

DETECCION DE FALLAS MEDIANTE SEÑALES ACUSTICAS EN VIGAS DE MATERIAL COMPUESTO USANDO REDES NEURONALES ARTIFICIALES

FAULT DETECTION ON COMPOSITE MATERIAL BASED ON ACOUSTIC SIGNALS AND ARTIFICIAL NEURAL NETWORKS

Carlos Tais^{a,d}, Juan Fontana^{a,c}, Leonardo Molisani^{a,c}, Ronald O'Brien^a, Yolanda Ballesteros^b y Juan C. del Real^b

^aGrupo de Acústica y Vibraciones (GAV), Universidad Nacional de Río Cuarto, Ruta Nac. N° 36 Km 601, 5800 Río Cuarto, Argentina, gav@ing.unrc.edu.ar,

^bDepartment of Mechanical Engineering, Institute for Research in Technology, Universidad Pontificia Comillas, Alberto Aguilera 25, 28015 Madrid, Spain

^cInstituto para el Desarrollo Agroindustrial y de la Salud (IDAS), CONICET-UNRC, 5800 Río Cuarto, Arg.

^dUniversidad Tecnológica Nacional, Facultad Regional Villa María, Av. Universidad 450 CP 5900 Villa María, Córdoba, Argentina

Palabras Clave: Detección de fallas, Nivel de Presión Sonora, Redes Neuronales.

Resumen. El uso de materiales compuestos está incrementándose en aplicaciones industriales. Las ventajas de estos materiales pueden verse disminuidas si no existen técnicas de detección de fallas adecuadas. Una técnica es el uso del sonido emitido por la estructura para predecir fallas utilizando inteligencia artificial como clasificador. En este trabajo se usa el nivel de presión sonora como método evaluador global para diagnosticar fallas en vigas de material compuesto de epoxi reforzado con fibras de carbono. El diagnóstico se realiza mediante un sistema de reconocimiento de patrones basado en el desempeño de clasificadores entrenados usando las técnicas de Redes Neuronales Artificiales (ARN). El entrenamiento, validación y testeo del clasificador mencionado fue realizado con señales acústicas emitidas por vigas sanas y dañadas luego de aplicarles una carga impulsiva. Los resultados demuestran un elevado porcentaje de detección de fallas, lo cual hace factible la implementación de esta técnica para la detección automática de daño en estructuras de material compuesto.

Keywords: Fault detection, Sound pressure level, Neural networks.

Abstract. The use of composite materials is increasing in industrial applications. The advantages of using these materials may be reduced if they are not monitored with adequate fault detection techniques. Pattern recognition techniques use artificial intelligence algorithms to predict failures in the composite structure based on acoustic signals. In this work, the sound pressure level was calculated from acoustic signals and used to develop a non-destructive evaluation method for fault diagnosis in structural beams. In the proposed method, Artificial Neural Networks (ARN) algorithms are trained to classify different levels of damage introduced to the structural beam. Training, validation and testing of the classifiers was performed with acoustic signals emitted by healthy and damaged beams after applying an impulsive load. The results showed a high percentage of fault detection accuracy, which suggests that the implementation of this technique for the automatic detection of damage in composite structures is suitable.

1 INTRODUCCIÓN

Un material compuesto resulta de la combinación de dos o más materiales distintos a nivel macroscópico para obtener nuevas propiedades físicas y mecánicas que no pueden ser alcanzadas por uno de ellos de manera individual. Comparados con los materiales tradicionales presentan ventajas en cuanto a una menor densidad y mayor resistencia y rigidez, buena capacidad de absorción de energía (amortiguamiento) y alta resistencia al desgaste y corrosión, entre otras características. De allí que su uso es cada vez más frecuente en la industria aeronáutica, automotriz, naval, deportiva, etc. (Gholami et al, 2013; Sathishkumar, 2014).

Las Técnicas No Destructivas son comúnmente utilizadas para determinar el nivel de daño en cierto tipo de estructuras empleando diferentes metodologías ya sea localmente o globalmente (Amenabar et al, 2011; Garnier et al, 2011; Gryzagoridis y Findeis, 2010).

Uno de los métodos empleados para la detección global de daño está basado en capturar la señal acústica a través de micrófonos que no tienen contacto directo y registra el sonido originado por la estructura cuando es excitada. Así, la señal acústica es procesada para predecir el nivel de daño presente en la estructura. Turbinas eólicas, rodamientos, cajas de transmisión y motores eléctricos son algunos ejemplos en los cuales se utilizan los métodos acústicos para su evaluación (Kane y Andhare 2016; Niezrecki et al, 2014; Glowacz, 2016).

Algoritmos de inteligencia artificial, en particular Redes Neuronales Artificiales (RNA), se emplean como metodologías de reconocimiento de patrones de daño, las cuales se han difundido con reconocido éxito (Jordan y Mitchell, 2015). Particular interés presentan las RNA en la detección de daño en rodamientos de elementos rotantes en máquinas y equipos. En An, Li y Wang (2020) se propone un nuevo esquema de trabajo utilizando redes neuronales recurrentes para diagnosticar fallas en rodamientos bajo condiciones de trabajo variables. Las redes neuronales convolucionales son ampliamente utilizadas en la detección e identificación de daños en este tipo de equipos y forman parte de una gestión integral de mantenimiento preventivo-predictivo (Zhang et al, 2020; Zhu et al, 2019; Bai et al, 2021)

En este trabajo se presenta un sistema para el reconocimiento global de patrones de daño en vigas de polímeros reforzada con fibra de vidrio (GFRP). Las señales acústicas son capturadas utilizando un micrófono para registrar la respuesta al impulso de probetas que simulan vigas sanas y con daño. Una ventaja importante de los métodos acústicos es el no agregado de masa a las probetas a ensayar. Luego, se entrena una RNA con estas señales previamente procesadas para detectar tipos de daño además de la condición sana. El preprocesamiento de la señal implica la eliminación de ruido mediante la técnica de Descomposición en Valores Singulares, (SVD, por sus siglas en inglés) y la compresión de datos utilizando el Análisis de Componentes Principales (PCA, por sus siglas en inglés).

2 EQUIPAMIENTO, MATERIALES Y ADQUISICIÓN DE LOS DATOS

Las mediciones de la señal acústica se efectuaron sobre una probeta de GFRP típica, fabricada por Carbon Composite Technology (Waldstetten, Alemania) de 175 mm de largo, 25.4 mm de ancho y 4 mm de espesor. A la probeta sana se le efectuaron sucesivamente mediante una sierra, 6 ranuras a diferentes profundidades (0.25, 0.5, 0.75, 1, 1.5 y 2 mm). Estos cortes se ubicaron transversalmente a la longitud de la probeta.

Para realizar las mediciones se utilizó un banco soporte universal y un micrófono FOG-800 del fabricante GTC. Este es un micrófono omnidireccional de alta sensibilidad, de pie metálico flexible que le permite ser orientado al extremo de la probeta a medir. Las especificaciones técnicas del micrófono son las siguientes: sensibilidad 58 dB [mV/Pa] \pm 3 dB, impedancia de salida 2,2 Ω , voltaje de alimentación 4.5 mV, frecuencia de respuesta: 100 Hz – 16000 Hz. Para la calibración de las frecuencias registradas por el micrófono se utilizó el método de

intercomparación; en la se compararon los resultados obtenidos de la misma probeta utilizando otros dos micrófonos realizando 20 medidas con cada uno de ellos, obteniendo un error inferior al 1%/00.

El micrófono se conecta a una PC con tarjeta de sonido que recolecta los datos. La probeta por ensayar se dispone simplemente apoyada sobre las cuerdas de nylon de manera de representar condiciones de vibración libre-libre (Figura 1a). La posición del micrófono, del punto de impacto y de las cuerdas han sido seleccionados de manera de conseguir una buena repetibilidad en los resultados de las frecuencias naturales durante los ensayos (Figura 1b).

Durante un ensayo se aplica una carga impulsiva mediante un elemento rígido metálico en un extremo de la viga y el micrófono ubicado en el otro extremo registra el sonido emitido durante la vibración de la muestra.

La frecuencia de muestreo utilizada es de 32 kHz obteniendo una medida en intervalos de 0.00003 segundos y se registra el ensayo durante 0.5 segundos. Este tiempo resulta adecuado para detectar el decaimiento logarítmico debido al amortiguamiento propio del material y una apropiada precisión al calcular la transformada de Fourier. Se presenta la señal de un ensayo sobre una viga sana en la Figura 2. Se observa que a partir de 0.25 segundos la amplitud se mantiene constante y corresponde al ruido ambiente presente durante el ensayo. Las vigas dañadas presentan un comportamiento similar en el dominio del tiempo.




Figura 1: Equipamiento y disposición de la probeta. (a) Preparación de la probeta, (b) Banco Universal

La señal acústica en el dominio del tiempo resulta de convertir la señal eléctrica medida en mV proveniente del micrófono a magnitudes de presión medidas en Pa. Luego, el Nivel de Presión Sonora (NPS), $L_p(\omega)$, se calcula efectuando la transformada de Fourier de la señal temporal:

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

Donde P_{rms} es la raíz cuadrada media de la transformada de Fourier de la señal acústica y P_{ref} es la presión de referencia ($20 \mu\text{Pa}$). Cada señal contiene 8000 puntos para representar el espectro de frecuencias en el rango de 0 a 16000 Hz. Es necesario normalizar L_p debido a que no es posible medir la magnitud del impulso. Esta normalización se hace respecto al mayor valor de L_p medido sobre la viga sana.

$$\bar{L}_p^i(\omega) = \frac{L_p^i(\omega)}{\max(L_p(\omega))} \quad (2)$$




Figura 2: Señal acústica del ensayo sobre una probeta sana obtenida mediante un micrófono.

Para cada condición de la probeta (sana y 6 profundidades de corte) se efectuaron 40 ensayos obteniendo un total de 280 muestras de señales acústicas como la que se presenta en la Figura 2. Esta cantidad resulta adecuada a los fines de su clasificación ya que contienen suficiente variabilidad.

3 PREPROCESAMIENTO DE LOS DATOS

3.1 Filtrado de la señal mediante Descomposición en Valores Singulares

Dado que los datos se tomaron de ensayos experimentales, es inevitable que se encuentren contaminados con ruido ambiental, provenientes de la misma estructura analizada y de los dispositivos electrónicos utilizados, por lo que es necesario su eliminación para mejorar la calidad de los datos (Fahey y Wicks, 2000).

En este trabajo se efectúa la reducción de ruido mediante la técnica de Descomposición en Valores Singulares (SVD) (Sanliturk y Cakar, 2005). Ésta consiste en eliminar una cierta cantidad de contenido no correlacionado manteniendo las características relevantes de la señal. Esto se logra eligiendo adecuadamente los autovalores y autovectores de la señal que permiten reconstruir la matriz de Hankel con un contenido de ruido atenuado. Luego, ésta matriz es utilizada para reconstruir la señal filtrada. En la Figura 3 se muestran los autovalores normalizados provenientes de una señal NPS. Se observa que la magnitud decrece rápidamente hasta antes de los 50 primeros valores singulares. Así, en este trabajo se utilizaron los primeros 30 autovalores para reconstruir la señal filtrada. Los autovalores restantes se consideran asociados al contenido de ruido por lo que fueron descartados




Figura 3: Magnitud normalizada de los autovalores de la señal de presión sonora.

En la Figura 4 se representa el espectro de frecuencias para la probeta sana donde puede observarse la señal procesada respecto a la original destacando la habilidad de SVD para el filtrado y reducción del contenido de ruido manteniendo la información de amplitudes y frecuencias naturales de la probeta. Este mismo efecto se logra en el caso de las señales provenientes de los ensayos sobre las probetas dañadas. El proceso de filtrado fue efectuado tanto sobre las señales de la probeta sana como sobre aquellas que contenían daño.




Figura 4: Aplicación de la técnica de filtrado SVD sobre la señal de NPS.

3.2 Compresión de datos mediante Análisis de Componentes Principales

Aun habiendo eliminado la mayor parte del contenido de ruido, la señal obtenida mediante SVD presenta una alta dimensionalidad, lo que la hace inadecuada para procesarla mediante una red neuronal. Así, antes de ser procesada, se requiere reducir la cantidad de datos. Para esto, se implementa la técnica de Análisis de Componentes Principales la cual reduce las

dimensiones de la señal manteniendo la información relevante de la respuesta en frecuencia (Jolliffe, 2014).

En PCA, el conjunto original de datos N dimensional se transforma en un nuevo conjunto de datos no correlacionados denominado componentes principales, cuya dimensión P es menor que N . La técnica consiste en utilizar los datos de NPS medidos en N puntos de frecuencia ω y se conforma una matriz de respuesta $[H(\omega)]_{MXN}$ con los M ensayos de NPS. Cada elemento de la matriz $[H(\omega)]$ se normaliza respecto de la media de cada columna de manera que cada conjunto de datos en columnas tenga media cero formando una nueva matriz $[\bar{H}(\omega)]$.

La matriz de correlación $[C]$ se define como:

$$[C]_{NXN} = [\bar{H}(\omega)]_{NXM}^T [\bar{H}(\omega)]_{MXN}. \quad (3)$$

Las componentes principales son los autovalores λ_i y autovectores Ψ_i de la matriz $[C]$. Esto es:

$$[C]\{\Psi_i\} = \lambda_i\{\Psi_i\}. \quad (4)$$

Si se ordenan las componentes principales λ_i en forma decreciente, la primera de ellas y su autovector asociado representa la cantidad y dirección de máxima variación en los datos originales. Las siguientes componentes representan las componentes de magnitud decreciente y sus autovectores asociados son mutuamente ortogonales. Por lo tanto, las primeras componentes principales son las más significativas y representan las características que predominan en las funciones de NPS. Además, teniendo en cuenta que el ruido aleatorio no se correlaciona con tales características globales y queda representado por las componentes principales menos significativas, éste queda eliminado haciendo una selección adecuada de las componentes a utilizar (Tang, 2005).

Una selección adecuada del número de componentes principales se consigue observando la Figura 5. De ésta puede deducirse que las primeras 14 componentes principales explican el 100% de la varianza de los datos originales. A fin de determinar un número apropiado de componentes principales a utilizar, se evaluó el comportamiento del algoritmo de inteligencia artificial para diferentes cantidades de componentes principales usadas como entradas a la red.




Figura 5: Porcentaje de la varianza de los datos originales explicado por cada componente principal.

Así, mediante SVD y PCA, se logra un filtrado y una compresión de datos además de una segunda eliminación de ruido de la señal original. Este nuevo conjunto de datos es utilizado como datos de entrada para entrenar la red neuronal de clasificación.

4 PROCESAMIENTO DE LOS DATOS PARA CLASIFICACIÓN

Las herramientas basadas en Redes Neuronales Artificiales (RNA) son una de las técnicas más utilizadas para resolver problemas que involucran identificación y clasificación, no solo en el ámbito de la ingeniería, sino en otras ramas de la ciencia y técnica (Alavi et al 2016; Fang et al, 2005; Law et al. 2005). Estas redes son entrenadas mediante el procesamiento de datos que contienen muestras de las probetas sana y dañadas de manera de ajustar sus propios parámetros con el objetivo de identificar muestras similares de manera correcta.

4.1 Característica de la red neuronal utilizada

Puede caracterizarse una RNA mediante tres propiedades particulares: a) su arquitectura: es decir el patrón de conexiones entre neuronas, b) su algoritmo de aprendizaje: también usualmente llamado algoritmo de entrenamiento, el cual es un método para establecer los pesos en las conexiones y c) sus funciones de activación: es la función utilizada para transformar los niveles de activación de una unidad (neurona) en una señal de salida. Entre los paradigmas de aprendizaje más conocidos se encuentran el aprendizaje supervisado y no supervisado. En el aprendizaje supervisado, que es el más habitual y el utilizado en este trabajo, se desea encontrar una función que ajuste un conjunto de ejemplos, es decir, se desea inferir cual será la salida o resultado después de que la red es provista con un conjunto de patrones de entrenamiento conocidos no sólo sus entradas sino también sus correspondientes objetivos (targets). Uno de los algoritmos de aprendizaje más utilizados es el de retropropagación (backpropagation), que se basa en minimizar el error, usando gradiente descendiente en el espacio de pesos, hasta que la red converja (Rojas, 1996). El objetivo del algoritmo es ajustar los pesos de la red que minimicen el error. Las salidas de la red y los targets son comparadas para establecer la función de error. En el comienzo la red es inicializada con pesos elegidos aleatoriamente, y el gradiente del error se utiliza para corregir los pesos iniciales. La red usualmente converge después de repetir el procedimiento un número adecuado de veces.

Entre los beneficios de las redes neuronales esta la generalización, es decir su capacidad de generalizar sus resultados a casos que no han estado involucrados en los pasos de entrenamiento, es decir, es la capacidad de aprender las salidas de entradas que no han sido previamente consideradas.

En nuestro trabajo se utilizó una RNA de tipo perceptrón (una capa oculta) completamente interconectada con una capa de entrada (input), y una capa de salida (output) con tres neuronas para representar las tres clases a discriminar (Figura 6).

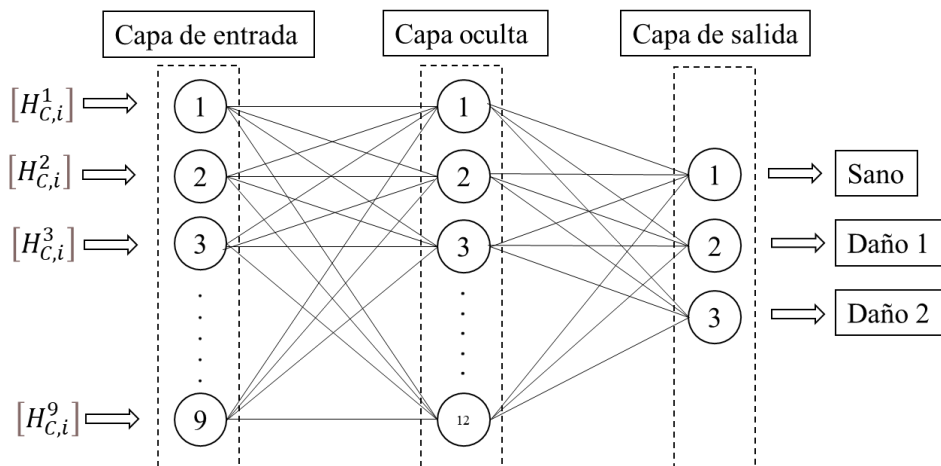


Figura 6: Topología de la RNA implementada para clasificación de daño.

Los datos de entrenamiento provienen de la matriz $[H_C]$ reconstruida con las componentes principales seleccionadas en PCA. Cada fila de esta matriz representa un dato de entrada y tiene asociado una etiqueta (T_i) que representa la categoría de nivel de daño al cual representa. En la Tabla 1 se muestran las categorías de nivel de daño de acuerdo a la profundidad de la ranura y su correspondiente etiqueta. A partir de esta tabla se puede ver que el algoritmo de inteligencia artificial debe discriminar datos de tres clases diferentes: probeta sana, probeta con nivel de daño 1 y probeta con nivel de daño 2.

Profundidad de la ranura [mm]	Categoría de nivel de daño de la probeta	Etiquetas de salida de la RNA
0,00	SANA	[0 0 0]
0.25		
0.5	DAÑO 1	[0 1 0]
0.75		
1.0		
1.5	DAÑO 2	[0 0 1]
2.0		

Tabla 1: Clasificación del daño según la profundidad de la ranura y su codificación en la RNA.

Así, un conjunto $\{[H_{C,i}], [T_i]\}$ es presentado a la RNA para su entrenamiento, validación y testeo en una proporción del 75%, 15% y 15% respectivamente, eligiendo al azar las muestras para cada etapa. Durante el entrenamiento se actualizan los pesos de las conexiones y el sesgo (bias) de la red calculando el gradiente de la función de error. En este caso, el algoritmo utilizado es el de propagación hacia atrás de Levenberg-Marquardt (Marquardt, 1963). Se efectúan el número suficiente de corridas de manera de que se asegure la repetibilidad en la convergencia de los resultados. La función de error alcanza un valor de 0.1 en 33 épocas.

El conjunto de validación se utiliza para controlar el error durante el entrenamiento y con el de test se evalúa el desempeño de la RNA. Estos últimos no se utilizan en la etapa de entrenamiento y validación. El parámetro utilizado para evaluar el desempeño de la RNA fue el de exactitud (en inglés, accuracy), entendiéndose como tal la relación entre las muestras correctamente identificadas y el número total de muestras en el conjunto de test.

5 RESULTADOS Y DISCUSIÓN

El daño presente en las probetas mecanizadas implica un cambio en su rigidez. Esto hace que existan diferencias en sus propiedades dinámicas respecto de la probeta sana. En particular, en las probetas dañadas se encuentran desplazados los valores de frecuencia que corresponden a la máxima amplitud (frecuencias naturales). Puede observarse en la Figura 7 que existe un desplazamiento más notable hacia la izquierda en la tercera, quinta y séptima frecuencia natural. Estas modificaciones en las frecuencias deben ser identificadas en la RNA para una correcta clasificación del nivel de daño presente.




Figura 7: Cambios en las frecuencias de las vigas dañadas respecto de la sana.

Para determinar el número óptimo de neuronas en la capa de entrada se utilizó un procedimiento consistente en evaluar la exactitud de la red variando la cantidad de neuronas en la capa oculta desde 1 a 30 para distintos valores de neuronas de entrada (número de componentes principales utilizados) en el rango de 1 a 18. De la Figura 8 se concluye que el valor adecuado de neuronas de entrada es de 9 ya que con este valor se obtiene una exactitud aproximada del 92% en promedio para las 30 pruebas con distinto número de neuronas en la capa oculta.




Figura 8: Exactitud promedio de la red variando la cantidad de neuronas en la capa de entrada.

En la etapa de testeo, la red entrenada es utilizada para clasificar 42 muestras elegidas aleatoriamente. Los resultados se muestran en la matriz de confusión en la Figura 9. Los números identificatorios de cada clase (1, 2 y 3) se corresponden con las tres condiciones de daño analizadas (Sana, Daño 1 y Daño 2). La exactitud de la red resulta en un 95.2%, es decir qué de las 42 muestras procesadas, la red ha sido capaz de clasificar correctamente 40 de ellas. A su vez, puede evaluarse la sensibilidad (recall) y la precisión de la RNA para cada clase, determinadas por la fila inferior y columna derecha de la matriz de confusión respectivamente. La precisión determina la fracción de muestras correctamente clasificadas como positivas sobre el total de muestras clasificadas positivas. Por otro lado, la sensibilidad indica qué porcentaje de casos positivos de cada clase fueron clasificados como tal. Estas métricas complementan la información de la calidad de la clasificación efectuada por la red. De la matriz de confusión se observa que los valores de precisión y sensibilidad para la clasificación de probetas sanas fue de 85.7% para ambos casos. Para la clase correspondiente a nivel de Daño 1 la precisión y la sensibilidad tuvieron un valor de 94.4%. La clase que mejor fue discriminada por la red fue la de correspondiente al nivel de Daño 2 con precisión y sensibilidad de 100%. Esta performance resultante es comparable con valores satisfactorios obtenidos en (Falk et al., 2003; Farooq et al., 2012; Story y Fry, 2014)

Predicción	1	6 14.3%	1 2.4%	0 0.0%	85.7% 14.3%
	2	1 2.4%	17 40.5%	0 0.0%	94.4% 5.6%
	3	0 0.0%	0 0.0%	17 40.5%	100% 0.0%
		85.7% 14.3%	94.4% 5.6%	100% 0.0%	95.2% 4.8%
	Objetivo	1	2	3	

Figura 9: Matriz de confusión que resulta de clasificar el conjunto de datos de testeos usando la RNA entrenada y validada.

6 CONCLUSIONES

En este trabajo demostramos la capacidad de la RNA de clasificar correctamente probetas de material compuesto con diferente tipo de daño, utilizando para su entrenamiento señales proveniente de ensayos acústicos con equipamiento no invasivo y de bajo costo. El daño fue generado artificialmente mediante cortes en el material con distintas profundidades que simulan fallas de distinta gravedad. Las señales utilizadas han sido previamente procesadas para eliminar su ruido y comprimir los datos a los fines de disminuir el costo computacional. Estos procesos se llevan adelante con debida eficiencia computacional en computadoras de escritorio

de características standard. Los resultados obtenidos muestran un adecuado nivel de confiabilidad y permite proponer esta metodología para el estudio de casos realísticos y/o de testeo en tiempo real. Dados los prometedores resultados obtenidos se propone en un futuro ampliar la metodología actual para que la RNA provea información acerca de la ubicación de la falla como así también del nivel de daño.

REFERENCIAS

- Alavi, A.H., Hasni, H., Lajnef, N., Chatti, K., Faridazar, F., An intelligent structural damage detection approach based on self-powered wireless sensor data. *Autom. Constr.* 62, 24e44. <http://dx.doi.org/10.1016/j.autcon.2015.10.001>. 2016.
- Amenabar, I., Mendikute, A., Lopez-Arraiza, A., Lizaranzu, M., Aurrekoetxea, J., 2011. Comparison and analysis of non-destructive testing techniques suitable for delamination inspection in wind turbine blades. *Compos. Part B Eng.* 42 (5), 1298e1305. <http://dx.doi.org/10.1016/j.compositesb.2011.01.025>.
- An, Z., Li, S., Wang, J., Jiang, X. A novel bearing intelligent fault diagnosis framework under time-varying working conditions using recurrent neural network. *ISA Transactions* , 100, 155–170. <https://doi.org/10.1016/J.ISATRA>. 2020.
- Bai, R., Xu, Q., Meng, Z., Cao, L., Xing, K., Fan, F. Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation. *Measurement*, 184, 109885. <https://doi.org/10.1016/J.MEASUREMENT>. 2021.
- Fahey, S. O. y Wicks, A.I., Noise sources in mechanical measurements. *Exp. Tech.* 24 (2), 40-43. <http://dx.doi.org/10.1111/j.1747-1567.2000.tb02271.x>. 2000.
- Falk, J.P., Steck, J.E., Smith, B.L., 2003. A nondestructive testing technique for composite panels using tap test acoustic signals and artificial neural networks. *Int. J. Smart Eng. Syst. Des.* 5 (4), 491e506. <http://dx.doi.org/10.1080/10255810390445364>.
- Fang, X., Luo, H., Tang, J., Structural damage detection using neural network with learning rate improvement. *Comput. Struct.* 83 (25e26), 2150e2161. <http://dx.doi.org/10.1016/j.compstruc.2005.02.029>. 2005.
- Farooq, M., Zheng, H., Nagabhushana, A., Roy, S., Burkett, S., Barkey, M., et al., 2012. Damage detection and identification in smart structures using SVM and ANN. In: Matikas, T.E. (Ed.), *Proceedings of SPIE*, vol. 8346. <http://dx.doi.org/10.1117/12.915189>.
- Garnier, C., Pastor, M.-L., Eyma, F., Lorrain, B., 2011. The detection of aeronautical defects in situ on composite structures using Non Destructive Testing. *Compos. Struct.* 93 (5), 1328e1336. <http://dx.doi.org/10.1016/j.compstruct.2010.10.017>.
- Gholami, M., Sam, A.R.M., Yatim, J.M., Tahir, M.M., 2013. A review on steel/CFRP strengthening systems focusing environmental performance. *Constr. Build. Mater.* 47, 301e310. <http://dx.doi.org/10.1016/j.conbuildmat.2013.04.049>.
- Glowacz, A., 2016. Diagnostics of rotor damages of three-phase induction motors using acoustic signals and SMOFS-20-EXPANDED. *Arch. Acoust.* 41 (3), 507e515.
- Gryzagoridis, J., Findeis, D., 2010. Impact damage detection on composites using optical NDT techniques. *Insight Non-Destr. Test. Cond. Monit.* 52 (5), 248e251. <http://dx.doi.org/10.1784/insi.2010.52.5.248>.
- Jolliffe, I., *Principal Component Analysis*. In *Wiley Stats Ref: Statistics Reference Online*. John Wiley & Sons, Ltd. Retrieved from. <http://onlinelibrary.wiley.com/doi/10.1002/9781118445112.stat06472/abstract>. 2014.
- Jordan, M.I., Mitchell, T.M., 2015. Machine learning: trends, perspectives, and prospects. *Science* 349 (6245), 255e260. <http://dx.doi.org/10.1126/science.aaa8415>. Kane, P.V., Andhare,

- Kane, P.V., Andhare, A.B., 2016. Application of psychoacoustics for gear fault diagnosis using artificial neural network. *J. Low Freq. Noise, Vib. Act. Control.* <http://dx.doi.org/10.1177/0263092316660915>, 263092316660915.
- Law, S. S., Li, X. Y., Zhu, X. Q., Chan, S. L., Structural damage detection from wavelet packet sensitivity. *Eng. Struct.* 27 (9), 1339e1348. <http://dx.doi.org/10.1016/j.engstruct.2005.03.014>. 2005.
- Marquardt, D., An Algorithm for Least-Squares Estimation of Nonlinear Parameters, *SIAM Journal on Applied Mathematics*, Vol. 11, N^o. 2: 431–441, 1963
- Niezrecki, C., Poozesh, P., Aizawa, K., Heilmann, G., 2014. Wind turbine blade health monitoring using acoustic beamforming techniques. *J. Acoust. Soc. Am.* 135 (4), 2392e2393. <http://dx.doi.org/10.1121/1.4877915>.
- Rojas, R., *Neural Networks - A Systematic Introduction*. Springer-Verlag, 1996.
- Sanliturk, K.Y., Cakar, O., Noise elimination from measured frequency response functions. *Mech. Syst. Signal Process.* 19 (3), 615e631. <http://dx.doi.org/10.1016/j.ymsp.2004.04.005>, 2005.
- Sathishkumar, T.P., Satheeshkumar, S., Naveen, J., 2014. Glass fiber-reinforced polymer composites e a review. *J. Reinf. Plastics Compos.* 33 (13), 1258e1275. <http://dx.doi.org/10.1177/0731684414530790>.
- Story, B.A., Fry, G.T., 2014. A structural impairment detection system using competitive arrays of artificial neural networks. *Computer-Aided Civ. Infrastruct. Eng.* 29 (3), 180e190. <http://dx.doi.org/10.1111/mice.12040>.
- Tang, J., Frequency response based damage detection using principal component analysis, *Information Acquisition, IEEE International Conference*, 2005.
- Zhang, D., Stewart, E., Entezami, M., Roberts, C., Yu, D. Intelligent acoustic-based fault diagnosis of roller bearings using a deep graph convolutional network. *Measurement*, 156, 107585. <https://doi.org/10.1016/J.MEASUREMENT>. 2020
- Zhu, Z., Peng, G., Chen, Y., Gao, H. A convolutional neural network based on a capsule network with strong generalization for bearing fault diagnosis. *Neurocomputing*, 323, 62–75. <https://doi.org/10.1016/J.NEUCOM.2019>