

SISTEMA EXPERTO HÍBRIDO BAJO EL ENFOQUE DE *ENSEMBLE LEARNING*
PARA LA MONITORIZACIÓN DE ESTRUCTURAS LAMINARES

GUSTAVO ADOLFO MORENO BELTRÁN

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS
ESCUELA DE INGENIERÍAS
ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
BUCARAMANGA

2020

SISTEMA EXPERTO HÍBRIDO BAJO EL ENFOQUE DE *ENSEMBLE LEARNING*
PARA LA MONITORIZACIÓN DE ESTRUCTURAS LAMINARES

GUSTAVO ADOLFO MORENO BELTRÁN

Trabajo de Grado para optar al título de
Magister en Ingeniería Electrónica

Director

Rodolfo Villamizar Mejía

Ph.D. en Tecnologías de la Información

Codirectores

Franklin Alexander Sepulveda

Ph.D. en Ingeniería

Jhonatan Camacho Navarro

Ph.D. en Ingeniería Civil

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS
ESCUELA DE INGENIERÍAS
ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
BUCARAMANGA

2020

DEDICATORIA

Este trabajo viene dedicado para todas aquellas personas que apoyaron el desarrollo y ejecución de este trabajo de grado.

AGRADECIMIENTOS

En primer lugar agradezco a mi familia por el apoyo económico y moral que tuvieron para conmigo durante el desarrollo de este proyecto.

Al director de este trabajo, el profesor Rodolfo Villamizar, que con su gran calidad humana y su dedicación, ha hecho de esta una experiencia extraordinaria.

A Jhonatan Camacho que fue de gran apoyo durante el desarrollo de este proyecto. Además de brindarme la oportunidad de trabajar en este proyecto.

A todos mis amigos que han sido parte y han hecho posible de cualquier manera la realización de éste proyecto.

Gracias a todos.

CONTENIDO

	pág.
INTRODUCCIÓN	18
1. MARCO CONCEPTUAL Y ESTADO DEL ARTE	22
1.1. MONITORIZACIÓN DE SALUD ESTRUCTURAL	22
1.2. DETECCIÓN DE DAÑOS BASADO EN PIEZODIAGNOSIS	23
1.3. ALGORITMOS DE DIAGNÓSTICO	27
1.4. DETECCIÓN DE DAÑOS USANDO MODELOS DE LINEA BASE	29
1.5. MÉTODOS DE REPRESENTACIÓN REDUCIDA	31
1.5.1. Modelo de línea base lineales.	31
1.5.2. Modelos de línea base no lineales.	32
1.6. ÍNDICES ESTADÍSTICOS PARA LA DETECCIÓN DE DAÑOS	36
1.7. LOCALIZACIÓN DE DAÑOS PARA LA MONITORIZACIÓN DE SALUD ESTRUCTURAL	38
1.7.1. Estado del Arte.	40
1.7.2. Metodología para localización de daños en estructuras basada en piezodiagnos y reconstrucción probabilística.	42
1.8. ENSEMBLE LEARNING PARA EL DISEÑO DE SISTEMAS EXPERTOS Y MONITORIZACIÓN DE DAÑOS	45
1.8.1. Componentes claves de un sistema <i>Ensemble Learning</i> .	45
1.8.2. Diseño de un sistema experto basado en <i>Ensemble Learning</i> .	46
1.8.3. Monitorización de salud estructural usando <i>Ensemble Learning</i> .	48
2. METODOLOGÍA PARA LA DETECCIÓN Y LOCALIZACIÓN DE DAÑOS BASADA EN EN- SEMBLE LEARNING	50
2.1. ETAPA 1: PIEZODIAGNOSIS Y ADQUISICIÓN DE DATOS	50

2.2. ETAPA 2: PRE-PROCESAMIENTO DE DATOS	52
2.3. FASE A: MODELADO	53
2.3.1. Etapa 3A: Base de casos nominal.	53
2.3.2. Etapa 4A: <i>Ensemble</i> de modelos.	54
2.4. FASE B: MONITORIZACIÓN CONTINUA	56
2.4.1. Etapa 3B: Vector de Datos en linea.	56
2.4.2. Etapa 4B: Evaluación del Modelo.	56
2.4.3. Etapa 5B: Detección y localización.	56
3. DISEÑO DEL EXPERIMENTO	60
3.1. ESTRUCTURA LAMINAR DE ESTUDIO	60
3.2. ACONDICIONAMIENTO DE SEÑALES Y MULTIPLEXADO	61
3.2.1. Generación de onda guiada.	63
3.3. ESCENARIOS DE DAÑO	65
3.3.1. Agregación de masas.	65
3.3.2. Orificios y cortes.	66
3.3.3. Ubicación de los daños.	68
4. VALIDACIÓN EXPERIMENTAL DE LA METODOLOGÍA	69
4.1. ROBUSTEZ DEL MODELO ENSAMBLADO ANTE VARIACIONES DE TEMPERATURA	69
4.2. DETECCIÓN CONTINUA DE DAÑOS	72
4.2.1. Detección de masas.	72
4.2.2. Detección de perforaciones y cortes.	76
4.3. Localización de daños	80
4.3.1. Localización de daños usando modelos MonoActuación/Monosensado.	80
4.3.2. Localización De daños usando modelo MonoActuación/Multisensado.	85
5. CONCLUSIONES Y TRABAJO FUTURO	89
5.1. CONCLUSIONES GENERALES	89

5.2. TRABAJOS FUTUROS	90
BIBLIOGRAFÍA	91
ANEXOS	100

LISTA DE FIGURAS

	pág.
Figura 1. Modelo de linea base	30
Figura 2. Modelo de linea base usando PCA	32
Figura 3. Autocodificadores	33
Figura 4. Kernel PCA	34
Figura 5. Función de distribución elíptica de la probabilidad de localización del defecto.	43
Figura 6. Sistema experto basado en <i>Ensemble Learning</i>	46
Figura 7. Proceso de diseño de un SE basado en <i>Ensemble Learning</i>	47
Figura 8. Criterios para selección de algoritmo base de un <i>Ensemble Learning</i>	49
Figura 9. Ensemble para la detección y Localización de daño	51
Figura 10. Secuencia de multi-actuación usando PZTs	51
Figura 11. Registro de datos	52
Figura 12. a) Matriz de datos para modelo por actuador b) Matriz de datos para modelo por cada sensor	54
Figura 13. Ensemble para la detección y localización de daño	55
Figura 14. Estructura de estudio	61
Figura 15. Modulo de amplificación	62
Figura 16. Modulo de multiplexado	62
Figura 17. Señal tipo <i>Burst</i> generada para excitación de piezoeléctricos.	64
Figura 18. Lamina 10 x 10 cm	64
Figura 19. Amplitud vs frecuencia de actuación	65
Figura 20. Masas agregadas para la generación de daños	66

Figura 21.	Masa agregada en estructura de estudio	66
Figura 22.	Escenarios de daño tipo perforación	67
Figura 23.	Ubicación de los daños	68
Figura 24.	Efecto de la temperatura	70
Figura 25.	Metodología Modelo extendido	71
Figura 26.	Detección de daño con modelo extendido	71
Figura 27.	Agregación de masas en diferentes posiciones	73
Figura 28.	Modelo extendido después de quitar la masa 1	74
Figura 29.	Índice combinado mediante la suma	75
Figura 30.	Índice combinado mediante el producto	75
Figura 31.	Resultados Detección de daños usando multiactuación	77
Figura 32.	Resultados índices usando <i>Ensemble Learning</i>	78
Figura 33.	Resultados índices EDR y Dist con PCA lineal	79
Figura 34.	RAPID con índice Q para el estado sin daños	81
Figura 35.	Contribuciones de índice Q para el daño (D1)	81
Figura 36.	RAPID con índice Q para el estado daño (D1)	82
Figura 37.	Imagen para escenario de daño D1	83
Figura 38.	RAPID con índice Q para el estado con daños	84
Figura 39.	RAPID con índice Q para el estado sin daños	85
Figura 40.	Contribuciones de índice Q para el estado sin daños	86
Figura 41.	RAPID con índice Q para daño (D1)	86
Figura 42.	Imagen para escenario de daño D1	87
Figura 43.	RAPID con índice Q para el estado con daños	88
Figura 44.	Distribución de modelos solución de un problema	103
Figura 45.	<i>Ensemble Learning</i> como comité de expertos	104
Figura 46.	Fuentes de información para identificación y reconocimiento de personas	105

Figura 47. Aproximación de una frontera no lineal usando un <i>Ensemble</i> de árboles de decisión.	106
Figura 48. Aproximación de una frontera altamente no lineal mediante un <i>Ensemble</i> no lineal circular.	107
Figura 49. Arquitecturas de <i>Ensemble Learning</i>	109
Figura 50. Arquitectura apilada y mezcla de <i>Ensemble Learning</i>	110
Figura 51. Manipulación de datos:	112
Figura 52. Manipulación del proceso de modelado	113
Figura 53. Manipulación de las características de entrada	113
Figura 54. Manipulación de la respuesta	114

LISTA DE TABLAS

	pág.
Tabla 1. Dimensiones de la estructura	60

LISTA DE ANEXOS

	pág.
Anexo A. <i>Ensemble Learning:</i>	100
Anexo B. Listado de publicaciones	116
Anexo C. Agradecimientos	118

GLOSARIO

Lamina se demonima a una placa de aluminio con dimensiones de 100cm x 100cm y 2 mm de espesor.

Daño Cambios introducidos a un sistema que afecta negativamente su rendimiento actual o futuro.

RESUMEN

TÍTULO: SISTEMA EXPERTO HÍBRIDO BAJO EL ENFOQUE DE *ENSEMBLE LEARNING* PARA LA MONITORIZACIÓN DE ESTRUCTURAS LAMINARES *

AUTOR: GUSTAVO ADOLFO MORENO BELTRÁN **

PALABRAS CLAVE: PCA, KERNEL PCA, *PIEZODIGNOSTICS*, SHM, *ENSEMBLE LEARNING*,

DESCRIPCIÓN:

En este proyecto de investigación se presentan los resultados de la implementación de un sistema experto híbrido para detección y localización de daños en estructuras laminares mediante la combinación de piezodiagnos, correlación cruzada y análisis de componentes principales (PCA) bajo el enfoque de *Ensemble Learning*. La metodología propuesta consiste en primero generar ondas guiadas a través de la superficie de la estructura mediante dispositivos piezoeléctricos. Luego, se aplica correlación cruzada entre las señales de actuación y sensado. Después, se construye un modelo de línea base aplicando análisis de componentes principales, que permite la identificación de defectos estructurales mediante índices de error. En este proyecto, *Ensemble Learning* es evaluado como aproximación para obtener algoritmos de diagnóstico robustos que permitan la generación de fronteras de decisión mejor definidas entre los estados de daño y sin daño de la estructura. La construcción del Ensemble se basa en algoritmos no lineales de PCA que permiten la construcción de los algoritmos base. Adicionalmente, una versión modificada del algoritmo de reconstrucción para inspección probabilística de daños es implementada para localización de defectos. La metodología propuesta fue experimentalmente validada para monitorización continua usando datos adquiridos de una placa de aluminio, en la que se estudiaron escenarios de daño de agrietamiento, perforaciones y agregación de masas. La efectividad de la metodología fue evaluada en condiciones ambientales variables de temperatura. Como resultado, se obtuvo un algoritmo robusto para detección y localización de daños en estructuras laminares mediante la combinación de piezodiagnos, correlación cruzada y PCA en un esquema paralelo de *Ensemble Learning*.

* Trabajo de grado

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y telecomunicaciones. Director: Rodolfo Villamizar Mejía, PhD. Codirectores: Franklin Alexander Sepulveda, PhD., Jhonatan Camacho Navarro, PhD.

ABSTRACT

TITLE: HYBRID EXPERT SYSTEM BASED ON ENSEMBLE LEARNING APPROACH FOR THE MONITORING OF LAMINAR STRUCTURES *

AUTHOR: GUSTAVO ADOLFO MORENO BELTRÁN **

KEYWORDS: PCA, KERNEL PCA, PIEZODIGNOSTICS, SHM, ENSEMBLE LEARNING.

DESCRIPTION:

This research project presents the results of implementing a hybrid expert system for damage detection and location in laminar structures by combining piezo diagnostics, cross-correlation functions and principal component analysis through an Ensemble Learning scheme. The proposed methodology consists of first generating guided waves along the monitored structure surface by using piezoelectric (PZT) devices. Then, cross-correlation analysis is applied to piezoelectric signals between actuation and sensing signals. Later, a baseline model is obtained by means of a PCA in order to identify possible damages through error indexes. In this thesis, Ensemble Learning is evaluated as approach for obtaining more robust diagnosis with high separable boundaries between undamaged and damage conditions taking advantages of learner algorithms built from Non-Linear PCA. Also, a modified version of the Reconstruction Algorithm for Probabilistic Inspection of Damage (RAPID) is implemented with the purpose of damage location. The proposed methodology was experimentally evaluated for continuous monitoring by using data acquired from an aluminum plate, where damage scenarios regarding to mass adding and cuts were studied. The effectiveness of the proposed methodology to detect and locate damages under varying temperature environmental conditions was demonstrated. As a result, robust damage detection and location in laminar structures are achieved through the combination of piezodiagnosics approach, cross-correlation analysis and principal component analysis techniques and Ensemble Learning.

* Master Thesis

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y telecomunicaciones. Director: Rodolfo Villamizar Mejía, PhD.Co-directors:Franklin Alexander Sepulveda, PhD.,Jhonatan Camacho Navarro, PhD.

INTRODUCCIÓN

Actualmente, debido al continuo uso y construcción de estructuras tales como aviones, puentes, oleoductos, plataformas marítimas, y torres, entre otros, existe la necesidad de desarrollar métodos que permitan evaluar su estado de salud estructural. Esto ayudaría en la toma de decisiones sobre cambios y modificaciones en la integridad de una estructura con el fin de reforzarlas o repararlas. Al incluir metodologías de detección de daños en un programa de mantenimiento de estructuras, estas ayudan a reducir las consecuencias producidas por un daño, tales como pérdidas económicas, accidentes y en ocasiones pérdidas humanas. La investigación actual en este campo se centra en la búsqueda de métodos de monitorización de la estructura usando pruebas no destructiva (NDT, Non-Destructive Testing) que permitan tener una evaluación continua de esta en el transcurso del tiempo con capacidad de detectar condiciones anómalas debido a factores tales como al envejecimiento por uso normal, sobrecargas, fatiga o en algunos casos por acontecimientos externos. En las últimas décadas, variadas técnicas de monitorización de salud estructural (SHM, Structural Health Monitoring) han sido investigadas para abordar la detección de daños en los componentes que conforman una estructura ¹. Sin embargo, uno de los principales retos en la implementación en campo es la incertidumbre debida a las condiciones ambientales y operacionales que presentan variaciones con el transcurso del tiempo. Por ejemplo, en ² estudiaron los efectos de las variaciones

¹ A. CANDELIERI y col. "A Hyper-resolution SVM Classification Framework: Application to On-line Aircraft Structural Health Monitoring". En: *Procedia - Social and Behavioral Sciences* 108 (2014), págs. 57-68.

² H. SOHN. "Effects of environmental and operational variability on structural health monitoring." En: *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences* 365.1851 (2007), págs. 539-560.

ambientales y operacionales en las estructuras que pueden causar diagnósticos erróneos. Partiendo de este análisis es recomendable el uso de metodologías que incluyan la compensación de dichos efectos, además de incluir capacidades adicionales en sistemas de monitorización como lo es la localización. Esto reduciría tiempos de intervención y reparación, que dependiendo de la estructura pueden ser determinantes para evitar fallos catastróficos.

Teniendo en cuenta el punto de vista planteado, el presente trabajo de investigación busca proponer una metodología para localización de defectos en estructuras laminares usando una arquitectura híbrida de aprendizaje conjunto (*Ensemble learning*) que logre un modelo robusto a condiciones variantes en el tiempo como la temperatura, al tiempo que se reduce la sensibilidad a los efectos adversos presentes en operación continua.

El desarrollo de esta investigación aborda el cumplimiento del objetivo general que busca Detectar y localizar daños en estructuras tipo lámina mediante un sistema experto que sea robusto a cambios de temperatura y operable de manera continua. para el cual se deben cumplir los siguientes objetivos específicos:

- Detectar y localizar daños en estructuras tipo laminar en condiciones de laboratorio, usando el principio de piezodiagnos y bajo el enfoque de una arquitectura paralelo de *Ensemble Learning*.
- Seleccionar características que permitan que el sistema experto propuesto opere de manera continua y sea robusto a cambios de temperatura.
- Validar experimentalmente la arquitectura propuesta con defectos tipo agregación de masa, cortes/grietas, perforaciones, los cuales se considerarán de manera independiente en una estructura tipo lámina en condiciones controladas de laboratorio.

El cumplimiento de los objetivos planteados en la investigación se llevo a cabo teniendo en cuenta la siguientes consideraciones:

- Para el desarrollo de la investigación se tomaron como punto de partida trabajos previos de los grupos de investigación CoDalab de la Universidad Politécnica de Cataluña y CEMOS de la Universidad Industrial de Santander
- El principio de actuación y sensado de señales a ser usado en la presente investigación, es la generación de ondas guiadas mediante de dispositivos piezoeléctricos comerciales.
- La ubicación de los sensores se limitó a donde mejor se obtuvieron las señales de sensado, variando frecuencia de excitación y en este estudio no se enfocará en buscar la ubicación óptima.
- La robustez de la propuesta se relacionó con la capacidad del sistema para detectar y localizar daños bajo condiciones variantes de temperatura.
- Con respecto a la detección que se encuentran algoritmos con alto desempeño, lo que se busca es mitigar la sensibilidad que estos presentan a la condición variable en el tiempo así como condiciones ambientales y operacionales a las que se someten.
- Para pruebas del algoritmo se realizaron registros continuos de 24 horas bajo condiciones de temperatura en ambiente de laboratorio.
- La arquitectura propuesta en esta investigación está enfocada a que sea funcional, robusta y permitió hacer una aplicación exploratoria de *Ensemble Learning*, a partir de recomendaciones generales de la metodología y otras obtenidas de la revisión bibliográfica, por tanto, no se asegura que sea la óptima.
- Los daños fueron de tipo agregación de masa, cortes/grietas, perforaciones, los cuales se consideraron de manera independiente.

El presente trabajo de investigación está organizado en 5 capítulos iniciando con una la introducción donde se presentan los objetivos, alcances, resultados generales y una marco motivacional de la temática de investigación para la detección y localización de daños en estructuras tipo lamina. En el segundo capítulo se incluye una revisión teórica con una breve definición de los métodos usados para el desarrollo de los algoritmos para detección y localización daños. La revisión cubre aspectos de monitorización de salud estructura, detección de daños usando modelos de linea base, métodos de representación reducida, índices estadísticos de daño y *Ensemble Learning*. En el tercer capítulo se presenta la metodología propuesta para la detección y localización de daños aplicando una arquitectura paralelo de *Ensemble Learning*. En este capítulo se describe el uso de índices estadísticos combinados para detección robusta de daños y una adaptación del método RAPID para la localización aprovechando las ventajas de piezodiagnosis en cuanto a diversidad de información. En el capítulo 3 se presentan detalles sobre el caso de estudio utilizado para validar el desempeño de la metodología desarrollada. En particular se presentan detalles del sistema de instrumentación, adquisición de datos y los escenarios con los respectivos casos de daño estudiados. En el capítulo 4 se presentan los resultados con el desempeño de la aplicación de la metodología para la detección y localización robusta. La metodología propuesta tiene la capacidad de detectar diferentes tipos de daño como agregación de masa, perforaciones y cortes, la robustez es evaluada analizando mediciones en diferentes condiciones de temperatura. Adicionalmente se demostró experimentalmente la capacidad de la metodología para localizar el daño considerando diferentes severidades del daño (diámetro de perforación). En el último capítulo se presentan las conclusiones recomendaciones y trabajos futuros.

1. Marco conceptual y estado del arte

1.1. MONITORIZACIÓN DE SALUD ESTRUCTURAL

La monitorización de Salud Estructural (SHM) cumple el propósito de brindar durante el tiempo de vida de la estructura, un diagnóstico del estado de los materiales que lo constituyen, de sus diferentes partes y del ensamblaje que integra la estructura como un todo ³. Además de lo anterior, busca por medio de diversas técnicas determinar el estado funcional de una estructura ⁴. El principal énfasis se encuentra en dos características:

- El uso de sensores para el registro de señales de una manera que se puedan realizar ensayos no destructivos (NDT), y se puedan convertir en una parte integral durante la operación y ciclo de vida de la estructura.
- Los métodos de reducción de datos y técnicas reversibles que permiten la identificación de parámetros físicos afectados por la presencia de los daños por lo cual se establece un diagnóstico.

SHM no está orientada por el tipo de aplicación ya que es una metodología, pero presenta amplias técnicas con las que se busca determinar el estado de una estructura. Dentro de estas se encuentran el análisis de vibración; análisis modal; análisis de ondas guiadas con el uso de sensores de fibra óptica; análisis acústico-

³ W. OSTACHOWICZ y col. "Damage localisation in plate-like structures based on PZT sensors". En: *Mechanical Systems and Signal Processing* 23.6 (2009), págs. 1805-1829.

⁴ C. PAGET y col. *Encyclopedia of Structural Health Monitoring, ch. Validation of SHM Sensors in Airbus A380 Full-Scale Fatigue Test*. 2009.

ultrasonido utilizando transductores piezoeléctricos entre otros ⁴⁵. En la siguiente sección se mostrará un enfoque de la detección de daños usando el principio de piezodiagnosis basado en SHM.

1.2. DETECCIÓN DE DAÑOS BASADO EN PIEZODIAGNOSIS

La piezodiagnosis se define como una técnica de SHM que se basa en el uso de señales eléctricas obtenidas al instrumentar una estructura con dispositivos piezoeléctricos PZT, aprovechando su dualidad actuador-sensor, siendo esta instrumentación la fuente de información para la extracción de características por medio de métodos estadísticos y posteriormente inferir un diagnóstico ⁵⁶⁷. La estudio de la piezodiagnosis se basa en dos conceptos principales: la piezoelectricidad y las ondas guiadas, los cuales se definen a continuación.

Piezoelectricidad y ondas guiadas en SHM

La piezoelectricidad o efecto piezoeléctrico es la aparición de un potencial eléctrico a través de algunas caras de un cristal cuando está bajo presión, y de distorsión cuando un campo eléctrico se aplica. Esto se explica por el desplazamiento de iones, causando la polarización eléctrica de los cristales de unidades estructurales ⁸. Cuando se aplica un campo eléctrico, los iones se desplazan por fuerzas elec-

⁵ G.S. MAVI y S. SHARMA. "FEASIBILITY OF USING ULTRASONIC GUIDED WAVES FOR UNDER WATER PIPE INSPECTION". Tesis doct. MED, TU, 2013.

⁶ S. S. KESSLER, S. M. SPEARING y C. SOUTIS. "Damage detection in composite materials using Lamb wave methods". En: *Smart Materials and Structures* 11.2 (2002), pág. 269.

⁷ M. L. WANG, J. P. LYNCH y H. SOHN. *Sensor Technologies for Civil Infrastructures: Sensing Hardware and Data Collection Methods for Performance Assessment*. Woodhead Publishing Series in Electronic and Optical Materials. Elsevier Science, 2014.

⁸ CERAMTEC.ES [Anónimo]. (2016). *Conceptos básicos de la tecnología piezocerámica*. [online] Available at:<http://www.ceramtec.es/materiales-ceramicos/piezoceramica/basicos/> .

trostáticas, lo que resulta en la deformación mecánica del cristal. Este efecto se produce naturalmente en los cristales de cuarzo, pero puede ser inducida en otros materiales, como los cerámicos que están compuestos principalmente de plomo, circonio, y titanio (PZT: zirconato-titanato de plomo $Pb(Ti,Zr)O_3$)⁹. Por tanto, los dispositivos piezoeléctricos son aquellos que se basan en cristales que presentan el efecto piezoeléctrico, estos dispositivos son usados como emisores y receptores de vibraciones mecánicas, convirtiendo energía eléctrica en acústica y viceversa¹⁰.

La importancia del uso de las ondas guiadas en la detección de daños es debido a que estas pueden viajar largas distancias dentro de los límites de la estructura a analizar, transmitiendo la onda con una leve atenuación y con una alta sensibilidad a pequeños defectos¹¹. Las ondas guiadas pueden ser transmitidas y generadas por elementos piezoeléctricos, donde por medio de PZT como actuador y otro PZT como sensor a cierta distancia se puede emitir y registrar una señal a una frecuencia específica, y así registrar las amplitudes de cada una de las mediciones en función del tiempo. Las mediciones son reflexiones y dispersiones que modifican la onda guiada las cuales son generados por alguna discontinuidad presente en la estructura⁵¹². De este modo la onda recolecta información de la estructura durante el recorrido entre el actuador y el sensor. Sin embargo, las ondas guiadas son muy sensibles a variaciones ambientales y operaciones en ocasiones llevando a produ-

⁹ JGVISUALSPLASH.COM. [Anónimo]. (2016). JG Visual Splash Available at:<http://jgvisualsplash.com/>.

¹⁰ PERU-V [Anónimo]., «Materiales piezoeléctricos,» [En línea]. Available: <http://www.ingenieria.peru-v.com>.

¹¹ K. SCHUBERT y col. "Analytical and Experimental Investigation of Environmental Influences on Lamb Wave Propagation and Damping Measured with a Piezo-Based System". En: *6th European Workshop on Structural Health Monitoring* 49 (2012), págs. 1-9.

¹² J. SHEN. "Non-destructive evaluation using guided waves in pipe-like structures". En: *Masters Abstracts International*. Vol. 51. 02. 2012.

cir falsas alarmas en un sistema de detección de daños. Esto se puede evidenciar por medio de las ecuaciones de velocidad de viaje de las ondas ya que dependen de las características del medio de propagación, y pueden cambiar en función de condiciones como la temperatura ¹³.

Una de las principales características de las ondas guiadas es que son multi-modales y dispersivas ¹⁴¹⁵, lo que dificulta la tarea de obtener información acerca del daño presente en una estructura a partir de las señales adquiridas. El significado de que una onda guiada es multi-modal es que cuando se excita una estructura con una señal en un rango de frecuencias determinadas, se activan diferentes modos de onda a diferentes velocidades de propagación. El significado de que una onda guiada es dispersiva es que para el mismo modo de onda, la velocidad varía con la frecuencia ¹⁶.

Efecto de la temperatura sobre las ondas guiadas: Las ondas guiadas son sensibles a los cambios de temperatura provocando cambios en las señales adquiridas. Los cambios de temperatura afectan las propiedades mecánicas del material en que las ondas guiadas se propagan, produciendo cambios en las señales recibidas por los sensores. Este efecto complica el análisis y enmascara la información relacionada con el defecto presente en la estructura. ¹⁷.

¹³ L. E. MUJICA y col. "Multivariate statistics process control for dimensionality reduction in structural assessment". En: *Mechanical Systems and Signal Processing* 22.1 (2008), págs. 155-171.

¹⁴ N. GANDHI. "Determination of dispersion curves for acoustoelastic Lamb wave propagation". Tesis doct. Georgia Institute of Technology, 2010.

¹⁵ B. M. LEMPRIERE. *Ultrasound and elastic waves: frequently asked questions*. Elsevier, 2003.

¹⁶ J. L. ROSE. *Ultrasonic waves in solid media*. 2000.

¹⁷ Y. LU y J. E. MICHAELS. "A methodology for structural health monitoring with diffuse ultrasonic waves in the presence of temperature variations". En: *Ultrasonics* 43.9 (2005), págs. 717-731.

Son dos los efectos esperados por la temperatura sobre la onda guiada. El primer efecto es el cambio en la distancia de propagación entre el actuador y el sensor debido a la deformación térmica del material ¹⁸. La relación entre la deformación lineal del material y la temperatura viene dada por la ecuación:

$$L_f = L_i(1 + \alpha * \Delta T) \quad (1)$$

donde L_f y L_i son las longitudes final e inicial del material, ΔT es el cambio de temperatura y α es el coeficiente de dilatación o expansión térmica, que para el aluminio, que es el material de la estructura que se está estudiando, es de $2,4 \times 10^{-5} \text{ } ^\circ\text{C}^{-1}$. El segundo efecto es el cambio de velocidad en la onda guiada. Wilcox et al ¹⁹ expresan la relación entre el tiempo de llegada de la onda y el cambio de temperatura en el material en función de la velocidad de la onda y la distancia recorrida:

$$\Delta t = \frac{d}{v} - \alpha - \frac{k}{v} \Delta T \quad (2)$$

donde t es el tiempo de llegada de la onda, d es la distancia recorrida por la onda, v es la velocidad de la onda y $k = \Delta v / \Delta T$. Ambos efectos resultan en un cambio en el tiempo de llegada de la onda al sensor, lo cual significa un desfase entre las ondas sensadas a diferentes temperaturas.

Debido a la complejidad presente, son ampliamente usados modelos de línea base utilizando descriptores estadísticos que permitan compararlo con la información estadística recurrente de la estructura y así determinar el estado en que se encuentra.

¹⁸ R. A. SERWAY y J. W. JEWETT. *Principles of physics: a calculus-based text*. Vol. 1. Nelson Education, 2012.

¹⁹ A. J. CROXFORD y col. "Strategies for guided-wave structural health monitoring". En: *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 463.2087 (2007), págs. 2961-2981.

1.3. ALGORITMOS DE DIAGNÓSTICO

En las últimas décadas, los cambios en la respuesta de vibración han sido ampliamente utilizados para la identificación de daños y vigilancia de la salud estructural. La principal premisa de los métodos de detección bajo el principio de vibraciones, es que la presencia de un daño altera las propiedades de rigidez, masa, y energía de dispersión, causando cambios en la dinámica de la estructura. No obstante, la detección mediante el análisis de vibración presenta baja sensibilidad a daños, ya que requiere daños de grandes magnitudes para que se vean reflejados en las señales sensadas.

En contraste con los algoritmos para identificación de daños basados en vibración, las metodologías para la detección y localización mediante el uso de ondas guiadas presentan mayor sensibilidad a pequeños daños. El principio se basa en el hecho que el viaje de una onda con características previamente definidas, es afectado por defectos presentes en la estructura. De esta manera, la información del defecto caracterizado por las dispersiones y reflexiones en el viaje de la onda guiada permite una mejor identificación. Esto se debe a que la mayor flexibilidad en configuración de parámetros como frecuencia de análisis y modo de operación, entre otros; generan mayor sensibilidad a pequeños daños. Otra ventaja relacionada con las ondas guiadas, es la practicidad de para su generación y sensado por medio de dispositivos piezoeléctricos, de bajo costo y fácil acceso.

Lo anterior muestra por qué las ondas guiadas son usadas como método de diagnóstico. Sin embargo, es necesario definir procedimientos para realizar el análisis de información proveniente de los sensores. Así, se identifican dos tendencias: basados en modelo de datos o modelos de simulación. Los algoritmos de diagnóstico basados en modelos de simulación, utilizan representaciones matemáticas formuladas

por ejemplo mediante técnicas de elementos finitos. Dicha representación permite estudiar condiciones de daño respecto a un estado sano. Sin embargo, requieren alto costo computacional y tienen limitaciones respecto a la manera como se simulan las condiciones de daño. Por otra parte, los enfoques basados en modelos de línea base utilizan información proveniente de las mediciones para representar las diferentes condiciones de la estructura. Por ejemplo, en ¹³ se muestra un enfoque basado en señales para caracterizar la estructura en el estado nominal y crear un modelo de línea base. Ésta aproximación permite diagnosticar el estado actual de la estructura comparando las señales en tiempos diferentes y determinar si se presentó o no un defecto.

En general, existe una gran cantidad de trabajos que estudian los algoritmos de diagnóstico; en ²⁰ se describe una metodología para creación de modelos de diagnóstico usando información de la velocidad de la señal; así, por medio del tiempo de viaje de la señal es posible determinar si existe un defecto en la estructura. En ²¹ utilizan un índice espectral de daño extraído de la información espectral. Así, de los armónicos fundamentales y correspondientes a las frecuencias más altas, se detecta la de-laminación en una lámina de material compuesto. Otras aplicaciones consisten en el análisis estadístico de las señales mediante técnicas como análisis de componentes principales ²² y análisis de componentes independientes ²³ como

²⁰ P. CAWLEY y D. ALLEYNE. "The use of Lamb waves for the long range inspection of large structures". En: *Ultrasonics* 34.2-5 (1996), págs. 287-290.

²¹ N. P. YELVE M. MITRA y P.M. MUJUMDAR. "Detection of delamination in composite laminates using Lamb wave based nonlinear method". En: *Composite Structures* 159 (2016), págs. 257-266.

²² D. TIBADUIZA. "Combined and I indices based on principal component analysis for damage detection and localization". En: (2012).

²³ Y. YANG y S. NAGARAJAIAH. "Blind identification of damage in time-varying systems using independent component analysis with wavelet transform". En: *Mechanical Systems and Signal Pro-*

herramientas para el reconocimiento de patrones y detección de daños en estructuras.

Por otra parte, para realizar una estimación de la localización se han desarrollado avances como ²²²⁴ que por medio del análisis de la información y aportes de los sensores obtiene una estimación de la posición; en ²⁵ por medio de la transformada de Hilbert se obtiene la envolvente de la señal y un procesamiento estadístico para dar una estimación de la posición de donde está el defecto; en ²⁶ mediante la velocidad de viaje de las ondas, una medida de la ubicación de los sensores, y la generación de una imagen con un índice estadístico se obtiene un mapa de la lámina y los posibles defectos presentes en ella.

1.4. DETECCIÓN DE DAÑOS USANDO MODELOS DE LINEA BASE

Los modelos de línea base buscan agrupar o extraer la mayor cantidad de información de un conjunto de datos reduciendo sus dimensiones, esto con el fin de volver el problema de comparación computacionalmente tratable, los modelos de línea base almacenan las principales características de un conjunto de datos, en la detección de daños basada en ondas guiadas se usa ya que se utilizan redes de sensores para la adquisición de datos, por lo cual las dimensiones de los datos almacenados

cessing 47.1-2 (2014), págs. 3-20.

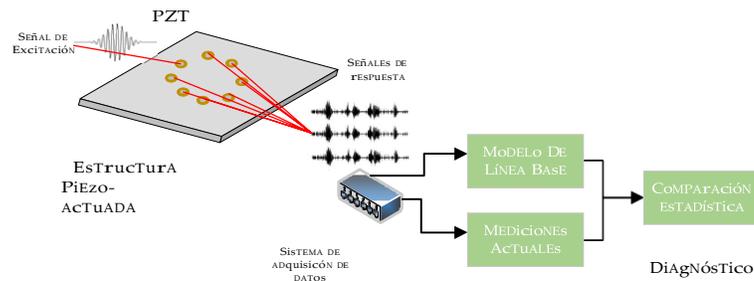
²⁴ L. E. MUJICA, D. A. TIBADUIZA y B. J. RODELLAR. "Data-driven multiactuator piezoelectric system for structural damage localization". En: *Fifth World Conference on Structural Control and Monitoring (5WCSCM): Tokyo, Japan: 12-14 July 2010*. 2010.

²⁵ G. LIU y col. "Baseline Signal Reconstruction for Temperature Compensation in Lamb Wave-Based Damage Detection". En: *Sensors* 16.8 (2016), pág. 1273.

²⁶ J. E. MICHAELS y T. E. MICHAELS. "Guided wave signal processing and image fusion for in situ damage localization in plates". En: *Wave Motion* 44.6 (2007), págs. 482-492.

suelen ser muy grandes, la reducción de las dimensiones es de gran importancia a la hora de la implementación de métodos de detección de daños en tiempo real o en línea.²⁷

Figura 1. Modelo de línea base



El principal objetivo de los modelos de línea base es re-organizar la información de tal forma que permite reducir el número de variables manteniendo la mayor información posible. En la figura 1 se puede observar la que partir de los datos provenientes de la estructura sin daños se crea un modelo en el cual se representa la información contenida en los datos pero en una dimensión menor que la original, esto con el fin de obtener una la mayor cantidad de características o descriptores que permitan comparar con datos recurrentes de provenientes de los sensores y dar un diagnóstico de la estructura a lo largo del tiempo. Sin embargo, es importante resaltar que para poder emitir un diagnóstico de la estructura es necesario contar con información de la estructura en estado nominal o previa al fallo. Lo cual requiere el almacenamiento periódico de la estructura para actualizar el estado nominal esto generan grandes volúmenes de información, esta característica puede ser optimiza-

²⁷ G. MUSTAFA y N. F. CATBAS. "Statistical pattern recognition for Structural Health Monitoring using time series modeling: Theory and experimental verifications". En: *Mechanical Systems and Signal Processing* 23.7 (2009), págs. 2192 -2204.

da mediante técnicas de extracción de características o compresión de datos como el análisis de componentes principales.

1.5. MÉTODOS DE REPRESENTACIÓN REDUCIDA

1.5.1. Modelo de línea base lineales.

Modelo de línea base usando Análisis de Componentes Principales (PCA). El objetivo de PCA es detectar información redundante, re-organizarla de tal forma que sea fácil de interpretar, y reducir el número de variables manteniendo la mayor cantidad de información posible, como se ilustra en la figura 2. Donde $X_{n \times m}$ es la matriz de casos de dimensiones $n \times m$, n es el número de variables y m es el número de experimentos, ϕ es la matriz de transformación y Z es la matriz de datos proyectados.

Por otra parte, PCA provee una forma simple de enfatizar relaciones entre patrones, describiendo cambios de los elementos en una matriz de datos por medio de una relación lineal expresada de la siguiente forma

$$\hat{X} = Z\phi^T + E \quad (3)$$

Donde:

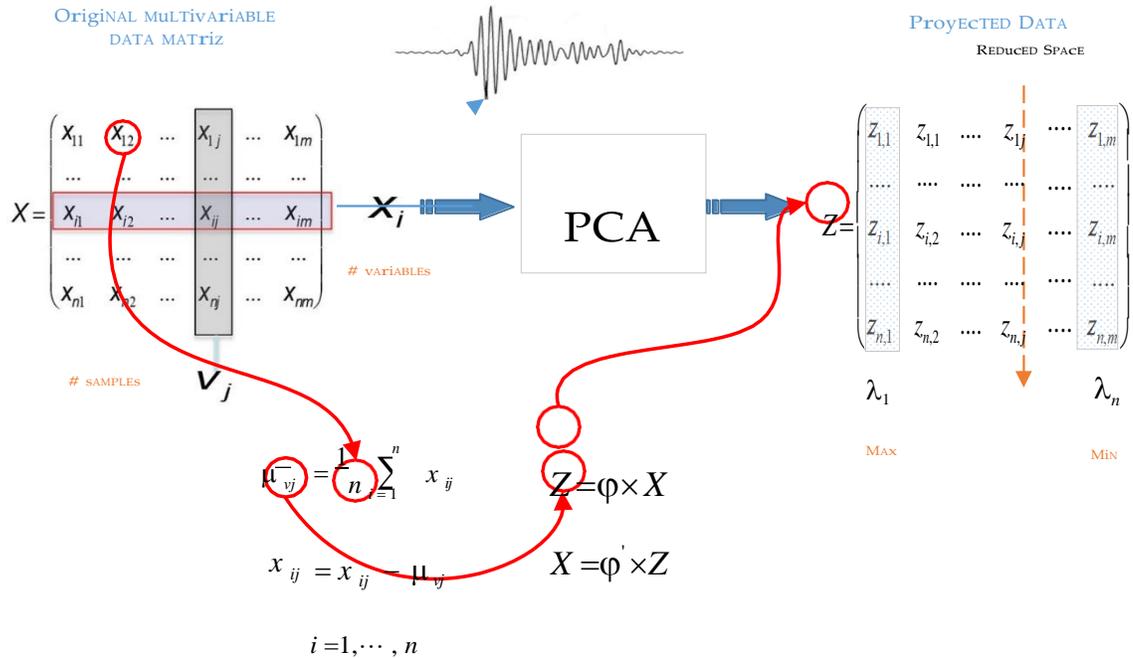
$$\hat{X} = \text{Matriz de datos recuperados}$$

$$Z = \text{Matriz de datos proyectados}$$

$$E = \text{Matriz de residuo}$$

La representación de PCA puede ser interpretada como un modelo usado para extraer características dominantes de datos experimentales. De esta forma el modelo $Z\phi^T$ corresponde a un nuevo espacio de coordenadas reducido con mínima redun-

Figura 2. Modelo de linea base usando PCA



dancia, basado en la covarianza de los datos originales. ϕ es una matriz de transformación lineal que relaciona la matriz de datos X con las nuevas coordenadas. ϕ corresponde a los componentes principales y Z a los datos proyectados en el espacio reducido. La matriz de ruido E describe la varianza residual no considerada en el modelo estadístico.

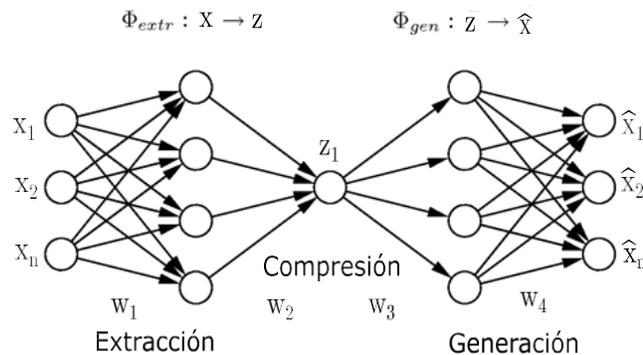
1.5.2. Modelos de linea base no lineales.

Modelo de linea base usando *autoencoders* o autocodificadores. Un auto-codificador es una red neuronal que está entrenada para replicar su entrada en su salida. Los autocodificadores se pueden utilizar como herramientas para aprender redes neuronales profundas. La capacitación de un autocodificador no está supervi-

sada en el sentido de que no se necesitan datos etiquetados. El proceso de capaci-

tación aún se basa en la optimización de una función de costo. La función de costo mide el error entre la entrada x y su reconstrucción en la salida \hat{x} .

Figura 3. Autocodificadores



Fuente: 28.

En la figura 3 se muestra un esquema general de un autocodificador como se puede observar se divide en 2 funciones principales la primera es $\Phi_{extr} : x \rightarrow z$ que representa la función de extracción y la segunda $\Phi_{gen} : z \rightarrow \hat{x}$ que representa la función de generación o reconstrucción, Una capa oculta en cada parte permite la red para realizar funciones de mapeo no lineal.

Es así como los autocodificadores permiten representar un conjunto y extraer las características principales, por lo cual es de gran utilidad en el caso de la detección de daños en estructuras.

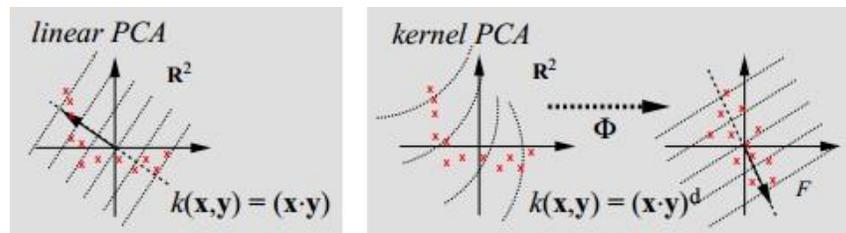
Para el entrenamiento del modelo de linea base usando un autocodificador se utiliza un conjunto de datos sin daños de la estructura, este conjunto de datos permite ajustar los valores de los pesos de cada una de las neuronas en el autocodificador ajustando este modelo para que sea capaz de reconstruir las señales de este

²⁸ M. SCHOLZ. "Validation of nonlinear PCA". En: *Neural processing letters* 36.1 (2012), págs. 21-30.

conjunto con el mínimo error posible.²⁸

Modelo de línea base usando Kernel (*Kernel PCA*). El análisis de componentes principales usando *kernel* (*kernel PCA*) es una extensión no lineal de PCA. En este caso se busca obtener una representación reducida en un espacio de mayor dimensión por medio de un *kernel*, el cual permite obtener características no lineales de los datos²⁹. En la figura 4 se describen los efectos del uso de las funciones *kernel* como método de extracción de características.

Figura 4. Kernel PCA



Fuente: 29.

Kernel PCA extiende PCA estándar a distribuciones de datos no lineales. Asumimos una distribución formada por n puntos de datos. $x_i \in \mathbb{R}$. Antes de realizar análisis de componentes principales (PCA), estos puntos de datos se asignan a un espacio de características de mayor dimensión F .

$$x_i \rightarrow \Phi(x_i) \tag{4}$$

En este espacio, se realiza PCA estándar. El truco aquí es que el PCA se puede cal-

²⁹ B. SCHÖLKOPF, A. SMOLA y K. R. MÜLLER. "Nonlinear component analysis as a kernel eigenvalue problem". En: *Neural computation* 10.5 (1998), págs. 1299-1319.

cular de tal manera que los vectores $\Phi(x_i)$ aparecen solo dentro de productos escalares. Por lo tanto, el mapeo de la Eq.4 se puede omitir. En su lugar, solo trabajamos con una función del *kernel* $k(x, y)$, que sustituye al producto escalar $(\Phi(x) \cdot \Phi(y))$ en el *kernel* PCA, un vector propio V de la matriz de covarianza en F es una combinación lineal de puntos $\Phi(x_i)$,

$$V = \sum_{i=1}^n \alpha_i \tilde{\Phi}(x_i) \quad (5)$$

con

$$\tilde{\Phi}(x_i) = \Phi(x_i) - \frac{1}{n} \sum_{r=1}^n \Phi(x_r) \quad (6)$$

Los vectores $\tilde{\Phi}(x_i)$ Se eligen de tal manera que se centren en torno al origen en F los α_i son los componentes de un vector α . Este vector es un vector propio de la matriz $\tilde{K}_{ij} = (\tilde{\Phi}(x_i) \cdot \tilde{\Phi}(x_j))$. la longitud de α se elige tal que los componentes principales de V tengan la longitud de uno: $\|V\| = 1 \Leftrightarrow \|\alpha\|^2 = 1/\lambda$, con λ siendo el valor propio de \tilde{K} correspondiente a α . Para calcular \tilde{K} , sustituimos $\tilde{\Phi}$ de acuerdo a la eq. 6. Esta sustitución da \tilde{K}_{ij} en función de la matriz del núcleo $\tilde{K}_{ij} = k(x_i, x_j)$:

$$\tilde{K}_{ij} = K_{ij} - \frac{1}{n} \sum_{r=1}^n K_{ir} - \frac{1}{n} \sum_{r=1}^n K_{rj} + \frac{1}{n^2} \sum_{r,s=1}^n K_{rs} \quad (7)$$

La ventaja de implementar funciones del núcleo es su capacidad para convertir las no linealidades en posibles linealidades sin conocer a priori la función de transformación. Comúnmente se utiliza un *kernel* gaussiano ver Eq.8 para problemas de extracción de características.

$$k(x, y) = \exp \left(-\frac{\|x - y\|^2}{2\sigma^2} \right) \quad (8)$$

Como característica para la detección de novedades se utiliza el error de recons-

trucción en el espacio de características, mas adelante se muestra el cálculo del error de reconstrucción como índice para la detección de daños sin necesidad de realizar una reconstrucción ³⁰ de los datos proyectados en el nuevo espacio F .

1.6. ÍNDICES ESTADÍSTICOS PARA LA DETECCIÓN DE DAÑOS

Los índices estadísticos permiten obtener una medida de diferencia entre el conjunto de datos que representa el estado nominal o sin daños y una medida durante su operación, esto con el fin de determinar que tan diferentes son las señales medidas a las que se registraron durante el estado nominal y así determinar si existe una anomalía o daño en la estructura. A continuación se describen los índices utilizados para la detección de daños:

Índice estadístico Q. El índice estadístico Q también conocido como el error de predicción cuadrático (*SPE- squared prediction error*) permite calcular la diferencia entre la reconstrucción de la proyección de un dato sobre el modelo de línea base, con lo cual se puede determinar si existe un daño o no en la estructura.

Usado para comparar los residuos de los nuevos datos experimentales utilizando como punto de comparación un conjunto de residuos de datos tomados bajo condiciones de operación normal ³¹. Este índice se define bajo la ecuación 9, la cual representa la suma de los cuadrados de la distancia de $(x - \hat{x})$ para el espacio

³⁰ H. HOFFMANN. "Kernel PCA for novelty detection". En: *Pattern recognition* 40.3 (2007), págs. 863-874.

³¹ J. A. WESTERHUIS, S. P. GURDEN y A. K. SMILDE. "Standardized Q-statistic for improved sensitivity in the monitoring of residuals in MSPC". En: *Journal of Chemometrics* 14.4 (2000), págs. 335-349.

k-dimensional que el modelo PCA define ³².

$$Q = (x - \hat{x})'(x - \hat{x}) \quad (9)$$

x representa la señal proveniente del sensor y \hat{x} representa la señal reconstruida después de ser proyectada sobre el modelo de línea base.

Índice usando distancia entre señales utilizando la distorsión dinámica del tiempo (dist). Dos señales con características equivalentes dispuestas en el mismo orden pueden parecer muy diferentes debido a las diferencias en la duración de sus secciones. La distorsión dinámica del tiempo (DWT) distorsiona estas duraciones, de modo que las características correspondientes aparecen en la misma ubicación en un eje de tiempo común, resaltando las similitudes entre las señales ³³. Con esta característica se busca evitar los cambios producidos por los desfases de las señales cuando hay cambios de temperatura en la estructura. Después de realizada la distorsión dinámica en tiempo se calcula la diferencia absoluta o distancia de Manhatam entre las señales x representa la señal proveniente del sensor y \hat{x} representa la señal reconstruida después de ser proyectada sobre el modelo de línea base.

$$dist(x, \hat{x}) = \sum_{i=1}^N \sqrt{\frac{(x[i] - dtw(x, \hat{x}[i]))^2}{N}} \quad (10)$$

³² J. E. JACKSON. "PCA with more than two variables". En: *User's Guide to Principal Component Analysis* (1991), págs. 26-62.

³³ K.K. PALIWAL, A. AGARWAL y S. S. SARVAJIT. "A modification over Sakoe and Chiba's dynamic time warping algorithm for isolated word recognition". En: *Signal Processing* 4.4 (1982), págs. 329-333.

Índice de distancia de edición entre señales (EDR). Calcula la distancia de edición para secuencias reales entre un par de series de tiempo numéricas, calcula la distancia de edición básica para secuencias reales entre dos series numéricas. La idea es contar el número de operaciones de edición (insertar, eliminar, reemplazar) que son necesarias para transformar una serie en la otra, de igual manera calculando la diferencia entre la señal sensada y la proyectada sobre el modelo base se calcula la cantidad de operaciones necesarias para que las señales sean iguales, señales con características equivalentes dispuestas en el mismo orden pueden parecer muy diferentes debido a las diferencias en la duración de sus secciones. La Distancia de edición entre señales distorsiona estas duraciones para que las características correspondientes aparezcan en la misma ubicación en un eje de tiempo común, resaltando así las similitudes entre las señales. El criterio utilizado para realizar la distorsión está diseñado para ser robusto a los valores atípicos. Por tanto este índice permite identificar cuando hay un daño en la estructura.³⁴

La penalización por hacer coincidir dos muestras es independiente de la diferencia de valor entre las muestras. Dos muestras que difieren un poco más que la tolerancia incurrir en la misma penalización que dos muestras que son marcadamente diferentes. Por esa razón, la distancia de edición no se ve afectada por los valores atípicos. Por el contrario, la repetición de muestras para alinear dos señales tiene un costo, que no es el caso de la distorsión de tiempo dinámico.

1.7. LOCALIZACIÓN DE DAÑOS PARA LA MONITORIZACIÓN DE SALUD ESTRUCTURAL

Según el estado del arte, la implementación de algoritmos de monitorización de daños en estructuras implica lograr capacidades para detección, localización y cuanti-

³⁴ L. CHEN, M. TAMER y V. ORIA. "Robust and Fast Similarity Search for Moving Object Trajectories". En: *Proceedings of the 2005 ACM SIGMOD International Conference on Management of Data*. SIGMOD '05. Baltimore, Maryland: ACM, 2005, págs. 491-502.

ficación del daño. Varias aproximaciones han sido reportadas en la literatura como exitosas respecto a la detección, siendo necesario el estudio de metodologías robustas para localización que permitan una estimación aproximada de la ubicación del daño, y que pueda ser generalizada a diferentes estructuras con bajos errores, facilidad de adaptación y uso; así como tolerancia a ruido.

La localización de daños en estructuras puede ser lograda mediante el uso de algoritmos de interpretación de datos basados en el análisis de mediciones experimentales; aprovechando información relacionada con la posición de los sensores y la magnitud de la respuesta ante un daño y parámetros relevantes como el tiempo de vuelo (ToF)³⁵. En esta sección, se presenta un algoritmo para localización de daños que integra la respuesta de una red de dispositivos piezoeléctricos ubicados en la superficie de la estructura. De esta manera, la localización del daño se estima mediante la combinación probabilística de diagnósticos obtenidos a partir de cada uno de los pares de sensores pertenecientes a la red de sensores. En particular, una versión modificada del algoritmo de reconstrucción probabilística de inspección de daños es usada en combinación con piezo-diagnos. Así, la arquitectura propuesta emplea una red de dispositivos piezoeléctricos configurada en un esquema de multi-actuación. La localización del daño se estima a través de las contribuciones de cada par de sensores en el respectivo modelo de línea base. Un ensamblaje de modelos de línea base obtenidos de diferentes combinaciones de parejas de sensores es usado para mejorar la probabilidad de la localización del daño.

³⁵ R. M. LEVINE y J. E. MICHAELS. "Model-based imaging of damage with Lamb waves via sparse reconstruction". En: *The Journal of the Acoustical Society of America* 133.3 (2013), págs. 1525-1534.

1.7.1. Estado del Arte. En los últimos años, diferentes técnicas de localización de daños han sido propuestas con diferentes grados de precisión de acuerdo a su complejidad y requerimientos. En esta sección se presenta una breve revisión de algoritmos propuestos para localización de daños en estructuras bajo el principio de ondas guiadas generadas por medio de dispositivos piezoeléctricos debido a sus atractivas ventajas como la alta sensibilidad al daño y el amplio rango de monitorización ³⁶³⁷. Por ejemplo, en ³⁸ se muestra la factibilidad del uso de una red de sensores PZT para estimar la posición de daños estructurales, en ³⁹ presenta el uso de señales envolventes para estimar la velocidad de grupo y el tiempo de vuelo, con las cuales infieren la localización de daños tipo grieta y agujeros. Asimismo, en ⁴⁰ se describe la implementación de un método de reconstrucción de imágenes a partir del tiempo de vuelo de ondas guiadas para localización de daños en una estructura laminar. En particular, los algoritmos de diagnóstico por imagen de daños se han estudiado cada vez más debido a que el resultado corresponde a una imagen interpretable e intuitiva que refleja la ubicación del daño a un alto costo computacional

³⁶ Z. LIU y H. CHEN. "Application and Challenges of Signal Processing Techniques for Lamb Waves Structural Integrity Evaluation: Part B-Defects Imaging and Recognition Techniques". En: *Structural Health Monitoring from Sensing to Processing* September (2018).

³⁷ Z. LIU y col. "Baseline-free delamination inspection in composite plates by synthesizing non-contact air-coupled Lamb wave scan method and virtual time reversal algorithm". En: *Smart Materials and Structures* 24.4 (2015), pág. 045014.

³⁸ Z. TIAN. "Guided Wave Based Integrated Structural Health Monitoring and Nondestructive Evaluation". En: (2015).

³⁹ M. SALMANPOUR, Z. S. KHODAEI y M. H. ALIABADI. "Guided wave temperature correction methods in structural health monitoring". En: (2016), págs. 1-15.

⁴⁰ A. EBRAHIMKHANLOU, B DUBUC y S. SALAMONE. "Damage localization in metallic plate structures using edge-reflected lamb waves". En: *Smart Materials and Structures* 25.8 (2016).

²⁵. Por ejemplo, en ⁴¹ se presenta un enfoque de matrices de fase donde se utilizan cuatro matrices de transductores para realizar un procedimiento de formación de haz y estimar la imagen de daño con la respectiva localización; en ⁴²⁴³ se describe el uso de técnicas de proyección de haz en abanico paralelo y reconstrucción algebraica (ART) de tomografía con orificio transversal para detectar y localizar fallas en materiales de aviones de varias capas. En ⁴⁴ se describe un algoritmo de retraso y suma basado en el tiempo de vuelo TOF para localizar daños en estructuras.

Por otra parte, los métodos basados en probabilidad como el algoritmo de reconstrucción probabilística RAPID (Reconstruction Algorithm for Probabilistic Inspection of Damage) ⁴⁵⁴⁶⁴⁷ aprovechan la información proveniente de un arreglo de sensores, para triangular y determinar la localización del daño usando métodos de diagnóstico

⁴¹ P. MALINOWSKI y col. "A phased array-based method for damage detection and localization in thin plates". En: *Structural Health Monitoring* 8.1 (2009), págs. 5-15.

⁴² J. C. MCKEON y M. K. HINDERS. "Parallel projection and crosshole Lamb wave contact scanning tomography". En: *The Journal of the Acoustical Society of America* 106.5 (1999), págs. 2568-2577.

⁴³ E. V. MALYARENKO y M.K. HINDERS. "Fan beam and double crosshole Lamb wave tomography for mapping flaws in aging aircraft structures". En: *The Journal of the Acoustical Society of America* 108.4 (2000), págs. 1631-1639.

⁴⁴ G. LU y col. "A multi-delay-and-sum imaging algorithm for damage detection using piezoceramic transducers". En: *Journal of Intelligent Material Systems and Structures* 28 (sep. de 2016).

⁴⁵ Z. S. KHODAEI y M. H. ALIABADI. "Assessment of delay-and-sum algorithms for damage detection in aluminium and composite plates". En: *Smart Materials and Structures* 23.7 (2014), pág. 75007.

⁴⁶ J. E. MICHAELS, A. J. CROXFORD y P.D. WILCOX. "Imaging Algorithms for Locating Damage via in Situ Ultrasonic Sensors". En: *Proc. of IEEE Sensors Applications Sym.* 3 (2008), págs. 63-67.

⁴⁷ M. SALMANPOUR, Z. SHARIF y M. ALIABADI. "Guided wave temperature correction methods in structural health monitoring". En: *Journal of Intelligent Material Systems and Structures* (2016), págs. 1-15.

por imágenes basados en probabilidad (PDI). Estos métodos tienen la ventaja de brindar información de la localización de daños espaciales proporcionada por las rutas del actuador-sensor para reconstruir la imagen del daño. Se basan en que la probabilidad de que ocurra un defecto en un cierto punto puede reconstruirse a partir de la gravedad del cambio de la señal y su posición relativa al par de sensores. En los algoritmos de reconstrucción probabilística (ARP) se analiza los aportes de todas las respuestas, lo que incluye el ToF, las formas de onda y la energía, permitiendo lograr una buena calidad de reconstrucción a alta velocidad.

1.7.2. Metodología para localización de daños en estructuras basada en piezo-diagnos y reconstrucción probabilística. En este trabajo de investigación se propone una adaptación del método RAPID para estimar la localización de daños en estructuras. Así, es posible aprovechar la información proveniente de los índices estadísticos utilizados para la detección de daños y la información espacial del arreglo de piezoeléctricos para obtener la respectiva localización del daño.

En el algoritmo RAPID ⁴⁸ usa el coeficiente de correlación definido en la ecuación 11 para la detección de defectos:

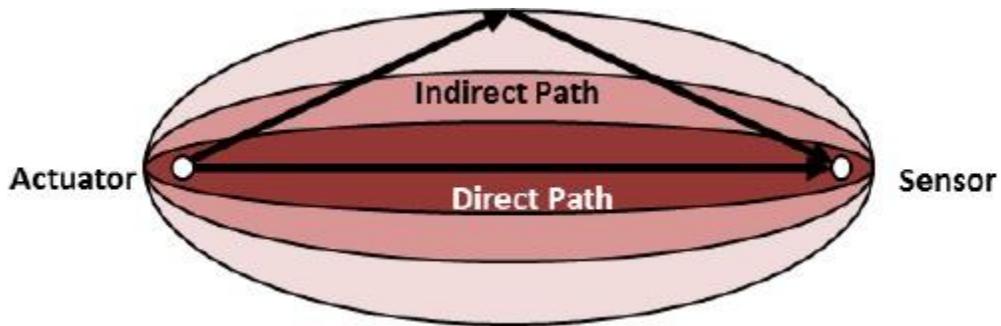
$$\rho = \frac{C_{AB}}{\rho_A \rho_B} \quad (11)$$

Donde C_{AB} es la coarianza entre el conjunto de datos que representa la condición sin daño (A) y nuevas mediciones con posible daño (B), ρ_A y ρ_B corresponden a la desviación estándar del conjunto de datos A y B respectivamente. Para estimar la ubicación del daño, la probabilidad de distribución de defectos se estima mediante

⁴⁸ G. ZHAO y col. "Active health monitoring of an aircraft wing with embedded piezoelectric sensor/actuator network: I. Defect detection, localization and growth monitoring". En: *Smart Materials and Structures* 16 (jun. de 2007), pág. 1208.

una suma lineal de los coeficientes de correlación de todos los pares actuador-sensor instalados en la superficie de la estructura. En el algoritmo RAPID se asume que la distribución espacial debe ser linealmente decreciente siguiendo una distribución elíptica como se muestra en la figura 5.

Figura 5. Función de distribución elíptica de la probabilidad de localización del defecto.



Fuente: 48.

De acuerdo con la figura 5, cuando ocurre un defecto, las señales del sensor en la ruta directa e indirecta se verán afectadas por una distribución elíptica. Asimismo, la probabilidad de distribución tendrá mayor amplitud en la localización del defecto (en comparación con otros puntos) según el coeficiente de correlación. La distribución espacial elíptica $S_{ij}(x, y)$ está definida por la ecuación 12:

$$S_{ij}(x, y) = \frac{(\beta - R_{ij}(x, y))}{(1 - \beta)}, \quad \text{for } \beta > R_{ij}(x, y) \quad (12)$$

$$S_{ij}(x, y) = 0 \quad \text{otherwise, where} \quad (13)$$

$$R_{ij}(x, y) = \frac{\sqrt{(x_i - x)^2 + (y_i - y)^2} + \sqrt{(x_j - x)^2 + (y_j - y)^2}}{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (14)$$

donde x e y definen cada posición de coordenadas en el plano 2D, limitada por las dimensiones de la estructura; y β es un parámetro de escala para controlar el tamaño de la función de distribución elíptica. x_i, x_j, y_i, y_j corresponden a las ubicaciones de cada par actuador-sensor.

En este trabajo de investigación se propone una versión adaptada del algoritmo RAPID en combinación con piezodiagnos y análisis de componentes principales como un enfoque para localizar daños estructurales. Así, en lugar del coeficiente de correlación, se sugiere el uso del índice Q normalizado obtenido para cada par de actuador-sensor. La normalización se calcula teniendo en cuenta el máximo valor de Q calculado a partir del modelo de línea de base para cada actuador Q_{ij} . Por lo tanto, la probabilidad de distribución de defectos $E_{ij}(x, y)$ para cada par de actuador-sensor se define por la ecuación 15:

$$E_{ij}(x, y) = \sum_{i=1}^N \sum_{j=i+1}^N Q_{ij} S_{ji}(x, y) \quad (15)$$

La ubicación del daño se estima aplicando el operador de suma de imágenes como técnica de procesamiento para combinar todas las contribuciones del índice Q . Así, para determinar la posición del daño en la estructura, se combinan las contribuciones de cada transductor en la red de sensores a cada índice de daño. Es importante señalar que el procedimiento de localización se aplica después de la etapa de detección de daños, cuando el índice de daños excede un umbral predefinido.

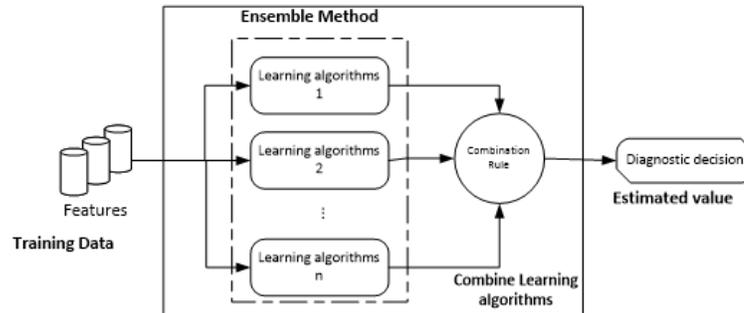
1.8. ENSEMBLE LEARNING PARA EL DISEÑO DE SISTEMAS EXPERTOS Y MONITORIZACIÓN DE DAÑOS

Los algoritmos utilizados comúnmente para la monitorización de daños en estructuras presentan inconvenientes relacionados con el manejo de datos no balanceados para las diferentes condiciones de daño (clases/tipo), los requisitos de entrenamiento óptimos, la baja capacidad para gestionar la diversidad de características y la baja tolerancia a errores; lo que se traduce en una alta probabilidad de diagnóstico erróneo. Asimismo, en la literatura se han reportado trabajos que describen diferentes algoritmos de diversa naturaleza que permiten solucionar el problema de identificación de daño con diferentes grados de precisión; dificultando su implementación debido a la falta de criterios unificados para selección de algoritmos, óptima selección de parámetros y la diversidad de las fuentes de información. En este sentido, se requiere la implementación de estrategias que permitan la integración de técnicas individuales para aprovechar sus ventajas y obtener un sistema de diagnóstico eficiente y robusto. En este capítulo se describe el paradigma de *Ensemble Learning* como alternativa de integración de algoritmos y fuentes de información (data fusión) para aumentar el rendimiento de un sistema experto de detección y localización de daños en estructuras. Así, mediante *Ensemble Learning*, es posible obtener un diagnóstico más robusto mediante la combinación de respuestas individuales lo que permite mejorar la probabilidad de detección y localización de daño.

1.8.1. Componentes claves de un sistema *Ensemble Learning*. En la figura 6 se muestra el esquema de un sistema experto basado en *Ensemble Learning*.

Los principales componentes de *Ensemble Learning* corresponden a múltiples algoritmos organizados en un esquema de combinación (regla de combinación). Así, las características del espacio de entrada son procesadas y manipuladas con los mé-

Figura 6. Sistema experto basado en *Ensemble Learning*



todos seleccionados para construir el *Ensemble* y obtener un diagnóstico final. En general, la respuesta final del *Ensemble* (predicción) es obtenida mediante el promedio de las predicciones de cada sub-modelo, o producida mediante la aplicación de métodos de votación o promedios ponderados como se detalla en la ecuación 6 4950:

$$f_{ens}(x) = \sum_{i=1}^M w_i \hat{f}_i(x) \quad (16)$$

En la ecuación 16, la predicción del *Ensemble* $f_{ens}(x)$ es obtenida a partir de las respuestas \hat{f}_i de los M modelos que componen el *Ensemble* sobre una entrada x . Los pesos w_i pueden ser ajustados según el grado de exactitud de cada modelo y deben ser definidos positivos con suma 1 ($w_i > 0, \sum_{i=0}^M w_i = 1$)⁵¹

1.8.2. Diseño de un sistema experto basado en *Ensemble Learning*. Un sistema experto basado en *Ensemble Learning* está caracterizado por los siguientes

⁴⁹ L. BREIMAN. "Bagging predictors". En: *Machine learning* 24.2 (1996), págs. 123-140.

⁵⁰ L. BREIMAN. "Random forests". En: *Machine learning* 45.1 (2001), págs. 5-32.

⁵¹ E. IKONOMOVSKA. "Algorithms for learning regression trees and ensembles on evolving data streams". Tesis doct. Doctoral Dissertation, 2012.

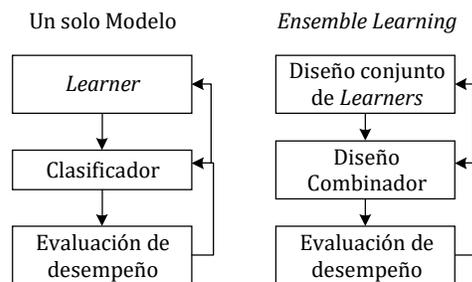
componentes:

- La arquitectura/topología: paralelo, serial, híbrido.
- Los algoritmos del *Ensemble*: Tipo y número de algoritmos base. El *Ensemble* puede ser sub-dividido en sub-conjuntos para el caso de arquitectura no paralelo.
- Combinador: Selección del método de combinación y estrategia para manejo del espacio de características.

En este sentido, el objetivo de un sistema experto basado en la metodología de *Ensemble Learning* es abordar el problema respecto a la selección del mejor conjunto de características y el mejor algoritmo. Así, en lugar de buscar el mejor algoritmo, se usa un método de combinación para obtener una mayor precisión aprovechando la incertidumbre y diversidad de diferentes algoritmos independientes. Los algoritmos base deben ser lo más precisos posible y tener diversos errores.

En la figura 7 se detalla una analogía para el proceso de diseño de un sistema experto usando la aproximación clásica de un solo modelo versus un esquema basado en *Ensemble Learning*.

Figura 7. Proceso de diseño de un SE basado en *Ensemble Learning*



El diseño de un sistema experto (SE) basado en *Ensemble Learning* implica dos fases principales: el diseño del conjunto base (Learners) y el diseño del combinador:

- El diseño del conjunto base (*Learners*) tiene como objetivo crear un conjunto de algoritmos complementarios / diversos"
- El diseño del método de combinación (combinador) tiene como objetivo crear un mecanismo de combinación que pueda explotar la complementariedad / diversidad de algoritmos y combinarlos de manera óptima.

En la figura 8 (modificado de ⁵²) se presenta una tabla que resume criterios que pueden ser usados para la selección de algoritmos base (*Learners*) según los requerimientos y características del problema.

1.8.3. Monitorización de salud estructural usando *Ensemble Learning*. En reportes de literatura en los últimos años se encuentra el uso de *Ensemble Learning* para la detección, clasificación y localización. En ⁴⁹ muestran el uso de mezclas de máquinas de soporte vectorial y redes neuronales para detectar y clasificar entre dos tipos de daños en el fuselaje de un avión los cuales son simulados por medio de elementos finitos. De otra parte en ⁵⁰ se usan medidas de diferentes sensores y de diferente naturaleza (señales de ultrasonido, emisiones acústicas, medidas de flujo) cuya información se fusiona mediante un clasificador con el fin de obtener mejores resultados en la detección de fugas en tuberías. Una aplicación similar es presentada en ⁵¹, en donde se propone el uso de medidas provenientes de diferentes sensores para obtener un diagnóstico con mayor nivel de seguridad. Así, mediante clasificadores independientes y combinación de voto por mayoría se obtiene un

⁵² T. HASTIE, R. TIBSHIRANI y J. FRIEDMAN. *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media, 2009.

Figura 8. Criterios para selección de algoritmo base de un *Ensemble Learning*

Algunas características de los diferentes métodos de aprendizaje.

▲ = bueno, ◆ = regular y ▼ = malo.

Características	Redes Neuronales	SVM	Arboles de decisión	MARS	K-NN kernel
Manejo natural de datos de tipo "mixto"	▼	▼	▲	▲	▼
Manejo de valores faltantes	▼	▼	▲	▲	▲
Robustez a los valores atípicos en espacio de entrada	▼	▼	▲	▼	▲
Insensible a transformaciones monotónicas en la entrada	▼	▼	▲	▼	▼
Escalabilidad computacional (N grande)	▼	▼	▲	▲	▼
Capacidad para lidiar con entradas irrelevantes	▼	▼	▲	▲	▼
Capacidad para extraer combinaciones lineales de características	▲	▲	▼	▼	◆
Interpretabilidad	▼	▼	◆	▲	▼
Poder de predicción	▲	▲	▼	◆	▲

Fuente: 52.

algoritmo para evaluación no destructiva aplicada a la identificación de defectos en tuberías.

2. METODOLOGÍA PARA LA DETECCIÓN Y LOCALIZACIÓN DE DAÑOS BASADA EN *ENSEMBLE LEARNING*

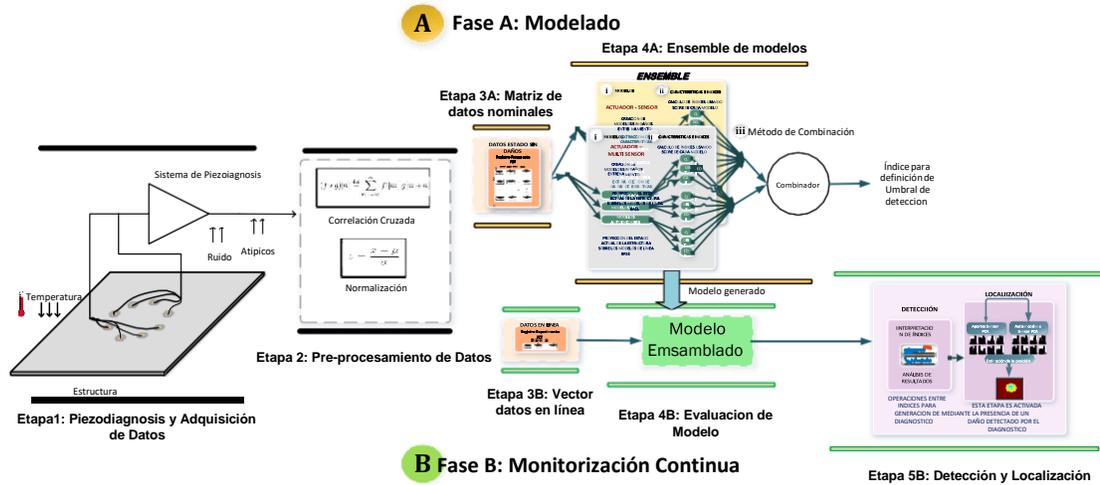
La metodología de detección y localización de daños en estructuras laminares propuesta en este trabajo de investigación, se presenta esquemáticamente en figura 9. Esta plantea el uso de una arquitectura paralelo de *Ensemble Learning* y consta de dos fases: modelado y monitorización continua. En la fase de modelado, las etapas de piezodiagnos, preprocesamiento de datos y *Ensemble* de modelos se aplican sobre una matriz de datos correspondiente al estado nominal (sin daño) de la estructura. En la fase de monitorización continua, se procesa un vector de datos en línea que corresponde a un estado desconocido de la estructura (con daño o sin daño) y se evalúa el modelo de *Ensemble* con el fin de detectar y localizar posibles daños. En las secciones del presente capítulo se describirán de manera detallada las fases de modelado y monitorización continua, así como cada una de las etapas que las conforman. Las etapas 1 y 2 son comunes para las 2 fases.

2.1. ETAPA 1: PIEZODIAGNOSIS Y ADQUISICIÓN DE DATOS

En esta etapa se aprovecha el principio de piezodiagnos en un esquema de multiactuación, que consiste en la instalación de un arreglo de piezoeléctricos en la superficie de la estructura, tal como se ilustra en la figura.10. Los transductores piezoeléctricos (PZT) poseen la característica de convertir ondas eléctricas en mecánicas y viceversa, permitiendo capturar la repuesta del viaje de ondas guiadas ante un posible defecto en la estructura.

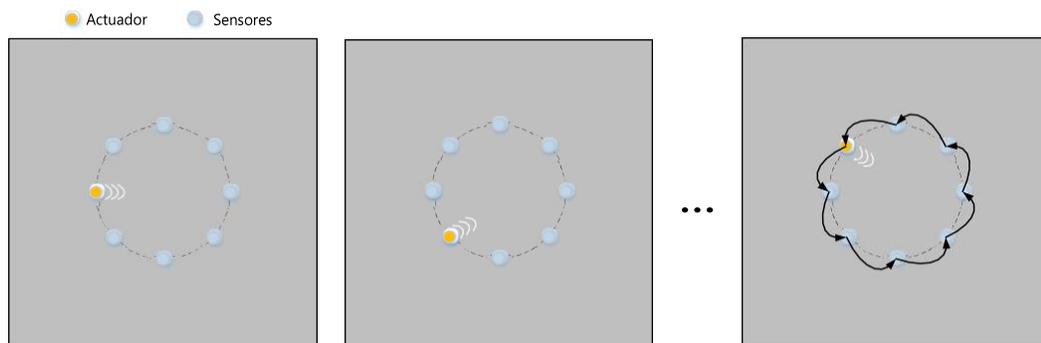
Tal como se muestra en la figura.10, un PZT se configura como actuador y los demás PZT son configurados como sensores; este proceso se repite sucesivamente

Figura 9. Ensamble para la detección y Localización de daño



hasta recorrer el arreglo completo de PZTs instalados en la estructura. El esquema de multiactuación permite adquirir ondas guiadas desde diferentes puntos de emisión, generando una cantidad de información redundante para la obtención de un modelo estadístico de diagnóstico robusto.

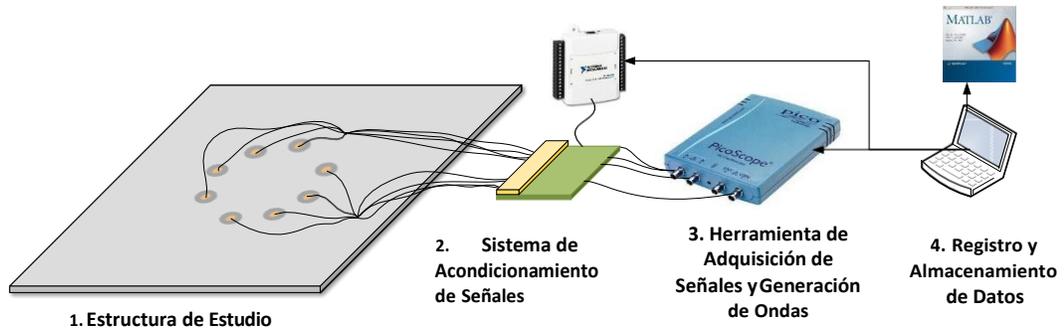
Figura 10. Secuencia de multi-actuación usando PZTs



El sistema de adquisición de datos para el esquema de piezodiagnosis utilizado en el presente trabajo, se ilustra en la figura 11. Este consiste de 4 etapas: estructura

de estudio, sistema de acondicionamiento de señales, herramienta de generación de ondas guiadas, y registro y almacenamiento de datos.

Figura 11. Registro de datos



Según se ilustra en la figura 11, los principales componentes del sistema de adquisición del esquema de piezodiagnóstico corresponden a los elementos de instrumentación de la estructura que comprenden los dispositivos PZT, elementos de acoplamiento mecánico, amplificadores para acoplamiento de impedancia eléctrica y amplificación, filtros reductores de ruido, generadores de onda arbitraria y un sistema de multiplexado para adquisición de alta frecuencia.

2.2. ETAPA 2: PRE-PROCESAMIENTO DE DATOS

En la etapa de pre-procesamiento de datos se aplican la correlación cruzada y la normalización o estandarización, con el fin de minimizar los efectos adversos debido a *Bias*, varianza, tendencias y datos atípicos, por una parte, la función de correlación cruzada entre dos señales $X(t)$ y $Y(t)$ se define como en la ecuación 17.

$$R_{XY}(t, t + \tau) = \lim_{i \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N X_k(t) Y_k(t + \tau) \quad (17)$$

Donde, N es el número de muestras y τ es el intervalo de tiempo de retraso utilizado para calcular la función de correlación cruzada.

Mientras que la normalización se aplica con el fin de minimizar los efectos de escala y varianza. En este caso se aplica la normalización GroupScaling⁵³), que se calcula utilizando la Ecuación 18

$$\bar{X}_{i,j} = \frac{x_{i,j} - \mu_j}{\sigma_s} \quad (18)$$

Donde, μ_j es la media de los datos para cada uno de los instantes de tiempo, teniendo en cuenta las diferentes repeticiones del experimento y σ_s es la desviación estándar de los datos correspondientes a las mediciones de cada sensor.

2.3. FASE A: MODELADO

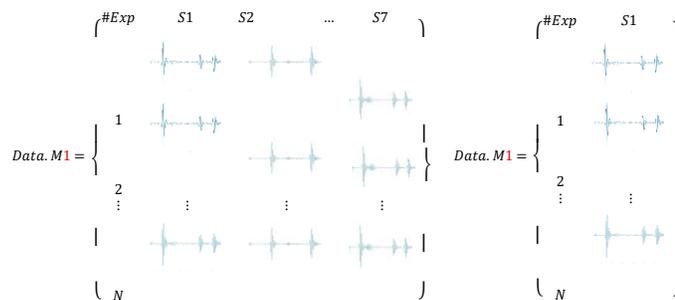
En la fase A se construye una matriz de la base de casos nominal descrita en la etapa 3A, para generar los modelos de línea base usando diferentes técnicas (PCA, KPCA, Autoencoders) y combinarlos como se describe en la etapa 4A, para finalmente crear un modelo ensamblado que se usa en la fase B.

2.3.1. Etapa 3A: Base de casos nominal. En esta etapa se organizan los datos del estado nominal de la estructura, con los que se crean los modelos de línea base. Se obtienen casos para dos tipos de modelo de línea base: MonoActuación/MonoSensado y MonoActuación/Multisensado. En la figura 12 a) se detalla la organización de registros piezoeléctricos para obtener un modelo MonoActuación/Multisensado donde se actúa en un solo punto y se sensa simultáneamente

⁵³ M. ANAYA, D. A. TIBADUIZA y F. POZO. "A bioinspired methodology based on an artificial immune system for damage detection in structural health monitoring". En: *Shock and vibration* 2015 (2015).

en todos los demás; mientras que en la figura 12 b) se detalla la organización de registros para obtener un modelo MonoActuación/MonoSensado donde se actúa en un solo punto y se sensa en otro punto de la estructura.

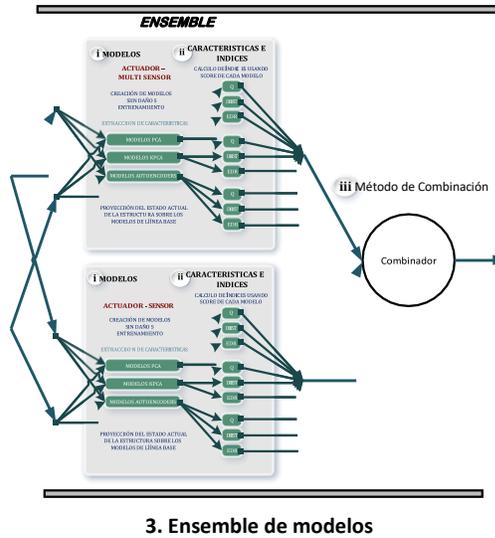
Figura 12. a) Matriz de datos para modelo por actuador b) Matriz de datos para modelo por cada sensor



2.3.2. Etapa 4A: Ensemble de modelos. Con el fin de representar la diversidad de la información recolectada de la estructura, se construye un *Ensemble* de modelos que consta de 3 componentes: i) conjunto de diferentes modelos de línea base ii) diversos índices de daño calculados a partir del error de reconstrucción y iii) método de combinación del conjunto de modelos de línea base y de los diferentes índices calculados. El conjunto de modelos de línea base se obtienen al aplicar PCA lineal, PCA no lineal y red neuronal tipo autoencoders. En la Figura 13 se muestra la arquitectura utilizada para la construcción del *Ensemble* de modelos de línea base.

i) Construcción de modelos de línea base. Los modelos de línea base se crean aplicando tres técnicas: PCA, PCA no lineal y redes neuronales tipo auto-encoders, sobre los datos del estado sin daño de la estructura. Los modelos usando PCA extraen características dominantes de un espacio de coordenadas reducido con mínima redundancia. Tal como se muestra en la sección 1.5.1, se comprime la

Figura 13. Ensemble para la detección y localización de daño



información del estado nominal a partir de las señales de los PZT. Mientras que los modelos representados en una red neuronal tipo auto-encoders, permiten reducir y extraer las principales características de los datos de entrenamiento, ajustando los pesos de las capas ocultas (tanto del codificador, como del decodificador) al estado nominal de la estructura. Tal proceso se muestra en la sección 1.5.2. Finalmente, los modelos de línea base usando KPCA permite obtener características representativas mediante un modelo de representación reducida en un espacio de mayor dimensión. Esto se hace mediante un *kernel* que permite extraer características no lineales de los datos como se muestra en la sección 1.5.2.

ii) Cálculo de índices de daño. El segundo componente del *Ensemble* son los índices de error entre el estado actual y el estado nominal (sin daño) de la estructura (ver sección 1.6). Los índices de error se calculan como la distancia entre la señal reconstruida del modelo de línea base y la señal de entrada que representa el estado

actual de la estructura, permitiendo identificar posibles cambios en el estado de la estructura asociados a un daño. Los índices calculados son Q-estadístico, distancia de edición entre señales (EDR) y distancia entre señales utilizando la distorsión dinámica del tiempo (dist).

iii) Combinación de índices. Los resultados de aplicar cada método de construcción de modelos de línea base (lineales y no lineales) y el cálculo de los diferentes índices, son combinados mediante métodos de sumas y productos. Esto permite obtener una respuesta integrada y robusta del sistema de detección, que minimiza los efectos individuales de cada índice.

2.4. FASE B: MONITORIZACIÓN CONTINUA

Esta fase consiste en la evaluación del estado actual de la estructura, a partir de señales piezoeléctricas previamente procesadas en las etapas 1 y 2.

2.4.1. Etapa 3B: Vector de Datos en línea. En esta etapa se realiza la organización de los datos de igual forma que en la etapa 3A, pero con la diferencia que los datos tienen una única fila siendo este un vector y no una matriz. El vector contiene un registro de las mediciones actuales de los sensores piezoeléctricos.

2.4.2. Etapa 4B: Evaluación del Modelo. En esta etapa se evalúan los datos provenientes de la etapa 3B, correspondientes a las mediciones actuales de los piezoeléctricos, utilizando el modelo ensamblado generado en la etapa 4A. De esta manera se generan los índices del estado actual de la estructura.

2.4.3. Etapa 5B: Detección y localización. En esta etapa, mediante los índices provenientes de la etapa 4B se detecta y localiza, de forma continua, los posibles

daños de la estructura.

Detección de daños. La detección de daños se realiza comparando el estado actual de la estructura con respecto al estado sin daño (modelo de línea base). Dicha comparación se hace con las combinaciones de los índices de daño (Q-estadístico, distancia de edición entre señales (EDR) y distancia entre señales utilizando la distorsión dinámica del tiempo (dist)). Las combinaciones usadas son la suma y producto de tales índices.

Localización de daños. La localización se hace a partir de las contribuciones de los índices. Tales contribuciones se proyectan en una imagen construida mediante el algoritmo RAPID, y escalada con las dimensiones y forma de la estructura real. Al presentarse un daño en un punto o zona de la estructura, esta condición se visualiza gráficamente como un punto o zona donde las contribuciones son mayores que las obtenidas con la imagen de la estructura sin daño (modelo de línea base).

Cálculo de contribuciones por tipo de modelo de línea base. Para la generación de las imágenes de las contribuciones, estas se calcularon en función de los dos tipos de modelo de línea base construidos: MonoActuación/Monosensado y MonoActuación/Multisensado . A continuación se describe la forma del cálculo para cada caso.

□ **Contribuciones para modelos MonoActuación/Monosensado**

Dado que se utilizan n puntos de actuación, se obtienen $n*(n-1)$ modelos, por tanto, estos se agrupan por el mismo punto de actuación. De esta manera se crean n grupos con $(n-1)$ índices cada uno. Con el fin de tener una medida comparable, se normaliza cada grupo por su máximo índice. Después de obtener los aportes de cada grupo, se usa la adaptación de RAPID aplicando la

ecuación 15 para la reconstrucción de la imagen de la estructura.

- **Contribuciones para modelos MonoActuación/Multisensado** En el caso de los modelos por actuador, el cálculo de las contribuciones se lleva a cabo realizando una descomposición en el cálculo del índice Q.

El índice Q es calculado usando la ecuación 19, que corresponde al error de reconstrucción y consiste en calcular la diferencia a el cuadrado de la señal original menos la señal reconstruida.

$$Q = \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (19)$$

Donde x_i representa la señal concatenada de todos los sensores como se muestra en la ecuación 20. y \hat{x}_i representa la señal reconstruida de x_i usando K componentes principales, como se muestra en la ecuación 21. En la ecuación 21 donde T es la proyección de x_i en el espacio de las componentes principales, P es la matriz de proyección y E corresponde a ruido.

$$x_i = [a_{i1}, a_{i2}, a_{i3}..a_{iN}; b_{i1}, b_{i2}, b_{i3}..b_{iN}; \dots; d_{i1}, d_{i2}, d_{i3}..d_{iN};] \quad (20)$$

$$\hat{x}_i = TP + E; \quad (21)$$

Donde se puede ver que \hat{X}_i corresponde a:

$$\hat{x}_i = [\hat{a}_{i1}, \hat{a}_{i2}, \hat{a}_{i3}..a_{iN}; \hat{b}_{i1}, \hat{b}_{i2}, \hat{b}_{i3}..b_{iN}; \dots; \hat{d}_{i1}, \hat{d}_{i2}, \hat{d}_{i3}..d_{iN};] \quad (22)$$

Tomando como concepto el hecho de que Q corresponde a el error de reconstrucción, se construye una aproximación del índice Q para cada uno de

los sensores, asumiendo que el error de reconstrucción para cada paquete de la señal como se aproxima como muestra en la ecuación 23, donde Q_a es el aporte correspondiente a uno de los sensores, y se calculan para los demás sensores de la misma manera.

$$Q_a = \sum_1^2 (x_a - \hat{x}_a) \quad (23)$$

donde

$$x_a = a_{i1}, a_{i2}, a_{i3}..a_{iN}; \cdot y \cdot \hat{x}_a = \hat{a}_{i1}, \hat{a}_{i2}, \hat{a}_{i3}.. \hat{a}_{iN}; \quad (24)$$

Después de calcular la aproximación de los aportes se normalizan respecto a el máximo de cada modelo de tal forma que $0 < Q_s < 1$.

Con las contribuciones para cada uno de los sensores por modelo se usa la adaptación de RAPID aplicando la ecuacion 15 para la reconstrucción de la imagen de la estructura.

3. Diseño del experimento

Para el desarrollo de la presente investigación se diseñó un experimento configurable, que permitió la creación de diferentes escenarios de daños para el registro de señales y creación de una base de casos. Como estructura de estudio se usó una lámina de aluminio de 1 metro x 1 metro y 2 mm de espesor instrumentada con 8 PZT en una configuración circular. En este capítulo se detallan las características de la estructura de estudio, la instrumentación utilizada para el acondicionamiento de señales, el sistema de recolección de información y finalmente se presentan los escenarios de daño utilizados para la validación de la metodología de detección y localización descrita en el capítulo 2

3.1. ESTRUCTURA LAMINAR DE ESTUDIO

Como estructura de estudio se utilizó una estructura laminar ya que este tipo de estructuras son las más usadas en estructuras más complejas como alas de avión, vehículos, barcos y puentes, entre otras. La estructura laminar utilizada para la generación de experimentos consiste de una sección en aluminio (ver figura 14) cuyas principales características se presentan en la Tabla 1.

Tabla 1. Dimensiones de la estructura

Característica	Descripción
Ancho	100 cm
Largo	100 cm
Espesor	2 mm

La estructura se instrumentó con ocho sensores piezoeléctricos PRYY+0110 PWAS (piezoelectric wafer active sensors) fabricados en material suave ferro-eléctrico (PIC255)

Figura 14. Estructura de estudio



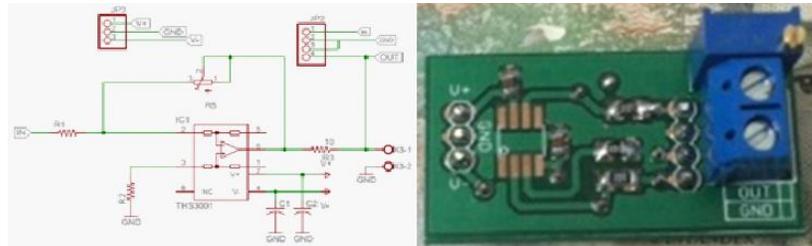
⁸, con Diámetro de 10 mm, Grosor de 0.5 mm, frecuencia de resonancia de 200 KHz, frecuencia de resonancia (radial) de 200 kHz y Frecuencia de resonancia (espesor) de 4000 kHz. Los sensores PZT fueron distribuidos de manera circular como se muestra en la figura 14. b).

3.2. ACONDICIONAMIENTO DE SEÑALES Y MULTIPLEXADO

Para el sistema de acondicionamiento de señales se usaron dos módulos para filtrado y amplificación. El primer módulo es conectado entre el generador de onda arbitraria y el módulo de multiplexado, lo que permite excitar cualquiera de los piezoeléctricos instalados en la estructura. El segundo módulo es conectado entre las señales provenientes de los piezoeléctricos configurados en modo sensor y el sistema de multiplexado, para realizar la adquisición de datos por medio de un osciloscopio con 2 canales de adquisición. Los módulos de acondicionamiento permiten obtener señales en la frecuencia de trabajo del sensor y a una amplitud adecuada, garantizando así la calidad de las señales obtenidas.

Los amplificadores de acondicionamiento de señal utilizados en el sistema de instrumentación tienen como características principal el alto rechazo al ruido, polarizado

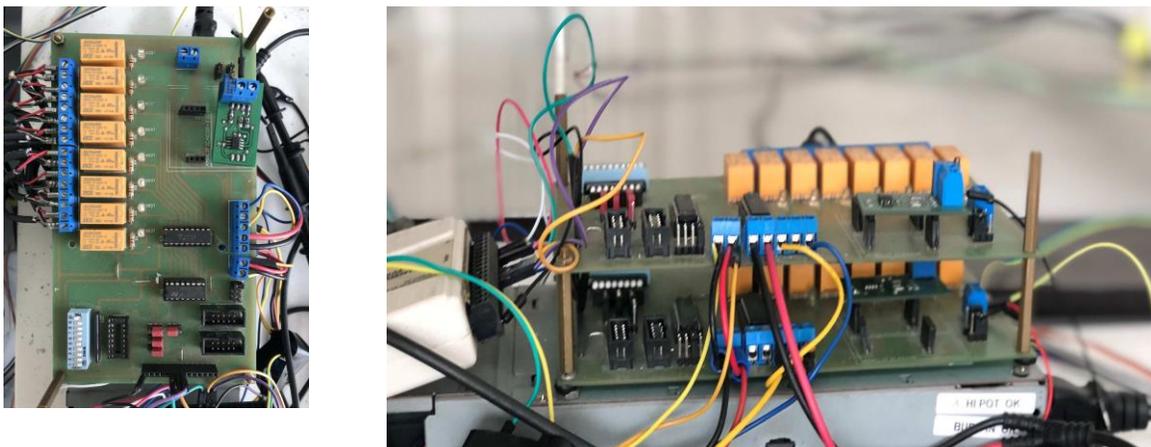
Figura 15. Modulo de amplificación



en configuración inversora con ganancia variable, y con tensión de alimentación de 24 Vpp.

Los módulos de multiplexado se basan en lógica digital para la activación de relés, que alternan entre 8 posibles canales de conexión a cada amplificador. La activación de los relés se realiza por medio de una secuencia binaria de tres bits provenientes de un DAQ. Este módulo se implementó con el fin de poder usar 8 canales de actuación y sensado de manera independiente, permitiendo de esta manera realizar multi-actuación. El módulo de multiplexado se muestra en la figura 16

Figura 16. Modulo de multiplexado



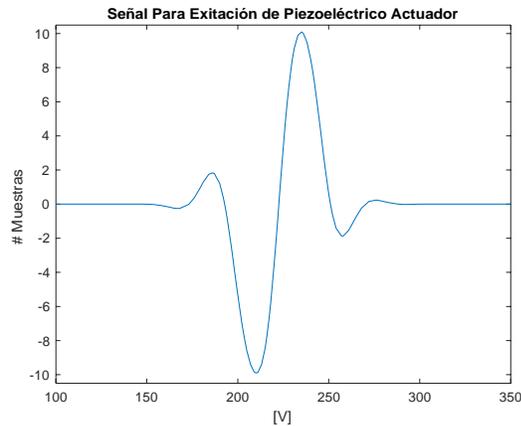
El sistema de multiplexado permite activar dos modos de funcionamiento para los dispositivos piezo-eléctricos: modo actuador y modo sensor.

- **Modo 1. Piezoeléctrico como actuador:** En este modo el multiplexor se encarga de alternar la señal del generador de onda a cada uno de los piezo-eléctricos conectados (para este proyecto ocho piezoeléctricos), de modo que cada cierto tiempo previamente definido la señal generada es transmitida por un piezoeléctrico diferente. El piezoeléctrico que se conecta como actuador queda deshabilitado para sensor. El piezoeléctrico en modo actuador convierte la señal eléctrica en una onda mecánica que viaja por la estructura.
- **Modo 2. Piezoeléctrico como sensor:** En el modo 2 un segundo multiplexor es encargado de conectar cada sensor con el sistema de adquisición. Esto permite que cada piezoeléctrico conectado sea usado como sensor, para que puedan recibir la señal mecánica que viaja por la estructura. Esta señal recolecta información de la estructura y el piezoeléctrico conectado como sensor, convierte la señal mecánica en eléctrica.

3.2.1. Generación de onda guiada. La generación de onda guiada a través de la estructura es implementada mediante un generador de onda arbitrario (AWG) *PicoScope* de la serie 2208. Para este caso se usó una onda tipo burst ajustada a la frecuencia de resonancia de los PZT (ver figura 17) mediante software de desarrollo *Matlab* considerando un modo de disparo ajustado para poder sincronizar los multiplexores de actuadores y sensores.

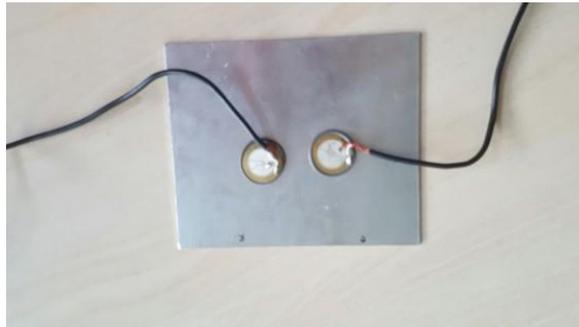
Para determinar la frecuencia de resonancia de los PZT se instrumentó una lámina de 10 x 10 cm y espesor de 2 mm con dos piezoeléctricos (uno como sensor y el otro como actuador) como se ilustra en la figura 18. Se realizó un barrido de fre-

Figura 17. Señal tipo *Burst* generada para excitación de piezoeléctricos.



cuencia para determinar la frecuencia a la cual se obtiene la mayor amplitud en el PZT usado como sensor.

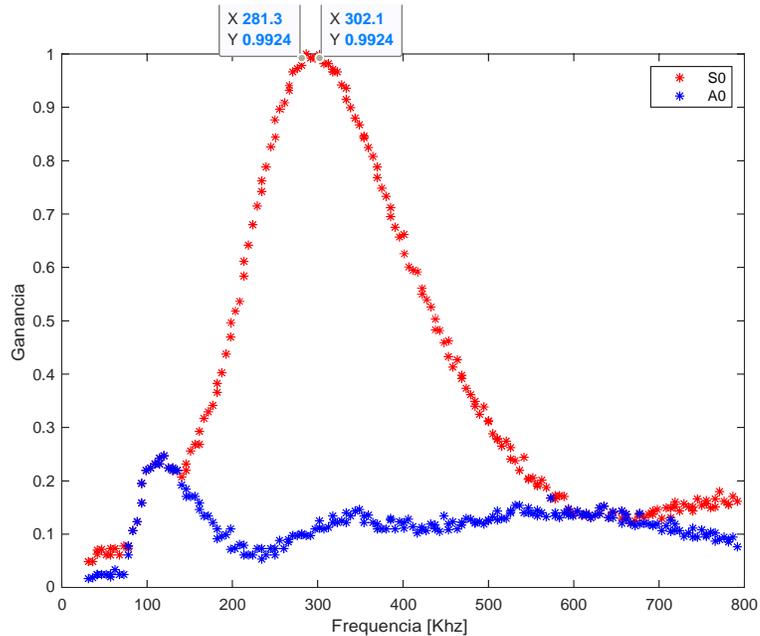
Figura 18. Lamina 10 x 10 cm



Con los datos obtenidos del experimento ilustrado en la figura 18, se realizó el cálculo de la ganancia de la señal generada y obtenidas por la pareja de PZT (Actuador - Sensor). En la figura 19 se muestra la relación Ganancia vs Frecuencia, donde se puede observar que en el rango de 281.3-302.1 kHz se encuentra la mayor ganancia para el sensor PZT. Basado en este experimento se determinó como frecuencia

de actuación para los PZT 300kHz.

Figura 19. Amplitud vs frecuencia de actuación



3.3. ESCENARIOS DE DAÑO

En esta sección se describen los escenarios de daño utilizados para la validación de la metodología de detección y localización de daños desarrollada en la presente investigación: Agregación de masas, orificios y grietas.

3.3.1. Agregación de masas. La agregación de masa consiste en la localización de elementos sólidos sobre la superficie de la lámina que representen un obstáculo en el viaje de la onda y cambios en la superficie laminar alrededor del objeto. Para las agregaciones de masa se probaron elementos de diferentes tamaños y adheridas usando gel de ultrasonido. Las masas fueron estudiadas bajo diferentes condiciones de temperatura (cambios ambientales en operación durante un día) y

localizaciones. Las masas agregadas en la lámina se presentan en la figura 20

Figura 20. Masas agregadas para la generación de daños

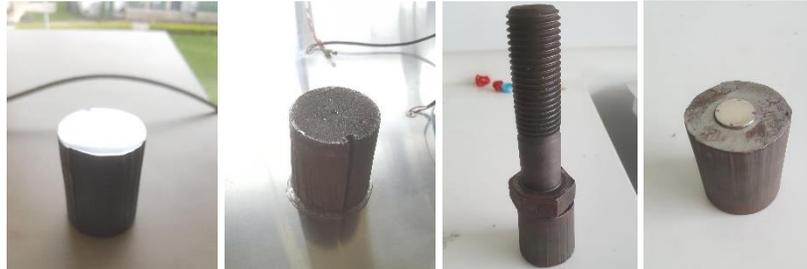
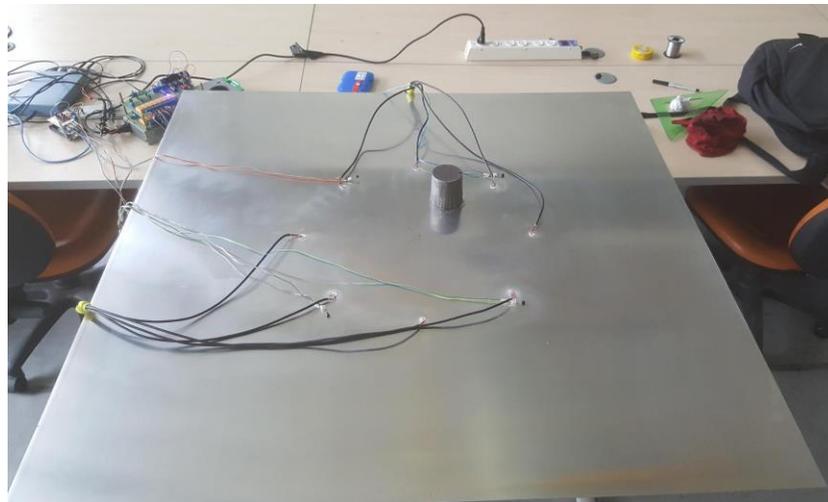


Figura 21. Masa agregada en estructura de estudio



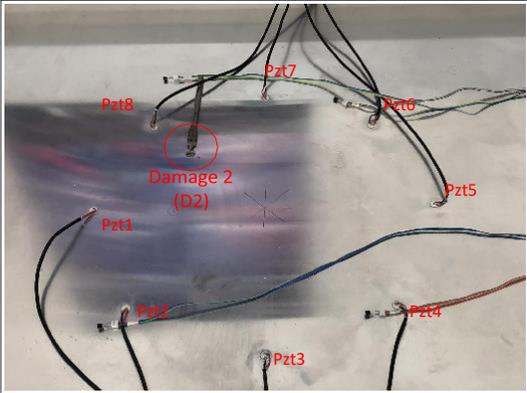
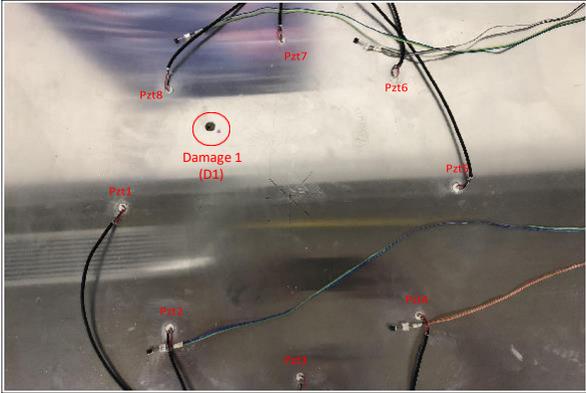
3.3.2. Orificios y cortes. El proceso de generación de los escenario con orificios consiste en perforar la lámina usando un taladro con brocas de 4 diámetros diferentes ($3/8"$, $7/16"$, $9/16"$, $1"$). En la figura 22 se muestran las perforaciones realizadas, que permiten evaluar la capacidad del algoritmo de detección y localización de daños de diferente magnitud. Adicionalmente, se generó un escenario de daño que consiste en la realización de un corte transversal en la superficie de la lámina localizado en la zona interna del arreglo de sensores. Se recolectaron 300 repeticiones

por experimento para la construcción de los miembros del ensemble.

Figura 22. Escenarios de daño tipo perforación

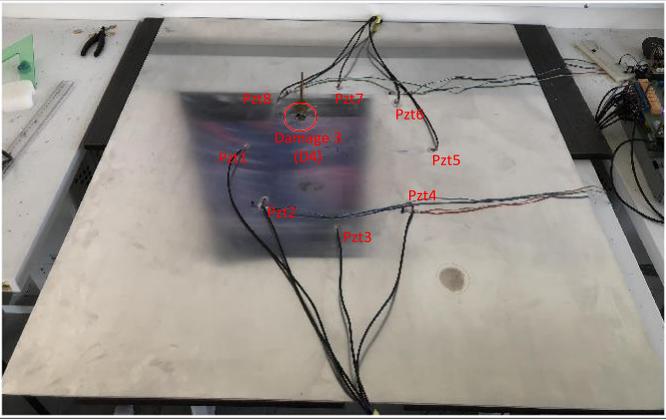
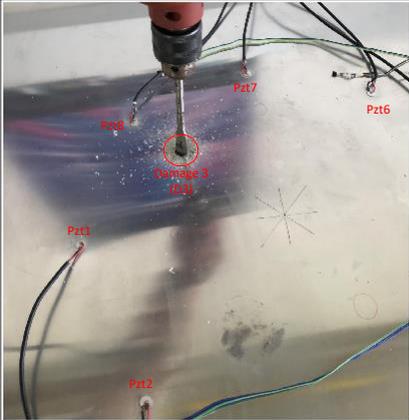
(a) D1: 3/8"(10mm)

(b) D2: 7/16"(11mm)



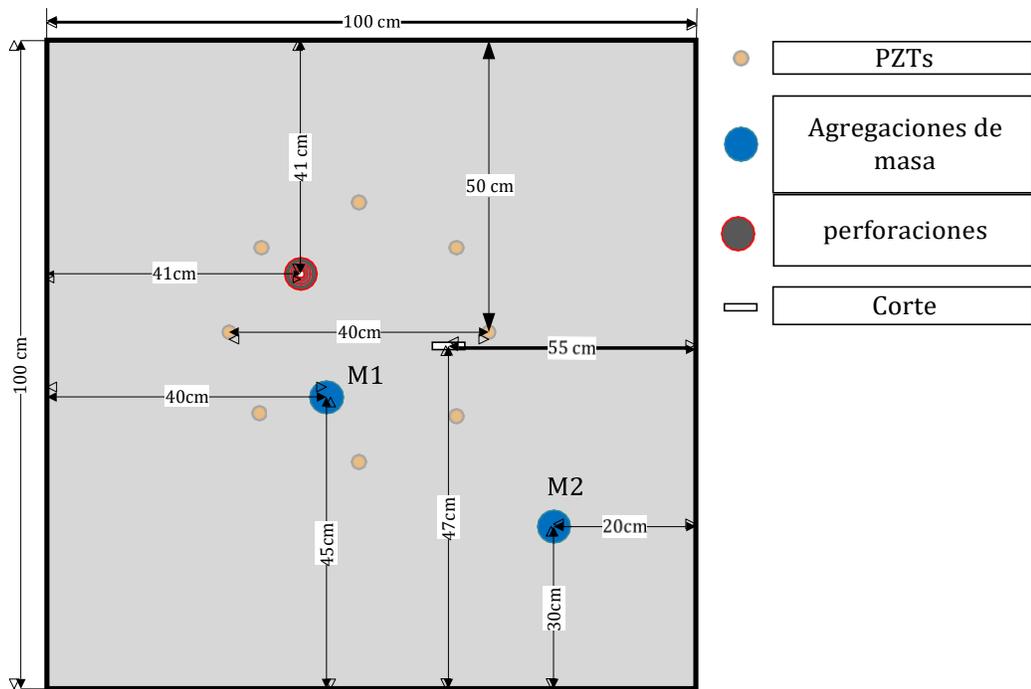
(c) D3: 9/16"(14mm)

(d) D4: 1"(25.4mm)



3.3.3. Ubicación de los daños. En la figura 23 se presentan los diferentes daños realizados a la estructura de prueba y sus respectivas ubicaciones.

Figura 23. Ubicación de los daños



4. Validación experimental de la metodología

En este capítulo se presentan los resultados de validación de la metodología para detección y localización robusta de daños basado en arquitectura de *Ensemble Learning* en paralelo. Primero, se describe una aproximación mediante modelos de línea base extendidos que permite la minimización del efecto de la temperatura y variaciones ambientales. Luego, se muestra el desempeño de los métodos de combinación en la arquitectura de *Ensemble Learning* usados para detección de daños tipo agregación de masa, presencia de cortes y perforaciones. Finalmente, se ilustra la capacidad de la metodología para localización de daños aplicando la versión adaptada del método de reconstrucción probabilística. Así, se demuestra la robustez de la metodología desarrollada ante condiciones ambientales variantes y su factibilidad para detección y localización de diversos tipos de daños estructurales.

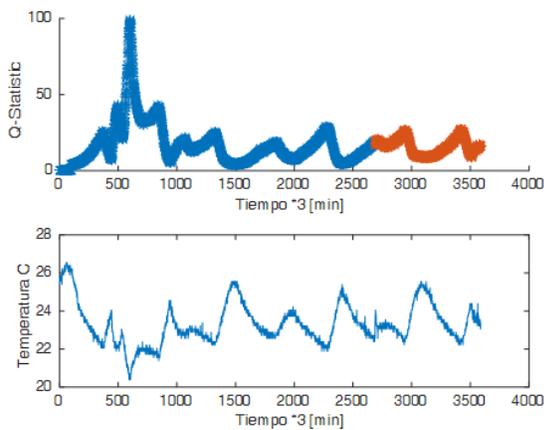
4.1. ROBUSTEZ DEL MODELO ENSAMBLADO ANTE VARIACIONES DE TEMPERATURA

En esta sección se presenta la aproximación utilizada para la minimización de efectos causados por variaciones de condiciones ambientales (temperatura/humedad) ocurridas durante la operación normal de la estructura. Así, se describe el uso de modelos de línea base extendidos, que incluyan las variaciones ambientales presentes en la estructura y que afecten la precisión en la detección y localización de fallas.

Para ilustrar el efecto no deseado de la temperatura en los algoritmos de detección de daños, se muestra el comportamiento de los índices de daño construidos con modelos de línea base sin extender, versus modelos de línea base extendidos, usando PCA lineal. Así, inicialmente se tomaron las primeras 200 muestras para crear el modelo de línea base y una vez creado este modelo se inició la monitoriza-

ción continua cada 3 minutos por un periodo de 140 horas (5.8 días). Después de 134 horas se agregó una masa (M1) (daños reversibles) en la superficie de la lámina que representa un daño reversible. En la figura 24 se muestran las variaciones en el comportamiento del índice de daño.

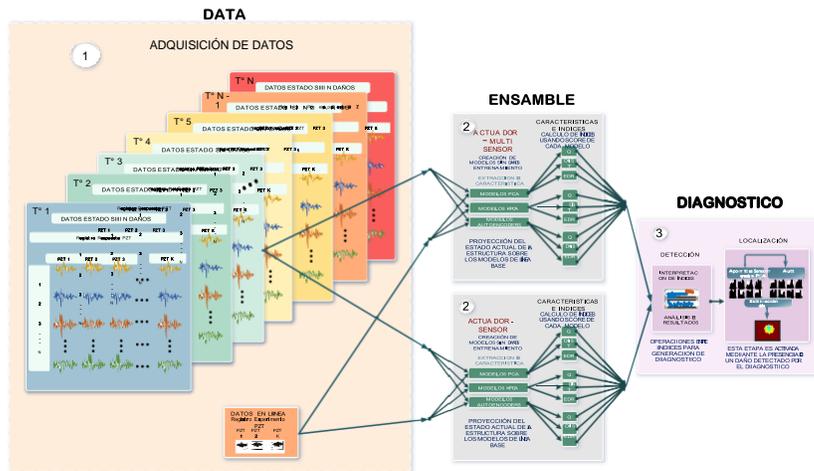
Figura 24. Efecto de la temperatura



Como se observa en la figura 24, las variaciones del índice de daño corresponden en las primeras 134 horas a cambios de temperatura en un rango de $[19 \text{ a } 27 \text{ } ^\circ\text{C}]$, ya que no existe daño. De esta manera, los resultados obtenidos no permiten distinguir la variación del estado de la estructura respecto a un daño, ya que las variaciones de temperatura generan cambios en la amplitud del índice de daño que no son diferenciables cuando se agrega el daño en la estructura.

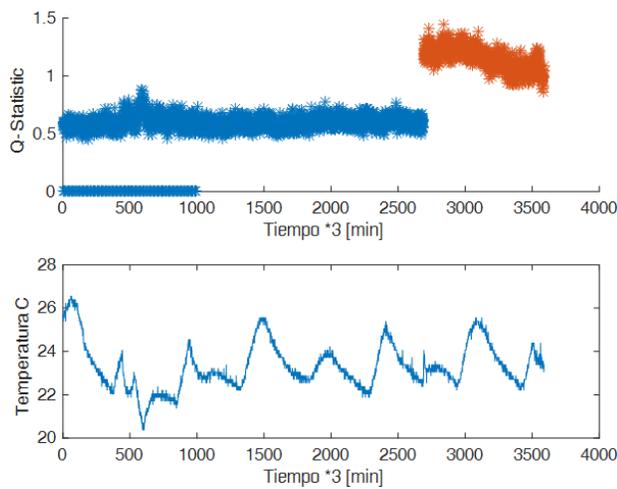
Debido a que el uso de modelos de línea base sin tener en cuenta variaciones ambientales no permite la detección robusta de daños, se creó un modelo incluyendo la información de cambios de temperatura y condiciones operacionales denominado modelo de línea base extendido como se muestra en la figura 25. Este modelo extendido incluye el efecto de la temperatura y las condiciones operacionales, durante un periodo de tiempo representativo que considere las condiciones a las que será sometida la estructura a monitorizar.

Figura 25. Metodología Modelo extendido



En la figura 26 se muestra el desempeño del modelo de línea base extendido, donde se logra diferenciar la agregación de masa (M1) respecto a la condición sin daño a diferentes temperaturas.

Figura 26. Detección de daño con modelo extendido



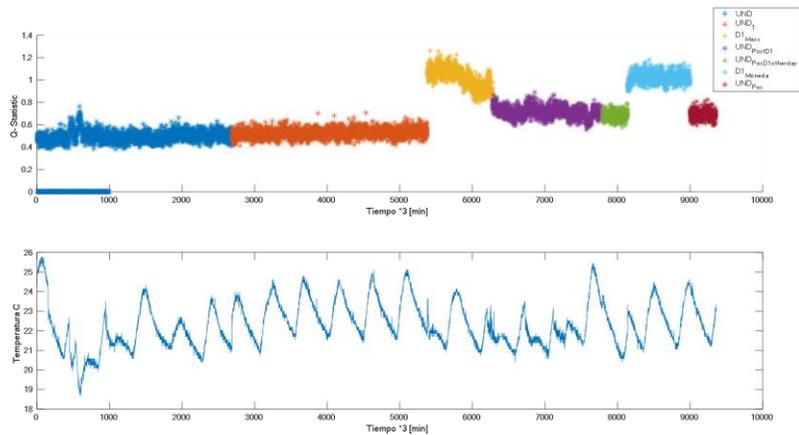
De los resultados mostrados en esta sección se concluye la pertinencia del uso de modelos de línea base extendidos para detección y localización robusta de daños. Así, en adelante se considera el uso de modelos de línea base extendidos debido a su capacidad de minimización de los efectos causados por variaciones ambientales y/o operacionales.

4.2. DETECCIÓN CONTINUA DE DAÑOS

En esta sección se describen los resultados para detección de daños en condiciones de temperatura variantes y en operación continua mayor a 1 día. Las variaciones de temperatura corresponden a condiciones ambientales variables en ambiente de laboratorio que representan la operación continua de la estructura. La metodología de detección fue validada para 3 condiciones de daño: agregación de masa, cortes y perforaciones. Los principales hallazgos se describen a continuación, haciendo énfasis en las ventajas del uso de diversos índices de diagnóstico usando modelos de línea base (lineales y no lineales) bajo el esquema de *Ensemble Learning*.

4.2.1. Detección de masas. Se realizaron pruebas agregando y quitando la masa dentro y fuera de la red de sensores. Las masas se agregaron durante un periodo de tiempo y luego fueron removidas para comprobar que los índices regresaban a su estado nominal. En la figura 27 se muestra los resultados para el índice Q asociado a masas agregadas en diferentes posiciones y calculado aplicando PCA lineal. Los resultados en la figura 27 evidencian el desplazamiento de la línea base después de agregada la primera masa y su posterior retiro. Asimismo, se observa en la figura 27 que si se usa el modelo inicial, existe un desplazamiento en los índices de daño para el estado nominal (sin daño) que hace necesario la actualización del modelo de línea base cada vez que ocurra una falla en la estructura.

Figura 27. Agregación de masas en diferentes posiciones

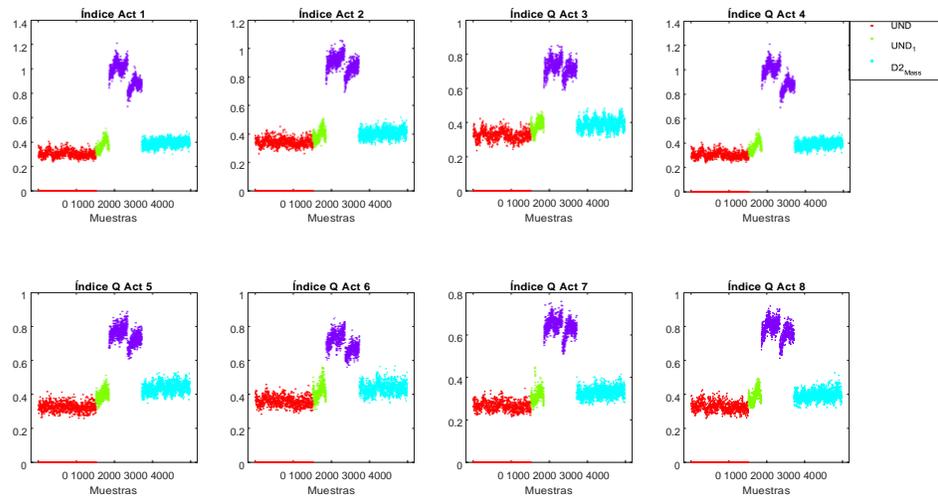


En la figura 28 se muestran los resultados de los 8 modelos (MonoActuación/Multisensado) creados con los datos del estado nominal después de remover la masa (M1) (modelo actualizado). En la imagen se observa que al actualizar el modelo, se logra la detección del daño con cada uno de los índices calculados para cada modelo MonoActuación/Multisensado. No obstante, se requiere el uso de un método de combinación que aproveche las características de amplitud y dispersión obtenidas en cada índice de daño.

En la figura 29 y la figura 30 se muestran la combinación de los índices Q para la detección de masas, usando la suma y producto entre los índices de cada modelo MonoActuación/Multisensado. Para este caso, se observa que:

- Al sumar los índices de daños de todos los modelos MonoActuación/Multisensado, se produce una dispersión menor de los valores del índice de daño resultante y una mejor frontera de separación entre las condiciones de daño, respecto al estado nominal (sin daño). Sin embargo, se requiere un procedimiento supervisado para definir el umbral de condición de daño.
- Al multiplicar los índices de daño de todos los modelos por actuador, hay una

Figura 28. Modelo extendido después de quitar la masa 1



mayor dispersión de los valores del índice de daño. No obstante, la condición nominal (sin daño) se agrupa en un valor cercano a cero, lo que facilita la definición de un umbral de separación.

Se puede concluir, que es más apropiado usar como método de combinación, el producto para casos en los que la condición nominal (sin daño) corresponde a índices con amplitud menor que uno. Además, en ambos casos se mejora la frontera de separación obtenida por los modelos individuales.

Figura 29. Índice combinado mediante la suma

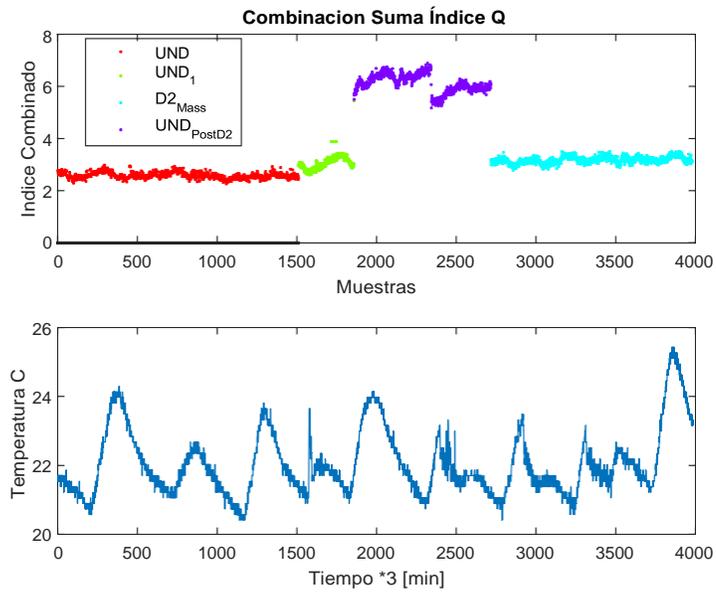
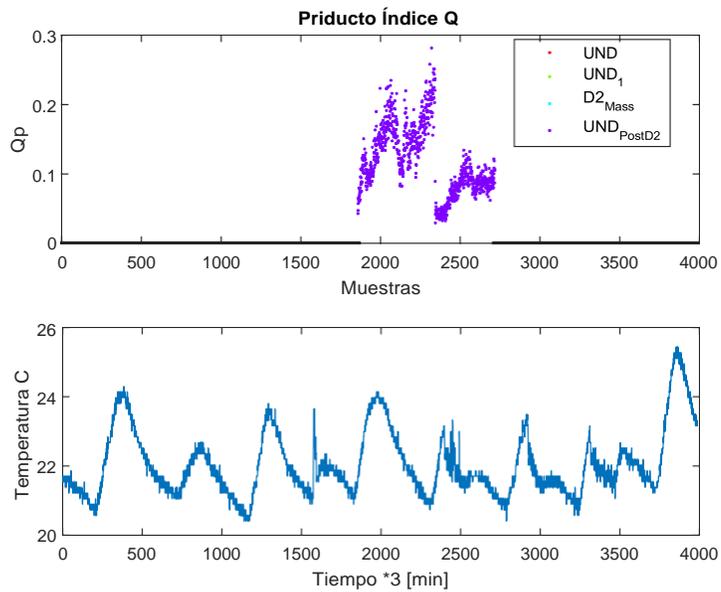


Figura 30. Índice combinado mediante el producto



4.2.2. Detección de perforaciones y cortes. En este experimento se realizaron perforaciones de diferentes tamaños durante varios días como se muestra en la figura 22. Adicionalmente, se realizó un corte con un mototool para representar condición de múltiples daños. Para este caso, se crearon 56 modelos de línea base, MonoActuación/Monosensado y aplicando PCA lineal y no-lineal. En la arquitectura Ensemble se usan dos etapas de combinación; primero, se combinan las respuestas de los índices obtenidos con el mismo tipo de aproximación usado para la generación de modelos (lineales o no-lineales). Luego, se combina el resultado de los índices obtenidos para cada método de construcción de modelos de línea base (PCA lineal y no-lineal) usando los operadores de suma y producto.

Inicialmente, se presentan en las figuras 31 y 32 los resultados de la primera etapa de combinación para los diferentes índices de daño. Según los resultados presentados en la figura 32, se obtienen varios grados de sensibilidad para cada modelo de línea base; donde se puede observar que el promedio de los índices de daño representa una mejora respecto al uso de un sólo índice de detección y evita la selección del peor de los casos garantizando un mejor rendimiento del sistema completo de detección.

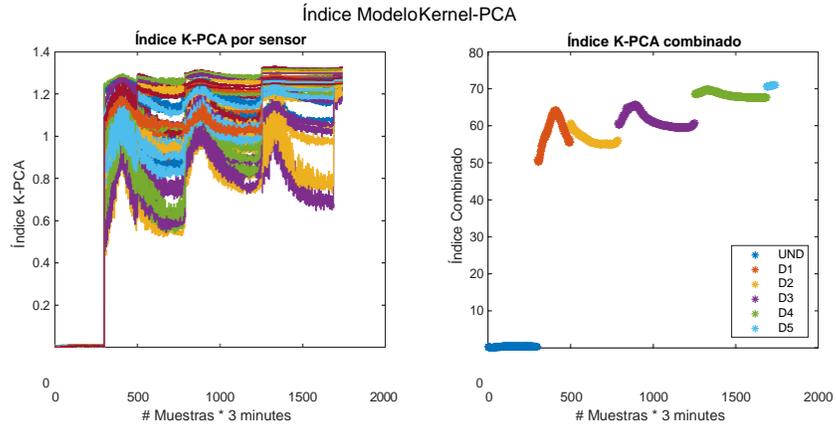
Los resultado de combinar la respuesta de los diferentes métodos PCA, segunda etapa de combinación de la arquitectura ensemble, se muestra en la figura 32.

Según los resultados presentados en la figura 32, mediante el uso de un índice combinado bajo el enfoque de *Ensemble Learning* se obtiene una mejor frontera de separación para las condiciones de daño respecto al estado nominal (sin daño), especialmente para el operador de suma. Además, el solapamiento de los datos se reduce y lo que implica una mejor separabilidad entre las condiciones de daño facilitando el proceso de identificación.

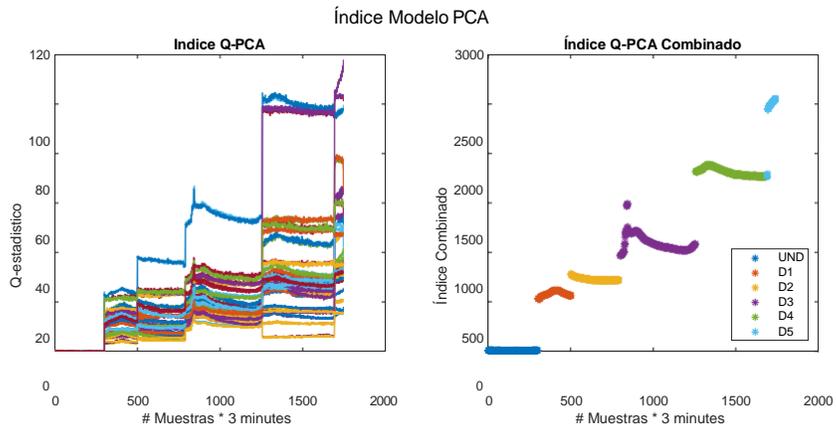
En la figura 33 se presentan resultados complementarios usando los índices EDR (Distancia de edición entre señales) y Dist (Distancia utilizando la distorsión dinámi-

Figura 31. Resultados Detección de daños usando multiactuación

(a) Kernel PCA



(b) PCA Lineal



(c) Autoencoders

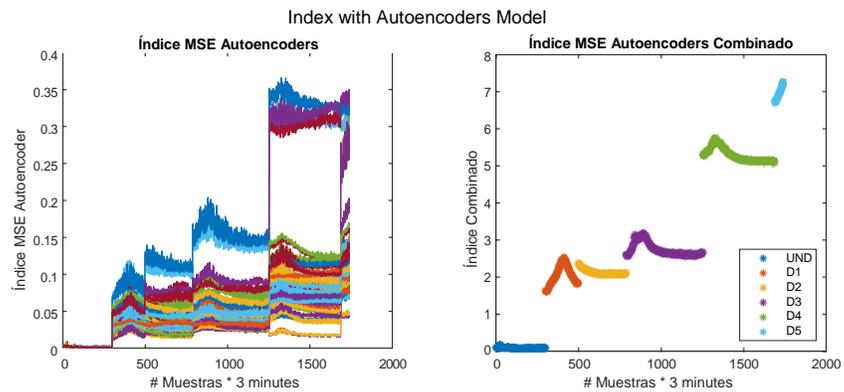
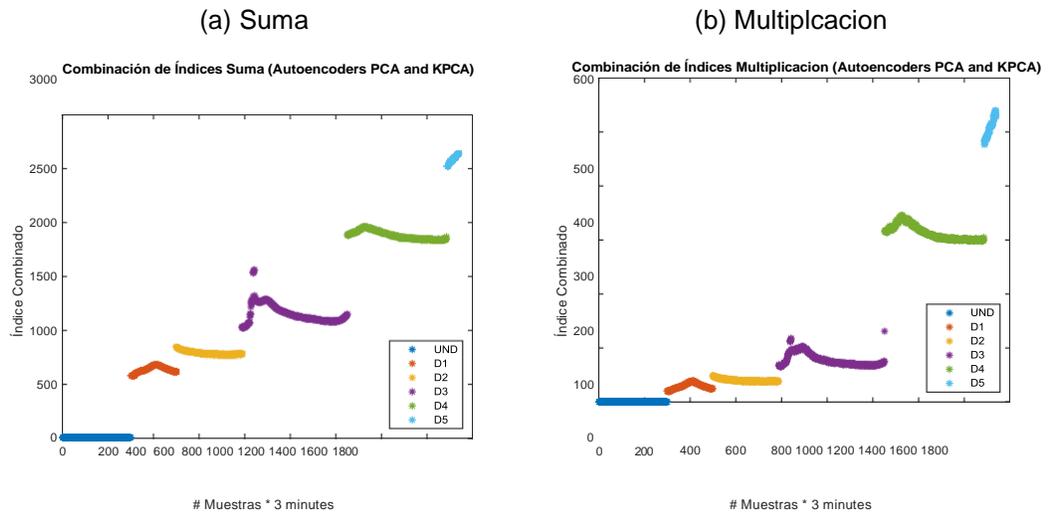


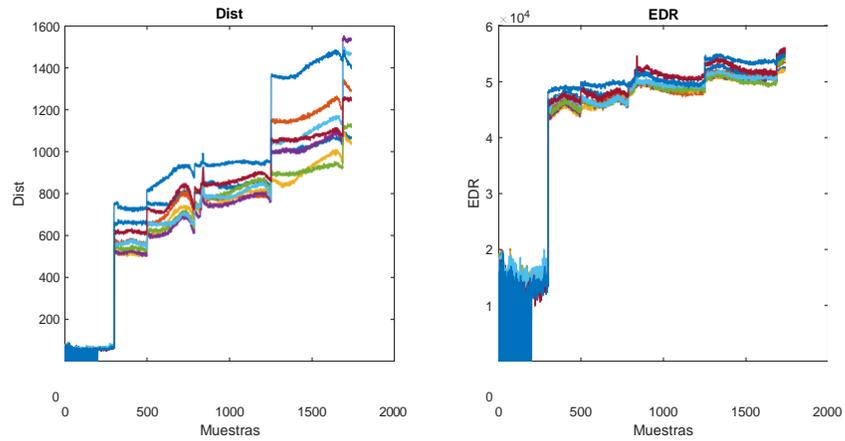
Figura 32. Resultados índices usando *Ensemble Learning*



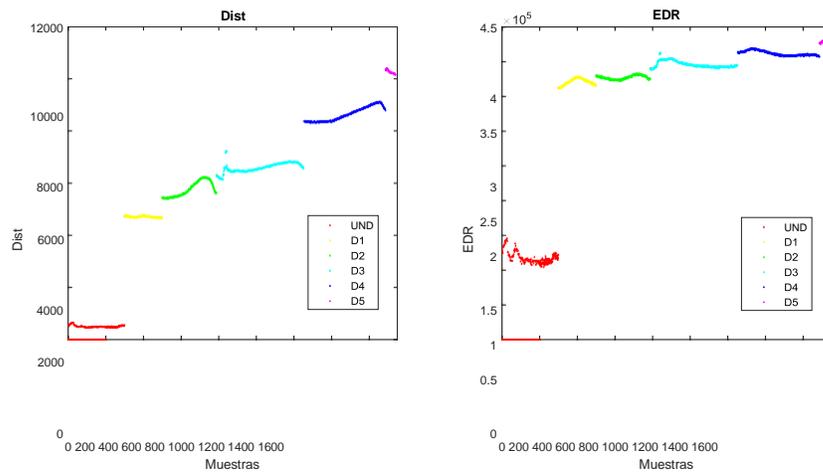
ca del tiempo) obtenidos mediante modelos de línea base aplicando PCA lineal. El costo computacional de los índices EDR y Dist es más alto que el cálculo del índice Q; sin embargo, permiten la diferenciación entre las condiciones de daño respecto al estado nominal.

Figura 33. Resultados índices EDR y Dist con PCA lineal

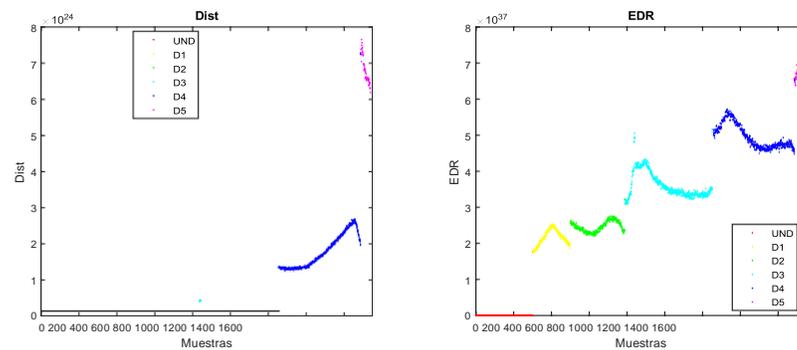
(a) Índices EDR y Dist



(b) Suma



(c) Multiplcacion



4.3. LOCALIZACIÓN DE DAÑOS

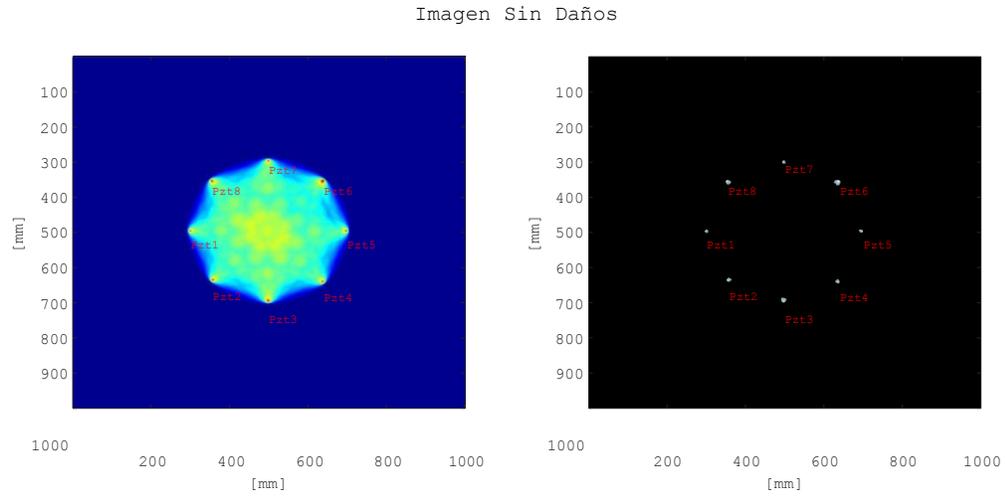
En esta sección se presentan los resultados de la aplicación de la metodología basada en contribuciones para localización de daños (ver sección 1.7.2), utilizando la adaptación del método de reconstrucción probabilística (RAPID) descrito en la sección 1.7.2). Primero, se muestran los resultados obtenidos para el caso de contribuciones de modelos de línea base MonoActuación/Monosensado; luego, se describen los resultados de localización mediante contribuciones de modelos de línea base calculados a partir de modelos MonoActuación/Multisensado. El análisis de resultados muestra que se obtiene una mejor identificación de la localización del daño usando contribuciones basado en modelos de línea base MonoActuación/Multisensado. No obstante, para ambos casos, es posible obtener una representación aproximada de la localización del daño mediante la reconstrucción de una imagen.

4.3.1. Localización de daños usando modelos MonoActuación/Monosensado.

En la figura 34 se presenta la imagen reconstruida de la estructura en estado nominal (sin daño) para el caso de contribuciones calculado usando modelos de línea base MonoActuación/Monosensado. En la imagen de la figura 34 se observan valores bajos del Índice Q excepto en las posiciones correspondientes a los dispositivos PZT. Así, los mayores contribuciones en la imagen corresponde a objetos identificados donde se ubican los dispositivos PZT.

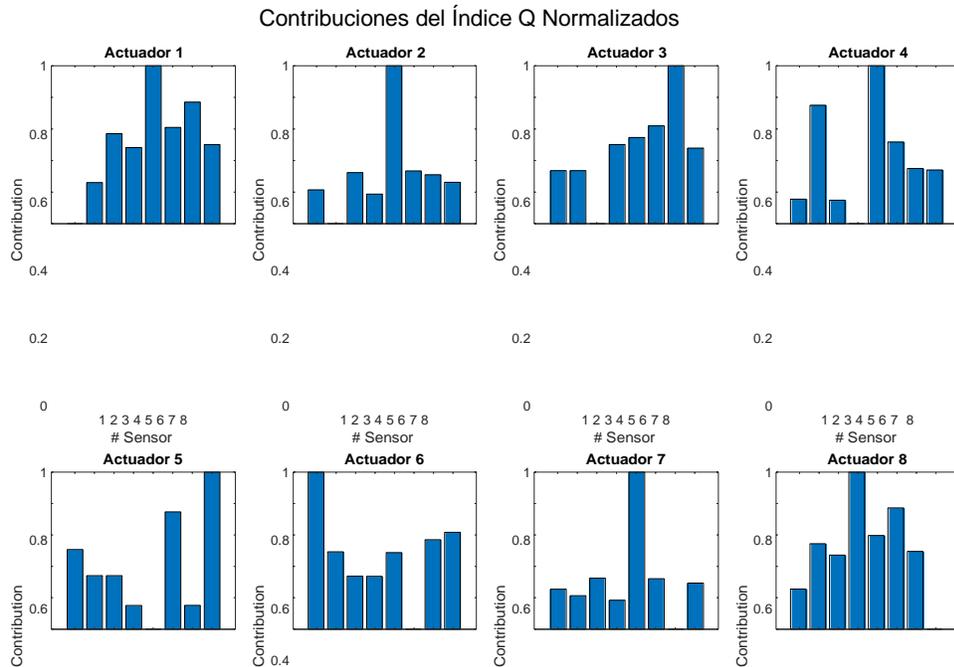
En la figura 35 se muestran las contribuciones del Índice Q para el primer escenario de daño (D1: perforación 3/8") para cada modelo de línea base, cuando cada uno de los dispositivos PZT funciona como actuador. En este caso, las mayores contribuciones corresponden a la ruta con mayor probabilidad de daño. Por ejemplo, en el modelo de línea base construido con el PZT-1 operando como actuador (Actuador

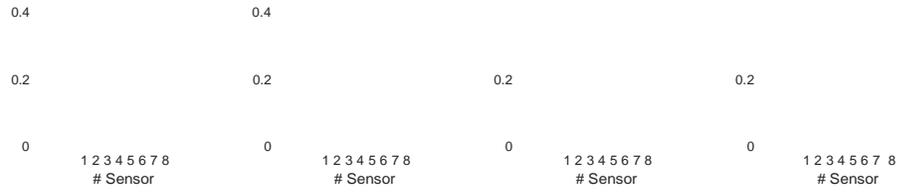
Figura 34. RAPID con índice Q para el estado sin daños



1), la ruta con mayor probabilidad de daño corresponde al camino directo hacia el PZT-5 (sensor 5).

Figura 35. Contribuciones de índice Q para el daño (D1)

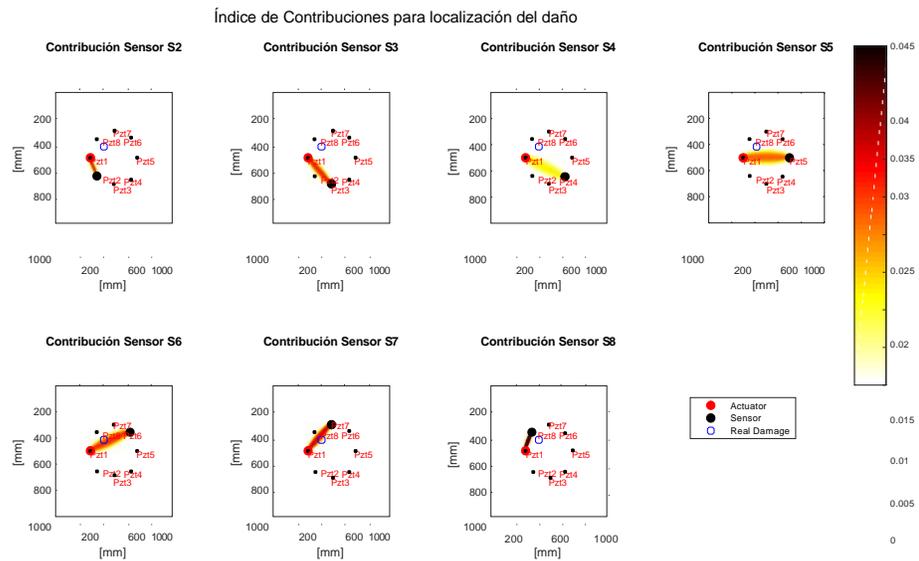




En la figura 36 se observa la distribución espacial elíptica normal entre pares de sensores escalado por las contribuciones del índice estadístico Q y obtenido del

modelo de línea base construido con el dispositivo PZT-1 operando como actuador. Esta imagen permite identificar las rutas de mayor probabilidad de localización del daño.

Figura 36. RAPID con índice Q para el estado daño (D1)

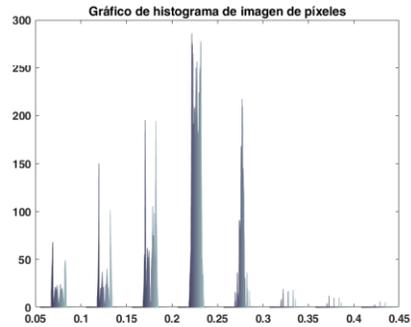


Según la figura 36, las contribuciones más importantes corresponden a rutas actuador-sensor cerca de la ubicación del daño, donde la señal se distorsiona por dispersión y reflexión debido a discontinuidades (daño). En la figura 37 se muestra la imagen reconstruida con la suma de todas las contribuciones para cada par actuador-sensor. La localización del daño se estima después de binarizar la imagen con la suma de las contribuciones correspondiente al análisis del primer escenario de daños (D1). La binarización se consigue filtrando los modos de baja frecuencia presentes en el histograma de la imagen luego de aplicar umbral (<0.3). La posición real del daño es especificada por la marca o-azul y se superpone la imagen reconstruida con los objetos identificados que representan posibles daños así como los dispositivos PZT para efectos de comparación.

Según los resultados en la figura 37, se demuestra la capacidad del algoritmo propuesto e localizar daños en láminas. Los resultados para los demás escenarios de daño estudiados se muestran en la figura 38

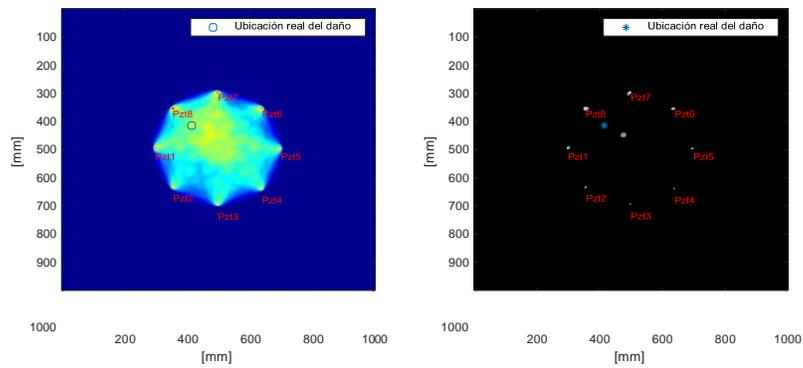
Figura 37. Imagen para escenario de daño D1

(a) D1: 3/8"(10mm)



(b) D1: 3/8"(10mm)

Imagen para la condición de daño (D1 diil 3/8 inch (10mm))

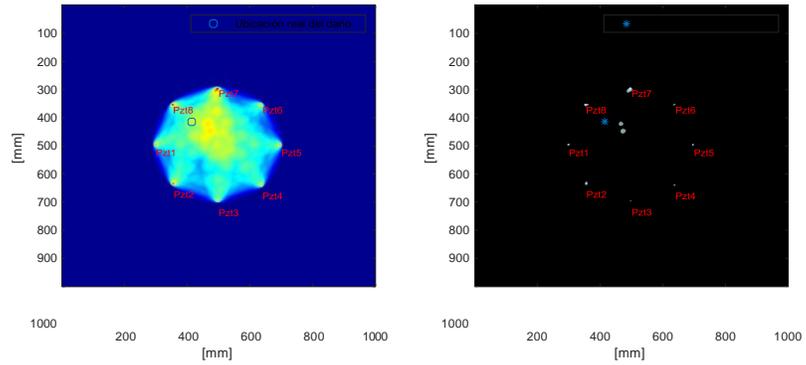


De acuerdo con los resultados de la figura 38, se demuestra la factibilidad de la metodología de localización de daños propuesta considerando diferentes tamaños. Sin embargo, los escenarios que corresponden a daños de mayor tamaño generan una imagen reconstruida levemente distorsionada alrededor del daño.

Figura 38. RAPID con índice Q para el estado con daños

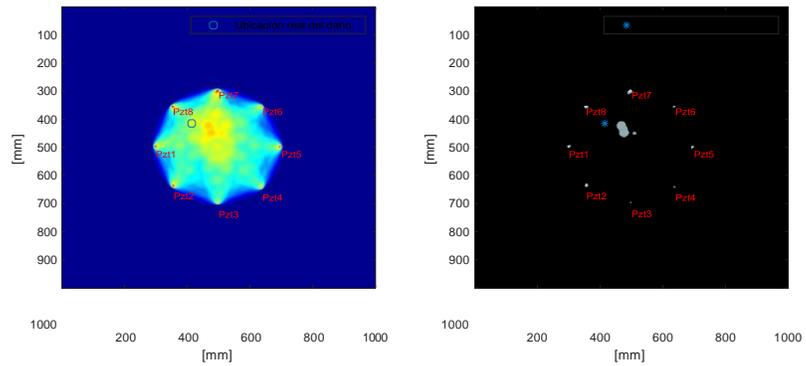
(a) D2: 7/16"(11mm)

Imagen para la condicion de daño(D2 dill 7/16 inch (11mm))



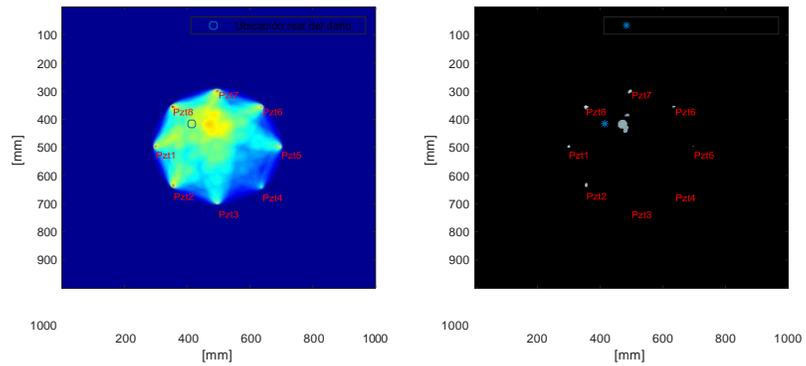
(b) D3: 9/16"(14mm)

Imagen para la condicion de daño (D3 dill 9/16 inch (14mm))



(c) D3: 1"(25.4mm)

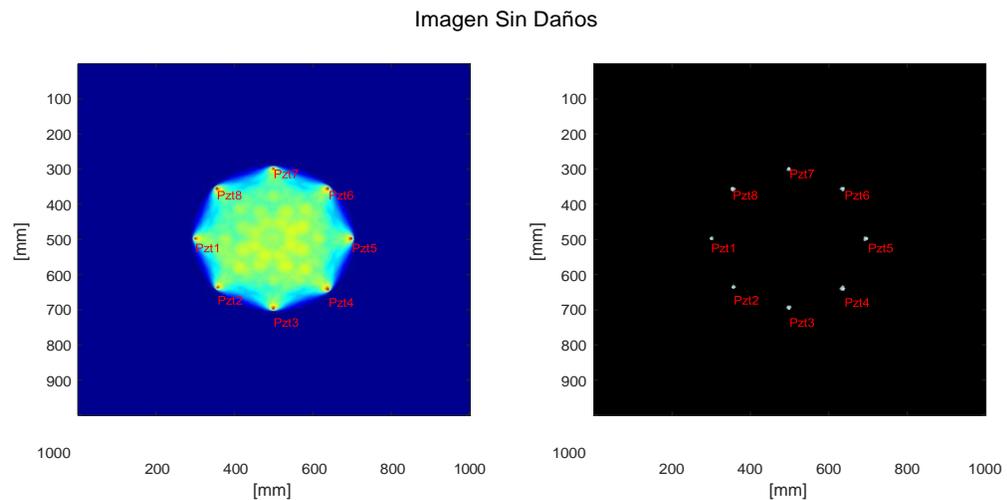
Imagen para la condicion de daño (D4 dill 1 inch (25.4mm))



4.3.2. Localización De daños usando modelo MonoActuación/Multisensado.

En esta sección se presentan los resultados para localización de daños para el caso de contribuciones del índice Q calculado usando modelos de línea MonoActuación/Multisensado. En este caso, las 7 contribuciones (una por modelo) fueron normalizadas sobre el máximo para su posterior combinación (suma) y generar la imagen reconstruida mediante el algoritmo RAPID adaptado (1.7.2). En la figura 39 se presenta la imagen reconstruida para el estado nominal (sin daño) de la estructura. En la imagen reconstruida se identifican los objetos que corresponden a los sensores PZT instalados en la estructura.

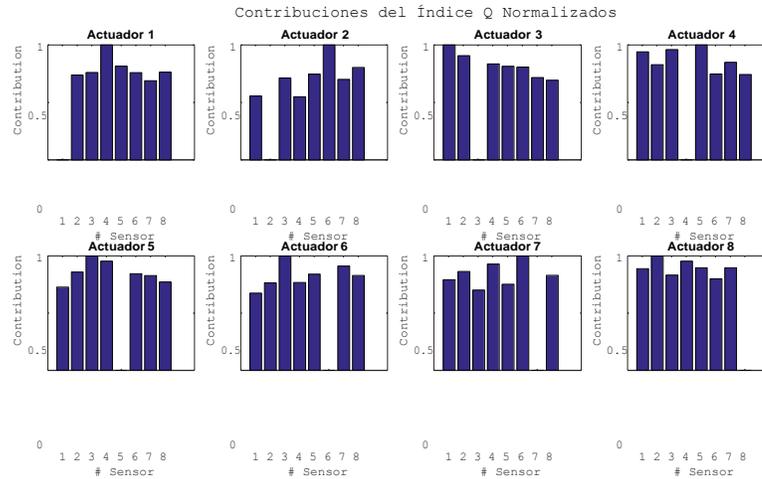
Figura 39. RAPID con índice Q para el estado sin daños



En la figura 40 se muestra la contribución del Índice Q para el primer escenario de daños (D1: perforación 3/8") para cada modelo de línea base, cuando cada uno de los dispositivos PZT funciona como actuador.

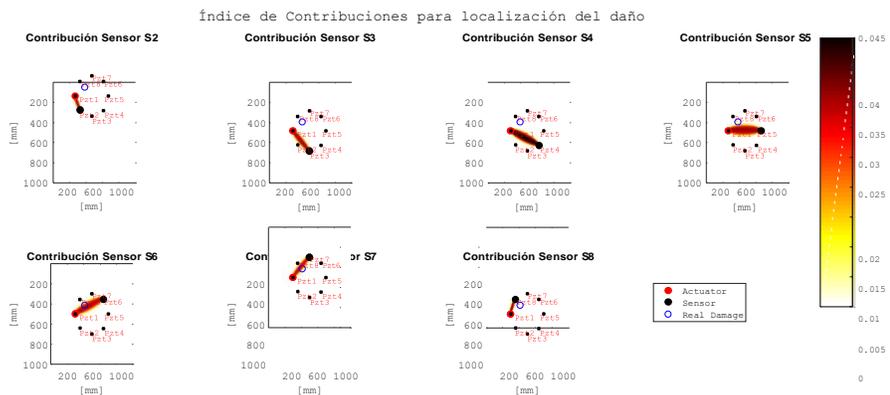
En la figura 41 se observa la distribución espacial elíptica normal entre pares de

Figura 40. Contribuciones de índice Q para el estado sin daños



sensores escalada por las contribuciones de índice estadístico Q obtenido del modelo de línea base construido con PZT-1 operando como actuador. En la imagen se identifican las rutas de mayor aporte alrededor del sensor 4, acorde a las contribuciones obtenidas en la figura 40.

Figura 41. RAPID con índice Q para daño (D1)



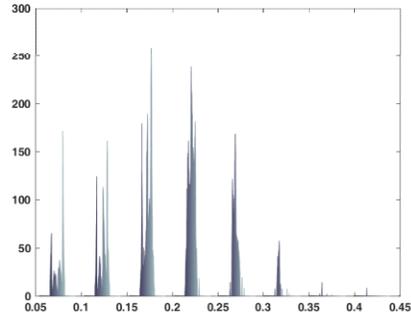
Según los resultados de la figura 41, las contribuciones más altas corresponden a rutas cercanas de la ubicación del daño. En la figura 42 se muestra la imagen con la

suma de todas las contribuciones para cada par actuador sensor, correspondiente al análisis del primer escenario de daños (D1).

Según los resultados en la figura 42, se demuestra la capacidad del algoritmo pro-

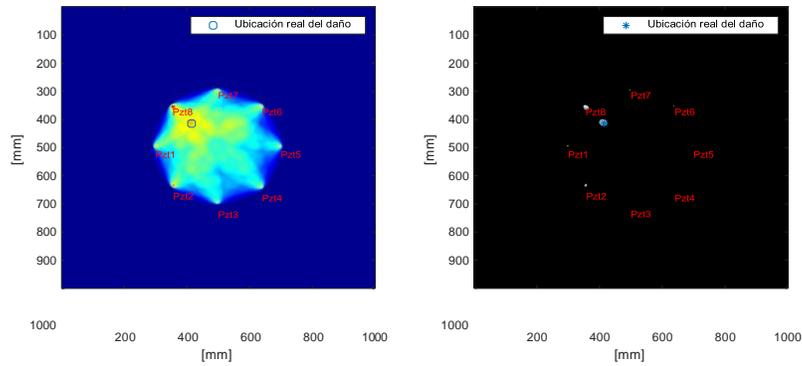
Figura 42. Imagen para escenario de daño D1

(a) D1: 3/8"(10mm)



(b) D1: 3/8"(10mm)

Imagen para la condición de daño (D1 diil 3/8 inch (10mm))



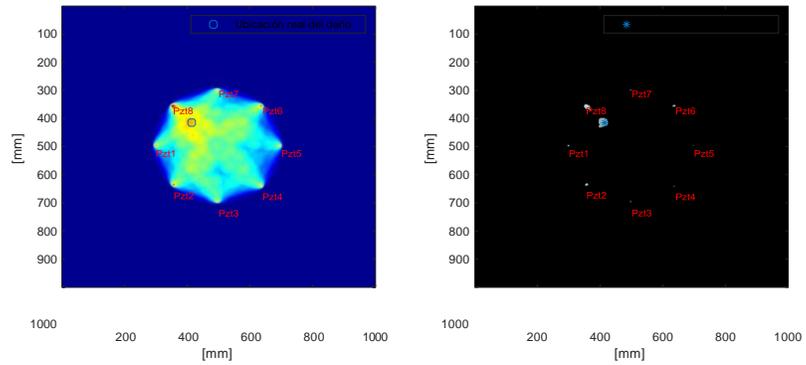
puesto e localizar daños en láminas. Los resultados para los demás escenarios de daño estudiados se muestran en la figura 43

De acuerdo con los resultados de la figura 43, se demuestra la factibilidad de la metodología de localización de daños propuesta considerando diferentes tamaños. Sin embargo, a pesar que los dos métodos para calcular las contribuciones permiten obtener una imagen representativa de la localización del daño, se obtienen mejores resultados para el caso cuando se utilizan modelos de línea base MonoActuación/Multisensado.

Figura 43. RAPID con índice Q para el estado con daños

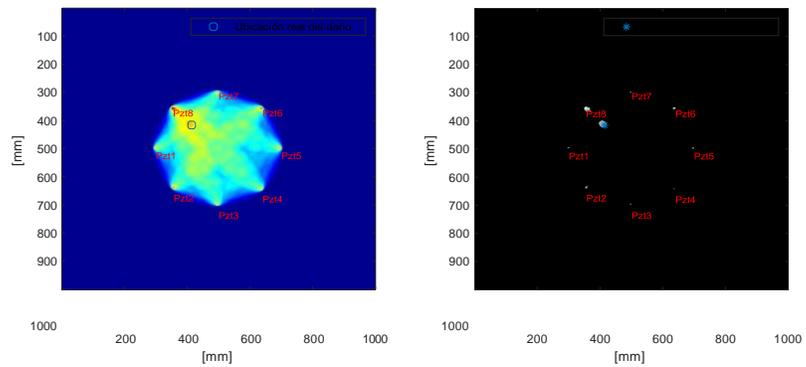
(a) D2: 7/16"(11mm)

Imagen para la condicion de daño(D2 dill 7/16 inch (11mm))



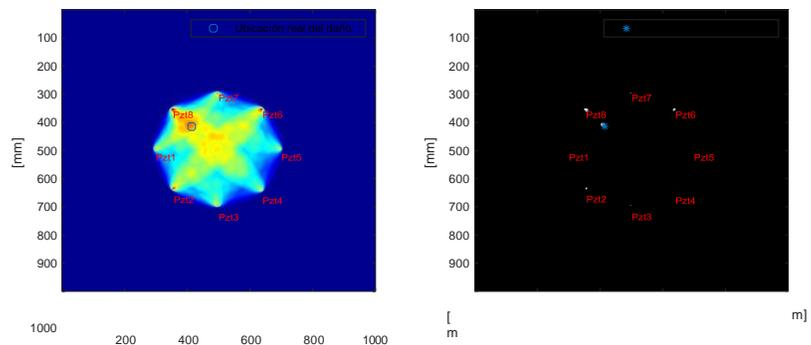
(b) D3: 9/16"(14mm)

Imagen para la condicion de daño (D3 dill 9/16 inch (14mm))



(c) D4: 1"(25.4mm)

Imagen para la condicion de daño (D4 dill 1 inch (25.4mm))



1000

200 400 600 800 1000
[mm]

5. Conclusiones y trabajo futuro

5.1. CONCLUSIONES GENERALES

- Se presentó un sistema experto híbrido para detección y localización de daños en estructuras laminares bajo el enfoque de *Ensemble Learning*, lo que permitió robustecer ante condiciones externas tales como temperatura.
- La metodología desarrollada combina índices estadísticos obtenidos mediante piezodiagnos, correlación cruzada y modelos de línea base lineales y no lineales en un esquema paralelo de *Ensemble Learning* aplicable a monitorización continua de defectos en estructuras laminares.
- La robustez de la metodología desarrollada fue experimentalmente validada en una estructura laminar de aluminio mostrando su capacidad para detección y localización de daños tipo agregación de masa, perforaciones y cortes. La factibilidad para operación continua del sistema fue evaluada en condiciones de laboratorio variantes en temperatura y humedad durante un periodo mayor a 24 horas.
- Diferentes índices basados en el error respecto a un modelo de línea base de la estructura sin daño fueron evaluados. Análisis de componentes principales lineal, no lineal y autoencoders fueron implementados para la extracción de características de la condición estructural (con daño / sin daño). Así, índices robustos fueron obtenidos con la capacidad de detectar defectos en la estructura de manera más distinguible reduciendo la generación de falsas alarmas y minimizando diagnósticos erróneos. Como resultado se mejora la diferenciación entre condiciones de daño y sin daños a través de un esquema de *Ensemble Learning*, donde el diagnóstico de varios subsistemas se combina

para obtener una frontera de decisión más distinguible definido por los índices de daño.

- Una versión adaptada del algoritmo de reconstrucción probabilística para inspección de daño (RAPID) fue desarrollada y experimentalmente validada demostrando su capacidad para localización de defectos en estructuras laminares. Un enfoque de *Ensemble Learning* fue utilizado permitiendo combinar índices de error obtenidos de parejas sensor-actuador de un esquema activo de piezo-diagnóstico.

5.2. TRABAJOS FUTUROS

- Evaluación e implementación de métodos para cuantificación y pronóstico de daños con el objetivo de mejorar la capacidad del sistema de monitorización de estructuras.
- Validación experimental para otros tipos de daños como corrosión y evaluación en otros tipos de estructuras como tuberías, puentes, entre otros.
- Adaptación de la arquitectura de *Ensemble Learning* usando otros algoritmos base mediante técnicas de análisis en tiempo-frecuencia y métodos alternativos para construcción de modelos de línea base.
- Implementación de métodos de combinación adaptativos en el esquema de *Ensemble Learning*.
- Estudios adicionales respecto al sistema de alimentación, acoplamiento, degradación de los sensores, propiedades de envejecimiento y factores operacionales y ambientales adicionales para monitorización continua.

BIBLIOGRAFÍA

ANAYA, M., D. A. TIBADUIZA y F. POZO. "A bioinspired methodology based on an artificial immune system for damage detection in structural health monitoring". En: *Shock and vibration 2015* (2015) (vid. pág. 53).

BREIMAN, L. "Bagging predictors". En: *Machine learning* 24.2 (1996), págs. 123-140 (vid. págs. 46, 48, 107).

— "Random forests". En: *Machine learning* 45.1 (2001), págs. 5-32 (vid. págs. 46, 48, 107).

CANDELIERI, A. y col. "A hyper-solution framework for SVM classification: Improving damage detection on helicopter fuselage panels". En: *AASRI Procedia* 4 (2013), págs. 31-36 (vid. pág. 108).

CANDELIERI, A. y col. "A Hyper-solution SVM Classification Framework: Application to On-line Aircraft Structural Health Monitoring". En: *Procedia - Social and Behavioral Sciences* 108 (2014), págs. 57-68 (vid. pág. 18).

CAWLEY, P. y D. ALLEYNE. "The use of Lamb waves for the long range inspection of large structures". En: *Ultrasonics* 34.2-5 (1996), págs. 287-290 (vid. pág. 28).

CERAMTEC.ES [Anónimo]. (2016). *Conceptos básicos de la tecnología piezocerámica*. [online] Available at: <http://www.ceramtec.es/materiales-ceramicos/piezoceramica/basi> (vid. págs. 23, 61).

CHEN, L., M. TAMER y V. ORIA. "Robust and Fast Similarity Search for Moving Object Trajectories". En: *Proceedings of the 2005 ACM SIGMOD International*

Conference on Management of Data. SIGMOD '05. Baltimore, Maryland: ACM, 2005, págs. 491-502 (vid. pág. 38).

CROXFORD, A. J. y col. "Strategies for guided-wave structural health monitoring". En: *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 463.2087 (2007), págs. 2961-2981 (vid. pág. 26).

DIETTERICH, T. G. "Ensemble Methods in Machine Learning". En: *Multiple Classifier Systems*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000, págs. 1-15 (vid. pág. 106).

EBRAHIMKHANLOU, A., B DUBUC y S. SALAMONE. "Damage localization in metallic plate structures using edge-reflected lamb waves". En: *Smart Materials and Structures* 25.8 (2016) (vid. pág. 40).

FERNANDEZ, A. *Curso::Reconocimiento De Patronos 2016*. <https://eva.fing.edu.uy/course/view.php?id=514/>. [Online; accessed 19-July-2016]. 2016 (vid. pág. 103).

GANDHI, N. "Determination of dispersion curves for acoustoelastic Lamb wave propagation". Tesis doct. Georgia Institute of Technology, 2010 (vid. pág. 25).

HASTIE, T., R. TIBSHIRANI y J. FRIEDMAN. *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media, 2009 (vid. pág. 48).

HOFFMANN, H. "Kernel PCA for novelty detection". En: *Pattern recognition* 40.3 (2007), págs. 863-874 (vid. pág. 36).

IKONOMOVSKA, E. "Algorithms for learning regression trees and ensembles on evolving data streams". Tesis doct. Doctoral Dissertation, 2012 (vid. págs. 46, 48).

JACKSON, J. E. "PCA with more than two variables". En: *User's Guide to Principal Component Analysis* (1991), págs. 26-62 (vid. pág. 37).

JACOBS, R. A. y col. "Adaptive mixtures of local experts." En: *Neural computation* 3.1 (1991), págs. 79-87 (vid. pág. 109).

JGVISUALSPLASH.COM. [Anónimo]. (2016). *JG Visual Splash Available at: <http://jgvisualsplash>* (vid. pág. 24).

JORDAN, M. I. y R. A. JACOBS. "Hierarchical mixtures of experts and the EM algorithm". En: *Neural computation* 6.2 (1994), págs. 181-214 (vid. pág. 111).

KESSLER, S. S., S. M. SPEARING y C. SOUTIS. "Damage detection in composite materials using Lamb wave methods". En: *Smart Materials and Structures* 11.2 (2002), pág. 269 (vid. pág. 23).

LEMPRIERE, B. M. *Ultrasound and elastic waves: frequently asked questions*. Elsevier, 2003 (vid. pág. 25).

LEVINE, R. M. y J. E. MICHAELS. "Model-based imaging of damage with Lamb waves via sparse reconstruction". En: *The Journal of the Acoustical Society of America* 133.3 (2013), págs. 1525-1534 (vid. pág. 39).

LIU, G. y col. "Baseline Signal Reconstruction for Temperature Compensation in Lamb Wave-Based Damage Detection". En: *Sensors* 16.8 (2016), pág. 1273 (vid. págs. 29, 41).

LIU, Z. y H. CHEN. "Application and Challenges of Signal Processing Techniques for Lamb Waves Structural Integrity Evaluation: Part B-Defects Imaging and Recognition Techniques". En: *Structural Health Monitoring from Sensing to Processing* September (2018) (vid. pág. 40).

LIU, Z. y col. "Baseline-free delamination inspection in composite plates by synthesizing non-contact air-coupled Lamb wave scan method and virtual time reversal algorithm". En: *Smart Materials and Structures* 24.4 (2015), pág. 045014 (vid. pág. 40).

LU, G. y col. "A multi-delay-and-sum imaging algorithm for damage detection using piezoceramic transducers". En: *Journal of Intelligent Material Systems and Structures* 28 (sep. de 2016) (vid. pág. 41).

LU, Y. y J. E. MICHAELS. "A methodology for structural health monitoring with diffuse ultrasonic waves in the presence of temperature variations". En: *Ultrasonics* 43.9 (2005), págs. 717-731 (vid. pág. 25).

MALINOWSKI, P. y col. "A phased array-based method for damage detection and localization in thin plates". En: *Structural Health Monitoring* 8.1 (2009), págs. 5-15 (vid. pág. 41).

MALYARENKO, E. V. y M.K. HINDERS. "Fan beam and double crosshole Lamb wave tomography for mapping flaws in aging aircraft structures". En: *The Journal of the Acoustical Society of America* 108.4 (2000), págs. 1631-1639 (vid. pág. 41).

MANDAYAM, S., R. POLIKAR y J. C. CHEN. *A data fusion system for the nondestructive evaluation of non-piggable pipes*. Inf. téc. Rowan University (US), 2005 (vid. pág. 108).

MAVI, G.S. y S. SHARMA. "FEASIBILITY OF USING ULTRASONIC GUIDED WAVES FOR UNDER WATER PIPE INSPECTION". Tesis doct. MED, TU, 2013 (vid. págs. 23, 24).

MCKEON, J. C. y M. K. HINDERS. "Parallel projection and crosshole Lamb wave contact scanning tomography". En: *The Journal of the Acoustical Society of America* 106.5 (1999), págs. 2568-2577 (vid. pág. 41).

MICHAELS, J. E., A. J. CROXFORD y P.D. WILCOX. "Imaging Algorithms for Locating Damage via in Situ Ultrasonic Sensors". En: *Proc. of IEEE Sensors Applications Sym.* 3 (2008), págs. 63-67 (vid. pág. 41).

MICHAELS, J. E. y T. E. MICHAELS. "Guided wave signal processing and image fusion for in situ damage localization in plates". En: *Wave Motion* 44.6 (2007), págs. 482-492 (vid. pág. 29).

MINSKY, M. L. "Logical versus analogical or symbolic versus connectionist or neat versus scruffy". En: *AI magazine* 12.2 (1991), págs. 34-34 (vid. pág. 100).

MITRA, N. P. YELVE M. y P.M. MUJUMDAR. "Detection of delamination in composite laminates using Lamb wave based nonlinear method". En: *Composite Structures* 159 (2016), págs. 257-266 (vid. pág. 28).

MUJICA, L. E., D. A. TIBADUIZA y B. J. RODELLAR. "Data-driven multiactuator piezoelectric system for structural damage localization". En: *Fifth World Conference on Structural Control and Monitoring (5WCSCM): Tokyo, Japan: 12-14 July 2010*. 2010 (vid. pág. 29).

MUJICA, L. E. y col. "Multivariate statistics process control for dimensionality reduction in structural assessment". En: *Mechanical Systems and Signal Processing* 22.1 (2008), págs. 155-171 (vid. págs. 25, 28).

MUSTAFA, G. y N. F. CATBAS. "Statistical pattern recognition for Structural Health Monitoring using time series modeling: Theory and experimental verifications". En: *Mechanical Systems and Signal Processing* 23.7 (2009), págs. 2192 -2204 (vid. pág. 30).

OPITZ, D. y R. MACLIN. "Popular ensemble methods: An empirical study". En: *Journal of Artificial Intelligence Research* 11 (1999), págs. 169-198 (vid. pág. 100).

OSTACHOWICZ, W. y col. "Damage localisation in plate-like structures based on PZT sensors". En: *Mechanical Systems and Signal Processing* 23.6 (2009), págs. 1805-1829 (vid. pág. 22).

PAGET, C. y col. *Encyclopedia of Structural Health Monitoring, ch. Validation of SHM Sensors in Airbus A380 Full-Scale Fatigue Test*. 2009 (vid. págs. 22, 23).

PALIWAL, K.K., A. AGARWAL y S. S. SARVAJIT. "A modification over Sakoe and Chiba's dynamic time warping algorithm for isolated word recognition". En: *Signal Processing* 4.4 (1982), págs. 329 -333 (vid. pág. 37).

PARIKH, D y col. "Combining classifiers for multisensor data fusion". En: *2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No. 04CH37583)*. Vol. 2. IEEE. 2004, págs. 1232-1237 (vid. pág. 107).

PERU-V [Anónimo]., Â«Materiales piezoeléctricos,Â» [En línea]. Available: <http://www.ingenieria v.com> (vid. pág. 24).

POLIKAR, R. "Ensemble based systems in decision making". En: *IEEE Circuits and systems magazine* 6.3 (2006), págs. 21-45 (vid. pág. 100).

— "Ensemble based systems in decision making". En: *IEEE Circuits and Systems Magazine* 6.3 (2006), págs. 21-45 (vid. pág. 106).

ROKACH, L. "Ensemble-based classifiers". En: *Artificial Intelligence Review* 33.1-2 (2010), págs. 1-39 (vid. págs. 100, 107).

ROSE, J. L. *Ultrasonic waves in solid media*. 2000 (vid. pág. 25).

S. KHODAEI, Z y M. H. ALIABADI. "Assessment of delay-and-sum algorithms for damage detection in aluminium and composite plates". En: *Smart Materials and Structures* 23.7 (2014), pág. 75007 (vid. págs. 41, 43).

SALMANPOUR, M., Z. S. KHODAEI y M. H. ALIABADI. "Guided wave temperature correction methods in structural health monitoring". En: (2016), págs. 1-15 (vid. pág. 40).

SALMANPOUR, M., Z. SHARIF y M. ALIABADI. "Guided wave temperature correction methods in structural health monitoring". En: *Journal of Intelligent Material Systems and Structures* (2016), págs. 1-15 (vid. pág. 41).

SCHÖLKOPF, B., A. SMOLA y K. R. MÜLLER. "Nonlinear component analysis as a kernel eigenvalue problem". En: *Neural computation* 10.5 (1998), págs. 1299-1319 (vid. pág. 34).

SCHOLZ, M. "Validation of nonlinear PCA". En: *Neural processing letters* 36.1 (2012), págs. 21-30 (vid. págs. 33, 34).

SCHUBERT, K. y col. "Analytical and Experimental Investigation of Environmental Influences on Lamb Wave Propagation and Damping Measured with a Piezo- Based System". En: *6th European Workshop on Structural Health Monitoring* 49 (2012), págs. 1-9 (vid. pág. 24).

SERWAY, R. A. y J. W. JEWETT. *Principles of physics: a calculus-based text*. Vol. 1. Nelson Education, 2012 (vid. pág. 26).

SHEN, J. "Non-destructive evaluation using guided waves in pipe-like structures". En: *Masters Abstracts International*. Vol. 51. 02. 2012 (vid. pág. 24).

SOHN, H. "Effects of environmental and operational variability on structural health monitoring." En: *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences* 365.1851 (2007), págs. 539-560 (vid. pág. 18).

SUMIJAN, S. *Ensemble Learning Model selection Statistical validation*. https://www.academia.edu/33583143/Ensemble_Learning_Model_selection_Statistical_validation. [Online; accessed 30-July-2018]. 2016 (vid. pág. 112).

TIAN, Z. "Guided Wave Based Integrated Structural Health Monitoring and Nondes- tructive Evaluation". En: (2015) (vid. pág. 40).

TIBADUIZA, D. "Combined and I indices based on principal component analysis for damage detection and localization". En: (2012) (vid. págs. 28, 29).

WANG, M. L., J. P. LYNCH y H. SOHN. *Sensor Technologies for Civil Infrastructures: Sensing Hardware and Data Collection Methods for Performance Assessment*. Woodhead Publishing Series in Electronic and Optical Materials. Elsevier Scien- ce, 2014 (vid. pág. 23).

WEBB, A. R. *Statistical pattern recognition*. John Wiley & Sons, 2003 (vid. págs. 108, 109).

WESTERHUIS, J. A., S. P. GURDEN y A. K. SMILDE. "Standardized Q-statistic for improved sensitivity in the monitoring of residuals in MSPC". En: *Journal of Chemometrics* 14.4 (2000), págs. 335-349 (vid. pág. 36).

WOLPERT, D. H. "Stacked generalization". En: *Neural networks* 5.2 (1992), págs. 241-259 (vid. pág. 109).

YANG, Y. y S. NAGARAJAIAH. "Blind identification of damage in time-varying systems using independent component analysis with wavelet transform". En: *Mechanical Systems and Signal Processing* 47.1-2 (2014), págs. 3-20 (vid. pág. 28).

ZHAO, G. y col. "Active health monitoring of an aircraft wing with embedded piezoelectric sensor/actuator network: I. Defect detection, localization and growth monitoring". En: *Smart Materials and Structures* 16 (jun. de 2007), pág. 1208 (vid. pág. 42).

ANEXOS

Anexo A. *Ensemble Learning*:

Terminología y conceptos básicos

La resolución de problemas realmente difíciles se aborda mediante representaciones diferentes que genera incertidumbre sobre qué tipo de técnica de reconocimiento de patrones es mejor. Así, es necesario construir sistemas de gestión para explotar las virtudes de los diferentes algoritmos y minimizar las limitaciones de cada uno de ellos ⁵⁴. *Ensemble Learning* puede ser considerada como una metodología de meta-algoritmos cuya idea principal es combinar varios modelos para mejorar el rendimiento de predicción. También se conoce en la literatura con varias palabras clave: *Ensembles*, métodos de conjunto, métodos de aprendizaje en conjunto, combinación de modelos, combinación de clasificadores, clasificadores múltiples, sistemas de clasificación múltiple, votación por mayoría o mezclas de expertos ⁵⁵⁵⁶⁵⁷. El enfoque tradicional de aprendizaje automático consiste en los siguientes pasos:

- i. Seleccionar un modelo de una clase de modelos a ser usado para el problema en particular.

⁵⁴ M. L. MINSKY. "Logical versus analogical or symbolic versus connectionist or neat versus scruffy". En: *AI magazine* 12.2 (1991), págs. 34-34.

⁵⁵ R. POLIKAR. "Ensemble based systems in decision making". En: *IEEE Circuits and systems magazine* 6.3 (2006), págs. 21-45.

⁵⁶ D. OPITZ y R. MACLIN. "Popular ensemble methods: An empirical study". En: *Journal of Artificial Intelligence Research* 11 (1999), págs. 169-198.

⁵⁷ L. ROKACH. "Ensemble-based classifiers". En: *Artificial Intelligence Review* 33.1-2 (2010), págs. 1-39.

- II. Ajustar el modelo a los datos de entrenamiento.
- III. Predecir la respuesta del modelo usando datos de prueba

Por otra parte, el enfoque de *Ensemble Learning* consiste en los siguientes pasos:

- I. Seleccionar un conjunto de modelos a ser usado para el problema en particular.
- II. Obtener un modelado base mediante el ajuste de múltiples modelos (conjunto) a los datos de entrenamiento.
- III. Usar el conjunto de modelos para predicción en datos de prueba mediante un esquema de votación similar a un comité de expertos.

Considerando las características de cada enfoque, se podría definir *Ensemble Learning* como una metodología que utiliza un conjunto de modelos, cada uno de ellos obtenido al aplicar un proceso de aprendizaje a un problema dado. Luego, este conjunto de modelos es integrado (combinado) de alguna manera para obtener la predicción final usando por ejemplo un sistema de votación.

Ventajas de *Ensemble Learning*

La metodología de *Ensemble Learning* es adecuada para gestionar algunos problemas cuando hay grandes o poco volumen de datos disponibles para el entrenamiento de un modelo. Además, *Ensemble Learning* es útil para integrar características de diversas fuentes de información, que sirve como un simple esquema de fusión de datos. Hay varias razones teóricas y prácticas que muestran que la eficiencia y la precisión de los sistemas expertos (incluyendo SHM) se maximizan mediante el uso de la metodología de *Ensemble Learning*:

- I. Razones estadísticas

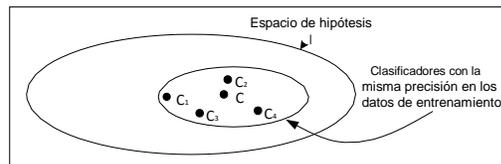
La selección del mejor modelo para solucionar un problema requiere identificar la complejidad apropiada del modelo. Desafortunadamente, no existe un modelo dominante para todas las distribuciones de datos ("no free lunch" theorem) y usualmente la distribución de los datos es desconocida. Por ejemplo, si se comparan dos modelos, uno con una precisión 10 % mayor que el otro, no es posible determinar con certeza cuál de los dos modelos es realmente mejor dado que su precisión es evaluada de manera estadística sobre un conjunto de datos de prueba. En este sentido, no es posible garantizar que sobre un conjunto de prueba completamente diferente el desempeño de los modelos será completamente igual y siempre existirá variabilidad en los resultados. Por tanto, para un problema dado, es necesario abordar aspectos relacionados con la selección apropiada del algoritmo de acuerdo al nivel de confianza de la respuesta del modelo. Típicamente, dos aproximaciones pueden ser usadas:

- Seleccionar según algún criterio el algoritmo más adecuado para el problema
- Adaptar los datos para mejorar el desempeño del algoritmo aplicando métodos de pre-procesamiento.

No obstante, el concepto de algoritmo apropiado depende del problema. Por ejemplo, en aplicaciones médicas los criterios para selección de modelos se basan en su capacidad de interpretación. Así, se prefieren modelos basados en árboles de decisión y redes bayesianas. En contraste, para aplicaciones de logística es más importante la precisión en la predicción del tiempo de viaje, que corresponde a un criterio más determinístico formulado mediante el error cuadrático medio por ejemplo. Mediante *Ensemble Learning* es posible manejar aspectos como la selección de un modelo mediante la combinación de respuestas individuales de algoritmos aplicables a la solución del problema (ver figura 44), ya que es más probable que el promedio de un conjunto de modelos tenga mejor desempeño que la selección de

un solo modelo; dada la baja probabilidad de seleccionar el mejor dentro de un conjunto de modelos. Así, mediante la combinación de las respuestas individuales de cada modelo se reduce el riesgo de seleccionar el modelo de más bajo desempeño.

Figura 44. Distribución de modelos solución de un problema

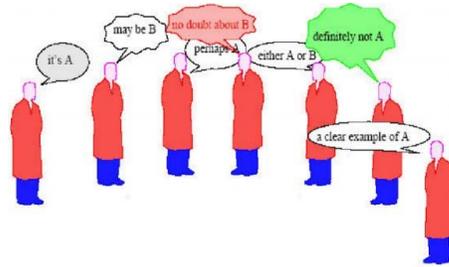


Ensemble Learning puede ser visto como un comité de expertos en forma análoga al proceso de diagnóstico médico realizado por un comité de especialistas como se ilustra en la Figura 45). Un sistema de diagnóstico que utiliza un conjunto (*Ensemble*) de respuestas, reduce el riesgo de una baja generalización obtenida mediante un solo modelo construido sobre un conjunto de datos específico y un espacio de generalización particular.

Por otra parte, el error no correlacionado de diferentes algoritmos de diagnóstico (clasificación o regresión) puede ser eliminado a través de un simple promedio. Por ejemplo, asúmase un problema de clasificación binaria para el cual se entrenan 21 clasificadores cada uno con un error del 30 % (0.3). Para este sistema, se construye un *Ensemble* combinando la predicción de los 21 clasificadores mediante un sistema de clasificación por mayoría de votos. Para que el *Ensemble* clasifique erróneamente un caso de ejemplo, 11 o más clasificadores (la mitad más uno) deben predecir

⁵⁸ A. FERNANDEZ. *Curso::Reconocimiento De Patrones 2016*. <https://eva.fing.edu.uy/course/view.php?id=514/>. [Online; accessed 19-July-2016]. 2016.

Figura 45. *Ensemble Learning* como comité de expertos



Fuente: 58.

erróneamente la respuesta; lo que resulta en una probabilidad de error de 0.026 para todo el *Ensemble*.

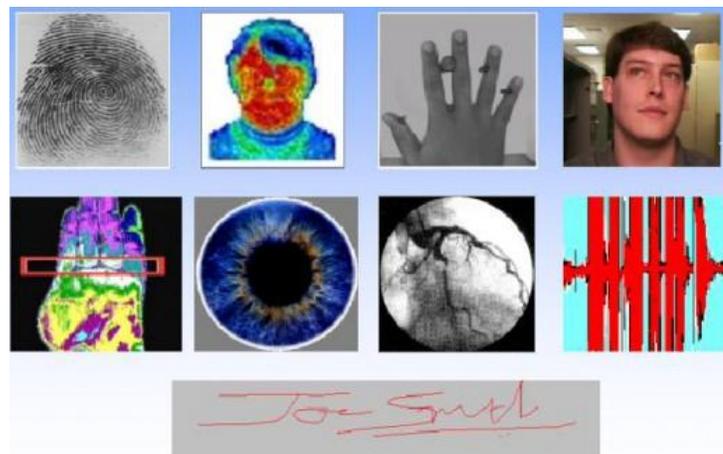
ii. Gran diversidad y características de los datos

Por lo general, entrenar un sistema de reconocimiento de patrones con una cantidad grande de datos no es práctico; así, un enfoque más eficiente consiste en dividir los datos en sub-conjuntos más pequeños y entrenar diferentes algoritmos con cada una de las diferentes particiones de datos y luego combinar sus salidas utilizando una regla de combinación. Por ejemplo, la inspección de las tuberías de transporte de gas utilizando técnicas de fuga de flujo magnético genera 10 GB de datos por cada 100 km de tubería, de los cuales hay más de 2 millones de km. En contraparte, los modelos de aprendizaje funcionan bien cuando hay disponible un conjunto de datos representativo (tamaño de muestra estadísticamente significativo), de modo que los errores estimados permitan obtener un algoritmo con un error de generalización adecuado. Así, para el caso cuando el tamaño de muestra es pequeño, es posible evitar de manera intuitiva la obtención de modelos con bajo error de generalización, por ejemplo, promediando algoritmos individuales obtenidos con sub-conjunto de datos. Asimismo, *Ensemble Learning* permite abordar problemas generados al tratar con problemas en los que existe pérdida de datos (*Missing*

Data). Para ello, se realiza la adaptación de técnicas de re-muestreo y se diseñan sistemas de respuesta basados en la combinación o promedio de decisiones. Las técnicas de re-muestreo permiten construir sub-conjuntos aleatorios superpuestos a partir de los datos disponibles, cada uno de los cuales se puede usar para entrenar un algoritmo diferente y crear un *Ensemble*.

Por otra parte, *Ensemble Learning* puede ser usada como técnica de fusión de datos en problemas que existe disponibilidad de varios conjuntos de datos obtenidos de diversas fuentes, donde la naturaleza de las características son diferentes (características heterogéneas). En este tipo de problemas no se puede usar un solo algoritmo para aprender la información contenida en todos los datos y se requiere de una metodología que permita combinar las respuestas de algoritmos entrenados para cada tipo de característica aprovechando las ventajas individuales. Por ejemplo, para el reconocimiento e identificación de personas es posible construir un *Ensemble* aprovechando las diferentes fuentes de información extraídas de la voz, iris y huellas entre otros (ver figura 46).

Figura 46. Fuentes de información para identificación y reconocimiento de personas

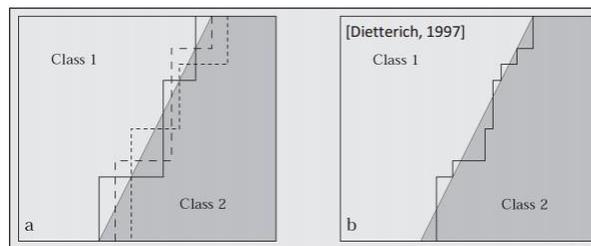


Fuente: 58.

III. Complejidad del problema

Para diferentes problemas de reconocimiento de patrones, la frontera de decisión o función objetivo puede no ser implementable con un solo algoritmo, pero puede ser aproximada por un *Ensemble* (conjunto). Así, un problema complejo puede descomponerse en múltiples sub-problemas que son más fáciles de resolver (divide y conquistarás). Por ejemplo, es posible aproximar una frontera de decisión no lineal usando árboles de decisión mediante la combinación de los hiperplanos lineales (paralelos a los ejes de coordenadas) obtenidos con varios modelos como se ilustra en la figura 47. .

Figura 47. Aproximación de una frontera no lineal usando un *Ensemble* de árboles de decisión.



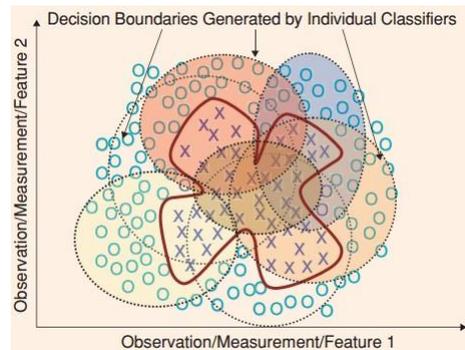
Fuente: 59.

Otro ejemplo es ilustrado en la Figura 48, en el que se aproxima una frontera de decisión altamente no lineal a partir de modelos no lineales simples que consisten de fronteras circulares.

⁵⁹ T. G. DIETTERICH. "Ensemble Methods in Machine Learning". En: *Multiple Classifier Systems*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000, págs. 1-15.

⁶⁰ R. POLIKAR. "Ensemble based systems in decision making". En: *IEEE Circuits and Systems Magazine* 6.3 (2006), págs. 21-45.

Figura 48. Aproximación de una frontera altamente no lineal mediante un *Ensemble* no lineal circular.



Fuente: 60.

En cierto sentido, el sistema sigue un enfoque de divide y vencerás dividiendo el espacio de datos en particiones más pequeñas y fáciles de aprender, donde cada algoritmo aprende solo una de las particiones más simples. Así, la frontera de decisión compleja puede ser aproximada por la apropiada combinación de diferentes algoritmos.

Topologías de *Ensemble Learning*

La implementación de metodologías de *Ensemble Learning* ha sido reportada en la literatura usando diferentes topologías (o taxonomía). Por ejemplo, algunos autores referencian aplicaciones implementadas como la combinación de múltiples modelos ⁵⁷⁴⁹⁵⁰, en otras aplicaciones se combina diferentes clasificadores ⁶¹, en otras aplica-

⁶¹ D PARIKH y col. "Combining classifiers for multisensor data fusion". En: *2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No. 04CH37583)*. Vol. 2. IEEE. 2004, págs. 1232-1237.

ciones se propone un comité de expertos ⁶² y otras implementaciones usan fusión de clasificadores ⁶³. Esto se debe a que la filosofía de *Ensemble Learning* no es solo la combinación de clasificadores, sino también de diferentes modelos, tipos de características, métodos o cualquier otra combinación que permita mejorar la precisión de un sistema experto. En esta sección se describen las principales arquitecturas y estrategias de combinación para *Ensemble Learning* reportadas en la literatura.

I. Tipos de arquitectura

Las principales arquitecturas de *Ensemble Learning* para definir su estructura pueden ser resumidas en 4 tipos: Paralelo, cascada o jerárquico, apilado generalizado y mixtura de expertos. En la figura 49 se detallan las arquitecturas paralelo y serie o cascada de *Ensemble Learning*. Para el caso de topología paralelo, todos los algoritmos se invocan de manera independiente, y sus resultados se fusionan con una regla de combinación (por ejemplo, promedio, votación ponderada) o un metaclasificador (por ejemplo, un algoritmo de generalización que combine los resultados individuales). La mayoría de los enfoques de *Ensemble Learning* reportados en la literatura pertenecen a esta categoría. Por otra parte, en el esquema cascada o jerárquico los algoritmos se invocan de forma secuencial o estructurada en árbol. En aras de la eficiencia, primero se invocan métodos inexactos pero rápidos (quizás utilizando un pequeño sub-conjunto de las características), y se dejan métodos computacionalmente más intensivos pero precisos para la última etapa. .

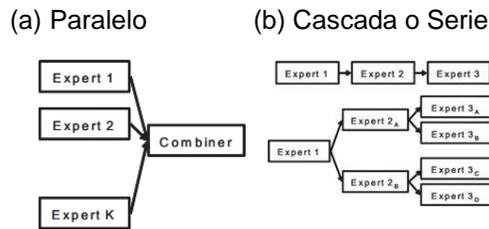
En la figura 50 se detallan las arquitecturas de generalización apilada y mezcla de

⁶² A. CANDELIERI y col. "A hyper-resolution framework for SVM classification: Improving damage detection on helicopter fuselage panels". En: *AASRI Procedia* 4 (2013), págs. 31-36.

⁶³ S. MANDAYAM, R. POLIKAR y J. C. CHEN. *A data fusion system for the nondestructive evaluation of non-piggable pipes*. Inf. téc. Rowan University (US), 2005.

⁶⁴ A. R. WEBB. *Statistical pattern recognition*. John Wiley & Sons, 2003.

Figura 49. Arquitecturas de *Ensemble Learning*



Fuente: 64.

expertos de *Ensemble Learning*. En la topología de generalización apilada, la salida del *Ensemble* sirve como entrada para un sistema experto de segundo nivel ⁶⁵. Por otra parte, la Mezcla de Expertos (ME) corresponde al método adaptativo clásico para *Ensemble Learning*. En ME se utiliza inicialmente una red de compuerta (Gating Network) para dividir el espacio de características en diferentes regiones, con un experto en el *Ensemble* responsable de generar la salida correcta dentro de esa región ⁶⁶. Los expertos en el *Ensemble* y la red de compuerta se entrenan simultáneamente. ME puede extenderse a una estructura jerárquica de multinivel, donde cada componente es en sí mismo un ME. En este caso, se puede usar una red lineal para los clasificadores terminales sin comprometer las capacidades de modelado del sistema. .

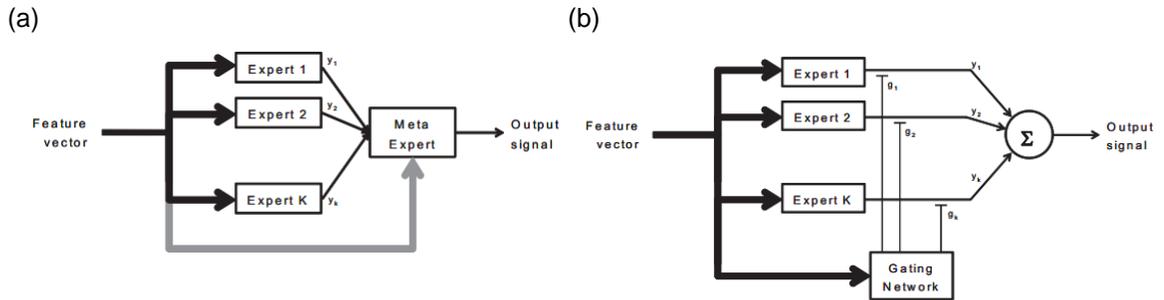
II. Estrategias de combinación

Las principales estrategias de combinación usadas en *Ensemble Learning* son descritas según el método de implementación y el manejo dado al espacio de carac-

⁶⁵ D. H. WOLPERT. "Stacked generalization". En: *Neural networks* 5.2 (1992), págs. 241-259.

⁶⁶ R. A. JACOBS y col. "Adaptive mixtures of local experts." En: *Neural computation* 3.1 (1991), págs. 79-87.

Figura 50. Arquitectura apilada y mezcla de *Ensemble Learning*



Fuente: 66.

terísticas (*Features*). Según el método las respuestas del *Ensemble* pueden ser combinadas usando estrategias algebraicas o mediante un sistema de votación, mientras que de acuerdo al manejo del espacio de características el *Ensemble* puede implementar un esquema de combinación estática o adaptativa.

Los principales métodos algebraicos incluyen promedio, suma, promedio y suma ponderada, producto, máximo, mínimo, y mediana de las respuestas individuales de los algoritmos que constituyen el Ensemble. Los métodos de votación incluyen votación por mayoría simple o ponderada, y cuenta de borda en el que se organizan las respuestas por rango en orden de preferencia.

Por otra parte, en un esquema de combinación estática las reglas de decisión son independientes del vector de características. Específicamente, puede ser implementado un sistema de votación independiente del desempeño para cada uno de los algoritmos del Ensemble (mayoría simple, promedio o cuenta de borda) o se puede construir un combinador que implemente una fase de entrenamiento separada para mejorar el desempeño del *Ensemble* (promedio ponderado, generalización apilada). Por otra parte, un combinador adaptativo consiste de una función que depende del

vector de características. Así, el *Ensemble* implementa una función que es local a cada región en el espacio de características. Por ejemplo, la aproximación divide y conquistarás, permite la obtención de un *Ensemble* modular donde algoritmos relativamente simples se especializan en diferentes partes del espacio de características. En contraste con esquemas de combinación estáticos, cada algoritmo del *Ensemble* no requiere un alto desempeño para todas las entradas si no únicamente para la región de experticia ⁶⁷.

Diseño de un sistema experto basado en *Ensemble Learning*

Un sistema experto basado en *Ensemble Learning* está caracterizado por los siguientes componentes:

- La arquitectura/topología: paralelo, serial, híbrido.
- Los algoritmos del Ensemble: Tipo y número de algoritmos base. El Ensemble puede ser sub-dividido en sub-conjuntos para el caso de arquitectura no paralelo.
- Combinador: Selección del método de combinación y estrategia para manejo del espacio de características.

En este sentido, el objetivo de un sistema experto basado en la metodología de *Ensemble Learning* es abordar el problema respecto a la selección del mejor conjunto de características y el mejor algoritmo. Así, en lugar de buscar el mejor algoritmo, se usa un método de combinación para obtener una mayor precisión aprovechando la incertidumbre y diversidad de diferentes algoritmos independientes. Los algoritmos base deben ser lo más precisos posible y tener diversos errores.

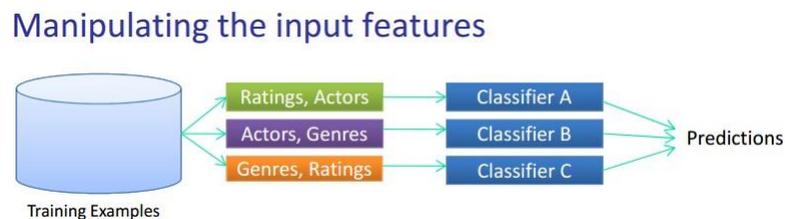
⁶⁷ M. I. JORDAN y R. A. JACOBS. "Hierarchical mixtures of experts and the EM algorithm". En: *Neural computation* 6.2 (1994), págs. 181-214.

1. Métodos para creación de un Ensemble

La creación de un *Ensemble* requiere que los algoritmos base (*Learners*) no sean idénticos y que exista diversidad. En este sentido, si todos los modelos son idénticos no se obtiene beneficio así como el desacuerdo total y el acuerdo total son obviamente malos. Por ejemplo, los clasificadores inestables se usan como modelos base, ya que pueden generar fronteras de decisión suficientemente diferentes incluso para pequeñas perturbaciones en sus parámetros de entrenamiento. Los miembros del Ensemble deben estar en desacuerdo y la medida de desacuerdo se llama diversidad. Los métodos para generación de un Ensemble pueden ser agrupados en 4 categorías:

- a. **Manipulación de datos:** Se generan múltiples modelos al entrenar algoritmos individuales usando diferentes conjuntos de datos obtenidos al volver a muestrear un conjunto de entrenamiento común (*Bagging, Boosting*).

Figura 51. Manipulación de datos:

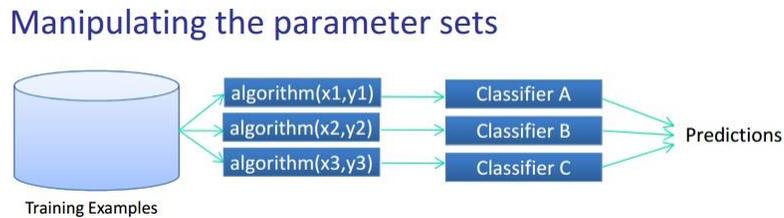


Fuente: 68.

⁶⁸ S. SUMIJAN. *Ensemble Learning Model selection Statistical validation*. https://www.academia.edu/33583143/Ensemble_Learning_Model_selection_Statistical_validation. [Online; accessed 30-July-2018]. 2016.

- b. **Manipulación del proceso de modelado:** Se cambia el algoritmo de inducción, el conjunto de parámetros o el modelo (el último es poco común) para obtener diferentes modelos. Se crean varios algoritmos con diferentes parámetros de aprendizaje, como el número de vecinos en una regla de Vecino más cercano, los pesos iniciales en un perceptrón multicapa (MLP), etc.

Figura 52. Manipulación del proceso de modelado



Fuente: 68.

- c. **Manipulación de las características de entrada:** Se generan múltiples modelos al entrenar algoritmos individuales en diferentes representaciones o diferentes subconjuntos de un vector de características común.

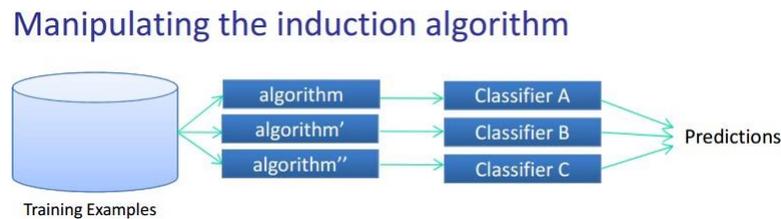
Figura 53. Manipulación de las características de entrada



Fuente: 68.

- d. **Manipulación de la respuesta:** Se generan variaciones del mismo algoritmo de inducción para crear diferentes modelos. Se pueden usar objetivos .^auxiliares.^adicionales para diferenciar los diferentes modelos.

Figura 54. Manipulación de la respuesta



Fuente: 68.

A continuación se describen los métodos para construcción de *Ensembles* más populares reportados en la literatura:

- a. **Bagging:** Consiste en realizar el promedio de la predicción sobre una colección de predictores inestables generados a partir de muestras de *Bootstrap* (clasificación y regresión).
- b. **Boosting:** Se realiza voto ponderado usando una colección de algoritmos entrenados secuencialmente a partir de conjuntos de entrenamiento, dando prioridad a los casos clasificados erróneamente (clasificación).
- c. **Random Forest:** Se promedia la predicción de una colección de árboles de decisión entrenados utilizando un subconjunto de características seleccionadas al azar (clasificación y regresión).

- d. **Random Subspace:** La idea es aleatorizar el algoritmo de aprendizaje, como elegir un subconjunto de características al azar antes de aplicar el algoritmo de entrenamiento. Cada modelo está entrenado en datos proyectados en un subespacio elegido al azar. Los resultados de los modelos se combinan, por lo general, por simple mayoría de votos.
- e. **Ensemble heterogéneo:** Combinación de un conjunto de predictores heterogéneos (clasificación y regresión)
- f. **Correlación negativa:** Generación de predictores secuencialmente nuevos correlacionados negativamente con los existentes (regresión).

Anexo B. Listado de publicaciones

Como resultado del desarrollo del presente trabajo de investigación se obtuvieron las siguientes contribuciones a en revistas especializadas y conferencias relevantes en el área de monitorización de salud estructural.

- Gustavo Moreno, Rodolfo Villamizar, Rolando Guzman, Jhonatan Camacho. **SOM network as approach for data fusion of piezo-diagnostics features and temperature measurements.** Workshop on civil structural health monitoring CSHM-7. Medellín-Colombia (Universidad Eafit). June 22nd-23rd, 2017
- Moreno Beltran, G. A., Villamizar Mejía, R., Camacho-Navarro, J., Ruiz Ordóñez, M., Mujica Delgado, L. E. **Structural damage localization through an innovative hybrid ensemble approach.** SMART 2017: ECCOMAS Thematic Conference on Smart Structures and Materials. proceedings book (pp. 1878-1889). Centre Internacional de Mètodes Numèrics en Enginyeria (CIMNE). Madrid, Espanya. June 5-8, 2017
- Rodolfo Villamizar-Mejia , Luis-Eduardo Mujica-Delgado , Magda-Liliana Ruiz Ordóñez ,Jhonatan Camacho-Navarro, Gustavo Moreno-Beltrán **Damage detection in cylindrical metallic specimens by means of statistical baseline models and updated daily temperature profiles**, 12th International Conference on Damage Assessment of Structures 10-12 July 2017, Kitakyushu, Japan Journal of Physics: Conference Series,842,1,012017,2017,IOP Publishing
- Gustavo Adolfo Moreno Beltrán, Jhonatan Camacho Navarro, Rodolfo Villamizar Mejia. **Detección y clasificación de defectos en estructuras tipo tubería mediante reconocimiento de patrones** I+D Revista de Investigaciones, Universidad de Investigación y Desarrollo - UDI, Bucaramanga - Colombia. ISSN 22561676 http://www.udi.edu.co/congreso/historial/congreso_2016/

ponencias/Ingenieria_Electronica/Deteccion_y_clasificacion_de_defectos_en_estructuras_tipo_tuberia_mediante_reconocimiento_de_patrones.pdf

- ÓSCAR PUENTES, ALEJANDRA IBARRA, RODOLFO VILLAMIZAR, GUSTAVO MORENO, JHONATAN CAMACHO. **DETECCIÓN DE DEFECTOS EN ESTRUCTURAS MEDIANTE PIEZODIAGNOSIS BASADO EN MULTIACTUACIÓN Y MODELOS DE LÍNEA BASE** Póster en FIMEC Research Day 2017, Bucaramanga, Colombia. 21 Noviembre
- Jhonatan Camacho-Navarro, Magda Ruiz, Rodolfo Villamizar, Luis Mujica, Gustavo Moreno-Beltrán and Jabid Quiroga. **Structural damage continuous monitoring by using a data driven approach based on principal component analysis and cross-correlation analysis.** Published under licence by IOP Publishing Ltd Journal of Physics: Conference Series, Volume 842, conference 1. IOP Conf. Series: Journal of Physics: Conf. Series 842 (2017) 012018 doi :10.1088/1742-6596/842/1/012018. <http://iopscience.iop.org/article/10.1088/1742-6596/842/1/012018/pdf> ISSN: 17426588
- Jhonatan Camacho-Navarro, Magda Ruiz, Rodolfo Villamizar, Luis Mujica and Gustavo Moreno-Beltrán. **Ensemble learning as approach for pipeline condition assessment.** Published under licence by IOP Publishing Ltd. Journal of Physics: Conference Series, Volume 842, conference 1 Series 842 (2017) 012018. doi :10.1088/1742-6596/842/1/012019. ISSN: 17426588. <http://iopscience.iop.org/article/10.1088/1742-6596/842/1/012019/pdf>

Anexo C. Agradecimientos

Los resultados de este trabajo de investigación hacen parte de un trabajo colaborativo entre grupo de control electrónica modelado y simulación (CEMOS) de la Universidad Industrial de Santander - UIS - (Colombia) y el grupo Control, Dynamics and Applications Laboratory (CoDALab)"de la Universitat Politècnica de Catalunya - UPC - (España). Así mismo, este proyecto de investigación fue parcialmente financiado mediante la convocatoria No.002 del Programa Generación ConCiencia, la cual estuvo dirigida a semilleros de investigación y jóvenes investigadores vinculados a grupos de investigación de universidades de Santander a través de la propuesta titulada "Técnicas estadísticas y de inteligencia artificial para la monitorización de estructuras basadas en ondas guiadas y emisiones acústicas".