

CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS
AVANZADOS DEL INSTITUTO POLITÉCNICO
NACIONAL

UNIDAD ZACATENCO
Departamento de Control Automático

Monitoreo de Salud Estructural empleando Análisis de Componentes Principales con Árboles de Decisión y Máquinas de Soporte Vectorial

TESIS

Que presenta

Ing. Karina Sánchez Sosa

Para obtener el grado de:

Maestra en Ciencias

En la especialidad de:

Control Automático

Director de la tesis:

Wen Yu Liu

Agradecimientos:

Agradezco al Consejo de Ciencia y Tecnología (CONACYT) y al Centro de Investigación y Estudios Avanzados, CINVESTAV Zacatenco por su apoyo y patrocinio para la realización de este proyecto de tesis.

Agradezco infinitamente al Dr. Wen Yu Liu por ser un excelente guía en esta tesis, por su tiempo dedicado, observaciones y paciencia.

A los revisores de este trabajo de investigación, el Dr. Fernando Castaños Luna por sus valiosas observaciones que hicieron posible un planteamiento más detallado de la solución propuesta y al Dr. Sergio Salazar Cruz por su visión propuesta para el proyecto para su implementación.

A mis compañeros del CINVESTAV, que se convirtieron en amigos, por no claudicar en las noches en vela.

A todos, gracias.

Karina Sánchez Sosa

Dedicatoria

A mi prometido:

Ricardo Carrillo, por todo, por el impulso y la confianza, por toda su alegría y amor, por ser parte de mi vida.

A mis padres:

Guadalupe y Mario, por apoyarme en el camino de la vida y hacer valer los pequeños momentos. Por hacerme quien soy.

A mis hermanos:

Por permitirme ser un ejemplo y una amiga.

A mi mejor amiga:

Kristal Trejo, por su sinceridad, apoyo y confianza, por ser quien es.



Índice general

| | |
|---|-----------|
| 1. Introducción | 1 |
| 1.1. Justificación | 1 |
| 1.1.1. Edificios | 1 |
| 1.1.2. Puentes | 2 |
| 1.1.3. Aeroespacial | 2 |
| 1.1.4. Tuberías | 3 |
| 1.1.5. Otros | 3 |
| 2. Monitoreo de Salud Estructural | 5 |
| 2.1. Definición | 5 |
| 2.1.1. Etapas | 5 |
| 2.2. Ventajas | 9 |
| 2.3. Clasificación | 9 |
| 2.3.1. Por complejidad | 9 |
| 2.3.2. Por temporalidad | 10 |
| 2.3.3. Por el tratamiento de los datos. | 10 |
| 2.4. Investigación Actual | 11 |
| 3. Metodologías empleadas en el SHM | 13 |
| 3.1. Identificación de parámetros modales, basada en vibración (Análisis Modal) . | 13 |
| 3.1.1. Análisis modal teórico | 14 |
| 3.1.2. Análisis modal experimental | 16 |
| 3.1.3. Indices de daño y Monitoreo a largo plazo | 20 |
| 3.1.4. Metodos para colocación óptima de sensores para SHM | 23 |
| 3.1.5. Métodos basados en Actualización del modelo | 24 |
| 3.1.6. Filtros y observadores | 26 |
| 3.1.7. Métodos basados en Algoritmos Genéticos | 32 |
| 3.1.8. Metodos basados en Propagación de ondas guiadas. | 33 |
| 3.1.9. Metodos integrales. | 36 |

| | |
|--|-----------|
| 4. Análisis de Componentes Principales en el SHM | 39 |
| 4.1. PCA | 39 |
| 4.2. Resultados y discusión | 42 |
| 4.2.1. Aplicación de PCA lineal a los datos de aceleración | 42 |
| 4.2.2. Análisis 1. Señales recopiladas bajo la entrada E1 | 42 |
| 4.2.3. Análisis 2. Señales recopiladas bajo la entrada E1+ND | 43 |
| 4.2.4. Análisis 3. Señales recopiladas bajo las entradas E1 y E2, +ND | 47 |
| 4.2.5. Análisis 4. Señales residuales | 49 |
| 4.2.6. Resumen | 49 |
| 4.3. Extracción de características sensibles | 51 |
| 4.3.1. <i>Características estadísticas en el dominio del tiempo</i> | 51 |
| 4.3.2. <i>Características transitorias</i> | 53 |
| 4.4. Kernel-PCA y OLPCA para detección de daño en la estructura | 54 |
| 4.4.1. Análisis de componentes principales con funciones Kernel | 54 |
| 4.4.2. Análisis de componentes principales en línea | 55 |
| 4.5. Resultados y discusión | 60 |
| 4.5.1. Extracción de características | 60 |
| 4.5.2. Obtención de los Componentes Principales sobre Características Sensibles. | 61 |
| 4.5.3. Obtención de Características Sensibles sobre los Componentes Principales. | 61 |
| 4.5.4. KPCA | 65 |
| | |
| 5. Clasificadores | 71 |
| 5.1. Máquinas de Soporte Vectorial (SVM) como clasificadores | 71 |
| 5.1.1. Metodología | 72 |
| 5.1.2. Caso linealmente separable | 74 |
| 5.1.3. Caso no linealmente separable | 75 |
| 5.1.4. Generalización en alta dimensión | 75 |
| 5.1.5. Resultados y discusión | 76 |
| 5.2. Árboles de Decisión como clasificadores | 77 |
| 5.2.1. Metodología | 77 |
| 5.2.2. Resultados y discusión | 79 |
| | |
| 6. Conclusiones y trabajo futuro | 81 |

Índice de figuras

| | |
|--|----|
| 3.1. Modelo de subestructuras propuesto. | 28 |
| 3.2. Implementación de filtro espectral. | 30 |
| 4.1. Mediciones de aceleración para excitación E1, estructura sin daño. | 43 |
| 4.2. Mediciones de aceleración para excitación E1, estructura con daño. | 44 |
| 4.3. Mediciones de aceleración para excitación E2, estructura sin daño. | 44 |
| 4.4. Mediciones de aceleración para excitación E2, estructura con daño. | 44 |
| 4.5. Espacio creado por los vectores de aceleración, estructura sin daño. | 45 |
| 4.6. Espacio formado por los vectores de aceleración, estructura con daño. | 45 |
| 4.7. Espacio formado por los vectores de aceleración. | 45 |
| 4.8. Componentes principales E1, fase de entrenamiento | 46 |
| 4.9. Componentes principales E2, fase de generalización. | 46 |
| 4.10. Componentes principales, fase entrenamiento E1+ND. | 47 |
| 4.11. Componentes principales E2, fase de generalización. | 47 |
| 4.12. Componentes principales E1 y E2 | 48 |
| 4.13. Componentes principales, entrenamiento con ND, generalización en D. | 48 |
| 4.14. Residuales para modelo de 2 PCs, por nivel. | 49 |
| 4.15. Espación formado por los vectores de Residuales del modelo PCA. | 50 |
| 4.16. Diagrama de flujo para actualización del modelo. | 59 |
| 4.17. Características estadísticas para excitación E1. Planta baja. | 60 |
| 4.18. Características estadísticas para excitación E2. Planta baja. | 60 |
| 4.19. Tiempo Central de la señal de aceleración, del segundo nivel en E2. | 61 |
| 4.20. Factor K, calculado sobre PCs | 62 |
| 4.21. Factor cresta, calculado sobre los PCs | 63 |
| 4.22. Desviación estandar, calculada sobre los PCs | 63 |
| 4.23. Oblicuidad, calculada sobre los PCs | 63 |
| 4.24. Kurtosis, calculado sobre los PCs | 64 |
| 4.25. Energía de los PCs | 64 |
| 4.26. Tiempo central, calculado bajo un valor preentrenado de Energía. | 67 |
| 4.27. Tiempo Central de los PCs | 67 |
| 4.28. Suma Acumulativa del calculo del tiempo central sobre los PC. | 68 |
| 4.29. Condición ALD para señal de vibración E1+ND | 68 |
| 4.30. Condición ALD para E1+ND, respuesta transitoria | 69 |

| | |
|---|----|
| 4.31. Modificación de la ALD por el cambio paramétrico en la estructura. | 69 |
| 4.32. Espacio creado por los valores de la ALD con un retraso de 2 tiempos. | 69 |
| 5.1. Hiperplanos para clases separables. | 73 |

SHM

Karina Sánchez Sosa

Diciembre-2015

Abstract

This thesis presents a method of analysis which enables the automatic recognition of a parametric change in structures. This change is caused by a mass modification or degradation of elasticity and damping parameters. It is representative of a mass-spring-damper system of two or more degrees of freedom in which the excitation energy is induced on one of the masses and the propagation of waves of movement results in the geometric and structural affectation of the system under study. The clearer example of this representation are the effects of an earthquake on a building of steel and concrete. The implementation of such methodologies in a real system, for the development of preventive, corrective and predictive maintenance, based on the collection of measurements and characterization of them, enables the reduction of costs and the generation of efficient maintenance plans.

The analysis of the data set is carried out in three stages: 1) preparation, 2) transformation domain and 3) classification.

Chapter I introduces the importance of the development of early detection systems for damage on structures, emphasizing the economic and security benefits that can be achieved with the development of a reliable system.

Chapter II and III contain a brief description of the methods widely used in Structural Health Monitoring for the treatment of collected measurements and obtaining useful information in determining the condition of the structure.

Chapter IV describes the methods proposed in a set of three stages for the analysis, considering for the conditioning step, obtaining the relative movements between the levels of the structure, or obtaining statistical characteristics. The second phase, transformation domain, is performed by Principal Component Analysis and kernel transformation functions defined for Support Vector Machines. Proper development of the second stage leads to a high efficiency during stage three, the focus is on the classification of the data obtained from the platform, labeling each sample within a predefined state, which is specified as: a) the structure in its original construction, with masses and homogeneous geometries between levels, b) the structure under a parametric modification induced by the withdrawal of a number of mass on the fourth level.

Chapter V describes the methods used to carry out the third stage, considering two separation algorithms: the hyperplane calculated by SVM and C4.5 algorithm for building a decision tree.

The selection of the methods used in this thesis is for the pursuit of the objective of making the diagnosis of the structure without prior knowledge of the behavior of the structure under different excitation inputs. The study is limited to a single structure and a single parameter change under two different inputs applying oscillatory motion in one degree of freedom.

Resumen

La presente tesis plantea un método de análisis de datos que permita el reconocimiento automático de un cambio paramétrico en una estructura. Este cambio es ocasionado debido a una modificación por pérdida de una cantidad certera de masa o una degradación de los parámetros de amortiguamiento y elasticidad, siendo representativo de un sistema masa-resorte-amortiguador de dos o más grados de libertad en donde la energía de excitación es inducida sobre una de las masas y la propagación de las ondas de movimiento resultan en la afectación geométrica y estructural del sistema bajo estudio. El ejemplo de mayor claridad de esta representación son los efectos del movimiento telúrico sobre una edificación de acero y concreto. La implementación de este tipo de metodologías en un sistema real, para el desarrollo de sistemas de mantenimiento preventivo, correctivo y predictivo, basados en la recolección de mediciones y caracterización de las mismas, permite la disminución de costos y la generación de planes de mantenimiento eficientes.

El análisis del conjunto de datos es efectuado en tres etapas: 1) acondicionamiento, 2) transformación de dominio y 3) clasificación.

En el Capítulo I se desglosa una introducción a la importancia del desarrollo de sistemas de detección de daño prematuro en estructuras, remarcando las ventajas económicas y de seguridad que pueden ser alcanzadas con el desarrollo de un sistema confiable, para lo cual es de alta relevancia diseñar de forma óptima y fiable cada uno de los elementos que permiten la conformación del sistema predictivo.

El Capítulo II y III contiene una breve descripción de los métodos de amplio uso en el Monitoreo de Salud Estructural para el tratamiento de las mediciones recolectadas y la obtención de información de utilidad en la determinación de la condición de la estructura.

El Capítulo IV describe los métodos propuestos durante las tres etapas planteadas para el análisis, considerando para la etapa de acondicionamiento la obtención de los movimientos relativos entre los niveles de la estructura, o la obtención de características estadísticas. La segunda etapa, transformación de dominio, es realizada por Análisis de Componentes Principales y por funciones de transformación kernel definidas para las Máquinas de Soporte Vectorial, encontrando que el empleo de la condición ALD calculada para un Análisis de Componentes Principales en Línea puede ser vista como una característica que permite la detección de un cambio paramétrico, sin necesidad de contar con un conocimiento previo de la condición de la estructura. Una evolución adecuada de la segunda etapa, conduce a una alta eficiencia durante la etapa tres, cuyo objetivo se centra en la clasificación de los datos obtenidos de la plataforma, etiquetando cada muestra dentro de un estado previamente definido, el cual es especificado como: a) la estructura en su estado de construcción original, con masas y geometrías homogéneas entre niveles, y b) la estructura sometida a una modificación paramétrica inducida por el retiro de una cantidad de masa en el cuarto nivel.

El Capítulo V, describe los métodos empleados para efectuar la tercera etapa, considerando dos algoritmos de separación: el hiperplano calculado mediante SVM y el algoritmo C4.5 para la creación de un árbol de decisión.

La selección de los métodos empleados en esta tesis corresponde a la búsqueda del objetivo de realizar el diagnóstico de la estructura sin contar con un conocimiento previo del comportamiento de la estructura bajo distintas entradas de excitación. El estudio se limita a una sola estructura y una sola modificación de parámetros, bajo dos diferentes entradas de movimiento oscilatorio aplicadas en un solo grado de libertad.

Capítulo 1

Introducción

En la actualidad las grandes ciudades tienen concentraciones poblacionales altas, las cuales suelen crecer bajo poco o ningún tipo de control, esto deriva en una tendencia de crecimiento acelerado. Por lo anterior, algunos de los problemas a resolver más importantes son la vivienda, el trabajo, la transportación, la salud pública entre otros. La satisfacción de estas necesidades deriva en la construcción de una mayor infraestructura, sin embargo, cada estructura realizada por el hombre posee un tiempo de vida útil el cual está dado por el uso, el diseño y condiciones ambientales, además de factores humanos como la calidad de los materiales durante la construcción y del trabajo realizado por los obreros.

De manera que, en base a nuevos requerimientos de infraestructura, es de suma importancia conocer cual es el tiempo de vida remanente de las estructuras ya construidas, cual es el tiempo máximo que pueden mantenerse en pie antes de requerir un programa de mantenimiento mayor o su completo reemplazo, así como el factor de seguridad con el que puede seguir operando una construcción después de verse afectada por un fenómeno de causa natural o humana que pudiese haberle provocado algún daño estructural. El conocimiento de lo anterior con precisión, evita costos innecesarios, aumenta la seguridad de la población que usa la instalación, provee de una herramienta eficaz para la planeación de la infraestructura futura dentro de una ciudad y es útil en la mejora de las técnicas de diseño y construcción.

1.1. Justificación

1.1.1. Edificios

La infraestructura mundial tiene tendencia al aprovechamiento del espacio, por lo que la construcción de edificios cada vez más altos plantea uno de los grandes desafíos actuales. La cantidad de rascacielos por ciudad (con un conteo de 7,463 en las primeras 100 ciudades con más rascacielos) plantea un gran campo para investigación y aplicación de técnicas enfocadas al aumento de la seguridad, optimización del mantenimiento, garantía de operación y reducción de costos. Tan solo América del Norte, concentra un 30% de los rascacielos a nivel mundial, lo que coloca la investigación en México como uno de los posibles pilares a

desarrollar en esta área.

Realizando un enfoque del territorio mexicano, la cantidad de edificios con mas de 20 pisos asciende a 109 (2014), con un crecimiento continuo por año. La mayoría de estas construcciones tienen una edad menor a 20 años, por lo que no existe un riesgo real actual de colapso por fin de vida útil. Además, la Ciudad de México se encuentra anclada sobre una zona poco convencional de tipo fangoso lo que la hace susceptible a mayor cantidad de daño durante terremotos y temblores [18]. Realizar una evaluación de la condición del edificio durante y después del evento resulta de gran utilidad para la prevención de tragedias como la ocurrida en el terremoto de 1985.

1.1.2. Puentes

Parte fundamental dentro de la infraestructura de comunicaciones y transportes, es la construcción de puentes vehiculares; la clasificación y complejidad de estas estructuras no se abarcará en el presente texto. La altura de los puentes puede incluso superar la de algunos edificios (el puente mas alto del mundo es el Siduhe River Bridge en China con una altura de 496m) y su extensión varia desde pocos metros hasta decenas de kilometros, siendo de 164.8 km la longitud del puente mas largo Danyang–Kunshan Grand Bridge ubicado también en China (2011) [54].

Al contrario de los edificios, los puentes operan bajo condiciones de carga variables durante el día e igualmente estan sometidos a cargas laterales provocadas por el viento. En Daniele Inaudi [23] se realiza una compilación de monitoreo sobre 40 puentes de diferentes tipos localizados en Austria, Belgica, Canada, Croacia, Francia, Alemania, Italia, Japón, Luxemburgo, Rusia, Suiza, Suecia, Taiwan y los E.U.A; la variedad en el tamaño y los materiales de estos puentes ponen en manifiesto la importancia de conocer el estado de cada uno independientemente de las características individuales que los definen.

1.1.3. Aeroespacial

La industria aeroespacial es especialmente susceptible a la fiabilidad de cada componente. Una falla proveniente de un daño no visible en zonas de alto estrés puede significar un desastre, debido a esto, el proceso de diseño-ensamble-puesta en servicio es susceptible a generar una falla en diferentes etapas [12]:

- **Diseño:** El equipo es diseñado para tener una vida de servicio, tanto en el sistema completo como en cada parte que lo compone. Los ciclos de mantenimiento y recambio estan planeados en base a estas especificaciones de diseño, sin embargo, si alguna de estas etapas es incorrecta, la vida del componente puede acortarse de manera drástica sobre todo en componentes de larga duración o en aquellos que sufren una modificación de diseño durante su vida útil.
- **Cadena de suministro:** Relacionadas directamente con la calidad de manufactura y rehabilitación otorgadas por el proveedor de piezas y componentes.

- Mantenimiento: Relacionadas con un plan de mantenimiento erróneo y mala ejecución del mismo.
- Operación: Derivadas de un uso práctico fuera de las especificaciones de diseño. Dadas también por exceder su uso más allá de su vida útil, lo que comúnmente conlleva a una falla por desgaste.

Los estudios en esta área se enfocan en la detección en extremo temprana del daño a nivel de partículas, por lo que el análisis del componente en laboratorio se vuelve una clave fundamental. El trabajo en esta área requiere alto grado de especialización y no será abordado ampliamente en el presente documento.

1.1.4. Tuberías

Una falla en tubería implica un alto costo en términos humanos y ambientales, en adición dependiendo del tipo de industria puede significar poner en peligro vidas humanas.

Los motivos de un fallo en tuberías pueden ocurrir desde su instalación por pandeos, sobrecargas, diseño deficiente; o pueden ocurrir durante la vida útil donde las causas abarcan desde una mala operación, fallas por corrosión ambiental, fatiga, cristalización, operaciones externas que repercutan en daños a la estructura, diseño deficiente, aumento de la carga por encima de las especificaciones, entre otros [10].

Muchos sistemas de tuberías abarcan grandes extensiones y por lo tanto se encuentran instaladas bajo suelo, por lo que un desafío presente en este campo es localizar el lugar exacto de la falla y su tipo, pues la revisión de toda la extensión de la tubería o de la mayor parte es inabordable.

Dentro de los sistemas que requieren tuberías, se encuentran también los tanques de almacenamiento, que son propensos a sufrir el mismo tipo de daño que las tuberías con la adición del daño provocado por la vibración de la tubería conectada. El monitoreo periódico de estos elementos suele llevarse a cabo fuera de línea por medio de métodos como la inspección visual, pruebas radiográficas y ultrasonicas. Debido al tipo de carga de trabajo, estos elementos pueden presentar desde fisuras y fugas, hasta ruptura completa del contenedor.

1.1.5. Otros

El análisis y modelado del comportamiento de una estructura, ha sido ampliamente extendido a otras aplicaciones que impliquen el análisis de problemáticas frecuentes en dispositivos, correlación entre análisis de elemento finito y resultados reales, modificación estructural, modelado matemático, predicción de respuesta forzada, identificación de fuerzas, predicción de comportamiento, detección de daño, control de vibraciones, monitoreo de procesos [25], caracterización dinámica [21], entre otros. Aplicado en ramas de estudio tales como acústica, música, electrónica, medicina, cambio climático [42], siendo las principales aeronáutica, automotriz [24] y mecánica (maquinaria [49], herramientas [13], rodamientos [48]).

Capítulo 2

Monitoreo de Salud Estructural

2.1. Definición

El monitoreo de salud estructural (SHM, por sus siglas en inglés) es el proceso de detección, localización, cuantificación y calificación de daño presente en una estructura bajo estudio o en elementos pertenecientes a ella. Se basa en la obtención de datos relacionados con cualidades físicas del sistema tanto en su estado sano como en el estado dañado y la realización de una comparación cualitativa a fin de lograr una evaluación del estado actual de la estructura.

El SHM es empleado en diversos campos siendo la ingeniería mecánica, civil y aeroespacial donde tiene un impacto mayor, sin embargo existen investigaciones en ingeniería eléctrica y la electrónica. Gran parte de su utilidad consiste en su aplicación a estructuras complejas donde la variabilidad de formas, materiales y estímulos es alta, lo que implica que un modelado matemático de todo el conjunto, considerando cada una de sus partes sea de muy elevada complejidad, aunando la consideración de las cargas, el envejecimiento de los materiales y los factores ambientales a los que se encuentra sometida la estructura. Es igualmente útil en sistemas donde los componentes críticos se encuentran ocultos o fuera del alcance de análisis físico costeable.

Para la caracterización de la estructura se emplean sobretodo mediciones dinámicas como la vibración bajo condiciones ambientales o de cargas de servicio, y la especificación del daño se logra comparando esta caracterización en el estado anterior al daño y en el estado posterior al daño.

Uno de los aspectos más remarcables del SHM es su naturaleza no destructiva. A pesar de que la colocación del equipo de monitoreo llega a ser invasiva, se busca que no sea necesario retirar componentes para una evaluación que no permita su puesta en servicio nuevamente.

2.1.1. Etapas

El proceso de monitoreo de salud estructural puede ser dividido de la siguiente manera:

Objetivo

Debe definirse si la “estructura en estudio” se encuentra en la etapa de diseño, construcción o utilización. Lo anterior definirá los objetivos del monitoreo, la frecuencia de muestreo y el tipo de sensores a utilizar; además impondrá las limitaciones y estímulos externos a los que estará sujeta, por lo tanto con lo anterior se definirá el método de análisis de datos a emplear que provea el menor error a un costo que sea acorde a las limitaciones. El sistema SHM debe de ser de fácil instalación y mantenimiento a la vez que debe mantenerse fuera del alcance de los usuarios comunes.

Modelado matemático.

El monitoreo de salud estructural requiere la construcción de un modelo, el cual sea capaz de predecir el comportamiento del sistema. Este modelo intensifica la certeza con la que puede identificarse una falla o un cambio en la estructura, además de proveer las herramientas necesarias para alcanzar un nivel de SHM mayor, haciendo posible la identificación del tipo y lugar de la avería, así como el tiempo remanente de la vida útil de la misma. Los modelos de mayor aplicación son variantes de los modelos dinámicos de 2do orden [14], o modelos de varios grados de libertad (MDOFs) tipo Espina [4], el análisis modal [22].

Instrumentación

Sensado y periodicidad de muestreo

Una vez definido el tipo de “estructura bajo estudio” y una vez determinados qué parámetros de la operación serán posibles de medir, es necesario realizar la elección de sensores, definiendo el tipo de señales de entrada y salida, la capacidad, la precisión y equipos adicionales necesarios. Un factor importante a considerar es el tiempo de vida de los sensores debido a que el monitoreo se lleva a cabo por periodos largos de tiempo, deben ser fiables durante el tiempo requerido y bajo las condiciones ambientales necesarias. Dentro de los tipos de sensores que pueden emplearse se destacan los que siguen.

- *Medidores de deformación*

Requieren un montaje directamente anclado al elemento monitoreado, esto puede llevarse a cabo asegurando el sensor sobre la superficie, mediante inserción directa en el concreto mientras este se encuentre fresco, preinserción en bloques de concreto que serán posteriormente añadidos a la estructura, o en algunos casos asegurando solo los extremos. Ofrecen ser robustos a no-homogeneidades del material por lo que son de amplia utilización dentro de muros y columnas con altas cargas. Es común encontrarlos con termistores incluidos, por lo que proveen información acerca de los cambios de temperatura sobre los materiales.

- *Medidores de desplazamiento relativo*

Usados para medir desplazamientos en uniones, articulaciones, grietas o fracturas o deformaciones entre capas de materiales. Altamente utilizados para medir desplazamientos por dilatación de componentes. Se encuentran de tipo potenciómetro o de medición de vibración.

- *Asentamiento diferencial*

Utilizados para medición de distancias verticales o asentamientos relativos en presas, terraplenes y suelos en general, además de permitir la medición de deformaciones sobre todo alrededor de excavaciones, deflexión de puentes y columnas.

- *Estabilidad de suelo*

Se basan en medidores de deformación diseñados para cubrir grandes distancias y con un incremento de superficie de contacto. Pueden encontrarse combinados con sensores de temperatura, deformación local inclinación y aceleración.

- *Rotación/Inclinación*

Empleados para detección de movimientos de cimientos de estructuras y como referencia para metodologías de cálculo que así lo requieran. Utilizados para detección de deslizamientos y vuelcos de bloques.

- *Medidores de Vibración*

Mejor conocidos como acelerómetros, proveen los movimientos sobre 1, 2 o 3 ejes por lo que son ampliamente utilizados en la obtención de frecuencias de vibración de las estructuras. Pueden encontrarse con inclinómetros incluidos.

- *Medidores de Carga*

Diseñados para proveer la medición de cargas por tensión o compresión. Empleados para la medición de carga total en sistemas de sustentación y cimentación, pernos de anclaje, y en general en elementos de carga casi-puntales de estructuras.

- *Medidores de Presión*

Sobre un área determinada determinan empujes activos y pasivos, así como la presión de contacto entre componentes y/o revestimiento.

- *Medidores de Nivel de agua*

Encontrados en presentaciones de medición en tubería, por vibración, de fibra óptica, piezómetros neumáticos. utilizados durante la construcción y monitoreo de diques y presas, pruebas de bombeo, pruebas de hidratación o deshidratación de suelo, detección de filtraciones.

- *Medidores de Temperatura*

Utilizados para realizar compensaciones de medición y cálculo por dilatación o contracción de materiales durante el monitoreo de estructuras. Encontrados normalmente acoplados a otros tipos de sensores.

- *Detectores de Fugas*

Se utilizan para monitoreo de obras de ingeniería, tales como estructuras hidráulicas, fundaciones, muros de contención, diques, excavaciones, túneles, sitios de almacenamiento de residuos entre otros.

- *Sensores de congelamiento*

Utilizados para medir congelamiento y descongelamiento en suelos.

Ya sea por una señal de salida del sensor discreta o por la limitación en la capacidad de almacenamiento de datos, no es posible obtener una secuencia de datos continua, por lo que debe elegirse el periodo de muestreo que será empleado y la duración del mismo; pudiendo intercalar etapas con un periodo de muestreo corto con etapas con un periodo de muestreo mayor, lo anterior basado normalmente en las condiciones de operación.

Administración de datos

Es necesario conservar los datos recopilados a fin de obtener un comportamiento histórico de la estructura, el cual es empleado para analizar los cambios paramétricos durante la operación. Para la generación de esta base de datos se puede emplear software de diseño propio o adquirir alguno comercial como *20.1010 SDB Software*(R) by Roctest Group el cual está diseñado para adquirir, administrar y desplegar los datos resultantes del monitoreo, así como para ser capaz de emitir alarmas predeterminadas.

La administración de datos debe poderse dar de manera remota o tener acceso directo en sitio.

Selección de la metodología a emplear

Análisis de datos

Las características de los datos obtenidos plantearán el desarrollo o la elección de la metodología que maximice la cantidad de información; además debe definirse que niveles de detección son requeridos (ver 2.1.2)

Implementación y validación.

Terminada la etapa de diseño se procede al montaje del equipo y a su puesta en funcionamiento. En este punto es importante considerar el costo y la capacitación del personal que estará a cargo de la gestión.

- Colocación de sensores

Abarca uno de los principales puntos de investigación, debido a que una colocación óptima de sensores disminuye los errores dentro del monitoreo y reduce el número de sensores al mínimo.

- Plan de reacción

El sistema para SHM proveerá la suficiente información que permita la emisión de alarmas, la programación de mantenimiento preventivo y correctivo, evaluación para reemplazo de componentes, o tiempo de vida de servicio restante antes de la inhabilitación de la estructura.

Indice de Falla o de Daño

Una estructura puede fallar de dos modos generales. El primero es por fractura, donde el componente se rompe en dos o más piezas. El segundo es por deformación permanente, en el cual la estructura cambia su forma de manera que se ve imposibilitada para seguir soportando la carga. En este último modo de falla el componente no se fragmenta por la acción de la corrosión, el desgaste, doblamiento o estiramiento provocados por una carga que excede las especificaciones de diseño.

El daño puede medirse mediante el cambio en propiedades físicas o mediante *índices de daño* que varían según la metodología empleada. Cualquier daño debe ser localizado y reparado oportunamente para el correcto funcionamiento del sistema.

2.2. Ventajas

El SHM presenta características que se convierten en beneficios para la comunidad de Ingeniería Civil tales como:

1. Mejora de la comprensión del comportamiento de la estructura en sitio.
2. Tiene como objetivo la detección temprana del daño.
3. Garantiza la continuidad del servicio bajo operación segura.
4. Busca la reducción del tiempo de inactividad por mantenimiento.
5. Plantea un mejoramiento de las estrategias de mantenimiento y de administración de recursos.

2.3. Clasificación

2.3.1. Por complejidad

Una clasificación para detección de daño fue presentada en Rytter (1993) [1], y define cuatro niveles en base al incremento de la complejidad del sistema de SHM:

Nivel 1. Detección del daño: abarca la inspección del daño presente en la estructura si lo hay.

Nivel 2. Localización del daño: determinación de la localización geométrico-espacial del daño.

Nivel 3. Evaluación de la severidad del daño.

Nivel 4. Predicción de la vida restante de la estructura.

2.3.2. Por temporalidad

La detección puede darse en diferentes espacios temporales:

1. Histórica. La falla tiene ocurrencia en el pasado. Utilizado en el análisis bajo perfiles de investigación para delegación de responsabilidades, mejoras de diseño o investigación básica de estructuras y materiales.

2. Actual. Evaluación de la condición de daño presente en una estructura en operación. Empleada principalmente para la generación de bases de datos de operación, programas de mantenimiento y confirmación de factores de diseño.

3. Predictiva. Necesario para el cálculo de la vida útil restante, se emplea conjuntamente con la detección de daño en el Presente.

2.3.3. Por el tratamiento de los datos.

Asociada con el tipo de dato de entrada requerido para el análisis de la estructura, de manera que el SHM se clasifica en [15]:

1. Basado en vibración.
 - a) En el dominio del tiempo
 - b) En el dominio de la frecuencia
- Basado en modelo
- Iterativo
- No iterativo
- No-basado en modelo
2. Basado en datos estáticos.
 - a) Iterativos
 - b) No iterativos
3. Inspección directa.

Basada en el uso de sensores de fatiga, reconocimiento de fracturas por imagenología, detección de fractura con sensores embebidos y procedimientos de detección de corrosión.

La inspección directa representa un mayor costo que los métodos basados en modelo, debido a la alta cantidad de sensores requeridos y a los sistemas de adquisición y almacenamiento.

2.4. Investigación Actual

Las aplicaciones de un sistema SHM para edificios son menos estudiadas e implementadas en comparación con los casos de estudio e implementaciones exitosas en puentes [11]. Considerando investigaciones realizadas previamente, existen una gran cantidad de edificios equipados con sistemas SHM, por ejemplo, California, E.U.A, cuenta con más de 160 edificios, Japón con mas de 100 y Taiwan con más de 40, con el principal objetivo de realizar un exámen de la condición del edificio después de sufrir un terremoto.

La investigación realizada, se encuentra a cargo tanto de universidades e instituciones, como de empresas cuyos productos son puestos en venta, para garantizar la disminución en costos de mantenimientos a las constructoras.

Capítulo 3

Metodologías empleadas en el SHM

Las técnicas empleadas para el análisis de las mediciones obtenidas durante el monitoreo, tienen dos etapas principales: la parametrización de la estructura y la identificación del daño. La diversidad de metodologías empleadas enfatiza la necesidad de una clasificación general en base a la elección de los siguientes puntos: a) preparación de la prueba (si es requerida por el método), b) mediciones y/o simulaciones, y c) identificación de la estructura. La clasificación abordada en el presente texto abarca los puntos 2.6.1 al 2.6.8.

3.1. Identificación de parámetros modales, basada en vibración (Análisis Modal)

El análisis modal se centra en la identificación teórica o experimental de los parámetros modales, los cuales son: las frecuencias naturales de la estructura, las formas de modo (patrones característicos de desplazamiento correspondientes a una frecuencia natural) y los factores de amortiguamiento. Este análisis está basado en que la respuesta de un sistema dinámico a una entrada de excitación vibratoria, puede ser expresada como combinación de sus “*modos naturales de vibración*”, los cuales no son otra cosa más que movimientos armónicos simples. Los *modos* están determinados completamente por las propiedades del sistema tales como la masa, la rigidez y el amortiguamiento, además de estar descritos en términos de sus parámetros modales. Si se incluye en el análisis teórico la distribución espacial de estas propiedades, las ecuaciones del sistema pasan de ser escalares a matriciales. La identificación modal es realizada a través del análisis modal y es una parte importante del análisis por elemento finito dinámico.

El análisis modal es empleado con diversos fines, [15] como son:

- Solución de problemas. Empleado en el análisis de estructuras como herramienta para encontrar la causa de problemas dinámicos. Se basa en el análisis experimental.
- Correlación de modelo de elemento finito y resultados experimentales. Empleado para la verificación de la fiabilidad del modelo matemático y su corrección en caso de ser necesario.

- Modificación estructural. Evalúa los efectos de algún cambio supuesto sobre la estructura bajo análisis. Puede emplearse para la optimización del diseño.
- Análisis de sensibilidad. Evalúa la sensibilidad de los parámetros modales al cambio de los parámetros físicos de la estructura.
- Reducción de modelos matemáticos. Un modelo modal de la estructura puede ser más simple que un modelo de elemento finito.
- Predicción de la respuesta forzada del sistema. Una vez establecido el modelo modal, es posible su empleo en la predicción de la respuesta de la estructura a excitaciones definidas.
- Identificación de excitación. Aplicable cuando la excitación a la estructura es desconocida y sobre todo no es medible.
- Predicción de respuesta. Se enfoca en obtener la respuesta del sistema a una variedad amplia de estímulos lo que puede ayudar a prevenir el fallo por fatiga de la estructura.
- Unión de subestructuras. Simplifica el análisis de estructuras complejas al reducir el análisis a un conjunto de subestructuras acopladas.
- Detección de daño estructural. Empleado en la detección temprana de daño estructural, principalmente cuando aún no es visible o en elementos ocultos. Se asume que los parámetros modales de la estructura cambian cuando existe un daño, por lo tanto es necesario contar con un modelo base de la estructura “sana”.
- Control activo de vibración. El análisis modal experimental es capaz de proveer un modelo matemático preciso, con el cual puede contruirse un lazo de control que permita ejercer control sobre ciertos modos de vibración de la estructura con el fin de evitar daños.

El análisis modal puede partir del modelo dinámico de la estructura o de la medición de datos, lo que divide a la investigación en dos ramas: análisis modal teórico y análisis modal experimental.

3.1.1. Análisis modal teórico

El análisis modal teórico es aplicable cuando la estructura es sometida a una excitación conocida. Consiste en plantear la ecuación del movimiento (3.1) de la estructura, realizar la suposición de la forma de la respuesta e imponer que esta cumpla la ecuación de movimiento, lo que supone resolver un problema de valores y vectores propios. Para obtener la ecuación de movimiento es necesario calcular (conocer previamente) las matrices de masa y rigidez y los factores de amortiguamiento.

$$M\ddot{x} + C\dot{x} + Kx = F \quad (3.1)$$

Donde

M = matriz de masas, simétrica usualmente definida positiva.

C = matriz de amortiguamiento.

K = matriz de rigidez, simétrica en ocasiones semidefinida positiva.

F = vector de fuerzas.

\ddot{x} = segunda derivada del desplazamiento en el tiempo.

\dot{x} = velocidad o primera derivada del desplazamiento.

x = desplazamiento

Si se transforma la ecuación de movimiento (3.1) a un problema de valores propios dado por la ecuación (3.2) pueden determinarse los parámetros modales.

$$(K - \omega^2 M) \Psi = 0 \quad (3.2)$$

Donde " Ψ " es un vector propio, ω^2 es un valor propio y "0" es un vector de ceros. De modo que, la raíz cuadrada de cada valor propio, corresponde a una frecuencia natural del sistema y los vectores propios son las formas de modo. De aquí se concluye fácilmente que si las frecuencias naturales son todas distintas de cero y diferentes entre sí, las formas de modo serán independientes. Se definen además las matrices de frecuencia natural y la matriz de la forma modal.

$$\text{Matriz de frecuencia natural } [\omega_r^2] = \begin{bmatrix} \omega_1^2 & 0 & \cdots & 0 \\ 0 & \omega_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \omega_n^2 \end{bmatrix}$$

$$\text{Matriz de forma modal } [\Psi] = [\Psi_1 | \Psi_2 | \cdots | \Psi_n]$$

Con las definiciones anteriores se obtiene la *masa modal* m_r y *rigidez modal* k_r del r -ésimo modo, de acuerdo con las ecuaciones (3.3) y (3.4) que definen matrices de masa $[m_i]$ y rigidez $[k_i]$ de manera similar a las matrices de frecuencia y forma modal.

$$\Psi_r^T M \Psi_r = m_r \quad (3.3)$$

$$\Psi_r^T K \Psi_r = k_r \quad (3.4)$$

Por último, se puede realizar la normalización de las matrices de la siguiente manera:

Para un sistema no amortiguado.

$$[\Phi] = [\Psi] [m_i]^{-1/2}$$

y se puede escribir:

$$[\Psi]^T (K - \omega^2 M) [\Phi] = [\Phi]^T [\alpha(\omega)]^{-1} [\Phi]$$

Con lo que la FRF se puede definir por la ecuación (3.5).

$$[\alpha(\omega)] = [\Phi] [(\omega_r^2 - \omega^2)]^{-1} [\Phi]^T \quad (3.5)$$

expresando cada término de forma individual se tiene la ecuación (3.6) que es la esencia del análisis modal.

$$\alpha_{jk}(\omega) = \left\{ \underbrace{\phi_{j1}\phi_{k1}}_{1A_{jk}} \quad \phi_{j2}\phi_{k2} \quad \dots \quad \phi_{jn}\phi_{kn} \right\} \left\{ \begin{array}{c} \frac{1}{\omega_1^2 - \omega^2} \\ \frac{1}{\omega_2^2 - \omega^2} \\ \vdots \\ \frac{1}{\omega_n^2 - \omega^2} \end{array} \right\} \quad (3.6)$$

Para un sistema amortiguado.

$$[\Phi] = [m_r]^{-1/2} [\Psi]$$

con lo que:

$$[\Phi]^T (K + jH - \lambda^2 M) [\Phi] = [(\lambda_r^2 - \omega^2)]$$

Donde λ_r son las frecuencias naturales del sistema, H es la matriz de amortiguamiento.

Por último, se encuentra la FRF, dada por la ecuación (3.7).

$$[\alpha(\omega)] = [\Phi] [(\lambda_r^2 - \omega^2)]^{-1} [\Phi]^T \quad (3.7)$$

$$\alpha_{jk}(\omega) = \left\{ \underbrace{\phi_{j1}\phi_{k1}}_{1A_{jk}} \quad \phi_{j2}\phi_{k2} \quad \dots \quad \phi_{jn}\phi_{kn} \right\} \left\{ \begin{array}{c} \frac{1}{\lambda_1^2 - \omega^2} \\ \frac{1}{\lambda_2^2 - \omega^2} \\ \vdots \\ \frac{1}{\lambda_n^2 - \omega^2} \end{array} \right\} \quad (3.8)$$

El tema puede abordarse mas a fondo en [23].

3.1.2. Análisis modal experimental

Este análisis se enfoca en establecer la relación existente entre la respuesta vibratoria del sistema y la excitación que la provoca, tomando en cuenta la localización de ambas y expresando la relación en términos de la frecuencia de excitación. Esta relación es conocida como Función de Respuesta en Frecuencia (FRF) y puede ser representada de forma matricial, de manera que la combinación de las respuestas, excitaciones junto con su localización dan lugar a un grupo de FRF. En el análisis modal experimental las FRF pueden obtenerse tomando la medición de la excitación en un punto de la estructura y la medición de la respuesta vibratoria en otro punto de la misma estructura. Las entradas de excitación pueden ser seleccionadas como: senoide, una función trasendente, aleatoria o de ruido blanco. Las respuestas pueden ser medidas con una amplia variedad de sensores, siendo los mas destacados los acelerómetros y los sensores piezoelectricos.

Con una cantidad suficiente de mediciones el análisis numérico resultará en la obtención de los parámetros modales utilizando técnicas de ajuste de curvas, siendo el método de mínimos cuadrados el mas popular, mas no el de mayor presición.

El análisis modal experimental esta compuesto de las siguientes etapas:

- Preparación de la prueba. Incluye la selección de la estructura de prueba, tipo de excitación y su localización, intrumentación para el sensado y excitación, determinacion de

los puntos de medición, realización del modelo estructural a nivel matemático, identificación de perturbaciones y motivos de imprecisión.

- Etapa de medición. Se realiza la medición de las respuestas del sistema. Estos datos deben ser almacenados de manera adecuada para su posterior análisis.
- Identificación modal paramétrica. Se procede a realizar el análisis con los datos almacenados.

Debido a que los datos medidos pueden estar en forma de funciones de respuesta en frecuencia o respuesta al impulso, el análisis puede efectuarse en dos modalidades: análisis modal en el dominio de la frecuencia y análisis modal en el dominio del tiempo.

Técnicas de estimación de respuesta libre en el dominio de la frecuencia.

Estos métodos buscan la curva adecuada que describa los datos de la función de respuesta en frecuencia medidos (datos FRF). Para la obtención de estos datos es necesario un preprocesamiento de los mismos, es decir, una serie de datos obtenidos en el dominio del tiempo son transformados a datos en el dominio de la frecuencia siendo dos métodos los más utilizados:

- Métodos de barrido. Se realizan mediciones de la salida del sistema y de la entrada excitadora, siendo esta última medible o conocida, posteriormente se obtiene el cociente entre ambas y el resultado en decibeles es la respuesta en frecuencia

- Prueba de impulso. Se calcula como el cociente de la transformada de Fourier de la función de excitación y la transformada de Fourier de la función de salida.

Las técnicas de análisis en el dominio de la frecuencia se basan en la suposición del conocimiento de los grados de libertad, el tipo de amortiguamiento y el número de formas de modo de la estructura, dentro del rango de frecuencia de los datos medidos; de manera que puede encontrarse la expresión matemática para cada FRF, lo que permite derivar los parámetros modales. Una FRF del sistema contiene información modal que incluye no solo el rango de frecuencias de los datos medidos, si no además, las frecuencias que están fuera de este rango, esto es porque la estructura contiene un número de grados de libertad infinitos [23]. Por ejemplo, suponiendo que se cuenta con una FRF de un sistema dado y asumiendo que:

- 1) Puede tomarse una discretización del sistema en uno de “N” grados de libertad,
- 2) Dentro de esta discretización, los primeros “m” modos son los que están dentro del rango de frecuencias regido por los datos obtenidos
- 3) Debido al punto anterior se considera un término residual de información contenida en las altas frecuencias $R(\omega)$.

Se obtiene la expresión analítica de la FRF dada por la ecuación (3.9).

$$\alpha(\omega) = \sum_{r=1}^m FRF_0^r + R(\omega) \quad (3.9)$$

Donde FRF_0 es la función de respuesta en frecuencia original del sistema y esta determinada por las características propias de la estructura. Si se trabaja con un sistema de

un simple grado de libertad y se define el desplazamiento como respuesta del sistema, $\alpha(\omega)$ se define como:

$$\alpha(\omega) = \frac{X(\omega)}{F(\omega)} \quad (3.10)$$

Donde $F(\omega)$ es la fuerza aplicada al sistema y $X(\omega)$ es la respuesta del sistema. Sin embargo, la respuesta vibratoria también puede ser la velocidad o la aceleración con lo que la ecuación (3.10) se modifica para convertirse en (3.11) para la velocidad y en (3.12) para la aceleración.

$$Y(\omega) = \frac{\dot{X}(\omega)}{F(\omega)} \quad (3.11)$$

$$A(\omega) = \frac{\ddot{X}(\omega)}{F(\omega)} \quad (3.12)$$

Los recíprocos de estas FRF tienen los siguientes significados físicos.

$$\text{Rigidez dinámica} \frac{1}{\alpha(\omega)} = \frac{\text{fuerza}}{\text{desplazamiento}}$$

$$\text{Impedancia mecánica} \frac{1}{Y(\omega)} = \frac{\text{fuerza}}{\text{velocidad}}$$

$$\text{Masa aparente} \frac{1}{A(\omega)} = \frac{\text{fuerza}}{\text{aceleración}}$$

Si ahora se define el error como la diferencia entre la FRF estimada desde los modos de vibración identificados $\alpha_{ij}(\omega)$ y los datos FRF medidos $\tilde{\alpha}_{ij}(\omega)$, se puede definir la ecuación (3.13) como función a minimizar por los métodos de análisis modal.

$$e_{ij} = \tilde{\alpha}_{ij}(\omega) - \alpha_{ij}(\omega) \quad (3.13)$$

Dentro de los métodos encontrados en la literatura en análisis modal en el dominio de la frecuencia se encuentran los siguientes:

- Métodos para sistemas de un solo grado de libertad.
- Método de recolección de picos. Estima la frecuencia natural en base al valor pico de la FRF y el amortiguamiento empleando los puntos de media potencia. Es un método rápido sin embargo no es robusto al ruido y es de baja precisión.
- Método de ajuste circular. Es un método basado en la circularidad de la gráfica de Nyquist de una FRF para un solo grado de libertad, provee una mayor precisión que el método de recolección de picos.
- Método de FRF inversa. Este método emplea la propiedad lineal de la inversión de los datos FRF y usando la separabilidad de la parte real y la imaginaria de esta inversa.

- Método de mínimos cuadrados. Este método busca la estimación de los datos modales de manera que se minimice la función del error. Se basa principalmente en convertir un modelo matemático no lineal en un lineal ponderado, y la diferencia entre ambos está dada por la función de error.
- Método de Dobson. Es una mejora del método de FRF inversa.
- Métodos para grados de libertad múltiples
- Polinomios de fracciones racionales. El objetivo de esta metodología es la expresión de la FRF en términos de polinomios fraccionales racionales, donde el análisis consiste en la identificación de los coeficientes de estos polinomios y calcular los parámetros modales en base a su relación con los coeficientes calculados.
- Estructuras ligeramente amortiguadas. Este método se trabaja con el análisis lejos de las frecuencias de resonancia lo que permite su aplicación en estructura con factores de amortiguamiento muy bajos.

Existen plataformas excitadoras ampliamente usadas, por ejemplo: a) el percusor, que es un dispositivo que produce un pulso de fuerza excitadora; b) el vibrador electromagnético, que produce una fuerza de vibración con determinada frecuencia, amplitud y rango dinámico; c) el excitador electrohidráulico, empleado en pruebas con señales de excitación de baja frecuencia y gran amplitud.

Técnicas de identificación modal en el dominio del tiempo.

Estas técnicas se basan en la respuesta del sistema en el tiempo, es decir, emplean directamente los datos recolectados tales como aceleraciones y fuerzas. El objetivo es la deducción de la función de la respuesta al impulso a partir de las mediciones en el tiempo para la extracción de los parámetros modales. Las excitaciones posibles son de dos tipos:

- Una excitación conocida, similar al análisis en el dominio de la frecuencia y con mucha mayor precisión

- Excitación ambiente, de naturaleza no medible, variable en características y proveniente de la superposición de diversas fuentes.

Por claras razones, este enfoque tiene mayor posibilidad de implementación en ambientes reales fuera de las condiciones controladas de laboratorio que se requieren para el análisis en el dominio de la frecuencia. A diferencia de las FRF, en la respuesta en el tiempo los modos de vibración no se presentan lo que conyeva un análisis matemático de mayor complejidad.

- Métodos para grados de libertad múltiples
- Método de mínimos cuadrados en el dominio del tiempo. Es un método iterativo que emplea los datos medidos de la respuesta a la vibración. Combina la búsqueda del ajuste de curvas con la comparación de estas mismas contra un modelo matemático definido de manera iterativa, lo que permite el cálculo de los parámetros modales.

- Método de Ibrahim en el dominio del tiempo. Convierte los datos de la función de respuesta al impulso (IRF, por sus siglas en inglés) en un problema de valores propios, derivando directamente las frecuencias naturales, los factores de pérdida de amortiguamiento y constantes modales a partir de los desplazamientos, velocidades y aceleraciones. El metodo mejora si se toman datos de la respuesta libre.
- Método del decremento aleatorio. Este método depende de los datos extraídos de la respuesta de libre decaimiento para la obtención de los parámetros modales
- Método ARMA de series en el tiempo. Es un metodo de identificación de sistemas a partir de las mediciones de la ponderación de sus respuestas y sus entradas pasadas
- Método exponencial de minimos cuadrados complejo. Trabaja en el establecimiento de la relación entre la IRF del sistema y sus polos complejos por medio de na exponencial compleja. El polinomio obtenido de la solución del modelo AR permite la obtención de las raíces complejas del sistema (frecuencias y amortiguamientos) y de los residuos (formas modales).

3.1.3. Índices de daño y Monitoreo a largo plazo

Dentro de los análisis mas simples se encuentran los que buscan el establecimiento de un índice de daño actual en base a mediciones directas sobre la estructura. Estas mediciones se realizan durante la operación mediante la colocación de sensores en puntos estratégicos.

En Jeremiah Fasl et al. (2013) [17] los autores enfocan su esfuerzo en la determinación de la vida restante de la estructura en análisis, en este caso, un puente vehicular de acero de 82 m de largo aproximadamente, mediante la medición de datos de tensión tomados directamente de las cargas de operación. La importancia de este trabajo radica en la comparación del enfoque probabilístico contra las especificaciones de diseño del *Manual para la evaluación de puentes dentro de la Asociación americana de carreteras del estado y oficiales del transporte* (AASHTO - por sus siglas en inglés), que es un enfoque determinístico que permite el cálculo del número de ciclos antes de falla (N_f) para un rango de esfuerzo dado (s_r) por medio de la ecuación (3.14), donde A es una constante de fatiga.

$$N_f = \frac{A}{S_r^3} \quad (3.14)$$

Además, permite la definición de la función de estado de limite de fatiga dada por la ecuación (3.15) donde Δ es el índice de acumulación de daño crítico y $d_L(t)$ es el daño inducido por fatiga en el año t . Los parámetros de distribución de Δ y A pueden ser determinados en pruebas de laboratorio.

$$g(N) = \Delta \times A - d_L(t) < 0 \quad (3.15)$$

Tomando como base la ecuación (3.15) los autores definen la probabilidad de falla p_r empleando

una función de distribución normal acumulativa $\Phi()$, donde el índice de fiabilidad β es dependiente de las distribuciones log-normales (λ 's y ζ 's) de Δ , A y $d_L(t)$.

$$p_f = \Phi(-\beta) \tag{3.16}$$

$$\beta = \frac{\lambda_\Delta + \lambda_A - \lambda_{d_L(t)}}{\sqrt{\zeta_\Delta^2 + \zeta_A^2 + \zeta_{d_L(t)}^2}}$$

Por último se define la acumulación de daño por medio de la ecuación (3.17). donde r es la constante de la tasa de crecimiento anual del tráfico, $\mu_{d_L(t)}$ es el daño medio por fatiga en el año t , $\mu_{d_m(k)}$ es el daño inducido durante el año actual (k) extrapolado desde las mediciones de esfuerzo.

$$\mu_{d_L(t)} = \underbrace{\frac{\mu_{d_m(k)}}{(1+r)^{k-1}}}_{\mu_{d_L(1)}} \frac{(1+r)^t - 1}{r} \tag{3.17}$$

Finalmente el daño inducido por fatiga durante un periodo en el año k es calculado directamente desde la ecuación (3.18), donde n_j es el número de ciclos en un intervalo de tiempo previamente determinado, \bar{S}_{rj} es rango promedio de esfuerzo en ese mismo intervalo y N es el numero de intervalos de tiempo a considerar.

$$d_m(k) = \sum_{j=1}^N (n_j \times \bar{S}_{rj}^3) \tag{3.18}$$

La principal diferencia entre estas evaluaciones consiste en las características de las cargas consideradas, los autores consideran los valores de carga variables de acuerdo al día y a la hora de operación, mientras que la AASHTO plantea un tiempo de vida para una carga máxima. El método es aplicable a puentes y estructuras cercanas a terminar su tiempo de vida pues el resultado es interesante desde que arroja un menor tiempo de vida restante que la AASHTO por lo que requiere un estudio en mayor cantidad de estructuras. Sin embargo, esta diferencia puede deberse a que el método requiere una estimación del daño anterior obtenida por extrapolación de datos, además de necesitar una estimación del crecimiento anual del tráfico. Lo anterior puede traducirse en la ventaja de tener la capacidad de proveer información del estado del puente en cualquier tiempo, ya sea pasado o futuro y en la desventaja de que este cálculo introduce errores de aproximación que no pueden ser cuantificados. Sin embargo, debido a que las cargas y estímulos son obtenidos directamente de la estructura en operación, las incertidumbres por cambio de propiedades, ruido ambiental, temperatura entre otras, están completamente consideradas dentro de las mediciones.

Anun Patjawit et. al. [38] los autores desarrollan un índice de salud (DHI) para el monitoreo de una presa de tierra, con el objetivo de que sea simple y de fácil implementación. Esta basado en la determinación de las frecuencias y formas modales a través del método de Mínimos cuadrados complejo-exponencial clasificado como un Método de Análisis modal en el dominio del tiempo, que establece la relación entre la función de respuesta al impulso y sus polos complejos y residuales en [21] puede encontrarse una explicación más amplia.

Una vez obtenidas las frecuencias el índice se calcula con la relación entre el número de estímulos vs. primera frecuencia natural modal al cuadrado, por lo que un cambio en la frecuencia es el indicador directo de daño. El índice se prueba sobre una maqueta de laboratorio con el empleo de acelerómetros como sensores y un péndulo percursor como actuador. Posee la ventaja de emplear la vibración ambiente como medio de estímulo, aún sin conocer su magnitud, simplemente suponiendo que la fuerza aplicada siempre es de la misma naturaleza. Además considera dentro del análisis el nivel del agua de la presa y la licuefacción gradual del piso.

El índice DHI, ecuación (3.20) se deriva a partir de la matriz de flexibilidad de la estructura, la cual refleja los cambios en la misma, ver ecuación (3.19), donde F es la matriz de flexibilidad modal, $[\varphi]$ con los vectores modales de masa normalizados y $[\omega^2]$ es una matriz diagonal que contiene las frecuencias modales en orden ascendente.

$$F = [\varphi] [\omega^2] [\varphi]^T \quad (3.19)$$

$$DHI = F^{-1} = \omega_1^2 \quad (3.20)$$

Sin embargo, es necesario desarrollar un modelo virtual para simulación que permita la colocación de los sensores en “el mejor lugar”, esto no está sustentado en un análisis matemático de optimización por lo que podría mejorarse con la aplicación de alguna de las metodologías correspondientes (ver sección 2.6.3)

Dentro de los trabajos desarrollados para la generación de bases de datos desde el punto cero de construcción se encuentra la investigación actual monitoreada por Michael Roussel Branko Glisic y Joo Ming Lau Chor Cheong Fong [43] sobre el Pinnacle Duxton localizado en Singapur, una construcción conformada por siete edificios de 50 pisos conectados por puentes puesta bajo observación desde las primeras etapas de construcción. Los sensores empleados son de fibra óptica de largo calibre tipo SOFO con longitud de 2m que trabajan junto con sensores de temperatura para realizar la compensación de las desviaciones provocadas por la dilatación.

El monitoreo está basado en extraer los componentes individuales del esfuerzo (sobre los puentes y los pisos inferiores) para posteriormente construir la matriz de correlación entre elementos similares con el fin de que la detección de una no-linealidad se traduce directamente en la localización del daño. Las principales ventajas del establecimiento del sistema SHMes que provee una herramienta altamente eficaz para establecer estrategias de mantenimiento, maximizar seguridad y minimizar costos pues provee información temprana. Claramente permite la evaluación directa de las especificaciones de diseño. Sin embargo, esta base de datos no puede ser generada para edificios ya construidos y en uso, donde es necesario la implementación de otras técnicas.

El esfuerzo medido por los sensores ε_m es calculado por medio de la ecuación (3.21), donde ΔL es el cambio en la longitud del sensor, L_s es la longitud calibrada del sensor, α es el coeficiente de expansión térmica e involucra los esfuerzos elásticos debido a carga (ε_E), temperatura (ε_T), arrastre (ε_C), contracción (ε_S).

$$\varepsilon_m = \frac{\Delta L}{L_s} = \varepsilon_E + \varepsilon_T + \varepsilon_C + \varepsilon_S + \varepsilon_{otros} \quad (3.21)$$

$$\varepsilon_T = \alpha \Delta T$$

Los autores desprecian los esfuerzos provocados por el arrastre y consideran que no existe contracción. En esta aplicación, la matriz de correlación esta compuesta por valores cercanos al uno fuera de la diagonal, debido a la relación de similitud existente entre componentes, de manera que aquellos cuya correlación se encuentren más alejada de 1 serán los que se encuentren soportando esfuerzos no previstos o que hayan sufrido algún tipo de daño.

3.1.4. Metodos para colocación óptima de sensores para SHM

Tomando como base este análisis en Seyed Kazem Sadat S. et. al. (2013), [44] se propone un método para la colocación óptima de sensores en estructuras de acero ligero, con el objetivo extra de que esta localización coincida con los puntos débiles de la estructura. Aquí se emplea el analisis de elemento finito como eje principal para la “medición” de los desplazamientos en x-y-z, bajo estímulos de terremotos reales ocurridos en el pasado y completamente registrados. La colocación de sensores por medio del metodo MinMAC (que utiliza el analisis modal y puede encontrarse mayor información en el artículo original) es comparada con la metodología propuesta por los autores definida como TTFD (algoritmo de transformacion del historial en el tiempo al dominio de la frecuencia) trabajando conjuntamente con algoritmos genéticos resultando en una mejoría en la determinación óptima del número y localización de sensores, sin embargo requiere de conocer: a) los parametros de los materiales con una alta precisión, b) el tipo de suelo y c) la cercanía a la falla telúrica. Si esta información se encuentra al alcance, entonces vence los principales inconvenientes del metodo MinMAC, el cual, al depender de que el primer grupo de sensores sea propuesto de manera intuitiva presenta diversas convergencias que permanecen cerca del óptimo e incluso puede existir superposición en la posición de los sensores; el algoritmo TTFD presenta un solo valor de convergencia con un número bastante bajo de sensores sin el problema de la superposición.

El procedimiento está compuesto por:

- Transformación al dominio de la frecuencia. Empleando la transformada rápida de Fourier se tranforma el historial de los desplazamientos medidos al dominio de la frecuencia.

- Análisis modal. Con el objetivo de encontrar las frecuencias naturales, encontrar las respuestas modales sobre el modelo de la estructura en elemento finito.

- Analisis estatico paso a paso no-lineal. Para relacionar los desplazamientos entre la base y el piso superior, obteniendo la distribución de carga a travez de los pisos.

- Análisis no lineal en el historial de tiempo. Realizado para la evaluación de la respuesta dinámica tales como corte y momento en la base, desplazamientos en las direcciones $x - y$.

- Algoritmo genético. Que permita la maximización del tiempo de detección y minimice la cantidad de sensores.

Otros autores como Peter Anderegg et. al. (2013) [3] realizan el análisis de las incertidumbres de los sensores empleados en el monitoreo así como la fiabilidad de los datos obtenidos, debido a que la vida útil de las estructuras supera la de los sensores en una relación de 10 a 1 en la mayoría de los casos.

Dentro de la temática del análisis en el empleo de los sensores en Naveet Kaur et. al. (2013) [27] se estudia la posibilidad de generación de energía por medio de los mismos sensores piezoeléctricos con los que se realiza el SHM. Aunque la generación se encuentra dentro del orden de los μW ($1.85V-1.417\mu W$), puede estudiarse la autosustentabilidad para elementos de muy bajo consumo.

3.1.5. Métodos basados en Actualización del modelo

El objetivo de las metodologías de actualización del modelo es realizar el ajuste del modelo de la estructura de manera que el comportamiento de este último concuerde con los resultados de las pruebas realizadas a la estructura real, con esto se obtiene una representación fiable que contemple desviaciones tales como cargas no contempladas, imperfecciones de materiales y de construcción o incluso la obtención del modelo representativo, cuando no se tienen los parámetros reales de masa amortiguamiento, valores de rigidez, entre otros.

Las metodologías basadas en actualización del modelo, parten de la obtención previa al análisis del modelo en elemento finito (FE, por sus siglas en inglés). Una vez que se cuenta con este modelo, se procede a su actualización mediante el cambio de parámetros seleccionados; este cambio está basado en las mediciones de la respuesta de la estructura real y termina hasta que la diferencia de comportamiento entre el modelo y la estructura cae dentro de un rango aceptable. Si se considera el modelo bajo la primera actualización como la *línea cero*, es decir, representa a la estructura sin daño, y posteriormente se compara con el modelo actualizado, que representa la estructura después de un tiempo de operación o “dañada” se puede obtener información relevante acerca del daño sufrido por la estructura y su localización.

Basicamente, el método consiste en abordar la tarea como un problema de optimización que busca la minimización del error entre el modelo y la estructura, y emplea como herramienta de cálculo el análisis modal.

Algunos de los parámetros a identificar pueden ser el módulo de elasticidad, fuerzas estructurales, rigidez geométrica entre otros. Un cambio detectado en estos parámetros puede indicar la degradación o debilidad de la estructura provocada por grietas, corrosión, fracturas, pérdida de componentes o desplazamiento entre los mismos.

Durante el análisis, las frecuencias modales son de utilidad para la detección del daño y las formas modales predicen la localización del mismo. Si se emplea un método analítico, será necesario el conocimiento de las matrices de masa y rigidez, mientras que en un método numérico no las requieren, solamente emplean los datos de múltiples análisis por FE siendo $n+1$ el número de análisis requerido (n -número de parámetros). El comportamiento de la estructura puede ser analizado empleando diferentes códigos FE, diferentes dimensiones del modelo y cambiando el tamaño y forma de la malla; además de encontrarse en la literatura

trabajando en conjunto con otras técnicas.

En Andrea Mordini et. al. [35] se desarrolla un algoritmo iterativo en Scilab para actualización del modelo que trabaja sobre las plataformas para FE OpenSees (mayor rapidez de cómputo) y ANSYS (mejor interfaz grafica). El trabajo de los autores consiste en la presentación de un metodo iterativo basado en sensibilidad que consiste en:

1) Análisis de sensibilidad. Realizado con el objetivo de seleccionar los parámetros más representativos del modelo FE, se obtiene mediante la ecuación (3.22) la matriz de sensibilidad en la j – esima iteración y s_i es la i – esima columna de la matriz S ; donde ∂p_j es la perturbación en los parámetros y ∂d_j es la diferencia entre los datos experimentales y los numéricos dependiente de la perturbación Δp_i en el i – esimo parámetro.

$$S_j = \frac{\partial d_j}{\partial p_j} \implies s_i = \frac{d(p_i + \Delta p_i) - d(p_i)}{\Delta p_i} \quad (3.22)$$

2) Escalamiento de la matriz de sensibilidad y forma modal. Desarrollado para evitar problemas numéricos, mejorar la estabilidad y velocidad de convergencia.

3) Actualización. Los autores definen la problema de optimización con la minimización del funcional $J(\Delta p)$ respecto a Δp sujeto a la restricción $\Delta d = S\Delta p$. Con lo que la actualización paramétrica se encuentra dada por la ecuación (3.23), donde W_d y W_p son matrices de pesos.

$$p_{j+1} = p_j + [S_j^T W_d S_j + W_p]^{-1} S_j^T W_d \Delta d_j \quad (3.23)$$

4) Convergencia. Se emplean dos criterios de convergencia dados por las ecuaciones (3.24) y (3.25), en la j – esima iteración, con $f_{exp,i}$ la i – esima frecuencia experimental, $f_{j,i}$ la i – esima frecuencia numérica, n el numero de parámetros, W_f los pesos de la frecuencia, W_Φ los pesos para la desviación MAC, MAC (Criterio de garantía modal, por sus siglas en inglés) evalúa la correlación entre formas modales y debe ser cercano a uno

Sin embargo, si no se alcanza, la actualización se detendrá en un numero máximo de iteraciones definido previamente y simplemente se tomarán los valores obtenidos para la menor CC calculada.

$$CC_{abs,j} = \frac{1}{n} \sum_{i=1}^n \frac{|f_{exp,i} - f_{j,i}|}{f_{exp,i}} \leq \varepsilon \quad (3.24)$$

$$CC_{tot,j} = \frac{1}{2n \cdot \max(W_f, W_\Phi)} \sum_{i=1}^n \left(W_f \frac{|f_{exp,i} - f_{j,i}|}{f_{exp,i}} + W_\Phi (1 - MAC_i) \right) \leq \varepsilon \quad (3.25)$$

Los autores aplican el algoritmo en dos elementos:

A) Una viga en forma “I”, bajo condiciones de carga incremental (45-145KN), con 74 sensores, llevando a cabo la actualización de 36 parámetros incluyendo el módulo de elasticidad, el cual es empleado como el principal indicador de daño. Los resultados de parametrización son aceptables y permiten la distinción entre la estructura sin daño y la dañada.

B) Cables del puente Lanaye, Bélgica, equipado con acelerómetros 3D y evaluado con el método de Recolección de picos para la búsqueda de las frecuencias modales. Los parámetros

usados para detección de daño son el momento de inercia del cable, la reducción de la fuerza axial y la rigidez a la tensión. Sin embargo se encontró que la rigidez a la tensión no es un parámetro sensible al daño en este tipo de componentes. Siendo la reducción de la fuerza axial un parámetro suficiente para la detección y ubicación del daño.

Es notable que con el uso de una mayor cantidad de frecuencias experimentales el número de iteraciones para alcanzar la convergencia se reduce drásticamente.

3.1.6. Filtros y observadores

Filtro de Kalman una técnica clasificada como de Asimilación de Datos, cuyo objetivo es la estimación de los estados desconocidos de un sistema dinámico ya sea pasados (suavizado), presentes (filtrado) o futuros (predicción), tal y como lo hace un observador tipo Luenberger, pero con la facultad de ser robusto al ruido blanco aditivo y poseer un mecanismo de ganancia adaptativa. Para ello, se emplea información observada combinada con la información estocástica del sistema, esto último debido a que la medición directa de las variables de estado debe involucrar cierto grado de incertidumbre. El filtro de Kalman es de aplicación a sistemas de naturaleza lineal, sin embargo el filtro de Kalman extendido se emplea como medio de “linealización a pedazos” por series de Taylor aplicable a sistemas no-lineales.

Basicamente el filtro de Kalman es un conjunto de ecuaciones matemáticas que representan una solución óptima recursiva mediante el empleo del método de mínimos cuadrados y permite obtener la estimación del estado del sistema en el instante $(k + 1)$ con el empleo de la información del estado en el instante k . Dada la naturaleza de un sistema SHM, se considera el sistema en tiempo discreto de la ecuación (3.26) como modelo, donde w_k es el ruido blanco relacionado a $x_k \in \mathbb{R}^n$ con varianza Q_k y v_k es ruido blanco relacionado al vector de mediciones $z_k \in \mathbb{R}^m$ con varianza R_k .

$$\begin{aligned} x_k &= A_{k-1}x_{k-1} + B_{k-1}u_{k-1} + w_{k-1} \\ z_k &= H_k x_k + v_k \end{aligned} \quad (3.26)$$

El proceso de estimación comienza con la formulación del modelo en espacio de estado con un conjunto inicial de parámetros dados y posteriormente se emplea el error de predicción generado por el filtro para evaluar recursivamente la verosimilitud hasta llevarla al máximo; se lleva a cabo en dos etapas:

1) Predicción. Estimación del nuevo vector de estado x_k en el instante k dependiente del instante $k - 1$, con lo que se obtiene el estimado $\hat{x}_{k|k-1}$ (a priori) dado por la ecuación (3.27) donde Φ_k es la matriz de transición de estados.

$$\hat{x}_{k|k-1} = \Phi_k x_{k-1|k-1} \quad (3.27)$$

El error de estimación (a posteriori) esta dado por:

$$e_{k-1} = x_{k-1} - \hat{x}_{k-1}$$

La covarianza del error (a priori) está dada por la ecuacion (3.28).

$$P_{k|k-1} = \Phi_k P_{k-1|l-1} \Phi_k^T + Q_k \quad (3.28)$$

2) Actualización. Incorporación de un nuevo vector de datos de medida z_k dentro del vector x_k , para lo cual se emplea el sistema de ecuaciones (3.29), donde y_k es la actualización de la medición, K_k es la ganancia de Kalman, $x_{k|k}$ es la estimación a posteriori, $P_{k|k}$ es la covarianza del error a posteriori, H_k matriz de relación entre mediciones y el estado . Puede encontrarse mas información en [41].

$$\begin{aligned} \tilde{y}_k &= z_k - H_k \hat{x}_{k|k-1} \\ K_k &= P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \\ \hat{x}_{k|k} &= \hat{x}_{k|k-1} + K_k \tilde{y}_k \\ P_{k|k} &= (I - K_k H_k) P_{k|k-1} \end{aligned} \quad (3.29)$$

Claramente, para el caso anterior es necesario conocer información a priori, sin embargo en [11] se puede estudiar acerca del procedimiento estocástico seguido a partir de la obtención de muestras.

El filtro de Kalman ha sido modificado para ser adaptado a distintas problemáticas dando como resultado otros algoritmos como el Filtro de Kalman extendido para sistemas no lineales.

Adam C. Cobb et. al. [9] aplican el filtro de Kalman sobre datos de medición ultrasónicos combinado con técnicas de estimación de crecimiento de fallas para la aproximación del tamaño de una fractura en tiempo real. El procedimiento es aplicado sobre barras de aluminio sujetas a fatiga por tensión con zonas de vulnerabilidad (barrenos y perforaciones). El procedimiento se compone de las siguientes etapas:

- 1) Detección de la falla. Llevada a cabo por medio de funciones de relación de energía.
- 2) Estimación del tamaño de la falla. Empleando el filtro de Kalman extendido.

El método plantea la subdivisión de la estructura en subestructuras para su identificación individual, esto presenta la ventaja de permitir la reutilización de parámetros calculados para una subestructura en otra siempre que sea similar, lo que reduce el costo de cómputo. En este trabajo no se analiza la efectividad del método empleando excitación natural por terremoto, pues la respuesta de la estructura es compleja. Otra desventaja del método es la necesidad de acotar los valores inicialización de los parámetros dentro de un rango cercano al real para que exista una convergencia rápida.

En Shutao Xing et. al. [55], los autores realizan el diseño de un filtro de Kalman extendido para identificación paramétrica (rigidez y amortiguamiento). El objetivo es la detección de

la existencia de falla mediante la advertencia de degradación en los parámetros modales. Se ejecutó sobre tres tipos de estructuras:

- Un edificio reforzado de 10 grados de libertad, al que se le aplicó un estímulo proveniente de la base emulando un terremoto real reconstruido a partir de los datos medidos durante el suceso. Los datos racabados durante esta prueba no presentan análisis ni resultados, por lo que se espera un trabajo futuro de los autores en este contexto.

- Un puente estructurado, al que se le aplicó una fuerza sinusoidal horizontal al plano del piso con una frecuencia en el rango de 1.75-55Hz.

- Un marco de estructura de 5 niveles, al que se le indujo vibración por medio de una fuerza sinusoidal en el centro superior vertical en un rango de frecuencias de 2-20Hz.

Las estructuras en estudio solo fueron analizadas bajo su modelo en elemento finito y las ecuaciones de movimiento por lo que presenta el inconveniente de hacer necesario el conocimiento previo de las masas, desplazamientos, velocidades y aceleraciones de la estructura en operación, así como de las fuerzas o estímulos externos que tienen efecto en la misma, datos que no se obtienen fácilmente en estructuras ya construidas que no hayan sido descritas mediante un modelo.

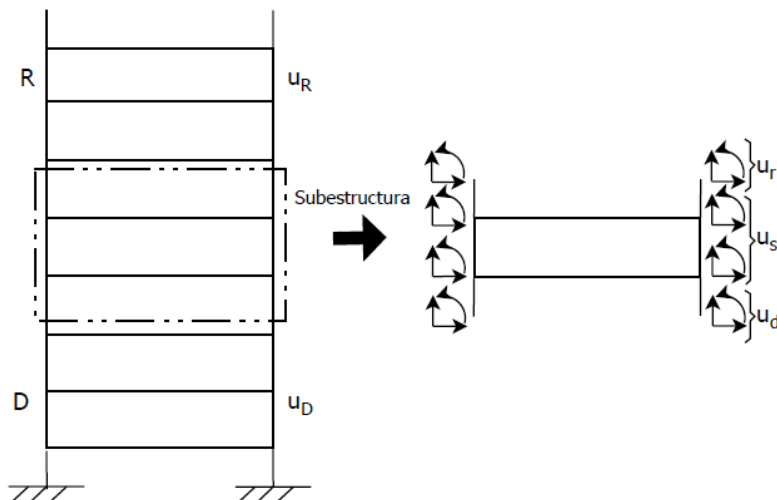


Figura 3.1: Modelo de subestructuras propuesto.

El análisis previo divide la estructura en subestructuras y las identifica de manera independiente, Figura 3.1, además se requiere conocer la respuesta en aceleración (por lo que los sensores empleados son acelerómetros) y los parámetros iniciales deben estar dentro de un rango razonablemente bueno para lograr una convergencia rápida. El método propuesto por los autores consta de las siguientes etapas:

- 1) Formulación de las subestructuras. La ecuación de movimiento matricial de la estructura (3.30) se reescribe en forma particionada conforme a la ecuación (3.31), donde r y d denotan los grados de libertad que funcionan como interfase entre la subestructura en análisis y sus vecinas, por lo tanto, se emplea la ecuación de la segunda fila como ecuación de estado y denotando con c los grados de libertad de las interfaces (r y d) se reescribe como

la ecuación (3.32)

$$M(t)U(t) + C(t)\dot{U}(t) + K(t)U(t) = F(t) \quad (3.30)$$

$$\begin{aligned} & \begin{bmatrix} M_{rr} & M_{rs} & 0 \\ M_{sr} & M_{ss} & M_{sd} \\ 0 & M_{ds} & M_{dd} \end{bmatrix} \begin{Bmatrix} \ddot{u}_r \\ \ddot{u}_s \\ \ddot{u}_d \end{Bmatrix} + \begin{bmatrix} C_{rr} & C_{rs} & 0 \\ C_{sr} & C_{ss} & C_{sd} \\ 0 & C_{ds} & C_{dd} \end{bmatrix} \begin{Bmatrix} \dot{u}_r \\ \dot{u}_s \\ \dot{u}_d \end{Bmatrix} + \\ & + \begin{bmatrix} K_{rr} & K_{rs} & 0 \\ K_{sr} & K_{ss} & K_{sd} \\ 0 & K_{ds} & K_{dd} \end{bmatrix} \begin{Bmatrix} u_r \\ u_s \\ u_d \end{Bmatrix} = \begin{Bmatrix} F_r \\ F_s \\ F_d \end{Bmatrix} \end{aligned} \quad (3.31)$$

$$M_{ss}\ddot{u}_s(t) + C_{ss}\dot{u}_s(t) + K_{ss}u_s(t) = F_s(t) - M_{sc}\ddot{u}_c(t) - C_{sc}\dot{u}_c(t) - K_{sc}u_c(t) \quad (3.32)$$

Enseguida se hace uso de la proposición de Koh sobre los desplazamientos ecuación (3.33), con el fin de remover los desplazamientos y velocidades del lado derecho de la ecuación (3.32).

$$u_s(t) = \underbrace{u_s^s(t)}_{\text{desplazamiento casi-estático}} + \underbrace{u_s^r(t)}_{\text{desplazamiento relativo}} \quad (3.33)$$

Realizando la sustitución de la ecuación de Koh [7] con el algebra correspondiente y agregando las suposiciones de: cero excitación externa, terminos derivados en tiempo iguales a cero, fuerza de amortiguamiento muy pequeña y que la matriz de masas es una matriz diagonal, los autores presentan la ecuación (3.34) como ecuación de movimiento para la subestructura.

$$M_{ss}\ddot{u}_s^r(t) + C_{ss}\dot{u}_s^r(t) + K_{ss}u_s^r(t) = F_s(t) - M_{ss}\eta\ddot{u}_c(t) \quad (3.34)$$

2) Cambio de variables. Para habilitar el empleo del filtro de Kalman, es requerimiento agregar los parámetros desconocidos del sistema al estado, por lo tanto se procede al cambio de variables dado por las ecuaciones (3.35), donde X_1 es el estado para los desplazamientos, X_2 son las velocidades y X_3 son los parámetros desconocidos a ser determinados

$$\begin{aligned} X_1 &= \begin{bmatrix} u_{s,1} & \cdots & u_{s,n} \end{bmatrix}^T \\ X_2 &= \begin{bmatrix} \dot{u}_{s,1} & \cdots & \dot{u}_{s,n} \end{bmatrix}^T \\ X_3 &= \begin{bmatrix} \theta_1 & \cdots & \theta_n \end{bmatrix}^T \end{aligned} \quad (3.35)$$

3) Aplicación del filtro de Kalman extendido. Una vez obtenidas las ecuaciones de movimiento para cada subestructura se procede a la aplicación del filtro de Kalman bajo la ecuación de observación (3.36), donde $Y(k)$ son las observaciones discretas que contiene las mediciones, $H(k)$ es la matriz de observación, $v(k)$ es el vector de ruido con covarianza R (elegida y adaptada durante el proceso), donde $k = t_k$.

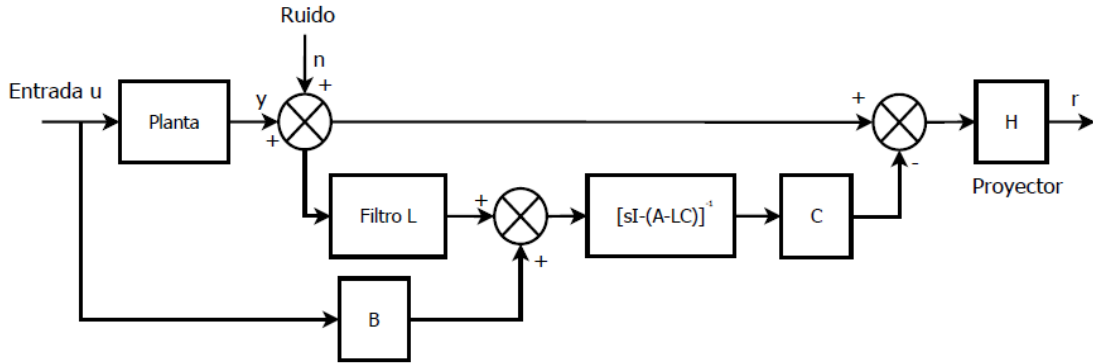


Figura 3.2: Implementación de filtro espectral.

$$Y(k) = H(k)X(k) + v(k) \quad (3.36)$$

La metodología presentada es una buena opción en el seguimiento de cambio de propiedades con errores $< 5\%$ o $< 9\%$ (sin y con presencia de ruido) para la estimación de rigidez, sin embargo presenta una convergencia lenta durante la estimación del amortiguamiento por lo que los errores son $< 15\%$ y $< 29\%$ (sin y con presencia de ruido). Presenta la ventaja de permitir la disminución en el cálculo, al “reutilizar” las estimaciones realizadas para una subestructura y aplicarlas a otra con características similares; remarcando como desventaja que el ruido debe ser menor al 2% y el error de estimación aumenta proporcionalmente a los grados de libertad.

Otros Observadores Sauro Liberatore et. al. [30] (2006) propusieron la detección y clasificación de fallas sobre una viga simple soportada empleando un filtro basado en el método espectral, Douglas y Speyer (1996,1999), cuya implementación está descrita por la Figura 3.2.

Se emplean sensores piezoeléctricos para detección de desplazamiento vertical y se aplica una excitación controlada en la primera frecuencia natural.

Se basa en los siguientes puntos:

- Se realiza el modelado del sistema por medio de la ecuación (3.37), donde A , B y C son las matrices del sistema considerado como lineal e invariante en el tiempo, F_i son los vectores de la dirección de la falla (conocidos) y μ_i son las magnitudes de las fallas (desconocidas) expresadas como funciones arbitrarias en el tiempo; con un total de q modos de falla de posible ocurrencia incluyendo las fallas de los actuadores.

$$\dot{x} = Ax + Bu + \sum_{i=1}^q F_i \mu_i \quad (3.37)$$

$$y = Cx$$

- El observador propuesto es un observador Luenberger, sobre el cual existe una amplia literatura, de manera que al ser aplicado al sistema arriba descrito se obtiene el error de

observación y los residuales en la ecuación (3.38).

$$\begin{aligned} \dot{e} &= (A - LC)e + \sum_{i=1}^q F_i \mu_i \\ r &= Ce \end{aligned} \quad (3.38)$$

- El error de modelo por elemento finito resulta en una matriz de datos que ayuda a localizar el fallo, además, los residuales de observación se emplean para la generación de probabilidad de que cada falla ocurra.

- El filtro de cada sección de la viga descarta las fallas que se encuentren fuera de cada zona de sensado, acotando así la localización de la falla. Esto se logra mediante la introducción de “proyectores” H_i que producen los residuales proyectados R_i de la relación (3.39) cuyo resultado será la exclusión de todas las fallas, excepto la i -ésima que es la que se requiere identificar.

$$R_i = H_i r \approx \gamma(t) \underbrace{H_i C A F_j}_{\neq 0, \text{ssi } i=j} \quad (3.39)$$

- Para el cálculo de la ganancia del observador, se considera el modelo estructural dado por la forma de la ecuación (3.40), descrita en el tema de Análisis Modal. Mediante la correcta manipulación de variables, se puede obtener el sistema de ecuaciones (3.41), donde $\zeta(t) = [x, \dot{x}]^T$, $\Delta\phi_A$ es el voltaje aplicado al actuador, $\Delta\phi_S$ es el vector de voltaje de salida del sensor.

$$M\ddot{x} + Dx + Kx = F \quad (3.40)$$

$$\dot{\zeta}(t) = A\zeta(t) + B\Delta\phi_A \quad (3.41)$$

$$\Delta\phi_S = C\zeta(t)$$

Las matrices A , B y C se definen en base a M , K , F y D

- El procedimiento entonces, se define como un problema de vectores y valores propios (Douglas y Speyer, 1996) dado por las ecuaciones (3.42) y (3.43) y cuya solución permite encontrar la ganancia del observador $L = (V^T)^{-1} W^T$, donde $V = \begin{bmatrix} V_D & V_C \end{bmatrix}$, $W = \begin{bmatrix} W_D & W_C \end{bmatrix}$.

$$\begin{bmatrix} \lambda_i I - A^T & C^T \\ \hat{F}_p^T & 0 \end{bmatrix} \begin{Bmatrix} V_D \\ W_D \end{Bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (3.42)$$

$$\begin{bmatrix} \lambda_i I & A_a^T & C_0^T \\ -I & \lambda_i + A_b^T & 0 \\ 0 & F_b^T & 0 \end{bmatrix} \begin{Bmatrix} V_C^1 \\ V_C^2 \\ W_C \end{Bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad (3.43)$$

- La ganancia L óptima estará dada por la minimización de la relación señal ruido de la ecuación (3.44), lo que significaría una mejora en la sensibilidad al daño.

$$\frac{r}{n} = H \{I - C [sI - A - LC]^{-1} L\} \quad (3.44)$$

Este método presenta las ventajas de proveer la localización precisa de la falla y del tipo de la misma, en etapas prontas o avanzadas. Además es robusto a cambios de masa, densidad y rigidez dentro de un 5% de variación, y permite el cambio de la vibración provocada por el actuador a la vibración inducida por el medio ambiente. Sin embargo su implementación se vuelve costosa al necesitar un gran número de filtros a lo largo del elemento analizado puesto que solo puede detectar fallas predeterminadas, agregando que la localización de sensores debe mantener al sistema observable y controlable. Este método pierde eficiencia con desgastes profundos que generen cortes casi transversales.

3.1.7. Métodos basados en Algoritmos Genéticos

Los algoritmos genéticos (AG) son un método de optimización y búsqueda, donde se define la función de costo y sus restricciones, así como las deficiones evolutivas. Están basados en la teoría evolutiva con mecanismos de selección y genética natural siguiendo el concepto de supervivencia del más apto. Este tipo de algoritmos permite encontrar mejores soluciones y evita convergencias a máximos o mínimos locales.

La evolución del algoritmo está basada en la definición de lo siguiente:

Individuo: posible solución. Cadena de bits.

Genes: información que compone a la posible solución. Bits o bloques cortos de bits.

Alelo: valor de un bit en una posición.

Cruce: intercambio de información entre dos individuos.

Mutación: modificación de algún bit en un lugar aleatorio.

Genotipo: configuración de bits.

Operadores: funciones que permiten la generación de nuevos individuos, entre los cuales se encuentran la selección, la combinación, la mutación, la permutación, la clonación y la regeneración.

Los AG son empleados para la solución de problemas complejos y trabajan mediante la combinación de soluciones (individuos padres) o la mutación de un individuo, para generar otra solución (individuo) la cual es evaluada y si resulta ser “más apta” sobrevive y la peor de todas muere, tal y como funciona un algoritmo basado en la capacidad de supervivencia.

Debido a la complejidad del tema, no se abordará a detalle, sin embargo puede encontrarse en [37], en donde el autor emplea el Método de Búsqueda Global (MBG) basado en vibración con parámetros como el módulo de elasticidad y rigidez, la masa y el mallado del FE con un modelo actualizado, como base para el diseño del AG. Para las pruebas de simulación del algoritmo, los daños considerados a la estructura son causados por el cambio del área de la sección transversal, y el estímulo aplicado es un pulso de sobre los siguientes elementos:

- Tipo barra: La detección y localización del daño es exitosa, con variaciones menores al 10%, los falsos positivos se localizan sobre solo un elemento finito y son separables y despreciables. se investigó sobre daños puntuales y sobre daños generalizados en diferentes localidades y gravedades, lo cual afecta la convergencia del algoritmo si la diferencia entre las extensiones de daño son grandes. Mayor eficiencia con operador de permutación.

- Marco estructural: presenta una convergencia aceptable, localizando el daño y calculando la severidad, sin embargo se obtienen falsos positivos no despreciables. Sin embargo parece localizar puntos donde los daños actuales provocan sobreesfuerzo que gradualmente puede conducir a una falla.

- Puente: Barranca Honda, Edo de México, México. Analizado con daño en una de las vigas longitudinales y en una transversal. El algoritmo localiza el daño pero arroja varios falsos positivos no descartables, por lo que funciona para reducir la zona de inspección de toda la estructura a puntos donde posiblemente exista daño.

La desventaja del uso de los AG es el tiempo de cómputo, para el caso anterior se necesitan 4 días para elementos simples y 6 para compuestos, lo cual permite no permite la implementación en tiempo real, y restringe su empleo a ser solamente una herramienta de análisis del estado actual de la estructura.

Metodologías anteriores Borges 2006, Meruane 2010, Waisman 2009, Kouchmeshky 2006, Casciati 2008, Kouchmeshky 2007.

3.1.8. Metodos basados en Propagación de ondas guiadas.

Estas metodologías estan diseñadas para realizar una evaluación directamente sobre elementos estructurales usando sistemas movibles de cero contacto. Dentro de estas se encuentran:

- Aplicación de ondas de volumen.
- Aplicación de ondas guiadas.
- Fuga de flujo magnético.
- Métodos micromagnéticos.

Estas metodologías emplean la estimulación del elemento mediante la inyección de ondas junto con la detección y análisis del eco producido por las misma y algunas se basan en el hecho de que las propiedades magneticas o ferromagneticas de los materiales estan relacionados con sus propiedades mecanicas. Debido a lo anterior es aplicable solo elementos estructurales metálicos y es potencialmente aplicable a elementos ocultos, aunque las ondas son amortiguadas en extremo por los recubrimientos.

En Jochen H. Kurz et. al [28] se realiza la inspección de cables que forman parte de la estructura del puente del rio Saar en Alemania. La investigación se realiza con la aplicacion de emisiones de ondas ultrasónicas guiadas (Emisión Acustica) comprobando la eficiencia en la propagación del estimulo aplicado y sobre el método micromagnetico 3MA . El objetivo es la detección de daño sobre cables sin recubrimiento, encontrando que este último provoca una degradación de la señal disminuyendo la distancia de propagación. Las pruebas arrojan

tambien que el eco producido en el elemento es distinguible entre si según el tipo de defecto.

Para el análisis con AE los autores realizan el diseño de los actuadores a emplear para la generación de la onda, denominados EMAT's (Electromagnetic Acoustic Transducers). Estos actuadores poseen la capacidad de generar ondas guiadas específicas durante las pruebas iniciales, logrando una detección de defectos a varios metros de distancia con una alta eficiencia (1-5 m). Frente a otros métodos, el análisis de eco puede detectar defectos tanto superficiales como de alta profundidad además de tener la capacidad de detección de daños en múltiples localidades, pero presenta la desventaja de reducir la detección con cortes diagonales.

El trabajo presentado por los autores empleando la metodología 3MA (Micromagnetic Multiparameter Microstructure and Stress Analysis-Micromagnetic methods) se basa en la suposición de que cualquier pérdida de material debido a fracturas se verá reflejado en una redistribución de la carga de tracción sobre diferentes localizaciones. Se comprobó la eficiencia del método al ser aplicado sobre las cuerdas del puente e incluso es capaz de detectar el paso de vehículos de masa alta localizándolas mediante rizados en la señal de eco magnético.

Presenta la ventaja del uso de sensores de carga anclados directamente a la estructura, con lo que puede realizarse la caracterización y filtrado la carga de tráfico, que es altamente variable, además, los autores consideran los cambios de temperatura como despreciables por lo que no se requiere un análisis de compensación de temperatura. presenta la desventaja de ser de reducida generalización, pues requiere un diseño óptimo de sensores de acuerdo a las propiedades del material y la geometría del elemento. Los autores proponen como aplicación la detección de cargas de tráfico de operación del puente.

La investigación sobre emisiones acústicas para detección de daño presentada por R. Vidya Sagar y B. K. Raghu Prasad [45] se centra sobre vigas de concreto bajo ciclos incrementales de carga causados principalmente por inclinación de las estructuras lo que provoca esfuerzos en tensión, flexión y del tipo cortante.

El método consiste en detectar la frecuencia, duración, amplitud, tiempo de rizo de las emisiones acústicas detectadas (*AE*), además de la determinación de los parámetros *b* y *D* como principales detectores de daño, por medio de la instalación de sensores piezoeléctricos y medidores de tensión.

Contrariamente la investigación de [28] es este caso se detectan las emisiones acústicas provocadas por el comienzo y avance de microfisuras, lo que permite

- Determinar la posición y evolución de las fallas.
- Clasificación por fracturas tempranas y fracturas mayores.
- Apreciación de fracturas múltiples.
- Distinción entre fallas por tensión y por esfuerzos cortantes.
- Predicción de daño.
- Caracterización de la causa del daño

Al análisis matemático realizado sobre la detección de las AE se sustenta en las ecuaciones siguientes.

Cálculo de la frecuencia promedio *AF*.

$$AF = \frac{NAE}{t}$$

Donde NAE es el número pulsos en una emisión acústica detectada, t la duración de la emisión. El tiempo de rizo se emplea para el cálculo del parámetro RA por medio de la ec (3.45), donde RT es el tiempo de rizo y A la amplitud de la AE .

$$RA = \frac{RT}{A} \quad (3.45)$$

Cálculo del valor "b", definido como la pendiente negativa entre el logaritmo de la frecuencia de un temblor y su magnitud según la ecuación (3.46), donde M es la magnitud de umbral para la magnitud de los impactos sufridos por la estructura bajo estudio, N es el número de impactos de magnitud mayor que M , A_{dB} es la amplitud pico en decibeles de evento AE registrado y a es una constante empírica.

$$\log_{10}N(M) = a - b \left(\frac{A_{dB}}{20} \right) \quad (3.46)$$

La detección de daño requiere una planeación de distribución de sensores lo que es realizado empíricamente, lo que dificulta su aplicación sobre elementos con diferente geometría.

Para la caracterización del daño, se emplea el parámetro D desarrollado para daño por compresión y aplicado en este trabajo para flexión bajo el conocimiento de que los especímenes terminan fallando por compresión. Este parámetro está descrito por la ecuación (3.47), donde c es una constante que los autores fijan en 3, y m es la amplitud del evento AE expresada en decibeles.

$$D = \sum 10^{c \cdot m} \quad (3.47)$$

Finalmente se combina el análisis anterior con el análisis de momento tensor (MTA) para identificar el desarrollo de las fracturas. En el trabajo presentado, las gráficas son de suma importancia:

- tiempo vs valor-b: Un decremento repentino en el valor mínimo del valor b significa la creación de una fractura.
- tiempo vs. parámetro D: Un incremento repentino o "pico" detecta la creación de una fractura.
- tiempo vs num de AE: determinan la edad de la fractura, intervalos de tiempo cortos entre AE detectadas indican el comienzo o formación de una fractura, mientras que una detección más espaciada indica el crecimiento de una fractura ya formada.
- AF vs. RA: progreso de la fractura.
- RT vs A: muestra una distribución de puntos por encima del umbral, conforme se aumentan los ciclos de carga. Además el tipo de distribución distingue entre fracturas por tensión y fracturas por esfuerzo cortante.

- A vs RMS. El valor RMS máximo predice fracturas al superar un valor de umbral predeterminado.

Los autores trabajan unicamente bajo condiciones de laboratorio, sin embargo, debido a la ausencia de actuadores o estímulos externos, la implementación de este método es amplia siempre y cuando se cuenten con un sistema de captura de datos continua de la suficiente capacidad.

3.1.9. Metodos integrales.

Cada una de las metodologías descritas anteriormente pueden ser estudiadas e implementadas de manera individual o en sinergia con otras. Existen investigaciones en las cuales se desarrollan metodos integrales con el objetivo de aumentar la fiabilidad, la precisión o la velocidad de análisis.

El metodo de análisis integral (IAM, por sus siglas en ingles) propuesto por Werner Lienhart [31] permite mejorar los resultados obtenidos a partir del *Análisis de epocas individuales de medición* y del *Análisis de deformación con deformación descriptiva* empleados individualmente, mediante el empleo del modelo en elemento finito para complementar las mediciones “perdidas” y la comparación entre la predicción resultante con las mediciones realizadas.

El análisis requiere de la determinación de la deformación de la estructura y un análisis de los resultados con el objetivo de separa las deformaciones causadas por cambios regulares (operación y ambiente)

1) Análisis de deformación. Llevado a cabo bajo la suposición de congruencia entre epocas, esto es, supone que el modelo sigue siendo congruente consigo mismo en dos puntos diferentes en el tiempo (i) con presencia de distorsiones geométricas reflejadas en diversos puntos del objeto. Consta de las siguientes etapas:

- Epocas de mediciones.

- Ajuste de mínimos cuadrados. El ajuste es dado por la ecuación (3.48) donde y son las mediciones, e son los residuales, ξ es el vector de parámetros y A es la matriz de relación entre las observaciones y los parámetros; además la solución al problema de minimización está dada por la ecuación (3.49), donde $\hat{\xi}$ son los parámetros estimados, \sum_{yy} es la matriz de varianza covarianza de las observaciones y N es la matriz normal.

$$y + e = A\xi \quad (3.48)$$

$$\hat{\xi} = \begin{bmatrix} \hat{x} \\ \hat{l}_1 \\ \hat{l}_2 \end{bmatrix} = \left(A^T \left(\sum_{yy} \right)^{-1} A \right)^{-1} A^T \left(\sum_{yy} \right)^{-1} y \quad (3.49)$$

- Calculo de la deformación. Mediante la diferencia en los parámetros de los puntos seleccionados entre dos epocas es decir, $d_{ij} = \hat{\xi}_j - \hat{\xi}_i$

- Prueba de congruencia global. En caso de existir deformación, se separan los puntos en movimiento de los puntos estáticos o de referencia.

2) Detección de deformación por condiciones ambientales. Si existen diferencias entre las deformaciones calculadas y las medidas, se procede a la aplicación del análisis integral. Las etapas para realizar esta detección son las que siguen:

- Realización de mediciones

- Modelo FE. Se construye el modelo en elemento finito para investigar el comportamiento de la estructura bajo condiciones ambientales cambiantes, en el presente artículo, estas condiciones se reducen a la temperatura.

- Predicción. El comportamiento o deformación de la estructura es predicho por el modelo de elemento finito

- Error de estimación. Se calcula la diferencia entre la deformación estimada dada por el FE (d_{FE}) y la deformación medida (d_{ME}) es decir $\delta = d_{FE} - d_{ME}$

- Prueba de significado. Si las mediciones y el modelo no son consistentes, se procede a realizar el Análisis integral

3) Análisis integral. Se asume que las deformaciones calculadas son idénticas a las medidas bajo la condición de que el modelo FE ha sido paramétricamente actualizado (ver sección 2.6.4)

- Toma de mediciones de deformación d_{ME} .

- Se asumen equivalentes a los desplazamientos u en los nodos, los cuales son los parámetros en el modelo .

- Cálculo de los parámetros \hat{p} . A partir de los parámetros desconocidos del modelo FE.

- Aplicación del modelo Gauss Markov. Basado en el establecimiento de la ecuación (3.50), donde \hat{u} es la estimación de la deformación de los nodos. Dentro de este modelo se considera la estimación y la medición de: las fuerzas f , los parámetros del material p , los desplazamientos nodales u , la derivación parcial de los desplazamientos nodales con respecto a los parámetros T_{up} y con respecto a las fuerzas T_{uf} y las derivaciones parciales las deformaciones con respecto a los desplazamientos nodales

$$A = \begin{bmatrix} T_{du} & & & \\ I & -T_{up} & -T_{uf} & \\ & I & & \\ & & & I \end{bmatrix} = \begin{bmatrix} \frac{\partial d}{\partial u} & & & \\ I & -\frac{\partial u}{\partial p} & -\frac{\partial u}{\partial f} & \\ & I & & \\ & & & I \end{bmatrix} \quad (3.50)$$

El autor demuestra que la aplicación del IAM sobre el puente monolítico Minkelkehre-Adlerhorst en Austria, genera cálculos de deformaciones que corresponden fuertemente con las deformaciones medidas.

Capítulo 4

Análisis de Componentes Principales en el SHM

4.1. PCA

El análisis de componentes principales (PCA, por sus siglas en inglés) es un método estadístico multivariable también conocido como transformada de Karhunen-Loeve y el objetivo principal es la transformación de un número de variables correlacionadas entre sí, en otra cantidad de variables “menor y no correlacionadas”. Este nuevo grupo de variables se llaman Componentes Principales (PC, por sus siglas en inglés) y deben preservar la mayor cantidad posible de información que estaba contenida en las variables originales (la mayoría de la variación/varianza debe estar contenida en los PC). El PCA se encuentra en el SHM combinado con otras metodologías tales como el análisis modal y puede ser aplicado a los parámetros modales.

Posee la ventaja de no requerir la parametrización o medición de las condiciones ambientales, sin embargo es una técnica de detección de daño que no provee su localización ni severidad.

La metodología para la obtención de los PC se describe simplificada a continuación:

1) Determinación de variables y mediciones. Una vez determinados los parámetros estructurales x_i a medir, se realiza un muestreo para la obtención de mediciones que conforman la matriz de observaciones $X \in \mathbb{R}^{n \times m}$, donde las columnas contienen los valores de cada x_i ($i = 1, \dots, m$) medidos en el tiempo t_j ($j = 1, \dots, m$), es decir las filas contienen el valor medido de todas las x_i en el j -ésimo tiempo como se ejemplifica en la ecuación (4.1).

$$X = \underbrace{\begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix}}_{x_1 \rightarrow x_m} \leftarrow \text{muestra 2 de todas las } x_i. \quad (4.1)$$

2) Obtención de Valores y Vectores Propios. Los PC son una combinación lineal de las

variables originales donde cada z_i no esta correlacionada con otra z_j , lo que se muestra en el sistema de ecuaciones (4.2) a (4.5), donde a_{ij} son los coeficientes a ser determinados durante el análisis de componentes principales.

$$z_1 = a_{11}x_1 + a_{12}x_2 + \dots + a_{1m}x_m \quad (4.2)$$

$$z_2 = a_{21}x_1 + a_{22}x_2 + \dots + a_{2m}x_m \quad (4.3)$$

$$\vdots \quad (4.4)$$

$$z_p = a_{p1}x_1 + a_{p2}x_2 + \dots + a_{pm}x_m \quad (4.5)$$

Cada z_i está determinado por la combinación lineal que tiene la máxima varianza de todas las combinaciones lineales posibles para x_1, \dots, x_m , además si se define la varianza del i –ésimo componente principal como $var(z_i) = \lambda_i$, entonces se cumple que:

$$\lambda_1 > \lambda_2 > \dots > \lambda_p$$

donde $p \leq m$. Se puede demostrar que las varianzas de los componentes principales corresponden a los valores propios de la matriz de covarianza o la matriz de coeficientes de correlación de las variables originales (a la que se denominará $\Lambda \in \mathbb{R}^{m \times m}$). Los coeficientes de los componentes principales corresponden a los vectores propios de Λ .

De manera que es necesario obtener la matriz Λ y su descomposición singular, dada por la ecuación (4.6), donde $U \in \mathbb{R}^{n \times n}$ y $UU^T = I$ cuyas columnas son los vectores propios que definen a los PC, Σ es una matriz diagonal formada por los valores propios en orden descendente de la matriz Λ .

$$\Lambda = U\Sigma U^T \quad (4.6)$$

3) Cálculo de los PC. Los PCs "Z" estan definidos por una transformación lineal ortogonal aplicada a las variables originales "X" dada por la ecuación (4.7).

$$Z = U^T X \quad (4.7)$$

4) Determinación del número de PCs. El número de PC puede determinarse por alguno de los siguientes métodos:

a) Contribución acumulada: la contribución de varianza acumulada por los k – primeros PCs se calcula mediante la ecuación (4.8). El número de PCs empleados corresponde a aquellos que acumulan una contribución de entre 70 % y 90 %.

$$\frac{\sum_{j=1}^k \lambda_j}{\sum_{j=1}^m \lambda_j} \times 100 \% \quad (4.8)$$

b) Valor propio promedio: Se conservan los componentes cuyos valores propios correspondientes se encuentran arriba del valor propio promedio.

c) Gráfica de puntos. Se realiza una gráfica de "valores propios" vs "número de valores propios". Se seleccionan los PCs que se encuentren antes de que la gráfica se vuelva "plana".

d) Separación de la señal del ruido. El problema de selección de PCs se convierte en un problema de filtrado del ruido de la señal. La relación de la ecuación (4.9) representa la relación entre dos compóentes consecutivos, por lo que puede ser enfocado en encontrar la relación entre el mínimo PC λ_k y el ruido máximo λ_{k+1} . De manera que los PC terminan donde γ_k es máxima.

$$\gamma_k = \frac{\lambda_k}{\lambda_{k+1}}, (k = 1, \dots, p - 1) \quad (4.9)$$

5) Reconstrucción de los datos originales. Los datos originales X pueden ser reconstruidos a partir de la ecuación (4.10) donde R es la matriz residual correspondiente a la información no conservada por los componentes principales y que probablemente representa el ruido en la información.

$$X = Z + R \quad (4.10)$$

Diferencias entre el empleo de la Matriz de Covarianzas y el empleo de la Matriz de Correlación

El Análisis de Componentes Principales puede ser ejecutado empleando tanto la matriz de correlación de los vectores como la matriz de covarianzas. La decisión entre el empleo de una u otra depende de las características intrínsecas de las mediciones efectuadas y difieren de acuerdo a lo que sigue.

Matriz de Correlación.

Empleado cuando los datos no tienen una dimension homogénea o poseen distintos valores medios de magnitud. La matriz de correlaciones está definida por:

$$\Lambda = R = [r_{ij}]$$

donde

$$r_{ij} = \frac{\text{cov}(x_i, x_j)}{\sqrt{\text{var}(x_i) \text{var}(x_j)}}$$

Matriz de Covarianzas.

Empleado con datos homogéneos en dimensión y en magnitud. Los datos, por lo tanto, deben de estar centrados en media cero (efectuando la resta de la media a cada columna) y escalados (división cada columna por su desviación estándar)

$$\Lambda = S = \frac{XX^T}{n - 1}$$

La principal ventaja del uso de este tipo de metodologías es su capacidad de extracción de características independientemente de la complejidad de la estructura bajo análisis.

4.2. Resultados y discusión

El objetivo del análisis experimental es realizar una aproximación al monitoreo de una estructura, que provea de datos e información que puedan contribuir a preservar la seguridad estructural y de usuarios en una construcción sujeta a temblores y terremotos o a altas vibraciones causadas por el medio ambiente, cuyo uso sera continuo e ininterrumpido. Estas construcciones civiles requieren una evaluación post-terremoto que determine la posibilidad de que la integridad de los usuarios pueda estar comprometida.

El análisis experimental fué llevado a cabo sobre un modelo estructural instrumentado *aluminum frame structure*, de seis niveles conectado a un actuador lineal de movimiento en un solo eje, que coincide con el eje de medición de los acelerómetros. Las mediciones generadas por los sensores son vistas como una serie de tiempo de dimensión tres, en donde cada medición efectuada en cada instante de tiempo representa una variable que conforma el vector X .

Tres sensores de aceleración son colocados en los niveles N_1 , N_3 y N_6 , y los valores de aceleración son recuperados con un intervalo de muestreo de 0.001seg.

4.2.1. Aplicación de PCA lineal a los datos de aceleración

Como prueba de clasificación entre la estructura sin presencia de daño y la estructura dañada, se realizó PCA directamente sobre las señales de aceleración. Tomando como datos muestrales todo el intervalo proporcionado (50 segundos) con un muestreo de 0.001seg. Teniendo así, un total de 50000 muestras de cada sensor. Se cuenta con un total de 3 sensores colocados en: planta baja, tercer piso y sexto piso. Además, los datos analizados provienen de la aplicación de dos señales de excitación diferentes: una periodica de frecuencia variable (E1) y otra aperiodica de amplitud aleatoria (E2).

Las Figuras 4.1 y 4.2 muestran las mediciones grabadas para la entrada 1 con la estructura sin y con presencia de daño.

Las Figuras 4.3 y 4.4 muestran los datos grabados para la entrada 2 con la estructura sin y con presencia de daño.

4.2.2. Análisis 1. Señales recopiladas bajo la entrada E1

Se definió el vector de variables como $X = [x_1 \ x_2 \ x_3]$ con:

$x_1 = a_g$: aceleración en la planta baja

$x_2 = a_1$: aceleración en la planta 3

$x_3 = a_2$: aceleración en la planta 6

Tomando un total de 100,000 observaciones. Obteniendose de esta manera tres conjuntos de datos en tres dimensiones, que se muestran en las Figuras 4.5, 4.6 y 4.7.

Se obtuvieron los componentes principales (PC) directamente de las series de tiempo “X” obtenidas durante la aplicación de la *señal de entrada 1 para la estructura “sin”*




Figura 4.1: Mediciones de aceleración para excitación E1, estructura sin daño.

(*E1+ND:E1+no daño*) y “con” (*E1+D:E1+daño*) presencia daño. Los PC obtenidos fueron aplicados a las secuencias de tiempo para la entrada 2, para las series de tiempo obtenidas “sin” (*E2+ND:E2+no daño*) y “con” presencia de daño (*E2+D:E2+daño*). El análisis de componentes, emplea el algoritmo de Descomposición en Valores Singulares (SVD por sus siglas en inglés), con el empleo de la matriz de covarianzas.

Los datos transformados al espacio PC se muestran en las Figuras 4.8 y 4.9. Como se puede observar, empleando estos PCs no es posible llevar a cabo la clasificación entre los vectores pertenecientes a la estructura dañada y los que pertenecen a la estructura sin daño en el mismo espacio dimensional en el que están contenidos originalmente.

Para la selección de los PC a ocupar, se empleó el criterio de varianza contenida. El primer PC contiene una varianza de 60.03 %, en segundo acumula 87.21 % y el tercero completa el 100 %. Por lo tanto, empleando solamente 2 PCs se puede realizar la transformación de los datos del espacio PCA con un contenido de información superior al 85 %.

Debido a que una red neuronal o un algoritmo de clasificación lineal no es capaz de separar las nubes de vectores anteriores, se procede a la aplicación de la etapa de entrenamiento 2, con la obtención de nuevos PCs.

4.2.3. Análisis 2. Señales recopiladas bajo la entrada E1+ND

Se definió el vector de variables como $X = [x_1 \ x_2 \ x_3]$ con:

$x_1 = ag$: aceleración en la planta baja

$x_2 = a1$: aceleración en la planta 3

$x_3 = a2$: aceleración en la planta 6

Tomando un total de 50,000 observaciones.

Se obtuvieron los componentes principales (PCs) directamente de las series de tiempo “ag”, “a1” y “a2” obtenidas durante la estimulación de la estructura con la *señal E1+ND*.




Figura 4.2: Mediciones de aceleración para excitación E1, estructura con daño.




Figura 4.3: Mediciones de aceleración para excitación E2, estructura sin daño.




Figura 4.4: Mediciones de aceleración para excitación E2, estructura con daño.

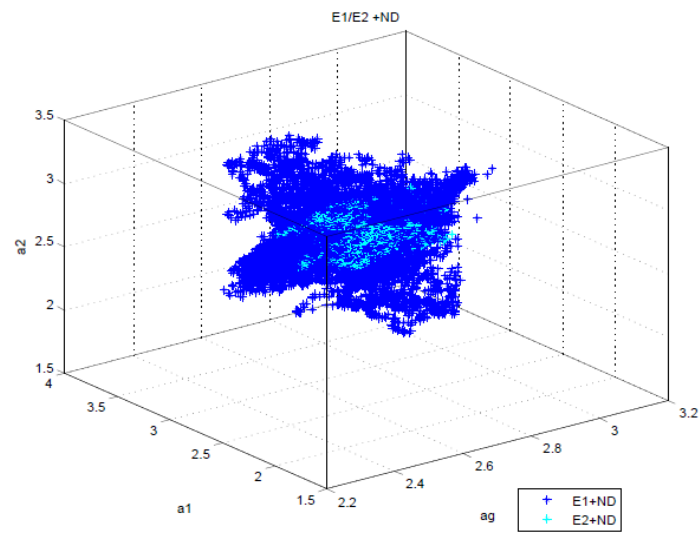


Figura 4.5: Espacio creado por los vectores de aceleración, estructura sin daño.

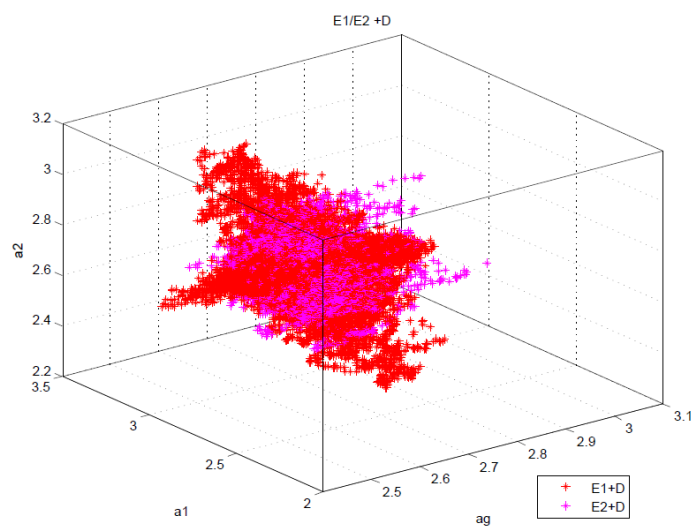


Figura 4.6: Espacio formado por los vectores de aceleración, estructura con daño.




Figura 4.7: Espacio formado por los vectores de aceleración.




Figura 4.8: Componentes principales E1, fase de entrenamiento




Figura 4.9: Componentes principales E2, fase de generalización.

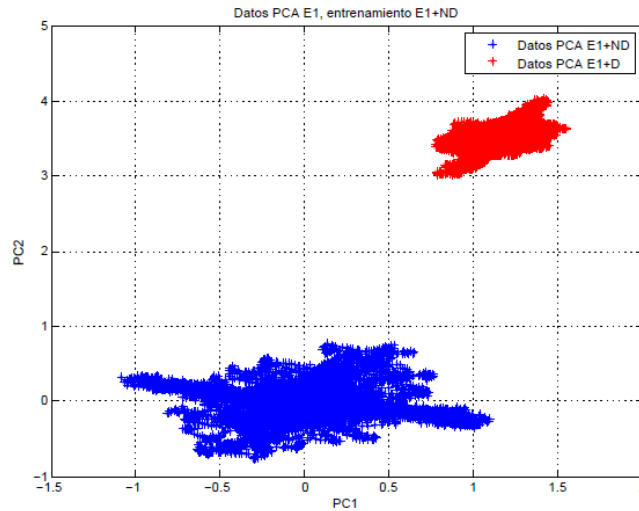


Figura 4.10: Componentes principales, fase entrenamiento E1+ND.




Figura 4.11: Componentes principales E2, fase de generalización.

Aplicando la transformación a las series de tiempo: E1+D, E2+ND, E2+D Se obtienen las nubes de puntos mostradas en las Figuras 4.10, 4.11 y 4.12.

Realizando una observación simple, se teoriza que un plano puede clasificar los datos de la estructura sin y con daño, pero solamente si la señal de excitación de la estructura es la misma con la que se ha diseñado el espacio PC. En caso de cambiar la señal de excitación de la estructura, los PCs ya no realizan una transformación útil, ubicando los datos de la estructura sin daño (E2+ND) dentro del mismo espacio que los datos con daño (E1+D, E2+D). Por lo tanto se procede a la etapa de entrenamiento 3.

4.2.4. Análisis 3. Señales recopiladas bajo las entradas E1 y E2, +ND

Se definió el vector de variables como $X = [x_1 \ x_2 \ x_3]$, para la estructura sin daño y con excitación E1 y E2:

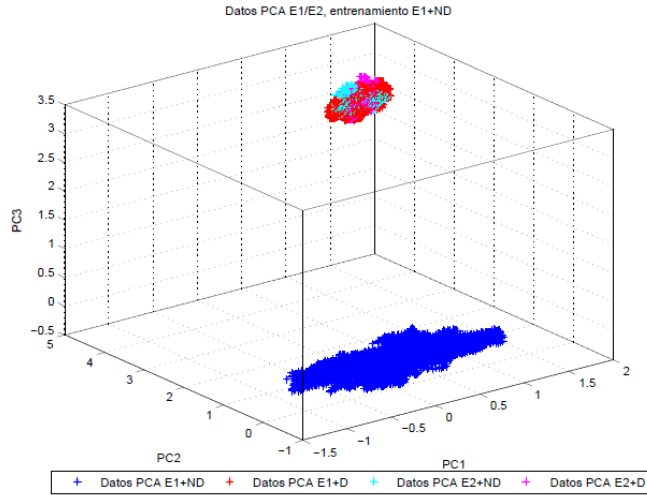


Figura 4.12: Componentes principales E1 y E2

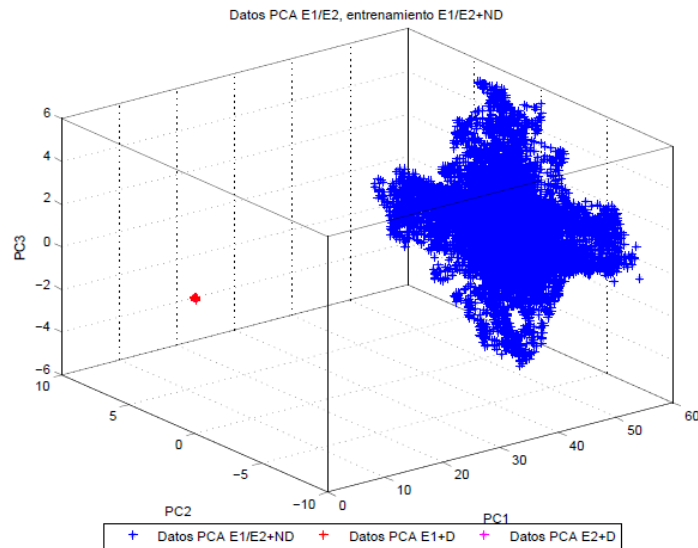


Figura 4.13: Componentes principales, entrenamiento con ND, generalización en D.

$x_1 = ag$: aceleración en la planta baja

$x_2 = a1$: aceleración en la planta 3

$x_3 = a2$: aceleración en la planta 6

Tomando un total de 90,000 observaciones.

Se obtuvieron los componentes principales (PC) directamente de las series de tiempo “ag”, “a1” y “a2” adquiridas durante la aplicación de la *entrada 1* y *entrada 2* para la *estructura sin presencia daño* E1+ND y E2+ND. Aplicando la transformación a las series de tiempo: E1+D y E2+D. Se obtienen las nubes de puntos mostradas en la Figura 4.13.

Empleando los PCs obtenidos para toda la serie de tiempo E+ND disponible, se logra una separación correcta de los datos, pudiendo clasificarlos con una RNA de 3 entradas o un algoritmo SVM rígido incluso de 2 dimensiones. Sin embargo, para lograr la repetitibilidad de la clasificación correcta de los datos y, por lo tanto el reconocimiento de la estructura dañada se necesita la adquisición de series de tiempo bajo diferentes entradas de excitación. Por lo

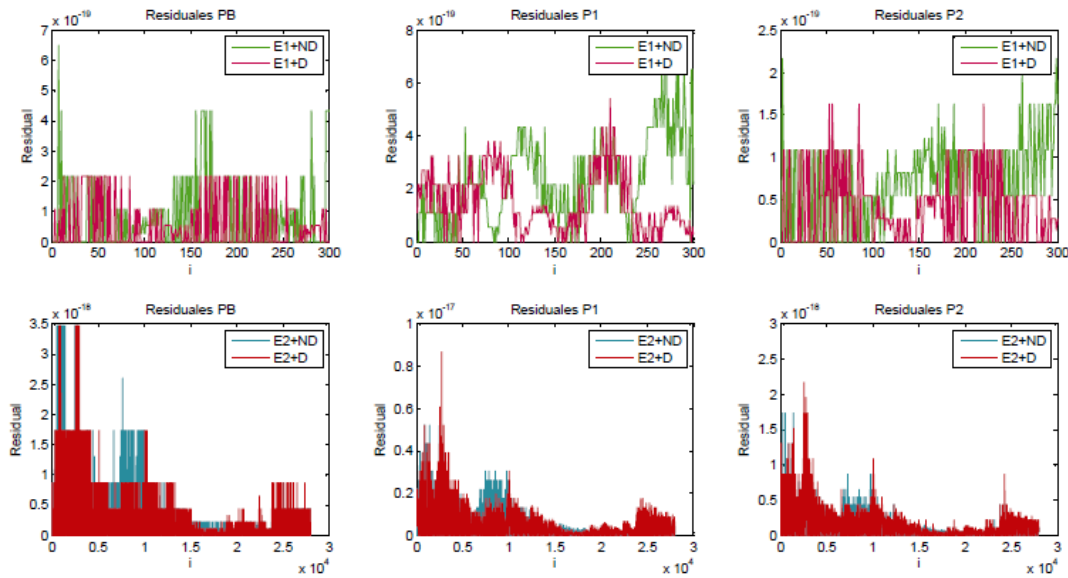


Figura 4.14: Residuales para modelo de 2 PCs, por nivel.

anterior es preferible encontrar coeficientes robustos al cambio de la entrada de excitación del sistema.

4.2.5. Análisis 4. Señales residuales

La transformación de las muestras al espacio PC con el empleo de la matriz de correlación permite la diferenciación de centroides. Este nuevo espacio permite la diferenciación entre señales de vibración de una estructura con cambios paramétricos.

Debido a que la información contenida en los PC dentro del 90% de varianza pueden contener o no información útil para la detección del daño de la estructura, puede ser empleada la información de los residuales de la reconstrucción de las señales de vibración. Estos residuales son calculados a partir de las diferencias entre la señal de vibración original y la señal reconstruida para cada uno de los niveles de la estructura Figura 4.14, durante el entrenamiento de los PC. Sin embargo, el uso de esta metodología no implica una mejora significativa en la ubicación espacial de las muestras que permita una clasificación simple, Figuras 4.2.5 y 4.15.

4.2.6. Resumen

El análisis anterior se llevó a cabo sin efectuar un acondicionamiento de la señal, procesando los datos de las aceleraciones directamente de las mediciones de los sensores. Sin embargo, si se hace uso del centrado de datos, el resultado de las mediciones en el espacio PC se modifica negativamente. La falta de desfase entre señales es una característica negativa para el uso del PCA como herramienta para la clasificación, combinando los grupos de datos con el mismo centroide.

Si, además de optarse por la resta de la media, los datos son normalizados, los resultados

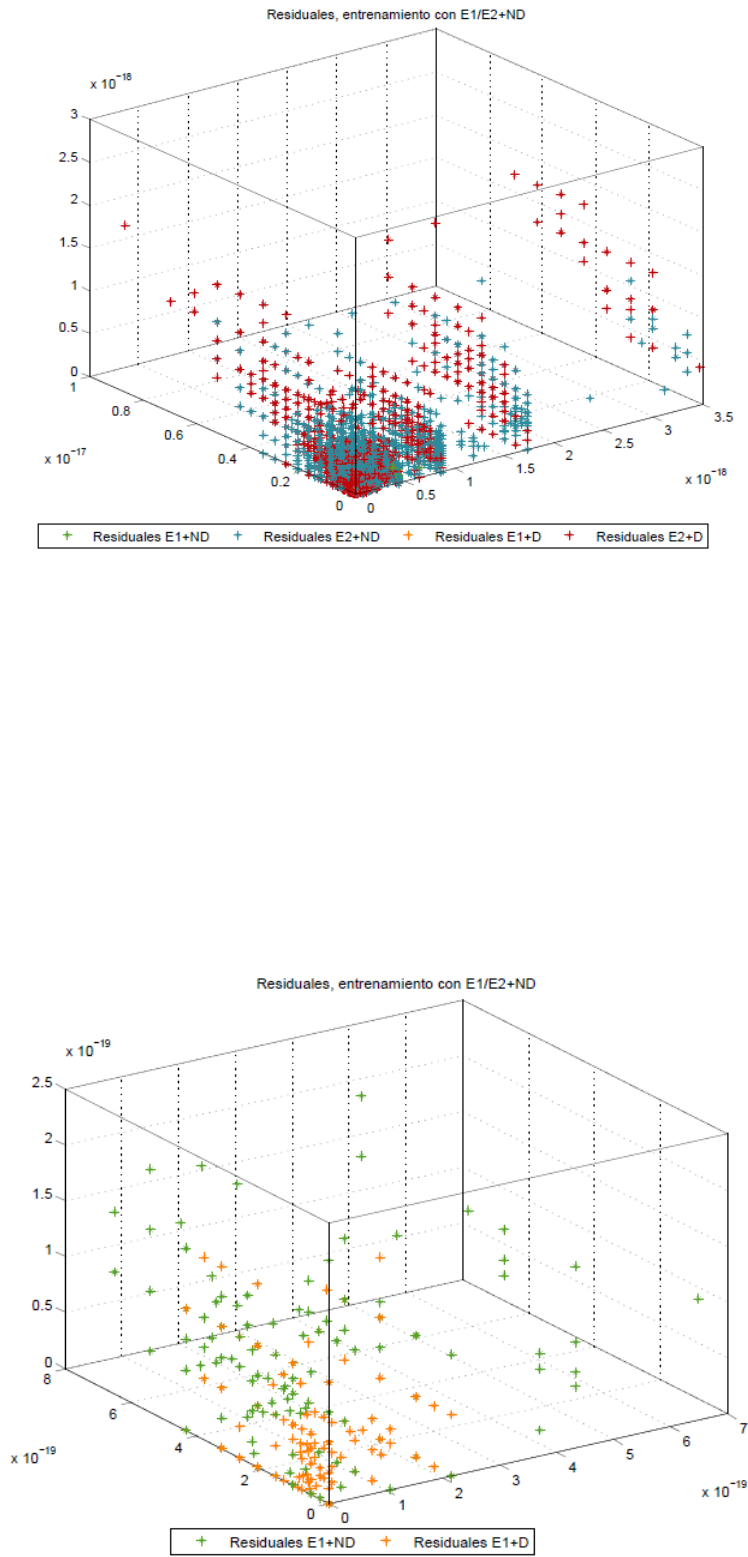


Figura 4.15: Espaciación formado por los vectores de Residuales del modelo PCA.

son igualmente desfavorables. Sin embargo puede optarse por una normalización de los datos y posteriormente un desfase artificial de los mismos, lo que proporciona centroides diferentes como una característica adicional.

La separación de los centroides de los datos unicamente se logra bajo entrenamiento. No es posible la clasificación de lecturas obtenidas bajo señales de excitación desconocidas. Las señales de vibración correspondientes a un edificio dañado unicamente puede ser reconocida si se ha entrenado el algoritmo con las señales de vibración recopiladas de un edificio sin daño bajo la misma señal de excitación.

En base a las observaciones de los graficos, se concluye que la aplicación de analisis de dispersión de datos y otras características puede ser útil para la diferenciación entre grupos de señales. Estas características suelen obtenerse directamente de las señales de vibración [13] , [49], [46], [24].

4.3. Extracción de características sensibles

La extracción de características se define como la transformación de los datos medidos a una forma alternativa en la cual la correlación con el daño o cambio de los parametros de la estructura es mas observable. La selección de características se basa en la determinación de cuales son útiles en el proceso de detección del daño. Sin embargo, las características que suelen ser sensibles al daño de la estructura, también son comunmente sensibles a otras alteraciones del sistema no relacionadas con este. Es recomendable entonces, aplicar un proceso de normalización a los datos adquiridos, para minimizar la influencia de condiciones ambientales y de operación.

Dentro de las características normalmente empleadas en el tratamiento de datos se encuentran las descritas a continuación.

4.3.1. *Características estadísticas en el dominio del tiempo*

Factor K: Característica que cuantifica la desviación desde la respuesta sinusoidal, se calcula sobre la serie temporal y_i por medio de la ecuación (4.11), donde n es el número de muestras, lo que requiere un cálculo por intervalos de tiempo, en los cuales las muestras son adquiridas, guardadas y analizadas en conjunto de manera que los valores rms obtenidos, pueden ser empleados para el cálculo de X_K .

$$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2}$$

$$y_{peak} = max|y_i|$$

$$X_K = y_{peak}(rms) \tag{4.11}$$

Factor de Cresta: Característica que cuantifica la desviación desde la respuesta sinusoidal, se calcula por medio de la ecuación (4.12).

$$X_{CF} = \frac{y_{peak}}{rms} \quad (4.12)$$

Varianza simple: Característica que cuantifica la variabilidad de los datos. Calculada a partir de la ecuación (4.13). Donde $\bar{n} = n$ ó $\bar{n} = n(n-1)$.

$$\nu = \frac{1}{\bar{n}} \sum_{i=1}^n (y_i - \bar{y})^2 \quad (4.13)$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

Desviación estandar: Característica que cuantifica la dispersión de los datos a partir de la media aritmetica de la distribución. Es una medida de la energía contenida en la señal de vibración. Calculada a partir de la ecuación (4.14)

$$\sigma = \sqrt{\nu} \quad (4.14)$$

Oblicuidad: Característica que cuantifica la falta de simetría de la señal respecto a su media. Calculada mediante la ecuación (4.15).

$$\gamma = \frac{\frac{1}{\bar{n}} \sum_{i=1}^n (y_i - \bar{y})^3}{\sigma^3} \quad (4.15)$$

Kurtosis: Característica que cuantifica la forma en base a la combinación de los datos extremos respecto a la media en contraposición con datos poco alejados de la misma. Suele presentarse en valores bajos para componentes no dañados y en valores altos para componentes con presencia de daño o en falla. Calculada mediante la ecuación (4.16) o la ecuación (4.17), dependiendo de la elección de cada autor. En el presente trabajo se emplea la ecuación (4.16).

$$\gamma = \frac{\frac{1}{\bar{n}} \sum_{i=1}^n (y_i - \bar{y})^4}{\sigma^4} \quad (4.16)$$

$$\gamma = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \frac{(y_i - \bar{y})^4}{\sigma^4} - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (4.17)$$

Rango o Valor pico-a-pico. Definida como la diferencia entre el valor máximo y el valor mínimo alcanzados por la señal de vibración.

$$P_p = \max(y_i) - \min(y_i)$$

Valor mínimo. Valor mínimo de una secuencia de datos. Si la muestra de datos es finita y con tamaño definido, pueden obtenerse distintos minimos a lo largo de la operación del sistema. Este valor se modifica comunmente hacia arriba en base al cambio paramétrico del mismo.

$$\min(y_i) = y_{\min} = y \mid y \leq y_i \forall i = 1, 2, \dots, n$$

Valor máximo. Valor máximo de una secuencia de datos. Calculado en los mismos intervalos que el valor mínimo.

$$\max(y_i) = y_{\max} = y \mid y \geq y_i \forall i = 1, 2, \dots, n$$

Suma. Se define como la suma de todos los valores puntuales de la señal discreta.

$$SUM = \sum_{i=1}^n y_i$$

4.3.2. *Características transitorias*

Existen características alternativas a las características estadísticas, las cuales son calculadas a partir de la recopilación de las señales de vibración obtenidas de la aplicación de una señal de excitación de duración finita a la estructura. Dentro de estas características llamadas transitorias se encuentran los momentos temporales, que son calculados empleando el cuadrado de las amplitudes de la señal [16]. Estos momentos pueden ser definidos tanto como para señales de desplazamiento como para otras, tales como mediciones de esfuerzo, aceleración, velocidad y en el caso particular bajo estudio en este trabajo, pueden aplicarse sobre los componentes principales.

Momento Temporal de Orden Cero o Energía: Característica que cuantifica el área bajo la curva de la serie de tiempo discreta de los datos. Es equivalente al cálculo de la energía de la señal.

$$E = M_0 = \sum_{i=1}^{n-1} \frac{\Delta t}{2} [y_i^2 + y_{i+1}^2]$$

Momento Temporal de Primer Orden o Tiempo Central: Definido como el momento temporal de primer orden normalizado alrededor del tiempo cero. Se define como el centroide del área bajo el cuadrado de la amplitud de la historia-tiempo.

$$T \simeq \frac{\frac{1}{2} \sum_{i=1}^{n-1} [\Delta t (i - 0,5)] \Delta t [y_i^2 + y_{i+1}^2]}{E}$$

Momento Temporal de Segundo Orden o Duración de la media cuadrática: Característica que cuantifica la dispersión de la energía de la señal alrededor del tiempo central. Es análoga a la desviación estándar.

$$D^2 = \frac{\frac{1}{2} \sum_{i=1}^{n-1} [\Delta t (i - 0,5) - T]^2 \Delta t [y_i^2 + y_{i+1}^2]}{E}$$

Las características M_0 , T , D^2 son calculadas directamente de los datos recopilados por los acelerómetros, cuando se aplica a la estructura una señal de excitación transitoria. Las mediciones son agrupadas en muestras de N datos discretos Δk_j , $j = 1, \dots, N$; en cada una de estas muestras es posible el cálculo de los momentos temporales cuya variación en

el tiempo depende directamente de la respuesta de la estructura al estímulo recibido en un periodo de tiempo acotado.

4.4. Kernel-PCA y OLPCA para detección de daño en la estructura

4.4.1. Análisis de componentes principales con funciones Kernel

El Kernel-PCA es un análisis que tiene el objetivo de encontrar la proyección de las características no lineales con máxima varianza dentro de un espacio de características inducido. Este espacio inducido es de una dimensión mayor, directamente relacionada con el número de muestras que están siendo procesadas. Una vez se ha realizado el mapeo, se procede a desarrollar el algoritmo PCA, lo que arroja como resultado el desarrollo de un análisis no lineal en el espacio original de características, ecuación (4.18).

Es claro que al realizar la proyección existirán más dimensiones que series de datos contrariamente a los análisis anteriores, en los que se considerarán únicamente tres series para a_g , a_1 y a_2 y por lo tanto tres dimensiones. Para el empleo de esta metodología es necesario realizar la suposición de que las direcciones con menor varianza contienen información referida al ruido contenido en las mediciones debido a la necesidad de discriminar una gran cantidad de dimensiones con el fin de reducir el tiempo de cómputo y que el método sea aplicable a cantidades grandes de datos. En primera instancia, esto es una complicación para el objetivo del presente trabajo, pues se ha demostrado que esta suposición no siempre es útil.

$$\Phi : \mathbb{R}^N \longrightarrow F \quad (4.18)$$

Siendo cada medición $x_i \in \mathbb{R}^N$ centrada en el espacio de características $\sum_{k=1}^l \Phi(x_k) = 0$ donde l es el número de muestras, Φ es una función Kernel que mapea a $F \in \mathbb{R}^M$ donde $M > N$.

Partiendo del PCA convencional se tiene que la matriz de covarianzas en el nuevo espacio está dada por la ecuación (4.19).

$$\tilde{C} = \frac{1}{l} \sum_{i=1}^l \Phi(x_i) \Phi(x_i)^T \quad (4.19)$$

$$K_{ij} = \Phi(x_i) \cdot \Phi(x_j) = (k(x_i, x_j))_{ij} \quad (4.20)$$

Cada vector propio está definido como V , cumpliendo con la normalización $V_k V_k^T = 1$ y con $\lambda V = \tilde{C} V$ se puede asegurar que se pueden encontrar valores propios $\lambda \geq 0$ y vectores propios V , tales que los vectores V permanezcan en el espacio de $\Phi(x_1), \dots, \Phi(x_l)$, que pueda ser considerado el sistema equivalente de la ecuación (4.21), para toda $k = 1, \dots, l$, y que además

existen coeficientes $\alpha_1, \dots, \alpha_l$ tales que se cumple $V = \sum_{i=1}^l \alpha_i \Phi(x_i) \epsilon F$.

$$\lambda (\Phi(x_k) \cdot V) = \left(\Phi(x_k) \cdot \bar{C}V \right) \quad (4.21)$$

Partiendo de las ecuaciones (4.19) y (4.21) se obtiene la ecuación (4.22), donde α es un vector columna con los coeficientes $\alpha_1, \dots, \alpha_l$. Lo anterior resulta en el problema de valores propios de la ecuación (4.23)

$$l\lambda K\alpha = K^2\alpha \quad (4.22)$$

$$l\lambda\alpha = K\alpha \quad (4.23)$$

La ecuación (4.20) puede reescribirse como $K(x, y) = \Phi(x) \cdot \Phi(y)$ que, conjugada con la ecuación (4.23) concluye en el hecho de que no es necesario conocer de forma explícita el valor de $\Phi(x_i)$, si no únicamente los valores de $\Phi(x_i) \cdot \Phi(x_j)$.

De este modo, los componentes principales t^k pueden ser obtenidos a partir de la ecuación (4.24).

$$t^k = V^k \cdot \Phi(x) = \sum_{i=1}^l \alpha_i^k (\Phi(x_i) \cdot \Phi(x)) \quad (4.24)$$

Este mapeo del espacio original al espacio no lineal es llevado a cabo mediante la aplicación de una función Kernel simétrica y definida positiva que satisface las condiciones de Mercer [19], la cual puede ser elegida entre las que se muestran en la tabla siguiente.

| Nombre | Función $K(x, y)$ |
|---|---|
| Polinomial | $(x^T y)^d$ |
| Polinomial | $(x^T y + c)^d$ |
| Función de Base Radial (RBF) | $\exp\left(\frac{-\ x-y\ _2^2}{2\sigma^2}\right)$ |
| Función de Base Radial Exponential (ERBF) | $\exp\left(\frac{-\ x-y\ }{2\sigma^2}\right)$ |
| Sigmoidal o perceptron multicapa | $\tanh(\kappa(x \cdot y) + \Theta)$ |
| Fourier | $\frac{\sin\left(N+\frac{1}{2}\right)(x-y)}{\sin\left(\frac{1}{2}(x-y)\right)}$ |
| Spline de grado m | $\sum_{r=0}^m x^r y^r + \sum_{s=1}^N (x - \tau_s)^m (y - \tau_s)^m$ |
| BSpline [-1,1] | $B_{2N+1}(x - y)$ |

NOTA: El cálculo de los vectores propios puede efectuarse por medio de la descomposición en valores singulares, con la ventaja de tener un tiempo de computo menor, sin embargo no es útil si se requiere discriminar algún conjunto de componentes principales.

4.4.2. Análisis de componentes principales en línea

En aras de proveer una herramienta flexible y con la capacidad de adaptarse a los cambios paramétricos de los procesos o de la maquinaria en la industria en [50], se desarrolla una

herramienta como método de modelado que provee al análisis de componentes principales la capacidad de modificar sus coeficientes con la introducción de cada nueva medición, algoritmo nombrado como Análisis de componentes principales en línea (OL-PCA, por sus siglas en inglés). Los autores remarcan la ventaja de la aplicación de este algoritmo como la reducción del tiempo de cómputo en comparación con el análisis de componentes principales de ventana desplazable convencional (MWPCA, por sus siglas en inglés), principalmente por que la síntesis de información contenida en los PC es actualizada en vez de reemplazada como en el MWPCA.

Dentro de la metodología del OL-PCA se propone el empleo de un índice de medida del cambio paramétrico del proceso monitoreado, llamado Condición de Dependencia Lineal Aproximada (ALD, por sus siglas en inglés). Este índice funciona como marco de referencia para indicar cuando debe o no ser actualizado el modelo PCA, con el fin de evitar que muestras linealmente dependientes de las anteriores sean consideradas y, por lo tanto, evitar la actualización innecesaria del modelo. En el presente trabajo, se estudia la aplicación de la variación de la condición ALD como indicador del cambio paramétrico de la estructura referido a un daño en la misma.

Procedimiento 1) Definir un grupo de datos o muestra, que son definidos como Diccionario original o Base, ecuación (4.25), donde $k = k_0$

$$D_k = \{x_i\}_{i=1}^k \quad (4.25)$$

2) Realizar la normalización y centrado de los datos empleando la matriz de desviación estandar $\Sigma_k = \text{diag}(\sigma_{k1}, \dots, \sigma_{kp})$, donde σ_{ki} es la desviación estandar de la i -ésima variable de entrada en la ecuación (4.26). Donde $X_k \in \mathbb{R}^{k \times p}$ son los datos normalizados, $X_k^0 \in \mathbb{R}^{k \times p}$ son los datos originales, $1_k \in \mathbb{R}^{k \times 1}$ es un vector cuyos elementos son 1, y $u_k^T \in \mathbb{R}^{1 \times p}$ es el vector de media de cada columna de X_k^0 .

$$X_k = (X_k^0 - 1_k u_k^T) \Sigma_k^{-1} \quad (4.26)$$

$$u_k^T = \frac{1}{k} (X_k^0)^T \cdot 1_k \in \mathbb{R}^{1 \times p} \quad (4.27)$$

3) Realizar el análisis de componentes principales convencional sobre los datos normalizados X_k , mediante el empleo de la matriz de correlación, ecuación (4.28); y el problema de valores propios, ecuación (4.29), donde λ_k son los valores propios, P_k son los vectores propios. Los nuevos datos en el espacio PC son obtenidos mediante la ecuación (4.30)

$$R_k \approx \frac{1}{k-1} X_k^T \cdot X_k \in \mathbb{R}^{p \times p} \quad (4.28)$$

$$(R_k - \lambda_k) P_k = 0 \quad (4.29)$$

$$T_k = X_k P_k \in \mathbb{R}^{k \times p} \quad (4.30)$$

4) Para cada nueva medición x_{k+1}^0 , realizar su normalización y centrado, ecuaciones (4.31) a (4.34).

$$u_{k+1} = \frac{k}{k+1}u_k + \frac{1}{k+1}(x_{k+1}^0)^T \in \mathbb{R}^{p \times 1} \quad (4.31)$$

$$\sigma_{(k+1)i}^2 = \frac{k-1}{k}\sigma_{ki}^2 + \Delta u_{k+1}^2(i) + \frac{1}{k}\|x_{k+1}^0(i) - u_{k+1}(i)\|^2 \quad (4.32)$$

$$\Delta u_{k+1}^2(i) = u_{k+1} - u_k$$

$$\sum_{k+1} = \text{diag}(\sigma_{(k+1)1}, \dots, \sigma_{(k+1)p}) \in \mathbb{R}^{p \times p} \quad (4.33)$$

$$x_{k+1} = (x_{k+1}^0 - 1 \cdot u_{k+1}^T) \sum_{k+1}^{-1} \in \mathbb{R}^{1 \times p} \quad (4.34)$$

5) Realizar el cálculo de la condición ALD δ_{k+1} de forma recursiva:

$$\tilde{k}_k = X_k \cdot x_{k+1}^T \in \mathbb{R}^{k \times 1}$$

$$k_{k+1} = x_{k+1} \cdot x_{k+1}^T \in \mathbb{R}$$

$$\tilde{K}_k = X_k X_k^T \in \mathbb{R}^{k \times k}$$

$$\delta_{k+1} = k_{k+1} - \begin{pmatrix} \tilde{k}_k \end{pmatrix}^T \begin{pmatrix} \tilde{K}_k \end{pmatrix}^{-1} \tilde{k}_k \in \mathbb{R}$$

6) Obtener la nueva \tilde{K} , y verificar si es definida positiva.

$$\tilde{K}_{k+1} = \begin{bmatrix} \tilde{K}_k & \tilde{k}_k \\ \begin{pmatrix} \tilde{k}_k \end{pmatrix}^T & k_{k+1} \end{bmatrix} \in \mathbb{R}^{(k+1) \times (k+1)}$$

7) Para el cálculo de la inversa de \tilde{K}_{k+1} , dentro de cualquiera de las siguientes 2 opciones:

a) Si es definida positiva, empleando la ecuación (4.35)

$$\begin{pmatrix} \tilde{K}_{k+1} \end{pmatrix}^{-1} = \frac{1}{\delta_{k+1}} \begin{bmatrix} \delta_{k+1} \begin{pmatrix} \tilde{K}_k \end{pmatrix}^{-1} + \begin{pmatrix} \tilde{k}_k \end{pmatrix}^{-1} \begin{pmatrix} \tilde{K}_k \end{pmatrix}^{-1} \begin{pmatrix} \tilde{k}_k \end{pmatrix} - \begin{pmatrix} \tilde{K}_k \end{pmatrix}^{-1} \begin{pmatrix} \tilde{k}_k \end{pmatrix} \\ - \begin{pmatrix} \begin{pmatrix} \tilde{K}_k \end{pmatrix}^{-1} \begin{pmatrix} \tilde{k}_k \end{pmatrix} \end{pmatrix}^T \\ 1 \end{bmatrix} \quad (4.35)$$

b) Si no es definida positiva, empleando la ecuación (4.36).

$$\begin{pmatrix} \tilde{K}_{k+1} \end{pmatrix}^{-1} = \begin{pmatrix} \tilde{K}_{k+1} \end{pmatrix}^T \begin{pmatrix} \tilde{K}_{k+1} \begin{pmatrix} \tilde{K}_{k+1} \end{pmatrix}^T \end{pmatrix}^{-1} \quad (4.36)$$

Notese que la dimensión de la matriz \tilde{K}_{k+1} , aumenta siempre a $k + 1$, y conforme se agregan muestras al diccionario base aumenta en $k + 2$.

8) Actualización del modelo PCA.

8.1) Definiendo un umbral v , tal que si se cumple que $\delta_{k+1} > v$, la nueva muestra es incluida en el diccionario, ecuación (4.37), y se calcula la nueva matriz de correlación, ecuación (4.38) :

$$\begin{aligned} D_{k+1} &= D_k \cup x_{k+1} \\ X_{k+1}^0 &= [X_{k+1}^0, x_{k+1}^0]^T \end{aligned} \quad (4.37)$$

$$R_{k+1} = \frac{k+1}{k} \Sigma_{k+1}^{-1} \Sigma_k R_k \Sigma_k \Sigma_{k+1}^{-1} + \Sigma_{k+1}^{-1} \Delta u_{k+1} \cdot \Delta u_{k+1}^T \Sigma_{k+1}^{-1} + \frac{1}{k} x_{k+1}^T x_{k+1} \quad (4.38)$$

Si por el contrario $\delta_{k+1} \leq v$, la muestra se excluye del diccionario.

$$\begin{aligned} T_{k+1} &= T_k \\ t_{k+1} &= x_{k+1} P_k \end{aligned}$$

$$\tilde{K}_{k+1} = \tilde{K}_k$$

8.2) Obtener la descomposición en valores singulares de R_{k+1} y obtener los vectores propios.

8.3) Obtener los nuevos valores en el espacio PC.

$$t_{k+1} = x_{k+1} P_{k+1}$$

$$T_{k+1} = \begin{bmatrix} T_k P_k \Sigma_k \Sigma_{k+1}^{-1} - 1_k \Delta u_{k+1}^T \Sigma_{k+1}^{-1} \\ x_{k+1} \end{bmatrix} P_{k+1}$$

9) Realizar del paso 4 al 9 para cada nueva muestra.

El diagrama de flujo del procedimiento para el calculo de la condición ALD y actualización del modelo PCA se muestra en la Figura 4.16.

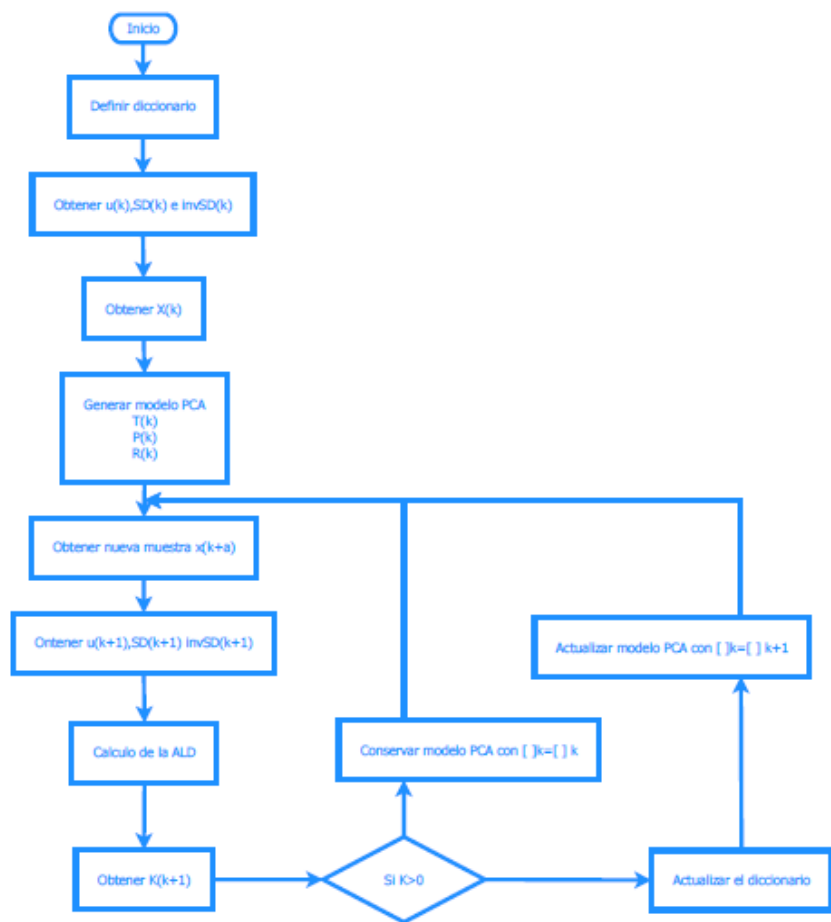


Figura 4.16: Diagrama de flujo para actualización del modelo.

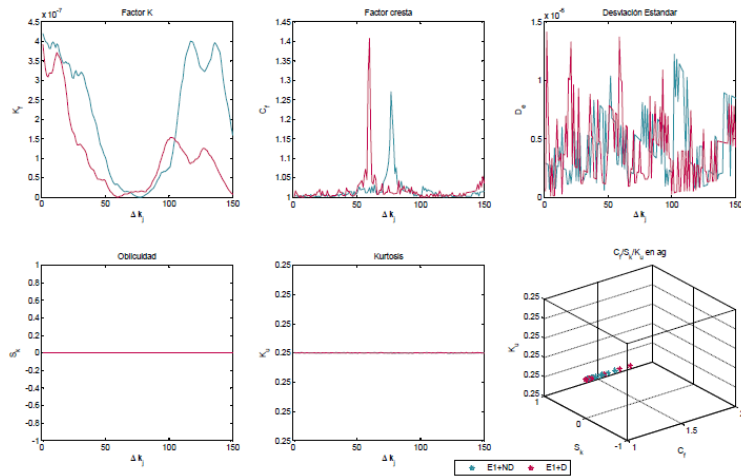


Figura 4.17: Características estadísticas para excitación E1. Planta baja.

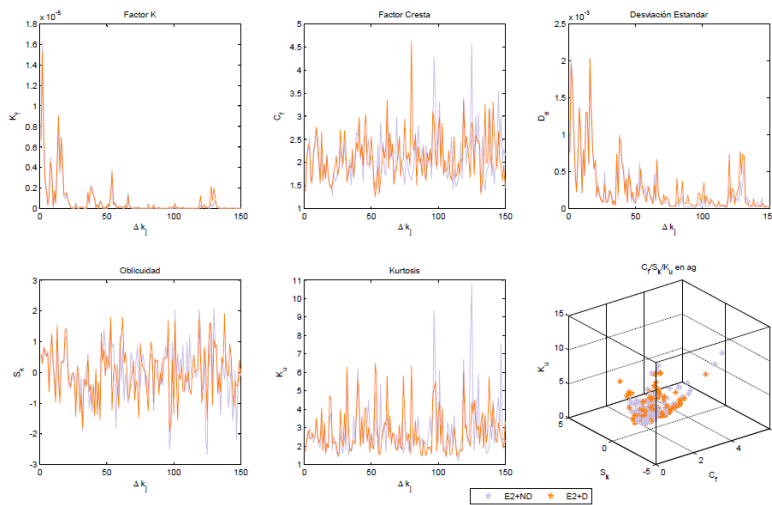


Figura 4.18: Características estadísticas para excitación E2. Planta baja.

4.5. Resultados y discusión

4.5.1. Extracción de características

Definiendo una muestra como $N=150$ mediciones consecutivas, se calcularon los valores de las características estadísticas para las señales de aceleración a_1 , a_2 y a_g . La variación de estos valores refleja el cambio de parámetros de la estructura afectando principalmente el valor máximo del Factor de cresta, siendo este alcanzado en un tiempo menor de excitación de la estructura, Figura 4.17, sin embargo, las características se notan estrechamente relacionadas con el cambio en la excitación, Figura 4.18, y no con el cambio paramétrico.

Por otro lado, la variación del valor de los momentos temporales en las muestras recolectadas, permite la diferenciación visual del cambio en el comportamiento de la estructura, Figura 4.19, sin que esto permita la diferenciación automática por medio de un algoritmo lineal.

Todos las características anteriores son obtenidas a partir de las señales de vibración

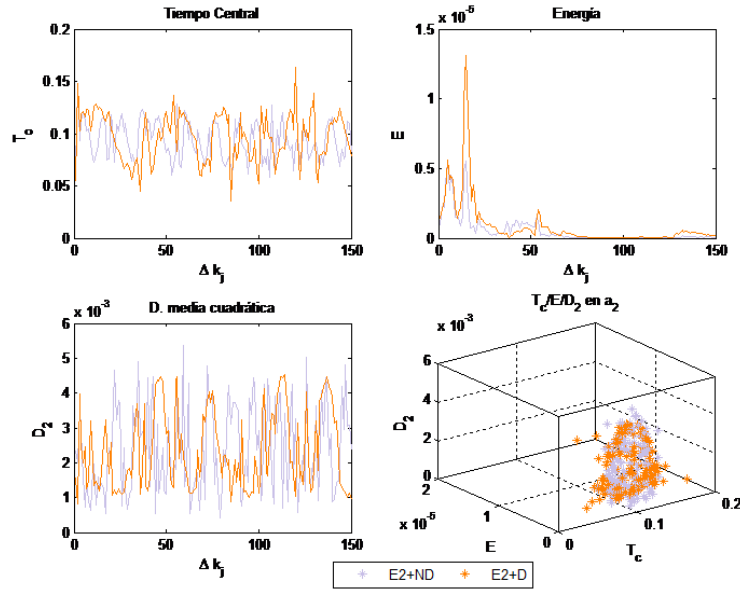


Figura 4.19: Tiempo Central de la señal de aceleración, del segundo nivel en E2.

recopiladas de los pisos de la estructura bajo análisis en el dominio del tiempo. La principal desventaja de su empleo es la dependencia con la señal de excitación del sistema, además, parte útil de la señal se encuentra oculta bajo señales de ruido [56]. Existen también conjuntos de características que pueden ser extraídas de la señal en el dominio de la frecuencia tales como las empleadas en [49] o en [51]. Estas características son tomadas del espectro de la señal de vibración y tienen la propiedad de estar directamente relacionadas con características de operación del sistema más que con las características relacionadas a la excitación del mismo [56]

4.5.2. Obtención de los Componentes Principales sobre Características Sensibles.

Los resultados mostrados a continuación emplean las características sensibles al daño listadas en la Tabla (4.1), considerando que se ha demostrado alta sensibilidad al daño para las características de valor mínimo, varianza, oblicuidad y kurtosis [24]. Cada señal de vibración en aceleración es seccionada en grupos de N datos discretos, que serán llamados *muestras* Δk_j , $j = 1, \dots, N$. Cada muestra es procesada para obtener el valor de sus características con el objetivo de observar la variación de las mismas a lo largo de la historia temporal de la señal. Se emplean únicamente los PCS necesarios, considerando una varianza mínima contenida de 85%.

4.5.3. Obtención de Características Sensibles sobre los Componentes Principales.

La obtención de los componentes principales permite la síntesis del comportamiento de la señal, sin embargo, al no ser suficiente esta información, es recomendable considerar la

Cuadro 4.1: Características sensibles empleadas

| Característica | Descripción |
|----------------|---------------------------------|
| K_f | factor K |
| C_f | factor de cresta |
| D_e | desviación estándar |
| S_k | Skewness |
| K_u | Kurtosis |
| E | Energía |
| T_C | Tiempo central |
| D_2 | Duración de la media cuadrática |

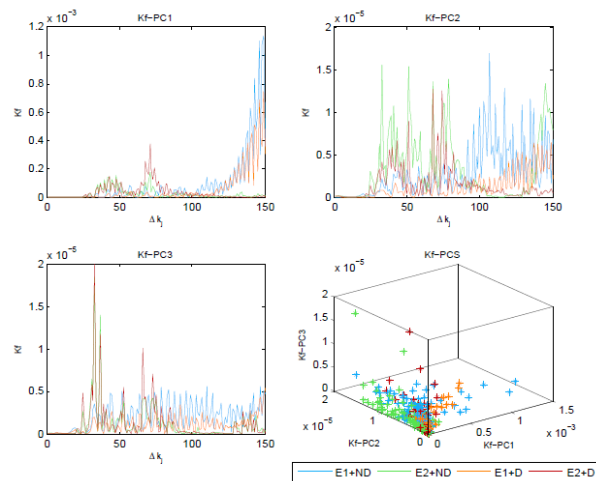


Figura 4.20: Factor K, calculado sobre PCs

dispersión de los datos en el dominio PC, la cual puede ser empleada como característica de clasificación. Dentro de este nuevo espacio dimensional, las características estadísticas proveen secuencias de datos cuya interpretación resulta de mayor simplicidad. Es posible observar, que la mayor variación con la presencia de daño en la estructura, no se encuentra sobre el primer componente principal, si no, sobre el segundo y el tercero. De modo que el clasificador tendrá mejores resultados al ser entrenado con estos últimos. Debe ser considerado también que las características de mayor sensibilidad al daño son el *Factor K*, Figura 4.20, la desviación estándar, Figura 4.22 y la medida de Kurtosis, Figura 4.24.

El clasificador puede ser entrenado para diferenciar cualquiera de las características estadísticas. Se logra un mejor resultado si se obtienen los componentes principales como última etapa de transformación.

La obtención de las características transitorias observa una mejor caracterización del daño en el segundo y tercer PC como se tenía previsto, Figura 4.25, sin embargo, contrario al desarrollo anterior, los valores máximos de Energía disminuyen para los datos obtenidos de la estructura sin daño, tanto para E1 como para E2; lo anterior debido a la discriminación de la energía principal contenida en la señal caracterizada por el primer PC, en el cual se puede

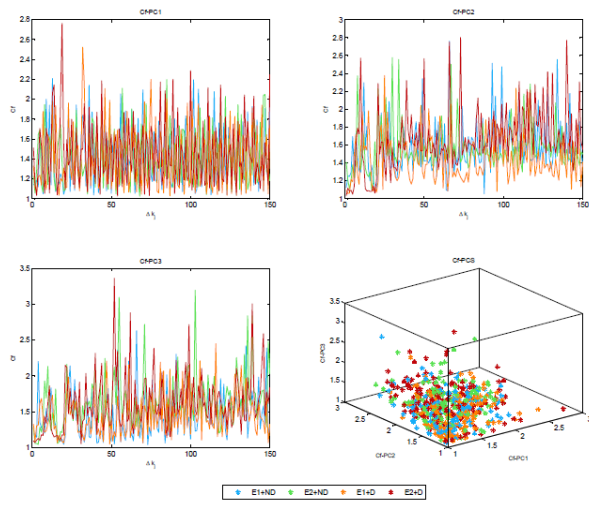


Figura 4.21: Factor cresta, calculado sobre los PCs

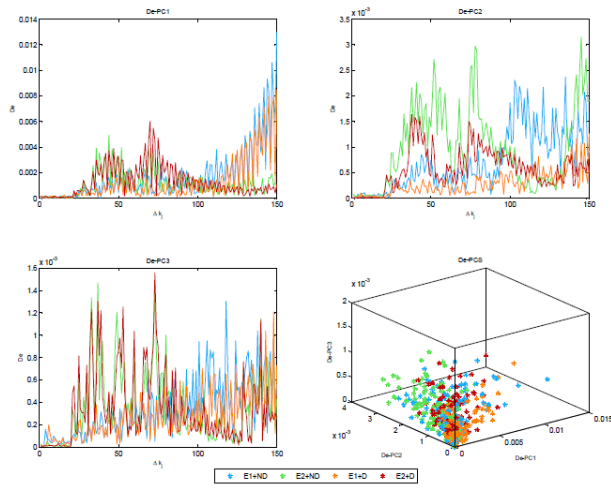


Figura 4.22: Desviación estándar, calculada sobre los PCs

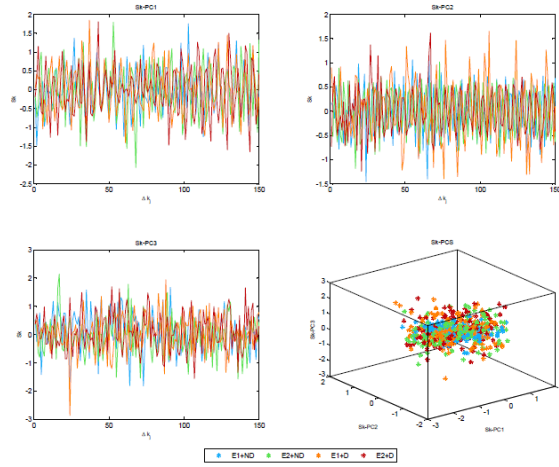


Figura 4.23: Oblicuidad, calculada sobre los PCs

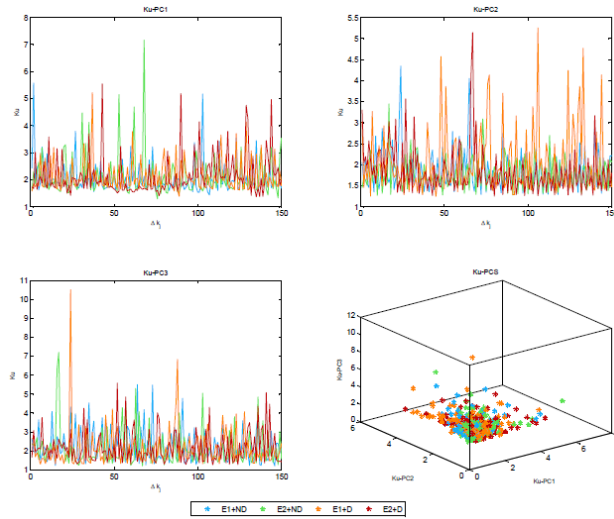


Figura 4.24: Kurtosis, calculado sobre los PCs

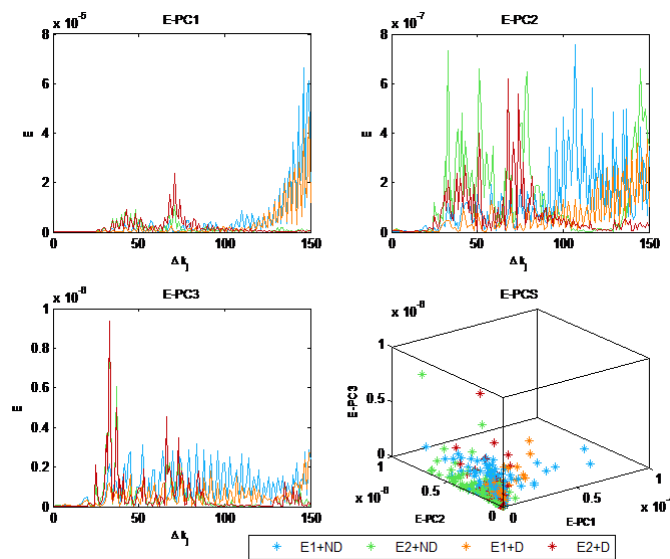


Figura 4.25: Energía de los PCs

observar un aumento de la energía conforme se incrementa la excitación de la estructura.

Las características transitorias arrojan resultados con menor variación y máximos mas distintivos en el segundo y tercer PC, para el cálculo del Tiempo Central empleando los valores para la Energía calculados sobre las señales de vibración de la estructura sin presencia de daño, Figura 4.26.

Si por el contrario, el valor de la energía se actualiza con el cambio de la estructura, entonces los valores para la característica T_c se ven afectados a modo de volverse indistinguibles para el análisis humano, Figura 4.27.

Como puede observarse, una sola característica no es suficientemente distintiva, notese la similitud entre los valores para el cálculo del tiempo central para el PC1, de las señales E1+ND y E1+D, constatandose unicamente que el área bajo la curva de la señal de la estructura sin daño, es mayor que el area bajo la curva de la señal con daño, Figura 4.28 en

el T_c del segundo PC, sin que esto sea un atributo constante.

4.5.4. KPCA

Tomando una muestra de 500 mediciones para la generación del hiperespacio KPCA, se obtienen nueve PCs para una varianza mínima del 85 %, para diferentes nucleos. Los PCs obtenidos durante el entrenamiento para las señales de aceleración en E1+ND son empleados para la transformación de los datos durante la fase de prueba para datos en E1+D, E2+ND y E2+D. La clasificación de las características para la detección de daño, se puede efectuar por medio de algoritmos lineales o no, tales como los empleados en el presente trabajo. El empleo del Kernel ERBF con $\sigma > 1$, implica un aumento del número de PC de forma proporcional a este parámetro, teniendo como mínimo 35 PCs. Es de gran importancia remarcar que, para obtener un modelo fiable es necesario el uso de una gran cantidad de muestras, lo que incrementa notablemente el tiempo de cómputo; llevar a cabo el análisis con todos los datos disponibles requiere de una capacidad de procesamiento alta por parte del hardware, de modo que es imperativo que la selección de las muestras de entrenamiento se realice de forma correcta, lo cual puede implicar hacer uso de conocimientos empíricos.

| PC | % RBF | Pol. grado 2 |
|----|-------|--------------|
| 1 | 33.66 | 45.42 |
| 2 | 51.01 | 68.92 |
| 3 | 63.19 | 81.63 |
| 4 | 74.23 | 89.53 |
| 5 | 79.75 | 96.5 |
| 6 | 83.75 | |
| 7 | 86.59 | |
| 8 | 88.88 | |
| 9 | 90.88 | |

OL-PCA

Empleando la segunda metodología OL-PCA, los datos de prueba son recreados a partir de la medición de las señales de aceleración bajo cierta señal de excitación, una vez que se ha alcanzado un valor de media estable para la ALD, se introduce un daño en la estructura, lo que cambia el comportamiento de las señales de vibración. Bajo esta simulación de daño ocurrido durante un sismo, se pueden remarcar tres resultados importantes:

1) La ALD requiere de una cantidad de muestras mínima para alcanzar una media estable, Figura 4.29 y Figura 4.30.

2) El cambio paramétrico de la estructura, introduce un nuevo periodo de aprendizaje para la condición ALD, Figura 4.31, lo que provoca un incremento en el valor de su media.

Este resultado es de gran utilidad para la detección de daño en sitio, bajo el mismo evento de excitación de la estructura.

3) Para la detección por software del daño infringido es posible considerar retrasos temporales en la señal ALD, de modo que un clasificador incluso lineal, podría clasificar los datos pertenecientes a la estructura dañada de los datos de la estructura sin daño, Figura 4.32.

El umbral ν , puede elegirse como $\nu = \text{máx}(\delta_{k+1})$ para $x_{k+1} \in X_{E+ND}$, o como $\nu = \delta_{k+1}$ tal que el error cuadrático medio del modelo PCA sea mínimo durante la fase de entrenamiento del modelo PCA.

Esta metodología para la detección de daño tiene la ventaja frente al PCA o al K-PCA de ser efectiva con los datos centrados. Esto evita la complicación del tratamiento previo de cada muestra adquirida para evitar que el tipo de sensor de adquisición, influya negativamente en los resultados del análisis.

Es posible también la creación de un modelo OL-PCA sobre las características estadísticas o transitorias revisadas en la sección 4.2.6 a 4.2.8.




Figura 4.26: Tiempo central, calculado bajo un valor preentrenado de Energía.

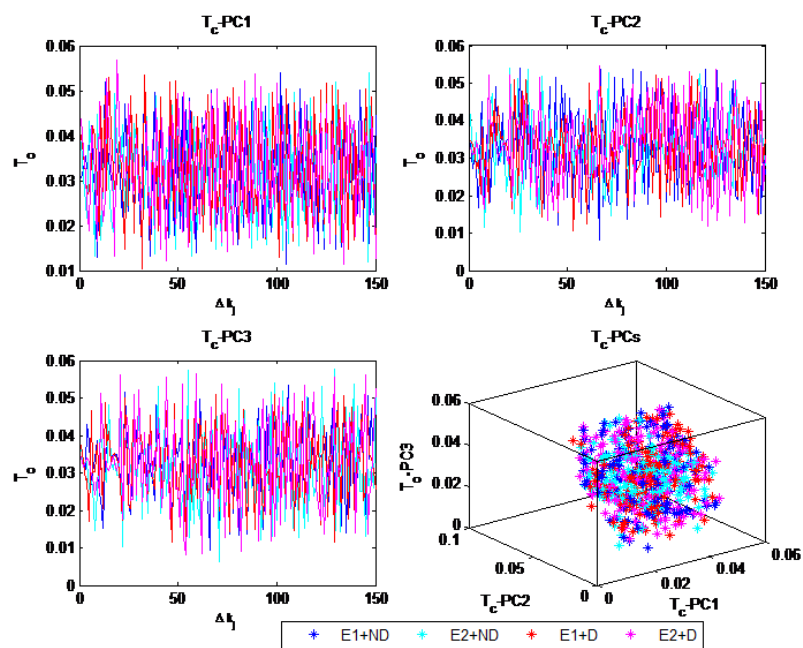


Figura 4.27: Tiempo Central de los PCs

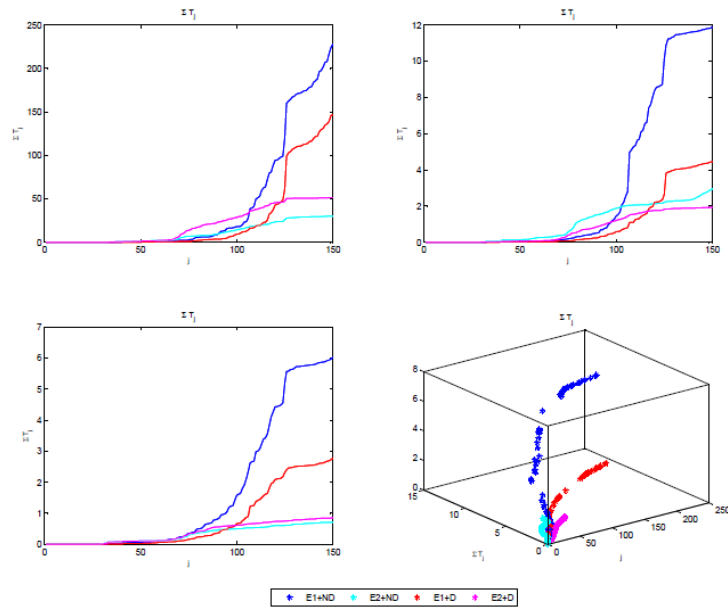


Figura 4.28: Suma Acumulativa del calculo del tiempo central sobre los PC.

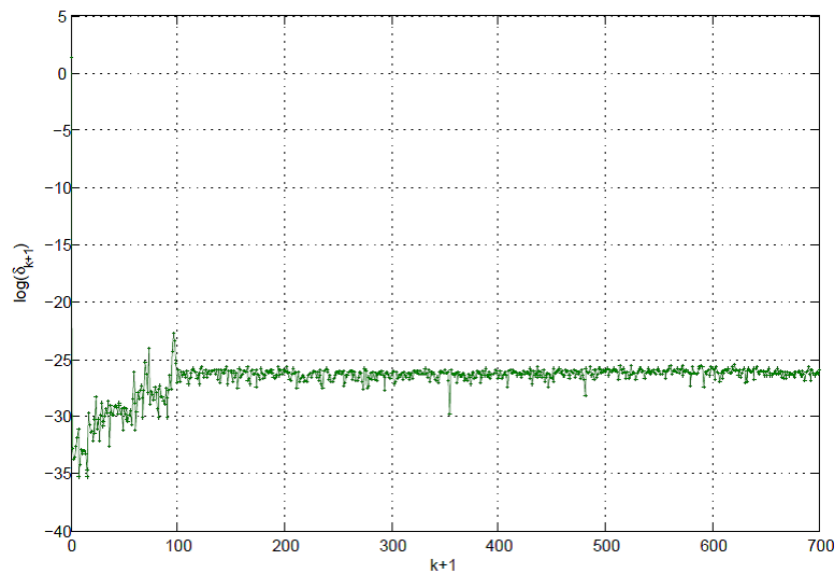


Figura 4.29: Condición ALD para señal de vibración E1+ND




Figura 4.30: Condición ALD para E1+ND, respuesta transitoria




Figura 4.31: Modificación de la ALD por el cambio paramétrico en la estructura.




Figura 4.32: Espacio creado por los valores de la ALD con un retraso de 2 tiempos.

Capítulo 5

Clasificadores

5.1. Máquinas de Soporte Vectorial (SVM) como clasificadores

Las máquinas de soporte vectorial (SVM, por sus siglas en inglés) fueron desarrolladas por Vapnik [53], para resolver problemas de clasificación, rama que puede ser denominada como Clasificación de Soporte Vectorial (SVC, por sus siglas en inglés). El SVC pertenece a la familia de clasificadores lineales, empleados para separar dos clases de datos mediante la búsqueda de un hiperplano óptimo. Este hiperplano busca mantener la distancia máxima posible a ambos grupos de datos, construyéndose a partir de los datos x^0 más cercanos entre clases. Esta selección de datos, permite la creación de Vectores de Soporte, los cuales se construyen sobre los x^0 como líneas paralelas al hiperplano.

Uno de los grandes problemas de los clasificadores por redes neuronales es el "sobreajuste", lo que conlleva la separación perfecta de los datos entrenados, sin que el hiperplano obtenido pueda garantizar la clasificación de otro conjunto de datos "nuevos". El SVM lidia de mejor forma con este problema siendo una metodología con mejor capacidad de generalización, sin embargo, para lograr minimizar este problema, es recomendable establecer un margen de error sobre la clasificación.

Esta metodología es empleada continuamente para la clasificación de datos o directamente el reconocimiento de fallas en combinación con otros métodos tales como Árboles de Decisión [46], discriminantes lineales [8], Kernel-PCA [26], lógica difusa [2], Kernel Spectral Clustering [29], Empirical Mode Decomposition [32], algoritmos genéticos [51].

El SVM puede ser extendido a clasificar más de dos clases de datos, con la aplicación de la metodología de manera secuencial, aislando una clase de datos de las demás en cada ciclo del algoritmo. Esta clasificación es llamada comúnmente Multiclass-SVM [20].

5.1.1. Metodología

La metodología tiene como objetivo encontrar la función que separe dos clases de datos, a partir de datos de entrenamiento disponibles, idealmente sin pérdida de generalidad. Esta función no es única, sin embargo se elegirá la que maximice la distancia entre la función y el punto de cada clase mas cercano a esta (margen ρ). Los vectores o datos son separables de manera óptima si no existen errores de clasificación y el margen es el máximo posible.

Considerando el problema de clasificación, se definen dos tipos de datos de entrenamiento completamente separables:

$$D = \{(x_1, y_1), \dots, (x_k, y_k)\}, \quad x \in \mathbb{R}^n, \quad y \in \{-1, 1\} \quad (5.1)$$

por medio del hiperplano dado por la ecuación (5.2), donde $w \in \mathbb{R}^n$ es un vector de pesos o coeficientes, bajo la restricción canonica de parámetros dada por la ecuación (5.3) [53] se define un hiperplano en forma canónica que satisface la restricción dada por la ecuación (5.4)

$$\langle w, x \rangle + b = 0 \quad (5.2)$$

$$\min_i |\langle w, x_i \rangle + b| = 1 \quad (5.3)$$

$$y_i [\langle w, x_i \rangle + b] \geq 1, \quad i = 1, \dots, k \quad (5.4)$$

Bajo esta restricción, el vector w esta definido tal que su norma debe ser igual al inverso de la distancia del punto mas cercano en el grupo de datos, al hiperplano, ecuación (5.5).

$$\min |\langle w, x_i \rangle + b| = 1 \quad (5.5)$$

$$\min |\langle w, x_i \rangle + b| = \frac{d^*(w, b; x)}{d^*(w, b; x)}$$

$$\|w\| \cdot d^*(w, b; x) = \min |\langle w, x_i \rangle + b|$$

$$d^*(w, b; x) = \frac{\min |\langle w, x_i \rangle + b|}{\|w\|}$$

De modo que la distancia de un punto x al hiperplano (w, b) es:

$$d(w, b; x) = \frac{|\langle w, x_i \rangle + b|}{\|w\|} \quad (5.6)$$

Sujeto a la restricción (5.4), se busca maximizar el margen ρ , en ambas clases para obtener el hiperplano óptimo, de modo que :

$$\rho(w, b) = \min_{x_i: y_i=1} d(w, b; x_i) + \min_{x_i: y_i=-1} d(w, b; x_i)$$

empleando la ecuación (5.6):

$$\rho(w, b) = \min_{x_i: y_i=1} \frac{|\langle w, x_i \rangle + b|}{\|w\|} + \min_{x_i: y_i=-1} \frac{|\langle w, x_i \rangle + b|}{\|w\|} \quad (5.7)$$

$$\rho(w, b) = \frac{1}{\|w\|} \left(\min_{x_i: y_i=1} |\langle w, x_i \rangle + b| + \min_{x_i: y_i=-1} |\langle w, x_i \rangle + b| \right)$$

De la ecuación (5.5) se tiene que:

$$\rho(w, b) = \frac{2}{\|w\|} \quad (5.8)$$

$$d(w, b; x_i) = \frac{\rho(w, b)}{2}$$

$$\frac{\|w\|}{\rho(w, b)} = \frac{\|w\|^2}{2}$$

De modo que, si los planos son paralelos y la separación entre ambos es $\rho(w, b)$, bajo la condición de que ningún vector del conjunto de entrenamiento se encuentra entre ellos, Figura 5.1, entonces la optimización consisten en buscar el mayor margen de separación $\rho(w, b)$ o minimizar la distancia del plano al punto más cercano de la clase correspondiente, lo que desemboca en el problema de minimización planteado por la ecuación (5.9), bajo la restricción (5.4)

$$\min_{w \in \mathbb{R}^n} \frac{1}{2} \|w\|^2 \quad (5.9)$$

El hiperplano es independiente del valor de b . Modificar este valor, permitirá el desplazamiento axial del hiperplano, como consecuencia el margen ρ permanecerá sin alteración, sin embargo se perderá la optimización, pues el hiperplano se encontrará a una menor distancia de una clase que se la otra. Por lo tanto, la solución del problema de optimización no se ve afectada por eliminar alguno de los vectores soporte, pero si lo es, si se agrega alguno que se encuentre entre los dos hiperplanos.

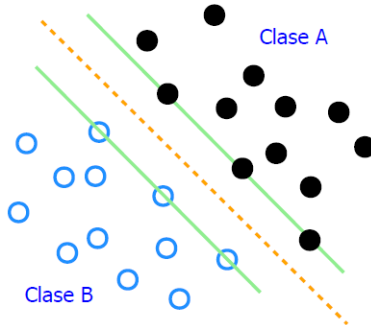


Figura 5.1: Hiperplanos para clases separables.

5.1.2. Caso linealmente separable

La solución al problema de optimización esta dada por el funcional de Lagrange, ecuación (5.10) [34], el cual debe ser minimizado respecto a w y b , y maximizado respecto a α .

$$\Psi(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i (y_i [\langle w, x_i \rangle + b] - 1) \quad (5.10)$$

donde α son los multiplicadores de Lagrange. Este funcional puede ser transformado en su problema dual, dado por:

$$\max_{\alpha} W(\alpha) = \max_{\alpha} \left(\min_{w, b} \Psi(w, b, \alpha) \right) \quad (5.11)$$

Obteniendo el mínimo con respecto a b se tiene la restricción $\sum_{i=1}^k \alpha_i y_i = 0$, y con respecto a w se obtiene que $w = \sum_{i=1}^k \alpha_i y_i x_i$, lo que concluye en el problema dual de la ecuación (5.12), cuya solución esta dada por (5.13), bajo la restricción de b , y de $\alpha \geq 0$.

$$\max_{\alpha} W(\alpha) = \max_{\alpha} \left(\sum_{l=1}^k \alpha_l - \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \right) \quad (5.12)$$

$$\alpha^* = \arg \min_{\alpha} \left(\frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle - \sum_{l=1}^k \alpha_l \right) \quad (5.13)$$

La solución a este problema de optimización, permite la definición del hiperplano como:

$$\begin{aligned} w^* &= \sum_{i=1}^k \alpha_i y_i x_i \\ b^* &= -\frac{1}{2} \langle w^*, x_A + x_B \rangle \end{aligned} \quad (5.14)$$

donde, x_A y x_B son algun vector del grupo de vectores soporte (SV), pertenecientes a cada una de las clases. Estos vectores serán aquellos que cumplan con la condición:

$$y_i [\langle w, x_i \rangle + b] = 1$$

El clasificador entonces, puede expresarse como:

$$f(x) = \varphi(z) = \varphi(\langle w^*, x \rangle + b) = \text{sgn} \left(\sum_{i \in SV} \alpha_i y_i \langle x_i, \bar{x} \rangle + b \right) \quad (5.15)$$

Si el conjunto de datos es linealmente sepalable, los vectores de soporte serán pocos y la cantidad de muestras de entrenamiento puede ser reducida.

Este clasificador es rigido o duro, pues trabaja bajo el supuesto de que ninguna muestra se encuentra entre los hiperplanos. Es la mayoría de los casos, mucho mas apropiado el uso de un clasificador suave, el cual permite cierto número de errores de clasificación, esto es:

$$\varphi(z) = \begin{cases} -1 & : z < -1 \\ z & : -1 \leq z \leq 1 \\ +1 & : z > 1 \end{cases} \quad (5.16)$$

5.1.3. Caso no linealmente separable

Generalmente, los datos de entrenamiento no son separables linealmente, por lo que la solución del problema sugiere un conocimiento previo del problema o una estimación del ruido contenido en la señal. Bajo esta premisa, se introduce una función de costo (5.17) asociada a los datos no clasificados, de modo que el problema de optimización se resuelve bajo la condición dada por (5.18), con $\xi_i \geq 0$, bajo lo cual las ecuaciones (5.9) y (5.10) se convierten en las ecuaciones (5.19) y (5.20), donde α , β son multiplicadores de Lagrange. Las ecuaciones (5.12) y (5.13), permanecen inalteradas como solución del problema bajo las nuevas restricciones dadas por (5.21) y (5.22).

$$F(\xi) = \sum_i \xi_i \quad (5.17)$$

$$y_i [\langle w, x_i \rangle + b] \geq 1 + \xi_i, \quad i = 1, \dots, k \quad (5.18)$$

$$\Psi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \quad (5.19)$$

$$\Psi(w, b, \xi, \beta) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_{i=1}^k \alpha_i (y_i [\langle w, x_i \rangle + b] - 1 + \xi_i) - \sum_{j=1}^k \beta_j \xi_j \quad (5.20)$$

$$0 \leq \alpha_i \leq C \quad (5.21)$$

$$\alpha_i + \beta_i = C$$

$$\sum_{j=1}^k \alpha_j y_j = 0 \quad (5.22)$$

El parametro C debe ser determinado reflejando el conocimiento del ruido contenido en los datos; puede elegirse con un valor de $C = 5$ [5].

5.1.4. Generalización en alta dimensión

Cuando los datos no son linealmente separables, pero incluso un hiperplano lineal con margen de error no es suficiente para llevar a cabo la clasificación de las muestras, el algoritmo SVM puede ser modificado para mapear los datos a un espacio de mayor dimensión $x \rightarrow z$ con $x \in \mathbb{R}^n$, $z \in \mathbb{R}^m$ y $n < m$. Este mapeo es realizado mediante el uso de una función no-lineal,

obteniendo como resultado un grupo de datos en un espacio en el cual son separables por el hiperplano diseñado. Las funciones $K(x_i, x_j)$ de mayor aceptación para llevar a cabo esta operación son las mismas que las empleadas para la aplicación de la metodología KPCA y son conocidas también como funciones Kernel.

Considerando lo anterior, el problema de optimización se convierte en :

$$\alpha^* = \arg \min_{\alpha} \left(\frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{l=1}^k \alpha_l \right) \quad (5.23)$$

manteniendo las restricciones (5.21) y (5.22) inalteradas. El hiperplano de clasificación, operante en el hiperespacio está dado por:

$$f(x) = \text{sgn} \left(\sum_{i \in SV} \alpha_i y_i K(x_i, x) + b \right) \quad (5.24)$$

donde

$$\begin{aligned} \langle w^*, x \rangle &= \sum_{i=1}^k \alpha_i y_i K(x_i, x) \\ b^* &= -\frac{1}{2} \sum_{i=1}^k \alpha_i y_i [K(x_i, x_A) + K(x_i, x_B)] \end{aligned} \quad (5.25)$$

5.1.5. Resultados y discusión

Para cada conjunto de características, es necesaria la identificación del tipo de clasificador a emplear. Los espacios de características y el clasificador propuesto se listan en la Tabla siguiente:

| # | Características | Separabilidad | Clasificador |
|----|---------------------------------------|------------------------|--------------|
| 1 | Aceleraciones no homogéneas por nivel | Linealmente | SVM rígido |
| 2 | Aceleraciones homogéneas por nivel | No linealmente | KSVM |
| 3 | Aceleraciones relativas a la entrada | No linealmente | KSVM |
| 4 | Aceleraciones relativas entre niveles | No linealmente | KSVM |
| 5 | Estadísticas | No linealmente | KSVM |
| 6 | PC de características estadísticas | No linealmente | KSVM |
| 7 | Caract. estadísticas de los PCs | No linealmente | KSVM |
| 8 | Características transitorias | No linealmente | KSVM |
| 9 | PCs de características Transitorias | No linealmente | KSVM |
| 10 | KPCA en aceleraciones homogéneas | No linealmente | SVM |
| 11 | Condición ALD | Linealmente con margen | SVM suave |

El resultado de la clasificación para todos los conjuntos de características puede mostrarse en un gráfico de dos dimensiones, sin importar la dimensión original de las muestras. El valor asignado por el clasificador para las características (1) a (10), *ceros* para muestras de una estructura sin daño y *uno* para muestras de una estructura con daño. El porcentaje de clasificación correcta de los datos obtenidos para la plataforma sin presencia de daño y con presencia del mismo, se muestran en la Tabla correspondiente, para cada uno de los clasificadores.

| Características | Clasificador | Eficiencia |
|-----------------|--------------|--------------|
| # 1 | SVM rígido | 100 % (Alta) |
| # 2 | KSVM | 40 % (Baja) |
| # 3 | KSVM | 70 % (Media) |
| # 4 | KSVM | <20 % (Baja) |
| # 5 | KSVM | <20 % (Baja) |
| # 6 | KSVM | <20 % (Baja) |
| # 7 | KSVM | <20 % (Baja) |
| # 8 | KSVM | <20 % (Baja) |
| # 9 | KSVM | <20 % (Baja) |
| # 10 | SVM | <20 % (Baja) |
| # 11 | SVM suave | 80 % (Alta) |

Es importante señalar, que únicamente se presentan resultados sobre datos de aceleración obtenidos directamente de sensores, sin embargo, mediante el uso de integradores [52] es posible emplear datos de velocidad y de posición, siendo aplicables todas las metodologías anteriores.

5.2. Árboles de Decisión como clasificadores

Los árboles de decisión son empleados para la selección de características [47], [13], de manera equivalente al PCA o para clasificación de las mismas [24], siendo posible la implementación simultánea de selección y clasificación. Existen otros algoritmos cuya superioridad sobre los árboles de decisión ha sido probada [36], tales como las redes de Bayes, sin embargo, los árboles de decisión son de fácil entendimiento e implementación, sin un gran consumo de tiempo y de mayor simplicidad que una red neuronal.

5.2.1. Metodología

El algoritmo C4.5, introducido por Quinlan [39] es un clasificador estadístico ampliamente usado basado en una representación matemática de un árbol con ramas, raíz, nodos y hojas, que definen análogamente las reglas de clasificación [24]. El algoritmo C4.5 consta de dos etapas de entrenamiento:

Etapa de crecimiento/construcción:

El árbol tiene una sola rama o nodo para todo el conjunto de datos de entrenamiento, conforme el grupo de datos S_b va particionandose en subconjuntos S_s , se agrega un nodo con su respectiva rama para cada S_s . La partición se realiza en base a un criterio de valores o sobre un atributo de una característica determinada. Este criterio de particion es calculado automáticamente durante la etapa de crecimiento conforme a la ganancia de información basada en la entropía. En Teoría de la información, la entropía es la medida de la insertidumbre contenida en una variable aleatoria; mientras que la ganancia de información, es la reducción esperada en la entropía ocasionada por la partición del conjunto de muestras bajo el valor de cierta característica. Esta ganancia se calcula segun la ecuación (5.26), en la cual, el segundo término es el valor esperado de la entropía después de llevar a cabo la partición de S_s bajo el valor conocido de la característica A :

$$G(S_s, A) = Entropia(S_s) - \sum_{v=1}^L \frac{|S_v|}{S_s} Entropia(S_v) \quad (5.26)$$

Donde $G(S_s, A)$ es la ganancia de información de una característica A relativa a un conjunto de muestras S_s , donde L es el número de salidas para el atributo A , $S_v = \{s \in S_s | A(s) = v\}$ es cada uno de los subconjuntos correspondiente a cada salida,

Por otro lado, la entropía mide la homogeneidad del conjunto de datos y esta dada por (5.27), donde P_i es la proporción de S_s , $frec(C_i, S_s)$ es número de casos incluidos en la clase C_i , $|S_s|$ es el número de casos en el conjunto de entrenamiento S_s y c es el número de clases.

$$Entropia(S_s) = \sum_{i=1}^c (-P_i \log_2 P_i) \quad (5.27)$$

$$P_i = \frac{frec(C_i, S_s)}{|S_s|}$$

El valor de la información correspondiente a la partición S_v , adquirida por la partición de S_s en L subconjuntos, corresponde a la ecuación (5.28), y la proporción de ganancia de $G(S_s, A)$ sobre $SvInfo(S_s, A)$, está dada por la ecuación (5.29). El atributo con mayor valor de ganancia $G_R(S_s, A)$, es tomado como la raíz del árbol de desición.

$$SvInfo(S_s, A) = -\frac{1}{2} \sum_{v=1}^L \left[\frac{|S_v|}{S_s} \log_2 \frac{|S_v|}{S_s} + \left(1 - \frac{|S_v|}{S_s}\right) \log_2 \left(1 - \frac{|S_v|}{S_s}\right) \right] \quad (5.28)$$

$$G_R(S_s, A) = \frac{G(S_s, A)}{SvInfo(S_s, A)} \quad (5.29)$$

De manera que el algoritmo es resumido en los siguientes pasos:

Paso 1. Calcular la entropía $Entropia(S_s)$.

Paso 2. Calcular el valor esperado de información $\sum_{v=1}^L \frac{|S_v|}{S_s} Entropia(S_v)$

Paso 3. Calcular la ganancia de información después de la partición $G(S_s, A)$

Paso 4. Calcular el valor de la información de la partición $SvInfo(S_s, A)$

Paso 5. Calcular la relación final de ganancia $G_R(S_s, A)$

Etapa de poda:

Debido a la pérdida de precisión por sobreentrenamiento (sobreajuste), es necesario eliminar las ramas menos útiles. Los métodos de poda se dividen principalmente en dos: los métodos de pre-poda y métodos de post-poda. Los primeros consisten en conocer el momento en el que debe detenerse el crecimiento del árbol y es aplicado durante la construcción del mismo. Los métodos de post-poda que son empleados después de permitir el crecimiento completo del árbol, la ventaja de emplear los métodos de post-poda sobre los métodos de pre-poda, es el uso de información global, sobre el uso de información local.

El algoritmo C4.5 emplea un método de poda basado en el error conformado por el acumulado de todos los errores de clasificación en un nodo en particular. La tasa de error es calculada como el límite superior de un intervalo de esperanza del 25 % para la media E/N de una distribución binomial $B(E/N)$ donde E/N es la proporción de errores de clasificación en el nodo en cuestión. esta técnica permite la simplificación de las ramas o la síntesis de nodos [6], [33], [40].

En resumen, el algoritmo C4.5 es un proceso de selección de los umbrales correctos para las características dadas, a fin de reducir los errores de clasificación, conociendo las clases requeridas. Un ejemplo numérico puede encontrarse en [49].

5.2.2. Resultados y discusión

El empleo del algoritmo C4.5 es de rápida implementación con un consumo bajo de tiempo de procesamiento, es posible implementarlo para cualquiera de los conjuntos de características seleccionados anteriormente. El árbol de decisión no es empleado para selección de las mejores características, sin embargo, se plantea como trabajo futuro. En la Tabla siguiente se muestra el porcentaje de eficiencia alcanzado por el clasificador, para cada conjunto de características. Es importante notar que, de manera similar al PCA, los resultados obtenidos con el clasificador dependen en gran medida de la calidad de los datos de entrenamiento.

| # | Características | Separabilidad | Eficiencia |
|----|---------------------------------------|------------------------|------------|
| 1 | Aceleraciones no homogéneas por nivel | Linealmente | >90 % |
| 2 | Aceleraciones homogéneas por nivel | No linealmente | 0 % |
| 3 | Aceleraciones relativas a la entrada | No linealmente | 0 % |
| 4 | Aceleraciones relativas entre niveles | No linealmente | 0 % |
| 5 | Estadísticas | No linealmente | <20 % |
| 6 | PC de características estadísticas | No linealmente | <20 % |
| 7 | Caract. estadísticas de los PCs | No linealmente | <30 % |
| 8 | Características transitorias | No linealmente | <20 % |
| 9 | PCs de características Transitorias | No linealmente | <20 % |
| 10 | KPCA en aceleraciones homogéneas | No linealmente | <20 % |
| 11 | Condición ALD | Linealmente con margen | >50 % |

En comparación de los resultados mostrados en la sección anterior, el algoritmo C4.5 implica alto incremento en el tiempo de clasificación, así como una disminución en la eficiencia de clasificación durante la fase de generalización.

Capítulo 6

Conclusiones y trabajo futuro

A fin de cumplir el objetivo de detectar un cambio paramétrico de la estructura en el menor tiempo posible (incluso, cuando la excitación aún no ha sido cesada) se demuestra que el empleo de la metodología de Analisis de Componentes Principales en Linea y el clasificador dado por un hiperplano SVM son suficientes. El uso de esta metodología se justifica cuando la señal recopilada de los sensores es altamente ruidosa y los parámetros de los dispositivos son desconocidos o no manipulables, a manera que los datos deben ser homogeneizados.

Sin embargo, entrenar un simple modelo PCA y utilizar un clasificador lineal tal como una red neuronal de una capa es eficiente para realizar el reconocimiento de un edificio dañado de uno que no lo está. Esta experimentación debe cumplir con el requerimiento de haberse realizado con una amplia variedad de señales de excitación, y contar con el conocimiento previo del estado de la estructura y las mediciones recopiladas durante este mismo estado, pues aquellas condiciones no incluidas en el análisis no serán reconocidas, por lo que el algoritmo no puede ser generalizado. Igualmente, exige un conocimiento específico de los parámetros del sistema de adquisición de datos, así como la necesidad del uso del offset de los sensores como una característica extra, de la cual hace uso el algoritmo. Sin esta característica, el sistema es incapaz de diferenciar una señal de otra.

El uso de características transitorias demuestra ser un método suficiente para diferenciar cambios en la estructura, remarcando el cambio en su energía. Es necesario llevar a cabo un mayor número de experimentos a fin de visualizar la proporción del cambio en relación a la modificación paramétrica realizada a la estructura.

La estructura puede modelarse como un sistema de n grados de libertad ($n - DOF$ o $MDOF$). El modelo construido tiene un error alto, por lo que es necesario verificar el tipo de sensores que se emplean durante el experimento y evaluar un cambio de especificaciones de los mismos.

Bibliografía

- [1] Rytter A. *Vibration based inspection of civil engineering structures*. PhD thesis, Aalborg University, 1993.
- [2] Shigeo Abe. Fuzzy support vector machines for multilabel classification. *Pattern Recognition*, 2015.
- [3] Peter Anderegg, Rolf Vrönnimann, and Urs Meier. Reliability of long term monitoring data. *Journal on Civil Health Monitoring*, 2013.
- [4] H. Khosravi A.R. Khaloo. Modified fish-bone model: A simplified mdof model for simulation of seismic responses of moment resisting frames. *Soil Dynamics and Earthquake Engineering*, 2013.
- [5] V. Blanz, B. Schölkopf, H. Bülthoff, C. Burges, V. Vapnik, and T. Vetter. Comparison of view-based object recognition algorithms using realistic 3d models. In C. von der Malsburg, W. von Seelen, J. C. Vorbrüggen, and B. Sendhoff, editors, *Artificial Neural Networks*, volume 1112 of *Springer Lecture Notes Computer Science*, pages 251–256, Berlin, 1996.
- [6] Leo Breiman, J.H. Friedman, and R.A. Olshen. *Classification and Regression Trees*. Wadsworth International Group, 1984.
- [7] Koh C.G., Hong B., and Liaw C.Y. Substructural identification for damage estimation of structures. *Structural Safety*, 19:121–140, 2003.
- [8] Asdrúbal López Chau, Xiaou Li, and Wen Yu. Support vector machine classification for large datadata using decision tree and fisher linear discriminant. *Future Generation Computer Systems*, 2014.
- [9] Adam C. Cobb, Jennifer E. Michaels, and Thomas E. Michaels. Experimental verification of a kalman filter approach for estimating the size of fastener hole fatigue cracks, 2008. Society of Photo-Optical Instrumentation Engineers.
- [10] TWI consultoría e investigación. Faq how can failure of pipelines and pressure vessels be prevented. Technical report, TWI, 2014.
- [11] Universidad Nacional de Quilmes Argentina. Filtro de kalman-bucy.

- [12] Artur Dubrawski and Norman Sondheimer. Techniques for early warning of systematic failures of aerospace components, 2011.
- [13] M. Elangovan, Babu Babu Devasenapati, N. R. Sakthivel, and K. I. Ramachandran. Evaluation of expert system for condition monitoring of a single point cutting tool using principal component analysis and decision tree algorithm. *Expert Systems with Application*, 2011.
- [14] Katsuhiko Emori and William C. Schnobrich. Analysis of reinforced concrete frame-wall structures for strong motion earthquakes. Technical report, Civil Engineering Department University of Illinois, 1978.
- [15] Diego F, Giraldo, and Shirley J. Dyke. *A structural health monitoring framework for civil structures*. PhD thesis, Washington University, 2006.
- [16] Charles R. Farrar and Keith Worden. *Structural Health Monitoring, a Machine Learning Perspective*. A John Wiley & Sons, Ltd., Publication, 2013.
- [17] Jeremiah Fasl, Todd Helwig, and Sharon L. Wood. Probabilistic method for estimating remaining fatigue life in steel bridges using measured strain data. *Civil Health Monitoring*, 2013.
- [18] Proveedor global de información de edificaciones. Base de datos emporis. Technical report, Emporis Statistics, 2014.
- [19] Steve R. Gunn. Support vector machines for classification and regression. Technical report, Universidad de Southampton, 1998.
- [20] Husheng Guo and Wenjian Wang. An active learning-based svm multi-class classification model. *Pattern Recognition*, 2015.
- [21] Jimmin He and Zhi-Fang Fu. *Modal Analysis*. Primera edición edition, 2001.
- [22] Howard H. M. Hwang and Yeng Keong Low. Seismic fragility analysis of plane frame structures. Technical report, Center for Earthquake Research and Information, Memphis State University, 1988.
- [23] Daniele Inaudi. Overview of 40 bridge structural health monitoring projects. Technical Report IBC 09-45, SMARTEC SA, Switzerland, Roctest Ltd, Canada, 2014.
- [24] R. Jegadeeshwaran and V. Sugumaran. Comparative study of decision tree classifier and best first tree classifier for fault diagnosis of automobile hydraulic brake system using statistical features. *Measurement*, 2013.
- [25] Mingxing Jia, Hengyuan Xu, Xiaofei Liu, and Ning Wang. The optimization of the kind and parameters of kernel function in kpca for process monitoring. *Computers and Chemical Engineering*, page 94104, 2012.

- [26] Xiangyang Jin, Lin Lin, Shisheng Zhong, and Gang Ding. Rotor fault analysis of classification accuracy optimization based on kernel principal component analysis and svm. *Procedia Engineering*, 2011.
- [27] Naveet Kaur and Suresh Bhalla. Feasibility of energy harvesting from thin piezo patches via axial strain (d31) actuation mode. *Journal on Civil Health Monitoring*, 2013.
- [28] Jochen H. Kurz, Laurent Laguerre, Frank Niese, Laurent Gaillet, Klaus Szielasko, Ralf Tschuncky, and Fabien Treysede. Ndt for need based maintenance of bridge cables, ropes and pre-stressed elements. *Civil Health Monitoring*, 2013.
- [29] Rocco Langone, Carlos Alzate, Bart De Ketelaere, Jonas Vlasselaere, Wannes Meert, and Johan A.K. Suykens. Ls-svm based spectral clustering and regression for predicting maintenance of industrial machines. *Engineering Applications of Artificial Intelligence*, 2015.
- [30] Sauro Liberatore, Jason L. Speyer, and Andy Chunliang Hsu. Application of a fault detection filter to structural health monitoring. *Automática*, 2006.
- [31] Werner Lienhart. Challenges in the analysis of inhomogeneous structural monitoring data. *Civil Health Monitoring*, 2013.
- [32] Xiaofeng Liu, Lin Bo, and Honglin Luo. Bearing faults diagnostics based on hybrid ls-svm and emd method. *Measurement*, 2015.
- [33] J. Mingers. An empirical cocomparison pruning method for decision tree induction. *Machine Learning*, 4:227–243, 1989.
- [34] M. Minoux. *Mathematical Programming: Theory and Algorithms*. John Wiley and Sons, 1986.
- [35] Andrea Mordini, Konstantin Savor, and Helmut Wenzel. The finite element model updating: A powerful tool for structural health monitoring. Technical report, VCE-Vienna Consulting Engineers, 2007.
- [36] V. Muralidharan and V. Sugumaran. A comparative study of native bayes classifier and bayesnet classifier for fault diagnosis of monoblock centrifugal pump using wavelet analysis. *Journal of Applied Soft Computing*, 2012.
- [37] Daniel Arceo Mari nelarena. Diseo de algoritmos genéticos para la detección de daños en estructuras. In *8vo Congreso Internacional de Ingeniería*, 2012.
- [38] Anun Patjawit and Chaiyuth Chinnarasri. Simplified evaluation of embankment dam health due to ground vibration using dam health index (dhi) approach. *Civil Health Monitoring*, 2013.

- [39] J. R. Quinlan. Improved use of continuous attributes in c4.5. *Journal of Artificial Intelligence Research*, 4:77–90, 1996.
- [40] J.R. Quinlan. Simplifying decision tree. *International Journal of Man-Machine Studies*, 27:221–234, 1987.
- [41] Álvaro Solera Ramírez. El filtro de kalman. Technical Report Nota técnica DIE-02-2003-NT, Banco Central de Costa Rica, 2003.
- [42] Sanjay S.P. Rattan and William W. Hsieh. Complex-valued neural networks for nonlinear complex principal component analysis. *Neural Networks*, 18:6169, 2005.
- [43] Michael Roussel, Branko Glisic, Joo Ming Lau, and Chor Cheong Fong. Long-term monitoring of high-rise buildings connected by link bridges. *Civil Health Monitoring*, 2013.
- [44] Seyed Kazem Sadat S. and Hamid Reza V. Optimal sensor placement in the light-weight steel framing structures using the novel ttfd approach subjected to near-fault earthquakes. *Journal on Civil Health Monitoring*, 2013.
- [45] R.Vidya Sagar and B. K. Raghu Prasad. Laboratory investigations on cracking in reinforced concrete beams using on-line acoustic emission monitoring technique. *Civil Health Monitoring*, 2013.
- [46] M. Saimurugan, K.I. Ramachandran, V. Sugumaran, and N. R. Sakthivel. Multi component fault diagnosis of rotational mechanical system based on decision tree and support vector machine. *Expert Systems with Applications*, 2011.
- [47] N .R. Sakthivel, V. Sugumaran, and S. Babudevasenapati. Vibration based fault diagnosis of monoblock centrifugal pump using decision tree. *International Journal of Expert Systems with Applications*, 2010.
- [48] V. Sugumaran, V. Muralidharan, and K.I. Ramachandran. Feature selection using decision tree and classification through proximal support vector machine for fault diagnostics of roller bearing. *Mechanical Systems and Signal Processing*, page 930942, 2007.
- [49] Weixiang Sun, Jin Chen, and Jiaqing Li. Decision tree and pca-based fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 2007.
- [50] Jian Tang, Tianyou Chai, Wen Yu, and Lijie Zhao. On-line principal component analysis with application to process modeling. *Neurocomputing*, 2011.
- [51] Jian Tang, Tianyou Chai, Wen Yu, and Lijie Zhao. Feature extraction and selection based on vibration spectrum with application to estimating the load parameters of ball mill in grinding process. *Control Engineering Practice*, 2012.

- [52] Suresh Thenozhi, Wen Yu, and Rubén Garrido. Novel numerical integrator for velocity and position estimation. *Transactions of the Institute of Measurement and Control*, 35(6):824–833, 2013.
- [53] V. Vapnik. *The Nature of Statistical Learning Theory*. Springer N. Y., 1995.
- [54] Wikipedia. List of longest bridges in the world, 2014.
- [55] Shutao Xing, Marvin W. Halling, and Shuwen Pan. Application of substructural damage identification using adaptative kalman filter. *Civil Health Monitoring*, 2013.
- [56] Y. Zeng and Forsberg E. Monitoring grinding parameters by vibration signal measurement- a primary application. *Minerals Engineering*, 1994.