



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

**IDENTIFICACIÓN DE DAÑO INCIPIENTE EN UN SISTEMA ROTOR MEDIANTE LA
MEDICIÓN DE VIBRACIONES TORSIONALES**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL MECÁNICO

GABRIEL ANTONIO PEÑA ÁLVAREZ

PROFESOR GUÍA:
VIVIANA MERUANE NARANJO

MIEMBROS DE LA COMISIÓN:
ENRIQUE LÓPEZ DROGUETT
RAFAEL RUIZ GARCÍA

Este trabajo ha sido parcialmente financiado por el proyecto Fondecyt: 1160494. “A Novel Damage Precursor Based Structural Health Monitoring and Prognostic Framework”.

SANTIAGO DE CHILE
2017

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL MECÁNICO
POR: GABRIEL ANTONIO PEÑA ÁLVAREZ
FECHA: 24/07/2017
PROF. GUÍA: VIVIANA MERUANE NARANJO

IDENTIFICACIÓN DE DAÑO INCIPIENTE EN UN SISTEMA ROTOR MEDIANTE LA MEDICIÓN DE VIBRACIONES TORSIONALES

Bajo el concepto de “Monitoreo de Salud Estructural”, que permite conocer el estado de salud actual de un equipo mediante el uso de sensores en línea, se propone desarrollar un estudio enfocado a detectar daño incipiente en los álabes de una turbina de laboratorio, a partir del análisis de vibraciones torsionales en el eje del sistema rotor.

El objetivo general consiste en identificar experimentalmente los parámetros que permitan detectar daño incipiente en un modelo de laboratorio de un sistema rotor. Los objetivos específicos abarcan la utilización de diversas técnicas de tratamiento de señales y extracción de parámetros, el estudio de estos en los dominios de tiempo y frecuencia bajo diversos niveles de daño en el sistema, y la selección de un set de parámetros que permitan detectar daño incipiente.

La metodología se desarrolla en cuatro etapas: Puesta a punto del montaje, mediciones experimentales, análisis y procesamiento de señales, y selección de parámetros.

Se efectúa una etapa inicial de toma de datos para dos casos: Caso base (o sano) con el sistema operando a la perfección, y un caso extremo (o con daño máximo), funcionando en ausencia de un álabe. Se extraen 100 parámetros para cada caso y se comparan de forma gráfica. Se realiza este análisis tanto para vibraciones torsionales, como transversales, medidas por un acelerómetro. Los resultados obtenidos de la primera etapa muestran 40 parámetros, calculados sobre las vibraciones torsionales, que presentaron mayores variaciones entre el caso base y extremo, y 6 parámetros que presentaron mayores variaciones para las vibraciones transversales. Estos parámetros sirvieron de referencia para ser proyectados a una segunda etapa de toma de mediciones.

En dicha etapa posterior, se estudian las vibraciones del sistema rotor, esta vez trabajando con un álabe expuesto a una grieta. Se prueban 6 álabes con distintas grietas realizando el mismo procedimiento de la etapa anterior. Finalmente se entrena un clasificador “Máquina de vectores de soporte”, el cual, en conjunto con el método “Selección secuencial hacia adelante”, selecciona el set de parámetros que permite identificar de mejor manera la presencia de grietas en el sistema.

Los resultados finales muestran un conjunto de 13 parámetros calculados sobre las vibraciones torsionales que permiten identificar la mayor parte de las grietas estudiadas. Por otra parte, se realiza el mismo estudio para las vibraciones transversales, concluyendo que estas no son capaces de identificar grietas con suficiente exactitud.

*Dedicado a mis padres,
y a cada persona que tuvo fé en mi,
y aportó, de alguna manera,
en mi formación personal y profesional.*

*"Mira que te mando que te esfuerces y seas valiente;
no temas ni desmayes, porque Jehová tu Dios
estará contigo en dondequiera que vayas".
Josué 1:9*

Agradecimientos

El día de hoy, vienen a mi mente recuerdos de mi adolescencia. Con solo 16 años y un skate en mi mano. Finalizando tercero medio, decidí luchar por entrar a estudiar ingeniería en el mejor lugar, la Universidad de Chile. Recuerdo mi primer ensayo PSU, donde los resultados me hicieron comprender lo difícil que sería lograr mi objetivo.

Pienso en el proceso de aprendizaje que comenzó ese día, y que hoy alcanza su fruto. Largas horas de estudio y falta de sueño para poder entrar a la universidad, y que siguieron a lo largo de ella. Mi paso por Bachillerato, y mi anhelada entrada a la FCFM. Recuerdo el largo camino recorrido, y la gente que de paso conocí, aportando de una u otra manera en esta etapa de mi vida.

En primer lugar, agradezco a Dios, por su guía en cada área de mi vida. Agradezco a mis padres, Gerardo Peña y Gloria Álvarez. Mi padre me enseñó la importancia del trabajo duro y el esfuerzo. Me enseñó que trabajar trae frutos, y que estos no son inmediatos. Mi madre me enseñó a ser perseverante y a confiar en mí mismo. Me enseñó que soy capaz de lograr cualquier objetivo que me proponga, con esfuerzo y dedicación. Estas enseñanzas son, hoy en día, mis mayores fortalezas.

Gracias a mis hermanos mayores, Jaime y Gerardo, quienes trazaron el camino que yo seguiría en el futuro. Gracias por ser un ejemplo en mi vida, y por todos aquellos momentos de felicidad que aún compartimos, haciendo las mismas tonteras de la infancia. Doy gracias a mi polola Maribel, que estuvo conmigo, entendiéndome, apoyándome en mis planes, esperándome y brindándome su cariño, siempre enseñándome a ser una persona más empática y preocupado por los que me rodean. Gracias a mi cuñada Noemí y sobrinos Emilia y Juan, por traer un rato de alegría y distracción cada fin de semana.

Agradezco de igual manera a mis amigos, quienes han permanecido conmigo, escuchándome y apoyándome: Mathias, Roberto, Pepe, Esteban. Y a cada uno de mis amigos de la iglesia, ellos se sentirán aludidos. Gracias a mis compañeros de taekwondo, que entregan esa cuota de desestrés semanal necesaria, y el sentido de compañerismo y superación.

Gracias a mis compañeros, que formaron parte de este ciclo, en particular, Ismael, Nacho, Carloto y Frodo. Incluyo a mis compañeros de Bachi e Ingeniería, gracias por los almuerzos, conversaciones de pasillo, paseos mecánicos, etc. Doy gracias también a mis amigos conocidos durante mi intercambio en Alemania, Rodri, Andrés e Iván, quienes hicieron que este proceso fuera mucho más enriquecedor. Y a Volker y Andrea Hubrich que fueron como una segunda familia.

Para finalizar, quisiera dar las gracias a mis profesores, Viviana y Enrique. Quienes han sido un apoyo fundamental para el desarrollo de este trabajo y han tenido siempre la disposición de ayudarme, aún en día de descanso. Gracias por compartir sus conocimientos conmigo. De igual manera, doy gracias al profesor Rafael Ruiz, por su buena disposición para ser parte en mi comisión.

Tabla de contenido

Resumen	i
Dedicatoria	ii
Agradecimientos	iii
Lista de Figuras	vi
Lista de Tablas	viii
1. Introducción	1
1.1. Objetivos	2
1.1.1. Objetivo General	2
1.1.2. Objetivos Específicos	2
1.2. Alcances	2
2. Antecedentes	3
2.1. Velocidad Angular Instantánea y Vibraciones Torsionales	3
2.2. Principales métodos de análisis de señales	4
2.2.1. Local Mean Decomposition	4
2.2.2. Empirical Mode Decomposition	7
2.3. Parámetros Estadísticos	8
2.3.1. Root Mean Square (RMS)	8
2.3.2. Delta RMS	9
2.3.3. Peak	9
2.3.4. Peak to Peak	9
2.3.5. Media aritmética	9
2.3.6. Varianza	9
2.3.7. Kurtosis	10
2.3.8. Crest Factor	10
2.3.9. Skewness	11
2.3.10. Momentos Centrados	11
2.3.11. Energía de Shannon	12
2.3.12. Entropía de Shannon	12
2.3.13. Derivada discreta de una señal	13
2.3.14. Integral discreta de una señal	13
2.4. Parámetros en el dominio de frecuencias	13
2.4.1. Media aritmética para una banda de frecuencias	13
2.4.2. Media geométrica para una banda de frecuencias	14
2.4.3. Armónicos de un eje	14

2.5. Support Vector Machine	15
2.6. Clasificación	19
2.6.1. Exactitud	19
2.6.2. Precisión	20
2.6.3. Tasa de acierto	20
2.7. Algoritmos de selección de parámetros	20
3. Metodología	21
4. Resultados y análisis	23
4.1. Resultados primera etapa de estudios. Velocidades angulares instantáneas	23
4.2. Análisis de velocidades angulares instantáneas	26
4.3. Resultados primera etapa de estudios. Parámetros sobre vibraciones torsionales	27
4.4. Análisis de resultados, primera etapa de estudios. Parámetros sobre vibraciones torsionales	34
4.4.1. Análisis de parámetros calculados sobre la señal original IAS	34
4.4.2. Análisis de parámetros calculados sobre la derivada de la señal original IAS	35
4.4.3. Análisis de parámetros calculados sobre la integral de la señal original IAS	35
4.5. Resultados primera etapa de estudios. Parámetros sobre vibraciones transversales	36
4.6. Análisis de parámetros calculados sobre la señal del acelerómetro	37
4.7. Resultados segunda etapa de estudios: Grietas	38
4.8. Análisis de resultados. Segunda etapa de estudios. Vibraciones torsionales	45
4.9. Resultados segunda etapa de estudios. Vibraciones Transversales	49
4.10. Análisis de resultados. Segunda etapa de estudios. Vibraciones Transversales	50
4.11. Resultados finales	53
5. Comentarios y conclusiones	54
Bibliografía	56

Índice de figuras

2.1. Voltaje y tiempo en un sensor encoder. Fuente: Adaptado de Ahmed A. Gubran, et.al. “ <i>Shaft instantaneous angular speed for blade vibration in rotating machine</i> ” [1].	3
2.2. Velocidad Angular Instantánea para un eje sin vibraciones torsionales	4
2.3. Velocidad Angular Instantánea para un eje con vibraciones torsionales	4
2.4. Componentes de descomposición PFs de una señal. Fuente propia.	6
2.5. Ejemplo SVM para dos parámetros. Fuente: Valveny E, et.al [12].	15
2.6. Posibles hiperplanos separadores entre clases. Fuente: Valveny E, et.al [12].	15
2.7. Margen e hiperplanos de soporte en SVM. Fuente: Valveny E, et.al [12].	16
2.8. Hiperplanos de soporte, ecuaciones. Fuente: Valveny E, et.al [12].	17
2.9. Esquema de clasificación binaria de datos con daño y sanos.	19
3.1. Montaje experimental.	21
4.1. Partición de datos y confección de matriz "Parámetros", caso sano. Fuente propia. .	23
4.2. IAS Caso Sano.	26
4.3. IAS Caso Extremo.	26
4.4. IAS calculado por vuelta, Caso sano.	26
4.5. IAS calculado por vuelta, Caso extremo.	26
4.6. Parámetro 2. Sano (Izquierda), extemo (derecha).	27
4.7. Parámetro 3. Sano (Izquierda), extemo (derecha).	27
4.8. Parámetro 4. Sano (Izquierda), extemo (derecha).	27
4.9. Parámetro 6. Sano (Izquierda), extemo (derecha).	27
4.10. Parámetro 7. Sano (Izquierda), extemo (derecha).	28
4.11. Parámetro 9. Sano (Izquierda), extemo (derecha).	28
4.12. Parámetro 10. Sano (Izquierda), extemo (derecha).	28
4.13. Parámetro 11. Sano (Izquierda), extemo (derecha).	28
4.14. Parámetro 12. Sano (Izquierda), extemo (derecha).	28
4.15. Parámetro 13. Sano (Izquierda), extemo (derecha).	28
4.16. Parámetro 14. Sano (Izquierda), extemo (derecha).	29
4.17. Parámetro 15. Sano (Izquierda), extemo (derecha).	29
4.18. Parámetro 16. Sano (Izquierda), extemo (derecha).	29
4.19. Parámetro 41. Sano (Izquierda), extemo (derecha).	29
4.20. Parámetro 49. Sano (Izquierda), extemo (derecha).	29
4.21. Parámetro 54. Sano (Izquierda), extemo (derecha).	29
4.22. Parámetro 56. Sano (Izquierda), extemo (derecha).	30
4.23. Parámetro 66. Sano (Izquierda), extemo (derecha).	30
4.24. Parámetro 71. Sano (Izquierda), extemo (derecha).	30
4.25. Parámetro 72. Sano (Izquierda), extemo (derecha).	30
4.26. Parámetro 73. Sano (Izquierda), extemo (derecha).	30
4.27. Parámetro 76. Sano (Izquierda), extemo (derecha).	30

4.28. Parámetro 79. Sano (Izquierda), extemo (derecha).	31
4.29. Parámetro 80. Sano (Izquierda), extemo (derecha).	31
4.30. Parámetro 81. Sano (Izquierda), extemo (derecha).	31
4.31. Parámetro 82. Sano (Izquierda), extemo (derecha).	31
4.32. Parámetro 83. Sano (Izquierda), extemo (derecha).	31
4.33. Parámetro 84. Sano (Izquierda), extemo (derecha).	31
4.34. Parámetro 85. Sano (Izquierda), extemo (derecha).	32
4.35. Parámetro 86. Sano (Izquierda), extemo (derecha).	32
4.36. Parámetro 88. Sano (Izquierda), extemo (derecha).	32
4.37. Parámetro 92. Sano (Izquierda), extemo (derecha).	32
4.38. Parámetro 93. Sano (Izquierda), extemo (derecha).	32
4.39. Parámetro 94. Sano (Izquierda), extemo (derecha).	32
4.40. Parámetro 95. Sano (Izquierda), extemo (derecha).	33
4.41. Parámetro 96. Sano (Izquierda), extemo (derecha).	33
4.42. Parámetro 97. Sano (Izquierda), extemo (derecha).	33
4.43. Parámetro 98. Sano (Izquierda), extemo (derecha).	33
4.44. Parámetro 99. Sano (Izquierda), extemo (derecha).	33
4.45. Parámetro 100. Sano (Izquierda), extemo (derecha).	33
4.46. Parámetro 2 (acelerómetro). Sano (Izq), extremo (der).	36
4.47. Parámetro 5 (acelerómetro). Sano (Izq), extremo (der).	36
4.48. Parámetro 16 (acelerómetro). Sano (Izq), extremo (der).	36
4.49. Parámetro 86 (acelerómetro). Sano (Izq), extremo (der).	36
4.50. Parámetro 87 (acelerómetro). Sano (Izq), extremo (der).	37
4.51. Parámetro 90 (acelerómetro). Sano (Izq), extremo (der).	37
4.52. Álabas con grietas.	38
4.53. IAS para cada caso (sin centrar).	39
4.54. Parámetro 87 Normalizado. Sano-grietas.	41
4.55. Parámetro 72 Normalizado. Sano-grietas.	41
4.56. Parámetro 3 Normalizado. Sano-grietas.	41
4.57. Parámetro 88 Normalizado. Sano-Grietas.	43
4.58. Parámetro 97 Normalizado. Sano-Grietas.	43
4.59. Parámetro 25 Normalizado. Sano-Grietas.	44
4.60. Parámetro 5 Normalizado. Sano-Grietas.	44
4.61. Parámetro 99 Normalizado. Sano-Grietas.	44
4.62. Parámetro 86 Normalizado. Sano-Grietas.	44
4.63. Parámetro 100 Normalizado. Sano-Grietas.	44
4.64. Parámetro 1 Normalizado. Sano-Grietas.	44
4.65. Parámetro 91 Normalizado. Sano-Grietas.	45
4.66. Parámetro 2 Normalizado. Sano-Grietas.	45

Índice de tablas

4.1. Parámetros señal original.	24
4.2. Parámetros para la derivada e integral de la señal original.	25
4.3. Designación de álabes con grietas. Tamaño y posición respecto al centro del rotor. .	38
4.4. Errores porcentuales de selección para cada caso de clasificación.	40
4.5. Lista de parámetros seleccionados. Caso <i>vi</i> : Sano y grietas 4, 5 y 6.	41
4.6. Clasificación de grietas por separado. Resultados estadísticos.	42
4.7. Clasificación de Grietas por separado. Parámetros seleccionados en cada clasificación.	43
4.8. Errores porcentuales de clasificación (acelerómetro).	49
4.9. Clasificación de grietas por separado. Acelerómetro. Resultados estadísticos. . . .	50
4.10. Parámetros finales.	53

1. Introducción

“Me he dado cuenta de que aun la gente que dice que todo está predestinado y que no podemos hacer nada para cambiarlo, mira antes de cruzar la calle” (Stephen Hawking).

Es de amplio conocimiento en el mundo de la ingeniería, que los sistemas mecánicos son constantemente expuestos a distintas cargas, las cuales producen en el tiempo cierto nivel de degradación del sistema, ocasionando potenciales fallas.

En la industria, un evento de falla de un sistema mecánico puede ocasionar grandes pérdidas, desde la disminución de productividad en una planta, hasta graves accidentes laborales con consecuencias fatales.

Resulta de vital importancia conocer el estado de salud actual de un sistema mecánico, detectando lo antes posible cualquier tipo de daño para así poder estimar el tiempo de vida remanente del equipo y programar una intervención de mantenimiento adecuada.

Por consiguiente, es de gran utilidad investigar qué sucede en el sistema, preferentemente antes de que se produzca una grieta, e identificar los parámetros que detectan este suceso. En consecuencia, es importante encontrar, en primer lugar, aquellos parámetros suficientemente sensibles, tal que permitan identificar la existencia de una grieta en el sistema.

El presente trabajo de título propone identificar de forma experimental el set de parámetros que permitan detectar daño incipiente en un modelo de laboratorio de un sistema rotor con una turbina, lo que se efectúa mediante la medición de vibraciones torsionales, y adicionalmente, a través de la medición de vibraciones transversales por medio de un acelerómetro.

El estudio se realiza a partir del cálculo de la velocidad angular instantánea del eje del rotor, bajo la premisa de que el daño en un álabe se verá reflejado en el eje del sistema por medio de las vibraciones torsionales. Se extrae una gran cantidad de parámetros de las señales vibratorias, medidas para situaciones con distintos niveles de daño. Finalmente se clasifica aquellos parámetros que son capaces de detectar correctamente el daño introducido al sistema en cada caso.

Los resultados del presente trabajo dan cuenta de la importancia del análisis de vibraciones torsionales para identificar daño en álabes y su mayor sensibilidad en comparación a las vibraciones transversales.

1.1. Objetivos

La presente sección detalla los objetivos en los que se enmarca el trabajo de título realizado.

1.1.1. Objetivo General

Identificar experimentalmente los parámetros que permitan detectar daño incipiente en un modelo de laboratorio de un sistema rotor con una turbina.

1.1.2. Objetivos Específicos

Los objetivos específicos son:

- Utilización de diversas técnicas de tratamiento de señales y extracción de parámetros relacionados al estado de salud.
- Estudio de parámetros en los dominios de tiempo y frecuencia bajo diversos estados de carga en el sistema.
- Selección de un set de parámetros que permitan detectar daño incipiente en el sistema.

1.2. Alcances

El presente trabajo consiste en la identificación del set de parámetros que acusan un daño incipiente en un sistema rotor con una turbina, proponiendo la utilización de esta misma metodología en estudios similares de rotores.

El estudio se desarrolla utilizando un sistema rotor, el cual se encuentra disponible en el Laboratorio “*Smart Reliability and Maintenance Integration*” del Departamento de Ingeniería civil Mecánica de la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile.

Los resultados obtenidos forman parte del banco de datos de un proyecto Fondecyt: 1160494. “*A Novel Damage Precursor Based Structural Health Monitoring and Prognostic Framework*”.

2. Antecedentes

La siguiente sección tiene por objetivo dar a conocer aspectos teóricos fundamentales para comprender el trabajo a realizar, su metodología, resultados y discusión de estos.

2.1. Velocidad Angular Instantánea y Vibraciones Torsionales

En un sistema rotor con turbina, las cargas producidas en álabes tienen un efecto directo reflejado como vibraciones torsionales en el eje [1]. Para medir estas vibraciones, se utiliza un sensor Encoder, el cual ayuda a medir la Velocidad Angular Instantánea en el eje. El sensor Encoder mide el tiempo que demora la rueda en recorrer cierto ángulo fijado por ranuras. La Figura 2.1 muestra la variación de voltaje y tiempo para un sensor de 360 ranuras (ángulo de 1° por ranura) y un eje girando a velocidad angular constante.

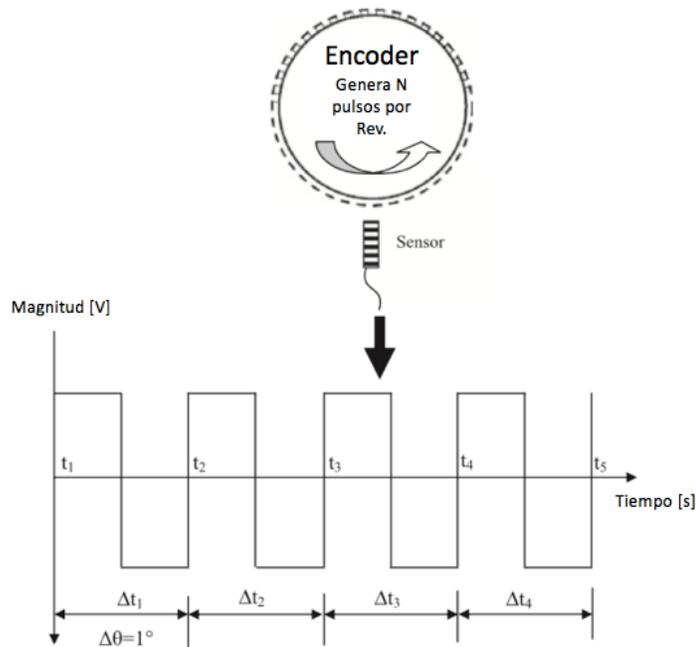


Figura 2.1: Voltaje y tiempo en un sensor encoder. Fuente: Adaptado de Ahmed A. Gubran, et.al. “Shaft instantaneous angular speed for blade vibration in rotating machine” [1].

La velocidad angular instantánea se calcula como:

$$\omega_i = \omega(T_i) = \frac{\Delta\theta_i}{2\pi\Delta t_i} [Hz] \quad (2.1)$$

Donde:

$\Delta\theta_i$ es el ángulo recorrido en el tiempo Δt_i .

$\Delta t_i = t_{i+1} - t_i$.

El tiempo de medición se asume como el promedio entre el tiempo inicial y final del pulso medido, es decir:

$$T_i = \frac{t_i + t_{i+1}}{2} \quad [seg] \quad (2.2)$$

La Figura 2.2 muestra la velocidad angular instantánea de un eje sin vibraciones torsionales, mientras que la Figura 2.3 presenta la velocidad angular instantánea de uno con vibraciones torsionales.

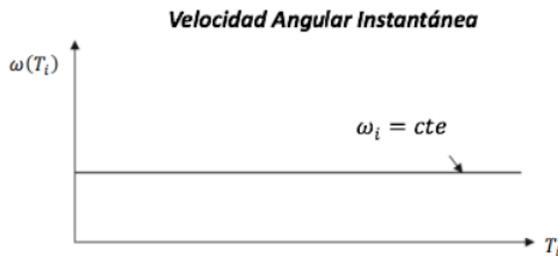


Figura 2.2: Velocidad Angular Instantánea para un eje sin vibraciones torsionales

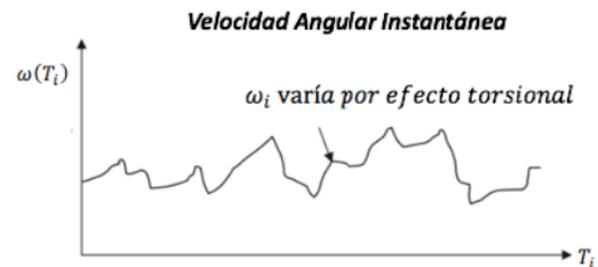


Figura 2.3: Velocidad Angular Instantánea para un eje con vibraciones torsionales

Fuente: Adaptado de Ahmed A. Gubran, et.al. “*Shaft instantaneous angular speed for blade vibration in rotating machine*” [1].

2.2. Principales métodos de análisis de señales

A continuación, se presentan los dos métodos de análisis de señales que serán ampliamente utilizados en el desarrollo de este trabajo de título, Local Mean Decomposition (Descomposición Local Media) y Empirical Mode Decomposition (Descomposición Empírica de Modos).

2.2.1. Local Mean Decomposition

Local Mean Decomposition (LMD) es un método utilizado para descomponer una señal vibratoria en varias otras, a las cuales posteriormente se extrae parámetros desde tres puntos de vista: Tiempo-frecuencia, energía y entropía, y a la vez, parámetros estadísticos característicos [2]. El método LMD se compone de los siguientes ocho pasos:

Paso 1:

Se seleccionan los mínimos y máximos locales de la señal original, estos puntos seleccionados son unidos mediante líneas, generando una curva envolvente superior $E_{max}(t)$ y una curva envolvente inferior $E_{min}(t)$.

Paso 2:

Se calcula la función local media y la función de estimación de la envolvente de la siguiente forma:

$$m_{11}(t) = \frac{E_{max}(t) + E_{min}(t)}{2} \quad (2.3)$$

$$c_{11}(t) = \frac{|E_{max}(t) - E_{min}(t)|}{2} \quad (2.4)$$

Paso 3:

Se calcula el término $h_{11}(t)$ como la resta entre la señal y la función local media:

$$h_{11}(t) = x(t) - m_{11}(t) \quad (2.5)$$

Paso 4: $h_{11}(t)$ es mostrada como una amplitud demodulada al ser dividida por $c_{11}(t)$:

$$s_{11}(t) = \frac{h_{11}(t)}{c_{11}(t)} \quad (2.6)$$

Paso 5:

Se calcula una función local media suavizada $m_{12}(t)$ utilizando el procedimiento anterior para $s_{11}(t)$ en lugar de $x(t)$, dado dicho procedimiento se obtiene $c_{12}(t)$, $h_{12}(t)$ y $s_{12}(t)$. Realizándose n iteraciones:

$$\left\{ \begin{array}{l} h_{11}(t) = x(t) - m_{11}(t) \\ h_{12}(t) = s_{11}(t) - m_{12}(t) \\ \vdots \\ h_{1n}(t) = s_{1n}(t) - m_{1n}(t) \end{array} \right\} \quad (2.7)$$

Donde,

$$\left\{ \begin{array}{l} s_{11}(t) = \frac{h_{11}(t)}{c_{11}(t)} \\ s_{12}(t) = \frac{h_{12}(t)}{c_{12}(t)} \\ \vdots \\ s_{1n}(t) = \frac{h_{1n}(t)}{c_{1n}(t)} \end{array} \right\} \quad (2.8)$$

El objetivo es que $\lim_{n \rightarrow \infty} c_{1n}(t) = 1$.

Paso 6:

Se define $c_1(t)$ como:

$$c_1(t) = c_{11}(t) \cdot c_{12}(t) \cdot \cdots \cdot c_{1n}(t) = \prod_{i=1}^n c_{1i}(t) \quad (2.9)$$

Paso 7:

$PF_1(t)$ es la componente de la descomposición:

$$PF_1(t) = c_1(t) \cdot s_{1n}(t) \quad (2.10)$$

Paso 8:

Se define $r_1(t)$ y se realiza nuevamente el procedimiento completo k veces para $r_k(t)$ en lugar de $x(t)$ hasta que $r_k(t)$ no contenga más oscilaciones:

$$\left\{ \begin{array}{l} r_1(t) = x(t) - PF_1(t) \\ r_2(t) = r_1(t) - PF_2(t) \\ \vdots \\ r_k(t) = r_{k-1}(t) - PF_k(t) \end{array} \right\} \quad (2.11)$$

La señal original puede ser reconstruida de la siguiente forma:

$$x(t) = \sum_{v=1}^k PF_v(t) + r_k(t) \quad (2.12)$$

La Figura 2.4 muestra una señal vibratoria en el dominio del tiempo, tres de sus cinco componentes calculadas y el resto o residuo, obtenidos por medio del algoritmo LMD.

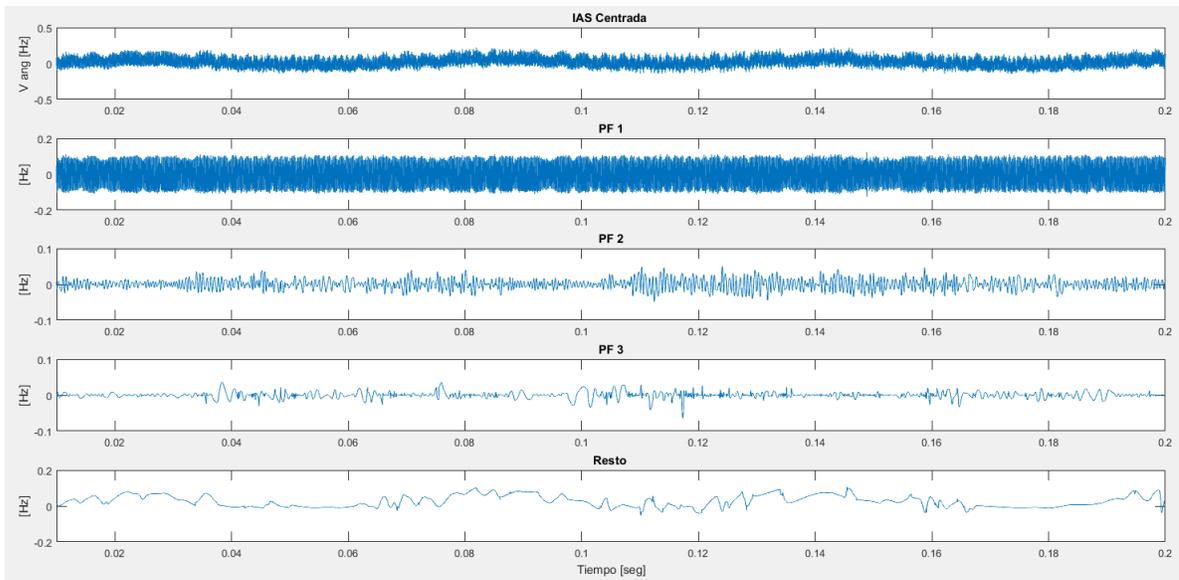


Figura 2.4: Componentes de descomposición PFs de una señal. Fuente propia.

2.2.2. Empirical Mode Decomposition

Empirical Mode Decomposition (EMD) se utiliza al igual que el método LMD para descomponer una señal obtenida en distintas Funciones de Modo Intrínseco (Intrinsic Mode Functions: IMF) [3]. Dichas IMF deben satisfacer los siguientes requisitos [4]:

- El número de extremos (Suma de máximo y mínimo) y el número de cruces por cero deben ser iguales o distintos en una unidad como máximo.
- En cualquier punto de una IMF, el valor medio de la envolvente definida por el máximo local y mínimo local debe ser cero.

La descomposición da como resultado un grupo de componentes IMF ordenados por frecuencia de mayor a menor. Finalmente se obtiene un residuo $r(t)$, el que permite recomponer la señal como el residuo más la sumatoria de las IMF obtenidas, si se desea se pueden eliminar algunas IMF que representan ruido (generalmente las primeras obtenidas), obteniendo una señal $x(t)$ suavizada.

El algoritmo se compone de los siguientes pasos:

Paso 1:

Extraer los máximos y mínimos locales de la señal original $x(t)$, e interpolarlos generando las envolventes superior e inferior, $E_{max}(t)$ y $E_{min}(t)$ respectivamente.

Paso 2:

Calcular la señal promedio de las envolventes superior e inferior denotada por $m_1(t)$. Posteriormente calcular el primer proto-modo $h_1(t)$:

$$m_1(t) = \frac{E_{max}(t) + E_{min}(t)}{2} \quad (2.13)$$

$$h_1(t) = x(t) - m_1(t) \quad (2.14)$$

Paso 3:

Reemplazar la señal original con $h_1(t)$ y repetir los pasos 1 y 2, luego calcular el siguiente proto-componente $h_{11}(t)$:

$$h_{11}(t) = h_1(t) - m_{11}(t) \quad (2.15)$$

donde $m_{11}(t)$ es el valor medio entre las dos envolventes generadas por $h_1(t)$.

Luego de realizar este procedimiento k veces, se obtiene:

$$h_{1k}(t) = h_{1(k-1)}(t) - m_{1k}(t) \quad (2.16)$$

Cuando dos proto-componentes sucesivos satisfacen los dos criterios mencionados anteriormente, entonces el primero de estos es un IMF y se denota como $c_1(t)$.

Paso 4:

Se separa el primer IMF de la señal, obteniendo un residuo:

$$r_1(t) = x(t) - c_1(t) \quad (2.17)$$

El residuo es introducido en el paso 1, iterando nuevamente. El procedimiento se repite n veces hasta obtener un residuo con no más de un máximo o mínimo.

Finalmente puede recomponerse la señal original de la siguiente forma:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (2.18)$$

El residuo obtenido representa la tendencia central de la señal, mientras que los modos descompuestos $c_i(t)$ (o IMFs) representan ruido o interferencia con alta frecuencia y propiedades intrínsecas de la señal.

2.3. Parámetros Estadísticos

2.3.1. Root Mean Square (RMS)

El valor RMS describe el contenido de energía de la señal [5]. RMS se utiliza para evaluar el estado general de los componentes. Debido a esto no es muy sensible a fallo incipiente, sin embargo, se utiliza para realizar un seguimiento de la progresión de fallo general.

$$S_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i)^2} \quad (2.19)$$

Donde:

N es el número de puntos en la historia de la señal S .

S_i es el punto i -ésimo en la evolución temporal de la señal S .

2.3.2. Delta RMS

El Parámetro Delta RMS es la diferencia entre dos valores RMS consiguientes, en un período de toma de datos “ T ” y en el anterior “ $T - 1$ ”. Este parámetro es muy utilizado en engranajes; Si se produce daño en un engranaje, el nivel de vibración se incrementará más rápidamente que en un caso normal sin dañar el engranaje.

$$\Delta RMS = RMS(T) - RMS(T - 1) \quad (2.20)$$

2.3.3. Peak

El valor peak es la máxima amplitud de la señal en cierto intervalo de tiempo.

2.3.4. Peak to Peak

Corresponde a la distancia entre la amplitud máxima y mínima de una señal.

$$S_{peak-peak} = S_{max} - S_{min} \quad (2.21)$$

2.3.5. Media aritmética

Para una señal S , la media aritmética o promedio se calcula como [6]:

$$\bar{S} = \frac{1}{N} \sum_{i=1}^N S_i \quad (2.22)$$

Donde:

N es el número de puntos en la historia de la señal S .

S_i es el punto i -ésimo en la evolución temporal de la señal S .

2.3.6. Varianza

La varianza da cuenta de la distancia entre cada punto y el valor medio en una serie de datos. Para una señal S , la varianza se calcula como:

$$\sigma^2 = \frac{1}{N - 1} \sum_{i=1}^N (S_i - \bar{S})^2 \quad (2.23)$$

Donde:

N es el número de puntos en la historia de la señal S .

S_i es el punto i -ésimo en la evolución temporal de la señal S .

\bar{S} es el valor promedio de los S_i .

2.3.7. Kurtosis

Kurtosis es un parámetro estadístico que proporciona información de cuan agudo son en promedio los peaks de una señal. Si el valor kurtosis es cercano a 3, se tendrá una distribución Gaussiana en relación a los peaks. Kurtosis mayores a 3 implican peaks más puntiagudos y Kurtosis menores a 3 implican peaks más planos.

$$kurtosis = N \frac{\sum_{i=1}^N (S_i - \bar{S})^4}{\left(\sum_{i=1}^N (S_i - \bar{S})^2\right)^2} \quad (2.24)$$

Donde:

N es el número de puntos en la historia de la señal S .

S_i es el punto i -ésimo en la evolución temporal de la señal S .

\bar{S} es el valor promedio de los S_i .

Kurtosis proporciona una medida del tamaño de las colas de la distribución y se utiliza como un indicador de los peaks principales en un conjunto de datos. Si un engranaje se desgasta y se rompe, esta característica debe señalar un error debido al mayor nivel de vibración.

2.3.8. Crest Factor

El Crest Factor (al cual también llamaremos Factor Cresta en español), da cuenta de la diferencia entre el peak de una señal respecto a su valor RMS. El valor del Factor cresta es normalmente entre 2 y 6. Un factor cresta mayor a 6 indica un posible fallo de la máquina. Los rodamientos poseen un valor de CF aproximado entre 2,5-3,5, rodamientos con factor cresta mayores a 7 representan una eventual falla [7].

Existen ciertas variaciones en la definición del factor de cresta, donde el numerador podría ser el valor peak (máximo o mínimo) o una media de los valores máximo y mínimo de la señal de interés.

El Factor cresta puede ser utilizado para indicar fallos en una etapa temprana. Esta función se utiliza para detectar cambios en el patrón de señal debido a las fuentes de vibración impulsivos tales como la rotura de dientes en un engranaje.

$$CF = \frac{S_{peak}}{S_{RMS}} \quad (2.25)$$

2.3.9. Skewness

El parámetro Skewness (o Asimetría) indica la simetría en la amplitud de la función de densidad de probabilidad de una serie de tiempo. Una serie de tiempo con un número igual de amplitudes grandes y pequeñas tiene una asimetría de cero.

$$Skewness = N \frac{\sum_{i=1}^N (S_i - \bar{S})^3}{\left(\sqrt{\sum_{i=1}^N (S_i - \bar{S})^2}\right)^3} \quad (2.26)$$

Donde:

N es el número de puntos en la historia de la señal S .

S_i es el punto i -ésimo en la evolución temporal de la señal S .

\bar{S} es el valor promedio de los S_i .

Una serie de tiempo con muchos valores pequeños y pocos valores grandes tiene un sesgo positivo (extremo derecho), y el valor de la asimetría es positiva. Una serie de tiempo con muchos de los grandes valores y unos valores pequeños es sesgada negativamente (cola de la izquierda), y el valor de la asimetría es negativo.

2.3.10. Momentos Centrados

Los momentos centrados de orden k de un set de datos S , representan la esperanza matemática $E \left[(S - \bar{S})^k \right]$, donde E es el operador Esperanza y $E[S] = \bar{S}$.

$$c_k = \frac{1}{N} \sum_{i=1}^N (S_i - \bar{S})^k \quad (2.27)$$

Donde:

N es el número de puntos en la historia de la señal S .

S_i es el punto i -ésimo en la evolución temporal de la señal S .

\bar{S} es el valor promedio de los S_i .

2.3.11. Energía de Shannon

Como se mencionó anteriormente, el valor RMS de una señal vibratoria se relaciona a la energía contenida en esta. La energía de Shannon para una señal de N datos dividida (por LMD o EMD, por ejemplo) en m componentes C_k se representa como una razón de la energía total [8].

$$T_k = \sqrt{\frac{1}{N} \sum_{i=1}^N C_{k,i}^2} = RMS(C_k) \quad (2.28)$$

$$E_k = \frac{T_k}{\sum_{k=1}^m T_k} \quad (2.29)$$

Donde:

C_k es la componente k de una señal S_i .

$C_{k,i}$ es el punto i-ésimo en la evolución temporal de la componente C_k .

T_k es el contenido energético (o valor RMS) de cada componente C_k .

E_k es la energía de Shannon para cada componente C_k .

2.3.12. Entropía de Shannon

La entropía de Shannon para una señal de N datos dividida (por LMD o EMD, por ejemplo) en m componentes C_k se representa como una función de la energía de Shannon [9].

$$H_k = -E_k \log E_k \quad (2.30)$$

Donde:

E_k es la energía de Shannon para cada componente C_k .

2.3.13. Derivada discreta de una señal

Para una señal S, su derivada discreta se representa como:

$$dS = S_i - S_{i-1} \quad (2.31)$$

Donde:

S_i es el punto i-ésimo en la evolución temporal de la señal S.

2.3.14. Integral discreta de una señal

La integral discreta de una señal S, se representa según la siguiente ecuación:

$$I_s = S_i + S_{i-1} \quad (2.32)$$

Donde:

S_i es el punto i-ésimo en la evolución temporal de la señal S.

2.4. Parámetros en el dominio de frecuencias

2.4.1. Media aritmética para una banda de frecuencias

La media aritmética para una banda de frecuencias dentro del espectro de Fourier A se calcula por medio de la siguiente ecuación:

$$\bar{A} = 20 \log \left(\frac{\frac{1}{N} \sum_{i=1}^N A_i}{10^{-5}} \right) \quad [dBm] \quad (2.33)$$

Donde:

A_i es el punto i-ésimo de la serie de amplitudes para la banda de frecuencias elegida.

N es el número de puntos en la historia de la serie A.

2.4.2. Media geométrica para una banda de frecuencias

La media geométrica para una banda de frecuencias dentro del espectro de Fourier A se calcula de la siguiente forma:

$$\overline{A_G} = \frac{1}{N} \sum_{i=1}^N 20 \log \left(\frac{A_i}{10^{-5} \sqrt{2}} \right) \quad [dBm] \quad (2.34)$$

Donde:

A_i es el punto i-ésimo de la serie de amplitudes para la banda de frecuencias elegida.

N es el número de puntos en la historia de la serie A.

2.4.3. Armónicos de un eje

Los armónicos son peaks que se encuentran a frecuencias múltiplos de la frecuencia de giro del eje. El estudio de la amplitud de estos armónicos ayuda a identificar potenciales fallas en un eje [10].

Shaft Order 1 (SO1): Representa la magnitud del primer armónico en el dominio de frecuencias del Eje. SO1 es un indicador de desbalance de masa o eje doblado.

Shaft Order 2 (SO2) : Segundo armónico en el dominio de frecuencias. El SO2 es sensible a los fallos de acoplamiento (desalineación) o eje doblado.

Shaft Order 3 (SO3): Tercer armónico. SO3 es sensible a los fallos de acoplamiento. Para el rotor principal, SO3 es impulsado por el efecto combinado de la sombra de la torre y la cizalladura del viento.

2.5. Support Vector Machine

Support Vector Machine (o Máquina de Vectores de Soporte: SVM) es un algoritmo de aprendizaje supervisado, que se utiliza frecuentemente para la clasificación de datos a partir de un conjunto de entrenamiento. SVM es empleado también para solucionar problemas de regresión [11]. Para el caso de datos binarios, linealmente separables, el algoritmo SVM opera de la siguiente manera:

A partir del conjunto de datos de entrenamiento, se busca encontrar el hiperplano que logra separar de mejor manera ambas clases, sin embargo, existe más de un hiperplano que logra separar dichas clases [12]. La Figura 2.5 muestra un ejemplo en dos dimensiones, cada eje corresponde a una característica o parámetro. La Figura 2.6 presenta la gran variedad de hiperplanos que podrían separar ambas clases.

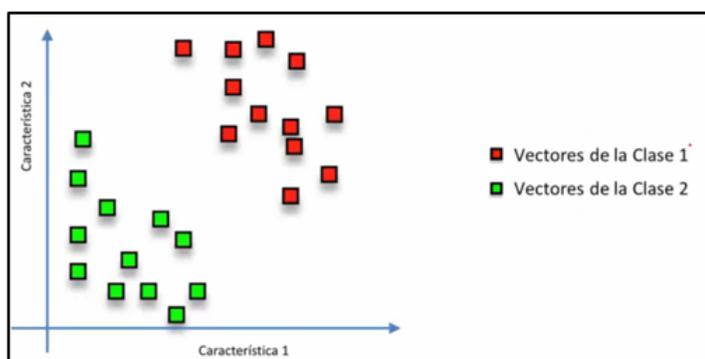


Figura 2.5: Ejemplo SVM para dos parámetros. Fuente: Valveny E, et.al [12].

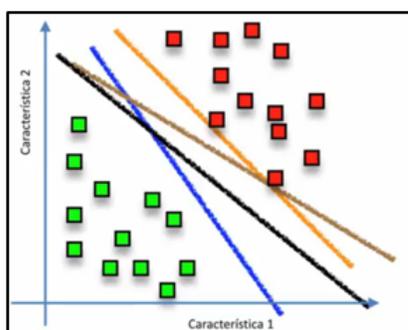


Figura 2.6: Posibles hiperplanos separadores entre clases. Fuente: Valveny E, et.al [12].

El problema se resuelve encontrando el hiperplano que posea un margen máximo. El margen corresponde a la distancia entre el hiperplano y los elementos más cercanos de cada clase, los cuales son llamados “Vectores de soporte”. A partir de los vectores de soporte se crean dos hiperplanos paralelos al hiperplano solución. La Figura 2.7 muestra estos últimos elementos mencionados.

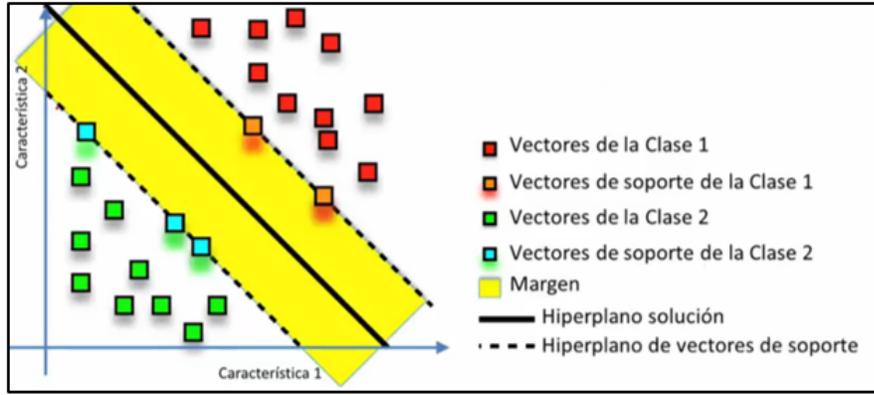


Figura 2.7: Margen e hiperplanos de soporte en SVM. Fuente: Valveny E, et.al [12].

El hiperplano solución se representa mediante la siguiente ecuación [13]:

$$\omega^T \vec{x} + b = 0 \quad (2.35)$$

Donde:

\vec{x} representa a la variable dependiente de la ecuación del hiperplano, es decir, un vector de características.

ω es el vector perpendicular al hiperplano solución, que va desde el hiperplano hasta el dato más cercano.

b es un coeficiente de posición del hiperplano.

Los hiperplanos de vectores de soporte se representan mediante las ecuaciones:

$$h^+ := \omega^T \vec{x} + b = 1 \quad (2.36)$$

$$h^- := \omega^T \vec{x} + b = -1 \quad (2.37)$$

Los datos de entrenamiento son denotados por una función de clasificación:

$$f(\vec{x}) = \begin{cases} +1, & \text{si } (\omega^T \vec{x} + b) \geq 0 \\ -1, & \text{si } (\omega^T \vec{x} + b) < 0 \end{cases} \quad (2.38)$$

De tal manera, los datos positivos corresponden a aquellos que se encuentran a la derecha del hiperplano solución, mientras que los datos negativos se encuentran a la izquierda del hiperplano solución. La Figura 2.8 expone de forma gráfica estas ecuaciones.

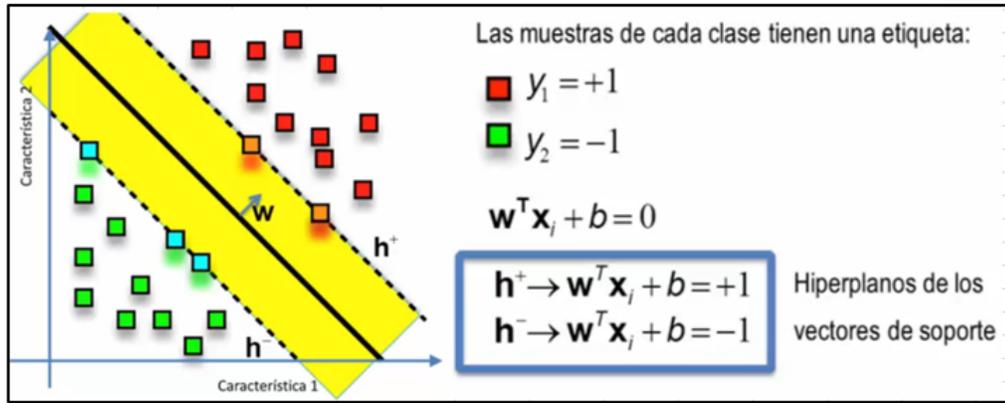


Figura 2.8: Hiperplanos de soporte, ecuaciones. Fuente: Valveny E, et.al [12].

Los datos bien clasificados serán aquellos que se encuentren afuera del margen creado por los hiperplanos de soporte, es decir $\omega^T \vec{x}_i + b > 1$ o por el contrario $\omega^T \vec{x}_i + b < -1$, por lo que se define la siguiente condición de clasificación:

$$f(\vec{x}_i) (\omega^T \vec{x}_i + b) > 1 \quad (2.39)$$

La distancia entre el hiperplano solución y un hiperplano de vectores de soporte se denota como:

$$d = \frac{\|\omega^T \vec{x} + b\|}{\|\omega\|} = \frac{1}{\|\omega\|} \quad (2.40)$$

Donde se tiene que el margen es:

$$\text{margen} = 2d = \frac{2}{\|\omega\|} \quad (2.41)$$

Sin embargo, es importante notar que maximizar el margen es equivalente al siguiente problema de minimización:

$$\begin{aligned} & \text{mín}_{\omega, b} \left(\phi(\omega) = \frac{\omega^T \omega}{2} \right) \\ \text{S.a} \quad & f(\vec{x}_i) (\omega^T \vec{x}_i + b) > 1 \end{aligned} \quad (2.42)$$

El problema se resuelve mediante el método del Lagrangiano, de la siguiente forma:

$$\text{máx}_{\alpha_i} \left(\text{mín}_{\omega, b} \left(L(\omega, b, \alpha_i) = \frac{\omega^T \omega}{2} - \sum_i \alpha_i [f(\vec{x}_i) (\omega^T \vec{x}_i + b) - 1] \right) \right) \quad (2.43)$$

Donde:

$L(\omega, b, \alpha_i)$ es el Lagrangiano asociado al problema de optimización.

α_i son los multiplicadores de Lagrange, donde $\alpha_i > 0 \quad \forall i$.

Para minimizar el Lagrangiano, se debe cumplir que $\nabla L(\omega, b, \alpha_i) = \vec{0}$, donde se obtiene:

$$\frac{\partial}{\partial \omega} L(\omega, b, \alpha_i) = 0 \quad \Rightarrow \quad \omega = \sum_i \alpha_i f(\vec{x}_i) x_i \quad (2.44)$$

$$\frac{\partial}{\partial b} L(\omega, b, \alpha_i) = 0 \quad \Rightarrow \quad \sum_i \alpha_i f(\vec{x}_i) = 0 \quad (2.45)$$

Reemplazando posteriormente en la ecuación 2.43 se obtiene el siguiente problema dual de optimización:

$$\begin{aligned} \text{máx}_\alpha \quad & \left(\theta(\alpha) = -\frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j f(\vec{x}_i) f(\vec{x}_j) x_i x_j + \sum_i \alpha_i \right) \\ \text{S.a} \quad & \sum_i \alpha_i f(\vec{x}_i) = 0, \quad \alpha_i > 0 \quad \forall i \end{aligned} \quad (2.46)$$

Finalmente se obtienen los valores ω y b correspondientes al hiperplano óptimo.

Luego de la obtención de un hiperplano óptimo a través de los datos de entrenamiento, el clasificador SVM es capaz de recibir nuevos datos desconocidos y clasificarlos en una de estas dos clases.

En casos de datos que no puedan ser linealmente separados, existe la posibilidad de trabajar mediante una función Kernel [6]. Dicha función proyecta los datos a un espacio de características de mayor dimensionalidad, espacio en el que los elementos si pueden ser separados. Existen diversos tipos de funciones Kernel, algunas de las más comunes son: Polinomial, de base radial, sigmoideal, de intersección, etc.

2.6. Clasificación

Supongamos que se tiene un conjunto de datos con daño y un conjunto de datos sin daño. Por medio de un clasificador se determina cual grupo de datos posee daño. El conjunto de datos estará dividido en verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, como se observa en la Figura 2.9.

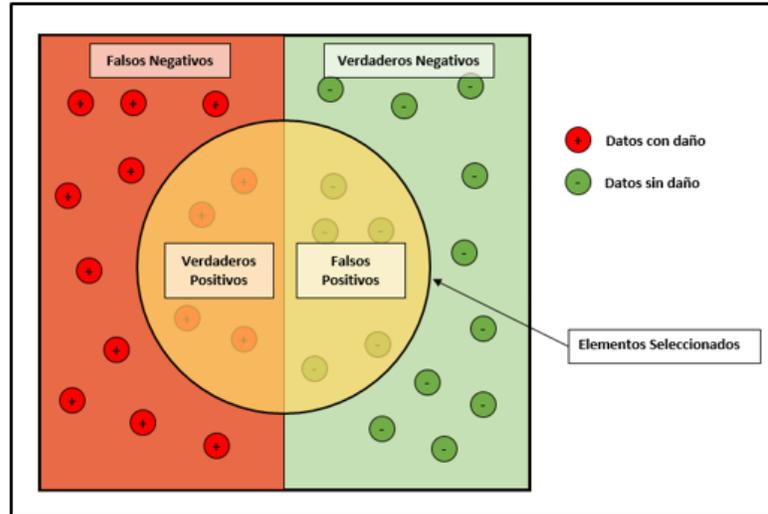


Figura 2.9: Esquema de clasificación binaria de datos con daño y sanos.

- **Verdaderos Positivos (TP):** Corresponde al conjunto de datos que teniendo daño fue bien clasificado.
- **Verdaderos Negativos (TN):** Corresponde al conjunto de datos sin daño que fue bien clasificado.
- **Falsos Positivos (FP):** Corresponde al conjunto de datos que no tenía daño y fue clasificado como si lo tuviera.
- **Falsos Negativos (FN):** Conjunto de datos que tenía daño y fue clasificado como sanos.

A partir de estos resultados se calculan los siguientes parámetros estadísticos:

2.6.1. Exactitud

Consiste en el porcentaje de datos que fue bien clasificado respecto del total de datos.

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} 100 \quad [\%] = 1 - Error_{tot} \quad [\%] \quad (2.47)$$

2.6.2. Precisión

Corresponde a la cantidad de elementos que realmente eran positivos, en comparación con todos los elementos clasificados como positivos.

$$Precisin = \frac{TP}{TP + FP} 100 \quad [\%] \quad (2.48)$$

2.6.3. Tasa de acierto

Da cuenta de cuantos elementos positivos fueron identificados respecto del total de elementos positivos.

$$Tasa \ de \ acierto = \frac{TP}{TP + FN} 100 \quad [\%] \quad (2.49)$$

2.7. Algoritmos de selección de parámetros

Los algoritmos de selección de parámetros se utilizan en conjunto con el clasificador para identificar cual es el conjunto de parámetros o características que obtienen un menor error en la clasificación. A continuación, se presentan 4 de estos:

- **Sequential Forward Selection (SFS):** Comienza analizando solamente un parámetro, agregando secuencialmente en cada paso un nuevo parámetro al conjunto y calculando el error. Finalmente obtiene el conjunto cuyo error de clasificación de datos es el menor.
- **Sequential Floating Forward Selection (SFFS):** Utiliza el mismo método que SFS, sin embargo, los parámetros eliminados pueden ser reutilizados.
- **Sequential Backward Selection (SBS):** Comienza analizando el conjunto total de parámetros y elimina secuencialmente el menos significativo hasta obtener el conjunto cuyo error de clasificación es mínimo.
- **Sequential Floating Backward Selection (SFBS):** Trabaja similar al SBS, sin embargo, los parámetros eliminados pueden ser reutilizados.

3. Metodología

La presente sección introduce en términos generales la metodología de trabajo utilizada, más detalles se muestran en la sección de resultados.

Con el objetivo de identificar el set de parámetros que determinan posibles fallas incipientes en un sistema rotor con una turbina, se analizan datos vibratorios medidos experimentalmente por medio de un sensor encoder y un acelerómetro.

El montaje experimental se observa en la Figura 3.1, y consiste en un motor eléctrico, conectado mediante una copla flexible a un eje, el cual es soportado por dos rodamientos, entre ellos lleva una turbina con álabes intercambiables y en el extremo un sensor encoder, bajo uno de los rodamientos se encuentra instalado un sensor acelerómetro [14].

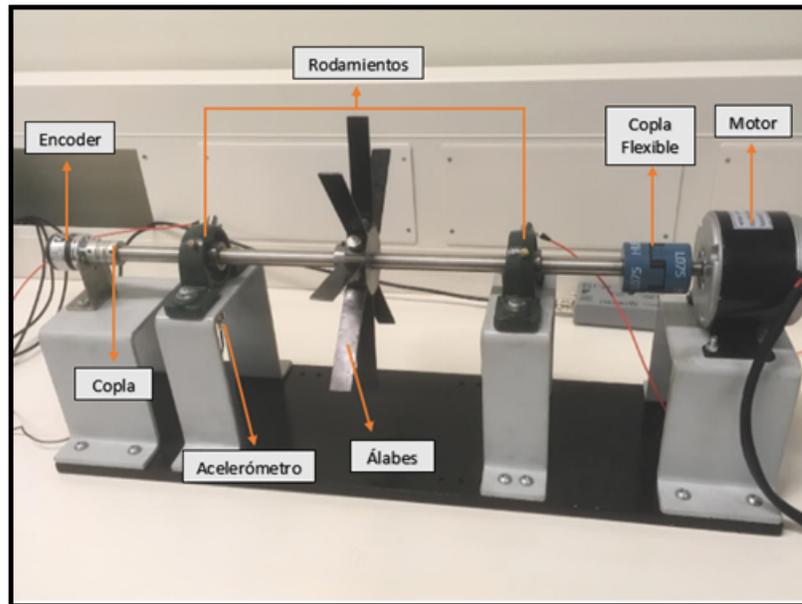


Figura 3.1: Montaje experimental.

Se analizan álabes de la turbina expuestos a distintos niveles de daño, tales como grietas de diversos tamaños y posición. Los resultados obtenidos son comparados con un caso base, en el cual todos los álabes están en perfecto estado, y un caso extremo, correspondiente al funcionamiento de la turbina en ausencia de un álabe.

La señal a analizar proviene del sensor encoder, en base a esta se calcula la velocidad angular instantánea del sistema (IAS). Se utilizan, entre otros, los algoritmos LMD y EMD para descomponer las IAS en distintos factores, y se extrae una serie de parámetros estadísticos de estos, tales como RMS, Peak to peak, kurtosis, asimetría, etc. Finalmente se utiliza el algoritmo de selección SFS en conjunto con Support Vector Machine para identificar un set de parámetros que permita detectar de mejor manera la existencia de daño en el sistema.

Se espera obtener vibraciones torsionales de menor amplitud en el caso base, por ende, parámetros estadísticos más moderados, en el caso extremo será lo contrario. En los casos con grietas, las vibraciones serán, en general, mayores cuando la grieta sea mayor.

Con estos resultados, se busca obtener un set de parámetros estadísticos capaz de detectar daño incipiente en el sistema rotor.

La metodología de trabajo se desarrolla en las siguientes etapas:

1. Puesta a punto del Montaje, esto contempla:
 - i.* Rectificación de componentes defectuosos y ensamble del montaje experimental.
 - ii.* Pruebas de funcionamiento.
2. Toma de datos.
3. Análisis y procesamiento de señales:
 - i.* Comprensión del dominio de medición y de los datos adquiridos en el estudio experimental.
 - ii.* Extracción de los datos desde los formatos de adquisición al software MATLAB.
 - iii.* Implementación de algoritmos EMD y LMD en código MATLAB.
 - iv.* Procesamiento de señales mediante la aplicación de los algoritmos EMD y LMD en MATLAB.
4. Selección de parámetros:
 - i.* Extracción de parámetros de las señales descompuestas obtenidas por medio de los algoritmos EMD y LMD, y de la derivada e integral discreta de cada señal.
 - ii.* Análisis de los resultados obtenidos.
 - iii.* Selección de parámetros que acusan daño incipiente en el sistema por medio de un clasificador SVM.

4. Resultados y análisis

El presente capítulo, tiene por objetivo dar a conocer los resultados más relevantes obtenidos en las dos etapas de toma de mediciones realizadas, y desarrollar el análisis de estos, comparando entre los resultados obtenidos por vibraciones torsionales y transversales. Al mismo tiempo, se explican detalles fundamentales en relación al procedimiento realizado para la extracción y clasificación de parámetros.

4.1. Resultados primera etapa de estudios. Velocidades angulares instantáneas

A continuación, se exponen los resultados más relevantes obtenidos en la primera etapa de toma de datos experimentales, correspondiente a la medición de vibraciones para el caso base (o sano), con todos los álabes funcionando sin problemas, y el caso extremo, con el rotor funcionando en ausencia un álabe.

La señal IAS es particionada en conjuntos de 1024 puntos de medición, de los cuales 512 puntos son superpuestos con el conjunto anterior. Para cada grupo de 1024 puntos de medición se calculan 100 parámetros, generando "N" vectores de 100x1 que más adelante serán denominados como "Datos", es importante destacar que el valor N dependerá directamente del tiempo de la toma de mediciones [15]. La Figura 4.1 muestra un ejemplo de la partición de datos para el caso sano.

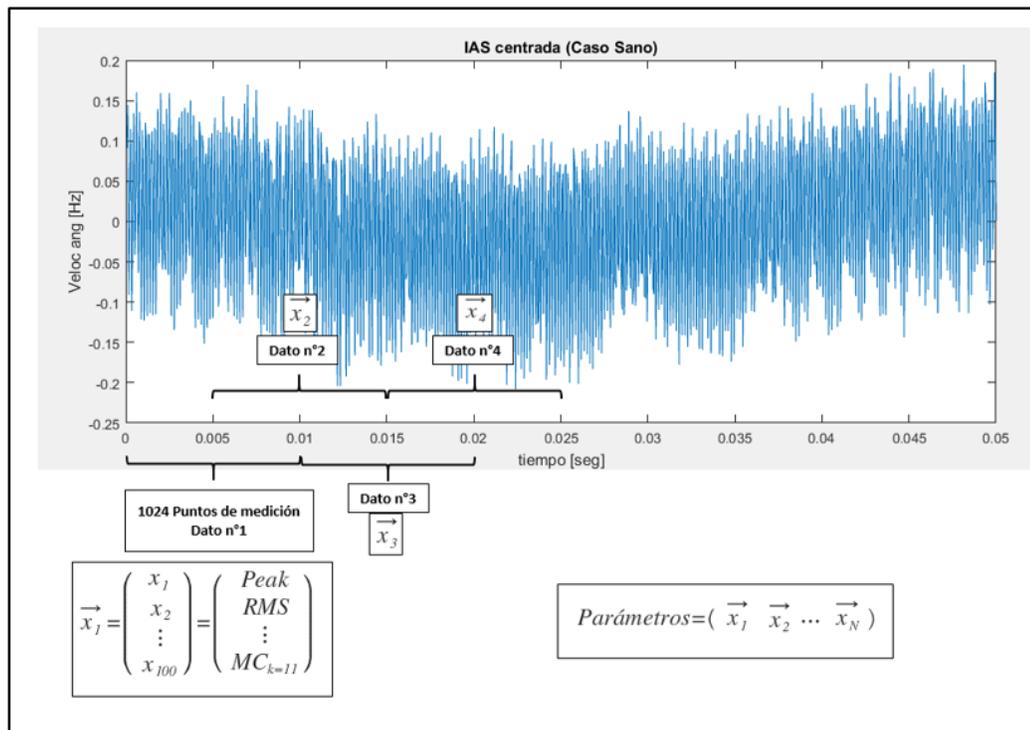


Figura 4.1: Partición de datos y confección de matriz "Parámetros", caso sano. Fuente propia.

Durante el estudio, se ha desarrollado en Matlab una función llamada “Parameters”, cuya respuesta es una matriz denominada “Parámetros” de 100xN que contiene en cada fila el cálculo de un parámetro a estudiar, como se muestra en la 4.1, donde N corresponde al número total de datos. Es importante destacar que dicha función calcula parámetros para la señal derivada e integrada, y también contiene las funciones LMD y EMD implementadas previamente en Matlab.

La Tabla 4.1 detalla el orden de los primeros 70 parámetros, los cuales se calculan sobre la señal original, incluyendo el espectro de Fourier y los algoritmos EMD y LMD, mientras que la Tabla 4.2 a continuación, detalla el orden de los parámetros 71 a 100 calculados sobre la derivada e integral de la señal original.

Tabla 4.1: Parámetros señal original.

Señal	Parámetro	Fila en la matriz "Parámetros"
Señal Original	Amplitud Máxima (peak)	1
	Root Mean Square (RMS)	2
	Amplitud Peak to peak	3
	Factor cresta	4
	Media Aritmética	5
	Varianza	6
	Asimetría	7
	Kurtosis	8
	Momentos Centrados (k=5-11)	9 a 15
	Media Aritmética de la Amplitud de Fourier, dividida en 25 Bandas de frecuencia	16 a 40
	RMS de los primeros 5 IMFs (Empirical Mode Decomposition)	41 a 45
	Energía de Shannon de los primeros 5 IMFs (Empirical Mode Decomposition)	46 a 50
	Entropía de Shannon de los primeros 5 IMFs (Empirical Mode Decomposition)	51 a 55
	RMS de los primeros 5 PFs (Local Mean Decomposition)	56 a 60
	Energía de Shannon de los primeros 5 PFs (Local Mean Decomposition)	61 a 65
	Entropía de Shannon de los primeros 5PFs (Local Mean Decomposition)	66 a 70

Tabla 4.2: Parámetros para la derivada e integral de la señal original.

Señal	Parámetro	Fila en la matriz "Parámetros"
Derivada de la señal original	Amplitud Máxima (peak)	71
	Root Mean Square (RMS)	72
	Amplitud Peak to peak	73
	Factor cresta	74
	Media Aritmética	75
	Varianza	76
	Asimetría	77
	Kurtosis	78
	Momentos Centrados (k=5-11)	79 a 85
	Integral de la señal original	Amplitud Máxima (peak)
Root Mean Square (RMS)		87
Amplitud Peak to peak		88
Factor cresta		89
Media Aritmética		90
Varianza		91
Asimetría		92
Kurtosis		93
Momentos Centrados (k=5-11)		94 a 100

En primer lugar, la Figura 4.2 consiste en la velocidad angular instantánea (IAS) centrada para el caso base, mientras que la Figura 4.3 corresponde a la IAS centrada del caso extremo. De igual manera, la Figura 4.4 presenta la IAS del sistema calculada por cada revolución para el caso base, y la Figura 4.5 muestra esta misma para el caso extremo. Los datos fueron obtenidos mediante un sensor encoder de 1024 ranuras por revolución. Las IASs fueron calculadas de acuerdo a las ecuaciones 2.1 y 2.2. Cabe destacar que el tiempo de muestreo ronda alrededor de 25 segundos y la frecuencia de muestreo utilizada es de 96 kHz, la cual corresponde a la máxima frecuencia de muestreo que puede utilizar el equipo, esto se realiza para asegurar que no ocurra el efecto de Aliasing [16].

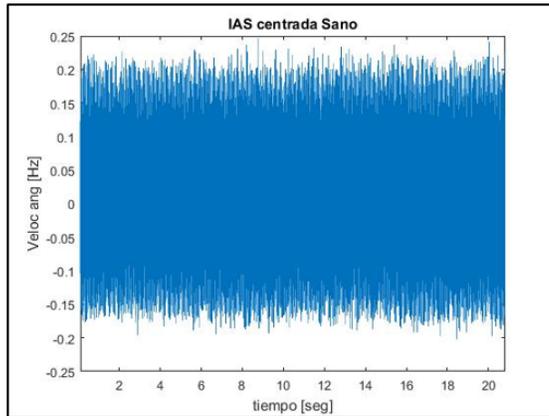


Figura 4.2: IAS Caso Sano.

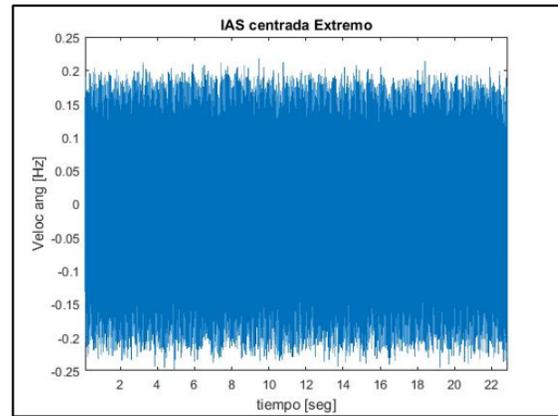


Figura 4.3: IAS Caso Extremo.

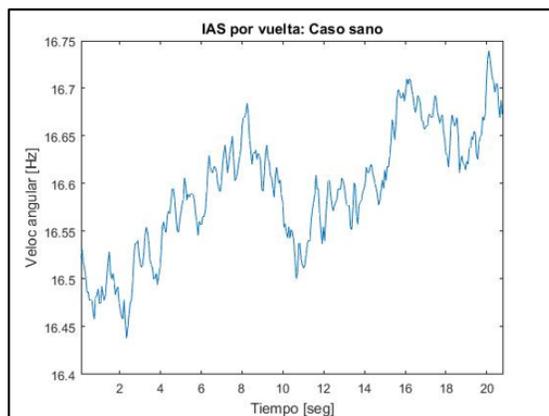


Figura 4.4: IAS calculado por vuelta, Caso sano.

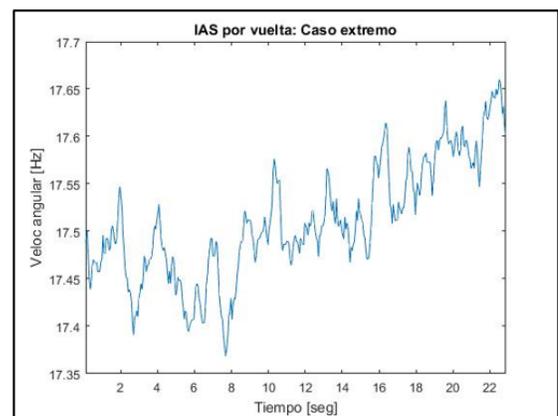


Figura 4.5: IAS calculado por vuelta, Caso extremo.

4.2. Análisis de velocidades angulares instantáneas

En la Figuras 4.2 y 4.3 se observa claramente, en ambos casos, un comportamiento oscilatorio en la velocidad angular instantánea del eje, esto quiere decir que efectivamente existen vibraciones torsionales en el sistema, como se ejemplifica en la Figura 2.3 de la sección de antecedentes.

Se observa también en ambos casos que el comportamiento oscilatorio no parece ser periódico, aunque la amplitud de oscilación resulta ser cercana a una constante. Este efecto puede deberse a que el sistema que alimenta de energía al motor eléctrico no es capaz de mantener su velocidad constante en el tiempo, más aún, las Figuras 4.4 y 4.5 dan cuenta de la notoria variación de velocidad entre cada revolución del sistema. Por otra parte, se observó que el voltaje y corriente entregados al motor variaban levemente en el tiempo durante las mediciones, sin haber manipulado el dispositivo.

Como fue mencionado, para cada caso existe una amplitud de oscilación relativamente constante, alrededor de 0,3 Hz para el caso base y 0,4 Hz para el caso extremo. Esto quiere decir que las vibraciones torsionales en el caso extremo son efectivamente mayores que en el caso base, este punto también se corrobora a continuación por medio de algunos parámetros como RMS y Peak to peak, y confirma lo esperado según la teoría.

4.3. Resultados primera etapa de estudios. Parámetros sobre vibraciones torsionales

A continuación, desde la Figura 4.6 hasta la Figura 4.45, se introducen gráficos comparativos entre el caso base y extremo, para los parámetros calculados sobre vibraciones torsionales, que presentaron variaciones visualmente más significativas respecto al resto de los parámetros calculados. En ambos casos, los parámetros calculados han sido normalizados respecto al caso base. En cada una de las figuras existe una línea divisora que separa el caso base (izquierda) del caso extremo (derecha). El eje X de cada gráfico representa el número correspondiente a cada dato medido.

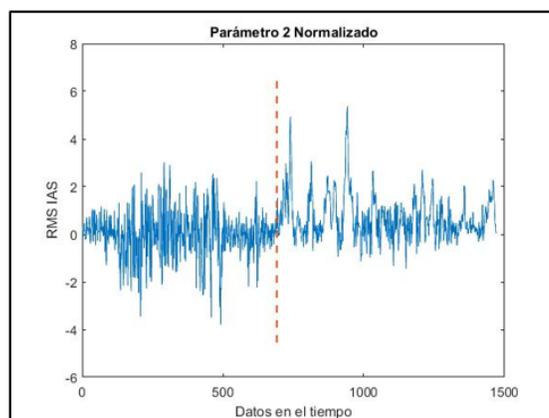


Figura 4.6: Parámetro 2. Sano (Izquierda), extremo (derecha).

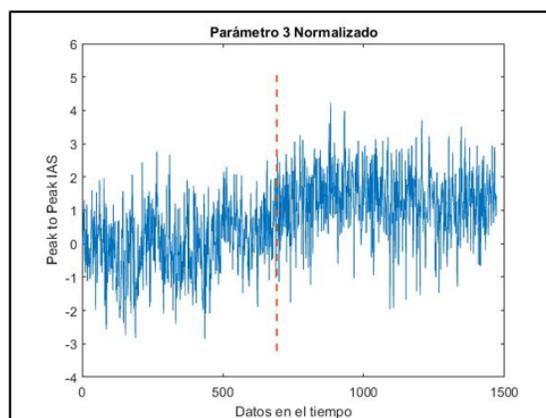


Figura 4.7: Parámetro 3. Sano (Izquierda), extremo (derecha).

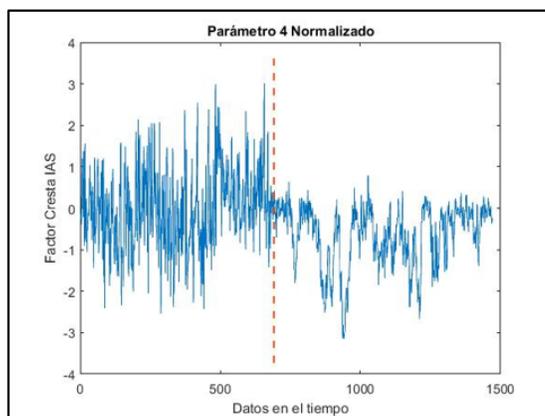


Figura 4.8: Parámetro 4. Sano (Izquierda), extremo (derecha).

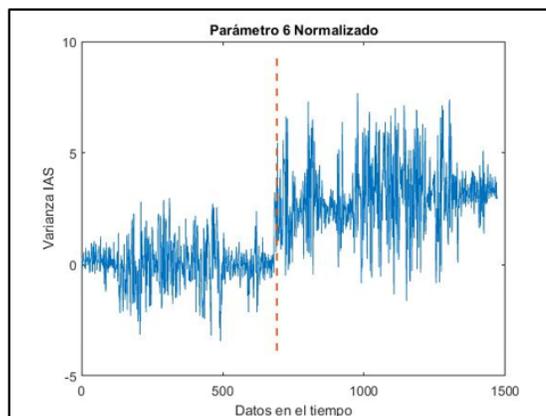


Figura 4.9: Parámetro 6. Sano (Izquierda), extremo (derecha).

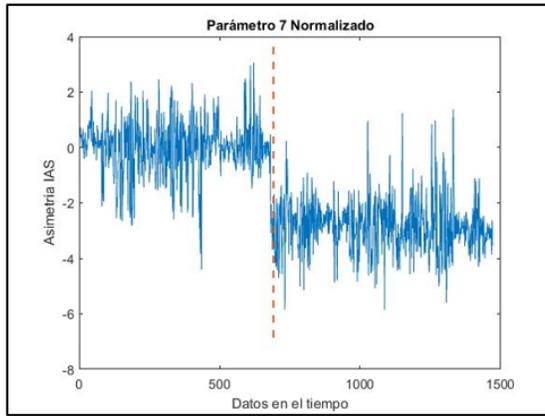


Figura 4.10: Parámetro 7. Sano (Izquierda), extemo (derecha).

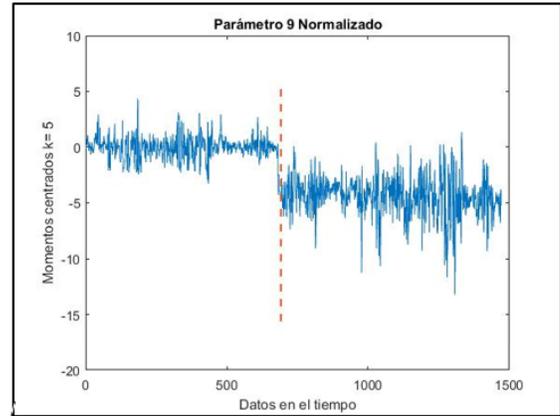


Figura 4.11: Parámetro 9. Sano (Izquierda), extemo (derecha).

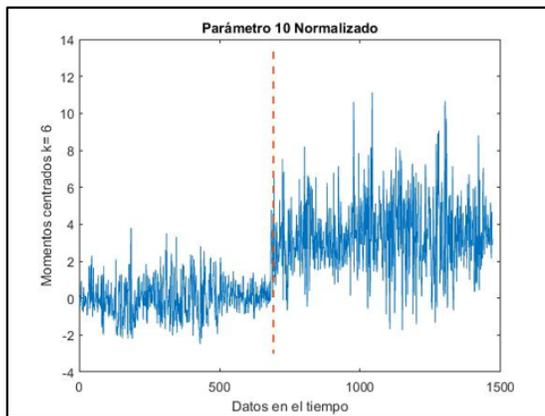


Figura 4.12: Parámetro 10. Sano (Izquierda), extemo (derecha).

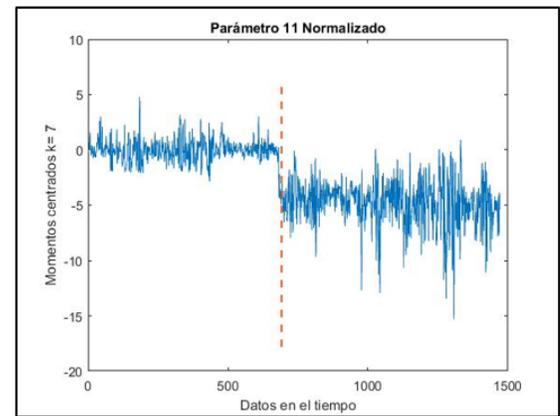


Figura 4.13: Parámetro 11. Sano (Izquierda), extemo (derecha).

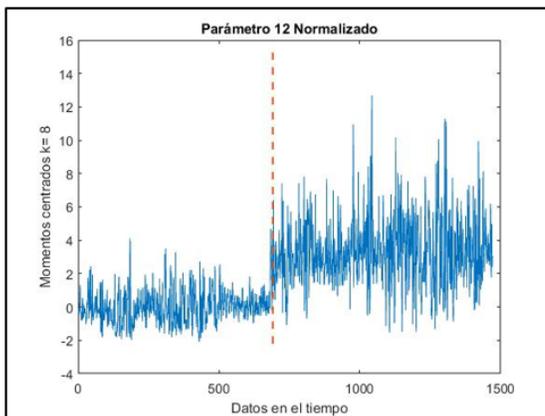


Figura 4.14: Parámetro 12. Sano (Izquierda), extemo (derecha).

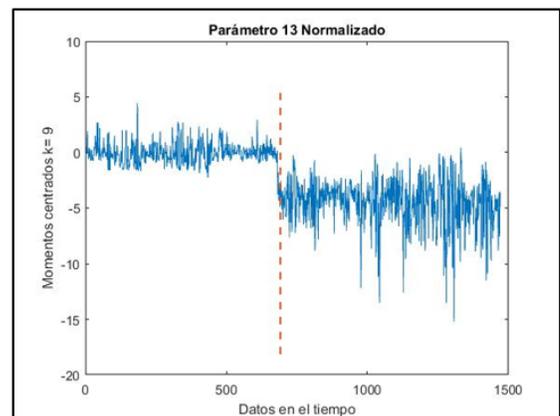


Figura 4.15: Parámetro 13. Sano (Izquierda), extemo (derecha).

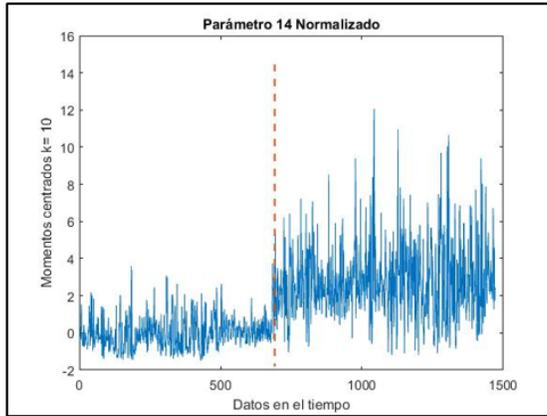


Figura 4.16: Parámetro 14. Sano (Izquierda), extemo (derecha).

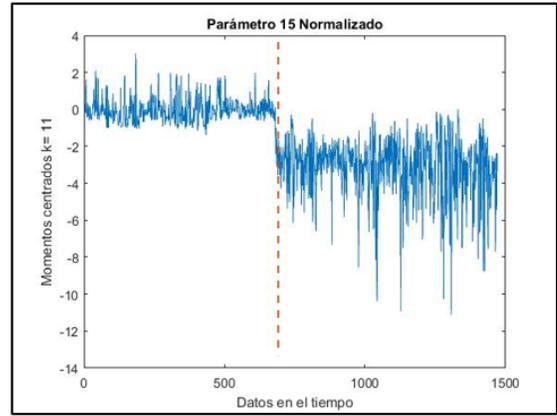


Figura 4.17: Parámetro 15. Sano (Izquierda), extemo (derecha).

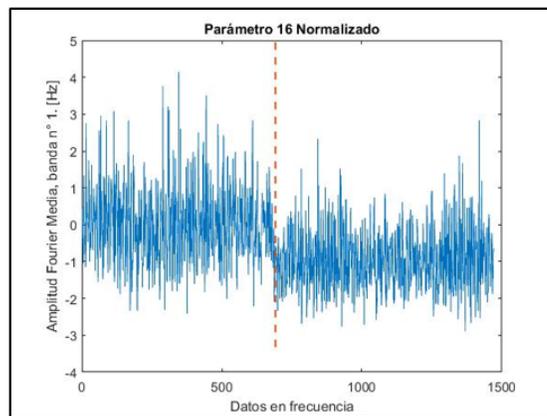


Figura 4.18: Parámetro 16. Sano (Izquierda), extemo (derecha).

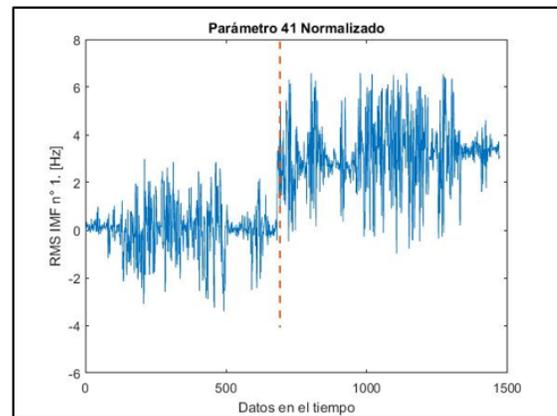


Figura 4.19: Parámetro 41. Sano (Izquierda), extemo (derecha).

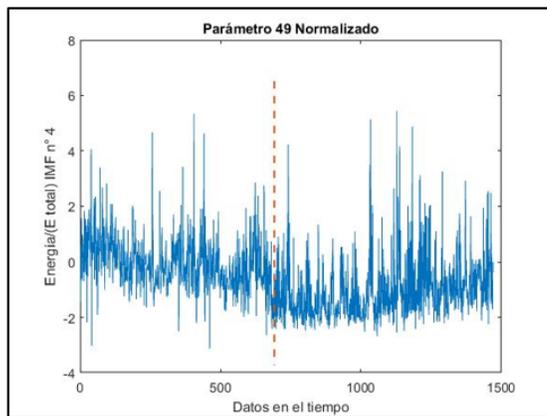


Figura 4.20: Parámetro 49. Sano (Izquierda), extemo (derecha).

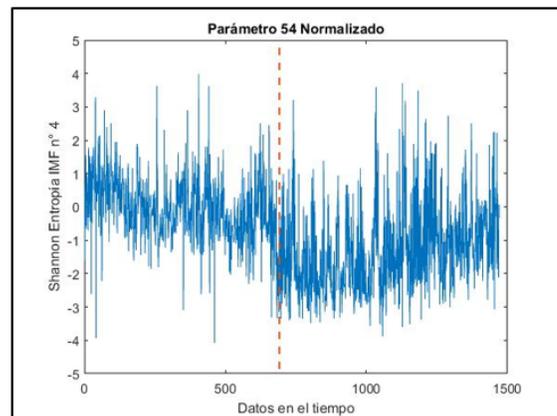


Figura 4.21: Parámetro 54. Sano (Izquierda), extemo (derecha).

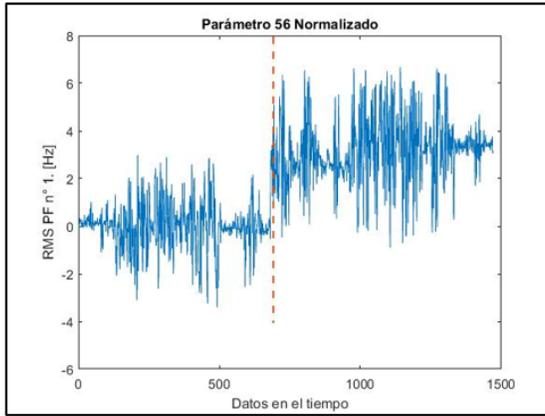


Figura 4.22: Parámetro 56. Sano (Izquierda), extemo (derecha).

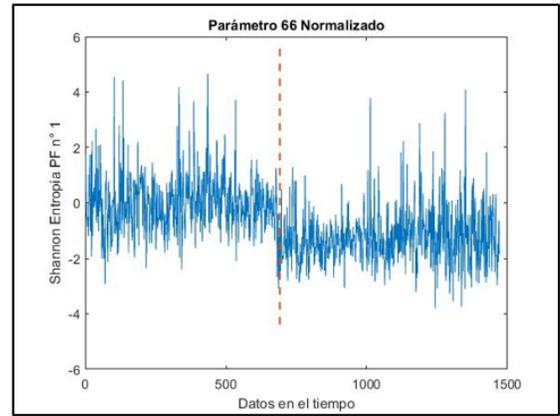


Figura 4.23: Parámetro 66. Sano (Izquierda), extemo (derecha).

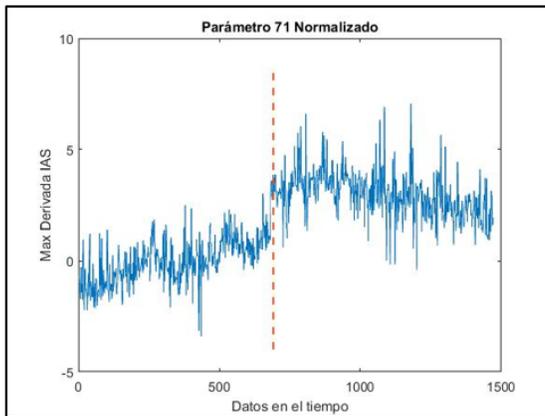


Figura 4.24: Parámetro 71. Sano (Izquierda), extemo (derecha).

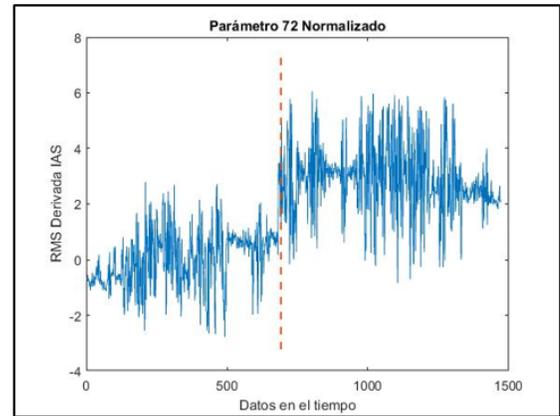


Figura 4.25: Parámetro 72. Sano (Izquierda), extemo (derecha).

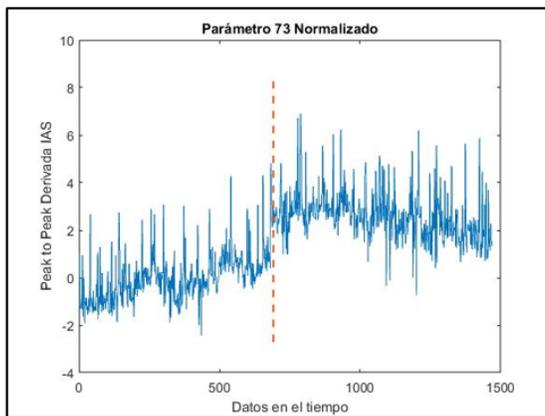


Figura 4.26: Parámetro 73. Sano (Izquierda), extemo (derecha).

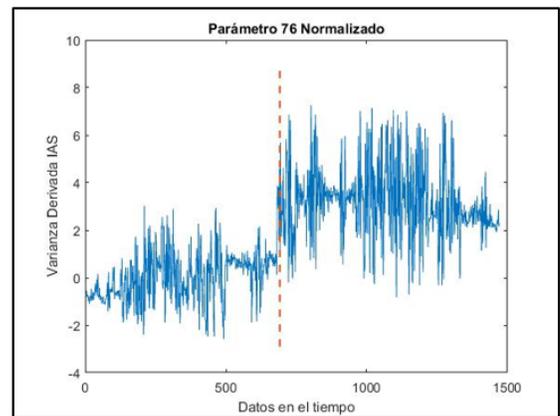


Figura 4.27: Parámetro 76. Sano (Izquierda), extemo (derecha).

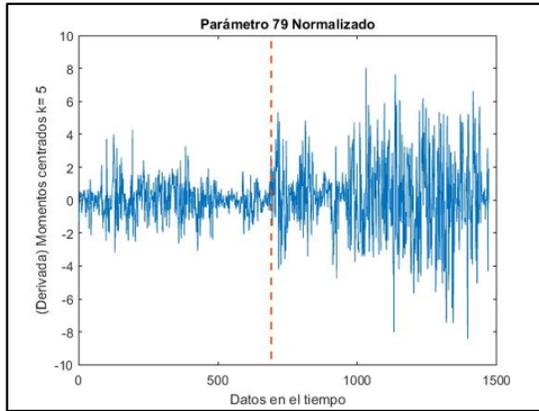


Figura 4.28: Parámetro 79. Sano (Izquierda), extemo (derecha).

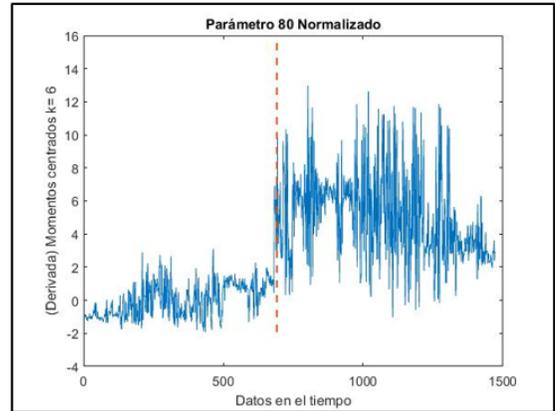


Figura 4.29: Parámetro 80. Sano (Izquierda), extemo (derecha).

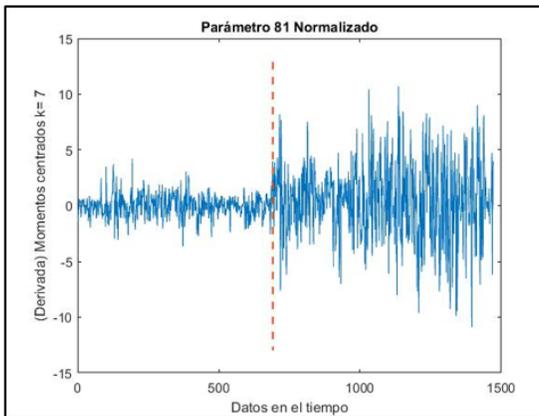


Figura 4.30: Parámetro 81. Sano (Izquierda), extemo (derecha).

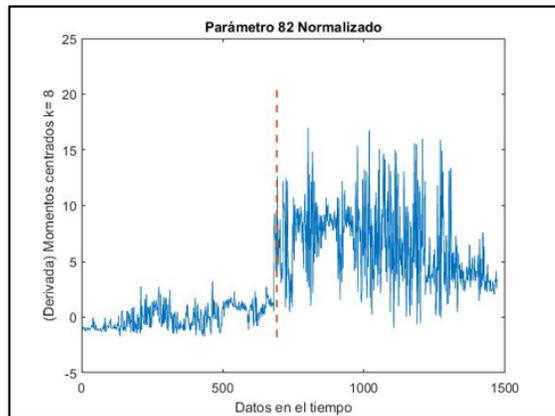


Figura 4.31: Parámetro 82. Sano (Izquierda), extemo (derecha).

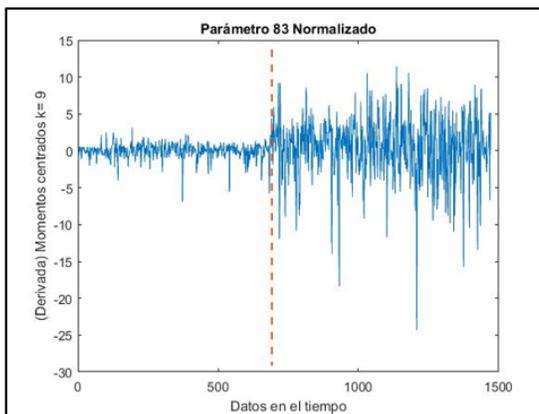


Figura 4.32: Parámetro 83. Sano (Izquierda), extemo (derecha).

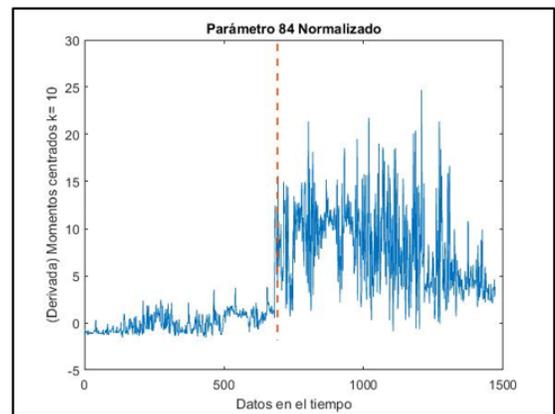


Figura 4.33: Parámetro 84. Sano (Izquierda), extemo (derecha).

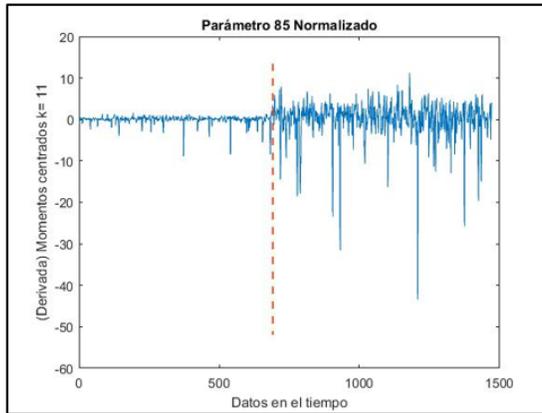


Figura 4.34: Parámetro 85. Sano (Izquierda), extemo (derecha).

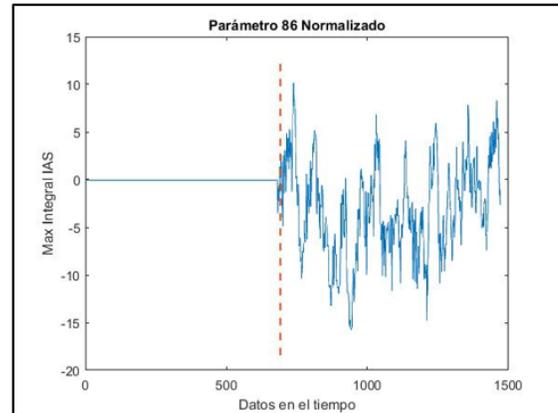


Figura 4.35: Parámetro 86. Sano (Izquierda), extemo (derecha).

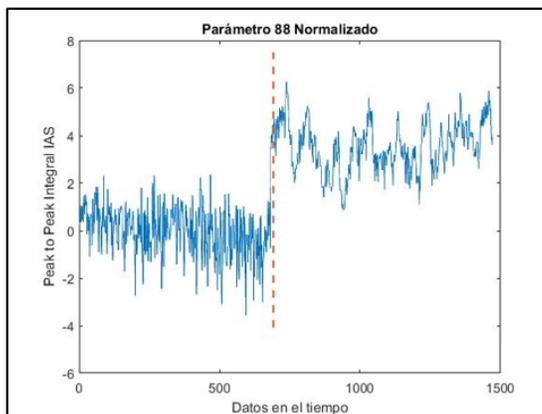


Figura 4.36: Parámetro 88. Sano (Izquierda), extemo (derecha).

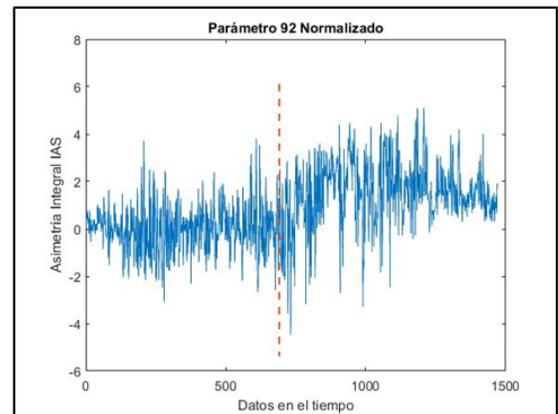


Figura 4.37: Parámetro 92. Sano (Izquierda), extemo (derecha).

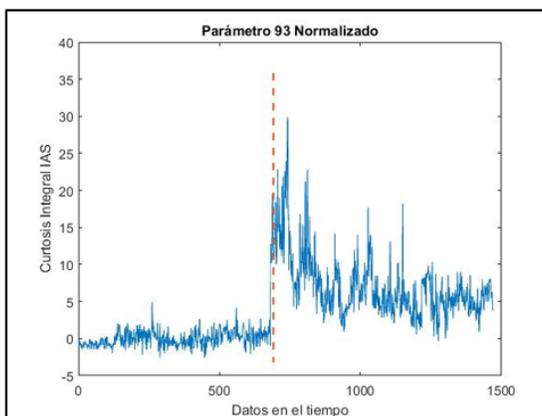


Figura 4.38: Parámetro 93. Sano (Izquierda), extemo (derecha).

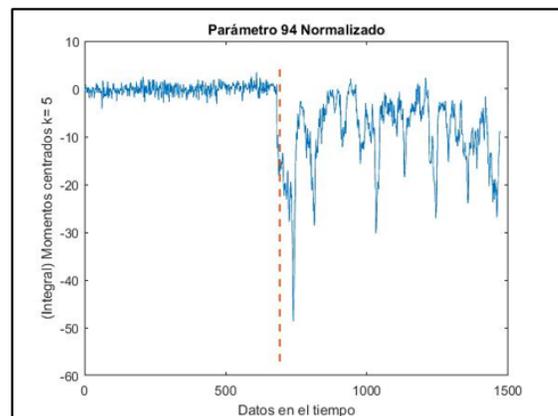


Figura 4.39: Parámetro 94. Sano (Izquierda), extemo (derecha).

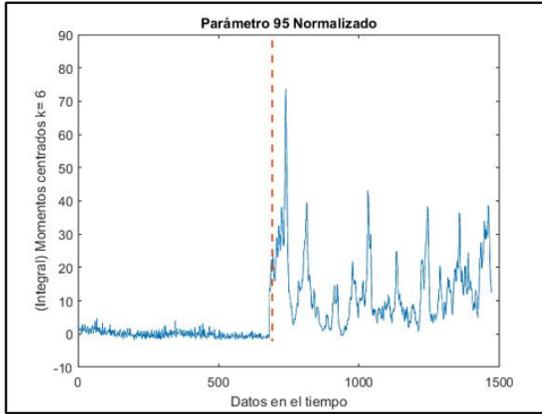


Figura 4.40: Parámetro 95. Sano (Izquierda), extemo (derecha).

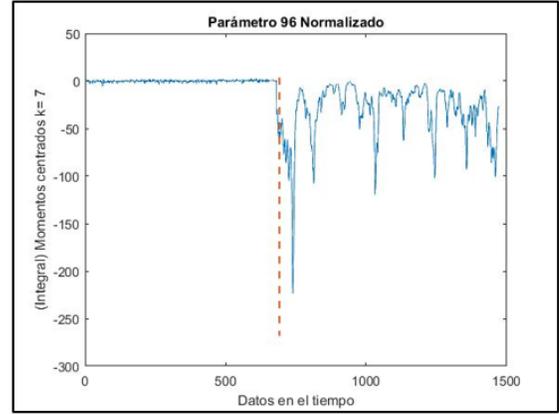


Figura 4.41: Parámetro 96. Sano (Izquierda), extemo (derecha).

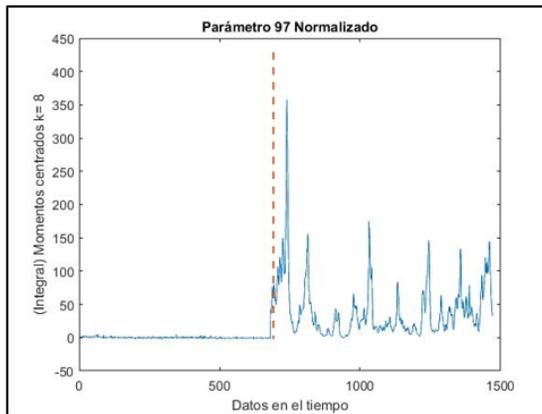


Figura 4.42: Parámetro 97. Sano (Izquierda), extemo (derecha).

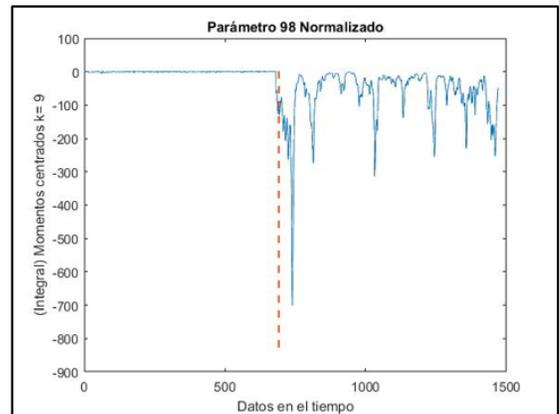


Figura 4.43: Parámetro 98. Sano (Izquierda), extemo (derecha).

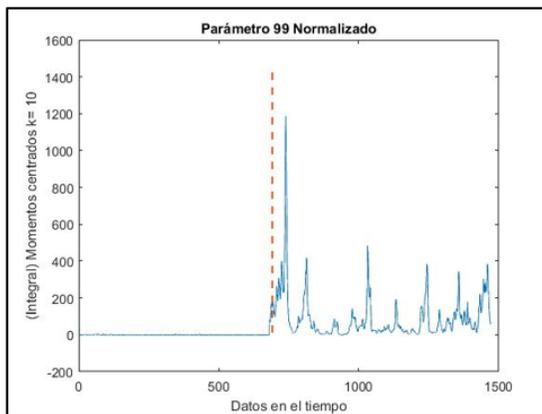


Figura 4.44: Parámetro 99. Sano (Izquierda), extemo (derecha).

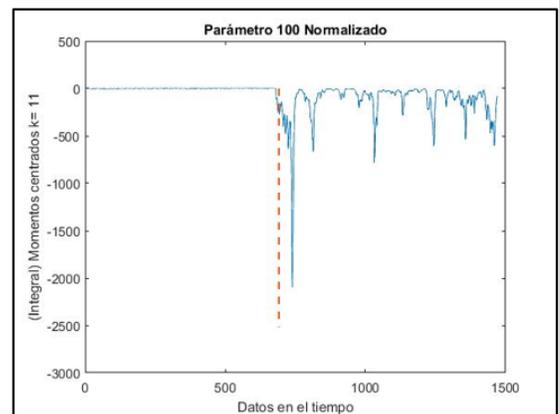


Figura 4.45: Parámetro 100. Sano (Izquierda), extemo (derecha).

4.4. Análisis de resultados, primera etapa de estudios. Parámetros sobre vibraciones torsionales

4.4.1. Análisis de parámetros calculados sobre la señal original IAS

Respecto a la Figura 4.6, se observa un aumento en el RMS de las IAS para el caso extremo, lo que concuerda con el análisis realizado para las Figuras 4.2 y 4.3. En relación al valor peak to peak, graficado en la 4.7, se observa de igual manera un leve aumento. Esto último, debido al aumento en la amplitud de las oscilaciones para el caso extremo explicada anteriormente.

La Figura 4.8 muestra una leve disminución del factor cresta en el caso extremo, de la ecuación 2.25 puede deducirse que existe un leve aumento en el valor RMS de las IASs respecto al valor Peak to peak, esto quiere decir que, en general, existe menor cantidad de peaks con altas amplitudes. Este dato resulta curioso, ya que usualmente se esperan valores mayores de Factor Cresta en el caso de fallas respecto a un caso sano.

En relación a la varianza, la Figura 4.9 presenta un notorio aumento de este parámetro, además de una oscilación de mayor amplitud de este mismo. Por lo que demuestra cierto nivel de sensibilidad al daño en álabes.

Respecto a las Figuras 4.10 a la 4.17, se puede notar que tanto la asimetría como los momentos centrados presentan una notable sensibilidad al daño en álabes. En relación a la media aritmética de la amplitud de Fourier, en la Figura 4.18, se encontró una pequeña variación para la primera banda de frecuencias (de 25 bandas), lo que está relacionado a frecuencias menores, donde posiblemente podría encontrarse el 1x de la frecuencia de giro del sistema, la cual se encuentra en torno a los 17,5 Hz.

Las Figuras 4.19 a la 4.21 se relacionan al primer y cuarto IMF del algoritmo Empirical mode decomposition (EMD). Se presentan valores RMS del primer IMF, energía de Shannon y entropía de Shannon para la cuarta IMF respectivamente. Se observa un notorio aumento en el valor RMS, lo que implica un aumento en el contenido energético de esta señal. Sin embargo, tanto la energía como entropía representan una disminución en la cuarta IMF. Es importante destacar que la energía de Shannon corresponde a un porcentaje de energía respecto a las 5 IMF calculadas, por ende, un aumento en la energía total (RMS) y disminución en la energía de Shannon significa que gran parte de la energía se concentra en las 4 IMFs restantes. Debido a la definición de entropía de Shannon (ver ecuación 2.28), al verse disminuida la energía también se verá una variación en la entropía. Estos resultados son interesantes desde el punto de vista de que la primera IMF es la que posee mayor parte del contenido en frecuencia de la señal original.

Similar a lo obtenido por EMD, los resultados del algoritmo Local Mean Decomposition (LMD) presentan, en las Figura 4.22 y 4.23, una variación significativa tanto en los valores RMS del primer PF como en la entropía del mismo. Resulta interesante notar la similitud que existe entre los gráficos de las Figuras 4.19 y 4.22, correspondientes a los RMS del primer IMF y el primer PF, respectivamente. Esto da cuenta de la gran similitud de ambos algoritmos de descomposición.

4.4.2. Análisis de parámetros calculados sobre la derivada de la señal original IAS

Nuevamente, puede notarse mayor sensibilidad para los parámetros Peak, RMS, Peak to peak y varianza, observados en las Figuras 4.24 a la 4.27. No obstante, se observa una variación mayor en estos parámetros respecto a la señal original. Así también, se aprecia en los momentos centrados, calculados sobre la derivada de la señal (Figura 4.28 a la 4.34), una variación más notoria, aunque las tendencias de cada gráfico no sean siempre similares respecto a los calculados sobre la señal original.

4.4.3. Análisis de parámetros calculados sobre la integral de la señal original IAS

Similar a los resultados obtenidos para la derivada de la señal original, se observa entre las Figura 4.35 y 4.37 una mayor sensibilidad para los parámetros Peak, Peak to peak y asimetría, calculados sobre la integral de la señal original. Adicionalmente, se presenta una variación en el parámetro Kurtosis, variación significativa que no se presentó en los casos anteriores (Figura 4.38). Nuevamente, los momentos centrados para $k=5$ a $k=11$ (Figura 4.39 a la 4.45) presentan una variación significativa y mayor en comparación a los calculados sobre la señal original y la señal derivada.

En general, es posible notar claramente que las variaciones en los parámetros, calculados sobre la integral de la señal original, resultan ser mucho más marcadas que en los parámetros calculados sobre la señal original y señal derivada. Este último punto da indicios de que, en una etapa próxima de selección, gran parte de los parámetros más relevantes correspondería a dicho grupo de características calculadas sobre la integral.

4.5. Resultados primera etapa de estudios. Parámetros sobre vibraciones transversales

Los siguientes resultados, consisten en aquellos parámetros calculados sobre las vibraciones transversales del sistema, medidas por medio del acelerómetro ubicado bajo un rodamiento. Desde la Figura 4.46 hasta la 4.51 se distinguen parámetros que presentan mayor diferencia visual entre el caso base y extremo.

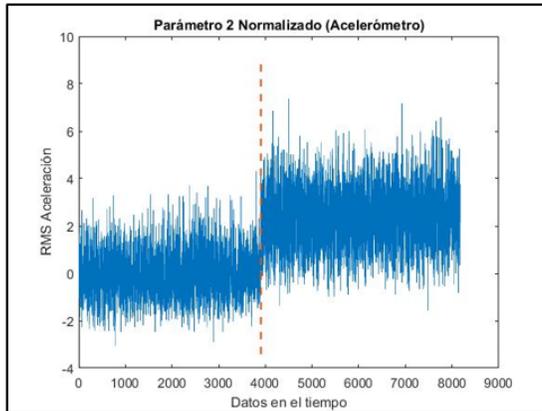


Figura 4.46: Parámetro 2 (acelerómetro). Sano (Izq), extremo (der).

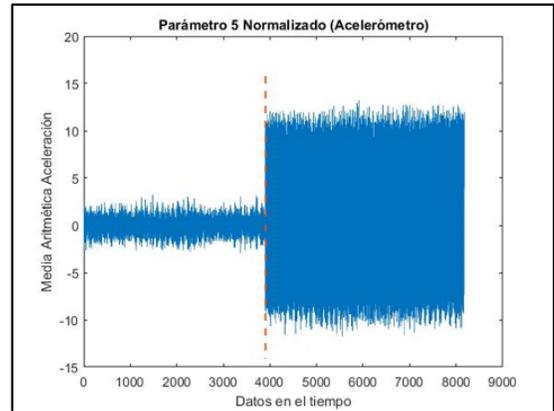


Figura 4.47: Parámetro 5 (acelerómetro). Sano (Izq), extremo (der).

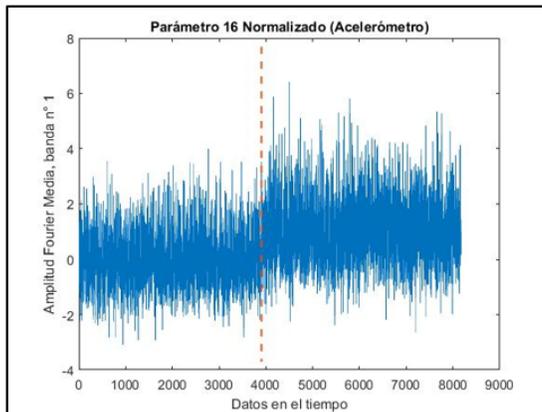


Figura 4.48: Parámetro 16 (acelerómetro). Sano (Izq), extremo (der).

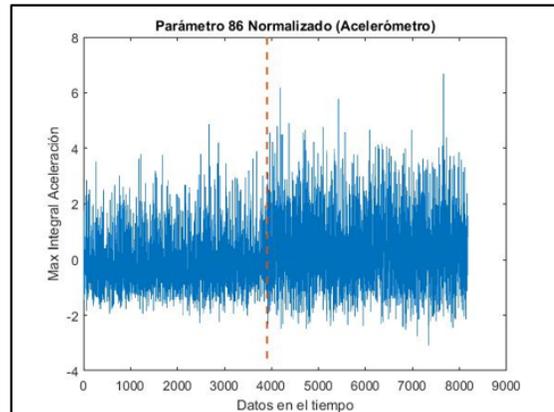


Figura 4.49: Parámetro 86 (acelerómetro). Sano (Izq), extremo (der).

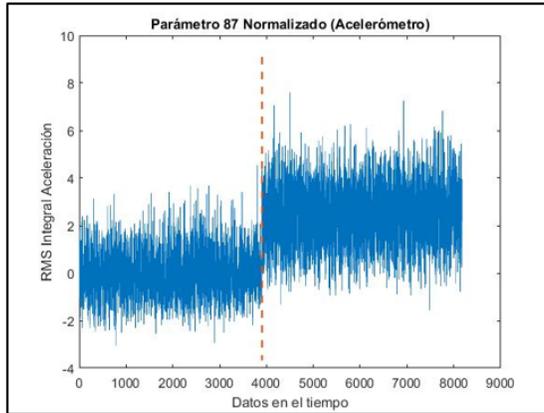


Figura 4.50: Parámetro 87 (acelerómetro). Sano (Izq), extremo (der).

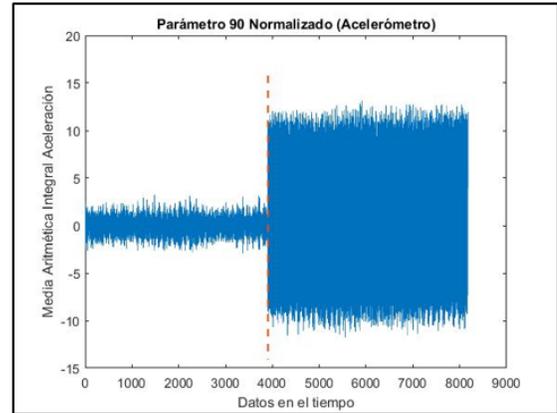


Figura 4.51: Parámetro 90 (acelerómetro). Sano (Izq), extremo (der).

4.6. Análisis de parámetros calculados sobre la señal del acelerómetro

Las Figura 4.46 a la 4.51 muestran 6 parámetros de 100 calculados, que presentan mayor sensibilidad a daño en los álabes de la turbina. Puede destacarse que corresponden principalmente a la media aritmética y RMS, que se relacionan a la variación en la amplitud de oscilación del sistema, reflejando un notorio aumento de esta.

Este cambio de amplitud de oscilación pudo visualizarse empíricamente a la hora de tomar mediciones, donde se observó que el montaje experimental se remeció con mucha más fuerza y ruido que en el caso base, esto probablemente producto del gran nivel de desbalance inducido al quitar un álabe del sistema. Naturalmente, estas fuertes vibraciones serían captadas de mejor manera por el acelerómetro, debido a que corresponden principalmente a vibraciones transversales.

Estos últimos resultados dan cuenta de la mayor sensibilidad, para detectar daño en los álabes, que presentan las vibraciones torsionales (sobre las transversales), reafirmando la importancia del estudio de estas y dando señales de que los resultados obtenidos en las siguientes etapas de estudio confirmarán este supuesto.

4.7. Resultados segunda etapa de estudios: Grietas

En una segunda etapa de toma de mediciones, se estudiaron álabes expuestos a grietas de distintos tamaños y posiciones. La Figura 4.52 muestra los 6 casos de álabes con grietas analizados.

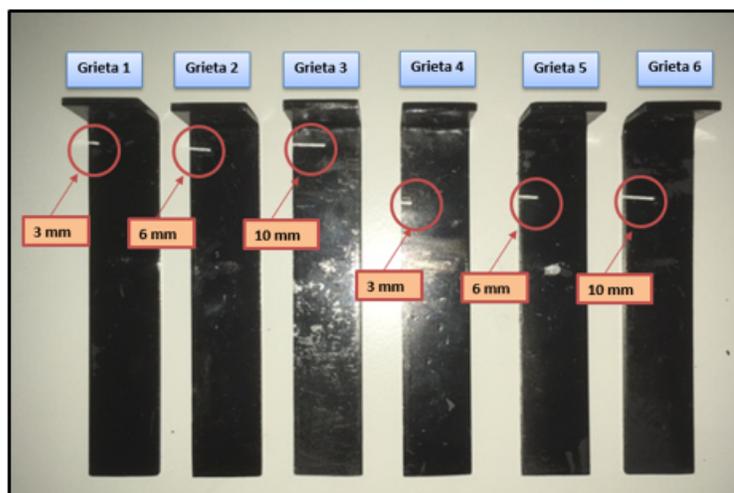


Figura 4.52: Álabes con grietas.

Los álabes con grietas fueron designados como se muestra en la Tabla 4.3 de acuerdo al tamaño de grieta y posición respecto al centro del rotor. En cada caso se instaló sólo un álabe agrietado a la vez, ubicado siempre en la misma posición en el rotor (posición utilizada anteriormente como libre para el caso extremo) para mantener condiciones similares en cada medición.

Tabla 4.3: Designación de álabes con grietas. Tamaño y posición respecto al centro del rotor.

Caso	Tamaño Grieta	Posición
Grieta 1	3 mm	5 mm
Grieta 2	6 mm	5 mm
Grieta 3	10 mm	5 mm
Grieta 4	3 mm	20 mm
Grieta 5	6 mm	20 mm
Grieta 6	10 mm	20 mm

La Figura 4.53 a continuación, compara las velocidades angulares para cada caso, muestreadas por cada revolución del rotor, con la finalidad de conocer el comportamiento en promedio de las velocidades de cada caso y descartar la posibilidad de que los cambios calculados en cada parámetro sean producto de una medición bajo distintas condiciones del sistema.

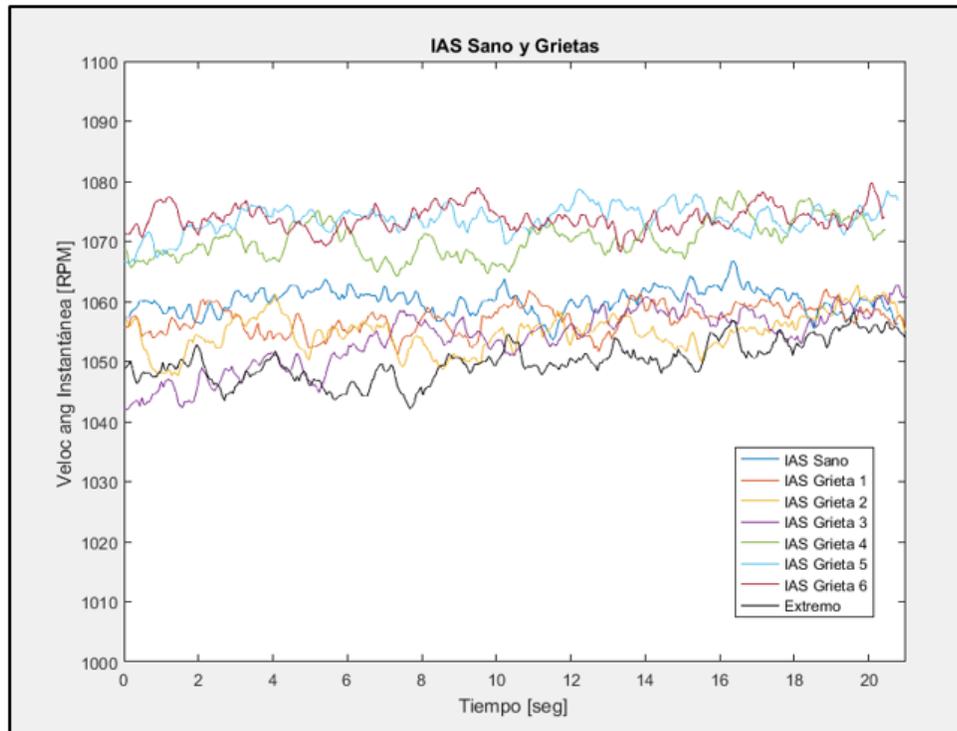


Figura 4.53: IAS para cada caso (sin centrar).

Análogo a la primera etapa, se extrajo 100 parámetros de cada medición (ver Tablas 4.1 y 4.2), los cuales fueron graficados en conjunto para obtener una comparación visual como primera aproximación a la selección de parámetros.

Posteriormente, se utilizó el algoritmo de clasificación Support Vector Machine en conjunto con un algoritmo de selección SFS, identificando dos clases: Sano (1) y Grieta (2), los valores obtenidos en la función de clasificación fueron elegidos como 1 y 2 respectivamente para cada caso. Se realizaron distintas pruebas de clasificación:

- i.* Considerando el caso sano, todos los casos con grieta, y caso extremo.
- ii.* Considerando el caso sano, grietas 1 y 4, y caso extremo.
- iii.* Considerando el caso sano, grietas 2 y 5, y caso extremo.
- iv.* Considerando el caso sano, grietas 3 y 6, y caso extremo.
- v.* Considerando el caso sano y las grietas 1, 2 y 3.
- vi.* Considerando el caso sano y las grietas 4, 5 y 6.

La Tabla 4.4 presenta los errores porcentuales de cada caso procesado en el clasificador. El error porcentual de cada caso es calculado de acuerdo al número de datos que se analiza en cada medición. A modo de ejemplo: el caso sano posee 600 datos, por lo tanto, su error se calcula como:

$$E_{Sano} = \sum_{i=1}^{600} \frac{|f(x)_{real,i} - f(x)_{clasificado,i}|}{600} \cdot 100 \quad [\%]$$

Donde:

$f(x)_{real,i}$ corresponde al dato real de clasificación del dato “i”, dicho valor es “1” si el dato corresponde a un caso sin daño y “2” si corresponde a un caso con daño.

$f(x)_{clasificado,i}$ corresponde al valor del dato “i” evaluado en la función de clasificación por medio del SVM, dicho valor es “1” si el dato es clasificado como sano y “2” si es clasificado como “con daño”.

Para los casos con grieta, la cantidad de datos seleccionados varía entre 100 y 200 datos. Por este motivo es importante que el error sea considerado de forma porcentual para cada caso. Para todos los casos estudiados la cantidad de datos del conjunto de entrenamiento es igual a la cantidad de datos del conjunto de validación.

La Tabla 4.5 presenta la lista de parámetros seleccionada por el caso (vi) de clasificación, estos han sido ordenados jerárquicamente, es decir, los primeros parámetros corresponden a los que mejor identifican el daño en cada caso.

Tabla 4.4: Errores porcentuales de selección para cada caso de clasificación.

Pruebas	<i>i</i>	<i>ii</i>	<i>iii</i>	<i>iv</i>	<i>v</i>	<i>vi</i>
Error Sano (%)	15,8	5,5	10,5	9,0	22,3	3,8
Error Grieta 1 (%)	87,0	52,5	-	-	79,0	-
Error Grieta 2 (%)	48,0	-	83,0	-	32,0	-
Error Grieta 3 (%)	60,0	-	-	72,0	36,0	-
Error Grieta 4 (%)	1,0	0,0	-	-	0,0	0,0
Error Grieta 5 (%)	0,0	-	0,0	-	0,0	0,0
Error Grieta 6 (%)	0,0	-	-	0,0	0,0	0,0
Error Extremo (%)	12,0	0,0	0,0	0,0	-	-
Error total (%)	23,3	12,6	23,5	18,0	23,4	1,9

Tabla 4.5: Lista de parámetros seleccionados. Caso *vi*: Sano y grietas 4, 5 y 6.

n° Parámetro		Descripción
1	87	RMS (Integral)
2	72	RMS (Derivada)
3	29	Amplitud de Fourier Media. Banda 14
Error Total		1,90%

La Figura 4.54, al igual que la Figura 4.55 y Figura 4.56 forma parte de los gráficos comparativos correspondientes al caso de clasificación *vi*, que considera sólo el caso sano y las grietas ubicadas a 20 mm del rotor (grieta 4, 5 y 6). Estos gráficos permiten identificar fácilmente la variación en la amplitud de cada parámetro para cada nivel de daño a estudiar.

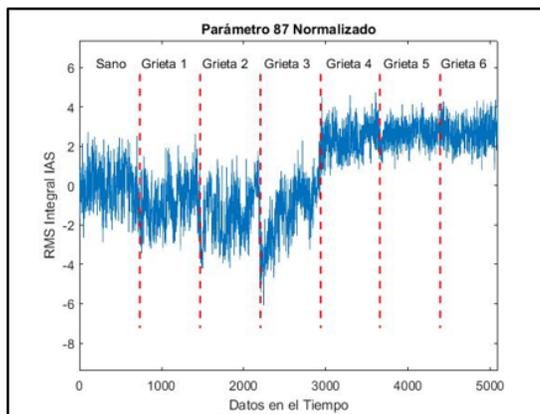


Figura 4.54: Parámetro 87 Normalizado. Sano-grietas.

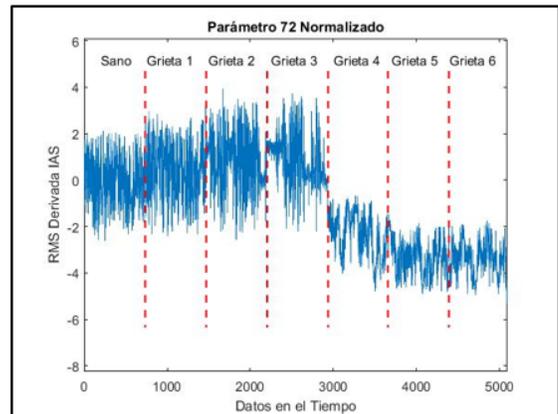


Figura 4.55: Parámetro 72 Normalizado. Sano-grietas.

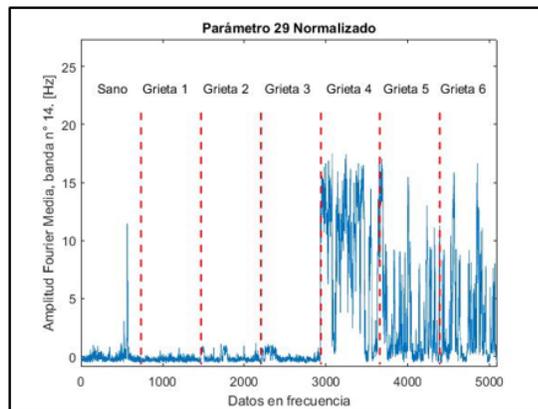


Figura 4.56: Parámetro 3 Normalizado. Sano-grietas.

En una nueva instancia de clasificación, se realizaron pruebas donde se entrena el clasificador para detectar cada grieta en específico. Se utilizaron conjuntos de entrenamiento y validación de 410 datos cada uno, los cuales se dividen en 210 datos sanos y 200 datos con alguna grieta en particular. De la clasificación se identifican los Verdaderos Positivos (TP), Verdaderos Negativos (TN), Falsos Positivos (FP) y Falsos Negativos (FN).

A partir de esto se obtienen la exactitud, precisión y tasa de acierto, calculados de acuerdo a las ecuaciones 2.47, 2.48 y 2.49, respectivamente. La Tabla 4.6 muestra los resultados obtenidos para cada procedimiento realizado. La Tabla 4.7 corresponde a los parámetros seleccionados en cada caso.

Tabla 4.6: Clasificación de grietas por separado. Resultados estadísticos.

	Grieta 1	Grieta 2	Grieta 3	Grieta 4	Grieta 5	Grieta 6
TP	157	182	198	200	171	200
TN	173	145	203	210	210	209
FP	37	65	7	0	0	1
FN	43	18	2	0	29	0
Error Sano (%)	17,6	31,0	3,3	0,0	0,0	0,5
Error Grieta (%)	21,5	9,0	1,0	0,0	14,5	0,0
Error Total (%)	19,5	20,2	2,2	0,0	7,1	0,2
Exactitud (%)	80,5	79,8	97,8	100,0	92,9	99,8
Precisión (%)	80,9	73,7	96,6	100,0	100,0	99,5
Tasa acierto (%)	78,5	91,0	99,0	100,0	85,5	100,0

Tabla 4.7: Clasificación de Grietas por separado. Parámetros seleccionados en cada clasificación.

Parámetros seleccionados							
Grieta 1	Grieta 2			Grieta 3	Grieta 4	Grieta 5	Grieta 6
88	88	80	6	88	86	1	91
86	31	81	23	97			2
23	67	82	39	25			
22	40	83	75	5			
100	7	84	2	99			
13	8	85	92	86			
15	9	93	78	100			
14	10	94	19				
12	11	95	16				
66	12	96	25				
	13	97	1				
	14	98	36				
	15	99	18				
	48	100	27				
	26	71					
	79	77					

Desde la Figura 4.57 hasta la 4.66 se presentan los gráficos comparativos correspondientes a los parámetros seleccionados para las grietas 3, 4, 5 y 6.

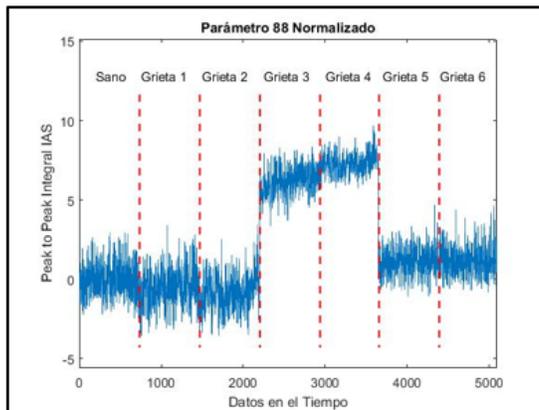


Figura 4.57: Parámetro 88 Normalizado. Sano-Grietas.

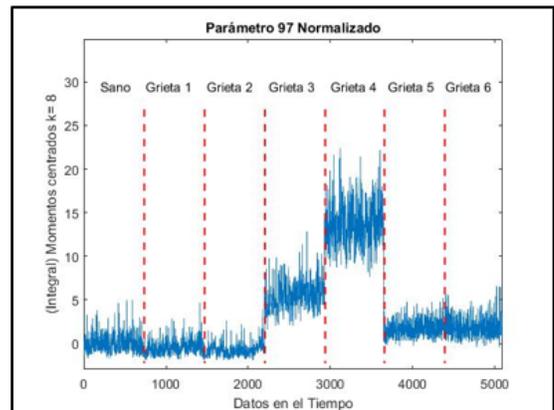


Figura 4.58: Parámetro 97 Normalizado. Sano-Grietas.

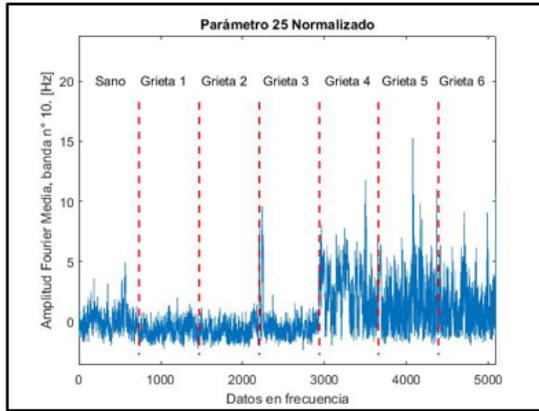


Figura 4.59: Parámetro 25 Normalizado. Sano-Grietas.

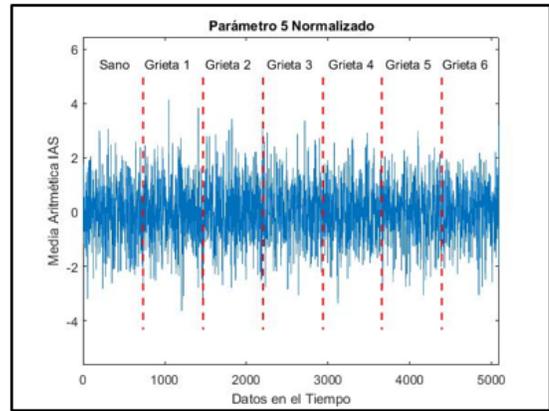


Figura 4.60: Parámetro 5 Normalizado. Sano-Grietas.

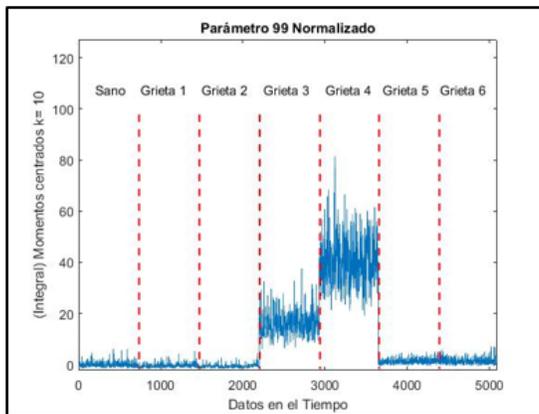


Figura 4.61: Parámetro 99 Normalizado. Sano-Grietas.

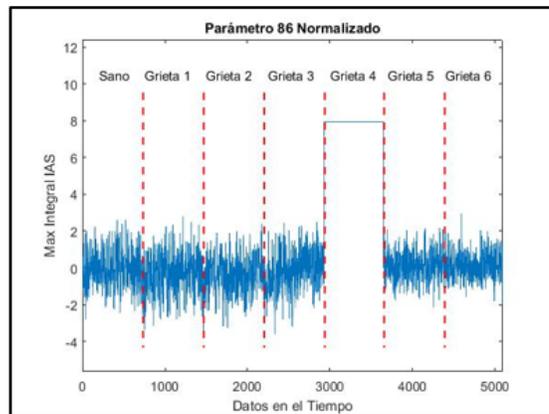


Figura 4.62: Parámetro 86 Normalizado. Sano-Grietas.

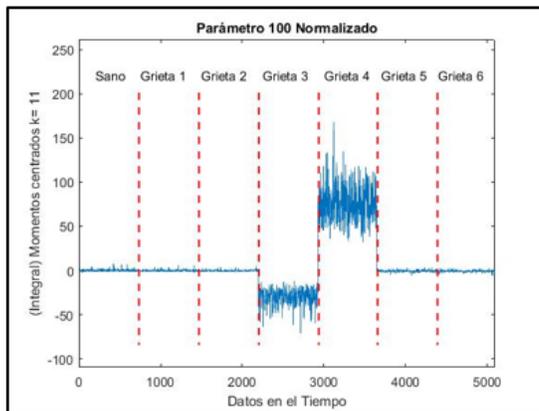


Figura 4.63: Parámetro 100 Normalizado. Sano-Grietas.

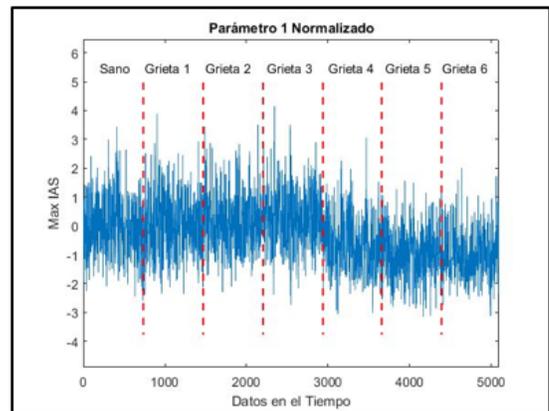


Figura 4.64: Parámetro 1 Normalizado. Sano-Grietas.

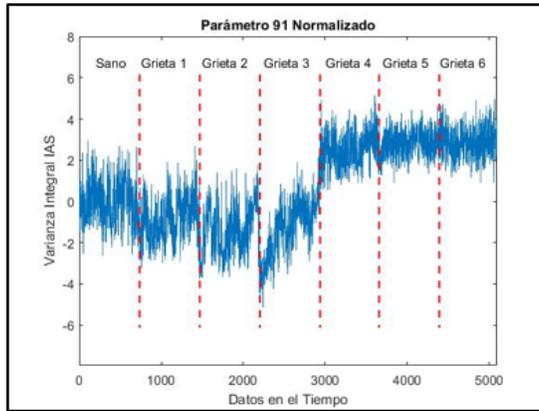


Figura 4.65: Parámetro 91 Normalizado. Sano-Grietas.

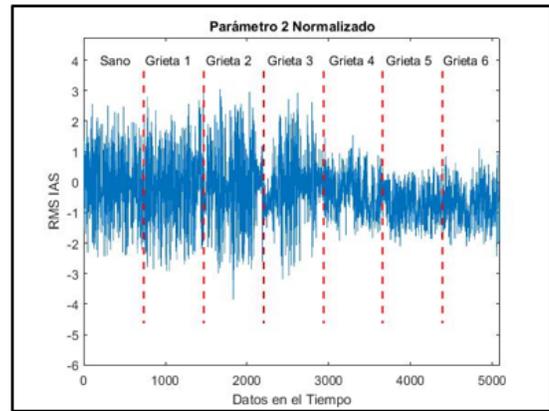


Figura 4.66: Parámetro 2 Normalizado. Sano-Grietas.

4.8. Análisis de resultados. Segunda etapa de estudios. Vibraciones torsionales

Respecto a la 4.53, se observan las velocidades angulares de cada caso de medición en el tiempo, medidas por cada revolución del eje. A pesar de que para cada caso la velocidad angular es notoriamente variable, puede notarse que el rango de velocidades de cada caso se encuentra entre las 1040 y 1080 RPM, con una diferencia máxima de un 3,7 %. De acuerdo a este punto, se descarta la posibilidad de que las variaciones observadas en cada parámetro sean producto de diferencias de velocidad de giro en cada medición.

En relación a la Tabla 4.4, el caso (i) de clasificación considera tanto el caso sano, como grietas y extremo. Los resultados muestran claramente un error grande en la diferenciación de las primeras tres grietas respecto al caso sano. Sin embargo, las grietas 4, 5 y 6 (ubicadas a 20 mm del centro del rotor) obtienen un excelente resultado de clasificación.

En los casos (ii), (iii) y (iv) se intentó clasificar por tamaño de grieta, ya que la grieta 1 y 4 difieren solo en posición y no en tamaño, así también las grietas 2 y 5, y las grietas 3 y 6. Los resultados muestran nuevamente una clasificación excelente para las grietas más externas (4, 5 y 6) y un error demasiado alto para las grietas cercanas al centro del rotor.

En cuanto a la prueba (v) de clasificación, se decidió eliminar del análisis al caso extremo, ya que su función solamente fue detectar diferencias entre un caso sano y uno con alto nivel de daño, y no representa el efecto de una grieta. Acá se observa que los resultados no cambian notoriamente respecto al caso (i), el error total de clasificación se mantiene prácticamente constante y las grietas 4, 5 y 6 se detectan con un error favorable de 0 %.

Finalmente, para la prueba (vi) de clasificación, se compara el caso sano con los tres casos de grietas ubicados a 20 mm del centro del rotor. Aquí se observa una clasificación perfecta para los casos con grietas, y un pequeño error de clasificación para los datos sanos. Esto último quiere decir que un 3,8 % de los datos sanos fueron clasificados como casos con falla, lo que se caracteriza como datos Falsos Positivos. En términos prácticos, un falso positivo no es demasiado perjudicial, ya que corresponde solo a una “falsa alarma” que puede llevar a una inspección que determinaría que efectivamente no hay daño. Que el error total sea de sólo un 1,9 % manifiesta que en este caso la clasificación fue excelente, corroborando la facilidad de identificación de las grietas ubicadas a 20 mm del centro del rotor.

La Tabla 4.5 presenta el listado de parámetros que fueron seleccionados en el caso (vi) de clasificación, en particular los parámetros 87 y 72 concuerdan con lo dicho anteriormente: “Los parámetros calculados de la derivada y la integral de la señal original presentan mayor sensibilidad al daño”. En conjunto con la Figura 4.54, 4.55 y 4.56 se observa una variación muy notoria entre las grietas 4, 5 y 6 respecto al resto de las mediciones.

En la siguiente instancia de clasificación, se entrenó un clasificador SVM para cada tipo de grieta, con la finalidad de entender el grado de detectabilidad de cada grieta en particular por parte del clasificador. Los resultados de la Tabla 4.6 desprenden lo siguiente:

En cuanto a la clasificación de la grieta 1, se observan errores del 17,6 % y 21,5 % en la clasificación de los datos sanos y los datos con grieta, respectivamente. Estos resultados indican que la clasificación es demasiado imprecisa, y el algoritmo no logra diferenciar un dato sano de un dato con grieta del tipo 1. Esto se corrobora de igual manera al observar que el error total es de un 19,5 %.

El clasificador logró sólo identificar 157 datos con daño de un total de 200, esto da cuenta de una tasa de acierto de un 78,5 %, este caso es el que tiene menor acierto respecto a todos los demás. Además, clasificó 37 datos sin daño como si tuvieran daño, y peor aún, clasificó 43 datos con daño como si tuvieran daño. Esto se corrobora de acuerdo a la precisión, que da cuenta de que el 80,9 % de los datos clasificados como con daño realmente tenía daño.

De aquí se desprende que no es posible identificar grietas del tipo 1 utilizando un clasificador de las características dadas, es más, probablemente con cualquier clasificador se obtendrán resultados desfavorables, esto debido al gran parecido existente entre las vibraciones torsionales del caso sano y del caso “grieta 1”.

En relación a la clasificación de los datos para el caso de la grieta 2, se observa que el error en la clasificación de los datos con grieta disminuye bastante, sin embargo, el error en la clasificación de los datos sanos aumenta. Esto quiere decir básicamente que el algoritmo SVM programado tiende a clasificar datos sin daño como si tuvieran, esto se expresa en el alto número de falsos negativos (65). Este último punto no es demasiado grave en términos prácticos ya que corresponden a falsas alarmas. Se observa además que este caso presenta la menor de las precisiones, esto quiere decir que de los elementos clasificados como “con daño”, solo el 73,7 % tenía daño.

Por lo tanto, los resultados obtenidos para la clasificación de la grieta 2, formulan que este tipo de grieta no es identificable por medio del clasificador programado, al obtener una insuficiente exactitud de un 79,8 %.

Cuando se entrenó el algoritmo SVM para clasificar grietas del tipo 3, se obtuvo resultados bastante mejores. Los errores disminuyeron notablemente a un 3,3 % y 1 % para los datos sin daño y con daño, respectivamente, observándose una exactitud de clasificación de un 97,8 %. Los datos con daño fueron casi en su totalidad identificados, salvo 2 falsos negativos, y hubo 7 datos clasificados como falsas alarmas o falsos positivos. Estos resultados dan cuenta de que la grieta 3 si puede ser casi perfectamente detectada por el clasificador, lo que no había sido notado en las primeras instancias de clasificación de grupos de grietas.

Los resultados obtenidos para la grieta 4 representan una clasificación perfecta. Fueron bien clasificados los 210 datos sanos y los 200 datos con daño, errores de 0 % y exactitud, precisión y tasa de acierto de 100 %. Por lo que se desprende que la grieta del tipo 4 es excepcionalmente detectable a través del clasificador programado.

En cuanto a la grieta 5, se lograron identificar los 210 datos sanos, sin embargo, se encontraron 29 falsos negativos, los cuales corresponden a datos con daño clasificados como datos sanos. Se observa una precisión del 100 % debido a que todos los datos que fueron clasificados como “con daño” realmente tenían daño. A pesar de la existencia de algunos datos erróneos en la clasificación, la exactitud alcanza un 92,9 %, valor suficiente para considerar que el tipo de grieta si es detectable por el algoritmo SVM programado.

Los resultados obtenidos para la grieta 6 son muy similares a los obtenidos para la grieta 4, lo que resulta muy favorable. Sólo existe un falso negativo, por lo cual se tiene una exactitud en la clasificación de un 99,8 %, resultando una clasificación prácticamente perfecta y sugiriendo que la grieta 6 si es altamente detectable por medio del algoritmo de clasificación.

En relación a los parámetros seleccionados por el método SFS, en conjunto con SVM, resulta importante notar que los casos con mayor exactitud fueron aquellos que seleccionaron un menor número de parámetros, tal como son los casos de clasificación para las grietas 4, 5 y 6. Esto propone la existencia de parámetros específicos que marcan una diferencia notoria en sus valores cuando el sistema es sometido a dichos niveles de daño.

A continuación, se analizan gráficamente los parámetros seleccionados para los cuatro casos con mayor nivel de exactitud en la clasificación, es decir, grieta 3, 4, 5 y 6.

En primer lugar, para la clasificación de daño con grieta del tipo 3, con un 97,8 % de exactitud, se han seleccionado 7 parámetros que permiten identificar de mejor manera dicho nivel de daño en el rotor. Las Figuras 4.57 a la 4.63 corresponden a estos parámetros. Puede notarse en particular que para los parámetros 88, 97, 99 y 100 se observa un cambio claro en los valores de estos mismos, para los datos de vibraciones torsionales con grieta 3 y 4. Es importante notar que estos cuatro parámetros fueron calculados sobre la integral de la señal original, corroborando nuevamente la sensibilidad de la integral de las IAS a detectar daño en álabes.

En particular los parámetros 5, 25 y 86 no presentan visualmente un cambio demasiado significativo en los datos para la grieta 3 respecto al resto de los datos. Cabe notar que el parámetro 86 muestra, sin embargo, una clara variación para los datos correspondientes a la grieta 4. Más aún, este último es el único parámetro seleccionado para identificar la grieta 4, el cual obtuvo una clasificación perfecta. Cabe destacar nuevamente, que corresponde a un parámetro calculado sobre la integral de la señal IAS, reafirmando su alto nivel de sensibilidad al daño en álabes.

Respecto a la Figura 4.64, apreciamos que no se observa una variación visualmente destacable entre los datos con grieta 5 del resto de los datos de vibraciones torsionales. Sin embargo, este parámetro es el que mejor identifica el daño “grieta 5” con un 92,9 % de exactitud. Es importante destacar que este parámetro corresponde simplemente al máximo de la señal IAS para distintas ventanas de tiempo. Desde este punto de vista, podemos inferir que para el tamaño y posición de la grieta 5 (6mm a 20 mm del centro) las vibraciones torsionales tienen una menor amplitud, a pesar de que en general la velocidad angular de rotación de la grieta 5 es mayor a la de la grieta 1 (ver Figura 4.53).

Finalmente, respecto de las Figuras 4.65 y 4.66, correspondientes a los parámetros seleccionados para la clasificación de la grieta 6, puede verse que no existe notoriamente una variación en la amplitud de dichos parámetros respecto al resto, sin embargo, en conjunto con los datos de las grietas 4 y 5, se observa una variación respecto a los casos sanos y grietas cercanas al centro (1, 2 y 3).

4.9. Resultados segunda etapa de estudios. Vibraciones Transversales

A continuación, se realiza el mismo estudio, esta vez para los resultados obtenidos por medio del acelerómetro. Se calculan los mismos parámetros y se estudia en primera instancia dos casos de clasificación:

- i.* Caso sano y todas las grietas.
- ii.* Caso sano y grietas ubicadas a 20 mm del centro (4, 5 y 6).

La Tabla 4.8 muestra los errores porcentuales de clasificación de estos dos casos de estudio. En ambos se utilizaron 300 datos sanos y 100 datos con cada tipo de daño, es decir, en total 600 datos con daño para el caso (i) y 300 datos con daño para el caso (ii). Los conjuntos de entrenamiento y validación tienen la misma cantidad de datos.

Tabla 4.8: Errores porcentuales de clasificación (acelerómetro).

Pruebas	i	ii
Error Sano (%)	64	23,3
Error Grieta 1 (%)	21	-
Error Grieta 2 (%)	9	-
Error Grieta 3 (%)	13	-
Error Grieta 4 (%)	8	18
Error Grieta 5 (%)	7	24
Error Grieta 6 (%)	5	15
Error total (%)	28,3	21,2

La Tabla 4.9 detalla los resultados de clasificación para la identificación de cada grieta en particular, utilizando los datos obtenidos del acelerómetro. El procedimiento es similar, sin embargo, esta vez se consideran 150 datos sanos y 150 datos con daño para cada caso. Es importante recalcar que los datos con daño se refieren a un tipo de grieta en específico para cada caso.

Tabla 4.9: Clasificación de grietas por separado. Acelerómetro. Resultados estadísticos.

	Grieta 1	Grieta 2	Grieta 3	Grieta 4	Grieta 5	Grieta 6
TP	102	103	99	107	114	112
TN	120	110	124	121	99	129
FP	30	40	26	29	51	21
FN	48	47	51	43	36	38
Error Sano (%)	20,0	26,7	17,3	19,3	34,0	14,0
Error Grieta (%)	32,0	31,3	34,0	28,7	24,0	25,3
Error Total (%)	26,0	29,0	26,7	24,0	29,0	19,7
Exactitud (%)	74,0	71,0	74,3	76,0	71,0	80,3
Precisión (%)	77,3	72,0	79,2	78,7	69,1	84,2
Tasa acierto (%)	68,0	68,7	66,0	71,3	76,0	74,7

4.10. Análisis de resultados. Segunda etapa de estudios. Vibraciones Transversales

A partir de los resultados obtenidos mediante la clasificación de parámetros, calculados sobre vibraciones transversales, se efectúa el siguiente análisis:

En relación al caso (i), presentado en la Tabla 4.8, puede notarse un error total de clasificación de un 28,3 %, el cual resulta ser demasiado alto, además de ser mayor a todos los errores obtenidos anteriormente para vibraciones torsionales. De aquí se desprende desde ya que la clasificación no fue exitosa. Se observa que las grietas exteriores (4, 5 y 6) tienden a ser clasificadas con menor error, sin embargo, los resultados obtenidos no son lo suficientemente satisfactorios como para determinar que estos tipos de daño hayan sido correctamente identificados. Es importante notar que los datos sanos fueron identificados con un error de un 64 %, esto quiere decir que el clasificador tiende a determinar que los datos dados corresponden a datos con falla. Es por esto que probablemente el error en los datos que realmente tienen falla es considerablemente más bajo.

Respecto al caso (ii), se observa una notoria disminución del error total, esta vez de un 21,2 %. Por otra parte, puede notarse también un aumento en el error de clasificación de las grietas 4, 5 y 6. De aquí se desprende que: a pesar de que resulta más fácil identificar grietas del tipo 4, 5 y 6, los resultados de clasificación son demasiado inexactos como para determinar que estos tipos de daño han sido bien identificados mediante los parámetros seleccionados.

En relación a la Tabla 4.9, que muestra los resultados de clasificación para cada grieta en particular, se observa en primer lugar que los errores de clasificación son todos notoriamente mayores a los obtenidos por medio del análisis de vibraciones torsionales. Es importante recalcar que en este caso se utilizaron 150 datos sanos y 150 datos con daño para cada nivel de daño estudiado.

En relación a la clasificación del caso grieta 1, se observan errores del 20 % y 32 % en la clasificación de datos sanos y datos con grieta del tipo 1. Este punto señala lo difícil que resulta para el clasificador identificar diferencias entre un caso sano y un caso con dicho nivel de daño. Notamos además que el número de verdaderos negativos es mayor al de verdaderos positivos, esto quiere decir que en general el clasificador tiende a identificar los datos como si no tuvieran daño. El alto número de falsos negativos podría ser preocupante en la práctica, ya que corresponden a datos que fueron clasificados como sin daño aun teniendo daño. La precisión obtenida significa que solo el 77,3 % de los datos clasificados como “con daño” fueron correctamente clasificados. Una tasa de acierto de un 68 % da cuenta de que sólo se encontró un 68 % de los datos con daño. De este último dato se concluye que el clasificador no pudo identificar correctamente la mayor parte de los datos con daño del tipo grieta 1.

Los resultados obtenidos para la clasificación del caso grieta 2, presentan un notorio aumento en el error de clasificación de los datos sanos (respecto al caso grieta 1). Nuevamente se observa un mayor número de verdaderos negativos y un alto número de falsos negativos. A pesar de que la exactitud es menor respecto al caso 1, la tasa de acierto es un poco mayor, mostrando que se identifica una mayor cantidad de datos con daño del tipo grieta 2 (respecto al caso grieta 1).

Para el caso grieta 3, los resultados son similares a los dos anteriores, sin embargo, en este caso se presenta una diferencia más notoria entre los verdaderos positivos y verdaderos negativos, siendo estos mayores. Esto concuerda con que el error de clasificación de los datos sanos sea menor. Por otra parte, se observa un mayor número de falsos negativos, lo que da cuenta de la mayor dificultad para identificar este tipo de daño, respecto de los dos casos anteriores.

Este último punto concuerda también con una baja tasa de acierto, la que muestra que sólo se identificó un 66 % de los datos con daño del tipo grieta 3. Finalmente, aunque el nivel de exactitud aumenta a un 74,3 %, este valor es insuficiente como para verificar que la grieta 3 ha sido correctamente identificada.

Los resultados obtenidos para el caso “grieta 4”, son similares a los tres mencionados anteriormente, sin embargo, el error de clasificación de la grieta es menor, lo que se ve reflejado en una tasa de acierto mayor a las anteriores, de un 71,3 %. Por lo tanto, al igual que los casos anteriores, la grieta 4 no logra ser correctamente identificada utilizando datos de vibraciones transversales.

De igual manera los resultados obtenidos para el caso “grieta 6” son similares a todos los anteriormente mencionados. Aunque, por otra parte, es el caso que obtiene mayor exactitud en la clasificación, esto se ve reflejado en una mayor precisión, lo que significa que de los datos clasificados como “con daño”, el 84,2 % fue bien clasificado. Además, se presenta una tasa de acierto superior a las anteriormente mencionadas. Concluyendo que la identificación de daño para este caso fue mejor que para los casos anteriores.

Para el caso “grieta 5” se observa un comportamiento un poco diferente: Esta vez el clasificador tiende a identificar los datos como “con daño”. Esto se ve reflejado en el mayor número de verdaderos positivos y el bajo error de clasificación de la grieta en comparación con el error de clasificación de los datos sanos. Se observa que consistentemente la tasa de acierto resulta ser mayor para este caso en comparación con los demás. De todas formas, se obtiene una exactitud del 71 %, que ronda en el orden de las obtenidas en las primeras cuatro grietas.

En términos generales, de la Tabla 4.9 se desprende que existe un bajo nivel de exactitud en la clasificación de los datos para cada caso, y se observa una mayor tendencia a identificar datos sanos que datos con daño. Por otra parte, los casos que presentan mejores resultados son los relacionados a las grietas 4, 5 y 6, siendo los resultados del caso “grieta 5”, los que mejor logran ser identificados, mostrando una mayor tasa de acierto. Esto último marca diferencia respecto de los resultados obtenidos con vibraciones torsionales, donde los casos con mayor exactitud correspondían a los casos “grieta 4” y “grieta 6”.

Finalmente se desprende que los resultados obtenidos de las vibraciones transversales (por medio del acelerómetro) resultan ser considerablemente inexactos en comparación a los resultados obtenidos por medio de vibraciones torsionales. La clasificación realizada a través de datos de vibraciones transversales posee un nivel de exactitud insuficiente como para determinar que las grietas han sido correctamente identificadas. De aquí que las vibraciones torsionales logran identificar de mejor forma daño en los álabes de la turbina.

4.11. Resultados finales

Por último, la Tabla 4.10 resume una lista de los parámetros fueron capaces de detectar grietas en álabes, tanto para las grietas 3 a la 6 por si solas, como para la clasificación de las grietas 4, 5 y 6 en conjunto. Es importante notar que gran parte de los parámetros seleccionados corresponde a amplitudes máximas, RMS y momentos centrados, lo que concuerda con lo afirmado en la primera etapa de toma de mediciones, además, más de la mitad de los parámetros seleccionados corresponden a parámetros calculados sobre la integral de la señal original.

Es interesante notar que la mayoría de los parámetros seleccionados, a excepción de las amplitudes de Fourier medias, son muy fáciles y casi directos de calcular, y no necesitan una descomposición previa de la señal por medio de LMD o EMD como podrían ser los parámetros de energía y entropía de Shannon. Este último punto es beneficioso, ya que, en términos prácticos, ayuda a que el monitoreo del estado de salud en línea sea más rápido y eficiente por medio de cálculos más simples.

Tabla 4.10: Parámetros finales.

Lista de parámetros finales		
n°	Parámetro	Descripción
1	1	Amplitud Máxima
2	2	RMS
3	5	Media Aritmética
4	25	Amplitud de Fourier Media. Banda 10
5	29	Amplitud de Fourier Media. Banda 14
6	72	RMS (Derivada)
7	86	Max (Integral)
8	87	RMS (Integral)
9	88	Peak to peak (Integral)
10	91	Varianza (Integral)
11	97	Momentos centrados. K=8 (Integral)
12	99	Momentos centrados. K=10 (Integral)
13	100	Momentos centrados. K=11 (Integral)

5. Comentarios y conclusiones

En relación a la primera etapa de estudios, donde se analizaron los casos bases y extremos, es importante recalcar que se cumplieron los objetivos de dicha etapa, ya que se logró identificar una variación significativa de los parámetros calculados en cada uno de estos casos. Por otra parte, sirvió para comprender el comportamiento de algunos parámetros y determinar visualmente un conjunto con mayor sensibilidad a este cambio de condición en el sistema. Adicionalmente permitió inferir desde ya, que los resultados obtenidos por medio de las vibraciones torsionales serían mucho mejores que los resultados de las vibraciones transversales.

Se observa gran similitud entre los resultados obtenidos por medio de los algoritmos LMD y EMD, lo que permite validar la relevancia de utilizar al menos alguno de estos en el estudio de vibraciones torsionales. A pesar de que los parámetros calculados sobre LMD y EMD no fueron seleccionados en el set final, se puede extraer un gran número de características a partir de estos algoritmos, las cuales pueden ser igualmente evaluadas en un trabajo futuro. El estudio de parámetros sobre la señal derivada e integrada presenta resultados más notorios que los obtenidos para la señal original, lo que representa mayor sensibilidad. Así también, los parámetros representados por momentos centrados presentaron notables variaciones entre el caso base y el extremo, tanto para la señal original, derivada e integrada.

En relación a la segunda etapa de estudios, correspondiente a los casos con grietas de distintos tamaños y posición, se concluye lo siguiente:

En términos generales resultó mucho más difícil obtener una clasificación correcta de los datos asociados a las grietas 1 y 2, ubicadas a 5mm del centro con tamaños de 3mm y 5mm respectivamente, más aún, los resultados no fueron los suficientemente precisos. Esto se debe a que los parámetros calculados para estos dos casos no difieren notoriamente de los parámetros calculados para los datos sanos.

Se obtuvo una excelente clasificación de los datos asociados a las grietas 3, 4, 5, y 6. Producto de una buena detección del daño en cada caso, se obtiene un set de parámetros que permite identificar, con alta exactitud, cada nivel de daño en específico asociado a estas grietas.

Los parámetros que resultaron ser más sensibles al daño en álabes efectivamente fueron, en su mayoría, los relacionados a la integral de la señal IAS. Por otra parte, en general, los parámetros seleccionados resultaron ser mayoritariamente los más sencillos de calcular, lo que favorecería en la práctica al monitoreo de salud en línea del sistema rotor.

Los resultados obtenidos por medio de las vibraciones transversales presentaron porcentajes de exactitud notoriamente menores, por lo que no pueden ser utilizados con seguridad para la detección de daño en álabes. Esto reafirma el hecho de que el estudio de vibraciones torsionales corresponde a un camino más adecuado (respecto a las vibraciones transversales) para identificar daño en los álabes de la turbina.

La metodología propuesta en el presente trabajo de título, resultó ser altamente eficiente para identificar gran parte de las grietas estudiadas, logrando el objetivo de identificar daño incipiente en el sistema rotor. Se propone realizar un estudio futuro probando grietas en posiciones más alejadas del centro del rotor, esperando obtener mejores resultados a medida que la grieta se aleja del centro del rotor.

Se propone realizar pruebas con distintos métodos de clasificación y selección de parámetros, tales como SFFS, SBS y SFBS, para determinar qué algoritmo es capaz de identificar de mejor manera el daño en álabes, superando los resultados obtenidos en el presente trabajo.

Adicionalmente, conociendo el nivel de degradación del sistema rotor, se propone realizar estudios que permitan estimar el tiempo de vida remanente del sistema, lo que en la práctica contribuiría a la correcta planificación de las intervenciones de mantenimiento del sistema, basadas más en el estado de salud del equipo que en el tiempo de operación.

Por último, se propone utilizar un sistema de control de velocidad sobre el rotor, para así asegurar condiciones similares de funcionamiento y disminuir el error en la medición. Por otra parte, esta medida sirve para realizar pruebas en el rotor bajo distintas velocidades de trabajo más similares a la velocidad real en que funciona, por ejemplo, una turbina a gas.

Bibliografía

- [1] A. A. Gubran y J. K. Sinha, «Shaft instantaneous angular speed for blade vibration in rotating machine,» *Mechanical System and Signal Processing*, 2013.
- [2] W. Dandan, Q. Yong, C. Xiaoqing, Z. Zhilong, L. Hengkui y D. Xiaojun, «Train Rolling Bearing Degradation Condition Assessment Based on Local Mean Decomposition and Support Vector Data Description.,» 2016.
- [3] C. Maior, M. Moura, I. Lins, E. López Droguett y H. Diniz, «Remaining Useful Life Estimation by Empirical Mode Decomposition and Support Vector Machine,» 2016.
- [4] L. Lu, J. Yan y d. S. C. W., «Feature selection for EGG signal processing using improved genetic algorithm and empirical mode decomposition,» *Measurement*, 2016.
- [5] J. Zhu, T. Nostrand, C. Spiegel y B. Morton, «Survey of Condition Indicators for Condition Monitoring Systems,» *Renewable NRG Systems*, 2016.
- [6] A. Nandi, C. Liu y M. Denis Wong, «Intelligent Vibration Signal Processing for Condition Monitoring».
- [7] M. Norton y D. Karczub, «Chapter 8. Noise and vibration as a diagnostic tool,» de *Fundamentals of Noise and Vibration Analysis for Engineers*, Cambridge, Cambridge University Press, 2003.
- [8] J. Sheng, S. Dong y Z. G. H. Liu, «Fault feature extraction method based on Local mean decomposition Shannon entropy and improved kernel principal component analysis model,» *Advances in Mechanical Engineering*, 2016.
- [9] J. Sun, Q. Xiao, J. Wen y Y. Zhang, «Natural gas pipeline leak aperture identification and location based on local mean decomposition analysis,» *Measurement*, 2016.
- [10] MQL5, «www.mql5.com,» 8 Mayo 2014. [En línea]. Available: <https://www.mql5.com/es/articles/439>. [Último acceso: 23 Octubre 2016].
- [11] E. Rabiei, E. López Droguett y M. Modarres, «A prognostics approach based on the evolution of damage precursors using dynamic Bayesian networks,» *Advances in mechanical engineering*, 2016.
- [12] E. V. J. González y R. Baldrich, «Clasificación de imágenes ¿Cómo reconocer el contenido de una imagen?,» 2017. [En línea]. Available: <https://es.coursera.org/learn/clasificacion-imagenes/lecture/52IRD/support-vector-machines-svm-conceptos-basicos>. [Último acceso: 05 Julio 2017].
- [13] S. Maldonado y R. Weber, «Modelos de selección de atributos para Support Vector Machines,» *Revista Ingeniería de sistemas*, vol. XXVI, Septiembre 2012.

- [14] G. Forbes y R. Randall, «Estimation of turbine blade natural frequencies from casing pressure and vibration measurements,» *Mechanical Systems and Signal Processing*, 2013.
- [15] H. Yang, J. Mathew y L. Ma, «Vibration Feature Extraction Techniques for Fault Diagnosis of Rotating Machinery- A Literature Survey,» QUT Digital Repository, Noviembre 2003.
- [16] V. Meruane, *Dinámica Estructural. Apunte para el curso ME706*, Santiago: Facultad de Ciencias Físicas y Matemáticas, 2016.
- [17] A-MAQ. *Análisis de Maquinaria.*, «www.mantenimientoplanificado.com,» Enero 2005. [En línea]. Available: <http://www.mantenimientoplanificado.com> [Último acceso: 15 Noviembre 2016].
- [18] H. Haifeng, O. Huajiang, G. Hongli, G. Liang, L. Dan y J. Wen, «A Feature Extraction Method for Vibration Signal of Bearing Incipient Degradation,» De Gruyter, 2016.