11)$$

Formando una nueva matriz de variación de respuesta $[\tilde{H}]$, a partir de la cual se crea una matriz de correlación definida como:

$$[C]_{N \times N} = [\tilde{H}(\omega)]_{N \times M}^T [\tilde{H}(\omega)]_{M \times N} \quad (12)$$

Los componentes principales son, por definición, los valores propios y vectores propios asociados a $[C]$:

$$[C]\{\Psi_i\} = \lambda_i\{\Psi_i\} \quad (13)$$

Donde i representa el índice del componente principal (C. Zang y M. Imregun, 2001).

El primer componente principal, es decir, el mayor valor propio y su correspondiente

vector propio, representan la cantidad y la dirección de variación máxima en los datos originales. El siguiente componente principal, el cual es ortogonal al primer componente, representa la segunda contribución más significativa en los datos originales, y así sucesivamente. Los componentes principales más significativos representan las características que predominan en las funciones de NPS. De ello se deduce que el ruido aleatorio, que no se correlaciona con tales características globales, es representado por los componentes menos importantes. Por lo tanto, la reconstrucción de la respuesta mediante el uso de los componentes principales más grandes no sólo provee la compresión de los datos, sino también la eliminación de parte del ruido (J. Tang, 2005).

Para la reconstrucción de la función de NPS, como $[C]$ es cuadrada, se obtienen N componentes principales y proyectando la matriz de variación de respuesta $[\tilde{H}]$ sobre los N componentes principales $[\Psi]$ se obtiene:

$$[A]_{M \times N} = [\tilde{H}(\omega)]_{M \times N} [\Psi]_{N \times N} \quad (14)$$

La matriz de proyección $[A]$ y la matriz de vectores propios $[\Psi]$ pueden partitionarse en dos submatrices, una con P componentes principales y otra con $(N - P)$ componentes principales:

$$[A]_{M \times N} = [[A_1]_{M \times P} \ ; \ [A_2]_{M \times (N-P)}] \quad (15)$$

$$[\Psi]_{N \times N} = [[\Psi_1]_{N \times P} \ ; \ [\Psi_2]_{N \times (N-P)}] \quad (16)$$

La matriz de variación respuesta $[\tilde{H}]$ ahora puede ser reconstruida sólo para P componentes principales:

$$[\tilde{H}_R] = [A][\Psi]^T = [[A_1]_{M \times P} \ ; \ [A_2]_{M \times (N-P)}][[\Psi_1]_{N \times P} \ ; \ [\Psi_2]_{N \times (N-P)}]^T$$

$$[\tilde{H}_R] \approx [A_1]_{M \times P} [\Psi_1]_{P \times N}^T \quad (17)$$

Finalmente, el elemento \tilde{h}_{ijR} de la matriz de respuesta de variación reconstruida se utiliza para obtener el elemento h_{ijR} de la matriz de NPS reconstruida:

$$h_{ijR}(\omega) = \tilde{h}_{ijR}(\omega) + \bar{H}_j \quad (18)$$

Donde el error relativo de reconstrucción es, ver C. Zang y M. Imregun (2001):

$$E = \frac{\sum_{i=P+1}^N \lambda_i}{\sum_{i=1}^N \lambda_i} \quad (19)$$

La compresión de los datos $[H_C]$ se logra manteniendo los P componentes deseados (vectores propios), formando una matriz de ‘características’ y tomando la transpuesta de la misma y multiplicando en el lado izquierdo del conjunto de datos $[\tilde{H}_R]$ transpuesto.

$$[H_C]_{P \times M} = [\Psi_1]_{P \times N}^T [\tilde{H}_R]_{N \times M}^T \quad (20)$$

La Ec. 20 nos dará los datos originales solamente en términos de los componentes principales que elegimos.

El objetivo final de nuestra aplicación de la técnica ACP es la obtención de la matriz $[H_C]$ para ser utilizada como entrada a una RNA que proporcione una herramienta de detección y clasificación de fallas, detectando los corrimientos de las frecuencias de resonancia en los NPS de las vigas con distintos niveles de daño.

La Figura 8 muestra el efecto de eliminación de ruido que puede tenerse reconstruyendo la función de NPS con unos pocos componentes principales, en este caso 5.

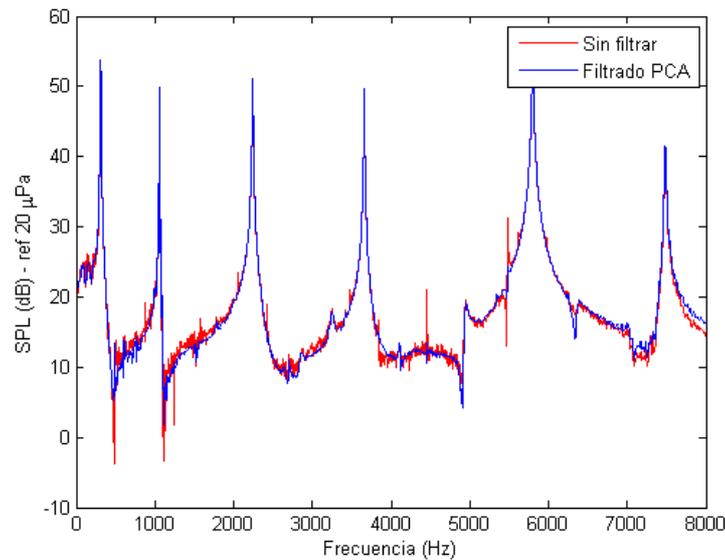


Figura 8: Nivel de Presión Sonora medido y reconstruido con 5 componentes principales.

5 APLICACIÓN AL DIAGNÓSTICO DE FALLAS UTILIZANDO REDES NEURONALES Y FUNCIONES DE NIVEL DE PRESIÓN SONORA

Como aplicación de los métodos DVS y ACP, se detectaron fallas que se simulan experimentalmente en la unión de dos vigas de aluminio. Dicha unión adherida se realiza con adhesivo acrílico tenaz bicomponente RT Loctite Speedbonder H4800 y la superficie de la unión que se solapa está totalmente adherida para simular la viga en perfectas condiciones o esta sólo parcialmente adherida con un 25%, 50% o un 75% de su superficie para simular diferente tipo de daño.

Como se ha dicho, el NPS contiene información sobre la dinámica de la viga, por ello se usaran los NPS de las vigas para la clasificación. Para cada viga hay unas 2750 líneas espectrales, lo que hace imposible el abordaje en esas condiciones con una red neuronal. En trabajos anteriores se utilizó una selección de entre 300 y 400 líneas espectrales, pero además de ser 'aleatorio' la representación sigue siendo por medio de muchas neuronas ya que cada neurona de la capa de entrada representa una línea espectral, por eso en este trabajo se plantea otro abordaje.

Los Niveles de Presión Sonora NPS emitidos por las vigas bajo una carga impulsiva son ligeramente alterados cuando se introducen fallas en las vigas, como se menciona anteriormente. En la [Figura 9](#) se observa como las frecuencias de los modos de vibrar se encuentran modificadas según la presencia de daño y tamaño de la falla.

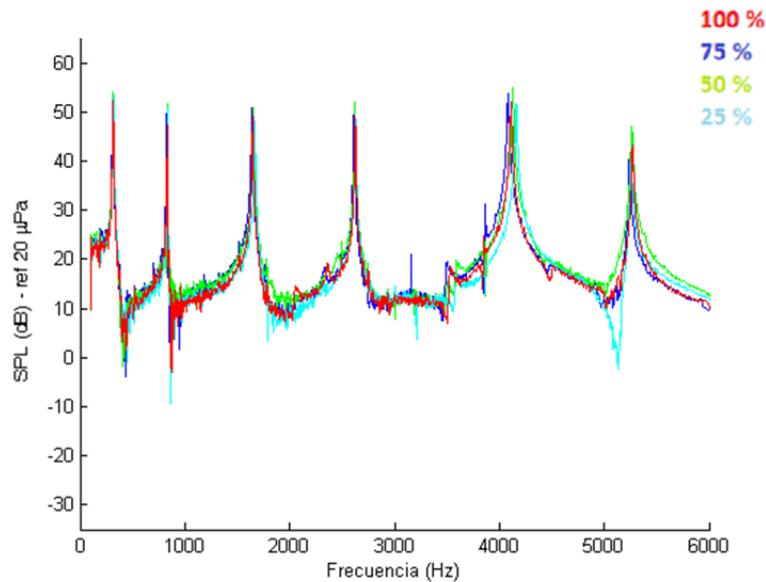


Figura 9: Nivel de Presión Sonora.

Luego de la medición, las señales de NPS son sometidas a la eliminación del ruido no correlacionado presente, por medio de la técnica de Descomposición de Valores Singulares (DVS), la cual es la que mejor resultado ha proporcionado para este fin. Posteriormente, las señales de NPS filtradas son comprimidas mediante la técnica de Análisis de Componentes Principales (ACP). Los arreglos originales de datos de 70 x 2750 (ensayos x líneas espectrales) para cada viga estudiada se redujeron a arreglos de 70 x 12, proyectando cada función de NPS filtrada sobre los 12 primeros vectores propios (componentes principales) asociados a los 12 primeros autovalores de la matriz de correlación [C]. Dichos autovalores se listan en la [Tabla 1](#), con sus contribuciones relativas y en la [Tabla 2](#) con sus contribuciones acumulativas, para cada porcentaje de superficie pegada de las vigas estudiadas. Se observa que los primeros 12 autovalores representan al menos el 98.98 % de la contribución en la variación de los datos.

N°	Componente Principal	Porcentaje sobre el total			
		Pegada 100%	Pegada 25%	Pegada 50%	Pegada 75%
1	14714.75	60.43	56.24	63.32	51.58
2	7790.62	22.72	18.42	24.55	27.31
3	2308.64	7.23	13.66	5.61	8.09
4	1295.43	3.16	4.15	1.93	4.54
5	683.17	2.79	3.18	1.34	2.39
6	579.27	1.27	1.50	1.20	2.03
7	271.12	0.65	1.02	0.71	0.95
8	195.01	0.44	0.50	0.33	0.68
9	159.79	0.30	0.27	0.32	0.56
10	89.97	0.22	0.27	0.15	0.32
11	84.43	0.18	0.16	0.15	0.30
12	65.33	0.14	0.12	0.10	0.23

Tabla 1: Porcentaje sobre el total de componentes principales

N°	Componente Principal	Porcentaje Acumulativo			
		Pegada 100%	Pegada 25%	Pegada 50%	Pegada 75%
1	14714.75	60.43	56.24	63.32	51.58
2	7790.62	83.15	74.66	87.87	78.89
3	2308.64	90.39	88.33	93.48	86.98
4	1295.43	93.55	92.48	95.41	91.52
5	683.17	96.33	95.66	96.75	93.92
6	579.27	97.60	97.16	97.95	95.95
7	271.12	98.25	98.18	98.66	96.90
8	195.01	98.70	98.68	98.99	97.58
9	159.79	98.99	98.95	99.30	98.14
10	89.97	99.21	99.22	99.46	98.46
11	84.43	99.39	99.38	99.61	98.75
12	65.33	99.53	99.50	99.71	98.98

Tabla 2: Porcentaje Acumulativo de componentes principales

Para facilitar la visualización de que unos pocos (los primeros 12) autovalores asociados a los componentes principales son los que se corresponden con las direcciones de máxima variación de los datos, la [Figura 10](#) muestra en diagramas de barras la contribución en porcentaje de cada autovalor sobre la suma de todos los autovalores.

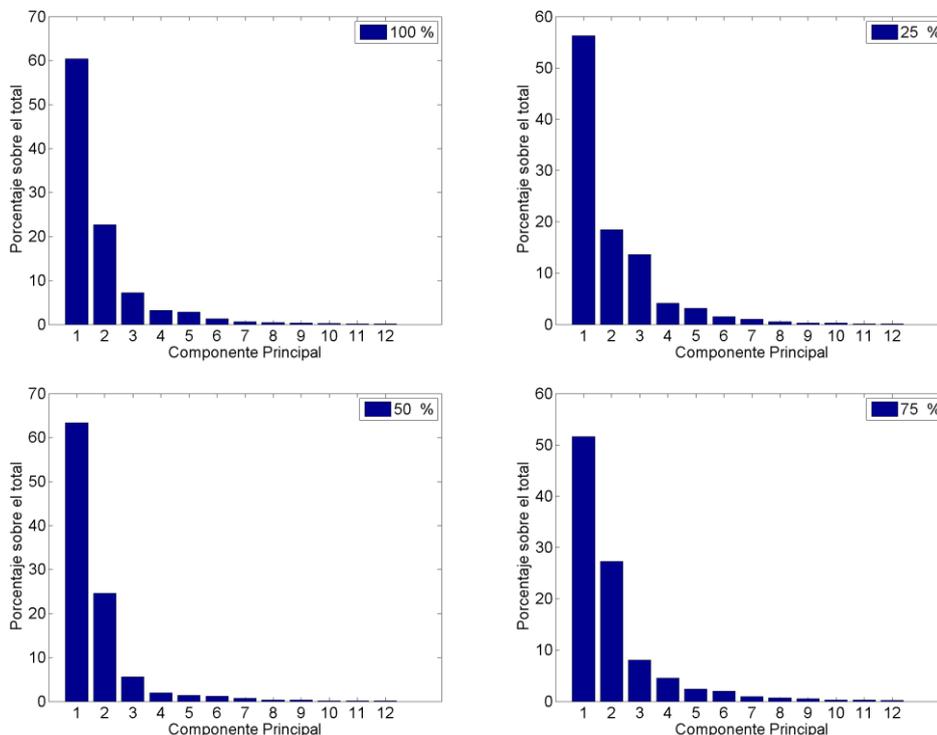


Figura 10: Porcentaje de cada autovalor sobre el total

La implementación a la detección y clasificación de fallas se realiza mediante una Red Neuronal Artificial totalmente interconectada con conexiones hacia delante (feedforward) con aprendizaje supervisado con algoritmo de entrenamiento Backpropagation á la Levenberg-

Marquardt. La estructura de la red tiene una capa oculta. La primera función de transferencia en la red es una función sigmoidea y la segunda es una función lineal. La estructura de la red es de 12-10-2 neuronas (entrada-ocultas-salida). Las entradas de las neuronas son cada uno de los 12 elementos de los vectores columna de la matriz $[H_C]$, descrita en la Sección 4.2.

Las dos neuronas de la capa de salida sirven una para clasificar según estén dañadas o sanas y la otra para determinar la naturaleza del daño. La red converge (en un promedio de 10 épocas) con un error medio (MSE) inferior al 1 %.

6 CONCLUSIONES

Se ha desarrollado, en este trabajo, un método efectivo de acondicionamiento de señales medidas experimentalmente de Niveles de Presión Sonora (NPS), para su empleo en una aplicación de detección y clasificación de fallas mediante el uso de una Red Neuronal Artificial (RNA).

La necesidad de bajo contenido de ruido en los NPS medidos en la etapa de detección y clasificación de fallas, es cubierta aplicando la técnica de Descomposición de Valores Singulares (DVS), la cual es, de las técnicas implementadas, la que mejores resultados arroja para la eliminación de contenido no correlacionado sin perjudicar los aspectos relevantes de los NPS.

El inconveniente de la gran cantidad de neuronas de entrada de la RNA y por consiguiente del tamaño e interconexiones de la misma, que implica la selección de líneas espectrales de la señal, como datos de entrada, es solucionado mediante la aplicación de la técnica de Análisis de Componentes Principales (ACP). Con ACP, se logra una reducción importante de los datos para la entrada a la RNA, permitiendo que con sólo 12 neuronas de entrada se obtengan resultados satisfactorios en la detección y clasificación de fallas.

Se ha implementado una RNA feedforward que clasifica las vigas de aluminio pegadas según el porcentaje de superficie de adherencia en la unión. El procedimiento fue establecido con éxito. La técnica solo requiere de un micrófono como sensor de presión y de un soporte universal de cuerdas con su correspondiente software de adquisición y procesamiento de la señal acústica.

La metodología presentada en este esfuerzo permite realizar un diagnóstico global de la unión adherida con ahorro de tiempo y costo de ensayo.

AGRADECIMIENTOS

Los autores de este trabajo agradecen el financiamiento aportado por la Secretaria de Ciencia y Técnica de la UNRC a través del programa PPI 18/B185 y al Consejo Nacional de Investigaciones Científicas y Técnicas.

REFERENCIAS

A. Zapico, y L. Molisani, Fault Diagnosis on steel structures using artificial neural networks, *Mecánica Computacional XXVIII*: 181-188, 2009a.

A. Zapico, y L. Molisani, Uso de Redes Neuronales para la detección de fallas en vigas de Acero, *II Congreso de Matemática Aplicada, Computacional e Ind.*, Rosario, 2009b.

A. Zapico, L. Molisani, et al., Determinación No Destructiva de Fallas en Materiales Compuestos Utilizando Redes Neuronales, *XI Congreso de Adhesión y Adhesivos*, Madrid, 2010.

A. Zapico, L. Molisani, et al., Global Fault Detection Using Artificial Intelligence, *Journal of Adhesion Science and Technology* in press., 2011a.

A. Zapico, L. Molisani, et al., Diagnostico Global De Fallas En Vigas De Aluminio

Usando Niveles De Presión Sonora, *Mecánica Computacional Vol XXX*, págs. 3271-3276, 2011b

A. Zapico y L. Molisani, Diagnóstico de Fallas en Material Compuesto de Fibra de Carbono (CFRP) usando Redes Neuronales, *7-Matemática Industrial y Aplicaciones. III MACI*, 2011c

C. M. BISHOP, Neural Networks for Pattern Recognition. *Oxford: Oxford University Press*, 1995.

C. R. Pickrel, Estimating the rank of measured response data using DVS and principal response functions, *Proceedings of the Second International Conference on Structural Dynamics Modeling, Test Analysis and Correlation DTA/NAFEMS*, pp. 89–100, 1996.

C. Zang y M. Imregun, Structural Damage Detection Using Artificial Neural Networks And Measured FRF Data Reduced Via Principal Component Projection, *Journal of Sound and Vibration, Volume 242, Issue 5*, 2001.

D. J. Ewins, Modal Testing: Theory, Practice and Applications, 2nd Edition, *Research Studies Press, Letchwor*, 2000.

D. W. Tufts, R. Kumerasan y I. Kirsteins, Data adaptive signal estimation by singular value decomposition of a data matrix, *Proceedings of the IEEE 70 (6)* 684–685, 1982.

I. T. JOLLIFFE, Principal Component Analysis. *New York: Springer-Verlag*, 1986.

J. N. Juang y R. S. Pappa, Effects of noise on modal parameters identified by the eigensystem realization algorithm, *Journal of Guidance, Control and Dynamics 9 (3)* 294–303, 1986.

K. G. McConnell, Vibration Testing, Theory and Practice, *Wiley, New York*, 1995.

K. Liu, Modal parameter estimation using the state space method, *Journal of Sound and Vibration 186 (2)* 185–195, 1996.

K. Y. Sanliturk y O. Cakar, Noise elimination from measured frequency response functions, *Mechanical Systems and Signal Processing, Volume 19*, 2005.

M. I. Friswell y J. E. T. Penny, Updating model parameters from frequency domain data via reduced order models, *Mechanical Systems and Signal Processing 4 (5)* 377–391, 1990.

N. Mohamad, et al, Artificial Neural Network for the Classification of Steel Hollow Pipe, *International Conference on Applications and Design in Mechanical Engineering, Penang, Malasya. 2001. 24(5): p. 813–827. 2009.*

R. J. Allemang y D. L. Brown, A unified matrix polynomial approach to modal identification, *Journal of Sound and Vibration 211 (3)* 301–322, 1998.

S. O. Fahey y A. L. Wicks, Noise sources in mechanical measurements, *Experimental Techniques 24 (2)* 40–43, 2000.

T. K. HASSELMAN y M. C. ANDERSON, Principal components analysis for non-linear model correlation, updating and uncertainty evaluation. *Proceedings of the 16th International Modal Analysis Conference, Santa Barbara, CA, 644}651*, 1998.

W. M. To y D. J. Ewins, The role of the generalized inverse in structural dynamics, *Journal of Sound and Vibration 186 (2)* 185–195, 1995.

Tang, J., Frequency response based damage detection using principal component analysis, Information Acquisition, *IEEE International Conference*, 2005.

Zang, C. y M. Imregun, Structural damage detection using artificial neural networks and measured frf data reduced by principal component projection, *Journal of Sound and Vibration. 2004.*