


**ALGORITMO DE SUPERVISIÓN EXPERTA BASADO EN REDES
NEURONALES TIPO SOM Y TRANSFORMADA WAVELET PARA LA
EVALUACIÓN DE DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS Y
SUJETAS A CARGAS DEFORMANTES**




**PABLO EMILIO ACEVEDO DÍAZ
DANIEL RICARDO OJEDA GIRATÁ**



**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO – MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
2010**



UNIVERSIDAD INDUSTRIAL DE SANTANDER
ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
Perfecta Combinación entre Energía e Intelecto
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS



Informe Final del Trabajo de Grado en la Modalidad Investigación

**ALGORITMO DE SUPERVISIÓN EXPERTA BASADO EN REDES
NEURONALES TIPO SOM Y TRANSFORMADA WAVELET PARA LA
EVALUACIÓN DE DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS Y
SUJETAS A CARGAS DEFORMANTES**

PABLO EMILIO ACEVEDO DÍAZ

DANIEL RICARDO OJEDA GIRATÁ

Trabajo de Grado Presentado como Requisito

Para optar al Título de Ingeniero Electrónico

Director

PhD. Rodolfo Villamizar

Codirector


MSC (c) WILMER ALEXIS SANDOVAL

Universidad Industrial de Santander
FACULTAD DE INGENIERÍAS FÍSICO – MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES

2010



UNIVERSIDAD INDUSTRIAL DE SANTANDER
ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
Perfecta Combinación entre Energía e Intelecto
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS




A mis padres, mis hermanas y mi sobrina

DANIEL RICARDO OJEDA GIRATÁ




UNIVERSIDAD INDUSTRIAL DE SANTANDER
ESCUELA DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA Y DE TELECOMUNICACIONES
Perfecta Combinación entre Energía e Intelecto
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS



*A mis padres, mis hermanas y a todos aquellos que me brindaron su
incondicional apoyo.*

PABLO EMILIO ACEVEDO DÍAZ




Agradecimientos

Agradezco a Dios por haberme bendecido con mi familia, con la vida que me ha dado y por rodearme siempre de gente buena. A mis padres y hermanas quienes con sacrificio me brindaron los medios necesarios para alcanzar mis ideales. A PhD. Rodolfo Villamizar Mejía y a MIE (c). Wilmer Alexis Sandoval Cáceres por sus invaluable aportes como director y codirector respectivamente de este trabajo de grado y a mis amigos quienes me acompañaron en este proceso de formación celebrando conmigo mis triunfos y motivándome a seguir adelante en mis derrotas.

DANIEL RICARDO OJEDA GIRATÁ


Agradezco a mis hermanos, ya que con su ayuda pude avanzar hasta este punto, a mi padre, que con sus consejos pude establecer claramente mis metas, a mis amigos, compañeros y a todos aquellos que me dieron ánimo aún en las situaciones más difíciles, pero sobre todo le agradezco a mi madre, una mujer luchadora que sacrificó su juventud y salud por todo lo que mis hermanos y yo somos, y a Dios, por mantenerme rodeado de las personas indicadas y haber enderezado mis sendas.

PABLO EMILIO ACEVEDO DÍAZ




Contenido

I INTRODUCCIÓN	1
II ANTECEDENTES Y JUSTIFICACIÓN	1
III MARCO CONCEPTUAL	2
IV SISTEMA EXPERTO	2
V VALIDACIÓN NUMÉRICA DEL SISTEMA EXPERTO	3
A Selección de casos de entrenamiento	4
B Extracción de características	4
C Reducción de la dimensionalidad	5
D Entrenamiento de las redes som	6
E Validación	6
VI RESULTADOS Y ANÁLISIS DE LOS MISMOS	8
VII CONCLUSIONES	9
VIII APÉNDICE	10
A Transformada wavelet	10
B Redes neuronales tipo SOM	10
C Análisis de componentes principales	11
IX REFERENCIAS	11
X BIOGRAFÍAS	12




Lista de Tablas

Tabla 1 Características seleccionadas para la generación y entrenamiento de las redes SOM.....	6
Tabla 2 Selección de subfamilias wavelet	8
Tabla 3 Rendimiento del sistema experto con el proceso de segmentación	8
Tabla 4 Rendimiento del sistema experto con el proceso de análisis de componentes principales.....	8



Lista de Figuras

Fig. 1 Ejemplo de sistema VBDI	2
Fig. 2 Esquema del algoritmo	2
Fig. 3 Acciones del sistema experto	3
Fig. 4 Etapas de funcionamiento del sistema experto para el entrenamiento y su posterior validación	3
Fig. 5 Disposición de sensores en la estructura.....	3
Fig. 6 Esquema de implementación.....	4
Fig. 7 Disposición de los casos suministrados.....	4
Fig. 8 Casos directos y simétricos de un solo elemento dañado	4
Fig. 9 Casos directos y simétricos de dos elementos dañados.....	4
Fig. 10 Casos especiales donde el caso directo es igual al caso simétrico en cuanto a ubicación	4
Fig. 11 Coeficientes de detalle de nivel tres y su respectiva segmentación	5
Fig. 12 Análisis multiresolución para la obtención de los coeficientes de descomposición de la TWD.....	5
Fig. 13 Organización del vector de características	5
Fig. 14 Varianzas de las componentes principales de la caracterización de los datos del sensor 3.....	5
Fig. 15 Comportamiento de la varianza con respecto al número de componentes seleccionadas.....	5
Fig. 16 Método para la organización de los datos de entrenamiento en clústeres de neuronas	6
Fig. 17 Esquema de validación del sistema experto	7
Fig. 18 Método para la búsqueda de casos cercanos al caso de entrada en cuanto a distancias euclidianas.....	7
Fig. 19 Porcentajes de acierto ante atenuaciones	9
Fig. 20 Porcentajes de acierto ante ruidos.....	9
Fig. 21 Esquemas básicos de funcionamiento del funcionamiento de la TF y la TW respectivamente	10
Fig. 22 Descomposición wavelet en coeficientes de detalle y aproximación	10
Fig. 23 Representación esquemática de la arquitectura SOM y su interacción con el espacio de entrada	11



Resumen Ejecutivo del Trabajo de Grado

Título	ALGORITMO DE SUPERVISIÓN EXPERTA BASADO EN REDES NEURONALES TIPO SOM Y TRANSFORMADA WAVELET PARA LA EVALUACIÓN DE DEFORMACIONES EN TUBERÍAS PIEZOACTUADAS Y SUJETAS A CARGAS DEFORMANTES [†]
Autores	Pablo Emilio Acevedo Díaz, pacevedo86@hotmail.com Daniel Ricardo Ojeda Giratá, richardo_0321@yahoo.com [‡]
Palabras Clave	Análisis de Componentes Principales (PCA), Detección de Daños, SOM, Reducción de Dimensionalidad, Sistema Experto, TWD.

Breve Reseña del Proyecto:


El interés por monitorizar continuamente el estado de las estructuras con el fin de detectar de forma temprana daños en las mismas, se ha incrementado paulatinamente tanto en el sector industrial como en el académico; esto se ve reflejado en el desarrollo de un elevado número de investigaciones, orientadas a la creación de nuevas herramientas diseñadas para mejorar las labores de monitorización, reducir costos y minimizar el riesgo de accidentes.

En el presente artículo, se describe el desarrollo de un algoritmo experto con capacidad de clasificar, detectar y estimar la severidad de averías de tipo geométrico, fundamentado en el uso de la Transformada Wavelet Discreta (TWD) para el análisis transitorio y caracterización de señales y en la implementación de redes neuronales tipo SOM (Mapas de Auto-Organización) como elemento clasificador de casos. El entrenamiento del algoritmo se realizó a partir de casos numéricos obtenidos mediante la simulación de un modelo simplificado de una tubería en apoyo simple bajo condiciones normales y de deformación.

Por último, a partir de diversas pruebas realizadas se determinó la wavelet madre que permite al algoritmo de supervisión experta lograr un mejor desempeño. Dicha mejora se vio reflejada en el porcentaje de detección de daños tanto en funcionamiento normal como en presencia de atenuación y ruido.

[†] Trabajo de grado desarrollado en la modalidad de investigación.

[‡] Facultad de Ingenierías Físico-Mecánicas, Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: PhD. Rodolfo Villamizar Mejía. Codirector: MIE (c). Wilmer Alexis Sandoval Cáceres.



Abstract of the Undergraduate Project

Title	EXPERT SUPERVISION ALGORITHM BASED ON SOM NEURAL NETWORKS AND WAVELET TRANSFORM FOR DAMAGES ASSESSMENT ON PIEZOACTUATED PIPES SUBJECTED TO DEFORMANT LOADS [†]
Authors	Pablo Emilio Acevedo Díaz, pacevedo86@hotmail.com Daniel Ricardo Ojeda Giratá, richardo_0321@yahoo.com [‡]
Key Words	Principal Component Analysis (PCA), Damage Detection, SOM, Dimensionality Reduction, Expert System, DTW.

A Brief Review of the Project:

Interest on monitoring structural health in order to evaluate early future damages, has been increasing in industrial and academic communities. This increase is reflected on development of several investigations orientated to create structural health monitoring tools in order to reduce costs and accident risks.

In this paper an expert algorithm able to detect, classify and estimate the severity of geometric damages based on the Discrete Wavelet Transform (DWT) used for signal temporal analysis and feature extraction and SOM neural networks (Self Organizing-Maps) used as classifiers is proposed. The algorithm training was achieved by using numerical cases of an ideal simple-supported pipe model by simulating its dynamic response in normal and deformation conditions.

Finally, several tests were made to reach a better algorithm performance. As a result, the most suitable mother wavelet for this application was determined. Also, the feature extraction process was improved and a dimensional reduction method was proposed to achieve an even better performance.

[†] Final undergraduate Project developed in the research modality.

[‡] Physics Mechanical Engineering Faculty. Electric, Electronic and Telecommunications Engineering School.
Director: PhD. Rodolfo Villamizar Mejía. Codirector: MEE (c). Wilmer Alexis Sandoval Cáceres.

Sistema Experto Para la Detección de Averías de Tipo Geométrico en Tuberías Simuladas

Pablo Emilio Acevedo Díaz, Daniel Ricardo Ojeda Giratá, Wilmer Alexis Sandoval Cáceres y Rodolfo Villamizar Mejía.

Resumen—El interés por monitorizar continuamente el estado de las estructuras con el fin de detectar de forma temprana daños en las mismas, se ha incrementado paulatinamente tanto en el sector industrial como en el académico [[1]-[2]]; esto se ve reflejado en el desarrollo de un elevado número de investigaciones, orientadas a la creación de nuevas herramientas diseñadas para mejorar las labores de monitorización, reducir costos y minimizar el riesgo de accidentes [[2]-[3]]. En este artículo, se describe el desarrollo de un algoritmo experto con capacidad de clasificar y detectar averías de tipo geométrico, fundamentado en el uso de la Transformada Wavelet Discreta (TWD) y redes neuronales tipo SOM (Mapas de Auto-Organización). El entrenamiento de algoritmo se realizó a partir del sensado de una tubería simulada bajo condiciones normales y de deformación.

Palabras claves—Análisis de Componentes Principales (PCA), Detección de Daños, SOM, Reducción de Dimensionalidad, Sistema Experto, TWD.

I. INTRODUCCIÓN

Uno de los principales inconvenientes que se presentan en sectores industriales, relacionados con procesos de transporte y distribución de fluidos mediante ductos, es la presencia de averías en su infraestructura [3]. Este tipo de daños, son causados principalmente por influencia tanto de factores internos (por ejemplo, las propiedades de los fluidos transportados) como externos (las cargas deformantes), los cuales aumentan la vulnerabilidad de la tubería, ocasionando así deformaciones de tipo geométrico [3]. Por tanto, es de vital importancia detectar, localizar y cuantificar tempranamente deformaciones presentes en las estructuras, con el fin de tomar medidas al respecto y prevenir posibles accidentes [1].

Algunas técnicas convencionalmente empleadas para la inspección del daño estructural, se fundamentan en el uso de métodos basados principalmente en: el ultrasonido, la óptica, la radiografía, las corrientes de Eddy, el flujo de campo magnético y el análisis del campo térmico. Una desventaja de dichos métodos, es que requiere localizar previamente el daño, ya sea de forma visual o experimental, a la vez que la

sección averiada de la estructura debe ser de fácil acceso [[1]-[4]]. Esto ha motivado el uso de nuevas herramientas computacionales, tales como los sistemas expertos programados con la capacidad de monitorizar la salud estructural en tiempo real, lo que reduce costos de mantenimiento y riesgo de accidentes [[2]-[5]].

El presente artículo presenta el desarrollo y validación de una herramienta software basada en la TW como técnica de procesamiento y análisis de señales, provenientes de tuberías simuladas bajo condiciones normales y de deformación, debido a sus características de respuesta en frecuencia y de localización de información en el tiempo [6]. Por otra parte, un sistema basado en redes neuronales tipo SOM es empleado como elemento clasificador de casos el cual toma como entrada, los patrones de los eventos obtenidos a partir de la transformación wavelet para su posterior organización y evaluación.

II. ANTECEDENTES Y JUSTIFICACIÓN

La monitorización de ductos a nivel industrial, es realizada usualmente por las denominadas herramientas de inspección en línea. Dichas herramientas tienen un alto grado de fiabilidad en la detección de múltiples tipos de daño debido a que supervisan punto a punto la tubería. Sin embargo, sus altos costos de operación y su baja disponibilidad, hacen que la adquisición de este servicio sea restringida.

En consecuencia, las empresas del sector de los hidrocarburos en conjunto con el sector académico, han impulsado la búsqueda de métodos alternativos que sean fiables, efectivos, económicos y que no presenten restricciones en cuanto a su disponibilidad de uso.

Una de las alternativas que ha sido ampliamente documentada desde su primera publicación en 1969 hasta la fecha, es la técnica conocida como VBDI (Vibration-Based Damage Identification) [2]. Ésta se basa en el principio de excitación del material a evaluar, mediante ondas de tipo

acústico [[7]-[9]], mecánico [2], [3], [5] ó ultrasónico [[7]-[8]]. El posterior análisis de propagación de la onda inducida permite realizar la identificación de defectos en el material o estructura evaluada, tales como pérdida de masa [2], deformaciones geométricas [[10]-[11]], entre otros.

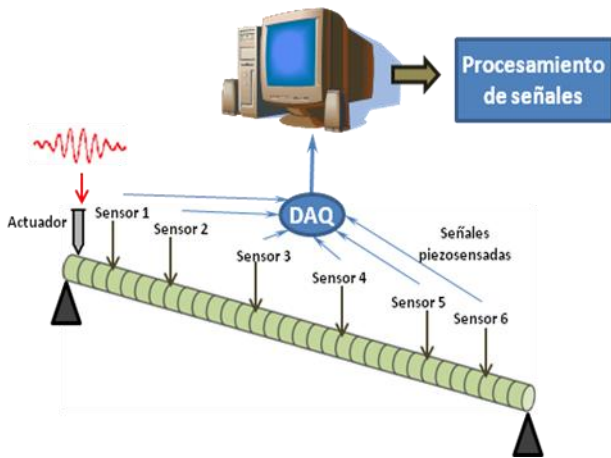


Fig. 1. Ejemplo de sistema VBDI.

En la actualidad, el desarrollo de herramientas de inspección basado en vibraciones se ha incrementado notablemente dado su alto grado de fiabilidad y su reducido costo en los procesos de generación y adquisición de señales [[1]-[3]]. Por tanto, es necesario el desarrollo de una herramienta a nivel de software que facilite el procesamiento y análisis de dichas señales.

Una solución viable es la generación de sistemas expertos, basados en el uso de herramientas matemáticas y técnicas de inteligencia artificial, que faciliten la detección y clasificación de averías de tipo geométrico. Por tal razón, se plantea el desarrollo de una herramienta software basada en la TW y redes SOM que permita realizar el procesamiento y análisis de señales provenientes de tuberías simuladas, bajo condiciones normales y de deformación.

El algoritmo presentado a continuación forma parte del proyecto de investigación denominado “Sistema Experto para la Evaluación del Estado de las Tuberías de Gas: Diseño y Validación Numérica”, el cual pretende dar una solución viable a la problemática mencionada.

III. MARCO CONCEPTUAL

En la actualidad, el diagnóstico de daños estructurales SHM (Structure Health Monitoring), se ha convertido en una de las prioridades en campos de la ingeniería mecánica, civil y aeroespacial, entre otras, con el fin de minimizar el riesgo de accidentes ocasionados por el deterioro de la vida útil de los materiales. Éste involucra varios procesos como son: la identificación del daño, su localización, el tipo y su cuantificación. Rytter define cuatro niveles de monitorización de daños [[12]-[13]]:

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.

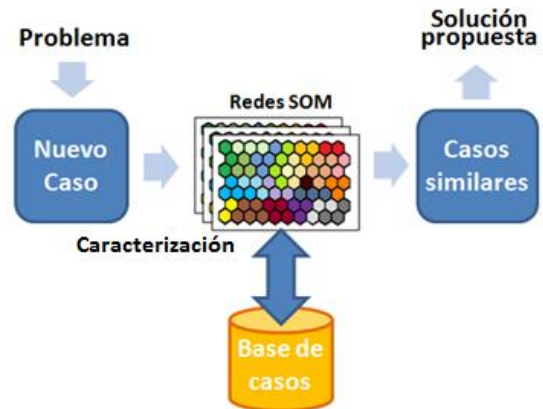


Fig. 2. Esquema del algoritmo.

Una de las técnicas utilizadas en el SHM es la de VBDI el cual asocia directamente los cambios en la respuesta dinámica de la estructura con la presencia de daños en la misma [[14]-[15]] (Ver Figura 1), para ello, requiere de sistemas expertos capaces de generalizar patrones de comportamiento a partir de un grupo de casos iniciales [16].

Dichos sistemas incorporan conocimiento sobre ámbitos específicos del razonamiento humano, tales como la medicina, la ingeniería o los negocios. Un algoritmo de inteligencia artificial, que adquiere la capacidad a nivel experto en la resolución de problemas mediante la reproducción de un cuerpo de conocimiento, se denomina sistema basado en conocimiento o sistema experto [16].

El algoritmo que se presenta en este artículo está basado en el uso de TW y redes SOM (ver apéndice) y su esquema de funcionamiento se observa en la figura 2.

IV. SISTEMA EXPERTO

El sistema implementado está diseñado para efectuar tres acciones fundamentales a partir de la respuesta dinámica de una estructura ante una excitación, como se observa en la figura 3. La primera corresponde al sensado de las señales propagadas a partir de un modelo experimental o un modelo matemático [3]. La segunda corresponde a todo el procesamiento realizado a las señales previamente adquiridas, con el fin de extraer patrones característicos de cada señal. En la última etapa se efectúa el análisis de la información mediante un sistema basado en inteligencia artificial.



Fig. 3. Acciones del sistema experto.

El esquema de funcionamiento propuesto, se fundamenta en trabajos previos destinados al diagnóstico de fallos estructurales [[2]-[3]], el cual fue dividido en 5 etapas básicas, las cuales se observan en la figura 4.

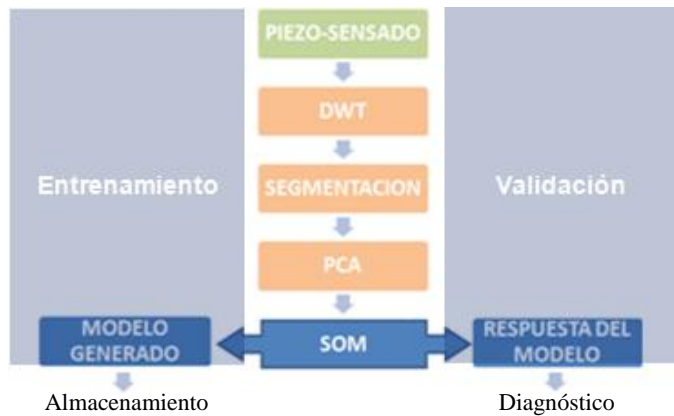


Fig. 4. Etapas de funcionamiento del sistema experto para el entrenamiento y su posterior validación.

Etapa 1: En esta etapa de sensado, se obtiene un conjunto de señales de la respuesta dinámica de la estructura al ser sometida a una señal de vibración en particular, donde cada señal corresponde a una situación de daño específica.

Etapa 2: Está dedicada al procesamiento de las señales piezo-sensadas mediante la TWD, obteniendo los coeficientes wavelet para cada señal.

Etapa 3: La descomposición obtenida, es segmentada para calcular las características de la señal, de forma tal que el sistema sea capaz de reconocer cada caso, a partir de una cantidad mínima de información.

Etapa 4: Esta etapa está dedicada a la reducción de dimensionalidad, en cuanto a la longitud de los vectores característicos de cada señal; conservando la mayor cantidad de información aportada por dichas caracterizaciones, en un nuevo espacio vectorial de menor número de dimensiones que el conjunto de entrada.

Etapa 5: La red SOM posee dos modos de operación. El primero de ellos está dedicado al entrenamiento de la red, mediante el cual se genera el modelo entrenado de la misma. El segundo modo, implementa el modelo generado para obtener las respuestas de la red entrenada y de esta manera conseguir un diagnóstico para el caso de entrada.

V. VALIDACIÓN NUMÉRICA DEL SISTEMA EXPERTO.

La etapa correspondiente al sensado es obviada (dado que la realización de este proyecto tiene como punto de partida el conjunto de datos obtenidos previamente de la simulación de la respuesta dinámica de una tubería), [3]. El escenario de simulación de los daños estructurales está basado en el modelo de una tubería de 32 elementos, dispuesta en configuración de apoyo simple y cuya respuesta dinámica es medida por un grupo de sensores ubicados sobre los elementos 3, 7, 13, 19, 25 y 29 como se muestra en la figura 5.




Fig. 5. Disposición de sensores en la estructura.

Las simulaciones de los casos de daño en la estructura fueron proporcionadas como punto de partida para el desarrollo de esta aplicación. Del conjunto de datos mencionado, se realizó una disposición de casos de la siguiente forma: 70% para entrenamiento y 30% para validación del sistema, aproximadamente. Las situaciones de daño consideradas fueron clasificadas de la siguiente forma:

- Un solo elemento dañado, porcentajes de daño desde el 5% hasta el 50% con paso del 5%, en cualquier ubicación.
- Dos elementos dañados, igual porcentaje de daño en ambos elementos desde el 5% hasta el 50% con paso del 5%, en cualquier ubicación.
- Dos elementos dañados, primer elemento con 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, primer elemento con 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.

Por otra parte, la implementación del sistema experto se estructuró como se observa en la figura 6, cuyas etapas se describen de forma detallada a continuación.

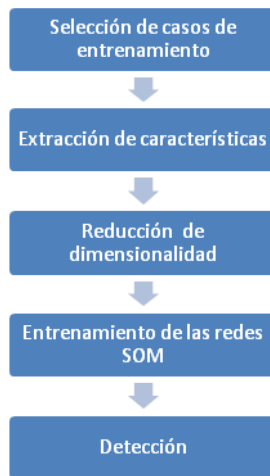


Fig. 6. Esquema de implementación.

A. Selección De Casos De Entrenamiento

En primera instancia, se seleccionaron casos de avería cuya severidad se consideró crítica, es decir, tanto del valor máximo como del mínimo dentro del rango de porcentajes de daño disponible. Esto último, con el fin de suministrarle a las redes neuronales 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 de las mismas.

La disposición del conjunto de datos suministrados se realizó como se explicó anteriormente, lo cual se observa en la figura 7, teniendo en cuenta que el conjunto de casos restantes de entrenamiento debe ser seleccionado de forma aleatoria para evitar sesgar la respuesta del sistema.




Fig. 7. Disposición de los casos suministrados.

En la selección aleatoria de los casos restantes de entrenamiento (Ver figura 7), se tomó en cuenta el problema de simetría presente en la tubería [3]. Con base en esta información y en los datos de simulación de la estructura, se verificó el problema mencionado mediante el entrenamiento de una red SOM, la cual fue utilizada únicamente para tal propósito. El conjunto de casos utilizados para el entrenamiento de dicha red fue seleccionado al azar, de tal forma que los casos seleccionados no tuvieran correspondencia simétrica entre sí. Una vez entrenada la red, se realizó el proceso de validación con los casos simétricamente relacionados a los datos de entrenamiento previamente seleccionados, verificando así la confusión de la

respuesta del sistema debido al gran nivel de correlación existente entre la señal de entrenamiento y su señal simétrica.

Debido al problema anteriormente expuesto, gran parte de las falencias en la detección de daños, fueron resultado de una disposición deficiente de los casos utilizados en el proceso de aprendizaje del sistema experto y de evaluación del mismo.

Por tanto, se planteó una estrategia para la selección y agrupación pseudo-aleatoria de casos de daño asociado directamente con su correspondiente caso simétrico de forma simultánea, como se observa en las figuras 8, 9 y 10, hasta completar, el número necesario de escenarios de daño para el entrenamiento como previamente se describió en la figura 7.




Fig. 8. Casos directos y simétricos de un solo elemento dañado.




Fig. 9. Casos directos y simétricos de dos elementos dañados.




Fig. 10. Casos especiales donde el caso directo es igual al simétrico en cuanto a ubicación.

B. Extracción De Características:

Para la extracción de las características de las señales, se realizó un debido procesamiento de las mismas, el cual está dividido en tres etapas: cálculo de la TWD, segmentación de datos y obtención de características.

La primera de ellas consiste en aplicar la TWD, utilizando la wavelet madre DB6 [2], [5], con un nivel de descomposición 7 (ver apéndice), para cada uno de los casos de interés.

Posteriormente, se efectuó el proceso de segmentación de la información procedente de la TWD, estableciendo como punto de referencia los coeficientes de detalle y aproximación del caso sin daño. Para ello se realizó el desplazamiento de una ventana a lo largo del vector de coeficientes de cada nivel de descomposición, analizando así, su comportamiento en cuanto al valor promedio de los datos contenidos dentro de dicha ventana. Esto último, con el fin de detectar los mínimos locales que delimitan los segmentos de datos, como se muestra en la figura 11.




Fig. 11. Coeficientes de detalle de nivel 3 y su respectiva segmentación.

Partiendo del fundamento matemático de la TWD, el cual establece que el número de coeficientes se reduce a medida que aumenta el nivel de descomposición [6], [[17]-[19]] tal y como se observa en la figura 12, se estimó que el ancho de la ventana debía ser inversamente proporcional al nivel de descomposición analizado, con el fin de tener una exploración más detallada de los datos.

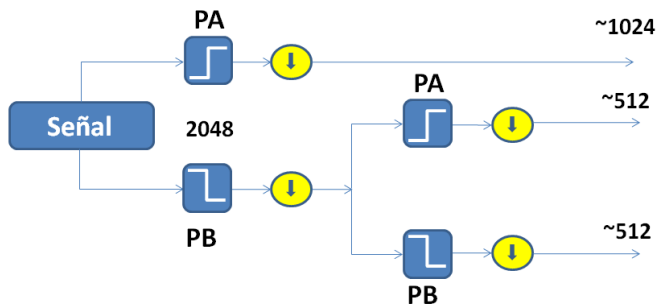


Fig. 12. Análisis multiresolución para la obtención de los coeficientes de descomposición de la TWD.

En la última etapa de este proceso, se obtuvo la diferencia entre los coeficientes de descomposición de los casos de interés y los del caso sin daño. Ésta operación se realizó nivel por nivel. En consecuencia, al aplicar el perfil de segmentación obtenido a partir del caso sin daño a dichas diferencias, se obtuvieron segmentos de datos a los cuales se les calculó la raíz cuadrada de su energía. Finalmente, las características resultantes se unen en un solo vector ordenado como se observa en la figura 13:




Fig. 13. Organización del vector de características.

C. Reducción de la Dimensionalidad

Con el fin de reducir los costos computacionales directamente relacionados con el tiempo de ejecución de los procesos de entrenamiento y validación del sistema [2], [[20]-[23]] fue necesario efectuar la reducción de la dimensionalidad, de cada uno de los vectores de características [2], mediante PCA; ajustando así, los resultados de la caracterización de los grupos de datos de entrenamiento y validación.

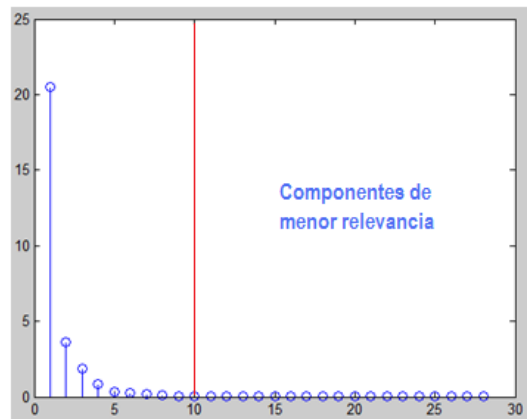


Fig. 14. Varianzas de las componentes principales de la caracterización de los datos del sensor 3.

Como resultado de lo anteriormente expuesto, se generó un espacio de componentes no correlacionadas de igual tamaño que los grupos de datos originales, cuyos ejes de coordenadas corresponden a los ejes de mayor varianza [[21]-[22]]. En la figura 14, se pueden observar, las varianzas de las componentes del nuevo sistema de coordenadas generado en esta etapa, para un grupo de datos en particular.

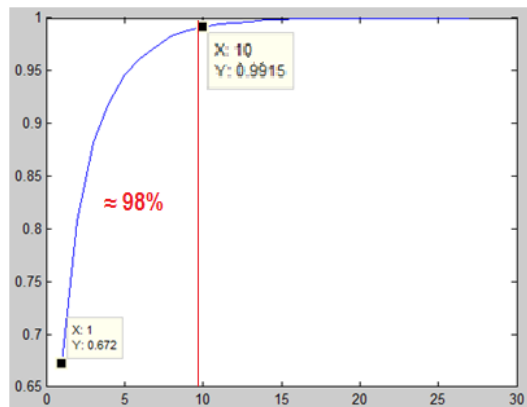


Fig. 15. Comportamiento de la varianza con respecto al número de componentes seleccionadas.

Posteriormente, a partir de los resultados obtenidos del algoritmo PCA, se seleccionaron las componentes de mayor relevancia, es decir, las que contenían el mayor porcentaje de la varianza total, como se observa en las figuras 14 y 15, suprimiendo así, las componentes menos significativas, con lo que se redujo la dimensión de los vectores a 10 componentes.

D. Entrenamiento de las Redes SOM

Considerando que se tenían seis grupos de datos simulados y procesados, correspondientes a señales monitorizadas en seis puntos específicos del modelo de la estructura, se estableció que el número necesario de redes neuronales para implementar el sistema experto debería corresponder con dicho número de grupos.

La generación y entrenamiento de las redes neuronales, se realizó teniendo en cuenta las características observadas en la TABLA I, basadas en las recomendaciones observadas en el estado del arte, utilizando la herramienta “SOM Toolbox for Matlab 5” [24].

TABLA I

Características seleccionadas para la generación y entrenamiento de las redes SOM.

Característica	Tipo
Normalización (normalization)	Logístico ('logistic')
Tamaño (size)	Grande ('big')
Topología (lattice)	Hexagonal ('hexa')
Malla (shape)	Plana ('sheet')
Inicialización (init)	Lineal ('lininit')
Tipo de entrenamiento (training)	Largo ('long')
Algoritmo de entrenamiento (algorithm)	Por lotes ('batch')

Basados en los resultados obtenidos a partir del proceso de entrenamiento, se realizó la organización de los datos utilizados para tal fin, en grupos o clústeres de acuerdo a la similitud de los datos modelados, mediante la red SOM [2], [[24]-[26]].

Para obtener dichos clústeres, se obtuvieron las respuestas de cada una de las redes neuronales para cada caso usado en el entrenamiento, con lo cual se determinaron los grupos de neuronas que se activaron con estos casos y los que no hicieron.

Posteriormente, se asociaron las neuronas inactivas a las activas más cercanas, es decir, aquellas cuya distancia euclidiana calculada entre sus respectivos vectores de pesos, fue la mínima, conformando así, colonias a partir de estas neuronas vecinas.

Así mismo, a cada una de las colonias mencionadas se le asignó un número de registro, el cual fue asociado con una base de datos que contiene la información referente a los casos

de entrenamiento, organizada de acuerdo a las neuronas activadas por dichos casos, como se observa en la figura 16.




Fig. 16. Método para la organización de los datos de entrenamiento en clústeres de neuronas.

E. Validación

Una vez entrenado el conjunto de redes neuronales y de haber generado la base de casos, se efectúa el proceso de detección de daños, cuyo esquema de funcionamiento se muestra en la figura 17.

Teniendo en cuenta el conjunto de casos de validación como punto de partida, se obtiene la descomposición wavelet, en una primera etapa del procesamiento de los datos. Posteriormente, dicha descomposición es segmentada en una segunda etapa, como se describió en la sección B, utilizando como señal de referencia el caso sin daño.

Una tercera etapa, se encargó del proceso de estandarización de los casos caracterizados, donde los grupos de características obtenidas como resultado de la etapa inmediatamente anterior, fueron centrados con base en los cálculos de valor medio y desviación estándar de cada una de las componentes originales de la caracterización del grupo de datos utilizado en el proceso de entrenamiento del sistema.

Una vez estandarizados los datos, se efectuó el proceso de reducción de dimensionalidad de la información, a partir de los coeficientes de PCA previamente obtenidos para cada sensor en la etapa anterior al entrenamiento de las redes SOM.

No obstante, fue necesario normalizar los datos transformados al espacio de PCA, utilizando para ello, los perfiles de normalización creados al ajustar los datos de entrenamiento, finalizando así las etapas correspondientes al procesamiento de las señales a evaluar.

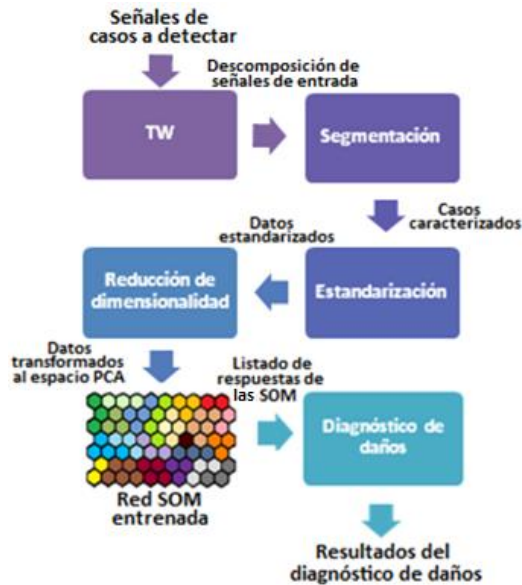


Fig. 17. Esquema de validación del sistema experto.

Siguiendo el orden del esquema propuesto en la figura 17, se procedió con la fase de funcionamiento de la red SOM, en la cual los datos previamente procesados son analizados mediante el conjunto de redes SOM entrenadas, esto con el fin de obtener la respuesta del sistema experto ante las señales de cada caso a detectar.

El sistema de inferencia, se basó en el análisis de las respuestas más significativas del sistema para el diagnóstico de daños considerando tres umbrales diferentes, aplicados a las distancias euclidianas entre los vectores de características de los casos de entrada y las caracterizaciones de los casos almacenados, para el filtrado de las respuestas de las redes SOM [2], tal y como se describe en la figura 18.

El primero de ellos (K1) determina cuáles redes neuronales son relevantes en el proceso de diagnóstico. El segundo (K2), corresponde a la selección de neuronas ganadoras dentro de cada SOM escogida y el último umbral (K3), define la recopilación de casos de daño, almacenados dentro de los clústeres correspondientes a las neuronas seleccionadas de cada una de las redes tomadas en cuenta [2].

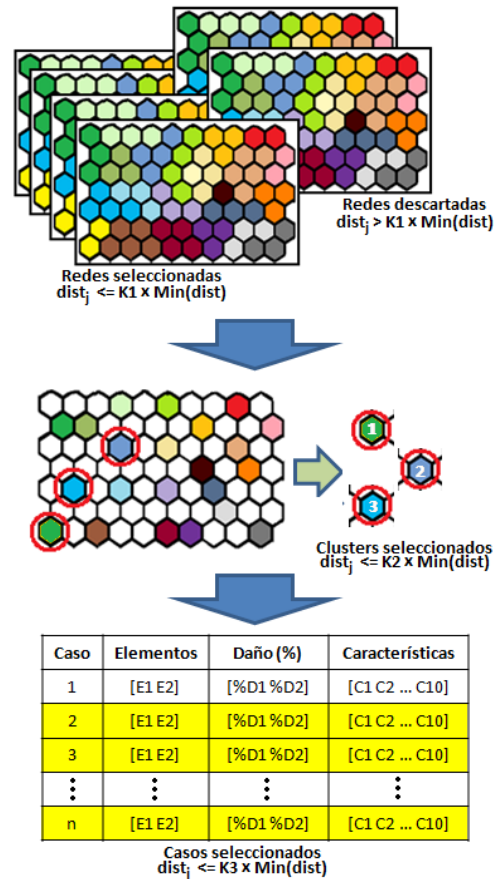


Fig. 18. Método para la búsqueda de casos cercanos al caso de entrada en cuanto a distancias euclidianas.

Posteriormente, se calcularon los factores de cada elemento presente en el conjunto de respuestas de la red y las estimaciones de daño para cada caso evaluado por el sistema [2]. El cálculo de los factores se realizó usando la ecuación 1, donde F_e es el factor calculado para el elemento e , d_e corresponde a las distancias euclidianas de las respuestas de la red, relacionadas con el elemento e y finalmente q es el total de casos obtenidos para el proceso de diagnóstico de daños [2].

Partiendo de los factores de mayor peso, se estableció un umbral, el cual determina cuales elementos se pueden considerar como averiados.

$$F_e = \sum_{j=1}^q \frac{1}{d_{ej}} \quad (1)$$

Por otra parte, se estimaron los porcentajes de daño de cada caso de entrada mediante la ecuación 2, la cual consiste en una suma ponderada de los daños correspondientes a las respuestas de las redes SOM con base en las distancias euclidianas calculadas con respecto a cada uno de los casos a analizar.

$$\%daño = \sum_{j=1}^n \frac{1/d_j}{\left(\sum_{i=1}^n 1/d_i\right)} \cdot daño_j \quad (2)$$

Donde, *daño* corresponde a los porcentajes de daño de los casos obtenidos del conjunto de redes SOM mediante el proceso descrito en la figura 18, *d* es la distancia euclidiana entre la caracterización del caso de entrada y la del caso entregado por el diagnóstico, *n* es el total de casos entregados por las redes SOM y *%daño* almacena la estimación de daño calculada para la entrada ya mencionada.

VI. RESULTADOS Y ANÁLISIS DE LOS MISMOS

Para las pruebas realizadas se seleccionaron aleatoriamente el 30 % del total de datos (4452 casos) como datos de validación.

Una vez seleccionados los grupos de casos empleados para los procesos de entrenamiento y validación de las redes, éstos se mantuvieron constantes con el fin de evaluar las variantes del sistema experto; conservando así, las mismas condiciones (grupos de datos predefinidos). Estandarizando de esta manera, el proceso de validez del sistema al establecer una comparación entre los diferentes esquemas de prueba implementados, los cuales se muestran en las TABLAS II, III y IV. Partiendo de los mismos grupos de datos como punto de referencia para su análisis.

TABLA II
Selección de subfamilias Wavelet.

Prueba #	Wavelet Madre	Detección (%)		
		Buena	Parcial	Mala
1	Db4	76,44	14,08	9,48
2	Db5	68,60	19,59	11,81
3	Db6	70,13	16,71	13,16
4	Db7	62,42	23,27	14,31
5	Db8	67,65	19,00	13,34
6	Db9	59,32	25,11	15,57
7	Db10	62,60	24,08	13,32
8	Sym2	62,76	18,49	18,76
9	Sym3	72,96	17,23	9,82
10	Sym4	73,97	16,37	9,66
11	Sym5	73,25	17,86	8,89
12	Sym6	70,01	16,73	13,25
13	Sym7	60,40	21,14	18,46
14	Sym8	66,06	19,16	14,78
15	Coif2	77,72	13,36	8,92
16	Coif3	59,34	23,50	17,16
17	Coif4	63,79	22,57	13,63
18	Coif5	46,97	31,00	22,03

En primera instancia, se realizó el estudio de las familias y subfamilias wavelet seleccionadas para el análisis de los diferentes escenarios de daño, con el fin de establecer la wavelet madre más apropiada para la implementación del sistema experto. Esto último partiendo de la información

recopilada en el estado del arte [2], [6], [17], [19], [23], [[27]-[28]].

Por lo tanto, se efectuaron pruebas de detección de daño con las subfamilias Daubechies Symlet y Coiflets como se observa en la TABLA II. Donde, los mejores resultados de detección fueron obtenidos a partir de una caracterización con las subfamilias Db4, Db6, Sym4, Sym5, Coif2, Coif4. Comprobando así que este tipo de wavelets son apropiadas en aplicaciones de detección de daños dado que tienen una función de escala ideal [17].

Una segunda prueba, consistió en comprobar la incidencia del proceso de segmentación en la eficiencia del sistema experto. Para ello, se tomaron como referencia los resultados obtenidos en la prueba anterior y con base en el esquema de la figura 17 se suprimió la etapa correspondiente al proceso de segmentación.

TABLA III

Rendimiento del sistema experto con el proceso de segmentación.

Prueba #	Wavelet Madre	Segmentación		Detección (%)		
		Con	Sin	Buena	Parcial	Mala
1	Db4	X		76,44	14,08	9,48
2			X	12,96	7,23	79,81
3	Db6	X		70,13	16,71	13,16
4			X	14,15	7,37	78,48
5	Sym4	X		73,97	16,37	9,66
6			X	13,05	6,87	80,08
7	Sym5	X		73,25	17,86	8,89
8			X	16,82	8,63	74,55
9	Coif2	X		77,72	13,36	8,92
10			X	12,87	6,22	80,81
11	Coif4	X		63,79	22,57	13,63
12			X	13,41	6,99	79,60

Demostrando así, que la supresión de ésta etapa reduce en gran medida la fiabilidad del sistema como se puede observar en la TABLA III.

De forma similar a la prueba anterior, con base en las wavelets madre seleccionadas en la TABLA I, se probó el desempeño del sistema al suprimir la etapa de reducción de dimensionalidad de la figura 17.

Por tanto, se comprobó que la inclusión de una etapa de reducción de dimensionalidad constituye una representación robusta, mejorando así el desempeño del sistema experto como se observa en la TABLA IV [43].

TABLA IV

Rendimiento del sistema experto con el proceso de análisis de componentes principales.

Prueba #	Wavelet Madre	PCA		Detección (%)		
		Con	Sin	Buena	Parcial	Mala
1	Db4	X		76,44	14,08	9,48
2			X	54,07	16,96	28,98
3	Db6	X		70,13	16,71	13,16
4			X	57,84	18,15	24,01
5	Sym4	X		73,97	16,37	9,66
6			X	53,21	17,83	28,95
7	Sym5	X		73,25	17,86	8,89
8			X	55,26	17,72	27,02
9	Coif2	X		77,72	13,36	8,92
10			X	54,81	19,05	24,15
11	Coif4	X		63,79	22,57	13,63
12			X	54,67	24,42	20,91

Finalmente se probó el desempeño del sistema bajo condiciones de atenuación y ruido aplicado al conjunto de señales empleadas para realizar el proceso de validación; para dicha evaluación se emplearon las wavelets madre seleccionadas a partir de los resultados que aparecen en la TABLA II.




Fig. 19. Porcentajes de acierto ante atenuaciones.

Para calcular la eficiencia del sistema en el diagnóstico de averías geométricas bajo situaciones de atenuación en los datos de entrada, se redujo la amplitud original de las señales empleadas para validación en un 5 y 10%. En esta prueba se observó que las wavelets madre con las cuales el desempeño del sistema es alto, fueron Db4 y Coif2 como se muestra en la figura 19

Para evaluar el desempeño del sistema ante problemas de ruido contenido en los datos de entrada, se adicionó una señal aleatoria a los datos originales empleados para validación; donde se notó una fuerte falencia del sistema

en la detección de daños cuando las señales a diagnosticar presentan ruido (Ver figura 20).




Fig. 19. Porcentajes de acierto ante ruidos.

En la figura 20 se observa que aunque el sistema no es robusto a los ruidos, las wavelets madre que permiten alcanzar un mejor desempeño del sistema, son las mismas dos que se seleccionaron en la prueba pasada.

VII. CONCLUSIONES

Se determinó que las wavelets madre, las cuales permiten al algoritmo de supervisión experta lograr un mejor desempeño en cuanto a atenuación, ruido y cantidad de información obtenida son las Sym4, Db4 y Coif2, siendo esta última la mejor entre las otras.

A partir de las pruebas realizadas, se concluye que la adición de una etapa de segmentación a los coeficientes de la TW, mejora considerablemente la eficiencia del sistema en cuanto a la detección de averías geométricas.

Por otra parte, se concluyó que el sistema es sensible a pequeñas variaciones de ruido (del orden del 0,01%). La presencia del mismo influye adversamente en el proceso de diagnóstico.

En cuanto a niveles de atenuación del sistema es bastante robusto, ya que posibilita que la señal de entrada sea atenuada hasta en 10% de la amplitud de la señal original y aun así el sistema es capaz de efectuar un diagnóstico con una alta probabilidad de acierto.

Aunque la eficiencia del algoritmo de supervisión experta en la detección de daños fue la más alta al usar la wavelet madre Coif2, en aplicaciones hardware se recomienda implementar la wavelet Db4 debido a su menor complejidad de cálculos, evidenciada por un menor tiempo de ejecución del análisis wavelet.

VIII. APÉNDICE

Transformada Wavelet

Las Wavelets son familias de funciones cuya energía está concentrada en el tiempo. Tienen una forma de onda característica que es oscilante y entre sus múltiples ventajas sobresale la versatilidad para examinar fenómenos variantes en el tiempo [[18]-[19]].

A diferencia de la Transformada de Fourier (TF), la Transformada Wavelet (TW) no descompone una señal en la suma de senos y cosenos para cada frecuencia ω de amplitud constante y de duración infinita. La TW descompone una señal temporal en una suma de funciones base en el dominio del tiempo con diferentes grados de resolución en cuanto a frecuencia como se aprecia en la figura 21 [6], [[18]-[19]].

Esta descomposición simultánea tiempo-frecuencia¹ da a la TW una ventaja especial sobre la tradicional TF en el análisis de señales no estacionarias.

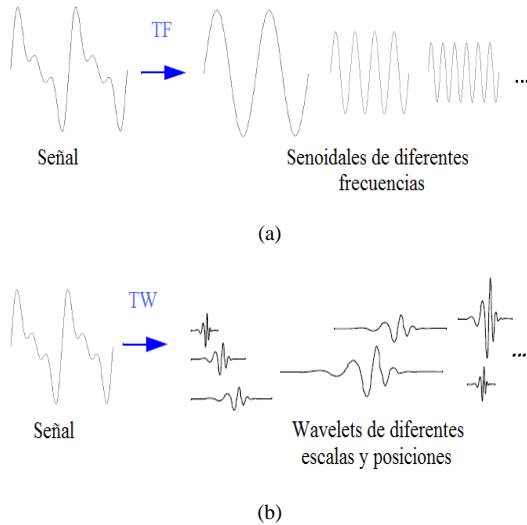


Fig. 21. Esquemas básicos del funcionamiento de la TF y la TW respectivamente [17].

Otra de las ventajas de la TW frente a la TF es el disponer de una amplia familia de wavelets², la cual permite analizar señales de diversa índole; sin embargo, la elección de la wavelet es un proceso que depende principalmente del tipo de señal que se desea analizar y del objetivo para el cual se pretenda realizar dicha transformación como por ejemplo: la detección de discontinuidades y puntos de ruptura de las señales, identificación de frecuencias puras, reducción de

¹ Una analogía clásica dada por Daubechies establece que el análisis tiempo-frecuencia realizado con ayuda de la transformada wavelet es similar al estudio que realiza un músico, quien analiza en el espacio tiempo el sonido de melodías creadas por la combinación de diferentes notas musicales y su frecuencia asociada [19].

² Existen varias familias wavelet entre las que se encuentran Haar, Daubechies, Symlets, Coiflets, Biorthogonal, Reverse Biorthogonal, Meyer, Gaussian, Mexican hat, Morlet, Shannon, B-Spline, entre otras [30].

ruido en señales, compresión de señales, aproximación de funciones, métodos espectrales para resolver ecuaciones diferenciables, análisis de fluidos turbulentos, entre otros [[29]-[30]].

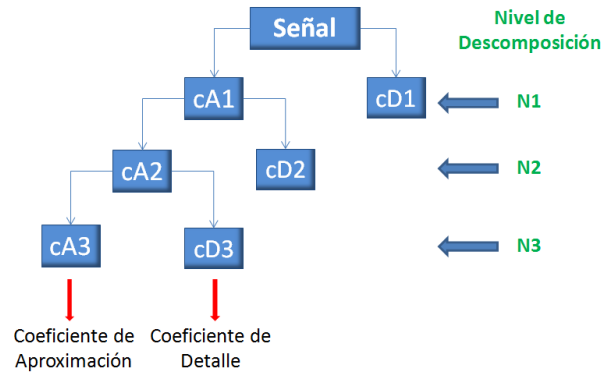


Fig. 22. Descomposición wavelet en coeficientes de detalle y aproximación.

Análogamente a la Transformada de Fourier se define para señales continuas y discretas, la TW permite hacer un análisis tanto en tiempo continuo (TWC) como discreto (TWD). Esta última está íntimamente ligada al análisis de multi-resolución (MRA), formulado por Mallat a finales de los 80's la cual permite realizar una transformada inversa de fácil cálculo y tan rápida como la transformada directa cuando la familia de wavelets es ortogonal³ [18], [28].

La TWD divide las señales en dos tipos de subseñales, la aproximación y los detalles como se puede apreciar en la Fig. 22. La aproximación corresponde a una copia de la señal a menor resolución y los detalles almacenan información referida a los cambios locales en la señal original. [6], [29].

Redes Neuronales Tipo SOM

Las redes neuronales artificiales son modelos aproximados que tratan de simular mediante procesos matemáticos el comportamiento del cerebro humano, suelen desempeñarse como máquinas de aprendizaje pues poseen la capacidad de aprender y generalizar a partir de un conjunto de datos [26], [31]. Existen varias arquitecturas de redes neuronales, cada una de ellas posee características diferentes que las hace apropiadas para abordar tareas específicas, tales como: el control de procesos industriales, el reconocimiento de patrones, la identificación, la clasificación, la visión, predicciones en el mercado financiero, entre otras, [20], [[25]-[26]].

³ Es conveniente que el conjunto de funciones wavelet sean ortogonales entre sí, de esta manera es posible recuperar la señal a partir de los coeficientes de la TWD [18].

A principios de los años ochenta Teuvo Kohonen, de la Universidad de Helsinki, Finlandia, basado en las evidencias que demuestran que el cerebro además de poseer una organización neuronal que está predeterminada genéticamente, también puede crear y ordenar grupos de neuronas especializadas que se originen mediante el aprendizaje [31], decidió emprender la búsqueda de un modelo de sistema con un comportamiento semejante al humano.

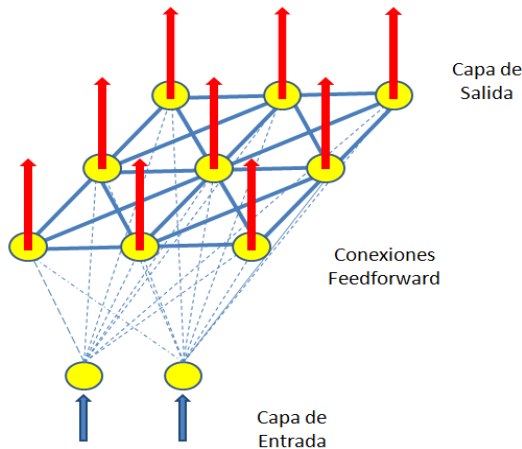


Fig. 23. Representación esquemática de la arquitectura SOM y su interacción con el espacio de entrada.

La característica principal del modelo de red propuesto por Kohonen fue la capacidad del mismo para formar mapas de características de forma similar al del cerebro humano, el cual permitiera preservar el orden del espacio de entrada en el espacio de salida como se muestra en la figura 23, facilitando así, la visualización de los datos en forma gráfica [26]. Posteriormente en el año 1982 crea una red no supervisada, conocidas como redes SOM y en la actualidad es quizás uno de los modelos más aproximados a las redes biológicas [26].

La popularidad de los mapas auto-organizativos, radica principalmente en la capacidad de preservar la topología de los datos, proyectándolos en una malla de dimensión más baja, permitiendo así encontrar patrones similares entre grupos de datos [[32]-[35]].

El proceso anteriormente expuesto, es realizado durante la etapa de entrenamiento de las redes SOM, obteniendo así una categorización (clusterización) de los datos introducidos a la red, de forma tal que aquellos con características similares son clasificados formando parte de una misma categoría y por lo, tanto solo algunas neuronas responderán a ciertos estímulos de entrada [20], [26].

Otra característica de la red propuesta por Kohonen es su aprendizaje de tipo competitivo suave con restricciones de topología, el cual se debe al proceso de actualización de la neurona ganadora, es decir la neurona más cercana al dato de entrada presentado a la red. Por lo tanto, la activación de una neurona dada tiene efecto sobre las neuronas que la rodean originando así una malla de vecindad [26].

Las características mencionadas previamente, hacen de este tipo de redes una herramienta valiosa para realizar aplicaciones relacionadas con la minería de datos, el reconocimiento de voz, reconocimiento de textos manuscritos, problemas de optimización, análisis de texturas, organización de documentos, extracción de características, entre otros [26], [31].

Análisis de Componentes Principales

El objetivo principal de este tipo de análisis, es detectar información redundante y re-organizarla de tal forma que sea fácil de interpretar [[20]-[23]], [26]. Esta herramienta permite reducir el número de variables manteniendo la mayor información posible.

Otro aspecto importante del fundamento de PCA es que las variables originales son transformadas en otro conjunto de variables que no tienen relación entre sí, midiendo el aporte de cada una de ellas sobre la varianza total de los datos. Así mismo las nuevas variables no tienen redundancia de información y son combinaciones lineales de las variables originales [[21]-[22]].

Adicionalmente, se busca obtener un menor número de variables que las originales y que a su vez almacenen la mayor parte de la información o variabilidad de los datos.

Por lo tanto el concepto de mayor información en el contexto de PCA está relacionado con la mayor variabilidad o varianza sin realizar suposiciones sobre el comportamiento de las variables [21].

Otro aspecto a tener en cuenta para el uso de esta herramienta computacional está fundamentado en que dado el hecho que si las variables originales no están inicialmente correlacionadas, no se justifica un análisis de componentes principales. De hacerlo, se obtendrían las mismas variables pero reordenadas de mayor a menor varianza [[21]-[22]].

IX. REFERENCIAS

- [1] Doebbling Scott W., Farrar Charles R., Michael Prime B., Shevitz Daniel W., “Damage Identification and Health Monitoring of Structural and Mechanical Systems from Changes in their Vibration Characteristics: A Literature Review”. Los Alamos National Laboratory, May 1996.
- [2] Kolakowski, Przemyslaw; Mujica, Luis Eduardo; Rodellar, José; 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.
- [3] 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-STSIIVA, 2009. Universidad Tecnológica de Pereira, Pereira, Colombia. Septiembre 9-11 de 2009.
- [4] Saad Soheil, Noori Mohammad N., Buckner Gregory D., Furukawa Tadatoshi, Suzuki Yoshiyuki, “Structural Health Monitoring and Damage Detection Using an Intelligent Parameter Varying (IPV) Technique”.

- Sciencedirect, Non-Linear Mechanics, Vol. 39_2004. Elsevier. 2004. Págs. 1687-1697.
- [5] Kolakowski, Przemyslaw; Mujica, Luis Eduardo; 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 63-79.
- [6] Vega Valdomiro, "Aplicación de la Transformada Wavelet Discreta (DWT) en la detección e identificación de eventos de la calidad de la energía eléctrica". Tesis de Pregrado. Universidad Industrial de Santander, Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones, Colombia. 2004.
- [7] Portoroz Slovenia, Zelesnev V, Aleshin V, Kobayakov V. Analysis of Corrode Pipeline Segments Using In-Line Inspection Data. The 8th international conference of the Slovenian Society for Non-Destructive Testing "Application of Contemporary Non-Destructive Testing in Engineering", September 1-3, 2005, pp.383-389.2005.
- [8] Vahaviolos Sotirios, Wang David, Carlos Mark. Advanced Acoustic Emission for On-Stream Inspection of Petrochemical Vessels. ECNDT 2006-We.3.6.5.2006.
- [9] Yang Shihui Kuang, Lee Jie Hung, Lee Ping Horn, Cheng Jyin Wen. The Effect of the Longitudinal Welded Support on the Pipe for Guided Wave Propagation. 12th A-PCNDT 2006. Asia-Pacific Conference on NDT, 5th-10th Nov 2006, Auckland, New Zealand. 2006.
- [10] Ai Changsheng, Zhao Honghua, Ma Rujian, Dong Xueren. Pipeline Damage and Leak Detection Based on Sound Spectrum LPCC and HMM. Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications (ISDA'06). IEEE computer society. 2006
- [11] Tracy M, Chang F. Identifying Impacts in Composite Plates with Piezoelectric Strain Sensors, part I: theory. Journal of intelligent material systems and structures, 9(11). Nov 1998. Pg 920-928.
- [12] Mújica Luis Eduardo, Vehí Josep, Rodellar Jose, Kolakowski Przemyslaw, Worden Keith. Impact Damage Detection in Aircraft Composites Using Knowledge-Based Reasoning. Structural Health Monitoring, An International Journal. SAGE Publications.
- [13] Ahn Seok-Hwan, Nam Ki-Woo, Takahashi Koji, Ando Kotoji. Comparison of experimental and finite element analytical results for the strength and the deformation of pipes with local wall thinning subjected to bending moment. Nuclear Engineering and Design 236, 2006. pp 140-155.
- [14] Mal Ajit, Ricci Fabrizio, Banerjee Sauvik, Shih Frank. A Conceptual Structural Health Monitoring System Based on Vibration and Wave Propagation. Structural Health Monitoring, 9 2005; VOL. 4. Pg. 283 - 293. 2005.
- [15] Harris Chuck, Tdw Ili Services. Advances in Pipelines Assessments. Pipeline & gas journal. August 2006. USA, Tulsa, OK.2006.
- [16] Nilsson Nils, Inteligencia Artificial una Nueva Síntesis. Mc. Graw Hill. Madrid, España, 1ra edición. 2001.
- [17] Ovanesova A. V., Suárez L. E., "Applications of wavelet transforms to damage detection in frame structures", Sciencedirect, Engineering Structures, Vol. 26_2004. Elsevier. 2004. Págs 39-49.
- [18] Mallat Stéphane, A Wavelet Tour of Signal Processing. Academic Press, Second Edition, 1999.
- [19] Daubechies I. Ten Lectures on Wavelets. The Society for Industrial and Applied Mathematics, 1992.
- [20] Cuta D. César, "Aplicación de Mapas Auto organizativos de Kohonen para la Identificación de Patrones de Comportamiento en los Precios de Oferta en la bolsa de los generadores en el mercado mayorista de energía en Colombia", Tesis de Pregrado, Universidad Industrial de Santander, Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones, Colombia. 2004.
- [21] Colmenares G. "Análisis Multivariante y Aplicaciones". Universidad de los Andes Mérida- Venezuela. Postgrado en economía. <http://webdelprofesor.ula.ve/economia/gcolmen/postgrado2.html>
- [22] Englehart K.; Hudgins B.; Parker P. "A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control". IEEE transactions on biomedical engineering, vol. 48, no. 3, March 2001.
- [23] 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
- [24] Vesanto Juha, Himberg Johan, Alhoniemi Esa, Parhankagas Juha, "SOM Toolbox for Matlab 5", SOM Toolbox team, Helsinki University of Technology, 2000.
- [25] Medina C. Fabián, Serrano T. Mauricio, "Red Neuronal Artificial de Kohonen para la Localización y Relocalización de Recursos Aplicado a la Ciudad de Bucaramanga", Tesis de Pregrado, Universidad Industrial de Santander, Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones, Colombia. 2004.
- [26] Moreno A. Sebastián, "Robustez y flexibilidad en los Mapas Auto Organizativos para Ambientes no Estacionarios", Tesis de Pregrado, Universidad Técnica Federico Santa María. Departamento de Informática, Chile, 2007. <http://www.cis.hut.fi/proyectos/somtoolbox/>.
- [27] Misiti Michel, Misiti Yves, Oppenheim Georges, Poggi Jean-Michel. The Mathworks- Wavelet Toolbox 4, 2007.
- [28] Hubbard Burke Barbara, The World According to Wavelets. A K Peters, Ltd. 1996.
- [29] Payman Jalali, Wavelets and Applications. Energy Technology Department, Lappeenranta University of Technology, August 2000.
- [30] Martínez Giménez Félix, Peris Manguillot Alfredo, Rodenas Escibá Francisco, Tratamiento de Señales Digitales Mediante Wavelets y su Uso con Matlab, Club Universitario, 2004.
- [31] Acosta, María; Zuluaga, Camilo, "Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web", Universidad Tecnológica de Pereira, 2000.
- [32] T. Kohonen, "Self Organizing and Associative Memory". Springer Verlag, New York, 2nd edition, 1988.
- [33] Teuvo Kohonen, "The Self-Organizing". In proceedings of the ieee, volume 78, 1990.
- [34] Teuvo Kohonen, "Self organizing maps", volume 30. Springer Verlag, 2001.
- [35] Erkki Oja, Samuel Kaski, "kohonen maps", Elsevier, 1999.

X. BIOGRAFÍAS

Daniel Ricardo Ojeda Giratá. Bachiller técnico electricista, Colegio Nacional de Bachillerato Técnico Gustavo Jiménez. Sogamoso, Boyacá, Colombia (2002). Estudiante de ingeniería electrónica en la Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones (E³T) de la Universidad Industrial de Santander, Bucaramanga, Colombia. Sus intereses profesionales se centran en el estudio de sistemas de control e instrumentación y el análisis de señales discretas.

Pablo Emilio Acevedo Díaz. Bachiller técnico en sistemas, Instituto Técnico Superior Dámaso Zapata. Bucaramanga, Santander, Colombia (2003). Estudiante de ingeniería electrónica en la Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones (E³T) de la Universidad Industrial de Santander. Sus intereses profesionales se centran en el estudio de procesamiento digital de señales e imágenes y el análisis de sistemas de comunicaciones.

MIE(c). Ing. Wilmer Alexis Sandoval Cáceres. Ingeniero electrónico egresado de la Universidad Pontificia Bolivariana. Bucaramanga, Santander, Colombia (2005), Candidato a maestría en ingeniería electrónica UIS (Universidad Industrial de Santander), Bucaramanga (2006-2008). Director del semillero de investigación Asimov, Universidad Santo Tomás De Aquino, Bucaramanga, Santander, Colombia (Primer semestre de 2009). Miembro del grupo de investigación CEMOS, UIS (2006-2009). Áreas de investigación: Robótica móvil, control, identificación de daños basados en vibraciones.

PhD Rodolfo Villamizar Mejía. Ingeniero electricista egresado de la UIS. Bucaramanga, Santander, Colombia (1999), Ingeniero electrónico egresado de la UIS, Bucaramanga, Santander, Colombia (2000). Doctor en Tecnologías Avanzadas de Control, Universitat de Girona, Girona, España (2005). Miembro del grupo de investigación CEMOS. Coordinador de la Maestría en Ingeniería Electrónica de la UIS. Miembro del grupo de investigación MICElab Research Group, Universitat de Girona. Áreas de investigación: Técnicas avanzadas de control, técnicas basadas en intervalos modales y control supervisorio.