

**DESARROLLO DE UNA METODOLOGÍA PARA LA DETECCIÓN DE FALLAS
A PARTIR DEL ANÁLISIS DE VIBRACIONES EN RODAMIENTOS USANDO
CARACTERÍSTICAS DE TIEMPO Y MODELOS OCULTOS DE MARKOV
(HMM)**

Henry Alexander Blandón Hurtado
Yamir Fernando Martínez Mendoza

Proyecto presentado como requisito parcial para optar al título de:
Ingeniero Electricista

Director:
Ph.D (C), M.Sc. Ing. Mauricio Holguín Londoño
Profesor Programa de Ingeniería Eléctrica

Universidad Tecnológica de Pereira
Facultad de Ingeniería Eléctrica
Pereira, Risaralda, Colombia
2013

RESUMEN

Evitar la ocurrencia de posibles fallas en una máquina es de vital importancia para garantizar una operación confiable y segura de una instalación. Anticipar y evitar potenciales anomalías en un equipo, minimiza el riesgo de que una máquina quede fuera de servicio como consecuencia de una falla. Los rodamientos son un componente esencial en cualquier máquina eléctrica, su capacidad de carga y confiabilidad son importantes para el desempeño general de la máquina. La función de los diferentes tipos de rodamientos es proporcionar el deslizamiento del rotor dentro del estator manteniendo un espacio de aire uniforme. La detección y diagnóstico de fallas, en las primeras etapas de desarrollo de una anomalía, son necesarios para evitar su mal funcionamiento durante su operación. Una de las herramientas fundamentales con que se cuenta en la actualidad para el mantenimiento predictivo orientado al tratamiento de fallas tempranas en los rodamientos de una máquina es la medición y análisis de vibraciones.

El presente proyecto de grado trata el tema del análisis de vibraciones, en el contexto del mantenimiento predictivo, enfocado al tratamiento de fallas prematuras e incipientes en los rodamientos, específicamente defectos localizados en el anillo interior, los elementos rodantes (bola) y la pista de rodadura exterior; utilizando el dominio del tiempo como técnica para el análisis de las señales.

Previamente se desarrollan conceptos importantes que permiten entender el procedimiento en el diagnóstico de fallas en rodamientos, enfocada exclusivamente en la etapa de detección, ya que en la literatura, las etapas de cuantificación y localización son aún subjetivas a un conocimiento a priori que se tenga de la máquina. Empleando un análisis documental, se estudian los principios básicos de los rodamientos, se hace énfasis en sus fallas más comunes; además, se obtienen las definiciones y la información general referente a la implementación de un sistema capaz de diagnosticar fallas en rodamientos.

Con el objetivo de simplificar y cambiar la representación de las señales en otras más significativas que faciliten su análisis, se segmentan las señales de vibraciones de una base de datos con prueba de rodamientos normales y defectuosos, proporcionados por el Bearing Data Center de la Western Reserve University; permitiendo así, alimentar el proceso de extracción de características.

Buscando maximizar el éxito potencial de la fase de clasificación y a su vez el rendimiento global del sistema, las señales de vibración originales son sometidas a un pre-procesamiento con el fin de realizar una óptima extracción de características. A partir de la creación de una representación manejable y significativa de las señales, se calculan y recolectan los atributos de las mismas en un formato de vector compacto que emplea el dominio del tiempo como espacio de representación.

Se emplean los fundamentos básicos en los que se basa el aprendizaje de máquina, para implementar un sistema clasificador basado en Modelos Ocultos de Markov (HMM) con una distribución de observación discreta que permita decidir a qué clase corresponde cada una de las fallas en los rodamientos. Mediante la implementación de un algoritmo para el

entrenamiento y la clasificación de la base de datos basados en los modelos ocultos de Markov, se verifica el desempeño del sistema de clasificación con diferentes pruebas.

Inicialmente se realiza un estudio de la calidad diagnóstica del sistema de clasificación para varios casos en los que se modifica el número de estados de los modelos ocultos de Markov (en el intervalo [2, 6]), con el fin de seleccionar el modelo posiblemente más óptimo descartando los modelos subóptimos. A partir de los resultados entregados por el clasificador después de hacer un barrido sobre un conjunto de K vectores representativos o centroides de la señal [2,4,6,8,10,12,14,16,20,24,28,32], empleando el 70% de los datos para el entrenamiento y el 30% restante para la validación, se construyen las curvas de evaluación de desempeño ROC, las cuales expresan la calidad del clasificador en términos de la sensibilidad (cociente entre el número de registros con falla correctamente clasificados y el número total de datos con falla) y 1- especificidad (cociente entre el número de registros normales incorrectamente clasificados y el número total de datos normales o sin falla.).

A continuación se efectúan pruebas para encontrar de entre el conjunto [2,4,6,8,10,12,14,16,20,24,28,32], el número óptimo de vectores representativos o centroides de las señales de vibración de entrenamiento. La tasa de acierto o exactitud diagnóstica final del sistema se evalúa a partir del cálculo de parámetros como las tasas de verdaderos positivos (tvp) (cociente entre el número de registros con falla correctamente clasificados y el número total de datos con falla), falsos negativos (tfn) (cociente entre el número de registros con falla incorrectamente clasificados y el número total de datos con falla), verdaderos negativos (tvn) (cociente entre el número de registros normales correctamente clasificados y el número total de datos normales o sin falla) y falsos positivos (tfp) (cociente entre el número de registros normales incorrectamente clasificados y el número total de datos normales o sin falla), presentados por medio de matrices de confusión [42].

Después de definir el número de estados y el número de centroides óptimos, se realiza una prueba de relevancia con el fin de discriminar aquellas características que no posean un aporte significativo al proceso de clasificación y que por el contrario puedan minimizar el óptimo rendimiento de los algoritmos de estimación de parámetros para los modelos ocultos de Markov. Finalmente se analizan los tiempos de ejecución de cada prueba efectuada, con el fin de determinar la conveniencia o no de elegir como óptimos los parámetros de entrada (número de estados, número de centroides, porcentaje (entrenamiento-validación)) que mejores resultados le brinden al clasificador en términos de calidad y exactitud diagnóstica, buscando siempre obtener los mayores y mejores resultados al menor costo computacional posible. Con base en lo anterior, se realizan las respectivas conclusiones.

CONTENIDO

Parte 1: Preliminares	7
Capítulo 1. Introducción	8
Capítulo 2. Definición del problema	11
Capítulo 3. Justificación	13
Capítulo 4. Objetivos	15
4.1. General	15
4.2. Específicos	15
Parte 2: Marco Teórico	16
Capítulo 5. Generalidades	17
5.1. Mantenimiento predictivo.....	18
5.2. Diagnóstico de fallas	20
5.3. Vibración	21
Capítulo 6. Análisis de Vibraciones	23
6.1. Enfoques del Análisis de Vibraciones	23
6.1.1. <i>Análisis Tradicional</i>	24
6.1.2. <i>Análisis Investigativo</i>	24
6.2. Técnicas de análisis de vibraciones	24
6.2.1. <i>Análisis en el dominio del tiempo (Forma de la onda)</i> ...	25
6.2.2. <i>Análisis espectral FFT (Fast Fourier Transformation)</i> .	25
6.2.3. <i>Análisis de fase de vibraciones</i>	25
6.2.4. <i>Análisis de los promedios sincrónicos en el tiempo</i>	25
6.2.5. <i>Análisis de órbitas</i>	26
6.2.6. <i>Análisis de demodulaciones</i>	26
6.2.7. <i>Análisis de vib. en partidas y paradas de una máquina</i> ...	26
6.2.8. <i>Transformadas tiempo-frecuencia</i>	26
Capítulo 7. Contexto Mecánico	27
7.1. Fallas detectadas por el análisis de vibraciones.....	28
7.1.1. <i>Desbalance</i>	28
7.1.2. <i>Desalineación</i>	29
7.1.2.1. <i>Desalineación Paralela</i>	30
7.1.2.2. <i>Desalineación Angular</i>	30
7.1.3. <i>Soltura mecánica</i>	31
7.1.3.1. <i>Clase A</i>	31
7.1.3.2. <i>Clase B</i>	31
7.1.3.3. <i>Clase C</i>	32
7.1.4. <i>Eje doblado</i>	32
7.2. Rodamientos.....	33
7.2.1. <i>Fallas en rodamientos</i>	33
7.2.2. <i>Estructura de un rodamiento</i>	35
7.2.3. <i>Diámetros</i>	36
7.2.4. <i>Frecuencias características en los rodamientos</i>	37
Capítulo 8. Proceso de Clasificación de Fallas	38
8.1. Segmentación	39

8.2. Espacios de Representación.....	41
8.2.1. <i>Análisis temporal</i>	41
8.2.2. <i>Análisis Frecuencial</i>	44
8.2.3. <i>Análisis Tiempo-Frecuencia</i>	45
8.3. Extracción y selección de características.....	46
8.4. Clasificación.....	47
8.4.1. <i>Modelos Ocultos de Markov(HMM)</i>	48
8.4.1.1. <i>Elementos que conforman un HMM</i>	51
8.4.1.2. <i>Los tres problemas básicos de los HMM</i>	52
8.4.2. <i>Libro de Código</i>	53
8.4.2.1. <i>Clustering</i>	55
8.4.2.2. <i>K-means</i>	55
Parte 3: Marco Metodológico	57
Capítulo 9. Desarrollo Experimental	58
9.1. Base de Datos	59
9.2. Segmentación	61
9.3. Extracción de Características.....	62
9.4. Clasificación	67
Capítulo 10. Metodología	71
10.1. Prueba 1 (Prueba de modelos)	72
10.2. Prueba 2 (Prueba de libro de códigos)	73
10.3. Prueba 3 (Análisis de relevancia)	73
Parte 4: Resultados y Discusiones	74
Capítulo 11. Prueba 1 (Prueba de Modelos)	75
11.1. HMM de Dos (2) estados.....	76
11.2. HMM de Tres (3) estados.....	78
11.3. HMM de Cuatro (4) estados	79
11.4. HMM de Cinco (5) estados	80
11.5. HMM de Seis (6) estados.....	81
11.6. Conjunto (entrenamiento-validación) óptimo	84
Capítulo 12. Prueba 2(Prueba de libro de código)	86
Capítulo 13. Prueba 3(Análisis de relevancia)	90
13.1. Entrenamiento con características en orden aleatorio.....	93
13.2. Entrenamiento con características en orden ascendente	94
13.3. Entrenamiento con características en orden descendente ...	95
Capítulo 14. Prueba 4(Análisis de tiempo de ejecución)	97
14.1. Análisis de tiempo de ejecución (Prueba de Modelos)	98
14.2. Análisis de tiempo de ejecución (Prueba conjunto (entrenamiento-validación))	100
14.3. Análisis de tiempo de ejecución (Prueba de libro de códigos)	103
14.4. Análisis de tiempo de ejecución (Prueba de relevancia) ...	105
Parte 5: Conclusiones	107
Bibliografía	

PARTE 1
PRELIMINARES

CAPITULO 1

INTRODUCCIÓN

La utilización de la medición y el análisis de vibraciones como herramienta para la determinación e identificación de fallas en procesos industriales, viene siendo desarrollado e investigado desde hace más de tres décadas. La mayoría de plantas industriales están compuestas por diferentes tipos de máquinas rotativas, que en conjunto forman parte de un sistema que posibilita la conversión de materia prima en productos terminados que son utilizados cotidianamente por el hombre. Debido al incremento exponencial de la población mundial, crece la demanda de productos que necesitan ser procesados diariamente trayendo como consecuencia el aumento proporcional en la complejidad y cantidad de procesos que necesitan ser controlados, originado así, una necesidad cada vez mayor de desarrollar metodologías de mantenimiento enfocadas en la obtención de la máxima productividad de estos sistemas.

La identificación temprana de fallas en una planta industrial se constituye en uno de los requerimientos principales en el logro de dicho objetivo, ya que permite mejorar el rendimiento de los procesos y evita que se presenten futuros inconvenientes que impidan a los sistemas trabajar dentro de los parámetros de diseño establecidos. Tradicionalmente el análisis y diagnóstico de fallas ha dependido de los conocimientos de un técnico encargado del mantenimiento y, por consiguiente, su diagnóstico era algo relativo ya que el acierto estaba sujeto, en gran medida, a la capacidad del técnico para interpretar anomalías asociadas a un sonido, calentamiento, movimiento y al modo de vibración que se pudieran presentar en una máquina.

A diferencia de lo que sucede en países en vía de desarrollo, donde se emplea un análisis de vibraciones con base en sistemas simples, que poseen una limitada capacidad de diagnóstico; en países desarrollados, con alto nivel tecnológico, el análisis de vibraciones como herramienta investigativa para diagnosticar fallas en máquinas rotativas, ha suscitado un gran impacto en la industria por sus beneficios económicos y su capacidad para evaluar, de manera prematura, una posible anomalía en los sistemas. En el caso de las máquinas rotativas, la ventaja que presenta el análisis vibratorio respecto a otras técnicas más tradicionales, es que poseen un carácter no invasivo y una gran capacidad para detectar fallos mientras la máquina funciona en condiciones normales, evitando así pérdidas de producción generadas por el paro de los equipos cuando se les realiza un mantenimiento correctivo.

Las señales de vibración en una máquina proporcionan información acerca del comportamiento de la misma, gracias a la conducta mecánica que poseen los componentes que la conforman y a su comportamiento dinámico originado por la interacción de los mismos. Dicha información ayuda a determinar el estado de salud de la máquina, relacionando un elemento del equipo a un comportamiento en particular [5].

El análisis de vibraciones abarca todo el proceso de reconocimiento y clasificación de patrones en las señales de vibración, y esta fraccionado en varias fases de acuerdo a la teoría de aprendizaje de máquina, como son el espacio de representación, la extracción de características, la reducción de dimensionalidad y la clasificación junto con la identificación [41].

La fase de clasificación, dentro del proceso de análisis de señales de vibración, es una parte muy importante y se considera como la tarea final de procesado, ya que, una vez definido el diseño del montaje del banco de pruebas, recogidos los datos y pre-procesados eficazmente, la etapa final es la implementación de un clasificador que permita identificar a qué clase corresponde cada una de las señales de vibración.

Diversas técnicas han sido utilizadas para la caracterización de señales de vibración en el diagnóstico de fallas en rodamientos, principalmente se han utilizado aquellas que emplean características en el dominio de la frecuencia, las cuales demandan un cierto nivel de carga computacional. No obstante, es posible realizar otro tipo de caracterización evaluando un conjunto de características en el dominio del tiempo que permitan extraer información sobre fallas en rodamientos y proporcionar un mejor rendimiento computacional global del sistema.

Por esta razón y para contribuir en la búsqueda de evaluar alternativas más económicas computacionalmente hablando, pero que preserven fiabilidad en la clasificación de fallas, este proyecto de grado está orientado al empleo de características del dominio tiempo en el análisis de señales de vibraciones para el diagnóstico de fallas en rodamientos en máquinas rotativas. El objetivo principal ha sido realizar la clasificación de señales de vibración para una base de datos de una prueba de rodamientos para cuatro estados de salud, a saber: rodamientos en buen estado (Normal), falla en el anillo interior (Inner), falla en los elementos rodantes (ball) y falla en la pista de rodadura exterior (Outer). Esta base datos pertenece al Bearing Data Center de la Western Reserve University [34].

Se desea identificar la pertenencia, o no, de una señal a uno de los cuatro estados de salud, utilizando en el proceso de identificación de fallas como técnica inteligente de clasificación los Modelos Ocultos de Markov (HMM) con una distribución de observación discreta, los cuales se constituyen como una herramienta útil y ampliamente utilizada para la estimación de estados no observados con base en características si observadas. Mediante la implementación de un algoritmo para el entrenamiento y la clasificación de la base de datos basados en los modelos ocultos de Markov, se verifica el desempeño del sistema de clasificación con diferentes pruebas.

Partiendo con la identificación de un conjunto de características que puedan ser extraídas de las señales de vibración, estas son segmentadas en celdas y se extraen los valores de cada característica por cada celda para todas las señales; luego, dichos valores extraídos son llevados al mismo espacio y a través de un análisis de relevancia, las características que generan información redundante son descartadas, quedando solo aquellas que proporcionan información de real importancia acerca de la señal.

En general, el trabajo se desarrolla en cinco fases principales, basadas en los objetivos específicos. Estas fases se llevan a cabo siguiendo una secuencia de actividades que permiten obtener los resultados de forma pertinente y apoyada en la técnica de análisis sistémico como método científico. Se modela un sistema clasificador de fallas basado en Modelos ocultos de Markov (HMM) mediante la determinación de sus componentes o fases como son, la extracción de características, el entrenamiento y validación de los modelos y la clasificación de fallas; de igual manera, los algoritmos para cada fase están desarrollados en el entorno integrado con el software MATLAB, y se hace uso de las herramientas disponibles para el entrenamiento y clasificación de modelos usando HMM. Cabe resaltar que el sistema clasificador se conforma de algoritmos modulares utilizables por cada fase, permitiendo verificar su buen funcionamiento a medida que se implementa el sistema.

CAPITULO 2

DEFINICIÓN DEL PROBLEMA

En la actualidad, el diagnóstico de fallas sigue siendo un requerimiento indispensable en toda planta industrial del mundo. En los últimos años ha tenido una gran evolución debido principalmente a la aparición de sistemas cada vez más complejos que traen consigo un incremento en la cantidad de procesos que necesitan ser controlados. Como respuesta a dichas necesidades producto de los mismos cambios tecnológicos, han surgido distintas metodologías y teorías para la detección e identificación de fallas como solución a problemas que pueden perjudicar el correcto funcionamiento de dichos procesos.

Una planta industrial, como un sistema integral donde intervienen diferentes tipos de variables a medir y complejos procesos, requiere que características como la alta calidad y el excelente desempeño de sus equipos sean objetivos primarios que permitan garantizar el cumplimiento de parámetros tan importantes como son la seguridad y la confiabilidad. La confiabilidad es el factor tras la seguridad, donde se centra la mayoría de los propósitos en el desarrollo y mantenimiento de los elementos relacionados con un sistema. Por confiabilidad se entiende la capacidad que posee un elemento de realizar una función requerida bajo condiciones dadas para un intervalo de tiempo dado. La confiabilidad puede ser expresada en términos de disponibilidad, entendiendo esta como la medida del estado del equipo en un momento dado cuando es requerido para su funcionamiento [1].

Uno de los parámetros que contribuye a la disponibilidad del equipo es la mantenibilidad. En el mantenimiento se consideran los efectos de los fallos del equipo y la forma de minimizarlos. Las distintas técnicas de mantenimiento generalmente han sido centradas en la confiabilidad, donde se emplea una metodología de análisis objetivo, sistemático y documentado; enfocándose en el mantenimiento preventivo de los elementos críticos del equipo, así como, en un mantenimiento correctivo en los elementos no críticos de dicho equipo [2],[3].

Pero el problema surge cuando lo que se busca es garantizar la competitividad de la empresa, asegurando niveles adecuados de confiabilidad y disponibilidad de los equipos, respetando los requerimientos de calidad y seguridad, que solo pueden ser garantizados por el hecho de que todo activo físico continúe desempeñando de forma ininterrumpida las funciones programadas. Es por eso que aunque el mantenimiento preventivo se base en acciones destinadas a mantener los equipos en buenas condiciones de funcionamiento y evitar fallas, el hecho de tener que realizar intervenciones a intervalos fijos para sustituir y/o reparar componentes, se convierte en su principal desventaja, debido a que no es posible asegurar niveles óptimos de confiabilidad, y al mismo tiempo genera sobre costo por sustitución de partes, que aún se encontraban aptas para el servicio, en repuestos y materiales, lubricantes, mano de obra y principalmente tiempo de indisponibilidad de los equipos [4].

Ahora bien, cuando de hablar de fallas en una máquina se trata, hay que hablar de las vibraciones, considerado muchas veces como el lado negativo de un proceso útil. En

general, las vibraciones en una máquina no son buenas, pues pueden causar desgaste, fisuras por fatiga, pérdida de efectividad de sellos, rotura de aislantes, ruido, etc. Pero al mismo tiempo las vibraciones son la mejor indicación de la condición mecánica de una máquina y pueden ser una herramienta de predicción muy sensible de la evolución de un defecto [5].

Los rodamientos son piezas importantes en la mayoría de las máquinas, ya que se utilizan para permitir el movimiento relativo entre dos componentes. Estos dispositivos se encuentran formados a su vez por cuatro elementos: anillo interior, anillo exterior, jaula y elementos rodantes. Muchas de las fallas que se presentan en las máquinas se deben a los rodamientos, ya sea por una selección inapropiada del lubricante, un montaje incorrecto, ajustes inadecuados, etc. [6].

Como técnicas para diagnosticar el estado en un rodamiento con y sin falla inducida, comúnmente se han usado aquellas extraídas fundamentalmente del campo del procesamiento de señales y en especial las que emplean el dominio de la frecuencia como espacio de representación. Entre estas técnicas destaca el análisis espectral, empleado cuando las vibraciones están compuestas de componentes estacionarias; o en caso contrario, destacan las transformadas tiempo-frecuencia, empleadas cuando las señales contienen componentes no estacionarias. Sin embargo, su implementación presenta una elevada carga computacional en comparación con el dominio temporal; las cuales, dados algunos requerimientos de optimización computacional, se pueden convertir en desventajas.

Cuando las señales de vibración son llevadas del dominio del tiempo al dominio de la frecuencia, descomponiendo una serie de tiempo estacionaria en una suma de componentes senoidales de diversas frecuencias y amplitudes[7], solo se está expresando la misma información de otra manera; es decir, la señal de vibración en el dominio espectral aún conserva la misma información que en el dominio temporal; pero para alterar sus características o forma de representación entre dominios, las señales deben ser sometidas a una serie de funciones que alteraren sus características.

Por lo tanto, resulta necesario disponer de un mínimo de herramientas o técnicas matemáticas de transformación (transformación de frecuencia o de transformación tiempo-frecuencia) que permitan hacer este cambio entre espacios de representación [8], generando ya de entrada incremento global del tiempo computacional. Además, la medición o análisis de datos en el dominio de la frecuencia es un proceso que demanda bastante tiempo computacional, especialmente cuando se trabaja en un rango amplio de frecuencias, por lo tanto, la obtención de datos de óptima calidad a muy bajas frecuencias no es nada sencillo [9].

En general, el problema de requerir mucho tiempo de cálculo, entorpece el desarrollo del sistema en tiempo real. Además las técnicas utilizadas para la extracción y clasificación de características en el dominio espectral, tales como Transformada Wavelet, Distribución Wigner Ville, Distribución Choi Williams, Transformada Rápida de Fourier, entre otras [10], dependen de funciones matemáticas, que en algunos casos, pueden llegar a ser muy complejas y sólo tratables a partir de simulaciones numéricas del propio sistema, generando más aumento de la carga computacional.

CAPITULO 3

JUSTIFICACIÓN

Para la realización de las tareas de mantenimiento en la industria, la táctica predominante es el mantenimiento preventivo, consistente en el cambio de piezas o elementos, o la reparación programada de los equipos en función del tiempo o las horas de operación. Sin embargo, se ha reconocido que este enfoque no garantiza que los equipos mantengan los altos niveles de confiabilidad que demanda la industria actual [11].

El mantenimiento predictivo permite programar la reparación de los equipos antes de que ocurra una deficiencia catastrófica; además, disminuye considerablemente los costos por el mantenimiento aplicado y por el paro del equipo. El mantenimiento predictivo se enfoca a los síntomas de falla (vibración, sonido, temperatura, etcétera) que se presentan una vez que la causa ya está presente y ocasionando desgaste (falla potencial). Por lo tanto, es mucho más eficiente atacar las causas y eliminarlas, que trabajar permanentemente en el efecto [4].

Por esta razón, el monitoreo y análisis de las condiciones de vibración como herramienta para detectar fallas en máquinas rotativas toma gran relevancia, en especial por la posibilidad que brinda de tomar acciones para evitar las consecuencias de posibles fallas, permitiendo planificar acciones que admitan disminuir las pérdidas de producción, incrementar la vida útil de las máquinas, disminuir el lucro cesante, reducir los inventarios de repuestos y los paros por el uso del mantenimiento correctivo y lograr un consecuente aumento de la disponibilidad de los equipos; lo cual derivara en un notable aumento de la confiabilidad. Además, el monitoreo de sistemas permite obtener información de las máquinas en forma de datos primarios que, mediante el uso de técnicas modernas de procesamiento de señales, hace posible dar información vital de la máquina antes de que una falla catastrófica ocurra [12].

Las investigaciones en el tópico del monitoreo y análisis de las vibraciones con el fin de establecer cuál es el estado de salud mecánica de las máquinas y en particular de sus elementos, además de importante es de actualidad, sobre todo por la necesidad de que los equipos mantengan los altos niveles de confiabilidad que demanda la industria actual.

Como técnicas para diagnosticar fallas en rodamientos a partir del análisis de vibraciones, principalmente se han utilizado aquellas que emplean características del dominio de la frecuencia, obtenidos a través de análisis espectrales. Sin embargo, la demanda computacional que poseen las herramientas matemáticas utilizadas por las diferentes técnicas de transformación, extracción y clasificación de dichas características en el dominio espectral se pueden convertir en desventajas, cuando lo que se busca es un rendimiento computacional global del sistema [8].

Si bien en general las señales que varían con una periodicidad definida o de naturaleza estacionaria no suelen ser las más comunes en el análisis de vibraciones; en la actualidad, con el desarrollo de nuevas herramientas computacionales, la simulación en el dominio del

tiempo es mucho más sencilla y en consecuencia [13], este tipo de análisis puede surgir como solución a la necesidad generada de evaluar alternativas más económicas computacionalmente hablando, pero que conserven la precisión y la fiabilidad en la clasificación de fallas.

La extracción de características en el dominio temporal posee un alto valor conceptual y una sencillez en la comprensión intuitiva muy importantes, al permitir calcular y agrupar los atributos de la señal de vibración original en una representación más manejable en forma de vector permitiendo maximizar el éxito de la fase de clasificación.

El análisis en el dominio del tiempo tiene grandes ventajas en lo que ha costo computacional se refiere, ya que al ser un método que no requiere técnicas de transformación (transformación de frecuencia o de transformación tiempo-frecuencia), demanda menos tiempo de cálculo, lo que posibilita el desarrollo de sistemas en tiempo real [8]; además, facilita el problema de la dimensionalidad del vector de características, al permitir de manera más intuitiva la reducción del número de variables de entrada mediante la selección del mejor subconjunto de características del conjunto de la señal original [14], eliminando datos que no representan información significativa y contribuyendo a la maximización del desempeño del clasificador. Pero todo esto no tiene sentido si no se implementa un sistema clasificador que pueda decidir a qué clase de falla corresponde cada una de las señales de vibración y que permita probar la eficacia y la fiabilidad de las características del dominio de tiempo propuestas.

Actualmente existen un gran número de técnicas o algoritmos de clasificación o reconocimiento de patrones; pero los Modelos Ocultos de Markov (HMM) se constituye en una de las herramientas más utilizadas y ampliamente extendidas, ofreciendo incluso mejores resultados que los arrojados por métodos relativamente más recientes como los basados en técnicas inteligentes como las redes neuronales; en donde al comparar el funcionamiento e implementación de ambas, se concluyó que los Modelos Ocultos de Markov (HMM) ofrecen mejores resultados con una menor implementación de equipos; lo que se traduce en una minimización de costos y ahorro de tiempo y destacando además que no presenta incertidumbre con el resultado final, al contrario de las redes neuronales, que, para poder clasificar, dispone de categorías que dependen del número de unidades de procesamiento a usar[15].

CAPITULO 4

OBJETIVOS

4.1 General

Implementar un sistema de clasificación basado en modelos ocultos de Markov (HMM) capaz de detectar fallas en rodamientos a partir del análisis en el dominio del tiempo de señales de vibraciones.

4.2. Específicos

4.2.1. Realizar la segmentación de las señales de vibración provenientes de rodamientos con el fin de alimentar el proceso de extracción de características; empleando para ello la base de datos del Bearing Data Center del Case Western Reserve University.

4.2.2. Caracterizar las señales de vibración empleando el dominio del tiempo como espacio de representación.

4.2.3. Implementar un sistema de clasificación de estados de degradación basado en Modelos Ocultos de Markov (HMM).

4.2.4. Evaluar el desempeño del sistema en el reconocimiento del estado de salud de los rodamientos a partir de señales de vibración.

PARTE 2
MARCO TEORICO

CAPITULO 5

GENERALIDADES

Para lograr obtener la máxima eficiencia de las máquinas rotativas en la industria, se han desarrollado técnicas de mantenimiento enfocadas en hacer que estos sistemas cumplan con los parámetros de diseño establecidos durante el mayor tiempo posible. Una de esas técnicas es el mantenimiento predictivo, que la norma UNE 13306 define como: mantenimiento basado en condición llevado a cabo siguiendo un pronóstico derivado del análisis y evaluación de los parámetros significativos de la degradación del elemento [1]; con el cual, se evalúa el estado de salud de una máquina y su evolución en el tiempo, mientras está en funcionamiento.

El mantenimiento preventivo, que la misma norma define como: mantenimiento realizado a intervalos predeterminados o según los criterios establecidos y destinados a reducir la probabilidad de fallas o la degradación en el funcionamiento del elemento [1]; es aplicado a un equipo en determinados periodos de tiempo, resultando mucho más económico y efectivo que el tradicional mantenimiento correctivo, que a su vez está definido por la misma norma como: mantenimiento realizado después del reconocimiento del fallo y la intención de poner un elemento en un estado en el que se pueda realizar una función requerida [1]; su aplicación en la industria se ha venido minimizando debido a que es una técnica costosa en comparación con las anteriores; además, tiende a ser riesgosa para quien la emplea.

Dentro del mantenimiento predictivo encontramos técnicas que permiten evaluar la condición de la máquina mientras está en funcionamiento, tal es el caso del análisis de vibraciones, definida como: técnica del mantenimiento predictivo que permite hallar las causas de posibles fallos anticipándose a la avería [25].

Las señales de vibración son medidas en términos de una función amplitud contra tiempo o frecuencia, denominados registro temporal y espectral respectivamente. Esto es lo que se conoce como espacios de representación y constituyen el desarrollo de la señal bajo una variable espacial determinada (tiempo, frecuencia, tiempo-frecuencia) [26].

Para efectos de monitoreo en línea, siempre es deseable reducir la cantidad de información contenida en la señal de vibración a un índice único o un pequeño número de especificaciones que reflejen las características generales de la señal. Este procedimiento se conoce como extracción de características de la señal y se define como el proceso mediante el cual se obtiene un espacio de características que representan de la manera más adecuada una señal que tiene una gran cantidad de puntos, con el fin de simplificar conjuntos de datos de alta dimensionalidad que afectan el desarrollo computacional del proceso disminuyendo la velocidad de convergencia [24].

Las características en el dominio del tiempo se extraen de la señal de vibración en bruto a través de parámetros estadísticos como por ejemplo: Valor pico o Peak value (Pv), Raíz media cuadrática o Root mean square (RMS); Factor de cresta o Crest factor (Cr_f), Kurtosis (Kv), Asimetría o Skewness (Sw), Factor de holgura o Clearance factor (Cl_f), Factor de impulso o Impulse factor (Im_f), Factor de forma o Shape factor (Sh_f), Desviación estándar o Standard deviation (std), Valor de la verosimilitud logarítmica negativa Normal o Normal negative log-likelihood value (Nnl), Valor de la verosimilitud logarítmica negativa de Weibull o Weibull negative log-likelihood value (Wnl), Entropía o Entropy (E), Límite superior del histograma o Histogram upper bound (UB), Límite inferior del histograma o Histogram lower bound (LB) [24], [26].

Las características extraídas se utilizan para entrenar y probar el clasificador, que se define como una estructura matemática y estadística que posee la propiedad del aprendizaje, permitiendo procesar información de carácter redundante, impreciso y distorsionado [27].

La etapa de clasificación es una parte importante de los sistemas inteligentes y es considerada como la tarea final de procesamiento, pues una vez recogidas y pre-procesadas las señales de forma conveniente y definido el vector de características representativo, el paso final es la implementación de un clasificador que pueda decidir a qué clase corresponde cada una de las señales [28].

Actualmente existen un gran número de algoritmos de clasificación, entre las técnicas más comunes utilizadas en dicho proceso están las redes neuronales (como el perceptrón multicapa, la red neuronal probabilística, redes ART, entre otras), máquinas de vectores de soporte (SVM), sistemas Fuzzy, los métodos estadísticos, de los cuales hacen parte los clasificadores bayesianos simples y los discriminadores lineales, los métodos basados en distancias como la distancia Euclídea y distancia Mahalanobis, los árboles de decisión, los algoritmos de las k-medias y los modelos ocultos de Markov (HMM).

A raíz del enfoque dado a la tesis, es este último quien cobra más importancia por ser la base de nuestro clasificador. Un HMM se define como; un modelo estadístico en el cual el sistema que se está modelando se asume que es un proceso de Markov con estados ocultos. La aplicación de los HMM se fundamenta en que el sistema a modelar consiste en una cadena de Markov de parámetros desconocidos [29].

5.1. Mantenimiento predictivo

El entorno tan competitivo en el que vivimos, ha obligado a las industrias a entrar en una constante búsqueda de mejores estrategias que sirvan como fuentes de reducción de costos. Dichas estrategias son orientadas a la minimización de tiempos muertos de producción, costos de operación, materiales e insumos, repuestos, mantenimientos correctivos y preventivos.

El mantenimiento correctivo además de ser costoso, tiende a ser riesgoso para el personal que lo realiza. El mantenimiento preventivo aunque es mucho más efectivo y económico que el mantenimiento correctivo, presenta desventajas al momento de revisar máquinas que

están operando en forma óptima, pues generalmente se realizan cambios de piezas que están en buen estado [10].

Por esta razón se han desarrollado estrategias de mantenimiento más eficientes como el mantenimiento predictivo [30], que basa su teoría en la hipótesis de que es mucho más eficiente atacar las causas y eliminarlas, que trabajar permanentemente en el efecto [4].

Su objetivo es evaluar la condición de la máquina mientras ella está en funcionamiento, para evitar detener la máquina y así disminuir los tiempos muertos de producción. Este tipo de mantenimiento basa su principio en pronosticar una falla antes de su ocurrencia, buscando adelantarse al instante en que la máquina o elemento deja de operar en sus condiciones óptimas, utilizando herramientas y técnicas de monitoreo de parámetros y variables físicas.

El control en la máquina o el reemplazo de alguna pieza, impone la necesidad de dominar el proceso y de obtener datos técnicos, que permitan involucrar una metodología científica de trabajo objetiva y rigurosa. Una de las grandes ventajas que otorga la implementación de este método se justifica en la mantención óptima de funcionamiento de máquinas y equipos, dado que los paros inesperados o innecesarios generan grandes pérdidas económicas.

Cuando se analiza el estado de salud de las máquinas o los equipos, se estiman un conjunto de síntomas que las mismas manifiestan, razón por la cual esta metodología de mantenimiento es conocida también como mantenimiento sintomático, donde destacan el análisis de aceites, el ultrasonido, la termografía y el análisis de vibraciones como métodos a tener en cuenta en la evaluación de dichos síntomas. No obstante, es el análisis de vibraciones sobre el que están enfocadas la mayoría de las implementaciones del mantenimiento predictivo, ver figura 5.1.




Figura 5.1: Ejecución de los diferentes tipos de mantenimiento [67]

Actualmente el uso de técnicas de mantenimiento predictivo en las grandes industrias del mundo está asociado a la necesidad que tienen de alcanzar el objetivo de garantizar que todos sus sistemas operen dentro de unos criterios de diseño previamente establecidos por el mayor tiempo posible con el fin de alcanzar la máxima productividad de sus máquinas y equipos.

Modernizar las metodologías de mantenimiento en la industria contribuye a maximizar la disponibilidad de los equipos y con ello minimizar los tiempos muertos de producción, lo que consecuentemente se traduce en un incremento exponencial de la competitividad en los mercados del mundo.

5.2. Diagnóstico de fallas

Al hablar de diagnosticar fallas, lo que se busca es precisar el origen de un problema en particular generado cuando el sistema de monitoreo advierte de la presencia de alguna alteración en las magnitudes de las variables físicas monitoreadas. La identificación de las causas de estos cambios en los medidores, permitirá saber a ciencia cierta si dicha alteración es causada por variaciones naturales de las condiciones de operación de las máquinas o si por el contrario son generadas por algún tipo de falla. Es de vital importancia identificar el tipo de falla al que se está haciendo frente, ya que en gran medida es de ella de quien depende la decisión de en qué momento se debe actuar en la máquina.

Todo queda sujeto a la gravedad de la falla, ya que cuando se trata de un problema leve, la máquina afectada podrá ser llevada hasta una simple parada rutinaria de mantenimiento. Sin embargo, si el problema puede ocasionar una falla grave, inevitablemente tendrá que existir una intervención inmediata. El diagnóstico de fallas en un sistema se basa en comparar variables de referencia con otras de entrada y de este modo diferenciar un estado de salud con un estado de falla. Se requiere conocimiento del sistema y sus variables de entrada y salida, un método adecuado de adquisición de datos y un procedimiento de diagnóstico basado en análisis de resultados [31].

Este diagnóstico tiene su principio en la adquisición de las señales a estudiar, que a continuación son analizadas para poder hacer un diagnóstico y así tomar decisiones, cabe resaltar la importancia que tiene la etapa del análisis de la señal, ya que la extracción de características juega un papel determinante en la efectividad del diagnóstico.

Dependiendo de las técnicas empleadas en el diagnóstico de fallas, este se clasifica en nivel básico, nivel medio y nivel avanzado. Siendo el nivel básico y el nivel medio los más utilizados en la mayor parte de las acciones de mantenimiento predictivo, tales como, el análisis temporal y el análisis frecuencial, mientras que por otro lado, el nivel avanzado es muy utilizado en la extracción de características a señales de vibración que poseen componentes de naturaleza estacionaria y no estacionaria con ayuda de las transformadas tiempo-frecuencia [43].

5.3. Vibración

En forma general, se denomina vibración a la propagación de ondas elásticas produciendo deformaciones y tensiones sobre un medio continuo. Toda máquina posee una señal de vibración donde se plasman algunas de sus características relacionadas con el movimiento [32], [10].

Las máquinas rotativas están compuestas por un conjunto de mecanismos diseñados para cumplir tareas específicas que van desde una parte generadora de movimiento (grupo motor-biela) hasta otra parte encargada de llevar la energía a todos los mecanismos que la conforman (eje). Siendo esta última, quien coordina el funcionamiento, ya que el eje determina la velocidad de giro de la máquina y es el encargado de transmitir las vibraciones a todos los mecanismos presentes como elementos rodantes o rodamientos, ruedas dentadas, acoples y soportes. La base principal de las señales de vibración en el dominio del tiempo son las ondas sinusoidales, ver figura 5.2 [26].

Las señales de vibración de una máquina pueden ser interpretadas como una suma vectorial de las vibraciones de cada mecanismo, con diferentes amplitudes y frecuencias que definen un estado general y permiten determinar el estado de salud de la máquina, al asociar el parámetro de la amplitud con la dureza de la vibración y el parámetro de la frecuencia con el mecanismo vibrante.

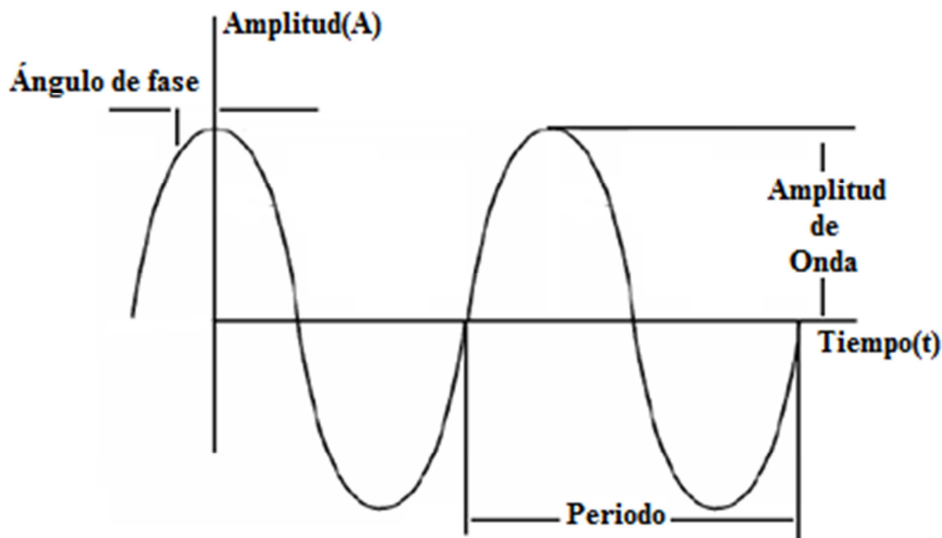


Figura 5.2: Onda de Vibración

El nivel de vibración puede estar dado en términos de la aceleración (g), la velocidad (mm/s) o el desplazamiento (μm), las cuales permiten calcular la amplitud de un espectro de una señal de vibración. La variable de la aceleración aplicada a la medida de la vibración, permite distinguir valores pico de medias y altas frecuencias, la variable de la velocidad permite reconocer valores pico de bajas y medias frecuencias y la utilización de

la variable de desplazamiento permite distinguir patrones que se encuentran a muy bajas frecuencias [10].

El interés de las vibraciones mecánicas aparece en el campo del mantenimiento industrial traído de la mano por el mantenimiento preventivo, como consecuencia de la necesidad de atención demandada por los elementos vibrantes en una máquina y la urgente necesidad de prevenir posibles fallas que traen consigo las vibraciones a mediano plazo [45].

De no ser así, las vibraciones mecánicas pueden influir en el normal funcionamiento de la máquina, ya que pueden provocar incrementos anormales en los esfuerzos y las tensiones, así como pérdidas de energía, desgaste de materiales, y tal vez las más peligrosas, daños por fatiga en los materiales. Dentro de las causas más habituales por las que una máquina, o mecanismo de la misma, puede llegar a vibrar están la falta de alineamiento, la excentricidad, la falla en rodamientos y cojinetes y problemas de engranajes y correas de transmisión (holguras, falta de lubricación, roces) [44].

En general, la presencia de vibraciones en una máquina no es un buen síntoma, pero al mismo tiempo, las vibraciones pueden servir como indicador del estado de salud, ya que cuando el nivel de las vibraciones es relativamente bajo puede ser un indicador de que la máquina operara eficientemente durante un largo período de tiempo; mientras que si el nivel de las vibraciones es elevado puede ser una alerta de que se aproxima algún tipo de anomalía en la máquina. Cuando ocurre una falla grave, es casi seguro que esta venía precedida con antelación por graduales cambios en las condiciones de vibración de la misma.

Debido a que casi el 90% de las fallas en máquinas vienen precedidas por una variación en los niveles de vibración de las mismas, la medición y análisis de vibraciones surge como herramienta fundamental en el mantenimiento predictivo de máquinas y equipos.

CAPITULO 6

ANÁLISIS DE VIBRACIONES

A medida que el costo y la complejidad de las máquinas aumentan, la aplicación de métodos fiables de mantenimiento resulta cada vez más importante. Estos métodos se han enfocado en la utilización de técnicas de mantenimiento predictivo: análisis de vibraciones, temperatura, corrientes, sonido, etc. El monitoreo de vibraciones es la más usada y rentable técnica de monitoreo para detectar, localizar y distinguir fallas en máquinas rotativas que en la mayoría de los casos, ocurren debido a una lubricación inadecuada del elemento y a un montaje incorrecto, lo cual implica desalineación [4].

A través del tiempo se han desarrollado una gran variedad de aplicaciones para este propósito, consistentes en su gran mayoría en sensores de vibraciones (acelerómetros), los cuales son distribuidos en varios sitios de las máquinas que se deseen monitorear. Estos sensores recogen una señal compuesta por una gama de frecuencias muy amplia, desde bajas frecuencias a frecuencias muy altas. Estas señales se pueden dividir en tres categorías [4]:

- Baja frecuencia (0 a 2kHz)
- Alta frecuencia (2 a 50kHz)
- Muy alta frecuencia (más de 50 kHz.).

Acto seguido, las vibraciones son transformadas en señales eléctricas por el sensor, para posteriormente ser capturadas por una tarjeta de adquisición de datos quien las ingresa a una computadora. Debido a que cuando se captura la señal de vibración esta contiene información que es irrelevante para el análisis, se requiere entonces el uso de un sistema acondicionador de señal para generar una secuencia que contenga solamente aquella información que facilite el análisis de la señal. Debido a que las vibraciones que se pueden presentar en máquinas rotativas no superan los 4kHz, generalmente se usan filtros digitales para eliminar frecuencias superiores a este valor [38].

Las señales de vibración contienen mucha información, la cual puede ser aplicada para monitoreo de condiciones, sin interferir con la operación de la máquina. Por ejemplo, cuando una falla localizada en una superficie del rodamiento choca con otra superficie, se generan vibraciones de impacto. La monitorización de condiciones se lleva a cabo mediante el análisis de los cambios en la firma de la vibración debido a la presencia de estos impulsos [24].

6.1. Enfoques del Análisis de Vibraciones

El análisis de la señal de vibración, para diagnóstico de fallas, puede ser encarado desde un punto de vista tradicional y otro investigativo. Los equipos disponibles en cada uno de los

dos enfoques para el análisis de las señales de vibración marcan la diferencia entre ambos, ya que no es lo mismo tener sistemas de monitoreo de condiciones complejas, que contienen un alto grado de eficiencia y tienden a realizar un diagnóstico automático como sucede en países altamente desarrollados, que tener sistemas simples con una limitada capacidad de diagnóstico que proveen una representación gráfica básica del dominio del tiempo o la frecuencia, para que con ayuda de un técnico se pueda deducir el estado de salud de la máquina, como ocurre en muchos países en vía de desarrollo.

6.1.1. Análisis Tradicional

Basa su análisis de la señal en el dominio del tiempo y la frecuencia y se caracteriza principalmente porque su diagnóstico y tasa de acierto dependen de los conocimientos y la habilidad que posea el técnico encargado del mantenimiento para interpretar las señales de vibración e identificar posibles fallas asociadas a un sonido, a la temperatura o a la forma de vibrar de la máquina [26].

Pese a que este tipo de análisis ha arrojado resultados aceptables, no se puede ocultar el hecho de estar supeditado a cierto número de limitaciones dependientes de las condiciones de operación de la máquina (velocidad de giro constante, carga constante, etc.). Este enfoque tradicional es consecuentemente menos práctico que el enfoque investigativo. Otro aspecto importante a tener en cuenta, es el riesgo que puede resultar de una mala interpretación por parte de la empresa, de los datos y resultados entregados por el técnico en el diagnóstico de la máquina y no hacer los correctivos necesarios.

6.1.2. Análisis Investigativo

Constituido por todo el proceso de reconocimiento y clasificación de patrones en las señales de vibración, clasificado a su vez en varias etapas que van desde el espacio de representación hasta la clasificación, pasando por fases como la estimación de características, la extracción de características y la reducción de dimensionalidad. Cabe resaltar la influencia que tiene el funcionamiento sincronizado de dichas etapas en la tasa de acierto de los resultados del diagnóstico automático [26].

6.2. Técnicas de análisis de vibraciones

El diagnóstico del estado de salud mecánica de una máquina rotativa empleando el análisis de sus vibraciones, basa su teoría en las fuerzas dinámicas generadas por las fallas que alteran su comportamiento vibratorio. Las vibraciones obtenidas de diferentes puntos de la máquina, se analizan empleando diferentes técnicas con el fin de encontrar indicadores vibratorios que caractericen la falla de la mejor manera [44].

6.2.1. Análisis en el dominio del tiempo (Forma de la onda)

Puede ser considerada como un complemento al análisis espectral, puesto que al analizar la forma de la señal de vibración en el dominio del tiempo, esta puede suministrar información complementaria al análisis espectral. Dicho análisis es comúnmente utilizado en el diagnóstico de problemas como impactos, modulaciones en amplitud y frecuencias, truncaciones o rozamientos intermitentes.

El análisis de la forma de la onda de la vibración es una de las técnicas del dominio tiempo más útiles para detectar defectos en rodamientos. Por ejemplo, el análisis de la forma de onda de la aceleración vibratoria permite identificar los impactos producidos por el paso de los elementos rodantes sobre un defecto localizado, y por medio de su periodicidad y su relación con la frecuencia de falla identificar la localización del defecto (pista interna, externa o elementos rodantes) [70].

6.2.2. Análisis espectral FFT (Fast Fourier Transform)

Se basa en la descomposición de la señal de vibración en el dominio del tiempo en sus componentes espectrales en frecuencia para poder analizarlas individualmente; en otras palabras, el análisis espectral fundamenta su idea en encontrar la relación existente entre la frecuencia de las componentes discretas presentes en el espectro y la frecuencia de las fuerzas dinámicas que generan las vibraciones. El espectro FFT se representa en gráficos que nos dan la amplitud de vibración en función de los múltiplos de la frecuencia de giro de la máquina (1x, 2x, 3x,.....).

6.2.3. Análisis de fase de vibraciones

Definiendo la diferencia de fase a la velocidad de giro de la máquina entre las vibraciones horizontal y vertical o entre las vibraciones axiales de los diferentes descansos del grupo motor-máquina, se pueden establecer los movimientos relativos entre ellos, y diferenciar entre problemas relacionados con desbalanceamiento, desalineamiento, eje doblado, resonancia y poleas excéntricas o desalineadas.

6.2.4. Análisis de los promedios sincrónicos en el tiempo

Agrupar señales de vibración en el dominio del tiempo y las suma y promedia simultáneamente con ayuda de un pulso de referencia que se repite varias veces. Las componentes coordinadas con el pulso se tienen en cuenta en el promedio y las no sincronizadas ven como su valor decrece con el número de promedios.

6.2.5 Análisis de órbitas

Permite identificar el movimiento del eje de la máquina en un momento de descanso al que sea sometida, al mezclar dos señales de vibración adquiridas por sensores ubicados aproximadamente a 90° entre sí.

6.2.6. Análisis de demodulaciones

Con ayuda del análisis de la envolvente de la señal temporal de una señal modulada, se pueden diagnosticar de manera fácil problemas relacionados con rodamientos picados, engranajes excéntricos o con dientes agrietados, deterioro de álabes en turbinas y problemas eléctricos en motores.

6.2.7. Análisis de vibraciones en partidas y paradas de una máquina

Permite evidenciar en forma más clara los problemas que generan vibraciones cuyas frecuencias son función de la velocidad de la máquina, ya que durante el periodo comprendido entre la partida y la parada de la máquina, la reducción de la velocidad disminuye de manera simultánea dichas componentes, por lo que en algún momento coinciden con alguna frecuencia natural de ella y son amplificadas.

6.2.8. Transformadas tiempo-frecuencia

Útiles ante la necesidad de un análisis que permita describir de forma más clara señales de naturaleza no estacionarias. Poseen la particularidad de ser un análisis tridimensional (amplitud-tiempo-frecuencia).

CAPITULO 7

CONTEXTO MECÁNICO

Una de las premisas que tiene el análisis de vibraciones es el de buscar el efecto para tratar de descubrir la causa raíz. Recopilando e interpretando de forma sistemática datos de la máquina a tratar, se pueden identificar posibles anomalías. Es recomendable realizar la adquisición de estas medidas en puntos diferentes de la máquina y en las direcciones, vertical, horizontal y axial, ya que algunos problemas en máquinas rotativas tienden a manifestarse más en alguna dirección que en otra.

Una vez obtenidos los datos de vibraciones, estos se comparan con los valores que recomienda el fabricante de la máquina, con el fin obtener un panorama generalizado del estado de salud de la misma. En caso de no poseer registros de valores del fabricante, la norma ISO 3945-1985 [63], dispone de tablas que pueden ser utilizadas para tal fin, donde se listan valores de referencia de amplitud de vibración que permiten analizar la condición mecánica de una máquina, ver tabla 7.1:

Severidad de Vibración RMS[mm/seg]	Tipo de Soporte	
	Rígido	Flexible
0,46	Buena	Buena
0,71		
1,12		
1,8		
2,8	Satisfactoria	Satisfactoria
4,6		
7,1	No Satisfactoria	No Satisfactoria
11,2		
18,0	Inaceptable	Inaceptable
28,0		
71,0		

Tabla 7.1: Valores de referencia de amplitud de vibración.

En general, el nivel de vibración debe estar dado en términos de la velocidad (mm/s), ya que esta variable posee bastantes atributos que facilitan el análisis del nivel de severidad de las vibraciones. Otra variable que influye en el nivel de vibraciones es el asociado con la cantidad de energía total entregada a la máquina, ya que mucha parte de esta se transforma en vibraciones y ruido.

Existen diversos problemas mecánicos y eléctricos asociados a las vibraciones que pueden causar fallas graves en una máquina (desbalanceo, desalineación, soltura mecánica,

rodamientos, entre otros), en la mayoría de los casos es posible asociar los niveles de vibración con el tipo de problema que se está enfrentando, mientras que la amplitud de las señales puede dar una medida de la severidad del problema. Es importante mencionar que a raíz del enfoque dado a este proyecto de grado, y a que la aplicación del análisis de vibraciones está orientado exclusivamente a fallas en rodamientos, los problemas de vibración originados por causas diferentes como desbalanceo, desalineación, soltura mecánica, poleas descentradas, entre otras, son encarados de una manera muy general.

7.1. Fallas detectadas por el análisis de vibraciones

Como ya se mencionó antes, el análisis de vibraciones busca asociar las frecuencias de vibración de una máquina con las causas probables de las anomalías presentes en la misma, empleando la amplitud de las señales de vibraciones emitidas por estas para determinar los niveles de severidad de dichos problemas, ver tabla 7.2:

Frecuencia	Causas Probables de Falla
1xRPM	Desbalanceo, engranajes o poleas descentradas, desalineamiento o eje flexionado, resonancia, problemas eléctricos, fuerzas alternas.
2xRPM	Huelgos o juegos mecánicos, desalineamiento, fuerzas alternativas, resonancia.
3xRPM	Desalineamiento, combinación de huelgos mecánicos axiales excesivos con desalineamiento.
< a 1xRPM	Remolino de aceite (oil whirl) en cojinetes o rotores.
Frecuencia de línea	Problemas eléctricos.
Armónicas de RPM	Engranajes dañados, fuerzas hidráulicas, huelgos o juegos mecánicos, fuerzas alternativas.
Alta Frecuencia (no armónicas)	Cojinetes antifricción en mal estado.

Tabla 7.2: Probables causas de falla y su frecuencia de vibración

7.1.1. Desbalanceo

Es la fuerza que se crea en una pieza, cuando su eje inercial se encuentra desplazado del eje geométrico de rotación, originado por causas como el desgaste de partes, la deformación del material, el desprendimiento de partes, el mal ensamble de componentes, golpes, entre otros. El desbalance casi siempre se observa como una alta amplitud a la velocidad de giro y medida en dirección radial; es decir, cuando se presenta una vibración por desbalance, predominan algunas características en ciertas componentes de la máquina; algunas de estas

componentes sufren incrementos en los niveles de amplitud a causa de la velocidad, otras experimentan bajos niveles de vibración, mientras que otras padecen elevados niveles de vibración radial pero bajísimos niveles de vibración en la dirección axial.

El desbalanceo se puede manifestar de forma estática, dual y dinámica; siendo en el primer caso, atribuida a desgaste radial superficial no uniforme en rotores en los cuales su largo es despreciable en comparación con su diámetro [10].

En este tipo de desbalanceo la forma de onda será siempre de tipo sinusoidal pura, se tendrá la misma fase y será constante en ambos soportes del eje, lo que facilita la identificación de este tipo de falla. El desequilibrio dual produce un desfase de 180° entre soportes del eje, puede ocasionar una alta vibración axial y radial.

Por otra parte, el desbalanceo dinámico, es el más frecuente y es una combinación de los dos anteriores, atribuido principalmente a desgastes radiales y axiales coincidentes en el rotor. En esta forma de desbalanceo la ubicación del ángulo de fase entre los bordes de apoyo del rotor puede producir una diferencia entre 45° o 135° .

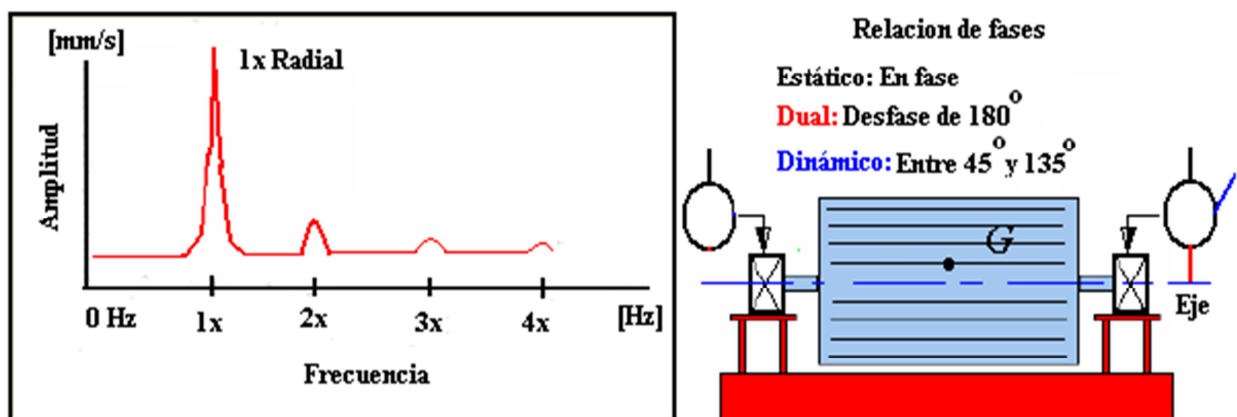


Figura 7.1: Espectro del desbalanceo y relación de fases entre soportes del eje

7.1.2. Desalineación

Considerado uno de los defectos más usuales en la industria, ocurre cuando dos ejes conectados mediante acoplamientos no se encuentran perfectamente colineales uno con respecto al otro. También se puede presentar entre los cojinetes de un eje sólido, o entre dos puntos cualesquiera de la máquina [46].

Cuando una vibración se presenta a dos veces la velocidad de giro significa desalineamiento. Si la amplitud a dos veces la velocidad de giro es superior al 75% de la velocidad de giro, quiere decir que se acerca la ocurrencia de una falla. Por consiguiente, la anomalía debe ser vigilada con cuidado y corregida a la primera oportunidad.

7.1.2.1. Desalineación Paralela

Ocurre cuando dos ejes están unidos en acople y están paralelos, pero no son colineales; es decir, desde un solo sitio se pueden observar dos puntos separados. Genera una alta vibración radial que se aproxima a un desfase de 180° en el acoplamiento. Cuando este tipo de desalineación presenta un alto nivel de severidad, se pueden producir elevados picos de amplitud a unos armónicos similares a los presentes en la holgura mecánica. El material de construcción del acoplamiento influye de cierta forma en la totalidad del espectro cuando la desalineación es severa [65].

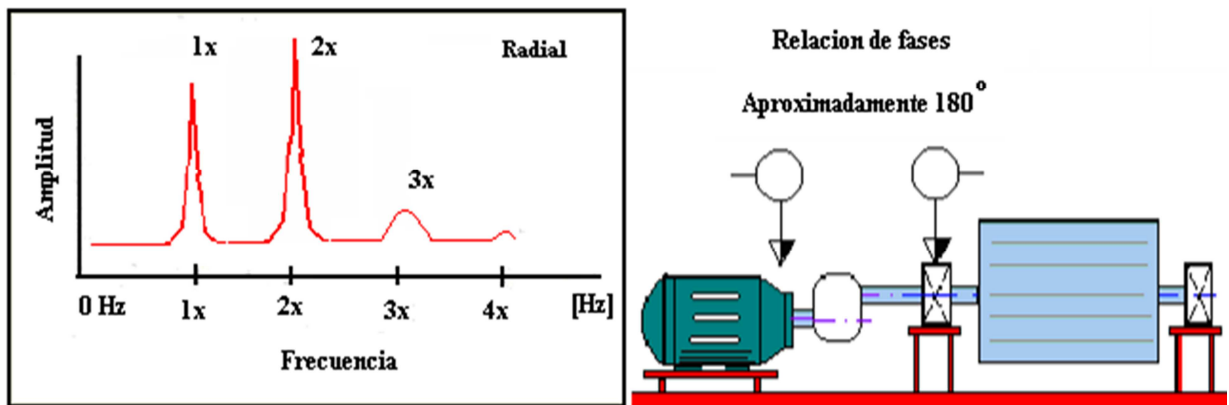


Figura 7.2: Espectro de la desalineación paralela y relación de fases en el acople

7.1.2.2. Desalineación Angular

Ocurre cuando dos ejes están unidos en acople pero no están paralelos entre sí, es decir, entre los ejes existe un pequeño ángulo o lo que es lo mismo, desde un solo sitio se puede observar la presencia de una línea inclinada a partir del centro. Este tipo de desalineación generará una elevada vibración axial, con un desfase de 180° a lo largo del acoplamiento.




Figura 7.3: Espectro de la desalineación angular y relación de fases en el acople

7.1.3. Soltura Mecánica

La soltura mecánica se caracteriza principalmente por tener una larga cadena de armónicos de la frecuencia de giro con altas amplitudes anormales, ver figura 7.4. La soltura mecánica está clasificada en tres categorías conocidas como clase 'A', 'B' o 'C' [26].

7.1.3.1. Clase A

Es atribuido al debilitamiento estructural de los apoyos de amarre de la máquina o por un desgaste en los cimientos. Para este tipo de problema en particular, la frecuencia predominante es la de giro de la máquina (1x), y tiende a proyectar su amplitud en dirección vertical. El análisis de la fase puede revelar una diferencia de fase de unos 90° a 180° entre mediciones verticales en un perno, pie de máquina, o en los cimientos.




Figura 7.4: Espectro de la soltura mecánica tipo A y relación de fases en perno o placa base

7.1.3.2. Clase B

Es atribuido al aumento en la soltura de los cojinetes de apoyo, o la existencia de pequeñas fisuras en el equipo. Esta clase de soltura genera vibraciones a dos veces la frecuencia de giro de la máquina (2x).




Figura 7.5: Espectro de la soltura mecánica tipo B

7.1.3.3. Clase C

Normalmente se le atribuye al aflojamiento de un cojinete en su caja o por un espacio excesivo en los elementos rodantes del rodamiento. Puede ocasionar la presencia de numerosas frecuencias armónicas o subarmónicas de la velocidad de giro del eje (0.5x, 1x, 1.5x, 2x, 2.5x, 3x, etc.). La soltura mecánica tipo C es generalmente muy inestable y puede variar mucho entre mediciones, particularmente si el rotor cambia de posición en el eje de una puesta en marcha a la siguiente.

Normalmente se le atribuye al aflojamiento de un cojinete en su caja o por un espacio excesivo en los elementos rodantes del rodamiento. Puede ocasionar la presencia de numerosas frecuencias armónicas o subarmónicas de la velocidad de giro del eje (0.5x, 1x, 1.5x, 2x, 2.5x, 3x, etc.). La soltura mecánica tipo C es generalmente muy inestable y puede variar mucho entre mediciones, particularmente si el rotor cambia de posición en el eje de una puesta en marcha a la siguiente.

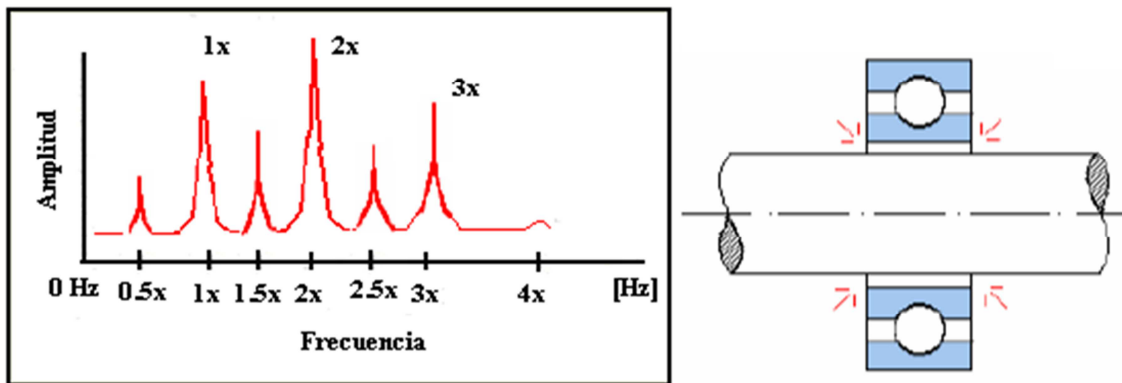


Figura 7.6: Espectro de la soltura mecánica tipo C

7.1.4. Eje Doblado




Figura 7.7: Espectro del eje doblado y relación de fases entre componentes de referencia

Cuando el eje está doblado cerca de su centro se produce una vibración dominante generalmente en 1x, pero si el eje está doblado cerca del acoplamiento, la vibración

dominante se producirá en $2x$. Este tipo de problema genera elevada vibración de naturaleza axial con unas diferencias de fase axial en torno a 180° en el mismo componente de la máquina [65].

7.2. Rodamientos

Los rodamientos son mecanismos que facilitan el movimiento relativo entre dos componentes de una máquina, generalmente empleados para orientar y minimizar la fricción de un eje en una máquina rotativa. Las aplicaciones de los rodamientos son muy variadas, estos se pueden encontrar en diferentes tipos de motores eléctricos, turbinas, taladros, entre otros. Los rodamientos están entre los más importantes y frecuentemente encontrados componentes en la gran mayoría de las máquinas rotativas, su capacidad de carga y confiabilidad son vitales para el adecuado desempeño de la máquina. La detección y diagnóstico de fallas en etapas prematuras de daño, son necesarias para evitar su mal funcionamiento y fallos durante su operación [24].

Cuando una falla localizada en una superficie del rodamiento choca con otra superficie, se generan componentes de vibración no sincrónicos. La existencia de componentes no sincrónicos en un espectro de vibraciones es el indicador más claro de problemas en los rodamientos y permite excluir otras posibles fuentes que originan la vibración [26].

Los rodamientos cumplen un papel muy importante en el diagnóstico de fallas, ya que, la presencia de defectos o anomalías en ellos, hace que estos se comporten como una gran fuente de ruido y vibración, incluso cuando éstos tienen perfectas dimensiones geométricas [47].

7.2.1. Fallas en rodamientos

Cuando existe algún rodamiento defectuoso en una máquina, este puede originar la salida de operación de la máquina, trayendo como consecuencia costosas pérdidas de producción, principalmente en las plantas industriales, ya que la cantidad de maquinaria utilizada en sus procesos es superior que el número de personas empleadas. Sin embargo, no solo del rodamiento depende el correcto funcionamiento de una máquina, pues además de lo anterior, el entorno de funcionamiento de los equipos, la instalación, el mantenimiento, entre otros, son factores que también pueden influir en su operación.

Las fallas en los rodamientos se pueden clasificar como localizados (grietas, hendiduras, resaltes, picaduras y descascaramiento) y distribuidos (rugosidades superficiales, ondulaciones sobre las pistas y elementos rodantes desiguales). Ahora bien, dependiendo de si la falla se presenta en alguno de sus principales componentes como el anillo interior, el anillo exterior, la jaula y los elementos rodantes, se generan vibraciones de diferente frecuencia calculadas a partir de la geometría del rodamiento y de las partes que lo componen, y por lo general, corresponden a un rango de alta frecuencia [33].

En otras palabras, cuando una superficie con falla entra en contacto con su superficie de encuentro, se generan unos pulsos periódicos de muy poca duración. Las periodicidades con que se producen tales pulsos son función de la geometría del rodamiento, la velocidad de rotación y la localización del defecto [48].

Generalmente los primeros indicios de problemas en un rodamiento aparecen en los niveles de frecuencia ultrasónica que varía entre los 250.000 y los 350.000 Hz; con el aumento del desgaste en el rodamiento, disminuye ese rango a un valor que oscila entre 20.000 y 60.000 Hz [65].

Las firmas de vibración para las señales en el dominio del tiempo consideradas para el análisis vibracional se muestran en la figura 7.8. En la figura se puede ver cuatro condiciones diferentes: (a) normal, (b) falla en elementos rodantes, (c) falla en la pista externa y (d) falla en la pista interna.

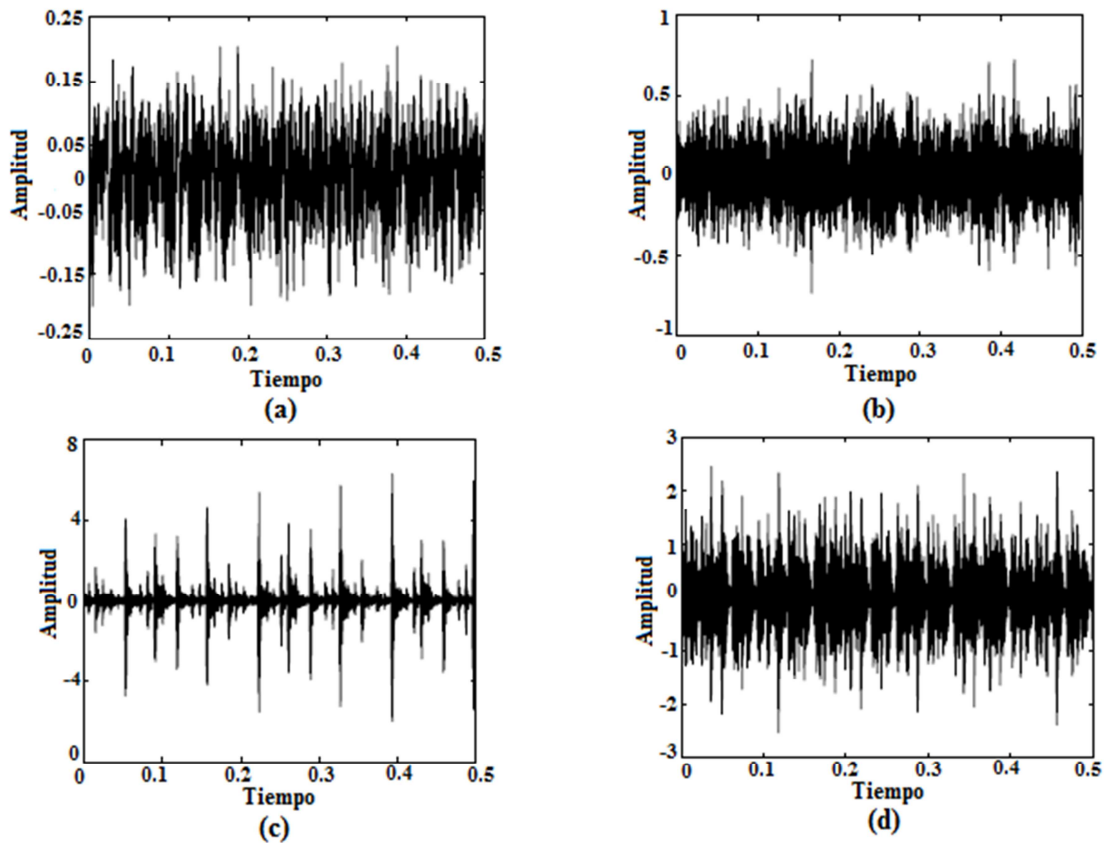


Figura 7.8: Firmas de vibración en rodamiento

Cabe resaltar que en cada rodamiento se pueden presentar diferentes tipos de falla con un grado de progresión diferente dependientes en gran medida de variables como la carga, la velocidad, la temperatura, la humedad y la lubricación a que estén sometidos. Cuando se producen cambios inesperados en los esfuerzos de contacto en sus interfaces, se generan pulsos de muy corta duración, que introducen componentes de alta frecuencia en las

frecuencias naturales de los elementos que conforman el rodamiento. La presencia de dichas componentes frecuenciales, permite detectar prematuramente la falla, ver figura 7.9 [64].




Figura 7.9: Señal generada por la presencia de una falla [64]

7.2.2. Estructura de un rodamiento

Estos dispositivos se encuentran formados a su vez por cuatro elementos: anillo interior, anillo exterior, jaula y elementos rodantes, ver figura 7.10.




Figura 7.10: Partes de un rodamiento [66]

- **Anillo Interior:** Constituye la superficie sobre la cual se deslizan las bolas o rodillos. Esta superficie, se encuentra ubicada en toda la parte periférica exterior del anillo más pequeño del rodamiento. Esta parte del rodamiento tiene la tarea de asegurar el rodamiento sobre el eje.
- **Anillo Exterior:** También constituye la superficie sobre la cual ruedan los elementos rodantes. Se ubica en la periferia interna del anillo más grande del rodamiento. La tarea principal del anillo exterior es la de fijar el eje y a la vez permitirle girar con libertad.
- **Elementos rodantes:** Constituyen la parte que facilita el movimiento entre los anillos interior y exterior. Aunque generalmente los elementos rodantes pueden ser bolas, también los hay en forma de rodillos o cilindros.
- **Jaula:** Es el elemento que tiene la tarea de mantener a los elementos rodantes espaciados entre sí.

7.2.3. Diámetros

Como ya se mencionó antes, dependiendo del elemento del rodamiento sobre el cual se presente la falla, se originan ciertas vibraciones de diferente frecuencia, las cuales pueden ser calculadas a partir de la geometría del rodamiento y de las partes que lo conforman.




Figura 7.11: Diámetros de un rodamiento y Ángulo de contacto [66]

- **Diámetro nominal exterior (d_e):** Determina el espacio radial necesario de las chumaceras.
- **Diámetro nominal del agujero (d_A):** Es el diámetro que se tiene en consideración para el tamaño del eje.

- **Diámetro de paso (D):** Es el diámetro a través del cual los centros de los elementos rodantes (bolas) giran.
- **Ángulo de contacto (θ):** Ángulo formado por la línea imaginaria que atraviesa los puntos de contacto (punto de contacto que se produce entre los elementos rodantes con los anillos) y el eje del rodamiento.

7.2.4. Frecuencias características en los rodamientos

Utilizando las ecuaciones de la tabla 7.3 es posible calcular las frecuencias asociadas a los elementos de los rodamientos, tanto para el caso en el que conocemos el ángulo de contacto del rodamiento, como para el caso en el que resulta difícil conocer el ángulo; dichas frecuencias son denominadas comúnmente como *BPFO* (frecuencia de paso de bola por pista externa), *BPMF* (frecuencia de paso de bola por pista interna), *BSF* (frecuencia de giro de bola) y *FTF* (frecuencia fundamental del tren o canastilla de rodadura), y pueden ser calculadas de manera analítica o mediante la utilización de algún software comercial.

$\mathbf{BPMF} = f * \frac{n}{2} (1 + \frac{d}{D} \cos \theta)$	$\mathbf{BPMF} = 0.6 * f * n$
$\mathbf{BPFO} = f * \frac{n}{2} (1 - \frac{d}{D} \cos \theta)$	$\mathbf{BPFO} = 0.4 * f * n$
$\mathbf{BSF} = f * \frac{D}{2d} (1 - (\frac{d}{D} \cos \theta)^2)$	$\mathbf{BSF} = 0.23 * f * n (n < 10)$
$\mathbf{FTF} = f * \frac{1}{2} (1 - \frac{d}{D} \cos \theta)$	$\mathbf{FTF} = 0.4 * f$
d = Diámetro de las bolas	n = Número de bolas
D = Diámetro del rodamiento	θ = Ángulo de contacto en la dirección radial

Tabla 7.3: Frecuencias en los rodamientos.

CAPITULO 8

PROCESO DE CLASIFICACIÓN DE FALLAS

En general son varias las etapas que hacen parte de un proceso de clasificación de fallas en rodamientos cuando se emplea el análisis de vibraciones, ver figura 8.1:

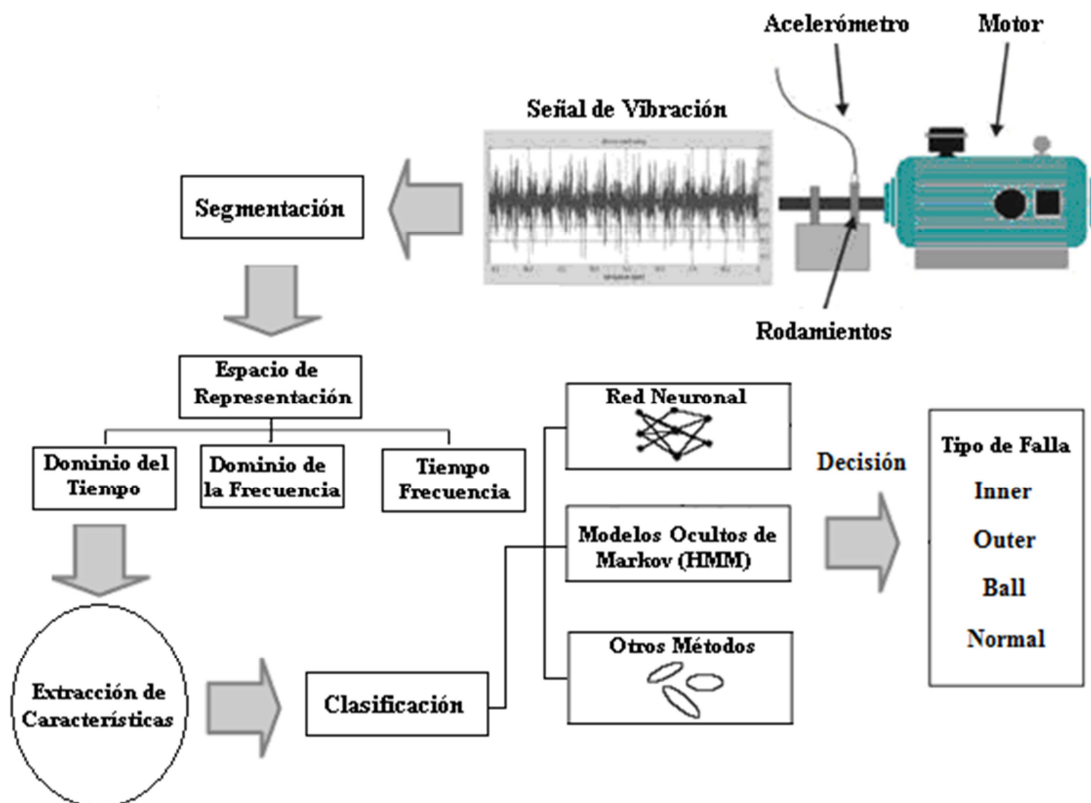


Figura 8.1: Proceso de la clasificación de una falla

La primera etapa involucra la adquisición de las señales de vibración, las cuales son medidas en puntos específicos donde se encuentran ubicados los rodamientos. Usualmente, la señal vibratoria es medida en función de la aceleración con el fin de identificar fallas incipientes en ellos. Ya obtenidas las señales de vibración, estas son segmentadas en tramas con el fin de extraer las características diferenciadoras eliminando ciertos datos que no representan información significativa.

La escogencia de un espacio de representación adecuado facilita la estimación de características al permitir concentrar la dinámica de la señal de vibración en un espacio transformado; para el caso del presente proyecto de grado, a partir del dominio del tiempo.

Por otra parte, la extracción de características facilita el rendimiento del clasificador, al permitir calcular características que ayudan a distinguir posibles fallas presentes en los equipos. Se puede complementar la fase de extracción de características con una fase de análisis de relevancia, el cual permite optimizar el proceso de clasificación eliminando todas aquellas características que sean redundantes e irrelevantes con la ayuda de un análisis estadístico [37].

Finalmente, la etapa de clasificación de las señales, permite concluir la capacidad de generalización y la efectividad para discriminar tipos de fallos con ayuda del índice de rendimiento. Esta tercera etapa realiza la clasificación de las señales a partir de las características obtenidas en la fase anterior para determinar la clase de falla a la que pertenece dicha señal.

Resulta lógico pensar que en estos tiempos donde la detección de fallas se ha vuelto un requerimiento indispensable en cualquier planta industrial, cuando lo que se busca es maximizar su competitividad, sale a relucir la importancia de tener un sistema de análisis que posea una gran habilidad de identificación de fallos, así como una precisa interpretación de los mismos.

8.1. Segmentación

Debido a que las señales de vibración presentan un comportamiento de naturaleza estocástica; es decir, sus variaciones temporales son aleatorias, se hace necesario tomar segmentos cortos de la señal, de manera que se pueda asumir estacionariedad en ellos para poder realizar los cálculos de las características de la señal de vibración en tramos.

Segmentar las señales de vibración de entrada, permite además, diferenciar las partes de señal que transportan información relevante de aquella que contiene información redundante; evitando de este modo, gastar memoria y tiempo de cálculo en las tramas que carecen de relevancia evitando así obtener resultados erróneos en el análisis de vibraciones.

De la correcta segmentación de la señal de vibración depende en gran medida la exactitud del proceso de clasificación, ya que las fallas en la segmentación de la señal constituyen una de las principales fuentes de error en los sistemas de clasificación. La segmentación consiste en partir la señal de entrada en segmentos de análisis de (N) muestras con una duración tal que pueda ser considerada estacionaria; generalmente se examina en intervalos de tiempo suficientemente cortos (entre 20 y 60 ms) donde sus características estadísticas permanecen invariantes.

En la figura 8.2 se representa la señal de vibración en el dominio del tiempo. Las muestras de la señal se dividen en secciones de igual tamaño (tramas o frames) y sobre cada conjunto de muestras correspondientes a una ventana se realiza la extracción de características.




Figura 8.2: Segmentación de la señal de vibración

Un aspecto importante que se debe tener en cuenta al momento de realizar la segmentación de la señal es la duración de las tramas y la separación entre tramas adyacentes, destacando el número de muestras de cada segmento (N) y las muestras de separación entre tramas adyacentes o traslape ($\text{delta}N$). La figura 8.2 representa un ejemplo de segmentación en tramas para el caso en el que el traslape ($\text{delta}N$) es igual a la mitad del número de muestras (N); es decir, $[\text{delta}N = (1/2)N]$, donde la primera trama contiene las primeras (N) muestras, la segunda trama empieza ($\text{delta}N$) muestras después de la primera y se solapa ($N - \text{delta}N$) muestras y así sucesivamente [71].

Con respecto a la relación que existe entre N y $\text{delta}N$, se pueden presentar tres situaciones:

- Si $\text{delta}N \leq N$ se solaparán las muestras adyacentes y el espectro resultante estará correlacionado trama a trama.
- Si $\text{delta}N \ll N$ la estimación espectral estará demasiado suavizada.
- Si $\text{delta}N > N$ no existirá solapamiento entre tramas adyacentes, perdiéndose parte de la señal de vibración y la correlación entre tramas adyacentes; por lo tanto, la estimación espectral resultante contendrá una componente ruidosa cuya magnitud crecerá con N .

Es importante mencionar que en el proceso de segmentación, se lleva a cabo una operación de enventanado, es decir, se multiplica la señal de vibración por una función ventana, con el objetivo principal de atenuar gradualmente la amplitud de la señal en los extremos del intervalo de extracción de características. Dentro de las funciones de ventanas existentes destacan la rectangular, Hanning, Hamming, Blackman, Barlett y Kaiser; sin embargo, es la ventana Hamming la más empleada en procesamiento de señales y está representada por la siguiente expresión [71]:

$$w_H(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (8,1)$$

Es importante mencionar la importancia que tiene la frecuencia de muestreo a la hora de diseñar el tamaño de la ventana, a causa de la relación inversa existente entre la resolución frecuencial y la resolución temporal, ya que una vez fijada una frecuencia de muestreo, si se incrementa el tamaño de la ventana temporal, esta podría ser demasiado grande como para captar cambios relevantes en la señal de vibración.

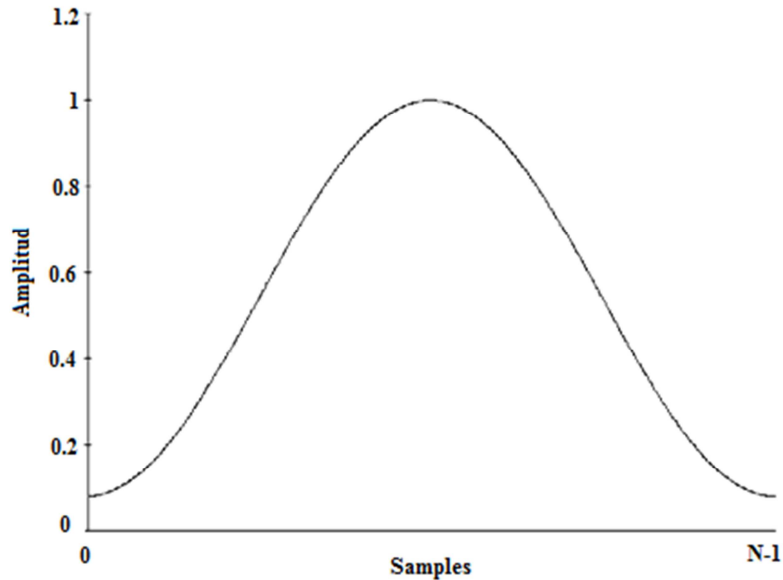


Figura 8.3: Ventana de Hamming

8.2. Espacios de Representación

Los espacios de representación comprenden el desarrollo de la señal de vibración bajo los parámetros de una variable espacial determinada (tiempo, frecuencia, TF).

8.2.1. Análisis Temporal

Matemáticamente hablando, una señal x en el dominio temporal es la señal de vibración medida del sistema e involucra la esencia del funcionamiento de la máquina. La señal de vibración puede ser vista como una sucesión de funciones seno con distintas frecuencias (f_i), amplitudes (A_i) y fases (φ_i), donde cada mecanismo en particular está representado por una senoide.

$$x(t) = \sum_i A_i \sin(2\pi f_i t + \varphi_i) \quad (8,2)$$

El subíndice (i) representa cada componente que hace parte de la máquina. Cuando se desea pasar del dominio temporal a otro espacio de representación, se hace necesario el empleo de funciones ortogonales que permitan transformar la señal $x(t)$ a otro espacio de representación. Se le llama serie temporal a una sucesión de valores organizados de manera cronológica y observada a lo largo del tiempo [51].

Valor Medio (V_m)	$\frac{\sum_{n=1}^N x(n)}{N}$	Cociente P_v y C_{lf} (C_{pc})	$\left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N}\right)^2$
Desviación Estándar (std)	$\sqrt{\frac{\sum_{n=1}^N (x(n) - V_m)^2}{N - 1}}$	Factor de Impulso (Imf)	$\frac{P_v}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Asimetría (S_w)	$\frac{\sum_{n=1}^N (x(n) - V_m)^3}{(N - 1)std^3}$	Límite superior del histograma (UB)	$\min(x(n)) + 0.3 * \left(\frac{\max(x(n)) - \min(x(n))}{N - 1}\right)$
Kurtosis (K_v)	$\frac{\sum_{n=1}^N (x(n) - V_m)^4}{(N - 1)std^4}$	Límite inferior del histograma (LB)	$\min(x(n)) - 0.3 * \left(\frac{\max(x(n)) - \min(x(n))}{N - 1}\right)$
Pico Positivo Máximo (P_v)	$\max x(n) $	Valor de la verosimilitud logarítmica negativa de Weibull (Wnl)	$-\sum_{n=1}^N \log(\text{Weibullpdf}(f((x_i, \beta, \alpha))))$
Raíz Media Cuadrática (RMS)	$\sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$	Valor de la verosimilitud logarítmica negativa Normal (Nnl)	$-\sum_{n=1}^N \log(\text{Normalpdf}(f((x_i, \mu, \sigma))))$
Factor de Forma (Shf)	$\frac{RMS}{\frac{1}{N} \sum_{n=1}^N x(n) }$	Entropía (E)	$-\sum_{n=1}^N P(x(n)) \log P(x(n))$
Factor de Cresta (C_{rf})	$\frac{P_v}{RMS}$	RMS de los picos (\tilde{x}_{peak})	$\sqrt{\frac{1}{N} \sum_{n=1}^N x_{npeak}^2}$
Factor k (K)	$P_v * RMS$	Desviación Estándar de los picos (σ)	$\sqrt{\frac{1}{N} \sum_{n=1}^N (x_{npeak} - \bar{x}_{peak})^2}$
Factor de Holgura (C_{lf})	$\frac{P_v}{\left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N}\right)^2}$	RMS de la distancia de los picos ($\tilde{\delta}_{posi Peak}$)	$\sqrt{\frac{1}{N} \sum_{n=1}^N \delta_n^2 \text{posi Peak}}$

Tabla 8.1: Características en el dominio del Tiempo.

Cuando se lleva a cabo la extracción de características en el dominio del tiempo, se registran las cualidades de las señales de vibración que caracterizan su estructura temporal relativa a una falla específica. Las características en el dominio del tiempo poseen la particularidad de no depender de ninguna transformación para ser calculadas, permitiendo así, que su extracción se pueda realizar de manera fácil y ágil [52].

Precisamente es la simplicidad una de las mayores cualidades que posee este tipo de análisis, ya que toma en cuenta valores globales (en rangos de frecuencia que van desde 10Hz hasta 10kHz), lo que equivale a decir que generalmente toma en consideración toda la señal para calcular sus valores.

Los parámetros estadísticos que se listan en la tabla 8.1, forman parte de un grupo de características que son consideradas como las más prácticas a la hora de ser calculadas por su simplicidad y por la buena interpretación que brindan al proceso de discriminación de fallas en máquinas rotativas. En total es un grupo de 20 características que representan el comportamiento temporal de la señal. En el capítulo 9 (sección 9.3), correspondiente al marco metodológico, se encuentra detallada la descripción de cada una de estas características.

No menos importante resulta subrayar la utilidad de las características en el dominio del tiempo en el análisis de fenómenos no estacionarios y pulsos de corta duración, los cuales resultan determinantes en la detección de fallas rudimentarias en los rodamientos. Con la ayuda de descriptores estadísticos, se puede tener una alerta temprana de posibles anomalías en el sistema, cuando estos experimentan alteraciones en sus valores de referencia que previamente han sido sensados en condiciones normales de funcionamientos [53].

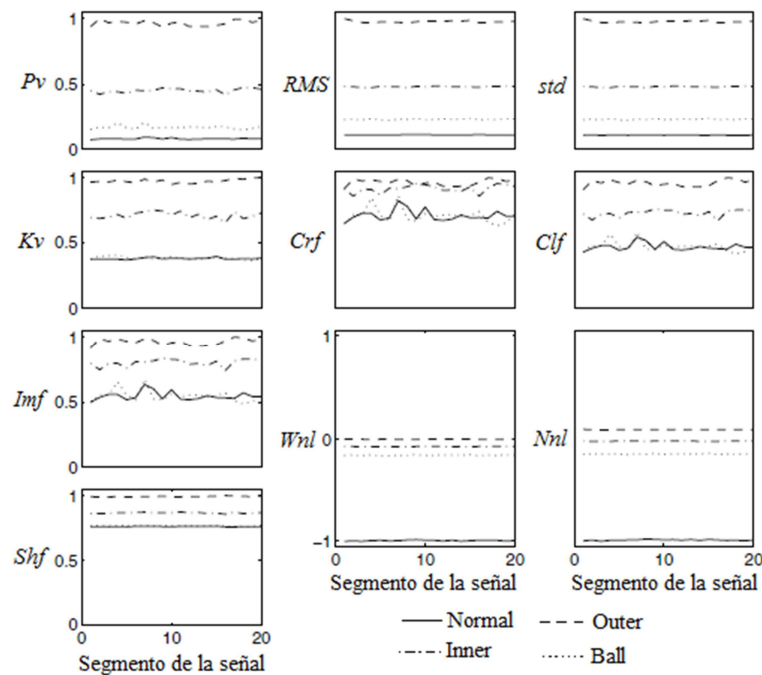


Figura 8.4: Características en el dominio del tiempo de una señal de vibración [39]

8.2.2. Análisis Frecuencial

La representación en el dominio de la frecuencia de las señales de vibración ofrece una buena cantidad de información relacionada con posibles fallas que pudieran tener lugar en los rodamientos, ya que por la naturaleza misma de las señales, permite conocer las frecuencias de falla para cada uno de los elementos que componen el rodamiento.

Dentro del diagnóstico de fallas en rodamientos empleando el análisis frecuencial se tienen en cuenta generalmente tres rangos de frecuencias para tal fin: franja de baja frecuencia (0 a 2kHz), franja de frecuencia intermedia (2 a 50kHz) y franja de alta frecuencia (mayor a 50 kHz). Generalmente el diagnóstico de fallas en rodamientos se basa en la frecuencia intermedia y alta [53].

Es evidente que el dominio de la frecuencia cuenta con interesantes ventajas a la hora de realizar un análisis de vibraciones, donde a diferencia de lo que sucede cuando se hace un registro global de los valores de la señal, el análisis de las frecuencias permite determinar si la falla proviene de la pista interna, externa, la jaula o de los elementos rodantes. Además, brinda la posibilidad de detallar de forma clara el espectro del valor de la frecuencia, facilitando así, la identificación de la componente que más influencia tiene en el nivel total de la vibración.

En la tabla 8.2 se listan un conjunto de características fundamentales obtenidas a partir del espectro de una señal de vibración.

Frecuencia Media (<i>MF</i>)	$\frac{\sum_{k=1}^k x(k)}{K}$	Frecuencia Central (<i>FC</i>)	$\frac{\sum_{k=1}^k f_k x(k)}{\sum_{k=1}^k x(k)}$
Varianza (<i>Var</i>)	$\frac{\sum_{k=1}^k (x(k) - MF)^2}{K}$	Desviación Estándar (<i>STDF</i>)	$\sqrt{\frac{\sum_{k=1}^k (f_k - FC)^2 x(k)}{K}}$
Asimetría (<i>Sf</i>)	$\frac{\sum_{k=1}^k (x(k) - MF)^3}{K(\sqrt{F_2})^3}$	Raíz Media Cuadrática (<i>RMSF</i>) $\sqrt{\frac{\sum_{k=1}^k f_k^2 x(k)}{\sum_{k=1}^k x(k)}}$	
Kurtosis (<i>Kf</i>)	$\frac{\sum_{k=1}^k (x(k) - MF)^4}{K(F_2)^4}$		

Tabla 8.2: Características en el dominio de la Frecuencia

Como técnica para diagnosticar fallas en rodamientos a partir del análisis de vibraciones, generalmente se han empleado aquellas que utilizan características del dominio de la frecuencia como espacio de representación. Sin embargo, la necesidad de convertir la señal original en un conjunto de componentes de frecuencias comprendidas entre la frecuencia cero y la media de la frecuencia de muestreo, obliga el cálculo de la densidad espectral de

potencia de la señal de vibración; requiriendo para ello, el uso de herramientas matemáticas como Transformadas de Fourier, Series de Fourier, La Transformada Discreta de Fourier y La Transformada Rápida De Fourier (*FFT*) [26], las cuales demandan una carga computacional considerable, haciendo que se convierta en desventaja cuando lo que se busca es un rendimiento computacional global del sistema.

Cabe mencionar; que además de lo expuesto anteriormente, existen otras desventajas de las transformadas relacionadas con el Aliasing y el Leakage, donde el primero introduce componentes de baja frecuencia que no están presentes en la realidad y el segundo introduce frecuencias en torno a la fundamental de una señal truncada [53].

8.2.3. Análisis Tiempo – Frecuencia

El análisis tiempo-frecuencia posibilita la localización conjunta de eventos tanto en tiempo como en frecuencia, resultando muy conveniente su aplicación en el análisis de las señales no estacionarias, ya sea por regímenes de carga y velocidad variable o por los transitorios causados por fallas en rodamientos.




Figura 8.5: Señales en el dominio del tiempo y la frecuencia (espectro) [26]

Ante los problemas de resolución presentes en las muy utilizadas herramientas de transformación basadas en el análisis de Fourier y su desventaja de no poder suministrar información temporal de la señal, surgen como alternativa para lograr la caracterización tiempo-frecuencia, la Transformada wavelet (TW) y las distribuciones Wigner Ville (*WVD*) y Choi Williams (*CWD*), las cuales suministran de manera simultánea una buena representación de la señal de vibración tanto en tiempo como en frecuencia, facilitando así, la delimitación del intervalo de tiempo donde se manifiestan ciertas componentes espectrales [58].

En consecuencia, se crea una obligación de garantizar una buena resolución en el tiempo o una buena resolución en frecuencia. El problema de la resolución tiempo-frecuencia ocurre sin importar cuál sea la transformada que se emplee, lo que obliga a la utilización de

técnicas alternativas de análisis de señales denominadas comúnmente análisis multiresolución (*AMR*), de la que forma parte la Transformada wavelet (*TW*), la cual funciona como un filtro (no lineal) el cual permiten extraer componentes que portan información en el dominio del tiempo y en el dominio de la frecuencia [53].

La distribución Wigner Ville (*WVD*) es una transformación cuadrática que describe la distribución de energía en el dominio de la frecuencia [10]. Esta técnica de análisis de señal en tiempo-frecuencia ofrece una buena resolución para un análisis preciso en los dos espacios de representación, sin embargo, posee ciertos problemas relacionados con el aliasing y la conducta no lineal.

La Distribución Choi Williams (*CWD*) pertenece también al grupo de transformadas cuadráticas. Surgió ante la necesidad de suprimir los términos cruzados de la distribución Wigner Ville mientras conserva las propiedades deseables de la (*WVD*) [10].

8.3. Extracción y Selección de características

Cuando la señal es obtenida después de ser filtrada, hay una etapa de procesamiento, ya que para efectos de monitoreo en línea, siempre es deseable reducir la gran cantidad de información contenida en la señal de vibración en línea a un índice único o un pequeño número de características que reflejen el comportamiento general de la señal. Este procedimiento es conocido como extracción de características de la señal [24].

El proceso de extracción de características calcula y recolecta en forma de vector compacto, las cualidades de las señales de vibración, ver figura 8.6.




Figura 8.6: Extracción de características estadísticas

El principal objetivo de esta etapa es generar una representación manipulable y relevante de la señal de vibración original, con el fin de maximizar la efectividad de la fase de clasificación y a su vez el rendimiento global del sistema. En otras palabras, la etapa de extracción de características busca extraer la mayor información útil posible de la señal, reduciendo el número de variables de entrada a una cantidad más relevante de información, con objeto de maximizar el desempeño de la fase de clasificación [49].

Cabe resaltar la importancia que tienen los métodos de extracción de características en la obtención del éxito en la etapa de clasificación, ya que el clasificador además de depender de las características propias como su estabilidad y su adaptabilidad, necesita que las estrategias de extracción y selección de características posean una alta efectividad que garanticen el éxito de la clasificación. Las aproximaciones paramétricas y no paramétricas son métodos empleados para llevar a cabo la extracción de características; Destacando dentro de la aproximación no paramétrica el análisis temporal, el análisis espectral y el análisis tiempo–frecuencia [50].

Es importante mencionar que a raíz del enfoque dado al presente proyecto de grado y a que el estudio del análisis espectral y tiempo-frecuencia no hacen parte de los objetivos, estos serán encarados de una manera muy general. Las características en el dominio del tiempo se extraen de la señal de vibración en bruto a través de parámetros estadísticos que permiten cuantificar la condición mecánica de los rodamientos. Dentro de los descriptores estadísticos más empleados por su sensibilidad ante posibles defectos en rodamientos encontramos aquellos que ya fueron listados en la tabla 8.1, tales como, Valor pico o Peak value (P_v), Raíz media cuadrática o Root mean square (RMS); Factor de cresta o Crest factor (Cr_f), Kurtosis (K_v), Asimetría o Skewness (S_w), Factor de holgura o Clearance factor (Cl_f), Factor de impulso o Impulse factor (Im_f), Factor de forma o Shape factor (Sh_f), entre otros [24].

8.4. Clasificación

En la resolución de problemas y en la toma de decisiones la primera parte de la tarea consiste precisamente en clasificar el problema o la situación, para después aplicar la metodología correspondiente que en buena medida dependerá de esa clasificación [35].

El procesamiento de datos de naturaleza redundante, incierta y distorsionada, desempeña un papel relevante en el campo de la solución de problemas reales de clasificación de fallas. El objetivo principal de los sistemas de clasificación es discriminar las señales de vibración, identificando los datos de entrada dentro de un número definido de clases, ya sea cuando se tiene un conjunto de datos de fallos estandarizados (clasificación multiclase) o un conjunto de datos de procedencia desconocida (clasificación mono-clase) [26].

La clasificación multiclase toma en consideración un conjunto clasificado de registros de vibración que facilitan la labor de discriminación, ya que contienen información relevante de ciertos estados de la máquina. Por otra parte, la clasificación mono-clase toma en consideración un abundante conjunto de datos conocidos, principalmente de la máquina en un estado normal.

Usualmente los problemas de clasificación de fallas son tratados bajo los fundamentos de la clasificación multiclase. En este caso particular, la estructura de los clasificadores multiclase están conformados de dos etapas: análisis de características y clasificación de patrones [36].

En la primera etapa se parametriza y se extraen las características a la señal de vibración con el fin de utilizar exclusivamente los parámetros que mayor información aportan al proceso y de esta manera lograr reducir el espacio de representación. En la segunda etapa, el clasificador procesa las características extraídas en la etapa anterior para poder determinar el tipo de falla.

La fase de clasificación se considera como la tarea final del procesamiento de señales, ya que una vez definido el diseño del montaje del banco de pruebas, recogidos los datos y pre-procesados eficazmente, la etapa final es la implementación de un clasificador que permita identificar a qué clase corresponde cada una de las señales de vibración. Los parámetros de entrada al clasificador son aquellos que se obtienen en la fase de extracción de características, y la salida será un índice de la pertenencia de una señal a uno u otro estado de salud del rodamiento, ya sea: falla en anillo interior, anillo exterior, elementos rodantes o rodamiento sin falla.

De acuerdo al modelo de señal a utilizar para caracterizar las propiedades de la señal de vibración, estos se clasifican en modelos deterministas y modelos estadísticos. Como consecuencia de la necesidad de caracterizar exclusivamente las propiedades estadísticas de la señal, se han desarrollado un gran número de procesos estadísticos como; los procesos gaussianos, los procesos poissonianos, los clasificadores bayesianos simples (*naiveBayes*), los discriminadores lineales, los procesos de Markov o los procesos ocultos de Markov [59].

Existen también otras técnicas de corte tradicional, comúnmente utilizadas en la fase de clasificación como son los árboles de decisión, los algoritmos de las k-medias o los métodos basados en distancias como la distancia Euclídea y distancia Mahalanobis. Dentro de otras técnicas se destacan las basadas en redes neuronales, máquinas de vectores de soporte (SVM) y sistemas Difusos [60].

8.4.1. Modelos Ocultos de Markov (HMM)

Un modelo oculto de Markov (HMM: *Hidden Markov Model*) corresponde a una cadena de Markov (q) en la cual la observación (O) de salida es una variable aleatoria generada de acuerdo a una función de probabilidad asociada a cada estado [29]; en otras palabras, es un modelo estadístico en el cual se asume que el sistema que se está modelando es un proceso de Markov con parámetros desconocidos, de allí que se le llamen “ocultos”. Es importante aclarar que el adjetivo “*oculto*” no se refiere a los parámetros del modelo sino a la ruta de estados a través del cual pasa el modelo.

Las cadenas de Markov son modelos estadísticos de señales observables representadas

como un proceso aleatorio paramétrico, es decir, los parámetros pueden determinarse con precisión. Por otro lado, los modelos ocultos de Markov son una extensión de las cadenas de Markov cuando las señales no son observables [62].

Como ya se mencionó, la ruta de estados no es observable, pero la salida, dependiendo del estado, si lo es. Cada estado posee una distribución de probabilidad sobre las posibles señales de salida. Por consiguiente, los modelos ocultos de Markov ofrecen indicaciones sobre el orden de los estados con ayuda de la secuencia de símbolos que estos generan. El siguiente ejemplo ilustra el caso general de un HMM con símbolos discretos.

El dueño de un local de perfumes planea obsequiar pequeñas botellitas con muestras de sus fragancias más costosas, pero antes de hacerlo decide generar una secuencia de observaciones a partir de las diferentes marcas de fragancias que planea regalar, con el fin de evaluar las probabilidades de obtener una cierta marca en una caja. Disponiendo de una cantidad N de cajas de cartón y ubicando en el interior de cada caja una cantidad M de botellitas con muestras, el dueño del local, valiéndose de algún procedimiento aleatorio y seleccionando de forma independiente las cajas, escoge una de estas, de la cual extrae al azar una botellita y registra su marca como una observación. Una vez retornada la muestra a la caja de la cual fue seleccionada originalmente, el dueño del local procede a seleccionar una caja diferente basándose en un procedimiento aleatorio dependiente de la caja actual, resultando en la elección de alguna fragancia repetida, generando así una secuencia de observación finita de marcas de fragancias O en un tiempo T , la cual puede ser modelada como la salida observable de un HMM.

Dentro de las posibles secuencias de observación del modelo de las cajas de cartón y las marcas de los perfumes se tiene:

$O_1 = (Jean\ Paul, Black, Lacoste, Black, Armani, Jean\ Paul, Zegna, Armani, Black, Lacoste, Jean\ Paul)$

$O_2 = (Jean\ Paul, Armani, Black, Armani, Lacoste, Zegna, Black, Armani, Lacoste, Jean\ Paul, Armani, Black)$

$O_3 = (Armani, Lacoste, Jean\ Paul, Armani, Lacoste, Black, Armani, Jean\ Paul, Zegna, Zegna, Black)$

$O_4 = (Armani, Black, Zegna, Armani, Armani, Lacoste, Black, Jean\ Paul, Lacoste, Armani, Black)$

El alfabeto es: $\Sigma = \{Jean\ Paul, Black, Lacoste, Armani, Zegna\}$ (Las marcas de las fragancias).

Los estados ocultos son: $Q = \{1, 2, \dots, N\}$ (las cajas de cartón).

Las probabilidades de pasar de una caja a otra son:

$P(1,1) = a_{11}$	$P(2,1) = a_{21}$	$P(3,1) = a_{31}$	$P(N,1) = a_{N1}$
$P(1,2) = a_{12}$	$P(2,2) = a_{22}$	$P(3,2) = a_{32}$	$P(N,2) = a_{N2}$
....
$P(1,N) = a_{1N}$	$P(2,N) = a_{2N}$	$P(3,N) = a_{3N}$	$P(N,N) = a_{NN}$

Tabla 8.3: Probabilidades de los estados ocultos de un HMM

Las probabilidades de extraer una marca en cada caja:

<i>Caja 1</i>	<i>Caja 2</i>	<i>Caja N</i>
$P(\text{Armani}) = b_1(1)$	$P(\text{Armani}) = b_2(1)$	$P(\text{Armani}) = b_N(1)$
$P(\text{Lacoste}) = b_1(2)$	$P(\text{Lacoste}) = b_2(2)$	$P(\text{Lacoste}) = b_N(2)$
$P(\text{Black}) = b_1(3)$	$P(\text{Black}) = b_2(3)$	$P(\text{Black}) = b_N(3)$
$P(\text{jean Paul}) = b_1(4)$	$P(\text{jean Paul}) = b_2(4)$	$P(\text{jean Paul}) = b_N(4)$
....
$P(\text{Zegna}) = b_1(M)$	$P(\text{Zegna}) = b_2(M)$	$P(\text{Zegna}) = b_N(M)$

Tabla 8.4: Probabilidades de los símbolos observados en un HMM

De acuerdo con lo mostrado en el ejemplo anterior, el modelo oculto de Markov más sencillo es aquel en el cual una caja determinada representa un estado y cada marca de fragancia representa un posible símbolo de observación. Por cada estado se fija una probabilidad de extraer una determinada marca de perfume y una probabilidad de pasar a la siguiente caja. Las marcas de las fragancias en el interior de cada caja pueden o no ser las mismas y pueden existir números diferentes de perfumes de cada marca en cada caja. Por consiguiente, una observación aislada de una marca en particular no aclara inmediatamente de cuál caja se extrajo. En la figura 8.7 se ilustra de la transición de estados en los HMMs del ejemplo anterior.

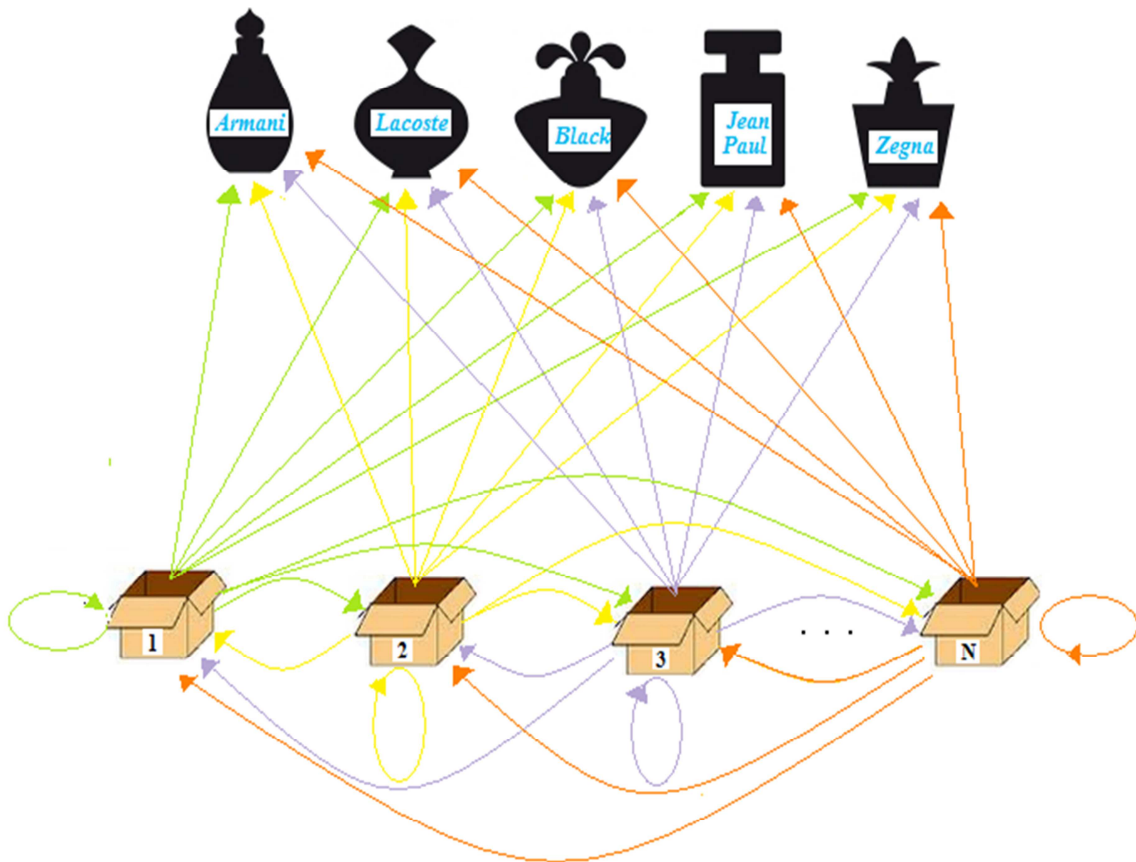


Figura 8.7: Arquitectura del grafo del modelo de cajas y perfumes

8.4.1.1. Elementos que conforman un HMM

Formalmente, un HMM discreto de primer orden está constituido por dos conjuntos (estados y observaciones) y tres conjuntos de probabilidades, que forman una quintupla [62], [29]:

$$\lambda = (\Sigma, Q, A, B, \pi) \quad (8,3)$$

Dónde:

- $\Sigma = \{O_1, O_2, O_3, \dots, O_M\}$: Es un conjunto discreto finito de M símbolos (estados observables) que representan los estados visibles del proceso, es decir, el alfabeto. Para el modelo de los perfumes y las cajas, los estados observables son las marcas de las fragancias escogidas de cada caja.
- $Q = \{1, 2, 3, \dots, N\}$: Es un conjunto finito de N estados (estados ocultos) que representan los estados (reales) del sistema que pueden ser descritos por el proceso de Markov. Aunque los estados están ocultos, para muchas aplicaciones hay un significado físico adjunto a los estados o al conjunto de estados del modelo. Normalmente, los estados están interconectados de tal manera que cualquier estado puede ser alcanzado desde otro cualquiera. Para el modelo del ejemplo, los estados ocultos están representados por las cajas.
- $A = (a_{ij})_{N \times N}$: Es una matriz (matriz de transición de estados) conformada por las probabilidades de transición donde a_{ij} es la probabilidad de transición desde el estado i al estado j , para todo $i, j \in N$. En el caso especial en donde cada estado pueda alcanzar cualquier otro en un solo paso, tenemos ($a_{ij} > 0$) para todo (i, j) . Para otros tipos de HMM, tendríamos ($a_{ij} = 0$) para uno o más pares (i, j) . Para el modelo del ejemplo sería como seleccionar una caja en función de la anterior, ver tabla 8.3.
- $B = (b_j(O_k))_{N \times M}$: Es un vector de probabilidades de emisión de símbolos (matriz de confusión), uno por cada estado, donde $b_j = (b_{j1}, b_{j2}, \dots, b_{jM})$ es la probabilidad de emisión del símbolo O_k del alfabeto en el estado j . Para el modelo del ejemplo sería como obtener una marca de perfume, ver tabla 8.4.
- $\pi = \{\pi_1, \pi_2, \dots, \pi_N\}$: Es un vector (distribución inicial de estado) de probabilidades del estado inicial q_0 en Q .

La notación compacta $\lambda = (A, B, \pi)$ se emplea para representar los modelos ocultos de Markov (HMM: *Hidden Markov Model*), en otras palabras, precisar un HMM involucra la escogencia de un número proporcional de estados N , y símbolos discretos M , y especificando las probabilidades A, B, π . Las probabilidades de iniciación, transición y emisión son los parámetros del modelo.

Un HMM se puede emplear como un generador de secuencias de observaciones [62]:

$$\mathbf{O} = \{O_1, O_2, \dots, O_T\}$$

Dónde:

- O_t es uno de los símbolos de Σ para $t \in \{1, 2, \dots, T\}$.
- T es la longitud de la secuencia de observación \mathbf{O} , es decir, el número de observaciones en la secuencia.
- $\lambda = (A, B, \pi)$ son los parámetros del modelo.

8.4.1.2. Los tres problemas básicos de los HMM

Jack Ferguson, fue el primero en formular que para cualquier clase de HMM se deben plantear tres problemas básicos cuya resolución posibilite que el modelo sea práctico al representar una señal [29]:

- **El problema de la evaluación:** Calcular eficientemente $P(\mathbf{O}|\lambda)$ la probabilidad de la secuencia de observación \mathbf{O} dado el modelo $\lambda = (A, B, \pi)$ y la secuencia de observación $\mathbf{O} = \{O_1, O_2, \dots, O_T\}$.

Dado un modelo y una secuencia de observaciones de la señal, ¿cuál es la probabilidad de que la secuencia de observaciones haya sido generada por el modelo? Este problema puede solucionarse con la ayuda del algoritmo de avance-retroceso, permitiendo con ello valorar la semejanza entre la señal que representa el modelo y la señal representada por la secuencia de observaciones.

- **El problema de la decodificación:** Encontrar $q = (q_1, q_2, \dots, q_T)$ la trayectoria más probable dado el modelo λ y la secuencia de observación $\mathbf{O} = \{O_1, O_2, \dots, O_T\}$.

Dado un modelo y una secuencia de observaciones, ¿cuál es el camino de estados óptimo para generar una salida lo más parecida posible a la secuencia de observaciones? Resolviendo este problema se puede encontrar la secuencia de estados de un modelo que mejor se ajusta a una secuencia de observaciones dada.

Desafortunadamente no se conoce de algún algoritmo que permita solucionar este problema de forma exacta, sin embargo, el algoritmo de Viterbi es capaz de calcular de manera eficiente una máxima verosimilitud local.

- **El problema del aprendizaje:** Ajustar los parámetros A, B, π con el fin de maximizar $P(O|\lambda)$.

Dado un HMM y una secuencia de observaciones, ¿cómo ajustar los parámetros del modelo para maximizar la probabilidad de generar esas observaciones? La solución a este problema aporta los medios necesarios para ajustar automáticamente los parámetros del modelo dado un conjunto de observaciones de entrenamiento. De manera similar a lo que ocurre en el segundo problema, no se conoce un procedimiento exacto para lograr dicha optimización, por lo que se usa un procedimiento iterativo llamado Método de Baum-Welch.

Es importante mencionar la existencia de diferentes maneras de adaptar la información inicial para el diseño del HMM y estimar sus parámetros. Es sabido que los estimativos iniciales uniformes o aleatorios de los parámetros π y A son adecuados en la mayoría de los casos y que los buenos estimativos iniciales para el parámetro B son útiles en el caso de secuencias con símbolos discretos y esenciales en el caso de distribuciones continuas [62], [29].

En general, todo el Modelo de Markov es caracterizado por la probabilidad de la observación del vector $b_j(O_t)$ para el k -ésimo elemento de emisión en cada estado j , la probabilidad de transición del estado a_{ij} que describe como el nuevo estado j puede ser alcanzado desde el anterior estado i , y la probabilidad del estado inicial π , indica la probabilidad que el i -ésimo estado, es el estado inicial de transición.

8.4.2. Libro de Código (codebook)

En el proceso de transformar el contenido de la señal de vibración en una representación codificada, cierto intervalo de tiempo es adquirido de la misma, y los elementos que se repiten de una manera predecible en este período son representados como un solo código. Este procedimiento es llevado a cabo reuniendo los patrones típicos de la señal (vectores de código o modelos), y designando un código a cada patrón.

La idea es encontrar y cambiar la representación de los vectores característicos (en este caso en el dominio temporal), que pueden tomar infinitos valores, por un conjunto finito de vectores que constituyen lo que se denomina un Libro de Código, donde una señal es cotejada con cada patrón en un cierto intervalo, y la señal en cada período es proyectada por un código que indica el patrón que es más parecido a la señal.

Esta cuantificación de vectores trae consigo la idea de clasificar un conjunto de vectores, luego de lo cual se buscarán los mejores representantes para reducir el tamaño de la información a manejar, con el fin de obtener un grupo de vectores representativos llamado libro de código (codebook).

En otras palabras, durante la etapa de entrenamiento del clasificador se deben generar un conjunto de patrones de referencia apoyándose en un grupo de vectores de entrenamiento, teniendo presente que el conjunto de patrones de referencia debe ser menor que el grupo de

vectores de entrenamiento. Al conjunto de patrones de referencia se los denomina libro de código y a los patrones, palabras de código.




Figura 8.8: Construcción del libro de código

Partiendo de un gran número de vectores de observación, V_1, V_2, \dots, V_L , que conforman el grupo de entrenamiento, se crea el grupo de vectores del libro de código (codebook) óptimo que representa la variabilidad observada en el grupo de entrenamiento. Inicialmente, se requiere medir la distancia entre cada par de vectores de observación con el fin de agrupar el conjunto de vectores de entrenamiento como así también para clasificar vectores arbitrarios a cada entrada del libro de código. Posteriormente, un algoritmo de clasificación basado en clustering (por ejemplo, K-means), permite ubicar y calcular los centroides de los vectores de observación, agrupando estos en torno a K valores medios arrojando como resultado un libro de códigos o codebook [69].

La etapa de validación del clasificador en el análisis de vibraciones consiste esencialmente en una búsqueda rigurosa en el libro de código del patrón que mejor se acomoda al vector característico asociado a la señal particular que se quiere reconocer. Este libro de códigos, además nos proporciona un conjunto idóneo de patrones que permiten minimizar la alteración producida cuando varios tipos de señales son representadas por un número limitado de patrones.

De forma general, podemos decir, que los N vectores originales quedarán representados por M vectores, cada uno de los cuales es llamado palabra de código o codeword, luego el grupo entero de dichos vectores, forma un libro de códigos o codebook, formando entonces M regiones, ver figura 8.9.




Figura 8.9: Libro de código o codebook [69]

En general existen dos formas de generar el libro de código; la primera está basada en aprendizaje aleatorio, la cual permite a los vectores ser elegidos de manera aleatoria de los datos de entrenamiento y luego ser guardados como vectores de códigos. La segunda forma de generar el libro de código se basa en clusters, la cual permite agrupar los datos de entrenamiento en grupos mutuamente separados y a cada grupo se le calculan las medias permitiendo minimizar la distorsión promedio, estas medias son archivadas como vectores de código.

8.4.2.1. Clustering

Clustering es el proceso de agrupar datos en clases de tal manera que los objetos de un clúster posean un nivel elevado de semejanza entre ellos, y un nivel bajo con objetos de otros clusters [67]. Los algoritmos que permiten clasificar un conjunto de vectores de entrenamiento en un grupo de clases distintas (o clusters) caracterizadas por un vector (el centroide de cada clúster) se denominan algoritmos de clustering. Existe una gran variedad de algoritmos de clustering como: K-means, CobWeb, Algoritmo EM (Expectation Maximization), SOM (self-organization maps), entre otros. Nuestro trabajo está enfocado en el estudio del algoritmo de K-means.

8.4.2.2. K-means

Tradicionalmente ha sido el algoritmo de clustering más empleado por su simpleza y eficacia. Se basa en un simple procedimiento de clasificación de un grupo de objetos en una cierta cantidad de K números de clústeres. Se le asigna el nombre de K-means porque representa cada uno de los clusters por la media de sus puntos, o lo que es lo mismo, por su centroide. Cuando la representación es llevada a cabo utilizando centroides, la inmediatez en la entrega de resultados se convierten en una gran ventaja gracias a su representación de naturaleza gráfica y estadística. Cada clúster por tanto es caracterizado por su centroide, ver figura 8.10 que se encuentra en el medio de los elementos que componen el clúster [67].




Figura 8.10: Clustering empleando K-means

El proceso de agrupamiento K-means es sencillo; como primer paso se define el número K de conjuntos y se asume el centro de esos grupos. La definición de los centroides se puede realizar tomando K objetos de forma aleatoria como los K clusters iniciales o tomando los primeros K objetos en forma secuencial. A continuación, se define el o los centroides iniciales con base al número de clúster esperado, luego se determina la distancia de cada objeto con relación a los centroides y finalmente se agrupan los objetos con base en la distancia mínima [67].

De forma general, los pasos del algoritmo de clustering empleando K-mean pueden resumirse en la figura 8.11:

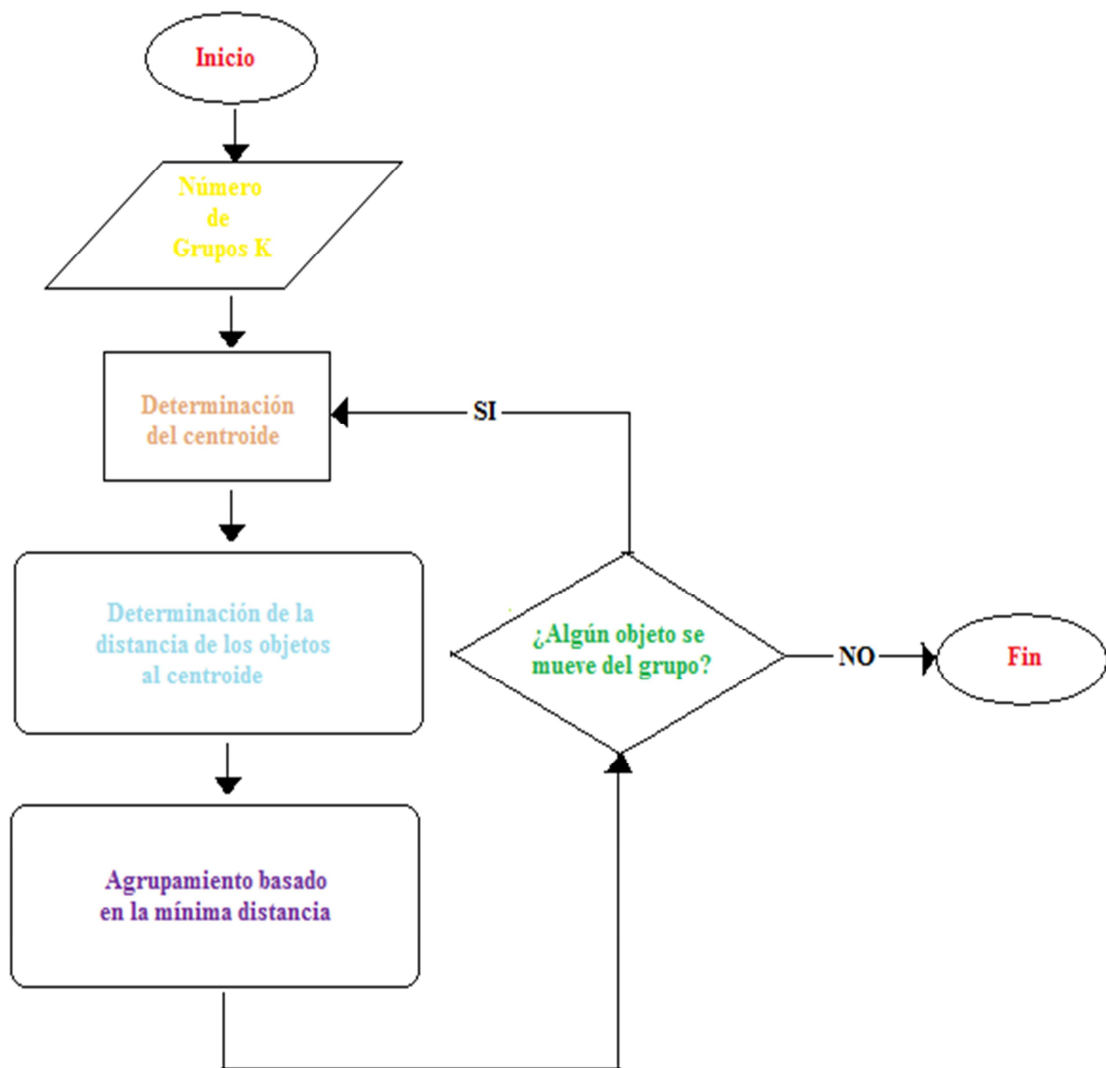


Figura 8.11: Algoritmo de clustering empleando de K-means

PARTE 3
MARCO METODOLÓGICO

CAPITULO 9

DESARROLLO EXPERIMENTAL

El objetivo del análisis de vibraciones es realizar un estudio riguroso de las señales vibratorias con el fin de determinar el estado de salud del equipo y detectar posibles anomalías mecánicas o funcionales de la misma. La etapa de adquisición de datos es el primer y principal paso a dar para llevar a cabo un buen análisis de vibraciones. La rigurosidad y la precisión en la toma de datos influirán en la exactitud del diagnóstico, ya que de una buena calidad de datos dependerá una correcta interpretación de los mismos.

En el caso de los rodamientos el análisis de vibraciones ha sido una de las herramientas más efectivas en la detección de fallas, la cual consiste en la medición de las señales de vibración en puntos claves donde se encuentran ubicados los rodamientos, permitiendo obtener la información necesaria del estado de salud del rodamiento. Estos elementos suelen ser fabricados y diseñados para ser los primeros en fallar dentro de una máquina, a raíz de su bajo costo y fácil sustitución. Por esta razón, es de gran importancia la constante vigilancia de su estado, para predecir el buen funcionamiento de la máquina.

En el presente documento se desarrolla una metodología de análisis y clasificación de fallos mecánicos en rodamientos de bola mediante el análisis de las vibraciones en dichos elementos, dentro del contexto del mantenimiento predictivo. El objetivo principal de esta metodología es detectar fallos con cierto nivel incipiente en rodamientos. Gracias a su simplicidad, se emplea el análisis temporal como herramienta para analizar las señales de vibración con distintos modos de fallo (fallo en pista interna, en pista externa o en bolas), ya que emplea valores globales y descriptores estadísticos para destacar ciertas características que posee la señal de vibración.

Posteriormente, se utilizan estas señales tratadas para diseñar un sistema clasificador basado en Modelos Ocultos de Markov (HMM) capaz de interpretar las vibraciones de distintos rodamientos y que posea la habilidad de distinguir si se está ante un rodamiento con fallo en bola, con fallo en la pista externa, con fallo en la pista interna o si por el contrario es un rodamiento en buen estado y sin defectos incipientes. La adquisición de las señales de vibración no forma parte del proyecto como tal, para tal fin se emplea una base de datos de una prueba de rodamientos normales y defectuosos obtenidas mediante el uso de acelerómetros, proporcionados por el Bearing Data Center de la Western Reserve University [34].

Para lograr implementar un sistema completo de análisis y clasificación de fallas, ver figura 8.1, se necesita el apoyo de personal calificado en el área del diagnóstico de fallas, en especial para el diseño y montaje del banco de pruebas para la adquisición de la base de datos. Sin embargo, cuando se dispone de una base de datos, como en nuestro caso, esta etapa no se tiene en cuenta. Por consiguiente, todos los esfuerzos se canalizan en el diseño de las otras fases que conforman el proceso de clasificación de fallas, que van desde la ya

mencionada base de datos, pasando por la extracción de características hasta el clasificador quien toma la decisión final.

9.1. Base de Datos

Organizar un archivo con los datos obtenidos en el análisis de vibraciones es muy útil para poder contar con una base de datos de cada elemento de una máquina que puedan servir como futuras referencias ante posibles anomalías. La importancia de contar con estos datos radica en la posibilidad que brindan poder llevar el monitoreo de su estado general y así poder elaborar la línea de tendencia de los equipos. Con estas lecturas se puede hacer una comparación con datos recientes y de esta manera poder monitorear las frecuencias de elementos críticos como son los rodamientos.

Es clave la adquisición de un conjunto de señales de vibración medidas en puntos claves donde se encuentran ubicados los rodamientos, con el fin de probar la eficiencia del sistema de clasificación de fallas basado en Modelos Ocultos de Markov (HMM). De igual forma, es importante tener una diversidad de registros tomados para diferentes tipos de fallas que permitan mostrar que el clasificador puede identificar la pertenencia de una señal a cualquiera de estos tipos de anomalías.

Este proyecto se centra en la detección de fallas en rodamientos empleando el dominio del tiempo como espacio de representación sobre una base de datos de una prueba de rodamientos normales y defectuosos, proporcionados por el Bearing Data Center de la Western Reserve University [34].

Esta central ha documentado cuidadosamente el estado de fallo del rodamiento para cada experimento, los cuales fueron realizados usando un motor eléctrico de 2 hp. El motor se conectó a un dinamómetro y a un sensor de par mediante un acoplamiento de auto alineación. Los datos de aceleración se midieron en ubicaciones cercanas y a distancia de los rodamientos. A los rodamientos se les crearon fallas artificiales mediante mecanizado por electro-descarga (EDM). Los fallos desde 0,007 pulgadas de diámetro a 0,040 pulgadas de diámetro y profundidades de 0.011024 pulgadas se introdujeron por separado en el anillo interior, los elementos rodantes (es decir, bola) y la pista de rodadura exterior.

Las especificaciones de los rodamientos empleados en la prueba fueron: diámetro de la bola 0.31260 pulgadas, diámetro de paso 1.537 pulgadas, número de bolas 9 y ángulo de contacto cero (0). Los rodamientos con falla fueron nuevamente instalados en el motor de prueba y los datos de vibración se registraron para cargas del motor de 0 a 3 hp (velocidad del motor de 1720 a 1797 RPM). La carga se aplicó utilizando el dinamómetro y los datos de velocidad y potencia se recolectaron a través de un transductor. Las señales de vibración se adquirieron a 12.000 muestras por segundo.

Los registros de las señales de vibración originales están almacenados en archivos con extensión (.mat) agrupados de acuerdo al estado de salud de los rodamientos: fallo en bola (Ball), fallo en la pista externa (Outer), fallo en la pista interna (Inner) o estado normal

(Normal). A su vez, cada falla se subdivide en tres niveles de severidad (N1, N2, N3) como se muestra en la figura 9.1:

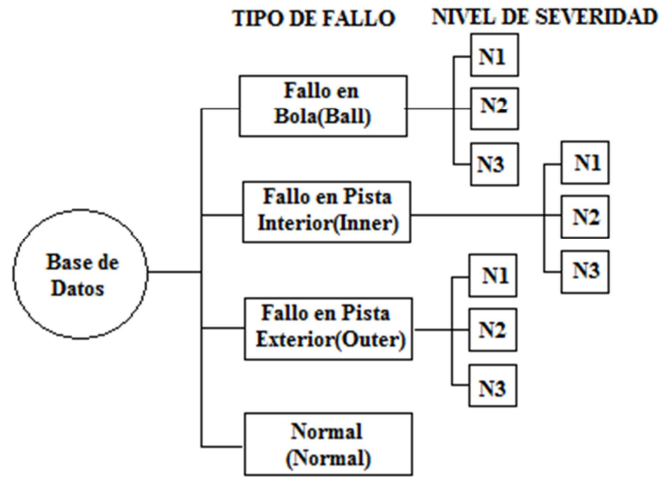


Figura 9.1: Distribución de la base de datos

Cada nivel de severidad (N1, N2, N3) correspondiente a cada tipo de falla (Ball, Outer, Inner y Normal) está compuesto por un conjunto de doce registros correspondientes a cuatro velocidades diferentes, donde cada registro almacena una matriz bidimensional de 40000x1, ver figura 9.2.

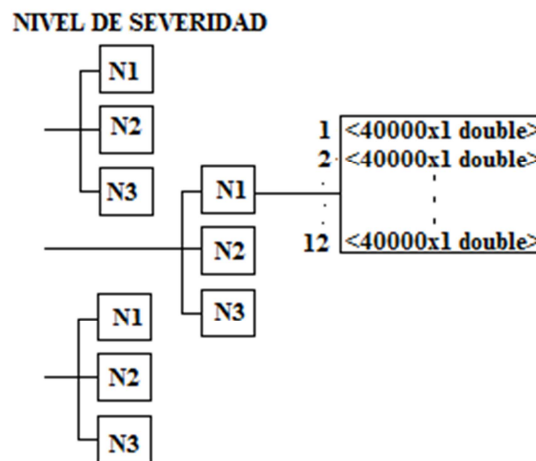


Figura 9.2: Distribución de la base de datos

Posteriormente, la base de datos es dividida en dos partes con el fin de poder realizar el entrenamiento y la validación del clasificador basado en Modelos Ocultos de Markov (HMM). La fase de aprendizaje le otorga al clasificador cierto conocimiento sobre las características de las señales de vibración; esta información es aprovechada por el clasificador para poder identificar la pertenencia de la señal a uno u otro tipo de fallo.

9.2. Segmentación

Como se mencionó en el capítulo 8 (sección 8.1), antes de realizar la extracción de características es importante dividir la señal de vibración de entrada en segmentos de igual tamaño (tramas o frames) que además de darle estacionalidad a las señales de vibración, permita también distinguir las partes de señal que contiene información relevante de aquella que posee la información redundante, evitando, de este modo, hacer cálculos innecesarios que solo incrementan la carga computacional y aumenta las probabilidades de obtener resultados erróneos en el análisis de las señales de vibraciones.

Recordemos que de una correcta fase de segmentación de la señal de vibración dependerá el nivel de precisión que se obtenga en el proceso de clasificación, ya que la incidencia de la etapa de segmentación de la señal en los resultados de la etapa de clasificación está condicionada por la cantidad de errores que se puedan cometer en el proceso de dividir las señales de entrada.

Para definir el intervalo de estacionalidad, las señales de vibración se dividen en N segmentos de longitud L que se traslapan entre sí. La longitud de los segmentos se eligió cuidadosamente con el fin de garantizar que estas tramas contenga la información suficiente como para capturar características localizadas de la señal de tal manera que el tiempo de cálculo sea mínimo y que sus características estadísticas permanezcan invariantes.

Los datos de vibración para cada estado de salud del rodamiento adquiridos a una velocidad de muestreo de 12000 muestras por segundo son segmentados por medio de tramas iguales de 200 ms y un traslape en tramas consecutivas de 800 muestras por frame con el fin de reducir pérdida de información por los bordes de las ventanas. Posteriormente los segmentos de datos son procesados para la extracción de características.

En la figura 9.3 se representa la señal de vibración en el dominio del tiempo. Las muestras de la señal se dividen en frames de igual tamaño de 200ms y conjuntos de 2400 muestras por ventana. Sobre cada conjunto de muestras correspondientes a una ventana se realiza la extracción de características.

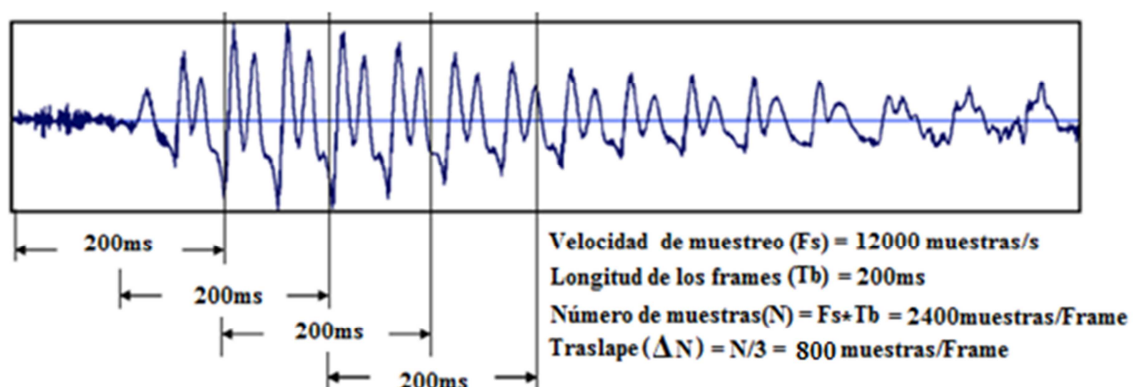


Figura 9.3: Segmentación de la señal de vibración

Al momento de diseñar la ventana se tuvo en cuenta la importancia que tiene la frecuencia de muestreo en la relación inversa existente entre la resolución frecuencial y la resolución temporal, ya que una vez fijada, se debe tener cuidado de no elegir una ventana tan grande que pudiera influir de manera negativa en la captación de cambios relevantes en la señal de vibración.

9.3. Extracción de Características

Como ya se mencionó anteriormente la etapa de extracción de características consiste en calcular y agrupar las cualidades de las señales de vibración en un formato de vector compacto, con el fin de crear una representación manejable y significativa de la señal de vibración original, que permita maximizar el éxito potencial de la fase de clasificación y a su vez el rendimiento global del sistema.

Es importante mencionar la importancia que tiene la fase de extracción de características en el desempeño y rendimiento general de la etapa de clasificación, ya que esta etapa, reduce el número de variables de entrada al clasificador extrayendo solo la información útil y comprimiendo los datos sin pérdida de información relevante.

Luego de la segmentación, sobre cada una de las tramas de las señales de vibración originales se calcularon las siguientes características estadísticas que representan el comportamiento temporal de la señal:

1. Valor Medio o Mean Value (V_m): Considerado como el primer momento estadístico. Este parámetro permite identificar el valor medio absoluto de la señal $x(n)$, en un determinado segmento, el cual tiene una longitud de N muestras. Donde, $x(n)$ representa los valores de la señal discreta, y N el número de puntos medidos [53].

Cabe resaltar lo sensible que resulta ser este parámetro a la aparición de interferencias o valores irregulares que se obtienen en el proceso de adquisición de la señal. El valor medio se expresa como la suma de todas las amplitudes de la señal $x(n)$, entre la longitud de la señal N , a través de la ecuación 9.1.

$$V_m = \frac{\sum_{n=1}^N x(n)}{N} \quad (9.1)$$

2. Desviación estándar o Standard Deviation (std): Considerado como el segundo momento estadístico de la señal. Sirve para cuantificar el grado de variabilidad y dispersión que presentan las amplitudes con respecto al valor medio (V_m) [26].

$$std = \sqrt{\frac{\sum_{n=1}^N (x(n) - V_m)^2}{N-1}} \quad (9.2)$$

3. Asimetría o Skewness (S_w): Considerado como el tercer momento estadístico. Permite establecer el grado de simetría (o asimetría) que presenta una distribución de probabilidad alrededor de la media. Una asimetría positiva indica una distribución con valores más separados de la media a la derecha y una asimetría negativa indica una distribución que se extiende a la izquierda. Este parámetro llega a ser tan eficiente como la kurtosis cuando los datos son expuestos a un proceso de normalización inicialmente. Se diferencia del valor de kurtosis tradicional por poseer una menor susceptibilidad a vibraciones adulteradas y una menor sensibilidad al cambio de carga y velocidad [26].

$$S_w = \frac{\sum_{n=1}^N (x(n) - Vm)^3}{(N-1)std^3} \quad (9.3)$$

4. Kurtosis (K_v): Considerado como el cuarto momento estadístico. Este parámetro hace énfasis en los incrementos de valor pico (causados por impactos) de una señal en el tiempo y da cuenta de la medida de picos o valles relativos de la distribución comparada con una distribución normal. Es empleado como un indicador de picos mayores en el conjunto de datos. Pese a ser un parámetro poco sensible a los cambios de carga, se ha demostrado que el valor de Kurtosis mayor a 3 (considerado como principio de falla en los rodamientos [56]) sólo es alcanzable en señales de tipo impulsivo. Sin embargo, posee la ventaja de no depender de las variaciones de carga y velocidad para calcular su valor [54].

Es importante mencionar la similitud existente entre este parámetro y el factor cresta, ya que en ambos a medida que la falla evoluciona su valor tiende a disminuir.

$$K_v = \frac{\sum_{n=1}^N (x(n) - Vm)^4}{(N-1)std^4} \quad (9.4)$$

5. Pico positivo máximo o Peak value (P_v): Es el nivel máximo de la señal adquirida, este valor resulta de mucha utilidad con otros estadísticos. Específicamente hablando, resulta muy conveniente su utilización en el monitoreo de la variación de los niveles de impulsividad, propiciado por impulsos que alimentan de forma gradual la falla. Sin embargo, la confiabilidad de este parámetro queda en entre dicho, ya que también existen otras anomalías que pueden influir en la alteración de los niveles pico de la señal adquirida, tales como movimientos violentos del sensor, interferencias o ruidos [54].

$$P_v = \max|x(n)| \quad (9.5)$$

6. Raíz media cuadrática o Root Mean Square (RMS): El valor RMS de una señal de vibración representa un promedio del nivel de vibración en el rodamiento, es un valor muy sensible a cambios en la carga. Permite estimar el grado de severidad de una falla cuando se sensa un valor y se compara con datos de referencia establecidos previamente en rodamientos sin falla. Realizando medidas periódicas permite visualizar tendencias que facilitan la evaluación de la condición del rodamiento. La aproximación más básica para la

medición de defectos en el dominio del tiempo es usar la aproximación RMS , sin embargo no es un buen estimador para detección temprana de fallas incipientes en particular [55].

$$RMS = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}} \quad (9.6)$$

7. Factor de forma o Shape Factor (Shf): Es la relación entre el valor RMS y la media de la magnitud de la señal $x(n)$. Este parámetro permite concentrar el valor RMS con el fin de minimizar la imprecisión que se crea en el momento de capturar los datos.

$$Shf = \frac{RMS}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (9.7)$$

8. Factor de cresta o Crest Factor (Cr_f): Ante la incapacidad del valor RMS de detectar alteraciones importantes en etapas prematuras de falla en engranes y rodamientos, surge como alternativa el (Cr_f), el cual es la relación entre el valor pico (Pv) de la señal de entrada y el valor RMS . Aunque no es considerado un estadístico muy sensible, permite detectar incrementos de valor pico con respecto al valor promedio [53].

Este parámetro es también muy usado en la detección de cambios en el comportamiento de la señal debido a fuentes generadoras de vibraciones impulsivas como pueden ser un diente roto en un engranaje o un defecto en la pista externa de un rodamiento.

$$Cr_f = \frac{Pv}{RMS} \quad (9.8)$$

9. Factor k (K): Es un parámetro muy sensible a los impactos, caracterizado por la relación de proporcionalidad existente entre el factor k (K) y los valores RMS y el valor pico (Pv); es decir, en caso de una disminución o un aumento en el valor RMS o el valor pico, el factor k disminuirá o aumentará de igual manera [57].

Contrario a lo que sucede con el decreciente valor del factor de cresta (Cr_f) en la etapa final de una falla, este parámetro sufre un aumento del valor RMS y una disminución en el nivel de los impactos producidos cuando una falla está en pleno desarrollo. Así el factor k se expresa como peak veces el valor RMS , a través de la ecuación 9.9.

$$K = Pv * RMS \quad (9.9)$$

10. Valor fundamental o Root value (Rv) = Es un valor equivalente al cociente entre el nivel máximo de la señal y el factor de holgura.

$$Rv = \left(\frac{\sum_{n=1}^N \sqrt{|x(n)|}}{N} \right)^2 \quad (9.10)$$

10. Factor de holgura o Clearance factor (*Clf*): Es la relación entre el pico máximo de la vibración analizada y el valor fundamental (*Rv*) de la señal $x(n)$. Este parámetro permite normalizar el valor del pico (*Pv*) con el fin de minimizar posibles ambigüedades que se generan en el momento de adquirir los datos.

$$Clf = \frac{Pv}{\left(\frac{\sum_{n=1}^N \sqrt{|x(n)|}}{N}\right)^2} \quad (9.11)$$

12. Factor de impulso o Impulse factor (*Imf*): Es la relación entre el nivel máximo de la señal adquirida y la media de la magnitud de la señal $x(n)$. Este parámetro permite concentrar el valor del pico (*Pv*) con el fin de minimizar la imprecisión que se crea en el momento de capturar los datos.

$$Imf = \frac{Pv}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (9.12)$$

13. Límite superior del histograma o Histogram upper bound (*UB*): Proporciona un panorama generalizado de los valores demarcados en el extremo superior de un conjunto de muestras; beneficiando el proceso de análisis de los datos de la señal, al permitirle evidenciar más fácilmente ciertas preferencias, tendencias, esquemas de comportamiento y pautas de variación de algún valor asociado con un falla que puede ser difícil de captar con otros parámetros. Es la relación entre la diferencia del dato mayor $\max(x(n))$ y el dato menor $\min(x(n))$ de las amplitudes en un conjunto de muestras y el número de puntos de muestreo N ; resultado, que luego de ser redondeado al entero mayor más cercano, se combina con el valor de amplitud máxima de la señal $\max(x(n))$ en este intervalo [24].

$$UB = \max(x(n)) + 0.3 * \left(\frac{\max(x(n)) - \min(x(n))}{N-1}\right) \quad (9.13)$$

Donde $x(n)$ es la amplitud en el punto de muestreo y N es el número de puntos de muestreo.

14. Límite inferior del histograma o Histogram lower bound (*LB*): De la misma manera como ocurre con el límite superior del histograma; este permite evidenciar comportamientos, variabilidades, tendencias y valores atípicos relacionados con una falla, que se encuentran acotados en el extremo inferior de un conjunto de muestras. Es la relación entre la diferencia del dato mayor $\max(x(n))$ y el dato menor $\min(x(n))$ de las amplitudes en un conjunto de muestras y el número de puntos de muestreo N ; resultado, que luego de ser redondeado al entero mayor más cercano, es sustraído del valor de amplitud máxima de la señal en este intervalo [24].

$$LB = \min(x(n)) - 0.3 * \left(\frac{\max(x(n)) - \min(x(n))}{N-1}\right) \quad (9.14)$$

Donde $x(n)$ es la amplitud en el punto de muestreo y N es el número de puntos de muestreo.

15. Valor de la verosimilitud logarítmica negativa de Weibull o Weibull negative log-likelihood value (Wnl): El valor Wnl de las señales de vibración en el dominio del tiempo, se utiliza como parámetro de entrada junto con las otras características definidas anteriormente en este documento [37]; la función Wnl está definida por la ecuación 9.15:

$$Wnl = -\sum_{n=1}^N \log(\text{Weibullpdf}(f((x_i; \beta, \alpha))) \quad (9.15)$$

Para calcular la función de distribución de probabilidad se emplea la ecuación 9.16:

$$\text{Weibullpdf}(f((x_i; \beta, \alpha))) = \beta \alpha^{-3} |x_i|^{\beta-3} \exp\left(-\frac{(x_i)^\beta}{\alpha}\right) \quad (9.16)$$

Donde β y α son los parámetros de forma y escala respectivamente.

16. Valor de la verosimilitud logarítmica negativa Normal o Normal negative log-likelihood value (Nnl): El valor Nnl de las señales de vibración en el dominio del tiempo, se utiliza como parámetro de entrada junto con las características anteriormente definidas en este documento [37]. La función Nnl está definida por la ecuación 9.17:

$$Nnl = -\sum_{n=1}^N \log(\text{Normalpdf}(f((x_i; \mu, \sigma))) \quad (9.17)$$

Para calcular la a función de distribución de probabilidad se emplea la ecuación 9.18:

$$\text{Normalpdf}(f((x_i; \mu, \sigma))) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_i-\mu}{\sigma}\right)^2} \quad (9.18)$$

Donde μ y σ son la media y la desviación estándar respectivamente.

17. Entropía (E): Es una característica que usualmente es conocida como una medida de la incertidumbre de un proceso [24].

Para un conjunto de eventos con función densidad de probabilidad $P\{x_i, i= 1,2,\dots,N\}$, la entropía de Shannon es definida por la ecuación 9.19:

$$E = -\sum_{n=1}^N P(x(n)) \log P(x(n)) \quad (9.19)$$

Donde $P(x(n))$ son las probabilidades calculadas de la distribución x_i .

18. Raíz media cuadrática de los picos o RMS of Peaks (\tilde{x}_{peak}): Es una característica derivada de un análisis de estadísticos calculados a partir de partes de la señal de tiempo en la que se tiene en cuenta la respuesta de impulso de impacto. La idea general parte de la utilización de secciones de la señal que poseen una estrecha relación con las fallas en los

rodamientos. Los picos de la señal de vibración son detectados para ser empleados en el proceso de generación de este parámetro [40].

El valor *RMS* de todas las amplitudes de los máximos locales (picos) en la señal de vibración normalizada se expresa a través de la ecuación 9.20:

$$\tilde{x}_{peak} = \sqrt{\frac{1}{N} \sum_{n=1}^N x_{npeak}^2} \quad (9.20)$$

19. Desviación estándar de los picos o Standard Deviation of Peaks (σ): Al igual que el valor *RMS* de los picos, este parámetro hace uso de los picos máximos de la señal como fuente de información correspondiente a los fallos de rodamientos. Permite cuantificar el grado de inestabilidad y dispersión que presentan las amplitudes de los máximos locales (pico) con respecto a su valor medio [40].

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_{npeak} - \tilde{x}_{peak})^2} \quad (9.21)$$

20. Valor RMS de la distancia entre picos o RMS of Peak Distance ($\tilde{\delta}_{posi Peak}$): Permite extraer la parte interesante de la señal de vibración que contiene la información deseada tomando en cuenta la variación de la distancia entre máximos locales (picos) en lugares adyacentes o no adyacentes sobre un valor de desplazamiento preestablecido [40].

$$\tilde{\delta}_{posi Peak} = \sqrt{\frac{1}{N} \sum_{n=1}^N \delta_{n\ posi Peak}^2} \quad (9.22)$$

9.4. Clasificación

Una de las técnicas que en la actualidad se utiliza para representar procesos aleatorios paramétricos, a partir de una cantidad limitada de variables de entrada, son los Modelo Ocultos de Markov (HMM).

Uno de los principales requerimientos al usar los Modelos Ocultos de Markov (HMM) es la correcta selección de la arquitectura y de los parámetros del clasificador. Para ello, se requiere contar con una base de datos lo suficientemente amplia para el entrenamiento y para la validación del clasificador. Se dividen los datos muestrales en dos partes; una parte se utiliza como conjunto de entrenamiento para determinar los parámetros del clasificador y la otra parte, llamado conjunto de validación, se utiliza para verificar el modelo. Aunque se suele utilizar el 70% de los datos para entrenar y el 30% como conjunto de validación, es posible trabajar con otros porcentajes, ya que no se está supeditado a este criterio.

El enfoque dado por los Modelos Ocultos de Markov (HMM) establece que cada señal es modelada por una red de transición la cual tiene un número de N estados, que corresponden con los estados no observables del sistema.

En general, la estructura de un clasificador de fallas en rodamientos basado en Modelos Ocultos de Markov (HMM) puede ser vista como un módulo donde entra una señal de vibración, después se segmenta con el fin de separar los datos en subgrupos o clases que pueden ser mutuamente exclusivas o jerárquicas y con traslapes, y pasa a un análisis donde se extrae un conjunto de estadísticos generando un vector de características; posteriormente, en la fase de entrenamiento se aplica el método de HMM y se crea un modelo para cada señal y finalmente en la fase de validación se verifica la confiabilidad del sistema y se procede al reconocimiento del tipo de falla obteniendo los resultados de dicha clasificación.

En este documento se modela un sistema clasificador de fallas basado en Modelos Ocultos de Markov (HMM) mediante la determinación de sus componentes o fases como son, la base de datos, la segmentación, la extracción de características, el entrenamiento y validación de los modelos y la clasificación de fallas; de igual manera, el software para cada fase está basado en un lenguaje matemático que ofrece un entorno de desarrollo integrado con un lenguaje de programación propio como MATLAB, pues contiene un toolbox dedicado al entrenamiento y clasificación de modelos usando Modelos Ocultos de Markov (HMM). Cabe resaltar que el sistema clasificador se conforma de pequeños algoritmos utilizables por cada fase, permitiendo verificar su buen funcionamiento a medida que se implementa el sistema.

Para la selección correcta de los parámetros del clasificador y para determinar la capacidad de generalización del mismo se utiliza la herramienta de validación cruzada; consistente en un conjunto de datos de entrenamiento, usados para seleccionar el modelo y un conjunto de datos de test, usados para evaluar o validar el modelo [10].

Entiéndase la validez como la capacidad que tiene un instrumento (sistema clasificador) para medir lo que intenta medir (discriminar elemento con y sin falla), sólo si existe un procedimiento de referencia (entrenamiento de modelos). Para tal situación, es necesario entender dos conceptos importantes como lo son la sensibilidad y la especificidad de una prueba.

La sensibilidad de una prueba responde a las preguntas de: ¿Cuántos resultados positivos se obtendrán en los elementos con falla? y ¿Cuántos casos del total de casos en la base de datos estudiada pueden identificarse por el resultado de la prueba?; mientras que la especificidad de una prueba responde a las preguntas de : ¿Cuántos resultados negativos se obtendrán en elementos sin falla? y ¿Cuántas veces el elemento sin falla se confirmará por el resultado de la prueba?. Para definir la sensibilidad y la especificidad se parte de la información entregada por el sistema clasificador concerniente a las clasificaciones actuales y predicciones hechas por el clasificador tras la ejecución del algoritmo.

El diseño de una matriz ($n \times n$) conocida como matriz de confusión, donde (n) representa el número de clases, permite visualizar los resultados tras la ejecución del algoritmo. Cada

columna de la matriz representa los casos en una clase real, mientras que cada fila representa los casos que el algoritmo predice, ver tabla 9.1:

		Diagnóstico actual (Real)	
		Falla (+)	Normal (-)
Decisión del Clasificador (Predicción)	Falla (+)	<i>vp</i>	<i>fp</i>
	Normal (-)	<i>fn</i>	<i>vn</i>

Tabla 9.1: Aspecto general de una matriz de confusión

Dónde:

- Verdaderos Positivos (*vp*): Son los casos que pertenecen a la clase y el clasificador los definió en esa clase.
- Falsos Negativos (*fn*): Son los casos que si pertenecen a la clase y el clasificador no los definió en esa clase.
- Falsos Positivos (*fp*): Son los casos que no pertenecen a la clase pero el clasificador los definió en esa clase.
- Verdadero Negativos (*vn*): Son los casos que no pertenecen a la clase y el clasificador definió que no pertenecen a esa clase.

Con base en esto se define lo siguiente:

- Tasa de verdaderos positivos (*tvp*) o sensibilidad: Es el cociente entre el número de registros con falla correctamente clasificados y el número total de datos con falla.

$$tvp = vp / (vp + fn) \quad (9.23)$$

- Tasa de falsos negativos (*tfn*): Es el cociente entre el número de registros con falla incorrectamente clasificados y el número total de datos con falla.

$$tfn = fn / (vp + fn) \quad (9.24)$$

- Tasa de verdaderos negativos (*tvn*) o especificidad: Es el cociente entre el número de registros normales correctamente clasificados y el número total de datos normales o sin falla.

$$tvn = vn / (vn + fp) \quad (9.24)$$

- Tasa de falsos positivos (*tfp*): Es el cociente entre el número de registros normales incorrectamente clasificados y el número total de datos normales o sin falla.

$$tfp = fp/(vn + fp) \quad (9.24)$$

- Exactitud (*e*): Proporción del total de predicciones correctas.

$$e = vp + vn/(vp + vn + fn + fp) \quad (9.25)$$

Una vez entregados los resultados por cada clasificador, el conjunto de pares ordenados (1-Especificidad, Sensibilidad) obtenidos, se representan gráficamente con ayuda de la curva característica operativa del receptor (ROC, por sus siglas en inglés). En este tipo de curvas se trata el resumen de la validez de una determinación continua para diferentes valores límite (puntos de corte), ver figura 9.4.

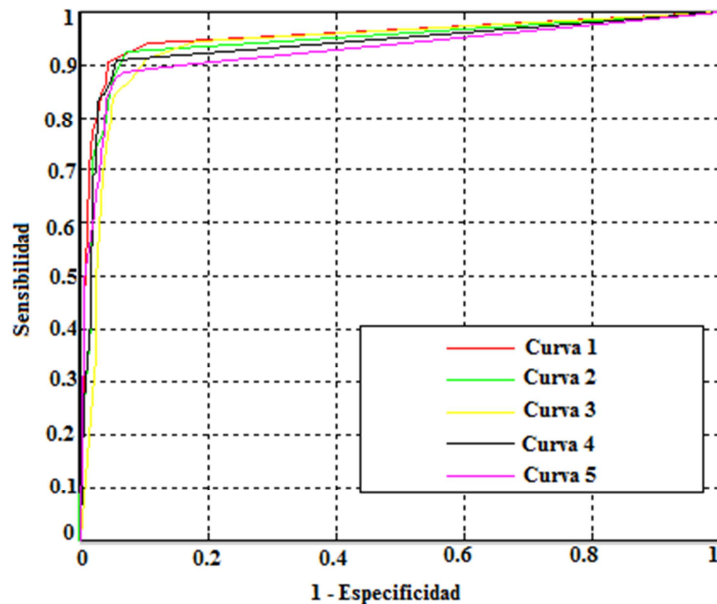


Figura 9.4: Curva ROC

En la gráfica anterior, se muestran algunas de las pendientes que se pueden obtener así como el valor nominal de cada una de ellas. Cabe mencionar que el criterio para el establecimiento del valor de la gráfica depende de factores como el tipo de falla a estudiar. Sin embargo, una interpretación generalmente aceptada se lleva a cabo mediante el análisis del área bajo la curva (AUC), que es una medida global de la calidad diagnóstica. El AUC es la probabilidad de clasificar correctamente un par de elementos (sano y con falla) seleccionados al azar de la base de datos, mediante los resultados obtenidos al aplicarles la prueba diagnóstica.

Para valores de AUC en el intervalo de [0.5-0.7], la exactitud de la prueba es baja, valores entre [0.7-0.9], pueden resultar útiles sólo bajo ciertas condiciones; en cambio, un valor mayor a 0.9, indica que existe una perfecta separación entre las distribuciones, indicando una alta exactitud de la prueba.

CAPITULO 10

METODOLOGÍA

Considerando la amplia variedad de registros de la base de datos de una prueba de rodamientos normales y defectuosos, proporcionados por el Bearing Data Center de la Western Reserve University [34], se realizan varias pruebas para mostrar la capacidad discriminante y la eficiencia de un sistema clasificador de fallas en rodamientos basado en Modelos Ocultos de Markov (HMM) que emplea el dominio del tiempo como espacio de representación, verificando el desempeño general de las fases de entrenamiento y validación de los HMM.

El conjunto de datos se divide en dos partes, la primera se utiliza como conjunto de entrenamiento con el fin de determinar los parámetros del clasificador y la segunda se utiliza como conjunto de validación para verificar el modelo. Para dotar al sistema de la capacidad suficiente de poder construir un modelo o clasificador a partir del conjunto de datos de entrenamiento, se emplea un aprendizaje inductivo no supervisado, el cual permite visualizar el efecto causado por cada uno de los grupos de datos que son tomados como ejemplos de entrada, en el proceso de obtención del concepto final, basándose en la similitud y disimilitud entre grupos. En otras palabras, La fase de aprendizaje de este clasificador consiste en almacenar en formato de vector compacto el conjunto de datos de entrenamiento, junto a la clase asociada a cada muestra de este conjunto [67].

Para ello se emplea un algoritmo inductivo no supervisado o clustering, con el fin de agrupar datos en grupos de tal forma que los elementos de un clúster posean una elevada similitud entre ellos, y una elevada disimilitud con elementos de otros clusters. Como algoritmo de clustering se emplea el K-means por su elevada simpleza y eficacia a la hora de ser aplicado.

Con el fin de garantizar la validez estadística de los resultados y poder precisar si el clasificador es capaz de generalizar, es decir si presenta buenos resultados al introducir datos no empleados durante el entrenamiento, se emplea un esquema de validación cruzada, con diferentes conjuntos de entrenamiento-validación (kfold), aleatoriamente escogidos del conjunto completo de datos. En este trabajo se emplean 10 conjuntos, utilizando el 70% de los datos para el entrenamiento y el 30% restante para la validación. Inicialmente se determinan el modelo con el número de estados óptimo y el número K de centroides óptimo del sistema; una vez definidos estos parámetros de entrada, se realiza un análisis de relevancia de características, con el fin de encontrar el conjunto óptimo de características.

Finalmente se comprueba el tiempo de CPU empleado, en segundos, desde que se ejecuta el programa, con el fin de evaluar el tiempo demandado por el algoritmo, antes y después del análisis de relevancia, es decir, primero empleando la totalidad de las características extraídas y luego el conjunto óptimo de características que se definió.

Como ya se mencionó antes, el objetivo de este proyecto de grado es realizar la implementación de un sistema de clasificación basado en Modelos Ocultos de Markov (HMM) capaz de discriminar fallas en rodamientos a partir del análisis en el dominio del tiempo de señales de vibraciones. Para este fin se llevan a cabo una serie de pruebas sobre el algoritmo propuesto buscando definir la capacidad discriminante y la eficiencia del sistema clasificador de fallas en rodamientos basado en HMM. Se emplean los toolboxes contenidos en MatLab™ como herramientas dedicadas al tratamiento digital de señales y a las funciones estadísticas relacionadas a los HMM. Dichas herramientas se emplearon para entrenar los modelos y clasificar las señales de vibración.

10.1. Prueba 1 (Prueba de modelos)

Para la realización de esta prueba se empleó la base de datos proporcionada por el Bearing Data Center de la Western Reserve University [34], para cuatro estados de salud: fallas en anillo interior (Inner), fallas en elementos rodantes (ball), fallas en anillo exterior (Outer) y un nivel base (normal).

La base de datos se segmentó en tramas iguales traslapadas entre sí y a cada una de ellas se le realizó la extracción de características empleando el algoritmo propuesto y empleando parámetros estadísticos en el dominio del tiempo como; Valor pico o Peak value (Pv), Raíz media cuadrática o Root mean square (RMS); Factor de cresta o Crest factor (Cr_f), Kurtosis (Kv), Asimetría o Skewness (Sw), Factor de holgura o Clearance factor (Cl_f), Valor fundamental o Root value (Rv), Factos k (K), Factor de impulso o Impulse factor (Im_f), Factor de forma o Shape factor (Sh_f), Desviación estándar o Standard deviation (std), Valor de la verosimilitud logarítmica negativa Normal o Normal negative log-likelihood value (Nnl), Valor de la verosimilitud logarítmica negativa de Weibull o Weibull negative log-likelihood value (Wnl), Entropía o Entropy (E), Límite superior del histograma o Histogram upper bound (UB), Límite inferior del histograma o Histogram lower bound (LB), Raíz media cuadrática de los picos o RMS of Peaks (\tilde{x}_{peak}), Desviación estándar de los picos o Standard deviation of peaks (σ) y Raíz media cuadrática de las distancias entre picos o RMS of peak distance ($\tilde{\delta}_{posi\ Peak}$). Una vez se realizó la extracción de características a cada segmento, toda esta información se almacenó en vectores de características (VibCaract).

Antes de realizar el entrenamiento y la validación de los Modelos Ocultos de Markov (HMM), se generó el libro de códigos (codebook), empleando para ello los vectores de características (VibCaract), los cuales se dividieron en dos partes: una parte se utilizó como conjunto de entrenamiento para determinar los parámetros del clasificador y la otra parte se utilizó como conjunto de validación para verificar el modelo.

Los conjuntos de entrenamiento se almacenaron en vectores de entrenamiento denominados X_{train} , los cuales se emplean en conjunto con el número de centroides (NumCen) para generar el libro de código (codebook). Es importante recordar que en la generación de los centroides, jugó un papel determinante el algoritmo de clustering de K-medias para el ajuste de los centroides; cada fila corresponde a un vector y K es el número deseado de

clusters o grupos. Una vez se obtuvo el libro de código, la información se almacenó en un vector denominado (VibCode).

En la etapa de entrenamiento de los HMM, se cargaron los vectores de entrenamiento (X_{train}), el libro de códigos (VibCode) y se definen el número de estados del modelo (NumEst). Se debe recordar que los vectores de entrenamiento son arreglos de matrices, donde cada matriz contiene los parámetros estadísticos obtenidos en la extracción de características. Finalmente se comprobó si el clasificador era capaz de generalizar, es decir si presentaba buenos resultados al introducir datos no empleados durante el entrenamiento en la etapa de validación, para lo cual se cargó el restante conjunto de datos en un vector de validación identificado como X_{prueba} . Una vez realizado lo anterior, se verificó el desempeño del sistema clasificador construyendo las curvas de evaluación de desempeño ROC, evaluando el rendimiento general en función de sensibilidad vs 1 - especificidad.

Cabe aclarar que este procedimiento fue efectuado empleando la totalidad de las características extraídas sobre todo los diferentes valores de centroides y para cada uno de los 5 estados analizados (en el intervalo [2, 6]), con el fin de obtener el mejor resultado representado por el nivel de eficiencia expresado por el área bajo la curva ROC.

10.2 Prueba 2 (Prueba de libro de código)

La prueba se efectuó con el objetivo de encontrar el número óptimo de los K vectores representativos o centroides de las señales de vibración de entrenamiento, con las cuales se generó el libro de códigos. La prueba partió con la configuración inicial del algoritmo, fijando el número de estados en 2 y particionando el conjunto total de vectores de características en 70% para entrenamiento y el 30% restante para validación. Se realizaron 100 iteraciones por cada grupo de centroides evaluado (en el intervalo [2, 32]). El promedio de los resultados finales se muestra a través de tablas, construidas a partir del cálculo de la tasa de verdaderos positivos (o sensibilidad), tasa de falsos negativos, tasa de verdaderos negativos (o especificidad) y tasa de falsos negativos. La tasa de acierto final se calculó como el cociente entre el número de registros correctamente clasificados y el número total de registros.

10.3. Prueba 3 (Análisis de relevancia)

La prueba se realizó con el fin de discriminar aquellas características que no poseían un aporte significativo de relevancia y que por el contrario pudieran minimizar el óptimo rendimiento de los algoritmos de estimación de parámetros para los modelos ocultos de Markov. Las pruebas se realizaron inicialmente con una sola característica evaluando el desempeño de clasificación cuando se tiene una sola coordenada, luego se incrementa la dimensión del espacio añadiendo otra característica y evaluando de nuevo el desempeño de clasificación, este proceso se repite hasta completar el total de características con las que se cuenta. La forma de incrementar la dimensión se realizó inicialmente en forma aleatoria y posteriormente en orden ascendente y orden descendente. Por último se evaluó el tiempo de ejecución requerido por el algoritmo, antes y después del análisis de relevancia.

PARTE 4
RESULTADOS Y DISCUSIÓN

CAPITULO 11

PRUEBA 1 (PRUEBA DE MODELOS)

La prueba se realizó sobre una base de datos proporcionada por el Bearing Data Center de la Western Reserve University [34], para cuatro estados de salud: fallas en anillo interior, fallas en elementos rodantes (bola), fallas en anillo exterior y un nivel base (normal). Cada tipo de falla posee tres niveles de severidad y cuatro velocidades diferentes. Los datos de vibración para cada estado de salud del rodamiento fueron adquiridos a una velocidad de muestreo de 12000 muestras/segundo.

Una vez cargada la base de datos, esta se segmentó en tramas iguales de 200 ms y un traslape entre tramas consecutivas del 50%, obteniéndose conjuntos de muestras de 2048 muestras/frame. Una vez obtenidas las tramas de la señal con la segmentación, a cada una de ellas se le realiza la extracción de características empleando parámetros estadísticos en el dominio del tiempo. Cada trama generó un conjunto de características que se almacenaron en vectores de características denominados (VibCaract).

El conjunto total de vectores de características (VibCaract) se divide de manera aleatoria en dos partes, una se utiliza como conjunto de entrenamiento para determinar los parámetros del clasificador y la otra parte se utiliza como conjunto de validación para ajustar el modelo. Tomando en cuenta criterios orientativos se empleó como punto de partida el 70% de los datos para entrenamiento y el 30% restante como conjunto de validación. Sin embargo, una vez definido el modelo con el número de estados óptimo, se tuvieron en cuenta otros conjuntos de entrenamiento-validación (40-60, 50-50, 60-40, 80-90, 90-10) en la evaluación del desempeño del sistema clasificador, con el fin de encontrar el porcentaje de entrenamiento-validación que mejor eficiencia brinda al sistema, pero sin perder capacidad de generalización.

Teniendo en cuenta que el tipo de distribución empleado para modelar la estadística de observación por estado fue discreta, se realizó la generación del libro de códigos mediante el algoritmo de clustering de K-medias, con el cual se estimaron los K centroides en el espacio de representación y luego se asociaron vectores de observación a un centroide determinado (el más cercano).

Empleando Modelos Ocultos de Markov (HMM) con una distribución de observación discreta y aplicando la totalidad de las características extraídas, se realizó la evaluación de la calidad diagnóstica del sistema de clasificación para varios casos en los que se modificó el número de estados de los modelos ocultos de Markov (en el intervalo [2, 6]), donde, haciendo un barrido sobre el conjunto [2,4,6,8,10,12,14,16,20,24,28,32] de vectores representativos o centroides de la señal y empleando el 70% de los datos para el entrenamiento y el 30% restante para la validación, se buscó seleccionar el modelo más óptimo.

A continuación se muestran los resultados obtenidos después de promediar los datos arrojados por el algoritmo propuesto tras haberlo corrido veinte (20) veces por cada modelo

evaluado, realizando el recorrido a través del conjunto [2,4,6,8,10,12,14,16,20,24,28,32] de centroides; inicialmente sobre el conjunto de entrenamiento-validación (70-30), con el objetivo de encontrar el modelo con el número óptimo de estados. El desempeño mostrado por cada modelo evaluado se reflejó en las curvas ROC, expresando la calidad diagnóstica en términos del conjunto de pares ordenados (1-Especificidad, Sensibilidad) y la medida global de la exactitud diagnóstica determinada a partir del área bajo la curva (AUC) para cada estado analizado permitió comparar los diferentes resultados obtenidos para determinar con cual parámetro (números de estados) se obtuvieron los mejores resultados.

11.1.HMM de Dos (2) Estados

Asignado inicialmente dos (2) estados al modelo y empleando el 70% de los datos para entrenamiento y el 30% restante como conjunto de validación sobre el conjunto de 12 libros de códigos [2,4,6,8,10,12,14,16,20,24,28,32], se obtuvo una matriz ROC, que al graficarla presentó la curva de desempeño de la figura 11.1.

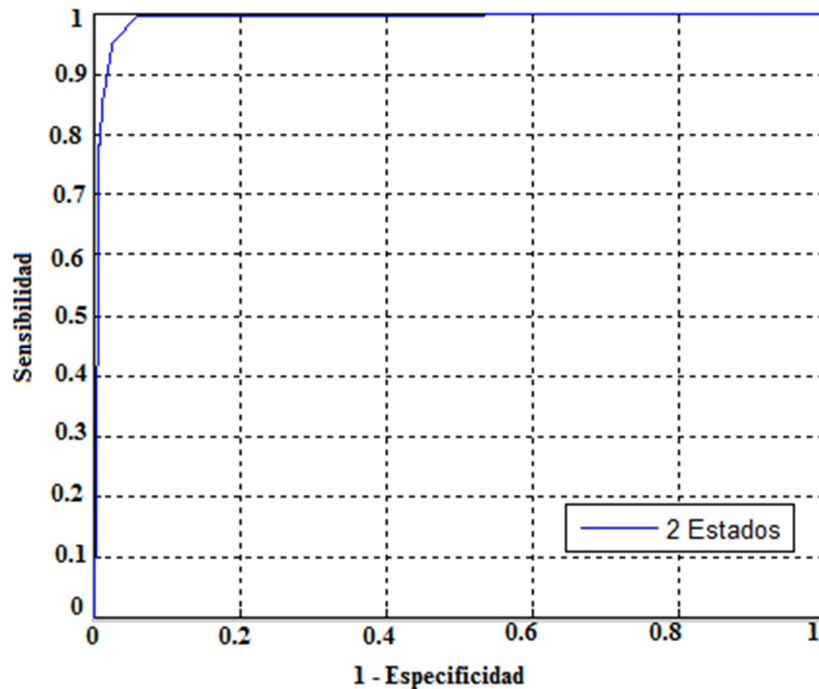


Figura 11.1: Rendimiento del sistema para HMM de dos (2) estados

Para determinar la capacidad o calidad discriminativa del sistema, cuantificada en su habilidad para distinguir señales de rodamientos en buen estado (normal) versus rodamientos con falla (fallas en anillo interior (Inner), fallas en elementos rodantes (ball) y fallas en anillo exterior (Outer)) se estimó el área bajo la curva ROC (AUC, area under the curve), ver figura 11.2. Este parámetro permitió determinar qué tan bueno era el sistema para discriminar señales con y sin falla a lo largo de todo el rango de puntos de corte posibles para los diferentes números de estados del modelo; en este primer caso para HMM de dos (2) estados.

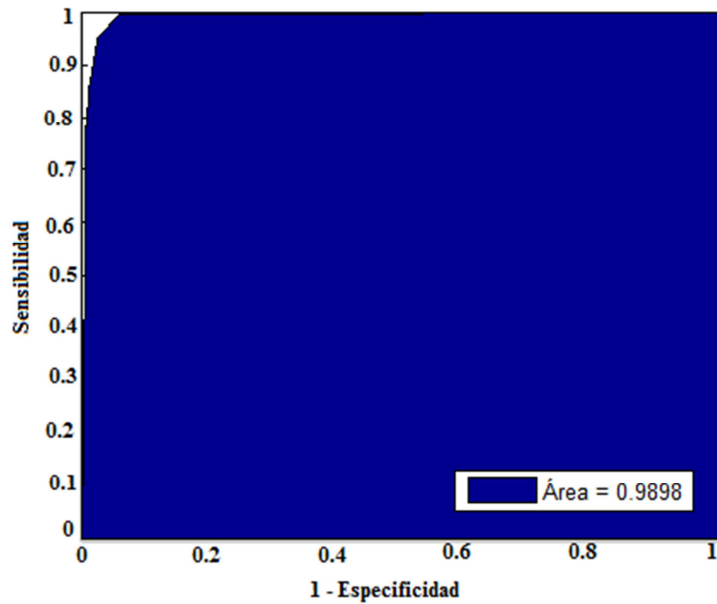


Figura 11.2: Área bajo la curva ROC (AUC) para HMM de dos (2) estados

Con el fin de eliminar posibles ruidos u otras estructuras a escala fina (fenómenos rápidos) y poder capturar exclusivamente las tendencias importantes evitando datos repetidos, se le aplicó un proceso de suavizado (Smoothing) al conjunto de datos obtenidos en la matriz ROC empleados previamente para graficar la curva mostrada en la figura 11.1.

Empleando el algoritmo de suavizado de “moving average” se creó una nueva función de aproximación que capturara solo los patrones importantes en los datos, dejando fuera datos irrelevantes, ver figura 11.3. Los puntos de los datos de la matriz se modificaron por puntos individuales, aumentando aquellos que eran más bajos que los puntos adyacentes para generar una curva más suave que reflejara un resultado más confiable.

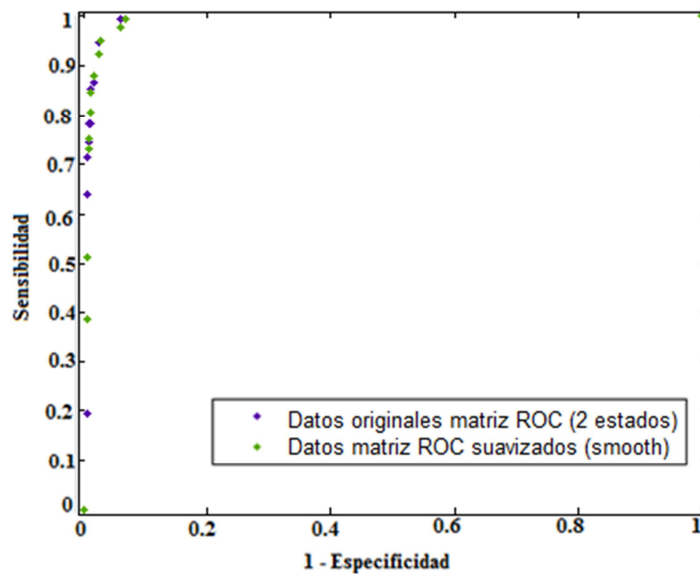


Figura 11.3: suavizado de los pares ordenados de la curva ROC para HMM de (2) estados

En la figura 11.4 se puede apreciar la diferencia entre el rendimiento de las curvas para dos (2) estados sin suavizar y la misma curva después de ser suavizada, evidenciándose en este caso, una caída de 0.04 puntos porcentuales en el desempeño general para el caso en el que se le aplicó el proceso de smoothing.

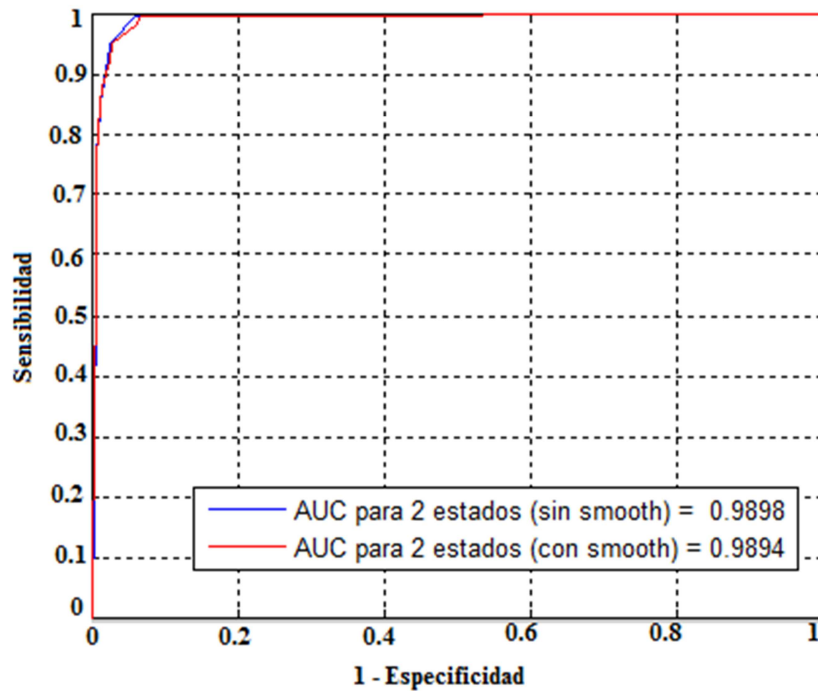


Figura 11.4: Rendimiento para HMM de (2) estados con y sin suavizado (smooth)

11.2. HMM de Tres (3) estados

Asignando tres (3) estados al modelo y empleando el mismo 70% de los datos para entrenamiento y el 30% restante como conjunto de validación sobre sobre el mismo conjunto de 12 libros de códigos [2,4,6,8,10,12,14,16,20,24,28,32] y tras correr el algoritmo propuesto otras veinte (20) veces, se obtuvo una nueva matriz ROC, la cual fue también sometida a un proceso de suavizado con el fin de reflejar un resultado lo más confiable posible en la curva ROC.

Al igual que lo ocurrido en el proceso de suavizado de la curva de desempeño para HMM de dos (2) estados, en la que dicho procedimiento redujo el rendimiento general expresado en la curva ROC; para el caso de tres (3) estados ocurrió lo mismo, el suavizado de la curva original redujo en 0.17 puntos porcentuales el rendimiento, bajando de un 98.67% hasta un 98.50%.

Sin embargo, hay que recordar que precisamente el proceso de smoothing busca generar una nueva función de aproximación lo más confiable posible capturando solo los patrones importantes en los datos, dejando fuera datos irrelevantes o repetidos.

Después de determinar la capacidad discriminativa del sistema estimando y suavizando el área bajo la curva ROC (AUC, area under the curve), se efectuó una comparación entre las eficiencias del sistema para el modelo con dos (2) estados y el modelo con tres (3) estados, ver figura 11.5.

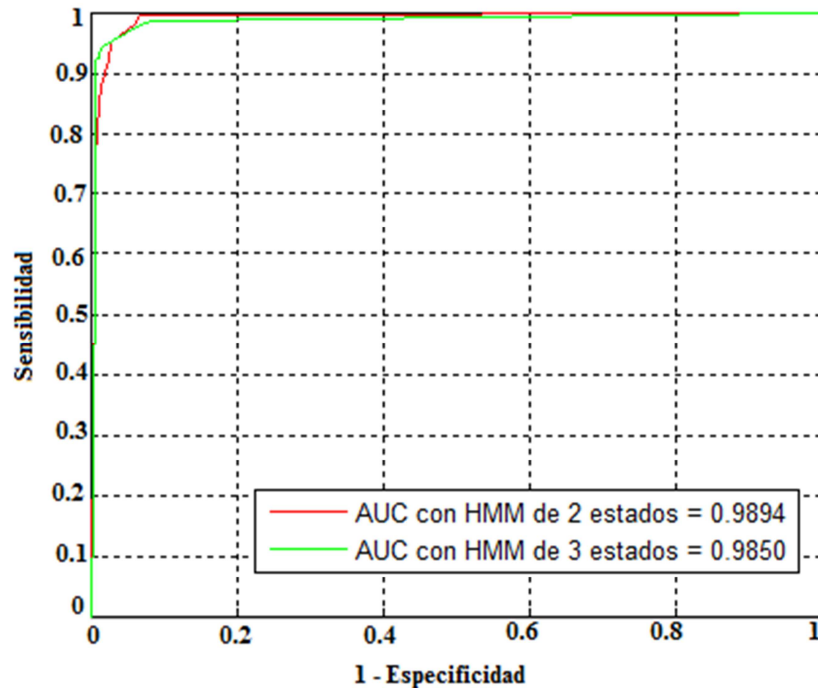


Figura 11.5: Desempeño del sistema para HMMs de dos (2) y tres (3) estados

Los resultados mostrados en la figura 11.5, representan los índices de rendimiento de clasificación del sistema para los modelos con dos (2) y tres (3) estados, en donde los valores del área bajo la curva (AUC) son una medida global de la exactitud diagnóstica del sistema. En el caso del modelo con tres (3) estados el AUC fue 0.9850 evidenciando una disminución de 0.44 puntos porcentuales en el rendimiento de clasificación con respecto al modelo con dos (2) estados, donde el AUC fue 0.9894. Estos resultados mostraron que el mejor desempeño hasta el momento se daba con el modelo de dos (2) estados.

11.3. HMM de Cuatro (4) estados

Asignando ahora cuatro (4) estados al modelo y empleando el mismo conjunto (entrenamiento-validación) sobre el mismo conjunto de 12 libros de código, la matriz ROC obtenida después de correr veinte (20) veces el algoritmo propuesto, fue también sometida a un proceso de suavizado.

Al igual que lo ocurrido en el proceso de suavizado de la curva de desempeño para dos (2) y tres (3) estados, en la que dicho procedimiento redujo el rendimiento general expresado en la curva ROC; para el caso de cuatro (4) estados ocurrió lo mismo, el suavizado de la curva original redujo en 0.02 puntos porcentuales el rendimiento, pasando de un 98.21% a

un 98.19%; debido tal vez a la eliminación de posibles ruidos u otros fenómenos que inicialmente pudieran estar presentes alterando la tendencia de la curva.

Una vez definida y suavizada la capacidad discriminativa del sistema evaluando el área bajo la curva ROC (AUC, area under the curve), se realizó una comparación entre las eficiencias del sistema para los modelos con dos (2), tres (3) y (4) estados, ver figura 11.6.




Figura 11.6: Desempeño del sistema para HMMs de (2), (3) y (4) estados

El área bajo la curva (AUC) para el modelo con cuatro (4) estados fue 0.9819, pero al comparar este resultado con el obtenido cuando se empleó el modelo con dos (2) estados, se pudo notar una disminución de 0.75 puntos porcentuales con respecto al rendimiento de clasificación del sistema; evidenciando con esto, más pérdida en el nivel de calidad diagnóstica.

11.4. HMM de Cinco (5) Estados

En este caso se le asignaron cinco (5) estados al modelo y se continuó empleando el 70% de los datos para entrenamiento y el 30% restante como conjunto de validación sobre el mismo conjunto de 12 libros de código. Al igual que en los pasos anteriores, la matriz ROC obtenida se sometió al proceso de suavizado y contrario a lo que sucedió en el proceso de suavizado de las curvas de desempeño para dos (2), tres (3) y cuatro (4) estados, en la que dicho procedimiento redujo el rendimiento general expresado en la curva ROC; para el caso de cinco (5) estados ocurrió todo lo contrario, el suavizado de la curva original benefició un poco el rendimiento, pasando de un 97.97% a un 98.01%.

El AUC del modelo con cuatro (4) estados reflejó una capacidad discriminativa un poco más elevada en comparación con el desempeño mostrado con el modelo de cinco (5) estados; sin embargo, siguió siendo inferior con respecto al presentado por el modelo con dos (2) estados, ver figura 11.7.




Figura 11.7: Desempeño del sistema para HMMs de (2), (3), (4) y (5) estados

El AUC para el modelo con cinco (5) estados fue 0.9801, evidenciando una caída de 0.18 puntos porcentuales en el desempeño del sistema con respecto al modelo con cuatro (4) estados; sin embargo, esta diferencia resulta mínima, si se compara con los 0.84 puntos porcentuales de diferencia entre el modelo con cinco (5) estados y el modelo con dos (2) estados, mostrando una caída aún más significativa en el nivel de desempeño del sistema.

11.5. HMM de Seis (6) Estados

Finalmente se le asignaron seis (6) estados al modelo y se continuó empleando el mismo porcentaje (entrenamiento-validación) sobre el mismo conjunto de 12 libros de código. Repitiendo los procedimientos anteriores, se obtuvo la curva de desempeño suavizada para el modelo con seis (6) estados, evidenciándose un aumento de 0.25 puntos porcentuales en el desempeño general cuando se le aplicó el proceso de smoothing a la matriz ROC original, pasando de un 97.07% a un 97.32%; sin embargo, el rendimiento del sistema obtenido con el modelo de seis (6) estados a través del AUC fue el más bajo en comparación con los modelos de dos (2), tres (3), cuatro (4) y cinco (5) estados, ver figura 11.8, ratificando con esto que el mejor desempeño fue mostrado por el modelo con dos (2) estados.

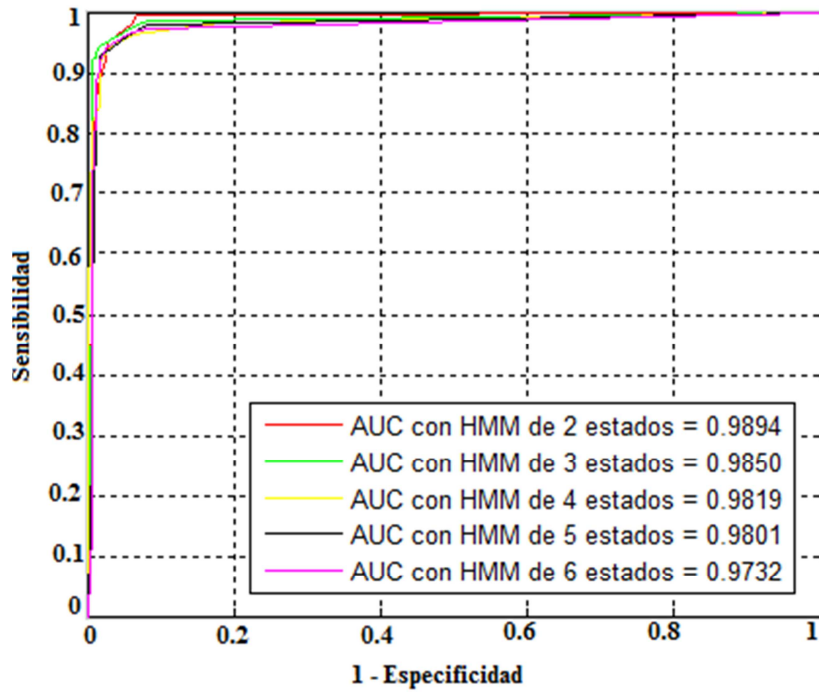


Figura 11.8: Desempeño del sistema para HMMs de (2), (3), (4), (5) y (6) estados

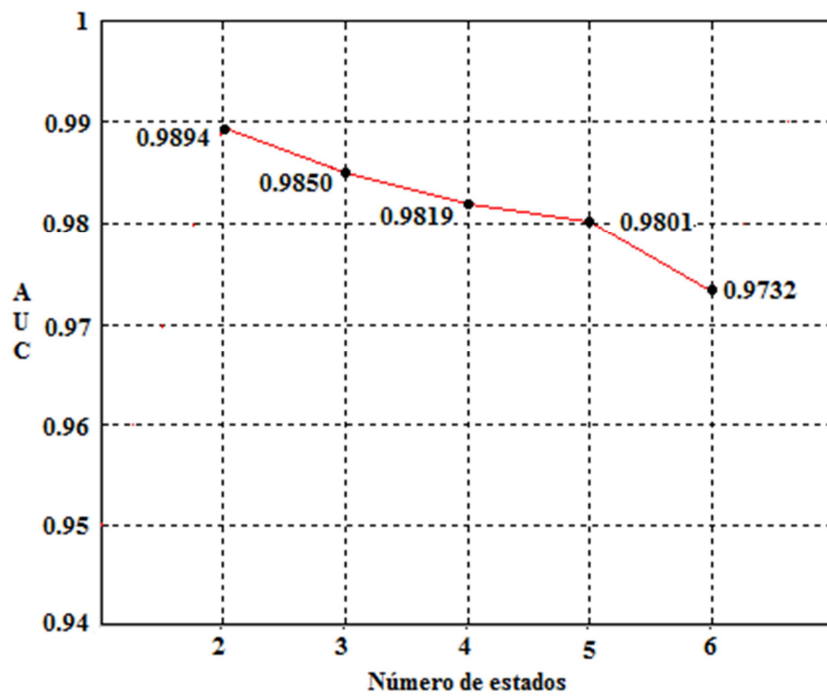


Figura 11.9: Resultados obtenidos en la prueba de modelos

En resumen, esta primera prueba se realizó empleando HMMs con una distribución de observación discreta, donde se realizó una evaluación del sistema de clasificación

obteniéndose el rendimiento para diferentes casos en los que se varió el número de estados sobre el libro de códigos. Los resultados se pueden observar en la figura 11.9, donde se puede apreciar que el máximo desempeño se alcanzó con dos (2) estados, permitiendo deducir que al no ser necesario usar un modelo con muchos estados, el sistema no demandará tanta carga computacional.

Con el fin de verificar la fiabilidad de los resultados obtenidos en la prueba de modelos, se realizaron 3 ensayos más; donde por cada estado evaluado, el algoritmo propuesto se corrió veinte (20) veces. A continuación se muestran los resultados obtenidos en los que se confirma que el modelo con dos (2) estados presentó el mejor desempeño.

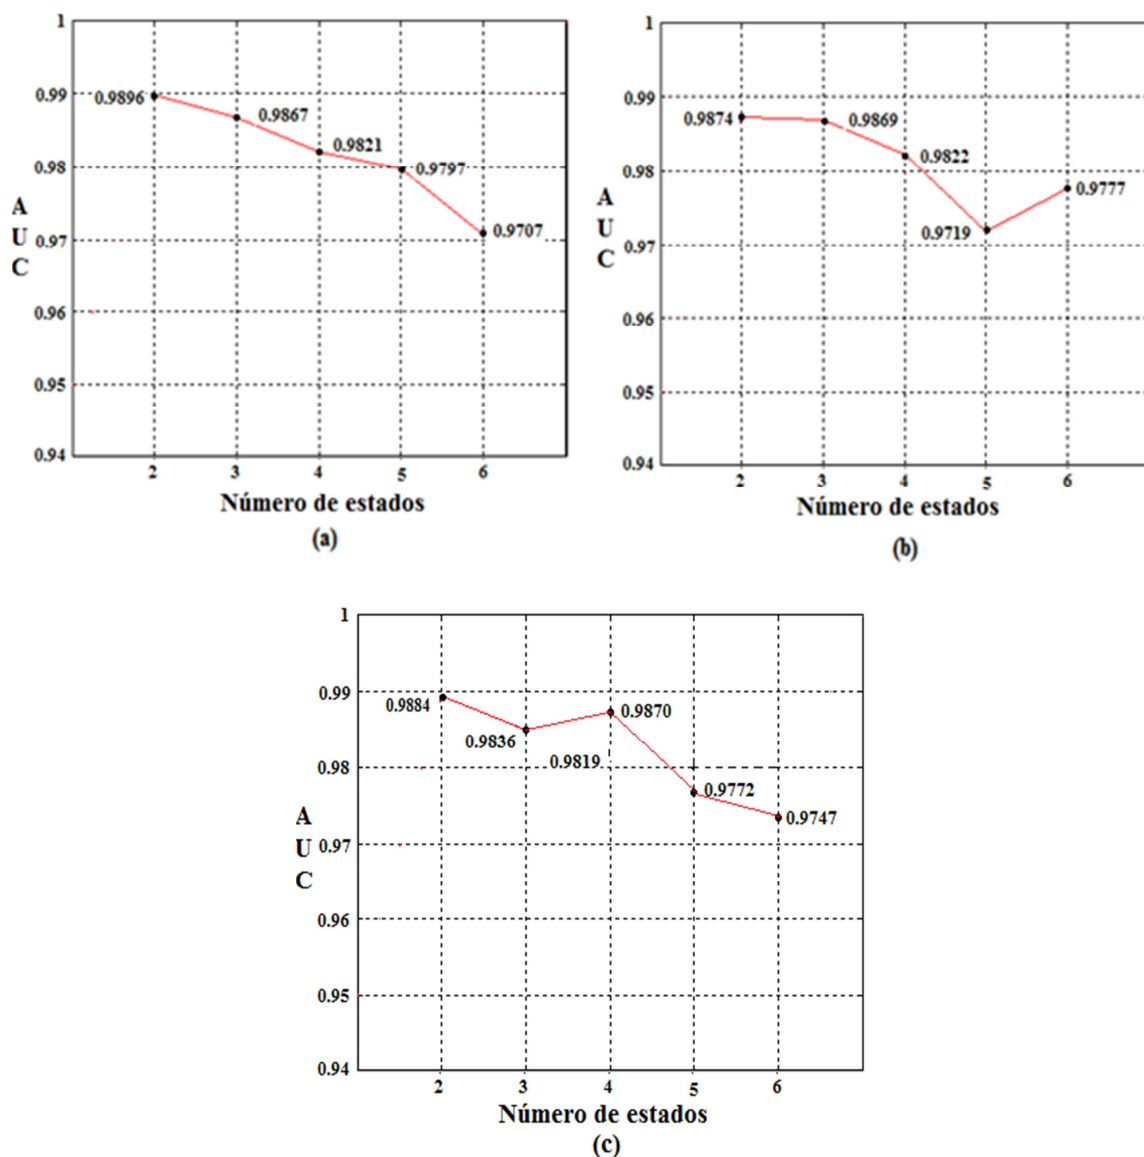


Figura 11.10: (a) y (b) Resultados obtenidos en otras pruebas de modelos empleando el conjunto entrenamiento-validación (70-30)

11.6. Conjunto (entrenamiento-validación) óptimo

Como se mencionó al principio de la prueba de modelos, una vez establecido el número de estados óptimo del modelo, que para nuestro caso fue dos (2) estados, se tuvieron en cuenta otros conjuntos de entrenamiento-validación (40-60, 50-50, 60-40, 80-90 y 90-10) en la evaluación del desempeño del sistema clasificador, con el fin de encontrar el conjunto que mejor calidad diagnóstica brindara al sistema, sin perder capacidad de generalización.

A continuación se muestran los resultados obtenidos para los diferentes conjuntos de entrenamiento-validación utilizados sobre el conjunto de 12 libros de código [2,4,6,8,10,12,14,16,20,24,28,32] y con el modelo de dos (2) estados fijo, ver figura 11.11.

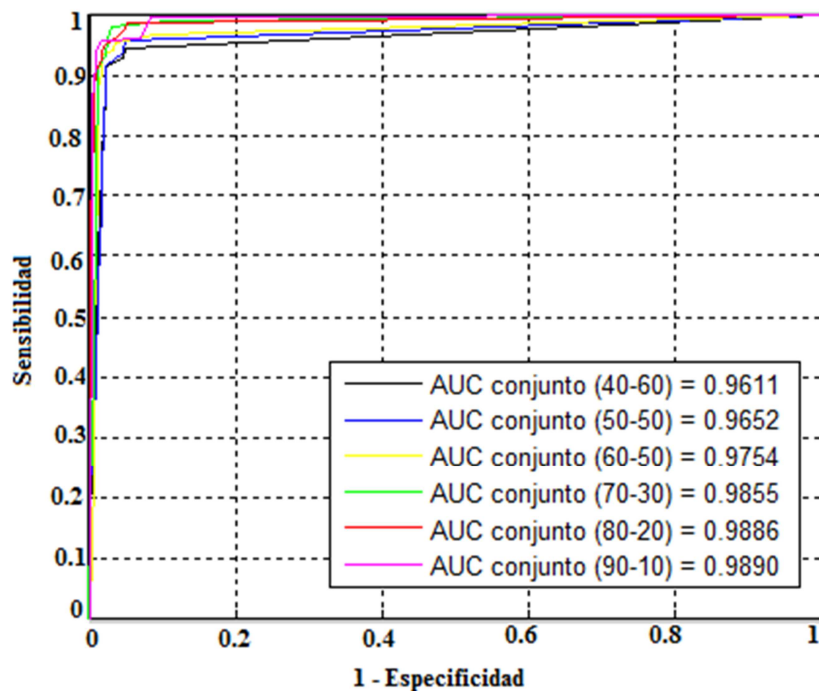


Figura 11.11: Resultados de la prueba de conjunto (entrenamiento-validación) óptimo

Después de analizar los resultados obtenidos en esta prueba, se puede apreciar que el rendimiento más alto se alcanzó con los conjuntos (entrenamiento-validación) (80-20) y (90-10); sin embargo, la necesidad de encontrar una generalización óptima por parte del sistema clasificador, nos sugería que el porcentaje del conjunto de entrenamiento no debía ser muy grande con respecto a la totalidad de la base de datos; ya que si el entrenamiento se lleva más allá del punto donde el error del conjunto de verificación es mínimo, el sistema clasificador empieza a aprender de memoria los datos del conjunto de entrenamiento y por consiguiente comienza a perder la capacidad de generalización.

Para garantizar una generalización óptima, que brindara al sistema la capacidad de proporcionar una respuesta correcta ante patrones que no han sido empleados en su entrenamiento, se optó por escoger el conjunto (entrenamiento-validación) (70-30), ya que

además de arrojar buenos resultados como se pudo apreciar en la figura 11.11, es en general el conjunto por defecto empleado en sistemas de clasificación de patrones. Sin embargo, esta regla es heurística, es decir no existe un resultado claro en la literatura estadística que diga cuál es la mejor manera de partir una base de datos. Este resultado depende en la mayoría de los casos del número de datos; es decir, cuanto mayor y más representativa sea la base de datos, importará menos el porcentaje de las divisiones.

En la figura 11.12 se muestran con más claridad los resultados obtenidos en la prueba de conjunto (entrenamiento-validación) óptimo en la que se pudo apreciar la relación proporcional entre el conjunto (entrenamiento-validación) y el desempeño del sistema clasificador; donde a mayor porcentaje de entrenamiento mayor era el desempeño alcanzado por el sistema. Sin embargo y como se explicó anteriormente, emplear valores muy elevados de entrenamiento, minimiza las posibilidades de una generalización óptima por parte del sistema clasificador.




Figura 11.12: Resultados de la prueba de conjunto (entrenamiento-validación) óptimo

No obstante, el criterio empleado para seleccionar el conjunto (70-30) tuvo que ver con la mejora desde el conjunto previo; es decir, observando los resultados de la figura 11.12, se apreció que del conjunto (40-60) al conjunto (50-50) hubo una mejora de 0.41 puntos porcentuales, tendencia que se mantuvo al pasar a (60-40) y posteriormente a (70-30) con mejoras de aproximadamente un (1) punto porcentual. El punto de inflexión lo marcó el paso de este último conjunto a (80-20) y posteriormente a (90-10), donde a pesar de haber mejoría, se pudo observar como el sistema tendió a estabilizarse, reduciendo la brecha entre las medidas registradas por cada conjunto, evidenciando con esto pérdida de aprendizaje por parte del clasificador que a su vez va en contra del sobreentrenamiento o pérdida de generalización.

CAPITULO 12

PRUEBA 2 (PRUEBA DE LIBRO DE CÓDIGOS)

Para determinar la capacidad de generalización del sistema clasificador, se adoptó un esquema de validación cruzada, con diferentes conjuntos de entrenamiento-validación (kfold), aleatoriamente escogidos del conjunto completo de vectores de características (VibCaract). Después de definir el conjunto de (entrenamiento-validación) y el número de estados óptimo del modelo, se realizan las configuraciones iniciales del HMM utilizando para el entrenamiento el 70% de los datos, para la validación el 30% restante y el número de estados se fijó en un valor de dos (2).

Con el fin de determinar el número óptimo de vectores representativos o centroides de entre el conjunto [2,4,6,8,10,12,14,16,20,24,28,32], que brindara mayor tasa de acierto o exactitud diagnóstica al sistema, se realizaron tres (3) pruebas cada una con 100 iteraciones por cada clúster, variando el número de centroides (en el intervalo [2, 32]). Una media de los resultados finales se presenta a través de las tablas (12.1, 12.2 y 12.3).

Para construir estas tablas se calcularon los siguientes parámetros: Tasa de verdaderos positivos o sensibilidad (tp), tasa de falsos negativos (fn), tasa de verdaderos negativos o especificidad (tn) y tasa de falsos positivos (fp). La tasa de acierto final del sistema se calculó como el cociente entre el número de registros correctamente clasificados y el número total de registros.

La figura 12.1 muestra la distribución de estos parámetros dentro de las tablas (12.1, 12.2 y 12.3), así como la forma en la que se calcularon:

$tp = vp / (vp + fn)$	$fp = fp / (vn + fp)$
$fn = fn / (vp + fn)$	$tn = vn / (vn + fp)$
$e = (vp + tn) / (vp + tn + fn + fp)$	

Figura 12.1: Distribución de parámetros en las tablas (12.1, 12.2 y 12.3)

Recordando que:

vp = Verdaderos positivos

fn = Falsos negativos

vn = Verdaderos negativos

fp = Falsos positivos

La tabla 12.1 muestra los resultados obtenidos tras la primera de las tres pruebas realizadas con el objetivo de determinar el número óptimo de vectores representativos o centroides para el libro de códigos:

Número de Estados	Número de Centroides	Matriz de Confusión	
2	2	36.94%	9.94%
		63.06%	90.06%
		Exact. 63.50%	
	4	50.62%	8.54%
		49.38%	91.46%
		Exact. 71.04%	
	6	66.85%	6.11%
		33.15%	93.89%
		Exact. 80.37%	
	8	72.11%	5.82%
		27.89%	94.18%
		Exact. 83.14%	
	10	75.35%	6.01%
		24.65%	93.99%
		Exact. 84.67%	
	12	76.85%	5.88%
		23.15%	94.12%
		Exact. 85.48%	
	14	77.39%	6.11%
		22.61%	93.89%
		Exact. 85.64%	
	16	78.64%	6.35%
		21.36%	93.65%
		Exact. 86.15%	
	20	74.56%	5.83%
		25.44%	94.17%
		Exact. 84.37%	
	24	84.75%	4.21%
15.25%		95.79%	
Exact. 91.27%			
28	79.12%	5.58%	
	20.88%	94.42%	
	Exact. 86.77%		
32	83.41%	4.82%	
	16.59%	95.18%	
	Exact. 89.30%		

Tabla 12.1: Resultados obtenidos en la primera prueba de libro de códigos

En ella se pudieron observar tasas de acierto inferiores o iguales al 80% para número de centroides en el intervalo [2, 6]. La utilización de 8 centroides mejoró en 2.77 puntos porcentuales el nivel de detección en comparación con el uso de 6 centroides, sin embargo, seguía siendo una tasa de acierto muy baja. Para número de centroides a lo largo del intervalo [10, 16], el sistema presentó una tendencia incremental leve en las tasas de acierto de dicho intervalo, logrando una mejora de 1.48 puntos porcentuales entre los extremos de dicho intervalo. Aunque el empleo de 20 centroides marcó un punto de inflexión al presentar una disminución de 1.78 puntos porcentuales con respecto a 16 centroides, la tasa de acierto para centroides en el intervalo [28, 32] siguió con tendencia incremental. La utilización de 24 centroides arrojó la mejor tasa de acierto, mejorando en 6,9 puntos porcentuales con respecto a 20 centroides y 27.77 puntos porcentuales con respecto a 2

centroides, evidenciando con esto la importancia de tener un número grande de conglomerados en el sistema de cuantificación.

La tabla 12.2 muestra los resultados obtenidos tras la segunda de las tres pruebas realizadas con el objetivo de determinar el número óptimo de clusters para el libro de códigos:

Número de Estados	Número de Centroides	Matriz de Confusión	
2	2	37.20%	9.09%
		62.80%	90.91%
		Exact. 64.05%	
	4	52.62%	7.84%
		47.38%	92.16%
		Exact. 72.39%	
	6	66.51%	5.30%
		33.49%	94.70%
		Exact. 80.60%	
	8	72.63%	5.01%
		27.37%	94.99%
		Exact. 83.81%	
	10	74.76%	5.03%
		25.24%	94.97%
		Exact. 84.86%	
	12	77.11%	5.34%
		22.89%	94.66%
		Exact. 85.88%	
	14	74.75%	5.10%
		25.25%	94.90%
		Exact. 84.83%	
	16	75.40%	5.43%
		24.60%	94.57%
		Exact. 84.98%	
	20	76.44%	5.16%
		23.56%	94.84%
		Exact. 85.64%	
	24	85.57%	3.35%
14.43%		96.65%	
Exact. 91.11%			
28	77.23%	4.99%	
	22.77%	95.01%	
	Exact. 86.12%		
32	84.61%	3.78%	
	15.39%	96.22%	
	Exact. 90.41%		

Tabla 12.2: Resultados obtenidos en la segunda prueba de libro de códigos

En ella se pudieron observar resultados muy similares a los obtenidos en la tabla 12.1, con tasas de acierto inferiores al 80% para número de centroides en el intervalo [2, 6]. Para número de centroides a lo largo del intervalo [8, 12] se obtuvieron respuestas por encima del 80% con incrementos consecutivos levemente superiores a 1 punto porcentual. Esta vez la utilización de 14 centroides fue quien marcó el punto de quiebre, al presentar una reducción de 1.05 puntos porcentuales con respecto a 12 centroides. Para los valores restantes de centroides correspondientes al intervalo [16, 32] se mantuvo la tendencia incremental en las tasas de acierto. Pese a que en general se evidenció una leve mejoría en los resultados con relación a las mostradas en la tabla 12.1, el uso de 24 centroides siguió arrojando la mejor tasa de acierto, mejorando esta vez en 5,5 puntos porcentuales en

comparación con el uso 20 centroides y 27.06 puntos porcentuales con respecto a 2 centroides.

Con el objetivo de verificar la fiabilidad de los resultados obtenidos en las anteriores dos pruebas realizadas para encontrar el número óptimo de clusters del libro de códigos, se realizó un tercer ensayo, donde por cada número de centroides evaluado a lo largo del intervalo [2, 32], el algoritmo propuesto se corrió cien (100) veces.

Número de Estados	Número de Centroides	Matriz de Confusión	
2	2	38.25%	8.43%
		61.75%	91.57%
		Exact. 64.91%	
	4	51.75%	6.69%
		48.25%	93.31%
		Exact. 72.53%	
	6	63.31%	3.34%
		36.69%	96.66%
		Exact. 79.99%	
	8	76.11%	3.75%
		23.89%	96.25%
		Exact. 86.18%	
	10	77.46%	4.02%
		22.54%	95.98%
		Exact. 86.72%	
	12	77.11%	3.54%
		22.89%	96.46%
		Exact. 86.78%	
	14	75.77%	3.60%
		24.23%	96.40%
		Exact. 86.06%	
	16	77.22%	3.54%
		22.78%	96.46%
		Exact. 86.84%	
	20	79.00%	3.32%
		21.00%	96.68%
		Exact. 87.84%	
	24	86.35%	1.89%
		13.65%	98.11%
		Exact. 92.23%	
	28	80.06%	4.02%
		19.94%	95.98%
Exact. 88.02%			
32	85.27%	2.04%	
	14.73%	97.96%	
	Exact. 91.61%		

Tabla 12.3: Resultados obtenidos en la tercera prueba de libro de códigos

En la tabla 12.3 se muestran los resultados obtenidos en los que pese a que se notó un punto de inflexión cuando se tenían 14 centroides, se mantuvo la relación proporcional entre el número de clusters y el desempeño del sistema clasificador; donde a mayor número de centroides mayor fue el desempeño alcanzado por el sistema. El hecho de que con 24 centroides se haya logrado la eficiencia más alta, demuestra que la utilización de un número significativo de conglomerados, en este caso mayor o igual a 24 en el sistema de clasificación, reduce la distorsión de los datos evitando comportamientos inesperados del sistema que puedan influir en su desempeño.

CAPITULO 13

PRUEBA 3 (ANÁLISIS DE RELEVANCIA)

Esta prueba se realiza con el objetivo de discriminar aquellas características que no poseen un aporte significativo de relevancia, y que por el contrario afectan el óptimo rendimiento de los algoritmos de estimación de parámetros para los Modelos Ocultos de Markov. Utilizando la misma base de datos de vibraciones proporcionada por el Bearing Data Center de la Western Reserve University [34], y empleando HMMs con una distribución de observación discreta, se realizó una evaluación del sistema de clasificación en la que se obtuvo el rendimiento para diferentes casos en los que se fue incrementando la dimensión del espacio de características; es decir, inicialmente se evaluó el desempeño de clasificación con una sola característica, luego se incrementó la dimensión del espacio añadiendo otra característica y evaluando de nuevo el desempeño de clasificación; este proceso se repitió hasta completar la totalidad de características con las que se contaba. El conjunto total de registros se dividió en 70% para entrenamiento y 30% para validación, los HMMs se entrenaron con 2 estados y se empleó un libro de códigos con 24 centroides.

En la figura 13.1 se muestra la relevancia de cada una de las características en la evaluación del desempeño de clasificación en solitario, donde el eje de la abscisa representa cada una de las características, mientras que el eje de la ordenada muestra la relevancia de cada característica dada por su magnitud, la cual es tomada en cuenta a la hora de entrenar los HMMs.




Figura 13.1: Relevancia de cada característica en el desempeño del clasificador

La forma de incrementar la dimensión del espacio de características se realizó inicialmente en orden aleatorio, es decir, sin tomar en cuenta el peso o la relevancia de las características, posteriormente el incremento se realizó de forma ascendente y finalmente en orden descendente.

Estado del Rodamiento											
Carac	Exactitud diagnóst. (%)	Efic_t									
		Fallo en bola (Ball)			Fallo en la pista interna (Inner)			Normal	Fallo en la pista exter. (Outer)		
		Ball N1	Ball N2	Ball N3	Inner N1	Inner N2	Inner N3	Normal	Outer rN1	Outer N2	Outer N3
<i>LB</i>	95,83	0,90	0,94	0,69	0,91	0,96	0,99	1	0,94	0,825	1
<i>K</i>	95,42	0,91	0,97	0,76	0,97	0,93	0,975	0,97	0,75	0,9	0,97
<i>RMS Peaks</i>	94,36	0,93	0,96	0,66	0,915	0,935	0,985	1	0,88	0,835	0,93
<i>Std Peaks</i>	94,31	0,90	1	0,85	1	0,90	1	1	0,75	0,90	1
<i>Pv</i>	94,03	0,91	0,99	0,87	0,815	0,89	0,945	0,995	0,865	0,905	0,98
<i>RMS</i>	93,89	0,94	0,97	0,76	1	0,905	0,795	1	0,83	0,875	1
<i>Std</i>	93,61	0,96	0,99	0,78	1	0,955	0,78	1	0,835	0,845	1
<i>UB</i>	92,20	0,93	0,98	0,72	0,91	0,875	0,905	0,95	0,755	0,84	0,925
<i>Nnl</i>	89,90	0,94	0,99	0,80	1	0,87	0,72	1	0,825	0,845	1
<i>E</i>	89,75	0,90	0,84	0,65	1	0,37	1	0,97	0,81	0,66	1
<i>Rv</i>	88,69	0,92	0,94	0,76	0,775	0,555	0,755	0,99	0,705	0,83	0,97
<i>RMS D.Peaks</i>	88,05	0,70	0,98	0,36	0,975	0,975	0,89	0,705	0,985	0,255	0,915
<i>Imf</i>	87,64	0,56	0,97	0,53	0,925	0,785	0,885	0,77	0,92	0,465	0,97
<i>Shf</i>	86,44	0,54	0,90	0,55	0,975	0,875	0,875	0,785	0,965	0,575	1
<i>Clf</i>	83,96	0,58	0,93	0,55	0,94	0,905	0,85	0,71	0,91	0,47	0,98
<i>Crf</i>	83,89	0,48	0,93	0,50	0,905	0,755	0,825	0,74	0,865	0,445	0,68
<i>Kv</i>	83,19	0,46	0,96	0,53	0,985	0,505	0,935	0,365	0,945	0,435	0,545
<i>Sw</i>	73,75	0,62	0,53	0,22	0,505	0,67	0,915	0,66	0,33	0,465	0,74
<i>Vm</i>	64,86	0,10	0,69	0,18	0,15	0,2	0,265	0,88	0,335	0,225	0,675

Tabla 13.1: Valores de rendimiento de clasificación entregados por la etapa de validación promediadas a partir de 100 iteraciones por cada característica

Los resultados mostrados en la tabla 13.1, se definieron a partir del vector de eficiencia total entregado por la etapa de validación, denominado (Efic_t) y representa los índices de rendimiento de clasificación de cada característica cuando actúa en solitario, permitiendo precisar la capacidad que tiene cada característica de discriminar uno u otro tipo de falla.

Con base en los resultados obtenidos en la tabla 13.1, se pudo individualizar la relevancia de cada una de las características dentro del proceso de clasificación de fallas; considerando el nivel de exactitud diagnóstica obtenido con cada una, se puede observar que los valores pico (P_v), RMS , desviación estándar (Std), factor k (K), Histogramas de límite inferior (LB) y superior (UB) y RMS de los picos (\tilde{x}_{peak}) tienen niveles de rendimiento superiores al 90%, demostrando que en general, son buenos indicadores de defectos.

El valor de eficiencia logrado por el valor peak (P_v), es un reflejo de lo sensible que es este parámetro con respecto a la impulsividad de la señal de vibración y en general para todos los tipos de fallos presentes en los rodamientos. El nivel RMS y la desviación estándar (Std) mostraron ser parámetros muy consistentes y efectivos, al no alejarse significativamente del valor de un rodamiento sano, brindándole al sistema clasificador una tasa de reconocimiento del 100% para fallo en la pista interna (Inner) de nivel 1, fallo en la pista externa (Outer) de nivel 3 y rodamiento saludable (Normal). Con respecto al factor k (K), se puede evidenciar también su sensibilidad a la impulsividad de las vibraciones generadas por todos los diferentes tipos de fallo, donde su valor fue consecuente con el tipo de daño que presentó cada rodamiento (la tendencia al alza para los defectos más importantes), demostrando que se puede usar como parámetro de severidad, aparte del valor RMS el cual ya está estandarizado.

A pesar de que las demás características presentaron porcentajes de rendimiento inferiores al 90%, esto no significó que su grado de aportación fuera mínima a la hora del sistema realizar la clasificación, ya que, parámetros como la entropía (E) y el valor de la verosimilitud logarítmica negativa normal (Nnl) con eficiencias de 89.75% y 89.90% respectivamente, le brindan al sistema una tasa de reconocimiento del 100% para fallo en la pista interna (Inner) de nivel 1 y 3, fallo en la pista externa (Outer) de nivel 3 y rodamiento saludable (Normal), similar a lo ocurrido con el valor RMS y la desviación estándar (Std).

Con base en esto, es posible inferir que aunque una característica presente un valor global de eficiencia bajo, esto no significa que este parámetro no pueda ser mejor indicador de una u otra falla, en comparación con otras características que poseen el mejor rendimiento global, es decir, cada característica posee una habilidad diferente para detectar con más acierto uno o varios de los tipos de falla, sin embargo, en el balance final, en el que se analiza la aportación de este parámetro en la detección de todo el conjunto de fallas presentes en el rodamiento, es posible que este no halla sido tan consistente en la detección de todos los tipos de fallos como si lo pudo haber sido con una o varias fallas en particular.

Generalizando todos los resultados de cada tipo de fallo, se observa que estos presentan una probabilidad inferior al 90% de ser detectados, salvo en el caso de fallas en elementos rodantes (ball) con nivel de severidad 2, en el que se registró una probabilidad de acierto del 91%, siendo este el valor más alto que se generó, debido tal vez al carácter muy impulsivo del defecto, ya que cuando las bolas ruedan sobre el lado del defecto, esta golpea tanto la

pista interior como la exterior excitando fuertemente los modos naturales de ambas pistas, causando niveles picos más altos que los que se pueden generar en los otros defectos.

Como ya mencionamos, el anterior análisis se realizó considerando cada característica por separado, con el fin de obtener una visión individualizada de la relevancia que poseía cada una en el proceso de clasificación. Sin embargo, este análisis es superficial, ya que el verdadero análisis está en ver el funcionamiento en grupo de todos los parámetros con el fin de seleccionar el mejor conjunto, buscando por un lado la optimización del tiempo de cálculo, evitar la redundancia al tratar con características altamente correlacionadas y por otro lado eliminar ciertos datos que no representan información significativa, disminuyendo así, la complejidad del proceso de clasificación e incrementando el desempeño del clasificador.

A continuación se muestran los resultados obtenidos después de evaluar el rendimiento del sistema de clasificación para tres casos en los que se fue incrementando la dimensión del espacio de características de forma gradual; inicialmente en orden aleatorio, en el que no se tomó en cuenta el peso o la relevancia de las características, posteriormente de forma ascendente y finalmente en orden descendente.

13.1. Entrenamiento con características en orden aleatorio

Inicialmente, se analizó el entrenamiento incrementando la dimensión del espacio en orden aleatorio, es decir, sin tener en cuenta la relevancia de las características. En la figura 13.2 se muestran los resultados obtenidos.




Figura 13.2: Entrenamiento con características en orden aleatorio

Con base en los resultados mostrados en la figura 13.2, se pudo inferir que era posible obtener un óptimo desempeño del sistema de clasificación a partir de un grupo reducido de características, evitando de esta manera tener que emplear un espacio de representación completo. Poder alcanzar un buen rendimiento con una cantidad baja de estadísticos significa que existe una determinada cantidad de información dentro del vector de características que era irrelevante y, que al contrario de brindar un aporte significativo al sistema de clasificación, lo que hace es desmejorar su desempeño, afectando el aporte del conjunto de características verdaderamente relevantes.

Sin embargo, individualmente cada parámetro puede tener su peso, pero al combinarlo con otras características pueden presentar respuestas diferentes como se observa en la figura 13.2, donde, en la medida en la que se adicionan características se notó una marcada uniformidad en el desempeño del sistema, es decir, el buen resultado alcanzado con una o varias características era contrarrestado por otra al momento de intervenir en el espacio. A partir de esto, se puede comprender que el incremento del espacio de representación no se debe realizar sin tener información sobre la relevancia de los parámetros a utilizar, es decir, añadir características sin un aporte significativo de relevancia claramente afecta el rendimiento de los algoritmos de estimación de parámetros para los modelos de HMM.

13.2. Entrenamiento con características en orden ascendente

En la figura 13.3 se plasman los resultados obtenidos del análisis, entrenando el modelo a partir de un incremento ascendente del espacio, es decir, partiendo con la característica de menor relevancia hasta la de mayor importancia.




Figura 13.3: Entrenamiento con características en orden ascendente

El eje de la abscisa representa la cantidad de características empleadas en cada punto y el eje de la ordenada representa la eficiencia obtenida por el sistema con los diferentes grupos de características.

Claramente, se observa como la tasa de acierto del sistema clasificador responde de tal forma que su tendencia corresponde con el incremento en la dimensión del espacio. Sin embargo, su valor máximo no superó el 95%, alcanzando picos máximos de 94.89% cuando se entrenó con espacios de 11 y 15 características. Pese a la tendencia ascendente de los resultados, el nivel de eficiencia obtenido no fue el más óptimo, ya que al comparar estos resultados con los obtenidos cuando se entrenó el modelo con un incremento aleatorio en la dimensión del espacio, se pudo evidenciar la influencia negativa que cierto grupo de características puede tener en el desempeño del sistema clasificador, ya que como se puede apreciar en los resultados de la figura (4.14), fue posible alcanzar rendimientos por encima del 95% con un reducido número de características.

Con base en lo anterior, se evidenció la posibilidad de lograr una máxima eficiencia a partir de un grupo reducido de característica discriminado aquellas que no tiene aporte significativo y que por el contrario afectan el rendimiento del sistema clasificador.

13.3. Entrenamiento con características en orden descendente

En la figura 13.4 se plasman los resultados obtenidos del análisis, entrenando el modelo a partir de un incremento descendente del espacio, es decir, partiendo con la característica de mayor relevancia hasta la de menor peso.




Figura 13.4: Entrenamiento con características en orden descendente

El eje de la abscisa representa la cantidad de características empleadas en cada prueba y el eje de la ordenada representa la eficiencia obtenida por el sistema con los diferentes grupos de características.

No cabe duda de que los resultados más importantes se obtienen cuando el espacio se incrementa partiendo con las características que más relevancia tienen, es decir, en orden descendente. En la figura 13.4 se observa cómo con un reducido grupo de características se pudo alcanzar un rendimiento superior al de cualquiera de los casos analizados anteriormente. Para este caso, el rendimiento máximo fue de 97.87%, obtenido con 10 características, 2 estados y un libro de códigos de 24 centroides. Nuevamente se puede observar como al adicionar nuevas características, el rendimiento del sistema presenta una notable reducción, demostrando una vez más que no se requiere del conjunto total de características para alcanzar niveles de eficiencia bastante buenos.

Con base a estos últimos resultados, se puede establecer que el hecho de lograr una eficiencia del 97.87% con un número reducido de características, definitivamente demuestra la existencia de una cantidad de información irrelevante o redundante dentro del vector de características empleado en el entrenamiento de los HMMs, y que por consiguiente puede ser excluida, reduciendo el tiempo de cómputo y garantizando una toma de decisión más confiable respecto al tipo de falla que se esté analizando.

CAPITULO 14

PRUEBA 4 (ANÁLISIS DE TIEMPO DE EJECUCIÓN)

Teniendo en cuenta que las principales características que se buscan de un algoritmo son que pueda generar un resultado óptimo en un tiempo limitado, que esté bien estructurado, que sea fácil de usar, y sobre todo que sea eficiente (entendiendo esto último como la cantidad de recursos de cómputo que se requiere; es decir, cuál es su tiempo de ejecución y qué cantidad de memoria utiliza); resulta obvia la necesidad de generar algoritmos que permitan mantener tan bajo como sea posible el consumo de recursos del sistema.

Tomando en consideración la importancia que tiene que un algoritmo sea lo más eficiente posible con independencia de la plataforma software/hardware que se utilice; o dicho en otras palabras, si partimos de la premisa de que un análisis computacional comparativo de algoritmos no debe depender del sistema informático, se infirió que si un algoritmo es ya eficiente de por sí, más veloz será si se ejecuta en una plataforma mucho más rápida y eficaz; razón por la cual, consideramos innecesario realizar un análisis de los tiempos de computación en un equipo con diferentes especificaciones.

Por otra parte, teniendo en cuenta que si se desea analizar un algoritmo complejo en forma detallada, el tiempo invertido en el análisis puede ser inaceptable en la práctica, motivo por el cual se hizo un análisis de forma aproximada. Se tomó en consideración para el análisis del coste computacional solamente el tamaño de los datos o parámetros de entrada (Número de estados, porcentaje (entrenamiento-validación) y libro de códigos), centrándonos en el análisis de la eficiencia del algoritmo en base al tamaño del conjunto de datos de entrada que este manipulaba. De esta forma se pudo comparar la eficiencia del algoritmo a través de las diferentes pruebas realizadas con independencia de cualquier característica que no fuera la rapidez con que el algoritmo alcanzó la solución teórica del problema.

Con el fin de apreciar como variaba la evolución del coste temporal en función de los valores asignados a los parámetros de entrada que manipulaba el algoritmo, se realizaron medidas del tiempo de ejecución del algoritmo sobre las diferentes pruebas efectuadas (prueba de modelos, prueba de libro de códigos y análisis de relevancia). Las pruebas se realizaron en un computador portátil con las siguientes especificaciones:

- Fabricante: Dell
- Modelo: Inspiron 1545, con procesador Pentium(R) Dual-Core CPU T4200 2.00 GHz.
- Memoria (RAM): 2.0 GB.
- Tipo de sistema: Sistema operativo de 32 bits



Figura 14.1: Equipo empleado en las pruebas

14.1. Análisis de tiempo de ejecución (Prueba de Modelos)

En la tabla 14.1 se muestra, por cada modelo evaluado, los tiempos de ejecución del entrenamiento, la validación, la generación del libro de códigos, la extracción de características y el tiempo de ejecución de todo el proceso. La última columna indica el porcentaje de tiempo que demandó pasar de un modelo a otro. Es importante recordar que la prueba de modelos se realizó variando el número de estados en el intervalo [2, 6], sobre un conjunto de 12 libros de códigos cada uno con un número K de centroides [2,4,6,8,10,12,14,16,20,24,28,32] y empleando como porcentaje de (entrenamiento-validación) el conjunto (70-30).

Tiempos de ejecución (Prueba de Modelos) [seg]						
Número de estados del modelo	Entren.	Valid.	Libro de código	Extrac. de caract.	Tiempo total	%T.
2	151,19	3,11	3,17	11,03	178,7	-
	Er: ± 5,5	Er: ± 0,09	Er: ± 0,18	Er: ± 0,11	Er: ± 11,5	
3	304,9	3,39	3,40	11,83	333,8	86,7
	Er: ± 6,4	Er: ± 0,09	Er: ± 0,19	Er: ± 0,16	Er: ± 6,64	
4	344,3	3,07	3,06	11,3	372,0	11,4
	Er:±11,2	Er: ± 0,08	Er: ± 0,21	Er: ± 0,19	Er: ± 11,5	
5	343	2,88	2,50	11,1	370	-0,005
	Er: ± 6,8	Er: ± 0,05	Er: ± 0,14	Er: ± 0,09	Er: ± 6,86	
6	373	2,93	2,72	11,6	399,6	7,71
	Er: ± 7,1	Er: ± 0,05	Er: ± 0,12	Er: ± 0,15	Er: ± 6,98	

Tabla 14.1: Informe del rendimiento del algoritmo para la prueba de modelos

Debido a que el clasificador empleaba un tipo de aprendizaje no supervisado, la función que entrenaba los modelos ocultos de Markov en MATLAB tenía partes aleatorias en su código, haciendo que el tiempo de ejecución para un mismo conjunto de datos, variara de una ejecución a otra, ya que en cada una, los bucles realizaban un número diferente de iteraciones; esta variación se hizo más notoria cuanto mayor era el número de muestras. Para contrarrestar un poco esta aleatoriedad de forma tal que se pudieran obtener resultados más ajustados y realistas, se promediaron veinte ejecuciones, de forma tal que el tiempo mostrado fuera la media de esas ejecuciones realizadas en condiciones similares.

En la tabla 14.1, se puede apreciar en promedio la evolución del coste temporal en función del número de estados que utilizó el algoritmo en los distintos modelos evaluados. Cuanto más grande fue el número de estados con los que se entrenó el modelo, mayor fue la demanda de tiempo computacional. La utilización del modelo con dos (2) estados, presentó el mejor rendimiento, al emplear en promedio un tiempo de 178,7 segundos por ejecución; mientras que la utilización del modelo con tres (3) estados que empleó en promedio un tiempo de 333,8 segundos por ejecución, empeoró el rendimiento en un 86,7% con respecto al rendimiento obtenido para dos (2) estados. El modelo de cuatro (4) estados que requirió un tiempo promedio por ejecución de 372 segundos, mejoró ostensiblemente en relación al tiempo que demandó pasar de un modelo a otro, al registrar una caída en el rendimiento de solo 11,7% con respecto a su antecesor; sin embargo, comparado con el modelo de dos (2) estados, la caída en el rendimiento fue de 108,2%.

Aunque la utilización del modelo con cinco (5) estados mejoró sensiblemente el rendimiento al realizar la ejecución un 0,005% más rápido que el modelo de cuatro (4) estados; si se tiene en cuenta el valor del error muestral, se podría inferir que el sistema se estabilizó entre estos dos modelos. Finalmente, la utilización del modelo con seis (6) estados claramente obtuvo el peor rendimiento al requerir 399,6 segundos por ejecución, tardándose aproximadamente un 7,71% más que los modelos con cuatro (4) y cinco (5) estados y un 123,6% con respecto al modelo de dos (2) estados.

Otro hecho que se hizo evidente observando los resultados de la tabla 14.1, fue la influencia que tuvo el número de estados en el aumento del tiempo de cómputo requerido por el sistema para entrenar los modelos. En general, la demanda computacional que tuvo la fase de entrenamiento ocupó entre el 85% y el 93% del tiempo total por ejecución de cada modelo evaluado. La fase de extracción de características registró un tiempo por ejecución de aproximadamente 11 segundos el cual no sufrió modificaciones entre modelo y modelo.

Por otro lado, se observó cómo los tiempos demandados por las fases de validación de modelos y generación de libro de códigos, además de que prácticamente no influyeron en el consumo de tiempo de todo el proceso, permanecieron más o menos estables entre modelo y modelo. Esto resulta coherente, teniendo en cuenta que para esta prueba se mantuvo constante el conjunto (entrenamiento-validación) y se trabajó siempre sobre el mismo conjunto de doce (12) libros de código.

A modo de análisis costo-beneficio, la figura 14,2 muestra los resultados obtenidos en la prueba de modelos.




Figura 14.2: Coste computacional contra calidad diagnóstica en prueba de modelos

Teniendo en cuenta que la finalidad del presente proyecto era la implementación de un ágil y eficaz sistema de clasificación de fallas en rodamientos basado en HMM, se evidenció la importancia de optimizar el algoritmo de la mejor forma posible, de modo que se produjese un sustancial aumento de la velocidad de ejecución sin alterar los resultados finales.

Con base en lo anterior se buscó definir los parámetros de entrada del clasificador (número de estados, porcentaje (entrenamiento-validación) y número de centroides) que permitieran garantizar la obtención de los mayores y mejores resultados en cuanto a exactitud diagnóstica al menor coste computacional. Se tuvo en cuenta el hecho de que si el porcentaje de exactitud diagnóstica obtenido superaba el coste computacional, el parámetro con el cual se logró dicho resultado sería en general considerado como óptimo. De acuerdo a esta lógica y observando la figura 14.2, se pudo demostrar como el modelo de dos (2) estados, que en el capítulo 11 (sección 11.5), había mostrado tener la mejor exactitud diagnóstica, resultó ser el que menos carga computacional demandó; con lo cual quedó demostrado que este parámetro (dos (2) estados), fue el más óptimo, al permitir que el clasificador obtuviera la mayor eficiencia al menor coste computacional.

14.2. Análisis de tiempo de ejecución (Prueba conjunto (entrenamiento-validación))

En la tabla 14.2 se muestra la evolución del coste temporal en función del porcentaje de datos que empleó el clasificador para entrenar y validar los modelos. El número de datos para validación empleados fue en decremento, mientras que los de entrenamiento fueron aumentando progresivamente. De este modo se pudo ver la diferencia o no de tiempo de ejecución del entrenamiento y la validación de los diferentes ensayos en función del

número de muestras a entrenar. Como se mencionó anteriormente, la aleatoriedad presente en el código de la función de entrenamiento, obligó nuevamente a promediar veinte ejecuciones, de forma tal que el tiempo obtenido fuera lo más ajustado posible. la prueba se realizó empleando un modelo de dos (2) estados, sobre todo el conjunto de 12 libros de códigos [2,4,6,8,10,12,14,16,20,24,28,32].

Tiempos de ejecución (Prueba conjunto (entrenamiento-validación)) [seg]						
Porcentaje (entrenamiento-Validación)	Entren.	Valid.	Libro de código	Extrac. de caract.	Tiempo total	%T.
(40-60)	122,02	6,40	2,93	11,40	154,50	-
	Er: ± 10,8	Er: ± 0,08	Er: ± 0,13	Er: ± 0,11	Er: ± 11,5	
(50-50)	150,10	6,10	4,86	11,83	187,3	21,2
	Er: ± 8,4	Er: ± 0,05	Er: ± 0,21	Er: ± 0,16	Er: ± 6,64	
(60-40)	177,5	5,10	5,30	11,3	213,50	13,9
	Er: ± 10,2	Er: ± 0,06	Er: ± 0,15	Er: ± 0,21	Er: ± 16,5	
(70-30)	162,00	3,40	3,30	11,2	191,00	-10,5
	Er: ± 6,8	Er: ± 0,07	Er: ± 0,18	Er: ± 0,09	Er: ± 6,86	
(80-20)	323,60	2,90	9,60	11,4	356,10	86,4
	Er: ± 10,1	Er: ± 0,05	Er: ± 0,15	Er: ± 0,13	Er: ± 8,93	
(90-10)	427,456	1,81	15,40	11,8	477,00	34,0
	Er: ± 12,8	Er: ± 0,09	Er: ± 0,12	Er: ± 0,23	Er: ± 8,56	

Tabla 14.2: Informe del rendimiento del algoritmo para la prueba conjunto (entrenamiento-validación) óptimo

En la tabla 14.2 se puede observar como el tamaño de la base para entrenar para el que se obtuvo el mejor tiempo se situó en torno al 40%. Sin embargo, porcentajes tan bajos de entrenamiento no garantizan que el clasificador mantenga una correcta generalización, ya que se origina un subajuste en el entrenamiento, debido a que se utilizan muy pocas muestras de entrenamiento, por lo que la máquina no generara buenos resultados con muestras nuevas.

Para tamaños superiores de base, el tiempo de entrenamiento de la máquina fue más elevado; es decir, hubo pérdida de rendimiento, ya que el aumento progresivo del conjunto de datos para entrenar, obligó al sistema a tener que realizar cálculos y operaciones cada vez más extensas. A partir del 80% de base para entrenar el tiempo empezó a aumentar más notablemente; sin embargo, un porcentaje tan alto de base para entrenar genera un sobreajuste en dicha fase, ya que los parámetros obtenidos en el entrenamiento se ajustan demasiado a las muestras por lo que se perderá generalización y al introducir una nueva muestra no la clasificará bien.

No obstante, vemos como cuando se empleó un porcentaje de entrenamiento del 70% la tendencia ascendente del tiempo de entrenamiento sufrió un punto de inflexión, ya que dicha acción se realizó 10,5 puntos porcentuales más rápido que cuando se empleó un

porcentaje de entrenamiento del 60% y tan solo 7,9 puntos porcentuales más lento con respecto al entrenamiento empleando el 50% de la base; lo cual puede ser un indicador de que tan óptimo resulta ser este porcentaje para entrenar, si se tiene en cuenta además, que por ser un valor intermedio, no generará subajustes ni sobreajustes en el entrenamiento, garantizando de esta forma la generalización del clasificador. Por otra parte, se pudo observar la evolución del coste temporal en función del porcentaje de datos para validación, donde claramente se observó la relación directa entre el tamaño de la base para validar y el tiempo demandado para realizar dicha función; donde a mayor porcentaje de base para test, mayor requerimiento de tiempo había por parte del sistema, lo que se traducía en pérdida de rendimiento.

Otro hecho que se evidenció mirando los resultados de la tabla 14.2, fue la influencia que tuvo el tamaño de la muestra para entrenar en el aumento del tiempo de cómputo requerido por el sistema para generar el libro de códigos, ya que entre los 2,93 segundos requeridos para generar el libro de códigos para el 40% de base y los 15,40 segundos requeridos para lo mismo cuando se empleó el 90% de la base, existe una brecha de casi 426 puntos porcentuales entre uno y otro. Mención especial nuevamente, para el caso en que se empleó el 70% de la base, ya que la diferencia de tiempo requerida para generar el libro de código entre este y el 40% de la base, fue de solo 0,37 segundos, equivalente a una brecha de 12,6 puntos porcentuales entre uno y otro.

Nuevamente a modo de análisis costo-beneficio, la figura 14,3 muestra los resultados obtenidos en la prueba para encontrar el porcentaje óptimo de base para entrenamiento y validación.




Figura 14.3: Coste computacional contra calidad diagnóstica en prueba conjunta (entrenamiento-validación)

Observando la figura 14.3, se pudo demostrar como la utilización de un porcentaje para entramiento del 70%; que si bien, no fue el porcentaje de base que le permitió al clasificador obtener la mejor exactitud diagnóstica, como se vio en el capítulo 11 (sección 11.6); si fue posible considerarlo como el más óptimo, ya que como se explicó anteriormente, este valor permitió garantizar la generalización del clasificador al no generar subajustes ni sobreajustes en el entrenamiento; además, como se puede ver también en la figura 14.3, el conjunto (entrenamiento-validación) (70-30), le permitió al clasificador obtener la mayor eficiencia al menor coste computacional.

14.3. Análisis de tiempo de ejecución (Prueba de libro de códigos)

En la tabla 14.3 se muestra la evolución del coste temporal en función del número K de centroides que empleó el clasificador para generar el libro de códigos. El número de centroides empleado se fue aumentando progresivamente, de este modo se pudo ver la relación entre el valor K del centroide y el tiempo de ejecución requerido para la generación del libro de códigos. Como se mencionó anteriormente, la aleatoriedad presente en el algoritmo, obligó esta vez a promediar cincuenta ejecuciones, de forma tal que el tiempo obtenido fuera lo más ajustado posible. la prueba se realizó empleando un modelo de dos (2) estados y un porcentaje para entrenamiento y validación de (70-30) respectivamente.

Tiempos de ejecución (Prueba de libro de códigos) [seg]						
Número de centroides	Entren.	Valid.	Libro de código	Extrac. de caract.	Tiempo total	%T.
2	10,10	0,23	0,05	11,2	23,20	-
	Er: ± 0,8	Er: ± 0,08	Er: ± 0,01	Er: ± 0,1	Er: ± 0,5	
4	10,50	0,23	0,06	11,43	23,60	1,70
	Er: ± 0,4	Er: ± 0,05	Er: ± 0,01	Er: ± 0,6	Er: ± 0,4	
6	11,60	0,23	0,09	11,3	24,70	4,70
	Er:±0,2	Er: ± 0,06	Er: ± 0,02	Er: ± 0,1	Er: ± 0,5	
8	12,90	0,24	0,09	11,2	26,00	5,30
	Er: ± 0,8	Er: ± 0,07	Er: ± 0,02	Er: ± 0,9	Er: ± 0,6	
10	11,80	0,23	0,10	11,4	25,00	-3,80
	Er: ± 0,1	Er: ± 0,05	Er: ± 0,03	Er: ± 0,3	Er: ± 0,3	
12	12,70	0,27	0,15	11,4	25,90	3,60
	Er: ± 0,8	Er: ± 0,09	Er: ± 0,02	Er: ± 0,3	Er: ± 0,6	
14	12,20	0,27	0,17	11,6	25,4	-1,90
	Er:±0,2	Er: ± 0,06	Er: ± 0,03	Er: ± 0,3	Er: ± 0,4	
16	12,60	0,27	0,25	11,5	25,90	1,97
	Er: ± 0,8	Er: ± 0,07	Er: ± 0,02	Er: ± 0,3	Er: ± 0,6	
20	14,80	0,32	0,34	11,4	28,20	8,90
	Er: ± 0,8	Er: ± 0,07	Er: ± 0,01	Er: ± 0,1	Er: ± 0,5	
24	13,40	0,29	0,46	11,2	27,0	-4,30
	Er:±0,2	Er: ± 0,06	Er: ± 0,03	Er: ± 0,3	Er: ± 0,4	

28	13,20	0,28	0,51	11,4	26,70	-1,10
	Er: $\pm 0,8$	Er: $\pm 0,09$	Er: $\pm 0,02$	Er: $\pm 0,1$	Er: $\pm 0,5$	
32	13,90	0,31	0,61	11,8	27,00	1,12
	Er: $\pm 0,8$	Er: $\pm 0,08$	Er: $\pm 0,01$	Er: $\pm 0,1$	Er: $\pm 0,3$	

Tabla 14.3: Informe del rendimiento del algoritmo para la prueba de libro de códigos

En la tabla 14.3 se puede observar como a medida que se aumentó el valor del centroide, el sistema demandó más tiempo para generar el libro de códigos, pasando de un requerimiento de 0,05 segundos cuando se emplearon 2 centroides, a un requerimiento de 0,61 segundos cuando se utilizaron 32 centroides, lo que se tradujo en una caída del rendimiento de casi 1.120 puntos porcentuales entre uno y otro.

Sin embargo, esta diferencia no influyó de forma significativa en el tiempo total de ejecución, ya que se registró una caída en el rendimiento de solo 16,4 puntos porcentuales entre 2 y 32 centroides. Con base en estos resultados y partiendo de la premisa de que a mayor número de conglomerados del sistema de cuantificación, menor será la distorsión de los datos; se puede demostrar que la selección de 24 centroides como número óptimo, además de cumplir con la premisa anterior, no influye de manera muy marcada en el requerimiento de tiempo total por ejecución; aun cuando su intervención en la generación del libro de códigos si lo sea. La figura 14,4 muestra de forma gráfica lo explicado anteriormente.




Figura 14.4: Coste computacional contra exactitud diagnóstica en prueba de libro de códigos

14.4. Análisis de tiempo de ejecución (Prueba de relevancia)

Con base en todos los resultados obtenidos con anterioridad, se pudo establecer que el tiempo promedio por ejecución requerido por el sistema para realizar la fase de extracción de características fue de $11,736 \pm 0,5$ segundos. En la tabla 14,4 se muestran ordenados de mayor a menor relevancia, los valores de eficiencia diagnóstica para cada característica calculados en el capítulo 13 (ver tabla 13,1) y sus respectivos requerimientos de tiempo.

Característica	Efic_t	Tiempo de ejecución [ms]	(%) del tiempo total
<i>LB</i>	0.9583	100	0,86
<i>K</i>	0.9542	10	0,09
<i>RMS Peaks</i>	0.9431	160	1,37
<i>Std Peaks</i>	0.9431	150	1,28
<i>Pv</i>	0.9404	110	0,94
<i>RMS</i>	0.9389	180	1,54
<i>Std</i>	0.9361	690	5,90
<i>UB</i>	0.9222	90	0,77
<i>Nnl</i>	0.8990	1.470	12,50
<i>E</i>	0.8975	920	7,80
<i>Rv</i>	0.8869	500	4,30
<i>RMS D.Peaks</i>	0.8806	160	1,37
<i>Imf</i>	0.8764	180	1,54
<i>Shf</i>	0.8644	170	1,45
<i>Clf</i>	0.8389	460	3,90
<i>Crf</i>	0.8389	20	0,17
<i>Kv</i>	0.8319	2.210	18,8
<i>Sw</i>	0.7375	3.350	28,6
<i>Vm</i>	0.6486	140	1,19

Tabla 14.4: Eficiencia diagnóstica por característica contra Rendimiento

En la tabla 14.4 se observa el listado completo de las características en el dominio del tiempo que fueron empleadas en el documento; de color rojo se encuentran marcadas aquellas que más relevancia tuvieron y por consiguiente las que finalmente fueron seleccionadas como las más importantes. Las restantes características, marcadas de color negro, fueron descartadas por no brindar un aporte significativo al proceso de clasificación de fallas.

Con base en lo anterior y observando los tiempos demandados por cada característica, notamos que del 100% del tiempo total requerido por la fase de extracción de características; que recordemos fue de $11,736 \pm 0,5$ segundos por ejecución, el 94,37% correspondió al tiempo demandado por el grupo completo de características, mientras que el otro 5,63% restante correspondió a otras líneas de código presentes en esta fase.

De acuerdo a estos datos, el tiempo de cómputo demandado por el grupo de estadísticos que más relevancia tuvieron (marcados con rojo), fue del 38,7% del tiempo total requerido para la extracción de características, mientras que el grupo de estadísticos que fueron descartados (marcados con negro), demandaron el 55,65%. Lo anterior demuestra claramente, que el conjunto de características que fue descartado, además de no brindar un aporte significativo a la eficiencia total del clasificador, demandó un 16,9% más de carga computacional que el conjunto que finalmente fue seleccionado.

Por consiguiente, la no utilización de estos parámetros redujo la exigencia de carga computacional en aproximadamente 56 puntos porcentuales en la fase de extracción de características, lo cual, es una pequeña contribución al mejoramiento del rendimiento general del sistema clasificador de fallas.

Finalmente haciendo un recuento de los resultados obtenidos en las diferentes pruebas y análisis realizados a lo largo del presente documento,

PARTE 5
CONCLUSIONES

Al dar cumplimiento a los procedimientos propuestos en los capítulos nueve (9) y diez (10), con el fin de alcanzar los objetivos propuestos y después de obtener los resultados expuestos en los capítulos once (11), doce (12) y trece (13) se ponen en manifiesto las siguientes conclusiones:

A través del estudio teórico y las evaluaciones realizadas de forma práctica, se logró determinar la gran importancia que la etapa de pre-procesamiento tiene en el análisis de señales; pues, además de servir como preámbulo a la etapa de parametrización, ésta permitió resaltar y mejorar sustancialmente las características de la señal a parametrizar. Dentro de esta fase, el proceso de segmentación fue de vital importancia para poder asumir que la señal de vibración era estacionaria en ese tramo y de esa forma poder aplicarle técnicas que permitieran el análisis de la misma, al aprovechar las bondades que ofreció la estacionalidad de la señal. Sin embargo, durante el proceso de segmentación, donde se dividió la señal de vibración en tramos, no se multiplicó la señal por ningún tipo de ventana, pues se observó que al hacerlo con las típicas funciones de ventanas existentes como Hamming, Blackman, Barlett, etc, se disminuía la capacidad del clasificador para discriminar los diferentes estado de salud del rodamiento.

Del estudio teórico y práctico realizado para la etapa de parametrización y extracción de las características más importantes de la señal de vibración y tomando en consideración la necesidad de evaluar alternativas más económicas computacionalmente hablando, pero que conservaran la precisión y la fiabilidad en la clasificación de fallas, se consideró desde un principio el uso de técnicas basadas en el cálculo de características en el dominio del tiempo. La calidad diagnóstica y el nivel de exactitud del clasificador de señales basado en modelos ocultos de Markov, dependió en gran medida de la extracción de características, ya que esta fase permitió simplificar el proceso al extraer únicamente la información más relevante de la señal de vibración. Como resultado del estudio de relevancia realizado, se comprobó la utilidad de las características en el tiempo, en cuanto a detectar algún tipo de anomalía presente en la señal de vibración del rodamiento y se vio que estadísticos como, Límite inferior del histograma o Histogram lower bound (*LB*), Factos *k* (*K*), Valor de la verosimilitud logarítmica negativa Normal o Normal negative log-likelihood value (*Nnl*), Raíz media cuadrática de los picos o *RMS* of Peaks (\tilde{x}_{peak}), Desviación estándar de los picos o Standard deviation of peaks (σ), Valor pico o Peak value (*Pv*), Raíz media cuadrática o Root mean square (*RMS*), Desviación estándar o Standard deviation (*std*), Límite superior del histograma o Histogram upper bound (*UB*), Entropía o Entropy (*E*) y Valor fundamental o Root value (*Rv*); fueron descriptores muy sensibles a los defectos presentes en la señal de vibración proveniente de rodamientos.

Una vez finalizado el procedimiento planteado en los capítulo nueve (9) y diez (10) y después de analizar los resultados obtenidos con la metodología propuesta para el reconocimiento automático de fallas en rodamientos, basado en modelos ocultos de Markov, caracterizados mediante estadísticos en el dominio del tiempo; se pudo evidenciar, en primer lugar, la vulnerabilidad de este clasificador a la forma aleatoria en la que son seleccionados los datos para entrenar y validar los HMMs; ya que al no disponer de un

conjunto de datos fijo para entrenamiento y validación, la probabilidad de extraer la máxima información de las secuencias de observación queda supeditada al correcto ajuste que se haga de los parámetros de entrenamiento del modelo; en otras palabras, la configuración inicial del clasificador se debe realizar empleando un número óptimo de estados para entrenar el HMM, un porcentaje de base óptimo para entrenar y validar los modelos y una óptima generación de los modelos de referencia (familia de centroides) correspondientes a cada una de las señales de vibración. Como se mencionó al principio, la naturaleza aleatoria del conjunto de datos para entrenamiento, obliga que el óptimo de cada uno de estos parámetros sea definido en pruebas separadas, en las que la cantidad de iteraciones hechas en la evaluación del algoritmo, es determinante en el resultado, pues a mayor número de iteraciones, mayor será la cantidad de datos de los que se podrá disponer para realizar un buen promedio que permita ajustar mejor los resultados. Cuando estos parámetros son definidos a partir de una o pocas iteraciones, la aleatoriedad de los datos de entrenamiento se ve reflejada en la inconsistencia e inexactitud de los resultados obtenidos, ya que generalmente, terminan favoreciendo a los parámetros menos óptimos.

Después de definir un HMMs de dos (2) estados como modelo óptimo a partir de la prueba de modelos, se comprobó que no necesariamente un mayor número de estados modela de mejor manera un sistema clasificador, así como tampoco tener un gran número de características que describa la datos de vibración garantiza un mejor modelado; pues con base en los resultados obtenidos al evaluar los modelos con mayor número de estados y características, se percibió una tendencia al sobredimensionamiento, tornándose muy exigentes para el algoritmo que requirió un aumento en la carga computacional y que contrario a lo que se podía esperar, arrojó resultados poco favorables. La prueba para escoger el conjunto (entrenamiento-validación) óptimo permitió comprender la influencia que tiene el porcentaje del conjunto de entrenamiento en la consecución de una generalización óptima por parte del clasificador que le permita a este adquirir la habilidad de proporcionar una respuesta acertada ante datos que no han sido empleados en su entrenamiento; ya que un porcentaje del conjunto de entrenamiento muy grande con respecto a la totalidad de la base de datos, causa un sobreajuste en el entrenamiento, haciendo que el clasificador empezara a memorizar los datos del conjunto de entrenamiento y por consiguiente la capacidad de generalización del sistema se perdió. Por otro lado, un porcentaje del conjunto de entrenamiento muy pequeño con respecto a la totalidad de la base de datos, causó un subajuste en el entrenamiento, haciendo que el clasificador no generara buenos resultados con muestras nuevas. Por otra parte, la prueba de libro de códigos, que permitió definir 24 como el número óptimo de vectores representativos o centroides de entre un conjunto de 12 opciones menores o iguales a 32, permitió demostrar que cuanto mayor es el número de conglomerados del sistema de cuantificación, menor será la distorsión de los datos.

Con base en los resultados obtenidos después de realizar el entrenamiento de forma incremental para el análisis de relevancia, se pudo constatar la fuerte dependencia existente entre el modelo y el grupo de características que intervienen en el entrenamiento, ya que si el conjunto de estadísticos inicial no es el más adecuado, el modelo perderá capacidad de discriminación y por consiguiente la probabilidad de clasificar correctamente un par de

condiciones del rodamiento, saludable y con falla (positivo o negativo) seleccionados al azar, será baja. En otras palabras, el peso del grupo de características que sea empleado al comienzo del entrenamiento será el que marque la tendencia a lo largo de toda la prueba. Aunque la adición gradual de las demás características, en este caso las de más relevancia, tiendan a mejorar un poco el desempeño del clasificador, el valor final, que se obtiene al incluir la totalidad de las características no será el más óptimo. Todo lo contrario ocurre cuando el entrenamiento se realiza de forma descendente, donde la utilización de un conjunto inicial apropiado de características o de más peso, contribuye a un rápido y óptimo desempeño del sistema clasificador, aportando una considerable reducción en la carga computacional. Lo anterior se suma al hecho de que utilizar un modelo de Markov discreto reduce notablemente la demanda computacional en comparación por ejemplo con un HMM con distribución continua; donde a pesar de que el HMM discreto está compuesto de una arquitectura más simple que el continuo, posee un grado de discriminación igual o superior que este último.

BIBLIOGRAFÍA

- [1] CEN (European Committee for Standardization), *Maintenance terminology*. European Standard. Brussels. CEN. 2001 EN 13306:2001
- [2] F.P. Schmid F. and Conde J. *Reliability Centered Approach to Remote Condition Monitoring. A Railway Points Case Study*. Engineering and System Safety.
- [3] Moubray J. *Reliability Centred Maintenance (RCM-II)* Butterworth Heinemann, Oxford, 1991.
- [4] SKF. *Manual SKF de mantenimiento de rodamientos*. Dinamarca, 1996.
- [5] Kulichevsky R. Sacchi, M. Martín Ghiselli A. *Medición y análisis de vibraciones, Una herramienta para la predicción y evaluación de fallas en maquinarias*.
- [6] Patton Jr. JD. *Preventive Maintenance*. New York: Instrument Society of America, 1983.
- [7] Álvaro Montenegro. *Análisis Espectral*. Departamento de Economía Universidad Javeriana, Noviembre 2008.
- [8] M. Hariharan, M. P. Paulraj, Sazali Yaacob. *Diagnosis of vocal fold pathology using time-domain features and systole activated neural network*. School of Mechatronic Engineering, University Malaysia Perlis (UniMAP), Perlis, Malaysia.
- [9] Xiao-Zi Yuan, Chaojie Song, Haijiang Wang, JiuJun Zhang . *Electrochemical Impedance Spectroscopy in PEM Fuel Cells*. Fundamentals and Applications.
- [10] Gustavo Adolfo Arango Flores. *Clasificación de Fallas en Motores Eléctricos utilizando Señales de Vibración*. Tesis presentada con el fin de optar al título de Magister en Ingeniería Eléctrica, Universidad Tecnológica de Pereira, 2007.
- [11] P.J. Unsworthc, D.F. Shia F. Tsungb. *Adaptive time frequency decomposition for transient vibration monitoring of rotating machinery*. Mechanical System and Signal Processing.
- [12] Flórez, E.; Cardona, S.; Jordi, L. *Caracterización de señales de vibración no estacionarias en el dominio conjunto tiempo-frecuencia*. A: Congreso Internacional de Ingeniería Mecánica y de Ingeniería Mecatrónica. "Proceedings del V Congreso Internacional de Ingeniería Mecánica y III de Ingeniería Mecatrónica". Bogotá: 2011.
- [13] Dinámica y Control de Procesos
http://www.fing.edu.uy/iq/cursos/dcp/teorico/17_DOMINIO_DE_LA_FRECUENCIA.pdf
- [14] Zecca M., Micera S, Carrozza M. *Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal*. ARTS Lab, Scuola Superiore Sant'Anna, Pontedera. Italy, 2002.
- [15] Becchetti y Prina. Becchetti, C. Prina, L. *Speech Recognition Theory and C++ Implementation*. Editorial John Wiley & sons. Inglaterra, 2004.

- [16] DLI Engineering Corporation. *Historia del análisis de vibración y su uso en el Mantenimiento de maquinaria*.
<http://www.dliengineering.com/vibmanspanish/historiadelanalisisdevibracinysuusoenelmantenimientodemaquinaria.htm>
- [17] National Instruments *Sistema de Evaluación y Diagnóstico de Máquinas Rotativas mediante Análisis de Vibraciones*.
<http://www.ni.com>.
- [18] Universidad Politécnica de Valencia. *Detección de Fallos por Vibraciones*. Departamento de Ingeniería Mecánica y de Materiales, Área de conocimiento de Ingeniería mecánica.
- [19] Peter W. Tse, Y. H. Peng and Richard Yam. *Wavelet Analysis and Envelope detection for Rolling Element Bearing Fault Diagnosis - Their Effectiveness and Flexibilities*. Journal of Vibration and Acoustics, July 001, Vol. 123.
- [20] Julio R. Navarro y Jaime F. Aviles Vifias. *Procesamiento Digital de Señales de Vibración con Fines de Diagnostico*. Tesis de Maestría en Ingeniería Mecatrónica; Cuernavaca, México, cenideg, Noviembre 2003.
- [21] Alberto Martelo. *Detección de Fallas en Rodamientos de Bolas de Motores Eléctricos Mediante Análisis Espectral de Vibración, Ruido y Corriente de Estator*. Programa de Magister-Tesis; Bogota, Colombia, Departamento de Ingeniería Mecánica, Universidad de los Andes; Diciembre 2000.
- [22] Jason R. Stack et al. *An amplitude Modulation Detector for Fault Diagnosis in Rolling Element Bearings*. EN: IEEE Transactions on Industrial Electronics, October 2004, Volume 51 (5), pp 1097-1102.
- [23] Alessandro Rivola. *Applications of Higher Order Spectra to the Machine Condition Monitoring*. Dipartimento di Ingegneria delle Costruzioni Meccaniche, Nucleari, Aeronautiche e di Metallurgia, Pubbl. DIEM, No, 07, Bologna, Italia, Luglio 2000.
- [24] Manish Yadav, Dr. Sulochana Wadhvani. *Vibration analysis of bearing for fault detection using time domain features and neural network*. Department of Electrical Engineering, Madhav Institute of Technology and Science Gwalior, India.
- [25] Adrian I. Cuc. *Vibration-based techniques for damage detection and health monitoring of mechanical systems*. Politehnica University of Timisoara, 1996.
- [26] Oscar Cardona Morales. *Análisis tiempo-frecuencia de señales de vibraciones mecánicas para la detección de fallos en maquinas rotativas*. Universidad Nacional de Colombia, 2011.
- [27] Alberto Delgado. *Inteligencia Artificial y Minirobots*. Textos Universitarios. Alberto Delgado, segunda edición, Julio 1998.
- [28] Carlos M. Belalcazar S. y Zully V. Rengifo V. *Clasificación de Señales Electromiográficas (EMG) para una prótesis de mano*. Universidad del Cauca, 2007.

- [29] Lawrence R. Rabiner. *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*. Proceedings of the IEEE, vol. 77, No. 2, February 1989.
- [30] G.E. Connaughton. *El estado de arte del mantenimiento en Norteamérica*.
- [31] Horacio R. Di Pratula. *Diagnóstico Predictivo de Fallas Rotóricas En Máquinas Eléctricas de Inducción*.
- [32] Wikipedia, La enciclopedia libre. (Sitio Web). Disponible: <http://es.wikipedia.org/wiki/Vibración>
- [33] White, G.: *Introducción al análisis de vibraciones*. Azima DLI, 2009.
- [34] Case Western Reserve University, Bearing data center. URL:<http://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-university-bearing-data-center-website>.
- [35] Luis M. Milliner. *Métodos estadísticos de clasificación*.
- [36] X. Wang and K. K. Paliwal, *Feature extraction and dimensionality reduction algorithms and their applications in vowel recognition*. Pattern Recognition, 36, pp 2429-2439. 2003
- [37] Lei, Y. He, Z. Zi, Y. A new approach to intelligent fault diagnosis of rotating machinery. *En: Expert Systems with Applications* 35, 2008, Nr. 4, p. 1593 – 1600.
- [38] JasonTranter, *Information and power in your hands: data collectors meet mobile computers –*, Application note Predict-DLI, 1998.
- [39] Manish yadav1, Dr. Sulochana wadhvani *Vibration analysis of bearing for fault detection using timedomain features and neural network* Department of Electrical Engineering, Madhav Institute of Technology and Science Gwalior, India
- [40] Stefan Goreczka and Jens Strackeljan Otto-von-Guericke- *Optimization of time domain features for rolling bearing fault diagnostics* niversität Magdeburg, Fakultät für Maschinenbau Institut für Mechanik Universitätsplatz 2, 30106 Magdeburg, Germany
- [41] Nils J. Nilsson. *Introduction to Machine Learning*. Stanford University, 1996.
- [42] N. Sáenz-Lechón, J.I. Godino-Llorente, V. Osmá-Ruiz, and P. Gómez-Vilda, "Methodological issues in the development of automatic systems for voice pathology detection," *Biomedical Signal Processing and Control*, vol 1, no 2, pp. 120-128. 2006.
- [43] Ali Akansu and Richard A. Haddad. *Multiresolution Signal Decomposition*. Number 0-12-047141-8. Bell Communications Research, Morristown, NJ, second edition, 2001.
- [44] Pedro Nelson Saavedra, *La medición y análisis de las vibraciones como técnica de inspección de equipos y componentes, aplicaciones, normativas y certificación*. Facultad de Ingeniería - Universidad de Concepción, Casilla 160 – Concepción – Chile.

- [45] Diagnóstico de Vibraciones en Máquinas Rotativas.
<http://www.dliengineering.com/section.asp?nID=22>
- [46] Gabriel López Solar, *Análisis de vibraciones para el mantenimiento predictivo*.
<http://www.tecnicaindustrial.es/tiadmin/numeros/14/35/a35.pdf>
- [47] Tandon, N. Nakra, B. C. *The Shock and Vibration Digest*, Vol. 24, 1992, N°3, pp. 3-10.
- [48] Harris, T. A. *Rolling Bearing Analysis*. John Wiley & Sons, Inc., N.Y., 1966
- [49] Ken Sharman, A. E., “*Interfaz Cerebro-Computadora*”, Grupo de Sistemas Adaptativos Complejos @ ITI, Enero 2004
- [50] Franco Baquero J. F., Giraldo Suárez E., Betancourt G. “*Reconocimiento De Patrones De Movimiento del Sistema Fisiológico Brazo-Antebrazo a Partir de Señales Electromiográficas*”. Universidad Tecnológica de Pereira, Grupo de Investigación en Instrumentación y Control. 2004.
- [51] Wikipedia, La enciclopedia libre. (Sitio Web). Disponible:
http://es.wikipedia.org/wiki/Serie_temporal
- [52] Zecca M., Micera S., Carozza M. “*Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal*”. ARTS Lab, Scuola Superiore Sant’Anna, Pontedera, Italy. 2002.
- [53] Cristian Mauricio Moncada Marino. *Estudio de fallas comunes en rodamientos rígidos de una hilera de bolas mediante análisis en el dominio tiempo y de la frecuencia*. Tesis presentada para optar al grado de Licenciado en Acústica y al título de profesional de Ingeniero Acústico, Universidad Austral de Chile
- [54] Gupta, K.: *Vibration — A tool for machine diagnostics and condition monitoring*. En: Sadhana 22 (1997), p. 393–410.
- [55] Yang, H. ;Mathew, J. ;Ma, L.: *Vibration feature extraction techniques for fault diagnosis of rotating machinery: a literature survey*. En: Asia-Pacific Vibration Conference, 2003
- [56] P. O. Garcia, “*Non-Destructive Failure Diagnostics for Ball/Roller-Bearing,*” Pag. 57-86. Memorias de 3ra Jornadas de Estudiantes de Ingeniería Acústica Valdivia (1994).
- [57] A. Barkov, N. Barkova, and J. Mitchell “*Condition Assessment and Life Prediction of Rolling Element Bearing-Part 1,*” Sound and Vibration, 10-17, June 1995.
- [58] Castro R., Martínez J. “*Análisis de la Teoría de Ondículas orientadas a las aplicaciones de ingeniería eléctrica*”. E T S I, Industriales Departamento de Ingeniería Eléctrica, Madrid. 2002.
- [59] Alberto García Duran, *Diseño de un clasificador de géneros musicales basado en modelos dinámicos*. Universidad Carlos III de Madrid – Escuela Politécnica Superior – Ingeniería de Telecomunicaciones.

[60] Carlos Mario Belalcazar Sandoval y Zully Viviana Rengifo Varila, *Clasificación de señales electromiográficas (EMG) para una prótesis de mano*. Universidad del Cauca – Facultad de Ingeniería Electrónica y Telecomunicaciones – Popayán, 2007.

[61] Br. Luz María Alejos Durán, *Software para la clasificación de huevos mediante Modelos Ocultos de Markov*, para la organización el Tunal CA, Quibor, estado Lara – Universidad Nacional Experimental Politécnica – Antonio José De Sucre.

[62] Cursos de Ingeniería virtuales
<http://www.virtual.unal.edu.co/cursos/ingenieria/2001832/lecturas/hmm.pdf>

[63] ISO Standards Handbook - *Vibration and Shock, Vol. 1*, Second edition, 1995

[64] Estupiñan, Edgar - Saavedra, Pedro *Técnicas de Diagnóstico para el análisis de vibraciones de rodamientos*. Universidad de Concepción.

[65] Mantenimiento industrial, *Interpretación de Espectros*. Escuela Politécnica Superior de Ingeniería de Gijón.

[66] Vicente Capistrán Gómez, Rodrigo Iván Paredes Portador, *Diagnóstico De Condiciones de Operación de Rodamientos en Máquinas usando Espectros de Alto Orden*. Centro Nacional de Investigación y Desarrollo Tecnológico – Cenidet.

[67] Cristina García Cambroner, Irene Gómez Moreno. *Algoritmos de Aprendizaje: KNN & KMEANS*. Universidad Carlos III de Madrid.

[68] N. Sáenz-Lechón, J.I. Godino-Llorente, V. Osmá-Ruiz, and P. Gómez-Vilda, "Methodological issues in the development of automatic systems for voice pathology detection," *Biomedical Signal Processing and Control*, vol 1, no 2, pp. 120-128. 2006.

[69] Fernando Martínez, Gustavo Portale, Hernan Klein, Osvaldo Olmos. *Reconocimiento de voz*. Apuntes de cátedra para Introducción a la Inteligencia Artificial.

[70] Edgar A. Estupiñan, Pedro N. Saavedra. "Análisis de vibraciones aplicado a las máquinas rotatorias de baja velocidad". Universidad de Concepción.

[71] Br. Escobar B, María Carolina Abigail. "Sistema de verificación de locutor basado en Modelos Ocultos de Markov". Universidad Nacional Experimental Politécnica Antonio José de Sucre.