


**ALGORITMO DE SUPERVISIÓN EXPERTA PARA LA EVALUACIÓN DE
DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS, BASADO EN REDES NEURONALES
SOM Y ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)**



**YIZETH ANGÉLICA ACUÑA HERNANDEZ
JAVIER MAURICIO REYES COMBARIZA**



**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO – MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

2011

**ALGORITMO DE SUPERVISIÓN EXPERTA PARA LA EVALUACIÓN DE
DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS, BASADO EN REDES NEURONALES
SOM Y ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)**

**YIZETH ANGÉLICA ACUÑA HERNANDEZ
JAVIER MAURICIO REYES COMBARIZA**

Trabajo de Grado Presentado como Requisito
Para optar al Título de Ingeniero Electrónico

Director

Rodolfo Villamizar Mejía (PhD)

Codirector

Wilmer Alexis Sandoval Cáceres (MEng)

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO – MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES**

2011

AGRADECIMIENTOS

En primer lugar queremos agradecerle a Dios por acompañarnos en cada paso de nuestras vidas, por rodearnos de personas maravillosas que fueron nuestro apoyo y compañía durante este periodo de estudio.

A nuestros padres por su dedicación, paciencia y apoyo incondicional a nuestros sueños. Por enseñarnos a perseverar por lo que queremos y porque siempre han estado ahí para brindarnos el aliento para seguir luchando a pesar de las adversidades.

A nuestros hermanos, por brindarnos ese verdadero sentimiento de amistad, porque a pesar de la distancia, el ánimo, apoyo y alegría que nos brindan nos dan la fortaleza necesaria para seguir adelante.

Especial agradecimiento a la Universidad Industrial de Santander, a nuestro director, PhD. RODOLFO VILLAMIZAR MEJÍA y codirector M.Sc. WILMER ALEXIS SANDOVAL, por haber compartido sus conocimientos, sus apreciaciones, su dedicación y apoyo necesarios para la ejecución de este trabajo de investigación.

De manera personal, Javier Mauricio Reyes Combariza, agradezco a la persona que tengo siempre a mi lado, mi abuelita Lolita, por sus consejos, su cariño y porque fue fundamental en mi formación personal, deseó un día estar al final de esta meta pero que desde el cielo está compartiendo conmigo este triunfo.

CONTENIDO

PÁG.

1.	INTRODUCCIÓN	13
2.	JUSTIFICACIÓN Y ANTECEDENTES	13
3.	MARCO CONCEPTUAL	14
4.	ALGORITMO DE MONITORIZACIÓN DE SALUD ESTRUCTURAL	14
5.	METODOLOGÍA	15
	5.1 SENSADO.....	15
	5.2 CLASIFICACIÓN.....	16
	5.3 PROCESAMIENTO.....	16
	5.3.1 Transformada corta de Fourier.....	16
	5.3.2 Análisis de correlación.....	17
	5.4 ENTRENAMIENTO.....	17
	5.4.1 Reducción de dimensionalidad.....	17
	5.4.2 Base de datos.....	18
	5.4.2.1 Redes SOM.....	18
	5.4.2.2 Matriz de distancias.....	18
	5.5 VALIDACIÓN.....	18
	5.5.1 Base de datos.....	18
	5.5.1.1 Redes SOM.....	18
	5.5.1.2 Matriz de distancias.....	19
	5.5.2 Inferencia.....	19
6.	ANÁLISIS DE RESULTADOS	20
7.	CONCLUSIONES	21
8.	REFERENCIAS	22

LISTA DE FIGURAS

FIGURA 1. Modelo experimental del sensado en una tubería piezo actuada.....	14
FIGURA 2. Acciones del algoritmo de supervisión.....	15
FIGURA 3. Esquema de funcionamiento del algoritmo de supervisión para el entrenamiento e inferencia.....	15
FIGURA 4. Señal excitadora del sistema.....	16
FIGURA 5. Ubicación de los sensores sobre la estructura.....	16
FIGURA 6. Casos directos y simétricos de un solo elemento dañado.....	16
FIGURA 7. Casos directos y simétricos de dos elementos dañados.....	16
FIGURA 8. Casos especiales donde el caso directo es igual al simétrico en cuanto a ubicación.....	16
FIGURA 9. Disposición de casos para la creación de listas.....	16
FIGURA 10. Ejemplo STFT obtenida para el primer caso de entrenamiento.....	17
FIGURA 11. Esquema de Implementación para la etapa de entrenamiento.....	17
FIGURA 12. Componentes Principales.....	17
FIGURA 13. Clusterización por kmeans.....	18
FIGURA 14. Esquema para la etapa de validación.....	18
FIGURA 15.a Método para la búsqueda de casos cercanos al caso de entrada en cuanto a distancias euclidianas en Red SOM.....	20
FIGURA 15.b Método para la búsqueda de casos cercanos al caso de entrada en cuanto a distancias euclidianas en PCA solamente.....	20

LISTA DE TABLAS

TABLA 1. Características de la Red SOM.....	18
TABLA 2. Comparación entre señal STFT completa y STFT segmentada.....	20
TABLA 3. Resultados globales del algoritmo de supervisión.....	21
TABLA 4. Resultados del algoritmo de supervisión en cuanto acierto de posición de elementos dañados.....	21
TABLA 5. Resultados Del algoritmo de supervisión En Cuanto Acierto De Cuantización De DañoEn Elementos.....	21
TABLA 6. Tiempo De Ejecución Del algoritmo de supervisión para un Solo caso de Validación.....	21
TABLA 7. Porcentajes De Acierto Y Fracaso Ante La Presencia De Ruido.....	21

RESUMEN

TÍTULO:ALGORITMO DE SUPERVISIÓN EXPERTA PARA LA EVALUACIÓN DE DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS, BASADO EN REDES NEURONALES SOM Y ANÁLISIS DE COMPONENTES PRINCIPALES (PCA).¹

AUTORES:ACUÑA Hernández, Yizeth Angélica, REYES Combariza, Javier Mauricio.²

PALABRAS CLAVE:Deformaciones geométricas, análisis de componentes principales (PCA), Detección De Daño, redes neuronales tipo SOM, Algoritmo de Supervisión.

El siguiente artículo presenta los resultados numéricos de la implementación de dos algoritmos expertos para la detección, localización y cuantificación de deformaciones geométricas en tuberías piezoactuadas. Los algoritmos están basados en el análisis de componentes principales (PCA, Principal Components Analysis) y redes neuronales tipo SOM (Self Organized Maps). Para el entrenamiento y validación numérica de tales algoritmos, se simuló casos de daño (cambios de rigidez) de una tubería sujeta a vibraciones.

En primer lugar, se realiza una introducción general de la investigación, su motivación, descripción y estado del arte referente a aplicaciones y metodología de referencia. Posteriormente, se aborda el marco conceptual que sustenta el trabajo de investigación,

En la siguiente sección, se describen las diferentes etapas que componen los procesos de entrenamiento y validación de los algoritmos de supervisión desarrollados.

El sexto apartado, está relacionado con la validación numérica de los algoritmos implementados en MATLAB, donde se comentan y presentan las diferentes pruebas realizadas y resultados obtenidos durante la investigación, las cuales sustentan todo el proceso de validación.

Finalmente, con el presente trabajo se logró generar un algoritmo de supervisión capaz de extraer y reducir las características de las señales simuladas, para su posterior clasificación según el tipo de daño y severidad, lo cual permitió detectar y cuantificar daños en la tubería simulada.

¹ Trabajo de grado.

² Facultad de Ingenierías Fisicomecánicas, Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones, Ingeniería Electrónica. Director: Rodolfo Villamizar Mejía (PhD). Co-director: Wilmer Sandoval Cáceres (MEng).

ABSTRACT

TITLE:ALGORITHM OF EXPERT SUPERVISION FOR THE EVALUATION OF DEFORMATIONS IN PIPELINES PIEZO SENSE, BASED ON SOM NEURAL NETWORKS AND PRINCIPAL COMPONENT ANALYSIS (PCA).¹

AUTHORS:ACUÑA Hernández, Yizeth Angélica, REYES Combariza, Javier Mauricio.²

KEYWORDS:Geometric deformations, Principal Components Analysis (PCA), SOM Neural Networks, Damages detection, Algorithm of supervision.

This article presents the numerical results of the implementation of the two expert algorithms for the detection, localization and quantification of geometric deformations in pipelines piezo sense. The algorithms are based on the Principal Component Analysis (PCA) and Neural Networks type SOM (Self Organized Maps). For the training and numerical validation of such algorithms, were simulated cases of damage (change of rigidity) of a pipeline subject to vibrations.

The first part of this report presents a general overview of the research, its motivation, description and the state of the art concerning to applications and reference methodologies. After that, the conceptual framework used on this research is explained.

The next section describes the different stages that compose the processes of the training and the validation of the algorithms of supervision developed.

The sixth section is dedicated to the numerical validation of the algorithm implemented in MATLAB, commenting the different tests realized and the results obtained during the investigation, which sustain the whole process of validation.

Finally, with the present work it was achieved to generate an algorithm of supervision capable of extracting and reducing the characteristics of the simulated signs, for his posterior classification according to the type of damage and severity, which allowed to detect and to quantify damages in the simulated pipeline.

¹Work of degree

²Faculty of Physic-Mechanical Engineerings. Electrical, Electronic Engineering and Telecommunications" School, Electronic Engineering. Director: Rodolfo Villamizar Mejía (PhD). Co-director: Wilmer Sandoval Cáceres (MEng).

ALGORITMO DE SUPERVISIÓN EXPERTA PARA LA EVALUACIÓN DE DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS, BASADO EN REDES NEURONALES SOM Y ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)

Javier Mauricio Reyes Combariza, Yizeth Angélica Acuña Hernández, Wilmer Alexis Sandoval Cáceres y Rodolfo Villamizar Mejía.

Resumen—Este artículo presenta los resultados numéricos de la implementación de dos algoritmos expertos para la detección, localización y cuantificación de deformaciones geométricas en tuberías piezoactuadas. Los algoritmos están basados en el análisis de componentes principales (PCA, Principal Components Analysis) y redes neuronales tipo SOM (Self-Organized Maps). Para el entrenamiento y validación numérica de tales algoritmos, se simuló casos de daño (cambios de rigidez) de una tubería sujeta a vibraciones.

Palabras claves—Análisis de Componentes Principales (PCA), SOM, Detección de Daños, Algoritmo de Supervisión.

I. INTRODUCCIÓN

El problema que afrontan diariamente las empresas de transporte de fluidos (por ejemplo gas, petróleo, entre otros), son las averías y deformaciones geométricas en sus ductos, causadas tanto por factores internos como externos, las que al ser detectadas tempranamente evitarán el posterior colapso. Por tanto, es de vital importancia que dichas empresas cuenten con programas y/o herramientas capaces de detectar, localizar y cuantificar dichas deformaciones, con el fin de tomar medidas al respecto y prevenir posibles accidentes [2], [5], [6].

Actualmente existe un gran interés y preocupación por el desarrollo de herramientas que permitan la monitorización en línea de estructuras, con lo que se lograría reducir el costo de mantenimiento de esta y aumentar su fiabilidad y seguridad [4], [5], [7], [8].

Para la detección de fallas, existen diversas técnicas de monitorización altamente fiables [2], [3], [4], [5], [6], [7], [8], pero con un elevado costo para la adquisición y/o uso. Por tanto surge la necesidad, entre el sector industrial y el académico, de desarrollar un sistema de monitorización de bajo costo y a la vez fiable, que permita procesar en línea la información obtenida y tomar decisiones preventivas [2], [5], [9], [11].

Por tanto, el objetivo de desarrollar el algoritmo reportado en este artículo, basado en el Análisis de Componentes Principales (Principal Components Analysis, PCA) y Redes neuronales tipo SOM (Mapas de Auto-Organización), capaz de detectar cambios de deformación a partir de información de vibración proveniente de la tubería, es la de contribuir al

problema de investigación anteriormente mencionado.

II. JUSTIFICACIÓN Y ANTECEDENTES

Varios aspectos destacan la importancia de desarrollar e implementar sistemas de monitorización de salud estructural de tuberías en tiempo real. En primer lugar, la evaluación en forma rápida y precisa de la condición de la estructura de la tubería ante acciones externas tales como un movimiento de tierra, es crítica para la determinación de interrupción o no del suministro del fluido, y la evaluación de la seguridad en zonas de influencia del ducto. Los retrasos en dicha evaluación no prevería el posible colapso de la tubería, lo que podría provocar graves accidentes tales como incendios o desastres ecológicos [48], [49]. En segundo lugar una correcta monitorización reduciría costos tanto de operación, como de mantenimiento en el que se usan equipos de alto costo.

Actualmente existen herramientas [1], [2], [6], [8], [9], [10] de monitorización de tuberías de tipo no destructivo, en las que se requiere la suspensión del servicio siendo en la mayoría de los casos de alto costo, de gran consumo de tiempo, y afectan la eficiencia de producción y transporte del proceso.

Debido a esto, la monitorización de salud estructural de tuberías es un problema de investigación abierto, en el que se busca el desarrollo de herramientas eficientes e implementables en línea con tecnologías y algoritmos de medición eficientes y económicos, comparados con las tecnologías comerciales actuales.

Una metodología emergente utilizada en problemas de monitorización de estructuras similares al aquí planteado, es la detección de daños basada en vibraciones (Vibration-Based Damage Identification-VBDI) [5], la que asocia los cambios en la respuesta dinámica de la estructura piezoactuada, con la presencia de daños (pérdida de masa [2] deformaciones geométricas [9], [10], corrosión, entre otros) a partir del sensado de vibraciones a lo largo de la estructura [41]. La estructura al ser piezoactuada, se producen ondas de tipo acústico [8], [14], mecánico [4], [5], [6] o ultrasónico [6], [7] que se propagan a lo largo de la tubería.

Para el análisis de las señales sensadas se requiere de sistemas expertos capaces de generalizar patrones de comportamiento a partir de un grupo de casos iniciales [42], [44]. Sin embargo, debido a que en la mayoría de procesos, particularmente los que involucran el sensado de variables, la cantidad de datos es significativamente grande, redundante y difícil de analizar, se hace uso de herramientas de procesamiento entre las que se destaca el análisis frecuencial

de la señal basado en la WVD (WignerVilleDistribution [5], la WT (Wavelet Transform) [6], [7], [8] y la transformada corta de Fourier (Short-Time Fourier Transform-STFT), los que proporcionan espectros frecuenciales instantáneos en varios puntos de la señal, logrando notable éxito en la detección de fallos localizados en tuberías. Otra técnica, es el análisis de componentes principales [20], [21], [24], que realiza la descomposición de la información y la extracción de patrones característicos de la señal para la detección y diagnóstico de fallos localizados en tuberías.

En cuanto a desarrollo de sistemas expertos se encuentran los casos [3], [5], [10], [20] donde se hace uso de herramientas matemáticas para el procesamiento de la señal (PCA, Transformada Wavelet), y para el razonamiento (redes neuronales artificiales tipo SOM), en las que para su entrenamiento y validación se recurre a casos numéricos obtenidos a partir de la simulación a modelos no lineales de estructuras sometida a vibraciones [42]. Por otra parte en [12], [14], [16],[18] se usa PCA en la selección óptima de los puntos desensado, a partir de la información que se obtiene de la simulación de la estructura piezoactuada.

Las herramientas de representación del conocimiento o razonamiento basado en casos, ofrecen una alta posibilidad de establecer la correspondencia entre los datos obtenidos y fallos detectados, por lo que resultan importantes en la detección de deformaciones. Para lograr dicha correspondencia en el presente problema, se utilizó las redes neuronales tipo SOM [26], [29], [30], [31], [37]. La utilidad de esta herramienta está, en que dentro de cada red SOM, los agentes (o neuronas) tienen un alto grado de autonomía, permitiéndoles decidir dinámicamente que interacciones son adecuadas, que tareas deben realizar, quien realiza cada tarea, y, además, es posible mantener conocimiento que no es globalmente consistente, incluso los agentes (o neuronas) pueden mantener objetivos globales diferentes [27], [29], [30], [31], [36].

Una de las mayores desventajas en el uso de las redes neuronales, es el tiempo que usan para su entrenamiento [26], [35]. La literatura menciona una técnica para mejorar (disminuir) este tiempo de entrenamiento, realizando un pre-procesamiento al conjunto de datos mediante selección de variables, es decir, eliminando variables redundantes e irrelevantes haciendo uso de PCA [40], [41], [42], [43]. Las variables seleccionadas servirán para formar un nuevo conjunto de datos, de menor dimensión que el original, disminuyendo así el tiempo de entrenamiento de las redes y por consiguiente el tiempo de ejecución del sistema experto. Este trabajo se articula con el desarrollo de una herramienta de monitorización de salud estructural en línea, de tuberías de gas.

III. MARCO CONCEPTUAL

La monitorización de salud estructural (Structural Health Monitoring -SHM) se refiere al proceso de implementar una estrategia global y *on-line* para la

identificación de daños en estructuras. Su objetivo primordial es el de mejorar la seguridad y la confiabilidad de una estructura y para lograrlo, se ha apuntado al desarrollo de técnicas que puedan reemplazar la inspección visual por métodos automatizados de valoración de daños. [2], [9].

Entre las líneas de investigación afines, se encuentra la evaluación no destructiva que se refiere básicamente a la inspección *off-line* de estructuras. Estahace uso del sensado de variables dinámicas en una estructura, con el fin de establecer su condición estructural actual (o de salud). Este estado de salud estructural actual (operación normal, daños o degradación), se obtiene evaluando el comportamiento de la estructura frente a variaciones de las condiciones operacionales y de su entorno [2], [4], [5], [9].




Fig. 1. Modelo Experimental

Rytter define cuatro niveles para la monitorización de daño en una estructura [4], [34]:

- Nivel 1, Determinar la existencia del daño estructural.
- Nivel 2, Nivel 1 más la localización del daño.
- Nivel 3, Nivel 2 más cuantificación de la gravedad del daño.
- Nivel 4, Nivel 3 más predicción de vida útil de la estructura.

Los algoritmos aquí propuestos están enfocados a alcanzar el nivel 3, con los que se obtiene, la detección, localización y cuantificación del daño, definido como un cambio porcentual de rigidez de uno o más elementos de la estructura.

IV. ALGORITMO DE MONITORIZACIÓN DE SALUD ESTRUCTURAL

El algoritmo desarrollado (sistema experto), presentado en la figura 2, está diseñado para efectuar dos acciones fundamentales sobre una base de casos (adquisición de datos): Procesamiento y Diagnóstico e inferencia.

1) *Adquisición de datos*. Es el sensado en diferentes puntos de un modelo de tubería piezoactuada simulada mediante el método de elementos finitos [1].

2) *Procesamiento*. Este se realiza a las señales previamente adquiridas, con el fin de extraer características en el tiempo de cada señal.

3) *Diagnóstico e inferencia*. Se utiliza el razonamiento basado en casos a partir de dos formas de recuperar casos de daño similares: i) mediante redes neuronales tipo SOM y ii) mediante matriz de distancias.




Fig.2. Acciones del algoritmo de supervisión.

Un esquema más detallado del funcionamiento del algoritmo se observa en la figura 3, donde se describe el proceso seguido por las dos versiones propuestas, uno utilizando solamente PCA y el otro PCA junto con redes neuronales tipo SOM.




Fig.3. Esquema de funcionamiento del algoritmo de supervisión para el entrenamiento e inferencia.

Las etapas presentes en el algoritmo, tanto para el entrenamiento, como para su operación en línea son las siguientes:

1) *Sensado*. Se obtienen señales de aceleración en diferentes puntos de un modelo de tubería simulada [1] como respuesta a una señal de excitación determinada aplicada a la misma. Esto corresponde a la base de casos proveniente del sensado de tuberías simuladas bajo condiciones normales y de deformación.

2) *Obtención de listas*. Las señales obtenidas en la etapa anterior (sensado) son separadas en dos grupos denominados: entrenamiento y validación.

3) *Procesamiento*. Con esta etapa, se busca segmentar las señales para el cálculo de características en el tiempo o la frecuencia, de tal manera que sean de características reducidas para que el sistema sea capaz computacionalmente de reconocer un caso de daño, a partir de una cantidad mínima de información.

3) *Reducción de dimensionalidad mediante PCA*. El propósito de esta etapa, es reducir los costos computacionales relacionados con el tiempo de ejecución en la etapa de entrenamiento y validación del sistema, mediante la reducción

de dimensionalidad de las señales obtenidas en el paso anterior (procesamiento). [3] [18], [19], [20], [22].

Sobre el vector de características en el tiempo o frecuencia de la señal, obtenidas en la etapa anterior, se procede a realizar una reducción de dimensionalidad mediante el análisis estadístico con PCA, el cual transforma el vector de características de cada señal a un nuevo espacio vectorial donde la mayor energía de la información está concentrada en un vector de menor dimensión que el original [18], [19], [20].

3) *Creación de la base de datos*. Esta etapa se aplica únicamente al grupo de entrenamiento. Aquí, se crea una base de datos en donde se almacenaran las señales del grupo de entrenamiento para ser usada más adelante en la inferencia del sistema experto. Se hizo uso de dos métodos para la creación de esta base de datos:

- *Base de datos usando redes SOM*. Una vez obtenidas las componentes principales del grupo de entrenamiento, se busca organizar esta información, de modo tal, que se agrupen señales con características similares, y así, al necesitarlas más adelante, poder acceder a esta información de forma rápida. De este modo, se usan las redes neuronales tipo SOM, que efectúa un agrupamiento o “*aglomeración*”, según determinadas características que son comunes en el conjunto de datos de entrada a las redes [26], [28], [31].

- *Base de datos usando matriz de distancias*. Se guarda en una matriz, la información sobre la posición y cuantificación de daño correspondiente a cada señal del grupo de entrenamiento.

4) *Inferencia*. Esta etapa corresponde únicamente al grupo de validación. El fin de la etapa de inferencia, es calcular el porcentaje de acierto en la inferencia de la posición y cuantificación de los elementos dañados, para cualquier caso de la lista de validación.

V. METODOLOGÍA

Siguiendo el proceso descrito en la figura 3, se especificará con más detalles cada una de las etapas

A. Sensado

La adquisición de las señales de aceleración dadas por los sensores y la lista de escenarios de daño, fueron obtenidas previamente como producto del trabajo de investigación denominado: “Sistema Experto para la evaluación del estado de deformación en tuberías de gas: diseño y validación numérica” [1]. Es por esto que el desarrollo presentado en este artículo omite este procedimiento y tiene como punto de partida el procesamiento y análisis de dicha información previamente recopilada.

La tubería simulada, dispuesta en configuración de apoyo simple, fue modelada mediante un modelo de elementos finitos de 32 elementos. La tubería se excita controladamente mediante una señal de la forma presentada en la figura 4, en la que se incluyen frecuencias de 56.08hz posibles de generar mediante un piezoactuador y en frecuencias cercanas a los

modos de resonancia. La vibración se mide sobre los elementos 3, 7, 13, 19, 25 y 29 (puntos donde se instalarían piezosensores) tal como se muestra en la figura 5, para diferentes casos de daño (cambios porcentuales de la rigidez en uno o más elementos). De allí se genera una lista, que contiene los diferentes escenarios de avería cuyos porcentajes de daño varían en un factor de 5 dentro de un rango de 5% a 50%.




Fig.4. Señal excitadora del sistema.




Fig.5. Ubicación de los sensores sobre la estructura.

Las situaciones de daño para la estructura fueron clasificadas de la siguiente forma [1]:

- Un elemento dañado, con incrementos del 5% entre porcentajes de daño desde 5% hasta el 50%, en cualquier ubicación.
- Dos elementos dañados, igual porcentaje de daño en ambos elementos con incrementos del 5% entre porcentajes de daño desde 5% hasta el 50%, en cualquier ubicación.
- Dos elementos dañados, en el primer elemento un porcentaje de daño menor que el segundo elemento, con una diferencia constante del 5%, porcentajes desde el 5% y 10% hasta el 45% y 50% en sus respectivos elementos con paso del 5%, en cualquier ubicación.
- Dos elementos dañados, en el primer elemento un porcentaje de daño mayor que el segundo elemento, con una diferencia constante del 5%, porcentajes desde el 10% y 5% hasta el 50% y 45% en sus respectivos elementos con paso del 5%, en cualquier ubicación.

B. Clasificación

A partir de las señales obtenidas en la etapa de sensado, se establecen dos tipos de listas o grupos: entrenamiento y validación.

La lista denominada de entrenamiento, corresponde en mayor parte, a aquellos casos que son críticos (casos de elementos con el mayor y menor porcentaje de daño, dentro del rango de porcentajes de daño disponible), con el fin de suministrarle al sistema experto, un grupo de datos

uniformemente distribuidos en cuanto al número de elementos dañados y a la severidad de los daños, mejorando así el proceso de entrenamiento. Los casos faltantes, son escogidos en forma pseudo-aleatoria, teniendo en cuenta, que cada caso tomado (caso directo) tiene un correspondiente caso simétrico, como se observa en las figuras 6, 7, 8 [1].



Fig. 6. Casos directos y simétricos de un solo elemento dañado.




Fig. 7. Casos directos y simétricos de dos elementos dañados.




Fig. 8. Casos especiales donde el caso directo es igual al simétrico en cuanto a ubicación.

La lista denominada de validación, corresponde a los casos restantes, y cada caso es usado como nueva entrada al sistema experto para determinar el porcentaje de acierto que este posee en cuanto a ubicación y cuantificación de daño.

La disposición de casos seleccionados se observa en la figura 9.




Fig.9. Disposición de casos para la creación de listas.

C. Procesamiento

Para la obtención de características en las señales correspondientes a las listas de entrenamiento y validación, se utilizaron dos métodos:

1) *Transformada corta de Fourier*. Primero se obtiene la diferencia entre las señales de los casos de interés y la señal excitadora del sistema. A estas señales de diferencia, se les aplica la STFT (Short Time Fourier Transform), la cual consiste, en descomponer la señal en una serie de segmentos y analizarlos independientemente [47]. Para esto se establece una ventana que permita enmarcar una muestra de la señal. A cada una de estas submuestras, se aplica la FFT obteniendo los coeficientes de frecuencia. Con toda la información de cada uno de los segmentos, ahora en el dominio de frecuencias, se solapa la información de modo tal que se elimine la

redundancia producida por la FFT [44] [45] [46] [47]. En la figura 10, se puede observar la STFT obtenida para el primer caso de la lista de entrenamiento.




Fig.10. Ejemplo STFT obtenida para el primer caso de entrenamiento.

2) *Análisis de correlación.* Se obtiene el coeficiente de correlación entre las señales de los casos de interés y la señal excitadora del sistema. Este coeficiente de correlación es calculado al desplazar una secuencia formada por M puntos de la señal a lo largo de esta. El periodo Δt , será el incremento de tiempo que existe entre dos puntos consecutivos, i e $i+1$, de la secuencia de valores. La función de autocorrelación así obtenida estará definida en un intervalo de tiempo T dado por la ecuación 1. [44] [45] [46] [47].

$$T = (N - M) \cdot \Delta t \quad (1)$$

D. Entrenamiento

Para el desarrollo de esta etapa, se siguió el esquema presentado en la figura 11.

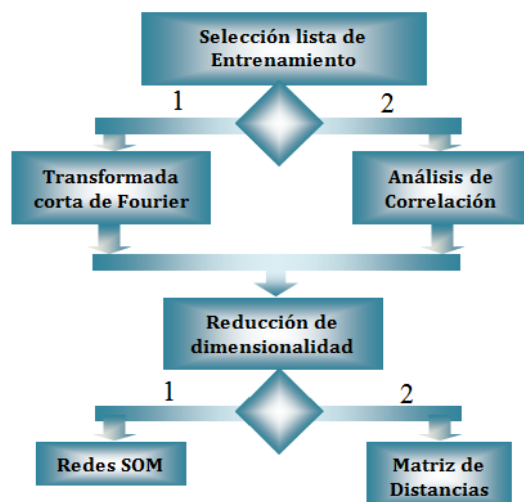


Fig.11. Esquema de Implementación para la etapa de entrenamiento.

a) Reducción de dimensionalidad mediante PCA

Los componentes principales se obtienen tras un proceso de cálculo de raíces y vectores característicos de una matriz simétrica y tienen como objetivo contener la mayoría de la varianza observada, con lo que se evita conseguir información redundante. A mayor varianza en cada una de estas componentes, implica que la misma contiene una mayor cantidad de información [19], [22], [21].

Antes de aplicar PCA a la lista de entrenamiento, se realizó una estandarización de datos (centralizar y escalar los datos mediante el cálculo de la media y desviación estándar), de tal modo, que los datos tengan unidades similares [19], [3], [18].

Una vez aplicada PCA sobre la señal estandarizada, y obtener sus componentes principales, como se puede observar en la figura 12, se decidió conservar aquellas componentes que fueran mayores al 2% del primer componente, eliminando aquellas menos significativas, reduciendo así la dimensionalidad de estas señales.

De esta etapa se guarda la información correspondiente a la media y desviación estándar, la matriz de coeficiente de PCA y el número de componentes principales escogidos, para ser usada, más adelante, en la etapa de Validación.




Fig.12. Componentes principales.

b) Base de datos

1) Entrenamiento Redes SOM

Obtenidas las componentes principales de la lista de entrenamiento, para cada elemento (en total seis, como se explicó al comienzo del ítem 5.A) se entrena una red neuronal tipo SOM, cada una de ellas con l neuronas (una por cada característica de la señal) en la capa de entrada y 50×50 neuronas en la capa de salida.

Antes del entrenamiento, se deben normalizar los datos de entrada, de tal modo, que todos los datos tengan unidades similares [26], [28], [37]. Los patrones de normalización obtenidos aquí, son guardados, para ser usados más adelante, en la etapa de validación.

En la tabla 1 se observan las características que se tuvieron en cuenta para el entrenamiento de las redes neuronales. Estas características fueron escogidas con base en lo leído en *SOM Toolbox for Matlab 5* [39]. Igualmente, la herramienta utilizada para la generación de las redes fue “somtoolbox” de Matlab.

TABLA I
CARACTERÍSTICAS DE LA RED SOM

Característica	Tipo
Normalización	Logístico (Logistic)
Tamaño	Grande (Big)
Topología	Hexagonal (hexa)
Malla	Plana (sheet)
Inicialización	Lineal (lininit)
Tipo de entrenamiento	Largo (Long)
Algoritmo de entrenamiento	Por lotes (Batch)

Una vez obtenidas las redes SOM entrenadas, se realizó una organización en clúster (grupos de datos con características similares) a los datos que las componen, esto con el fin, en la etapa de validación, de poder acceder en forma rápida a la información guardada en cada Red SOM [12], [26], [27], [28].

La organización se hizo teniendo en cuenta el algoritmo kmeans, el cual encuentra una partición de los datos en k grupos, tal que la distancia dentro de los puntos de cada grupo sea mínima. Este método permite asignar a cada observación el cluster que se encuentre más próximo en términos del centroide (media), haciendo uso del cálculo de la distancia euclidiana. Los pasos a seguir para aplicar este algoritmo son [26], [27], [28]:

1) Se especifican aleatoriamente k centroides iniciales (figura 13.a).

2) Para el conjunto de observaciones, se vuelve a calcular las distancias a los centroides de los clusters y se resignan a los que estén más próximos. Se vuelven a recalcular los centroides de los k clusters después de las reasignaciones de los elementos (figura 13.b y 13.c).

3) Se repiten los dos pasos anteriores hasta que no se produzca ninguna reasignación, es decir, hasta que los elementos se establecen en algún grupo (figura 13.d).

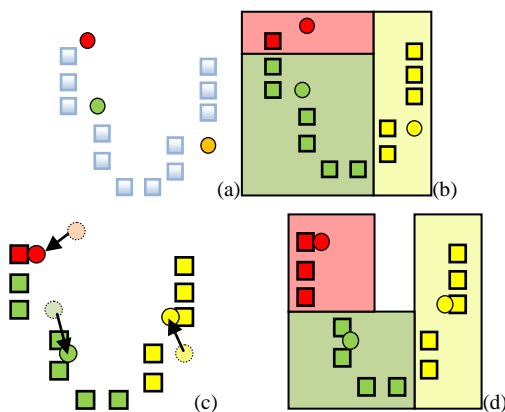


Fig.13. Clusterización por kmeans

2) *Matriz de distancias*

Las componentes principales obtenidas de las listas de entrenamiento, son guardadas junto con la información

correspondiente a la posición y cuantificación de daño, de cada señal de esta lista.

E. *Validación*

Una vez finalizada la etapa de entrenamiento del sistema experto, se procedió a realizar la validación del mismo. En la figura 14 se presenta un esquema general de esta etapa.

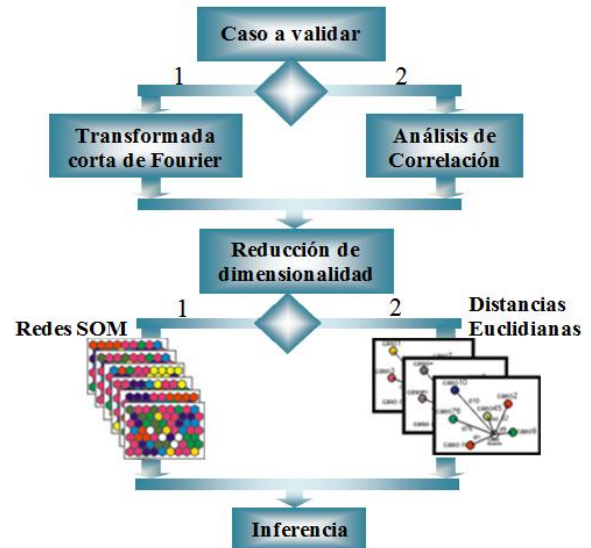


Fig.14. Esquema para la etapa de validación.

Para el sistema experto, se tiene como entrada un caso de la lista de validación obtenida en la sección 5.A (nuevo caso de entrada) y la información sobre el tratamiento dado a la lista de entrenamiento, es decir:

1) Se calculó la STFT o el coeficiente de correlación descrito en la sección 5.C

2) Para la creación de la base de casos, se utilizó una red SOM o matriz de distancias. (Item 5.D.b)

Una vez hallado la señal en frecuencia o los coeficientes de correlación de la lista de validación, y antes de aplicar PCA, se estandarizaron estas señales, teniendo como referencia el valor medio y desviación estándar hallados en la etapa de entrenamiento (sección 5.D).

Para el cálculo de las componentes principales de las señales estandarizadas ya descritas, se hizo uso de los coeficientes de PCA previamente obtenidos para cada elemento en la etapa de entrenamiento (como puede verse en la sección 5.D), esto con el fin, de que todos los casos (de entrenamiento y validación), quedaran en un mismo espacio de PCA.

a) *Base de datos*

1) *Redes SOM entrenadas*

Se normalizan las componentes principales obtenidas del nuevo caso de entrada, usando los patrones guardados en la sección 5.D.b.1. Normalizados los datos, se busca dentro de cada red entrenada, la respuesta de estas redes ante la señal del

nuevo caso de entrada, obteniendo un vector de distancias euclidianas, que indica, la distancia que hay del dato de entrada a los clusters que conforman la red SOM. Esta respuesta se denomina RSOM.

2) Matriz de distancias

Se buscó un método con el cual se pudiera establecer una relación entre el nuevo caso de entrada, y la lista de entrenamiento, y a partir de esta, poder realizar la inferencia de los elementos dañados y porcentaje de daño. El método escogido, es el cálculo de la distancia euclidiana, la cual da una medida de cuan lejano o cercano se encuentra uno dato de otro.

En esencia, el cálculo de la distancia euclidiana, es la aplicación repetida del teorema de Pitágoras, es decir, la distancia euclidiana entre dos puntos $P = (p_1, p_2, \dots, p_n)$ y $Q = (q_1, q_2, \dots, q_n)$, es definida en la ecuación 2 [28].

$$d(P, Q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2)$$

Al final, se obtiene un vector de distancias calculadas entre las componentes principales del nuevo caso de entrada y las componentes principales de la lista de entrenamiento.

Con la aplicación de este método de distancias euclidianas se obtendrán dos vectores:

- 1) Las distancias euclidianas calculadas entre los casos de entrenamiento y el nuevo caso de entrada.
- 2) La información sobre posición y cuantificación de daño del caso de entrenamiento que corresponde a cada una de estas distancias.

A los vectores descritos se les denominara CDE.

b) Inferencia

Obtenida la respuesta RSOM o CDE, el paso siguiente, es el uso de un sistema de inferencia, el cual determinara la localización y cuantificación del daño ante un nuevo caso de entrada. Este análisis se realiza, aplicando al vector de distancias euclidianas (RSOM o CDE) tres umbrales diferentes [12] (figura 15):

a) *Primer umbral (Um1)*. Determina cuáles RSOM o CDE, son importantes en el proceso de diagnóstico.

b) *Segundo umbral (Um2)*. Corresponde a la selección de neuronas ganadoras dentro de cada RSOM escogida o en la selección de distancias dentro de cada CDE escogida.

c) *Tercer umbral (Um3)*. Define los casos de daño, los cuales están almacenados dentro de los clústeres correspondientes a las neuronas seleccionadas de cada una de las redes tomadas en cuenta RSOM o asociadas al vector de información de los CDE tomados en cuenta. A estos casos de daños se les llamará CDS.

Para determinar la posición y cuantificación de daño del nuevo caso de entrada, se calcula un factor de repetición de los

elementos presentes en CDS y las estimaciones de daño para cada uno de ellos [13].

El cálculo de este factor, se realizó usando la ecuación 3, donde F_e es el factor calculado para el elemento e , d_e corresponde a las distancias euclidianas de CDS relacionadas con el elemento e y n que es el total de casos obtenidos en CDS.

$$F_e = \sum_{i=1}^n \frac{1}{[(d)_e]_i} \quad (3)$$

Partiendo de los factores obtenidos anteriormente, se estableció un umbral calculado por la ecuación 4, con lo cual se determina, que elementos se pueden considerar como averiados [13].

$$Dimension = \sum_{i=1}^n \dim(i) * \frac{d(1)/d(i)}{\sum_{k=1}^n d(1)/d(k)} \quad (4)$$

En la ecuación 4, dimensión indica el número de elementos dañados, donde: n es el total de casos obtenidos en CD, \dim indica el número de elementos en cada caso de CDS (en el caso de haber un cero, este no se tomara en cuenta), $d(1)$ es la mínima distancia euclidiana entre todos los casos que se encuentra en CDS y d la distancia euclidiana de cada caso en CDS.

Teniendo en cuenta el valor de dimensión, los elementos escogidos serán aquellos que tienen el mayor factor F_e .

Finalmente, se aplica la ecuación 5, con la cual, se calcula la estimación de daño total en cada elemento escogido anteriormente. **Daño**, indica el porcentaje de daño en el elemento escogido ef , pes el total de casos obtenidos en CDS que contienen a ef , $dam(i)_{ef}$ indica el porcentaje de daño en cada caso de CDS (de haber un cero, este no se tomara en cuenta) que contiene a ef , $d(1)$ es la mínima distancia euclidiana entre los casos que se encuentra en CDS y contiene a ef y d_{ef} es la distancia euclidiana de cada caso en CDS y que contiene a ef .


$$Daño_{ef} = \sum_{i=1}^p \frac{dam(i)_{ef} * \frac{d(1)/d(i)_{ef}}{\sum_{k=1}^n d(1)/d(k)_{ef}}}{\sum_{k=1}^n d(1)/d(k)_{ef}} \quad (5)$$

VI. ANÁLISIS DE RESULTADOS

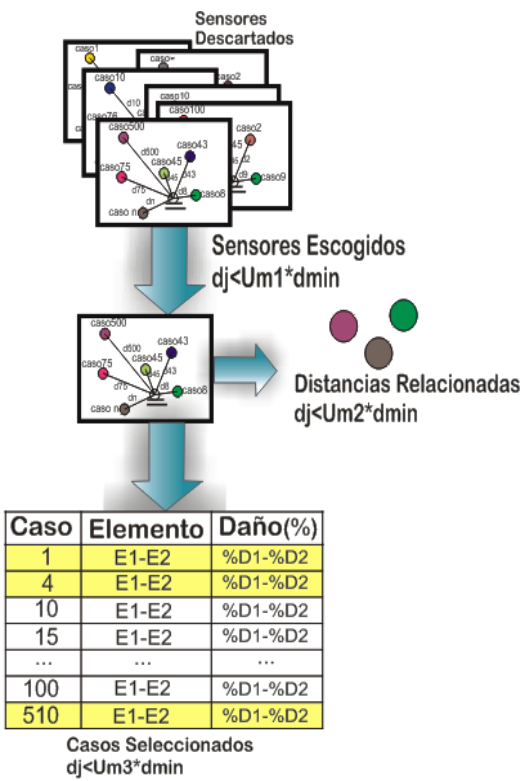
Para las pruebas realizadas, de acuerdo a la sección 5.A, se seleccionó aleatoriamente el 30% del total de casos para validación. Esta lista de casos, tanto de entrenamiento como para validación, se mantuvieron constantes con el fin de evaluar las diferentes opciones del sistema experto, manteniendo así, las mismas condiciones (grupos de datos predefinidos), en todas las pruebas.

Las primeras pruebas sobre el sistema experto fueron realizadas aplicando la STFT a la señal diferencia entre la señal excitadora del sistema de la tubería piezoactuada y las señales de los casos con daño para cada sensor de interés. Se utilizó, una ventana de tipo rectangular con un ancho de 512 muestras y un traslape entre estas de 256 muestras.

Los resultados obtenidos que se muestran en la tabla 2, corresponden a utilizar el espectro en frecuencia completo de la señal STFT obtenida o aplicando segmentación para la eliminación de coeficientes que no aporten información importante a la señal STFT.



(a)



(b)

Fig.15. Método para la búsqueda de casos cercanos al caso de entrada en cuanto a distancias euclidianas en (a) Red SOM. (b) PCA solamente

Tabla 2: COMPARACIÓN ENTRE SEÑAL STFT COMPLETA Y STFT SEGMENTADA

Método		% Acierto Total (Posición+ Porcentaje de daño)	% Acierto Posición Total ^[1]	% Acierto Daño Total ^[1]
P C A	Distancias Euclidianas	69.05	83.36	54.74
	Transformada corta de Fourier completa	70.6	86.23	54.97

[1] AL MENOS UN ELEMENTO CORRECTO

De los resultados de la tabla 2, se determinó trabajar con la señal STFT segmentada.

Los resultados obtenidos en la tabla 3 corresponden a los porcentajes de acierto alcanzados por el sistema experto al localizar y cuantificar el daño en un nuevo caso de entrada. En la tabla 4 y 5, se obtuvieron por separado los porcentajes de acierto de posición y cuantificación de daño en un nuevo caso de entrada.

Observando la tabla 6, existe una considerable diferencia entre los tiempos de procesamiento para las distintas variantes del sistema experto, se denota que los mayores tiempos al igual que los más bajos resultados de efectividad (Tabla 3), se obtienen al incluir redes neuronales tipo SOM, lo cual se debe a que los patrones de entrenamiento no son claramente distinguibles para la red neuronales topo SOM, dificultando la obtención de un buen modelo de generalización.

A partir de los resultados experimentales de la tabla 3, se puede apreciar que el mejor algoritmo generado para el sistema experto implementado, está basado en una configuración "coeficiente de correlación-PCA", fundamentada en el cálculo del coeficiente de correlación por ventanas con un ancho de 512 muestras y un solapamiento entre éstas de 10 muestras. Este cálculo se hace, entre la señal

ALGORITMO DE SUPERVISIÓN EXPERTA PARA LA EVALUACIÓN DE DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS

excitadora del sistema y las señales de los casos con daño respectivas, para cada sensor de interés.

TABLA 3
RESULTADOS GLOBALES DEL ALGORITMO DE SUPERVISIÓN

Método			% Acierto Total (Posición+ Porcentaje de daño)		% Fallo Total (Posición+ Porcentaje de daño)	
			Mín.	Máx.	Mín.	Máx.
P C A	Distancias Euclidianas	Coficiente de correlación	70	75	30	25
		Transformada corta de Fourier	65	73.5	35	26.5
	SOM	Coficiente de correlación	40.83	45	59.17	55
		Transformada corta de Fourier	45.83	48.3	54.17	51.7

TABLA 4
RESULTADOS DEL ALGORITMO DE SUPERVISIÓN EN CUANTO ACIERTO DE POSICIÓN DE ELEMENTOS DAÑADOS

Método			% Acierto Posición Total ^[1]		% Acierto Posición ^[2]	
			Mín.	Máx.	Mín.	Máx.
P C A	Distancias Euclidianas	Coficiente de correlación	85.78	86.67	76.7	77.12
		Transformada corta de Fourier	81.23	86.23	69.5	73.27
	SOM	Coficiente de correlación	36.66	45	16.7	23.3
		Transformada corta de Fourier	42	47	20.1	22.5

[1] AL MENOS UN ELEMENTO CORRECTO

[2] DOS ELEMENTOS CORRECTOS

TABLA 5
RESULTADOS DEL ALGORITMO DE SUPERVISIÓN EN CUANTO ACIERTO DE CUANTIZACIÓN DE DAÑO EN ELEMENTOS

Método			% Acierto Daño Total ^[1]	% Acierto Daño ^[2]
P C A	Distancias Euclidianas	Coficiente de correlación	60	22
		Transformada corta de Fourier	54.97	13.75
	SOM	Coficiente de correlación	53.33	17.16
		Transformada corta de Fourier	50.5	15.6

[1] AL MENOS UN ELEMENTO CORRECTO

[2] DOS ELEMENTOS CORRECTOS

Otro tipo de prueba que se realizó, fue la adición de ruido aleatorio a las señales proveniente de los sensores, con el fin de observar el desempeño del sistema frente al ruido. Para ello, se utilizaron los algoritmos con mejor desempeño, siendo estos PCA-Distancias euclidianas-STFT o Correlación, cuyos resultados obtenidos se encuentran en la tabla 7, en la cual se observa que los algoritmos implementados son sensibles al ruido, mostrando un bajo desempeño en la localización y cuantificación de daño. Sin embargo, el esquema que mostró el porcentaje de acierto más alto es el que realiza PCA-Distancias euclidianas-Correlación.

TABLA 6

TIEMPO DE EJECUCIÓN DEL ALGORITMO DE SUPERVISIÓN PARA UN SOLO CASO DE VALIDACIÓN

Método			Tiempo de ejecución de etapa de entrenamiento y validación (segundos)	Tiempo de ejecución de etapa de validación (segundos)
P C A	Distancias Euclidianas	Coficiente de correlación	621	20
		Transformada corta de Fourier	724	20
	SOM	Coficiente de correlación	2843	19
		Transformada corta de Fourier	1352	20

TABLA 7

PORCENTAJES DE ACIERTO Y FRACASO ANTE LA PRESENCIA DE RUIDO

Método			% Acierto Posición Total ^[1]	% Acierto Daño Total ^[1]
P C A	Distancias Euclidianas	Coficiente de correlación	11	13.6
		Transformada corta de Fourier	6.67	16.67

[1] AL MENOS UN ELEMENTO CORRECTO

VII. CONCLUSIONES

Se diseñaron y validaron numéricamente los algoritmos computacionales basados en PCA y PCA-SOM, dando como resultado, que el algoritmo generado con mejor detección y cuantificación de daño en una tubería piezo actuada, está basado en una configuración “coeficiente de correlación-PCA”.

Con el fin de obtener característica en las mediciones de aceleración tomada de tuberías piezoactuadas, se aplica la operación de correlación y el cálculo de la transformada corta de Fourier (STFT) entre la señal de excitación del sistema y las señales con daño.

En el caso de utilizar Redes SOM, los resultados obtenidos en detección y cuantificación de daño, no son recomendables.

El algoritmo propuesto usando correlación-PCA-Red SOM, al ser la correlación, una medida de similitud entre señales, dificulta la etapa de generalización de la SOM, pues esta necesita patrones claramente distinguibles para la clasificación de estas señales.

La adición de una etapa de segmentación a los coeficientes de la STFT, mejora considerablemente la eficiencia del sistema en cuanto a la detección de averías geométricas.

El sistema es sensible a pequeñas variaciones de ruido (del orden de 10dB). La presencia de éste, influye en el sistema experto, mostrando un bajo desempeño en la localización y cuantificación de daño.

El presente trabajo cumple con el objetivo propuesto de analizar el comportamiento de ciertas herramientas computacionales para la detección de deformaciones en tuberías. Dentro de un contexto general, esta es una herramienta valiosa para posteriores trabajos, pues se establecen las ventajas y desventajas de la aplicación de ciertos algoritmos.

REFERENCIAS

- [1] Sandoval Cáceres W., Villamizar Mejia R., Begambre Carrillo., “Evaluación de Deformaciones Geométricas en Estructuras Basado en Vibraciones- Análisis Numérico Preliminar”. XV Simposio de tratamiento de señales, imágenes y Visión artificial-STSIVA, 2009. Universidad Tecnológica de Pereira, Pereira, Colombia. Septiembre 9-11 de 2009.
- [2] C. Boller, W.J. Staszewski, K. Worden, G. Manson, and G.R. Tomlinson. “Structure integrated sensing and related signal processing for condition-based maintenance”. Symposium on Condition-Based Maintenance for Highly Engineered Systems, September 2000.
- [3] P. De Boe, and J.C. Golinval. “Principal component analysis of piezo-sensor array for damage localization”. Structural Health Monitoring: An International Journal, 2(2):137144, 2003.
- [4] A. Rytter, Vibration Based Inspections of Civil Engineering Structures, PhD Thesis, Department of Building Technology and Structural Engineering, university of Aalborg, Denmark (1993).
- [5] Kolakowski, Przemyslaw; Mujica, Luis Eduardo, Rodellar, José and Vehí, Josep, “A Hybrid Approach of Knowledge-Based Reasoning for Structural Assessment”. Smart Materials and Structures Institute of Physics Publishing Impact Factor. Volume 14, Number 6, December 2005.
- [6] J. Cattarusa and D. J. Inmana. Time domain analysis for damage detection in smart structures. Mechanical Systems and Signal Processing, 11(3):409423, May 1997.
- [7] S.W. Doebling, C.R. Farrar, and M.B. Prime. A summary review of vibration-based damage identification methods. The Shock and Vibration Digest, 30(2):91105, 1998.
- [8] R. Lopez de Mantaras and E. Plaza. Case-Based Reasoning: An overview. AI Communications, 10(1):2129, 1997.
- [9] P. Hajela and F.J. Soeiro. Recent developments in damage detection based on system identification methods. Structural Optimization, 2:110, 1990.
- [10] Ho Y.K and D.J. Ewins. Numerical evaluation of the damage index. In Structural Health Monitoring 2000, pages 9951011, Palo Alto, California, 1999. Stanford University.
- [11] A. Raich and T. Liszkai. Benefits of implicit redundant genetic algorithms for structural damage detection in noisy environments. In Cantú-Paz, Foster, Deb, Davis, Roy, O’Reilly, Beyer, Standish, and Kendall, editors, Genetic and Evolutionary Computation GECCO-2003, number 2724 in LNCS, pages 24182419, Chicago, September 2003. Springer-Verlag.
- [12] Kolakowski, Przemyslaw, Mujica, Luis Eduardo and Vehí, Josep, “Multivariate Statistics Process Control for Dimensionality Reduction in Structural Assessment”. Journal IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE Computer Society. Pages 61-73.
- [13] Kolakowski, Przemyslaw, Mujica, Luis Eduardo and Vehí, Josep, “Two Approaches to Structural Damage Identification: Model Updating versus Soft Computing”. Journal of Intelligent Material Systems and Structures, SAGE Publications. Volume 17, Number 1, January 2006, Pages 79-96.
- [14] K. Worden. Structural fault detection using a novelty measure. Journal of Sound and Vibration, 201(1):85101, mar 1997.
- [15] M.L. Wang, F.L. Xu, and G.M. Lloyd. A systematic numerical analysis of the damage index method used for bridge diagnostics. In Smart Structures and Materials 2000: Smart Systems for Bridges, Structures, and Highways, number 988, pages 154164, Newport Beach.
- [16] S.M. Yang and G.S. Lee. Effects of modeling error on structure damage diagnosis by two stage optimization. In F.K. Chang, editor, Structural Health Monitoring, pages 871880, Palo Alto, California, 1999. Stanford University.
- [17] L. Zhang, W. Quijón, and M. Link. A structural damage identification approach based on element modal strain energy. In Proceedings of ISMA23, Noise and Vibration Engineering, Leuven, Belgium, 1999.
- [18] G. Kerschen, P. De Boe, J.C. Golinval, and K. Worden. Sensor validation using principal component analysis. Smart Materials and Structures, 14:3642, 2005.
- [19] Lindsay I. Smith. “A tutorial on Principal Components Analysis”. 2002. [Online]. Fecha de consulta: 20 Noviembre 2008. Hora: 4pm. Sin restricciones. Disponible: http://csnet.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf
- [20] P. Nomikos and J.F. MacGregor. Monitoring batch processes using multiway principal component analysis. AIChE Journal, 40(8):1361 1375, August 1994.
- [21] M. Ruiz, M. Villez, G. Sin, J. Colomer, and P. Vanrolleghem. Different PCA approaches for monitoring nutrient removing batch process: Pros and cons. Submitted to American Institute of Chemical Engineers Journal (AIChE), 2006.

- [22] B.M. Wise, N.B. Gallagher, S. Watts, D.D. White, and G.G. Barna. A comparison of PCA, Multiway PCA, trilinear decomposition and parallel factor analysis for fault detection in semiconductor etch process. *Journal of Chemometrics*, 13:379396, 1999.
- [23] J. Westerhuis, T. Kourti, and J. MacGregor. Comparing alternative approaches for multivariate statistical analysis of batch process data. *Journal of Chemometrics*, 13:397413, 1999.
- [24] K. Worden and G. Manson. Visualization and dimension reduction of high-dimensional data for damage detection. *imac 17*. In S. Ganeriwala and S. Patel and H. Hartung, editors, *Proceedings of the 17th International Modal Analysis Conference*, pages 15761585, 1999.
- [25] B. Edlund, P. Löfqvist, and P. Johansson. Case Based Reasoning in bridge design. In 1st Workshop "Applications of Artificial Intelligence in Structural Engineering", pages 6061, Lausanne, 1994. EG-SEA-AI.
- [26] T. Kohonen. The self-organizing map. *Proceeding in IEEE*, 78(9):1464 1480, 1990.
- [27] El modelo de Kohonen". [Online] Fecha de consulta: 30 Octubre 2008. Hora: 7pm. Sin restricciones Disponible: <http://thales.cica.es/rd/Recursos/rd98/TecInfo/07/capitulo6.html>
- [28] Kohonen, Teuvo. *Self-organizing maps*, 3rd ed., Springer Verlag, 2001.
- [29] R.T. Jones, J.S. Sirkis, E.J. Friebele, and A.D. Kersey. Location and magnitude of impact detection in composite plates using neural networks. In William B. Spillman, editor, *Proc. SPIE Vol. 2444, Smart Structures and Materials 1995: Smart Sensing, Processing, and Instrumentation*, pages 469480, April 1995.
- [30] T. Marwalla. Probabilistic fault identification using vibration data and neural networks. *Mechanical Systems and Signal Processing*, 15(6):11091128, 2001.
- [31] J. Melendez and J. Colomer. Inteligencia artificial para la detección y el diagnóstico de fallos. *Automática e Instrumentación*, 340:27, Mayo 2003.
- [32] J. Rhim and S.W. Lee. A neural network approach for damage detection and identification of structures. *Computational mechanics*, 16(6):437443, November 1995.
- [33] M. Verleysen. Machine learning of high-dimensional data: local artificial neural networks and the curse of dimensionality. Aggregation in higher education thesis, Université Catholique de Louvain, Louvain la Neuve, February 2001.
- [34] León V. Fabián, Camacho N. Jhonatan, "Diseño de una Interfaz Electrónica para el Reconocimiento de Patrones EMG para Prótesis de Mano", Tesis de Pregrado, Universidad Industrial de Santander, Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones, Colombia. 2008
- [35] M. Verleysen. Limitations and future trends in neural computation, volume 186, chapter Learning high-dimensional data, pages 141162. IOS Press, Amsterdam (The Netherlands), 2003.
- [36] K. Worden and W.J. Staszewski. Impact location and quantification on a composite panel using neural networks and a genetic algorithm. *Strain*, (36):6170, 2000.
- [37] K.C. Yap and D.C. Zimmerman. The effect of coding on genetic algorithm based structural damage detection. In *Proceedings of the 16th International Modal Analysis Conference*, number 1, pages 165171, Santa Barbara, CA, February 1998. Society for Experimental Mechanics, Inc, Bethel.
- [38] G.L. Zheng and S.A. Billings. Fault diagnosis using radial basis function neural networks. Technical report, Department of Automatic Control and Systems Engineering, University of Sheffield, 1993.
- [39] SOM Toolbox for Matlab 5, Helsinki University of Technology, Vesanto, Juha. Himberg, Johan. Alhoniemi, Esa, and Parhankangas, Juha, 2000
- [40] LukPeeters, Alain Dassargues. Comparison of Kohonen's Self-Organizing Map algorithm and principal component analysis of a groundwater quality dataset.
- [41] C. Zang and M. Imregun. Structural damage detection using artificial neural networks and measured for data reduced via principal component projection. *Journal of Sound and Vibration*, 242(5):813827, 2001.
- [42] P. Demartines and J. Héroult. Curvilinear component analysis: a self-organizing neural network for nonlinear mapping of data sets. *IEEE Transactions on Neural Networks*, 8(1):148 154. 1997.
- [43] De la Fraga, Luis Gerardo. Segmentación. Curso: Tópicos Avanzados en Visualización, Reconocimiento 3D. Sección de Computación, Departamento de Ingeniería Eléctrica. Centro de Investigación y de Estudios avanzados del Instituto Politécnico Nacional, 2005. [Online]. Disponible: <http://delta.cs.cinvestav.mx/~fraga/Cursos/Reconocimiento3D/2005/segmentacion.pdf>
- [44] Carranza-Athó, Fredy. Implementación de FFT, STFT, filtro de pre énfasis y visualización del espectrograma en señales del habla.
- [45] Rosado Muñoz, Alfredo. Desarrollo de Técnicas de Detección de Fibrilación Ventricular Basadas en Algoritmos Tiempo-Frecuencia
- [46] M. Algaba, M. Solís, P. Galvín. Detección de daño en estructuras mediante la aplicación de la transformada Wavelet a su deflexión estática

[47] P.A. Meroño, F.C. Gómez de León. Análisis comparativo de técnicas de procesamiento de señales de vibración para la detección de fallos en engranajes

[48] National Transportation Safety Board, "Natural Gas Pipeline and Fire Near Carlsbad, New Mexico, August 19, 2000." Pipeline Accident Report NTSB/PAR-03/01, Washington, D.C. (2000): 1-57.

[49] National Transportation Safety Board, "Pipeline Rupture and Subsequent Fire in Bellingham, Washington, June 10, 1999." Pipeline Accident Report NTSB/Par-02/02, Washington, D.C. (1999): 1-57.