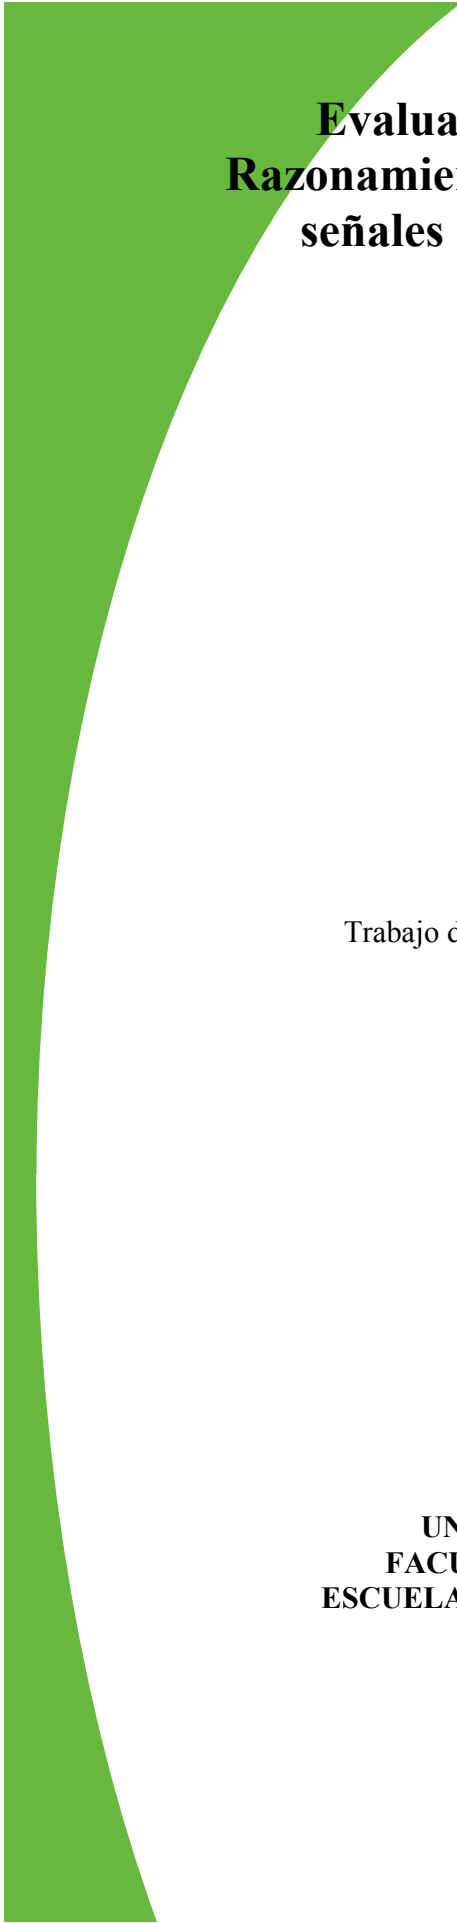


**Evaluación de daños en tuberías, mediante
Razonamiento Basado en Casos y procesamiento de
señales con transformada Wavelet y MPCA.**

**José de Jesús Gómez Pérez
Diana Marcela González Quintana**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA
2010**



**Evaluación de daños en tuberías, mediante
Razonamiento Basado en Casos y procesamiento de
señales con transformada Wavelet y MPCA.**

**José de Jesús Gómez Pérez
Diana Marcela González Quintana**

Trabajo de grado presentado como requisito para optar el título de:
INGENIERO ELECTRÓNICO

**DIRECTOR:
Rodolfo Villamizar Mejía. Ph.D.**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA
2010**

DEDICATORIA

A lo largo de mi vida universitaria me di cuenta que el gran aprendizaje de la vida trae consigo maravillosas experiencias que son efímeras en el pasado y pilares en el presente, inexplicablemente me encontré con personas cuyas almas, pensamientos y sentimientos trascienden más allá de lo objetivo y dejan en mí enseñanzas de amor, amistad, paz, comprensión y tolerancia, es por ello, que encuentro en este proyecto de grado mi más humilde muestra de gratitud y amor, agradeciéndoles inmensamente a las personas que estuvieron allí entregando gran parte de su vida a beneficio de este logro.

A Dios, por obsequiarme el regalo más grande que todo ser humano tiene, la familia. Fuiste tú, mi guía, mi luz y te doy gracias porque me iluminaste para ver en la penumbra de la oscuridad una ilusión de esperanza y paz. A mis papas, mis hermanos, cuñados y sobrinos, por su amor, trabajo incansable y tolerancia, por haberme inculcado valores de lealtad, respeto, humildad, trabajo y sinceridad...Gracias por creer en mí.

A Oscar, por ser la voz de mi conciencia, por sus enseñanzas de amor puro e incondicional, por ayudarme a vencer mis miedos y por demostrarme que el amor eterno tiene su origen sagrado y que solo faltan dos almas como las nuestras para materializarse. Te amo.

A mi míguis, Jose y Mokina, gracias a ustedes creo en la amistad, les agradezco por haberme mostrado que existen personas que aunque no compartan lazos de sangre, sus realidades, formas y vidas están unidas por lazos inquebrantables que duran toda una vida.

To bb, daughter and Sarí.....guys...you´r awesome.. Thanks for being an important part of my life....my life is not the same after I met you guys...you´r in my mind and my heart..luv y a guys...

A la familia Cadena, familia Castillo, familia Gómez, familia Ariza, a Sergio, al Corazono, a Jorge y Oscar....por estar ahí en diferentes momentos de mi vida, su compañía, alegría, afecto y solidaridad me ayudaron a ser quien soy, gracias por sus enseñanzas y por permitirme entrar en sus vidas.

DIANA GON.

Durante el transcurso de esta etapa de mi vida he conocido personas que me han ayudado brindándome su apoyo, comprensión y colaboración, abriendo las puertas de sus hogares y permitiéndome ser un miembro más de sus familias. Es por eso, que quiero compartir esta gran satisfacción de mi sueño y agradezco este triunfo:

A Dios y a la Santísima Virgen, quienes me han regalado la vida y me han dotado de grandes capacidades; por estar siempre a mi lado en cada paso y en cada momento, por ayudarme a cumplir cada una de las cosas que me propuse durante el transcurso de mi carrera.

A mis padres José de Jesús y Cenaida que me dieron la vida, por su confianza y ayuda en momentos buenos y malos. Porque me han enseñado a encarar las adversidades sin perder nunca la dignidad ni desfallecer en el intento. Me han dado todo lo que soy como persona, mis valores, mis principios, mi perseverancia y mi empeño, y todo ello, con una gran dosis de amor y sin pedir nunca nada a cambio.

A mis hermanas Lady y Diana, por su amor y tolerancia desmedidos y porque han estado conmigo en todo momento, Por ser ustedes al igual que mis padres las personas más importantes en mi vida, por enseñarme a perseverar en mis metas sin importar que tan grande sea la adversidad, por inculcarme el verdadero sentido del valor de la amistad, por apoyarme en mis triunfos y en mis derrotas, por enseñarme a ser una mejor persona y aumentar el grado de sencillez y humildad día a día.

A mi madrina y a su familia quienes me han acompañado desde el comienzo de esta etapa.

A mi tío Toño por estar siempre dispuesto a ayudarme.

A mi amigo Oscar Rueda, sus padres Jesús y Blanca, y a sus hermanas Laurita y María por su constante afecto y solidaridad, por todos los gratos momentos vividos en éste mi primer hogar adoptivo y hacerme sentir como en casa cuando lo necesité.

A Dianis gracias por este tiempo que llevamos de conocernos, y en el cual hemos compartido muchas cosas, gracias por su amistad incondicional y por el apoyo que me ha dado para continuar. A sus padres y hermanos gracias por dejarme entrar en sus vidas y compartir con ustedes de momentos íntimos como familia.

A Diana Gon por su amistad y por ser la persona con quien realice este trabajo para lograr mi meta. Por su sencillez y empuje, por compartir momentos agradables y de dificultad, pero son esos momentos los que nos

hacen crecer y valorar a las personas que nos rodean. A Don Carlos y la Sra. Fabiola por hacerme sentir que estaba en casa, por la confianza entregada y por los muchos recuerdos que nunca olvidaré.

A mis amigos y compañeros Hugo, Edwin, Jorge, Judita, y a los del grupo "Bancolombia" muchas gracias por estar conmigo en todo este tiempo donde he vivido momentos felices y experiencias imborrables.

A la Sra. María, Don Benja, Fifi, Jennifer y mi "gorgojo" Juan Diego, quienes en esta última etapa de mi vida universitaria me acogieron como su hijo y amigo, compartiendo momentos de familia inolvidables para mi vida.

Les agradezco a todos ustedes el haber llegado a mi vida, el haber compartido diversos momentos que nunca olvidaré. No me puedo ir, sin antes decirles que sin ustedes a mi lado no lo hubiera logrado, tantas desveladas sirvieron de algo y aquí está el fruto.

José Gómez.

AGRADECIMIENTOS

A Dios.

A la Universidad Industrial de Santander UIS.

*A la Escuela de Ingenierías Eléctrica, Electrónica y de
Telecomunicaciones (E³T).*

*Al Grupo de Investigación en Control, Electrónica, Modelado y
Simulación (CEMOS).*

A nuestro director Rodolfo Villamizar Mejía.

A nuestro codirector Wilmer Sandoval.

*A todas las personas que hicieron posible que culmináramos esta etapa de
la vida.*

Los autores

Tabla de Contenido

I. INTRODUCCIÓN.....	17
II. JUSTIFICACIÓN Y ANTECEDENTES	17
III. MARCO CONCEPTUAL.....	18
IV. METODOLOGÍA UTILIZADA	19
V. VALIDACIÓN NUMÉRICA.....	20
A. Sensado	20
B. Clasificación de la información.....	21
C. Entrenamiento	21
D. Validación.....	23
E. Método de inferencia.....	23
VI. RESULTADOS	25
A. Prueba Uno	25
B. Prueba dos	26
C. Prueba tres.....	26
D. Prueba cuatro.....	26
E. Prueba cinco	27
VII. CONCLUSIONES Y OBSERVACIONES	27
APÉNDICE.....	28
A. Transformada Wavelet.....	28
B. Análisis de Componentes Principales Multivariables	29
C. Razonamiento Basado en casos.....	31
D. Correlación Cruzada	31
REFERENCIAS.....	31

Lista de Figuras

FIGURA 1. DINÁMICA GENERAL DEL SISTEMA	18
FIGURA 2. CLASIFICACIÓN DE LOS SISTEMAS DE RECONOCIMIENTO DE FALLAS.	19
FIGURA 3. ESQUEMA GENERAL DEL SISTEMA.	19
FIGURA 4. METODOLOGÍA DE DESARROLLO.	19
FIGURA 5. PROCESO DE LOS ALGORITMOS.	20
FIGURA 6. SELECCIÓN DE CASOS DE ENTRENAMIENTO Y VALIDACIÓN.....	21
FIGURA 7. PROCESOS PARA CASOS DE ENTRENAMIENTO.....	21
FIGURA 8. ÁRBOL DE DESCOMPOSICIÓN HASTA EL NIVEL 3 (N=3).....	21
FIGURA 9. PROCESO DE SEGMENTACIÓN DEL COEFICIENTE DE DETALLE 1.	22
FIGURA 10. DESCRIPTORES CD1, CASO F (D.E CD1)..	22
FIGURA 11. DISTRIBUCIÓN DE VECTORES CARACTERÍSTICOS DE LOS DIFERENTES CASOS DE ENTRENAMIENTO.	22
FIGURA 12. COMPONENTES PRINCIPALES.	22
FIGURA 13. COMPONENTES SELECCIONADOS.....	23
FIGURA 14. MECANISMO DE VALIDACIÓN DEL ALGORITMO.....	23
FIGURA 15. TÉCNICA DE INFERENCIA	23
FIGURA 16. EJEMPLO DEL MECANISMO DE INFERENCIA.....	24
FIGURA 17. CUATRO PRIMERAS PRUEBAS APLICADAS A LOS ALGORITMOS.....	25
FIGURA 18. ETAPA 1 DE LA TRANSFORMADA WAVELET. A) ESCALA INICIAL DE LA SEÑAL, B) DESPLAZAMIENTO EN EL TIEMPO DE LA WAVELET SELECCIONADA.	28
FIGURA 19. VARIACIÓN EN LA ESCALA Y DESPLAZAMIENTO EN EL TIEMPO.....	28
FIGURA 20. ÁRBOL DE DESCOMPOSICION TWD.....	29
FIGURA 21. ESPACIO VECTORIAL PCA.	30
FIGURA 22. ESQUEMA DE PCA.....	30
FIGURA 23. CICLO CBR.....	31

Lista de Tablas

TABLA 1. DESCRIPCIÓN DE LOS ESCENARIOS DE DAÑO	21
TABLA 2. DATOS DEL EJEMPLO ESTIPULADO.....	24
TABLA 3. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN, (ALGORITMO UNO).	25
TABLA 4. ACIERTOS Y FRACASOS EN EL PROCESO DE CUANTIFICACIÓN DEL DAÑO, (ALGORITMO UNO).	25
TABLA 5. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	25
TABLA 6. ACIERTOS Y FRACASOS EN EL PROCESO DE CUANTIFICACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	25
TABLA 7. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO UNO).	26
TABLA 8. ACIERTOS Y FRACASOS EN EL PROCESO DE CUANTIFICACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO UNO).	26
TABLA 9. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	26
TABLA 10. ACIERTOS Y FRACASOS EN EL PROCESO DE CUANTIFICACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	26
TABLA 11. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO UNO).	26
TABLA 12. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO UNO).	26
TABLA 13. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	26
TABLA 14. ACIERTOS Y FRACASOS EN EL PROCESO DE CUANTIFICACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	26
TABLA 15. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO UNO).	27

TABLA 16. ACIERTOS Y FRACASOS EN EL PROCESO DE SEVERIDAD DEL SISTEMA DE SUPERVISIÓN (ALGORITMO UNO).	27
TABLA 17. ACIERTOS Y FRACASOS EN EL PROCESO DE LOCALIZACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	27
TABLA 18. ACIERTOS Y FRACASOS EN EL PROCESO DE CUANTIFICACIÓN DEL SISTEMA DE SUPERVISIÓN (ALGORITMO DOS).	27
TABLA 19. PORCENTAJES DE ACIERTO Y FRACASO ANTE LA PRESENCIA DE RUIDO.	27

RESUMEN

TITULO Evaluación de daños en tuberías, mediante Razonamiento Basado en Casos y procesamiento de señales con Transformada Wavelet y MPCA.*

AUTORES José de Jesús Gómez Pérez, jgomez1865@hotmail.com
Diana Marcela González Quintana, gon_diana@hotmail.com**

PALABRAS CLAVES Sistema de Supervisión, TWD, MPCA, Mecanismo de Inferencia, Distancia Euclidiana.

DESCRIPCIÓN

La existencia de una falla en los ductos durante los procesos de distribución de hidrocarburos, produce un efecto no deseado que altera el tránsito normal del fluido que circula a través de las tuberías, desencadenando un comportamiento atípico en el patrón de propagación del mismo. Es por ello, que la academia ha fusionado sus esfuerzos junto con el sector industrial para implementar sistemas que permitan prever dichas situaciones, diagnosticando tempranamente fallas en las estructuras. El presente artículo expone dos algoritmos de supervisión útiles para el proceso de detección, localización y cuantificación de daños percibidos en una tubería de gas. El primero de ellos, tiene como herramientas de procesamiento la Transformada Wavelet Discreta (TWD) y el Análisis de Componentes Principales Multivariados (MPCA), además de una técnica de diagnóstico llamada Razonamiento Basado en Casos (CBR). El segundo algoritmo, cuenta sólo con MPCA como elemento de procesamiento, seguido por el CBR. El estudio expuesto en este artículo se hace con base en señales sensadas de una tubería simulada en condiciones de daño y de deformación en ubicaciones puntuales. La metodología propuesta en este artículo tiene como punto de partida 14209 señales, extraídas por 6 sensores localizados a lo largo de la estructura. Cada señal posee 2048 muestras, estas son organizadas en seis matrices cuyo tamaño esta dado por los casos de daño presentes y sus señales correspondientes.

* Trabajo de grado

** Facultad de Ingenierías Fisicomecánicas, Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Director: Rodolfo Villamizar Mejía, Co-director: Wilmer Sandoval.

ABSTRACT

TITLE Evaluation of damages in pipelines, using Case Based Reasoning and signals treatment applying the Wavelet Transform and MPCA.*

AUTHORS José de Jesús Gómez Pérez, jgomez1865@hotmail.com
Diana Marcela González Quintana, gon_diana@hotmail.com**

KEYWORDS Supervision Systems, TWD, MPCA, Interference Mechanism
Euclidean Distances

DESCRIPTION

The existence of any damage along the ducts involved in distribution processes produces no desired effects that change the normal displacement of a fluid that circulates through the pipelines, bringing wrong behaviors on its propagation patterns. That's why, the academy has merged its efforts into the industry proposing and applying methods in order to prevent and diagnose any change in the structures. This article exhibits two expert algorithms useful to detect, localize and quantify specific damages along a pipeline, those damages are treated as severity changes in the pipeline's structure. The first algorithm has as a treatment tool the discrete wavelet transform (TWD) for pattern extraction and the multivariate principal components analysis (MPCA) for dimensionality reduction, in addition of it, this computational program uses a diagnosis technique called case based reasoning (CBR). The second algorithm, only works with MPCA as signals treatment element, applying forward CBR as an inference mechanism. The methodology proposed in this article take as initial step 14209 signals, extracted by six sensors localized along a simulated pipeline with damaged and deformation conditions, knowing its specific location and severity. Each signal has 2048 samples; these signals are organized into 6 matrices whose size is given by the simulated damages and its signals.

* Undergraduate thesis project.

** Faculty of physics-Mechanical Engineering, School of Electrical, Electronic and Telecommunications Engineering. Director: Rodolfo Villamizar Mejía, Co-director: Wilmer Sandoval

Evaluación de daños en tuberías, mediante Razonamiento Basado en Casos y procesamiento de señales con transformada Wavelet y MPCA

José de Jesús Gómez Pérez, Diana Marcela González Quintana, Wilmer Alexis Sandoval Cáceres y Rodolfo Villamizar Mejía.

Resumen—La existencia de una falla en los ductos durante los procesos de distribución de hidrocarburos, produce un efecto no deseado que altera el tránsito normal del fluido que circula a través de las tuberías, desencadenando un comportamiento atípico en el patrón de propagación del mismo. Es por ello, que la academia ha fusionado sus esfuerzos junto con el sector industrial para implementar sistemas que permitan prever dichas situaciones, diagnosticando tempranamente fallas en las estructuras. El presente artículo expone dos algoritmos de *supervisión útiles para el proceso de detección, localización y cuantificación de daños percibidos en una tubería de gas*. El primero de ellos, tiene como herramientas de procesamiento la Transformada Wavelet Discreta (TWD) [1] y el Análisis de Componentes Principales Multivariantes (MPCA) [2], además de una técnica de diagnóstico llamada Razonamiento Basado en Casos (CBR) [3]. El segundo algoritmo, cuenta sólo con MPCA como elemento de procesamiento, seguido por el CBR. El estudio expuesto en este artículo se hace con base en señales sensadas de una tubería simulada en condiciones de daño y de deformación en ubicaciones puntuales.

Palabras claves—Análisis de Componentes Principales Multivariantes (MPCA), Extracción de características, Monitorización de salud estructural (SHM), Razonamiento basado en casos (CBR), Sistemas Experto, Transformada Wavelet (TW).

I. INTRODUCCIÓN

Las empresas encargadas de la distribución y transporte de fluidos, enfrentan diariamente problemas asociados con el deterioro de la vida útil de las tuberías que se han dispuesto para tal fin, debido a las deformaciones causadas por agentes internos y externos al sistema [4]. Éstos cambios abruptos en el entorno ocasionan obstrucciones y/o averías en los ductos que impiden la correcta propagación de los fluidos a lo largo de su proceso de transmisión o distribución, ocasionando accidentes e innumerables daños ambientales [[5]-[7]].

Es por ello, que en los últimos años el interés de la industria se ha enfocado en el desarrollo de sistemas de monitoreo robustos, compuestos por un constante control de los procesos y que involucra tecnologías de supervisión innovadoras que proporcionen alta fidelidad y demanden el menor costo posible [[8]-[10]]. Estos sistemas de monitoreo [11], [12], detectan, localizan y evalúan averías presentes en los ductos, previniendo oportunamente cualquier pérdida de

continuidad en el proceso de distribución de fluidos [13], [14].

En el presente artículo se exponen dos algoritmos capaces de identificar la ubicación de la falla y valorar de forma cuantitativa las deformaciones en los ductos, por medio de herramientas de análisis matemático y estadístico como la TW, MPCA y CBR.

II. JUSTIFICACIÓN Y ANTECEDENTES

La necesidad de prevención y adquisición de herramientas eficaces en los procesos de transporte y distribución en la industria de los hidrocarburos, se ha incrementado en los últimos años de manera considerable, a causa de diferentes eventualidades que dejan un impacto negativo en la sociedad y el ambiente [15], [16]. Un caso como el desastre petrolero en Alaska en 2006 por causa de una falla en las tuberías debido a la corrosión, generó pérdidas de más de US\$7 billones de dólares a la compañía British Petroleum, y cuyo derrame se estimó en 267.000 galones [17]. Éste desastre es uno de tantos producidos por fallas en las estructuras de transporte de fluidos, que ocasionan una gran preocupación entre la comunidad no solo por su connotación social, sino por el impacto ambiental y económico derivado de esta situación.

Por ello, es de vital importancia implementar sistemas de inspección que permitan diagnosticar y prever estas situaciones [18], monitorizando el estado de las estructuras con la mínima participación de mano de obra humana posible, garantizando así seguridad y confiabilidad en dicho proceso [19], [20].

En el caso de la monitorización de salud estructural (SHM) se encuentran grandes adelantos, tales como la monitorización “on-line” de procesos en plataformas marítimas, utilizando el método de inspección ultrasónica con “*intelligent pig*” [21], la evaluación tradicional no destructiva de estructuras aplicada a aviones [22] y el uso de sistemas de mantenimiento y monitorización autónoma de tuberías, basados en sensores (SPAMMS) [23]. Estos avances marcan una referencia significativa en el desarrollo de técnicas que dan solución a problemas en el área de la salud estructural.

Por otra parte, uno de los métodos de SHM, es la detección de daños basada en vibraciones (VBDI) [24], cuyos progresos como el estudio del impacto en la frecuencia natural de las estructuras debido a su composición heterogénea [25], el análisis de eventos atípicos en las tuberías usando procesadores de señales digitales (DSP) [26] y la monitorización de las tuberías mediante el sensado de vibraciones inducidas [27], marcan la pauta en cuanto a este tipo de técnica de diagnóstico.

Para llevar a cabo el SHM, se hace imperativa la existencia de un sistema experto que diagnostique fallas estructurales [28], [29], ejecutando tareas como el procesamiento de datos, reconocimiento de patrones y clasificación de la información. Esto debido a que en la mayoría de procesos, particularmente en los cuales está involucrado el sensado de variables, la cantidad de datos es significativamente grande, redundante y difícil de analizar.

En cuanto a adelantos en el desarrollo de sistemas expertos se encuentra la plataforma de apoyo a la detección y diagnóstico de fallas en montajes interoceánicos que condensa subsistemas eléctricos [30], mecánicos [31], hidráulicos [32] y de comunicación [33], en un mismo sistema de monitorización automatizado [34]; asimismo, se han diseñado sistemas expertos implementados con lógica Fuzzy [35], que se orientan al análisis de indicadores de seguridad, ergonómicos, ambientales y demás, en sistemas de refinería de gas [36], por último, estudios enfocados hacia el buen estado de los transformadores han desarrollado sistemas expertos que diagnostican fallas por características de aislamiento de los mismos vistas durante las pruebas de impulso [37].

Del mismo modo, se destacan herramientas de procesamiento anteriormente nombradas como TWD y el análisis de componentes principales, que realizan la descomposición de la información y la extracción de patrones característicos de la señal para la detección y diagnóstico de las averías.

En el caso de la Transformada Wavelet, en la industria productora de fibra de carbón para aplicaciones aeroespaciales, se han desarrollado algoritmos que involucran esta herramienta para la identificación de daños en estructuras susceptibles a impactos, obteniendo excelentes resultados [38]; además, investigaciones en el área de ingeniería eléctrica, específicamente en mantenimiento de transformadores, han utilizado esta técnica como elemento de análisis tempo-frecuencial de señales de corriente no-estacionaria [39]. Finalmente, se señala la importancia de esta herramienta matemática para estudiar el grosor y el “stress” en las tuberías de largas distancias mediante señales ultrasónicas guiadas [40].

En cuanto a MPCA, ese tipo de análisis ha sido aplicado a la extracción de características para el uso del modelo de HMM (“HiddenMarkovMethod”), en el funcionamiento de válvulas en procesos industriales [41]. En adición a esto, este elemento estadístico también muestra un desempeño significativo tanto en el tratamiento de imágenes faciales

[42], [43] y en 3-D [44], como en el monitorización “on line” de estructuras de aluminio [45].

III. MARCO CONCEPTUAL

El diagnóstico de daños estructurales o SHM tiene como objetivo monitorizar el estado de las estructuras a través de la detección y determinación de daños en las mismas, evaluando su comportamiento frente a variaciones de las condiciones operacionales y de su entorno [46]. Dichas variantes son producto de innumerables fuentes, tales como las transiciones climáticas, alteraciones geométricas de la estructura, la variabilidad en la naturaleza de los componentes de la misma, entre otros, que alteran su funcionamiento y por ende afectan significativamente la vida útil de las estructuras.

Actualmente, existen varias técnicas de SHM que enfatizan su estudio en procedimientos experimentales de localización de fallas, como lo son los métodos acústicos, ultrasónicos, de campo magnéticos [47]. Asimismo, existe otra técnica, que se caracteriza no solo por su frecuente uso en investigaciones orientadas a la detección de fallas en estructuras, también por su monitoreo en tiempo real que genera un decremento en cuanto a costos se trata [48], esta se denomina VBDI.

Su principio básico afirma que dichos daños cambian las propiedades de los elementos (entendiéndose por propiedades la masa, la rigidez y el coeficiente de amortiguamiento), dichas alteraciones se traducen en variaciones en la respuesta dinámica del sistema.

El procedimiento a seguir para el análisis con VBDI se basa en la inserción de una señal de excitación a la estructura de estudio, para así analizar la respuesta dinámica resultante de su propagación [49] (Figura 1).

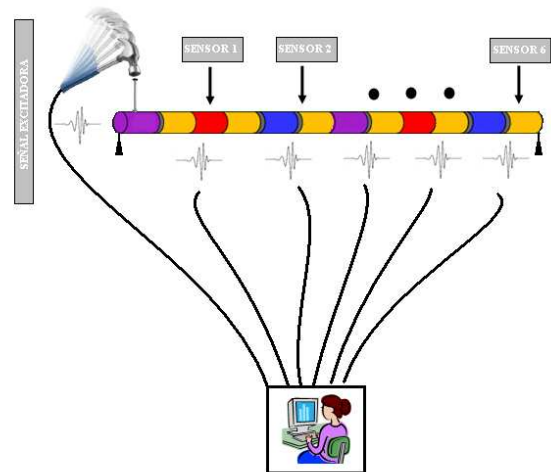


Figura 1. Dinámica general del sistema. Fuente: Autores

Por otra parte, es necesario reconocer cuales son los tipos de fallas existentes para así determinar el tipo de monitoreo a realizar. Una de las metodologías ampliamente usadas para este fin es postulada por Rytter [50], donde presenta en cuatro niveles la posible clasificación de los sistemas de reconocimiento de fallas, ver figura 2.

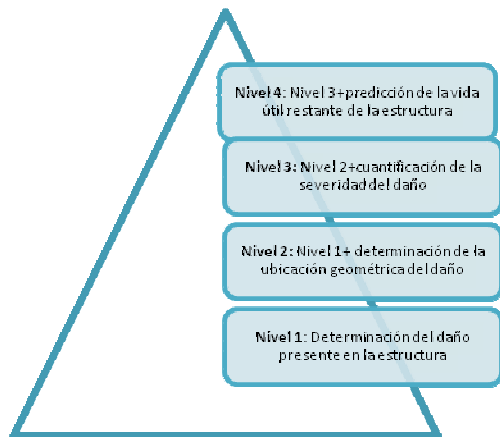


Figura 2. Clasificación de los sistemas de reconocimiento de fallas. Fuente: Autores.

Esta jerarquización demuestra su utilidad a la hora de determinar los parámetros a monitorizar dentro del esquema de supervisión experta. Estos sistemas permiten de manera óptima y automatizada aplicar mecanismos de procesamiento de información proporcionada por cambios en la entrada del sistema y así inferir y proporcionar un diagnóstico específico.

Existen varias herramientas computacionales orientadas al aprendizaje adaptativo e inferencia del sistema experto, entre ellas se encuentran, las redes neuronales, los algoritmos genéticos, la lógica Fuzzy [51], entre otros. Por otro lado, en cuanto al mecanismo de procesamiento de datos, se encuentran la transformada Wavelet [52], el Análisis de Componentes Principales [53], la transformada de Hilbert-Huang [54], etc.

Teniendo como prioridad localizar y cuantificar daños en una tubería simulada, los algoritmos que aquí se presentan se encuentran catalogados como de nivel 3, dando como resultados la ubicación geométrica de la avería presente y su cuantificación.

IV. METODOLOGÍA UTILIZADA

El sistema experto implementado posee como esquema general tres procesos básicos, que se observan en la figura 3, el primero de ellos, obedece a la adquisición de datos provenientes del sensado en diferentes puntos de un modelo de tubería simulada mediante el método de elementos finitos [55] ante una excitación previa, orientado bajo el principio de VBDI.

En segunda instancia, se realiza el procesamiento de los datos, que no son más que señales de aceleración correspondientes a la onda propagada, dicho procedimiento tiene como objetivo descomponer la información en sus

patrones característicos, reduciendo su dimensionalidad y extrayendo datos no correlacionados entre sí, que contengan gran parte de la información relevante del comportamiento original de la señal.

En la tercera y última etapa, se realiza el proceso de validación de la información, fundamentados en el CBR [56], [57], que permite evaluar y analizar el desempeño y acierto de los algoritmos propuestos.

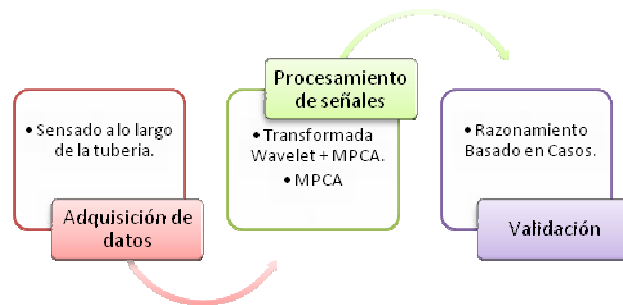


Figura 3. Esquema general del sistema. Fuente: Autores.

La metodología de desarrollo es sintetizada en 6 pasos y se muestra en la figura 4 de manera detallada, cabe aclarar que los dos algoritmos de supervisión que aquí se desarrollan muestran sus diferencias en la etapa de procesamiento de la información, ya que el primero de ellos realiza la extracción de patrones característicos aplicando la TWD y la reducción de dimensionalidad con MPCA, mientras que el segundo de ellos, utiliza MPCA como herramienta de extracción y reducción de datos.



Figura 4. Metodología de desarrollo. Fuente: Autores.

Paso 1 Sensado: Se obtienen señales de aceleración en diferentes puntos de un modelo de tubería simulada [55] como respuesta a una señal de excitación determinada aplicada a la misma.

Paso 2 Clasificación de información: Los datos obtenidos del proceso anterior son separados en dos grandes grupos denominados: entrenamiento y validación.

Paso 3 Extracción de información relevante: Mediante la TWD, tanto los datos de entrenamiento como los de validación son procesados y reducidos a sus patrones característicos, con el fin de facilitar el tratamiento y análisis de la información [55], [56].

Paso 4 Segmentación: Se utiliza un enventanado de medias móviles para segmentar la señal, permitiendo obtener información sobre cambios abruptos en secciones de la señal que se pasarían por alto en el caso de estudiar la totalidad de la misma. Para observar dichas variaciones eventuales se tienen como parámetros, algunos descriptores de la señal, entre los que se encuentran la desviación estándar, la media, la varianza, la moda, el máximo y el mínimo de la señal [57], [58].

Paso 5 Diferencias: Se realiza la diferencia entre el caso nominal (sin daño) y los casos restantes (con diferentes porcentajes de daño), con el objetivo de minimizar el efecto de diferentes perturbaciones en las señales de aceleración sensadas [55].

Paso 6 Reducción de dimensionalidad: Por medio de MPCA, las señales originales son expresadas en un nuevo espacio vectorial como variables no correlacionadas entre sí, dichas variables se reducen en un número mínimo de vectores propios que condensan la información más importante de la señal, descartando redundancia en la información y minimizando la cantidad de datos [59].

Paso 7 Mecanismo de inferencia: A través del cálculo de las distancias euclidianas se establecen similitudes entre el caso a validar y los casos previamente entrenados, para así, predecir la localización y el porcentaje presente en el caso de estudio [60], [61].

Es importante mencionar que todos los pasos, se aplican tanto para el grupo de entrenamiento como para el de validación, dado que para realizar la inferencia es necesario tener ambos conjuntos de datos en un mismo plano y bajo las mismas condiciones [58].

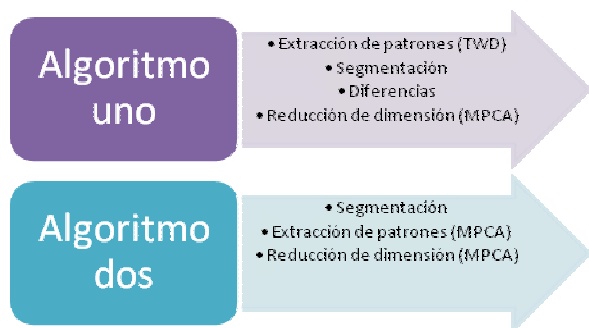


Figura 5. Proceso de los algoritmos. Fuente: Autores

Adicionalmente, la metodología condensada en los 6 pasos anteriores corresponde en su totalidad al primer algoritmo desarrollado, utilizando TWD y MPCA en el tratamiento de las señales. Por otro lado, el segundo

algoritmo realiza la segmentación de cada una de las señales de entrenamiento, posterior a ello, extrae los patrones característicos de las mismas y por último reduce la cantidad de datos analizados utilizando solo MPCA. En la figura 5 se muestra en detalle la distribución de los procesos realizados por cada algoritmo.

V. VALIDACIÓN NUMÉRICA

Siguiendo con el orden estipulado en la figura 4, a continuación se muestra el desarrollo de cada uno de los pasos mostrados.

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” [55]. 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.

Se cuenta entonces con un conjunto de 6 sensores localizados (sensores 3, 7, 13, 19, 25 y 29) en puntos específicos de una tubería simulada, como se muestra en la figura 1. Estos detectan las diferentes respuestas dinámicas de la estructura sometida a vibración. De allí se genera una lista, que contiene los diferentes escenarios de avería cuyos porcentajes de daño son discretos y varían en un factor de 5 dentro de un rango de 5% a 50%, su distribución y organización se muestran en la tabla 1.

GRUPO	ELEMENTOS AVERIADOS	SEVERIDAD (%)
1	Ninguno (caso nominal)	No daño
2	1 elemento	Diferentes % de daño
3	2 elementos contiguos	Igual % de daño
4	2 elementos no contiguos	Diferentes % de daño
5	2 elementos contiguos	Diferentes % de daño, avería del primer elemento < avería del segundo
6	2 elementos no contiguos	Diferentes % de daño, avería del primer elemento < avería del segundo
7	2 elementos contiguos	Diferentes % de daño, avería del primer elemento > avería del segundo

8	2 elementos no contiguos	Diferentes % de daño, avería del primer elemento > avería del segundo
---	--------------------------	---

Tabla 1. Descripción de los escenarios de daño

B. Clasificación de la información

La selección de los casos se realizó aleatoriamente, de la siguiente manera:

Grupo 1: Este consta de un solo caso, denominado nominal, ya que es el único que no tiene daño y servirá de referencia en los procesos que se llevan a cabo a lo largo de todo el tratamiento de las señales.

Grupo 2: Se escoge al azar el 70% de los casos que tengan el mismo elemento dañado con diferente porcentaje de daño y se clasifica como entrenamiento, mientras el 30% restante se almacena como validación (Figura 6).

Grupo 3, 5 y 7: Se escoge el 70% de los casos que posean los mismos elementos contiguos para entrenamiento y el 30% restante para validación. Por ejemplo, todos los casos cuyos elementos averiados sean el 1 y el 2 se separan en entrenamiento y validación.

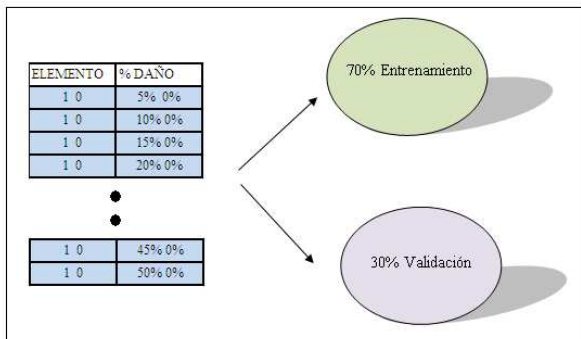


Figura 6. Selección de casos de entrenamiento y validación. Fuente: Autores.

Grupo 4, 6 y 8: Se repite el procedimiento realizado para los grupos impares, pero esta vez, se seleccionan las parejas de elementos no contiguos. Por ejemplo, todos los casos cuyos elementos dañados sean el 1 y el 3 se dividen en entrenamiento y validación (70%, 30%), así como aquellos que tengan los elementos 2 y 4, 3 y 5 y así sucesivamente.

De esta etapa se tiene como resultado 9649 y 4560 casos para entrenamiento y validación respectivamente. Cada señal de aceleración tiene una longitud de 2048 muestras.

C. Entrenamiento:

A continuación se explican los diferentes métodos utilizados en el procesamiento de los casos utilizados para la etapa de entrenamiento (Figura 7).

Extracción de patrones:

Una vez clasificada la información, se procesan los datos de entrenamiento, realizando como primera instancia la extracción de patrones.

Este proceso tiene como herramienta de análisis la TWD (ver apéndice), para ello se toma como Wavelet madre la familia Daubechies de orden 6, por ser la más utilizada en estos procesos [62]. Este procedimiento arroja 8 coeficientes, de los cuales 7 son de detalle (CD) y 1 de aproximación (CA). El árbol de descomposición es mostrada en la figura 8 respectivamente. La TWD dispone de filtros pasa altas y pasa bajas que junto a un proceso de submuestreo permiten expresar las señales en coeficientes de aproximación y detalle [63], [64].



Figura 7. Procesos para casos de entrenamiento. Fuente: Autores.




Figura 8. Árbol de descomposición hasta el nivel 3 (N=3). Fuente: Autores.

Segmentación:

En esta etapa se realiza una segmentación de medias móviles [57], [65], para ello se desplaza una ventana con un ancho preestablecido a través de los coeficientes obtenidos en cada uno de los niveles de descomposición. A medida que se traslada la ventana, se calcula el promedio de los datos allí agrupados, cuando se detecte un cambio abrupto en esta medida se delimita el segmento de datos y se

establecen ventanas de análisis de los coeficientes (Figura 9).




Figura 9. Proceso de segmentación del coeficiente de detalle 1. Fuente: Autores

Para fijar el ancho de cada ventana, se tiene en cuenta que a medida que aumentan los niveles de descomposición resultantes de la TWD [58], la longitud de sus coeficientes va disminuyendo, mostrando una relación inversamente proporcional, es por ello que para cada uno de los grados de descomposición el tamaño de la ventana disminuye, con el fin de recoger información detallada en cada uno de los segmentos.

La segmentación se realiza inicialmente a los coeficientes del caso nominal o sin daño, y una vez estipulados los tamaños de las ventanas para cada nivel, éstas se toman como perfil o patrón para los demás casos de entrenamiento.

- *Diferencias:*

Una vez divididas las señales en varios intervalos se realiza la diferencia entre los coeficientes segmentados del caso nominal y de los casos restantes [55], dicha operación se realiza en cada nivel de descomposición.

- *Reducción de dimensionalidad:*

Posteriormente, se calculan diferentes descriptores a cada uno de los grupos resultantes de la etapa anterior, dichos indicadores son la media, la varianza, la moda, la desviación estándar, el valor mínimo y máximo, condensando la información de cada una de las señales de interés.




Figura 10. Descriptores CD1, caso f (D.E CD1). Fuente: Autores.

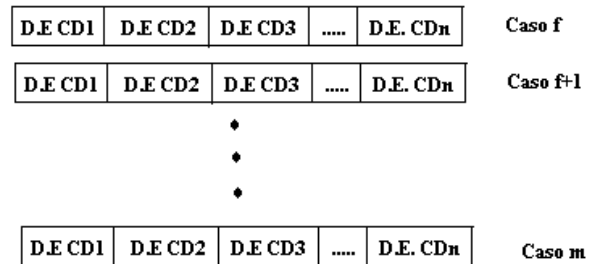


Figura 11. Distribución de vectores característicos de los diferentes casos de entrenamiento. Fuente: Autores.

Una vez extraídos, los parámetros se organizan en un vector, donde la información se encuentra distribuida en el siguiente orden: (Figura 10 y 11).

Debido a que la cantidad de datos procesados sigue siendo significativa (matrices de tamaño 9649x234), es imperativo el uso de una herramienta que además de simplificar la dimensión de los datos, permita analizar los mismos de manera independiente, [66] para ello se aplica MPCA (ver apéndice). Esta herramienta expresa en un nuevo espacio vectorial la información original (descriptores) en función de sus valores y vectores propios, centrando los nuevos datos alrededor de su media y desviación estándar [67], [68].

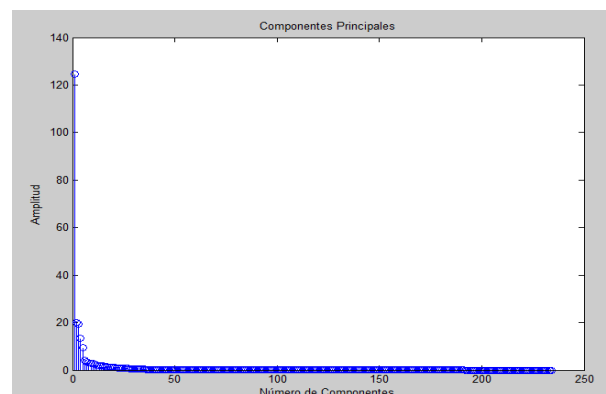


Figura 12. Componentes principales. Fuente: Autores

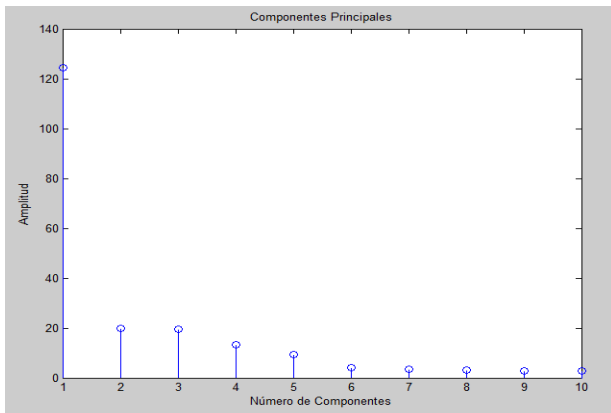


Figura 13. Componentes seleccionados. Fuente: Autores

El principio de funcionamiento de esta herramienta depende del número de valores propios que según la aplicación son suficientes para representar la totalidad de la información [60], [69]. En este caso, se extraen los 10 valores propios que contengan la mayor varianza [55], como se muestra en la figura 13.

De este procedimiento se obtiene como resultado la reducción de los datos de entrenamiento originales en componentes no correlacionados entre sí y ubicados en un nuevo espacio PCA [43].

Por otra parte, es necesario almacenar en esta etapa tanto la media como la desviación estándar del grupo de datos de entrenamiento, ya que estas medidas serán útiles para centrar bajo las mismas condiciones y en el mismo plano vectorial los datos de validación [55]. Se tiene entonces como resultado una matriz con menos elementos que la original (tamaño 9649x10).

D. Validación:

Después de culminar el tratamiento de los casos de entrenamiento y de recolectar medidas estadísticas necesarias para la evaluación de los algoritmos, se procede a estudiar los casos de validación, teniendo en cuenta los mismos pasos expuestos en la figura 7.

En primera instancia, se aplica la TW, para extraer los patrones característicos de la señal y descomponer la misma en sus coeficientes de detalle y aproximación, como se explicó en la sección C. Posteriormente, se segmentan los coeficientes obtenidos bajo el mismo criterio de enventanado (medias móviles) aplicado. Como tercera etapa, se realiza la diferencia entre los coeficientes obtenidos del caso nominal y los demás casos de validación, como se expuso anteriormente. Después, de realizar esto, se realiza una simplificación del tamaño de variables medidas aplicando MPCA, este proceso difiere al aplicado en el entrenamiento, ya que aquí se centran los datos a validar respecto a la media y la desviación estándar obtenida en la etapa de entrenamiento, esto para que ambos conjuntos de datos se encuentren en el mismo plano vectorial.

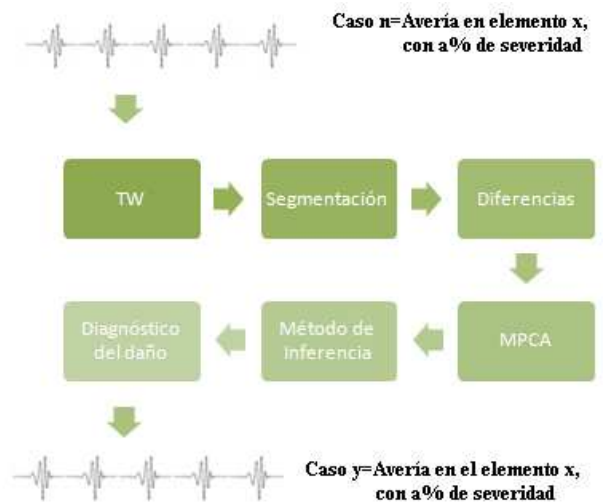


Figura 14. Mecanismo de validación del algoritmo. Fuente: Autores.

El criterio que se utiliza para la selección de los componentes principales es el mismo que se aplicó en la sección C, es decir, los 10 valores propios que posean la mayor varianza, ya que estos poseen la información más relevante de los datos [70]. El resultado y procedimiento descrito en la etapa de evaluación del algoritmo se visualiza en la figura 14. Se obtiene como resultado, un arreglo matricial reducido de tamaño 4560x10.

E. Método de inferencia

Después de centralizar y simplificar los datos de validación, se establece un método de inferencia para el diagnóstico de averías, evaluando al mismo tiempo el desempeño de los algoritmos implementados. Los resultados de interés en esta etapa se centran en la detección y localización acertada de la avería, así como en el valor estimado de la severidad del daño encontrado.

La técnica de inferencia que aquí se presenta está fundamentada en el cálculo de las distancias euclidianas presentes entre todos los casos de entrenamiento y el caso a validar. Su funcionamiento se presenta en la figura 15.




Figura 15. Técnica de inferencia. Fuente: Autores

En esta etapa se busca hallar por medio de la mínima distancia euclidiana cual de los casos de entrenamiento es el más parecido o similar al caso a validar [55], [58], [60],

para ello se calculan cada una de las distancias existentes entre los mismos y estableciendo un umbral se escoge una cantidad de casos determinada. Es necesario recordar, que cada caso tiene adjunto uno o dos elementos dañados y un porcentaje de daño respectivo. Con ello en mente, se seleccionan entonces, los 10 casos cuyas distancias euclidianas respectivas sean las más pequeñas y se almacenan en una matriz de discriminación [55].

Con esta información almacenada se busca concluir cual elemento y qué porcentaje de daño corresponde al caso de validación analizado, para ello se buscan aquellos elementos de la tubería que muestren mayor moda, ya que si un componente de la misma está presente en varios escenarios de daño, tiene mayor probabilidad estar averiado [55], [58], [60].

Con esta información se logra discriminar el/los elementos que generan perturbaciones en el funcionamiento de la tubería, detectando y localizando los componentes de daño. Asimismo, es preciso establecer un criterio o una expresión para predecir tanto el número de los elementos averiados como el porcentaje de daño respectivo, esto [58] se logra haciendo uso de la ecuación 1 y 2.

$$Severidad = \sum_{j=1}^n dam(j) * \frac{1}{\sum_{j=1}^n \frac{1}{d(j)}} \quad Ec. 1$$

$$Dimensión = \sum_{j=1}^n dim(j) * \frac{\frac{d(1)}{d(j)}}{\sum_{j=1}^n \frac{d(1)}{d(j)}} \quad Ec. 2$$

Donde d(1) expresa la distancia más pequeña detectada en la matriz de discriminación, dam(j) y d(j) corresponden al porcentaje del daño y a las distancias entre los diferentes casos en estudio respectivamente.

Esta dinámica responde a las siguientes preguntas:

- ¿Dónde se encuentra el daño?
- ¿En cuánto se estima la severidad del daño?

A continuación se muestra un ejemplo del mecanismo de inferencia utilizado y su esquema respectivo (Figura 16).

En este ejemplo se toma como caso de estudio, un escenario cuya dimensión de daño es de dos elementos averiados, con una ubicación conocida y severidad conocida, expresada así:

Caso a validar : Cantidad de elementos dañados:2
 Ubicación: elementos 9 y 30
 Severidad: 35% 40%

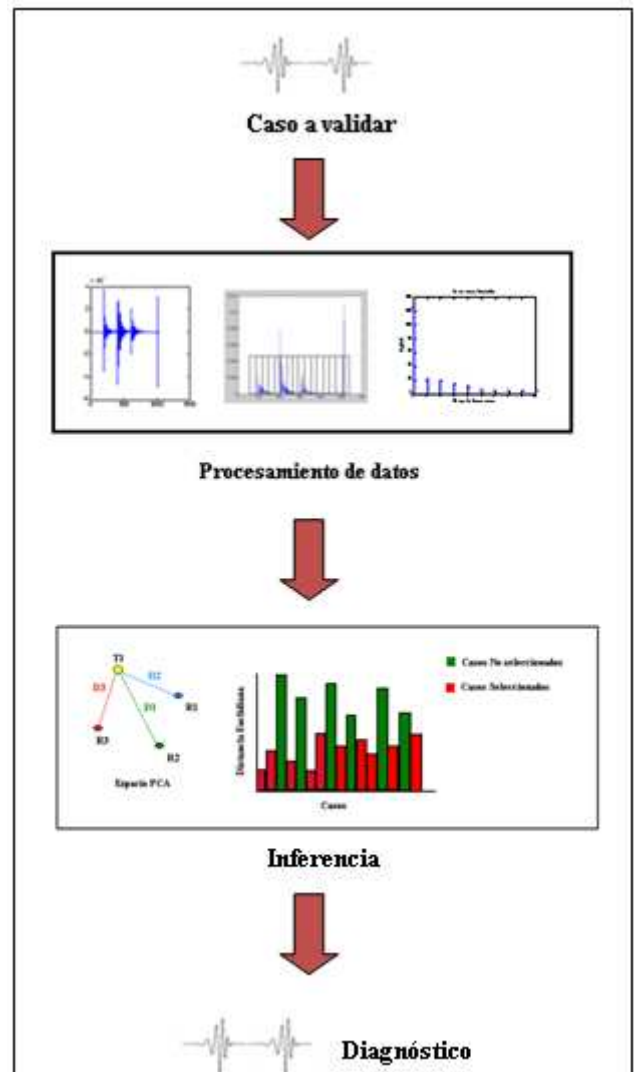


Figura 16. Ejemplo del mecanismo de inferencia. Fuente: Autores.

Se aplica TWD, segmentación, diferencias y MPCA, para el tratamiento de sus variables, luego, se calculan las distancias existentes entre todos los casos de entrenamiento y el caso en análisis, extrayendo los 10 casos que muestren las distancias euclidianas más pequeñas, como se visualiza en la tabla 2.

Elementos dañados		Severidad		distancia
9	30	40	35	1.9075
9	30	40	40	2.7815
19	20	40	35	4.0651
19	20	40	40	4.5382
8	9	35	40	4.7054
19	20	35	40	4.8090
9	25	40	35	5.1646
9	25	35	35	5.2519
8	20	35	35	5.2886
2	19	35	35	5.3621

Tabla 2. Datos del ejemplo estipulado.

Aplicando las ecuaciones 1, 2 e infiriendo de la tabla 2, se puede observar que los elementos que más se repiten son el 9 y 30, además de mostrar la mínima distancia euclidiana. En adición a esto, se calcula una severidad del 40% y 35% respectivamente, como se muestra a continuación:

Diagnóstico: Cantidad de elementos dañados: 2
 Ubicación: elemento 9 y 30
 Severidad: 40% y 35%

De este modo se validan los algoritmos realizados. La evaluación numérica de los mismos, además de su desempeño son mostrados en la siguiente sección.

VI. RESULTADOS

Para la validación numérica de los dos algoritmos implementados se tomó como referencia una muestra significativa compuesta por el 30% del universo de datos original (14209) y se realizaron 5 pruebas con pequeñas variantes en sus estructuras, como se muestra en la figura 17.

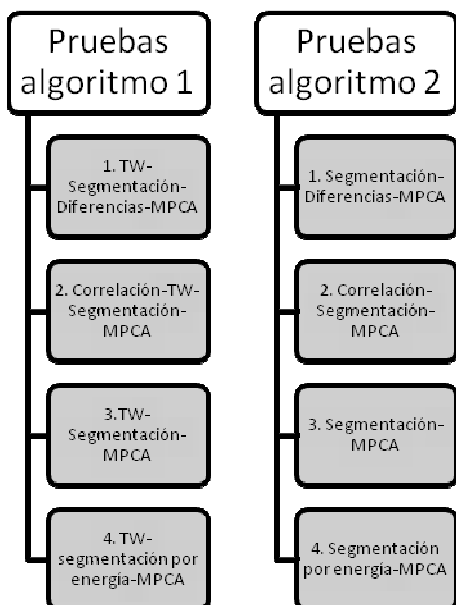


Figura 17. Cuatro primeras pruebas aplicadas a los algoritmos. Fuente: Autores.

La prueba faltante en la figura 17 se realizó observando la respuesta de las señales que componen cada uno de los casos de validación ante la presencia de ruido. Esta se lleva a cabo con las diferentes familias que muestren el mejor comportamiento en los experimentos anteriores.

Es vital mencionar que las pruebas se realizaron con diferentes familias Wavelet, seleccionadas según el comportamiento encontrado en el trabajo de grado “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” [58], enfocado también hacia la aplicación mostrada en el presente artículo.

A. Prueba Uno

Para la primera prueba se toman las familias: Daubechies(db), Coifflets (coiff) y Symlets (Sym) y teniendo como prioridad la localización y la cuantificación del daño en la tubería, se calculó tanto el número de aciertos como el número de fracasos en el diagnóstico del sistema de supervisión, dichos resultados se muestran en la tabla 3 y 4.

Familia	Acierto (%)	Fracaso (%)
Db6	74.55	25.44
Db4	79.04	20.95
Coiff4	77.94	22.05
Coiff2	80.23	19.76
Sym5	76.54	23.45
Sym4	76.94	23.05

Tabla 3. Aciertos y fracasos en el proceso de localización del sistema de supervisión, (Algoritmo uno).

Familia	Acierto (%)	Fracaso (%)
Db6	83.43	16.56
Db4	80.13	19.86
Coiff4	80.23	19.76
Coiff2	81.13	18.86
Sym5	79.34	20.65
Sym4	81.33	18.66

Tabla 4. Aciertos y fracasos en el proceso de cuantificación del daño, (Algoritmo uno).

Por otra parte, se realizó la misma prueba al algoritmo dos (solo MPCA), obteniéndose los resultados expuestos en la tabla 5 y 6.

Acierto (%)	Fracaso (%)
71.65	28.34

Tabla 5. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo dos).

Acierto (%)	Fracaso (%)
74.35	25.64

Tabla 6. Aciertos y fracasos en el proceso de cuantificación del sistema de supervisión (Algoritmo dos).

Comprobándose así que la extracción de patrones con TWD y la reducción de dimensiones con MPCA proporcionan mejores resultados que solo realizando el procesamiento de la señal con MPCA. Además de ello, la familia que mejores resultados arrojó en cuanto a aciertos en la localización de daños fue la Coiff2, mientras que para el proceso de cuantificación de la severidad de la avería, la Db6 resulta más adecuada.

B. Prueba dos

Se elaboró la segunda prueba omitiendo la etapa de diferencias e incluyendo un proceso de correlación cruzada [55] (ver apéndice), esta operación se realiza entre la señal excitadora aplicada a la tubería y las señales de aceleración correspondientes a los casos de validación. Con dicho proceso se busca establecer en un principio el grado de similitud entre ellas y observar el desempeño del método de inferencia en esta nueva estructura de procesamiento. Lo anterior se aplica para ambos algoritmos, modificando su esquema de funcionamiento. Los aciertos respectivos se observan en las tablas 7 -10.

Familia	Acierto (%)	Fracaso (%)
Db6	48.50	51.49
Db4	53.89	46.10
Coiff2	48.70	51.29
Coiff4	49.70	50.29
Sym4	45.09	54.91
Sym5	50.69	49.30

Tabla 7. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo uno).

Familia	Acierto (%)	Fracaso (%)
Db6	58.58	41.42
Db4	56.08	43.91
Coiff2	56.22	43.78
Coiff4	60.67	39.32
Sym4	51.09	48.90
Sym5	54.29	45.70

Tabla 8. Aciertos y fracasos en el proceso de cuantificación del sistema de supervisión (Algoritmo uno).

Acierto (%)	Fracaso (%)
42.61	57.39

Tabla 9. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo dos).

Acierto (%)	Fracaso (%)
50.89	49.10

Tabla 10. Aciertos y fracasos en el proceso de cuantificación del sistema de supervisión (Algoritmo dos).

Según los porcentajes de acierto y fracaso arrojados por las tablas 7-8, se observa que la familia Db4 y Coiff 4 muestran un mejor desempeño, tanto en la localización de la avería como en su severidad. Por el contrario, las tablas 9-10 exponen unos porcentajes muy bajos de acierto, catalogando entonces, el procedimiento del algoritmo uno como el mejor en esta prueba.

C. Prueba tres

La tercera prueba se llevo a cabo esta vez sin la operación de diferencias quedando como estructura de funcionamiento para el algoritmo uno: TWD, segmentación y MPCA, y para el algoritmo dos: Segmentación y MPCA. Los resultados se muestran en las tablas 11-14.

Familia	Acierto (%)	Fracaso (%)
Db6	85.93	14.07
Db4	87.42	12.57
Coiff2	86.58	13.42
Coiff4	87.62	12.37
Sym4	86.16	13.84
Sym5	87.32	12.67

Tabla 11. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo uno).

Familia	Acierto (%)	Fracaso (%)
Db6	81.63	18.36
Db4	84.43	15.56
Coiff2	79.24	20.75
Coiff4	80.23	19.76
Sym4	62.07	37.93
Sym5	81.13	18.86

Tabla 12. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo uno).

Acierto (%)	Fracaso (%)
80.83	19.16

Tabla 13. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo dos).

Acierto (%)	Fracaso (%)
73.45	26.54

Tabla 14. Aciertos y fracasos en el proceso de cuantificación del sistema de supervisión (Algoritmo dos).

De acuerdo a los porcentajes mostrados en las tablas, se infiere que esta vez la familia Coiff4 proporciona un mejor diagnóstico en la localización de la avería, mientras que Db4 muestra el mejor desempeño en la predicción de la severidad.

D. Prueba cuatro

Para esta prueba se utiliza otro criterio para segmentar las señales, persiguiendo el objetivo de estudiar la señal según sus variaciones de energía, estipulando como ancho de ventana los puntos en los cuales existen cambios abruptos en la señal determinados por sus picos y valles. Una vez segmentada la señal, se calcula la energía de cada una de las particiones de la misma, esto se realiza para todo el conjunto de validación. De allí, resulta una matriz de

energías, tomándose esta medida como descriptor para el análisis de componentes multivariantes.

La prueba se hizo para los dos algoritmos y sus resultados se muestran en las tablas 15-18.

Familia	Acierto (%)	Fracaso (%)
Db6	84.03	15.96
Db4	85.92	14.07
Coiff2	84.11	15.89
Coiff4	86.12	13.87
Sym4	82.53	14.47
Sym5	81.44	18.56

Tabla 15. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo uno).

Familia	Acierto (%)	Fracaso (%)
Db6	79.17	20.83
Db4	82.53	17.47
Coiff2	81.67	18.33
Coiff4	83.13	16.86
Sym4	78.44	21.55
Sym5	83.65	16.35

Tabla 16. Aciertos y fracasos en el proceso de severidad del sistema de supervisión (Algoritmo uno).

Acierto (%)	Fracaso (%)
59.98	40.02

Tabla 17. Aciertos y fracasos en el proceso de localización del sistema de supervisión (Algoritmo dos).

Acierto (%)	Fracaso (%)
58.58	41.42

Tabla 18. Aciertos y fracasos en el proceso de cuantificación del sistema de supervisión (Algoritmo dos).

Se observa que el algoritmo uno brinda un diagnóstico más acertado en comparación al dos. Por otro lado, las familias Wavelet que mejor se comportan en esta estructura son la Coiff4 y Sym5, localizando y cuantificando el daño.

E. Prueba cinco

La quinta prueba se ejecutó pensando en observar el desempeño de la señal ante un ruido aleatorio presente, que puede presentarse eventualmente. Para ello, se eligieron las familias Wavelet que mostraron el mejor desempeño en el proceso de localización en cada una de las pruebas anteriores, siendo estas las Coiff2, Db4, Coiff4 y Coiff4, respectivamente. De manera adicional se incluyó para este análisis aquella configuración en la cual el algoritmo dos tuvo el porcentaje más alto de acierto en la localización, siendo este aquel que solo posee segmentación y MPCA. Los resultados se exponen a continuación (tabla 19):

Wavelet madre	Estructura	Acierto	Fracaso
Coiff2	TWD -dif-segm-MPCA	10.97	89.02
Db4	TWD-corr-segm-MPCA	10.14	89.86
Coiff4	TWD-segm-MPCA	10.37	85.52
Coiff4	TWD energ-MPCA	13.97	86.02
Ninguna	Segm-MPCA	12.81	87.19

Tabla 19. Porcentajes de acierto y fracaso ante la presencia de ruido.

Se observa que los algoritmos implementados son sensibles al ruido, mostrando un bajo desempeño en la localización de averías. No obstante, el esquema que mostró el porcentaje de acierto más alto es el que realiza el tratamiento de las señales con TWD, diferencias, segmentación y MPCA, utilizando la familia Coiff4.

VII. CONCLUSIONES Y OBSERVACIONES

- Con el presente proyecto se logró adaptar un algoritmo de supervisión para la evaluación de daños en tuberías (nivel 3¹), que combina análisis de vibraciones [55] (modelado y experimentos), procesamiento de señales (extracción de características y reducción de dimensionalidad) e identificación de daños usando Razonamiento Basado en Casos.
- La evaluación del daño comprende desde la identificación y ubicación geométrica de este, hasta su cuantificación, obteniendo como resultados los mostrados en el presente artículo.
- Dentro de la estructura general del proyecto de investigación [55] al que se encuentra adscrito el presente trabajo de grado, se logró determinar el número y porcentajes de daño en la tubería sujeta a vibraciones, necesarios para entrenar y validar numéricamente el algoritmo.
- Revisando los resultados obtenidos se puede concluir que es posible realizar el proceso de extracción de características y reducción de dimensionalidad mediante transformada Wavelet discreta y MPCA sin afectar de manera significativa la información contenida en la matriz de datos principal.
- Se validaron numéricamente los algoritmos expuestos y se obtuvo como resultado que el esquema de procesamiento más adecuado para

¹ Nivel 3. Etapa en la cual se determina el daño presente en la tubería, ubicación geométrica del daño y se cuantifica la severidad del daño. Estos niveles son útiles para el diagnóstico de daños en sistemas estructurales que requieren de la ubicación, tipo y la severidad de daños en dichas estructuras. [50]

aplicaciones de supervisión y diagnóstico de fallas en tuberías de gas, es aquel que utiliza TWD, segmentación y MPCA, ya que demuestra altos porcentajes de acierto tanto en los procesos de cuantificación como de localización de averías, comparado con otros esquemas analizados a lo largo del presente trabajo.

- Se determina que las Wavelets que mejor desempeño muestran en los diferentes esquemas son la Coiff2, Db4, Coiff4 y Coiff4 en cuanto a localización. Por otro lado, se observa que las familias Db6, Coiff4, Db4 y Sym5 obtienen buenos resultados en términos de severidad de daño.
- Respecto al tiempo de computo de los algoritmos, se percibe que este se ve afectado por las diferentes configuraciones de Wavelets madre, esto debido a que los niveles de descomposición difieren entre ellas, generando así mayor demanda en sus recursos de procesamiento.
- Se observa que los dos algoritmos expuestos en este artículo pueden ser utilizados bajo diferentes parámetros para dos partes del proceso de diagnóstico, el primero para la localización de elementos averiados y el segundo para la cuantificación de daños presentes.
- Se observa que en el esquema en el que se usa como característica la energía, el algoritmo número uno es en el que se obtienen mejores resultados. Adicionalmente, se observa que la Wavelet madre que mejor comportamiento tiene es la Coiff4 en localización y la Sym5 en cuantificación.
- Se observa que el sistema de supervisión implementado no es robusto al existir ruido en las diferentes señales, sin embargo, el esquema que menos sensibilidad mostró ante el ruido es aquel que aplica TWD, energía y MPCA para el procesamiento de los datos.
- El presente trabajo cumple con el objetivo propuesto de analizar el comportamiento de ciertas herramientas computacionales para la detección de deformaciones en tuberías. Analizado dentro de un contexto general, se considera que es una herramienta valiosa para la posterior comparación respecto a otro tipo de herramientas aplicadas al mismo caso de ingeniería, definiendo ventajas y desventajas de forma comparativa, El presente proyecto sienta las bases para trabajos futuros enfocados en el análisis mencionado anteriormente.

A. Transformada Wavelet

La Transformada Wavelet (TW) es una herramienta matemática que permite analizar en un plano frecuencial y temporal una señal, además la descompone en sus elementos más importantes [71],[72]. Su principio de funcionamiento se basa en la representación de una señal determinada como la superposición de diferentes señales base llamadas *Wavelets madre*, que son escaladas y trasladadas en el tiempo a través de la señal original [73], [74]. De allí, se desprende como resultado los coeficientes wavelets representados en un plano de tiempo-escala, cuya longitud depende del nivel de descomposición y contiene información de la señal original [58][75].

Existen diversos tipos de wavelets madre, tales como: *Haar, Daubechies, Biortogonal, Coifflets, Symlets, Morlet, Sombrero mexicano y Meyer* [76]. El procedimiento general de esta herramienta se describe a continuación:

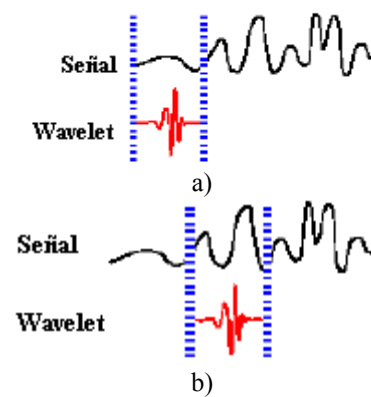


Figura 18. Etapa 1 de la transformada Wavelet. a) Escala inicial de la señal, b) desplazamiento en el tiempo de la Wavelet seleccionada. Fuente: SAMIR, RODRIGO [76]

En primera instancia, se define una escala inicial que modifica la forma de la Wavelet madre y se desplaza a lo largo del eje temporal de la señal original, como se observa en la figura 18.




Figura 19. Variación en la escala y desplazamiento en el tiempo. Fuente: SAMIR, RODRIGO [76]

Posteriormente y después de desplazar la señal por todo el eje de tiempo, se varía la escala de la Wavelet y se repite el procedimiento anterior, como se muestra en la gráfica 19.

Estos pasos se hacen continuamente hasta culminar todos los valores en tiempo y escala deseados. Por otro lado, cabe mencionar que la transformada Wavelet esta definida para el tiempo continuo y discreto [55], [77],[78].

La transformada Wavelet continua (TWC), esta expresada como la suma en todo instante de tiempo de la totalidad de la señal multiplicada por la escala respectiva [79],[80], variando las versiones de la Wavelet utilizada dependiendo del caso, como se muestra en la ecuación 3.

$$Wf(s, p) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} f(t) \Psi\left(\frac{t-p}{s}\right) dt \quad \text{Ec. 3}$$

Donde s denota la escala, p es la posición y $\frac{1}{\sqrt{s}}$ corresponde a un factor de energía normalizado para las diferentes escalas. Se puede afirmar entonces, que el parámetro s proporciona información sobre el comportamiento de la señal en frecuencia, mientras la variable p brinda información en el dominio del tiempo [74]. En adición a esto, se encuentra que a mayor escala, menor longitud de la señal Wavelet y en consecuencia se adquieren características detalladas de la señal.




Figura 20. Árbol de descomposición TWD. Fuente: RAFIEE, SCHOEN, PRAUSE URFER [77]

En cuanto a la transformada Wavelet discreta (TWD) [81], la idea es separar la señal original en secuencias de datos de bajas y altas frecuencias, realizando un submuestreo para descomponer la señal en sus niveles correspondientes [55],[79], como resultado de esta operación se tiene una representación que inicia con N muestras de la señal original y que al término de cada nivel de simplificación resultan dos grupos de datos, uno correspondiente a la información de detalle y otro a la de aproximación, cada uno con $2^{m-1}N$ muestras [82]. Un esquema del proceso que realiza la TWD se ilustra en la figura 20 y sus ecuaciones características se enumeran a continuación.

$$y_{low} = x[k] * g[n] = \sum_{k=-\infty}^{\infty} x[k] * g[2n - k] \quad \text{Ec. 4}$$

$$y_{high} = x[k] * h[n] = \sum_{k=-\infty}^{\infty} x[k] * h[2n + 1 - k] \quad \text{Ec. 5}$$

Donde $x[k]$ es la señal original, $g[n]$ y $h[n]$ denotan la respuesta al impulso en bajas frecuencias y altas frecuencias respectivamente, y k son las diferentes muestras de la señal.

La diferencia entre TWC y TWD radica en la manera en la cual los coeficientes son calculados en términos de sus escalas y desplazamientos en el tiempo. Es decir, la TWC

opera para toda escala desde la mínima hasta la máxima, mientras que la TWD escoge las escala y posiciones en potencias de dos (2^m) [79].

B. Análisis de Componentes Principales Multivariabales

El análisis de componentes principales (PCA) es un mecanismo estadístico que analiza un gran número de variables correlacionadas entre sí [43]. Como producto de este análisis se logra una reducción del universo de variables manteniendo la mayor cantidad de información posible bajo las siguientes premisas [56]:

- Las variables resultantes no se encuentran correlacionadas entre sí.
- Las variables resultantes son combinaciones lineales del grupo de elementos original.

Ese tipo de análisis tiene como objetivos[84] :

- Extraer la información más importante de un conglomerado de datos.
- Reducir el tamaño del mismo, conservando sus elementos más significativos.
- Analizar la nueva estructura de las variables.

Básicamente, PCA crea un nuevo espacio vectorial definido por varios vectores perpendiculares entre sí que sirven de sistema de referencia [84] . El primero de ellos se sitúa en la dirección donde mas varían los datos (posee la mayor varianza de todos los componentes ubicados en el espacio) , el siguiente se ubica perpendicular al anterior, obteniendo gran parte de la variabilidad restante y así sucesivamente [85] . Estos vectores definen nuevas variables que no son mas que representaciones lineales de la información original, y se denominan componentes principales.

Con base en ellas, se reduce la dimensión del conglomerado inicial, bajo la premisa de seleccionar aquellas que recojan la mayor varianza posible de los datos, garantizando entonces, que estas no contienen información redundante y por ende condensan la mayoría de la información.

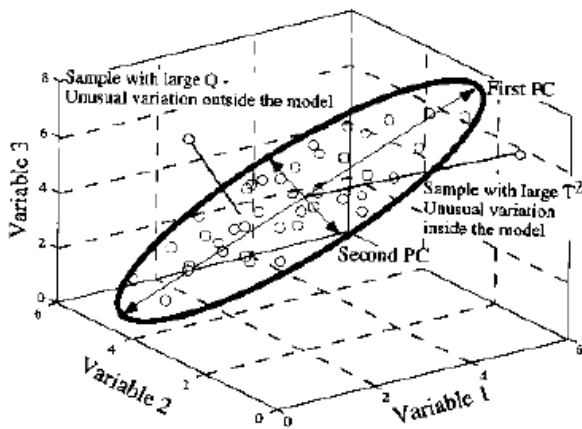


Figura 21. Espacio vectorial PCA. Fuente: BREZMES [42]

Entonces, partiendo de lo mencionado anteriormente, es posible, partir de un conjunto de datos multidimensionales y proyectar sus medidas en un grupo de menor dimensión [42], como se observa en la figura 21. Allí se parte de una estructura de 3 variables (3 dimensiones) y se lleva a un espacio bidimensional en función de 2 componentes principales.

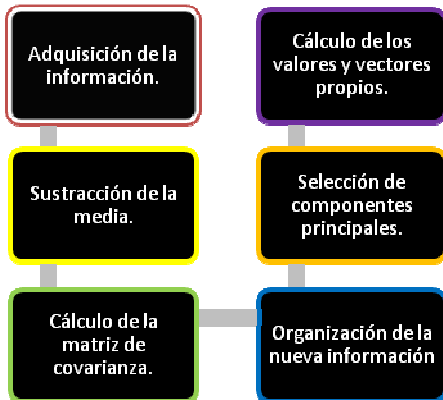


Figura 22. Esquema de PCA. Fuente: Autores

Respecto al procedimiento matemático, a continuación se muestra un diagrama (Figura 22) en el cual se exponen los pasos necesarios para realizar el análisis de componentes principales [56].

Paso 1: Adquisición de la información: Se recolectan numerosas estructuras de datos correlacionados entre sí, para iniciar el proceso de reducción de dimensionalidad.

Paso 2: Sustracción de la media: Se normalizan los datos alrededor de su media, este proceso se hace para todas las dimensiones, es decir que si se tienen dos conjuntos de datos (a y b), entonces tanto a los valores de (a) como a los de (b) se les restan sus medias respectivas. Esta operación se realiza para llevar todos los datos que poseen muchas escalas a una sola en común y así evitar problemas de

interpretación y contribución a la varianza de las señales[56], [42].

Paso 3: Cálculo de la matriz de covarianza: Debido a que todos los datos están representados en una misma escala (normalizados), se calcula la matriz de covarianza entre los mismos, permitiendo destacar cada una de las variables por su grado de variabilidad. No obstante, existe otra opción, el cálculo de la matriz de correlaciones, esta se tiene en cuenta cuando los datos no están normalizados y se considera que todas las variables tienen la misma importancia.[86].

Paso 4: Cálculo de los vectores y valores propios: Se hallan los vectores y valores propios de la matriz de covarianza, estos se encuentran distribuidos en orden descendente según su varianza y brindan información importante sobre los datos originales[56].

Paso 5. Selección de componentes principales: En este punto es donde realmente se ve la importancia de esta herramienta, ya que aquí es cuando se realiza la reducción de dimensionalidad. Para ello se debe seleccionar un número adecuado de valores propios que contengan el mayor porcentaje de variabilidad sobre la varianza total. Para esto existen varios métodos [87], tales como:

- Porcentaje explicado: Consiste en estipular un porcentaje de varianza fijo. Por ejemplo, el 70% y tener en cuenta todos los valores propios cuya variabilidad no supere la cantidad estipulada.
- Criterio de Kaiser: Todos los componentes cuyos eigenvalores sean mayores al promedio de los mismos se conservan.
- Criterio Jolliffe: Se tienen en cuenta los componentes cuya varianza sea mayor que 0.7.
- Scree test de Cattell: Es un método visual, se consideran todas las componentes cuyos descensos sean poco significativos.

Este proceso ayuda a eliminar las componentes que no son representativas, aunque como efecto colateral se puede llegar a sufrir una ligera pérdida de información en proporción a su varianza, es decir, si el eigenvalor tiene un valor pequeño no se perderá mucha información y viceversa [84]. Ya seleccionadas las componentes principales, se debe formar un vector característico que contenga todos los eigenvalores seleccionados [67], como se muestra en la ecuación 6.

$$\text{Vector Característico} = (eig1 \ eig2 \ eig3 \ \dots \ eig_n) \text{ Ec. 6}$$

Donde n es el número de valores propios seleccionados.

Paso 6. Organización de la nueva información: Para ello se deben multiplicar los datos normalizados en el paso 2 con el vector característico [67], como se observa en la ecuación 7.

$$\text{Datos finales} = V.C * D.N \text{ Ec. 7}$$

Donde V.C y D.N denotan los vectores característicos y los datos normalizados respectivamente.

Se tiene como resultado de aplicar estas ecuaciones, los datos expresados en un nuevo espacio vectorial en términos de sus eigenvectores.

Por otra parte, cabe destacar que existe otra técnica llamada Análisis de Componentes Multivariantes (MPCA) que es una extensión de PCA, con la diferencia que la primera puede simplificar el tamaño de los datos que contengan tres o más dimensiones, brindando una mejora significativa en esta herramienta estadística [88].

C. Razonamiento Basado en casos

El razonamiento basado en casos (CBR), es una técnica que se enfoca en solucionar situaciones nuevas partiendo de casos previamente resueltos, reutilizando soluciones o adaptándolas por medio de inferencias a nuevos casos [89], [90]. Se fundamenta en la manera como la mente humana resuelve problemas diariamente a partir de episodios vividos con anterioridad, pues ésta crea una base de soluciones que puede aplicar en diferentes momentos de la vida [91].

Este método se desagrega en ciclos o etapas secuenciales, cuyo objetivo fundamental es la solución de un problema utilizando analogías. En otras palabras, “el CBR recupera soluciones de casos obtenidos en el pasado y los reutiliza en casos similares en el presente” [60].

El proceso del razonamiento es secuencial y está basado en cuatro acciones [93], [91]:

- Recuperar el caso o casos pasados más similares a la nueva situación presentada.
- Reutilizar la información para resolver el nuevo caso.
- Revisar la solución propuesta.
- Retener o almacenar la nueva solución una vez ha sido confirmada o validada, de manera que pueda ser útil para resolver problemas futuros. Lo anterior se puede observar figura 23.

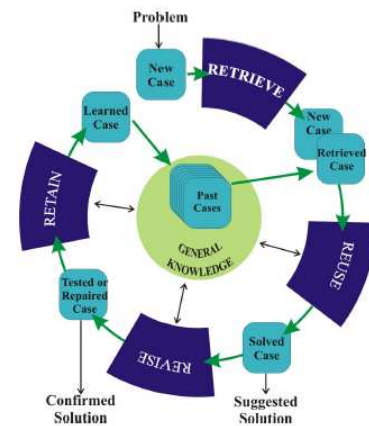


Figura 23. Ciclo CBR. FUENTE: MUJICA [60].

D. Correlación Cruzada

La correlación mide la relación lineal existente entre dos variables cuantitativas determinadas [93] en tiempo continuo o discreto [55]. Para señales continuas, la función de correlación cruzada está definida en la ecuación 8.

$$R_{XY} = x(t) ** y(t) = \int_{-\infty}^{\infty} x(\lambda) x(\lambda - t) d\lambda \text{ Ec. 8}$$

Donde: t denota retraso, R_{XY} corresponde a la correlación entre dos señales diferentes (x(t) y y(t)), más conocida como correlación cruzada.

Por otro lado, en la ecuación 9, se define la función de la correlación para tiempo discreto.

$$R_{XY} = x[p] ** y[p] = \sum_{n=-\infty}^{\infty} x[n]y[n - p] \text{ Ec. 9}$$

Donde: p=0,±1,±2,±3... y R_{xy} corresponde a la correlación cruzada entre x[p] y y[p].

REFERENCIAS

[1] Percival, Donald; Walden, Andrew. Cambridge series in statistical and probabilistic mathematics: Wavelet methods for time series analysis. Estados Unidos de América. Cáp. 4. Pág. 56-156. 2002.

[2] Aranguren, Liz. Identificación de patrones de consumo de los venezolanos mediante máquinas de vectores soporte. Universidad de Mérida. Venezuela. 2008.

[3] Derere, L. Case-based reasoning: diagnosis of fault in complex systems through reuse of experience. International test conference 2000 (ITC'00). 2000

[4] Ávila, Humberto; Clavijo, William; Renovación y rehabilitación de redes de distribución de agua potable y de alcantarillado. XX Congreso latinoamericano de hidráulica. Cuba. 2002.

[5] D. Levitan. Fixing the Gulf Oil Leak: Blowout Preventers and Robotic Submarines. Tomado de <http://spectrum.ieee.org/energywise/energy/fossil-fuels/fixing-the-gulf-oil-leak-blowout-preventers-and-robotic-submarines>. Última revisión: 1 de Agosto de 2010.

- [6] P. Meyer. Biofuel review part 2: Emission impacts and infrastructure development. Tomado de <http://www.todaysengineer.org/2009/Nov/Biofuels-pt2.asp>. Última revisión: 25 de Julio de 2010.
- [7] Kemp, David. Exploring environmental issues: An integrated approach. Canada. Pág. 201-202. 2004
- [8] Berrios, Rodrigo; Nuñez, Felipe; Cipriano, Aldo; Paredes, Rodrigo. Expert fault detection and diagnosis for the refrigeration process of a hydraulic power plant. Proceedings of the 27th Chinese Control Conference. China. 2008.
- [9] Wang, Xiaoning; Zhu, Deheng; Li, Fuqi; Liu, Na. Application of expert system (es) technology in fault diagnosis of steam turbine generators. Proceedings of IEEE TENCON'02. China. 2002.
- [10] Long, Hao; Wang, Xinmin. Aircraft fuel system diagnostic fault detection through expert system. Proceedings of the 7th world congress on intelligent control and automation. China. 2008.
- [11] J. Li, Y. Zhang, S. Jin. Pipeline leakage monitor system based on virtual instrument. Proceedings of the 2009 IEEE international conference on mechatronics and automation. China. 2009.
- [12] S. Sadovnychiy. Automation system for pipelines plan reconstruction. International symposium on industrial electronics. ISIE'00. Mexico. 2000.
- [13] I. awhar, N. Mohamed, K. Shuaib. A framework for pipeline infrastructure monitoring using wireless sensor network. International federation for information processing IFIP. Vol. 264. Estados Unidos de América. Pág. 185-196. 2008.
- [14] T. Kaewkonga, J. Lim. Statistical estimated parameter for pipeline condition monitoring using acoustic emission. Instrumentation and measurement technology conference. IMTC 2007. Polonia. 2007.
- [15] M. Guarino. BP oil spill: undersea accident increases flow of oil into Gulf. The christian science monitor. Estados Unidos de América. 2010.
- [16] Willoughby, David; Woodson, Roger; Sutherland, Rick. Plastic piping handbook. Estados Unidos de América. Pág. 12-40. 2002.
- [17] K. John. Major oil spill disclosed in Alaska, oil spill is largest ever on North slope. Tomado de <http://www.cbsnews.com/stories/2006/03/10/business/main1391608.shtml?tag=mncol;lst;5>. Última revisión: 10 de Marzo de 2010.
- [18] Baptista, Fabricio; Vieira, Jozue. A new impedance measurement system for PZT-based structural health monitoring. IEEE transactions on instrumentation and measurement. Vol. 58. No. 10. 2009.
- [19] E. Altamiranda, E. Colina. Intelligent Supervision and Integrated Fault Detection and Diagnosis for Subsea Control System. IEEE Oceans 2007-Europe conference. 2007
- [20] Huang, Minshui; Li, Jie; Lu, Xinhai; Hu, Guoxiqang. Study on damage identification for bridge structure based on improved genetic algorithm. 2010 international conference on mechanic automation and control engineering. China. 2010.
- [21] W. Zhongwei, C. Qixin, L. Nan, Z. Lei. Development of new pipeline maintenance system for repairing early-built offshore oil pipelines. Research Institute of Robotics, Shanghai Jiao Tong University, Shanghai P.R of China. 2008.
- [22] S. Bo-lin, S.Bi-feng, C. Fei. New sensor technologies in aircraft structural health monitoring. 8th conferencia internacional sobre monitoreo y diagnósticos de condiciones, Beijing, China. 2008.
- [23] K. Jong-Hoon, S. Gokarna, B. Noureddine, I. Sitharama. SPAMMS: A sensor-based pipelines autonomous monitoring and maintenance system. Departamento de ciencias de la computacion, Louisiana State University, Baton Rouge, Louisiana. Escuela de ingeniera de comunicaciones. Tunes. 2010.
- [24] G. Hamdreza, S. Esmaeel, Z. Abolghassem, A. Roya. Vibration based damage detection in smart non-uniform thickness laminated composite beams. Canada. 2009.
- [25] Ghaffari, Hamidreza; Saeedi, Esmaeel. Vibration based damage detection in smart non-uniform thickness laminated composite beams. Science and technology for humanity (TIC-STH), 2009 IEEE Toronto international conference. Canada. 2010.
- [26] Li, Lian; Jiang, Guoxing; Lai, Ping; Jin, Shijiu. Recognition system for pipeline typical abnormal events based on DSP. The 9th international conference on electronic measurement and instruments (ICEIM'09).
- [27] Awawdeh, Amjad; Bukkapatnam, Satish; Kumara, Soundar; Bunting, Charles; Komanduri, Ranga. Wireless sensing of flow-induced vibrations for pipeline integrity monitoring. 4th IEEE workshop on sensor array and multichannel processing. Estados Unidos de América. 2006.
- [28] Jong, Kim; Gokarna, Sharma; Noureddine, Boudriga; Sitharam, Iyengar. RAMP system for proactive pipeline monitoring. 2nd international conference on communication systems and networks (COMSNETS'10). India. 2010.
- [29] Yang, Jin. A research of massive data processing and correlation analysis. IEEE international conference on industrial technology (ICIT'08). China. 2008.
- [30] Zhao, M. Chen, Z. F. Blaabjerg. Optimization of electrical system for offshore wind farms via genetic algorithm. Renewable power generation (IET). Vol. 3. Pág. 205-216. 2009.
- [31] Guoquan, Ren; Zhang, Peilin; Fang, Liqing. Application of remote diagnosis expert system in the failure of mechanical facilities based on oil analysis. The international conference on control and automation (ICCA'02). Estados Unidos de America. Pág. 217-220. 2002.
- [32] Angeli, Chr. An online expert system for fault diagnosis in hydraulic systems. Expert systems. Technological Institute of Piraeus. Grecia. 1999.
- [33] Kang, Bavarian; Tan, H. Lo, Z. A hybrid neural system for traffic estimation and failure detection in communication networks. Proceedings of the 34th Midwest symposium on Circuits and systems. Estados Unidos de America. Vol. 1. Pág. 541-544. 1991.
- [34] Chandler, T. The technology development of automatic metering and monitoring systems. The 7th international power engineering conference (IPEC'05). Singapur. Pág. 1-147. 2005.
- [35] A. Azadeh; M. Fam; M. Khoshnoud; M. Nikafrouz. Design and implementation of a fuzzy expert system for performance assessment of an integrated health, safety, environment (HSE) and ergonomics system: the case of a gas refinery. Tomado de <http://portal.acm.org/citation.cfm?id=1412108>. Última revisión: Agosto 14 de 2010.
- [36] Azadeh, A; Fam, I; Khoshnoud, M; Nikafrouz, M. design and implementation of a Fuzzy expert system for performance assessment of an integrated health, safety, environment (HSE) and ergonomics system: the case of a gas refinery. Information sciences. Vol. 178. Pág. 4280-4300. 2008.
- [37] P. Purkait; S. Chakravorti. An expert system for fault diagnosis in transformers during impulse tests. IEEE power engineering society winter meeting. 2000.
- [38] Baglio, Salvatore; Savalli, Nicolo. "Fuzzy tap-testing" sensors for material health-state characterization. IEEE transactions on instrumentation and measurement. Vol. 55. No. 3. Alemania. Pág. 167-770. 2006.
- [39] Purkait, p. Chakravorti, S. Wavelet transform-based impulse fault recognition in distribution transformers. IEEE transactions on power delivery. Vol. 18, No. 4. Australia. 2003.
- [40] Lytak, Igor. Wavelet analysis of ultrasonic guided waves in pipeline inspection. IEEE workshop on intelligent data acquisition and advanced computing systems: technology and applications. Bulgaria, 2005.
- [41] Tsohope, Constanze; Wolff, Matthias. Automatic decision making in SHM using Hidden Markov models. 18th international workshop on database systems applications. Alemania. Pág. 307-311. 2007.
- [42] Brezmes, Jesús. Diseño de una nariz electrónica para la determinación no destructiva del grado de la maduración de la fruta. Universitat Politècnica de Catalunya. España. 2001.
- [43] Eskandari, Maryam, Toygar, Osen. Effect of eyelid and eyelash occlusions on iris images using subpattern-based approaches. First international conference on soft computing, computing with words and perceptions in system analysis, decision and control (ICSCCW'09). 2009. Pág. 1-4. Chipre.
- [44] H. Lu, K. Plataniotis, A. Venetsanopoulos. MPCA: multilinear principal component analysis of tensor objects. IEEE transactions on neural networks, Vol. 19, No. 1. 2008.
- [45] Majid, Nazatul; Young, Brent; Taylor, Mark; Chen, Jhon. R. Real-time for monitoring aluminium reduction cells using Multi-way PCA (MPCA) and dynamic Euclidean distances. 2009 IEEE international conference on control and automation. Nueva Zelanda. 2009
- [46] Dezfouli, Siavash; Zabihollah, Abolghasem. Structural health monitoring of buried pipelines under static dislocation and vibration. 2010 IEEE/ASME international conference on Mechatronics and embedded systems and applications (MESA). Pág. 325-329. 2010

- [47] Hillger, Wolfgang; Pfeiffer, Uwe. NDT and SHM of carbon composites using acoustic ultrasonic methods. Aerospace testing expo2006 Europe, AeroNDT forum. Alemania. 2006.
- [48] Mueller, Ingolf; Larrosa, Cecilia; Roy, Surajit; Chang, Fu. An integrated diagnostic and prognostic SHM technology for structural health management. Stanford University. 2009.
- [49] Adewuyi, P.; Wu, S. Vibration-based structural health monitoring technique using statistical features from strain measurements. ARPN journal of engineering and applied sciences. Vol.4. No.3. Asia. 2009
- [50] Zang, C; Friswell, M; Imregun, M. structural damage detection using independent component analysis. SAGE journals online. Tomado de <http://shm.sagepub.com/content/3/1/69.short>. Última revisión: 15 de Agosto de 2010.
- [51] Dreo, Johann; Aumasson, Jean; Tfaili, Walid; Siarry, Patrick. Adaptive learning search, a new tool to help comprehending metaheuristics. Proceedings of the 11th annual conference companion on genetic and evolutionary computation conference: Late breaking papers. 2007.
- [52] Edwards, Tim. Discrete Wavelet Transform: Theory and Implementation, Draft #2 Stanford University, Junio 1992.
- [53] Smith, Lindsay. A tutorial on Principal Components Analysis, Notas de clases, Febrero de 2002.
- [54] Huang Norden. Hilbert-Huang Transform: A method for analyzing nonlinear and nonstationary data. NASA medical technology Summit, USA, Febrero de 2003
- [55] Sandoval, Wilmer. Sistema expert para la evaluación del estado de deformación en tuberías de gas: diseño y validación numérica. Universidad Industrial de Santander. Colombia. 2010
- [56] León, Fabian; Camacho, Jhonatan. Diseño de una interfaz electrónica para el reconocimiento de patrones EMG para prótesis de mano. Universidad Industrial de Santander. 2008
- [57] Trnkoczy, Amadej. Understanding and setting STA/LTA trigger algorithm parameters for the K2. Pág. 7-8. 1998.
- [58] Ojeda, Daniel; Acevedo, Pablo; Villamizar, Rodolfo; Sandoval, Wilmer. 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. Universidad Industrial de Santander. 2010
- [59] Lu, Haiping; Plataniotis, K. Venetsanopoulos, A. MPCA: multilinear principal component analysis of tensor objects. IEEE 2006 Biometrics symposium. Estados Unidos de América. 2006
- [60] 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. 2005
- [61] Richly Optimised soudprint selection for identification in audio streams. IEE proceedings on communications. Pág. 287-289. 2001.
- [62] Sandberg, Kristian. The daubechies wavelet transform. University of Colorado at Boulder. 2004
- [63] 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.
- [64] Ballesteros, Dora. Aplicación de la transformada Wavelet discreta en el filtrado de señales bioeléctrica. Fundación Universitaria Manuela Beltrán. Colombia. 2004.
- [65] García, Antonio. Estación sísmica digital. Tratamiento digital de señales. Universidad de Cádiz. España. 2004
- [66] Colmenares, Alejandro. Análisis multivariante y aplicaciones. Capitulo 2. Tomado de http://webdelprofesor.ula.ve/economia/gcolmen/programa/economia/ejercicios_capitulo_1.pdf. última revisión: 18 de Julio de 2010.
- [67] Cormode Graham. Korn flip. Summarizing Two-Dimensional Data With Skyline-Based Statistical Descriptors, AT&T Labs-Research, Rutgers University. 2009
- [68] Accelrys, R Statistics Component Collection, Accelrys corporation 2010.
- [69] Métodos multivariante y series temporales. Tomado de http://www2.uca.es/grup-invest/teloydisren/alumnos/transparencias/tr_am_cm_03.pdf últimas revisión: 14 de Agosto de 2010.
- [70] 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.
- [71] Cupala W. The upper Bound of the Number of Eigenvalues for a class of Perturbation. Institute of Mathematis, Polish Academy of Sciences, Polonia, 1994.
- [72] Sobrino, Jose. Avances en infromática y sistemas computacionales. Tomo 2. Universitat de Valencia. España. Pág. 265-270. 2000.
- [73] P. Ales, K. Jaromir, V. Oldrich. Wavelet Transform use ofr feature extraction and EEG signal segmentsm classification. IEEE 3th symposium on Communications, Control and signal processing. ISCCSP 2008.Malta. Pág. 719-722. 2008.
- [74] B. Savitri. Still image compression on parallel computer architectures.Kluwer Academic Publishers. Pág. 11-12. 1999.
- [75] Y. bastiaensen, T. Schaepe, J. Baeyens. Analyzing ansEMG signal using Wavelet. The 4th European Congress of the International Federation for Medical and Biological Federation.Vol. 2, Pag.157-160. Antwerp, Belgica. 2008.
- [76] S. Jayaraman, S. Esakirajan, T. Veerakumar. Digital Image Processing.Mc Graw Hill.Cap. 12. Nueva Delhi. Pág. 615-625 2009.
- [77] Q. Ma, S. Wang, J. Zhu, C. Zhang. Damage identification of structure and test study based on Wavelet Transform. Proceedings of the 2008 International Conference on Wavelet Analysis and Pattern Recognition. Pag. 569-573.Hong Kong, 2008.
- [78] K. Samir, M. Rodrigo. Tutorial introductorio a la teoria de Wavelet Tomado de la URL: <http://www2.elo.utfsm.cl/~elo377/documentos/Wavelet.pdf>, el dia 14 de Octubre del año 2010.
- [79] J. Rafiee, M. Schoen, N. Prause, A. Urfer, M. Rafiee. A comparison of forearm EMG and psychophysical EEG signals using statistical signal processing. 2nd International conference on computer, control and communication (IC4), Pakistan. Pág. 1-5. 2009.
- [80] A. Riyasat, A. Shahedul, A. Shah, S. Asaduzzaman, A. Nahidul. Feature extraction of human sleep EEG signals using Wavelet Transform and Fourier Transform. 2nd International Conference on signal processing systems (ICSPS '10). Vol. 3. China. Pág. 701-705. 2010.
- [81] K. Dimitris. Knowledge science, engineering and managment. 3th international conference, KSEM 2009.Austria. Pág. 287-288. 2009.
- [82] S. Eduardo. Introduccion a la transformada Wavelet y sus aplicaciones al procesamiento de señales de emisión acústica. Segundo encuentro del grupo latinoamericano de emisión acústica. Argentina. Pág. 171-185. 2001.
- [83] L. Jongwoo, K. Daryl. Neural signal processing using Discrete Wavelet Transform for Neural Interfaces. Proceedings of 2006 International Conference on Microtechnologies in Medicine and Biology. Japón. Pág. 169-172. 2006.
- [84] Mallat, Stephane. A theory for multiresolution signal decomposition: The Wavelet Representation. IEEE transaction on pattern analysis and machine intelligence. Vol.11. No. 7. Pág. 674-693. 1989.
- [85] Maji, Aini; Young, Brent; Taylor, Mark; Chen, Jhon. Real-time for monitoring aluminium reduction cells using Multi-way PCA (MPCA) and dynamic euclidean distances. 2009 IEEE international conference on control and automation. Nueva Zelanda. Pág. 454-458. 2003. 2009
- [86] Abdi, Hervé; Williams, Lynne. Principal component analysis.Wiley interdisciplinary reviews: Computational Statistics. Vol. 2, Issue. 4. Pág. 433-459. 2010.
- [87] Villardón, José. Analisis de componentes principales. Tomado de: <http://biplot.usal.es/DOCTORADO/3CICLO/BIENIO-04-06/ACP/ACP.pdf>, última revisión: 5 de Julio de 2010.
- [88] Martín, Pilar; Pascual, Amelia; Lezama, Enrique; Olmos, Elsy. Una aplicación del análisis de componentes principales en el área educativa.Tomado de http://iies.faces.ula.ve/Revista/Articulos/Revista_09/Pdf/Rev09Gonzalez_Diaz.pdf, última revisión: 1 de Septiembre de 2010.
- [89] Grane, Aurea. Análisis de componentes principales. Universidad Carlos III de Madrid. Tomado de http://halweb.uc3m.es/esp/Personal/personas/agrane/ficheros_docencia/MULTIVARIANT/slides_comp_reducido.pdf, última revisión: 13 de Septiembre de 2010.

- [90] X. Meng; E. Martin; A. Morris. A comparative study of Bi-linear and tri-linear approaches for the monitoring of an industrial batch facilities. European symposium on computer aided process engineering-10. Pág. 1051-1056. 2010
- [91] Tomado de <http://www.edicionsupc.es/ftppublic/pdfmostra/IN01305M.pdf>. última revisión: 23 de Julio de 2010.
- [92] P. Yan, Z. Like. A Case-based Reasoning with Feature Weights Derived by BP Network. Workshop on Intelligent Information Technology Application. Beijing, China. Pág 26-29. 2007.
- [93] Berenji, Hamid. Case-Based Reasoning for Fault Diagnosis and Prognosis. IEEE International Conference on Fuzzy Systems. Vancouver, Canada. Pág 1316-1321. 2006.
- [94] Tomado de :<http://jair.lab.fi.uva.es/~josesan/ia2/cbr/index.html>. Última revisión: 5 de Julio de 2010.
- [95] Moore, David. Estadística Aplicada Básica. Segunda Edición. España. Cap. 2. Pág. 112-113 . 2000.

José de Jesús Gómez Pérez. Bachiller académico con profundización en educación, Escuela Normal Superior. Charalá, Santander, 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, instrumentación y automatización.

Diana Marcela González Quintana. Bachiller académico, Colegio de la Presentación. Bucaramanga, Santander, 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, instrumentación y automatización.

MIE. Ing. Wilmer Alexis Sandoval Cáceres. Ingeniero electrónico egresado de la Universidad Pontificia Bolivariana. Bucaramanga, Santander, Colombia (2005), Maestría en ingeniería electrónica UIS (Universidad Industrial de Santander), Bucaramanga (2010). Director del semillero de investigación Asimov, Universidad Santo Tomas De Aquino, Bucaramanga, Santander, Colombia (Primer semestre de 2009). Miembro del grupo de investigación CEMOS, UIS (2006-2010). Áreas de investigación: Robótica móvil, control, identificación de daños basados en vibraciones.

PhD Rodolfo Villamizar Mejía. Ingeniero electricista egresado de la Universidad Industrial de Santander 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.