

MEJORAMIENTO DE HERRAMIENTA COMPUTACIONAL
PARA EL DIAGNÓSTICO TÉCNICO A TRAVÉS DEL
MONITOREO MULTIDIMENSIONAL DE LA CONDICIÓN

WALTER PÉREZ VILLA

UNIVERSIDAD EAFIT
ESCUELA DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA MECÁNICA
ÁREA DE MANTENIMIENTO
MEDELLÍN
2008

MEJORAMIENTO DE HERRAMIENTA COMPUTACIONAL
PARA EL DIAGNÓSTICO TÉCNICO A TRAVÉS DEL
MONITOREO MULTIDIMENSIONAL DE LA CONDICIÓN

WALTER PÉREZ VILLA

Proyecto de Grado para optar por el título de Ingeniero Mecánico

Asesor

M.Sc. Ing. German René Betancur Giraldo

UNIVERSIDAD EAFIT
ESCUELA DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA MECÁNICA
AREA DE MANTENIMIENTO
MEDELLÍN
2008

A mi familia, gran acompañante y testigo de mi crecimiento personal y académico.

AGRADECIMIENTOS

El autor expresa sus agradecimientos al Grupo de Estudios en Mantenimiento Industrial (GEMI) de la Universidad EAFIT y a todos sus miembros en la Línea de Diagnóstico Técnico, coordinada por el Dr. Ing. Leonel Castañeda, a quien debe un enorme reconocimiento por el apoyo recibido y la disciplina recibida durante el tiempo de permanencia en el grupo.

De igual manera agradece también al M.Sc. Ing. German René Betancur por su acompañamiento y asesoría durante el transcurso del proyecto, apoyo que lo llevó a feliz término.

GLOSARIO

ATENUACIÓN EXPONENCIAL: Es un proceso utilizado para revisar constantemente un pronóstico a la luz de la experiencia más reciente.

CBM: Del inglés *Condition-based Maintenance* (Mantenimiento Basado en la Condición), es un programa de mantenimiento que recomienda tomar las decisiones de mantenimiento basadas en la información recolectada por medio del monitoreo de la condición.

CMD: Sigla del conjunto de indicadores: Confiabilidad – Mantenibilidad – Disponibilidad. Tríada básica dentro de la gestión del mantenimiento de equipos industriales.

CONFIABILIDAD: Probabilidad de que un equipo desempeñe correctamente las funciones para las cuales fue diseñado.

DISPONIBILIDAD: Probabilidad de que un equipo funcione correctamente en el momento en el cual sea requerido.

MANTENIBILIDAD: Probabilidad de que un equipo, máquina o sistema regrese a su estado de funcionamiento normal después de una avería o falla posterior a una reparación.

MMC: Monitoreo Multidimensional de la Condición, es una técnica basada en la condición del equipo que permite vigilar, evaluar y controlar la fiabilidad y disponibilidad de un sistema técnico.

PCA: Del inglés *Principal Component Analysis* (Análisis de Componentes Principales), es un procedimiento matemático que transforma un número de

posibles variables correlacionadas en un pequeño número de variables sin correlación llamadas componentes principales.

PROMEDIO MÓVIL: Se obtiene encontrando la media de un conjunto específico de valores y usándola después para pronosticar el siguiente período.

PROMEDIO SIMPLE: Se obtiene encontrando la media de todos los valores aplicables y empleando después esa media para pronosticar el siguiente período.

SVD: Del inglés *Singular Value Decomposition* (Descomposición en Valores Singulares), es un importante caso de factorización de una matriz rectangular real o compleja. Tiene muchas aplicaciones en procesamiento de señales y estadística.

TIEMPO LENTO: Tiempo que describe la evolución de un sistema técnico.

TIEMPO RÁPIDO: Tiempo que refiere la dinámica actual de un sistema técnico.

CONTENIDO

	pág.
INTRODUCCIÓN	11
1. OBJETIVOS	17
1.1. OBJETIVO GENERAL	17
1.2. OBJETIVOS ESPECÍFICOS	17
2. DEFINICIONES Y MARCO TEÓRICO	18
2.1. MODELOS DE DIAGNÓSTICO	19
2.2. MANTENIMIENTO BASADO EN LA CONDICIÓN	20
2.2.1. Objetivos del monitoreo de la condición	22
2.2.2. Implementación del monitoreo de la condición	22
2.3. ENERGÍA INTERNA DE DISIPACIÓN	23
2.4. DETERIORO DE UN SISTEMA TÉCNICO	23
2.5. MATRIZ DE OBSERVACIÓN DE SÍNTOMAS	24
2.6. TRANSFORMACIÓN DE UN ESPACIO DE SÍNTOMAS A UN ESPACIO DE FALLAS	26
2.7. MONITOREO MULTIDIMENSIONAL DE LA CONDICIÓN	26
3. HERRAMIENTA COMPUTACIONAL	29
3.1. ANTECEDENTES	29
3.2. PROPÓSITO	38
3.3. ESTRUCTURA DE LA HERRAMIENTA COMPUTACIONAL	41
3.3.1. Rutina para Experimento pasivo	41
3.3.2. Rutina para Fallo Generalizado	47
3.3.3. Estructura de programación - navegación	49
4. ANÁLISIS DE COMPONENTES PRINCIPALES Y DESCOMPOSICIÓN EN VALORES SINGULARES	51
4.1. PROPÓSITO DEL ANÁLISIS DE COMPONENTES PRINCIPALES	51

4.2.	MATRICES DE COVARIANZA Y CORRELACIÓN	54
4.3.	ANÁLISIS DE COMPONENTES PRINCIPALES USANDO LA DESCOMPOSICIÓN EN VALORES SINGULARES	59
4.3.1.	Análisis de Componentes Principales	61
4.3.2.	Extracción de Características en Señales Vía PCA	62
4.3.3.	Conclusión	63
5.	MÉTODOS DE PRONÓSTICO	64
5.1.	MÉTODOS DE ATENUACIÓN EXPONENCIAL	66
5.2.	ATENUACIÓN EXPONENCIAL DOBLE	67
5.3.	MÉTODO DE HOLT: ATENUACIÓN EXPONENCIAL AJUSTADA A LA TENDENCIA	68
5.4.	MÉTODO DE WINTER: ATENUACIÓN EXPONENCIAL AJUSTADA A LA TENDENCIA Y A LA VARIACIÓN ESTACIONAL	69
	CONCLUSIONES Y RECOMENDACIONES	72
	BIBLIOGRAFÍA	74
	ANEXOS	78

CONTENIDO

	pág.
INTRODUCCIÓN	11
1. OBJETIVOS	17
1.1. OBJETIVO GENERAL	17
1.2. OBJETIVOS ESPECÍFICOS	17
2. DEFINICIONES Y MARCO TEÓRICO	18
2.1. MODELOS DE DIAGNÓSTICO	19
2.2. MANTENIMIENTO BASADO EN LA CONDICIÓN	20
2.2.1. Objetivos del monitoreo de la condición	22
2.2.2. Implementación del monitoreo de la condición	22
2.3. ENERGÍA INTERNA DE DISIPACIÓN	23
2.4. DETERIORO DE UN SISTEMA TÉCNICO	23
2.5. MATRIZ DE OBSERVACIÓN DE SÍNTOMAS	24
2.6. TRANSFORMACIÓN DE UN ESPACIO DE SÍNTOMAS A UN ESPACIO DE FALLAS	26
2.7. MONITOREO MULTIDIMENSIONAL DE LA CONDICIÓN	26
3. HERRAMIENTA COMPUTACIONAL	29
3.1. ANTECEDENTES	29
3.2. PROPÓSITO	38
3.3. ESTRUCTURA DE LA HERRAMIENTA COMPUTACIONAL	41
3.3.1. Rutina para Experimento pasivo	41
3.3.2. Rutina para Fallo Generalizado	47
3.3.3. Estructura de programación - navegación	49
4. ANÁLISIS DE COMPONENTES PRINCIPALES Y DESCOMPOSICIÓN EN VALORES SINGULARES	51
4.1. PROPÓSITO DEL ANÁLISIS DE COMPONENTES PRINCIPALES	51

4.2.	MATRICES DE COVARIANZA Y CORRELACIÓN	54
4.3.	ANÁLISIS DE COMPONENTES PRINCIPALES USANDO LA DESCOMPOSICIÓN EN VALORES SINGULARES	59
4.3.1.	Análisis de Componentes Principales	61
4.3.2.	Extracción de Características en Señales Vía PCA	62
4.3.3.	Conclusión	63
5.	MÉTODOS DE PRONÓSTICO	64
5.1.	MÉTODOS DE ATENUACIÓN EXPONENCIAL	66
5.2.	ATENUACIÓN EXPONENCIAL DOBLE	67
5.3.	MÉTODO DE HOLT: ATENUACIÓN EXPONENCIAL AJUSTADA A LA TENDENCIA	68
5.4.	MÉTODO DE WINTER: ATENUACIÓN EXPONENCIAL AJUSTADA A LA TENDENCIA Y A LA VARIACIÓN ESTACIONAL	69
	CONCLUSIONES Y RECOMENDACIONES	72
	BIBLIOGRAFÍA	74
	ANEXOS	78

LISTA DE FIGURAS

	pág.
Figura 1. Metodología MMC propuesta para el proyecto de mejoramiento.	40
Figura 2. Ejemplo de resultado de una distribución normal y sus límites.	43
Figura 3. Contribución de los valores propios por sus estimadores.	44
Figura 4. Sensibilidad de síntomas antes de la transformación y reducción de la matriz.	46
Figura 5. Contribución de los valores propios por sus estimadores antes de la transformación y reducción de la matriz.	46
Figura 6. Estructura de programación – navegación para la herramienta computacional	50

SIGLAS, NOMENCLATURAS Y SÍMBOLOS

α	Constante de atenuación de los datos ($0 \leq \alpha \leq 1$)
β	Constante de atenuación de la estimación de la tendencia ($0 \leq \beta \leq 1$)
λ	Vector de valores propios
γ	Constante de atenuación de la estimación de la estacionalidad ($0 \leq \gamma \leq 1$)
Θ	Tiempo lento, tiempo de vida global del sistema
a_t	Diferencia entre los valores atenuados exponencialmente
A_t	Valor atenuado exponencialmente de Y_t en el período t
A'_t	Valor doblemente atenuado exponencialmente de Y_t en el período t
b_t	Factor adicional de ajuste de la serie atenuada exponencialmente
CBM	Del inglés <i>Condition-based Maintenance</i> (Mantenimiento Basado en la Condición)
CMD	Confiabilidad – Mantenibilidad – Disponibilidad
L	Longitud de la estacionalidad
MMC	Monitoreo Multidimensional de la Condición
O_{pr}	Matriz de observación de síntomas
p	Número de períodos a pronosticar en el futuro
PCA	Del inglés <i>Principal Component Analysis</i> (Análisis de Componentes Principales)
Pg	Reparaciones innecesarias (en rutina del experimento pasivo)
Ps	Probabilidad de no sobrepasar el valor límite para cada variable (en rutina del experimento pasivo)
SOM	Del inglés <i>Symptom Observation Matrix</i> (Matriz de Observación de Síntomas)
S_t	Estimación de la estacionalidad
SVD	Del inglés <i>Singular Value Decomposition</i> (Descomposición en Valores Singulares)

t	Punto en una serie de tiempo
t	Tiempo rápido, tiempo dinámico
T_t	Estimación de la tendencia
Y_t	Nueva observación o valor real de la serie en el período t
Y'_t	Valor atenuado anterior o experiencia promedio de la serie atenuada al período $t - 1$
Y'_{t+1}	Nuevo valor atenuado o valor de pronóstico para el siguiente período
Y'_{t+p}	Pronóstico de p períodos en el futuro

LISTA DE ANEXOS

	pág.
ANEXO A. LISTA DE RUTINAS EN VERSIÓN MATLAB® DE PROGRAMACIÓN	78
ANEXO B. CÓDIGOS DE LAS RUTINAS DE MATLAB® DE LOS MÉTODOS PREDICTIVOS PROPUESTOS	79
ANEXO C. PROCEDIMIENTO PARA LA CREACIÓN DE UNA VERSIÓN EJECUTABLE	87
ANEXO D. MANUAL DE USUARIO PARA INSTALACIÓN Y EJECUCIÓN DE LA HERRAMIENTA COMPUTACIONAL	89

INTRODUCCIÓN

El mantenimiento industrial tiene como función principal el “sostener la funcionalidad de los equipos y el buen estado de las máquinas a través del tiempo” (Mora, 2007). Dada esta premisa se entiende entonces que es prioritario, para el encargado de mantenimiento en la industria, lograr que la maquinaria cumpla con la disponibilidad y las exigencias presentadas por los coordinadores de la producción.

Existen muchas metodologías de mantenimiento para que éste en un equipo conduzca a aumentar sus niveles de confiabilidad y disponibilidad, entendiendo la confiabilidad como la probabilidad que tiene un sistema de realizar correctamente las funciones para las cuales fue diseñado y la disponibilidad como el porcentaje de tiempo que un equipo se encuentra en estado óptimo para la realización de las tareas para las cuales fue diseñado.

Dichas metodologías de mantenimiento se encuentran presentes a lo largo de la evolución del mantenimiento industrial y están directamente relacionado con el nivel de criticidad con el cual se clasifican los equipos industriales: inicialmente se concibió el mantenimiento de rotura o correctivo, luego empezaron las tareas de mantenimiento programado o preventivo y finalmente entraron, por su relevancia dentro de las labores de sostenimiento de los equipos y el avance en la tecnología disponible, el mantenimiento predictivo. Se pueden conjugar algunas técnicas de mantenimiento que hacen uso de los métodos de mantenimiento y que buscan mejorar los indicadores del mantenimiento de la maquinaria.

Mora (Mora, 2007) define el papel del mantenimiento como el incrementar la confiabilidad de los sistemas de producción al realizar actividades tales como planeación, organización, control y ejecución de métodos de conservación de los

equipos. Sus funciones van más allá de las reparaciones; su valor se aprecia en la medida en que éstas disminuyan como resultado de un trabajo planificado y sistemático.

Es de mucha importancia para la gestión del mantenimiento el hacer uso de tres indicadores básicos: confiabilidad, disponibilidad y mantenibilidad. El conjunto de los tres indicadores se designa como CMD. La confiabilidad es la probabilidad de que un equipo desempeñe correctamente las funciones para las cuales fue diseñado. La disponibilidad es la probabilidad de que un equipo funcione correctamente en el momento en el cual sea requerido. La mantenibilidad es la probabilidad de que un equipo, máquina o sistema regrese a su estado de funcionamiento normal después de una avería o falla posterior a una reparación.

Dichos indicadores CMD son básicos en los cuatro niveles jerárquicos de la gestión de mantenimiento: el instrumental, relacionado con las funciones y acciones que procuran el correcto funcionamiento de la máquina; el operacional, asociado con el conjunto de acciones a corto plazo que dirigen el mantenimiento de los equipos; el táctico, concerniente a la metodología de mantenimiento afiliada a la gestión; y el estratégico, compuesto por los indicadores y el seguimiento y revisión de la administración del mantenimiento industrial.

Es importante definir algunos tipos de mantenimiento que pueden direccionar la gestión del mantenimiento dentro de una organización: mantenimiento correctivo, ejecutado luego de reconocer una avería en un equipo para devolverle su funcionalidad de diseño; mantenimiento preventivo, realizado con base en criterios de periodicidad o de condición previstos con el propósito de reducir la probabilidad de fallo; mantenimiento predictivo, efectuado bajo la determinación del estado de la máquina en operación para después tomar acciones de intervención; y el mantenimiento basado en la condición (CBM) es aquel basado en el control de

determinadas condiciones, que están generalmente bajo monitoreo, cuyo valor determina las actuaciones subsiguientes de la gestión.

Existen dentro del mantenimiento predictivo y el basado en la condición un gran número de alternativas que se pueden agrupar de la siguiente manera por característica de revisión: i). Por sentidos de visión, tacto o auditivo, ii). Térmicos, iii). Tribológicos, iv). Fugas, v). Detección de grietas exteriores (líquidos penetrantes, partículas magnéticas, resistencia eléctrica, corrientes inducidas, ultrasonidos, radiografía), vi). Análisis de vibraciones, vii). Corrosión (corrosímetro, resistencia de polarización y potencial de corrosión, probeta de hidrógeno, perforaciones con taladros, probetas de corrosión, ultrasonidos). (Mora, 2007)

Las técnicas más comunes para mantenimiento predictivo en el medio son el análisis de vibraciones, la ferrografía (análisis de lubricantes) y la termografía infrarroja.

Es de gran importancia, por lo menos en los equipos de mayor criticidad de un sistema, la realización de programas de mantenimiento predictivo por parte de los técnicos encargados o de terceros especializados que, en la medida de la confiabilidad deseada, diagnostiquen el estado de la máquina como conclusión del análisis de la evidencia de falla. Basado en el monitoreo de señales, establecer la posibilidad de predicción de una falla por medio del seguimiento de una variable de la máquina puede ser de mucha utilidad, pero tiene mucha más adhesión a la realidad de la condición del equipo el seguir un conjunto de variables que tengan en cuenta la correlación entre diversas señales de la condición de la máquina que pueden ser evidencia de un fallo que la afecte.

El Monitoreo Multidimensional de la Condición (MMC) es la revisión del estado de un equipo en diversos momentos de la operación de ésta, refiriéndose a un conjunto de variables diferentes que, enfrentadas a un período de tiempo, puedan

dar información sobre la condición de la máquina. Consiste en la medición de fenómenos físicos tal como temperaturas, aceleraciones, desplazamientos, fuerzas y otras que se puedan convertir en síntomas del estado funcional actual y próximo del equipo.

Un síntoma es una característica del equipo debe cumplir con las siguientes propiedades (NATKE, 2000): i). Medible directa o indirectamente, ii). Que tenga relación funcional a la medición de un daño, iii). Alta sensibilidad a una falla o daño como una propiedad local, pero resistente a disturbios desconocidos como una propiedad global, iv). Distinguible de varios términos en el modelo de falla, el cual también incluye separación de fallas, v). El valor absoluto del síntoma es una función no decreciente en el tiempo, a menos que el sistema sea reparado, vi). Permite estimar tendencias.

El Grupo de Estudios en Mantenimiento Industrial (GEMI) ha creado una herramienta computacional para el análisis de señales que, bajo la práctica del mantenimiento basado en la condición mediante el uso del Monitoreo Multidimensional de la Condición, ha realizado importantes aportes en el diagnóstico técnico de equipos críticos. Este programa ha sido desarrollado acorde con las necesidades demandadas por sus usuarios y ha cumplido siempre una buena función; la principal propuesta de este proyecto de grado es el reestructurar la herramienta para finalmente volverla más cercana con el usuario por medio de su interfase, establecer una nueva estructura de programación e incluir nuevos métodos de predicción para el diagnóstico técnico.

El mejoramiento de la herramienta computacional aplicado al diagnóstico técnico a través del MMC, propuesta de este proyecto de grado, tiene como propósito lograr el perfeccionamiento de un instrumento de mucha importancia para dicho monitoreo que, como función primordial del MMC, “permite vigilar, evaluar y

controlar la fiabilidad y disponibilidad del sistema” (Zoltowsky, Castañeda y Betancur, 2007).

La herramienta computacional sirve al diagnóstico técnico en cuanto le es útil al personal de mantenimiento para tomar las decisiones de intervención en el equipo, con base en su condición, mientras éste se encuentre en marcha, fundamento básico del mantenimiento predictivo y del mantenimiento basado en la condición. El monitoreo del equipo se hace de acuerdo con el nivel de criticidad que arroja la evaluación de esta característica y el monitoreo multidimensional de la condición se convierte entonces en herramienta muy valiosa para determinar cuáles son las variables que pueden dar información sobre la condición del equipo y permitir la intervención oportuna al sistema.

La herramienta computacional, desarrollada en MatLab® desde hace varios años por estudiantes de pregrado en Ingeniería Mecánica y la Maestría en la misma área, requiere un mejoramiento del código actual del programa que incluye la verificación de funciones, estandarización de la estructura, incorporación de nuevas funciones y la creación de una versión ejecutable de la herramienta que permita ser implementada en cualquier sistema técnico.

Uno de los propósitos del proyecto consiste en efectuar una comparación entre el Análisis de Componentes Principales (PCA, por sus siglas en inglés) y la Descomposición en Valores Singulares (SVD, por sus siglas en inglés), cuyo objetivo es analizar la manera en la que ambos métodos pueden extraer los modos de falla. Adjunto a la comparación anterior se pretende examinar el uso del PCA como método de diagnóstico técnico. En este momento existe en el software una herramienta de pronóstico por Método de Atenuación Exponencial (Método de Brown-Mayer) y la intención es incluir nuevos métodos de pronóstico. Finalmente se tiene el propósito de realizar un mejoramiento de la versión por la implementación de un archivo ejecutable (*.exe) que no dependa del programa en

el cual se programa la herramienta computacional, en este caso MatLab®. Para la realización de esta versión ejecutable se hará uso del MatLab® Compiler, instrumento de MatLab® que permite la realización de versiones ejecutables o bibliotecas compartidas que admitan la ejecución de un código programado en el lenguaje, de dedicación exclusiva y sin necesidad de poseer MatLab®.

1. OBJETIVOS

1.1. OBJETIVO GENERAL

Reestructurar la herramienta computacional para el diagnóstico técnico desarrollada por el Grupo de Estudios en Mantenimiento Industrial GEMI de la Universidad EAFIT.

1.2. OBJETIVOS ESPECÍFICOS

- Realizar una revisión del estado actual de la herramienta computacional.
- Establecer una nueva estructura para la herramienta, de forma modular, generando los seudocódigos correspondientes.
- Estandarizar la estructura de programación de la herramienta.
- Comparar los algoritmos SVD y PCA, identificando la funcionalidad de cada uno, sus ventajas y desventajas en la aplicabilidad en el diagnóstico.
- Examinar el uso del PCA como método de diagnóstico técnico.
- Incluir un nuevo método de pronóstico en la herramienta.
- Crear una versión ejecutable de la herramienta computacional, verificando su correcto funcionamiento con una base de datos entregada por el grupo GEMI.

2. DEFINICIONES Y MARCO TEÓRICO

Este capítulo inicial tiene como propósito establecer las definiciones básicas propias del diagnóstico técnico y el estado de la maquinaria, además de la conceptualización del mantenimiento basado en la condición (CBM) y el monitoreo multidimensional de la condición (MMC).

Es importante unificar conceptos sobre estos aspectos elementales para así poder iniciar con la presentación del uso de la herramienta computacional y cuál es su importancia dentro del mantenimiento industrial y las posibilidades que este ofrece.

Portala (Portala, 2004) presenta unas definiciones básicas que son necesarias para la inducción de este proyecto: i). Modelo: Esquema teórico o matemático de un sistema que se elabora para facilitar su comprensión y el estudio de su comportamiento, ii). Diagnóstico de fallas: Consiste en detectar anomalías del comportamiento de un sistema técnico, con el fin de determinar el tamaño de las fallas, sus localizaciones y la severidad de su evolución, iii). Modelos de diagnóstico: Algoritmos que relacionan las condiciones de estado de un artefacto con el conjunto de mediciones y evaluaciones de los procesos generados a la salida del sistema o de los síntomas.

Otras definiciones relevantes en este punto son la de los tiempos en un sistema técnico: Tiempo lento y Tiempo rápido. El primero es el que describe la evolución de un sistema técnico, el tiempo de vida global del sistema θ . El segundo se refiere a la dinámica actual de dicho sistema técnico.

2.1. MODELOS DE DIAGNÓSTICO

Los modelos de diagnóstico son modelos matemáticos que describen, con aproximación, los procesos que ocurren en la maquinaria y, además, buscan el mejor canon de operación para ellas. Utilizan dichos modelos mediciones limitadas que se toman directamente desde el sistema técnico, extendiéndose y complementándose desde un análisis teórico del sistema, permitiendo la investigación del proceso dinámico y las propiedades propias del sistema. En sistemas complejos estos modelos proponen la mejor fuente de conocimiento para hallar los comportamientos anormales del sistema técnico.

Existen dos tipos de modelos de diagnóstico: el modelo sintomático y el holístico. El primero, de diagnóstico sintomático, describe el estado técnico de un sistema a partir de los síntomas que presenta, considerando el tiempo de vida global del sistema pero no el dinámico. De otro lado, el modelo sintomático es el más utilizado para la evaluación del estado de maquinaria, permite estudiar la evolución de los procesos de desgaste (corrosión, fatiga, abrasión, erosión) basándose en los síntomas que se observan en los sistemas técnicos, utilizando el tiempo lento.

El modelo de diagnóstico holístico es el modelo que revisa el comportamiento global del equipo en todo su ciclo de vida. Toma en cuenta la historia del tiempo lento (incluyendo sus cambios a lo largo de la vida) y considera además la dinámica del sistema a en su tiempo rápido. Este modelo describe la evolución de un sistema y su comportamiento dinámico.

NATKE (Natke, 2000) asegura que deben permitir los modelos holísticos: Predecir el comportamiento de un artefacto desde el instante en el que se desarrollan hasta el momento de su liquidación, predecir el cambio de estado del sistema técnico a través de todo su ciclo de vida, determinar el conjunto de síntomas necesarios

para determinar la degradación del equipo y desarrollar los algoritmos de control de estado y localización del daño en los sistema técnicos.

2.2. MANTENIMIENTO BASADO EN LA CONDICIÓN (Jardine, 2005)

El Mantenimiento basado en la condición (CBM, por sus siglas en inglés) es un programa de mantenimiento que recomienda tomar las decisiones de mantenimiento basado en la información recogida a través del monitoreo de la condición. Este consiste en tres pasos principales: adquisición de información, procesamiento de los datos y toma de decisiones de mantenimiento. Diagnósticos y pronósticos son dos aspectos importantes de un programa de CBM. La investigación en el área del CBM crece rápidamente.

La confiabilidad ha sido siempre un aspecto importante en la evaluación de productos y/o equipo industriales. Un buen diseño de producto es esencial para productos con alta confiabilidad. Sin embargo, sin importar que tan bueno sea el diseño del producto, estos finalmente se van deteriorando al pasar el tiempo debido a su operación bajo condiciones de tensión o carga en su ambiente real, incluyendo siempre algunos imprevistos. El mantenimiento ha sido entonces introducido como una manera eficiente de asegurar un nivel satisfactorio de confiabilidad durante la vida útil de un bien.

La técnica de mantenimiento más temprana es el Mantenimiento Correctivo (llamado también Mantenimiento No Planeado o Mantenimiento de Rotura), el cual toma lugar solo en el momento de la avería. Una técnica posterior de mantenimiento es el Mantenimiento Preventivo Basado en el Tiempo (llamado igualmente como Mantenimiento Planeado), el cual propone un intervalo de tiempo para desarrollar acciones de mantenimiento preventivo que procuren el bienestar en la condición del activo. Con el rápido desarrollo de la tecnología moderna los

productos han llegado a ser cada vez más complejos, a la vez que se exige una mejor calidad y mayor confiabilidad. Esto hace que el costo del mantenimiento sea cada vez mucho mayor. Eventualmente el mantenimiento preventivo ha llegado a ser uno de los mayores costos en compañías industriales. Por lo anterior se ha empezado a implementar un programa de mantenimiento más eficiente tal como el Mantenimiento Basado en la Condición para poder manejar la situación.

CBM es un programa de mantenimiento que recomienda actuar basado en la información recogida por medio del monitoreo de la condición. Procura dicho método evitar tareas innecesarias de mantenimiento al tomar acciones de reparación solo cuando haya evidencia de comportamientos anormales en el equipo. Un programa de CBM, si se propone de manera correcta y se implementa efectivamente, puede significar reducciones en el costo del mantenimiento al reducir el número de operaciones innecesarias de mantenimiento preventivo planeado.

Un programa de mantenimiento consiste de tres pasos principales:

- i. Adquisición de datos (recolección de información), obtener los datos relevantes de la condición del sistema.
- ii. Procesamiento de datos (manipulación de la información), manipular y analizar los datos o señales recogidos en el paso inicial para una mejor comprensión e interpretación de éstos.
- iii. Toma de decisiones de mantenimiento, recomendar políticas efectivas de mantenimiento.

Los diagnósticos y pronósticos son dos aspectos importantes en un programa de mantenimiento basado en la condición. Los primeros apuntan a la detección de fallos, el aislamiento y la identificación cuando éstos ocurran. La detección de fallos es una actividad que indica cuando algo está mal en un sistema

monitoreado, el aislamiento de fallos ubica el componente que está fallando y la identificación del fallo determina la naturaleza de la falla cuando se le detecta. Los pronósticos buscan predecir la falla antes de su ocurrencia. La predicción busca determinar cuándo una falla se convertirá en avería y a su vez saber cuándo y cómo será la ocurrencia de ésta.

2.2.1. Objetivos del monitoreo de la condición (Donellan, 2002)

Los objetivos del monitoreo de la condición son los siguientes:

- i. Recolectar la mínima información necesaria para planear el mantenimiento predictivo y así evitar los altos costos del mantenimiento correctivo.
- ii. Detectar los defectos de la planta y el desarrollo de fallas durante la operación de ésta.
- iii. Detectar los defectos introducidos durante la instalación de la planta o la reinstalación luego de mantenimiento.

2.2.2. Implementación del monitoreo de la condición (Donellan, 2002)

Al momento de instalar el monitoreo de la condición se deben cumplir los siguientes aspectos:

- i. Selección de las máquinas a implementar usando análisis de criticidad y de modo de falla.
- ii. Selección de las técnicas apropiadas de monitoreo de la condición.
- iii. Aplicación del monitoreo de la condición (Por ejemplo: pruebas específicas, frecuencia de monitoreo).
- iv. Definición de los niveles de alarma.
- v. Implementación de reportes y responsabilidades de actuación.
- vi. Administración y dirección del sistema.

2.3. ENERGÍA INTERNA DE DISIPACIÓN (Cempel, 2003)

Existe un gran número de modos de desgaste en máquinas y la mayoría de ellos están asociados con los fenómenos vibroacústicos. Para maquinaria y sistemas de operación mecánica dicho desgaste corresponde a la disipación de la energía interna, el cual resulta en daños y el deterioro de la condición del equipo.

La energía interna de disipación y el desgaste asociada a ella en el sistema está relacionada a varios tipos de fatiga: volumétrica, superficial, corrosiva, abrasiva, erosiva y de fluencia. Dichos tipos de fatiga y la hipótesis de la energía interna de disipación está asociada a la teoría de las máquinas como procesadores de energía, la cual asume al equipo como un sistema operativo que transforma energía para cumplir su tarea principal y está continuamente intercambiando energía con el medio ambiente además de acumular alguna que puede influir en la condición técnica del equipo, desvirtuando su función principal y llevándolo finalmente a la falla.

2.4. DETERIORO DE UN SISTEMA TÉCNICO (Neale, 2001)

El grado de deterioro de un equipo es detectado por el nivel de una medición y su cambio en el tiempo.

Hay cinco técnicas de medición básicas que pueden ser usadas para monitorear máquinas y la condición de sus componentes:

- i. Residuos de desgaste: La extracción de partículas de desgaste del lubricante de la máquina, el cual ha sido generado por interacciones al roce de los componentes de la máquina.

- ii. Vibración: La medición del movimiento cíclico o vibración generada por la acción dinámica de los componentes internos de la máquina.
- iii. Temperatura: La medición de la temperatura en puntos críticos cercanos a las superficies en movimiento de los componentes de la máquina, o la observación de los patrones de temperatura en el ensamble de un sistema.
- iv. Rendimiento: El estudio de las relaciones entre las características de operación de una máquina, o la consistencia del comportamiento de sus componentes.
- v. Vencimiento de la vida: La grabación del tiempo de operación a diferentes condiciones de un componente sujeto a deterioro por factores tales como fricción o fatiga, que permite su remoción del servicio antes que suceda una falla esperada.

2.5. MATRIZ DE OBSERVACIÓN DE SÍNTOMAS (Portala, 2004)

Tal como se definió anteriormente por la importancia de su ilustración, un síntoma es una característica del equipo debe cumplir con las siguientes propiedades (NATKE, 2000):

- i. Medible directa o indirectamente.
- ii. Que tenga relación funcional a la medición de un daño.
- iii. Alta sensibilidad a una falla o daño como una propiedad local, pero resistente a disturbios desconocidos como una propiedad global.
- iv. Distingible de varios términos en el modelo de falla, el cual también incluye separación de fallas.
- v. El valor absoluto del síntoma es una función no decreciente en el tiempo, a menos que el sistema sea reparado.
- vi. Permite estimar tendencias.

La matriz de observación de síntomas definida por $O_{pr} = S^{r \times p}$ es un arreglo de los síntomas medidos: p , la dimensión fila, es el número de observaciones por síntoma y r , la dimensión de las columnas, es el número de síntomas observados. En otras palabras, se puede decir que la matriz de observación de síntomas es una forma discreta de observar síntomas. El objetivo consiste en extraer las características que dependen de la condición de la matriz O_{pr} e interpretarlas en términos de las modificaciones del sistema técnico tales como el desgaste, las fallas y demás características operacionales. De esta manera, para un sistema crítico en operación, se pasará de un síntoma basado en inferencia a la matriz de observación de síntomas basada en inferencia. (Cempel, 2000) (Portala, 2004)

La matriz de observación de síntomas de un sistema está representada de la siguiente manera.

$$= \left\{ \begin{array}{c} \\ \vdots \end{array} \right\} = \left[\begin{array}{cccc} \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \vdots & \vdots & \ddots & \vdots \\ \cdot & \cdot & \dots & \cdot \end{array} \right] \quad (2.1)$$

La matriz O_{pr} en ocasiones puede ser una matriz muy larga, esto significa que sea una matriz rectangular con más columnas que filas $r > p$. Sin embargo se puede presentar lo contrario, especialmente cuando el monitoreo de condición de estado de un sistema técnico ya haya sido desarrollado, esto quiere decir que por medio de información obtenida previamente o por medio de la observación de los síntomas se reduzca el número de síntomas (columnas) de la matriz original. (Portala, 2004)

Una matriz de observación de síntomas de gran tamaño debe ser manejada de tal manera que se pueda extraer la máxima información sobre las fallas y daños. En ciertos casos la información en varias columnas puede ser redundante sin varía

ligeramente otros síntomas contenidos en la matriz O_{pr} , esto puede ser evitado por medio de la eliminación de las columnas correspondientes. Para ejecutar este procedimiento de eliminación es recomendable que se conozca como esos síntomas de esas columnas se desarrollan a través del tiempo. (Natke, 2000)

2.6. TRANSFORMACIÓN DE UN ESPACIO DE SÍNTOMAS A UN ESPACIO DE FALLAS

La matriz de observación de síntomas O_{pr} genera el espacio de síntomas a través de sus r columnas. Estos síntomas dependen en gran parte de las veces de otros síntomas o de un proceso de vida no medible como en el caso de la corrosión, esto hace entonces que las columnas de síntomas sean no ortogonales. Los síntomas deben ser independientes unos de otros de manera que las columnas de síntomas sean ortogonales y se pueda pasar mediante transformaciones a la matriz O_{pr} de un espacio de síntomas a un espacio de fallas. En el espacio de fallas es posible observar la vida del sistema en términos de la evolución de las fallas $F_t(\theta)$ con $t = 1, 2, \dots, z$. De esta transformación de espacios se espera obtener $F_t(\theta)$ de algunos valores o índices que describan la evolución real de la destrucción del sistema. En algunos $F_t(\theta)$ describirá la forma esencial del proceso de desgaste o las modificaciones de las propiedades del sistema tal como el comportamiento lineal y el cúbico o el aumento cuadrático. (Portala, 2004)

2.7. MONITOREO MULTIDIMENSIONAL DE LA CONDICIÓN

Mediante el estudio de la energía de salida se puede conocer el estado técnico de un sistema técnico y su nivel de desgaste. Para realizar dicha revisión es necesario primero ejecutar un procesamiento de señales para reconocer

fenómenos físicos existentes en el sistema y que puedan dar fe su condición, tales como la vibración, el ruido y el calor.

Las señales adquiridas se convierten en datos de entrada para la matriz y se puede apoyar la búsqueda en alguna norma o la revisión estadística de una señal temporal en la cual se pueden hallar sus valores estadísticos típicos: media, desviaciones, valores pico a pico, correlaciones de variables, varianzas, covarianza, etc. Se pueden hallar otros datos descriptivos del sistema más complejos como la búsqueda de espectros y análisis estadísticos de orden superior.

Para poder realizar el Monitoreo Multidimensional de la Condición es necesario armar la Matriz de Observación de Síntomas, la cual está compuesta de síntomas en sus columnas y de observaciones en sus filas. Se reduce dicha matriz a través de un Análisis de Componentes Principales (PCA), que permite establecer cuáles son los síntomas que contienen la información de mayor relevancia sobre el estado del sistema.

Luego del PCA se logra una matriz reducida a la cual se le aplica la Descomposición en Valores Singulares (SVD) que determina el fallo generalizado que muestra la evolución del sistema. Cuando se llega a este punto es factible la realización de un diagnóstico integral y, luego de establecerse su valor límite de síntomas, se podrá determinar en qué condiciones el fallo generalizado sobrepasará el valor límite. En este punto se podrán entonces realizar actividades de pronóstico del estado futuro de la máquina.

También se podrán crear indicadores que apoyen el diagnóstico del sistema, tales como funciones de confiabilidad y riesgo. Se podrán establecer modelos generales lineales que describan la manera en la cual se comporta el fallo generalizado, buscando conocer el estado cercano del equipo y lograr un pronóstico que permita la realización de mantenimientos que no interrumpan la operación del equipo y

esperando hasta el punto último de mantenimiento sin que no se vaya a afectar la función principal del equipo.

3. HERRAMIENTA COMPUTACIONAL

Este capítulo tiene como propósito dejar en evidencia la historia de la herramienta computacional y su relevancia para el diagnóstico técnico, la manera en la cual está configurada para cumplir su objetivo de diseño. Se señala el estado anterior de la herramienta y finalmente se deja en claro la nueva estructura propuesta, hablando además de la manera en la cual se ha estandarizado la estructura de programación.

3.1. ANTECEDENTES

La metodología para el Monitoreo Multidimensional de la Condición ha sido utilizada con éxito por el Grupo de Estudios en Mantenimiento Industrial (GEMI) en proyectos de investigación en diagnóstico técnico y ha sido motor de varios estudiantes de Pregrado en Ingeniería Mecánica y Maestría en Ingeniería Mecánica para realizar sus Proyectos de Grados y Tesis, respectivamente.

La primera tesis en la cual se evidencia el uso de la metodología para diagnóstico técnico fue la del M.Sc. Ing. Francisco Javier Botero, quién hizo uso de este paquete para su “Desarrollo de un modelo predictivo computacional para el diagnóstico de la condición de bombas centrífugas”. Concluye Botero que el diagnóstico técnico realizado a un sistema, en este caso experimental de bombeo, puede definir su estado técnico actual, las causas de este estado y también en el horizonte futuro el cambio de este estado. Asegura que la información que alimenta los modelos propuestos en el proyecto, es fundamental en el proceso de diagnóstico y que datos recolectados sin ninguna rigurosidad pueden producir resultados errados en las tareas del diagnóstico, o por otro lado, la redundancia de

información puede hacer que el proceso sea lento, por lo cual concluye que los criterios para recolectar la información son el primer paso en el proceso de diagnóstico, porque de lo contrario, se pueden afectar significativamente las posteriores tareas de diagnóstico.

Afirma Botero que el método para definir valores límite para las distribuciones de los estimadores vibro-acústicos medidos en el sistema de bombeo experimental que produjo mejores resultados, es el método basado en el valor promedio del parámetro de diagnóstico antes del estado de avería y que, de los métodos de pronóstico tratados para el parámetro de diagnóstico: eficiencia, el método adaptativo de Brown-Mayer de segundo orden, fue el que arrojó mejores resultados de acuerdo a los criterios establecidos.

Así mismo, el primer proyecto de grado es del Ing. Ricardo Andrés Guerrero, quién hizo un aporte valioso en el procesamiento de señales con su “Desarrollo de un procesador computacional de señales aplicado al diagnóstico técnico”. Muestra en su proyecto que se diseña un software que permite realizar un procesamiento de señales con base en el diagnóstico técnico. El *software* posee una interfaz que permite un acceso rápido a los diferentes estimadores definidos en el desarrollo del proyecto de grado. El programa se define como un compilador de estimadores que permite al usuario establecer un punto de vista comparativo en el diagnóstico técnico y establece prioridades en el momento de definir con cuál procesamiento es más fácil llegar a un resultado asertivo. La conceptualización de los métodos usa una metodología sobre la cual se expresa el principio matemático y su aplicación. Por medio de un ejemplo sobre una señal simulada o capturada se realiza la comprobación de cada uno de los métodos. La adquisición de los datos se realiza por medio de EXCEL o simulando la señal desde el mismo programa. Adicional a esto, antes de realizar cualquier procesamiento sobre la señal es posible realizar filtrados que permitan eliminar frecuencias no asociadas al interés en el diagnóstico.

Señala Guerrero que cada uno de los métodos presenta estimadores que son más sensibles de acuerdo al tipo de falla. Por ejemplo para los fallos asociados a presencia de bandas laterales, el Cepstrum y la modulación se convierten en herramientas útiles en el diagnóstico. Afirma además que el desarrollo del *software* presenta, mediante diagramas de flujo, el procedimiento a seguir para la ejecución adecuada de cada una de las ventanas. Adicional a esto se expresa el flujo de información que se debe seguir para el correcto procesamiento sobre cada uno de los estimadores.

En cuanto a la prueba, narra Guerrero que el caso utilizado para la comprobación presenta un estado de cavitación en un sistema de bombeo y realiza el procesamiento sobre los métodos más representativos. Para el ejemplo específico se observa una mayor significancia en los estimadores asociados a cambios en la frecuencia y amplitud como lo son los espectros, las medidas de frecuencias y amplitud, entre otros. Por ser un sistema lineal en su funcionamiento, los procesamientos asociados a la linealidad del sistema como el biespectro, la bicoherencia o el triespectro pierden valor dentro del diagnóstico. En la herramienta computacional, adicional al procesamiento individual, es posible generar un reporte en EXCEL que permita visualizar cada uno de los estimadores de tal manera que se pueda ir acumulando y así poder llevar una tendencia del estado del sistema a diagnosticar.

El Ing. Juan Sebastián Ortiz con su proyecto de grado “Modelo regresivo de diagnóstico técnico para la interfase vía-vehículo de un sistema ferroviario” describe que realizó una descripción general sobre los diferentes modelos de diagnóstico que definen el estado de los sistemas técnicos, de este modo se identificó el modelo regresivo como un modelo sintomático, el cual relaciona las variables de estado de condición con los parámetros de diagnóstico los cuales permiten detectar fallos que se pueden presentar dentro del sistema. Mediante los

ejercicios realizados logró identificar parámetros de diagnóstico que permiten representar algunas de las variables de estado técnico asociadas a la corrugación de la vía.

Afirma Ortiz que parámetros de diagnóstico como el sesgo, el índice armónico y la desviación estándar hacen parte de los parámetros que preliminarmente pueden indicar las características de la condición de la vía en lo que respecta a la corrugación en este caso de estudio. Señala que los valores medidos a la interfase se ajustaron muy bien al modelo regresivo, existiendo otros tipos de matriz de estado que se pudieron haber utilizado pero que no se llevaron a cabo ya que los resultados arrojados no eran buenos, no significando que el modelo estuviera mal, sino que simplemente fueron muy pocas las relaciones directas que se encontraron entre los parámetros de diagnóstico y las matrices de variables de estado concernientes a la geometría de la vía. Además asevera que las probabilidades de los coeficientes beta permitieron estimar si el cambio de las variables de estado eran significativos para el parámetro de diagnóstico en cada uno de los ejercicios, esto permitió tener una mayor certeza sobre el análisis y control sobre las regresiones ya que existían muy buenos índices y coeficientes de correlación pero estos eran contrariados por los valores probabilísticos.

Posteriormente el M.Sc. Ing. Germán René Betancur y el M.Sc. Ing. Iván Abril Hernández hicieron importantes aportes con sus tesis de maestría, el primero de estos hizo uso del programa en “Monitoreo multidimensional para el mantenimiento de la interfase vía-vehículo de sistemas ferroviarios” y el segundo con su tesis “Sistema de diagnóstico para vías férreas utilizando modelos matemáticos”.

Betancur propone que una aproximación holística de mantenimiento para un sistema técnico puede ser alcanzada mediante el uso del monitoreo multidimensional de la condición, metodología que transforma información

relevante sobre el estado técnico del sistema, en un único indicador denominado fallo generalizado, por medio del cual pueden realizarse tareas de diagnóstico y pronóstico; y generar indicadores de gestión del mantenimiento. Dicho monitoreo permite establecer, en el caso ferroviario, los tramos de vía y los vehículos susceptibles de una revisión más exhaustiva por parte del personal de mantenimiento de vía permanente y su movilización. Es posible, además, obtener pistas sobre el fenómeno que esté aconteciendo en el tramo a revisar. Por lo tanto este tipo de monitoreo, en el caso específico analizado, genera un apoyo en las decisiones de mantenimiento, lo que repercute en una disminución de los costos asociados a esta actividad y un óptimo uso del personal; también genera un aumento en la disponibilidad y fiabilidad del sistema.

El estudio de Betancur fue realizado en condiciones reales de explotación y se tuvieron en cuenta variables dinámicas de los vehículos, estimadores relacionados con la interfase rueda-riel y con los parámetros usualmente usados por el personal de mantenimiento de vía permanente y movilización, con el fin de conseguir información del estado técnico general del sistema. En el caso de estudio del Metro de Medellín la corrugación de los rieles se presenta como el principal factor que afecta la fiabilidad del sistema, tanto en tramos rectos como curvos, pues ésta tiene gran influencia sobre el fallo generalizado, el cual permite inferir sobre el estado técnico general o integral del sistema. Se sabe, además, que la corrugación de la vía genera vibraciones de las masas suspendidas del vehículo que son transmitidas a los pasajeros generando incomodidad (carencia de confort).

Expone Betancur que se establecieron dos modelos generales para la evaluación del fallo generalizado en tramos rectos y curvos, esto con el fin de hacer una rápida cuantificación del fallo en condiciones actuales de la vía y el vehículo, lo que permite apoyar las decisiones de mantenimiento.

Abril en su tesis afirma que existe relación entre las propiedades de la interfase, contenida en la geometría de la vía, el perfil de riel y de la rueda, y los parámetros obtenidos con la implementación de la norma UIC 518. El grado de relación no es el más alto esperado, esto responde a que el experimento como tal es una combinación de muchos factores que afectan las señales.

Asevera Abril que el indicador de relación utilizado fue el coeficiente de correlación, este requiere que las variables analizadas contengan todas las condiciones posibles de estados del sistema, para algunas propiedades en especial las correspondientes a las de la rueda, los valores obtenidos eran similares en varias observaciones o unidades. Esta situación limita la capacidad de la función para encontrar relación entre las variables. Las secciones de vía con mayor facilidad debido a las características geométricas y las condiciones de operación son las curvas y en especial las de pequeños radios, en estas secciones hay mayor relación con los parámetros. Las condiciones de operación y las propiedades de estado de los componentes son exigidas en mayor grado sobre esta parte de la vía.

En el caso de estudio, el caso ferroviario, las propiedades de la pestaña como son la altura, el ancho y la escarpadura son propiedades que afectan el confort de los vehículos férreos, la condición buena de estas impiden obtener mejores valores de correlación. El experimento es la combinación de factores percibidos en las señales capturadas y finalmente visualizados en las gráficas de dispersión, para encontrar relaciones con alta correlación, la propiedad debe afectar considerablemente la operación del sistema, para así la señal pueda identificar la alteración de la propiedad.

Expone Abril que las nubes de puntos alrededor de las líneas de tendencia son la representación de la incertidumbre de las medición, y la combinación de otros factores que afectan la señal. Los valores de correlación y coeficiente de

determinación r cuadrado eran menores de 0.8, indicando una aceptable relación entre las variables, explicable por la naturaleza del experimento, donde no se controlaron algunos factores, como son el peso del vehículo y las condiciones de operación del sistema. Se estimaron alrededor de 60 indicadores escalares, para 14 canales, en total 840 indicadores fueron calculados por sección, este volumen de datos fueron comparados con tablas de resumen que permiten identificar el punto de medición, el canal, el estimador y las propiedades con mayor correlación, esta información a pesar de ser verídica requiere de ser manejada cuidadosamente, ya que esta asociación no puede ser generalizada.

Los parámetros que evalúan el nivel de la señal como son el RMS, la media y la amplitud en ciertas frecuencias en el espectro son sensibles al cambio de las propiedades. El factor de forma, la kurtosis y el factor de holgura que evalúan la distribución de los datos, se relacionaron con las propiedades de corrugación, esta última apreciación infiere que la corrugación es un fenómeno que distorsiona la distribución de los datos de las señales, modificando la normalidad de ésta. Mejorar los resultados de estas apreciaciones, requiere ajustar las condiciones del experimento y tener mayor control sobre éste, con esto buscando disminuir la información aleatoria identificada en las gráficas de dispersión.

Creó Abril un módulo integrado de análisis de señales denominado MULTIPLE, capaz de procesar la información por observaciones y crear una matriz de diagnóstico para ser evaluada por diferentes métodos como son el de la correlación o la descomposición de valores singulares. Como resultado valioso de esta investigación se obtuvo un módulo integrado de funciones utilizadas en el diagnóstico de vibraciones, que permite mejorar el estudio de la identificación de fallos en equipos técnicos y facilita la ejecución de futuras investigaciones.

La Ing. Ángela María Arévalo Hurtado y el Ing. Alexander Portala Contreras hicieron contribuciones a la teoría de la Descomposición por Valores Singulares

(SVD) en sus proyectos de grado: “Verificación experimental de la metodología de diagnóstico técnico multidimensional basada en el SVD” y “El método de descomposición SVD en el diagnóstico técnico”, respectivamente.

Arévalo plantea que el método evaluado ha probado tener una gran aplicación y validez dentro de muchos campos de la ingeniería como lo demostró la revisión de la literatura y estado del arte. Sin embargo los resultados del experimento realizado entregaron evidencia para inferir que las transformaciones aplicadas actualmente a la Matriz de Observación de Síntomas, influyen en la relación entre los síntomas y los fallos. Demostró que por medio de la perturbación de un síntoma manipulado se puede modificar completamente el comportamiento del primer fallo y que, aunque este síntoma no corresponde a ningún síntoma real medido, no hay ninguna razón para suponer que sus comportamientos no sean semejantes. Propone la autora que la criticidad que el método otorga a un síntoma determinado depende de su valor inicial y su variación (rango), que la dependencia de uno o de otro depende de la transformación aplicada, siendo la primera transformación la que da importancia al valor inicial del síntoma y a su variación. Las demás transformaciones presentaron comportamientos similares entre ellas, dando mayor importancia a la variación de los síntomas. Afirma Arévalo que no hay razón para suponer que el valor inicial y el alcanzado por un síntoma en un instante de tiempo θ sean parámetros determinantes en la condición del estado de un sistema técnico y que por esta razón puede concluir que el método, tal y como ha sido concebido hasta el momento, presenta limitaciones en términos del sistema de unidades, de la escala utilizada para cuantificar la naturaleza de los síntomas y de restricciones propias del funcionamiento del sistema.

Finalmente concluye, a partir de este hallazgo, que ninguna de las transformaciones consideradas actualmente por el método da igual tratamiento a síntomas de diferente naturaleza o escala, sugiriendo esto que el método puede

requerir de una posterior revisión en términos de la o las transformaciones que se aplique a la SOM. Señala Arévalo que, aunque los resultados mostraron algunas deficiencias del método para este caso en particular, no se puede negar la validez de los resultados experimentales presentados en las publicaciones de los investigadores Cempel y Natke obtenidos a partir de aplicaciones como un ventilador industrial, una plataforma petrolera, un motor diesel de locomotora, entre otras. En estas publicaciones se reportaron buenos comportamientos de los indicadores del daño; debido a las características de las SOM ensambladas, ya que para dichas pruebas se midieron y analizaron síntomas de la misma naturaleza, medidos bajo el mismo sistema de unidades, para los cuales se podrían suponer variaciones similares.

Portala a su vez afirma que se clasifica el SVD como un modelo procesador de energía que relaciona los síntomas medidos con la evolución del desgaste interno y el comportamiento dinámico de un sistema técnico. La información existente de las investigaciones que tratan sobre la aplicación del SVD en el diagnóstico técnico fue recopilada en su proyecto y presentada de forma clara y concisa, extrayendo de ahí conocimiento sobre el método y las bases teóricas necesarias para crear y procesar una matriz de observación de síntomas y, a su vez, analizar la condición de estado de una máquina a partir de la evolución de sus índices de falla generalizada. Aclara que uno de los conceptos más importantes del método SVD es el análisis de covarianza de los síntomas medidos con el síntoma de falla generalizada, que permite descartar los síntomas redundantes de la matriz de observación de síntomas y generar una matriz más sensible al daño que entregue índices certeros sobre la evolución de la destrucción de la máquina.

3.2. PROPÓSITO

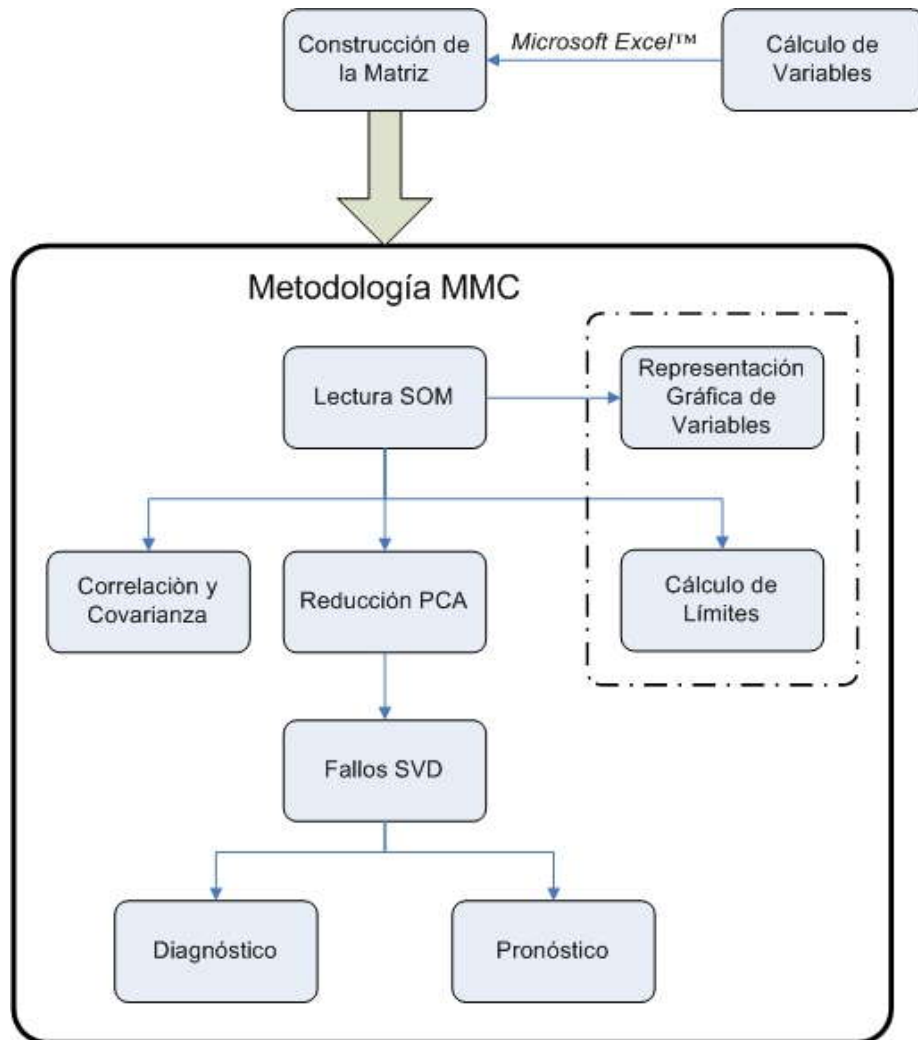
El Monitoreo Multidimensional de la Condición (MMC) es una metodología de mantenimiento que permite evaluar el estado técnico de un sistema por medio de la evaluación, en diferentes períodos de tiempo, de síntomas que revelen la condición del equipo.

El diagnóstico y pronóstico de la condición de la maquinaria son parte del mantenimiento basado en la condición como eventos posteriores y previos, respectivamente. Del diagnóstico hace parte la detección, el aislamiento y la identificación de fallas. Por su parte el pronóstico tiene como objetivo la predicción de fallas, determinando aproximadamente cuando y como podría llegar a ocurrir una falla. El pronóstico es mucho más eficiente que el diagnóstico en el propósito de lograr una efectividad en el indicador de disponibilidad de cero-averías. También se debe mencionar que el diagnóstico técnico es siempre requerido cuando una falla sucede, esto debido a la prioridad que tiene el responsable del sistema técnico de conocer el estado de la condición técnica del equipo y tener jerarquizado, por orden de ocurrencia y gravedad de estas, los modos de falla del equipo. (Jardine, Lin y Banjevic, 2006)

El CBM practica el pronóstico y diagnóstico de sistema por medio de tres señales de tres tipos: Puntuales, Ondulantes y Multidimensionales (Jardine, Lin y Banjevic, 2006). El MMC, al cumplirse como un sistema propio para el mantenimiento basado en la condición, tiene como entradas las señales propuestas por la teoría en cuanto puntuales y ondulantes, con el propósito de llevarles a señales de tipo multidimensional al ingresar en la matriz y correlacionarlas, logrando la evaluación de los síntomas propios del equipo para poder entonces tener la posibilidad de realizar el diagnóstico técnico y el pronóstico acertado de acuerdo al estado de salud del equipo.

En la figura 1 se puede ver el esquema de la metodología MMC que, mediante el mejoramiento de la herramienta computacional, se quiere lograr tras la ejecución del proyecto. El propósito de la herramienta es lograr que, al tener ya construida la matriz con toda la información de la maquinaria y haber calculado antes las variables, se ejecuta la metodología: Se procede inicialmente con la lectura de la matriz de observación de síntomas y se puede lograr la representación gráfica de las variables, permitiendo conocer tendencias de incremento o decremento de alguna de estas. Después de la lectura se puede hacer el análisis de correlación y covarianza, la reducción PCA y el cálculo de límites. Desde la reducción PCA surge el análisis de fallos por SVD para finalmente obtener el diagnóstico y el pronóstico del equipo.

Figura 1. Metodología MMC propuesta para el proyecto de mejoramiento.



3.3. ESTRUCTURA DE LA HERRAMIENTA COMPUTACIONAL

El recorrido histórico de la herramienta computacional, tal como se ha mostrado en este capítulo, ha estado ligado al trabajo de muchos estudiantes que han agregado valor a ella y la han compuesto. Dentro de los objetivos de este proyecto se encuentra el revisar su estado actual, establecer su estructura y estandarizarla. Este parte del informe señalará entonces la manera en la cual se ha efectuado dicha revisión en sus rutinas para el experimento pasivo y el fallo generalizado. Se ha basado dicha consideración con base en el estudio previo realizado por el Ing. German René Betancur.

3.3.1. Rutina para Experimento pasivo

El experimento pasivo considera las primeras reducciones básicas de la matriz de observación de síntomas, la definición de algunos límites, el análisis de componentes principales y la reducción posterior de la matriz de observación.

La rutina del experimento pasivo está dada en los siguientes pasos:

- Se prepara la Matriz de Observación de Síntomas (SOM) y se disponen las variables que se van a trabajar durante el Experimento Pasivo.
- Se asume un nivel de confianza (significancia) de $\alpha = 0.05$ para los análisis estadísticos.
- Se da la opción de eliminar manualmente las variables que no se quiere tener en cuenta para el análisis, estos síntomas no aparecerán en los análisis que siguen a continuación.

- Se realiza el cálculo de la sensibilidad de síntomas mediante la ecuación 3.1:

$$= \frac{(\quad)(\quad)}{\quad} \quad (3.1)$$

- Se transforma la matriz centrando con respecto a la media y normalizando respecto a la desviación estándar de cada columna, como se señala en la ecuación 3.2. Esta transformación no fue considerada por Arévalo.

$$= \frac{\quad}{\quad} \quad (3.2)$$

- Se ingresa la disponibilidad del sistema objeto de estudio.
- Se recalcula el valor límite para cada columna de la matriz, de acuerdo con la teoría de Neyman & Pearson. Se tiene en cuenta la disponibilidad (Pg) y el Coeficiente de Reserva ingresado.
- Se consideran dos situaciones: la primera es el comportamiento ascendente del síntoma, para el cual el límite debe estar por encima de su valor promedio, este caso se da por ejemplo con síntoma relacionado con la temperatura, la cual tiende a aumentar en el tiempo de vida, para este caso el límite se calcula mediante la ecuación 3.3:

$$S_{lim} = \bar{S} + \sigma_s \sqrt{\frac{Pg}{2A}} \quad \text{Límite Calculado} \quad (3.3)$$

- La segunda situación se da cuando el síntoma tiene un comportamiento descendente, por ejemplo un síntoma relacionado con el desgaste, para este el valor límite estará por debajo de la media de la serie de datos y es calculado mediante la ecuación 3.4:

$$S_{lim} = \bar{S} - \sigma_s \sqrt{\frac{Pg}{2A}} \quad \text{Límite Calculado} \quad (3.4)$$

- Para determinar cual límite seleccionar, entre el límite calculado anteriormente y el límite fijado por el fabricante, la empresa o alguna norma, se tiene el siguiente criterio:

- Para síntomas ascendentes (ecuación 3.5):

$$Límite_final = \min(Límite_calculado, Límite_norma) \quad (3.5)$$

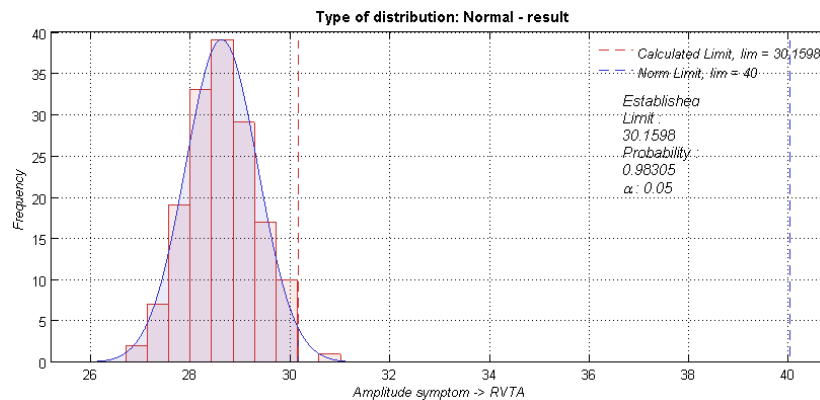
- Para síntomas descendentes (ecuación 3.6):

$$Límite_final = \max(Límite_calculado, Límite_norma) \quad (3.6)$$

- Se determina la probabilidad del síntoma de no sobrepasar el valor límite (*Probability*), calculando el tipo de distribución estadística teórica.

Ejemplo: para el caso mostrado en la figura 2, el límite de temperatura máxima fijada por el fabricante es de 40°C, el límite calculado por medio de la fórmula de *Neyman & Pearson* para un estimador ascendente es de 30.1598 con $P_g = 0.1$ y $A = 0.9$. Se selecciona entonces el límite calculado debido a que es menor al límite normal. El límite calculado tiene una probabilidad de que el estimador sobrepase este valor fijado en 98.305%. Los datos obedecen a una distribución normal con un nivel de confianza de $\alpha = 0.05$.

Figura 2. Ejemplo de resultado de una distribución normal y sus límites.



Posteriormente se continúa con el análisis de componentes principales con los siguientes pasos:

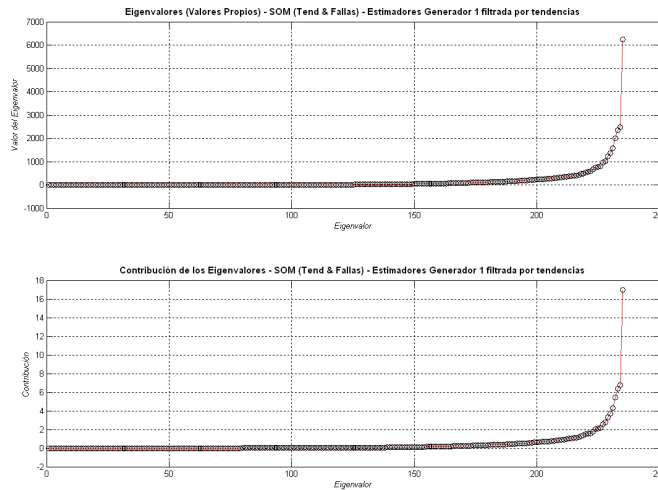
- Se determina la Matriz de correlación relativa con base en la ecuación 3.7:

$$O_{pr} = SOM^T .SOM \quad (3.7)$$

- Cálculo de los vectores propios y de los valores propios de la matriz de variables mediante la función *eig* de MatLab® aplicada a la Matriz de Correlación Relativa. Se tiene en cuenta lo siguiente:
 - Los vectores propios correspondientes a los valores propios son linealmente independientes.
 - Los Valores Propios (λ) se encuentran en la diagonal de la matriz *sorted_eigVals*, ordenados de manera ascendente.
- Se determina la contribución de los valores propios mediante la ecuación 3.8:

$$Contribución(\lambda_i) = \frac{\lambda_i}{\sum \lambda_i} * 100 \quad (3.8)$$

Figura 3. Contribución de los valores propios por sus estimadores.



Posteriormente se continúa con el análisis de componentes principales con los siguientes pasos:

- Se analiza el acierto de la información, el grado de variabilidad del experimento, el producto de valores propios, la redundancia de la información (o sobredimensionamiento) y la medida de agrupación k .
- Se calculan inicialmente $trazaK$ y $detK$, para utilizarlos como valor de referencia, antes de la eliminación iterativa.
- Se establece el coeficiente para el grado de variabilidad del experimento como igual a 0.7.
- Se determina la variable con menor aporte en el espacio multidimensional para una posterior eliminación de aquel estimador con menor valor de proyección en las componentes principales mediante:
 - Se establece un valor límite para el análisis de variables con menor aporte, en la contribución de los valores propios.
 - Se reordenan descendentemente la matriz con los vectores propios (la primera columna corresponde al vector relacionado con el valor propio mas alto) y el vector de valores propios λ .
 - Se determina la contribución de los valores propios.
 - Se establece la suma acumulada de las contribuciones de los valores propios.
 - Se determina la columna donde se cumpla el valor límite para el análisis de variables con menor aporte de los valores propios.

El resultado de estos procedimientos se pueden observar en las figuras 4 y 5, en el cual se muestra la sensibilidad de síntomas antes de la transformación y reducción de la matriz y además la contribución de los valores propios por sus estimadores antes de la transformación y reducción de la matriz.

Figura 4. Sensibilidad de síntomas antes de la transformación y reducción de la matriz.


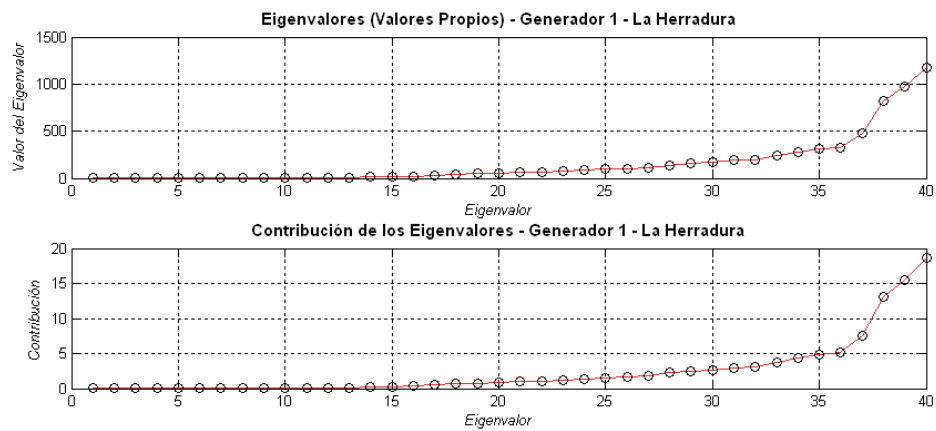


Figura 5. Contribución de los valores propios por sus estimadores antes de la transformación y reducción de la matriz.



3.3.2. Rutina para Fallo Generalizado

El fallo generalizado inicia su camino al cargar los resultados del experimento pasivo y cargar la información de la matriz de observación de síntomas, realiza algunos cálculos estadísticos propuestos y corre funciones de PCA y SVD. Revisa pruebas de bondad y ejecuta análisis de distribución estadística. Finalmente define límites, halla probabilidades, propone diagnósticos de fallo y grafica algunos límites de la condición.

La rutina del fallo generalizado fluye de la siguiente manera:

- Se abren los resultados del experimento pasivo.
- Se carga la información de la hoja de cálculo.
- Se prepara la matriz SOM, los límites, las etiquetas de los síntomas y el criterio de seguridad.
- Se asume un nivel de confianza (significancia) de $\alpha = 0.05$ para los análisis estadísticos.
- Se realiza el cálculo de la sensibilidad de síntomas mediante la ecuación 3.1, al igual que en el experimento pasivo.
- Se determina el valor inicial de cada síntoma tomado desde la matriz de observación de síntomas. En caso de ser cero, se toma el valor siguiente.
- Se transforma la matriz centrando con respecto a la media y normalizando respecto a la desviación estándar de cada columna por medio de la ecuación 3.2, al igual que en el experimento pasivo.
- Se imprime el reporte de actividades.
- Se realiza el análisis de componentes principales por medio de la subrutina MathWorks del código de fallo generalizado.
- Se realiza una descomposición de los discriminantes SDi.
- Se suman los SDi y se toma su valor absoluto.

- Se calcula la distribución de síntomas para los dos primeros síntomas generalizados.
- Se halla el vector Generalizado SDi (Propuesto por Tabaszewski).
- Se inicia el cálculo correcto de SI (Propuesto por Cempel).
- Se realiza la Descomposición en Valores Singulares (SVD).
- Se procesa una “Evolución de los Valores Singulares” para luego realizar un segundo PCA.
- Se busca el fallo generalizado dado un vector columna que ha sido ordenado.
- Se corre un Test de bondad para determinar el tipo de distribución, cálculo de la medición del daño generalizado en el tiempo de vida.
- Se imprime nuevamente el reporte de actividades.
- Se determina si se desea proceder a pronóstico y correr su respectiva rutina.
- En el caso de no distribuir se debe proceder a un procedimiento especial propuesto como subrutina que ejecuta inmediatamente.
- Se halla función de confiabilidad.
- Se halla el límite de la fiabilidad sintomática.
- Se halla la función de la velocidad del riesgo sintomático.
- Se halla la función de riesgo sintomático.
- Se halla el límite de la función de riesgo sintomático acumulado.
- Se halla la cantidad residual de observaciones hasta la avería.
- Se halla el cálculo del límite de *Neyman & Pearson*.
- Se halla el cálculo del límite *3 Sigma*.
- Se realiza análisis tipo *Pareto*.
- Se realiza análisis tipo *Weibull*.
- Se realiza análisis tipo *Gamma*.
- Se realiza análisis tipo *Logarítmico normal*.
- Se realiza análisis tipo *Exponencial*.

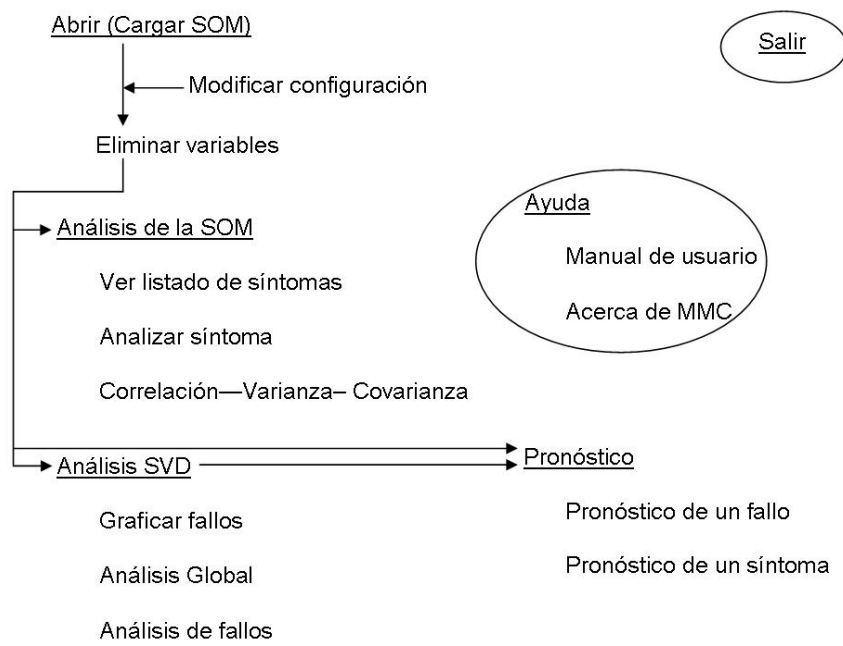
- Se realiza análisis tipo *Normal*.
- Se realiza análisis tipo *Uniforme*.
- Se realiza análisis tipo *Frechet*.
- Se realiza análisis tipo *Cúbico*.
- Se definen límites en zonas de Alarma y Alerta.
- Se imprime la Matriz de Descomposición de Discriminantes, SD
- Se activan gráficos y eventos.
- Se corre un test de bondad con variables definidas.
- Se definen los límites superiores e inferiores para los diferentes tipos de análisis (Pareto, Weibull, Gamma, Logarítmico normal, etc.) y en caso de existir algún inconveniente surge un aviso que señala que “No hay distribución para condición de falla” o “No hay distribución para condición de buen estado”.
- Se grafican algunas probabilidades.
- Se diagnostica el fallo probable del equipo con base en las variables que intervienen.
- Se grafican algunos límites de la condición.

3.3.3. Estructura de programación - navegación

Dentro de la propuesta de estructura de programación de la herramienta computacional se ha buscado siempre que el usuario de ésta se puede acercar fácilmente y no tenga problemas de navegación, por lo cual, además, se le brinda un manual de usuario que puede consultar en cualquier momento en el cual surja una duda: se encuentra disponible en la barra de navegación al extremo derecho.

En la figura 6 se puede ver como se ha propuesto la estructura de programación – navegación para la herramienta computacional para el diagnóstico técnico. Esta imagen se convierte en la explicación gráfica de lo señalado en este capítulo.

Figura 6. Estructura de programación – navegación para la herramienta computacional



4. ANÁLISIS DE COMPONENTES PRINCIPALES Y DESCOMPOSICIÓN EN VALORES SINGULARES

La Descomposición en Valores Singulares (SVD) y el Análisis de Componentes Principales (PCA) son técnicas comunes de análisis de información multivariable. Un simple experimento puede generar mediciones para decenas o hasta incluso cientos de variables resultantes. Hughes *et al.* aseguran que la mayoría de experimentos actuales consisten típicamente de menos de diez ensayos, pero que pueden llegar a ser cientos, a lo cual hay que agregarle que el número de mediciones puede ser de un tamaño bastante considerable. Al tener un gran número de mediciones suele suceder que un gran número de ellas y a la vez un gran número de variables son ruido de los datos de mayor importancia. El SVD puede detectar y extraer las señales que se sugieren ruidosas dentro de un conjunto de mediciones. (Wall, 2003)

4.1. DEFINICIÓN MATEMÁTICA DEL SVD¹

Dado X se tiene una matriz de $m \times n$ de información con variables reales y un rango r , donde no se pierde la generalidad $m \geq n$, y por lo tanto $r \leq n$. En el caso del Monitoreo Multidimensional de la Condición, X_{ij} es la expresión de la i -ésima medición de la j -ésima variable monitoreada. Los elementos de la i -ésima fila de X forman el vector n -dimensional G_i , el cual se refiere a la respuesta de la máquina ante la condición evaluada en una medición dada, que se denominará respuesta

¹ Esta sección de capítulo se ha desarrollado con base en WALL, Michael E.; RECHTSTEINER, Andreas y ROCHA, Luis M. Singular value decomposition and principal component analysis. A Practical Approach to Microarray Data Analysis. Kluwer: Norwell, 2003. Páginas 91-109. Algunos fragmentos se han adaptado parafraseándolos y algunos otros, tal como las fórmulas, han sido literalmente transcritos.

transcripcional. Alternativamente, los elementos de la j -ésima columna de X forman el vector m -dimensional H_j , el cual se refiere a la respuesta en el tiempo de una variable monitoreada, que se denominará expresión del perfil.

La ecuación para la Descomposición en Valores Singulares de X es la siguiente:

$$X = USV^T \quad (4.1)$$

En el cual U es una matriz de $m \times n$, S es una matriz diagonal $n \times n$, y V^T es también una matriz de $n \times n$. Las columnas de U son llamadas los vectores singulares izquierdos, $\{u_k\}$, y forman una base ortonormal para las expresiones de perfil, por lo cual $u_i^*u_j = 1$ para $i = j$, y $u_i^*u_j = 0$ de lo contrario. Las filas de V^T contienen los elementos de los vectores singulares derechos, $\{v_k\}$, y forman una base ortonormal para las respuestas transcripcionales. Los elementos de S son solo números diferentes de cero en su diagonal, y son llamados los valores singulares. Entonces, $S = \text{diag}(s_1, \dots, s_n)$. Además $s_k > 0$ para $1 \leq k \leq r$, y $s_i = 0$ para $(r+1) \leq k \leq n$. Para convención, el ordenamiento de los vectores singulares está determinado de mayor a menor de valores singulares, con el mayor valor singular en el índice superior izquierdo de la matriz S . Se debe tener en cuenta que para una matriz cuadrada simétrica X , la descomposición en valores singulares es equivalente a la diagonalización, o solución del problema del eigenvalor.

Un resultado importante del SVD de X es que:

$$() = \quad (4.2)$$

Es el rango l de matriz más cercano a X . El término "cercano" significa que $X^{(l)}$ minimiza la suma de los cuadrados a la diferencia de los elementos de X y $X^{(l)}$, $\sum_{ij} |x_{ij} - x^{(l)}_{ij}|^2$.

Una manera de calcular el SVD es calcular primero V^T y S al diagonalizar $X^T X$:

$$X^T X = VS^2V^T \quad (4.3)$$

Y luego calcular U así:

$$U = XVS^{-1} \quad (4.4)$$

Donde las columnas $(r+1), \dots, n$ de V para las cuales $s_k = 0$ son ignoradas en la matriz de multiplicación de la ecuación 5.4. Las opciones para el resto de los vectores singulares $n - r$ en V ó U pueden ser calculados usando el proceso de ortogonalización o algún otro método de extensión. En la práctica hay varios métodos para calcular el SVD que son altamente efectivos y eficientes.

Relación con el Análisis en Componentes Principales. Hay una relación directa entre el PCA y el SVD en el caso en el cual los componentes principales son calculados desde la matriz de covarianza. Si se condiciona la matriz de datos X al centrar cada columna, entonces $X^T X = \sum_i g_i g_i^T$ es proporcional a la matriz de covarianza de las variables de g_i (por ejemplo la matriz de covarianza de la toma de muestras). Por medio de la ecuación 4.3 la diagonalización de $X^T X$ entrega V^T , el cual a su vez proporciona los componentes principales de $\{g_i\}$. Los eigenvalores de $X^T X$ son equivalentes a s_k , los cuales son proporcionales a las varianzas de los componentes principales. La matriz U contiene entonces los valores componentes principales, los cuales son las coordenadas de los síntomas en el espacio de los componentes principales.

Si se da que cada fila de X es centrada, $XX^T = \sum_j a_j a_j^T$ es proporcional a la matriz de covarianza de las variables de a_j (por ejemplo la matriz de covarianza de los síntomas). En este caso, los vectores singulares izquierdos $\{u_k\}$ son los mismos que los componentes principales de $\{a_j\}$. Los s_k^2 son de nuevo proporcionales a las varianzas de los componentes principales. La matriz $S V^T$ otra vez contiene los valores componentes principales, los cuales son las coordenadas de las mediciones en el espacio de los componentes principales.

Relación con el Análisis de Fourier. La aplicación del SVD en el análisis de información tiene similitudes con el Análisis de Fourier. Como en el caso con el SVD, el Análisis de Fourier involucra la expansión de la información original en una base ortogonal:

$$x = \dots / \dots \quad (4.5)$$

La conexión con el SVD puede ser explícitamente ilustrada al normalizar el vector $\{e^{i2\pi jk/m}\}$ y al nombrarlo v'_k :

$$x = \dots = \dots \quad (4.6)$$

La ecuación anterior genera normalmente la ecuación matricial $X = U'S'V'^T$, similar a la ecuación 4.1. A diferencia del SVD, y a pesar de estar $\{v'_k\}$ en una base ortonormal, $\{u'_k\}$ no es generalmente ortogonal. No obstante esto demuestra como el SVD es similar a la transformada de Fourier, en la cual los vectores $\{v_k\}$ están determinados de una manera muy específica desde la ecuación 5.1, en lugar de ser al inicio como la Transformada de Fourier.

4.2. ANÁLISIS DE COMPONENTES PRINCIPALES²

El Análisis de Componentes Principales es un procedimiento matemático que transforma un conjunto de variables correlacionadas en un conjunto menor de variables no correlacionadas llamadas componentes principales. Es útil realizarlo en diferentes circunstancias:

- Permite cribar datos, identificando grupos correlacionados, ayudando a determinar *outliers* y otras anomalías de muestreo.
- Permite ejecutar agrupamiento de variables compatibles entre sí, en subgrupos.

² Esta sección de capítulo se ha desarrollado con base en ROLDÁN Quintero, Raúl Eduardo. Problemas de Regresión: Soluciones por Modelos Estadísticos y Redes Neuronales Artificiales. Disertación doctoral para optar al título de *PhD in System Engineering*. Tecana American University, 2002. Algunos fragmentos se han adaptado parafraseándolos y algunos otros, tal como las fórmulas, han sido literalmente transcritos.

- Es un paso preliminar que puede ayudar en gran medida al momento de realizar análisis factorial.
- Cuando existe alta correlación entre las variables predictoras en un proceso de regresión, caso conocido como multicolinealidad de las variables, el análisis de componentes principales puede ayudar a determinar esta situación.

Dos son los objetivos fundamentales al realizar un análisis de esta índole:

- *Descubrir la verdadera dimensionalidad de los datos.* Aún cuando se disponga de p variables en un experimento dado, es importante determinar si la dimensión real es p o menor. En caso que sea menor, el problema de análisis de las variables puede ser simplificado a un número menor de variables subyacentes, que describen el comportamiento de todas las variables, sin perder información.
- *El análisis de componentes principales siempre implicará la creación de nuevas variables.* Pero estas variables han de ser entendidas en el contexto de proveer información adicional o pistas de agrupamiento de variables, más que la generación de nuevas variables significativas en sí mismas, caso que es el menos frecuente. La interpretación de las componentes principales no es necesariamente el objetivo primordial, y si se puede lograr tal interpretación, eso ha de ser considerado un caso excepcional.

El proceso de selección de componentes principales, en general, sigue los pasos que se indican a continuación:

- i. Las componentes principales no han de estar correlacionadas.
- ii. La primera componente principal debe explicar la variabilidad de los datos tanto como sea posible.
- iii. Cada componente principal subsiguiente debe tomar en cuenta tanta variabilidad en los datos como sea posible.

Para lograr la definición de las componentes principales hará falta acudir al álgebra lineal.

La primera componente principal se define por $y_1 = a_1'(x - \mu)$ en donde a_1 se elige de forma tal que la varianza de $a_1'(x - \mu)$ se maximice para todos los vectores a_1 que satisfagan $a_1' \cdot a_1 = 1$. Ese valor máximo de la varianza es el eigenvalor λ_1 más grande de Σ , el cual ocurre cuando a_1 es un eigenvector de Σ correspondiente con λ_1 y que satisface que $a_1' \cdot a_1 = 1$.

De manera análoga se identifican las siguientes componentes principales, siempre haciendo referencia a todas las combinaciones lineales del vector de variables restantes.

De esta forma $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ representan los eigenvalores ordenados de Σ , y a_1, a_2, \dots, a_p denotan los eigenvectores normalizados correspondientes de Σ . Ante estos principios se puede afirmar que:

- Dos componentes principales no están correlacionadas si y sólo si sus eigenvectores de definición son ortogonales entre sí.
- La varianza de la j -ésima componente es el j -ésimo eigenvalor ordenado.
- La traza de Σ , $tr(\Sigma) = \sigma_{11} + \sigma_{22} + \dots + \sigma_{pp}$. Mide la variación total de las variables originales.
- Por definición, $tr(\Sigma) = \lambda_1 + \lambda_2 + \dots + \lambda_p$, por lo que la variación total de las componentes principales explica en igual medida la variación total de las variables originales.

- En consecuencia a lo anterior, la relación $\frac{\lambda_j}{tr(\Sigma)}$ mide la proporción de variabilidad total en las variables originales que es explicada por la j-ésima componente principal.
- Sea x'_r el vector correspondiente a las variables medidas en la r-ésima unidad experimental. Entonces, la calificación de la j-ésima componente principal de la r-ésima unidad experimental será $y_{rj} = a'_j \cdot (x - \mu)$.
- Los valores de un eigenvector no pueden ser comparados con los de otro, dado que todos ellos son normalizados, y en consecuencia tienen una longitud de 1.
- Los valores necesarios de la matriz de varianzas y covarianzas, así como de la media, se toman de sus estimaciones muestrales.

Para seleccionar el número de componentes principales se puede utilizar el siguiente método: supóngase que se desea tomar en cuenta $\gamma \cdot 100\%$ de la variabilidad total de las variables originales y dígase que d es el número de componentes principales que se deben utilizar para lograr esa variabilidad.

Entonces, calcúlese $V = \frac{(\lambda_1 + \lambda_2 + \dots + \lambda_k)}{tr(\Sigma)}$, donde $k < p$, y d será el menor valor de k para el cual, por primera vez se sobrepase el valor de γ . Recuérdese que un 95% de variabilidad puede ser fácilmente alcanzable en datos de laboratorio, pero un 70% de variabilidad puede ser difícil de alcanzar si se trata con datos de personas. Además, mientras más componentes principales, menos útil es el análisis.

Hay un conjunto de observaciones que se debe agregar al estudio de componentes principales, según se indica a continuación:

- En primer lugar, el objeto del PCA no es eliminar variables, sino lograr un entendimiento de la verdadera dimensionalidad del experimento. Cuando

las variables originales están poco correlacionadas, no tiene mucho sentido aplicar este tipo de análisis y siempre las variables originales son necesarias para calificar o evaluar las componentes principales.

- Las variables que intervienen en el PCA deben estar medidas en las mismas unidades, o en el peor de los casos, comparables.
- Las variables que intervienen en el PCA deben tener una varianza en magnitudes muy semejantes.

Estas últimas dos condiciones es lo que se define como evaluar las variables “sobre un fundamento igual”. Si ello no ocurre, se aplica un PCA sobre la matriz de correlaciones R , lo cual asume que las variables están normalizadas. Los cálculos se realizan de manera análoga a la forma como se realizaron sobre la matriz de varianzas y covarianzas, con la única excepción que la calificación de las componentes principales se realiza sobre el vector de variables normalizado y no sobre el vector de variables original.

Para seleccionar la cantidad de componentes principales se aplican los mismos métodos descritos anteriormente. Además se puede usar uno adicional, que consiste en seleccionar los eigenvalores que sean mayores que 1. La razón de esto es que si un componente principal no puede explicar más variación que una variable por sí misma, entonces es probable que no sea importante. Nótese que esto aplica sólo cuando las variables están normalizadas, por lo que su varianza es 1.

Otro aspecto importante es determinar si efectivamente, en caso que los datos provengan de una distribución normal multivariada, las variables respuesta son independientes, es decir, no están correlacionadas. Esta prueba es importante puesto que si las variables no están correlacionadas no aplica un PCA. Tal situación ocurriría si $P = I$. Para probar esta hipótesis nula, se calcula el estadístico V , de alguna de las siguientes maneras:

- $V = |R|$
- $V = \lambda_1^* \cdot \lambda_2^* \cdots \lambda_p^*$, es decir, el producto de los eigenvalores de la matriz de correlación.
- $V = \frac{\lambda_1 \cdot \lambda_2 \cdots \lambda_p}{\sigma_{11} \cdot \sigma_{22} \cdots \sigma_{pp}}$, donde los lambda son los eigenvalores de la matriz de varianzas y covarianzas.

Para valores grandes de n (mayores que 25), se rechaza la hipótesis nula (es decir, se puede aplicar un PCA) si:

$$-a \cdot \log V > \chi_{\alpha, p(p-1)}^2 \quad \text{donde} \quad a = n - 1 - (2p + 5)/6$$

Si no se puede rechazar la hipótesis nula, no se debe aplicar un análisis de componentes principales.

4.3. REVISIÓN DEL ANÁLISIS DE COMPONENTES PRINCIPALES COMO MÉTODO DE DIAGNÓSTICO³

El Análisis de las Componentes Principales es una herramienta estadística aplicable a sistemas multivariados, que permite la transformación de los datos multivariados a un espacio de menor dimensión el cual retiene la información más relevante acerca del proceso. Esta compresión de información favorece el uso de esquemas de monitoreo de procesos multivariados mediante técnicas aplicadas a procesos univariados como gráficas de Control Estadístico de Procesos (SPC por

³ Esta sección de capítulo se ha desarrollado con base en MINA, J. y VERDE, C. Detección de Fallas usando Análisis de Componentes Principales. En: Congreso anual de la *Air Movement and Control Association* (AMCA). 2004. Algunos fragmentos se han adaptado parafraseándolos y algunos otros, tal como las fórmulas, han sido literalmente transcritos.

sus siglas en inglés). Así, una muestra actual del proceso se compara con las condiciones de operación normal resumidas en la gráfica de SPC, para detectar fallas en sensores y actuadores así como del proceso.

Las aplicaciones de PCA en el área de diagnóstico de fallas de procesos multivariados se inició a partir de los 90's. Entre otros resultados, [Lewin] además de realizar detección de fallas, propone un algoritmo de identificación de las causas de fallas futuras basado en PCA para fines de mantenimiento predictivo.

[Dunia] usa PCA para la reconstrucción de variables entre un conjunto de sensores correlacionados, además propone un indicador llamado *Sensor Validity Index* para determinar el estado de cada sensor. [Gómez] explota la relación que existe entre las propiedades de PCA y las ecuaciones de paridad para llevar a cabo la tarea de diagnóstico bajo el enfoque de redundancia analítica. PCA ha tenido gran aplicación en procesos químicos/bio-químicos como se muestra en [Ciappelloni] en el que propone un esquema de diagnóstico para una planta piloto SBR aeróbico en el tratamiento de aguas residuales.

Se propone explotar las propiedades de PCA directamente sobre un componente del proceso sin considerar su acoplamiento con otros. Se aborda el problema de detección de fallas bajo el enfoque de reconocimiento de patrón de señales, ya que en el caso de algunos componentes del proceso, como los dispositivos de campo, prácticamente no se tienen modelos matemáticos y relaciones de redundancia a partir de las cuales implementar esquemas de detección de fallas basados en modelo. El patrón de referencia se obtiene a partir de un mínimo adecuado de características en la respuesta al escalón del componente bajo monitoreo. Como caso de estudio se considera un sistema canónico de segundo orden cuyo coeficiente de amortiguamiento y frecuencia natural son inciertos.

4.3.1. Análisis de Componentes Principales

En los procesos industriales se dispone de un número considerable de variables asociadas ya sea al control, monitoreo o simplemente como indicadores del proceso, este tipo de procesos se conocen como multivariados, y es común que la mayoría de las variables se encuentren correlacionadas. Estas relaciones son útiles para llevar a cabo tareas de SPC, FDI, etc. Sin embargo, dado el número de variables disponibles, el volumen de datos puede ser demasiado para su análisis, por lo tanto, conviene una reducción de variables a un número tal que conserven la mayor variabilidad (información) de los datos originales.

PCA transforma el conjunto original de variables en un conjunto reducido de k -componentes principales, combinaciones lineales, que contienen la mayoría de la varianza del conjunto original. Así, dada una matriz de observaciones de $n \times m$, $X = [X_1 X_2 \dots X_m]$.

El procedimiento es el siguiente [Jackson]:

- i. Dado que las m -variables pueden tener rangos muy diferentes, es necesario que los datos sean estandarizados. resulta de la extracción de las medias en X , y resulta de la extracción de las medias y división por sus correspondientes desviaciones estándar.
- ii. Se obtiene la matriz de covarianza S de X .
- iii. Se calculan los m -valores propios de S y se ordenan decrecientemente: $\lambda_1, \lambda_2, \dots, \lambda_m$.
- iv. Se calculan los m -vectores propios de magnitud unitaria de S asociados a cada λ : V_1, V_2, \dots, V_m .
- v. Los m -vectores propios son ortonormales y constituyen una base para el espacio \mathbb{R}^m , por lo tanto, se puede definir una matriz de transformación de $m \times k$ (k -factores principales), $V_T = [V_1 V_2 \dots V_k]$ como base para un espacio reducido \mathbb{R}^k , donde $k \leq m$.

vi. Las k-componentes principales se obtienen de:

$$Y = V_T \text{ esto es } Y_{(j)} = v_{(j)1} x_1 + \dots + v_{(j)m} x_m, \text{ para } j = 1, 2, \dots, k$$

Cuando se trabaje con datos estandarizados, los pasos ii a vi se llevan a cabo a partir de la matriz de correlación R .

4.3.2. Extracción de Características en Señales Vía PCA

Existen componentes, como es el caso de los sensores y actuadores, en los que se tiene poca información, ya sea en forma de modelo analítico de señales medibles, necesaria para llevar a cabo tareas de FDI. Ante esto, se propone con un enfoque de análisis de señales, la extracción y selección, vía PCA, de un número adecuado de características de las señales en los dispositivos. La idea es que en una señal se pueden definir múltiples características que la describen, sin embargo, entre todas éstas, algunas guardan una muy débil correlación con respecto a los fenómenos que se desean estudiar, por lo que se pueden eliminar y retener sólo aquellas que están más fuertemente correlacionadas y que son más representativas del fenómeno.

Las características a definir dependen de la naturaleza de las señales a las que se puede tener acceso en un componente particular. En el caso de válvulas por ejemplo, es común considerar de la respuesta a escalón, las características de: tiempo muerto, tiempo de levantamiento, tiempo pico, sobre paso, tiempo de asentamiento, ganancia, etc., [Karpenko]. El conjunto de características extraídas en una señal constituyen las “múltiples variables” y sus valores están directamente relacionados con el tipo de falla y su magnitud. Se considera como caso de estudio un sistema canónico de segundo orden:

$$\frac{Y(s)}{X(s)} = \frac{\omega}{s^2 + 2\zeta\omega s + \omega^2}$$

Se asume que las variaciones normales de los parámetros son de: $0.27 \leq \zeta \leq 0.33$ y $3 \leq \omega_n \leq 4$.

Las características consideradas de la respuesta al escalón son: tiempo de levantamiento t_r , tiempo pico t_p , sobrepaso M_p y tiempo de asentamiento t_s , $X = [t_r \ t_p \ M_p \ t_s]$. Las características en X se extraen de las respuestas al escalón que resultan de 35 combinaciones para los valores de ζ y ω_n dentro del rango de variaciones normales.

4.3.3. Conclusión

Se muestra que PCA en el enfoque de reconocimiento de patrones es una herramienta atractiva para las tareas de diagnóstico. El marco multivariado necesario para aplicar PCA se resuelve a través de la extracción de múltiples características en una señal típica del componente bajo monitoreo. De los resultados obtenidos en el desarrollo de PCA es posible hacer una selección de las características más descriptivas de una señal. En una aplicación real, fuera de línea es posible mediante pruebas obtener el modelo de referencia, sin embargo, en la etapa de monitoreo que se lleva a cabo en línea, en algunos dispositivos las pruebas de respuesta al escalón se podrían llevar a cabo mediante pruebas específicas periódicas.

5. MÉTODOS DE PRONÓSTICO⁴

Las técnicas más comunes de pronóstico son de tres tipos: no formales, de promedio y de atenuación. Los métodos no formales se utilizan para desarrollar modelos sencillos que suponen que los últimos períodos son los que mejor pronostican el futuro. Los métodos de promedio se cumplen con base en el promedio de la ponderación de las mediciones. Los métodos de atenuación se basan en promedios de valores anteriores, dándole peso a la tendencia que se haya mantenido durante momentos anteriores en la medición.

Para la herramienta computacional, debido a la importancia de la tendencia en el diagnóstico técnico, se ha propuesto hacer uso de los métodos de atenuación ya que estos procuran realzar el valor de la historia para el pronóstico de los valores que se continúan en un conjunto de observaciones temporales. Cabe anotar que los anteriores programadores de la herramienta computacional, Botero y Betancur, han desarrollado el método de Brown, que es un método de atenuación exponencial simple, en su primer y segundo orden. Este proyecto de grado propone el método de Holt, atenuación exponencial ajustada a la tendencia, y el de Winter, atenuación exponencial ajustada a la tendencia y a la variación estacional. Dichas herramientas han sido programadas en MatLab® y se han llevado a una versión ejecutable, tal como fue uno de los objetivos del anteproyecto de este documento. No se ahondará en los métodos de atenuación exponencial simple debido a que son métodos ya programados en otros proyectos de grado y actividades de investigación.

⁴ Este capítulo se ha desarrollado con base en HANKE, John E. y REITSH, Arthur G. Pronósticos en los negocios. Quinta Edición. Prentice Hall Hispanoamericana. México. 1996. Algunos fragmentos se han adaptado parafraseándolos y algunos otros, tal como las fórmulas, han sido literalmente transcritos.

El Dr. Ing. Raúl Roldán en su tesis de disertación doctoral “Problemas de Regresión: Soluciones por Modelos Estadísticos y Redes Neuronales Artificiales” propone una orientación básica sobre el análisis estadístico de series de tiempo que aquí se muestran en los siguientes tres párrafos:

En los análisis de series de tiempo se buscan dos metas principales: la identificación de la naturaleza del fenómeno presentado por la secuencia de valores en el tiempo y la predicción de valores futuros con base en las observaciones disponibles. Consecuentemente esto requiere la identificación de patrones sobre los valores vistos en las series de tiempo y que al mismo tiempo puedan ser adecuadamente descritos.

Un análisis de series de tiempo sugiere que los datos siguen un patrón sistemático y que existe un ruido aleatorio que muchas veces hace que dicho patrón pueda ser difícil de reconocer. Por lo tanto, muchas técnicas de análisis de series acostumbran filtrar ese ruido aleatorio para identificar el patrón que se disimula en los datos observados de la serie.

Una serie de tiempo puede ser descrita en términos de dos componentes: tendencia y estacionalidad. Por tendencia se concibe el componente sistemático que implica un cambio en el tiempo y que no es repetitivo, por lo menos dentro de la muestra de datos observados. La estacionalidad se entiende como el patrón sistemático de repetición en el tiempo. Tendencia y estacionalidad pueden coexistir en datos reales. Por ejemplo, no es raro que el comercio muestre una tendencia ascendente en sus ventas y que al mismo tiempo muestre un patrón de estacionalidad entre agosto y diciembre, donde las ventas pueden incrementarse significativamente con respecto a las ventas logradas a lo largo del año; este patrón puede ser observado sistemáticamente año tras año.

5.1. MÉTODOS DE ATENUACIÓN EXPONENCIAL

Son utilizados estos métodos para revisar una estimación dándole relevancia a los últimos valores pero sin olvidar la historia que ha transcurrido en las mediciones. Se basa en la atenuación, promedio de los valores de una serie, haciéndolo de manera decreciente (exponencial): las mediciones se promedian, dándole más peso a las más recientes. Las ponderaciones se designan como α para la última medición, $\alpha (1 - \alpha)$ para la siguiente más reciente, $\alpha (1 - \alpha)^2$ para la que sigue y así sucesivamente.

De forma atenuada, se podría pensar en un nuevo pronóstico (para el período $t+1$), como el promedio ponderado de la nueva observación (en el período t) y el promedio anterior (para el período t). Se asigna la ponderación α al nuevo valor observado y $1 - \alpha$ al pronóstico anterior, suponiendo que $0 < \alpha < 1$. Así:

$$\text{nuevo pronóstico} = \alpha \times (\text{nueva observación}) + (1-\alpha) \times (\text{pronóstico anterior})$$

La ecuación de atenuación exponencial queda de la siguiente manera:

$$Y'_{t+1} = \alpha Y_t + (1 - \alpha) Y'_t \quad (5.1)$$

Se transcribe la ecuación 6.1 así:

$$Y'_{t+1} = Y'_t + \alpha (Y - Y'_t) \quad (5.2)$$

La atenuación exponencial es entonces el pronóstico anterior (Y'_t) más α veces el error ($Y - Y'_t$), en el pronóstico anterior.

El valor α es el factor de ponderación, éste determina el nivel hasta el cual la última observación puede influenciar el valor de pronóstico. Entre mayor sea α , que es un valor entre 0 y 1, mayor será el ajuste de cualquier error que haya

ocurrido en la última observación; entre más cercano esté α a 0, más se parece el pronóstico al valor de la última medición.

5.2. ATENUACIÓN EXPONENCIAL DOBLE

Esta técnica de atenuación, también conocida como Método de Brown, se usa para el pronóstico de observaciones temporales que tengan una marcada tendencia lineal. Los conceptos básicos de este método son muy cercanos a los de otra técnica llamada Promedios Móviles Dobles, que no será discutida en este documento.

El valor simple atenuado exponencialmente, A_t , se calcula así:

$$A_t = \alpha Y_t + (1 - \alpha) A_{t-1} \quad (5.3)$$

Esta ecuación se utiliza para calcular el valor doblemente atenuado exponencialmente:

$$A'_t = \alpha A_t + (1 - \alpha) A'_{t-1} \quad (5.4)$$

Para calcular la diferencia entre los valores atenuados exponencialmente:

$$a_t = 2A_t - A'_t \quad (5.5)$$

Existe un factor adicional de ajuste que es similar a la medición de una pendiente que puede cambiar durante la serie y se calcula de la siguiente manera:

$$b_t = \alpha / (1-\alpha) (A_t - A'_t) \quad (5.6)$$

Esta última ecuación para la atenuación exponencial doble es la utilizada para formular el pronóstico de p períodos en el futuro:

$$Y'_{t+p} = a_t + b_t p \quad (5.7)$$

5.3. MÉTODO DE HOLT: ATENUACIÓN EXPONENCIAL AJUSTADA A LA TENDENCIA

El método de dos parámetros de Holt es otro método muy utilizado frecuentemente para el manejo de una tendencia lineal. Dicho método atenúa en forma directa la tendencia y la pendiente empleando constantes de atenuación en cada una de ellas (β y α , correspondientemente). En el método de Brown solo se usa la constante de atenuación para la pendiente (α) y los valores estimados de la tendencia son muy sensibles a variaciones aleatorias; el método de Holt proporciona mayor flexibilidad debido a que se le pueden asignar las proporciones con las cuales se llevará la tendencia y la pendiente.

La serie exponencialmente atenuada se calcula así:

$$A_t = \alpha Y_t + (1 - \alpha) (A_{t-1} + T_{t-1}) \quad (5.8)$$

Del mismo modo la estimación de la tendencia:

$$T_t = \beta (A_t - A_{t-1}) + (1 - \beta) T_{t-1} \quad (5.9)$$

El pronóstico de p períodos en el futuro puede ser conocido:

$$Y'_{t+p} = A_t + pT_t \quad (5.10)$$

La ecuación 5.8 para la atenuación se parece a la ecuación 5.1 para una atenuación exponencial simple solo que ahora se le añade el valor del término para la tendencia (T_t). La estimación de la tendencia se calcula mediante la diferencia entre los valores sucesivos de atenuación exponencial ($A_t - A_{t-1}$), como estos valores se atenuaron buscando aleatoriedad, su diferencia se toma a manera de estimación de la tendencia de los datos.

Para la atenuación de la estimación de la tendencia se utiliza β como constante de atenuación. La ecuación 5.9 muestra que la diferencia correspondiente a la estimación de la tendencia ($A_t - A_{t-1}$) se multiplica por dicha constante de atenuación y luego se suma a la anterior estimación de la tendencia (T_t), multiplicada previamente por $(1 - \beta)$. Las ecuaciones 5.8 y 5.9 son bastante similares, solo que la última calcula la atenuación de la tendencia mientras que su anterior lo hace para los datos. El resultado de la ecuación 5.9 es una tendencia atenuada que excluye cualquier aleatoriedad.

La ecuación 5.10 se utiliza para dar un pronóstico de p períodos en el futuro. El número de períodos a pronosticar se multiplica por la estimación de la tendencia para luego sumar dicho producto al nivel actual de los datos reales, buscando eliminar aleatoriedad.

5.4. MÉTODO DE WINTER: ATENUACIÓN EXPONENCIAL AJUSTADA A LA TENDENCIA Y A LA VARIACIÓN ESTACIONAL

El modelo de atenuación exponencial y estacional de tres parámetros de Winter, que es una evolución del modelo de Holt, es muy acertado en la manera en la que minimiza el error en el pronóstico. Se utiliza en este procedimiento una ecuación adicional para determinar la estacionalidad de un conjunto de observaciones. Dicha estimación tiene un índice que se calcula con la ecuación 5.13, en cuya expresión existe un valor Y_t que se divide con A_t para señalar la razón en forma de índice en vez de hacerlo de manera absoluta, de tal manera que puede promediarse con el índice estacional atenuado al período $t - L$.

La serie exponencialmente atenuada se calcula así:

$$A_t = \alpha Y_t / S_{t-L} + (1 - \alpha) (A_{t-1} + T_{t-1}) \quad (5.11)$$

De igual manera la estimación de la tendencia:

$$T_t = \beta (A_t - A_{t-1}) + (1 - \beta) T_{t-1} \quad (5.12)$$

La estimación de la estacionalidad:

$$S_t = \gamma Y_t / A_t + (1 - \gamma) S_{t-L} \quad (5.13)$$

El pronóstico de p períodos en el futuro:

$$Y'_{t+p} = (A_t + pT_t) S_{t-L+p} \quad (5.14)$$

En cada iteración la ecuación 5.11 actualiza la serie atenuada. Existe una pequeña diferencia entre ésta y la ecuación 5.8: en la ecuación 5.11 Y_t se divide S_{t-L} , lo cual ajusta Y_t a la estacionalidad, eliminando entonces los efectos estacionales que pueden existir en el dato original de observación.

Luego de la estimación de la estacionalidad y la tendencia en las ecuaciones 5.12 y 5.13, se obtiene un pronóstico con la ecuación 5.14; siendo ésta última la misma empleada en el método de Holt con la ecuación 5.10, solo que se diferencian en que la utilizada para el método Winter, buscando la estimación para un período futuro $t + p$, se multiplica por S_{t-L+p} . Este valor estacional es el último disponible, por lo cual es el que se utiliza para ajustar el pronóstico a la estacionalidad.

Para la comparación entre los métodos de Brown y sus evoluciones: Holt y Winter, se utiliza la medición de los errores para su comparación, siendo el método de los Mínimos Cuadrados el escogido para conocer el nivel de error que aporta cada uno de los modelos. Normalmente los últimos dos métodos son los que menos nivel de error entregan al realizarse los pronósticos, ya que el ajuste en los datos, en la tendencia y en la estacionalidad, este último solo para Winter, van ajustando los datos de pronóstico que son los que finalmente interesan al usuario de estos métodos. En la herramienta computacional se han implementado estos métodos,

dándole así cumplimiento a uno de los objetivos más importantes trazados en este proyecto de grado.

CONCLUSIONES Y RECOMENDACIONES

La herramienta computacional desarrollada por GEMI, a través de este proyecto, ha sido modificada a una versión más amigable con el usuario, que normalmente no está interesado en conocer todos los detalles de fondo del sistema sino que busca conocer cuales partes de su sistema son las que están más cerca del fallo.

El incluir la estructura modular y por pasos al sistema le permite al usuario un acercamiento muy básico de la herramienta de modo que, sin importar el nivel de experticia de éste en el manejo de estos sistemas o de la misma técnica de mantenimiento, puede navegar a través del software y conocer el estado de la máquina.

Gracias a la estandarización de la herramienta computacional se ha logrado que, en futuras versiones de la herramienta, se pueda modificar cualquiera de sus módulos o rutinas sin posibilitar la afectación del resto del programa.

El SVD y el PCA son herramientas que permiten la reducción de matrices de datos en un ambiente multivariante. Con ambas es posible trabajar por separado pero, tal como lo propone la filosofía MMC, aplicar a una matriz el PCA para luego hacerlo con el SVD le permite al diagnóstico técnico la posibilidad de concentrarse en las variables que más afectan la máquina y la pueden llevar a la falla, asunto central de la gestión del mantenimiento.

El PCA es una herramienta muy útil para la reducción de matrices de datos. Uno de sus pocos problemas se reduce a la no posibilidad de utilización cuando los datos contenidos no tienen un nivel importante de reciprocidad en sus matrices de varianza y covarianza. Teniendo en cuenta esta premisa se puede proponer el uso

del PCA como método de diagnóstico técnico debido a que en los sistemas técnicos y en matrices como la de Observación de Síntomas, SOM en la filosofía MMC, las variables medidas son los síntomas de falla y están ampliamente relacionadas entre sí. A pesar de esto se recomienda continuar con la aplicación del SVD posterior a la del PCA para poder lograr una eliminación de variables que no enriquecen el diagnóstico técnico y se convierten en ruido comparadas con el peso que pueden presentar otras.

El uso de los métodos de Holt (atenuación exponencial ajustada a la tendencia) y de Winter (atenuación exponencial ajustada a la tendencia y a la variación estacional) permite que el modelo de predicción para la probabilidad de falla sea mucho más eficiente y le permita al usuario de la herramienta computacional lograr predicciones más reales, posibilitando una mayor detección de fallo y evitando mantenimientos programados innecesarios.

La creación de la versión ejecutable le permite a GEMI poderla ofrecer como producto de la investigación a los usuarios de ésta, evitando que la pueda modificar y con la ventaja de que el usuario no tiene que tener instalado MatLab® ni pagar algún valor, ya que el programa es Royalty-Free, característica que ofrece MatLab® Compiler. El usuario solo debe instalar el archivo ejecutable (*.exe) que se le entregue en un CD. Se recomienda el desarrollo de un documento legal que exima a GEMI por el mal uso que del software pueda hacer el usuario o por los daños que pueda causar por el desconocimiento que pueda tener de éste el beneficiario.

BIBLIOGRAFÍA

ABRIL Fernández, Iván Leonardo. Sistema de diagnóstico para vías férreas utilizando modelos matemáticos. Medellín, 2007. Tesis presentada como requisito para optar al título en Maestría en Ingeniería Mecánica. Universidad EAFIT. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

AREVALO Hurtado, Ángela María. Verificación experimental de la metodología de diagnóstico técnico multidimensional basada en el SVD. Proyecto de grado para optar al título de Ingeniero Mecánico. Universidad EAFIT, 2007. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

BETANCUR Giraldo, Germán René. Monitoreo multidimensional para el mantenimiento de la interfase vía-vehículo de sistemas ferroviarios. Medellín, 2007. Tesis presentada como requisito para optar al título en Maestría en Ingeniería Mecánica. Universidad EAFIT. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

BETANCUR Giraldo, Germán René. Investigación para el diagnóstico técnico de una turbina Francis en la minicentral hidroeléctrica La Herradura, bajo una aproximación holística – Difranci. Informe del proyecto: “Monitoreo multidimensional de la condición aplicado a la minicentral La Herradura”. Agosto de 2008. Grupo de Estudios en Mantenimiento Industrial (GEMI), Universidad EAFIT. Medellín, Colombia.

BOTERO Herrera, Francisco Javier. Desarrollo de un modelo predictivo computacional para el diagnóstico de la condición de bombas centrífugas. Medellín, 2005. Tesis presentada como requisito para optar al título en Maestría

en Ingeniería Mecánica. Universidad EAFIT. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

CEMPEL, C., TABASZEWSKI, M. y KRAKOWIAK, M. Extraction Methods of Multi-Fault Information in Machine Condition Monitoring. Key Engineering Materials. Vol. 245-246. 2003. Páginas 215-222.

CLAVIJO Méndez, Jairo A. Análisis de componentes principales – ACP. Ibagué: Universidad del Tolima, 2007, 20 p. [en línea]. Disponible en internet: <http://www.monografias.com/trabajos15/analisis-acp/analisis-acp.shtml>. Consulta: Enero de 2009.

DONELLAN, Paul. Condition monitoring of cooling tower fan gearboxes. Condition monitoring: engineering the practice. 2002.

GUERRERO Bahamón, Ricardo Andrés. Desarrollo de un procesador computacional de señales aplicado al diagnóstico técnico. Proyecto de grado para optar al título de Ingeniero Mecánico. Universidad EAFIT, 2005. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

HANKE, John E. y REITSH, Arthur G. Pronósticos en los negocios. Quinta Edición. Prentice Hall Hispanoamericana. México. 1996.

HOLT, C. C. Forecasting seasonal and trends by exponentially weighted moving averages. Office of Naval Research, Memorandum #52, 1957.

HUGHES, T.R. *et al.* Functional discovery via a compendium of expression profiles. Cell, N° 26. Julio de 2000. Páginas 102-109.

JARDINE, Andrew K.S., LIN Daming y BANJEVIC Dragan. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, vol. 20, N° 7. Octubre de 2006. Páginas 1483-1510. Ed. Elsevier.

MINA, J. y VERDE, C. Detección de Fallas usando Análisis de Componentes Principales. En: Congreso anual de la *Air Movement and Control Association* (AMCA). 2004.

MORA Gutiérrez, Luis Alberto. Mantenimiento estratégico empresarial: enfoque sistémico kantiano. Fondo Editorial Universidad EAFIT. Medellín, Colombia: Mayo de 2007. 406 p.

MURSHUDOV, Garib Novruz. Notas de Clase: Topics in data analysis, Lecture 11: Principal Component Analysis. 2004. York Structural Biology Laboratory, The University of York. Heslington, York, England. [en línea]. Disponible en internet: http://www.ytbl.york.ac.uk/~garib/mres_course/2004/. Consulta: Enero de 2009.

NEALE, Michael y GEE, Mark. A guide to wear problems and testing for industry. Elsevier, 157 páginas, 2001.

OCAMPO, J. Emilio; CASTAÑEDA, Leonel F.; BETANCUR, Germán R. y BERRIO, Carlos A. Diagnóstico Técnico de una turbina hidráulica tipo Francis bajo una aproximación holística. En: X Congreso Internacional de Mantenimiento (10°: 2008, Bogotá). Exposición industrial de productos y servicios de mantenimiento, Memorias. Bogotá: Asociación Colombiana de Ingenieros ACIEM, 2008.

ORTIZ Calvo, Juan Sebastian. Modelo regresivo de diagnóstico técnico para la interfase vía-vehículo de un sistema ferroviario. Proyecto de grado para optar al

título de Ingeniero Mecánico. Universidad EAFIT, 2005. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

PORTALA Contreras, Alexander. El método de descomposición SVD en el diagnóstico técnico. Proyecto de grado para optar al título de Ingeniero Mecánico. Universidad EAFIT, 2004. Escuela de Ingeniería. Departamento de Ingeniería Mecánica.

ROLDÁN Quintero, Raúl Eduardo. Problemas de Regresión: Soluciones por Modelos Estadísticos y Redes Neuronales Artificiales. Disertación doctoral para optar al título de *PhD in System Engineering*. Tecana American University, 2002.

WALL, Michael E.; RECHTSTEINER, Andreas y ROCHA, Luis M. Singular value decomposition and principal component analysis. A Practical Approach to Microarray Data Analysis. Kluwer: Norwell, 2003. Páginas 91-109.

WINTERS, P.R. Forecasting sales by exponentially weighted moving averages. *Management Science* 6. 1960. Páginas 324-342.

ZOLTOWSKI, Bogdan; CASTAÑEDA Heredia, Leonel Francisco y BETANCUR Giraldo, Germán René. Monitoreo Multidimensional de la Condición (MMC) basado en la descomposición en valores singulares (SVD), Caso de estudio: Sistema Ferroviario. *Revista Universidad EAFIT*, vol. 43, N° 147, julio, agosto, septiembre 2007. Medellín, Colombia. Pg. 81-94.

ZOLTOWSKI, Bogdan; CASTAÑEDA, Leonel F. y BETANCUR, Germán R. Monitoreo Multidimensional de la Interfase Vía-Vehículo de un Sistema Ferroviario. En: IX Congreso Internacional de Mantenimiento (9°: 2007, Bogotá). Lecciones aprendidas en la aplicación del mantenimiento, Memorias. Bogotá: Asociación Colombiana de Ingenieros ACIEM, 2007.

ANEXOS

ANEXO A. LISTA DE RUTINAS EN VERSIÓN MATLAB® DE PROGRAMACIÓN

Las rutinas seguidas en MatLab® son las que a continuación se enlistan. La rutina que empieza con todo el programa es MMC.m.

Acerca de.jpg	INPUT.m
AcercaDeMMC.fig	Manual de Usuario.doc
AcercaDeMMC.m	Manual de Usuario.pdf
AnalisisGlobal.m	MMC.fig
BROWN1.m	MMC.m
BROWN2.m	MMC.prj
BuscarDistribucion.m	MostrarLista.fig
Configuracion.mat	MostrarLista.m
DistribucionProbabilidad.m	my_alpha1.m
Ejemplo.xls	my_alpha2.m
Fondo.jpg	PDFfill.m
GraficarDistribucion.m	plot_bar.m
GraficarSerie.m	Pronostico.m
HOLT.m	WINTERS.m
INPUT.fig	

ANEXO B. CÓDIGOS DE LAS RUTINAS DE MATLAB® DE LOS MÉTODOS PREDICTIVOS PROPUESTOS

Se anexan los códigos de los métodos para predicción propuestos por el autor de este proyecto de grado. Están diseñados los programas en lenguaje MatLab®.

MÉTODO HOLT:

```
% =====  
% FUNCIÓN  
% [Result] = HOLT(X,Y,Ylim,periods)  
% =====  
% Programado por:      Walter Pérez Villa - wperezvi@eafit.edu.co  
% Dentro del proyecto: Mejoramiento de herramienta computacional para  
%                      el diagnóstico técnico a través del monitoreo  
%                      multidimensional de la condición  
%                      Mayo de 2009  
% =====  
% Estos códigos están basados en Brown 1 y 2 realizados por Francisco  
% Javier Botero (fboteroh@eafit.edu.co) en julio de 2005 y modificados  
% por German René Betancur Giraldo (gbetanc4@eafit.edu.co) en septiembre  
% de 2006  
% =====  
% ENTRADAS  
% X      : Vector de valores de la abscisa (tiempo).  
% Y      : Vector de valores de la ordenada (valor del  
%          síntoma).  
% Ylim: Valor límite del síntoma.  
% periods : Número de periodos de tiempo futuros.  
% =====  
% SALIDAS  
% Result: Resultados  
% Result.actual   : valores actuales de la serie.  
% Result.forecast : valores pronosticados de la serie.  
% Result.error    : error (diferencia) entre el valor actual y  
%                  pronosticado  
% Result.a        : Parámetro de la regresión.  
% Result.b1       : Parámetro de la regresión.  
% =====  
  
function [Result] = HOLT(X,Y,Ylim,periods)
```

```

% Determinar la longitud de los vectores de entrada.
n = length(X);
m = length(Y);
if n ~= m
    disp('Las longitudes de los vectores deben ser iguales')
else

    % Determinación del alpha óptimo
    [alpha_opt Result] = my_alpha1(X,Y,periods,n,n);

    % Se toma el alpha óptimo calculado teniendo en cuenta el error SSE
    alpha = alpha_opt(1);
    alpha_opt = alpha_opt(1);

    % Se propone una conservadora constante de atenuación de la
    % estimación de la tendencia
    beta = 0.5;

    Y1(1:2)=Y(1);
    A=Y(1);
    T=0;

    for i=2:n
        A(i)=alpha*Y(i)+(1-alpha)*(A(i-1)-T(i-1));
        T(i)=(beta)*(A(i)-A(i-1))+(1-beta)*T(i-1);
        if i<n
            Y1(i+1)=A(i)+T(i);
        else
            Y1(i+1)=A(i)+periods*T(i);
        end
    end

    Y1=Y1';
    T=periods;
    error=sqrt(sum((Y-Y1(1:end-1)).^2));

    % Determinación de los intervalos de confianza, con base en:
    % BOWERMAN, Bruce L. and O'CONNELL, Richard T. Forecasting and time
    % series: an applied approach. Duxbury Press, Third edition. Miami,
    % 1993. Chapter 8. ISBN 0-534-93251-7.

% Determinación del error absoluto medio MAE
for j=1:n
    e(j) = abs(Y(j) - Y1(j));
    DT    = cumsum(e)/X(j);
end

% Determinación de la constante dt.
a = alpha_opt;
v = 1-a;

```

```

dt =
1.25*sqrt((1+((a/(1+v)^3)*((1+4*v+5*v^2)+2*a*(1+3*v)*T+2*a^2*T^2)))/...
        (1+(a/(1+v)^3)*((1+4*v+5*v^2)+2*a*(1+3*v)+2*a^2)));

% Determinación del coeficiente de confianza, con base en:
% HANKE, Jhon E. and REITSH, Arthur G. Pronósticos en los negocios.
% Editorial Prentice Hall Hispanoamericana, Quinta edición. Mexico,
% 1996. Pág. 211-212. ISBN 0-205-16005-0.

if n >= 30
% Si el número de muestra es mayor a 30 se utiliza la
% distribución
% Normal, para intervalos de confianza del 95% y 90%.
z1 = abs(norminv(0.05/2,0,1));
z2 = abs(norminv(0.01/2,0,1));
else
% Si el número de muestra es menor a 30 se utiliza la
% distribución
% de Student (t), para intervalos de confianza del 95% y 90%.
z1 = abs(tinv(0.05/2,n-2));
z2 = abs(tinv(0.01/2,n-2));
end

% Determinación de los radios de confianza.
for k = 1:n
r1.sup(k) = Y1(k+1)+z1*dt*DT(k);
r1.inf(k) = Y1(k+1)-z1*dt*DT(k);
r2.sup(k) = Y1(k+1)+z2*dt*DT(k);
r2.inf(k) = Y1(k+1)-z2*dt*DT(k);
end

% Determinar el cruce de los intervalos de confianza con el valor
% límite, basado en: TYLICKI, Henryk. Optymalizacja procesu
% prognozowania stanu technicznego pojazdów mechanicznych. AKADEMIA
% TECHNICZNO - ROLNICZA BYDGOSZCZ, Bydgoszcz 1997.
%
% if Y(end) > Ylim
%
% X1 = X(end) + ((Y1(end-1)-(r1.sup(end)-
% Y1(end)))*T)/(Y1(end-1)-Y1(end));
%
% X2 = X(end) + ((Y1(end-1)-(r2.sup(end)-
% Y1(end)))*T)/(Y1(end-1)-Y1(end));
%
% else
%
% X1 = X(end) + ((Ylim-(r1.sup(end)-
% Y1(end)))*T)/(Y1(end)-Y1(end-1));
%
% X2 = X(end) + ((Ylim-(r2.sup(end)-
% Y1(end)))*T)/(Y1(end)-Y1(end-1));
%
% end

% Propuesta para determinar el próximo término de diagnóstico
if Y(end) > Ylim
X1 = X(end) + ((Y1(end-1)-(r1.sup(end)-Y1(end))-Ylim)*T)/(Y1(end-
1)-Y1(end));

```

```

        X2 = X(end) + ((Y1(end-1)-(r2.sup(end)-Y1(end))-Ylim)*T)/(Y1(end-1)-Y1(end));
    else
        X11 = X(end) + ((Ylim-(r1.sup(end)-Y1(end))-Y1(end))*T)/(Y1(end)-Y1(end-1));
        X12 = X(end) + ((Ylim-(r1.sup(end)-Y1(end))-Y1(end-1))*T)/(Y1(end)-Y(end));
        X21 = X(end) + ((Ylim-(r2.sup(end)-Y1(end))-Y1(end))*T)/(Y1(end)-Y1(end-1));
        X22 = X(end) + ((Ylim-(r2.sup(end)-Y1(end))-Y1(end-1))*T)/(Y1(end)-Y(end));
        X1 = max([X11,X12]);
        X2 = max([X21,X22]);
    end

    Result.actual      = Y;
    Result.forecast    = Y1;
    Result.cuad_error  = error;
    Result.error       = Y - Y1(1:end-1);
    Result.error1      = (1/n)*sum(Result.error);
    Result.error2      = (1/n)*sum(abs(Result.error));
    Result.error3      = (1/n)*sum(Result.error.^2);
    Result.error4      = (1/((1/n)*sum(Y.^2)))*(Result.error3);
    Result.error5      = sum(Result.error.^2)/sum(Y.^2);
    Result.a           = A;
    Result.b           = T;
    Result.r1          = r1;
    Result.r2          = r2;
    X(end+1)          = X(end)+periods;
    Result.X           = X;
    Result.X1          = X1;
    Result.X2          = X2;

```

```
end
```

MÉTODO DE WINTERS:

```
% =====  
% FUNCIÓN  
% [Result] = WINTERS(X,Y,Ylim,periods)  
% =====  
% Programado por:      Walter Pérez Villa - wperezvi@eafit.edu.co  
% Dentro del proyecto: Mejoramiento de herramienta computacional para  
%                      el diagnóstico técnico a través del monitoreo  
%                      multidimensional de la condición  
%                      Mayo de 2009  
% =====  
% Estos códigos están basados en Brown 1 y 2 realizados por Francisco  
% Javier Botero (fboteroh@eafit.edu.co) en julio de 2005 y modificados  
% por German René Betancur Giraldo (gbetanc4@eafit.edu.co) en septiembre  
% de 2006  
% =====  
% ENTRADAS  
% X      : Vector de valores de la abscisa (tiempo).  
% Y      : Vector de valores de la ordenada (valor del  
%          síntoma).  
% Ylim: Valor límite del síntoma.  
% periods: Número de periodos de tiempo futuros.  
% =====  
% SALIDAS  
% Result: Resultados  
% Result.actual   : valores actuales de la serie.  
% Result.forecast : valores pronosticados de la serie.  
% Result.error    : error (diferencia) entre el valor actual y  
%                  pronosticado  
% Result.a        : Parámetro de la regresión.  
% Result.b1       : Parámetro de la regresión.  
% =====  
  
function [Result] = WINTERS(X,Y,Ylim,periods)  
  
% Determinar la longitud de los vectores de entrada.  
n = length(X);  
m = length(Y);  
if n ~= m  
    disp('Las longitudes de los vectores deben ser iguales')  
else  
  
    % Determinación del alpha óptimo  
    [alpha_opt Result] = my_alphal(X,Y,periods,n,m);  
  
    % Se toma el alpha óptimo calculado teniendo en cuenta el error SSE  
    alpha = alpha_opt(1);  
    alpha_opt = alpha_opt(1);  
  
    % Se propone una conservadora constante de atenuación de la  
    % estimación de la tendencia
```

```

beta = 0.5;

% Se propone una conservadora constante de atenuación de la
% estimación de la estacionalidad
gamma = 0.5;

Y1(1:2) = Y(1);
A = Y(1);
T = 0;
S = 1;
L = 4;

for i = 2:n
    if i <= L
        A(i) = alpha*Y(i)+(1-alpha)*(A(i-1)-T(i-1));
        T(i) = (beta)*(A(i)-A(i-1))+(1-beta)*T(i-1);
        S(i) = gamma*Y(i)/A(i)+(1-gamma);
        if i < n
            Y1(i+1) = A(i)+T(i);
        else
            Y1(i+1) = A(i)+periods*T(i);
        end
    else
        A(i) = alpha*Y(i)/S(i-L)+(1-alpha)*(A(i-1)-T(i-1));
        T(i) = (beta)*(A(i)-A(i-1))+(1-beta)*T(i-1);
        S(i) = gamma*Y(i)/A(i)+(1-gamma)*S(i-L);
        if i < n
            Y1(i+1) = (A(i)+T(i))*S(i-L);
        else
            Y1(i+1) = (A(i)+periods*T(i))*S(i-L);
        end
    end
end

Y1 = Y1';
T = periods;
error = sqrt(sum((Y-Y1(1:end-1)).^2));

% Determinación de los intervalos de confianza, con base en:
% BOWERMAN, Bruce L. and O'CONNELL, Richard T. Forecasting and time
% series: an applied approach. Duxbury Press, Third edition. Miami,
% 1993. Chapter 8. ISBN 0-534-93251-7.

% Determinación del error absoluto medio MAE
for j = 1:n
    e(j) = abs(Y(j) - Y1(j));
    DT = cumsum(e)/X(j);
end

% Determinación de la constante dt.
a = alpha_opt;
v = 1-a;

```

```

dt =
1.25*sqrt((1+((a/(1+v)^3)*((1+4*v+5*v^2)+2*a*(1+3*v)*T+2*a^2*T^2)))/...
        (1+(a/(1+v)^3)*((1+4*v+5*v^2)+2*a*(1+3*v)+2*a^2)));

% Determinación del coeficiente de confianza, con base en:
% HANKE, Jhon E. and REITSH, Arthur G. Pronósticos en los negocios.
% Editorial Prentice Hall Hispanoamericana, Quinta edición. Mexico,
% 1996. Pág. 211-212. ISBN 0-205-16005-0.

if n >= 30
% Si el número de muestra es mayor a 30 se utiliza la
% distribución
% Normal, para intervalos de confianza del 95% y 90%.
z1 = abs(norminv(0.05/2,0,1));
z2 = abs(norminv(0.01/2,0,1));
else
% Si el número de muestra es menor a 30 se utiliza la
% distribución
% de Student (t), para intervalos de confianza del 95% y 90%.
z1 = abs(tinv(0.05/2,n-2));
z2 = abs(tinv(0.01/2,n-2));
end

% Determinación de los radios de confianza.
for k = 1:n
r1.sup(k) = Y1(k+1)+z1*dt*DT(k);
r1.inf(k) = Y1(k+1)-z1*dt*DT(k);
r2.sup(k) = Y1(k+1)+z2*dt*DT(k);
r2.inf(k) = Y1(k+1)-z2*dt*DT(k);
end

% Determinar el cruce de los intervalos de confianza con el valor
% límite, basado en: TYLICKI, Henryk. Optymalizacja procesu
% prognozowania stanu technicznego pojazdów mechanicznych. AKADEMIA
% TECHNICZNO - ROLNICZA BYDGOSZCZ, Bydgoszcz 1997.
if Y(end) > Ylim
%
% X1 = X(end) + ((Y1(end-1)-(r1.sup(end)-
% Y1(end)))*T)/(Y1(end-1)-Y1(end));
%
% X2 = X(end) + ((Y1(end-1)-(r2.sup(end)-
% Y1(end)))*T)/(Y1(end-1)-Y1(end));
%
% else
%
% X1 = X(end) + ((Ylim-(r1.sup(end)-
% Y1(end)))*T)/(Y1(end)-Y1(end-1));
%
% X2 = X(end) + ((Ylim-(r2.sup(end)-
% Y1(end)))*T)/(Y1(end)-Y1(end-1));
%
% end

% Propuesta para determinar el próximo término de diagnóstico
if Y(end) > Ylim
X1 = X(end) + ((Y1(end-1)-(r1.sup(end)-Y1(end))-Ylim)*T)/(Y1(end-
1)-Y1(end));
X2 = X(end) + ((Y1(end-1)-(r2.sup(end)-Y1(end))-Ylim)*T)/(Y1(end-
1)-Y1(end));

```

```

else
    X11 = X(end) + ((Ylim-(r1.sup(end)-Y1(end))-Y1(end))*T)/(Y1(end)-
Y1(end-1));
    X12 = X(end) + ((Ylim-(r1.sup(end)-Y1(end))-Y1(end-
1))*T)/(Y1(end)-Y(end));
    X21 = X(end) + ((Ylim-(r2.sup(end)-Y1(end))-Y1(end))*T)/(Y1(end)-
Y1(end-1));
    X22 = X(end) + ((Ylim-(r2.sup(end)-Y1(end))-Y1(end-
1))*T)/(Y1(end)-Y(end));
    X1 = max([X11,X12]);
    X2 = max([X21,X22]);
end

Result.actual      = Y;
Result.forecast    = Y1;
Result.cuad_error  = error;
Result.error       = Y - Y1(1:end-1);
Result.error1     = (1/n)*sum(Result.error);
Result.error2     = (1/n)*sum(abs(Result.error));
Result.error3     = (1/n)*sum(Result.error.^2);
Result.error4     = (1/((1/n)*sum(Y.^2)))*(Result.error3);
Result.error5     = sum(Result.error.^2)/sum(Y.^2);
Result.a          = A;
Result.b          = T;
Result.r1         = r1;
Result.r2         = r2;
X(end+1)         = X(end)+periods;
Result.X          = X;
Result.X1         = X1;
Result.X2         = X2;

end

```

ANEXO C. PROCEDIMIENTO PARA LA CREACIÓN DE UNA VERSIÓN EJECUTABLE

Se anexa una versión sencilla de cómo se crea una versión ejecutable de un programa en MatLab®. La versión completa de este manual se encuentra disponible en línea en:

<http://www.mathworks.com/access/helpdesk/help/toolbox/compiler/index.html>

Magic Square Example

This example shows you how to:

- Access the examples provided with MATLAB® Compiler.
- Use MATLAB® Compiler to create and package a simple standalone application.

The examples for MATLAB® Compiler are in *MatLab® root\extern\examples\compiler*. For *MatLab® root*, substitute the MATLAB® root directory on your system. Type MatLab® root to see this directory name. The Magic Square example shows you how to create and package a simple application that compiles an M-file, *magicsquare.m*.

magicsquare.m

```
function m = magicsquare(n)
%MAGICSQUARE generates a magic square matrix of the size specified
% by the input parameter n.
% Copyright 2003-2007 The MathWorks, Inc.
if ischar(n)
n=str2num(n);
end
m = magic(n)
```

1 Create a subdirectory in your work directory and name it MagicExample. This procedure assumes that your work directory is D:\Work.

2 Copy the following file to MagicExample: *MatLab® root\extern\examples\compiler\magicsquare.m*

3 At the MATLAB® command prompt, change directory to D:\Work\MagicExample.

4 While in MATLAB®, type *deploytool* to open the Deployment Tool window. The Deployment Tool opens as a dockable window in the MATLAB® desktop, and a menu labeled **Project** is added to the MATLAB® menu bar.

5 Create a new project:

a In the Deployment Tool toolbar, click the New Project icon. As an alternative, you can select **File > New Deployment Project** in the MATLAB® menu bar.

b In the New Deployment Project dialog box, select **Standalone Applications**, and enter the following settings:

- In the **Name** field, enter MagicExample.prj as the project name.
- In the **Location** field, enter the name of your work directory followed by the project name. In this example, that is D:\Work\MagicExample.

c Click **OK**.

MATLAB® Compiler displays the project folder (MagicExample.prj) in the Deployment Tool window. The folder contains three folders, which are empty.

d Drag the magicsquare.m file from the Current Directory browser in MATLAB® to the project folder in the Deployment Tool window.

MATLAB® Compiler adds the M-file to the **Main function** folder.

6 Build the application as follows:

- In the Deployment Tool toolbar, click the Build Project icon.
- As an alternative, you can select **Tools > Build** in the MATLAB® menu bar.

The build process begins, and a log of the build appears in the **Deployment Tool Output** pane. The status of the process is displayed in the status bar at the bottom of the output pane. The **Deployment Tool Output** pane is dockable; by default it appears across the bottom of the MATLAB® desktop.

MATLAB® Compiler puts the files that are needed for the application in two newly created subdirectories, src and distrib, in the MagicExample directory. A copy of the build log is placed in the src directory.

Tip When your source code has been compiled successfully, a file named readme.txt is written to the src directory. Use this file as a guide to the system requirements and other prerequisites you must satisfy to deploy your first component on a target computer.

7 Package the application so it can run on machines that do not have MATLAB® installed. The **Include MATLAB® Compiler™ Runtime (MCR)** option is selected (in the **Packaging** pane of Project Settings) by

default. Clear the option if you do not want to include the MCR in your package.

- In the Deployment Tool toolbar, click the Package Project button.
- As an alternative, you can select **Tools > Package** in the MATLAB® menu bar.

MATLAB® Compiler creates a package in the distrib subdirectory. On Windows, the package is a self-extracting executable, and on platforms other than Windows, it is a .zip file.

8 Deploy the application to end users as described in “Deploying to End Users”.

ANEXO D. MANUAL DE USUARIO PARA INSTALACIÓN Y EJECUCIÓN DE LA HERRAMIENTA COMPUTACIONAL

Este manual presenta los pasos necesarios para aplicar la metodología de Monitoreo Multidimensional de la Condición (MMC), la cual permite evaluar la condición del estado técnico de un equipo desde una visión holística del sistema que tiene como fin último el recomendar la intervención del equipo.

INSTALACIÓN

El proceso de instalación se compone de dos etapas, la primera consiste en la instalación como tal del programa MMC y la segunda en la instalación del programa MCR (*Matlab Component Runtime*), necesario para la ejecución del programa MMC – DIFRANCI.

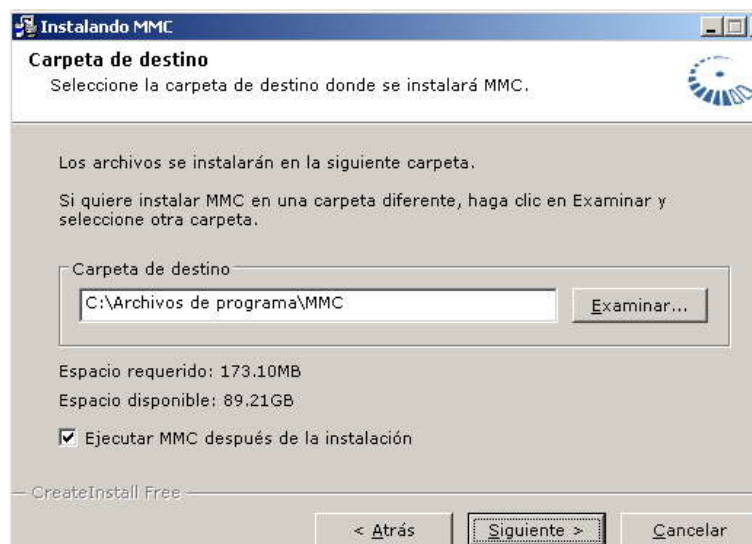
Para iniciar la instalación del software MMC se debe hacer doble clic en el icono *setup*.



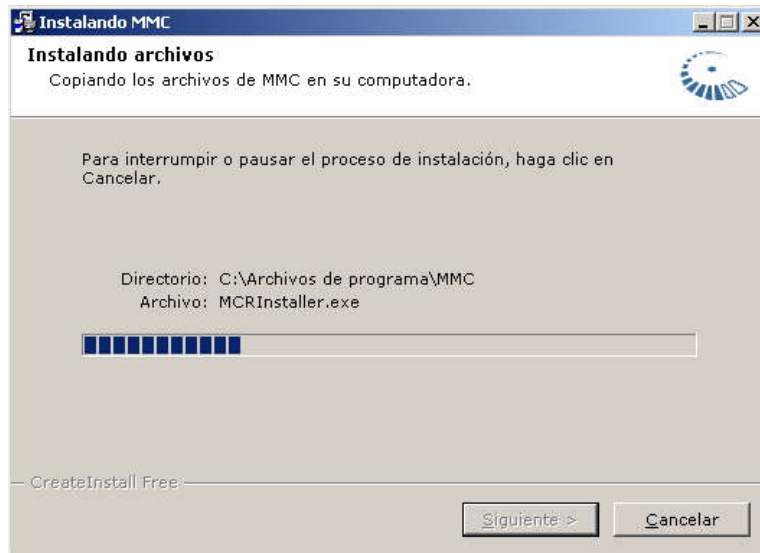
Se genera una ventana de bienvenida, donde se debe seleccionar la opción *Siguiente >*.



Se debe seleccionar la carpeta de destino del software, por defecto este se ubicará en *C:\Archivos de programa\MMC*, si se desea instalar en otro destino, se debe seleccionar la opción *Examinar...*, en ambos casos se debe verificar que el espacio requerido esté disponible en la unidad seleccionada. Para continuar el proceso de instalación se selecciona la opción *Siguiente >*.



Los archivos necesarios para la ejecución del programa son guardados en el destino especificado anteriormente, este proceso es seguido en la siguiente pantalla.



Una vez los archivos están copiados en la ubicación de destino se presenta una ventana de información donde se informa que la instalación ha sido exitosa, para culminar el proceso de instalación se debe seleccionar la opción *Finalizar*.

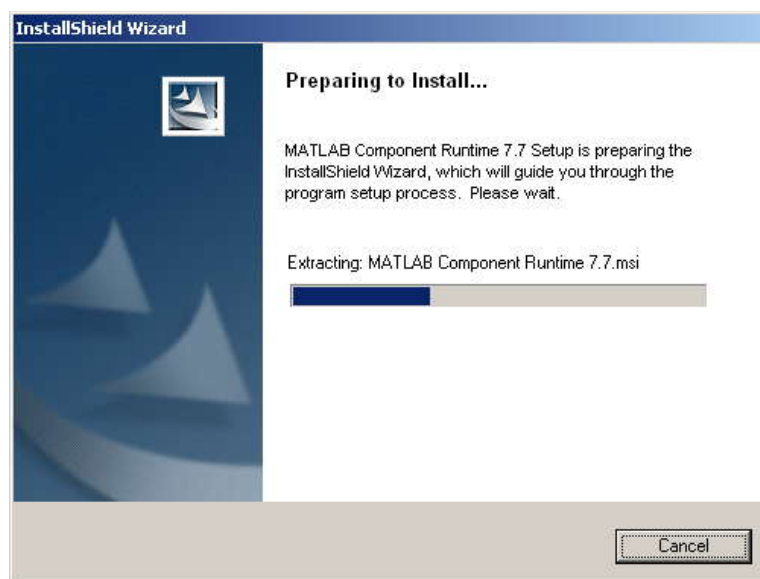


Inmediatamente se inicia la instalación del programa MCR (*Matlab Component Runtime*) necesario para la ejecución del programa MMC – DIFRANCI.

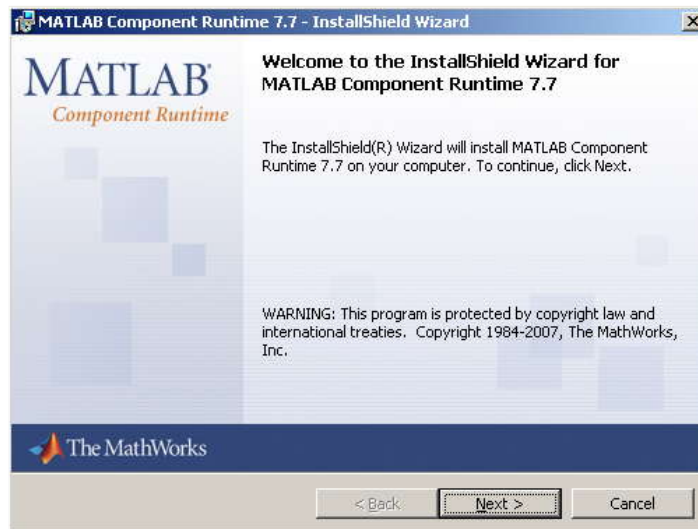
Se selecciona el lenguaje para la instalación del MCR, seleccionar *Inglés (Estados Unidos)* y luego la opción *OK*.




Se genera una ventana donde se presenta el proceso de preparación de la instalación.




Tras terminar este proceso se presenta una ventana de bienvenida al la instalación del MCR, en donde se selecciona la opción *Next >*.



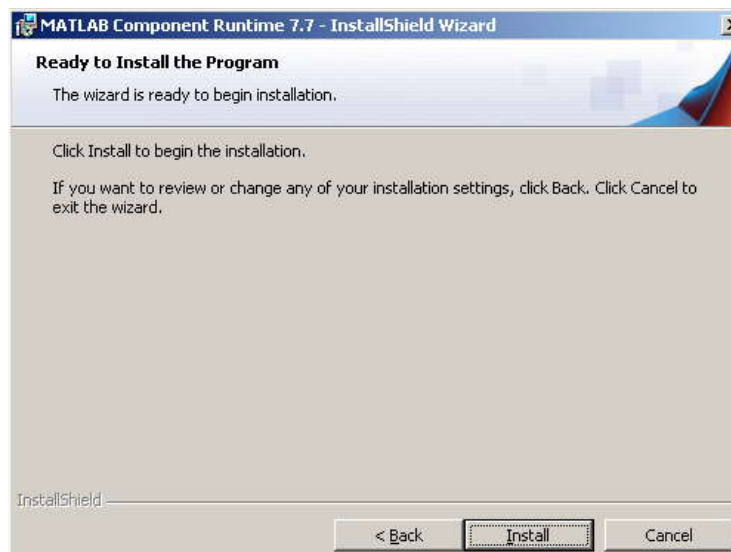
La instalación requiere información del consumidor final, en este punto puede llenar los espacios requeridos o dejar los que aparecen por defecto, tras lo cual se debe seleccionar la opción *Next >*.



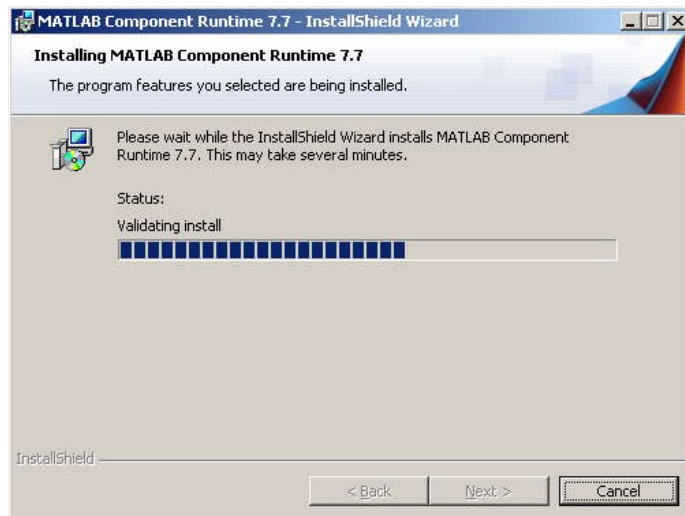
Se solicita determinar la carpeta de destino de la aplicación, se recomienda dejar la ruta dada por defecto, luego se selecciona la opción *Next >*.



Hasta este punto se tiene todo preparada para iniciar la instalación del MCR, si está segura de la información ingresada anteriormente, debe seleccionar la opción *Install*.



Se inicia el proceso de instalación del MCR, en la ventana se observa el avance del proceso, el cual puede tardar varios minutos dependiendo de las características del equipo.

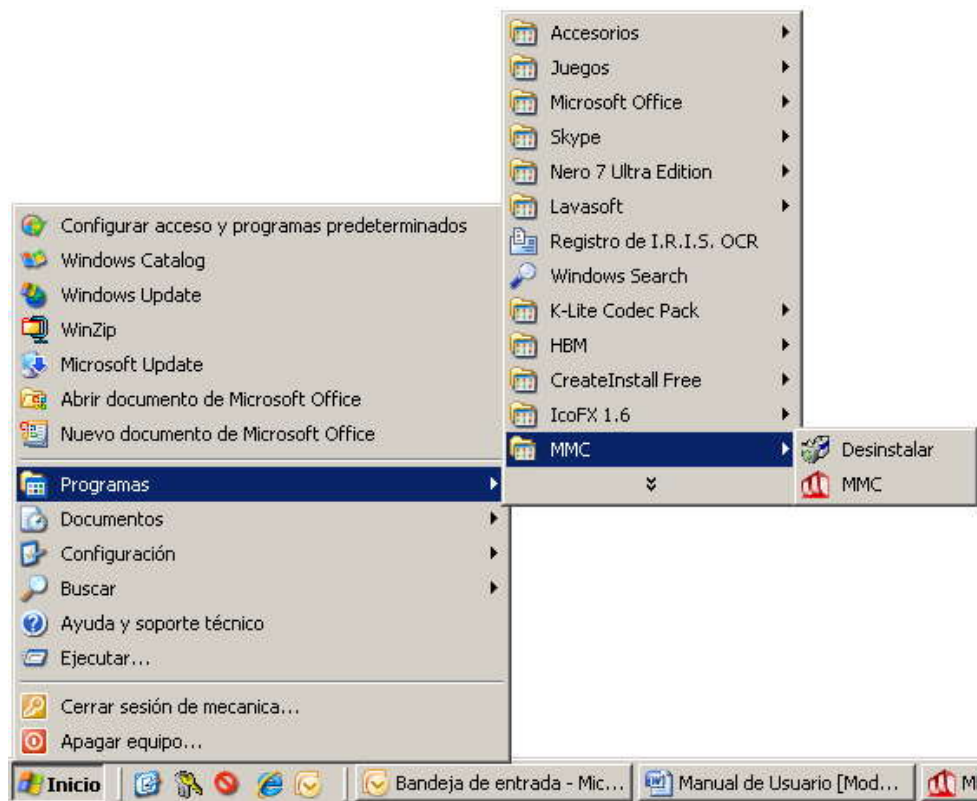


Una vez termina el proceso de instalación del MCR aparece la siguiente ventana de información, en donde se informa que la instalación ha culminado. Por último se selecciona la opción *Finish*.



DESINSTALACIÓN


Para iniciar la desinstalación del programa se tienen dos opciones, la primera consiste en seguir la siguiente ruta *Inicio > Programas > MMC > Desinstalar*, la segunda opción consista en ir a la carpeta donde está instalado el programa, si esta no fue modificada durante la instalación del programa se encuentra en la siguiente ruta *C:\Archivos de programa\MMC*, allí se selecciona el icono *Desinstalar*.



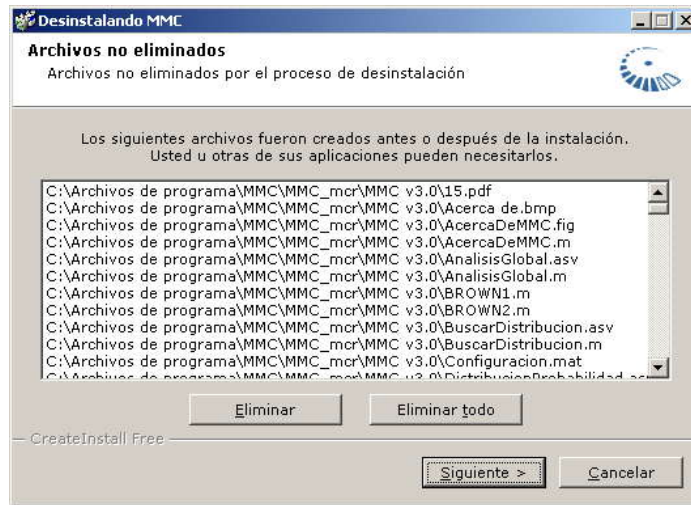
Aparece una ventana de bienvenida al proceso de desinstalación, en donde se selecciona la opción *Siguiente >*.



Se inicia el proceso de desinstalación, una vez este culmina se selecciona la opción *Siguiente >*.

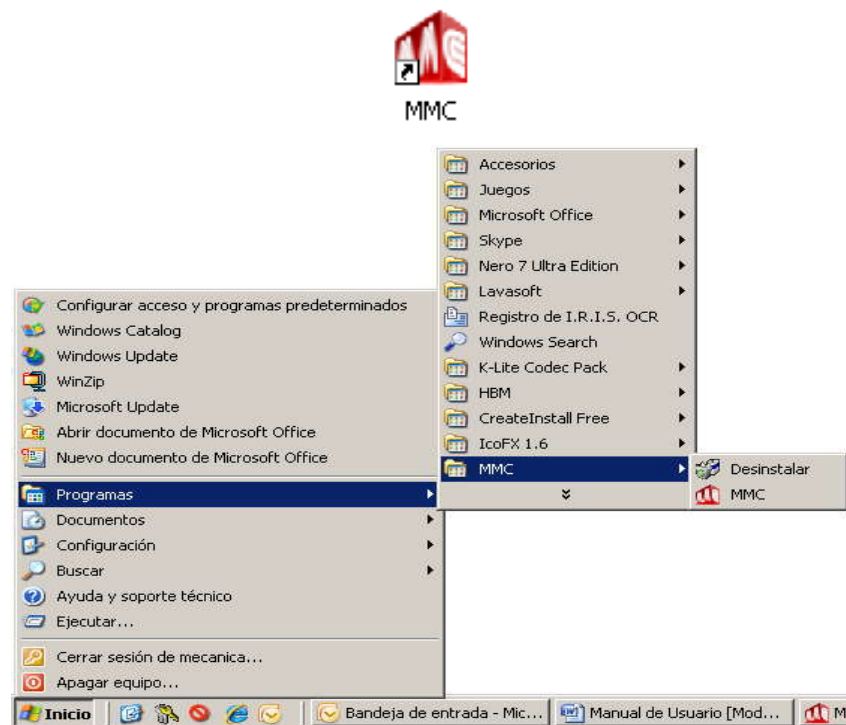


Durante la instalación o después de ella durante la ejecución del programa, es posible que se generen algunos archivos, para eliminarlos seleccionar la opción *Eliminar todo*, con lo cual termina el proceso de desinstalación del programa MMC.




USO DEL PROGRAMA


El ingreso al programa puede realizarse por dos vías, la primera mediante el acceso directo creada en el escritorio tras la instalación. O también se puede ingresar por medio de la ruta *Inicio > Programas > MMC > MMC*.




Cuando se ejecuta la aplicación se presenta la siguiente ventana la cual no debe ser cerrada, en ella se presenta cualquier eventualidad generada en la ejecución del programa.



El programa tiene la siguiente ventana inicial:




La ejecución del programa se realiza mediante el siguiente menú.




MENÚ ARCHIVO

En el menú *Archivo* se encuentran las opciones *Abrir*, *Configuración* y *Salir*.

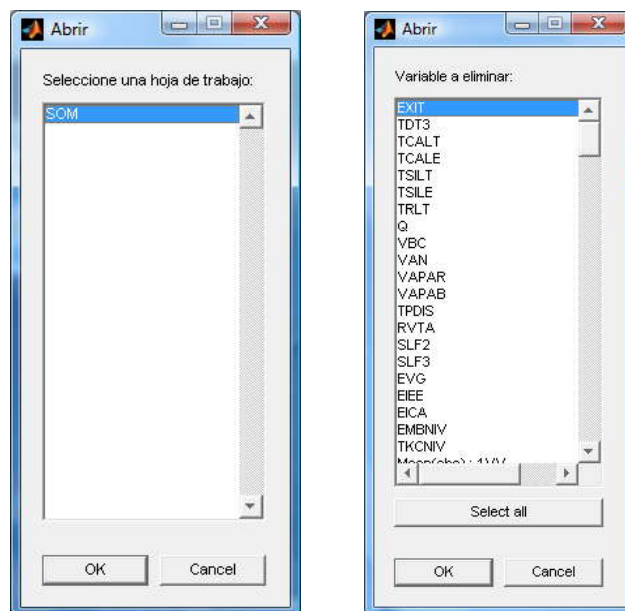


Por medio de la opción *Abrir*, se selecciona la Matriz de Observación de Síntomas (SOM) que se desea analizar.

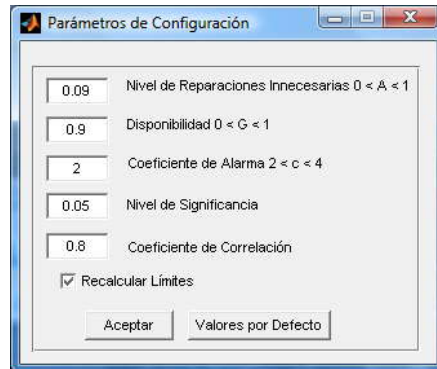


En la siguiente ruta *C:\Archivos de programa\MMC\MMC_mcr\MMC v3.0*, es posible encontrar una matriz SOM de ejemplo.

Dentro de un mismo archivo de Excel® puede encontrarse mas de una matriz de observación (una en cada hoja), por lo tanto se da la opción de seleccionar una hoja en particular. Se presenta la opción de eliminar una o varias variables de la matriz, para salir de esta opción de eliminación se selecciona la opción *EXIT* y luego el botón *OK*.




La siguiente opción dentro del menú archivo es *Configuración*, en ella es posible definir algunos parámetros para la ejecución de los análisis del programa. Para guardar los cambios se debe seleccionar la opción *Aceptar*, si se desea volver a los valores dados por defecto y presentados en la siguiente ventaja se elige la opción *Valores por Defecto*.



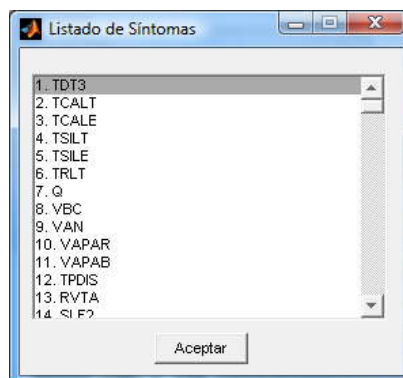
La última opción *Salir*, cierra el programa y automáticamente la ventana en fondo negro creada al iniciar la aplicación.

MENÚ ANÁLISIS DE LA SOM

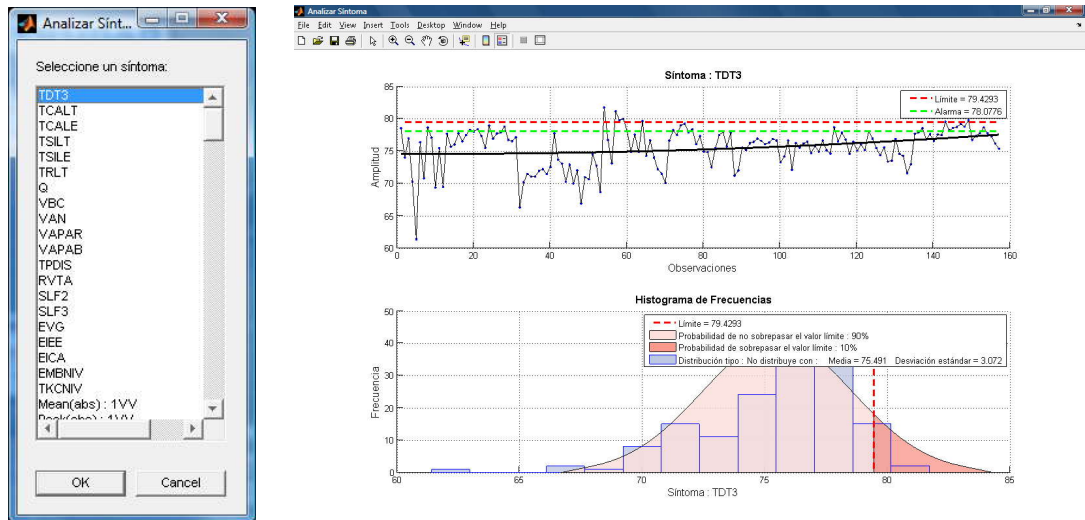
Este menú tiene tres opciones: *Ver listado de síntomas*, *Analizar síntoma* y *Correlación – Varianza – Covarianza*.



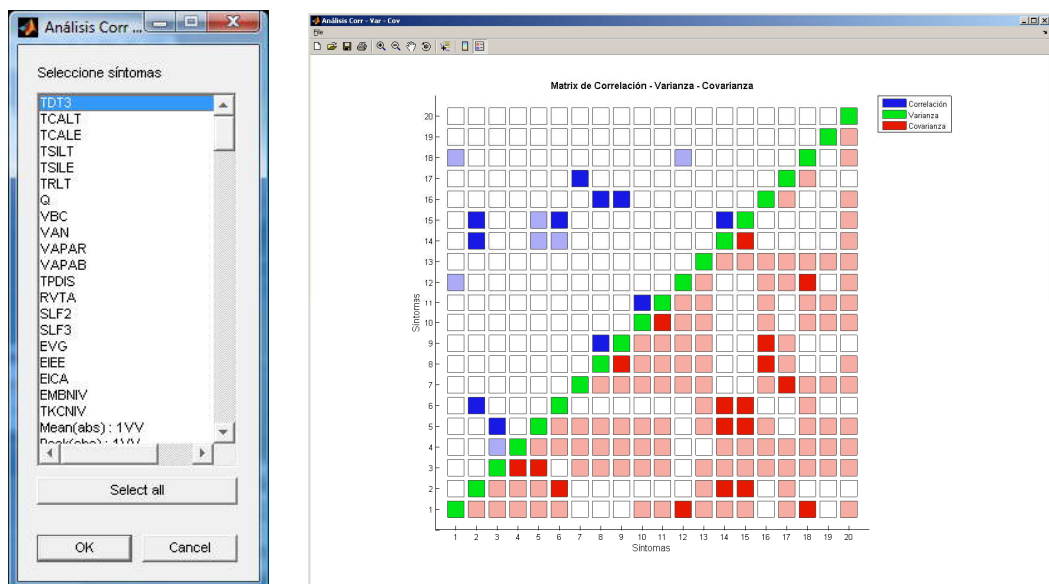
Mediante la opción *Ver listado de síntomas* es posible observar el listado de síntomas con el fin de relacionar las gráficas que hacen referencia a los síntomas.



Mediante la opción *Analizar Síntoma* es posible observar gráficamente la evolución de un síntoma en particular seleccionado y su distribución estadística.




Mediante la opción *Correlación – Varianza – Covarianza*, es posible determinar la matriz de correlación, varianza y covarianza de un conjunto de síntomas seleccionados.

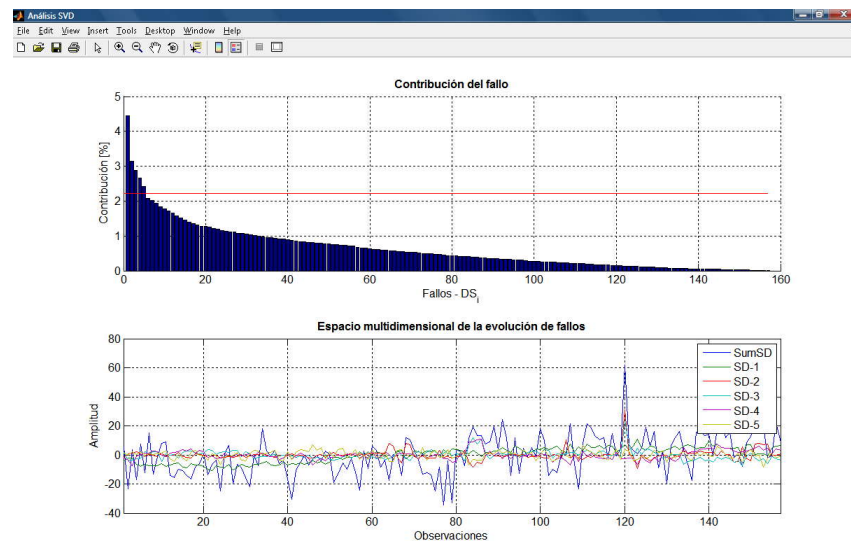


MENÚ ANÁLISIS SVD

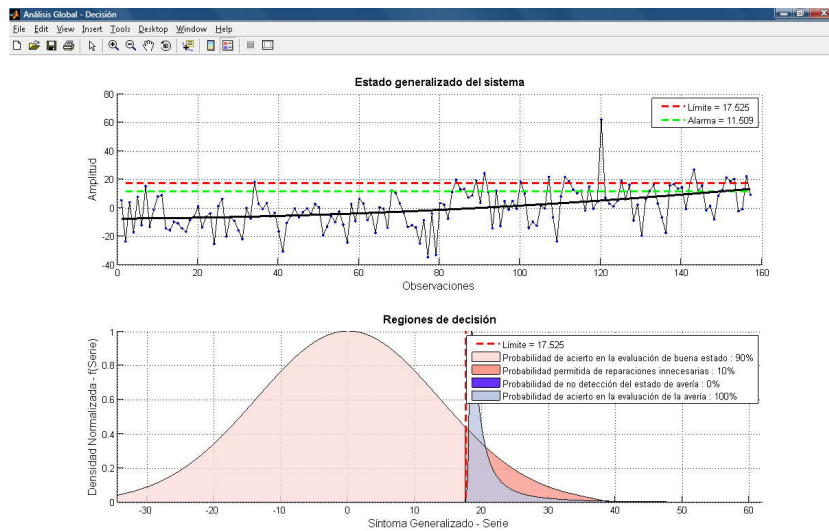
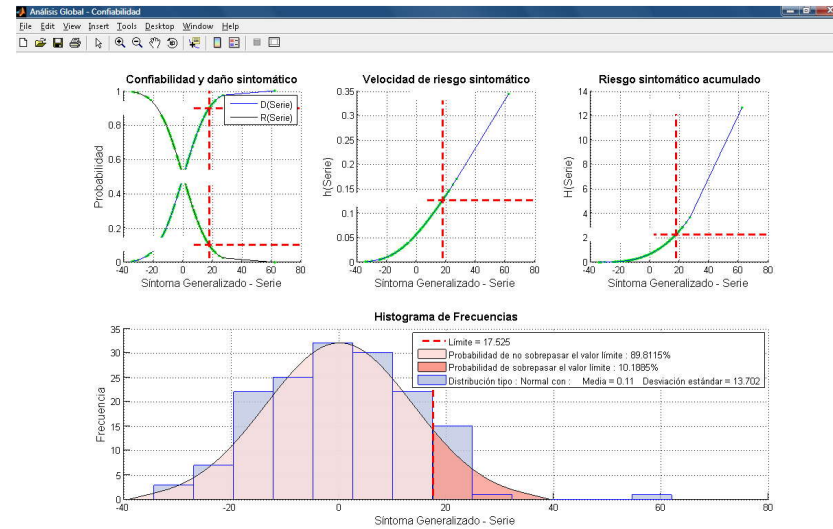
Este menú está compuesto por las siguientes opciones: *Graficar Fallos*, *Análisis Global* y *Análisis de Fallos*.



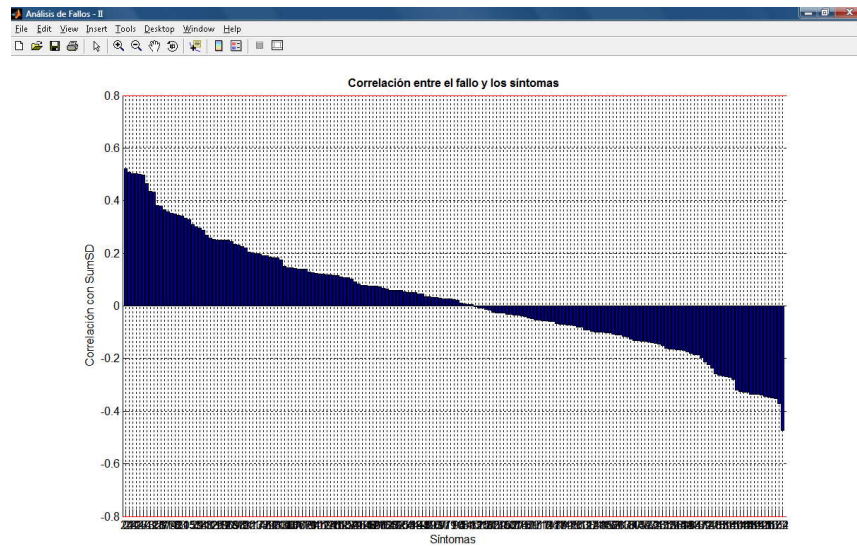
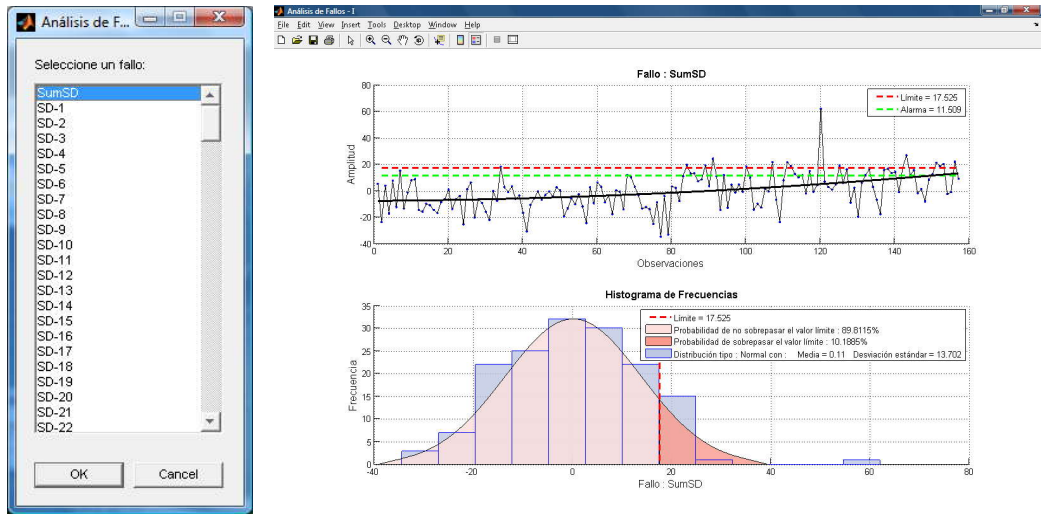
Mediante la opción *Graficar Fallos* se genera una gráfica del siguiente tipo, en la primera figura se observa la contribución de cada fallo y en la segunda la evolución de los fallos que están por encima del valor fijado de mínima contribución.



Con el uso de la opción *Análisis Global* se generan dos gráficas, en la primera se observa la evolución del fallo generalizado y las regiones de decisión, mientras que en la segunda se observan las curvas de supervivencia y la distribución estadística del fallo generalizado.




Mediante la opción *Análisis de Fallos*, es posible seleccionar un fallo específico y se generan dos gráficas, en la primera se observa la evolución del fallo seleccionado y su distribución estadística, en la segunda gráfica se observa la correlación que existe entre el fallo seleccionado y cada uno de los síntomas.





MENÚ PRONÓSTICO



El menú pronóstico cuenta con dos opciones, en donde es posible pronosticar la evolución de un fallo o síntoma específico.



Mediante la opción *Pronóstico de un Fallo*, es posible determinar el pronóstico de un fallo especificado.



Mediante la opción *Pronóstico de un Síntoma*, es posible determinar el pronóstico de un síntoma especificado.



MENÚ AYUDA

En este menú posee dos opciones: *Manual de Usuario* y *Acerca de MMC*. Mediante la primera opción es posible observar el presente manual de usuario y la segunda opción presenta información acerca del programa.

