



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA MECÁNICA

# EMISIONES ACÚSTICAS COMO PRECURSOR DE DAÑO PARA CARACTERIZAR LA DEGRADACIÓN EN UNA BOMBA CENTRÍFUGA

MEMORIA PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL MECÁNICO

ANGELO MAURICIO HERMOSILLA PÉREZ

PROFESOR GUÍA:  
ENRIQUE LÓPEZ DROGUETT

MIEMBROS DE LA COMISIÓN:  
VIVIANA MERUANE NARANJO  
MARCOS ORCHARD CONCHA

SANTIAGO DE CHILE  
2017



RESUMEN DE LA MEMORIA PARA OPTAR  
AL TÍTULO DE INGENIERO CIVIL MECÁNICO  
POR: ANGELO MAURICIO HERMOSILLA PÉREZ  
FECHA: 2017  
PROF. GUÍA: ENRIQUE LÓPEZ DROGUETT

## EMISIONES ACÚSTICAS COMO PRECURSOR DE DAÑO PARA CARACTERIZAR LA DEGRADACIÓN EN UNA BOMBA CENTRÍFUGA

El presente trabajo de título tiene como objetivo realizar una caracterización del estado de degradación de una bomba centrífuga en base a datos de emisiones acústicas (EA) medidas durante el período de operación hasta la falla. Las EA se pueden considerar como un indicador indirecto del daño, ya que permiten tener una noción de la evolución de este aún cuando no es directamente observable/medible.

La distancia de *Mahalanobis* (DM), calculada a partir de las señales de EA obtenidas, permite obtener la medida de desviación de nuevas observaciones respecto a un conjunto de observaciones que den cuenta de un estado inicial. Con esto, es posible generar un índice de degradación a lo largo de la vida de operación del componente, tomando como el subconjunto de comparación a las mediciones que representan el estado saludable (sin degradación) del equipo bajo estudio.

El diagnóstico de la bomba se realiza por medio de un filtro de partículas (FP), utilizado como método de inferencia dentro de una red *Bayesiana* dinámica (RBD). Esta permite representar la dependencia temporal y funcional entre todas las variables involucradas en el proceso de degradación considerado. Es necesario especificar cada dependencia dentro de la RBD. En particular se debe determinar el modelo de estado, que da cuenta de la evolución del daño en el tiempo, y el modelo de medición, que establece la relación entre las mediciones de EA con la degradación. En este caso, no existen modelos físicos que relacione las variables antes mencionadas, por lo tanto, ambos modelos se generan en base a datos.

El modelo de estado es obtenido de una regresión polinomial entre los valores de la DM en base a la eficiencia de la bomba y el tiempo respectivo de cada medición. Para la generación del modelo de medición, se emplea la técnica de *Support Vector Regression* (SVR), la cual permite establecer una correlación no lineal entre las EA con el estado de daño.

El FP emplea 1000 partículas para realizar la estimación del daño en cada instante de tiempo, este logra generar una estimación del daño de la bomba muy cercana a los valores de degradación real en el tiempo. Entre otras métricas de error, se obtuvo un coeficiente de determinación de  $R^2 = 0,9975$ .

En base a los resultados, se puede concluir que el FP utilizado, en conjunto con los modelos generados, conducen un buen diagnóstico del estado de degradación de la bomba. Permitiendo tener una idea de la evolución del daño sufrido por la máquina a lo largo de su vida útil.



*A mis padres, Elena y Jorge,  
y a mi amor, Nayara.*



# Agradecimientos

Quisiera expresar mis agradecimiento a cada uno de los profesores que formaron parte de la comisión de mi trabajo de título, al Profesor Enrique López Droguett, a la Profesora Viviana Meruane y al Profesor Marcos Orchard, por el continuo apoyo y la gran disponibilidad de cada uno.

Agradecer, por su puesto, a mi hermosa familia, que siempre estuvo presente durante este largo proceso. A mis padres, Elena y Jorge, a mis hermanos, Fabian y Freddy, a mis cuñadas, la Ale y la Sole, y a mis hermosas sobrinitas, la Vale, la Cony y la Monse. Agradecimiento especial al Pizuzo y a la Minie. Agradecer también a mi tío pollo, a mi tío Ariel, a mi tío Cholo y a mi tía Vero, a mi Nana, a la Gice y la Andre, a mi tía Paty y sus ricas tortas, y también a mi compadre Nacho.

Agradecimientos también a la familia de la Nay, mi segunda familia. A mi suegra/*partner*, Andrea, a la Vale y, por supuesto, a la Loly. También agradecer a mi bebés, la Kaly y el Ragnar, por su cariño y mordiscos.

Agradecimientos especiales a aquellos que me acompañaron durante estos años en la Universidad, e incluso desde antes. A los Liceanos, al Mati y a la Lisa, al Papa, al JK, al Americo y al Aldo. A aquellos que se fueron sumando durante los años para conformar a los Cartoneros, al Seba, a la Tami, al Kirby y al Nelson.

Agradecer a mis amigos de la vida, del carrete y del deporte. Al Simpson, al Rugrats y al Cogote, al Tercera del RCH, al Diego y al Rafa, al Tano. De nuevo a mis dos hermanos, a mi tío pollo y al Nacho y su Mati.

Finalmente, agradezco a mi hermosa y amada polola, al amor de mi vida, a la Nay. Sin su apoyo y su amor esto no sería posible, tampoco sin su PC que me salvó un par de veces. Gracias por tanto, te amo.

Gracias a todos, gracias a aquellos que hicieron de mí una mejor persona. Gracias totales.



# Tabla de Contenido

<b>Tabla de Contenido</b>	<b>ix</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Problemática . . . . .	1
1.2. Contexto . . . . .	1
1.3. Objetivos . . . . .	2
1.4. Alcances . . . . .	2
<b>2. Antecedentes</b>	<b>4</b>
2.1. <i>Prognostics and Health Management</i> . . . . .	4
2.1.1. <i>Structural Health Monitoring</i> . . . . .	5
2.1.2. PHM e indicadores de daños . . . . .	6
2.2. Precursores de Daño . . . . .	6
2.3. Diagnóstico de falla . . . . .	8
2.3.1. Enfoque basado en datos . . . . .	8
2.4. Emisiones Acústicas . . . . .	9
2.4.1. Principios de la medición y análisis de datos de EA . . . . .	11
2.4.2. Parámetros de EA . . . . .	12
2.4.3. Correlación entre parámetros y degradación . . . . .	15
2.5. Distancia de Mahalanobis . . . . .	16
2.5.1. Propiedades de distancia . . . . .	16
2.5.2. Covarianza y correlación . . . . .	16
2.5.3. Caracterización del estado de salud . . . . .	18
2.6. Filtro de Partículas . . . . .	20
2.6.1. Modelos de estado y de medición . . . . .	23
2.7. <i>Support Vector Machines</i> . . . . .	23
2.7.1. Clasificación . . . . .	23
2.7.2. Support Vector Regression . . . . .	30
<b>3. Definición del problema</b>	<b>33</b>
3.1. Antecedentes . . . . .	33
3.1.1. Bomba centrífuga . . . . .	33
3.1.2. Modos de falla más comunes de la bomba centrífuga . . . . .	34
3.1.3. Sensores de EA . . . . .	35
3.2. Montaje experimental . . . . .	35
3.3. Adquisición de datos . . . . .	38

<b>4. Implementación del modelo de diagnóstico</b>	<b>39</b>
4.1. Mirada general del algoritmo . . . . .	39
4.1.1. Definición del precursor de daño . . . . .	39
4.1.2. Red Bayesiana Dinámica (RBD) . . . . .	39
4.1.3. Inferencia en la RBD utilizando Filtro de Partículas . . . . .	40
4.2. Herramientas utilizadas . . . . .	42
4.3. Consideraciones respecto a los archivos de datos . . . . .	43
4.3.1. Estructura de archivos . . . . .	43
4.4. Preprocesamiento de datos . . . . .	45
4.4.1. Eficiencia de la bomba . . . . .	45
4.4.2. Parámetros de EA . . . . .	47
4.5. Rutinas principales . . . . .	47
4.6. Distancia de Mahalanobis . . . . .	49
4.6.1. Eficiencia . . . . .	50
4.6.2. Emisiones Acústicas . . . . .	51
4.7. Modelo de medición . . . . .	52
4.8. Filtro de partículas . . . . .	53
4.8.1. Algoritmo utilizado en el FP . . . . .	53
<b>5. Discusión de resultados</b>	<b>55</b>
5.1. Generación del índice de daño . . . . .	55
5.2. Precursor del daño . . . . .	57
5.3. Estimación del daño utilizando Filtro de Partículas . . . . .	60
5.3.1. Modelo de estado . . . . .	60
5.3.2. Modelo de medición . . . . .	61
5.3.3. Filtro de Partículas . . . . .	63
<b>6. Conclusiones</b>	<b>65</b>
<b>Bibliografía</b>	<b>67</b>
<b>Anexos</b>	<b>I</b>
<b>A. Gráficos</b>	<b>II</b>
A.1. Parámetros estadísticos de la eficiencia . . . . .	II
A.2. Parámetros de EA . . . . .	III

# Capítulo 1

## Introducción

### 1.1. Problemática

El problema a abordar en este trabajo de memoria, consiste en caracterizar la degradación de una bomba centrífuga a partir de Emisiones Acústicas (EA) medidas a lo largo del período de operación de esta. La bomba se encuentra bajo condiciones de operación controladas, en un laboratorio. La idea principal es determinar la evolución del estado de degradación de la máquina a lo largo de su vida útil.

Para comprender el desarrollo del presente trabajo, es necesario introducir algunos conceptos que darán forma al marco teórico.

### 1.2. Contexto

El Pronóstico y Manejo de la Salud (PHM, por sus siglas en inglés) es una metodología de trabajo integrada por tres tareas principales: diagnóstico, pronóstico y Mantenimiento en Base a la Condición (CBM).

Existen técnicas de Inspección No Destructivas (IND) que pueden detectar el daño en estructuras. Sin embargo, cuando estas técnicas son capaces de realizar esta detección, la vida útil del componente ya ha expirado casi en su totalidad. Con el fin de realizar un diagnóstico en una etapa temprana, se introduce el concepto de Precursor de Daño (PD), o indicador indirecto de daño, asociado a variaciones perceptibles de las propiedades del componente que den cuenta de la evolución de la degradación. Así, la contribución de la información contenida en los PD en el marco teórico del PHM, constituye una poderosa herramienta para estimar el estado de un componente incluso cuando señales directas de daño aún no son detectables.

Las EA son un indicador indirecto de daño, o PD. Los instrumentos de EA perciben el movimiento detectado en la superficie del componente y lo transforman en señales eléctricas.

Este movimiento en la superficie del componente es consecuencia de la radiación de ondas elásticas, producidas por deformaciones plásticas a nivel microscópico dentro del material.

No existe un modelo que relacione las EA con la degradación, por lo que se hace necesario la generación de uno. Support Vector Machine (SVM) comprende una herramienta muy versátil y robusta, capaz de identificar y clasificar patrones de comportamiento de datos y generar regresiones (Support Vector Regression, SVR) en base a un conjunto de datos de entrenamiento. Así es posible determinar una co-relación entre ambas variables.

Las Redes Bayesianas Dinámicas (RBD) permiten incorporar información desde distintas fuentes, con el fin de construir una representación gráfica simple de un sistema dinámico complejo que involucre distintas variables. Además, utilizando el Filtro de Partículas (FP), como el método de inferencia dentro de la RBD, es posible estimar el estado de degradación.

## 1.3. Objetivos

### Objetivo General

- Caracterizar el estado de degradación de una bomba centrífuga en base a datos de EA.

### Objetivos Específicos

- Generar un índice de degradación a partir de los datos de la eficiencia de la bomba centrífuga.
- Determinar una correlación entre el daño y las señales de EA.
- Desarrollar un modelo, utilizando SVR, que de cuenta de la función de verosimilitud entre las emisiones acústicas y el estado de la bomba.
- Caracterizar el estado de degradación de la bomba utilizando la técnica de FP.

## 1.4. Alcances

Este trabajo busca implementar un método para caracterizar el estado de degradación de una bomba centrífuga utilizando EA. Se pretende, con esta caracterización, poder determinar la evolución de la degradación a lo largo de la vida útil de la bomba centrífuga.

Para efectos de este trabajo, los datos de EA y eficiencia de la bomba son facilitados por el Profesor Guía, limitando esta memoria al procesamiento de los mismos mediante herramientas computacionales.

Los datos son obtenidos de un procedimiento experimental realizado en las dependencias de

la Universidad de Maryland (UMD), Maryland, Estados Unidos. Este consta en el monitoreo continuo de una bomba centrífuga en un sistema cerrado de recirculación de agua de mar a alta temperatura, con la idea de que esta sea expuesta a condiciones extremas de operación para acelerar el proceso de degradación.

# Capítulo 2

## Antecedentes

### 2.1. *Prognostics and Health Management*

Esta es una metodología de trabajo que agrupa a aquellos métodos utilizados para prevenir y predecir fallas en sistemas completos. En particular, el pronóstico es el proceso de predecir la confiabilidad futura de un producto por medio de la evaluación del grado de desviación o degradación de este respecto a la condición normal de operación esperada; el manejo de la salud es el proceso de medición, grabación y monitoreo en tiempo real de la degradación del producto.

En general, el flujo de trabajo típico de una estrategia de Prognostics and Health Management (PHM) puede ser ilustrada de manera conceptual, tal como se muestra en la Figura 2.1. Tres tareas principales pueden ser identificadas en este flujo de trabajo: diagnóstico de falla, pronóstico y mantenimiento basado en la condición [1]. La primera tarea consiste en el diagnóstico y la identificación de la causa raíz de la falla del sistema. La segunda tarea toma como entrada los datos procesados y los modelos existentes del sistema o de degradación y utiliza los distintos algoritmos de pronóstico existentes para actualizar en línea los modelos de degradación y predecir los tiempos de falla. La tercera tarea hace uso de los resultados del pronóstico y considera los costos versus los beneficios para las distintas acciones de mantenimiento y determinar cuándo y cómo realizar las labores de mantenimiento preventivo de tal manera de lograr mínimos costos y riesgos de operación.

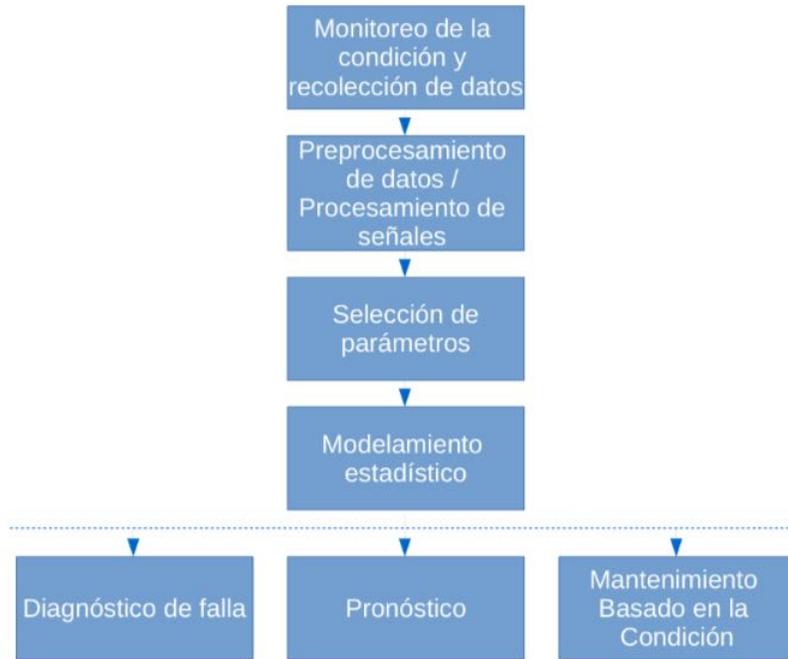


Figura 2.1: Flujo típico de la aplicación de PHM. Adaptada de [1]

### 2.1.1. *Structural Health Monitoring*

El proceso de implementar una estrategia de detección y caracterización de daño para estructuras de ingeniería, es conocido como Monitoreo de Condición Estructural (SHM, por sus siglas en inglés). Este tiene como objetivo dar a conocer, en cada instante a lo largo de la vida de la estructura, un diagnóstico del estado del componente bajo monitoreo [2]. El estado de la estructura debe permanecer dentro de ciertos límites especificados por el diseño, sin embargo es aceptable cierto nivel de degradación debido al desgaste propio del uso, condiciones ambientales y eventos aleatorios. Gracias a la dimensión temporal del proceso de monitoreo continuo, propio del SHM, es posible contar con el historial completo de los datos de la estructura, lo que permite también realizar un pronóstico de, por ejemplo, la evolución del daño o la vida remanente de uso.

Considerando sólo la función de diagnóstico, el SHM puede ser considerado una nueva y mejorada manera de realizar un ensayo no destructivo (NDT, por sus siglas en inglés). El marco teórico del SHM integra el uso de sensores, transmisión de datos, potencia computacional y capacidad de procesamiento. El uso exitoso del SHM puede guiar al rediseño de la estructura y a reconsiderar todo el plan de mantenimiento de esta y del sistema al que pertenece.

En la Figura 2.2 se representa la organización de la metodología SHM dentro de PHM. En esta se observan las distintas interacciones de los dispositivos y sistemas que participan en el proceso de obtención de datos y su tratamiento. La etapa de diagnóstico está directamente relacionada a la función de monitoreo llevada a cabo por el sistema integrado de sensores, encargado de capturar la información proveniente del fenómeno físico asociado al daño que se

busca determinar. En paralelo, es necesario monitorear la estructura para conocer su estado respecto a lo recomendado por el diseño (monitoreo del uso). La etapa de pronóstico incorpora las funciones de diagnóstico y monitoreo del uso de la estructura. Sin embargo, para poder realizar un pronóstico, además, es necesario conocer la dinámica de la evolución del desgaste, descrita mediante modelos asociados a alguna ley física o bien generado a partir de datos.

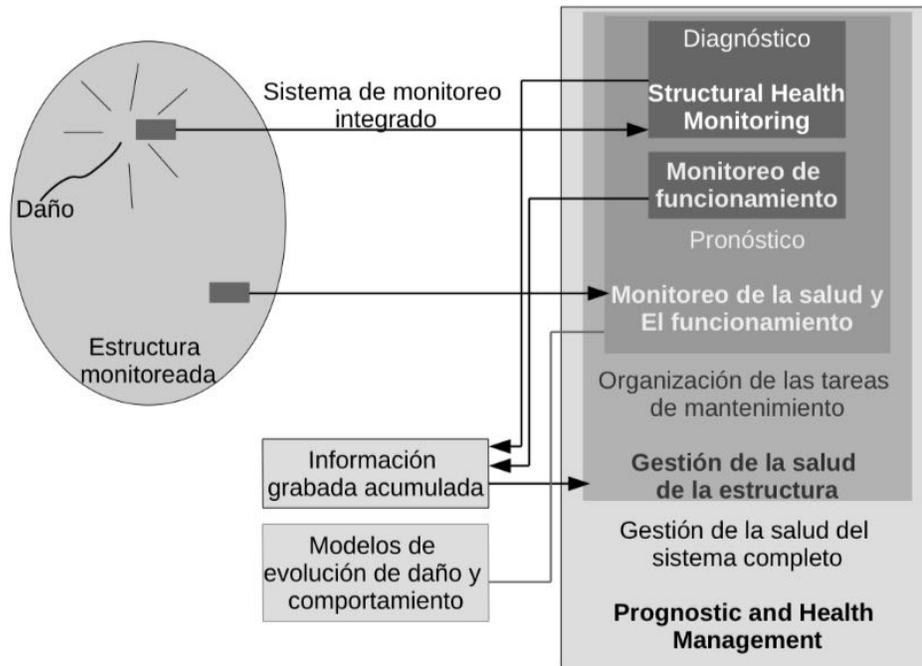


Figura 2.2: Organización de la metodología SHM. Adaptada de [3]

### 2.1.2. PHM e indicadores de daños

La mayoría de las estrategias de PHM propuestas en la literatura se basan en la estimación de los *indicadores directos de daño*, los que son considerados como “marcadores observables del daño”, como por ejemplo el tamaño de grieta. Sin embargo, para el tiempo donde las técnicas usuales de inspección logran identificar este tipo de marcadores, la mayor parte de la vida útil del componente ya ha sido consumida. Incluso existe la posibilidad de que el daño permanezca indetectable y termine por desatar, por ejemplo, una falla catastrófica. Es por lo anterior que surge una nueva idea respecto a un marco de referencia para SHM, propuesto por Rabiei E. et al., [2] basado en *indicadores indirectos de daño* o *Precursores de Daño*.

## 2.2. Precursores de Daño

No existe consenso de una definición única para el concepto de precursores de daño (DPs, por sus siglas en inglés). La interpretación de DP puede variar dependiendo del campo de estudio y el tipo de daño considerado. Una de estas definiciones describe a los DPs como

la progresión de la degradación de las propiedades estructurales que pueden convertirse en daño [2]. Esta descripción implica que un DP es algún cambio microestructural que ocurre “antes” del daño y puede “convertirse en daño”. Sin embargo, esta noción dependerá de la propia definición del daño. De hecho, la definición del daño debido a mecanismos físicos varía para distintos materiales, geometrías y escalas. En algunos casos, la propia deterioración de las propiedades estructurales puede considerarse como daño del componente, a escala microscópica, a pesar de que NDTs comunes podrían no ser capaces de identificarlos.

Es por lo anterior que surge la necesidad de establecer una definición más amplia de los DPs. Así, Rabiei E. et al., en [2], define DP como “cualquier variación perceptible de las propiedades físicas del componente que den cuenta de la evolución del daño oculto/inaccesible/no medible durante la degradación”. En esta definición, DP puede referirse a cualquier signo indirecto de daño que es revelado como una señal del cambio microestructural, y puede describir el proceso de degradación subyacente cuando los signos directos de daño convencionales, como una grieta, aún no son detectables o accesibles. De esta forma, y en base a la definición anterior, es que se utilizan de manera indistinguible los conceptos de precursores de daño e indicadores indirectos de daño.

En la Figura 2.3 se ven representado los DPs en un segundo nivel de jerarquía, traducidos en el cambio de propiedades físicas, después de la medición propiamente tal por medio de sensores y antes de que se produzca daño.



Figura 2.3: DP dentro de un nivel jerárquico de ocurrencia. Modificada de [4].

La idea de considerar los DPs como parte del marco teórico del SHM entrega la posibilidad de estimar el estado de daño de un componente cuando los signos directos de daño aún no se han desarrollado o son difíciles de medir. Permitiendo realizar un diagnóstico en una etapa temprana de la vida útil de la estructura.

## 2.3. Diagnóstico de falla

El diagnóstico de falla busca identificar de manera eficiente y precisa la causa raíz de la falla. La detección de falla se define como la tarea de determinar si un sistema está experimentando problemas. El diagnóstico de falla, entonces, se define como la tarea de determinar la severidad de la falla una vez que se ha detectado aquella [1].

En general, las metodologías utilizadas en el diagnóstico de falla pueden ser clasificadas en dos categorías [1]: enfoque basado en modelos y enfoques libres de modelos. En la primera categoría, se proponen algunas formas de modelos subyacentes que vinculan modos de falla y observaciones. Estos modelos a menudo se derivan de principios elementales y mecanismos físicos. Basándose en la estructura del modelo y los parámetros, las observaciones se pueden utilizar para inferir las causas raíz o los modos de falla utilizando diferentes algoritmos. Por otro lado, la segunda categoría a menudo no asumen el conocimiento de un modelo subyacente. A pesar de que en muchos casos se utilizan modelos implícitos o estadísticos en el diagnóstico de falla, también existe la posibilidad de utilizar enfoques basados únicamente en datos, sin suposiciones adicionales en los mecanismos de operación del sistema.

En diagnóstico de falla, se desearía conocer el momento exacto cuando la falla ocurre, su ubicación y la severidad de esta. Por lo tanto, el diagnóstico se puede dividir en tres etapas básicas [1]: (1) detección de anomalías, identificando cualquier potencial desviación del rendimiento de operación normal; (2) localización de la falla, localizando el problema al componente o subsistema específico; (3) clasificación de la falla, discriminando fallas conocidas o desconocidas e identificando el tipo de falla si es previamente conocida.

### 2.3.1. Enfoque basado en datos

En la actualidad existe la posibilidad de coleccionar de manera automática una gran cantidad de datos en un período corto de tiempo. Esto, por medio de sensores conectados on-line en los distintos componentes de interés. Sin embargo, esta gran cantidad de datos muchas veces sugiere un problema en cuanto a la calidad de los mismos. Por consiguiente, surge la necesidad de un pre-procesamiento y extracción de características (*feature extraction*) de datos con el fin de mejorar su calidad, reducir la redundancia de información y aumentar la eficiencia de análisis [1].

Existe una amplia gama de técnicas, en el contexto de PHM, para realizar el procesamiento de datos. Estas técnicas pueden clasificarse en métodos estadísticos y métodos basados en conocimiento de ingeniería. Los métodos incluidos en la segunda categoría, en particular, utilizan los conocimientos de alguno de los campos de la ingeniería en el proceso de extracción de características de señales. En el contexto del mantenimiento basado en la condición, el tipo de datos puede ser clasificada en tres categorías [1]: valor (por ejemplo: temperatura, presión), multidimensional (por ejemplo: imágenes de rayos-X, datos de imagen) y forma de onda (por ejemplo: vibraciones, señales de Emisiones Acústicas). Siendo este último tipo de datos (forma de onda) el más utilizado en el diagnóstico de sistemas mecánicos, debido a la popularidad de datos con forma de onda extraídos mediante sensores, particularmente en

análisis de señales de vibración en elementos rotativos.

Las Emisiones Acústicas son datos del tipo con forma de onda. Estas son más sensibles a cambios microestructurales que, por ejemplo, las vibraciones [5]. Así, al considerar los datos de Emisiones Acústicas como Precursores de Daño, es posible obtener información de los procesos microestructurales de un componente en una etapa temprana, y así poder diagnosticar antes de que los indicadores directos de daño se hagan presente.

## 2.4. Emisiones Acústicas

El fenómeno de Emisión Acústica (EA) está relacionado al evento de radiación de ondas elásticas (sonido y ultrasonido) en materiales bajo procesos de deformación plástica. Las Pruebas de Emisiones Acústicas (AET, por sus siglas en inglés) se encuentran dentro de la clasificación de NDTs. AET es usualmente aplicado durante operación con carga, mientras la mayoría de estos métodos son aplicados después o antes de la carga. Por otro lado, las EA son utilizadas a menudo para detectar fallas en una etapa temprana, mucho antes de que una estructura falle por completo.

Un atributo más dominante para distinguir entre las diferentes NDTs, tiene relación con la manera en que esta es aplicada y el tipo de información que se puede extraer. El método de ultrasonido, por ejemplo, es capaz de determinar la forma geométrica del defecto en una muestra, utilizando una señal de una fuente generada artificialmente y un receptor, mientras que las AET detectan las ondas elásticas radiadas productos de deformaciones plásticas a nivel microscópico. De esta manera, las NDT se pueden clasificar en técnicas activas o pasivas. En la Figura 2.4 se representa el funcionamiento de ambas. De este modo, el método de EA es considerado como un ensayo no destructivo pasivo, ya que por medio de estas usualmente se identifican defectos sólo cuando estos se desarrollan durante la prueba.

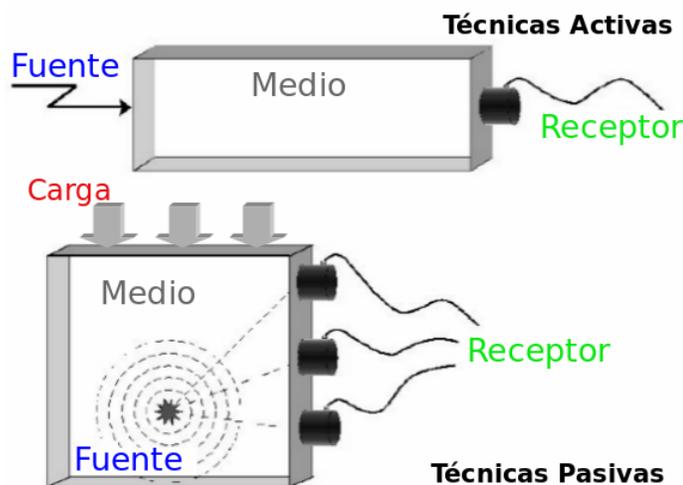


Figura 2.4: Comparación de los principios de NDT utilizando técnicas activas o pasivas .  
Modificada de [5].

En la Tabla 2.1 se presenta un resumen de las diferencias entre las AET y otras técnicas NDT.

Tabla 2.1: Comparación entre EA y otras técnicas NDT [5]

<b>Emisiones Acústicas</b>	<b>Otras técnicas</b>
Detectan movimiento de defectos	Detectan geometría de defectos
Requieren carga	No requieren carga
Cada carga es única	Inspecciones pueden ser repetitivas
Mayor sensibilidad a materiales	Menos sensible a materiales
Menos sensible a geometrías	Mayor sensibilidad a geometrías
Menos intrusiva al proceso	Más intrusivas al proceso
Sólo se requiere acceso a sensores	Se requiere acceso a toda el área de inspección
Se testea toda la estructura de una vez	Se escanean regiones locales de manera secuencial
Problema principal: relacionados a ruido	Problema principal: relacionados a la geometría

En la estructura típica de los instrumentos para medir Emisiones Acústicas, como se puede apreciar en la Figura 2.5, podemos encontrar los siguientes componentes: Sensor, encargado de detectar los eventos de EA, convirtiendo el movimiento en la superficie de un material en señales eléctricas; Preamplificador y amplificador principal, dado que las señales de EA son débiles, normalmente se cuenta con dos procesos de amplificación de las señales extraídas por los sensores; y Filtro Pasa Bandas, el cual elimina el ruido de la señal extraída, otorgando una mejor calidad de los datos para su posterior análisis.

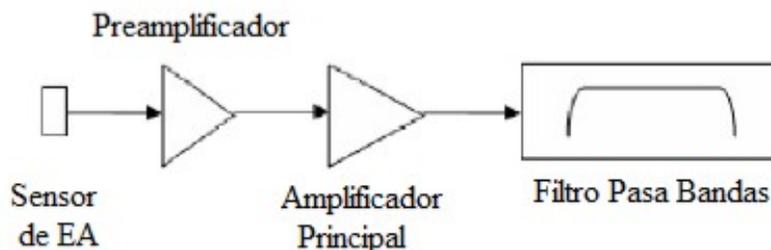


Figura 2.5: Estructura típica de un instrumento para medir EA. Adaptada de [5].

Luego de la detección, amplificación y filtro de las señales de EA, estas pasan a un Dispositivo de Adquisición de Datos (ver Figura 2.6) donde se almacena la información de EA, se evalúan los parámetros de la señal, se realiza el análisis de los datos y se tabulan y grafican los resultados presentados en la interfaz de un monitor.

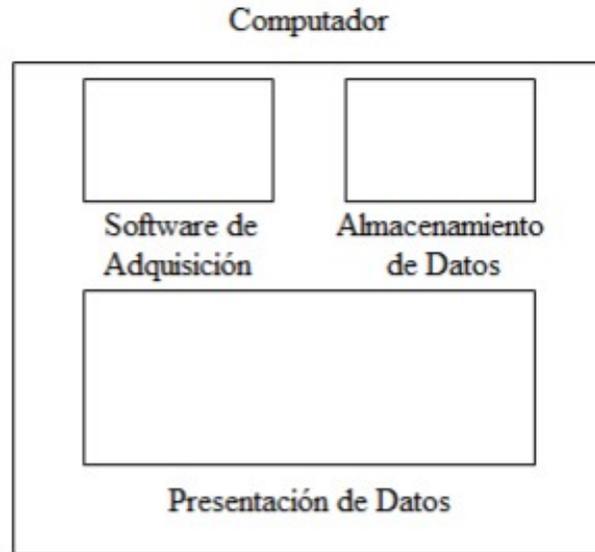


Figura 2.6: Estructura típica de un dispositivo de adquisición de datos.

### 2.4.1. Principios de la medición y análisis de datos de EA

Para la realización de una correcta adquisición de datos es necesaria la configuración de ciertos parámetros de detección de señales. En el caso de las EA, existen dos parámetros que nos permiten, tras una correcta configuración, una buena adquisición de las señales de EA. Por un lado, debemos establecer un límite (Threshold) [6] desde el cual se considerará que la señal detectada corresponde a una señal de EA, y de este modo ignorar aquellas mediciones que representen eventos por causas diferentes a EA, como por ejemplo el movimiento de partes mecánicas en contacto con la estructura en estudio. Por otro lado, y a partir desde que se detecta una señal de EA, se debe establecer la duración del golpe (Hit Definition Time, HDT), lo que permite al sistema determinar el fin de una excitación, cerrar el proceso de medición y almacenar los parámetros medidos de las señales [6].

En la Figura 2.7 se puede observar una señal que registra claramente dos golpes que representan EAs (comenzando en las líneas negras trazadas verticalmente), además se señala un umbral o threshold (línea roja horizontal) y se presentan dos ejemplos erróneos de la duración del golpe o HDT: en verde se aprecia un HDT muy largo, registrando información de dos golpes diferentes. Y en rojo un HDT muy corto, lo que no permite registrar por completo un sólo golpe.

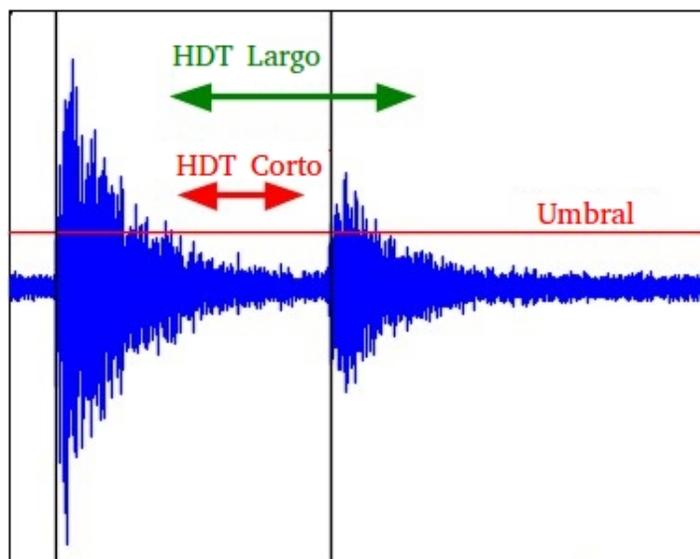


Figura 2.7: HDT y Threshold en una señal de EA. Adaptada de [6].

## 2.4.2. Parámetros de EA

Existe una gran cantidad de parámetros de Emisión Acústica. A la hora de buscar una correlación entre los datos de EA y el estado de degradación de un componente, es de gran importancia comprender el significado de cada parámetro. Algunos de los parámetros típicos de EA se ven representados en la Figura 2.8.

La definición y uso de los parámetros de EA más importantes, y más utilizados en la literatura [7], se presenta a continuación.

- **Golpe:** Cualquier señal de emisión acústica que sobrepase un umbral (*Threshold*), previamente definido, y que agregue un registro de fecha en algún canal (sensor) es llamado Golpe.

Refleja la cantidad total y la frecuencia de las emisiones acústicas. Usualmente se utiliza para medir la actividad de estas.

- **Evento:** Los sucesos que generen emisiones acústicas en un material, tales como deformación plástica, son llamados Eventos.

Los Eventos dan cuenta de la cantidad total y la frecuencia con que ocurre este tipo de sucesos. Se utilizan para evaluar la fuente de actividad y el grado de concentración de irregularidades.

- **Conteo:** El número de veces que la oscilación de la señal cruza por el umbral.

Es un método sencillo para procesar la señal. Con este se puede reflejar la potencia y la frecuencia de la señal de manera aproximada, lo que se utiliza ampliamente en la evaluación de la actividad de emisiones acústicas.

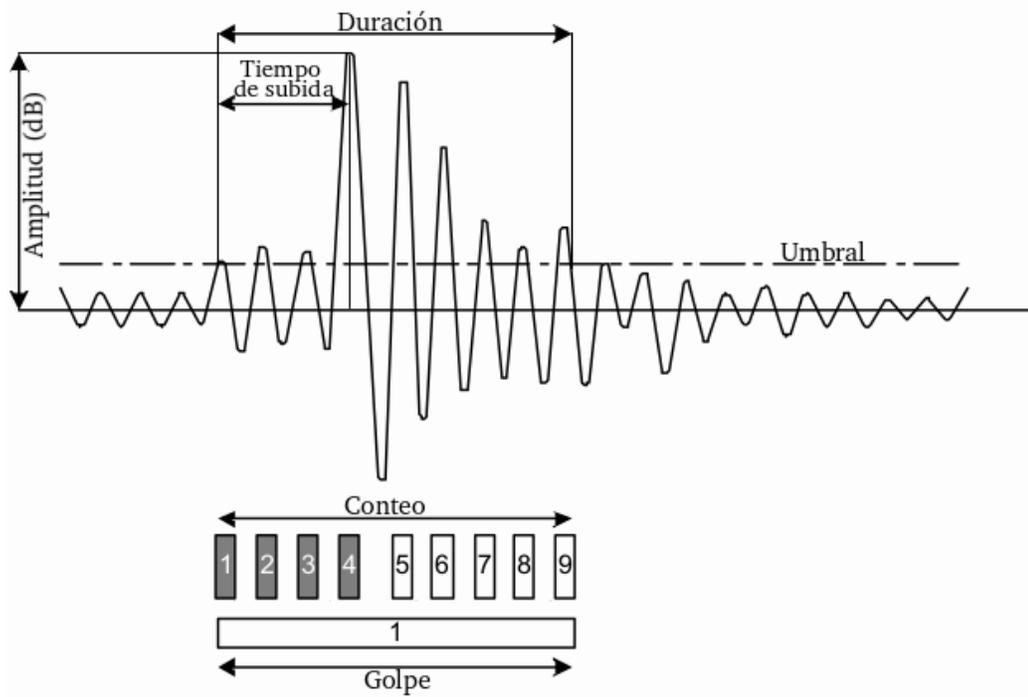


Figura 2.8: Algunas características típicas de EA. Adaptada de [5].

### Características de amplitud

- **Amplitud:** La amplitud de vibración máxima de la forma de onda de la señal, generalmente se expresa en decibeles (dB). Refleja la magnitud del evento. Se utiliza comúnmente para identificar el tipo de fuente de onda, y para medir la fuerza y la atenuación.
- **RMS:** El valor cuadrático medio de la señal durante el muestreo, usualmente expresado en voltaje (V). Es utilizado para medir la actividad continua de emisiones acústicas. Dado que la actividad de emisión acústica se atribuye a liberaciones rápidas de energía en el material, el contenido energético de la señal de emisión acústica está relacionado con esta liberación de energía. El RMS o, también llamado, energía promedio (AERms) se puede definir, en su versión continua, como:

$$RMS = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} \nu^2(t) dt} \quad (2.1)$$

y de manera discreta:

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N \nu^2(n)} \quad (2.2)$$

donde  $\nu$  es el voltaje generado en los sensores de EA,  $t_0$  es el tiempo inicial,  $T$  el tiempo de integración de la señal, y  $N$  el número de datos de EA en el intervalo de tiempo  $T$ .

- **ASL:** Es el nivel promedio de la señal durante el tiempo de muestreo, se expresa en V o dB.

Es muy útil en el caso de señales continuas, que tienen alta demanda del rango dinámico de la amplitud y baja demanda en resolución del tiempo. También se utiliza para medir el nivel de ruido de fondo. El ASL expresado en V, se define, en su versión continua, como:

$$ASL_\nu = \frac{1}{T} \int_{t_0}^{t_0+T} |\nu(t)| dt \quad (2.3)$$

o, en su versión discreta:

$$ASL_\nu = \frac{1}{N} \sum_{n=1}^N |\nu(n)| \quad (2.4)$$

El correspondiente nivel promedio de la señal en dB, se expresa como:

$$ASL_{dB} = 20 \log \frac{ASL_\nu}{V_0} \quad (2.5)$$

con  $V_0 = 1[V]$ .

### Características de energía

- **Energía:** El área bajo la envolvente de la señal detectada. Refleja la energía relativa o potencia. Este parámetro puede reemplazar al Conteo, también es utilizado para identificar el tipo de fuente de onda.
- **Energía absoluta:** Da cuenta de la energía de impacto de la señal de emisión acústica. Se define como:

$$ABSENE = \frac{\Delta T}{R} \sum_{t=0}^m V_i^2 \quad (2.6)$$

donde  $V_i$  representa el voltaje para el punto de muestreo  $i$ ,  $\Delta T$  es el intervalo de muestreo,  $m$  es la duración de la observación  $i$ , y  $R$  representa la impedancia del circuito de medición.

- **Potencia de la señal:** Medida de la energía de impacto de la señal de emisión acústica. Está dada por:

$$SIGSTR = \Delta T \sum_{t=0}^m |V_i| \quad (2.7)$$

## Características de tiempo

- **Tiempo de duración:** Intervalo de tiempo desde el primer evento que pasa por sobre el umbral y vuelve a caer por debajo de este valor, usualmente se expresa en microsegundos ( $\mu s$ ).

Es muy similar al Conteo. Sin embargo, este se utiliza para identificar tipos especiales de onda y el ruido de la señal.

- **Tiempo de subida:** Intervalo de tiempo desde el primer evento que pasa por sobre el umbral y alcanza la máxima amplitud.

Su significado físico no es claro debido a la influencia de la transmisión. Se suele utilizar para medir el ruido mecánico y eléctrico.

## Características de frecuencia

- **Frecuencia promedio:** Es la frecuencia promedio a lo largo del período de muestreo, es una medida de la señal de impacto de emisión acústica completa, se mide en kHz (kilohertz).

Está asociada con el Conteo y la duración, refleja la frecuencia de la señal de manera aproximada.

- **Frecuencia inicial:** La frecuencia correspondiente al tiempo de subida, se mide en kHz. Se relaciona con el Conteo, antes de alcanzar la amplitud máxima, y tiempo de subida, refleja la frecuencia de la señal de manera aproximada.

- **Frecuencia centro:** Corresponde al componente de frecuencia correspondiente al centro de gravedad en el espectro.

Refleja la frecuencia de la señal de manera aproximada.

- **Peak de frecuencia:** Corresponde al componente de frecuencia correspondiente a la amplitud máxima en el espectro.

Refleja la frecuencia de la señal de manera aproximada.

### 2.4.3. Correlación entre parámetros y degradación

La proximidad es un concepto generalmente utilizado para indicar similitud o diferencia. Y las mediciones de distancias son buenos indicadores de proximidad.

Se utiliza el concepto de *Distancia de Mahalanobis* para determinar la medida de desviación entre los datos de entrada, en este caso, los parámetros asociados a cada observación. Y luego, se construye un índice que permita clasificar cada punto respecto a un estado de degradación, dado por la desviación de estos respecto a un subconjunto de puntos considerados en estado saludable (sin degradación).

## 2.5. Distancia de Mahalanobis

### 2.5.1. Propiedades de distancia

En general la distancia mide que tan cercano, o alejado, se encuentra un objeto de otro. La distancia indica proximidad, y esta última permite establecer similitud o diferencia entre un conjunto de elementos.

En coordenadas Cartesianas, si  $p = (p_1, p_2, \dots, p_n)$  y  $q = (q_1, q_2, \dots, q_n)$  son dos puntos en el espacio Euclidiano  $\mathbb{R}^n$ , la distancia entre  $p$  y  $q$  está dada por:

$$\begin{aligned}d(p, q) &= \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \\ &= \sqrt{\sum_{i=1}^n (p_i - q_i)^2}\end{aligned}\tag{2.8}$$

La distancia satisface las siguientes propiedades [8]:

$d(p, q) > 0$	No negatividad
$d(p, q) = d(q, p)$	Simetría
$d(p, q) < d(p, k) + d(k, q)$	Desigualdad Triangular

donde  $p, q$  y  $k$  son puntos en  $\mathbb{R}^n$ . Estas propiedades se ven representadas en la Figura 2.9.

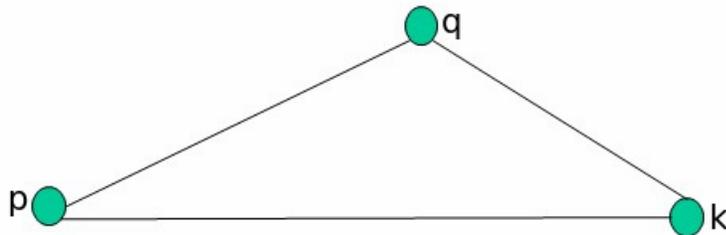


Figura 2.9: Representación gráfica de las propiedades de distancia.

### 2.5.2. Covarianza y correlación

En estadísticas y probabilidades, la covarianza es una medida de la variabilidad conjunta entre dos variables aleatorias. Cuando ambas variables muestran un comportamiento similar,

esto es, los valores de una variables son, aproximadamente, directamente proporcionales a los valores de la otra variables, la covarianza en positiva. En el caso contrario, cuando los valores entre ambas variables muestran un comportamiento indirectamente proporcional, la covarianza es negativa [8].

Sean  $x = (x_1, x_2, \dots, x_n)$  e  $y = (y_1, y_2, \dots, y_n)$  dos variables aleatorias que representan observaciones de dos parámetros distintos, la covarianza entre ellos está dada por:

$$Cov(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (2.9)$$

donde  $n$  es el número de observaciones de cada variable, y  $\bar{x}$  e  $\bar{y}$  son los promedios para los valores de las variables aleatorias  $x$  e  $y$  respectivamente. El promedio de una variable aleatoria  $x$  está dado por:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.10)$$

De manera similar, cuando se trabaja con más de dos parámetros, se define la matriz de covarianza como sigue:

$$V = \frac{D^T D}{n-1} \quad (2.11)$$

donde  $D$  es una matriz de  $n$  filas (observaciones) y  $p$  columnas (parámetros). Cada observación está centrada respecto al promedio de su respectivo vector de parámetro, esto es, cada observación  $i$  (con  $i : 1, 2, \dots, n$ ) de un parámetro  $j$  (con  $j : 1, 2, \dots, p$ ) es de la forma:  $x_{ji} - \bar{x}_j$ . De este modo,  $D$  queda expresado como:

$$D = \begin{bmatrix} (x_{11} - \bar{x}_1) & (x_{21} - \bar{x}_2) & \dots & (x_{j1} - \bar{x}_j) & \dots & (x_{p1} - \bar{x}_p) \\ (x_{12} - \bar{x}_1) & (x_{22} - \bar{x}_2) & \dots & (x_{j2} - \bar{x}_j) & \dots & (x_{p2} - \bar{x}_p) \\ \vdots & \vdots & & \vdots & & \vdots \\ (x_{1i} - \bar{x}_1) & (x_{2i} - \bar{x}_2) & \dots & (x_{ji} - \bar{x}_j) & \dots & (x_{pi} - \bar{x}_p) \\ \vdots & \vdots & & \vdots & & \vdots \\ (x_{1n} - \bar{x}_1) & (x_{2n} - \bar{x}_2) & \dots & (x_{jn} - \bar{x}_j) & \dots & (x_{pn} - \bar{x}_p) \end{bmatrix} \quad (2.12)$$

Los métodos para medir distancias Euclidianas asumen que los parámetros son proporcionales [8], esto es, cada parámetro tiene las misma unidades. Sin embargo, cuando se miden parámetros de distinto tipo (por ejemplo: temperatura, peso y voltaje), no existe una conversión de unidades que permita establecer proporcionalidad. Por lo tanto, cuando los datos no cumplen con esto, se debe llevar a cabo un proceso de estandarización.

El proceso de estandarización, en este caso, consta de dividir cada observación, de un parámetro, por su respectiva desviación estándar. Donde la desviación estándar de un parámetro

$x$ , está dada por:

$$\sigma_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.13)$$

El concepto de correlación incorpora el proceso de estandarización de datos, lo que permite determinar la dependencia de los parámetros a pesar de su discrepancia de unidades. Para dos variables,  $x$  e  $y$ , se escribe la correlación como:

$$Corr(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)\sigma_x\sigma_y} \quad (2.14)$$

Combinando las ecuaciones (2.9) y (2.14), se puede observar que la correlación puede ser interpretada como una "covarianza con datos estandarizados":

$$Corr(x, y) = \frac{cov(x, y)}{\sigma_x\sigma_y} \quad (2.15)$$

Ahora bien, cuando se tienen  $p$  parámetros  $(x_1, x_2, \dots, x_p)$ , es necesario construir una matriz de correlación para poder establecer una comparación entre ellos. Esta matriz queda compuesta, a partir de la ecuación (2.15), de la siguiente manera [8]:

$$C = \begin{bmatrix} \frac{Cov(x_1, x_1)}{\sigma_{x_1}\sigma_{x_1}} & \frac{Cov(x_1, x_2)}{\sigma_{x_1}\sigma_{x_2}} & \dots & \frac{Cov(x_1, x_p)}{\sigma_{x_1}\sigma_{x_p}} \\ \frac{Cov(x_2, x_1)}{\sigma_{x_2}\sigma_{x_1}} & \frac{Cov(x_2, x_2)}{\sigma_{x_2}\sigma_{x_2}} & \dots & \frac{Cov(x_2, x_p)}{\sigma_{x_2}\sigma_{x_p}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{Cov(x_p, x_1)}{\sigma_{x_p}\sigma_{x_1}} & \frac{Cov(x_p, x_2)}{\sigma_{x_p}\sigma_{x_2}} & \dots & \frac{Cov(x_p, x_p)}{\sigma_{x_p}\sigma_{x_p}} \end{bmatrix} \quad (2.16)$$

donde se cumple que  $\frac{Cov(x_i, x_i)}{\sigma_{x_i}\sigma_{x_i}} = 1$  y  $\frac{Cov(x_i, x_j)}{\sigma_{x_i}\sigma_{x_j}} = \frac{Cov(x_j, x_i)}{\sigma_{x_j}\sigma_{x_i}}$ , con  $i, j : (1, 2, \dots, p)$

### 2.5.3. Caracterización del estado de salud

El aprendizaje de un patrón de comportamiento, a partir de un conjunto de observaciones (conjunto de entrenamiento), es un atributo importante, y deseable, dentro de un algoritmo de reconocimiento/clasificación para una tarea de diagnóstico.

Para este propósito, existen cuatro enfoques importantes [8]: Comparación de plantillas (template matching), Concordancia sintáctica o estructural (syntactic or structural matching), Redes Neuronales y clasificación estadística.

## Enfoque de clasificación estadística

Aquí, cada vector (variable aleatoria) está representada por  $p$  parámetros y es considerado un punto, de  $p$  dimensiones, en el espacio de entrada. El objetivo es elegir aquellos parámetros que permiten que los vectores pertenecientes a diferentes categorías (cada parámetro es una categoría) ocupen regiones compactas y disjuntas en el espacio de características.

Dentro del enfoque estadístico existen dos métodos para abordar la tarea de reconocimiento: Métodos paramétricos y métodos no paramétricos. Los primeros, asumen que los datos están asociados a cierta distribución. Por otro lado, los métodos no paramétricos, no realizan ninguna asunción respecto a la distribución de los datos. Estos últimos obtienen sus fortalezas desde los datos (mientras mayor la cantidad, más acertado el método) y sus parámetros, un ejemplo de este tipo de métodos es la Distancia de Mahalanobis.

## Metodología de detección utilizando Distancia de Mahalanobis [8]

La Distancia de Mahalanobis basa su metodología en reducir un sistema multivariable a uno univariable, utilizando la correlación entre los parámetros que componen el espacio multidimensional. Se busca comparar nuevas observaciones, y clasificar su estado, con un conjunto de observaciones iniciales que representan el estado saludable (*baseline*). Este método permite detectar anomalías y tendencias respecto al comportamiento de los parámetros.

En la Figura 2.10 se aprecia un ejemplo de gráfico para valores de la Distancia de Mahalanobis, de cierto set de datos de entrada en un espacio multidimensional, en función del tiempo. Aquí, la zona entre las líneas rojas representa el conjunto de observaciones iniciales que dan cuenta del estado saludable del componente estudiado. A partir de cierto punto, los valores comienzan a sobrepasar esta zona. Esto se puede interpretar como una anomalía del comportamiento de los datos de entrada (parámetros), que se asocia a una desviación de estos en relación al conjunto de datos saludables.

Sea un punto  $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$  en el espacio  $p$ -dimensional, donde cada componente representa la observación  $i$  de cada uno de los  $p$  parámetros. El punto  $Z_i$  representa la normalización (datos centrados en su promedio y divididos por su desviación estándar) de este, y está dado por:

$$Z_i = \frac{x_i - \bar{x}}{\sigma_x} \quad (2.17)$$

Para un punto  $Z_i$  en el espacio  $p$ -dimensional, el valor de la Distancia de Mahalanobis está dado por:

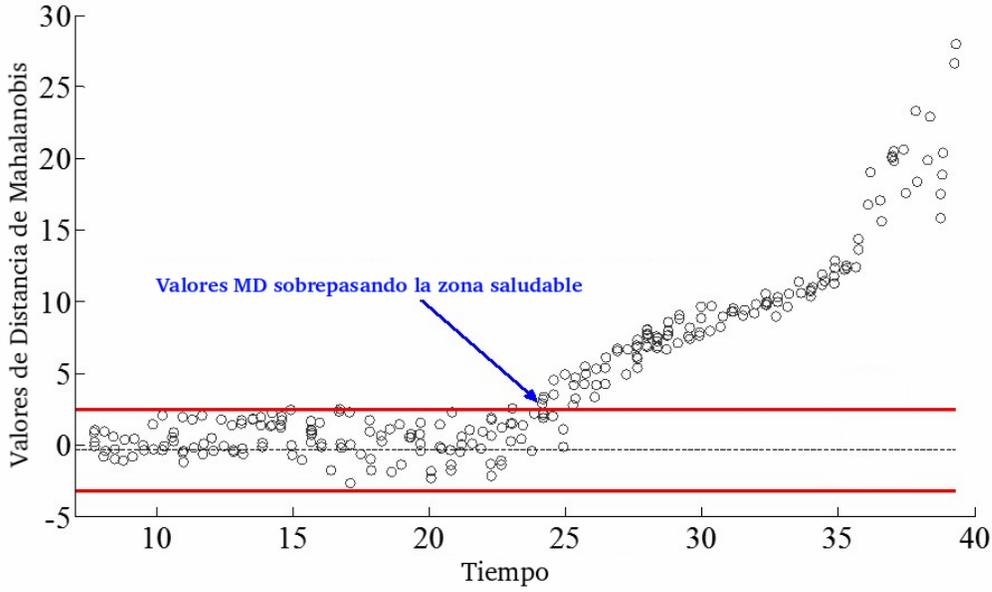


Figura 2.10: Gráfico de Distancia de Mahalanobis en función del tiempo, representación de zona saludable. Modificada de [8].

$$MD_i = \frac{1}{p} Z_i C^{-1} Z_i^T \quad (2.18)$$

donde  $C$  es la matriz de correlación para los  $p$  parámetros (Ver ecuación (2.16)) y  $p$  es el número de parámetros.

## 2.6. Filtro de Partículas

El Filtro de Partículas (FP) es una técnica computacional, también denominada Monte Carlo Secuencial, que utiliza estimaciones Bayesianas recursivas para abordar el problema de filtrado especialmente cuando se trata con procesos no lineales y/o no Gaussianos [2].

Sea  $x_k$  el estado de un sistema en el período de tiempo  $t_k$ . La evolución de este sistema está descrita por el modelo de estado, que se asume conocido:

$$x_k = f_k(x_{k-1}, \omega_{k-1}) \quad (2.19)$$

donde  $f_k : \mathbb{R}^{n_x} \times \mathbb{R}^{n_\omega}$  es una función no lineal del estado  $x_{k-1}$  y  $\{\omega_k, k \in \mathbb{N}\}$  es un vector de ruido de estado con distribución conocida. El objetivo es estimar de manera recursiva  $x_k$  a partir de mediciones:

$$z_k = h_k(x_k, \nu_k) \quad (2.20)$$

con  $h_k : \mathbb{R}^{n_x} \times \mathbb{R}^{n_\nu}$  la función no lineal de medición y  $\{\nu_k, k \in \mathbb{N}\}$  un vector de ruido de medición con distribución conocida. El FP busca estimar el estado dinámico  $x_k$  dadas las mediciones  $z_k$  hasta el tiempo  $k$ , esto es, estimar la distribución de probabilidad condicional:

$$P(x_k | z_{1:k}) \quad (2.21)$$

La probabilidad (2.21) puede ser obtenida, de manera recursiva, en dos etapas: predicción y actualización. La etapa de predicción asume que la función de probabilidad  $P(x_{k-1}|z_{1:k-1})$ , en el período de tiempo  $k-1$ , está disponible y, utilizando la función de estado (2.19), se obtiene la función de probabilidad previa (a priori) del estado en el período de tiempo  $k$  por medio de la ecuación de Champman-Kolmogorov [9][10]:

$$P(x_k|z_{1:k-1}) = \int P(x_k|x_{k-1}, z_{1:k-1}) \cdot P(x_{k-1}|z_{1:k-1}) \cdot dx_{k-1} \quad (2.22)$$

Dado que las mediciones  $\{z_k, k \in \mathbb{N}\}$  son condicionalmente independientes dado el modelo de estado  $\{x_k, k \in \mathbb{N}\}$ , esto es,  $P(x_k|x_{k-1}, z_{1:k-1}) = P(x_k|x_{k-1})$ , la ecuación (2.22) se puede escribir como:

$$P(x_k|z_{1:k-1}) = \int P(x_k|x_{k-1}) \cdot P(x_{k-1}|z_{1:k-1}) \cdot dx_{k-1} \quad (2.23)$$

A continuación, en la etapa de actualización, en el período de tiempo  $k$ , una nueva medición  $z_k$  está disponible. Esta nueva información se utiliza para actualizar la función de probabilidad previa (ecuación (2.23)) y se obtiene la función de probabilidad posterior del estado actual  $x_k$ , mediante la regla de Bayes [10]:

$$P(x_k|z_{1:k}) = \frac{P(z_k|x_k) \cdot P(x_k|z_{1:k-1})}{P(z_k|z_{1:k-1})} \quad (2.24)$$

Donde  $P(z_k|z_{1:k-1}) = \int P(x_k|z_{1:k-1}) \cdot P(z_k|x_k) \cdot dx_k$ , es una constante de normalización. Que a su vez depende del modelo de medición (2.20).

Si bien se llega a una solución, expuesta en la ecuación (2.24), esta no es posible de evaluar analíticamente, debido a que se requiere evaluar integrales complejas de alta dimensionalidad.

El algoritmo del FP comienza asumiendo la disponibilidad de un conjunto de muestras aleatorias (partículas) del estado del sistema en el período de tiempo  $k-1$ ,  $\{x_{k-1}^i, i = 1, \dots, N\}$ , producto de la realización de la función de probabilidad posterior  $P(x_{k-1}|z_{1:k-1})$ .

Luego, se realiza una predicción para el tiempo  $k$ , a partir de la función de probabilidad  $P(x_k|z_{1:k-1})$ , simulando la dinámica del sistema para generar un nuevo conjunto de muestras  $\{x_k^i, i = 1, \dots, N\}$ .

Finalmente, se actualizan los valores de las partículas proyectadas en el tiempo. Esta actualización se realiza en base a las observaciones  $z_k$  colectadas al período de tiempo  $k$ . Lo anteriormente explicado se puede observar en la Figura 2.11.

A cada muestra de partículas es asignado un peso  $w_k^i$ , y así se puede obtener una aproximación de la función de probabilidad posterior  $P(x_k|z_{1:k})$  a partir de las muestras ponderadas:  $\{(x_k^i, w_k^i), i = 1, \dots, N\}$ .

El peso asociado a cada partícula puede ser elegido de distintas maneras, dependiendo del método utilizado en el FP.

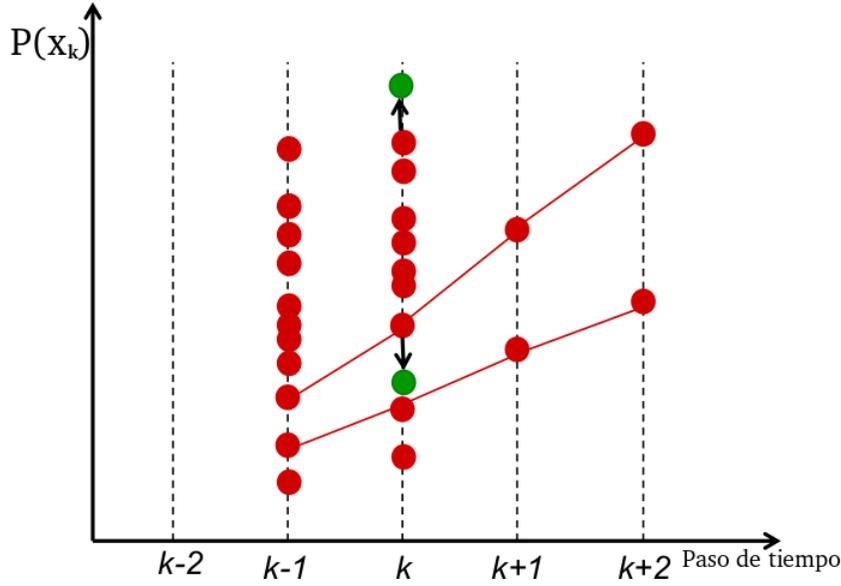


Figura 2.11: Partículas proyectadas (rojas) y actualizadas (verdes). Modificada de [9].

### Muestreo de Importancia Secuencial

El algoritmo de Muestreo de Importancia Secuencial (SIS, por sus siglas en inglés) es un método de Monte Carlo (MC) que forma las bases de la mayoría de filtros de MC secuenciales desarrollados en las últimas décadas [9].

Este algoritmo tiene como fin la representación de la función de probabilidad posterior por medio de un conjunto de muestras aleatorias ponderadas por un peso asociado [9][10]:

$$P(x_k | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_k - x_k^i) \quad (2.25)$$

El peso asociado a cada partícula está determinado por [9][10]:

$$w_k^i \propto w_{k-1}^i \frac{P(z_k | x_k^i) \cdot P(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{k-1}, z_k)} \quad (2.26)$$

donde  $q(\cdot)$  es la densidad de importancia propuesta, con la cual se generan las muestras  $x_k^i \sim q(x_k)$ ,  $i = 1, \dots, N$ .

### Remuestreo

Después de algunas iteraciones, ciertas partículas tendrán un peso despreciable. La variación de los pesos de las partículas crece con el tiempo, por lo que se hace imposible evitar el fenómeno de degeneración. Este fenómeno implica un alto gasto de recursos computacionales en la actualización de partículas cuyo aporte a la aproximación de 2.25 es casi nulo.

La idea del remuestreo consiste en eliminar aquellas partículas con pesos pequeños. Generando un nuevo conjunto  $(x_k^{i*})_{i=1}^N$  por medio del reemplazo de las partículas con pesos menores por aquellas con pesos mayores, tal que  $Pr(x_k^{i*} = x_k^j) = w_k^j$  [9]. Para luego reiniciar los valores de los pesos como  $w_k^i = 1/N$ . De este modo, pasarán el filtro sólo aquellas partículas con mayor probabilidad, asegurando la convergencia del algoritmo sin un gasto innecesario de recursos.

### 2.6.1. Modelos de estado y de medición

El algoritmo de FP asume conocidos el modelo de estado y el modelo de medición. Sin embargo, muchas veces no es posible contar con estos. En casos donde los modelos que correlacionan ciertas variables no han sido explorados, las técnicas de mayor flexibilidad como Support Vector Machine para regresión pueden ser de mucha utilidad para definir una posible dependencia entre estas variables.

## 2.7. Support Vector Machines

Support Vector Machines (SVMs) son métodos de aprendizaje supervisado ampliamente utilizados en reconocimiento de patrones, clasificación de datos y problemas de regresión. Estas *máquinas* son capaces de aprender a partir de datos en la forma de (entrada, salida), llamado conjunto de datos de entrenamiento. A partir de estos, se estiman funciones de mapeo entre los datos de entrada y salida. La función de mapeo puede ser una función de clasificación (SVM) o una función de regresión (*Support Vector Regression, SVR*).

### 2.7.1. Clasificación

Dada una base de datos  $D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$ , con  $\mathbf{x}_i \in \mathbb{R}^p$ , donde  $p$  representa la cantidad de parámetros asociados a la observación  $i$  ( $\forall i \in \{1, 2, \dots, n\}$ ). A cada uno de estos vectores está asociada una etiqueta  $y_i = \pm 1$ , que representa una de dos categorías (por ejemplo: degradado y no degradado).

Los vectores  $\mathbf{x}_i$  definen un espacio de puntos etiquetados conocido como el espacio de entrada (*input space*). El objetivo es encontrar un *hiperplano* de separación entre las categorías que representan a estos puntos. Sin embargo, existe más de una solución para este problema, y tal como se observa en la Figura 2.12, existen varios hiperplanos que pueden separar ambas clases.

La solución óptima se encuentra al maximizar la separación (Margen) entre el hiperplano y los puntos de cada clase. Los puntos que sirven como pivote, aquellos que se encuentran más cercanos al hiperplano, y que a su vez maximizan este, son llamados support vectors. El hiperplano óptimo del ejemplo mostrado en la Figura 2.12, dada la maximización del margen, se muestra representado en la Figura 2.13.

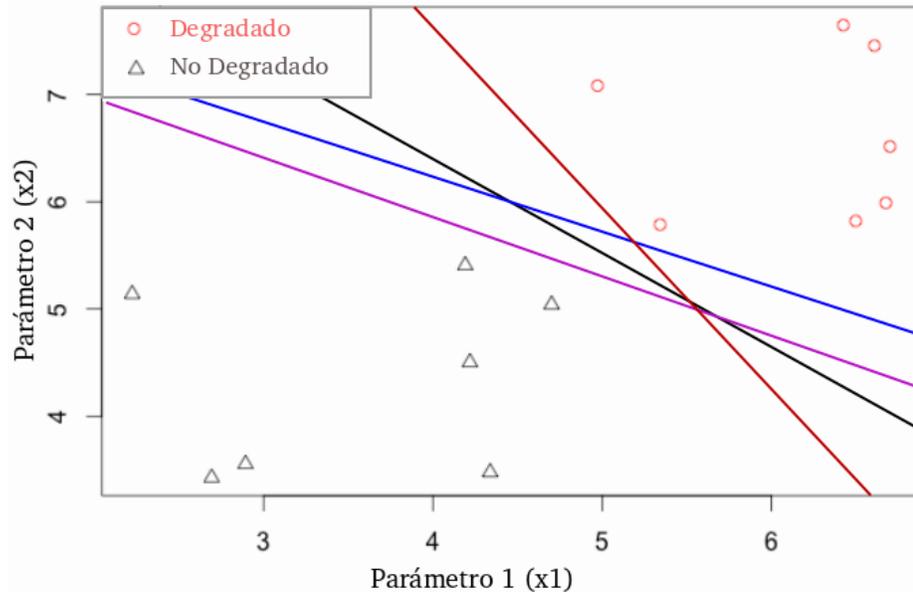


Figura 2.12: Diferentes hiperplanos de separación. Modificada de [11].

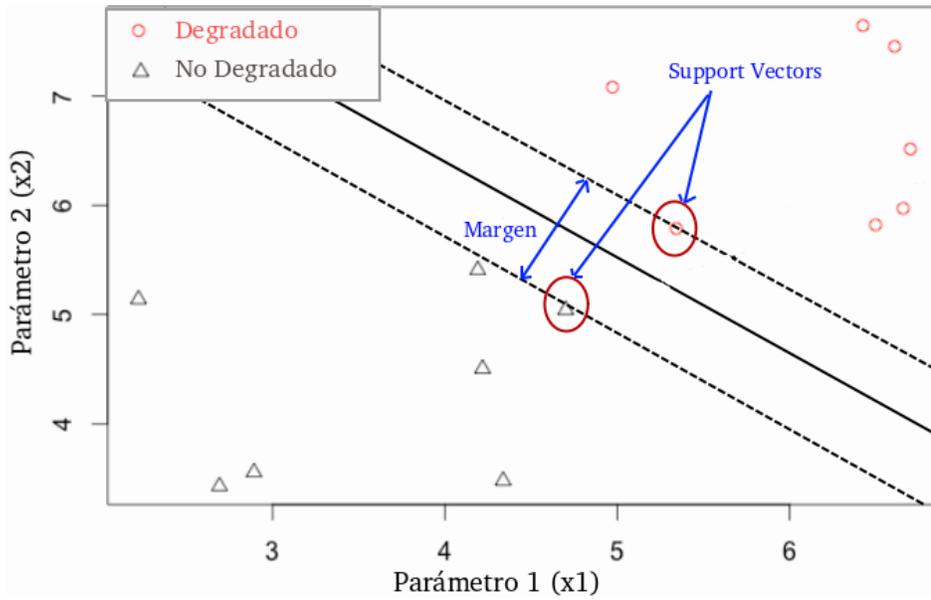


Figura 2.13: Maximización del margen. Modificada de [11].

## Datos linealmente separables

Cuando los datos son linealmente separables, en un espacio dimensional arbitrariamente escogido, se puede utilizar un hiperplano escrito de la forma presentada a continuación:

$$\mathbf{w} \cdot \mathbf{x} + b = 0 \quad (2.27)$$

Aquí  $\mathbf{w}$  es un vector con pesos, que tienen la cualidad de ser normales al hiperplano, por lo tanto determinan la orientación de cada vector de entrada  $\mathbf{x}$  contenido en este,  $(\cdot)$  representa el producto interno ( $\mathbf{w} \cdot \mathbf{x} \equiv \mathbf{w}^T \mathbf{x}$ ), y  $b$  es la desviación del hiperplano respecto al origen en el espacio de entrada.

La función de decisión, para asignar los datos nuevos a una categoría, está dada por:

$$d(\mathbf{x}) = \text{sign}(\mathbf{w} \cdot \mathbf{x} + b) \quad (2.28)$$

Los datos estarán correctamente clasificados cuando  $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) > 0 \forall i$ , dado que  $(\mathbf{w} \cdot \mathbf{x}_i + b)$  es positivo cuando  $y_i = +1$ , y negativo cuando  $y_i = -1$ .

Por otro lado, tenemos que el margen se puede escribir como:

$$M = \frac{2}{\|\mathbf{w}\|} \quad (2.29)$$

De este modo, el problema de maximizar el margen que determina el hiperplano óptimo, para evaluar datos nuevos y clasificarlos en una de las dos categorías, es equivalente al siguiente problema de minimización:

$$\begin{aligned} &\text{minimizar} && \frac{1}{2} \mathbf{w}^T \mathbf{w} \\ &\text{sujeto a:} && y_i[(\mathbf{w} \cdot \mathbf{x}_i) + b] \geq 1 \quad ; i = 1, \dots, n. \end{aligned} \quad (2.30)$$

Este es un problema de programación cuadrática con restricciones de desigualdad, y puede ser resuelto mediante la función de Lagrange (formulación Primal):

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^n \alpha_i \{y_i[\mathbf{w} \cdot \mathbf{x}_i + b] - 1\} \quad (2.31)$$

donde el vector  $\alpha_i$  corresponde a los multiplicadores de Lagrange.

La formulación Dual del problema de optimización presentado en la ecuación (2.31), tomando ventaja del teorema de Karush-Kuhn-Tucker (KKT), está dada por:

$$\begin{aligned}
& \underset{\alpha_i}{\text{maximizar}} && \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \\
& \text{sujeto a:} && \alpha_i \geq 0 && ; i = 1, \dots, n. \\
& && \sum_{i=1}^n \alpha_i y_i = 0 && ; i = 1, \dots, n.
\end{aligned} \tag{2.32}$$

Y tiene como solución  $(\mathbf{w}^*, b^*, \alpha_i^*)$ :

$$\begin{aligned}
\mathbf{w}^* &= \sum_{i=1}^n \alpha_i^* y_i \mathbf{x}_i \\
b^* &= \frac{1}{n_{SV}} \sum_{i=1}^{n_{SV}} (y_i - \mathbf{x}_i \cdot \mathbf{w}_i^*)
\end{aligned} \tag{2.33}$$

donde  $n_{SV}$  es el número de support vectors.

De este modo, aplicando el resultado de la ecuación (2.33) a la ecuación (2.28), el hiperplano óptimo queda determinado por:

$$\begin{aligned}
d(\mathbf{z}) &= \text{sign}[\mathbf{w}^* \cdot \mathbf{z} + b^*] \\
&= \text{sign} \left[ \sum_{i=1}^n \alpha_i^* y_i (\mathbf{x}_i \cdot \mathbf{z}) + b^* \right]
\end{aligned} \tag{2.34}$$

siendo  $\mathbf{z}$  un dato de entrada nuevo (no participa del entrenamiento del SVM).

### Datos linealmente separables con margen flexible

Si bien el objetivo es clasificar correctamente todos los datos, cuando se trabaja con una cantidad muy grande, es conveniente flexibilizar el algoritmo permitiendo cierta holgura, controlada, a la hora de imponer una función de decisión. De esta forma, se seleccionará un margen que, además de cumplir con las características mencionadas en la sección anterior, permitirá que ciertos puntos caigan dentro del margen, e incluso, algunos de ellos, caigan dentro de la clasificación contraria.

Cuando se le otorga esta flexibilidad al algoritmo, la ecuación (2.32) no tiene solución, dado que los puntos superpuestos no pueden ser correctamente clasificados. Un punto  $\mathbf{x}_i$  mal clasificado tiene un gran impacto en la función de decisión, dado que este intenta ser clasificado de manera correcta, lo que hace que el correspondiente multiplicador de Lagrange tienda al infinito ( $\alpha_i \rightarrow \infty$ ).

La medida de la distancia, de los puntos que cruzan el margen, desde la zona correspondiente a su correcta clasificación, está determinada por las variables de holgura ( $\xi_i$ ). Se tienen distintas situaciones, tal como se ilustra en la la Figura 2.14.

Cuando un punto queda contenido en el límite del margen ( $x_4$ ), la variable de holgura correspondiente ( $\xi_4$ ) tendrá un valor igual a 0, esto es,  $x_4$  es un support vector. En el caso de que el punto quede contenido dentro del margen, pero no pase del hiperplano de separación, como sucede con  $x_3$ , el valor de la variable de holgura cumplirá con  $0 \leq \xi_3 \leq 1$ . Ahora bien, cuando el punto traspase el hiperplano de separación, podemos tener dos casos. El primero, consta en que el punto quede contenido dentro del margen,  $x_1$ , este caso es llamado clasificación incorrecta positiva, y la variable de holgura cumple con  $\xi_1 = 1 - d(\mathbf{x}_1) > 1$ , dado que  $d(\mathbf{x}_1) < 0$ . Y el segundo caso, corresponde a aquellos puntos que cruzan hasta la zona de la clasificación contraria, como ocurre con  $x_2$ , este caso es llamado clasificación incorrecta negativa, y la variable de holgura cumple con  $\xi_2 = 1 + d(\mathbf{x}_2) > 1$ , ya que  $d(\mathbf{x}_2) > 0$ .

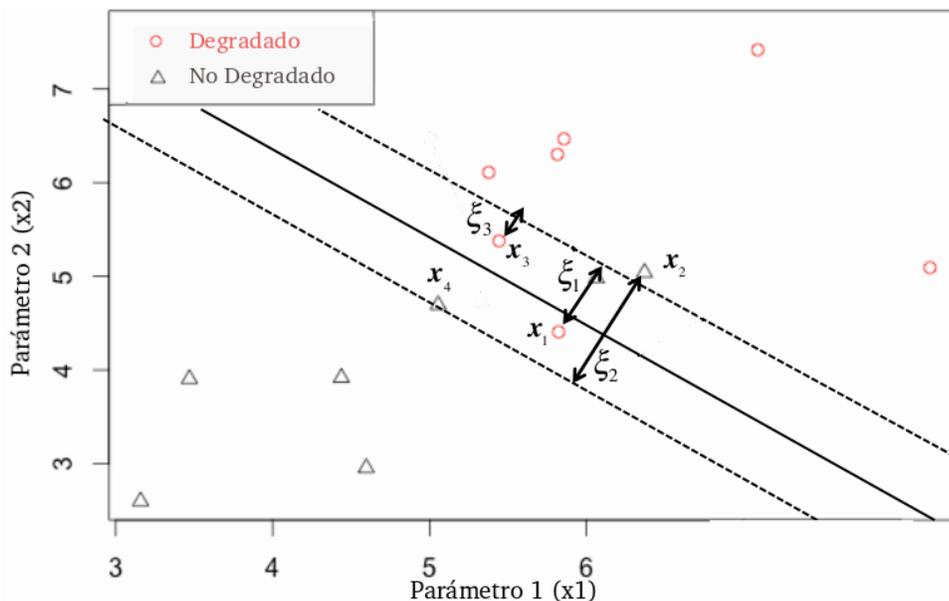


Figura 2.14: Margen flexible y variables de holgura. Modificada de [11].

De este modo, el hiperplano de separación, para el caso de margen flexible, queda determinado por:

$$\begin{aligned}
 &\text{minimizar} && \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + C \sum_{i=1}^n \xi_i \\
 &\text{sujeto a:} && y_i [(\mathbf{w} \cdot \mathbf{x}_i) + b] \geq 1 - \xi_i \quad ; i = 1, \dots, n. \\
 &&& \xi_i \geq 0 \quad ; i = 1, \dots, n.
 \end{aligned} \tag{2.35}$$

donde  $C$  es un parámetro de penalización que determina el ancho del margen.

Para valores altos del parámetro  $C$ , se tiene como resultado un número pequeño de errores de clasificación, valores altos para  $\mathbf{w}^T \cdot \mathbf{w}$  y, por tanto, un margen de menor longitud. Hacer que  $C \rightarrow \infty$  requiere que el número de errores de clasificación sea cero, lo cual no es posible para datos superpuestos (no linealmente separables).

Al igual que lo resuelto para la ecuación (2.30), el problema de optimización en la ecuación (2.35) tiene una formulación Dual, que se obtiene a partir de la aplicación del Lagrangiano, y está dada por:

$$\begin{aligned}
& \underset{\alpha_i}{\text{maximizar}} && \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \\
\text{sujeto a:} &&& 0 \leq \alpha_i \leq C && ; i = 1, \dots, n. \\
&&& \sum_{i=1}^n \alpha_i y_i = 0 && ; i = 1, \dots, n.
\end{aligned} \tag{2.36}$$

### Datos no linealmente separables con margen flexible

Cuando los datos de entrada no son separables linealmente, se utiliza el *Método Kernel*. Este método consiste en utilizar funciones Kernel no lineales para llevar los datos de entrada a un espacio de características (*Feature Space*) de mayor dimensiones, en el cual sí es posible realizar una separación lineal de estos datos. En la Figura 2.15 se representa el traslado de los datos de entrada, no separables linealmente, a otro espacio de mayor dimensión, donde sí son separables linealmente, por medio de una función no lineal  $\phi$ .

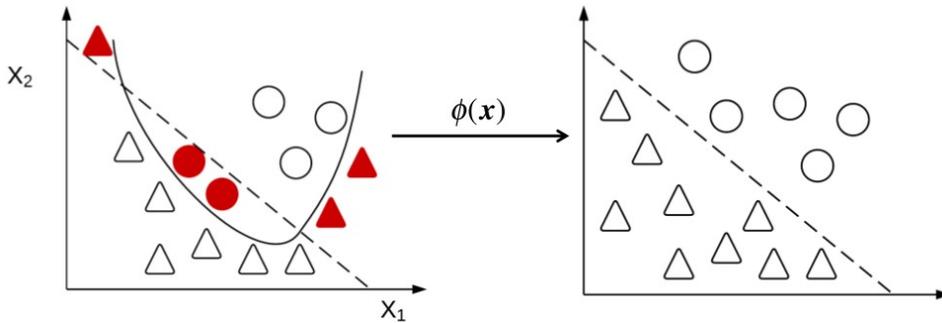


Figura 2.15: Mapeo de los datos, del espacio de entrada hacia el espacio de características. Obtenida de [11].

El objetivo es que el SVM logre crear una *hipersuperficie* (hiperplano en un espacio de mayor dimensiones) para clasificar datos no lineales. Esto se logra considerando un clasificador lineal en el espacio de características.

Considerando la formulación Dual presentada en la ecuación (2.36), se observa que los datos de entrada  $\mathbf{x}_i$  sólo aparecen dentro del producto interno. Una mejor representación de los datos se puede obtener al mapear estos a un espacio alternativo de mayor dimensión, como sigue:

$$\mathbf{x}_i \cdot \mathbf{x}_j \longrightarrow \phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j) \tag{2.37}$$

Este espacio de características debe ser un *Espacio de Hilbert*, y por tanto debe cumplir con que el producto interno esté definido dentro del mismo espacio de características.

Para una función de mapeo  $\phi$ , desde el espacio de entrada hacia algún espacio de características, la función Kernel para dos vectores,  $\mathbf{x}_i$  y  $\mathbf{x}_j$ , es el producto interno de sus imágenes

en el espacio de características:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j) \quad (2.38)$$

Existen varias funciones Kernel, y por lo tanto el Espacio de Hilbert será distinto para cada una de estas. Los Kernels comúnmente utilizados en SVMs [12] se presentan a continuación:

- Kernel lineal:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (2.39)$$

- Kernel polinomial:

$$K(\mathbf{x}_i, \mathbf{x}_j) = (s \cdot \langle \mathbf{x}_i, \mathbf{x}_j \rangle + o)^d \quad (2.40)$$

donde  $s$  es un parámetro de escala,  $o$  es un parámetro de compensación y  $d$  es el grado.

- Kernel de Función de Base Radial (RBF) Gaussiana :

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (2.41)$$

con  $\gamma = \frac{1}{2\sigma^2}$ , y  $\sigma$  un parámetro libre.

- Kernel de Función de Base Radial (RBF) de Laplace :

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|) \quad (2.42)$$

Los Kernel RBF Gaussiano y de Laplace son Kernels de propósito general, son muy utilizados en el caso de no haber información previa de los datos. El Kernel lineal es útil cuando se tiene gran cantidad de datos dispersos, como es el caso de la clasificación de texto. Y el Kernel polinomial es popular en procesamiento de imágenes [12].

Al trabajar en un espacio de características de mayor dimensión, aplicando el método de Kernel, el problema Dual de la ecuación (2.36), queda de la siguiente manera:

$$\begin{aligned} \text{maximizar}_{\alpha_i} \quad & \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i \cdot \mathbf{x}_j) \\ \text{sujeto a:} \quad & 0 \leq \alpha_i \leq C \quad ; i = 1, \dots, n. \\ & \sum_{i=1}^n \alpha_i y_i = 0 \quad ; i = 1, \dots, n. \end{aligned} \quad (2.43)$$

Y entonces, la función de decisión queda determinada por:

$$d(\mathbf{z}) = \text{sign} \left[ \sum_{i=1}^n \alpha_i^* y_i K(\mathbf{x}_i, \mathbf{z}) + b^* \right] \quad (2.44)$$

### 2.7.2. Support Vector Regression

SVMs también es aplicable a problemas de regresión, este algoritmo es llamado Support Vector Regression (SVR). Este mantiene todas las propiedades principales que caracterizan al algoritmo de SVM para clasificación, en particular, se busca la maximización del margen. Esto sucede cuando se logra estimar una función no lineal a partir del entrenamiento de un modelo lineal generado en un espacio de características de mayor dimensión, inducido por funciones Kernel.

Del mismo modo que con el enfoque utilizado para clasificación, el objetivo es buscar y optimizar el margen que determina las distancias de los valores generados por la regresión y los valores objetivos. Este margen se basa en la definición de la función de pérdida (*loss function*) que ignora algunos puntos que se sitúan a cierta distancia de los valores reales. Este tipo de funciones son conocidas como "funciones de pérdida  $\varepsilon$ -concentradas". La Figura 2.16 muestra una regresión no lineal con bandas  $\varepsilon$ -concentradas en un espacio bidimensional. Las variables  $\xi$  miden el costo asociado a errores de los puntos de entrenamiento que van más allá del error permitido por las bandas.

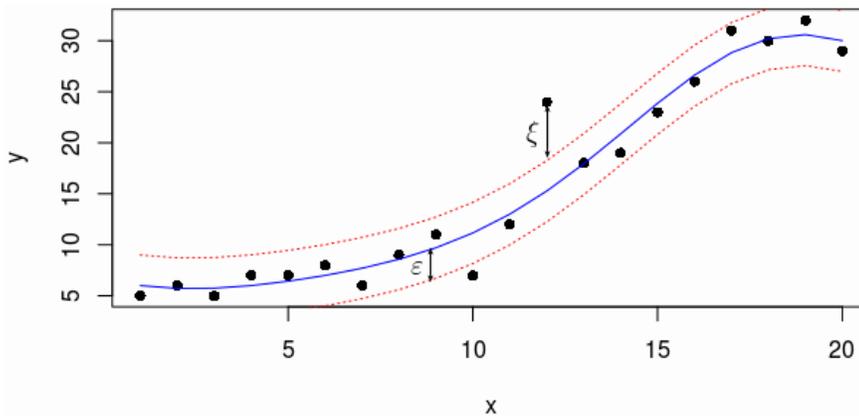


Figura 2.16: Regresión no lineal en dos dimensiones con bandas  $\varepsilon$ -concentradas.

En la Figura 2.17 se aprecia el mapeo, por medio de una función no lineal  $\phi$ , desde el espacio de entrada (imagen de la izquierda) hacia el espacio de características de mayor dimensión (imagen del centro), donde se genera el modelo de regresión lineal. La función de pérdida (imagen de la derecha) está determinada por los valores de las variables  $\xi_i$  y  $\xi_i^*$ .

En SVR, los valores de entrada  $\mathbf{x}$  primero son mapeados a un espacio de características  $p$ -dimensional (con  $p$  el número de parámetros que definen a cada punto  $\mathbf{x}$ ) utilizando alguna función no lineal  $\phi$ , y luego un modelo lineal se construye en este espacio de características. Este modelo lineal  $f(\mathbf{x})$  está dado por:

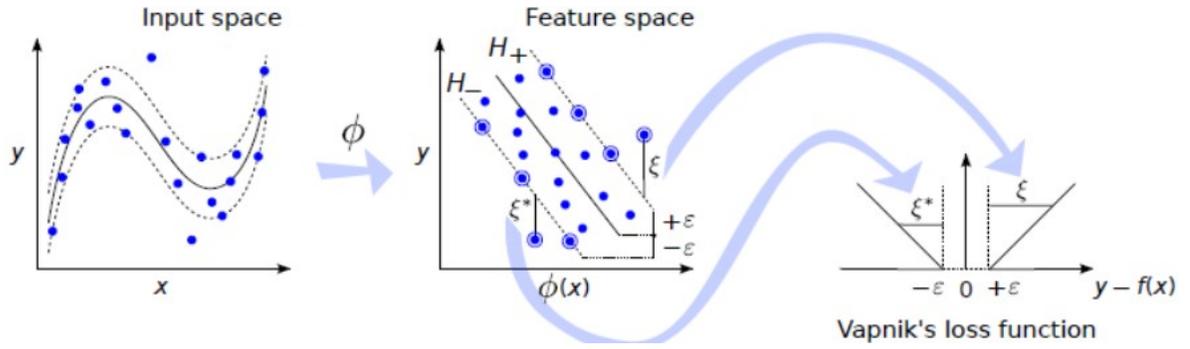


Figura 2.17: Espacio de características y parámetros de ajuste de SVR. Obtenida de [4].

$$f(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b \quad (2.45)$$

La constante  $b$  es un término que da cuenta de la desviación de los datos. Por lo general se asume que los datos poseen un promedio igual a cero (esto se puede lograr mediante un pre-procesamiento), y entonces el término de desviación puede ser desechado.

La calidad de la estimación es medida mediante la función de pérdida  $L(y, f(\mathbf{x}))$ . En particular, en SVR, se suele utilizar un tipo de función de pérdida llamada función de pérdida  $\varepsilon$ -concentrada [13]:

$$L_\varepsilon(y, f(\mathbf{x})) = \begin{cases} 0, & \text{si } |y - f(\mathbf{x})| \leq \varepsilon \\ |y - f(\mathbf{x})| - \varepsilon, & \text{si } |y - f(\mathbf{x})| > \varepsilon \end{cases} \quad (2.46)$$

Al mismo tiempo que se genera la regresión lineal en el espacio de características, SVR trata de reducir la complejidad del problema maximizando el margen, y entonces minimizando  $w^T w$ . Esto se puede representar mediante la inclusión de variables de holgura no negativas  $\xi_i$  y  $\xi_i^*$ , con  $i = 1, 2, \dots, n$ , para medir la desviación de los datos de entrenamiento por fuera de las bandas  $\varepsilon$ -concentradas. De este modo, SVR se formula como un problema de optimización dado por:

$$\begin{aligned} & \underset{\mathbf{w}, \xi, \xi^*}{\text{minimizar}} && \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ & \text{sujeto a:} && y_i - \mathbf{w}^T \phi(\mathbf{x}_i) - b \leq \varepsilon + \xi_i \quad ; i = 1, \dots, n. \\ & && \mathbf{w}^T \phi(\mathbf{x}_i) + b - y_i \leq \varepsilon + \xi_i^* \quad ; i = 1, \dots, n. \\ & && \xi_i, \xi_i^* \geq 0 \quad ; i = 1, \dots, n. \end{aligned} \quad (2.47)$$

La correspondiente formulación Dual de este problema, está dada por:

$$\begin{aligned}
& \underset{\alpha, \alpha^*}{\text{maximizar}} && \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(\mathbf{x}_i, \mathbf{x}_j) - \sum_{i=1}^n [\varepsilon(\alpha_i + \alpha_i^*) + y_i(\alpha_i - \alpha_i^*)] \\
& \text{sujeto a:} && \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\
& && 0 \leq \alpha_i^* \leq C; i = 1, \dots, n.
\end{aligned} \tag{2.48}$$

Y este, tiene como solución la función de regresión dada por:

$$\begin{aligned}
f(\mathbf{z}) &= \mathbf{w}^T \phi(\mathbf{z}) + b \\
&= \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{z}) + b
\end{aligned} \tag{2.49}$$

## Métricas de error

Para cada observación  $\mathbf{x}_i$  el modelo de regresión generado por el SVR entrega una predicción  $\hat{y}_i$ . Con el fin de medir la certeza del modelo, es necesario medir el error de estas predicciones. De este modo, la diferencia entre los valores predichos y los valores objetivos ( $\hat{y}_i - y_i$ ), asociados a cada observación ( $\mathbf{x}_i$ ), da cuenta de la precisión del modelo.

Una forma común de medir el error en modelos de predicción, es el uso del Error Cuadrático Medio de la Raíz o *RMSE* (por sus siglas en inglés). Este se define como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \tag{2.50}$$

# Capítulo 3

## Definición del problema

### 3.1. Antecedentes

El problema a abordar consiste en la caracterización de la evolución del daño en una bomba centrífuga, una de las máquinas rotativas más utilizadas en la industria. Esta bomba es testeada de manera controlada bajo condiciones de laboratorio, midiendo datos de emisiones acústicas a lo largo del tiempo de operación. Además, en forma simultánea, se miden datos de voltaje, corriente, flujo de agua y diferencia de presión de la bomba, con el fin de monitorear la eficiencia de la misma. El procedimiento se realiza de manera continua durante la operación de la máquina, hasta la falla, y se lleva a cabo en las dependencias de la Universidad de Maryland (UMD), Maryland, Estados Unidos.

#### 3.1.1. Bomba centrífuga

La bomba utilizada corresponde a una bomba centrífuga Jabsco [15] (ver Figura 3.1), perteneciente a la serie 50840 de Bombas Centrífugas de Baja Presión. Esta es una bomba centrífuga de acero inoxidable de propósito general, diseñada específicamente para el mercado industrial y marítimo. Las aplicaciones típicas serían para aplicaciones de circulación tales como sistemas de agua caliente, vivero o instalaciones de tanques de carnada. La vida útil nominal del motor es de 3.500 horas, posee un levantamiento de succión de 2 metros de altura y temperaturas de fluido aceptadas de  $+4^{\circ}\text{C}$  (mínima) y  $+95^{\circ}\text{C}$  (máxima).



Figura 3.1: Bomba centrífuga Jabsco 50840-0012. Obtenida de [15]

### 3.1.2. Modos de falla más comunes de la bomba centrífuga

Dado que la bomba centrífuga es uno de los tipos de bomba más utilizados en el mundo, sus parámetros de operación tanto como sus vulnerabilidades son bien conocidos. En particular, se conocen los modos de falla más comunes de este tipo de máquinas, y se pueden agrupar en tres categorías [16]:

#### Modos de falla hidráulicos

- Cavitación
- Pulsaciones de presión
- Recirculación de la bomba
- Empuje radial y axial

#### Modos de falla mecánicos

- Ruptura del eje
- Falla de cojinetes
- Falla de sellos
- Fatiga

#### Otros modos de falla

- Erosión
- Corrosión

El objetivo de este trabajo no es determinar el modo de falla presentado por la bomba, sino, más bien, busca detectar cualquier tipo de signo que se pueda asociar a una desviación de las condiciones de operación esperadas. De este modo, se cuenta con tres sensores de EA ubicados en diferentes partes de la bomba. La información recolectada por estos sensores

se procesa de forma conjunta dado que previamente no se conoce el lugar del cual podrían provenir aquellas señales que den cuenta de la degradación.

### 3.1.3. Sensores de EA

Se utilizan sensores miniatura de EA Micro30 [17] (Ver Figura 3.2) de Physical Acoustic Corporation (PAC), para medir actividad continua de este fenómeno en la bomba. Estos sensores son seleccionados debido a su buena respuesta en frecuencia en el rango de 150-400 kHz, y buena sensibilidad a las señales de EA incluso en presencia de alto ruido de fondo.



Figura 3.2: Sensor de EA miniatura Micro30 . Obtenida de [17]

## 3.2. Montaje experimental

La bomba es expuesta a agua de mar a alta temperatura ( $70^{\circ}$ ,  $80^{\circ}\text{C}$ ) en un circuito cerrado. El banco de pruebas, mostrado en la Figura 3.3, y que está representado por el esquema de la Figura 3.4, consta de dos ciclos principales: 1) un ciclo de calentamiento para elevar la temperatura del fluido, que está compuesto de una bomba de circulación, un calentador de inmersión de titanio en línea, y una cubierta y un intercambiador de calor de titanio; 2) un ciclo de testeo para exponer a la bomba a condiciones extremas de operación, este circuito está compuesto por la bomba bajo estudio y sensores para la adquisición de los datos deseados.



Figura 3.3: Banco de pruebas.

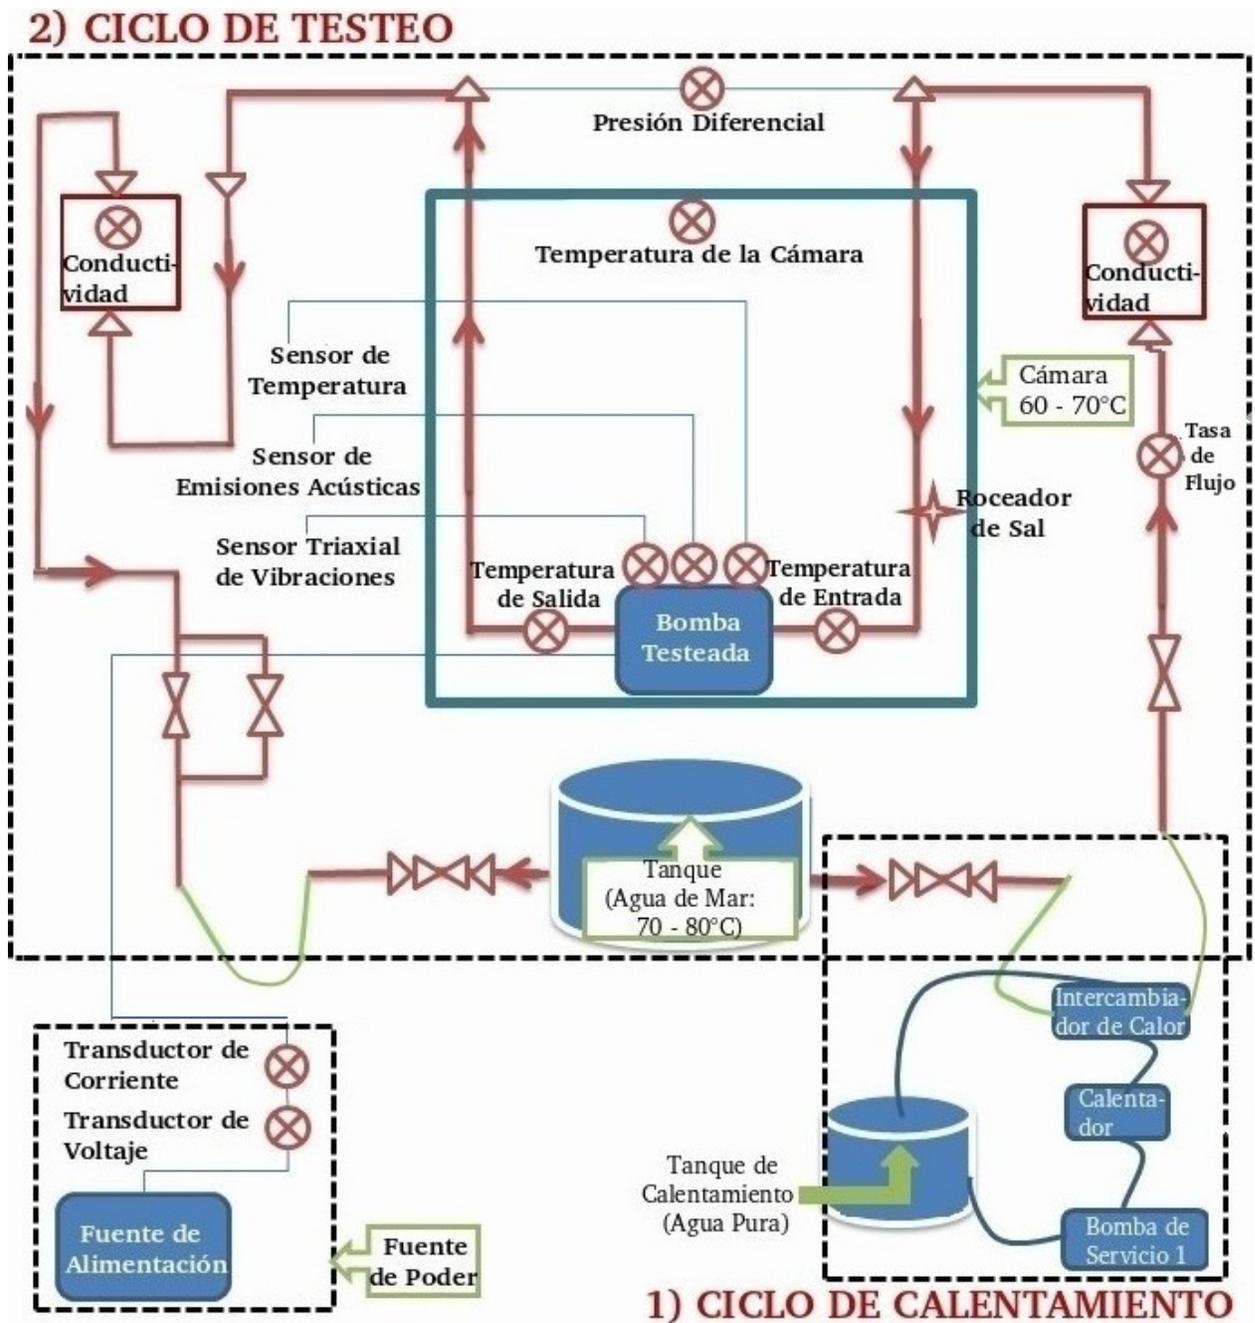


Figura 3.4: Esquema de la configuración del banco de pruebas.

El modelo de diagnóstico se basa en el análisis de las Emisiones Acústicas obtenidas del monitoreo de estas bombas. En efecto, tres sensores de EA Micro30 son utilizados para medir actividad continua de EA. Estos tres sensores son montados en las zonas de succión (Canal 1), descarga (Canal 2) y motor eléctrico (Canal 3) de la bomba, tal como se muestra en la Figura 3.5. Se utiliza grasa de litio (*lithium-thickened grease*) para fijar los sensores de EA a la superficie de la bomba.

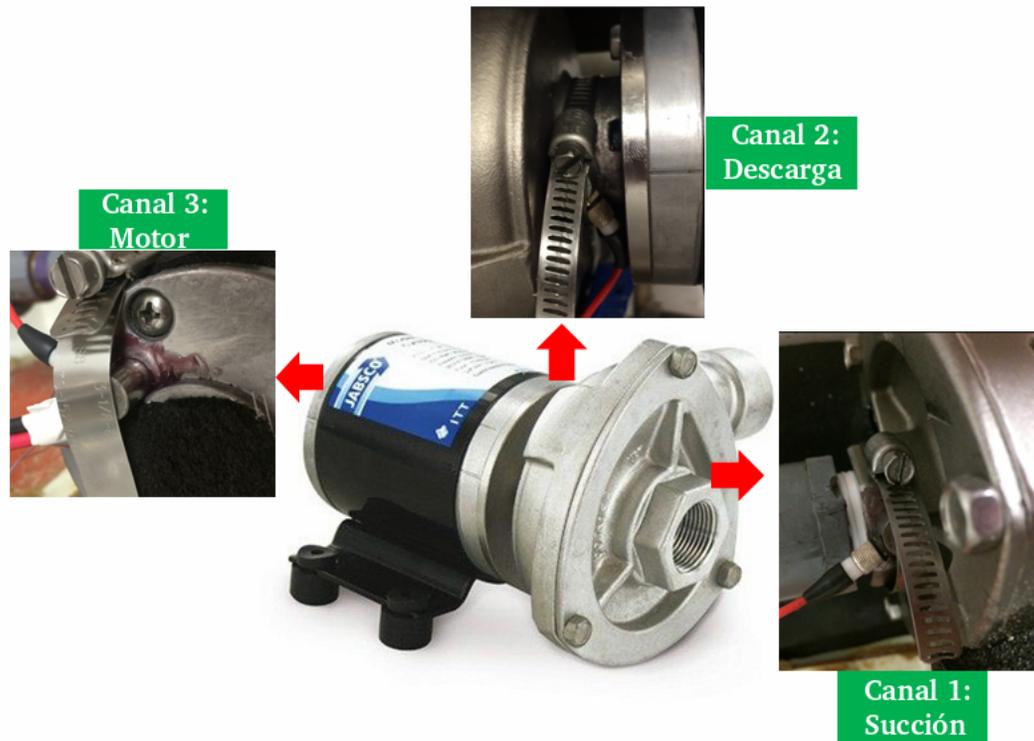


Figura 3.5: Ubicación de sensores de EA en bomba centrífuga.

La señal de EA de salida es pre-amplificada a 40 dB y es incorporada mediante un Sistema de Adquisición de Datos comercial implementado por PAC. Las señales amplificadas se introducen luego en un sistema de monitoreo de AE comercial con una forma compacta para proporcionar hasta 8 canales de AE de alta velocidad simultáneamente.

### 3.3. Adquisición de datos

Se mide actividad continua de EA a una tasa de muestreo de 1 MHz durante todo el período de operación de la bomba testeada. Esta se mantuvo en operación durante 81 días.

Los parámetros de las señales de EA son medidos de manera simultánea, junto con los datos brutos de EA, por el sistema de adquisición de señales. Así mismo, los datos de voltaje, corriente, tasa de flujo de agua y diferencia de presión de la bomba son obtenidos en forma paralela por medio de los instrumentos especificados en la Figura 3.4.

Los datos de EA como los parámetros respectivos, además de los datos de voltaje, corriente, tasa de flujo de agua y diferencia de presión de la bomba son proporcionados por el Profesor Guía, y el trabajo se limita sólo a la manipulación de estos mediante herramientas computacionales.

# Capítulo 4

## Implementación del modelo de diagnóstico

### 4.1. Mirada general del algoritmo

Como se ha mencionado en las secciones previas, se busca realizar un diagnóstico del estado de degradación de una bomba, cuando aún no existen signos visibles de que esta está ocurriendo. Para lo anterior, es necesario identificar y medir algún tipo de variación en las propiedades del componente que den cuenta de la evolución de la degradación.

#### 4.1.1. Definición del precursor de daño

En este caso, se utilizan las Emisiones Acústicas (EA) como el Precursor de Daño (PD) que da cuenta de la degradación que ocurre de manera imperceptible.

No existe un modelo que relacione las EA con la degradación. Sin embargo, con la aplicación del concepto de la Distancia de Mahalanobis (DM), es posible construir un índice de daño utilizando los parámetros de las señales de EA. Además, conocido el momento en que la máquina falla, se puede calcular un parámetro de daño normalizado, entre 0 y 1. Siendo 0 el valor asociado al instante inicial de operación, y 1 el valor del daño que indica la falla de la bomba.

El proceso de degradación, así como las variables involucradas en este, se representan en una Red Bayesiana Dinámica.

#### 4.1.2. Red Bayesiana Dinámica (RBD)

La Figura 4.1 representa la RBD que modela la evolución de la degradación de la bomba. Aquí se muestran todas las variables consideradas dentro de este proceso, y la dependencia entre ellas. La evolución de la degradación resulta en variaciones de la señal de emisiones acústicas (EA), que pueden ser medidas de manera continua durante la operación de la

máquina y, por medio de la DM, se puede calcular un índice de degradación representativo de la evolución del daño oculto. Por otro lado, por medio de múltiples sensores, es posible medir una serie de variables utilizadas para calcular la eficiencia de la bomba. Esta, se utiliza para caracterizar la degradación ( $D$ ).

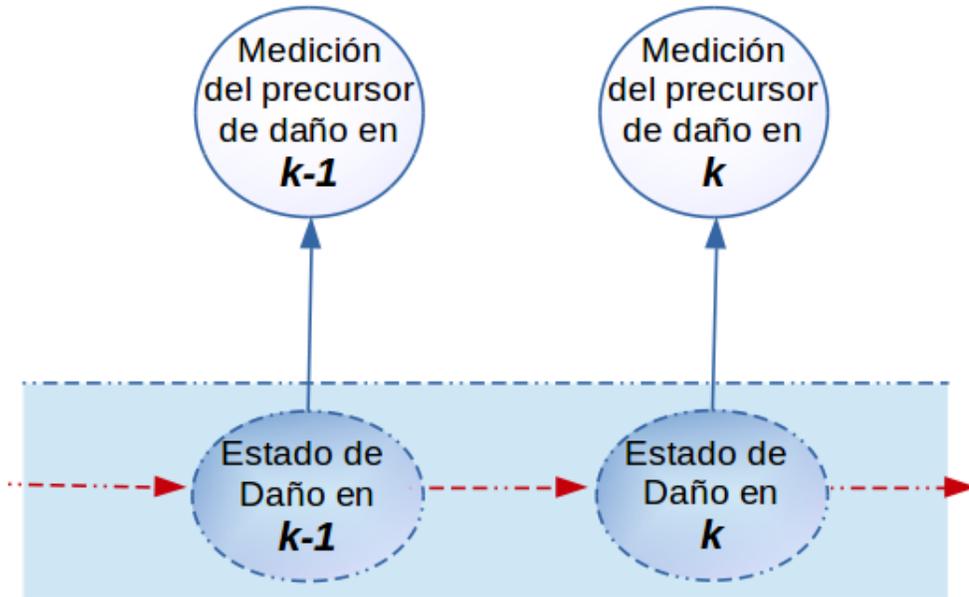


Figura 4.1: Red Bayesiana Dinámica que representa la evolución del daño en la bomba, considerando el mecanismo de degradación no visible.

Una vez determinada la estructura de la RBD, es necesario definir las dependencias entre cada variable para luego realizar el proceso de inferencia en el Filtro de Partículas. Cada flecha en la Figura 4.1 representa un probabilidad condicional entre nodos que debe ser modelada por medio de modelos físico o modelos basados en datos. De este modo, cada probabilidad condicional,  $P(D_k|D_{k-1})$  y  $P(AE_k|D_k)$ , debe ser proporcionada de manera explícita para cada período de tiempo  $k$ .

### 4.1.3. Inferencia en la RBD utilizando Filtro de Partículas

Para realizar una inferencia acerca de la variable oculta (daño  $D$ ) en la RBD, los modelos de estado y de medición necesitan ser identificados.

#### Modelo de estado

El modelo de estado caracteriza la dinámica del estado de la bomba en el tiempo. En otras palabras, relaciona el estado actual de degradación (en período de tiempo  $k$ ), con el estado anterior (período de tiempo  $k - 1$ ).

Se utiliza un modelo basado en datos, en particular, se utilizan los valores de la eficiencia de la bomba en el tiempo. Por medio de la DM, aplicada a los parámetros estadísticos obtenidos de los datos de eficiencia, se genera un índice que da cuenta de la degradación que sufre la máquina.

De los valores de la DM obtenidos, en función del tiempo, se realiza una serie de regresiones para relacionar estos datos, de tal manera de seleccionar aquel modelo que presente un mejor ajuste respecto al resto. Dado que se necesita determinar esta función para cada período de tiempo  $k$ , es necesario generar una versión discretizada de la regresión. Para aquello, se utiliza la fórmula [2]:

$$D_k = D_{k-1} + \frac{\delta D}{\delta t}|_{k-1} \cdot \delta t \cdot \exp(\omega_k) \quad (4.1)$$

donde  $D$  es el polinomio obtenido de la regresión y  $e^{\omega_k}$  es el ruido Gausiano que representa el comportamiento aleatorio del modelo de estado. Esta fórmula es válida para un  $\delta t$  pequeño, para este caso se toma igual a 1 hora (respecto a los 81 días de operación).

## Modelo de medición

El modelo de medición permite conocer la probabilidad de obtener un determinado valor de las EA medidas, dado el daño oculto (conocido el modelo de estado) en ese mismo período de tiempo. Este modelo se utiliza para actualizar la predicción del estado de degradación realizada mediante el modelo de estado.

En este caso, dado que no existe un modelo que correlacione ambas variables, se realiza una regresión mediante el algoritmo de Support Vector Regression. Así, el modelo de medición se puede escribir como:

$$P(AE_k|D_k) = \text{SVR}(AE_k \sim D_k) \quad (4.2)$$

## Esquema detallado de la RBD

En la Figura 4.2 se presenta una RBD especificando todas las variables consideradas. En esta se puede observar la relación entre cada una de las variables dentro del proceso de degradación, así como los términos que dan cuenta del carácter aleatorio de cada modelo. En este caso,  $\omega$  es el ruido Gausiano asociado a la adquisición de EA.

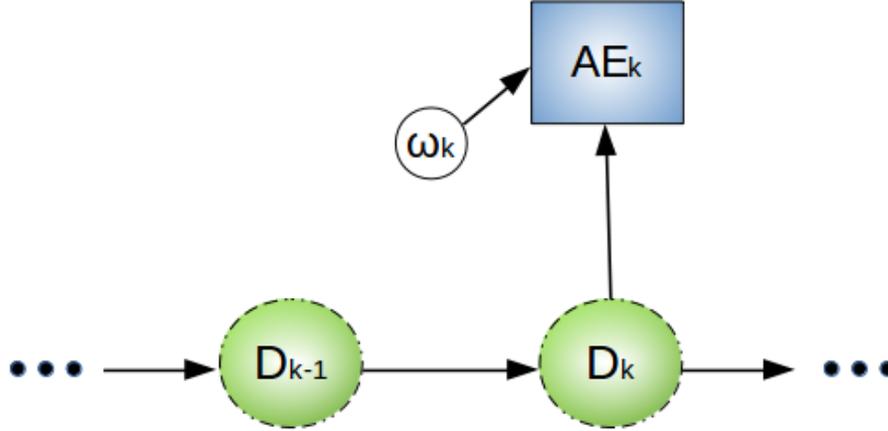


Figura 4.2: RBD detallada de la evolución del daño en la bomba.

## 4.2. Herramientas utilizadas

Para la realización de este trabajo se utilizó de manera exclusiva el software **R**. Este es un entorno y lenguaje computacional gratuito para la computación estadística y gráfica. En particular se utiliza **R** versión 3.3.3 en sistema operativo Ubuntu 16.04 LTS.

Dentro de **R** se utilizan los paquetes 'readr', 'EMD', 'hht' y 'e1071'. El primero proporciona una herramienta efectiva para leer (importar) archivos "rectangulares", en particular, archivos de texto (.txt), hojas de cálculo Microsoft® Excel 97-2003 (.xls) y archivos de datos tabulados separados por comas (.csv). El segundo y tercer paquete funcionan de manera conjunta en la implementación de la Descomposición Modal Empírica. Y el cuarto provee las herramientas necesarias para la implementación de SVR en **R**. Todos estos son de carácter gratuito.

El computador utilizado para el completo desarrollo del trabajo, cuenta con un procesador Intel® Core™ i5-3230M CPU @ 2.60GHz x 4 y 7,7 [GiB] de memoria RAM.

## 4.3. Consideraciones respecto a los archivos de datos

Antes de presentar la implementación propiamente tal del código, se hace necesario considerar ciertos aspectos de estructura y orden para lograr facilitar la comprensión del mismo.

### 4.3.1. Estructura de archivos

Los datos proporcionados por el Profesor Guía corresponden a los parámetros de señales de EA y a una serie de variables, especificadas en la Sección 3.2. Estas últimas son utilizadas para el cálculo de la eficiencia de la bomba.

### Eficiencia de la bomba

La información necesaria para calcular la eficiencia de la bomba está contenida en archivos *.xls*. Cada archivo posee la información correspondiente a un día de operación de la bomba, por lo que se cuenta con un total de 81 archivos de este tipo (nombrados por el día correspondiente: "01.xls", "02.xls", etc.). Estas hojas de cálculo poseen la información de todas las variables medidas, a excepción de las de EA, durante la operación de la bomba centrífuga. Cada columna representa una variable distinta, mientras que cada fila da cuenta de una observación medida.

La primera columna es el tiempo, este representa la hora en que se realiza cada una de las mediciones de las variables. Posee un formato de: hh:mm:ss, y va desde la hora 00:00:00 hasta la hora 23:59:58, con una diferencia entre medición de 2 segundos, esto es, 30 observaciones por minuto, sumando un total de 43.200 observaciones diarias. La cantidad de observaciones es la misma para todas las variables.

Las restantes variables medidas en el banco de pruebas (Ver Figura 3.4), representadas por cada columna de los archivos *.xls*, de izquierda a derecha, son:

- Temperatura de soporte del motor.
- Temperatura de carcasa trasera del motor.
- Tasa de flujo de la bomba.
- Voltaje, medido en transductor de voltaje.
- Corriente, medido en transductor de corriente.
- Presión diferencial de la bomba.
- Temperatura 1 de la cámara.
- Temperatura 2 de la cámara.
- Conductividad de salida.
- Temperatura de salida del ciclo de prueba.
- Temperatura de entrada al ciclo de prueba.
- Conductividad de entrada.

- Temperatura ambiente de la habitación.
- Temperatura de carcasa superior del motor.
- Temperatura de salida de la bomba.
- Temperatura de entrada a la bomba.
- Temperatura de entrada al tanque de agua de mar.
- Temperatura de salida del tanque de agua de mar.

Cabe destacar que el archivo del primer día ("01.xls") es diferente del resto. En la primera fila se tienen los nombres de cada variable, mientras en la segunda se observan las medidas utilizadas para cada una. Desde la tercera fila en adelante sólo se ven los valores de las diferentes variables. Desde el archivo del segundo día en adelante, en todas las filas sólo se observan valores respectivos a cada medición.

La eficiencia de la bomba se calcula de la siguiente manera:

$$\eta = 1 - \frac{\Delta P \cdot Q}{V \cdot I} \quad (4.3)$$

donde  $\Delta P$  es la diferencia de presión entre la entrada y la salida de la bomba,  $Q$  es el caudal, o tasa de flujo, de agua, y  $V$  e  $I$  son el voltaje y la corriente, respectivamente, con que se alimenta la bomba. El numerador, en el término de la derecha en (4.3), representa las variables de salida, mientras el denominador da cuenta de las variables de entrada de la bomba.

De este modo, sólo se desea contar con las columnas 4, 5, 6 y 7 de los archivos .xls, además de la primera columna que indica la hora de cada medición.

## Parámetros de EA

Son tres los sensores de EA instalados en la máquina, y cada uno de estos captura las señales y, de manera simultánea, los parámetros de: Energía (*ENER*), valor cuadrático medio (*RMS*), nivel promedio de la señal (*ASL*), potencia de la señal (*SIGSTR*) y energía absoluta (*ABSEN*) de EA.

Estos datos están almacenados en archivos .txt y se encuentran separados por sensor (canales 1, 2 y 3). Poseen la siguiente estructura:

Date, Time, ENER, RMS, ASL, SIGSTR, ABSEN

mm/dd/yy, hhM:mm:ss.ssssss, EEEE, M.MMMM, AA, SSSSSSSS, BBBBBBBB

En total se cuenta con tres archivos de texto, estos se presentan en la Tabla 4.1.

Tabla 4.1: Archivos de texto con información de parámetros de EA

Canal 1	AEfeature_CH1.txt
Canal 2	AEfeature_CH2.txt
Canal 3	AEfeature_CH3.txt

La bomba se mantuvo en operación durante 81 días. Es necesario mencionar que cada canal extrae una cantidad distinta de datos. Sin embargo, la diferencia es mínima respecto a la cantidad total de datos obtenidos. Las horas de medición de cada sensor, con la respectiva cantidad de observaciones capturadas por estos, se tabulan en la Tabla 4.2.

Tabla 4.2: Total de observaciones por canal

Canal	1	2	3
Total de horas medidas	1.954,013	1.954,011	1.954,012
Total de observaciones	586.195	586.129	586.174

Con las anteriores consideraciones, y para mantener archivos de largos uniformes, se opta por normalizar el número de datos, esto es, los tres canales de la bomba se dejan con la misma cantidad de observaciones. La cantidad de horas efectivas consideradas, con la respectiva cantidad de observaciones asociadas, se muestran en la Tabla 4.3.

Tabla 4.3: Horas y observaciones consideradas para los 3 canales

Horas efectivas consideradas	1.952,679
Número de observaciones	586.000

## 4.4. Preprocesamiento de datos

Los sensores de EA poseen una tasa de muestreo de 1 Mhz. De manera simultánea, los parámetros de EA son calculados, dentro del sistema de adquisición de señales, a una tasa de muestreo de 5 mediciones por minuto. Por otro lado, las demás variables son medidas cada 2 segundos, esto es, con una tasa de muestreo de 30 observaciones por minuto.

### 4.4.1. Eficiencia de la bomba

Utilizando el software **R**, se importan los 81 archivos *.xls* con la información de las variables necesarias para el cálculo de la eficiencia, y se genera una matriz con la información de los 81 días. El primer paso es el cálculo de la eficiencia, para esto se utiliza la ecuación (4.3) y como resultado se obtiene una matriz con dos columnas, la primera representa la hora de medición y la segunda da cuenta de la eficiencia asociada.

La estrategia es monitorear el comportamiento de la eficiencia en el tiempo, buscando variaciones en el valor medio o algún otro parámetro que pueda dar cuenta de esto, utilizando la DM.

## Parámetros estadísticos de la eficiencia

Los parámetros extraídos de los datos de eficiencia son los siguientes:

- Valor medio: Entrega el valor promedio de los datos en un período de tiempo, se define como:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.4)$$

- Desviación estándar: Da cuenta de la variación o dispersión de un conjunto de datos, está dada por:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1}} \quad (4.5)$$

- Amplitud de pico a pico: Define al rango en que se mueven las mediciones, se calcula como la diferencia entre el máximo y el mínimo de los valores:

$$x_{p-p} = \max x_i - \min x_i \quad (4.6)$$

- Valor RMS: Es el promedio cuadrático de los datos en un intervalo de tiempo, está dado por:

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4.7)$$

- Factor de cresta (CF): Es la razón entre la amplitud máxima y el valor RMS:

$$CF = \frac{x_p}{x_{RMS}} \quad (4.8)$$

donde  $x_p = \max x_i$ , es el valor máximo de las mediciones.

- Factor de forma (SF): Es la razón entre el valor RMS y el promedio:

$$SF = \frac{x_{RMS}}{\bar{x}} \quad (4.9)$$

Utilizando las ecuaciones anteriormente presentadas, se calculan los parámetros para los valores de eficiencia dentro de un período de 1 hora. De este modo, se tiene una tasa de muestreo de 1 observación por hora para estos valores.

Finalmente, se genera un archivo de datos *.csv* con la información de los parámetros estadísticos de la eficiencia, llamado *features\_eff.csv*, que luego será utilizada para el cálculo de la DM.

#### 4.4.2. Parámetros de EA

Utilizando el software **R**, se importan los archivos de texto presentados en la Tabla 4.1. A continuación, se genera una matriz de 16 columnas, con los datos de todos los canales. La primera columna representa la hora de medición, de la segunda a la sexta columna se tienen los parámetros de EA del canal 1, y las 10 columnas restantes representan a los parámetros de EA de los canales 2 y 3 respectivamente.

Con la idea de igualar el número de mediciones a la de los datos de eficiencia, se toma el valor promedio de los parámetros de EA en un período de una hora. Finalmente se genera un archivo de datos, llamado *features\_ae.csv*, con la información antes descrita.

De este modo, se cuenta con dos archivos *.csv* con la información de los parámetros estadísticos de la eficiencia y los parámetros de EA. Todos con una tasa de muestreo de 1 observación por hora, esto es, 1.944 mediciones a lo largo de los 81 días de operación de la bomba.

### 4.5. Rutinas principales

Antes de explicar cada una de las rutinas que conforman el algoritmo, con el fin de tener una mejor comprensión del mismo, en la Figura 4.3 se presenta un esquema del flujo general de este. Se diferencian los archivos de entrada y/o generados (en rectángulos), los modelos generados (en cilindros) y los archivos **R** (en óvalos). El algoritmo se puede dividir en dos grandes bloques. El primero, correspondiente al preprocesamiento, explicado en la sección anterior. Y el segundo, contiene las rutinas principales, descritas en las siguientes secciones.

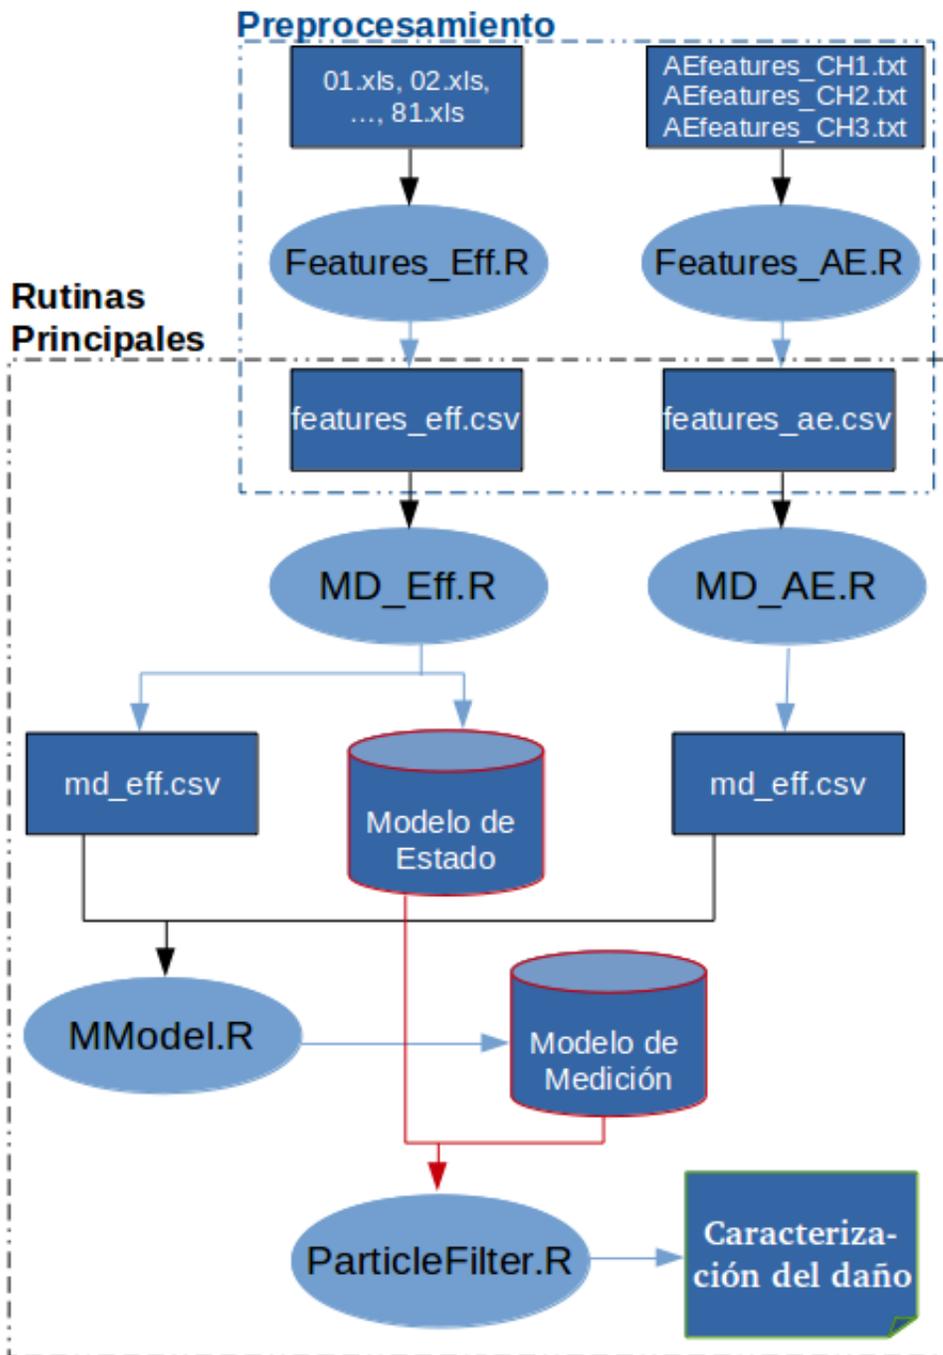


Figura 4.3: Flujo del algoritmo para generar diagnóstico

## 4.6. Distancia de Mahalanobis

Como se mencionó en la Sección 2.5.3, la DM mide la desviación de los datos respecto a una línea base. Esta da cuenta de observaciones en un período temprano de operación de la máquina, y se asocian a un estado sin degradación de la misma.

Se considera aceptable tomar los primeros 10 días (240 horas) de operación como un período donde el componente no sufre mayor degradación bajo las condiciones de operación mencionadas en el capítulo previo.

De este modo, se dividen los datos en dos subconjuntos. El primero, contiene las primeras 240 observaciones, que representa los puntos de la línea base. Y el otro, con las 1.704 observaciones restantes, contiene los puntos que serán comparados al período saludable.

El conjunto de datos  $D$ , posee la siguiente estructura:

$$D = \begin{bmatrix} P_{11} & P_{21} & \dots & P_{j1} & \dots & P_{p1} \\ P_{12} & P_{22} & \dots & P_{j2} & \dots & P_{p2} \\ \vdots & \vdots & & \vdots & & \vdots \\ P_{1i} & P_{2i} & \dots & P_{ji} & \dots & P_{pi} \\ \vdots & \vdots & & \vdots & & \vdots \\ P_{1n} & P_{2n} & \dots & P_{jn} & \dots & P_{pn} \end{bmatrix} \quad (4.10)$$

donde cada columna representa un parámetro y cada fila representa una observación.

De tal forma de tener mediciones comparables, se debe normalizar cada punto. De esta manera, el conjunto de datos normalizados queda como:

$$Z_{-}D = \begin{bmatrix} \frac{P_{11}-\bar{P}_1}{\sigma_1} & \frac{P_{21}-\bar{P}_2}{\sigma_2} & \dots & \frac{P_{j1}-\bar{P}_j}{\sigma_j} & \dots & \frac{P_{p1}-\bar{P}_p}{\sigma_p} \\ \frac{P_{12}-\bar{P}_1}{\sigma_1} & \frac{P_{22}-\bar{P}_2}{\sigma_2} & \dots & \frac{P_{j2}-\bar{P}_j}{\sigma_j} & \dots & \frac{P_{p2}-\bar{P}_p}{\sigma_p} \\ \vdots & \vdots & & \vdots & & \vdots \\ \frac{P_{1i}-\bar{P}_1}{\sigma_1} & \frac{P_{2i}-\bar{P}_2}{\sigma_2} & \dots & \frac{P_{ji}-\bar{P}_j}{\sigma_j} & \dots & \frac{P_{pi}-\bar{P}_p}{\sigma_p} \\ \vdots & \vdots & & \vdots & & \vdots \\ \frac{P_{1n}-\bar{P}_1}{\sigma_1} & \frac{P_{2n}-\bar{P}_2}{\sigma_2} & \dots & \frac{P_{jn}-\bar{P}_j}{\sigma_j} & \dots & \frac{P_{pn}-\bar{P}_p}{\sigma_p} \end{bmatrix} \quad (4.11)$$

Y la Distancia de Mahalanobis se calcula utilizando la ecuación (2.18):

$$MD = \frac{1}{p} ZC^{-1}Z^T$$

donde  $Z$  es una observación normalizada de dimensión  $p$ ,  $C$  es la matriz de correlación entre los parámetros y  $p$  es el número de parámetros.

Todos estos procedimientos son realizados mediante la utilización de las operaciones matemáticas incorporadas en el software **R**. A continuación se necesita calcular la matriz de

correlación entre los parámetros, esta se obtiene por medio de una función interna del mismo software, y basta darle como datos de entrada la matriz de datos normalizados antes obtenida.

El mismo procedimiento se realiza para los valores que no don parte del conjunto saludable. Sin embargo, dado que se busca comparar los datos con la línea base, se utiliza la misma matriz de correlación obtenida de las primeras observaciones.

A continuación se grafican los valores de la DM de cada observación en función del tiempo. Sin embargo, debido al ruido propio de las mediciones, es necesario aplicar alguna técnica computacional que permita obtener la tendencia general de estos. Para este propósito, se aplica el método de Descomposición Modal Empírica (DME). Este permite descomponer la señal en sus funciones básicas (funciones de modo intrínseco), así como obtener el valor residual que da cuenta de la tendencia general de los datos. Se utilizan las funciones EEMD y EEMDCompile, que utilizan como dato de entrada los valores de la DM previamente calculada.

### 4.6.1. Eficiencia

Para el cálculo de la DM para la eficiencia, que da cuenta de la degradación de la bomba, se realiza el procedimiento descrito anteriormente utilizando los parámetros calculados en la etapa de preprocesamiento, importados del archivo *features\_eff.csv*. De este modo, cada observación tendrá la forma:

$$\{P_{\bar{x}}, P_{\sigma}, P_{x_{p-p}}, P_{x_{RMS}}, P_{CF}, P_{SF}\}$$

### Modelo de estado

Para generar el modelo de estado se utilizan los valores de la DM en función del tiempo. Se realiza un análisis de sensibilidad en búsqueda de una regresión que logre representar de buena manera la correlación de estos datos. Para este propósito se utiliza la función **lm** en **R** para generar las distintas regresiones a comparar. En el siguiente extracto de código se presenta el cálculo de las regresiones:

---

#### Código 4.1 Extracto de código R: Generación de regresiones

---

```
m2 <- lm ( trend ~ t + I ( t ^ 2 ) )
m3 <- lm ( trend ~ t + I ( t ^ 2 ) + I ( t ^ 3 ) )
m4 <- lm ( trend ~ t + I ( t ^ 2 ) + I ( t ^ 3 ) + I ( t ^ 4 ) )
m5 <- lm ( trend ~ t + I ( t ^ 2 ) + I ( t ^ 3 ) + I ( t ^ 4 ) + I ( t ^ 5 ) )
m6 <- lm ( trend ~ t + I ( t ^ 2 ) + I ( t ^ 3 ) + I ( t ^ 4 ) + I ( t ^ 5 ) + I ( t ^ 6 ) )
m7 <- lm ( trend ~ t + I ( t ^ 2 ) + I ( t ^ 3 ) + I ( t ^ 4 ) + I ( t ^ 5 ) + I ( t ^ 6 ) + I ( t ^ 7 ) )
m8 <- lm ( trend ~ t + I ( t ^ 2 ) + I ( t ^ 3 ) + I ( t ^ 4 ) + I ( t ^ 5 ) + I ( t ^ 6 ) + I ( t ^ 7 )
                                                + I ( t ^ 8 ) )
```

---

Para evaluar el desempeño de cada modelo, se utilizan varias métricas de error. Para el cálculo de estas métricas, dentro de **R**, se utiliza el paquete 'MLmetrics'. Este contiene distintas funciones para realizar estos cálculos, en particular se utilizan las métricas de error: Coeficiente de determinación ( $R^2$ ), Error Absoluto Promedio (MAE), Error Absoluto Mediano (MAD), Error Cuadrático Medio (RMSE), Error Cuadrático Relativo (RRSE).

---

**Código 4.2** Extracto de código R: Cálculo de métricas de error

---

```
r2.m2 <- R2_Score(predict(m2), trend)
mae.m2 <- MAE(predict(m2), trend)
mdae.m2 <- MedianAE(predict(m2), trend)
rmse.m2 <- RMSE(predict(m2), trend)
rrse.m2 <- RRSE(predict(m2), trend)
```

---

En el extracto de código anterior, se calculan las métricas de error antes mencionadas para el modelo 2, regresión cuadrática. El cálculo para los restantes modelos es idéntico. Así, es posible observar la variación del valor de cada métrica de error, para cada regresión. De este modo, se selecciona aquella regresión que no presente una variación notoria respecto a la regresión de grado inmediatamente menor, con el fin de no elegir un modelo sobre ajustado.

De este modo, se logra obtener una función que modele el estado de degradación en el tiempo. Sin embargo, es necesario obtener una función definida en cada instante de tiempo  $k$ , por lo que se hace necesario construir una versión discretizada de la regresión. Esta se obtiene a partir de la ecuación (4.1), lo que implica derivar el polinomio escogido anteriormente. Este cálculo, dentro del software utilizado, se presenta a continuación:

---

**Código 4.3** Extracto de código R: Versión discreta de la regresión

---

```
c<-m7$coefficients

x<-c[1]+c[2]*t+c[3]*t^2+c[4]*t^3+c[5]*t^4+c[6]*t^5
                                     +c[7]*t^6

dx<-x+c[2]+2*c[3]*t+3*c[4]*t^2+4*c[5]*t^3+5*c[6]*t^4
                                     +6*c[7]*t^5
```

---

Aquí **c** es un vector que contiene los coeficientes de la regresión Reg, y dx es la versión discretizada de la misma.

## 4.6.2. Emisiones Acústicas

De antemano se desconoce la fuente que podría estar causando la degradación (y por tanto el lugar donde ocurre), por esto se considera apropiado analizar de manera conjunta los datos aportados por los tres sensores de EA, para medir la degradación.

Para señales de EA continuas, los parámetros más utilizados son *RMS* y *ASL* [7][18]. Por esta razón, se utilizan sólo estos para el cálculo de la DM, importados del archivo *features\_ae.csv*. De este modo, cada observación tendrá la forma:

$$\{P_{RMS_{ch1}}, P_{RMS_{ch2}}, P_{RMS_{ch3}}, P_{ASL_{ch1}}, P_{ASL_{ch2}}, P_{ASL_{ch3}}\}$$

## 4.7. Modelo de medición

El modelo de medición relaciona las EA, variable observable, con la degradación, dada por la eficiencia. De antemano, no existe un modelo conocido que relacione ambas variables mencionadas. Por este motivo, se utiliza la técnica de Support Vector Regression (SVR), la que genera una regresión no lineal entre los datos de EA y eficiencia. Este cálculo se presenta en el extracto de código mostrado a continuación:

---

**Código 4.4** Extracto de código R: SVR entre valores MD de eficiencia y EA

---

```
svr <- svm (md.Eff, md.AE)

tune.svr <- tune (svm, md.Eff, md.AE,
                 ranges =
                   list (epsilon = seq (0.002, 0.005, 0.001),
                          cost = 2 ^ (7:9)))

svr.tuned <- tune.svr$best.model

svr.tuned.y <- predict (svr.tuned)

svr.tuned.error <- md.AE - svr.tuned.y

svr.tuned.rmse <- rmse (svr.tuned.error)
```

---

Para esta tarea se utiliza el método `svm`, perteneciente al paquete 'e1071' del software **R**, y que necesita como datos de entrada los valores de la DM calculados de la eficiencia (`md.Eff`) y de las EA (`md.AE`). Con el fin de encontrar los parámetros óptimos para el cálculo del SVR que mejor correlacione ambas variables, se utiliza la función `tune`. Esta función analiza diferentes modelos para el SVR, utilizando las combinaciones de los parámetros `epsilon` y `cost`, dadas por los rangos especificados. Y, por último, se valida el modelo por medio del cálculo del valor RMSE entre los valores generados por el SVR y los reales.

## 4.8. Filtro de partículas

El Filtro de Partículas (FP) realiza una estimación del estado de degradación de la bomba, de manera recursiva, dentro de la Red Bayesiana Dinámica, utilizando los modelos de estado y de medición antes obtenidos.

El objetivo del FP es determinar el estado actual de degradación ( $D_k$ ) de la máquina, a partir de las mediciones de EA ( $AE_k$ ) realizadas hasta el momento. En otras palabras, se busca calcular la probabilidad condicional de:

$$P(D_k | AE_{1:k}) \quad (4.12)$$

El FP busca estimar de manera aproximada el valor de esta probabilidad condicional, por medio de un conjunto de partículas ponderadas.

### 4.8.1. Algoritmo utilizado en el FP

El primer paso es asumir disponible un conjunto de muestras (partículas) aleatorias  $x_{k-1}^i$ ,  $i = 1, \dots, N$  del estado de la máquina en el período de tiempo  $k - 1$ , producto de la realización de  $P(x_{k-1} | y_{1:k-1})$ . En este caso, se comienza asumiendo que la degradación en el tiempo  $t = 0$  es muy cercana a 0 (sin degradación).

A continuación, se realiza una predicción del estado de degradación en el período de tiempo  $k$ . Esto se lleva a cabo por medio del modelo de estado, evaluando cada una de las  $N$  partículas anteriormente generadas, simulando la evolución de la degradación.

Ahora se tiene un conjunto de partículas  $x_k^i$ , en el período de tiempo  $k$ . Con el fin de mejorar la predicción realizada en el paso anterior, cada partícula es evaluada utilizando el modelo de medición, que asocia el estado actual a la medición del mismo período. Así, se actualiza el valor anteriormente obtenido. De este mismo modo, a cada partícula se le asocia un peso ( $w_k^i$ ) que da cuenta de la semejanza de los valores pronosticados con los valores actualizados. De este modo, aquellas partículas con valores más cercanos a los valores reales del estado, tendrán pesos mayores.

Después de algunas iteraciones, algunas partículas tendrán pesos despreciables. Por este motivo, se aplica el método de remuestreo. Este consiste en ignorar las partículas con bajos pesos y enfocarse en aquellas de mayor. Así, en cada iteración, se debe generar un nuevo conjunto de partículas  $x_k^{i*}$ ,  $i = 1, \dots, N$ . Este nuevo conjunto de  $N$  partículas es obtenido de los estados con mayor probabilidad, tal que:  $Pr(x_k^{i*} = x_k^i) = w_k^i$ . En otras palabras, las  $N$  partículas se distribuirán en las "zonas" de los estados con mayores pesos. Estas nuevas partículas deben ser reiniciadas, otorgándoles un mismo peso a cada una ( $w_k^i = 1/N$ ) con tal de no influir en la siguiente iteración.

Finalmente, se puede realizar una aproximación de (4.12), a partir del conjunto de partículas y sus pesos respectivos, utilizando la ecuación (2.25):

$$P(x_k | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_k - x_k^i) \quad (4.13)$$

# Capítulo 5

## Discusión de resultados

### 5.1. Generación del índice de daño

Se utiliza la eficiencia de la bomba como un indicador indirecto del daño que sufre la bomba a lo largo del tiempo. El cálculo de la eficiencia se realiza a partir de las distintas variables medidas durante la operación de la bomba, tal como se describe en el capítulo previo. Luego, se calculan algunos parámetros estadísticos (ver Sección 4.4.1) con el fin de monitorear el comportamiento de la eficiencia en el tiempo.

En la Figura 5.1 se presentan los parámetros estadísticos de la eficiencia utilizados para determinar el comportamiento de esta. Sólo se utilizan aquellos parámetros que muestran una clara tendencia. Los parámetros restantes se presentan en el Anexo A.1 .

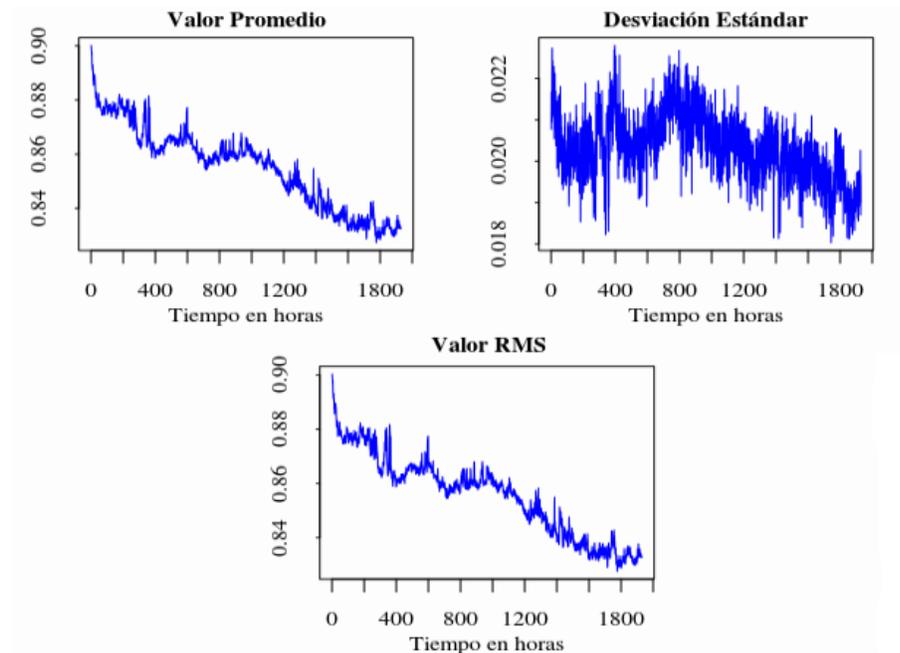


Figura 5.1: Parámetros estadísticos de la eficiencia y su comportamiento en el tiempo.

Se puede apreciar claramente el comportamiento general de los parámetros medidos. En particular, el valor promedio de la eficiencia (esquina superior izquierda) decae a medida que pasa el tiempo, tal como se espera que suceda producto de la degradación del componente.

A continuación se aplica la Distancia de Mahalanobis en relación a las primeras 240 horas de operación para construir el índice de degradación. Se utilizan los 3 parámetros de la eficiencia, mostrados anteriormente, como datos de entrada y se obtiene el gráfico mostrado en la Figura 5.2.

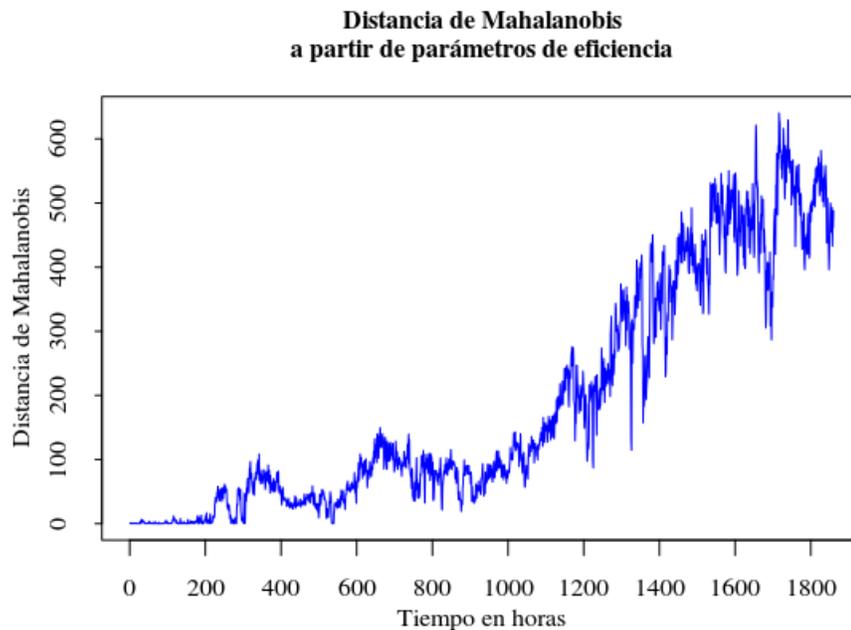


Figura 5.2: Distancia de Mahalanobis calculada a partir de los parámetros de eficiencia de la bomba.

Aquí, es posible apreciar una clara diferencia entre los valores iniciales, que representan al estado sin degradación, y los valores posteriores. Si bien existe una tendencia que indica un crecimiento sostenido en el tiempo, esta presenta variaciones.

Con el objetivo de extraer la tendencia de los valores de la DM, se aplica el método de Descomposición Modal Empírica (DME). Además, se normalizan los valores entre 0 y 1, para representar la degradación sufrida desde un estado sin degradación hasta la falla. El resultado se muestra en la Figura 5.3.

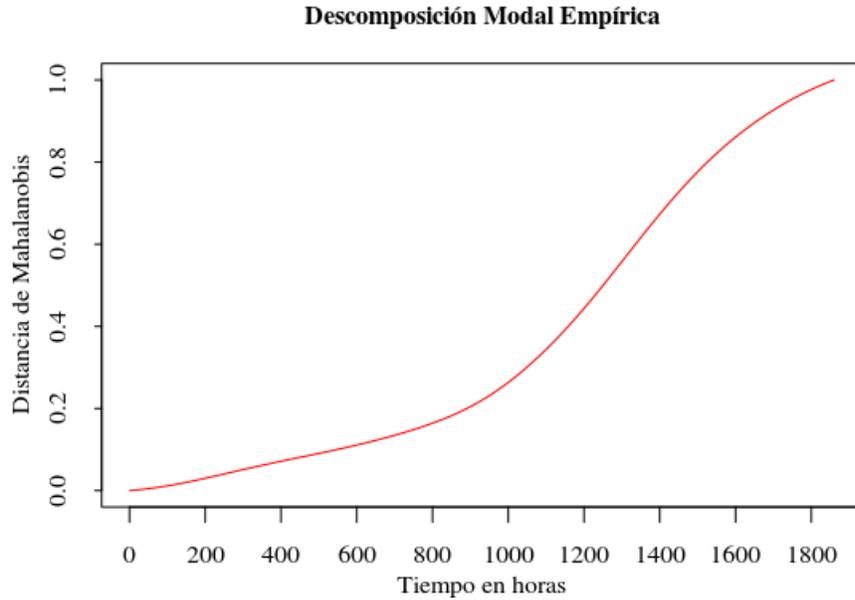


Figura 5.3: Tendencia de la DM para eficiencia.

## 5.2. Precursor del daño

Por otro lado, se utilizan las EA para representar el indicador indirecto del daño estimado. En la Figura 5.4 se presentan los parámetros de *ASL* y *RMS* de las emisiones acústicas medidas por los 3 sensores instalados en la bomba. Los restantes parámetros de EA se presentan en el Anexo A.2

Los canales 1 y 3, zona de succión y motor de la bomba, respectivamente, presentan mediciones ruidosas, producto de las condiciones que existe en estos sectores. Sin embargo, es posible notar una leve tendencia de los datos. Esto, en conjunto con la información aportada por el canal 2 (zona de descarga de la bomba), nos permitirá, por medio de la DM, obtener de manera más clara la tendencia de los datos de EA.

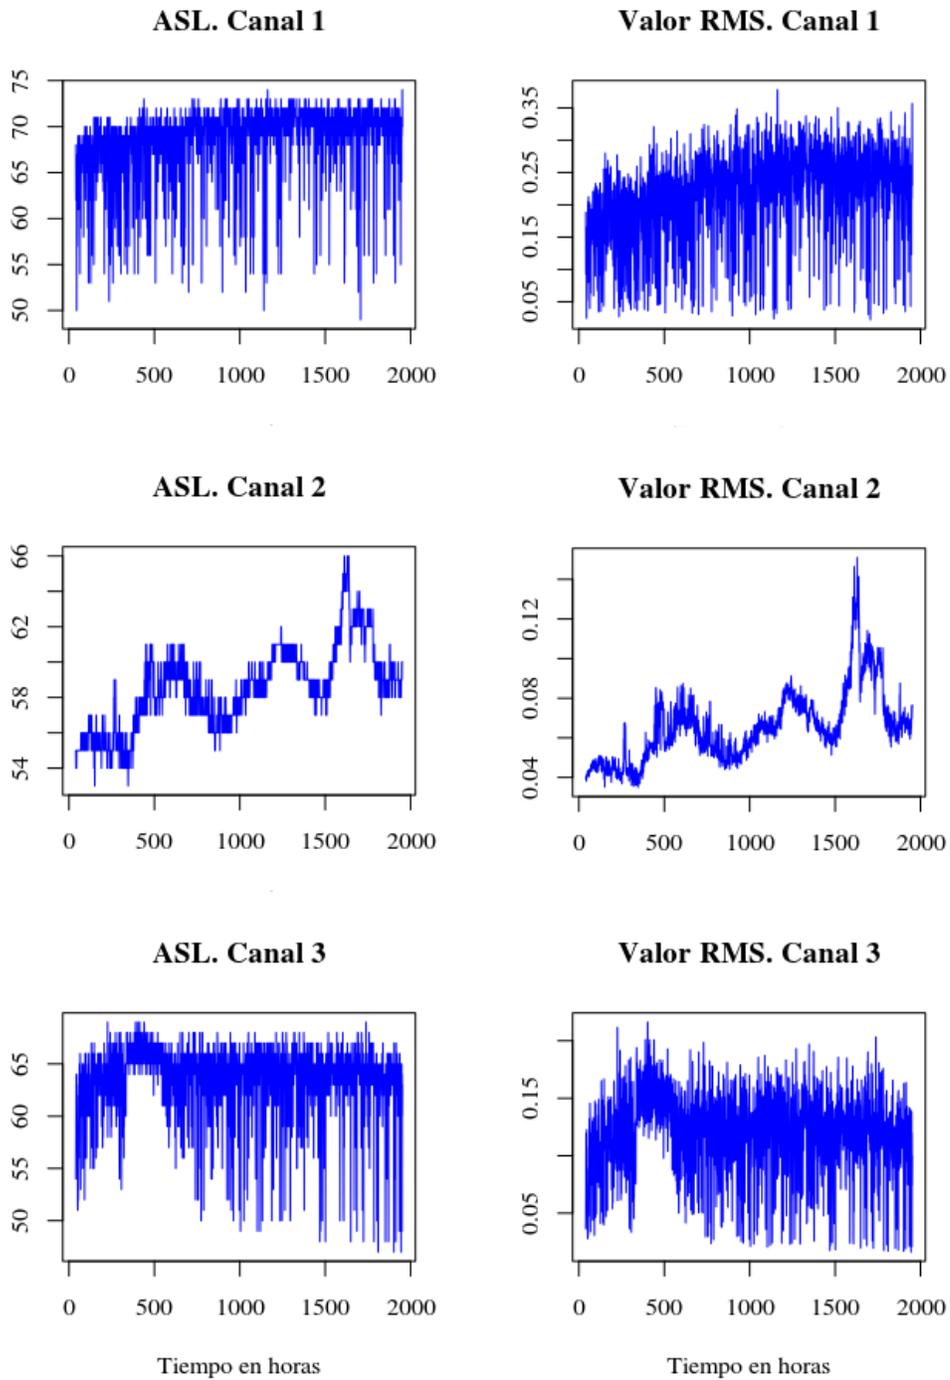


Figura 5.4: Parámetros de emisión acústica y su evolución en el tiempo.

A partir de los parámetros antes expuestos, al igual que con los parámetros de eficiencia, se calcula la DM. En la Figura 5.5 se muestra el resultado obtenido.

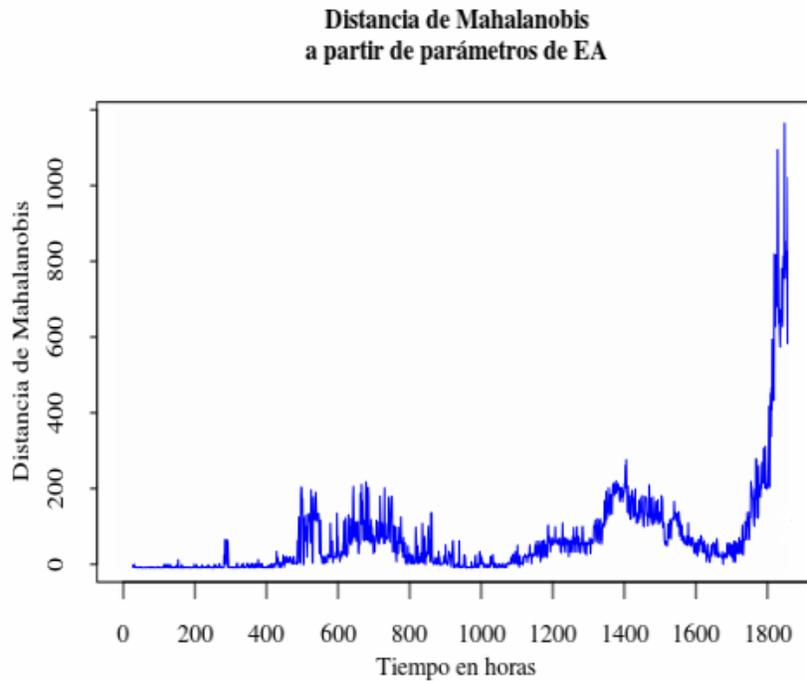


Figura 5.5: Distancia de Mahalanobis calculada a partir de los parámetros de EA.

Dado que los valores de la DM presentan un comportamiento oscilante y creciente en el tiempo, se aplica la DME para poder extraer la tendencia general. El resultado de esta aplicación se muestra en la Figura 5.6.

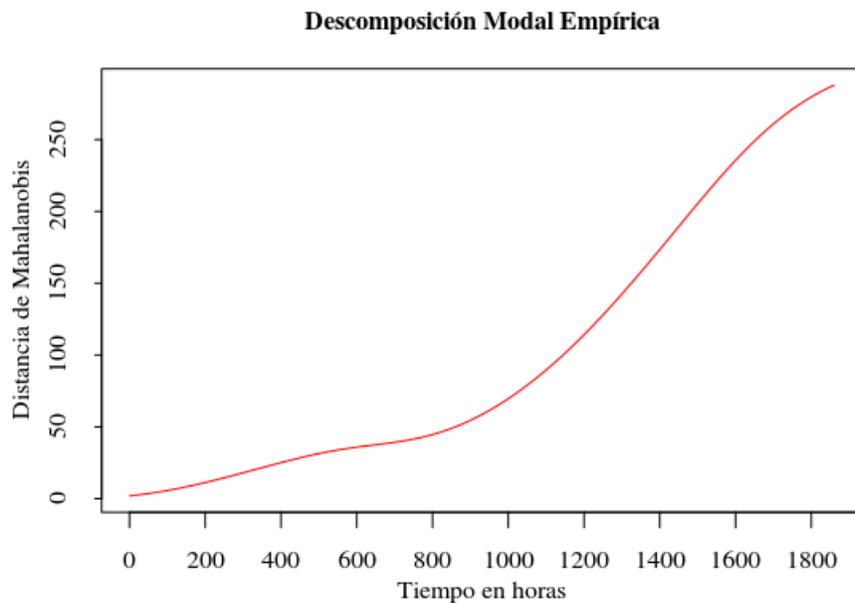


Figura 5.6: Tendencia de la DM para EA.

### 5.3. Estimación del daño utilizando Filtro de Partículas

Para realizar el diagnóstico por medio del FP, es necesario conocer el modelo de estado y el modelo de medida. Con el primero se generan  $N$  hipótesis del estado de la bomba, a partir del estado anterior en el tiempo. Y el segundo, permite actualizar el valor de cada hipótesis, por medio de las observaciones de EA obtenidas en ese instante.

#### 5.3.1. Modelo de estado

Se realiza una regresión polinomial de grado 7 entre los valores de la tendencia de la DM, obtenidos de la DME, y el tiempo asociado. De esta manera, se obtiene una función que modela la degradación de la bomba. El resultado de la regresión se presenta en la Figura 5.7.

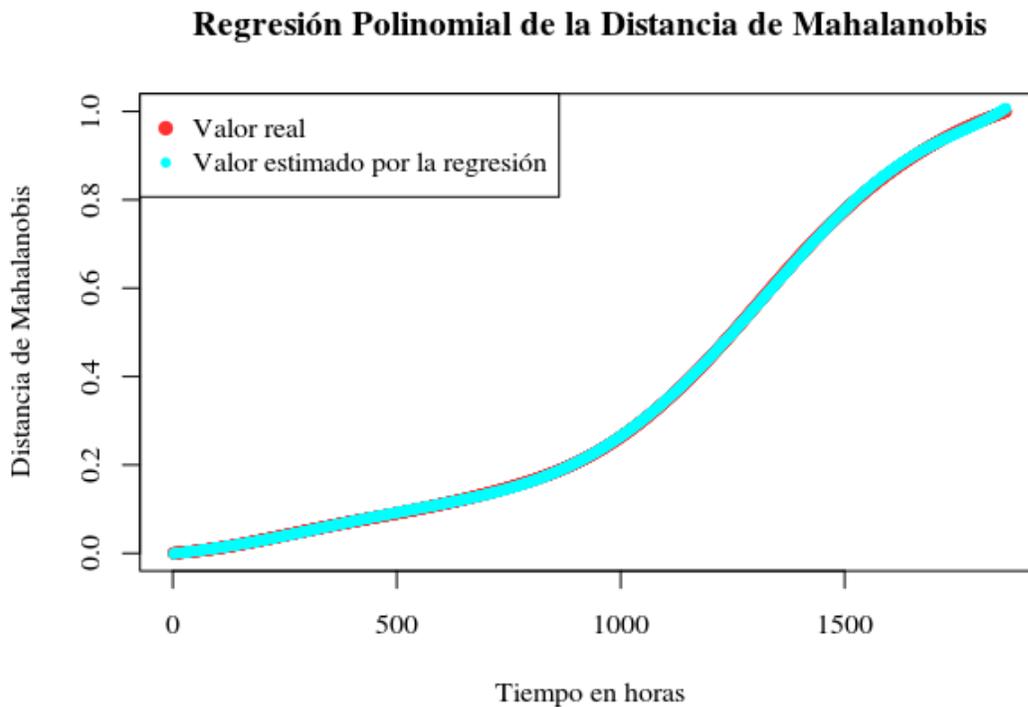


Figura 5.7: Regresión polinomial de grado 10. Modela la evolución de la degradación.

## Versión discretizada

Para poder introducir el modelo de estado al algoritmo del FP, se debe contar con un modelo discretizado. Para realizar esto, se aplica la ecuación (4.1) a la función polinomial anteriormente obtenida. El resultado de esto se presenta en la Figura 5.8.

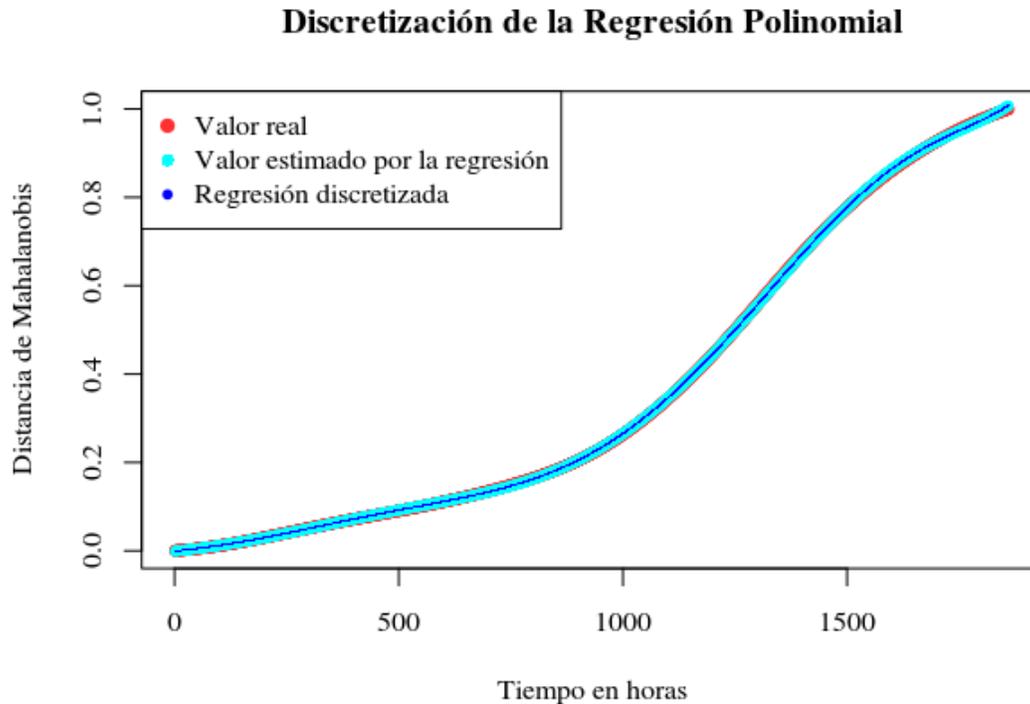


Figura 5.8: Versión discretizada del modelo de estado.

El modelo de estado, en ambas formas (continua y discretizada), presenta un buen ajuste a los valores reales. La versión discretizada, que luego se utilizará en el FP, entrega un valor  $R^2 = 0,9973$ , lo que da cuenta del buen ajuste del modelo generado.

### 5.3.2. Modelo de medición

El modelo de medición nos entrega una correlación entre las observaciones de EA y la degradación dada por los datos de la eficiencia. De antemano no se conoce un modelo o función que relacione ambas variables, por lo que se opta por generar un modelo basado en datos.

## Support Vector Regression (SVR)

El SVR permite generar una regresión no lineal entre las variables antes mencionadas. De este modo se puede obtener la probabilidad de un estado de degradación a partir de las mediciones de EA. Esto es conocido como el modelo de medición.

El calculo del SVR requiere de la especificación de los parámetros  $\varepsilon$  y  $C$ . Con el objetivo de seleccionar los valores óptimos para estos, se realiza una búsqueda por barrido (*grid research*) entre una serie de combinaciones para diferentes valores de estos. Esta búsqueda (representada en la Figura 5.9), termina con la selección de los valores de:  $\varepsilon = 0,003$  y  $C = 512$ .

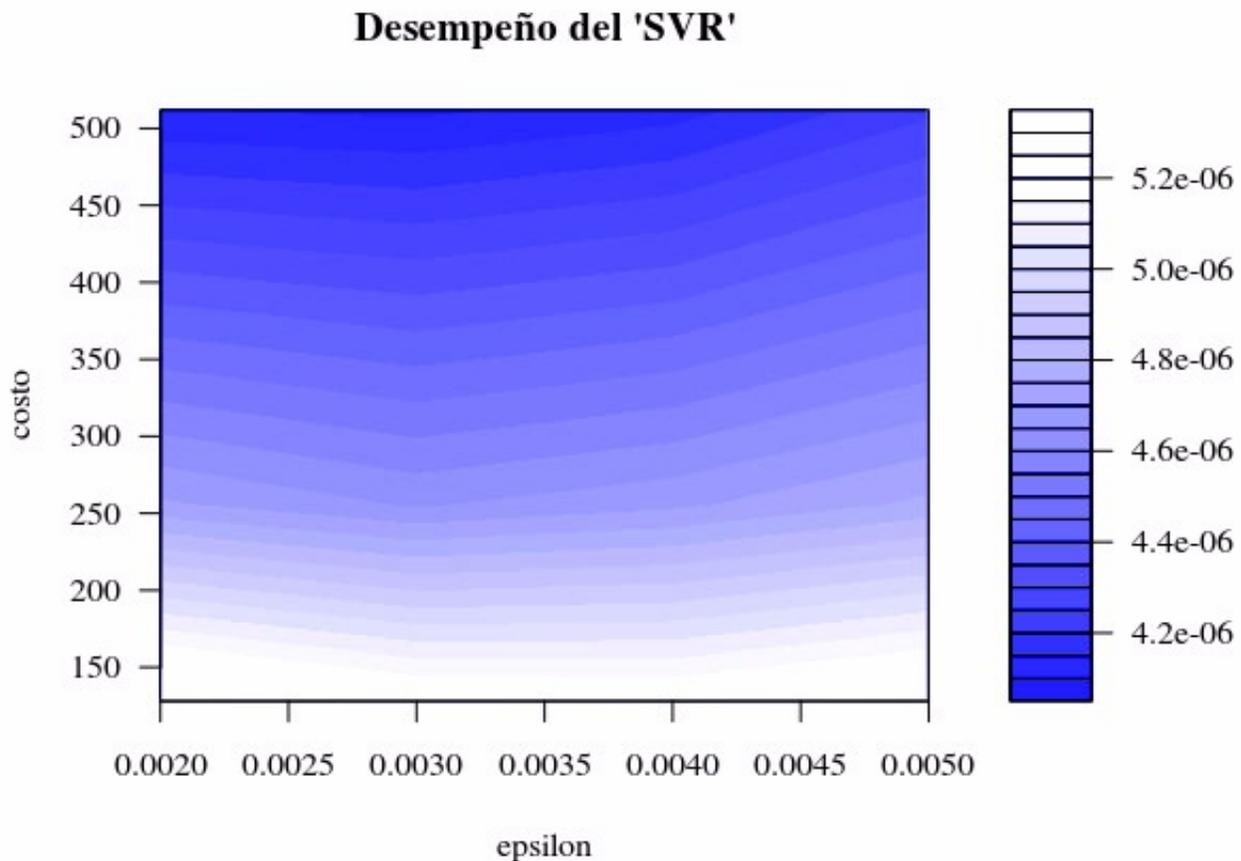


Figura 5.9: Búsqueda de barrido para determinar parámetros óptimos del SVR.

Se hace necesario notar, que el parámetro de penalización  $C$  puede ser tan grande como se desee y no tendrá mayor influencia en el modelo. Esto último, debido a que el parámetro  $\varepsilon$  es el encargado de definir la distancia mínima a la cual se considerará una penalización para los valores generados por el SVR, y en este caso se obtiene un valor muy bajo.

En la Figura 5.10 se muestra el SVR generado. Se obtiene un valor  $R^2 = 0,9998$ .

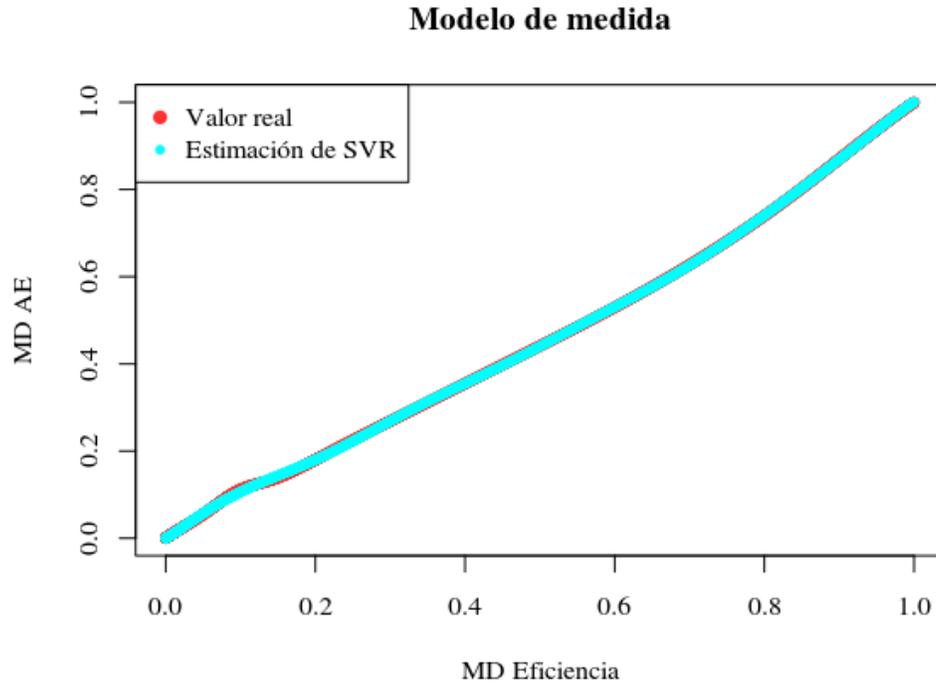


Figura 5.10: Modelo de medición generado por medio de SVR.

### 5.3.3. Filtro de Partículas

Con ambos modelos especificados, se procede a realizar el FP. Se utilizan  $N = 1000$  partículas aleatoriamente seleccionadas para cada predicción realizada mediante el modelo de estado. Además, para el estado de degradación inicial, se generan estas partículas alrededor de un valor  $D = 0,001$ , que da cuenta del daño casi inexistente que debería existir en ese momento. Se utilizan los valores del ruido asociado al modelo de estado y a las observaciones de EA, de  $\theta = 1,2247$  y  $\omega = 0,0632$ , respectivamente. El resultado obtenido se presenta en la Figura 5.11, y entrega un valor  $R^2 = 0,9975$ .

### Daño Estimado mediante Filtro de Partículas

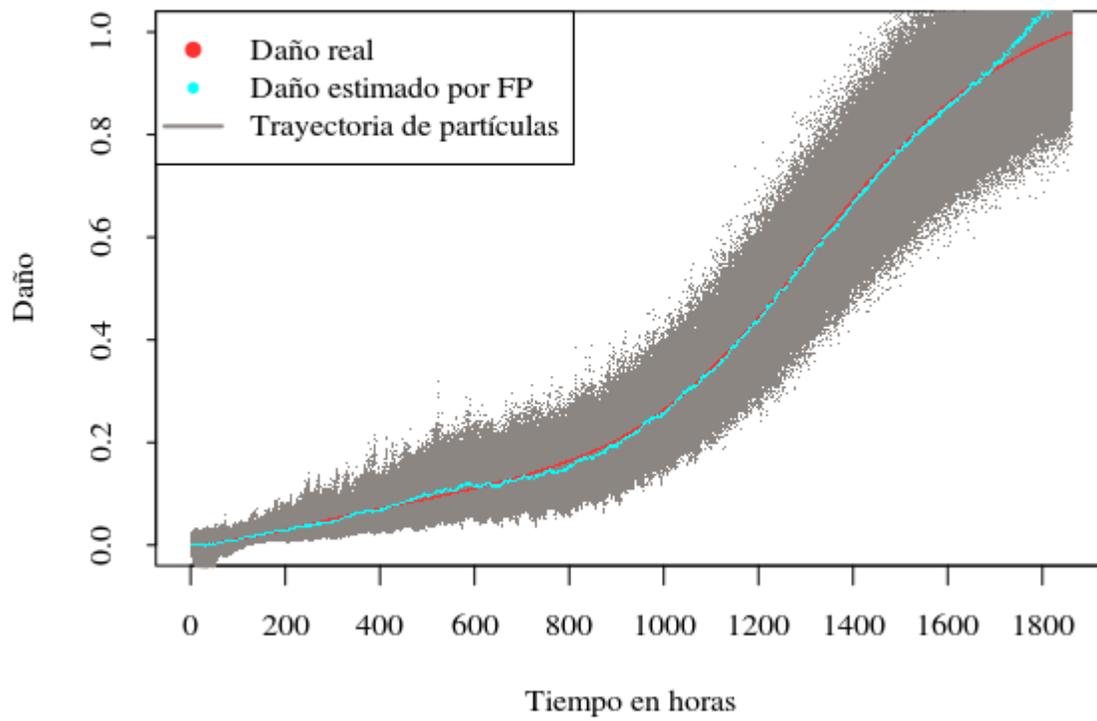


Figura 5.11: Estimación del daño utilizando filtro de partículas

# Capítulo 6

## Conclusiones

A la vista de los resultados, es posible concluir que la caracterización de daño en la bomba, utilizando la técnica de FP, se realizó de manera satisfactoria.

La metodología aplicada para implementar el modelo de diagnóstico, logra generar una herramienta capaz de estimar de manera muy acertada los valores de la degradación a partir de las señales de EA, medidas durante todo el período de operación de la máquina. Con esto, se valida el uso de las EA como un buen precursor del daño subyacente que sufre la bomba.

Utilizando el concepto de la Distancia de Mahalanobis, a partir de los datos de la eficiencia de la bomba, se logra generar un índice de degradación de la bomba en el tiempo. Esto permite tener un punto de comparación para los valores posteriormente arrojados por el FP.

A pesar de no contar con los modelos físicos necesarios para representar cada una de las dependencias mostradas en la RBD que describe el proceso de degradación propuesto, los modelos basados en datos desarrollados, logran este objetivo de manera satisfactoria. En particular, con la técnica de SVR es posible determinar una correlación entre el daño no observable y las mediciones de EA, representadas en una función no lineal que presenta un buen ajuste a los valores reales de las dos variables utilizadas (ver Figura 5.10). Además, por medio de una regresión polinomial que utiliza los valores de la degradación en función de la eficiencia, se logra determinar una función para modelar el proceso de degradación en el tiempo.

En la Figura 5.11 se aprecia la estimación de la degradación mediante el FP, que utiliza los modelos previamente obtenidos, comparada con la degradación caracterizada en base a la evolución de la eficiencia. Es notoria la similitud de ambos valores. Sin embargo, existe una leve desviación en las últimas horas de medición. Este hecho puede estar relacionado con el peak que se observa en el gráfico de la DM obtenido de los valores de EA (Figura 5.5), el cual podría estar asociado a un error de medición. No obstante a esto, este trabajo busca realizar el diagnóstico en la etapa temprana de operación y, como se aprecia en la figura antes mencionada, el FP tiene un muy buen desempeño en las horas iniciales.

Los ruidos de estado y medición utilizados se escogieron de manera arbitraria, en busca de aplicar incertidumbre a los resultados sin perder certeza de las estimaciones realizadas. Sin embargo, los valores de ruido introducidos en cada modelo deben estar definidos en función de las características de los instrumentos utilizados para realizar las observaciones de las variables en cuestión. Es por esto, que el modelo de diagnóstico generado sólo es válido para las condiciones utilizadas en este trabajo.

La eficiencia constituye un indicador indirecto del daño que ocurre en la bomba, por lo tanto el diagnóstico realizado por el presente modelo no describe el daño real que tiene lugar en la bomba y, más bien representa un índice de degradación general.

La caracterización del daño por medio de un indicador directo, como por ejemplo el tamaño de grieta, resultaría en una mejora importante del diagnóstico, dado que este estaría referido a un estado de daño real de la máquina. Ahora bien, la metodología utilizada presenta bastante flexibilidad en cuanto a la integración de los modelos de estado y medición, en particular el algoritmo de FP utilizado integra de manera independiente cada uno de los modelos. De este modo, sólo bastaría definir los nuevos modelos de estado y medición dentro del FP para realizar el nuevo diagnóstico.

# Bibliografía

- [1] **Tsui, K., Chen, N., Zhou, Q., Hai, Y., Wang, W.** Prognostic and Health Management: A Review on Data Driven Approaches. *Hidawi Publishin Corporation*. 2015. October 2014.
- [2] **Rabiei, E., Droguett, E.L., Modarres, M.** A Prognostic Approach Based on the Evolution of Damage Precursors using Dynamic Bayesian Networks. *Original research article*. 2016.
- [3] **Balageas, D.** Introduction to Structural Health Monitoring, in *Structural Health Monitoring* (eds D. Balageas, C.-P. Fritzen and A. Güemes), ISTE, London, UK, 2006. doi: 10.1002/9780470612071.ch1
- [4] **Droguett, E.L.** *ME709 Module 6 Diagnostics and Prognostics SVR DBN with PF.pdf* [Diapositivas] Gestión de Activos Físicos Aplicada, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile, 2016.
- [5] **Grosse, C.U., Ohtsu, M., eds.,** *Acoustic Emission Testing*, Springer-Verlag, Berlin, 2008. doi: 10.1007/978-3-540-69972-9
- [6] **Muravin, B.** *Acoustic Emission basics presentation for students* [en línea] <http://muravin.com/> [consulta: 24 noviembre 2016]
- [7] **Dong, D., Xiangdong, Z., Libin, L.** Research on Relationship Between Parameters Correlation of Acoustic Emission and Rock Failure. *Sensors & Transducers*. 183 (12): 147-154. December 2014.
- [8] **Petch, M.** *Precursors to Failures Data-Driven Analysis for Diagnostics and Prognostics.pdf* [Diapositivas], University of Maryland, College Park, MD 20742, 2008.
- [9] **Droguett, E.L.** *ME709 Module 3 Bayesian Reliability Bayesian Networks.pdf* [Diapositivas] Gestión de Activos Físicos Aplicada, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile, 2016.
- [10] **Arulampalam, M.S., Maskell, S., Gordon, N., Clapp, T.** A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking. *IEEE Transaction on signal processing*. 50 (2). February 2002.
- [11] **Droguett, E.L.** *ME709 Module 4 Diagnostics and Prognostics Support Vector Machi-*

*nes.pdf* [Diapositivas] Gestión de Activos Físicos Aplicada, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile, 2016.

- [12] **Karatzoglou, A., Meyer, D., Hornik, K.** Support Vector Machines in R. *Journal of Statistical Software*. 15. April 2006.
- [13] **Smola, A. J., Schölkopf, B.** A Tutorial on Support Vector Regression. *NeuroCOLT2 Technical Report Series*. 27150. October 1998.
- [14] **Hastie, T., Tibshirani, R., Friedman, J.** *The Elements of Statistical Learning*. 2<sup>a</sup> ed. Springer-Verlag New York, 2009. doi: 10.1007/978-0-387-84858-7
- [15] *50840 Series Low Pressure Centrifugal Pump: "CYCLONE PUMP"*. 43000-0820. Rev: B. JABSCO Xylem Inc. 2012.
- [16] **Nuclear Power** *Major Failure Modes of Centrifugal Pumps* [en línea] <http://www.nuclear-power.net> [consulta: 6 Septiembre 2017]
- [17] **Physical Acoustics** *Micro30 - 150-400 kHz Miniature AE Sensor Product Description* [en línea] <http://www.physicalacoustics.com/> [consulta: 16 mayo 2017]
- [18] **Kaewwaewnoi, W., Pratepasen, A., Kaewtrakulpong, P.** Measurement of Valve Leakage Rate using Acoustic Emission. *ECTI Transactions on Electrical Engineering, Electronics, and Communications*. 5. February 2007.

## **Anexos**

# Anexo A

## Gráficos

### A.1. Parámetros estadísticos de la eficiencia

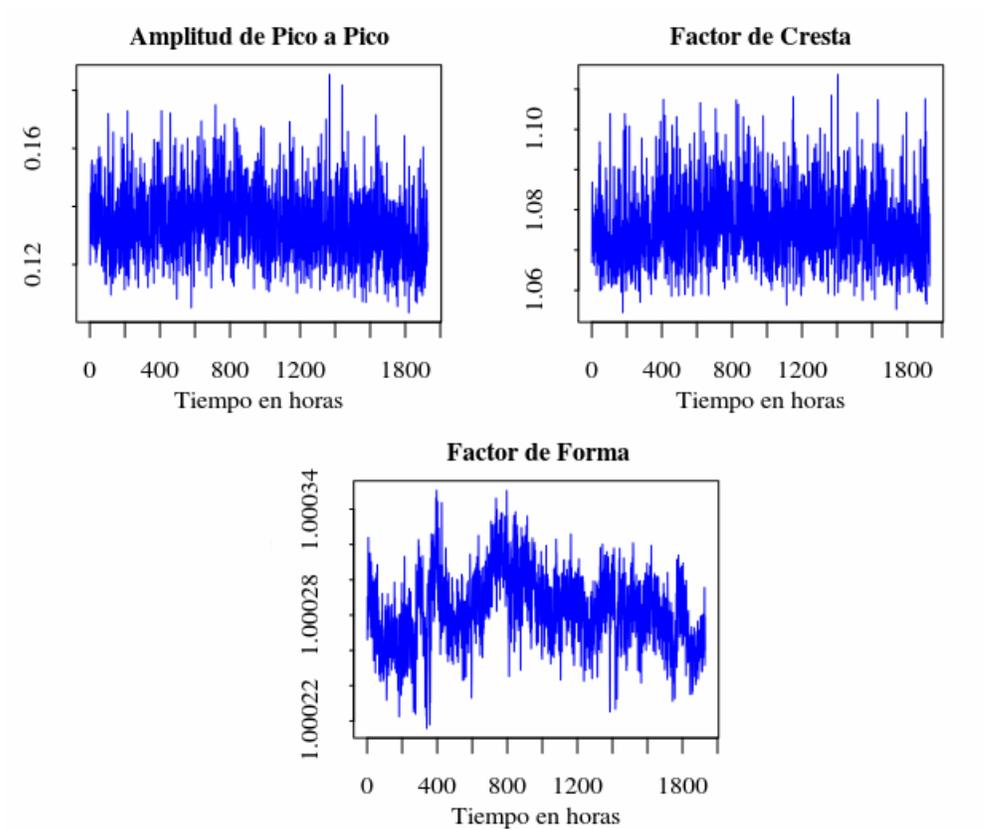


Figura A-1: Parámetros estadísticos de la eficiencia que no presentan una tendencia notable a lo largo del tiempo.

## A.2. Parámetros de EA

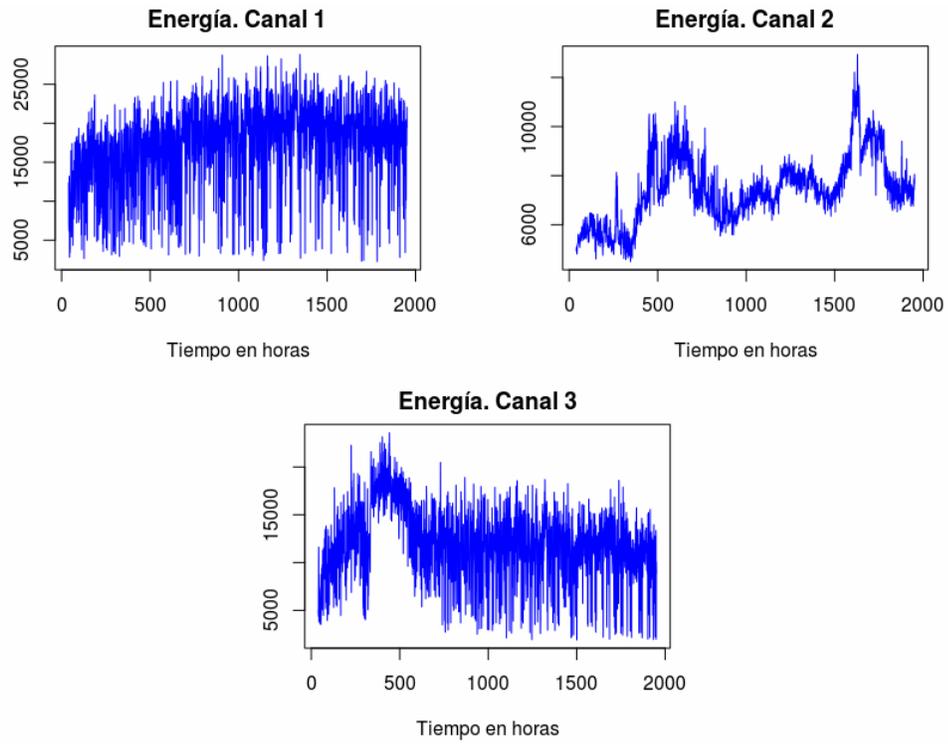


Figura A-2: Energía de la señal de EA medida en los 3 sensores.

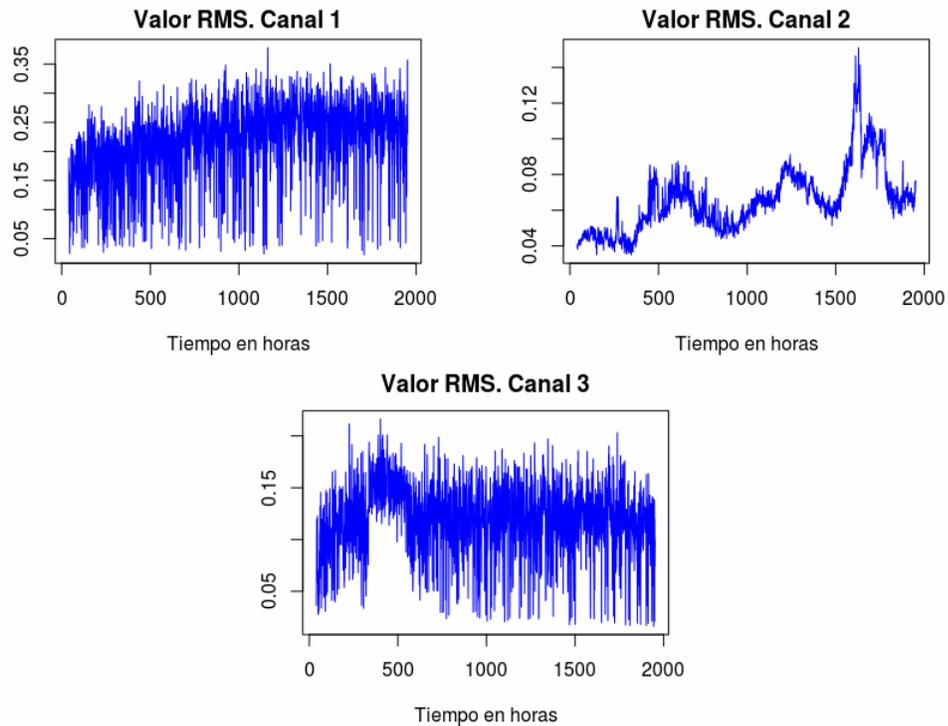


Figura A-3: Valor RMS de la señal de EA medida en los 3 sensores.

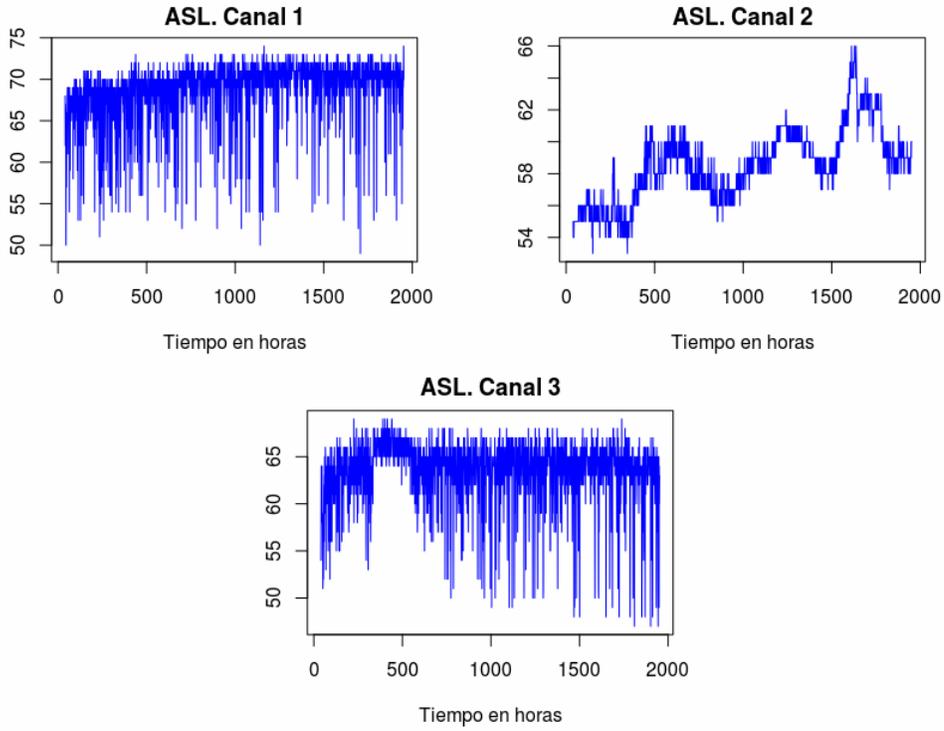


Figura A-4: Nivel promedio de la señal de EA medida en los 3 sensores.

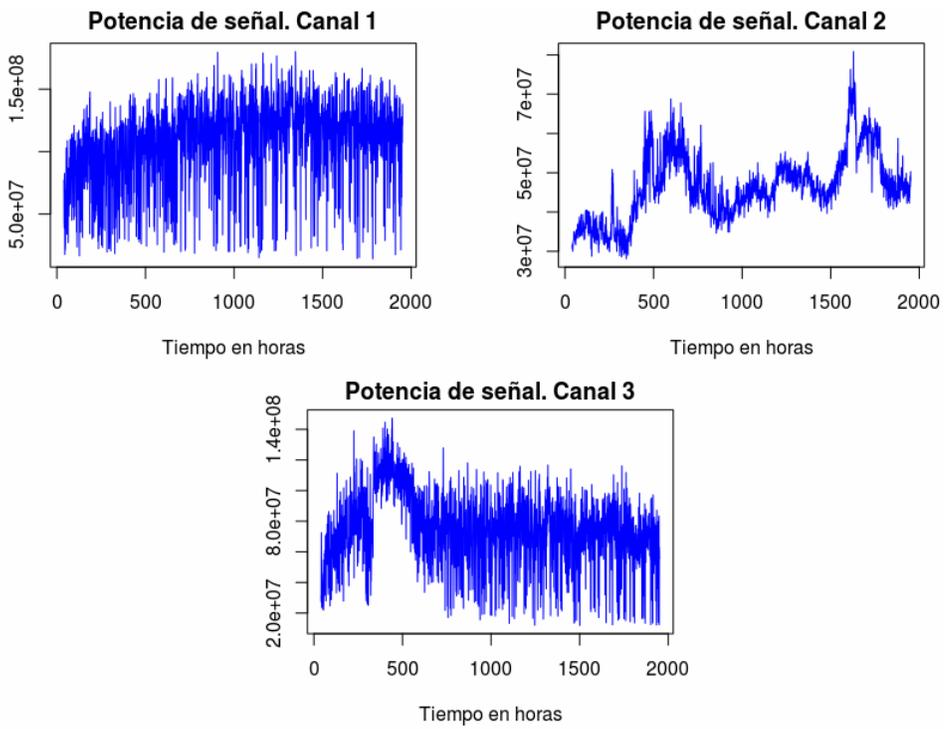


Figura A-5: Potencia de la señal de EA medida en los 3 sensores.

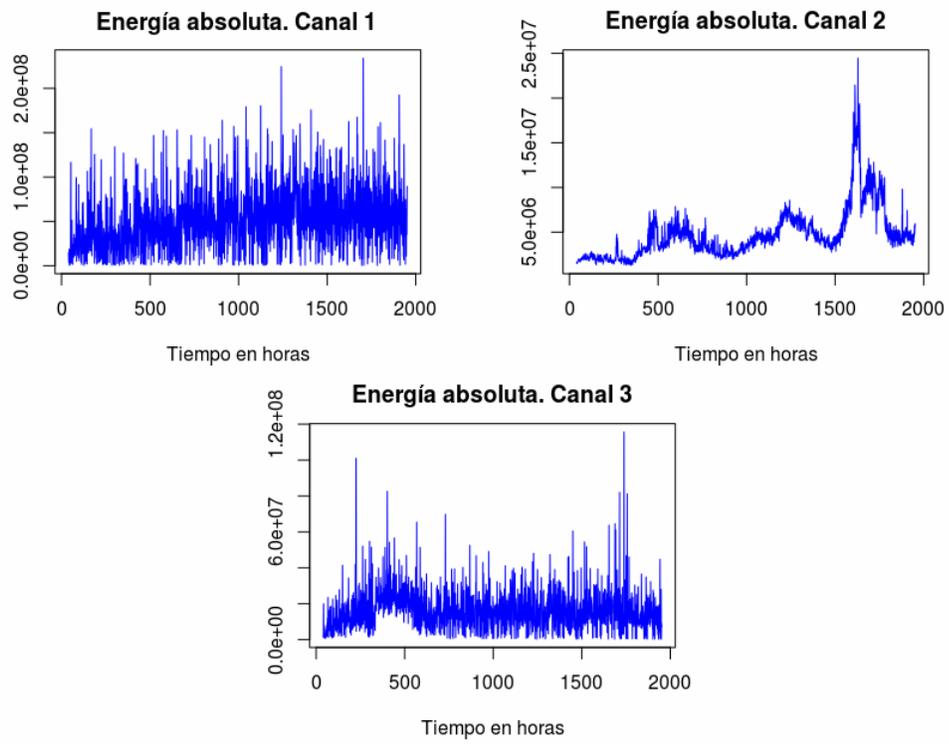


Figura A-6: Energía absoluta de la señal de EA medida en los 3 sensores.