

CLASIFICACION DE DEFECTOS EN UNIONES PEGADAS UTILIZANDO INTELIGENCIA ARTIFICIAL

DEFECTS CLASSIFICATION IN BONDED JOINTS USING ARTIFICIAL INTELLIGENCE

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

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

^b *Mechanical Engineering Department, Institute for Research in Technology Universidad Pontificia Comillas de Madrid, Alberto Aguilera, 23, 28015 Madrid, España*

^c *Instituto para el Desarrollo Agroindustrial y de la Salud (IDAS), UNRC-CONICET, Ruta Nac. N° 36 Km 601, 5800 Río Cuarto, Argentina*

^d *Universidad 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. La aplicación de adhesivos se encuentra ampliamente difundida en una amplia gama de industrias. Sin embargo, su uso ha sido evitado en estructuras en las cuales la seguridad es un factor crítico. A partir de la utilización de señales acústicas es posible detectar la degradación del material. En este trabajo se emplea el análisis del Nivel de Presión Sonora (NPS) como método evaluador global no destructivo de fallas en uniones adhesivas de probetas fabricadas con vigas de aluminio como sustrato y adhesivo acrílico. El diagnóstico se realiza preprocesando la señal de NPS y clasificando el daño mediante un sistema de reconocimiento de patrones basado en las técnicas de Redes Neuronales Artificiales (RNA). Los resultados de la validación cruzada demuestran que el clasificador presenta un adecuado porcentaje de detección de fallas.

Keywords: Faults detection, Sound Pressure Level, Neural Networks.

Abstract. The application of adhesives is widespread in a wide range of industries. However, its use has been avoided in structures in which safety is a critical factor. By using acoustic signals, it is possible to detect the degradation of the material. In this work, the analysis of the Sound Pressure Level (SPL) was used as a global non-destructive evaluation method of failures in adhesive joints of experimental samples consisting of aluminum beams as substrate and acrylic adhesive. The diagnosis is made by preprocessing the SPL signal and classifying the damage using a pattern recognition system based on Artificial Neural Network (ANN) techniques. The results of the cross validation show that the classifier presents an adequate failure detection percentage.

1 INTRODUCCIÓN

Los adhesivos estructurales son una alternativa muy prometedora en la sustitución de técnicas y elementos de unión como la soldadura, los tornillos o los remaches. El empleo de uniones adhesivas permitirá una mayor eficacia y flexibilidad en los procesos productivos. Por otro lado, precisamente la capacidad de unir materiales diferentes ofrece muchas ventajas sobre otras técnicas convencionales de unión, ya que supone reducción de peso, elevada resistencia a la fatiga, aislamiento eléctrico y térmico, etc. (Adams, 2021).

Otros beneficios importantes de las uniones adhesivas es que no distorsionan los componentes adheridos como sucede en el caso de la unión por soldadura o en uniones con elementos mecánicos. Además, son uniones continuas en lugar de puntuales (como lo es por ejemplo la soldadura por puntos, muy utilizada en automoción), lo que genera una distribución de tensiones uniforme y aporta mayor rigidez. A su vez, una unión bien diseñada presentará una gran capacidad de absorción de energía, así como buenas propiedades de amortiguamiento de vibraciones y de ruido.

En los últimos tiempos, la utilización de los adhesivos estructurales ha encontrado un extenso campo de aplicación en distintos sectores industriales, tales como el aeroespacial, automoción, construcción naval, electrodomésticos y construcción metálica (da Silva et al, 2018).

El término estructural se emplea para un amplio rango de adhesivos entre los que se incluyen los adhesivos epoxis, cianoacrilatos, fenólicos y poliuretanos, siendo los más usados los epoxis, especialmente en las industrias aeroespacial y de automoción (Papon, 2018).

Una familia de adhesivos con un gran potencial de aplicación, como son los adhesivos acrílicos tenaces, han sido poco empleados y estudiados en la unión de estructuras de componentes de aleaciones base aluminio. Estos adhesivos presentan algunas características que les hacen especialmente útiles en la unión de materiales metálicos; su capacidad de curado a temperatura ambiente, su elevada velocidad de curado, resistencia a la fractura y pelado elevada y su capacidad de producir uniones satisfactorias en superficies con una escasa preparación superficial hacen que estos adhesivos puedan ser una solución a muchos procesos de unión (Righettini, 2002; del Real et al, 2011; Huang y Lean, 2023).

Sin embargo, estas uniones no están exentas de problemas, presentando algunas limitaciones tales como problemas de tiempo de manipulación, debidas al calor o tiempo que se necesita para su curado, y no menos importante, la baja resistencia de las uniones adhesivas a esfuerzos de pelado, siendo este un factor limitante en el diseño de las uniones.

Los defectos se producen principalmente durante el proceso de aplicación y de curado, y pueden conducir a una reducción en las fuerzas cohesivas de la capa del adhesivo. El proceso de curado es el más importante, y el que más afecta a la resistencia el adhesivo. Generalmente se producen en la interfase adhesivo-sustrato o dentro del propio adhesivo sin considerar los defectos en los sustratos. La falta de adhesión puede ser atribuida a una pobre preparación de la superficie del sustrato. Los pretratamientos de las superficies, apropiados para las condiciones de servicio y compatibles con el adhesivo, mejoran la adhesión y son particularmente importantes para la adhesión del aluminio. Sin embargo, cualquier contaminación de la superficie, como grasa, que pueda quedar después de la limpieza y el pretratamiento, tiene como consecuencia fallos en la adhesión (Adams, 2018).

Para el control de estos posibles defectos existen varios métodos de ensayos no destructivos (NDT), como la inspección visual, la microscopía óptica y electrónica, los rayos X, el C-Scan, la termografía IR y la radiometría IR, para evaluar la integridad de la línea de unión (Zhuang et al, 2018). Otro grupo de técnicas son los métodos de ondas acústico-ultrasónicas, como las técnicas de pulso-eco y transmisión, la espectroscopia acústica y los métodos basados en ondas

guiadas, que permiten recopilar información detallada sobre la estructura real y las propiedades de los materiales (Maeva et al, 2011).

En la actualidad junto con los ensayos no destructivos se utilizan herramientas de inteligencia artificial para automatizar el proceso de reconocimiento de alteraciones o daños en sistemas estructurales (Tais, Fontana et al, 2022, Jordan y Mitchell, 2015, O'Brien, 2017). En particular, las redes neuronales artificiales (RNA) han demostrado su aptitud para tal fin (An, Li y Wang, 2020) por lo que habitualmente forman parte de una gestión integral de mantenimiento preventivo-predictivo (Zhang et al, 2020; Zhu et al, 2019; Bai et al, 2021, Zapico et al, 2011).

En este trabajo se presenta un sistema para el reconocimiento y clasificación de patrones de daño en probetas de uniones adheridas constituidas por placas de aluminio como sustrato y adhesivo acrílico Hysol H4800 Speedbonder y en las cuales se ha simulado un determinado defecto. Este sistema utiliza señales acústicas relacionadas con la respuesta al impulso de las probetas. Dichas señales fueron capturadas con un micrófono y procesadas con una PC. Dado que las probetas a ensayar son ligeras, el método propuesto presenta la ventaja de no agregar masa a las mismas. Luego, se entrena una RNA con estas señales previamente procesadas para detectar tipos de daño además de la condición sana. Previo a ello, se efectúa el preprocesamiento de la señal para la eliminación de ruido y compresión de datos.

2 METODOLOGÍA

Teniendo en cuentas las características de las estructuras analizadas en este trabajo, no todas las técnicas convencionales de NDT son adecuadas para la detección de los fallos en estos materiales (Qing, 2005; Qing, 2006). Así, se emplean técnicas de monitoreo por emisión acústica basadas en el análisis de la señal de respuesta, teniendo en cuenta que los sonidos emitidos por un objeto cambian si el objeto contiene daños estructurales ya que en presencia de defectos se producen cambios en sus propiedades dinámicas y por tanto se modifican los modos de vibración y frecuencias características cuando es excitada con una fuerza externa (Nair, 2010).

Este trabajo se basa en el uso de la espectroscopia acústica mediante el análisis de la señal acústica dada por el Nivel de Presione Sonora (NPS). La probeta excitada por un impulso emite una onda acústica que es captada por un transductor (micrófono) y luego transmitida como señal eléctrica. El NPS se obtiene de convertir ésta última a magnitudes de presión medidas en Pa. Luego, el 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 μ Pa). 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.

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

2.1 Diseño y construcción de las probetas

Las probetas ensayadas se prepararon utilizando adherentes de aluminio EN AW 6082 de 150x25x4 mm y adhesivo acrílico, obteniendo una unión por solape simple. El aluminio es un metal de uso muy común en aplicaciones industriales con uniones adhesivas por su ligereza y facilidad de adhesión. Para la unión se utiliza el adhesivo acrílico tenaz Loctite Hysol H4800 Speedbonder. La longitud de solape es de 30 mm y se aplica el adhesivo formando una adhesión

de 25 mm de ancho con un espesor de adhesivo de 1 mm. En la Figura 1 se muestran 4 probetas con diferentes niveles de defecto, el cual está relacionado con el porcentaje de adhesión y fue simulado mediante una ranura generada en la unión adhesiva. Los cuatro porcentajes de adhesión constituyen las cuatro clases a discriminar mediante la red neuronal




Figura 1: Disposición del sustrato y adhesivo para cada porcentaje de adherencia

Para preparar estas muestras se introdujo una lámina de teflón de espesor 1 mm, longitud 25 mm y ancho variable según la longitud de la ranura deseada y sus correspondientes porcentajes de adhesión en el sustrato. Ésta se colocó en el centro de la unión adhesiva, evitando que este hueco se rellene de adhesivo y, una vez curado, fue extraída quedando el espacio libre de adhesivo. En la Tabla 1 se detallan las dimensiones de las distintas ranuras y el tipo de defecto (% de adhesión) asociado a cada una.

| <i>Clase defecto</i> | <i>% de adhesión</i> | <i>Longitud de la ranura [mm]</i> |
|----------------------|----------------------|-----------------------------------|
| 1 | 25 % | 22.5 |
| 2 | 50 % | 15 |
| 3 | 75 % | 7.5 |
| 4 | 100 % | 0 |

Tabla 1: Dimensiones del defecto introducido en las probetas. La primera columna indica la clase asignada a cada defecto y que luego es utilizada como etiqueta en el modelo de clasificación.

2.2 Ensayos experimentales

Las mediciones del NPS se realizaron utilizando 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.

El micrófono se conecta a una PC a través de la 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 2a). El micrófono se ubica en el extremo opuesto al cual se aplica el impacto mientras que las cuerdas transversales a la probeta se ubican de manera que coincidan con los dos nodos que corresponden al primer modo de resonancia a los efectos de prevenir efectos de bloqueo (Figura 2b).

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 16 kHz 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.




Figura 2: a) Banco de ensayo por impulso de excitación, b) Dimensiones de la probeta (en mm).

Para cada dimensión de ranura asociada a una longitud del defecto particular en la probeta (Tabla 1), se prepararon 10 probetas diferentes y se efectuaron 20 ensayos a cada una obteniendo un total de 200 ensayos para cada tipo de defecto y un total de 800 para todas las probetas fabricadas. Estas muestras constituyen el conjunto de datos de entrenamiento de la RNA, considerando que esta cantidad resulta adecuada a los fines de su clasificación.

3 PROCESAMIENTO DE LA SEÑAL

La señal de NPS obtenida de los ensayos contiene inevitablemente una cierta cantidad de ruido ambiental y proveniente de los dispositivos electrónicos utilizados, entre otros factores, la cual se considera como información no relevante, por lo que es necesario su eliminación para mejorar la calidad de los datos (Fahey y Wicks, 2000). Aun filtrada, contiene una alta dimensionalidad por lo que es necesario efectuar una compresión de datos para adecuarla como información útil de entrada a la red neuronal (Jolliffe, 2014).

La técnica de Descomposición en Valores Singulares (SVD) (Sanliturk y Cakar, 2005) es utilizada en este trabajo como método de reducción de ruido. 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 mínimo, o al menos atenuado. Luego, esta matriz es utilizada para reconstruir la señal filtrada. Para la señal de NPS del ensayo de las uniones adheridas se utilizaron los primeros 30 autovalores para su reconstrucción. Los autovalores restantes se consideran asociados al contenido de ruido por lo que fueron descartados.




Figura 3: Señal de NPS original (con ruido) y filtrada.

Se muestra en la Figura 3, el NPS en el dominio de frecuencia para un ensayo particular, apreciándose la diferencia entre la señal filtrada y la original demostrando la habilidad de SVD para el filtrado y reducción del contenido de ruido manteniendo la información de amplitudes y frecuencias naturales.

Posteriormente al filtrado, mediante la técnica de Análisis de Componentes Principales (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 . Esto se logra proyectando los mismos sobre la base de un nuevo espacio vectorial formado por los autovectores de la matriz de correlación calculada a partir del conjunto de datos de los experimentos. Los autovalores asociados a los autovectores constituyen las componentes principales representan la cantidad y dirección de máxima variación en los datos originales. Si se ordenan en forma decreciente, las primeras componentes principales son las más significativas y representan las características que predominan en las funciones de NPS.

Una selección adecuada del número de componentes principales a utilizar se consigue observando la Figura 4. De ésta puede deducirse que con las primeras 20 componentes principales se explica el 95% de la varianza de los datos originales. Una explicación detallada de PCA puede encontrarse en Ponso (2019).




Figura 4: Porcentaje de la varianza de los datos originales explicado por cada componente principal.

4 MODELO DE CLASIFICACIÓN

El algoritmo de inteligencia artificial utilizado en el presente trabajo es una Red Neuronal Artificial (RNA), de tipo perceptrón (Zapico, 2009) de una capa oculta de 20 neuronas completamente interconectada con una capa de entrada (input) de 30 neuronas, y una capa de salida (output) con cuatro neuronas para representar las cuatro clases a discriminar (Figura 5).

Los datos de entrenamiento $[H_{C,i}]$ se presentan a la red en forma matricial y sus valores son las componentes principales obtenidas en la etapa de compresión de datos. Cada fila de esta matriz representa un dato de entrada y tiene asociado una etiqueta (T_i) que representa la categoría a la que corresponde según el porcentaje de adhesión (Tabla 1).

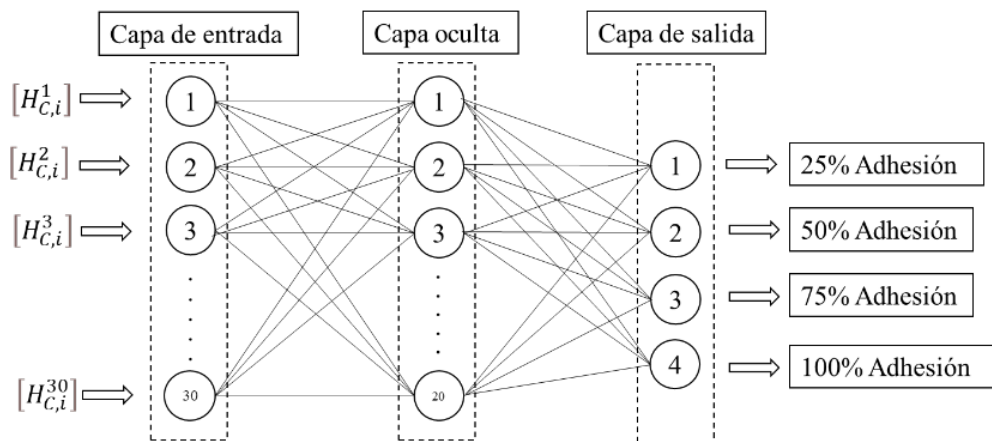


Figura 5: Arquitectura de la Red Neuronal utilizada para detectar defectos en uniones pegadas. A partir de las componentes principales obtenidas de la señal acústica, la red puede discriminar 4 clases asociadas al porcentaje de adhesión.

Para el entrenamiento y la evaluación del desempeño de la RNA se emplea el método de validación cruzada (cross-validation) que consiste en utilizar, del total de las 10 probetas de cada clase, 9 de ellas para entrenar y la restante para testear. De esta manera se asegura la independencia de los datos utilizados en la etapa de testeo frente a los de entrenamiento. Luego, se va intercambiando sucesivamente la probeta testeada hasta obtener 10 redes en las que se han testeado todas las probetas sin haber sido utilizadas durante el entrenamiento. Esta organización de los datos se indica en la Tabla 2.

5 RESULTADOS

El desempeño de cada una de las RNA indicadas en la Tabla 2 se evalúa utilizando la métrica de exactitud (accuracy), entendiéndose como tal la relación entre las muestras correctamente identificadas y el número total de muestras en el conjunto de test. Esta métrica se obtiene de la matriz de confusión de cada red. A modo de ejemplo se muestra en la Figura 6 la matriz de confusión correspondiente a la primera de las redes evaluadas (Net1).

Confusion Matrix

| | 25% | 50% | 75% | 100% | |
|------|--------------|----------------|----------------|--------------|----------------|
| 25% | 20 25.0% | 0 0.0% | 2 2.5% | 0 0.0% | 90.9% 9.1% |
| 25% | 0 0.0% | 15 18.8% | 1 1.2% | 0 0.0% | 93.8% 6.2% |
| 75% | 0 0.0% | 0 0.0% | 17 21.2% | 0 0.0% | 100% 0.0% |
| 100% | 0 0.0% | 5 6.2% | 0 0.0% | 20 25.0% | 80.0% 20.0% |
| | 100% 0.0% | 75.0% 25.0% | 85.0% 15.0% | 100% 0.0% | 90.0% 10.0% |
| | 25% | 50% | 75% | 100% | |

Target Class

Figura 6: Matriz de confusión correspondiente a la Net1.

La exactitud de todas las redes evaluadas se resume en la Tabla 2, obteniendo una exactitud promedio para las 10 redes del 90.8%. Puede interpretarse entonces que se han clasificado correctamente 73 de las 80 muestras evaluadas en la etapa de test (20 muestras de cada clase).

| <i>Red</i> | <i>Entrenamiento</i> | <i>Test</i> | <i>Exactitud</i> | <i>Sensibilidad</i> | <i>Precisión</i> |
|-----------------|----------------------------|-------------|------------------|---------------------|------------------|
| Net1 | Probetas 2 a 10 (P2 a P10) | P1 | 90,0% | 90,0% | 91.2% |
| Net2 | P1 y P3 a P10 | P2 | 95,0% | 95,0% | 95.8% |
| Net3 | P1 a P2 y P4 a P10 | P3 | 82,5% | 82.5% | 85.9% |
| Net4 | P1 a P3 y P5 a P10 | P4 | 93,8% | 82.5% | 94,0% |
| Net5 | P1 a P4 y P6 a P10 | P5 | 88,8% | 88.8% | 92.3% |
| Net6 | P1 a P5 y P7 a P10 | P6 | 83,8% | 83.8% | 85.5% |
| Net7 | P1 a P6 y P8 a P10 | P7 | 97,5% | 97.5% | 97.8% |
| Net8 | P1 a P7 y P9 a P10 | P8 | 91,2% | 91.3% | 91.9% |
| Net9 | P1 a P8 y P10 | P9 | 93,8% | 83.8% | 94.2% |
| Net10 | P1 a P9 | P10 | 91,2% | 91.3% | 92.3% |
| <i>Promedio</i> | | | 90.8% | 88.6% | 92.1% |

Tabla 2: Resultados de exactitud, sensibilidad y precisión para cada red.

De la matriz de confusión de la Figura 6 y de la Tabla 2 también puede evaluarse la sensibilidad (recall) y la precisión de la RNA para cada clase, determinadas por la fila inferior y columna derecha respectivamente. La precisión determina la fracción de muestras de cada clase correctamente clasificadas sobre el total de muestras clasificadas en cada clase, resultando en un valor promedio para las 10 redes del 92.1%, mientras que la sensibilidad indica qué porcentaje de casos positivos de cada clase fueron clasificados como tal. En la Tabla 2 se resume el promedio para las cuatro clases de esta métrica obtenida para cada red, resultando un promedio de 88.6%. Tanto el valor de precisión como de sensibilidad se consideran aceptables y junto con el resultado de la exactitud promedio aseguran un desempeño satisfactorio de la red (Falk et al., 2003; Farooq et al., 2012; Story y Fry, 2014).

6 CONCLUSIONES

En este trabajo demostramos la capacidad de la RNA para identificar con valores satisfactorios de exactitud, precisión y sensibilidad probetas compuestas de sustrato de aluminio y adhesivo acrílico adheridos con cuatro diferentes porcentajes de superficie adherida, los cuales representan cuatro niveles diferentes de daño. La obtención de las señales acústicas se efectuó con equipamiento estándar de bajo costo y han sido previamente procesadas para eliminar su componente de ruido, para posteriormente efectuar una compresión y así reducir la dimensionalidad de los datos a analizar con la RNA. El procesamiento final se realizó con adecuado costo computacional utilizando PC de escritorio de mediana o baja capacidad de cálculo. Los prometedoros resultados obtenidos permiten proponer la utilización de esta metodología para ensayar adhesivos de distinto tipo (epoxi, poliuretano, etc.).

REFERENCIAS

- Adams, R. Bonding Adhesive: Science, Technology and Applications. Second Edition. Woodhead Publishing, 2021
- Adams, R. D. Non destructive testing. en: da Silva, L., Öchsner, A., Adams, R. (eds) Handbook of Adhesion Technology. Springer, 2018.
- 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>. 2021.
- da Silva, L. F. M., Öchsner, A., Adams, R. D. Introduction to Adhesive Bonding Technology. en: da Silva, L., Öchsner, A., Adams, R. (eds) Handbook of Adhesion Technology. Springer, 2018.
- del Real-Romero, J. C., Ballesteros, Y., Chamochín, R., Abenojar, J., Molisani, L. Influence of surface preparation on the fracture behavior of acrylic adhesive/CFRP composite joints. *The Journal of Adhesion*. Vol. 87, nº. 4, pp. 366 - 381, 2011.
- 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., 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>. 2003.
- Farooq, M., Zheng, H., Nagabhushana, A., Roy, S., Burkett, S., Barkey, M., et al., 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>. 2012.
- Huang, J. P., Lean, J. Advances in acrylic structural adhesives. *Advances in Structural Adhesive Bonding (Second Edition)*, David A. Dillard (Ed), Woodhead Publishing, 69-101. 2023
- 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., Mitchell, T, Machine learning: trends, perspectives, and prospects. *Science* 349 (6245), 255e260. <http://dx.doi.org/10.1126/science.aaa8415>. Kane, P.V., Anghare, 2015.
- Maeva, E., Severina, I., Bondarenko, S., Chapman, G., O'Neill, B., Severin, F, Maev R. G.. Acoustical methods for the investigation of adhesively bonded structures: A review. *Canadian Journal of Physics*. 82(12): 981-1025. <https://doi.org/10.1139/p04-056>. 2011
- Nair A, Cai C., Acoustic emission monitoring of bridges: Review and case studies. *Engineering Structures*; 32(6): 1704-1714. 2010.
- O'Brien R., Fontana, J. M., Ponso, N., Molisani, L., A pattern recognition system based on acoustic signals for fault detection on composite materials. *European Journal of Mechanics A/Solids* 64. 1-10. <http://dx.doi.org/10.1016/j.euromechsol.2017.01.007>. 2017
- Papon, E. Adhesive Families. Handbook of Adhesion Technology. Springer, 2018.
- Ponso, N., Molisani, L., Zapico, Adriana, Del Real, J. C., Ballesteros, Y., Eliminación de ruido de señales acústicas usando descomposición de valores singulares y análisis de componentes principales. *Mecánica Computacional*. Vol XXXI, págs. 4013-4027. 2014
- Qing X., Chan HL, Beard SJ, et al. An Active Diagnostic System for Structural Health Monitoring of Rocket Engines. *Journal of intelligent material systems and structures*. 17(7),: 619-628. 2006

- Qing X., Kumar A, Zhang C. A hybrid piezoelectric/fiber optic diagnostic system for structural health monitoring. *Smart Materials and Structures*; 14(3) ,: S98-S103. 2005
- Righettini, R. F., Structural acrylics. en: *Surfaces, Chemistry and Applications 2. Adhesion Science and Engineering Series*, M. Chaudhury, A.V. Pocius (Ed.), Elsevier, Amsterdam, 2, 823-846. 2002.
- 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.ymssp.2004.04.005>, 2005.
- Story, B.A., Fry, G.T., 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>. 2014.
- Tais, C., Fontana, J., Molisani, L., Obrien, R., Ballesteros, Y., Del Real, J., Detección de fallas mediante señales acústicas en vigas de material compuesto usando redes neuronales artificiales, *Mecánica Computacional* vol XXXIX, 199-210, 2022
- Zapico, A., Molisani, L., Fault diagnosis on steel structures using artificial neural networks, *Mecánica Computacional* Vol XXVIII, págs. 181-188. 2009
- Zapico, A, Molisani, L, .del Real-Romero, J. C., Ballesteros, Y. Global fault detection in adhesively bonded joints using artificial intelligence. *Journal of Adhesion Science and Technology*. Vol. 25, nº. 18, pp. 2435 - 2443, 2011
- 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>. 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>. 2019.
- Zhuang Y, Kopsaftopoulos F, Dugnani R, Chang F-K. Integrity monitoring of adhesively bonded joints via an electromechanical impedance-based approach. *Structural Health Monitoring*;17(5):1031-1045. 2018