

DETECCIÓN DE DAÑO ESTRUCTURAL UTILIZANDO REDES NEURONALES ARTIFICIALES: Un estado del Arte.

Jesús D. Villalba¹ & José E. Laier²

Resumen

En las últimas décadas, redes neuronales artificiales han emergido como una poderosa herramienta para la determinación del estado actual de una estructura a partir de los cambios que esta presenta en la respuesta estática o dinámica como resultado de la presencia del daño. En este trabajo se realiza un estado del arte de las metodologías que emplean redes neuronales para identificar, localizar y/o cuantificar el daño. Diferentes tipos de redes, metodologías de entrenamiento y técnicas de generación de casos de entrenamiento han sido utilizados buscando definir la mejor opción para detectar daño. Por lo tanto, se realiza un análisis de la influencia de estos aspectos en el buen desempeño de la red y se muestran algunas potenciales áreas de investigación. Finalmente, se observó que en la actualidad el costo computacional asociado a la implementación de la red neuronal puede ser una limitante para su aplicación práctica en grandes estructuras.

Palabras claves: redes neuronales, detección de daño, parámetros dinámicos, análisis estructural.

STRUCTURAL DAMAGE DETECTION BY USING ARTIFICIAL NEURAL NETWORKS: STATE OF THE ART

Abstract

Nowadays, artificial neural networks have emerged as a powerful tool for the assessment of the current state of a structure from changes in its static or dynamic response as a consequence of the damage. In this paper it is presented a state of the art on methodologies that use artificial neural networks to identify, to locate and to quantify damage. Different network types, training algorithms and techniques for the generation of the training cases have been proposed to define the best setting to detect damage. Therefore, an analysis of the influence of the mentioned aspects on the methodologies' performance is carried out and it is shown some potential research areas on the subject. Finally, it was observed that currently the computational cost associated with the computational implementation of the network could be a drawback to apply it in large structures.

Keywords: neural networks, damage detection, dynamic parameters, structural analysis.

1 INTRODUCCIÓN

Doebling (1998) define el daño como cualquier cambio en un sistema que perjudica su comportamiento actual o futuro, siendo necesaria la comparación entre dos estados del sistema. Su presencia en una estructura puede tener serias implicaciones económicas y sociales como mostrado por Sohn et al (2004), lo que justifica el interés por parte de la comunidad científica en desarrollar técnicas que permitan la valoración del estado de una estructura. Siendo así, el conocimiento que podemos tener sobre el daño puede alcanzar uno de los niveles definidos por Rytter (1993): nivel 1:

¹ Candidato a Doutor em Engenharia de Estruturas - EESC-USP, villalba@sc.usp.br

² Professor Titular do Departamento de Engenharia de Estruturas da EESC-USP, jelaier@sc.usp.br

determinación de la presencia del daño, nivel 2: nivel 1 más localización del daño, nivel 3: nivel 2 más cuantificación del daño, y nivel 4: nivel 3 más determinación de la vida útil de la estructura.

El área de investigación relacionada con la detección de daño en una estructura comenzó hace algunas décadas y en la actualidad muchos tópicos deben ser investigados con el fin de obtener metodologías que permitan evaluar el daño de forma confiable. Uno de esos tópicos corresponde al tipo de herramienta matemática que permitirá resolver el problema asociado con la detección del daño en una estructura. Hoy en día, técnicas de inteligencia computacional son ampliamente utilizadas para resolver el problema anterior, siendo la computación evolucionaria y las redes neuronales dos de las técnicas más empleadas. En relación a las redes neuronales, se observa en la literatura que ellas han posibilitado la solución de problemas de muy diversos campos que envuelven principalmente aproximación de funciones, control de procesos, reconocimiento de patrones, agrupamiento de datos, sistemas de predicción, optimización de sistemas y memorias asociativas (NUNES *et al.*, 2010). Así mismo, redes neuronales tienen aplicación en el campo de la ingeniería de estructuras, donde han sido utilizadas para resolver algunos problemas como la definición de una configuración estructural óptima (RAFIQ *et al.* 2001), la clasificación de señales sísmicas (CURILEM *et al.*, 2009), la identificación de sistemas (SUBUDHI& JENA, 2009), entre otros.

En este artículo se presenta una completa revisión sobre trabajos reportados en la literatura que utilizan redes neuronales artificiales (RNAs) como parte de una metodología de detección de daño. En esencia, dichas metodologías buscan utilizar las diferencias que existen en el comportamiento dinámico y/o estático de la estructura entre las condiciones inicial y actual. Debido a la gran cantidad de trabajos realizados, se decidió presentar metodologías publicadas a partir del año 2000 pero sin incluir aquellas aplicadas sobre estructuras hechas de materiales compuestos. Un gran énfasis se da en esta revisión a diversos tópicos que garantizan un buen desempeño de la red, tal como la definición del tipo de red, el tipo de entrenamiento, parámetro de entrada, entre otros. Finalmente, la realización de la presente revisión se encuentra justificada en la necesidad de mostrar el estado actual de las investigaciones en el área y de motivar al desarrollo de nuevas metodologías que nos permitan obtener el estado real de la estructura con un mayor grado de confianza.

2 TEORÍA DE REDES NEURONALES

RNAS simulan el comportamiento del cerebro humano para la solución de problemas que las técnicas computacionales tradicionales no consiguen resolver, siendo su primera aparición en la literatura referida al trabajo de McCulloch & Pitts en 1943 quienes presentaron algunas indicaciones sobre la operación de las neuronas (Ham & Kostanic, 2001). Entre las principales características de la RNAs se encuentran su capacidad para aprender y generalizar a partir de ejemplos, manejar datos incompletos, imprecisos y/o ruidosos, capacidad de auto-adaptación a cambios en las condiciones del problema, entre otros. Uno de los tipos de RNAs más utilizados es el llamado Perceptrón Multicapa (PMC) el cual permite mapear las relaciones que existen entre un conjunto de entradas y sus respectivas salidas, tal que la presentación de nuevas entradas pueda resultar en valores de salida confiables. La arquitectura tipo de esta red se constituye por neuronas distribuidas en tres tipos de capas - entrada, ocultas y salida- como mostrado en la Figura 1. Las neuronas en la capa de entrada reciben la información medida y en ellas no se realiza ninguna operación. Con respecto a la capa oculta, esta puede ser una, dos o más de dos. La capa de salida tiene un número de neuronas igual al tamaño del vector de salida. Las neuronas de las diferentes capas están interconectadas y para cada conexión existe un valor de peso que imita la sinapsis entre neuronas en el cerebro. Esos pesos pueden asumir valores positivos (excitadores) o negativos (inhibidores). Otro término a ser determinado es el *bias* o valor de sesgo, el cual es utilizado para aumentar o disminuir el umbral de activación de una neurona. Pesos y sesgos contienen las relaciones entre los valores de entrada y los de salida que permiten a la red funcionar y corresponden a las variables que deberán ser calculadas.

Su determinación será realizada a partir del entrenamiento de la red como explicado en el siguiente párrafo.

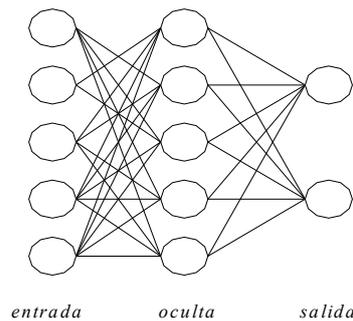


Figura 1. Red Neuronal Perceptrón Multicapa.

El entrenamiento original de redes PMC, conocido como Back-Propagation (BP), consiste en dos pasos: *forward* and *backward*. Inicialmente son definidos valores aleatorios para los pesos sinápticos (conexiones entre neuronas) y sesgos. En el primer paso cada caso de entrenamiento es presentado a la red y es propagado hasta obtener un valor en las neuronas de salida. En cada neurona de las capas ocultas y de salida es realizado un proceso de suma donde se pondera el valor que viene de una neurona en la capa anterior por su respectivo peso. El valor obtenido se introduce en una función de activación la cual permite determinar el valor de salida de la correspondiente neurona. Las funciones de activación tienen como objetivo limitar los valores que salen de una neurona a un determinado rango, usualmente entre 0 y 1 ó entre -1 y 1. Algunos tipos de funciones de activación son mostrados en la Figura 2. Los valores encontrados después de aplicar las funciones de activación en las neuronas de salida se comparan contra las verdaderas salidas y el proceso se realiza para todos los ejemplos de entrenamiento. Generalmente se utiliza la función de error promedio para determinar el error sobre todas las muestras analizadas. El error total producido se utiliza para actualizar los pesos de las diferentes capas en un proceso realizado en sentido contrario al primer paso y que envuelve el cálculo de algunas derivadas del error en relación a los pesos. Se considera que una época ha pasado después que la propagación del error es realizada. El entrenamiento de la red puede detenerse después que se tenga un error mínimo deseado o cuando se alcance un número máximo de épocas.

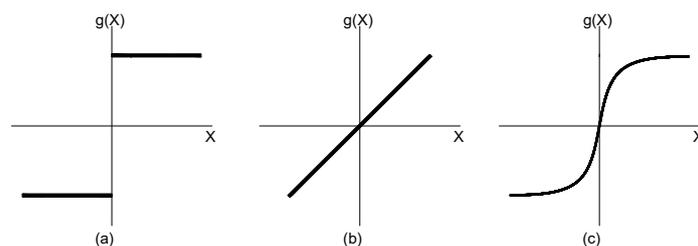


Figura 2. Tipos de funciones de activación: a) *Hard Limiter*, b) Lineal y c) sigmoideal.

No existe una regla única para establecer el número de neuronas en las capas ocultas, este valor es dependiente del problema analizado y generalmente es calculado por el método de la validación cruzada. Su definición es de gran importancia ya que un número pequeño no permitirá que la red aprenda adecuadamente (*underfitting*) y un número grande hará que la red se adapte demasiado a los casos de entrenamiento y pierda capacidad de generalización (*overfitting*). La definición del número de muestras de entrenamiento también es dependiente del problema.

3 METODOLOGIAS DE DETECCIÓN DE DAÑO QUE UTILIZAN RNA

Para la organización de la presente revisión se definieron algunos tópicos relacionados con el desempeño de la RNA para identificar daño en una estructura, siendo cada una de las metodologías clasificada en uno de ellos según su principal contribución. Por ejemplo, uno de los tópicos corresponde al tiempo necesario que se requiere para el entrenamiento de la red, el cual puede convertirse en un gran limitante para la aplicación práctica de RNAs. Es importante aclarar que una metodología puede tener contribuciones en relación a diferentes tópicos y que la clasificación utilizada no es rigurosa, sino que obedece a una simple organización lógica de la información basada en la experiencia de los autores. Por otro lado, muchas metodologías utilizan reducciones en la rigidez de los elementos de la estructura para formar el vector de salida. Esas reducciones asumen valores entre 0 y 1 indicando la no presencia del daño y la pérdida total del elemento, respectivamente. En esta revisión, si para una metodología no se indica el vector de salida es porque se utilizó tal descripción.

3.1 Disminución del tiempo requerido para entrenar la red.

El tiempo que requiere la realización del entrenamiento de una RNA varía en función de ciertos parámetros tal como i) el número de casos necesarios para una buena generalización, ii) la definición y el tamaño de los vectores de entrada y de salida y iii) el algoritmo de entrenamiento utilizado. En detección de daño, el tiempo de entrenamiento gana importancia en la medida en que el tamaño de la estructura aumenta ya que, en general, se observa que la relación entre el tiempo de entrenamiento y el tamaño de la estructura no sigue una relación lineal (VILLALBA *et al*, 2012). Dicha cuestión podría tornar inviable la aplicación de RNAs en estructuras de gran tamaño a menos que algunas medidas para disminuir el tiempo de entrenamiento sean tomadas, lo que involucra trabajar en relación a los parámetros antes mencionados. A continuación serán tratados los parámetros 1 y 3, siendo la reducción del vector de entrada abordada en la sección 3.2.

Cuando se desea determinar, localizar y/o cuantificar la magnitud del daño en una estructura a partir de RNAs se requiere que sean generados un número determinado de casos de entrenamiento que involucren las diversas combinaciones posibles de posiciones y magnitudes de daño. En ese sentido, se debe tener cuidado con el hecho de que las RNAs tienen poca capacidad de extrapolación de datos, por lo tanto, los casos de entrenamiento deben contener los valores extremos de las variables buscadas. Siendo así, la elección del método de generación de casos de entrenamiento juega un papel importante en la capacidad de generalización de la red.

Chang *et al.* (2000) utilizaron una RNA iterativa PMC para detectar daño en estructuras y cuyos casos de entrenamiento se generaron mediante la utilización del *ortogonal arrays method* (OAM). El método busca generar la menor cantidad de experimentos, o combinaciones, a partir de un número determinado de variables y de valores posibles pero garantizando que estas combinaciones sean representativas de los datos. Se utilizaron frecuencias naturales y cambios en la primera curvatura modal para definir el vector de entrada. La red se entrenó en diversas ocasiones teniendo como criterio de parada un valor de tolerancia para la diferencia entre los parámetros dinámicos determinados experimentalmente y aquellos que resultan de los parámetros identificados por la red. El algoritmo de entrenamiento correspondió al BP, pero para mejorar su desempeño se propuso una tasa de aprendizaje dinámica. Esa variación dependía de si se había conseguido una disminución en el error de entrenamiento. La metodología propuesta fue comprobada numérica y experimentalmente en una viga en voladizo cuyo modelo de elementos finitos (MEF) tenía 8 elementos. Chang *et al* (2002) compararon diferentes métodos de generación de casos de entrada (OAM, el *hypercube*, el lineal, el full factorial y la generación aleatoria) con aplicación al problema de actualización de modelos. Se observó que el mejor desempeño en términos de precisión era logrado por el OAM.

Una forma de disminuir la complejidad de la red que alcanza el nivel 3 de detección, y por ende el tiempo de procesamiento, es dividiendo el proceso de detección de daño en diversas etapas. Esta clase de metodologías ha sido ampliamente acogida por la comunidad científica debido a la

complejidad implícita del problema de detección de daño, la cual se incrementa en la medida que el tamaño de la estructura crece. La idea básica consiste en determinar inicialmente zonas probablemente dañadas para posteriormente calcular las magnitudes de daño en los elementos que pertenecen exclusivamente a dichas zonas. Este tipo de planteamiento del problema debe garantizar que los elementos que realmente presentan daño se encuentren en las zonas identificadas en la etapa de localización porque sino la etapa de cuantificación se llevará a cabo utilizando variables equivocadas.

Ni et al (2002) utilizaron una red neuronal con vectores de entrada conformados por parámetros dinámicos que solo dependían de la localización del daño: la relación entre los cambios en las frecuencias naturales (KAMINSKI, 1995) y cambios en las formas modales (LAM *et al.*, 1998). La red fue entrenada utilizando el algoritmo BP cuyos casos de entrenamiento se generaron a partir de escenarios de daño con diferentes elementos dañados pero con una única extensión del daño. Para ilustrar al lector sobre el nivel de reducción en el número de escenarios probables que puede ser obtenido con esta técnica considérese una estructura con 10 elementos, para la cual existe la posibilidad de tener hasta 3 elementos dañados simultáneamente y con un rango de daño que varía entre 0 a 0.5 dividido en 10 valores. Para estas condiciones hay un total de 12×10^7 escenarios de daño posibles mientras que si no llevamos en cuenta la extensión del daño ese número de combinaciones disminuiría para 120. El tamaño del vector de salida era igual al número de elementos en la estructura y podía asumir en cada posición un valor de 1 o 0 para indicar la presencia o no del daño en un elemento determinado. Una segunda red se utiliza para cuantificar la magnitud del daño en aquellos elementos identificados con ayuda de la primera red. En esta ocasión los vectores de entrada son dependientes de la extensión del daño. Un pórtico de dos pisos, cuyo MEF tenía 18 elementos, se utilizó para demostrar el desempeño de la metodología. Una simulación numérica de posibles escenarios de daño permitió concluir que la capacidad de la red para localizar el daño dependía de la cantidad de modos utilizada. Se observó que las extensiones de daño calculadas convergían a un valor dado en la medida en que el número de casos de entrenamiento aumentaba.

Otra forma de disminuir la complejidad de la red neuronal es estudiar la estructura por sub-dominios o zonas, lo que implica realizar el análisis de la presencia de daño en forma separada para cada zona. Las RNAs son, entonces, entrenadas en forma independiente para cada zona en la estructura considerando únicamente la información proveniente de esa zona, esto reduce la cantidad de datos que entra a la red y por consiguiente disminuye su tamaño. Cabe anotar que es mucho más rápido entrenar varias redes pequeñas en forma independiente que una única red de gran tamaño.

Wu *et al.* (2002) implementaron un sistema de RNAs con evaluación paramétrica descentralizada para en una primera instancia identificar el sistema y después poder determinar la extensión del daño. La descentralización de la red se debe a que la información que se utiliza para identificar el sistema viene desde varios lugares de la estructura. Siendo así, se entrena una red neuronal por cada sub-estructura con el algoritmo BP; teniendo como vectores de entrada los valores de fuerzas de restauración obtenidos en la etapa de identificación a partir de registros de aceleraciones de un terremoto. Si la estructura presenta daño estos valores de fuerza no se corresponderán con aquellos de la condición sin daño. Se realizó una simulación numérica de un edificio de 7 pisos, modelado considerando 1 grado de libertad por piso, y cuyos casos de entrenamiento se generaron utilizando las aceleraciones en cada sub-estructura producidas por el terremoto de El Centro. Para indicar la presencia del daño se utilizó el *relative root mean square error*, el cual es una medida de error que no es influenciada por el registro sísmico utilizado. Esta formulación tendrá problemas en la detección de elementos de diferentes sub-estructuras que presenten daño simultáneamente.

Bakhary *et al.* (2010) utilizaron dos redes neuronales PMC para inicialmente localizar posibles zonas dañadas y luego determinar en forma más exacta la localización del daño y su magnitud. El proceso consiste en dividir la estructura en varias sub-estructuras, para las cuales se considera que la interface entre ellas es fija. Un conjunto de redes PMC, cuyo número es igual al número de subestructuras, son entrenadas para que obtengan la relación entre las frecuencias y las formas modales de la estructura completa y las frecuencias de cada sub-estructura. Un índice de daño es propuesto en función de los cambios entre las frecuencias anteriores y aquellas obtenidas experimentalmente para la condición con daño. Las sub-estructuras que son identificadas como dañadas se utilizan en la segunda etapa de esta metodología y se entrena una nueva red para cada una. En esta etapa, el vector de entrada es formado por las frecuencias y coordenadas de formas modales que corresponden a cada sub-estructura. El algoritmo Levenberg-Mardquart (LMA) se utilizó para realizar el entrenamiento de las redes con casos de entrenamiento generados por los métodos

OAM y *Latin Hypercube Sampling Method* (LHSM). Se analizó una losa de concreto cuyo MEF tenía 32 elementos y que fue dividida en 4 sub-estructuras. Los resultados de la aplicación de esta metodología a diferentes escenarios de daño se compararon con los resultados obtenidos por una única red neuronal PMC, observándose que la localización y magnitud del daño se determinaba en forma más confiable y en un tiempo computacional menor. Los autores mostraron que para estructuras de tipo viga la capacidad de la metodología para detectar la presencia del daño depende del tamaño de la subestructura utilizada, del nivel de daño y del tamaño de los elementos dañados.

3.2 Desempeño del algoritmo de entrenamiento.

El método de entrenamiento utilizado juega un papel importante para garantizar un buen desempeño de la red neuronal. En detección de daño, la elección de tal método debería obedecer a un equilibrio entre la capacidad de generalización y el tiempo de entrenamiento. Así por ejemplo, se sabe que el algoritmo LM tiene una capacidad mayor de generalizar que el *Scaled Gradient Conjugate* (SGC); sin embargo, su tiempo de ejecución es más alto y consume una cantidad mayor de memoria. Estos dos aspectos son claves para la aplicación de RNA en grandes estructuras ya que se puede sobrepasar la capacidad de los PCs utilizados.

Fang *et al.* (2005) propusieron utilizar una versión mejorada del algoritmo *Tunable Steepest Descent* (TSD), el cual es una versión modificada del BP, en el entrenamiento de una red PMC para localizar y cuantificar daño en una viga. El algoritmo controla la variación de la tasa de aprendizaje en función del error entre épocas sucesivas y no permite que los pesos sean actualizados cuando el error en la época actual es mayor a aquel de la época anterior. Su principal desventaja radica en la posibilidad de que la red quede atrapada en un mínimo local, para lo que los autores recomiendan entrenar con un conjunto de redes que tengan diferentes valores para los pesos iniciales o para la tasa de aprendizaje inicial. A partir de un ejemplo numérico se mostró que el TSD converge más rápidamente que los algoritmos *Dynamic Steepest Descent* y *Fuzzy Steepest Descent*. Se utilizó una viga en voladizo, cuyo MEF tenía 20 elementos, para demostrar el desempeño de la red. El vector de entrada estaba compuesto de datos de la FRF de punto sobre el extremo de la viga que se encuentra en voladizo. Solo aquellos puntos dentro de un rango de frecuencias alrededor de las frecuencias de resonancia se utilizaron, esto con el fin de disminuir el número de datos que entraban a la red. Una característica importante de la red propuesta es que los pesos se inicializaron con valores pequeños para evitar problemas relacionados a la saturación de las funciones de activación. Los casos de entrenamiento se generan en forma distribuida con uno y dos elementos dañados. Para los ejemplos probados la red mostró una precisión en la determinación del escenario de daño mayor a 80%.

Hung & Kao (2002) exploran la utilización de redes PMC para realizar la identificación del sistema para las condiciones con y sin daño, tal como Wu *et al.* (2002); evitando así un conocimiento previo de las propiedades físicas de la estructura para detectar el daño. El vector de entrada se conformó con aceleraciones, velocidades y desplazamientos relativos y las excitaciones externas en tiempos anteriores; mientras que el vector de salida era constituido por las mismas respuestas estructurales pero en el instante actual. El algoritmo de entrenamiento utilizado es el gradiente conjugado Broyden-Fletcher-Goldfarb-Shanno de memoria limitada. Este algoritmo permite una mejor convergencia de la red en comparación con aquella obtenida empleando el BP debido a que utiliza las derivadas de segundo orden de la función error en relación a los pesos de la red. La localización y cuantificación del daño se realiza en una fase posterior a partir de los pesos óptimos que se obtienen en la fase de identificación. Como vectores de entrada se utilizaron las derivadas de las salidas de la red propuesta para la identificación en relación a sus entradas, las cuales son poco afectadas por errores en el sistema. Un edificio de cortante con 5 pisos se utilizó para demostrar el comportamiento de la metodología y considerando que las mediciones eran incompletas. Los resultados mostraron que la red podía determinar el estado de daño para los casos de prueba. Hung & Kao en 2003 utilizaron la misma red neuronal para detectar daño pero en este caso a partir de la respuesta en vibración libre de la estructura. La extensión del daño se calcula en función de las diferencias entre los periodos y las amplitudes de la respuesta de vibración libre para las condiciones con y sin daño. La información anterior se obtiene desde la red neuronal que permite realizar la identificación del sistema. Un pórtico metálico de 5 pisos se sometió a diversas intensidades del terremoto de Kobe y se encontró que el daño podía ser detectado solo a partir de cierto nivel de aceleración.

En 2011, Dee *et al.* realizaron un estudio de comparación de métodos de entrenamiento de una red PMC, el cual incluyó los métodos LMA, Resilian Propagation (RP), SCG, *Conjugate Gradient* con

re-iniciación Powell- Beale (CGB), Polak-Ribiere *Conjugate Gradient* (PRCG) y Fletcher-Reeves *Conjugate Gradient* (FRCG). Como criterios de comparación se utilizaron el tiempo de entrenamiento y la capacidad de generalización de la red. Los vectores de entrada a la red consistían de frecuencias y formas modales. El estudio se llevó a cabo en una losa, cuyo MEF tenía 128 elementos, considerando diversas combinaciones entre la cantidad de puntos en los cuales se disponía de mediciones (33, 17 ó 9) y el número de variables de salida (32 ó 16). El algoritmo LMA presentó en general la mejor capacidad de generalización y mayor cantidad de tiempo en la realización del entrenamiento. El algoritmo de entrenamiento más rápido fue el FRCG pero tuvo una mala capacidad de generalización, al igual que el algoritmo RP. El algoritmo SCG presentó una buena capacidad de generalización para tiempos de entrenamiento razonables. Se observó que una menor cantidad de puntos de mediciones y una mayor cantidad de salidas disminuían la capacidad de generalización de todos los algoritmos de entrenamiento estudiados.

Todos los trabajos aquí reportados utilizan técnicas clásicas de optimización para realizar el entrenamiento de la red neuronal. Sin embargo, existe la posibilidad de emplear metaheurísticas para ello, las cuales podrían proveer un mejor desempeño. Al respecto, Alba & Martí (2006) compilaron una serie de trabajos que utilizan metaheurísticas para entrenar redes neurales.

Finalmente, es importante anotar que diversos estudios en los cuales se hace la comparación de métodos de entrenamiento de RNAs aplicadas a problemas de ingeniería (TIVIVE & BOUZERDOUM, 2005; GOPALAKRISHNAN, 2010; ZAKARIA et al, 2010) confirman la importancia que tiene la elección de un algoritmo adecuado para resolver correctamente el problema analizado.

3.3 Compresión de los datos de entrada y reducción del ruido.

La Función de Respuesta en Frecuencia (FRFs) de una estructura ha sido bastante utilizada en la literatura para detectar variaciones en su comportamiento. Sin embargo, su utilización como parámetro de entrada a una red neuronal se ve condicionada por la gran cantidad de información, lo que ocasiona un aumento en la complejidad de la red debido al alto número de neuronas ocultas que se requiere para una correcta generalización. Por lo tanto, se hace necesaria la utilización de una técnica que permita reducir la cantidad de datos sin que se pierdan las características más importantes que existen en ellos. Una forma de realizar reducción de información y extracción de características esenciales es a través de la técnica Análisis de Componentes Principales (PCA por su sigla en inglés). En esta técnica los datos son proyectados sobre las componentes principales más importantes consiguiendo que sean reducidos sin afectar considerablemente la información que contienen. Otra ventaja del PCA es que ayuda a disminuir el efecto del ruido presente en los datos originales. Algunas otras técnicas que podrían ser aplicadas son, por ejemplo, el *independent component analysis* (HYVARINEN *et al.*, 2001) y el *partial least square procedure* (WOLD, 1985).

Ni *et al.* (2006) utilizaron una red neuronal PMC con solo una capa oculta y entrenada con el algoritmo BP para localizar daño en un edificio de 38 pisos, el cual fue hecho a escala y sometido a un evento sísmico por medio de una mesa vibratoria. El nivel de aceleración del evento fue incrementado desde cero con el objetivo de inducir diferentes niveles de daño en el edificio. Los vectores de entrada fueron formados con FRFs obtenidas a partir de mediciones de vibraciones ambientales realizadas cuando determinados valores de la excitación eran alcanzados. Dichas mediciones fueron tomadas en 9 niveles de piso con la ayuda de 3 sensores por piso. El estado global de la estructura fue determinado a partir de tres vectores diferentes de entrada a la red: 1) información parcial de las FRFs, 2) las 13 primeras componentes principales de la FRF obtenida en el último piso del edificio o 3) esa misma cantidad de componentes pero considerando la información desde todos los pisos medidos. La salida de la red consistía de un rango de valores entre cero y uno, el cual fue dividido en función de un grado cualitativo de daño, donde un valor mayor a 0.8 correspondía a daño total y un valor menor a 0.2 a una estructura sin daño. Los mejores resultados para predecir la extensión del daño fueron obtenidos cuando se utilizó la información de todos los sensores localizados en la estructura. Por otro lado, los autores muestran que la información obtenida desde un nivel de piso en específico podría ser utilizada para determinar si el daño se encuentra cerca de ese piso.

Li *et al.* (2011) utilizaron redes neuronales PMC y las diferencias entre las FRFs (residuales) para los estados con y sin daño, comprimidas con PCA, para localizar y cuantificar daño en estructuras. Un análisis de sensibilidad mostró que los residuales eran más sensibles al daño cuando comparados con las FRFs en sí mismas. Un segundo estudio de sensibilidad permitió determinar la cantidad óptima de componentes principales que era necesaria para garantizar una correcta detección

del daño. Se encontró que era posible utilizar una cantidad tan baja como 10 componentes para un nivel bajo de ruido en los datos. Con el fin de aumentar la efectividad de la red, se propuso utilizar un conjunto de redes neuronales que trabajara simultáneamente. En ese conjunto, cada red es responsable por la información que proviene de un sensor localizado en un determinado punto sobre la estructura; mientras que la respuesta final sobre el estado de daño de la estructura se obtiene a partir de la combinación de información desde cada una de las redes. Como algoritmo de entrenamiento se utilizó el de gradientes conjugados descendiente. Un análisis numérico y experimental se realizó sobre una viga simplemente apoyada y considerando mediciones en 7 puntos. Se estudiaron diferentes escenarios de daño que presentaban un único elemento con niveles específicos de daño. La habilidad de la red para detectar daño fue limitada por el nivel de ruido en las mediciones y por la cantidad de daño, consiguiendo localizar correctamente el elemento con daño para valores de daño medio y una intensidad máxima de ruido de 10%. Daño ligero solo fue detectado cuando el ruido era menor a 2%.

Otra forma de comprimir información y de reducir el ruido en los datos es a través de la aplicación de la transformada wavelet sobre registros de aceleraciones en el tiempo. La utilización de este tipo de transformada presenta algunas ventajas en relación a la aplicación de la popular FFT, como es la posibilidad de mantener información tanto en el tiempo como en la frecuencia. Una de las principales desventajas se encuentra en que se debe escoger un tipo de función wavelet adecuada.

Sun & Chang (2002) aplicaron la transformada Wavelet Packet (TWP) DB15 a una señal obtenida desde un ensayo de impacto sobre una viga con múltiples soportes, cuyo MEF tenía 10 elementos, y utilizaron coeficientes de energía específicos para formar el vector de entrada a una red neuronal. La carga era aplicada en el centro de la viga y en ese mismo punto se tomaron mediciones de aceleraciones. Los casos de entrenamiento se generaron a partir de modelos numéricos de la estructura en el estado inicial y con daño simple y considerando que un cargamento de impacto era aplicado repetidamente en un punto determinado de la estructura. En la formulación propuesta, las magnitudes de las componentes wavelets en un determinado nivel de descomposición de la señal dependen no solo de la estructura analizada sino también del cargamento que está siendo aplicado sobre ella. El nivel de descomposición se determinó a partir de un análisis de sensibilidad por prueba y error, buscando aquellos componentes de energía con valores mayores y que fueran más sensibles al daño. El nivel de detección de daño alcanzando por la red podía ser el nivel 1 o nivel 3. A partir de los resultados se observó un buen desempeño de la metodología propuesta incluso para los ejemplos de validación que consideraban la presencia de ruido en las mediciones.

La TWP sobre una respuesta en aceleración fue además utilizada por Liu et al en 2011 como vector de entrada a una red neuronal PMC para detectar daño en un pórtico espacial. A diferencia del trabajo anterior donde la respuesta de la estructura era medida en un único punto, en este trabajo se consideraba que mediciones podían ser realizadas en varios puntos de la estructura. Lo anterior con el fin de aumentar la capacidad de generalización de la red a partir de las características específicas que podría contener una medición determinada. La TWP se aplicaba sobre cada respuesta medida y sus componentes principales de energía eran determinadas, las cuales pasan entonces a formar el vector de entrada a la red. El nivel de descomposición de la señal que debería ser alcanzado se determinó en igual forma que en Sun & Chang (2002), pero en este caso utilizando la función Wavelet Battle-Lemarie. En relación a las características de la red esta tenía una única capa oculta, fue entrenada con el algoritmo BP y el vector de salida correspondía a un nivel de identificación de daño (hasta 3er nivel).

Finalmente, los autores gustaría de sugerir el artículo de Staszewski (2000) como una lectura importante en el tema tratado en esta sección, quien realizó un análisis sobre la aplicación de algunos algoritmos de pre-procesamiento de la información (análisis espectral, distribución Wigner-Ville y Transformada Wavelet) y su aplicación a identificación de daño.

3.4 Autoconfiguración de la arquitectura de la red.

La definición de la arquitectura de la RNA es vital para la correcta generalización entre entradas y salidas. Redes con pocas neuronas no serán capaces de aprender correctamente y si se presenta un alto número de neuronas entonces los casos de entrenamiento serán sobreaprendidos. La definición de la arquitectura de la red requiere que para cada estructura en particular se realice un estudio específico sobre la cantidad de neuronas ocultas necesarias. Así, para una estructura dada y con cierto tamaño del vector de entrada, ¿cuál debe ser la cantidad de neuronas ocultas aproximada para iniciar el proceso de ensayo y error?. Al respecto, varias metodologías reportadas utilizan ciertas reglas

de dedo que relacionan la cantidad de neuronas ocultas a la cantidad de neuronas de entrada y salida. Algunas otras no hacen ningún comentario sobre esta elección. A continuación se muestran algunos trabajos que toman en cuenta una definición de la arquitectura óptima de la red y se invita al lector a estudiar el trabajo de Saxen & Petterson (2006), el cual hace una discusión interesante al respecto.

Lam & Yuen (2006) detectaron daño en estructuras utilizando una red PMC cuya arquitectura fue definida siguiendo un procedimiento basado en teoría bayesiana, el cual no tiene ningún paso subjetivo y evita el *overfitting*. En la determinación del número de muestras de entrenamiento los autores llevaron en cuenta que en etapas tempranas del daño, los elementos dañados en la estructura serán pocos. Así que la red fue entrenada considerando dos elementos dañados; sin embargo, las características de la red le permitirán determinar escenarios con una cantidad ligeramente mayor de elementos dañados. Otro aspecto estudiado aquí, fue la determinación de los parámetros de entrada, para lo cual los autores utilizaron los cambios que se presentan en los vectores de Ritz. La utilización directa de estos vectores no es recomendada por su sensibilidad a errores en el modelamiento. El desempeño de la metodología se demostró utilizando una cercha con 9 elementos.

En otro estudio de los mismos autores, Yuen & Lam (2006), el proceso de detección de daño fue dividido en dos etapas, las cuales utilizan la red descrita anteriormente. Probables elementos con daños se determinaron inicialmente utilizando la relación entre los cambios en las formas modales y los cambios en las frecuencias (LAM et al, 1998) como vector de entrada, la cual depende únicamente de la posición del daño. La salida de la red correspondía a un índice de posición de daño que asumía un valor igual a 1 cuando el elemento se encontraba dañado y 0 cuando no había la presencia de daño. En la segunda etapa de esta metodología los vectores de entrada estaban conformados por frecuencias naturales y formas modales y las salidas correspondían a un índice de daño de aquellos elementos identificados en la etapa 1. La metodología fue probada en un edificio de 5 pisos considerando únicamente detección de daño a nivel de piso y la presencia de ruido en las mediciones.

Sahoo & Maity (2007) utilizaron un algoritmo neuro-genético para detección de daño, donde el algoritmo genético tiene la función de optimizar la cantidad de neuronas de las dos capas ocultas y las tasas de momento y aprendizaje del algoritmo BP. El proceso de determinación de la configuración de la red óptima consistía en realizar el entrenamiento de la red hasta alcanzar un número determinado de épocas y después elegir la configuración que producía el menor valor de la función de error utilizada. De esta forma, la elección de la configuración de la red se hace de forma automática evitando que el usuario tenga que realizarla a través de ensayo y error. Los parámetros de entrada a la red correspondieron a las primeras frecuencias naturales y a deformaciones medidas en puntos específicos de la estructura. Los casos de entrenamiento se generaron aleatoriamente suponiendo que una localización aproximada del daño era conocida, con lo cual la información de entradas y salidas a la red correspondía sólo a aquella zona. Dicha información era obtenida a partir de la aplicación de una técnica de sub-estructuración; la cual, como visto anteriormente, permite reducir la complejidad de la red. Para mostrar el desempeño de la metodología propuesta se utilizó una viga en voladizo y un pórtico plano, cuyos MEF tenían 20 y 42 elementos, respectivamente. La cantidad de elementos en las subestructuras analizadas fue de 4 para la viga y 10 para el pórtico. Diferentes escenarios de daño fueron determinados con una buena exactitud en el cálculo de la magnitud del daño.

3.5 Origen de las características que permiten formar el vector de entrada.

La definición de una o varias características de la respuesta de la estructura que sirva(n) como vector de entrada a la red es de gran importancia, ya que debe(n) ser sensitiva(s) al daño y contener información suficiente para garantizar una correcta identificación. Gran variedad de características se han utilizado para detectar daño sin que se haya definido cuál es la más adecuada. Lo anterior, lleva a la necesidad de entender las ventajas o desventajas que tendría la utilización de cada uno de ellas.

Marwala (2000) detectó daño a partir de la combinación de tres redes PMC cada una con un vector de entrada diferente. El primer vector era formado por FRFs, el segundo por formas modales y el tercero por la transformada wavelet (TW) D4 de una señal de aceleración medida en un punto determinado de la estructura. La TW fue formulada de tal forma que la información wavelet fuera independiente de la excitación. Entre las razones que justifican el esquema anterior cabe resaltar que la utilización de FRFs o TW implica en una menor cantidad de puntos de mediciones sobre la estructura. La salida del conjunto de redes correspondía al estado de daño de la estructura y era determinada mediante la combinación lineal de la salida de cada red. Se demostró analíticamente que

el error en la determinación del daño producido por el conjunto de redes siempre será menor o igual que el error promedio de las 3 redes actuando individualmente. Una validación experimental se realizó sobre un cilindro hueco de acero, el cual se sometió a unas pocas diferentes clases de daño. Un análisis de la sensibilidad de las características dinámicas utilizadas al daño mostró que diferentes escenarios de daño presentan diferentes niveles de sensibilidad y que este varía también dependiendo de la característica empleada, siendo en general la TW sobre la señal de aceleración la característica más sensible. Aquí es importante anotar que la detección de niveles bajos de daño se facilita en la medida en que la característica de la respuesta de la estructura utilizada es más sensible al daño. Se observó un buen desempeño de la metodología en la simulación numérica de un sistema masa-resorte de 3 grados de libertad y bajo la considerando de diferentes niveles de ruido.

Pawar et al (2007) utilizaron coeficientes de Fourier de formas modales para formar el vector de entrada a una red PMC y así determinar la posición y magnitud de un único elemento con daño. Algunos aspectos sobre este indicador son comentados: el valor de los coeficientes crece directamente proporcional con el daño, los armónicos más altos contienen más información sobre la localización del daño, la utilización de coeficientes anti-simétricos es necesaria para detectar daño entre dos posiciones simétricas y cada local dañado con su respectiva magnitud de daño posee un único conjunto de coeficientes de Fourier. Tres RNAs fueron entrenadas con diferentes neuronas en la capa de entrada, referida a diferentes cantidades de coeficientes de Fourier. Una única capa oculta fue utilizada y la capa de salida estaba conformada por la posición y la magnitud del daño. La metodología fue aplicada para detectar daño en una viga empotrada en sus dos extremos, cuyo MEF tenía 20 elementos. El entrenamiento de las redes se realizó a partir de la generación aleatoria de diferentes escenarios de daño. Resultados muestran que la metodología produce un error bajo en la determinación tanto de la ubicación como de la magnitud del daño, incluso cuando se consideraba la presencia de ruido en las mediciones.

Lee & Kim (2007) propusieron el *Signal Anomaly Index* (SAI) para localizar daño en una estructura a partir de su utilización como parámetro de entrada a una red PMC. El SAI se calcula a partir de la variación en las FRFs entre las condiciones con y sin daño en diferentes rangos de frecuencia y a partir de diversos sensores situados en la estructura. Esto permite que la cantidad de información que entra a la red sea considerablemente reducida. La metodología se probó experimentalmente en un modelo de puente para el cual se definieron casos específicos de daño. El entrenamiento se realizó considerando los casos anteriores y la presencia de ruido en las mediciones. Resultados mostraron que la red conseguía tasas menores de error en la localización del daño en la medida en que la magnitud del daño aumentaba y cuando se utilizaban señales obtenidas desde mediciones de deformación en lugar de aceleraciones.

Lam & Ng (2008) compararon el desempeño de una red neuronal PMC para detectar daño en un pórtico de acero (IASC-ASCE Phase I SHM Benchmark; JOHNSON et al, 2000) cuando se varía el origen del vector de entrada. En este estudio dos diferentes vectores de entrada son formados a partir de las diferencias que existen en los vectores Ritz y en los parámetros modales (frecuencias naturales y formas modales) para las condiciones con y sin daño. La red tiene como característica que su arquitectura (ver Lam & Yuen, 2006) y el tipo de funciones de transferencia son seleccionadas en forma automática. Los casos de entrenamiento se obtuvieron considerando daño a nivel de piso y 5 valores de disminución de la rigidez. Una lista de patrones de daño definidos para la estructura Benchmark se utilizaron para mostrar el desempeño de la red. Los resultados muestran que ambos parámetros tienen una capacidad similar para determinar la extensión real del daño pero que los vectores de Ritz resultan en valores de daño mayores en aquellos elementos erróneamente identificados como dañados. Sin embargo, la utilización de vectores de Ritz implica en una menor cantidad de neuronas ocultas debido a que introduce una menor cantidad de datos a la red en comparación con la cantidad que introducen los parámetros modales.

Li & Yang (2008) emplearon cambios en las varianzas de la respuesta dinámica de la estructura fueron empleadas por para formar el vector de entrada de una red PMC, la cual fue entrenada con el LMA. La elección de este tipo de parámetro se debe a que presenta una mayor sensibilidad al daño que las respuestas en sí mismas y porque se formula de tal forma que se disminuye el efecto negativo de la presencia de ruido. Un estudio de sensibilidad de parámetros al daño mostró que la varianza del desplazamiento era más sensible a cambios en la rigidez que la varianza de la aceleración, razón por la cual se escogió para formar el vector de entrada. Se utilizó el OAM para determinar los casos que irían a ser utilizados para entrenar la red neuronal. Una viga con 4 soportes, cuyo MEF tenía 30 elementos, se utilizó para mostrar el desempeño de la metodología en la detección de escenarios que

tengan uno o dos elementos dañados. Se consideró que mediciones fueron realizadas en tres puntos de la viga quedando el vector de entrada formado por varianzas correspondientes a cada una de las mediciones y las covariancias entre cada dos respuestas. En el caso en que se esperan dos elementos con daño, los autores suponen que el daño se origina en dos diferentes tramos de la viga – se define tramo como cada parte de la viga entre soportes. Aquí el procedimiento de identificación se realizó en 3 etapas. Primeramente el daño se localizaba de forma aproximada en dos de los tramos de la viga, luego la posición exacta de los dos elementos se valora y finalmente se calcula la extensión del daño. Este hizo que los vectores de entrada y salida de la red cambiaran para cada etapa en función de la información requerida. Por ejemplo, para realizar el primer paso, los cambios en las varianzas de las 3 mediciones de desplazamiento y las 3 covarianzas entre las respuestas se utilizaron para formar el vector de entrada. En relación al vector de salida, este consistía de los números de los dos tramos de la viga que presentaban los dos elementos dañados. Un total de 120 ejemplos se utilizaron para determinar el desempeño de la red la cual mostró una tasa de predicción correcta entre 80 y 88%.

Qian & Mita (2008) utilizaron como vector de entrada a una red PMC las aceleraciones del terreno y a nivel de piso, en una estructura de tipo cortante de 5 niveles, ocasionadas por un terremoto. Dos parámetros extras deben definirse para la formación del vector de entrada a la red: i) el número de medidas de aceleración que va a ser utilizada para predecir la aceleración del tiempo t y ii) el tiempo de atraso de la aceleración del terreno en relación a la aceleración medida. La red tenía una única capa oculta cuyas conexiones no se corresponden con todas las neuronas de la capa de entrada. La salida de la red fue formada por la aceleración de la estructura en el tiempo t en uno o más pisos. La aceleración dada por la red se compara con aquella medida en campo para diferentes pasos de tiempo y, entonces, se determina si la estructura presenta o no daño a partir de una medición estadística de las diferencias encontradas. El algoritmo empleado para realizar el entrenamiento de la red fue el LMA cuyos casos de entrenamiento y validación fueron obtenidos desde registros de aceleraciones de terremotos diferentes. En relación a la aplicación de la metodología, los autores muestran que funciona independientemente de la señal de excitación de la estructura y que es poco influenciada por el ruido en las mediciones. Se realizó una validación experimental sobre un modelo de un pórtico de 5 pisos, el cual permitió verificar el desempeño de la metodología propuesta.

Park et al (2009) dividieron el proceso de detección de daño en dos etapas. Primero, se utiliza una red PMC para determinar la ocurrencia de daño en la estructura en tiempo real desde medidas de aceleración. Los autores comentan que usar directamente los datos de aceleración para la entrada de la red no es conveniente debido a que sería necesario conocer las fuerzas que las producen y utilizar estas mismas fuerzas para el entrenamiento de la red. Por esto, los autores propusieron que se utilizara una función de covarianza cruzada entre dos aceleraciones medidas en puntos diferentes de la estructura para generar el vector de entrada a la red. La red neuronal es entrenada para diferentes modelos probables de excitación, definidos en base a su respuesta al impulso, y utilizando casos de entrenamiento referentes a potenciales escenarios de daño. La ocurrencia del daño en un elemento determinado se calcula en forma estadística desde la respuesta de cada una de las redes. En caso de que la estructura presente daño, una segunda red neuronal PMC es utilizada para determinar la posición y extensión del daño a partir de un vector de entrada formado por las energías de deformación modal. El algoritmo que se utiliza para entrenar ambas redes es el BP. La metodología se aplicó a una viga, cuyo MEF tenía 8 elementos, sometida a diferentes tipos de carga y considerando un único elemento con daño. Resultados mostraron que para todos los casos la red correspondiente a la etapa 1 consigue determinar la presencia del elemento dañado y que las etapas correspondientes a la localización y cuantificación del daño se realizaron correctamente. La metodología propuesta se validó experimentalmente en una viga de aluminio de 56 cms.

Dackermann et al (2010) detectaron daño simple en una viga a partir de un conjunto de redes PMC cuyo vector de entrada era formado por las componentes principales de un índice de daño basado en energía de deformación modal (ver LI et al 2011). Para eso se calcula un coeficiente normalizado relacionado a un elemento y un modo específico. El conjunto de los coeficientes que pertenecen a un mismo modo se utilizan como vectores de entrada a una red individual, así en el caso de tener 8 formas modales disponibles sería necesario que el conjunto sea formado por 8 redes. Este tipo de característica requiere de formas modales completas, las cuales fueron obtenidas a partir de una técnica de interpolación de *spline* cubica. Cada red individual se entrenó con el algoritmo gradientes conjugados descendiente y los casos de entrenamiento se generaron utilizando la técnica *chessboard*. La metodología se aplicó sobre una estructura de tipo viga, cuyo MEF se obtuvo de la división de la viga en 4x4 elementos para la sección transversal y 200 elementos en la longitudinal.

Resultados mostraron que el desempeño de redes individuales varía en función del modo escogido, mientras que la fusión de las soluciones en el conjunto de redes produce detecciones más confiables. La utilización de PCA mostró ser de gran ayuda para eliminar los efectos del ruido sobre el proceso de detección. Esta metodología se validó experimentalmente en una viga de acero de 2.4 m de largo.

Villalba et al (2012) propusieron una red PMC para detectar daño en vigas considerando mediciones únicamente en los grados de libertad verticales. Los datos de entrada a la red corresponden a la diferencia en la diagonal de la matriz de flexibilidad modal entre los estados con y sin daño. Para generar los casos de entrenamiento, estos fueron divididos según correspondían a datos desde escenarios de daño simples y múltiples. Los escenarios de daño múltiple fueron generados aleatoriamente considerando que había entre 2 y 4 elementos dañados y que el rango de daño evaluado correspondía a reducciones en la rigidez de la viga entre 10 y 50%. En un intento de relacionar el número de casos de entrenamiento con el tamaño de la estructura, los autores formularon una ecuación que permite determinar el número aproximado de neuronas en las capas ocultas necesarias para una correcta capacidad de generalización de la red. Resultados fueron presentados como la capacidad de la red para alcanzar un nivel dado de error en la identificación de la extensión del daño. Se observó que en algunos casos la red puede no determinar cuáles son los elementos dañados. Por otro lado, los autores muestran como la aplicación a grandes estructuras requerirá de un esfuerzo computacional muy alto.

3.6 Utilización de redes neuronales diferentes a PMC.

Otra forma de abordar el problema de detección de daño es considerándolo como un problema de reconocimiento de patrones y resolviéndolo a través de RNAs no supervisionadas, las cuales buscan determinar las diferentes relaciones existentes en la información obtenida experimentalmente. El patrón analizado se introduce a la red después de que ha sido entrenada y ella determinará si es similar o no a los casos previos. Yeung & Smith (2005) utilizaron espectros de respuesta obtenidos desde mediciones de la respuesta de la estructura a vibraciones ambientales para entrenar las redes PRAN (*Probabilistic Resource Allocating Network*) y DIGNET. Los autores justifican la elección de los dos tipos de redes anteriores en la capacidad que tienen para discriminar y generalizar. Los parámetros de tolerancia de ambas redes se definieron en tal forma que un número semejante de *clusters* para las redes fuera generado; con esto los resultados obtenidos por las redes podían ser comparados. La metodología se aplicó sobre el puente colgante Clifton localizado en Inglaterra y se observó que ambas redes tenían un buen nivel de confiabilidad para identificar la presencia del daño, el cual dependía de la cantidad de ruido en las mediciones y del número de *clusters*. Para niveles bajos de ruido la red PRAN presentaba los mejores resultados; sin embargo, la red DIGNET es más confiable cuando las mediciones presentan un nivel moderado de ruido si el número de *clusters* se selecciona adecuadamente.

Para el manejo de información vaga las RNA pueden ser combinadas con lógica fuzzy para formar los llamados sistemas neuro-fuzzy (SNF) en los cuales los parámetros del sistema fuzzy se obtienen por medio de una red neuronal. En ese sentido, las capas ocultas realizan los procesos de fuzzificación y de establecimiento de las reglas fuzzy y la capa de salida se encarga de realizar la defuzzificación. Este tipo de red fue utilizada por Wen et al (2007) en una forma no supervisada para localizar daño. Como entrada a la red se definió un parámetro llamado *damage localization feature* (DLF), el cual depende únicamente de la posición del elemento dañado en la estructura. La idea es comparar el DLF medido con diversos DLFs obtenidos desde escenarios de daño generados analíticamente. El escenario cuyo resultado presente la mayor correlación con el medido corresponderá al estado de daño de la estructura. La metodología se aplicó a una estructura de 5 pisos para detección de daño a nivel de piso. La SNF propuesta se mostró más robusta y flexible para detección de daño cuando comparada con una red PMC, incluso cuando mediciones eran incompletas y ruidosas. Sin embargo, el desempeño de esta red tendría que ser evaluado para grandes estructuras donde se tiene un número considerable de clases a ser determinadas. La elección del tipo de red se basó en el hecho que la determinación de la posición del daño por medio del DLF es más próxima de un problema de reconocimiento de patrones que de un problema de mapeamiento de funciones.

Otro tipo común de RNAs son las denominadas Redes de Base Radial (RBR) las cuales utilizan funciones de activación de tipo Gaussiana. A diferencia de redes PMC, las RBR cuentan con una única capa oculta y el proceso de entrenamiento comienza como no supervisado para la capa oculta y supervisado para la capa de salida (HAM & KOSTANIC, 2001). En general el entrenamiento de RBSs

es mucho más rápido que el de redes PMC. Sin embargo, su aplicación a problemas con un gran número de clases puede no ser adecuada. En detección de daño la eficiencia de este tipo de red fue valorada experimentalmente por Zang et al en 2007 sobre una estructura *Bookshelf* de 3 pisos. Para crear el vector de entrada se definieron dos indicadores de daño basados en funciones de correlación globales de las FRFs para las condiciones con y sin daño. Una integración promedio de los indicadores fue realizada por ventanas con el objetivo de disminuir la cantidad de información obtenida por la correlación. El indicador de daño mostró que era sensible a diferentes estados de daño de la estructura y que en la medida en que el número de ventanas aumentaba la descripción del estado de daño era mejor. Sin embargo, no es claro cuál debe ser el umbral que define si la estructura presenta o no daño. La red mostró un buen desempeño para los diferentes escenarios de daño analizados y se observó que una mayor cantidad de sensores permitía disminuir el efecto del ruido en las mediciones.

Para la generalización de funciones surgió en la década de los 90 un nuevo paradigma computacional conocido por red neuronal wavelet, RNW, (ZHANG & BENVENISTE, 1992). Este tipo de red utiliza principios desde la teoría de la transformada wavelet para realizar el mapeamiento entre entradas y salidas. Su principal diferencia con redes neuronales clásicas consiste en que utiliza funciones Wavelet como funciones de activación. Esto hace que además de los pesos deba ser necesario calcular los parámetros de la transformada. Su principal ventaja radica en que podría alcanzar un mismo nivel de aproximación que redes tradicionales pero con un menor número de neuronas, lo que hace que su entrenamiento sea más rápido (PARASURAMAN & ELSHORBAGY, 2005). Sin embargo, presenta la desventaja de que se debe seleccionar el tipo de función wavelet a utilizar. Detalles de la implementación de RNW puede ser encontrado en (CLANCY & OZGUNER, 1994). RNW fueron utilizadas por Jiang & Adeli (2007) para determinar la presencia de daño en edificios de gran altura mediante el análisis de las aceleraciones de la estructuras en ciertos niveles de piso. El daño de la estructura es clasificado en ninguno, leve, moderado, severo, colapso a partir de criterios Fuzzy. Para poder utilizar la información desde varios sensores se utiliza el algoritmo MUSIC. El tamaño del vector de entrada es disminuido por la aplicación de una transformada Wavelet Hat sobre los datos y mediante la eliminación de los valores wavelet nulos.

Redes Neuronales Probabilísticas (RNP) fueron propuestas por Specht en 1990 para clasificar patrones utilizando la teoría de Bayes. La red está constituida por 4 capas: entrada, patrones, sumatoria y salida. RNP son muy útiles cuando los datos para el entrenamiento contienen ruido y para disminuir el tiempo de entrenamiento en comparación con el obtenido por otras RNAs. Su principal desventaja se encuentra en que requiere grandes cantidades de memoria y que la determinación de la estructura de la red juega un papel importante para su correcto desempeño (Mao et al., 2000). RNP fueron aplicadas por Jiang et al (2006), en combinación con técnicas de fusión de información, para definir un proceso de detección de daño en estructuras. Dicho proceso se dividió en 5 etapas comprendiendo pre-procesamiento de la información, extracción de características, utilización de RNP, fusión de datos para dar la respuesta final y toma de decisiones. Datos análogos medidos desde diversos sensores se transforman en un formato digital y se someten a una técnica que permite disminuir el ruido. De los datos se extraen coeficientes de energía wavelet e indicadores de cambios en parámetros modales para servir como vector de entrada a la RNP. La cual tiene como objetivo clasificar el patrón de entrada en una clase de daño predefinida. Como resultado ofrece una estimación de la función de densidad de probabilidad (FDP) para cada clase patrón. La clase con la FDP más grande corresponderá al modelo de daño buscado. La fusión de datos se utilizó para manejar la información resultante de varios sensores y finalmente se determinó una única clase desde métodos estadísticos. La metodología fue aplicada sobre un pórtico de acero (IASC-ASCE Phase I SHM Benchmark; JOHNSON et al, 2000) y sobre el modelo de un edificio de 7 grados de libertad. Los resultados muestran que la red consigue clasificar el modelo de daño correctamente hasta cierto nivel de ruido. Este tipo de red puede tener inconvenientes para ser aplicada en grandes estructuras ya que habría que definir un gran número de clases.

3.7 Consideración de incertidumbres.

Un reto bastante alto para cualquier metodología de detección de daño corresponde a la necesidad de utilizar un MEF para representar la condición inicial de la estructura. Este modelo puede no representar completamente a la estructura debido a errores en la definición de las propiedades de los materiales, condiciones de apoyo y conectividad, entre otros.

Lee et al (2005) hicieron un estudio para detectar daño en puentes utilizando redes neuronales PMC y tomando en cuenta la presencia de los errores anteriormente mencionados. Para eso definieron un vector de entrada en función de la diferencia, o la relación, entre las coordenadas de las formas modales para las condiciones con y sin daño, ya que estos parámetros son menos sensibles a errores en el modelamiento. Proponen utilizar el criterio Vapnik-Chervonenkis Dimension para determinar el número de casos de entrenamiento y utilizar el LHMS para generar los casos de entrenamiento en tal forma que el espacio de búsqueda sea representado en forma confiable. Para disminuir los efectos del ruido en las mediciones se utilizó la técnica *noise injection learning* (MATSUOKA, 1992). La arquitectura de la red se definió en función de las curvas de aprendizaje de diferentes configuraciones propuestas y su entrenamiento se realizó con el algoritmo LMA. Una viga, cuyo MEF tenía 8 elementos, se utilizó para demostrar en forma numérica la capacidad de la metodología para detectar diferentes escenarios de daño. Un modelo de puente y el puente Hannan Grand en Corea sirvieron para mostrar experimentalmente el desempeño de la metodología. Los autores comentan que frecuencias naturales no deberían ser utilizadas para formar los vectores de entrada a la red ya que estas pueden variar considerablemente con cambios en la temperatura y estas variaciones pueden ser incluso mayores que aquellas introducidas por el daño.

Bakhary et al (2007) consideraron los errores presentes en el modelo inicial y en las mediciones mediante una red PMC estadística. En esta red, tanto el MEF como los datos medidos, frecuencias y formas modales, son considerados como variables aleatorias independientes que siguen una distribución normal. Los valores analíticos de las variables anteriores son perturbados por pequeñas variaciones aleatorias para tener en cuenta la incertidumbre. El método *point estimation* se utilizó para el cálculo de los valores medios y desviaciones estándar de las variables, lo cuales servirán para formar el vector de entrenamiento. Así mismo, la probabilidad de un elemento de presentar daño (PDE) es calculada. La red se entrenó con el algoritmo LMA y con casos de entrenamiento obtenidos mediante la técnica LHMS. La metodología se probó numéricamente sobre un pórtico plano cuyo MEF tenía 30 elementos, pero con el objetivo de disminuir el esfuerzo computacional estos elementos fueron agrupados en 6 segmentos. Dos escenarios de daño fueron probados para los cuales la metodología consiguió obtener valores de PDEs altos para los segmentos que realmente contenían daño, siendo su desempeño influenciado en forma negativa por un decremento en la severidad del daño y por el aumento en el nivel de incertidumbre en los datos de entrada. Los autores realizaron una validación experimental en una losa de concreto.

3.8 Aplicaciones.

Diversos trabajos tratan de la aplicación de metodologías de detección de daños basadas en RNAs sobre estructuras reales. En la mayoría de estos casos se definen daños específicos que pueden acontecer sobre la estructura y la red es entrenada para identificar esos daños. Algunos de estos trabajos son Zapico et al (2001), Ko et al (2002), Sahin & Shenoj (2003), Xu & Humar (2006), Efstathiades et al (2007), Kanwar et al (2007), Qian & Mita (2007), Bagchi et al (2010), Arangio & Bontempi (2010), González-Pérez & Valdés-González (2011). Además, RNAs han sido aplicadas para identificar y/o clasificar daño debido a la ocurrencia de un terremoto como en Ni et al (2006), Gonzalez & Zapico (2008), de Lautour & Omenzetter (2009 y 2010), Alvanitopoulos et al (2010).

4 DISCUSIÓN

A partir de la revisión realizada es posible determinar algunos aspectos tanto positivos como negativos sobre la aplicación de redes neuronales en detección de daño:

- Aún no se define cual es el mejor tipo de red neuronal que se debe utilizar en detección de daño, siendo que se emplea generalmente la red neuronal perceptron multicapa. Sólo en pocos casos se comenta el porqué de la escogencia del tipo de red utilizada sobre otros tipos.
- Diferentes niveles de detección de daño pueden ser alcanzados utilizando redes neuronales: identificación, localización y/o cuantificación. Principalmente, las metodologías utilizadas hasta ahora alcanzan nivel I o nivel III en forma directa o por una reducción del espacio de búsqueda.

- Aquellos trabajos que alcanzan un nivel III de identificación tienen como limitación que el número de elementos con daño en la estructura debe ser bajo. Esto se debe al hecho que el número de ejemplos que la red necesita para llevar a cabo una buena generalización aumenta en una forma no lineal con relación a la cantidad de elementos con daño que son considerados. Esto sería una grave limitante si se desea aplicar este tipo de metodologías para detectar daño producto de eventos extremos como terremotos, donde es posible que diversas zonas de la estructura se encuentren con daño. La necesidad de muchos casos de entrenamiento podría inviabilizar la aplicación de redes neuronales para detección de daño.
- La generación de los ejemplos de entrenamiento parte de la definición de los escenarios de daño, los cuales pueden ser especificados en forma aleatoria o por métodos de muestreo. La técnica *Orthogonal Arrays* podría ser muy adecuada ya que permite determinar la cantidad mínima de casos que garantizan una buena representación de los datos.
- En relación al tipo de respuesta de la estructura que se utiliza para formar los vectores de entrada se observa que en la mayoría de los casos se utiliza la respuesta dinámica siendo unos pocos trabajos los que emplean la respuesta estática de la estructura.
- La utilización de una red neuronal deberá ser realizada para cada estructura en particular debido a que será necesaria la configuración de los parámetros de la red neuronal.
- El empleo de técnicas de reducción de la información de entrada a la red neuronal es muy importante para disminuir el costo computacional relacionado al entrenamiento de la red. Es importante anotar que en general los tiempos de entrenamiento de las redes no son mostrados en los artículos reportados en la literatura.
- La implementación en paralelo de la redes podría ayudar a los investigadores a la aplicación de sus metodologías a estructuras de gran porte.
- La consideración de incertidumbres en los modelos y las mediciones en el desarrollo de una metodología de detección de daño es de gran importancia para poder garantizar un desempeño de la metodología robusto.
- Diferentes algoritmos de entrenamiento han sido empleados mostrando que su elección juega un papel importante en la capacidad de detección de daño de la red. Algoritmos como el de regularización bayesiana y el Levenberg-Mardquart obtienen buenas generalizaciones; sin embargo, su costo computacional es muy alto. Futuros trabajos podrán intentar determinar el desempeño de la red utilizando técnicas heurísticas como algoritmos de entrenamiento.
- Finalmente, la investigación en el campo de redes neuronales en detección de daño ha mostrado la posibilidad de utilizar algoritmos híbridos, como es el caso de los trabajos presentados por quienes propusieron una metodología de dos etapas para detección de daño. En la primera etapa una red neuronal podría ser utilizada para localizar el daño y en la segunda etapa se utilizaría un algoritmo basado en poblaciones para cuantificar el daño.

5 CONCLUSIÓN

En este trabajo fue presentada una revisión de la literatura en la aplicación de redes neuronales a detección de daño. Existe un gran número de metodologías reportadas en la literatura que utilizan la técnica anterior, razón por la cual la revisión fue organizada en función de los tópicos de discusión que fueron propuestos. A partir de esta revisión se observó que las redes neuronales tienen gran aplicabilidad para detección de daño, pero que aún tiene algunos temas a resolver para su aplicación a estructuras reales. Uno de ellos es el tiempo que lleva realizar el entrenamiento de la red el cual para estructuras de gran tamaño puede ser demasiado alto. Otras cuestiones fueron ampliamente discutidas.

6 AGRADECIMIENTOS

Los autores agradecen a la CNPq (Consejo Nacional de Desarrollo Científico y Tecnológico, Brasil) por el apoyo financiero dado a la presente investigación.

7 REFERENCIAS

- ALBA, E.; MARTÍ, R. **Metaheuristics Procedures for Training Neural Networks**. New York: Ed. Springer, 2006. 255p.
- ALVANITOPOULOS, P. F.; ANDREADIS, I.; ELENAS, A. Neuro-fuzzy for the classification of earthquake damages. **Measurement**, v. 43, p. 797-809, 2010.
- ARANGIO, S.; BONTEMPI, F. Soft computing based multilevel strategy for bridge integrity monitoring. **Computer-Aided Civil and Infrastructure Engineering**, v. 25, p. 348-362, 2010.
- BAGCHI, A.; HUMAR, J.; XU, H.; NOMAN, A. S. Model-based damage identification in a continuous bridge using vibration data. **Journal of Performance of Constructed Facilities**, v. 24, n. 2, p. 148-158, 2010.
- BAKHARY, N.; HAO, H.; DEEKS, A. Damage detection using artificial neural networks with consideration of uncertainties. **Engineering Structures**, v. 29, p. 2806-2815, 2007a.
- BAKHARY, N.; HAO, H.; DEEKS, A. Structure damage detection using neural network with multi-stage substructuring. **Advances in Structural Engineering**, v. 13, n.1, p. 95-110, 2007b.
- CHANG, C. C.; CHANG, T. Y. P; XU, Y. G.; WANG, M. L. Structural damage detection using an iterative neural network. **Journal of Intelligent Material Systems and Structures**, v. 11, p. 32-42, 2000.
- CHANG, C. C.; CHANG, T. Y. P; XU, Y. G.; TO, W. M. Selection of training samples for model updating using neural networks. **Journal of Sound and Vibration**, v. 249, n. 5, p. 867-883, 2002.
- CLANCY, D.; OZGUNER, U. Wavelet neural networks: A design Perspective. In: THE 1994 IEEE INTERNATIONAL SYMPOSIUM ON INTELLIGENCE CONTROL, 1994, Columbus, USA. **Proceedings...**Columbus, 1994. p. 376-381.
- CURILEM, G.; VERGARA, J.; FUENTEALBA G.; ACUÑA, G.; CHACON, M. Classification of seismic signals at Villarrica volcano (Chile) using neural networks and genetic algorithms. **Journal of Volcanology and Geothermal Research**, v. 180, p. 1-8, 2009.
- DACKERMANN, U.; LI, J.; SAMALI, B. Dynamic-based damage identification using neural network ensembles and damage index method. **Advances in Structural Engineering**, v. 13, n. 6, p. 1001-1016, 2010.
- DEE, G. L.; BAKHARY, N.; RAHMAN, A. A.; AHMAD, B. H. A comparison of Artificial Neural Network Learning Algorithms for Vibration-Based Damage Detection. **Advanced Materials Research**, v.163-167, p. 2756-2760, 2011.
- DE LATOUR, O. R.; OMENZETTER, P. Prediction of seismic-induced structural damage using artificial neural networks. **Engineering Structures**, v. 31, p. 600-606, 2009.
- DE LATOUR, O. R.; OMENZETTER, P. Damage classification and estimation in experimental structures using time series analysis and pattern recognition. **Mechanical Systems and Signal Processing**, v. 24, p. 1556-1569, 2010.
- DOEBLING, S.; FARRAR, C.; PRIME, M. A summary review of vibration- based damage identification methods. **The Shock and Vibration Digest**, v. 30, n. 2, p. 91-105, 1998.
- EFSTAHIADES, Ch.; BANIAPOULUS, C. C.; NAZARKO, P.; ZIEMIANSKI, L.; STAVROULAKIS, G. E. Application of neural networks for the structural health monitoring in curtain-Wall Systems. **Engineering Structures**, v. 29, p. 3475-3483, 2007.

- FANG, X.; LUO, H.; TANG, J. Structural damage detection using neural network with learning rate improvement. **Computers and Structures**, v. 83, p. 2150-2161, 2005.
- GONZALEZ, M. P.; ZAPICO, J. L. Seismic damage identification in buildings using neural networks and modal data. **Computer and Structures**, v. 86, p. 416-426, 2008.
- GONZALEZ-PEREZ, C.; VALDEZ GONZALEZ, J. Identification of structural damage in a vehicular bridge using artificial neural networks. **Structural Health Monitoring**, v. 10, n. 1, p. 33-48, 2011.
- GOPALAKRISHNAN, K. Effect of training algorithms on neural networks aided pavement diagnosis. **International Journal of Engineering Science and Technology**, v. 2, n. 2, p. 83-92, 2010.
- HAM, F.; KOSTANIC, I. **Principles of neurocomputing for science & engineering**. New York: Ed. McGraw-Hill Higher Education, 2001. 642p.
- HYVARINEN, A.; KARHUNEN J.; OJA, E. **Independent component analysis**. New York: Ed. John Wiley & Sons, 2001. 481p.
- HUNG, S. L.; KAO, C. Y. Structural damage detection using the optimal weights of the approximating artificial neural networks. **Earthquake Engineering & Structural Dynamics**, v. 31, p. 217-234, 2002.
- JIANG, S. F.; ZHANG, C. M.; KOH, C. G. Structural damage detection by integrating data fusion and probabilistic neural network. **Advances in Structural Engineering**, v. 9, n. 4, p. 445-458, 2006.
- JIANG, X.; ADELI, H. Pseudospectra, MUSIC, and dynamic wavelet neural network for damage detection of highrise buildings. **International Journal for Numerical Methods in Engineering**, v. 71, 606-629, 2007.
- JOHNSON, E. A.; LAM, H. F.; KATAFYGIOTIS L. S.; BECK, J.L. A benchmark problem for structural health monitoring and damage detection. *In: INTERNATIONAL SYMPOSIUM ON EM2000 (CD Rom)*, 2000, Austin, Texas, USA. **Proceedings...**Austin: 2000.
- KAMINSKI, P. C. The approximate location of damage through the analysis of natural frequencies with artificial neural networks. **Journal of Process Mechanical Engineering**, v. 209, p. 117- 123, 1995.
- KANWAR, V.; KWATRA, N.; AGGARWAL, P. Damage detection for framed RCC buildings using ANN modelling. **International Journal of Damage Mechanics**, v. 16, p. 457-472, 2007.
- Kao, C. Y.; HUNG, S. L. Detection of structural damage via free vibration responses generated by approximating artificial neural networks. **Computers and Structures**, v. 81, p. 2631-2644, 2003.
- KO, J. M.; SUN Z. G.; NI, Y. Q. Multi-stage identification scheme for detecting damage in cable-stayed Kap Shui Mun bridge. **Engineering Structures**, v. 24, p. 857-868, 2002.
- LAM, H. F.; KO J. M.; WONG, C. W. Localization of damaged structural connections based on experimental modal and sensitivity analysis. **Journal of Sound and Vibration**, v. 210, p. 91-115, 1998.
- LAM, H. F.; NG C. T. The selection of pattern features for structural damage detection using an extended bayesian ANN Algorithm. **Engineering Structures**, v. 30, p. 2762-2770, 2008.
- LAM, H. F.; YUEN K. V. Structural health monitoring via measured ritz vectors utilizing artificial neural networks. **Computer-Aided Civil and Infrastructure Engineering**, v. 21, p. 232-241, 2006.
- LEE, J. J.; LEE, J. W.; YI, J. H; YUN, C. B.; YUNG, H. Y. Neural networks-based damage detection for bridges considering errors in baseline finite element models. **Journal of Sound and Vibration**, v. 280, p. 555-578, 2005.

LEE, J.; KIM S. Structural damage detection in the frequency domain using neural networks. **Journal of Intelligent Material Systems and Structures**, v. 18, p. 785-792, 2007.

LI, J.; DACKERMANN, U.; XU, Y.-L.; SAMALI, B. Damage identification in civil engineering structures utilizing PCA-compressed residual frequency response functions and neural networks ensembles. **Structural Control and Health Monitoring**, v.18, p. 207-226, 2011.

LI, Z. -X.; YANG, X. -M. Damage identification for beams using ANN based on statistical property of structural responses. **Computers and Structures**, v. 86, p. 64-71, 2008.

LIU, Y. -Y.; JU, Y. -F.; DUAN, C. -D.; ZHAO X. -F. Structure damage diagnosis using neural networks and feature fusion. **Engineering Applications of Artificial Intelligence**, v. 24, p. 87-92, 2011.

MAO, K. Z.; TAN, K. -C.; SER, W. Probabilistic neural-network structure determination for pattern classification. **IEEE Transactions on Neural Networks**, v. 11, n. 4, p. 1009-1016, 2000.

MARWALA, T. Damage identification using committee of neural networks. **Journal of Engineering Mechanics**, v. 126, n. 1, p. 43-50, 2000.

MATSUOKA, K. Noise injection into inputs in back-propagation learning. **IEEE Transactions of Systems, Man, and Cybernetics**, v. 22, n. 3, p. 436-440, 1992.

NI, Y. Q.; WANG, B. S.; KO, J. M. Constructing input vectors to Neural Networks for Structural Damage Identification. **Smart Materials and Structures**, v. 11, p. 825-833, 2002.

NI, Y. Q.; ZHOU, X. T; KO, J. M. Experimental investigation of seismic damage identification using PCA-compressed frequency response functions and neural networks. **Journal of Sound and Vibration**, v. 290, p. 242-263, 2006.

NUNES DA SILVA., I; SPATTI, D.; FLAUZINO, R. **Redes neurais artificiais para engenharia e ciências aplicada: Curso prático**. Brasil: Artliber Editora, 2010. 399p.

PARASURAMAN, K.; ELSHORBAGY, A. (2005). Wavelet networks: As alternative to classical neural networks. *In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS*, 2005, Montreal, Canada. **Proceedings...** Montreal: 2005. p. 2674-2679.

PARK, J. H.; KIM, J. T.; HONG, D. S.; HO, D. D.; YI, J.H. Sequential damage detection approaches for beams using time-modal features and artificial neural networks. **Journal of Sound and Vibration**, v. 323, p. 451-474, 2009.

QIAN, Y.; MITA, A. Structural damage identification using Parzen-window approach and neural networks. **Structural Control and Health Monitoring**, v. 14, p. 576-590, 2007.

QIAN, Y.; MITA, A. Acceleration-based damage indicators for building structures using neural networks emulators. **Structural Control and Health Monitoring**, v. 15, p. 901-920, 2008.

RAFIQ, M. Y.; BUGMANN, G.; EASTERBROOK, D. J. Neural network design for engineering applications. **Computers and Structures**, v. 79, p. 1541-1552, 2001.

RYTTER, A. **Vibration based inspection of civil engineering**. Ph.D.Dissertation, University of Aalborg, Denmark, 1993.

SAHIN, M.; SHENOI. R. A. Quantification and localization of damage in beam-like structures using artificial neural networks with experimental validation. **Engineering Structures**, v. 25, p. 1785-1802, 2003.

- SAHOO, B.; MAITY, D. Damage assessment of structures using hybrid neuro-genetic algorithm. **Applied Soft Computing**, v. 7, p. 89-104, 2007.
- SAXEN, H.; PETERSON, F. Method for the selection of inputs and structure of feedforward neural networks. **Computers and Chemical Engineering**, v. 30, p. 1038-1045, 2006.
- SPECTH, D. Probabilistic neural networks. **Neural Networks**, v. 3, p. 109-118, 1990.
- SOHN, H.; Et al. (2004). **A review of structural health monitoring literature: 1996–2001**. Los Alamos National Laboratory, 2004. (Report LA-13976-MS). Disponível em: http://www.lanl.gov/damage_id/reports/LA_13976_MS_Final.pdf. Acesso em: 26 março, 2008.
- SUBUDHI, B.; JENA, D. An improved differential evolution trained neural network scheme for nonlinear system Identification. **International Journal of Automation and Computing**, v. 6, n. 2, p. 137-144, 2009.
- SUN, Z.; CHANG, C. C. Structural damage assessment based on wavelet packet transform. **Journal of Structural Engineering**, v. 128, n. 10, p. 1354-1361, 2002.
- TIVIVE, F. H. C.; BOUZERDOM, A. Efficient training algorithms for a class of shunting inhibitory convolutional neural networks. **IEEE Transactions on Neural Networks**, v. 16, n. 3, p. 541-556, 2005.
- VILLALBA, J. D.; LAIER, J. E. Damage detection in beams by using neural networks and dynamic parameters. **Revista Facultad de Ingeniería Universidad de Antioquia**, No. 63, p. 141-153, 2012.
- WEN, C. M.; HUNG, S. L.; HUANG, C. S.; JAN, J. M. Unsupervised fuzzy neural networks for damage detection of structures. **Structural Control and Health Monitoring**, v. 14, p. 144-161, 2007.
- WOLD, H. (1985). **Partial least squares**. In S. Kotz & N. L. Johnson (Eds), *Encyclopedia of Statistical Sciences* 6, p. 581-591. New York: Ed. Wiley.
- WU, Z.; XU, B.; YOKOYAMA K. Decentralized parametric damage detection based on neural networks. **Computer-Aided Civil and Infrastructure Engineering**, v. 17, p. 175-184, 2002.
- XU, H.; HUMAR J. M. Damage detection in a girder bridge by artificial neural network technique. **Computer-Aided Civil and Infrastructure Engineering**, v. 21, p. 450-464, 2006.
- YEUNG, W. T.; SMITH, J. W. Damage detection in bridges using neural networks for pattern recognition of vibration signatures. **Engineering Structures**, v. 27, p. 685-698, 2005.
- YUEM, K. V.; LAM, H. F. On the complexity of artificial neural networks for smart structures monitoring. **Engineering Structures**, v. 28, p. 977-984, 2006.
- ZAKARIA, Z.; MAT IS, N. A.; SUANDI, S. A. A study on neural network training algorithm for multiface detection in static images. **World Academy of Science, Engineering and Technology**, v. 62, p. 170-173, 2010.
- ZANG, C.; FRISWELL, M.I.; IMREGUM, M. Structural health monitoring and damage assessment using frequency response correlation criteria. **Journal of structural mechanics**, v. 133, n. 9, p. 981-993, 2007.
- ZAPICO, J. L.; WORDEN, K.; MOLINA, F. J. Vibration-based damage assessment in steel frames using neural networks. **Smart Materials and Structures**, v. 10, p. 553-559, 1992.
- ZHANG, Q.; BENVENISTE, A. Wavelet networks. **IEEE Transactions on Neural Networks**, v. 3, n. 6, p. 889-898, 1992.