



# POSGRADOS

## MAESTRÍA EN ELECTRICIDAD

RPC-SO-22-No.325-2018

OPCIÓN DE  
TITULACIÓN:

PROYECTO DE DESARROLLO

TEMA:

DIAGNÓSTICO DE LA SEVERIDAD DE FALLOS EN MÁQUINAS  
ROTATIVAS A TRAVÉS DE TÉCNICAS DE AGRUPAMIENTO  
APLICADAS A SEÑALES DE CORRIENTE

AUTORES:

DOUGLAS VLADIMIR MONTALVO URETA  
JONATHAN XAVIER ZAMBRANO MENDOZA

DIRECTOR:

MARIELA CERRADA LOZADA

GUAYAQUIL - ECUADOR  
2021

### ***Autores:***



#### **Douglas Vladimir Montalvo Ureta**

Ingeniero en Eléctrico Mecánica con Mención en Gestión Empresarial Industrial  
Candidato a Magíster en Electricidad, Mención Sistemas Eléctricos de Potencia  
Universidad Politécnica Salesiana, Sede Guayaquil  
dmontalvou@est.ups.edu.ec



#### **Jonathan Xavier Zambrano Mendoza**

Ingeniero en Electrónica Control y Redes Industriales  
Candidato a Magíster en Electricidad, Mención Sistemas Eléctricos de Potencia  
Universidad Politécnica Salesiana, Sede Guayaquil  
jzambranom12@est.ups.edu.ec

### ***Director:***



#### **Mariela Cerrada Lozada**

Ingeniero de Sistemas  
Magister Scientiae en Ingeniería de Control  
Doctor en Especialidad Sistemas Automáticos  
mcerrada@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2021 Universidad Politécnica Salesiana.

CUENCA – ECUADOR – SUDAMÉRICA

DOUGLAS VLADIMIR MONTALVO URETA

JONATHAN XAVIER ZAMBRANO MENDOZA

**DIAGNÓSTICO DE LA SEVERIDAD DE FALLOS EN MÁQUINAS ROTATIVAS A TRAVÉS DE TÉCNICAS DE AGRUPAMIENTO APLICADAS A SEÑALES DE CORRIENTE**

## **Agradecimientos**

Esta obra se ha realizado gracias a la bendición de Dios, que nos ha dado discernimiento, sabiduría, fortaleza y salud.

Este trabajo ha sido gracias al apoyo y orientación de la Doctora Mariela Cerrada Lozada. Gracias por su amistad, motivación y apoyo.

Gracias a los miembros del grupo GIDTEC de la UPS Cuenca por su amabilidad, hospitalidad y colaboración.

Gracias a la Universidad Politécnica Salesiana por su excelencia académica.

Gracias a nuestros padres por los valores transmitidos desde la niñez y todo el esfuerzo hecho por nuestra educación.

## **Dedicatorias**

Dedico este trabajo a mi hijo Nicolás Gabriel Montalvo Cabrera que es mi mayor motivación y mi pilar fundamental en la vida.

Dedico este trabajo a mis padres Jhon Eduardo Montalvo y Ana Lucia Ureta que son mi apoyo principal para todo lo que realizo.

Douglas Montalvo

## **Dedicatorias**

Dedico este logro a toda mi familia, de manera especial a mi padre José Lorgio Zambrano, quien ha sido mi inspiración a lo largo de mi vida y ha creído en mis capacidades.

A mi madre Marta Marisela Mendoza por brindarme su apoyo incondicional y desinteresado en todo momento, mi hermano Cristian, a mi amado hijo Emiliano por ser mi fuente de motivación para luchar cada día y a mi novia por los momentos de alegría que me regala a diario, gracias a todos por su ayuda que fue fundamental para la culminación de este trabajo.

También agradezco a mis amigos y compañeros de trabajo, por darme su apoyo a lo largo de este proceso y finalmente, agradezco a mi tutora Mariela Cerrada por su guía y paciencia en el trascurso de este proceso.

Xavier Zambrano

# Índice general

<b>Índice de Contenidos</b>	<b>8</b>
<b>Índice de Figuras</b>	<b>8</b>
<b>Índice de Tablas</b>	<b>19</b>
<b>Resumen</b>	<b>20</b>
<b>Abstract</b>	<b>20</b>
<b>1. Introducción</b>	<b>24</b>
1.1. Antecedentes . . . . .	24
1.2. Justificación . . . . .	28
1.3. Objetivos . . . . .	29
1.3.1. Objetivo general . . . . .	29
1.3.2. Objetivos específicos . . . . .	29
1.4. Contribuciones . . . . .	30
1.5. Organización del manuscrito . . . . .	30
<b>2. Fundamentos teóricos</b>	<b>31</b>
2.1. Señales de corriente eléctrica en el mantenimiento basado en condición . . . . .	31
2.2. Detección y diagnóstico de fallos en cajas de engranajes y compresores recíprocos . . . . .	33
2.2.1. Cajas de engranajes . . . . .	33
2.2.2. Compresores Recíprocos . . . . .	38
2.3. Dominio de representación de señales . . . . .	41
2.4. Extracción y selección de atributos de series temporales . . . . .	47

2.4.1. Atributos estadísticos en el dominio del tiempo, frecuencia y tiempo-frecuencia . . . . .	47
2.4.2. Selección de atributos usando ANOVA e índice de validación de clusters . . . . .	53
2.5. Clasificación por agrupamiento de datos . . . . .	59
2.5.1. Algoritmo LAMDA . . . . .	60
2.5.2. Algoritmo LAMDA HAD . . . . .	64
<b>3. Detección y diagnóstico de fallas en compresores recíprocos y cajas de engranajes usando el algoritmo LAMDA HAD</b>	<b>69</b>
3.1. Adquisición de señales de corriente . . . . .	70
3.1.1. Compresor recíproco . . . . .	70
3.1.2. Caja de Engranaje . . . . .	72
3.2. Procesamiento de señales y extracción de atributos estadísticos . . . . .	84
3.3. Preparación de los datos . . . . .	87
3.4. Reducción y selección de mejores atributos estadísticos . . . . .	88
3.5. Algoritmo de clasificación LAMDA HAD . . . . .	91
<b>4. Análisis de resultados</b>	<b>103</b>
4.1. Análisis de resultados de la selección de atributos . . . . .	103
4.1.1. Resultados en el CR . . . . .	103
4.1.2. Resultados en CE con atributos de tiempo y frecuencia . . . . .	108
Modo de falla: Diente roto en piñón . . . . .	108
Modo de falla: Grieta en piñón . . . . .	116
Modo de falla: Picadura en piñón . . . . .	124
Modo de falla: Rayadura en piñón . . . . .	132
4.1.3. Resultados en CE con atributos de Wavelets . . . . .	141
4.2. Análisis de resultados de la aplicación del algoritmo LAMDA HAD en compresores recíprocos y cajas de engranajes . . . . .	154
4.2.1. Resultados de la clasificación de fallos en CR . . . . .	154
4.2.2. Resultados de la clasificación de fallos en CE . . . . .	155
Modo de falla: Diente roto en piñón . . . . .	155
Modo de falla: Grieta en piñón . . . . .	160
Modo de falla: Picadura en piñón . . . . .	163
Modo de falla: Rayadura en piñón . . . . .	168
4.2.3. Resultados de la evaluación para la clasificación de las clases desconocidas usando los valores de GAD . . . . .	172

<i>ÍNDICE GENERAL</i>	7
<b>5. Conclusiones y Recomendaciones</b>	<b>176</b>
5.1. Conclusiones . . . . .	176
5.2. Recomendaciones . . . . .	178
<b>Glosario</b>	<b>179</b>
<b>Referencias</b>	<b>181</b>
<b>Anexos</b>	<b>192</b>
<b>A. Atributos estadísticos en el dominio del tiempo y la frecuencia</b>	<b>193</b>
A.1. Atributos estadísticos en el dominio del tiempo . . . . .	193
A.2. Atributos estadísticos en el dominio de la frecuencia . . . . .	199



# Índice de Figuras

2.1. Diagrama de las componentes vectoriales de las corrientes del motor de inducción [1] . . . . .	35
2.2. Señal de onda sinusoidal de corriente sin carga . . . . .	36
2.3. Señal de onda sinusoidal de corriente con carga . . . . .	36
2.4. Espectro de la señal de corriente del MI con condición normal en la CE . . . . .	37
2.5. Espectro de la señal de corriente del MI con anomalía en la CE . . . . .	38
2.6. Tabla de organización del plan experimental de fallos en rodamientos para CR [2] . . . . .	39
2.7. Espectros de frecuencia de las señales acústicas de fallos en rodamientos en CR [2] . . . . .	39
2.8. Espectros de frecuencia de las señales de vibración de fallos en rodamientos en CR [2] . . . . .	40
2.9. Descomposición de paquetes de wavelets [3] . . . . .	46
2.10. Representación de las wavelets Madre . . . . .	51
2.11. Proceso de extracción de todos los atributos estadísticos . . . . .	52
2.12. Pseudo código de ANOVA y prueba de Tukey para selección de atributos [4] . . . . .	55
2.13. Pseudo código para selección de atributos según Índice de validación de clústers [4] . . . . .	58
2.14. Representación gráfica de agrupamiento de datos . . . . .	59
2.15. Diagrama de flujo del algoritmo LAMDA . . . . .	63
2.16. Diagrama de flujo del algoritmo LAMDA HAD . . . . .	67
3.1. Esquema de desarrollo del marco metodológico . . . . .	70
3.2. Esquema del banco de pruebas del compresor . . . . .	71
3.3. Modos de fallos en rodamiento de CR . . . . .	72
3.4. Esquema del banco de pruebas de la caja de engranaje . . . . .	73

3.5. Modo de fallo: Diente roto en piñon con diferentes grados de severidades . . . . .	75
3.6. Modo de fallo: Grieta en piñon con diferentes grados de severidades . . . . .	78
3.7. Modo de fallo: Picadura en piñon con diferentes grados de severidades . . . . .	81
3.8. Modo de fallo: Rayadura en piñon con diferentes grados de severidades . . . . .	83
3.9. Menú de selección de base experimental según los atributos estadísticos en CR . . . . .	85
3.10. Interfaces de CE en tiempo y frecuencia: a) Modos de fallas, b) Atributos estadísticos y c) Combinación de grados de severidades . . . . .	86
3.11. Interfaces de CE usando Wavelets: a) Modos de fallas, b) Atributos estadísticos con Wavelets y c) Combinación de grados de severidades . . . . .	86
3.12. Menú de selección del tipo de normalización . . . . .	87
3.13. Interfaces para la prueba ANOVA . . . . .	89
3.14. Tabla de atributos estadísticos de los resultados de ANOVA . . . . .	90
3.15. Gráfica de resultados usando ANOVA y la métrica CDbw en la base de datos de CR . . . . .	91
3.16. Gráfica de resultados de los 3 mejores atributos usando previamente correlación de Pearson para la base de datos de diente roto con el grupo de severidad N-1-2-3 en CE con Wavelets . . . . .	92
3.17. Menú de selección de la base de prueba a utilizar para el algoritmo LAMDA HAD . . . . .	93
3.18. Menú de selección de modo de falla de CE . . . . .	93
3.19. Interfaces de selección del grupo de severidades para entrenamiento y prueba de los datos de CE para aplicar el algoritmo LAMDA HAD . . . . .	94
3.20. Gráfica de datos de entrenamiento para CR . . . . .	95
3.21. Gráfica de datos de prueba del entrenamiento para CR . . . . .	96
3.22. Matriz de confusión para evaluación del rendimiento de la clasificación en los datos de CR . . . . .	96
3.23. Resultados de clasificación de severidades para los datos de entrenamiento de las clases N-4-5-6 del modo de falla de grieta en piñon para CE usando 10 atributos en tiempo y frecuencia y un alfa de 0.6 en el algoritmo LAMDA HAD . . . . .	97

ÍNDICE DE FIGURAS	10
3.24. Resultados de clasificación de severidades para los datos de prueba de las clases N-4-5-6 del modo de falla de grieta en piñon para CE usando 10 atributos en tiempo y frecuencia y un alfa de 0.6 en el algoritmo LAMDA HAD	98
3.25. Matriz de confusión para evaluación del rendimiento de la clasificación en los datos de CE	99
3.26. Gráfica de los datos de grupo de severidades para la prueba del entrenamiento N-4-5-6 del modo de falla de grieta en piñon usando 10 atributos y un alfa de 0.6 para CE en tiempo y frecuencia en el algoritmo LAMDA HAD	100
3.27. Resultados de precisión del clasificador LAMDA HAD para el grupo de severidades N-4-5-6 y clases desconocidas 1-2-3-7-8-9 del modo de falla de grieta en piñon para CE con atributos en tiempo y frecuencia	100
3.28. Resultados de precisión de los clasificadores para cada grupo de severidades del modo de falla de grieta en piñon para CE para muestras de clases conocidas y desconocidas	101
3.29. Tabla de resultados del clasificador que presentó el valor mas alto de los GAD para las clases de los grupos de severidades entrenadas para grieta en piñon	102
4.1. Tabla de resultados de los mejores atributos estadísticos aplicando ANOVA y la métrica $CDbw$ en CR	104
4.2. Gráfica TSNE de los 3 mejores atributos estadísticos en CR	105
4.3. Gráfica TSNE de los 7 mejores atributos estadísticos en CR	106
4.4. Gráfica TSNE de los 10 mejores atributos estadísticos en CR	107
4.5. Gráfica de resultados de los 3 mejores atributos estadísticos aplicando ANOVA y la métrica $CDbw$ en CR	108
4.6. Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla de diente roto	109
4.7. Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-1-2-3 de diente roto en CE	110
4.8. Gráfica TSNE de los 7 mejores atributos estadísticos para el grupo de severidad N-1-2-3 de diente roto en CE	110
4.9. Gráfica TSNE de los 10 mejores atributos estadísticos para el grupo de severidad N-1-2-3 de diente roto en CE	111

4.10. Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla de diente roto . . . . .	111
4.11. Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-4-5-6 de diente roto en CE . . . . .	112
4.12. Gráfica TSNE de los 7 mejores atributos estadísticos para el grupo de severidad N-4-5-6 de diente roto en CE . . . . .	112
4.13. Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-4-5-6 de diente roto en CE . . . . .	113
4.14. Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla de diente roto . . . . .	113
4.15. Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-7-8-9 de diente roto en CE . . . . .	114
4.16. Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-7-8-9 de diente roto en CE . . . . .	114
4.17. Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-7-8-9 de diente roto en CE . . . . .	115
4.18. Tablas de resultados de los 10 de 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica <i>CDbw</i> para diente roto en CE . . . . .	116
4.19. Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla grieta en un diente del piñon . . . . .	117
4.20. Gráfica TSNE de los 3 mejores atributos estadísticos en el grupo de severidades N-1-2-3 para grieta en el diente de CE . . . . .	118
4.21. Gráfica TSNE de los 7 mejores atributos estadísticos en el grupo de severidades N-1-2-3 para grieta en el diente de CE . . . . .	118
4.22. Gráfica TSNE de los 10 mejores atributos estadísticos en el grupo de severidades N-1-2-3 para grieta en el diente de CE . . . . .	119
4.23. Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla grieta en piñon . . . . .	119
4.24. Gráfica TSNE de los 3 mejores atributos estadísticos en el grupo de severidades N-4-5-6 para grieta en el diente de CE . . . . .	120
4.25. Gráfica TSNE de los 7 mejores atributos estadísticos en el grupo de severidades N-4-5-6 para grieta en el diente de CE . . . . .	120

4.26. Gráfica TSNE de los 10 mejores atributos estadísticos en el grupo de severidades N-4-5-6 para grieta en el diente de CE . . . . .	121
4.27. Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla grieta en el diente del piñón . . . . .	121
4.28. Gráfica TSNE de los 3 mejores atributos estadísticos en el grupo de severidades N-7-8-9 para grieta en el diente de CE . . . . .	122
4.29. Gráfica TSNE de los 7 mejores atributos estadísticos en el grupo de severidades N-7-8-9 para grieta en el diente de CE . . . . .	122
4.30. Gráfica TSNE de los 10 mejores atributos estadísticos en el grupo de severidades N-7-8-9 para grieta en el diente de CE . . . . .	123
4.31. Tablas de resultados de los 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica $CD_{bw}$ para grieta en el diente del piñón en CE . . . . .	124
4.32. Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla picadura en piñón . . . . .	125
4.33. Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-1-2-3 para picadura en diente de CE . . . . .	126
4.34. Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-1-2-3 para picadura en diente de CE . . . . .	126
4.35. Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-1-2-3 para picadura en diente de CE . . . . .	127
4.36. Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla picadura en piñón . . . . .	127
4.37. Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-4-5-6 para picadura en diente de CE . . . . .	128
4.38. Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-4-5-6 para picadura en diente de CE . . . . .	128
4.39. Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-4-5-6 para picadura en diente de CE . . . . .	129

4.40. Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla picadura en piñon . . . . .	129
4.41. Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-7-8-9 para picadura en diente de CE . . . . .	130
4.42. Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-7-8-9 para picadura en diente de CE . . . . .	130
4.43. Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-7-8-9 para picadura en diente de CE . . . . .	131
4.44. Tablas de resultados de los 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica <i>CDBw</i> para picadura en CE . . . . .	132
4.45. Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla rayadura en piñon . . . . .	133
4.46. Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-1-2-3 para rayadura en el diente de piñon de CE . . . . .	134
4.47. Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-1-2-3 para rayadura en el diente de piñon de CE . . . . .	134
4.48. Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-1-2-3 para rayadura en el diente de piñon de CE . . . . .	135
4.49. Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla rayadura en piñon . . . . .	135
4.50. Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-4-5-6 para rayadura en el diente de piñon de CE . . . . .	136
4.51. Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-4-5-6 para rayadura en el diente de piñon de CE . . . . .	137

4.52. Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-4-5-6 para rayadura en el diente de piñón de CE . . . . .	137
4.53. Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla rayadura en piñón . . . . .	138
4.54. Gráfica TSNE de agrupación de datos con los 3 mejores atributos estadísticos en los niveles de severidades N-7-8-9 para rayadura en el diente del piñón de CE . . . . .	139
4.55. Gráfica TSNE de agrupación de datos con los 7 mejores atributos estadísticos en los niveles de severidades N-7-8-9 para rayadura en el diente del piñón de CE . . . . .	139
4.56. Gráfica TSNE de agrupación de datos con los 10 mejores atributos estadísticos en los niveles de severidades N-7-8-9 para rayadura en el diente del piñón de CE . . . . .	140
4.57. Tablas de resultados de los 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica <i>CD<sub>bw</sub></i> para rayadura en CE . . . . .	141
4.58. Tabla de resultados de los mejores atributos estadísticos aplicando ANOVA y la métrica <i>CD<sub>bw</sub></i> para los 4 modos de fallos en CE con Wavelets con la correlación de Pearson . . . . .	142
4.59. Gráfica de los mejores 3 atributos estadísticos de Wavelets para los niveles de severidad N-1-2-3 para diente roto en CE, previa aplicación de la correlación de Pearson . . . . .	143
4.60. Gráfica de los mejores 3 atributos estadísticos de Wavelets para los niveles de severidad N-1-2-3 para grieta en el piñón en CE, previa aplicación de la correlación de Pearson . . . . .	144
4.61. Gráfica de los mejores 3 atributos estadísticos de Wavelets para los niveles de severidad N-1-2-3 para rayadura en el diente del piñón en CE, previa aplicación de la correlación de Pearson . . . . .	145
4.62. Gráfica de los mejores atributos estadísticos para N-1-2-3 aplicando ANOVA y la métrica <i>CD<sub>bw</sub></i> para rayadura en piñón en CE con Wavelets con la correlación de Pearson . . . . .	146
4.63. Tabla de resultados de los 10 mejores atributos estadísticos para los 4 modos de fallos en CE con Wavelets sin la correlación de Pearson . . . . .	147

4.64. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para diente roto de piñon en CE, sin aplicar correlación de Pearson . . . . .	147
4.65. Gráfica TSNE de los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para diente roto de piñon en CE, sin aplicar correlación de Pearson . . . . .	148
4.66. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para diente roto de piñon en CE, sin aplicar correlación de Pearson . . . . .	148
4.67. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para grieta en diente del piñon de CE, sin aplicar correlación de Pearson . . . . .	149
4.68. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para grieta en diente del piñon de CE, sin aplicar correlación de Pearson . . . . .	149
4.69. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para grieta en diente del piñon de CE, sin aplicar correlación de Pearson . . . . .	150
4.70. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para picadura de diente en el piñon de CE, sin aplicar la correlación de Pearson . . . . .	150
4.71. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para picadura de diente en el piñon de CE, sin aplicar la correlación de Pearson . . . . .	151
4.72. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para picadura de diente en el piñon de CE, sin aplicar la correlación de Pearson . . . . .	151
4.73. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para rayadura en el diente de piñon de CE, sin aplicar la correlación de Pearson . . . . .	152
4.74. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para rayadura en el diente de piñon de CE, sin aplicar la correlación de Pearson . . . . .	152
4.75. Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para rayadura en el diente de piñon de CE, sin aplicar la correlación de Pearson . . . . .	153
4.76. Tabla de resultados de exactitud del clasificador LAMDA HAD en CR . . . . .	155



4.77. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	156
4.78. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	156
4.79. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	157
4.80. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	157
4.81. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	158
4.82. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	158
4.83. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	159
4.84. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 10 atributos estadísticos para el modo de falla diente roto en piñon . . . . .	159
4.85. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla grieta en piñon . . . . .	160
4.86. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla grieta en piñon . . . . .	160
4.87. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla grieta en piñon . . . . .	161
4.88. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla grieta en piñon . . . . .	161

4.89. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla grieta en piñon . . . . .	162
4.90. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla grieta en piñon . . . . .	162
4.91. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla grieta en piñon . . . . .	163
4.92. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla picadura en piñon . . . . .	164
4.93. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla picadura en piñon . . . . .	164
4.94. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla picadura en piñon . . . . .	165
4.95. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla picadura en piñon . . . . .	165
4.96. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla picadura en piñon . . . . .	166
4.97. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla picadura en piñon . . . . .	166
4.98. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla picadura en piñon . . . . .	167
4.99. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 10 atributos estadísticos para el modo de falla picadura en piñon . . . . .	167
4.100. Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	168

4.10	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	169
4.102	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	169
4.103	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	170
4.104	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	170
4.105	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	171
4.106	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	171
4.107	Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 10 atributos estadísticos para el modo de falla rayadura en piñon . . . . .	172
4.108	Tabla de resultados del clasificador que presentó el valor mas alto de los GAD para las clases de los grupos de severidades para picadura en piñon . . . . .	173
4.109	Tabla de resultados del clasificador que presentó el valor mas alto de los GAD para las clases de los grupos de severidades para rayadura en piñon . . . . .	174
4.110	Tabla de resumen de los datos clasificados en cada una de las clases para grieta en piñon . . . . .	174
4.111	Tabla de resumen de los datos clasificados en cada una de las clases para picadura en piñon . . . . .	175
4.112	Tabla de resumen de los datos clasificados en cada una de las clases para rayadura en piñon . . . . .	175

# Índice de Tablas

2.1. Atributos estadísticos en el dominio del tiempo . . . . .	47
2.2. Atributos estadísticos en el dominio de la Frecuencia . . . . .	49
2.3. T-norms and T-conorms . . . . .	62
3.1. Descripción de fallas de diente roto en piñon . . . . .	74
3.2. Descripción de fallas de grieta en piñon . . . . .	75
3.3. Descripción de fallas de picadura en piñon . . . . .	78
3.4. Descripción de fallas de rayadura en piñon . . . . .	81
A.1. Atributos estadísticos en el dominio del tiempo . . . . .	193
A.2. Atributos estadísticos en el dominio de la Frecuencia . . . . .	199

# Resumen

El presente trabajo aborda dos aspectos importantes del desarrollo de modelos de Aprendizaje Automático (Machine Learning) para detección y diagnóstico de fallos en máquinas rotativas a partir de señales de corriente eléctrica, los cuales consisten, primero, en realizar una apropiada identificación y selección de atributos informativos respecto a su capacidad de proveer estructuras de agrupamiento en el espacio de atributos para mejorar el desempeño de clasificadores de fallas y, segundo, probar el desempeño de técnicas de clasificación conocidas, que permitan identificar automáticamente la clase de falla inherente a una muestra de señal de corriente medida. Específicamente, en este trabajo se evaluó una técnica que indica tener la funcionalidad de identificar la aparición de nuevos, no conocidos, grupos de datos que se asocian a condiciones de fallos no previamente identificados.

Para este propósito, se analizaron experimentalmente de forma exhaustiva seis bases de datos de dos clases de maquinaria rotativa, con atributos extraídos de la representación en el dominio del tiempo, frecuencia y tiempo-frecuencia, de señales de corriente eléctrica.

Para la primera parte, se aplica el algoritmo de análisis de varianza ANOVA y el índice de validez de clusters basado en la métrica  $CDbw$  para la identificación y selección de los mejores atributos estadísticos en las bases de datos proporcionadas por el grupo de investigación GIDTEC de la UPS sede Cuenca. Estas bases de datos están conformadas por datos recolectados de señales de corriente eléctrica de un motor de inducción acoplado a una caja de engranaje y a un compresor recíprocante, en donde en el primer caso se introdujeron 4 modos de fallas en los dientes del piñón, en diferentes niveles de severidad, y en el segundo caso se introdujeron fallas en los rodamientos, relativos a 3 modos de fallas.

Para la segunda parte, usa el algoritmo de clasificación y agrupamiento LAMDA-HAD con los mejores atributos estadísticos previamente identificados, para ajust-

tar cuatro clasificadores. Específicamente, para el análisis de las fallas en los rodamientos del compresor recíprocante se ajustó un solo clasificador, mientras que para los fallos en la caja de engranaje se ajustaron 3 clasificadores dedicados a 4 niveles de severidad de fallos, incluida la clase normal, para cada clasificador. En la fase de pruebas de clasificación, usando datos de las clases conocidas, se lograron precisiones sobre el 90 % para el compresor recíprocante, y precisiones entre el 82 % y 95 % para la caja de engranajes.

Finalmente, se evaluó la capacidad de la técnica de clasificación y agrupamiento LAMDA-HAD para detectar nuevos patrones de fallas no conocidas por un clasificador dedicado, mediante la comparación de los valores de los grados de adecuación marginal asignados por cada clasificador de las clases conocidas. Esta evaluación determinó que aún es necesario mejorar el mencionado algoritmo para esta funcionalidad, al menos en los casos de estudio, donde los datos no presentan estructuras de grupos (clústers) bien definidas.

# Abstract

This work addresses two important aspects of the development of Machine Learning models for fault detection and diagnosis in rotating machines from electrical current signals. The first aspect consists of the proper identification and selection of informative attributes to improve the performance of fault classifiers, and second aspect is performance evaluation of known classification techniques, which allow to automatically identify the fault condition inherent to a sample of measured current signal. Specifically, in this work a technique was evaluated which have the functionality of identifying new, or unknown, data groups that are associated with fault conditions not previously identified.

For this purpose, six databases of two types of rotating machinery were exhaustively analyzed experimentally, with attributes extracted from the representation in the time domain, frequency and time-frequency, of electric current signals.

In the first part, the Analysis of Variance (ANOVA) algorithm and the cluster validity index based on the metric  $CD_{bw}$  are applied for the identification and selection of the best statistical attributes in the databases, which were provided by the GIDTEC research group at UPS-Cuenca. These databases are composed by data collected from electric current signals from an induction motor coupled to a gearbox (GB) and a reciprocating compressor (RC). In case of the GB, four failure modes were introduced in the pinion teeth, at different levels of severity. In case of the RC, three failure modes in the bearings were considered.

For the second part, the LAMDA-HAD classification and clustering algorithm is used for training four classifiers with the best previously identified statistical attributes. Specifically, for the analysis of failures in the RC, a single classifier was adjusted, while three classifiers were adjusted for the GB each one oriented to four levels of failure severity, including the normal class. In the test phase, each classifier performance is tested with the known classes by means of the

classification precision metric, accuracies over 90% were achieved for the case of RC, and accuracies between 82% and 95% for the GB.

Finally, the ability of the LAMDA-HAD classification and clustering algorithm to detect new failure patterns by a dedicated classifier was evaluated by comparing the values of the marginal adequacy degrees assigned by each classifier of the known classes. This evaluation suggested that it is still necessary to improve the aforementioned algorithm for this functionality, at least in the case studies, where the data do not present well-defined group structures (clusters).



# Capítulo 1

## Introducción

Este capítulo describe la problemática de la investigación, justificación y necesidades que generaron el interés por realizar el análisis del comportamiento del algoritmo LAMDA HAD para diagnosticar diferentes niveles de severidades de fallas en máquinas rotativas usando las señales de corriente eléctrica. Inicialmente se describen los antecedentes, justificaciones, los objetivos y contribuciones científicas en relación a este trabajo.

### 1.1. Antecedentes

Las **Máquinas Rotativas (MR)** cumplen un rol importante en los sistemas industriales, ya que de éstos depende que exista un proceso continuo y confiable. Cuando una **MR** empieza a presentar una condición anormal de trabajo, el proceso de un sistema puede verse afectado, generando altos costos de mantenimiento, afectación a la seguridad del personal y altas pérdidas económicas por tiempo improductivo, por lo tanto, el monitoreo y diagnóstico de las **MR** es crucial para garantizar la confiabilidad y mantenibilidad de un proceso industrial [5, 6]. Cuando se menciona a las **MR** se hace referencia a máquinas comúnmente usadas en las industrias como son motores eléctricos, compresores, bombas, cajas de engranajes, entre otros. Las cajas de engranajes (**Cajas de engranajes (CE)**) son una de las **MR** más usadas en la mayor parte de las industrias debido a su característica de transmitir pares mecánicos elevados en espacios pequeños; a pesar de su gran robustez, las **CE** pueden presentar fallos debido a varios factores como son, deficiencia del material de fabricación, desgaste por los ciclos de trabajo, inadecuada lubricación, defectos de montaje,

entre otros [7–10]. Generalmente las fallas inician en los dientes de los engranes, por su apariencia las fallas pueden ser descritas como; picaduras, desgaste, grietas y astillamiento [11–14].

Por otro lado los compresores reciprocantes (**Compresores reciprocantes (CR)**) son **MR** que utilizan un método confiable y eficiente al comprimir casi cualquier tipo de mezcla de gas y llevarlos a altas presiones para luego emplearlos en un trabajo determinado, es por eso que estas máquinas son usadas en numerosas aplicaciones industriales, también son propensas a sufrir defectos en cualesquiera de sus componentes que lo conforman ya que pueden fallar por desgaste, corrosión, inadecuada lubricación, fatiga, fractura de partes entre otros [2, 15, 16].

En la actualidad existen varias técnicas de monitoreo y diagnóstico aplicadas a **MR** como el análisis de espectros de vibración, emisiones acústicas, análisis de la señal de corriente del motor, entre otras [17–30]. Los métodos más comunes para diagnosticar fallos en **MR** son el **Análisis de vibraciones (AV)** y actualmente se está enfatizando el uso del **Análisis espectral de la corriente del motor (MCSA)** para detectar fallos en las máquinas acopladas en los Motores de Inducción (**Motores de inducción (MI)**). El **MCSA** en principio se lo utilizó para detectar problemas en los **MI** como son identificación de barras rotas en el rotor, excentricidades en el entrehierro, fallos de rodamiento y cortocircuitos entre espiras, esta técnica también se la ha utilizado para detectar problemas en elementos mecánicos fuera del motor como por ejemplo las **CE** y **CR** [14], [31–38].

Las oscilaciones causadas por defectos en las cargas acopladas en los **MI** pueden transmitirse hasta el eje causando movimientos radiales y axiales entre el rotor y estator, se puede decir que el motor actúa como un transductor ya que estas oscilaciones mecánicas provocan cambios en los flujos magnéticos del motor reflejándose en la corriente eléctrica como patrones de frecuencias características, por lo tanto, el uso del **MCSA** para la detección de fallas en las **MR** es un tema de interés que se encuentra en estudio ya que es una técnica de diagnóstico no intrusiva y de bajo presupuesto de implementación comparada con otras técnicas tradicionales [1, 39, 40].

Para el uso de técnicas de monitoreo y diagnóstico se usan equipos sofisticados los cuales utilizan sensores y transductores para captar magnitudes físicas y convertirlas en señales eléctricas para luego ser procesadas mediante algoritmos basados en técnicas matemáticas en donde se analizan estas señales en el dominio del tiempo y frecuencia. Los métodos estándares más utilizados para el procesamiento de señales tiempo-frecuencia son la **Transformada rápida de Fourier (FFT)** y la **Transformada discreta de Fourier (FDT)**, sin embargo cuando

la máquina está en operación el proceso mecánico es dinámico y los diferentes modos de fallas son estocásticos, por lo tanto, estas técnicas presentan problemas por las interferencias del medio en el acondicionamiento de la señal y esto genera pérdida de la información cuando se realizan las transformaciones de tiempo a frecuencia, incluso el uso de los variadores de frecuencia pueden hacer que estas señales presenten interferencia o ruidos inducidos por las mismas frecuencias de conmutación que son alrededor de los KHz. Una de las técnicas que está ganando importancia en el área de procesamiento de señales es la [Descomposición en paquetes de Wavelets \(DPW\)](#) que es una versión mejorada de la [Transformada de Wavelet \(TW\)](#), que proporciona una alternativa mejorada a las técnicas tradicionales debido a su capacidad para descomponer las señales a niveles completos y de alta resolución en tiempo-frecuencia en estado estacionario y no estacionario [41–50].

El objetivo principal de monitorear y diagnosticar la condición de una MR es de mantenerla el máximo tiempo posible en operación, y en base a esto se requiere el enfoque de nuevas técnicas computacionales para diagnósticos más eficientes que permitan identificar y clasificar de una manera más óptima los modos de falla que afecten la operatividad de las MR. Existen varias investigaciones enfocadas al uso del [Machine Learning \(ML\)](#) que usan redes neuronales, árboles de decisión, máquinas de soporte vectorial, o arquitecturas de aprendizaje profundo, como modelos de diagnósticos de fallas en MR, usando señales de vibración principalmente, donde primero se extraen atributos de tales señales y luego se clasifican las fallas [38], [3, 51–57]. El uso de la [Lógica Difusa \(LD\)](#) como herramienta de deducción o inferencias a partir de premisas que permite simular los procedimientos de razonamiento humano, también ha sido utilizado en la detección y diagnóstico de fallas de MR, específicamente en rodamientos [58]. En [59–63] se aplican técnicas difusas específicas, como diagnosticadores de fallas en rodamientos y cajas de engranajes helicoidales.

En el uso de modelos de ML, es importante hacer una apropiada selección de atributos para mejorar el desempeño de los clasificadores. Por ejemplo, en [4] se propone la identificación de mejores atributos basadas en [Análisis de Varianza \(ANOVA\)](#), e índices de validez de grupos (clústers) mediante técnicas de agrupamiento y [K-vecinos mas cercanos \(KNN\)](#) para diagnósticos de fallas en rodamientos. Otros trabajos que abordan el problema de selección de atributos se presenta en [64–66].

Los trabajos mencionados anteriormente abordan el problema de detección y diagnóstico de fallas como un problema de clasificación, sin embargo, en la práctica no se tiene disponibilidad de todas las señales en las diferentes condi-

ciones de falla, para ejecutar un aprendizaje supervisado del modelo de clasificación. Para ello se han dirigido esfuerzos para la posición de enfoques semi-supervisados o no supervisados de detección de nuevos patrones de comportamiento que van apareciendo que pudiesen estar asociados a nuevas condiciones de fallas, no conocidas previamente para un aprendizaje fuera de línea. En [67] se analiza una técnica híbrida llamada HHA-EMCC que está basada en dos algoritmos de ML, K-media (K-means) y 1-NN para clasificación y agrupamiento, que analiza la búsqueda de nuevos patrones que puedan estar asociados a nuevas condiciones de fallas en cajas de engranajes el cual está inspirado en la propuesta [68].

Un esfuerzo en desarrollar algoritmos para detectar la aparición de nuevos grupos de datos se presenta en [69] llamado LAMDA, pensado en principio para datos cualitativos incorporando la LD para asociar una representación numérica. El Algoritmo de aprendizaje para análisis de datos multivariantes (LAMDA) es un método difuso utilizado para la clasificación y agrupamiento, está basado en la exploración del grado de adecuación global de un individuo a una clase, considerando las aportaciones de cada variable, el cual permite trabajar en modo supervisado y no supervisado, también una de sus mayores ventajas con respecto a otras técnicas de clasificación y agrupamiento es la capacidad de generar nuevas clases después de la etapa de entrenamiento. LAMDA ha sido utilizado en [70] como modelo de aplicación para la producción de petróleo, también en [71] se lo ha utilizado como método de diagnóstico de fallas y aislamiento, en [72] se lo ha utilizado en la detección de estados funcionales en un proceso de coagulación de tratamiento de aguas.

Con todo lo presentado en esta sección, resulta interesante pensar en la aplicación del algoritmo LAMDA para la detección de nuevas condiciones funcionales en MR que puede estar asociada a la aparición de nuevas condiciones de fallo, similarmente a lo planteado en [67].

Finalmente, el Grupo de investigación y desarrollo en tecnologías industriales (GIDTEC) de la UPS, sede Cuenca, tiene experiencia comprobada en el área de detección y diagnóstico de fallas en MR, usando modelos computacionales de ML, por lo que la investigación planteada puede ser desarrollada apropiadamente.

## 1.2. Justificación

En los procesos industriales es de vital importancia disminuir los tiempos de inactividad por desperfectos, por lo cual se vuelve necesario contar con indicadores de condición que faciliten identificar el estado de las MR. En la actualidad existen varias técnicas de monitoreo y diagnóstico aplicadas a MR como el análisis de espectros de vibración, emisiones acústicas, análisis de la señal de corriente del motor, entre otras. El pronóstico de la vida útil, la condición a futuro o la probabilidad de operación óptima en base a los datos de la condición, da la posibilidad de reducir el tiempo de inactividad en máquinas rotatorias [73]. El uso de la señal de la corriente, no solo desde la perspectiva del MCSA sino desde el análisis de atributos extraídos de la señal en el dominio del tiempo o de tiempo-frecuencia, sería de gran utilidad como técnica alternativa de monitoreo y diagnóstico de la condición. Específicamente se desea identificar el estado de funcionamiento nominal o de fallo de la MR de carga al motor usando modelos computacionales del ML, los cuales tienen como entrada atributos extraídos de la señal cruda de vibración o corriente, y presenta como salida las condiciones funcionales estimadas.

Los atributos, o parámetros de condición, están asociados a parámetros estadísticos calculados sobre la señal en el dominio del tiempo, o también pueden calcularse sobre los coeficientes obtenidos de la descomposición de la señal por DPW. La TW no solo tiene un significado físico explícito, sino también provee de parámetros informativos, la descomposición por paquetes, lo que proporciona una manera de abordar los desafíos anteriores en la detección y diagnóstico de fallas [74].

Las ventajas de disponer de un modelo computacional que sirva de apoyo al monitoreo de la condición del equipo, permite que no exista la necesidad de detener los procesos en los cuales están involucrados las MR asociadas a CE. Además, considerando el rápido avance de los métodos que involucran la tecnología del ML, así que la aplicación del ML enfocada a la identificación de los fallos que podría presentar la máquina, puede llevarse de manera adecuada y automática, con el objetivo de optimizar costos de mantenimiento y mejorar los tiempos en la detección de dichas fallas.

La investigación que se propone pretende abordar dos aspectos importantes del desarrollo de modelos de ML para detección y diagnóstico de fallos; primero la identificación de atributos informativos respecto a su capacidad de proveer estructuras de agrupamiento en el espacio de atributos y segundo el desarrollo de modelos de agrupamiento difuso, que permita identificar automáti-

camente la aparición de nuevos, no conocidos, grupos de datos que se asocien a condiciones de fallos no previamente identificados. Para la primera parte se pretende aplicar el algoritmo de análisis de atributos presentado en [4] de forma supervisada considerando algunas condiciones de fallas conocidas, mientras que para la segunda parte se desea utilizar el algoritmo de agrupamiento [LAMDA](#), el cual permite trabajar en modo supervisado y no supervisado. En este trabajo se quiere explotar, unas de las mayores ventajas de dicho algoritmo, con respecto a otras técnicas de clasificación y agrupamiento, el cual tiene la capacidad de generar nuevas clases después de la etapa de entrenamiento [75]. Además, de acuerdo a la manera en la que esta técnica requiere ser ejecutada, los costos de implementación disminuyen en comparación con otras técnicas y los tiempos de adquisición de información son cortos, con el objetivo de analizar una mayor cantidad de información.

### **1.3. Objetivos**

#### **1.3.1. Objetivo general**

Proponer un modelo de aprendizaje automático semi supervisado basado en agrupamiento difuso para el diagnóstico de severidad de fallos en maquinarias rotativas a partir del análisis de la señal de corriente eléctrica.

#### **1.3.2. Objetivos específicos**

- Establecer el estado del arte acerca de detección de fallas en maquinarias rotativas, específicamente cajas de engranajes y compresores recíprocos mediante el análisis de la corriente eléctrica, el uso de indicadores estadísticos de condición y técnicas de procesamiento de señales, como la Descomposición en Paquetes de Wavelets, así como el uso de algoritmos de agrupamiento difuso para la detección de nuevos patrones de comportamiento de la señal.
- Comprender las bases de datos de atributos extraídos de señales de corriente asociadas a cajas de engranajes y compresores recíprocos, extraídos en el laboratorio del grupo de investigación [GIDTEC](#) de la UPS-Cuenca.

- Evaluar el algoritmo de agrupamiento [LAMDA](#), conjuntamente con otras métricas de agrupamiento, para la detección de nuevas condiciones de severidad de fallos en cajas de engranajes y compresores recíprocos.
- Identificar los atributos informativos extraídos del dominio del tiempo y del tiempo-frecuencia, con base en su capacidad de producir estructuras de agrupamientos adecuadas para detección y diagnósticos de fallos.
- Proponer un modelo de aprendizaje automático con base en el algoritmo de agrupamiento difuso [LAMDA](#), conjuntamente con otras métricas de agrupamiento, para la detección de nuevas condiciones de severidad de fallos en cajas de engranajes y compresores recíprocos.
- Establecer la factibilidad de uso de la señal de corriente para el diagnóstico de severidad de fallos en engranajes y compresores, usando el modelo propuesto.

## 1.4. Contribuciones

Como contribución se va a evaluar, compartir resultados y conclusiones sobre el uso del [Algoritmo de aprendizaje para análisis de datos multivariantes con un grado de adecuación superior \(LAMDA HAD\)](#) con datos adquiridos mediante señales de corriente eléctrica para la clasificación de diferentes grados de severidades de fallos en máquinas rotativas.

## 1.5. Organización del manuscrito

El manuscrito de este trabajo ha sido organizado como sigue:

El capítulo 1 presenta la descripción del problema y objetivos de este trabajo. El capítulo 2 presenta los fundamentos teóricos relacionados a mantenimiento basado en condición en máquinas rotativas, procesamiento de señales, extracción y selección de atributos de series temporales, y detalles sobre el algoritmo [LAMDA HAD](#). En el capítulo 3 se describe la formulación del problema, se describe como se utiliza el algoritmo [LAMDA HAD](#), y el procedimientos de los planes experimentales. El capítulo 4 se relaciona con el análisis de resultados bajo descripción del algoritmo y simulación en el software Matlab. Finalmente el capítulo 5 concluye este trabajo.

# Capítulo 2

## Fundamentos teóricos

En este capítulo se describe algunos aspectos básicos sobre mantenimiento basado en condición, detección y diagnóstico de fallos en compresores recíprocos y cajas de engranajes, extracción y selección de atributos estadísticos en tiempo, frecuencia y tiempo-frecuencia y la teoría relacionada con el algoritmo [LAMDA HAD](#).

### 2.1. Señales de corriente eléctrica en el mantenimiento basado en condición

Es una técnica de mantenimiento en donde su metodología está basada en diagnosticar y evaluar el estado operativo de las máquinas en tiempo real utilizando información recopilada mediante variables o señales de proceso como vibraciones mecánicas, señales acústicas, presión, temperatura, análisis de aceite, señales de corriente y voltajes del motor, entre otras [2]. Uno de los objetivos principales de esta metodología es conocer el estado de degradación de las máquinas y así mediante el diagnóstico tomar una decisión y planificar con anticipación el tipo de mantenimiento a realizar antes de que se produzca un fallo [19].

La técnica de monitoreo y análisis de señales de vibraciones mecánicas sigue siendo una de las más utilizadas y aplicada en la industria puesto que logra detectar aproximadamente el 90% de todas las fallas en las [MR](#), sin embargo presenta ciertos inconvenientes en el diagnóstico de fallas en etapas tempranas debido a presencias de fuentes de ruido, eventos transitorios en las máquinas como oscilaciones en la velocidad o en las cargas, o problemas con el



emplazamientos de los sensores para la toma de datos, maquinarias en ambientes industriales agresivos en donde se puede ver afectada la sensibilidad de los sensores y dar lecturas erróneas [2, 31].

Si bien las señales de vibración son las más comunes en estudiar, en este trabajo se analizan las señales de corriente como fuente de información relevante para el monitoreo de la condición de las MR.

La utilización de la señal de la corriente del motor generalmente es denominada MCSA, el cual consiste en medir las señales de corrientes que circulan por las líneas que alimentan al motor. El MCSA en principio se lo utilizó para detectar problemas en los MI como son identificación de barras rotas en el rotor, excentricidades en el entrehierro, fallos de rodamiento y cortocircuitos entre espiras, esta técnica también se la ha utilizado para detectar problemas en elementos mecánicos fuera del motor como por ejemplo los CR y las CE [14, 31–38].

El principio fundamental de esta técnica para detectar fallas en cargas o máquinas acopladas al eje del motor es que las oscilaciones causadas por defectos en las cargas acopladas en los MI pueden transmitirse hasta el eje causando movimientos radiales y axiales entre el rotor y estator, se puede decir que el motor actúa como un transductor ya que estas oscilaciones mecánicas provocan cambios en los flujos magnéticos del motor reflejándose en la corriente eléctrica como patrones de frecuencias características. Por lo tanto, el uso del MCSA para la detección de fallas en las MR es un tema de interés que se encuentra en constante estudio ya que es una técnica de diagnóstico no intrusiva que se realiza directamente desde el accionamiento eléctrico y de bajo presupuesto de implementación ya que solo se necesita unas pinzas amperímetros, una etapa de conversión de señales y adquisición de datos y el uso de un software [1, 40]. Comparada con otras técnicas tradicionales no se necesita estar en el sitio de las MR que en muchas ocasiones las condiciones ambientales y el acceso son complicaciones para la recolección de datos y la evaluación de las fallas.

Si bien existen formulaciones matemáticas para detectar fallos en motores a partir de las señales de corriente [39], este trabajo usa esta señal de corriente para detectar fallos en CR y CE, a través de la extracción de atributos apropiados de dicha señal, en el dominio del tiempo, de la frecuencia y del tiempo-frecuencia.

## 2.2. Detección y diagnóstico de fallos en cajas de engranajes y compresores reciprocantes

### 2.2.1. Cajas de engranajes

Las cajas de engranajes son las máquinas más usadas en la industria para transmitir potencias desde un eje de entrada y otro de salida con cambios de velocidades y pares mecánicos, están compuestos principalmente por cojinetes, trenes de engranes y ejes, estos elementos generalmente están inmersos en aceite lubricante para disminuir la fricción de los componentes. Las fallas más comunes en las cajas de engranajes pueden ser dientes rotos, picaduras, ralladuras, grietas, daños en los cojinetes, etc. La detección de problemas en las cajas de engranajes pueden ser detectadas mediante técnicas comunes de monitoreo de condición como son análisis de aceite lubricante, análisis de vibraciones, emisión de señales acústicas y la señal de la corriente eléctrica del motor [24, 53].

Como se mencionó anteriormente, los defectos en las CE pueden ser detectados por medio de la señal de la corriente eléctrica debido a transitorios u oscilaciones del par generados por fallos en los dientes de los engranes. En [1, 28] se definen varias ecuaciones como principio del diagnóstico de fallas en cajas de engranajes por medio de la señal eléctrica del motor. La ecuación (2.1) describe el par electromagnético T del MI.

$$T = \frac{3 \cdot P_p}{2} \lambda_s \cdot i_{sT} \quad (2.1)$$

donde:

- $P_p$  - # de par de polos
- $\lambda_s$  - enlace del flujo del estator
- $i_{sT}$  - vector de la corriente del estator a 90 grados por delante del vector de flujo o del par del motor

En presencia de las oscilaciones torsionales a la frecuencia ( $T_0$ ) el par del entrehierro (T) del MI se calcula con la ecuación (2.2).

$$T = T_0 + A_T \cdot \text{Cos}(2\pi f_0 t + \phi) \quad (2.2)$$

donde:

- $T_0$  - par promedio
- $A_T$  - par entregado por la máquina rotativa
- $f_0$  - velocidad de salida de la máquina rotativa
- $\phi$  - fases del motor

Por lo tanto, sólo los efectos de las oscilaciones torsionales producidas por las frecuencias rotacionales en el eje son considerados en las señales de corriente. La componente de la corriente magnetizante  $i_{sM}$  se encuentra en cada corriente de las fases del estator, y estas se encuentran en fase con el vector de flujo, y una componente de par del motor  $i_{sT}$ , que se encuentra a  $90^\circ$  por delante del vector de flujo como se indica en la figura 2.1. Estas componentes están definidas por las ecuaciones (2.3) y (2.4).

$$i_{sM} = i_{sMo} + A_{sM} \cdot \text{Sen}(2\pi f_0 t + \phi_M) \quad (2.3)$$

$$i_{sT} = i_{sTo} + A_{sT} \cdot \text{Sen}(2\pi f_0 t + \phi_T) \quad (2.4)$$

donde:

- $i_{sMo}$  e  $i_{sTo}$  - valor promedio de los vectores  $i_{sM}$  e  $i_{sT}$
- $A_{sM}$  y  $A_{sT}$  - son proporcionales a  $A_T$
- $\phi_M$  y  $\phi_T$  - son las fases proyectadas de la corriente magnetizante y el par del motor.




Figura 2.1: Diagrama de las componentes vectoriales de las corrientes del motor de inducción [1]

La componente del estator  $i_{sr}$  como se muestra en la figura 2.1, se puede medir cuando es proyectada sobre la corriente de fase  $r$  del motor con una frecuencia de de red  $f$ . El cálculo de la corriente se puede realizar con la ecuación (2.5).

$$\begin{aligned}
 i_{sr} = & i_{s0} \text{Sen}(2\pi f t + \phi_{s0}) + \\
 & \frac{1}{2} \left\{ A_{sM} \text{Cos} [2\pi (f - f_0) t - \phi_M] + \right. \\
 & \left. A_{sT} \text{Cos} [2\pi (f - f_0) t - \phi_T] \right\} - \\
 & \frac{1}{2} \left\{ A_{sM} \text{Cos} [2\pi (f + f_0) t - \phi_M] - \right. \\
 & \left. A_{sT} \text{Cos} [2\pi (f + f_0) t - \phi_T] \right\}
 \end{aligned} \tag{2.5}$$

En la ecuación (2.5) se establece que el efecto de una oscilación con una frecuencia  $f_0$  se puede observar fácilmente en la corriente del motor como componentes de bandas laterales de frecuencia  $(f + f_0)$  y  $(f - f_0)$ .

Cuando el motor de inducción carece de anomalías y no existe ningún par oscilante o vibraciones generadas por algún fallo, la corriente esta representada por una onda sinusoidal pura, pero debido a las  $i_{sM}$  e  $i_{sT}$  como se presenta en la ecuación (2.5), la señal de la corriente se verá perturbada en cualquiera de

sus fases, producto de alguna oscilación generada por algún tipo de anomalía propia del motor o de la carga.




Figura 2.2: Señal de onda sinusoidal de corriente sin carga

La figura 2.2 representa la señal de corriente cuando el MI se encuentra acoplado a una CE sin ningún tipo de daño.




Figura 2.3: Señal de onda sinusoidal de corriente con carga

La figura 2.3 representa la señal de corriente cuando el MI se encuentra acoplado a una CE con un grado severo de diente roto. El daño ejercido por la carga genera un torque oscilante en el eje del motor, y este induce frecuencias armónicas como bandas laterales con respecto a la frecuencia de la red.

Como se puede observar en las figuras 2.2 y 2.3 no se puede apreciar un cambio notable en la forma de onda de la condición normal y la condición con falla, por lo tanto se debe recurrir a la representación de estas señales en el dominio de la frecuencia en donde se puede analizar los armónicos de frecuencia y bandas laterales generadas por algún tipo de anomalía.

Las figuras 2.4 y 2.5 representan en el dominio de la frecuencia a las señales de corriente que se mostraron en las figuras 2.2 y 2.3, como se mencionó corresponden a un MI que se encuentra acoplado a una CE en condición normal y con un grado severo de diente roto.




Figura 2.4: Espectro de la señal de corriente del MI con condición normal en la CE




Figura 2.5: Espectro de la señal de corriente del MI con anomalía en la CE

### 2.2.2. Compresores Reciprocantes

Los compresores reciprocantes sirven para absorber aire del ambiente para luego ser comprimido y entregado a mayores presiones, son máquinas muy usadas en las industrias y pequeños comercios debido a su sencillo mantenimiento, disponibilidad y fácil uso. Como datos estadísticos de encuestas realizadas a consumidores y fabricantes de CR en varios países, se concluyó que las fallas en los sistemas mecánicos producen alrededor del 76.5% de averías imprevistas del compresor, generalmente los componentes críticos que fallan son las válvulas y los cojinetes, cuando estos componentes fallan existe una alta probabilidad de que se produzcan anomalías como ruidos excesivos, fugas de aire comprimido, consumo de energía adicional, daños graves o incluso daño total de la maquinaria [15, 16].

En [2] se presenta el uso de las señales acústicas y señales de vibración en un CR donde se han introducido diferentes modos de fallos, incluidos fallos en los rodamientos, los cuales se pueden apreciar en la figura 2.6.

Codificación de prueba	Rodamiento B1	Rodamiento B2	Descripción del fallo
P1	N	N	Condiciones normales
P2	B1_1_4	N	Fallo en pista interna
P3	B1_2_4	N	Fallo en elemento rodante
P4	B1_3_4	N	Fallo de pista externa

Figura 2.6: Tabla de organización del plan experimental de fallos en rodamientos para CR [2]

En las figuras 2.7 y 2.8 se muestran distintos espectros de frecuencia de señales acústicas y de vibración para cada modo de falla introducido en el rodamiento del CR.

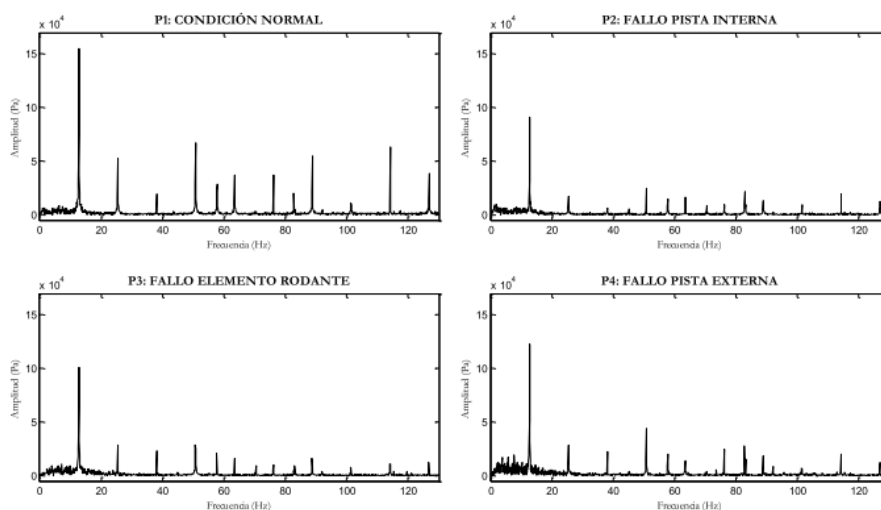


Figura 2.7: Espectros de frecuencia de las señales acústicas de fallos en rodamientos en CR [2]



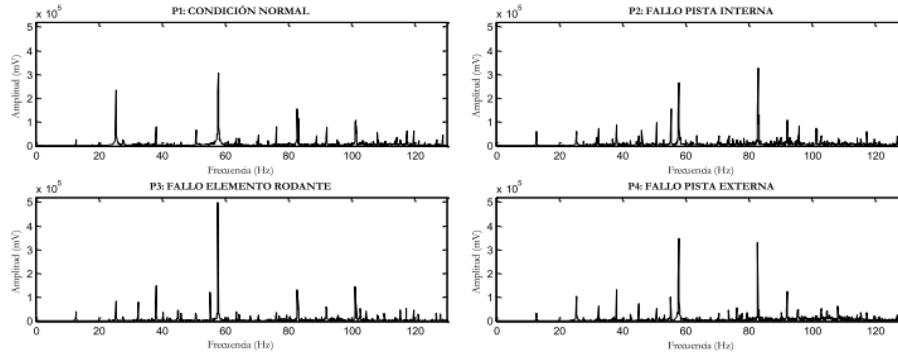


Figura 2.8: Espectros de frecuencia de las señales de vibración de fallos en rodamientos en CR [2]

En [16], se propuso una mejora a los algoritmos de optimización de ML para un diagnóstico de fallas efectivo en CR. El enfoque que se propuso entrena iterativamente un grupo de modelos de memoria a corto y a largo plazo (LSTM) a partir de una representación de series de tiempo de señales de vibración recopiladas de un CR. La búsqueda de hiperparámetros fue guiada por un punto de vista bayesiano que determina el espacio de búsqueda en cada iteración. El enfoque se lo aplicó para detectar fallas en válvulas de admisión de descarga en maquinaria de doble etapa. La precisión del reconocimiento de las fallas del mejor modelo alcanzó el 93% después de la selección estadística entre un grupo de modelos candidatos. Además, hicieron una comparación con los enfoques clásicos, los enfoques de diagnóstico de fallas de última generación basados en ML y el modelo basado en LSTM mostró una mejoría notable en el rendimiento mediante el uso del enfoque propuesto.

En [15], se propuso la implementación de un banco de pruebas compuesto por un CR de dos etapas que simuló un conjunto de 13 condiciones diferentes de fallas combinadas en válvulas y rodamientos de rodillos. Utilizaron tres acelerómetros para recopilar las señales de vibración y para extraer tres tipos diferentes de características. Estas características la analizaron además, mediante el uso de dos modelos de Random Forest para clasificar las diferentes fallas. El primer conjunto de características lo obtuvieron aplicando algoritmos de dinámica simbólica, que proporciona el histograma de un conjunto de símbolos.

Este conjunto de símbolos lo obtuvieron subdividiendo un diagrama de Poincaré en 2D, en regiones angulares y contando la intersección de las trayectorias de fase en cada una de las regiones. El segundo tipo de características corresponde a la medida de correlación compleja que se calcula como la suma de las áreas de triángulos pertenecientes a una gráfica de Poincaré. Además, también utilizaron un pequeño conjunto de características estadísticas clásicas para comparar las capacidades de clasificación con el nuevo conjunto de características propuestos. Los tres conjuntos de características le permitieron una clasificación altamente precisa del conjunto de fallas como cuando utilizaron modelos de clasificación de Random Forest.

Si bien el uso de las señales de vibración es conocida en este tipo de máquinas, el uso de la señales de corriente no esta ampliamente utilizada, siendo algunos resultados reportados en [76, 77]. En esta investigación se analizan diferentes modos de fallos en rodamientos de agujas que utiliza un CR, de donde se extrajeron datos de las señales de corriente eléctrica en el dominio del tiempo y de la frecuencia.

## 2.3. Dominio de representación de señales

Cuando se realiza la recolección de datos de una señal física como vibración, corriente eléctrica, etc, estos datos generalmente son recolectados en primera instancia como una representación en el dominio del tiempo (series temporales) que luego puede ser convertida en el dominio de la frecuencia y también puede ser representada en tiempo-frecuencia. La representación de la señal en cada uno de estos dominios pueden ofrecer información diferente que pueden mejorar la eficiencia de los sistemas de diagnostico [78].

### 1. Señales en el dominio del tiempo

La señal  $x(t)$  es una representación de la señal de corriente adquirida, que representa la naturaleza y funcionamiento del MI en el dominio del tiempo. La señal obtenida puede ser analizada como la sumatoria de las funciones sinusoidales con diferentes frecuencias,  $f$ , amplitudes,  $A$ , y fases,  $\phi$ , donde cada onda seno representa una condición en particular. La ecuación (2.6) define la señal  $x(t)$  como una variable representada en el dominio del tiempo [32, 79]:

$$x(t) = A_0 + \sum_{i=1}^N A_i \text{Sin}(\omega_i t + \phi_i) \quad (2.6)$$

que se puede expresar como una suma de N componentes de frecuencias sinusoidales  $\omega_i$ , y cambios de fase  $\phi_i$ , como se describe en la ecuación (2.7).

$$\omega_i = \frac{2\pi f_{si}}{N} \quad (2.7)$$

donde:

- $\omega_i$  - es la frecuencia angular
- $f_{si}$  - es la frecuencia de la red

La misma señal también se puede representar utilizando la ecuación (2.8):

$$x(t) = A_0 + \sum_{i=1}^N (a_i \text{Cos}(\omega_i t) + b_i \text{Sin}(\omega_i t)) \quad (2.8)$$

La figura 2.2 representa una serie temporal de una señal de corriente representada por las ecuaciones (2.6) ó (2.8).

## 2. Señales en el dominio de la frecuencia

Para pasar del dominio del tiempo a otro dominio de representación se hace uso de funciones ortogonales o funciones base que permitan transformar la señal  $x(t)$  a otro espacio como el dominio de la frecuencia [79]..

La Transformada de Fourier (FT), transforma una señal del dominio del tiempo al dominio de la frecuencia, es una de las técnicas más utilizadas en el procesamiento de señales. Descompone una señal o función periódica en senos y cosenos de diferentes frecuencias y cuya suma corresponde a la señal original. Se obtiene asumiendo las siguientes funciones base:

$$\phi(s, t) = \phi(t, s) = e^{-jst} \quad (2.9)$$

para  $t \in (-\infty, \infty)$  y  $s \in (-\infty, \infty)$

La función base es determinada por la frecuencia del parámetro  $s$ , y usualmente, se percibe por alguna de las variables de frecuencia angular  $\omega$ , o por una frecuencia lineal  $2\pi f$ . Reemplazando el valor de  $s$  en la ecuación (2.9), se obtiene la representación integral de Fourier.

$$F\{x(t)\} = X(f) \int_{-\infty}^{+\infty} X(t) e^{-2\pi f t} dt \quad (2.10)$$

En la ecuación (2.10) la señal  $x(t)$  es la suma continua de las funciones exponenciales en donde las frecuencias se encuentran en el intervalo  $(-\infty, \infty)$ . La amplitud relativa de los componentes a cualquier frecuencia  $f$  es proporcional a  $X(f)$ . La FT es útil cuando es aplicada a señales estacionarias. Sin embargo, si es aplicada a señales no estacionarias  $x(t)$ , cualquier perturbación en la señal en el dominio del tiempo se verá ampliada en el dominio de frecuencia, por lo tanto distintas muestras temporales de  $x(t)$ , de principio a fin de la señal, así como las apariciones de perturbaciones, no pueden ser examinados apropiadamente por el análisis de Fourier. Para el procesamiento de señales digitales, la Transformada de Fourier no es tan útil por el hecho de ser una función continua, para esto existe una derivada de esta transformada conocida como la Transformada Rápida de Fourier FFT, que es un acercamiento numérico a la transformada de Fourier [46, 50, 79].

La FFT es una versión computacional eficiente de la FT que reduce el número necesario de cálculo computacional (de  $O(N^2)$  a  $O(N \log N)$ ). Después de realizar FFT en la señal de la corriente de suministro del estator, las componentes de las amplitudes de frecuencia están normalizados por el valor de la amplitud del primer armónico. La normalización de los componentes de frecuencia reducen las influencias de las condiciones de carga del motor [32].

La importancia práctica de la FFT es que permite identificar un conjunto de señales de frecuencia que se encuentran delimitadas en un rango desde la frecuencia 0 hasta  $f_s/2$ , donde  $f_s$  es la frecuencia de muestreo de la señal. Lo anterior es determinado mediante el teorema de Nyquist, la cual consiste en que una señal discreta en el dominio del tiempo será bien representada si la frecuencia de muestreo es igual o superior a la

frecuencia máxima del sistema [79].

Las figuras 2.4, 2.5, 2.7 y 2.8 son espectros de frecuencia obtenidos por la FFT de señales de corriente, vibración y señales de emisión acústica.

### 3. Señales en tiempo-frecuencia

El análisis de los datos evaluados en el dominio del tiempo y la frecuencia son los más usados para análisis de fallos en maquinas rotativas pero muchas veces las maquinas están sometidas a oscilaciones torcionales, variaciones de velocidad, cambios en la carga, resonancias, etc, todos estos cambios producen transitorios en los datos de las señales que son recolectadas y generan ruidos o datos atípicos, para los cual las señales evaluadas en el dominio del tiempo y la frecuencia ya no son tan eficientes para analizar diferentes tipos de fallos, por tal motivo se ha visto la necesidad de evaluar los datos de las señales adquiridas con otro tipo de técnicas matemáticas como son en tiempo-frecuencia [79].

Una representación tiempo-frecuencia consiste en una superficie tridimensional cuyos ejes son el tiempo y la frecuencia, y en la que cada par tiempo-frecuencia se dispone de un valor de amplitud al que se le puede llamar energía del punto, pero sin que ello implique que su significado sea el clásico, ya que en muchos casos los valores de amplitud obtenidos no se corresponden con la definición teórica de energía, pero sirve para conocer la forma de la señal en el plano tiempo-frecuencia y obtener el valor de la concentración de intensidad en cada punto de la distribución global para apreciar la evolución de dicha amplitud tanto en el tiempo como en la frecuencia. Así se pueden aprovechar las características producidas por la concentración de la energía en dos dimensiones (tiempo y frecuencia) en vez de solo una (tiempo o frecuencia) [79].

En el presente trabajo la técnica que se utiliza para la representación de las señales en el tiempo-frecuencia es la transformada de wavelets TW, que son productos internos entre las señales y la familia de wavelets, que se derivan de la wavelet madre por dilatación y traslación. Sea  $\psi(t)$  de la madre wavelet, la wavelet hija será  $\psi_{a,b}(t) = \psi((t-b)/a)$ , donde  $a$  es el parámetro de escala y  $b$  es la traslación del tiempo. Variando los parámetros  $a$  y  $b$ , podemos obtener diferentes wavelets hijas que constituyen una familia de wavelets. La transformada wavelet TW se define en la ecuación (2.11) [46, 80]:

$$W(a, b) = \frac{1}{\sqrt{a}} \int x(t) \psi_{a,b}^*(t) dt \quad (2.11)$$

donde  $x(t)$  es la señal para ser procesada y '\*' es la conjugación compleja.

La descomposición por paquetes de wavelets DPW es una forma mejorada de la TW que descompone la señal a un nivel completo, acepta la propiedad de ortogonalidad y localización de frecuencia de tiempo. La señal se muestrea y se descompone para aumentar la resolución de tiempo-frecuencia, la selección de la banda de frecuencia correcta basada en las características de la señal para un espectro consistente la realiza la DPW. El refinamiento de la componente de alta frecuencia es la esencia principal de DPW, ya que también descompone la alta frecuencia y mejora la localización [44]. Sean  $\psi$  y  $\phi$  la función de onda seleccionada y su función de escala correspondiente, dada por las ecuaciones (2.12) y (2.13) respectivamente, donde  $g(k)$  y  $h(k)$  son la respuesta al impulso del filtro de paso bajo  $\phi$  y el filtro de paso alto  $\psi$ , respectivamente,  $k$  es un índice de cambios.

$$\phi_t = \sqrt{2} \sum_k g(k) \phi(2t - k) \quad (2.12)$$

$$\psi_t = \sqrt{2} \sum_k h(k) \phi(2t - k) \quad (2.13)$$

Los filtros mencionados dependen de la familia de wavelets y también se conocen como filtros de espejo de cuadratura. La descomposición de una señal mediante el uso de una función de wavelet se define como:

Sea  $V_0$  un espacio que se genera por las funciones de escala  $\phi(t)$  y sus correspondientes traslaciones  $\phi(t - k)$ . El espacio vectorial  $V_1$  es tal que  $V_1 \subset V_0$ , y su función correspondiente de escala y traslación son  $\phi(2t)$  y  $\phi(2t - k)$ , respectivamente. Es posible pasar de  $V_0$  a  $V_{-1}$  y en general de  $V_j$  a  $V_{j-1}$  a través de la operación vectorial, donde  $W_j$  es el espacio vectorial ortogonal llamado espacio de wavelet, que se genera a partir de la función wavelet  $\psi_t$  y sus traslaciones correspondientes  $\psi_{t-k}$ .

$$V_{j-1} = V_j \oplus W_j \quad (2.14)$$

Entonces, la ecuación (2.14) indica que una función que se define en  $V_{j-1}$  podría descomponerse en una función que pertenezca a  $V_j$  y otra función que pertenece a  $W_j$ , sin tener pérdidas de información.

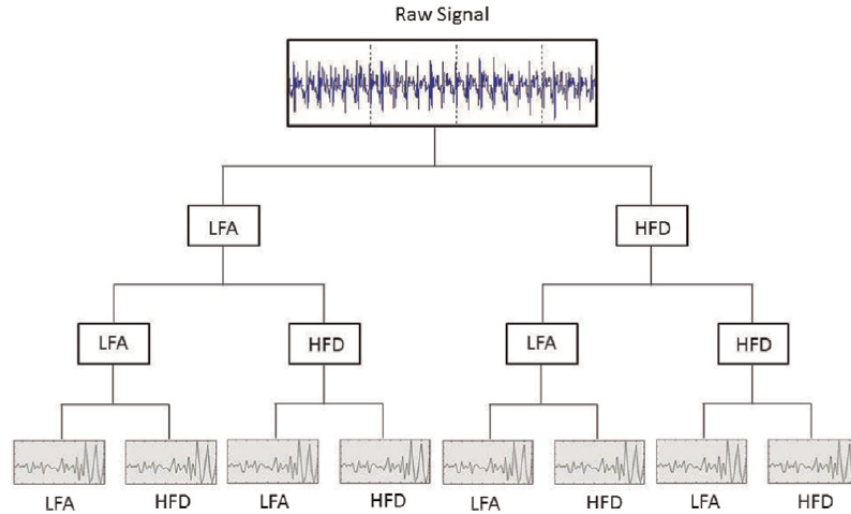


Figura 2.9: Descomposición de paquetes de wavelets [3]

Sea  $x(t)$  la señal de tiempo discreta. Entonces, esta señal  $x(t)$  se descompone en la aproximación de frecuencia baja (LFA), con el filtro  $\phi(t)$  usando la ecuación (2.15), y en el detalle de alta frecuencia (HFD) con el filtro  $\psi(t)$  usando la ecuación (2.16), donde  $\downarrow 2$  es la operación de submuestreo para el desplazamiento de  $V_j$  a  $V_{j-1}$ .

$$\text{LFA} = (x * \phi) \downarrow 2 \quad (2.15)$$

$$\text{HFA} = (x * \psi) \downarrow 2 \quad (2.16)$$

En la DPW, este proceso se repite de forma recursiva para cada señal resultante LFA y HFD, hasta que obteniendo el nivel de descomposición requerido. Como resultado, el dominio de tiempo indiscreto de la señal sin procesar se descompone en un árbol con las señales LFA y HFD. Los coeficientes de wavelets son el resultado en el último nivel del árbol, como se ilustra en la figura 2.9 [3, 66].

## 2.4. Extracción y selección de atributos de series temporales

El paso de extracción y selección de atributos o características es muy importante dentro de los problemas de clasificación basados en ML, porque ayuda a representar grandes volúmenes de datos de entrada (muestras de cada clase) en un conjunto reducido de patrones de datos, que proporcionan información relevante de las muestras [54]. Aunque los distintos espacios de representación de atributos estadísticos permiten observar y evaluar comportamientos en las señales, normalmente estas representaciones espaciales producen conjuntos de datos de alta dimensionalidad que influyen en el desarrollo computacional disminuyendo la velocidad de convergencia. Y en algunos casos, los datos de los espacios de representación no son lo suficientemente discriminatorios o se requiere grupos de atributos que se estiman a partir del espacio de representación. De esta manera se ajustan los espacios de atributos que representan de la manera más factible una señal que tiene una gran cantidad de datos [79].

### 2.4.1. Atributos estadísticos en el dominio del tiempo, frecuencia y tiempo-frecuencia

#### 1. Atributos estadísticos en el dominio del tiempo

Para el cálculo de los atributos estadísticos se asume que durante la adquisición de la señal en el dominio del tiempo  $x(t)$  se pasa de un tiempo continuo  $t$  a un tiempo discreto  $n$ , el cual es finito y  $n \in \mathbb{R}$ , entonces  $x_t = \{x(n)\}_{n=1}^N$ . En la tabla 2.1 se enlistan algunos de los 64 atributos estadísticos usadas en el dominio del tiempo, usados en este proyecto.

Tabla 2.1: Atributos estadísticos en el dominio del tiempo

ítem	Nombre Características	Fórmula
1	Mean	$T1 = \frac{1}{N} \sum_{i=1}^N X_i$
2	Variance	$T2 = \frac{1}{N} \sum_{i=1}^N (X_i - T1)^2$
3	Standard desviation (STD)	$T3 = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - T1)^2}$



4	Root mean square (RMS)	$T4 = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i)^2}$
5	Max value	$T5 = \max (X_i)$
6	Kurtosis	$T6 = \frac{N \sum_{i=1}^N (X_i - T1)^4}{[\sum_{i=1}^N (X_i - T1)^2]^2}$
7	Skewness	$T7 = \frac{N \sum_{i=1}^N (X_i - T1)^3}{T3^3}$
8	Energy operator (EO)	$T8 = \frac{N^2 \sum_{i=1}^N (\Delta_{yi} - \Delta_{\bar{y}})^4}{[\sum_{i=1}^N (\Delta_{yi} - \Delta_{\bar{y}})^2]^2}$ $\Delta_{\bar{y}} = \text{mean of } \Delta_y$ $\Delta_{\bar{y}i} = X_{i+1}^2 - X_i^2$
9	Mean of absolute values (Mean abs)	$T9 = \frac{1}{N} \sum_{i=1}^N  X_i $
10	Square root amp. value (SRAV)	$T10 = \left( \frac{\sum_{i=1}^N \sqrt{ X_i }}{N} \right)^2$

De esta manera cada ejemplo de señal de corriente tiene asociado 64 atributos de tiempo. La lista completa de todos los atributos estadísticos en el dominio del tiempo se encuentra en el anexo [A.1](#).

## 2. Atributos estadísticos en el dominio de la frecuencia

En muchas ocasiones, el análisis en el dominio del tiempo no es suficiente para revelar toda la información que porta una señal determinada, por esta razón, es necesario el uso de transformaciones. Para movernos al dominio de la frecuencia, se utiliza la **FFT**. Para realizar el cómputo de los distintos indicadores es necesario tener datos de una señal **FFT** discretizada. A partir de esto se extrae un conjunto de características estadísticas donde  $X_k$ , según la tabla [2.2](#), es el valor del espectro (magnitud) obtenido con la **FFT**,  $K$  es el número total de líneas o componentes de frecuencia que tiene el espectro, donde  $k = 1, 2, \dots, K$  y  $f_k$  es la  $k$ -ésima componente de frecuencia (valor correspondiente de frecuencia en esa componente o línea de espectro).

En la tabla 2.2 se enlistan algunos de los 25 atributos estadísticos usadas en el dominio de la frecuencia.

Tabla 2.2: Atributos estadísticos en el dominio de la Frecuencia

ítem	Nombre Características	Fórmula
1	Mean Frequency	$F1 = \frac{\sum_{k=1}^K X_k}{K}$
2	Variancef	$F2 = \frac{\sum_{k=1}^K (X_k - F1)^2}{K-1}$
3	Skewnessf	$F3 = \frac{\sum_{k=1}^K (X_k - F1)^3}{(X_k - F1)^3} K(\sqrt{F2})^3$
4	Kurtosisf	$F4 = \frac{\sum_{k=1}^K (X_k - F1)^4}{K(F2)^4}$
5	Central Frequency	$F5 = \frac{\sum_{k=1}^K f_k X(k)}{\sum_{k=1}^K X(k)}$
6	STDF	$F6 = \sqrt{\frac{\sum_{k=1}^K (f_k - F5)^2 X(k)}{\sum_{k=1}^K X(k)}}$
7	RMSF	$F7 = \sqrt{\frac{\sum_{k=1}^K f_k^2 X(k)}{\sum_{k=1}^K X(k)}}$
8	CP1	$F8 = \frac{\sum_{k=1}^K (f_k - F5)^3 X(k)}{K(F6)^3}$
9	CP2	$F9 = \frac{F6}{F5}$
10	CP3	$F10 = \frac{\sum_{k=1}^K (f_k - F5)^{\frac{1}{2}} X(k)}{K\sqrt{F6}}$

De esta manera cada ejemplo de señal de corriente tiene asociado 25 atributos de frecuencia. La lista completa de todos los atributos estadísticos en el dominio del tiempo se encuentra en el anexo A.2.

### 3. Atributos estadísticos en tiempo-frecuencia

Los atributos estadísticos en el dominio del tiempo y frecuencia solo son validas si se asume que la señal analizada es de carácter estacionario,

lo cual implica que este tipo de características son útiles bajo régimen permanente. Por lo tanto, en condiciones de donde la operación no es estable, definir una caracterización empleando los atributos estadísticos mencionados anteriormente no es factible ni recomendable, ya que este proceso será erróneo, de poca confiabilidad e interpretación al no mantener las condiciones estacionarias de una señal.

Si se establece que las señales de vibración son de carácter variable o no estacionario, ya sea por oscilaciones o cambios de carga, velocidad variable o por los transitorios causados por defectos en los rodamientos, es necesario emplear nuevas técnicas de análisis. Tomando en cuenta que el uso del espacio de representación de las señales en el dominio del tiempo-frecuencia permiten conocer el estado dinámico de la señal de vibración en función de los componentes de frecuencias a través del tiempo, es preciso utilizar este tipo de representaciones. Sin embargo, las representaciones en tiempo-frecuencia tienen una alta separación de la información adquirida de la señal, por lo que es complejo definir áreas o zonas donde se pueda discriminar la información obtenida de los tipos de fallas [79].

La descomposición de wavelet tiene como objetivo principal es adquirir la energía presente en el último nivel para ser usados como parámetros de condición para diagnosticar fallas. Siete wavelets madre son consideradas en la figura 2.10: Daubechies (db3, db5 y db7), Symlet(sym), Coiflet(coif4), Biortogonal(bior6.8) y Reverse Biorthogonal (rbior6.8).

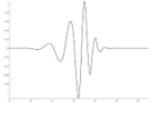
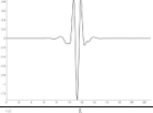
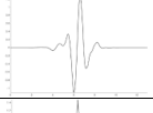
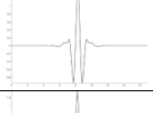
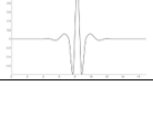
Familias Wavelet	Representación	Nivel	Característica Extraída
Daubechies3		3	Energía
Daubechies5		3	
Daubechies7		4	
Coiflet4		4	Energía
Symlet		4	Energía
Biort6.8		4	Energía
Rbiort6.8		4	Energía

Figura 2.10: Representación de las wavelets Madre

Para este trabajo se utilizan las familias de wavelets daubechies7, coiflet4, symlet5, biort6.8 y rbior6.8, y por cada uno se utilizan 16 atributos estadísticos, correspondientes al cálculo de la energía  $E$  de cada uno de los 16 coeficiente de nivel 4 de descomposición:

$$E = \sum_{n=1}^N |x(n)|^2 \quad (2.17)$$

siendo  $x(n)$  el coeficiente wavelet del nivel determinado, ver figura 2.9.

En la figura 2.11 se muestra en detalle el proceso de extracción de atributos en las diferentes representaciones espaciales tiempo, frecuencia y tiempo-frecuencia.

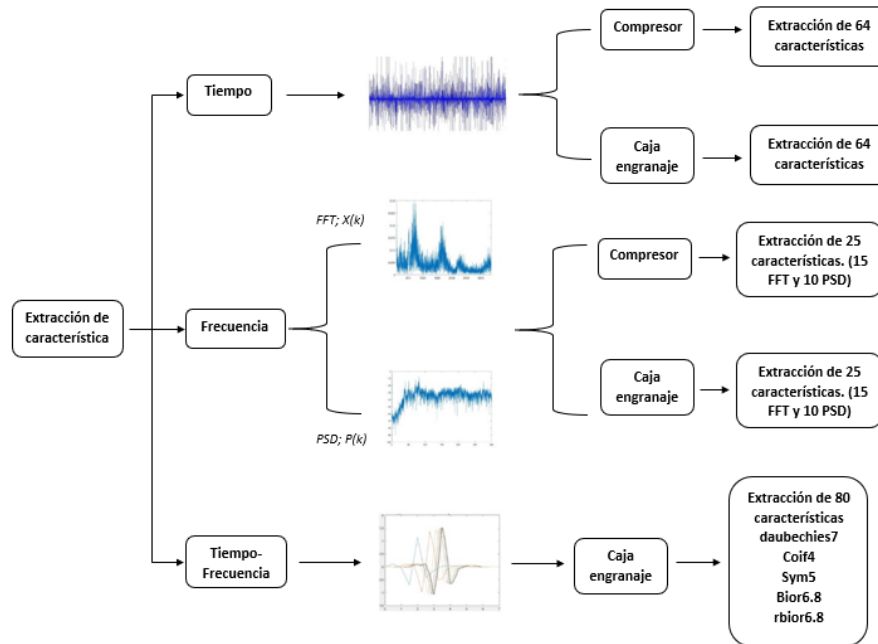


Figura 2.11: Proceso de extracción de todos los atributos estadísticos

Con base en la figura 2.11, por cada señal de corriente se tendrán diferentes vectores de  $n$  componentes correspondientes a atributos extraídos de las señales en cada dominio de representación.

Por otro lado la normalización de bases de datos consiste en transformar los datos a una escala común en la que los datos puedan relacionarse entre si para evitar manejos de datos en diferentes magnitudes [81]. En [82] se detallan algunos tipos de normalizaciones de datos usados en modelos de ML. Existen diferentes normalizaciones disponibles como Z-score, normalización L1, normalización L-infinita, la mediana, pero específicamente en este trabajo se usará la estandarización min-max.

En la normalización min-max se reemplaza la escala de cada función para que oscile entre un valor mínimo de 0.0 y un valor máximo de 1.0 o también en muchos casos de suele optar por un valor mínimo de -1 y un valor máximo de 1. Esta estandarización esta definida por la ecuación (2.18)

$$\bar{x}_j = \frac{x_j - x_{jmin}}{x_{jmax} - x_{jmin}} \quad (2.18)$$

### 2.4.2. Selección de atributos usando ANOVA e índice de validación de clusters

Dado un conjunto de datos relativos a un conjunto de vectores de atributos asociados a diferentes clases o grupos, se puede realizar un proceso de selección de aquellos atributos que mejor discriminan las diferencias entre clases. Una forma de abordar este problema puede ser la combinación de diferentes métodos. Específicamente, la propuesta de [4] combina el clásico Análisis de Varianza (ANOVA) y prueba de Tuckey, para identificar atributos informativos acerca de la diferencia de medias entre clases, y luego analiza estos atributos, de acuerdo a su capacidad para generar estructuras de clústers (agrupamientos), separados y densos. A continuación se dan la bases de la propuesta de [4].

#### Análisis ANOVA

ANOVA es una poderosa prueba estadística para rechazar la hipótesis nula  $H_0$  expresada como  $H_0: \mu_1 = \mu_2 = \dots = \mu_k$ , donde  $\mu_i$ ,  $i = 1, \dots, K$  son los medios de la  $K$  población de datos diferentes, asumiendo de la población independencia, normalidad y homocedasticidad. Sin embargo, ANOVA puede funcionar suficientemente bien incluso bajo ligeras violaciones de supuestos. La hipótesis alternativa  $H_a$  establece que  $H_a: \mu_i \neq \mu_j$  para algunos  $i, j$ . t.  $i \neq j, j \leq i$ . Cada población, es decir, valores continuos de la variable de respuesta  $Y$ , se caracteriza por uno o más factores categóricos, luego ANOVA compara las medias de la respuesta variable en los diferentes niveles de factores. ANOVA puede considerar un solo factor con dos o más niveles (o grupos). Para aceptar  $H_0$  de una forma ANOVA, la prueba  $F$  se utiliza calculando las estadísticas  $F$  dadas por la ecuación (2.19):

$$F = \frac{\frac{\sum_{i=1}^K n_i (\bar{Y}_i - \bar{Y})^2}{K-1}}{\frac{\sum_{i=1}^K \sum_{j=i}^{n_i} (\bar{Y}_{ij} - \bar{Y}_i)^2}{N-K}} \quad (2.19)$$

donde  $\bar{Y}_i$  denota la media muestral en el  $i$ -ésimo grupo,  $n_i$  es el número de muestras en el  $i$ -ésimo grupo,  $\bar{Y}$  denota la media general de las muestras,  $\bar{Y}_{ij}$  es la  $j$ -ésima muestra en el  $i$ -ésimo grupo, y  $K$  denota el número de grupos.

En la práctica, el valor de referencia para rechazar  $H_0$  se basa en el valor  $p$ , que es la probabilidad de un valor observado de  $F$ . Comúnmente,  $H_0$  se rechaza si  $p \leq 0.05$ . Una vez la prueba ANOVA rechaza la hipótesis nula, se requiere una comparación múltiple mediante el uso de la prueba de Tukey para identificar cualquier diferencia entre dos medias  $\mu_i - \mu_j$ , calculando la razón en la ecuación (2.20):

$$q_s = \frac{\mu_i - \mu_j}{SE_{\bar{x}}}, \quad \mu_i - \mu_j > 0 \quad (2.20)$$

donde  $SE_{\bar{x}}$  es el error estándar esperado de la media. El valor de  $q_s$  se compara con el valor crítico de  $q$  de la distribución T-student. Si  $q_s$  es mayor que el valor crítico obtenido de la distribución, las dos medias son significativamente diferentes.

Específicamente, en la propuesta de [4] el resultado de aplicar la prueba ANOVA es identificar los atributos del conjunto de datos que son estadísticamente significativos para distinguir dos medias  $\mu_i, \mu_j$ , relativas a las clases de fallas. El clásico ANOVA ha sido entonces adaptado para este fin, de acuerdo al macro-algoritmo de la figura 2.12.

---

**Algorithm 1** ANOVA and Tukey's test algorithms

---

**Data:**  
Dataset  $S$ ,  $S = \{(x^k, y^k)\}$ ,  $k = 1, \dots, m$   
Set  $F = \{f_j\}$ ,  $j = 1, \dots, n$   
Set  $P = \{P_i\}$ ,  $i = 1, \dots, c$   
Value of the threshold significance  $Th_s$   
Value of the threshold Pairwise Significance  $Th_{PW_s}$   
Number of randomly examples  $q$ ,  $q < m$   
Number of repetitions  $rep$

**Result:**  
Subset of significant features  $F_p$

```

for  $p \leftarrow 1$  to  $rep$  do
  Create  $F_{P'_i}^p = \emptyset$ 
  Chose randomly the set  $S' = \{(x^k, y^k)\}$ ,  $S' \subset S$ ,
   $k = 1, \dots, q$ 
  for  $j \leftarrow 1$  to  $n$  do
    Compute  $p_j$ -value of the  $j$ th feature through
    the one-way-ANOVA applied on  $S'$ 
    if  $p_j\text{-value} \leq Th_s$  then
      Create the set  $P' = \{P'_i = \{P_r, P_s\} \mid$ 
       $P_r, P_s \in P, P_r \neq P_s\}$ 
      for  $i \leftarrow 1$  to  $|P'|$  do
        Compute  $\hat{p}_j$ -value through the
        Tukey's test to the pairwise compar-
        ison of  $P'_i$   $F_{P'_i}^p = F_{P'_i}^p \cup \{f_j \mid$ 
         $\hat{p}_j\text{-value} \leq Th_{PW_s}\}$ 
  Obtain the set  $F_p$  such that  $f_j \in F_{P'_i}^p \quad \forall i, p$ 

```

---

Figura 2.12: Pseudo código de ANOVA y prueba de Tukey para selección de atributos [4]

En este macroalgoritmo,  $F = f_j$  representa el conjunto de atributos,  $P = P_i$  es el conjunto de fallas, y  $S = (x_k, y_k)$  es el conjunto de datos, donde  $x_k \in \mathbb{R}^n$  es el vector de atributos  $f_j$  and  $y_k$  es una variable categórica,  $y_k \in P$ . El análisis se ejecuta un número establecido de repeticiones para que los resultados obtenidos sean estadísticamente representativos. Cada repetición se aplica sobre



un subconjunto aleatorio de  $S$ , y los atributos seleccionados son aquellos que fueron siempre elegidos en cada repetición, es decir, aquellos  $f_j$  tales que  $F_{p_i}^p \forall i, p$ . Estos atributos se almacenan en el conjunto  $F_p$ .

Usualmente, antes de aplicar la prueba ANOVA para selección de atributos, se hace una primera selección de atributos eliminando aquellos que están altamente correlacionados de acuerdo al índice de correlación de Pearson. La correlación de Pearson es un índice que calcula el grado de covarianza entre diferentes variables de forma lineal, esto quiere decir que pueden existir varias variables altamente relacionadas entre sí, pero no de forma lineal [83].

### Índice de validación de grupos

Otro enfoque para seleccionar atributos es elegir aquellos que permiten generar estructuras de grupos (cluster) apropiadamente separados y densos. Esta característica es especialmente importante cuando se desean usar estos atributos para propósitos de clasificación basado en ML. En [4], se usa este enfoque como una segunda etapa, luego de tener un subconjunto de atributos seleccionados según la prueba ANOVA. El enfoque consiste en calcular un índice de validez de clusters llamado Componente de Densidad entre y con agrupaciones (CDBw) el cual sirve para medir estructuras apropiadas de grupos.

Ésta métrica pone énfasis en las características geométricas de los grupos (clústers o conglomerados). Dada una partición de clúster, en lugar de usar solo información de distancia intra-clúster e inter-clúster, la información de densidad también está considerada por el índice CDBw, como se indica en la ecuación (2.21):

$$CDBw_{(c)} = Intra\_D(c)Sep(c) \quad (2.21)$$

donde  $c$  es el número de clúster en la partición,  $Sep(c)$  mide la separación entre conglomerados y  $intra\_D(c)$  mide la densidad intragrupo. Por un lado,  $Sep(c)$  en 2.21 se considera tanto la distancias entre grupos y la densidad entre grupos, como se propone en la ecuación (2.22):

$$Sep(c) = \sum_{i=1}^c \sum_{j=1, j \neq i}^c \frac{\|C\_R(i) - C\_R(j)\|}{1 + Inter\_D(c)}, \quad c > 1 \quad (2.22)$$

donde  $C\_R(i)$  y  $C\_R(j)$  son el par más cercano de representaciones de dos clústeres vecinos  $i$  y  $j$ , y  $inter\_D(c)$  mide la densidad entre clústers definido como

la densidad en las áreas entre conglomerados.  $Inter\_D(c)$  se define en la ecuación (2.23):

$$Inter\_D(c) = \sum_{i=1}^c \sum_{j=1, j \neq i}^c \frac{\|C\_R(i) - C\_R(j)\|}{\|sd(i) - sd(j)\|} d(u_{ij}), \quad c > 1 \quad (2.23)$$

donde  $u_{ij}$  es el punto medio entre el par  $(C\_R(i), C\_R(j))$ ,  $sd(\cdot)$  es el vector de desviación estándar de un grupo, y  $u_{ij} = \sum_{k=1}^{n_i+n_j} f(x_k, u_{ij})$  es una densidad,  $n_i$  y  $n_j$  son el número de muestras que pertenecen a los conglomerados  $i$  y  $j$ , respectivamente, y  $x_k$  es un dato o punto de los racimos. La función  $f(x_k, u_{ij})$  está definida por la ecuación (2.24) :

$$f(x_k, u_{ij}) = \begin{cases} 1, & \text{if } \|x_k, u_{ij}\| \leq \frac{\|sd(i) - sd(j)\|}{c} \\ 0, & \text{otherwise} \end{cases} \quad (2.24)$$

Por otro lado,  $Intra\_D(c)$  en la ecuación (2.21) se define como el número de puntos pertenecientes a la zona de puntos representativos de los clusters, según lo propuesto en la ecuación (2.25) :

$$Intra\_D(c) = \frac{1}{c} \sum_{i=1}^c \sum_{j=1}^{r_i} Den(v_{ij}), \quad c > 1 \quad (2.25)$$

donde  $r_i$  es el número de puntos representantes del primer clúster, y  $Den(v_{ij}) = \sum_{l=1}^{n_i} f(x_l, v_{ij})$  es una densidad,  $x_l$  es una muestra que pertenece al  $i$ -ésimo clúster,  $v_{ij}$  es el  $j$ -ésimo punto representativo del  $i$ -ésimo grupo;  $f(x_l, v_{ij})$  es dada por la ecuación (2.26):

$$f(x_k, u_{ij}) = \begin{cases} 1, & \text{if } \|x_l, v_{ij}\| \leq sd_a \\ 0, & \text{otherwise} \end{cases} \quad (2.26)$$

donde  $sd_a$  es el promedio de la desviación estándar de todos los vectores de desviación estándar  $sd$  asociados con cada grupo. La densidad y separación intra-clúster será significativamente alto para grupos bien separados [4].

La propuesta en [4] consiste en seleccionar aquellos atributos que generan grupos de clases con altos valores del índice  $CDbw$  sobre una partición de clases determinadas en un conjunto  $\hat{P} \subset P$ .

Entonces, del conjunto de atributos en  $F_p$ , se conforma un subconjunto de  $n$ -tuplas  $\tilde{F} = \tilde{f}_z$ , para la tupla de clases (fallas) en  $\hat{P}_i = \{P_r, P_s\}$ , con  $P_r, P_s \in \hat{P}$ , se

calcula el índice  $CDbw_i^z$  de acuerdo con la ecuación (2.21), y luego se calcula el índice para todo el conjunto  $F_z$  según la ecuación (2.27)

$$CDbwF_z = \frac{\prod_i CDbw_i^z}{\sum_i CDbw_i^z} \quad (2.27)$$

Seguidamente, la n-tuple de atributos mas significativos  $f_{best}$  que crea la mejor estructura de cluster para el conjunto de clases (fallas)  $\hat{P}$  es según la ecuación 2.28:

$$f_{best} = \tilde{f}_z \text{ t.q. } CDbwF_z \text{ es máximo} \quad (2.28)$$

En la figura 2.13 se muestra el macroalgoritmo de para la selección de atributos de acuerdo al índice de validación de clusters  $CDbw$ .

---

**Algorithm 2** Cluster validity assessment algorithm
 

---

**Data:**Dataset  $S$ ,  $S = \{(x^k, y^k)\}, k = 1, \dots, m$ Set  $\hat{P} \in P$ Set  $F_P$  $n$  features to be analysed,  $n \leq |F_P|$ **Result:**Subset of  $n$  significant features  $f_{best}$  for the set  $\hat{P}$  under studyCreate the  $\tilde{F} = \{\tilde{f}_z = (n - \text{tuple}) \text{ over } F_P\}$ Create the set  $\hat{P}' = \{\hat{P}'_i = \{P_r, P_s\} \mid P_r, P_s \in \hat{P}, P_r \neq P_s\}$ **for**  $z \leftarrow 1$  **to**  $|\tilde{F}|$  **do**    **for**  $i \leftarrow 1$  **to**  $|\hat{P}'_i|$  **do**        Create the set  $\tilde{S} = \{(x^k, y^k)\}, x^k$  is a vector of features  $\tilde{f}_z, y^k \in \hat{P}'_i$         Compute  $CDbw_i^z$  over the dataset  $\tilde{S} \subset S$     Compute  $CDbwF_z$ Select  $f_{best}$ 

Figura 2.13: Pseudo código para selección de atributos según Índice de validación de clústers [4]

## 2.5. Clasificación por agrupamiento de datos

La agrupación es una técnica de análisis exploratorio de datos con el objetivo de segmentar un número finito de datos, sin etiquetar, conjunto de datos multivariante en un conjunto de grupos homogéneos, categorías o racimos. Alternativamente, el agrupamiento de datos puede verse como el proceso de identificar grupos en los datos para que los datos en un grupo son similares entre sí, y son lo más diferente posible de los datos de otros grupos [62]. El problema de agrupamiento puede formalmente, definirse como un problema de optimización, donde las variables de optimización representan las membresías de los puntos de datos a un clúster determinado, y la función objetivo maximiza una cuantificación matemática concreta de similaridad intra grupo, en términos de tales variables.

Si los atributos para representar los grupos de datos en el espacio n-dimensional son apropiados, estos grupos pueden usarse como punto de partida para abordar el problema de clasificación basada en grupos. En la figura 2.14 se muestra gráficamente una representación de agrupamiento de datos en un espacio 2-dimensional apropiado, en la que cada color de grupo representa una clase claramente separada de las otras.




Figura 2.14: Representación gráfica de agrupamiento de datos

La clasificación es una técnica que se usa en ML para minería de datos, se utiliza para asignar cualquier elemento en grandes conjuntos de datos a una clase apropiada o categorías. El principal objetivo de la clasificación es conectar un dato desconocido a la categoría relacionada [84]. KNN y KNN Fuzzy, son algunas de las técnicas de clasificación, incluyendo al algoritmo LAMDA el cual se está estudiando en esta investigación.

Genéricamente, la clasificación basada en grupos se basa en una métrica de distancia entre dos muestras, una cuya clase es desconocida, y otra representativa de una clase conocida. El valor de la distancia entre dos muestras se puede medir mediante diferentes métricas, por ejemplo, euclidiana, coseno, Pearson, Mahalanobis, entre otras. Las muestras con altas similitudes se agrupan o clasifican utilizando una estrategia de aprendizaje supervisado o no supervisado [56].

### 2.5.1. Algoritmo LAMDA

LAMDA es un método de clasificación basado en LD. A diferencia de algoritmos convencionales, no es un método basado en la distancia, que realiza un análisis de similitud entre descriptores (características o atributos) de los individuos, con el fin de establecer una relación entre cada uno de sus respectivas clases. Este algoritmo está basado en el concepto del grado de adecuación de un individuo  $X$  a una clase  $C = \{C_1, C_2, \dots, C_k, \dots, C_m\}$ . Uno de los aportes de LAMDA es que propone una clase NIC, que identifica a la clase no informativa (Non Informative Class)

El objeto, o individuo,  $X$  debe estar representado por un vector que se compone de un conjunto de características que aportan información sobre el individuo:

$$X = [x_1, x_2, \dots, x_j, \dots, x_n] \quad (2.29)$$

donde  $x_j$  es el descriptor (atributo o característica)  $j$  del objeto  $X$ , los cuales deben escalarse según la normalización min-max, descrita en la ecuación (2.18). De esta manera,  $\bar{x}_j$  es el valor normalizado del atributo.

El algoritmo LAMDA hace uso de los siguientes conceptos [71, 72, 75]:

#### Grado de adecuación marginal (MAD)

Los MAD establecen qué tan similar es un descriptor con respecto al mismo descriptor en una clase dada. Para un individuo definido, el vector MAD se determina para caracterizar su situación con respecto a cada clase. Para el cálculo de MAD, las funciones de densidad de probabilidad utilizadas más comunes son función binomial difusa y función gaussiana.

La **Función Binomial Difusa** es una extensión difusa de la función binomial que permite calcular el grado de membresía, como una probabilidad bayesiana:

$$\text{MAD}_{k,j}(\bar{x}_j|\rho_{k,j}) = \rho_{k,j}^{\bar{x}_j} (1 - \rho_{k,j})^{(1-\bar{x}_j)} \quad (2.30)$$

donde  $\rho_{k,j}$  es el valor medio del descriptor  $j$  que pertenece a la clase  $k$ , y es calculado para el caso de aprendizaje supervisado utilizando la ecuación (2.31):

$$\rho_{k,j} = \frac{1}{n_{k,j}} \sum_{t=1}^{t=n_{k,j}} \bar{x}_j(t) \quad (2.31)$$

siendo  $n_{k,j}$  es el número de datos del descriptor  $j$  perteneciente a la clase  $k$ .

La **Función Gaussiana** asume una distribución normal del descriptor, se calcula usando la ecuación (2.32):

$$\text{MAD}_{k,j}(\bar{x}_j|\rho_{k,j}) = e^{-\frac{1}{2} \left( \frac{\bar{x}_j - \rho_{k,j}}{\sigma_{k,j}} \right)^2} \quad (2.32)$$

donde  $\sigma_{k,j}$  es la desviación estándar del descriptor  $j$  que pertenece a la clase  $k$ :

$$\sigma_{k,j}^2 = \frac{1}{n_{k,j} - 1} \sum_{t=1}^{t=n_{k,j}} (\bar{x}_j(t) - \rho_{k,j})^2 \quad (2.33)$$

La posibilidad de calcular MAD a través de las ecuaciones (2.30) y (2.32), dependerán de cómo los datos se distribuyen en cada clase. Se considera  $\rho_{\text{NIC}} = 0,5$ , porque con este valor en la función probabilística de la ecuación (2.30), el  $\text{MAD}_{\text{NIC}} = 0,5$  para cualquier valor del descriptor  $\bar{x}_j$ . En caso de la ecuación (2.32), se asigna  $\rho_{\text{NIC}} = 0,25$

### Grado de Adecuación Global (GAD)

Los GAD establecen la adecuación del individuo a cada clase, que se calcula combinando los MAD a través de funciones de agregación difusas usando cualquiera de las tuplas que se muestran en la Tabla 2.3, con el nivel de exigencia  $\alpha \in [0,1]$ , que permite una clasificación estricta o permisible. Si  $\alpha$  aumenta, la clasificación es más estricta, por lo que no se reconocerán más individuos (enviados a la NIC), lo que hace que el algoritmo sea más selectivo. El GAD de un individuo  $\bar{X}$  en la clase  $k$  se calcula mediante:

$$\begin{aligned} & \text{GAD}_{k,\bar{X}}(\text{MAD}_{k,1}, \dots, \text{MAD}_{k,N}) \\ &= \alpha T(\text{MAD}_{k,1}, \dots, \text{MAD}_{k,N}) + (1 - \alpha) S(\text{MAD}_{k,1}, \dots, \text{MAD}_{k,N}) \end{aligned} \quad (2.34)$$

donde  $\bar{X}$  es el individuo normalizado; T es t-norma (intersección) y S es t-conorma (unión).

Tabla 2.3: T-norms and T-conorms

Type	T-norms	T-conorms
Min-Max	$T(a,b)=\min(a,b)$	$S(a,b)=\max(a,b)$
Product sum	$T(a,b)=ab$	$S(a,b)=a + b - ab$
Hammacher	$T(a, b) = \frac{ab}{p+(1-p)(a+b-ab)}$	$S(a, b) = \frac{a+b-ab-(1-p)ab}{1-(1-p)ab}$

El individuo  $\bar{X}$  se asigna a la clase con el máximo GAD como en la ecuación (2.35), donde el índice corresponde al identificador de la clase.

$$index = \max(\text{GAD}_{1,\bar{X}}, \text{GAD}_{k,\bar{X}}, \dots, \text{GAD}_{m,\bar{X}}, \text{GAD}_{\text{NIC},\bar{X}}) \quad (2.35)$$

En la figura 2.15 se muestra el esquema operativo del algoritmo LAMDA.

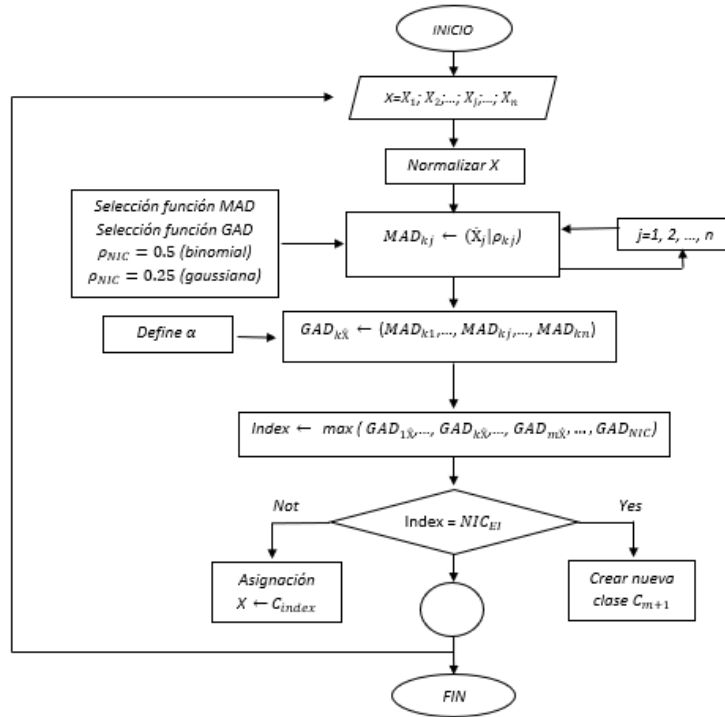


Figura 2.15: Diagrama de flujo del algoritmo LAMDA

Los cálculos de MAD se realizan para cada descriptor en cada clase, utilizando la funciones de probabilidad de densidad. Con las MAD, el cálculo de la GAD de cada clase se realiza utilizando funciones de agregación y el nivel de exigencia. Finalmente, la clase correspondiente es según el máximo valor de GAD calculado para el individuo  $\bar{X}_j$ . Si el GAD más alto es el  $GAD_{NIC}$  el individuo no pertenece a ninguna clase y es enviado al NIC para crear una nueva clase. En el pseudo código Algoritmo 1 se presenta el procedimiento para clasificación, según el algoritmo LAMDA.



---

**Algoritmo 1** Macro Algoritmo LAMDA

---

**Input:** Individuo X

Procedimiento:

- Paso: 1 Normalizar los atributos de los individuos usando la ecuacion (2.18)
- Paso: 2 Calcular el MAD de cada atributo y cada clase basado en la selección de la función de densidad probabilística descrita en la ecuacion (2.30) o (2.32)
- Paso: 3 Calcular el MAD de la NIC, considerando el  $\rho_{NIC} = 0.5$ , para la función binomial  $\rho_{NIC} = 0.5$  y para la función gaussiana  $\rho_{NIC} = 0.25$
- Paso: 4 Calcular el GAD de cada clase usando la t-norma y la t-conorma, con cualquiera de las ecuaciones que se muestran en la tabla 2.3 y en la ecuacion (2.34)
- Paso: 5 Para identificar la clase a la que pertenece  $\tilde{X}$ , elija el GAD máximo de la ecuacion (2.35)
- Paso: 6 Fin

**Output:** Índice de Clase

---

**2.5.2. Algoritmo LAMDA HAD**

De acuerdo con [70, 85], el clásico LAMDA exhibe dos problemas: el envío a la clase NIC de un individuo cuyo GAD en la clase correcta es ligeramente menor a la clase NIC, y por otro lado, el error en la clasificación (asignación a otra clase) debido al solapamiento entre los GAD de las clases). Entonces, se propone una modificación en [70, 85] para atacar estos dos problemas, utilizando dos estrategias:

1. Primero, calcular tantas NIC como el número de clases existentes. En este caso, cada NIC y su GAD se calcula en función de la características intrínseca de cada clase, lo que impide enviar individuos bien clasificados a la NIC, como ocurre en el algoritmo LAMDA original, donde solo una NIC es calculado para todas las clases existentes.
2. La segunda estrategia se basa en el cálculo del Grado de Adecuación Superior (HAD), que consiste en medir el grado de similitud del GAD de un

individuo en relación al promedio de los GADs de las clases existentes a través de operadores probabilísticos, permitiendo conocer con mayor certeza la clase al que pertenece un individuo. Permite mejorar la robustez del algoritmo y evitando que individuos con características similares entre las clases estén mal clasificados.

Entonces, el objetivo principal de **LAMDA HAD** es reducir los inconvenientes correspondientes a los individuos enviados incorrectamente a la NIC. A continuación se describe la implementación de las extensiones de **LAMDA HAD**. [70, 85].

### **Extensión 1:** GAD<sub>NIC</sub> Adaptable

Para el cálculo de GAD<sub>NIC</sub> Adaptable, se tienen las siguientes definiciones, que consisten en operaciones matemáticas simples que no consumen demasiado tiempo de máquina.

#### **Definición 1.**

MGAD<sub>k,p</sub> es el valor medio de los GAD de la clase  $p$  en una clase  $k$ . Considerando que  $n_k$  es el número de individuos pertenecientes a la clase  $k$  y  $p = \{1, \dots, m\}$ . Podemos calcular este parámetro por la ecuación (2.36):

$$\text{MGAD}_{k,p} = \frac{1}{n_k} \sum_{t=1}^{t=n_k} \text{GAD}_{p,t} \quad (2.36)$$

donde GAD<sub>p,t</sub> es el GAD del individuo  $t$  para la clase  $p$ , en la clase  $k$ .

#### **Definición 2.**

Sea GAD<sub>NIC<sub>k</sub></sub> el GAD de la NIC para la clase  $k$ , se calcula como el valor promedio de todos los MGAD<sub>k,p</sub> en cada clase, por ejemplo, si hay tres clases, se calcularán GAD<sub>NIC<sub>1</sub></sub>, GAD<sub>NIC<sub>2</sub></sub> y GAD<sub>NIC<sub>3</sub></sub>. El cálculo de GAD<sub>NIC<sub>k</sub></sub> se realiza mediante la ecuación (2.37):

$$\text{GAD}_{\text{NIC}_k} = \frac{1}{m} \sum_{p=1}^{p=m} \text{MGAD}_{k,p} \quad (2.37)$$

Como se muestra en la ecuación (2.37),  $GAD_{NIC_k}$  depende de las contribuciones de todos los MGAD, por lo tanto, también depende de la distribución de todos los GAD en cada clase.

**Extensión 2:** Cálculo del grado de adecuación superior (HAD)

Para disminuir la probabilidad de obtener una clasificación errónea individual debido a la similitud de sus descriptores con características de diferentes clases, se propuso el cálculo del Grado de Adecuación Superior. Este parámetro permite establecer la similitud entre el  $GAD_{p,\bar{X}}$  del individuo normalizado  $\bar{X}$  y los GADs de cada clase  $k$ . A diferencia de LAMDA original, no se elige directamente el GAD máximo. Primero, se hace una estimación de la clase índice al cual los GADs del individuo son más similares. Para ello, se propuso realizar cálculos adicionales al algoritmo basados en las siguientes definiciones.

**Definición 3.**

$AD_{GAD_{k,p,\bar{X}}}$  es un parámetro que permite obtener una medida de similitud entre el GAD de un individuo  $\bar{X}$  y cada  $MGAD_{k,p}$ . Este se calcula mediante el uso de la función de densidad de probabilidad como se muestra en la ecuación (2.38).

$$AD_{GAD_{k,p,\bar{X}}} = MGAD_{k,p}^{GAD_{p,\bar{X}}} (1 - MGAD_{k,p})^{1-GAD_{p,\bar{X}}} \quad (2.38)$$

para un  $\bar{X}$  evaluado en cada clase. Esta expresión, al ser una extensión difusa de la función binomial, presenta los mejores resultados cuando el objetivo es medir la similitud entre el individuo y las clases.

**Definición 4.**

Sea  $AD_{GAD_{k,p,\bar{X}}}$  el nuevo grado de adecuación del GAD, el cálculo del Grado de Adecuación Superior (HAD) de un individuo  $\bar{X}$  a una clase se obtiene sumando todos los  $AD_{GAD_{k,p,\bar{X}}}$  en la clase  $k$  a través de la ecuación (2.39).

$$HAD_{k,\bar{X}} = \sum_{p=1}^{p=m} AD_{GAD_{k,p,\bar{X}}} \quad (2.39)$$

Con base en este cálculo, se determina el valor más alto de  $HAD_{k,\bar{X}}$  obteniendo el índice estimado  $E_I$  de la clase para la que el individuo tenga la mayor probabilidad de pertenecer, esto es, según la ecuación (2.40):

$$E_I = \max(HAD_{1,\bar{X}}, \dots, HAD_{k,\bar{X}}, \dots, HAD_{m,\bar{X}}) \quad (2.40)$$

**Definición 5.**

Sea  $E_I$  el índice de la clase con el mayor grado de adecuación, entonces es necesario verificar si el valor máximo de  $GAD_{E_I,\bar{X}}$ , es mayor que el  $GAD_{NIC_{E_I}}$ . Si esto se cumple, entonces el individuo  $\bar{X}$  pertenece a la clase  $E_I$ , de lo contrario, se enviará al  $NIC_{E_I}$ . Esto se define en la ecuación (2.41):

$$index = \max(GAD_{E_I,\bar{X}}, GAD_{NIC_{E_I}}) \quad (2.41)$$

En la figura 2.16 se muestra el esquema operativo del algoritmo LAMDA HAD.

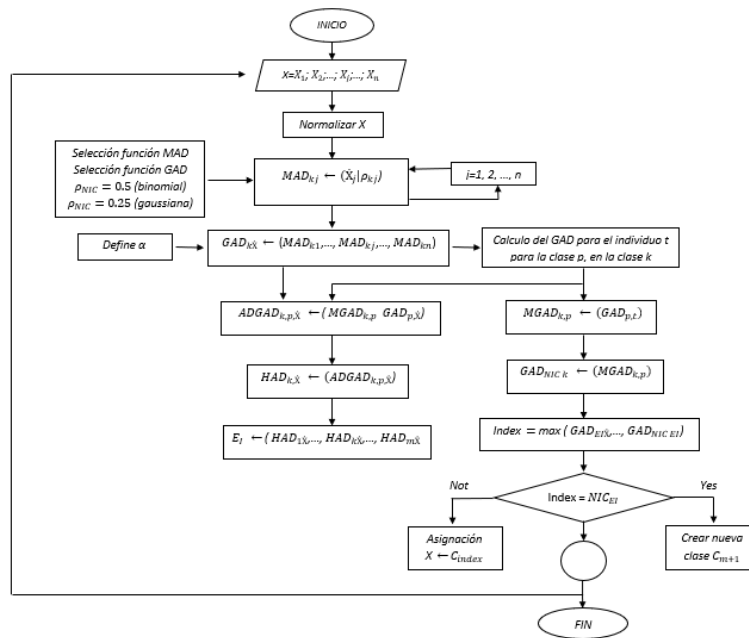


Figura 2.16: Diagrama de flujo del algoritmo LAMDA HAD

En el pseudo código Algoritmo 2 se presenta el procedimiento del algoritmo LAMDA HAD.

---

**Algoritmo 2** Macro Algoritmo LAMDA HAD

---

**Input:** Individuo X

Procedimiento:

- Paso: 1 Normalizar los atributos de los individuos usando la ecuacion (2.18);
- Paso: 2 Calcular el MAD de cada atributo y cada clase basado en la selección de la función de densidad probabilística descrita en la ecuacion (2.30) o (2.32)
- Paso: 3 Calcular el GAD de cada clase usando la t-norma y la t-conorma, con cualquiera de las ecuaciones que se muestran en la tabla 2.3 y en la ecuacion (2.34)
- Paso: 4 Calcule el MGAD en cada clase a través de la ecuacion (2.36) en la definición 1
- Paso: 5 Utilice de la ecuacion (2.37) en la definición 2 para el calculo del ( $GAD_{NIC}$ ) para cada clase  $k$
- Paso: 6 Calcule el grado de adecuación ( $AD_{GAD}$ ) con la ecuacion (2.38) en la definición 3, y el HAD como la suma de ellos con la ecuacion (2.39) en la definición 4
- Paso: 7 Encuentre el índice de estimación  $E1$  de la clase a la que el individuo podría pertenecer en la ecuacion (2.41)
- Paso: 8 En la clase estimada, determine si el GAD máximo es mayor que el ( $GAD_{NIC}$ ) correspondiente con la definición 5
- Paso: 9 Fin

**Output:** Índice de Clase

---

## Capítulo 3

# Detección y diagnóstico de fallas en compresores recíprocos y cajas de engranajes usando el algoritmo LAMDA HAD

En el presente capítulo se presenta el desarrollo del marco metodológico que aborda el problema de detección y diagnóstico de fallas en **MR** usando el algoritmo **LAMDA HAD**:

1. Como primer paso se analizan las bases de datos de los indicadores estadísticos de condición en el dominio del tiempo, frecuencia y tiempo - frecuencia. Estas bases de datos fueron proporcionadas por el grupo de investigación **GIDTEC** de la UPS sede Cuenca, y están compuestas por mediciones de la corriente eléctrica de un **MI** el cual está acoplado a un **CR** y a una **CE**, en dos bancos de pruebas diferentes, en las que se implementaron distintos modos de fallas y diferentes grados de severidades.
2. Como segundo paso se detalla la aplicación del algoritmo para la selección y extracción de mejores atributos estadísticos el cual usa **ANOVA** y la métrica *CDBw* (ver capítulo 2).
3. Como tercer paso se analiza la visualización del espacio N-dimensional de atributos a través de la transformada t-SNE.

- Como cuarto paso una vez ya identificados los mejores atributos estadísticos se utiliza el algoritmo **LAMDA HAD** para realizar pruebas de clasificación de los grados de severidades en los diferentes modos de fallos de los rodamientos en los compresores y los engranes en las cajas reductoras.

En la figura 3.1 se muestra un esquema representativo de como se irá desglosando el presente capítulo.

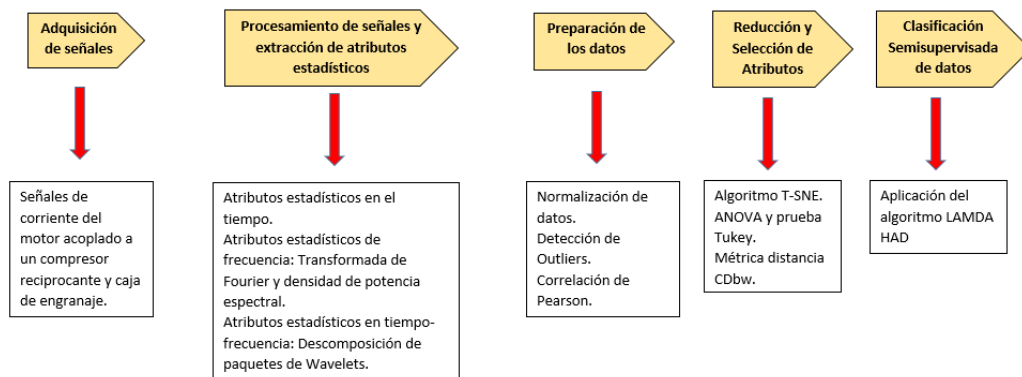


Figura 3.1: Esquema de desarrollo del marco metodológico

## 3.1. Adquisición de señales de corriente

### 3.1.1. Compresor recíprocante

Para obtener la base de datos se cuenta con un compresor recíprocante de dos etapas, un motor de inducción de 5.5 HP accionado por un variador de frecuencia, acoplado por dos poleas, con sus correas trapezoidales y un tanque de aire de 250 lt. Los instrumentos de medición de las señales de corriente son 3 pinzas amperimétricas, una por cada línea. Los tipos de rodamientos utilizados en el experimento son rodamientos de rodillos cónicos debido a la capacidad de soportar altas cargas combinadas. Para la adquisición de datos se utiliza una NI 9234 a 50 KS/s como frecuencia de muestreo. En la figura 3.2 se muestra una representación de lo mencionado.




Figura 3.2: Esquema del banco de pruebas del compresor

Las condiciones de operación en las que se tomaron los datos se enumeran de la siguiente manera:

1. Duración de cada muestra: 10 segundos
2. Repetición de las pruebas: 15 veces por cada prueba (R1, R2, R3,... R15) por cada sensor de corriente
3. Frecuencia de rotación del motor: 57,7 Hz (3462 rpm)
4. Presión del tanque: 3 bar

Los modos de fallas inducidos en los rodamientos de rodillos cónicos se mencionan a continuación:

1. Normal - Condiciones saludables (N)
2. Grieta de pista interior (1); usando técnica de electro-erosión, posición alineada con el eje de rotación, longitud en toda la pista de rodadura, ancho 2.00 mm y profundidad: 1.00 mm



3. Grieta del elementos rodantes de rodillo (2); usando técnica de electro-erosión, posición alineada con el eje de rotación, longitud en toda la pista de rodadura, ancho 2.00 mm y profundidad: 0.50 mm
4. Grieta de la pista exterior (3); usando técnica de electro-erosión, posición alineada con el eje de rotación, longitud en toda la pista de rodadura, ancho 2.00 mm y profundidad: 1.00 mm




Figura 3.3: Modos de fallos en rodamiento de CR

Por lo tanto se obtendrá una base de datos para análisis de fallas en el CR compuesta de 4 modos de fallos, normal, daño en pista interior, daño en pista exterior y daño en elementos rodantes como se muestra en la figura 3.3, realizando 15 repeticiones para cada modo de fallo, obteniendo un total de 60 muestras por cada sensor de corriente. El plan experimental detallado esta disponible en el grupo de investigación [GIDTEC](#).

### 3.1.2. Caja de Engranaje

En la CE se adquirieron 4 bases de datos, una por cada modo de fallo simulado en un piñon del juego de engrane, los cuales son diente roto, rayadura, pica-

dura y rotura en la base del diente. Los planes experimentales detallados están disponible en el grupo de investigación [GIDTEC](#).

Para obtener la base de datos se tiene un motor de 2 HP accionado por un variador de frecuencia, una caja de engranajes, una polea con su correa trapezoidal y un freno magnético. Los instrumentos de medición de las señales de corriente son 3 pinzas amperimétricas, una por cada línea. Para la adquisición de datos se utiliza una NI 9234 a 50 KS/s como frecuencia de muestreo. En la figura 3.4 se muestra una representación de lo mencionado.




Figura 3.4: Esquema del banco de pruebas de la caja de engranaje

Las condiciones de operación en las que se tomaron los datos se enumeran de la siguiente manera:

1. Duración de cada muestra: 10 segundos

### CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 74

2. Repeticiones de las pruebas: 10 veces por cada prueba (R1, R2, R3,... R10)
3. Frecuencia de giro del motor (velocidad constante): 8 Hz (F1), 14 Hz (F2), 19,8 Hz (F3)
4. Carga: 0 V (L1), 10 V (L2), 20 V (L3)

Los modos de fallas inducidos en la caja de engranajes se mencionan en la tabla 3.1 para diente roto, en 3.2 para grieta, en 3.3 para picadura y en 3.4 para rayadura de piñón:

Tabla 3.1: Descripción de fallas de diente roto en piñón

Tipo falla	Porcentaje falla	Descripción falla
Normal	0%	Condición normal
Diente roto	1.30%	Volumen de falla: 4,62 mm <sup>3</sup> en un diente
Diente roto	4.00%	Volumen de falla: 14,25 mm <sup>3</sup> en un diente
Diente roto	7.50%	Volumen de falla: 27 mm <sup>3</sup> en un diente
Diente roto	11.30%	Volumen de falla: 40,5 mm <sup>3</sup> en un diente
Diente roto	20.40%	Volumen de falla: 73,2 mm <sup>3</sup> en un diente
Diente roto	30.60%	Volumen de falla: 109,6 mm <sup>3</sup> en un diente
Diente roto	40.80%	Volumen de falla: 146 mm <sup>3</sup> en un diente
Diente roto	70.20%	Volumen de falla: 251,6 mm <sup>3</sup> en un diente
Diente roto	100.00%	Volumen de falla: 357,2 mm <sup>3</sup> en un diente

En la figura 3.5 se muestra diferentes niveles de severidades de diente roto en piñón como lo mencionado en la tabla 3.1.




Figura 3.5: Modo de fallo: Diente roto en piñon con diferentes grados de severidades

Tabla 3.2: Descripción de fallas de grieta en piñon

Tipo falla	Porcentaje falla	Descripción falla
Normal	0%	Condición normal
Grieta	5%	Raíz del diente profundidad:0.10 mm longitud:1.00 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	12.5%	Raíz del diente profundidad:0.20 mm

CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 76

		longitud:2.50 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	25 %	Raíz del diente profundidad:0.50 mm longitud:5.00 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	37.5 %	Raíz del diente profundidad:0.70 mm longitud:7.60 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	45 %	Raíz del diente profundidad:0.90 mm longitud:9.00 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	60 %	Raíz del diente profundidad:1.00 mm longitud:12.00 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	75 %	Raíz del diente profundidad:1.50 mm longitud:15.00 mm

CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 77

		ancho:0.40 mm $\alpha = 45^\circ$
Grieta	85 %	Raíz del diente profundidad:1.70 mm longitud:17.00 mm ancho:0.40 mm $\alpha = 45^\circ$
Grieta	100 %	Raíz del diente profundidad:1.90 mm longitud:20.30 mm ancho:0.40 mm $\alpha = 45^\circ$

En la figura 3.6 se muestra diferentes niveles de severidades de grieta en piñon como lo mencionado en la tabla 3.2.




Figura 3.6: Modo de fallo: Grieta en piñon con diferentes grados de severidades

Tabla 3.3: Descripción de fallas de picadura en piñon

Tipo falla	Porcentaje falla	Descripción falla
Normal	0%	Condición normal
Picadura	1.96%	Raíz del diente diámetro: 1.5 mm profundidad: 0.5 mm 1 agujero en 1 diente total de picaduras de dientes: 1
Picadura	5.89%	Raíz del diente diámetro: 1.5 mm profundidad: 0.5 mm 3 agujero en 1 diente

CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 79

		total de picaduras de dientes: 1
Picadura	7.85 %	<p>Raíz del diente  diámetro: 1.5 mm  profundidad: 0.5 mm  4 agujeros en 1 diente y  1 agujero en 2 y 3 dientes  total de picaduras de dientes: 3</p>
Picadura	11.78 %	<p>Raíz del diente  diámetro: 1.5 mm  profundidad: 0.5 mm  6 agujeros en 1 diente y  3 agujeros en 2 y 3 dientes  total de picaduras de dientes: 3</p>
Picadura	15.70 %	<p>Raíz del diente  diámetro: 1.5 mm  profundidad: 0.5 mm  8 agujeros en 1 diente  y 4 agujeros en 2 y 3 dientes  total de picaduras de dientes: 3</p>
Picadura	34.91 %	<p>Raíz del diente  diámetro: 2 mm  profundidad: 0.5 mm  10 agujeros en 1 diente, 3 agujeros en 2 y 3  dientes y 1 agujero en 4 y 5 dientes  total de picaduras de dientes: 5</p>



CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 80

Picadura	41.89 %	<p>Raíz del diente  diámetro: 2 mm  profundidad: 0.5 mm  12 agujeros en 1 diente, 10 agujeros en 2 y 3 dientes, 3 agujeros en 4 y 5 dientes y 1 agujero en 6 y 7 dientes  total de picaduras de dientes: 7</p>
Picadura	69.81 %	<p>Raíz del diente  diámetro: 2 mm  profundidad: 0.5 mm  20 agujeros en 1 diente, 10 agujeros en 2 y 3 dientes, 3 agujeros en 4 y 5 dientes y 1 agujero en 6 y 7 dientes  total de picaduras de dientes: 7</p>
Picadura	100 %	<p>Agujeros irregulares a lo largo del diente  total de picaduras de dientes: 6</p>

En la figura 3.7 se muestra diferentes niveles de severidades de picadura en piñón como lo mencionado en la tabla 3.3.




Figura 3.7: Modo de fallo: Picadura en piñon con diferentes grados de severidades

Tabla 3.4: Descripción de fallas de rayadura en piñon

Tipo falla	Porcentaje falla	Descripción falla
Normal	0%	Condición normal
Rayadura	1.67%	Longitud: 1.50 mm Ancho: 0.50 mm Profundidad: 0.10 mm Líneas: 2
Rayadura	3.33%	Longitud: 1.50 mm Ancho: 1.00 mm Profundidad: 0.10 mm

CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 82

		Líneas: 2
Rayadura	5.00%	Longitud: 1.50 mm Ancho: 1.50 mm Profundidad: 0.10 mm Líneas: 2
Rayadura	6.67%	Longitud: 1.50 mm Ancho: 2.00 mm Profundidad: 0.10 mm Líneas: 2
Rayadura	8.89%	Longitud: 2.00 mm Ancho: 2.00 mm Profundidad: 0.10 mm Líneas: 2
Rayadura	16.67%	Longitud: 2.50 mm Ancho: 3.00 mm Profundidad: 0.10 mm Líneas: 2
Rayadura	23.33%	Longitud: 3.00 mm Ancho: 3.50 mm Profundidad: 0.10 mm Líneas: 2
Rayadura	40.00%	Longitud: 4.50 mm Ancho: 4.00 mm

		Profundidad: 0.10 mm Líneas: 2
Rayadura	60.00 %	Longitud: 4.50 mm Ancho: 4.00 mm Profundidad: 0.10 mm Líneas: 3

En la figura 3.8 se muestra diferentes niveles de severidades de rayadura en piñón como lo mencionado en la tabla 3.4.




Figura 3.8: Modo de fallo: Rayadura en piñón con diferentes grados de severidades

## 3.2. Procesamiento de señales y extracción de atributos estadísticos

En el procesamiento de las señales adquiridas en el CR por medio de la corriente del motor, se aplican la FFT y la densidad de potencia espectral *Densidad de potencia espectral* (PSD) para transformar las señales del dominio del tiempo a la frecuencia, en donde se tienen 25 atributos estadísticos en el dominio de la frecuencia, 15 atributos utilizando la FFT y 10 atributos utilizando PSD, como lo indicado en la sección 2.4.1. La cantidad de atributos estadísticos utilizados en el dominio del tiempo son 64. Cada uno de los atributos en el tiempo y en la frecuencia se los aplica a cada señal adquirida por los tres sensores de corriente, en total se obtiene una base de datos conformada de 267 atributos estadísticos en tiempo y en frecuencia, se realizaron 15 repeticiones para los 4 modos de fallo en los rodamientos teniendo una base de datos de 60 muestras con 267 atributos para cada muestra.

Para el procesamiento de las señales obtenidas en la CE por medio de la corriente del motor, se obtienen dos bases de datos, una base de datos con atributos estadísticos en tiempo y frecuencia, y otra base de datos con atributos estadísticos en tiempo-frecuencia (Wavelets), como indicado en la sección 2.4.1. En la base de datos de CE en tiempo y frecuencia, la cantidad de atributos estadísticos utilizados en el dominio del tiempo son 64. Para el procesamiento de señales de corriente se aplica la FFT y la PSD para transformar las señales del dominio del tiempo a la frecuencia, en donde se tienen 25 atributos estadísticos en el dominio de la frecuencia, 15 utilizando la FFT y 10 utilizando PSD. Esta base fue obtenida de los tres sensores de corriente de tal manera que se obtiene un total de 267 atributos estadísticos y como se menciona en la sección 3.2 se realizaron 10 repeticiones por cada grado de severidad, para los 4 modos de fallas, siendo estos diente roto, grieta, picadura y rayadura en piñón, para todo lo mencionado se obtienen cuatro bases de datos de 900 muestras por 267 atributos.

En la base de datos de CE en donde se extraen atributos estadísticos en el dominio del tiempo-frecuencia usando la DPW se usaron 5 familias de wavelets llamadas Daubechies 7, Symlet 5, Coiflet 4, Biort 6.8, y RBiort 6.8, cada una con una descomposición hasta el nivel 4. En esta base de datos se obtienen 16 atributos relacionados con la energía de cada coeficiente de la descomposición, como indicado en la sección 2.4.1, por cada familia de wavelets para cada uno de los sensores de corriente, obteniendo 48 atributos estadísticos por las cinco

familias de wavelets y un total de 240 atributos de energía. Se obtiene, entonces, una base de datos de 900 muestras por 240 atributos.

Luego de obtener las bases de datos de **CR** y **CE** con sus respectivos atributos estadísticos, y para facilitar la fase de selección de atributos, se diseñan varias interfaces en Matlab para la selección de las bases de datos experimentales que serán utilizados en el algoritmo de selección de mejores atributos estadísticos. En el caso de la base de datos de **CR** se tiene una interfaz de selección de bases experimentales según los atributos estadísticos que se desean utilizar como se muestra en la figura 3.9. La necesidad de realizar pruebas con los atributos estadísticos en tiempo y frecuencia por separado y luego combinados, es para evaluar el aporte de cada uno de los dominios y de forma combinada: solo los atributos de tiempo, solo los obtenidos por **FFT**, solo los obtenidos por **PSD**, combinados solo los de frecuencia, combinados atributos de tiempo y de frecuencia.

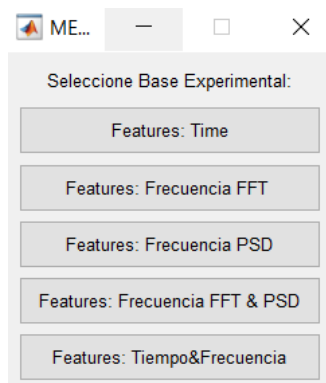
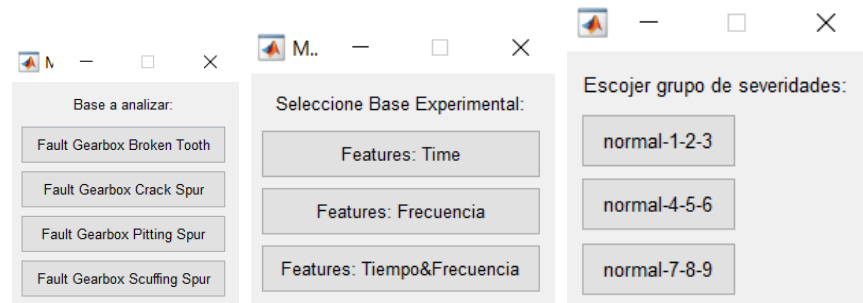


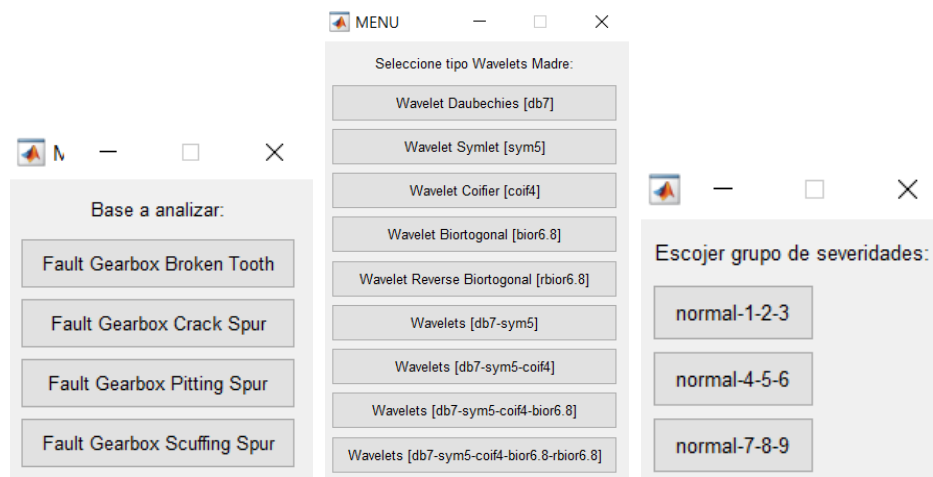
Figura 3.9: Menú de selección de base experimental según los atributos estadísticos en CR

En el caso de las bases de datos de **CE** en tiempo y frecuencia y tiempo-frecuencia (Wavelets), se diseñaron varias interfaces como se muestra en las figuras 3.10 y 3.11 para la selección de bases de datos experimentales, en la interfaz a), se selecciona el modo de falla que se desea utilizar, en la interfaz b), se seleccionan los atributos estadísticos, y en la interfaz c), se seleccionan los diferentes grados de severidades con los que se desea trabajar.



(a) Selección de modos de fallos (b) Selección de atributos estadísticos (c) Selección de combinación de grados de severidades

Figura 3.10: Interfaces de CE en tiempo y frecuencia: a) Modos de fallos, b) Atributos estadísticos y c) Combinación de grados de severidades



(a) Selección de modos de fallos (b) Selección de atributos estadísticos con Wavelets (c) Selección de combinación de grados de severidades

Figura 3.11: Interfaces de CE usando Wavelets: a) Modos de fallos, b) Atributos estadísticos con Wavelets y c) Combinación de grados de severidades

De manera similar como se menciona para **CR**, se evalúan los atributos estadísticos de **CE** en dominios de tiempo y frecuencia y tiempo-frecuencia (Wavelets) por separado y luego combinados, adicional a esto, también se separan en tres

grupo los grados de severidades manteniendo la condición normal en cada uno de ellos. Esta separación por grado de severidades, incluyendo en cada caso la clase normal, es con el fin de evaluar el desempeño de clasificadores dedicados por conjunto de clases. Todo lo mencionado se realiza para evaluar el aporte en la selección de los mejores atributos estadísticos en el ajuste de clasificadores usando el algoritmo [LAMDA HAD](#).

### 3.3. Preparación de los datos

Después de la selección del tipo de bases de datos experimentales que se desean utilizar se aplican técnicas de limpieza y preparación de datos que sirven para evaluar si los atributos no se encuentran correlacionados entre sí, o si presentan datos atípicos (outliers). Para evitar trabajar con datos de distintas escalas se aplicaron procedimientos de normalización ó estandarización, que se pueden seleccionar a través de la interfaz de figura 3.12. Luego de varios experimentos de visualización, para este caso de investigación en la prueba de selección de los mejores atributos estadísticos se utilizó la estandarización en el intervalo  $[-1,1]$ , según lo indicado en la Ecuación 2.18, en las bases de datos bajo estudio.

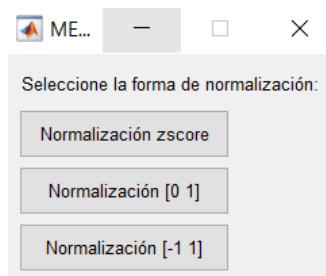


Figura 3.12: Menú de selección del tipo de normalización

Luego de realizar la estandarización en las tres bases de datos, se procede a aplicar la partición de las bases de datos, para este caso de investigación se designa 80 % para datos de entrenamiento y 20 % para datos prueba a las cuales se las denomina `data_train` y `data_test`. Esta partición de la bases de datos se realizaran en las tres bases de datos con las que se están trabajando, para [CR](#), [CE](#) en tiempo y frecuencia y [CE](#) con wavelets. De aquí en adelante solo se trabajará



con los datos de entrenamiento (`data_train`) en lo que es la fase de reducción y selección de los mejores atributos estadísticos que se desarrolla en la sección 3.4.

Una vez realizada la partición de las bases de datos para entrenamiento y prueba se procede a aplicar un análisis de correlación de Pearson en los datos de entrenamiento, con el fin de determinar si existen atributos redundantes y que puedan ser eliminados, previo al paso de selección de atributos detallado en la sección 2.4.2 . Este análisis reportó que:

1. Para las bases de datos de CR y CE con los atributos de tiempo y de frecuencia no se detectaron atributos redundantes, considerando un umbral de correlación de 0.95, y por ello todos los atributos pasarán a la fase de selección de atributos.
2. Para la base de datos de entrenamiento de CE con Wavelets, considerando un umbral de correlación de 0.95, se encontró que la mayor parte de los atributos estaban altamente correlacionados, quedando conjuntos de 3 hasta 5 atributos disponibles para análisis.

Los resultados de estos análisis serán presentados con mayor detalle en el capítulo 4.

### **3.4. Reducción y selección de mejores atributos estadísticos**

Luego de realizar la limpieza y el arreglo de los datos se procede a utilizar el algoritmo para reducir y extraer los mejores atributos estadísticos en donde se utiliza ANOVA junto con la métrica CDbw según la propuesta de [4] la cual se describe en la sección 2.4.2.

En primer lugar se aplica ANOVA y la prueba de Tukey en donde se determina si hay diferencia estadísticamente significativa entre los atributos estadísticos. Para ello se diseñan varias interfaces, la primer interfaz es para seleccionar el valor de significancia, para esta investigación se utiliza un valor de 0.05, luego se utiliza una interfaz para seleccionar la forma de ordenamiento de los atributos que obtuvieron un valor menor que el valor de significancia, para este caso se utiliza el ordenamiento por el numero de p\_valores menores que el valor de significancia, como se muestra en la figura 3.13.

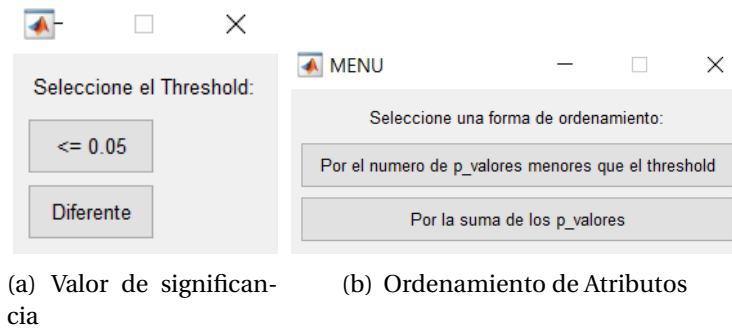


Figura 3.13: Interfaces para la prueba ANOVA

Después de haber seleccionado el valor de significancia y la forma de ordenamiento se muestra, como ejemplo, una tabla de resultados de la base de datos de CR usando todos los atributos de tiempo y frecuencia que conforman un total de 267 atributos estadísticos, en donde se enlistan de forma descendente 30 de los 267 atributos como se muestra en la figura 3.14, siendo los últimos los que presenten mayor diferencia entre las medias de los grupos de atributos estadísticos. Los resultados para todas las bases de datos se detallarán en el capítulo 4.

Q	Num_feature	Name_feature	suma_pvals	pvals_menor_Ths
30	181	'time.MFL_3_1'	0.57973	4.8667
29	184	'time.DASDV_3_1'	0.56134	4.8667
28	82	'time.DVARV_3_1'	0.54395	4.8667
27	115	'time.Sure_entropy_3_1'	0.95171	4.9
26	118	'time.Thres_entropy_3_1'	0.95143	4.9
25	46	'time.CPT3_3_1'	0.79775	4.9333
24	123	'time.SSC_EMG_5_1'	0.92831	5
23	59	'time.SDIF_4_1'	0.86321	5
22	116	'time.Sure_entropy_4_1'	0.86265	5
21	119	'time.Thres_entropy_4_1'	0.86253	5
20	162	'time.MYOP_5_1'	0.78453	5
19	44	'time.CPT2_4_1'	0.70163	5
18	31	'time.sf_3_1'	0.6276	5
17	40	'time.clearance_3_1'	0.57475	5
16	105	'time.NNML_5_1'	0.29858	5
15	161	'time.MYOP_4_1'	0.27854	5.0333
14	122	'time.SSC_EMG_4_1'	0.19019	5.0333
13	124	'time.WL_3_1'	0.24087	5.1
12	172	'time.AAC_3_1'	0.23704	5.1
11	1	'time.mean_3_1'	0.098036	5.2667
10	104	'time.NNML_4_1'	0.097531	5.3667
9	76	'time.MDR_3_1'	0.11652	5.4667
8	189	'time.TM_5_1'	0.048973	5.6667
7	33	'time.sf_5_1'	0.030831	5.8667
6	3	'time.mean_5_1'	0.006124	6
5	78	'time.MDR_5_1'	0.0035407	6
4	70	'time.PI_3_1'	0.00016422	6
3	190	'time.WI_3_1'	4.7079e-05	6
2	187	'time.TM_3_1'	3.5225e-05	6
1	103	'time.NNML_3_1'	7.24e-06	6

Figura 3.14: Tabla de atributos estadísticos de los resultados de ANOVA

En esta investigación solo se seleccionarán los 10 atributos mas significativos, que son los que se analizarán con la métrica *CDbw*, la cual determinará la mejor combinación de atributos se debe seleccionar la cantidad de atributos que se desean obtener como resultado final de los atributos estadísticos que pasarán a la fase de entrenamiento de los clasificadores basados en el algoritmo [LAMDA HAD](#).

En esta investigación se realizaron varias pruebas en donde se seleccionaron combinaciones de 3 hasta 10 atributos estadísticos para aplicar la métrica *CDbw*; por ejemplo, 3 de 10 significa que se selecciona los 10 atributos mas significativos de la tabla de [ANOVA](#) y 3 significa que quedarán 3 mejores atributos aplicando la métrica *CDbw*. El algoritmo de selección de los mejores atributos estadísticos se lo aplico en las tres bases de datos estudiados.

Como un ejemplo, en la figura 3.15 se muestran 5 clusters que representan a 5 clases con sus respectivos datos obtenido en 3 dimensiones, con los datos de test de CR, a partir de los atributos obtenidos aplicando la métrica de distancia  $CDbw$  con todos los atributos estadísticos en tiempo y frecuencia, usando una combinación de 3 de 10. Los resultados para todas las bases de datos se detallarán en el capítulo 4.

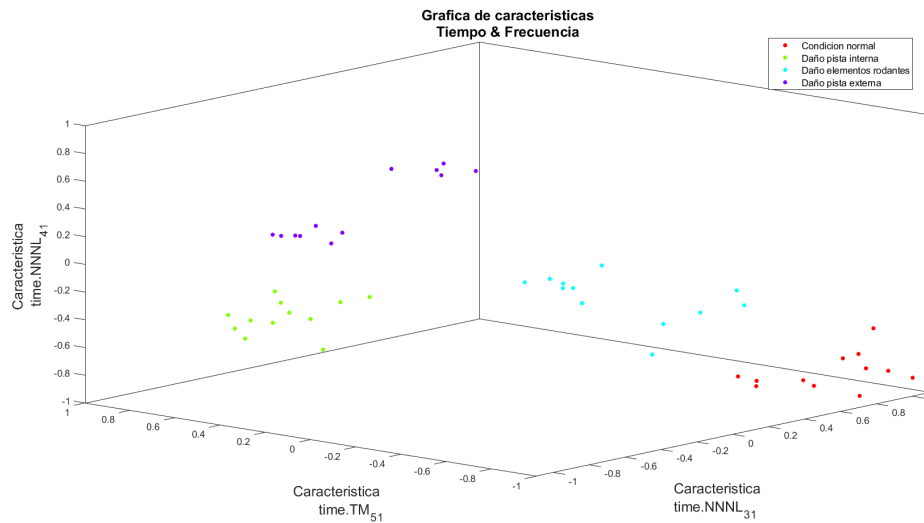


Figura 3.15: Gráfica de resultados usando ANOVA y la métrica  $CDbw$  en la base de datos de CR

### 3.5. Algoritmo de clasificación LAMDA HAD

Para el ajuste de los clasificadores con el algoritmo LAMDA HAD, se consideraron los siguientes escenarios:

1. Para la base de datos CR, se decidió ajustar el clasificador con 3 los mejores atributos estadísticos del dominio tiempo y frecuencia que se obtuvieron luego de aplicar la métrica  $CDbw$ , por cuanto la estructura de clusters visualizados en este caso, ver figura 3.15, sugiere que se pueden encontrar resultados apropiados con esta selección.

2. Para la base de datos de CE con atributos de tiempo-frecuencia, no se consideró ajustar un clasificador por cuanto los mejores atributos estadísticos seleccionados usando la métrica  $CDbw$  no mostraron una apropiada agrupación como se muestra en la figura 3.16, que representa los resultados obtenidos de los 3 mejores atributos estadísticos aplicando la correlación de Pearson y utilizando el grupo de severidades N-1-2-3 del modo de fallo diente roto. Esta gráfica fue realizada con el algoritmo TS-NE en 2D para una mejor visualización de lo expuesto. Los resultados de las pruebas con la base de datos de CE con los atributos de tiempo-frecuencia, se detallaran en el capítulo 4.
  
3. Para la base de datos de CE se decidió analizar atributos de tiempo y de frecuencia, donde se consideraron desde los 3 hasta 10 mejores atributos por cada modo de falla, teniendo un total de 8 bases de datos por cada modo de falla. También se consideró ajustar un clasificador para los mejores atributos por grupo de severidades como N-1-2-3, N-4-5-6, N-7-8-9, siendo N la condición normal y de 1 hasta 9 son los grados de severidades como se mencionó en la sección 3.1.2, organizados en 24 bases de datos. Por cada grupo de severidades se obtuvieron clasificadores que usan desde 3 hasta 10 mejores atributos por cada modo de falla.




Figura 3.16: Gráfica de resultados de los 3 mejores atributos usando previamente correlación de Pearson para la base de datos de diente roto con el grupo de severidad N-1-2-3 en CE con Wavelets

Una vez obtenida las bases de datos de los mejores atributos estadísticos para **CR** y **CE** en tiempo y frecuencia, se procede a utilizar el algoritmo **LAMDA HAD**. El primer paso es seleccionar el equipo al que se le va a ajustar el clasificador, ya sea **CR** o **CE**, y para esto se crea una interfaz como se muestra en la figura 3.17. Para el caso de haber seleccionado la base de **CR**, se carga la base de datos que contiene los 3 mejores atributos estadísticos anteriormente seleccionados, ver figura 3.15. Para el caso de haber seleccionado la base de prueba de **CE**, se tiene una interfaz en donde se deben seleccionar los modos de fallas que se desean utilizar, como se muestra en la figura 3.18.




Figura 3.17: Menú de selección de la base de prueba a utilizar para el algoritmo LAMDA HAD

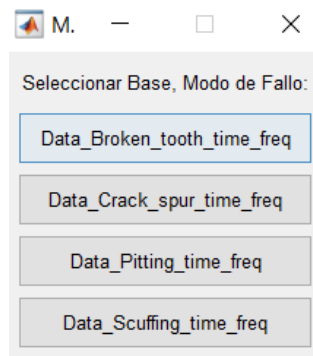
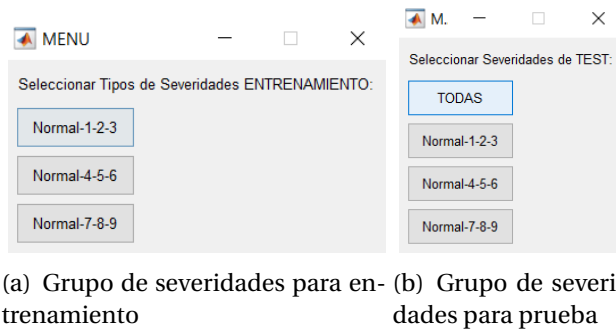


Figura 3.18: Menú de selección de modo de falla de CE

Una vez seleccionado el modo de falla para CE se deben seleccionar con cuantos atributos estadísticos se desea trabajar para este caso de 3 hasta los 10 mejores atributos estadísticos. Una vez seleccionado la cantidad de atributos estadísticos con las que se desea trabajar, se abren dos interfaces en las que se deben seleccionar los grupos de severidades con los que se desea trabajar para el entrenamiento y para la prueba del algoritmo LAMDA HAD, como se muestra en la figura 3.19.



(a) Grupo de severidades para entrenamiento (b) Grupo de severidades para prueba

Figura 3.19: Interfaces de selección del grupo de severidades para entrenamiento y prueba de los datos de CE para aplicar el algoritmo LAMDA HAD

Después de haber hecho la selección apropiada, se procede a realizar la partición de los datos en un 70% para entrenamiento y un 30% para la prueba del entrenamiento. Una vez realizada la partición de los datos, se procede a estandarizar los datos sobre el intervalo  $[0,1]$ , lo cual es requerido para la aplicación del algoritmo LAMDA HAD.

Seguidamente se procede a la fase de entrenamiento, la cual básicamente consiste en, ver sección 2.5.2:

1. El ajuste de la función que determina el grado de adecuación marginal (MAD) para cada clase de severidad de falla, y sus correspondientes clases NIC.
2. El ajuste del valor del parámetro  $\alpha$  en el cálculo del grado de adecuación global (GAD).

En este proyecto de investigación para el calculo del MAD se aplica la función binomial difusa y para la selección del valor de  $\alpha$  en el cálculo del GAD se realizó una interacción automática para evaluar como influye su comportamiento en

los resultados de la clasificación de los datos de entrenamiento con valores de  $\alpha$  desde 0 hasta 1, con pasos de 0.1. En el cálculo del GAD se utiliza el operador min y max para las funciones T-norma y T-conorma, ver la tabla 2.3.

Una vez establecidas las condiciones de entrenamiento, se aplica el algoritmo 2 de la sección 2.5.2.

En la figura 3.20 se muestra un ejemplo gráfico de los datos de entrenamiento para la base de datos de CR, de los cuales se usa un 70% para entrenamiento, usando un alfa de 0.3 y el 30% se lo deja para probar el rendimiento del clasificador. En el eje de las ordenadas se encuentran las cantidades de clases que van desde 1 a 4, mas las clases NIC que serian desde 5 a 8 y en el eje de las abscisas se encuentran los datos pertenecientes a cada clase. Los puntos de color azul significan la cantidad de clases, para este caso son la condición normal y los 3 modos de fallos en los rodamientos, los puntos rojos significan la cantidad de datos para cada clase en este caso serán 10 datos para cada clase.



Figura 3.20: Gráfica de datos de entrenamiento para CR

En la figura 3.21 se muestra la gráfica perteneciente al 30% de los datos de prueba para evaluar al clasificador del ejemplo de la figura 3.20, de la misma manera los puntos de color azul significan la cantidad de clases, para este caso son la condición normal y los 3 modos de fallos en los rodamientos, los puntos rojos significan la cantidad de datos para cada clase en este caso serán 5 datos para cada clase.






Figura 3.21: Gráfica de datos de prueba del entrenamiento para CR

Para analizar el rendimiento de cada clasificador, en la correcta clasificación de los datos pertenecientes a cada clase, se usa la matriz de confusión y se calcula la precisión. Por ejemplo, la figura 3.22 es la matriz de confusión para el caso de CR con los resultados de la figura 3.21, donde se observa que la precisión promedio es del 90 %.




Figura 3.22: Matriz de confusión para evaluación del rendimiento de la clasificación en los datos de CR

Para el caso de CE en tiempo y frecuencia, para la comprobación del rendimiento del uso del algoritmo LAMDA HAD, se realizan dos evaluaciones:

1. El desempeño del clasificador para cada conjunto de fallas y grados de severidades, solo considerando los datos de las clases para el cual fue entrenado.
2. El desempeño del clasificador para cada conjunto de fallas y grados de severidades, considerando además los datos de las fallas no utilizadas en el entrenamiento, para evaluar la capacidad del clasificador de asignar estos individuos a las clases NIC del correspondiente clasificador.

Como ejemplo de lo mencionado, se selecciona la base de datos del grupo de severidades N-4-5-6 del modo de falla de grieta en piñón usando 10 atributos estadísticos y un alfa de 0.6, del cual se hace la partición de la base de datos en 70% para entrenamiento y 30% para la prueba de desempeño del entrenamiento. Los puntos de color azul señalan las clases, para este caso en el eje de las ordenadas, 1 pertenece a la condición normal, 5 al grado de severidad #4, 6 al grado de severidad #5 y 7 al grado de severidad #6, los puntos rojos significan la cantidad de datos para cada clase, en este caso para el entrenamiento serán 60 datos para cada clase que se encuentran en el eje de las abscisas. En la figura 3.23 se muestran los resultados con los datos de entrenamiento, donde se evidencia que apenas pocas muestras no se clasificaron apropiadamente.




Figura 3.23: Resultados de clasificación de severidades para los datos de entrenamiento de las clases N-4-5-6 del modo de falla de grieta en piñón para CE usando 10 atributos en tiempo y frecuencia y un alfa de 0.6 en el algoritmo LAMDA HAD

En la figura 3.24 se muestra la clasificación del 30% de los datos de prueba para evaluar al clasificador del ejemplo de la figura 3.23. De la misma manera los puntos de color azul señalan las clases, para este caso en el eje de las ordenadas, 1 pertenece a la condición normal, 5 al grado de severidad #4, 6 al grado de severidad #5 y 7 al grado de severidad #6, 11, 12, 13 y 14 pertenecen a los NIC de cada clase, los puntos rojos significan la cantidad de datos para cada clase, en este caso serán 30 datos para cada clase que se encuentran en el eje de las abscisas. Los resultados muestran que pocas muestras no se clasificaron apropiadamente.




Figura 3.24: Resultados de clasificación de severidades para los datos de prueba de las clases N-4-5-6 del modo de falla de grieta en piñon para CE usando 10 atributos en tiempo y frecuencia y un alfa de 0.6 en el algoritmo LAMDA HAD

En la gráfica de la figura 3.25 se muestra como resultado una matriz de confusión en donde se mide la precisión del clasificador, en donde se usó el 30% de los datos que quedaron para la prueba del entrenamiento, los cuales corresponden a los puntos rojos de la gráfica de la figura 3.24, donde se observa que la precisión promedio es del 95.8%.

### CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 99




Figura 3.25: Matriz de confusión para evaluación del rendimiento de la clasificación en los datos de CE

Una vez entrenado al algoritmo **LAMDA HAD** con el 70% de los datos vistos en el ejemplo de la gráfica de la figura 3.23, se tienen disponibles los GAD que definen la nueva función de distribución que sirven para estimar la clase a la que deben pertenecer los individuos. Con esto se procede a evaluar todos los datos de prueba de las clases de severidades que no fueron considerados para el entrenamiento como son 1-2-3-7-8-9, estos servirán para evaluar la capacidad del clasificador de asignar estos individuos a las clases NIC del correspondiente clasificador. En la gráfica de la figura 3.26 se muestra como resultado lo mencionado, los puntos de color rojo son los datos de prueba que corresponden al 30% de los datos de la partición para prueba del entrenamiento y los datos de color azul son los datos desconocidos para prueba de los grupos de severidades 4-5-6-7-8-9 para la clasificación del algoritmo **LAMDA HAD**.




Figura 3.26: Gráfica de los datos de grupo de severidades para la prueba del entrenamiento N-4-5-6 del modo de falla de grieta en piñon usando 10 atributos y un alfa de 0.6 para CE en tiempo y frecuencia en el algoritmo LAMDA HAD

En esta figura 3.26 se observa que el clasificador no es capaz de clasificar las muestras de otras clases en las las clases NIC. Para cuantificar esta situación se calculan los valores de precisión, para diferentes valores de  $\alpha$ , que se muestran en la figura 3.27. En estos resultados se puede observar que si bien la precisión para los datos de prueba de las clases de entrenamiento (TEST\_TRAIN) son apropiados para  $\alpha = 0,6$ , para los datos de prueba de las clases desconocidas (TEST) es 0.

ALFA	TEST_TRAIN	TEST
0	0.73333	0.066667
0.1	0.80833	0.055556
0.2	0.84167	0.016667
0.3	0.86667	0
0.4	0.86667	0
0.5	0.91667	0
0.6	0.95833	0
0.7	0.95	0
0.8	0.95	0
0.9	0.94167	0
1	0.94167	0.0055556

Figura 3.27: Resultados de precisión del clasificador LAMDA HAD para el grupo de severidades N-4-5-6 y clases desconocidas 1-2-3-7-8-9 del modo de falla de grieta en piñon para CE con atributos en tiempo y frecuencia

Finalmente se propone un nuevo análisis, el cual consiste en seleccionar los valores mas altos de precisión de los resultados del clasificador los cuales corresponderían a la columna 2 que son las pruebas de los entrenamientos llamados (Test\_Train), como los mostrados en la tabla de resultados de precisión 3.27. Como ejemplo de lo mencionado se muestran las tablas de la figura 3.28, que son los resultados de los valores mas altos de precisión que se obtuvieron del clasificador para el modo de falla de grieta en piñon con 10 atributos estadísticos en los tres grupos de severidades.

Como se indicó previamente, los clasificadores dedicados a un grupo de fallas no son capaces de asignar las muestras de datos desconocidos de otros niveles de falla a las clases NIC, tal y como se evidencia en los bajos niveles de precisión en la tercera columna de las tablas de la figura 3.28.

N-1-2-3-10features			N-4-5-6-10features			N-7-8-9-10features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	58,33%	18,89%	Alfa 0	79,33%	6,67%	Alfa 0	65,83%	12,78%
Alfa 0.1	73,33%	20,56%	Alfa 0.1	80,83%	5,56%	Alfa 0.1	66,67%	11,11%
Alfa 0.2	78,33%	16,11%	Alfa 0.2	84,17%	1,67%	Alfa 0.2	73,33%	9,44%
Alfa 0.3	82,50%	14,44%	Alfa 0.3	86,67%	0,00%	Alfa 0.3	85,83%	8,89%
Alfa 0.4	82,50%	14,44%	Alfa 0.4	86,67%	0,00%	Alfa 0.4	88,33%	7,78%
Alfa 0.5	81,67%	11,11%	Alfa 0.5	91,67%	0,00%	Alfa 0.5	88,33%	5,56%
Alfa 0.6	81,67%	7,78%	Alfa 0.6	95,83%	0,00%	Alfa 0.6	87,50%	0,56%
Alfa 0.7	85,83%	7,22%	Alfa 0.7	95,00%	0,00%	Alfa 0.7	85,00%	0,00%
Alfa 0.8	88,33%	15,00%	Alfa 0.8	95,00%	0,00%	Alfa 0.8	81,67%	0,00%
Alfa 0.9	88,33%	21,11%	Alfa 0.9	94,17%	0,00%	Alfa 0.9	81,67%	0,00%
Alfa 1	87,50%	22,22%	Alfa 1	94,17%	0,56%	Alfa 1	81,67%	0,00%

Figura 3.28: Resultados de precisión de los clasificadores para cada grupo de severidades del modo de falla de grieta en piñon para CE para muestras de clases conocidas y desconocidas

Con el fin de evaluar el desempeño simultáneo de los tres clasificadores, con base en los valores de los GAD asignados a una muestra de una clase para la que no fue entrenado cada clasificador, se procedió a realizar un análisis adicional, el cual se detalla a continuación, teniendo como base los mejores clasificadores obtenidos, por ejemplo, los de las tablas de la figura 3.28, para el modelo de fallos de fisura de diente:

1. Dada una muestra  $\bar{X}$  de los datos de prueba de todas las clases, la misma es enviada a los 3 clasificadores simultáneamente.
2. Se calculan los GAD que cada clasificador asigna, para tomar la decisión

CAP 3. DETECCIÓN Y DIAGNÓSTICO DE FALLAS USANDO EL ALGORITMO LAMDA HAD 102

de la clase, el cual puede ser una clase específica  $k$  o una clase  $NIC_k$ . Estos GAD son los mismos que se evalúan en la ecuación (2.41).

- La muestra  $\bar{X}$  se asigna a la clase que tiene el mayor GAD, calculado para cada clasificador.

Lo que se espera verificar en este análisis, es que el mayor GAD provenga del clasificador que fue entrenado con la clase a la que pertenece la muestra  $\bar{X}$ . Siguiendo el procedimiento indicado, se pudo verificar que la mayoría de las muestras fueron asignadas las clases del clasificador para las clases N-7-8-9, evidenciando que no es cierto que el mayor GAD es el calculado por el clasificador de la clase correspondiente, ver figura 3.29. Este resultado indica que es necesario aún realizar mejoras en el algoritmo LAMDA HAD para aumentar su capacidad de enviar a las clases  $NIC_k$  a las muestras que no son de las clases entrenadas.

CLASES	INDIVIDUOS CLASIFICADOS PARA CHACK																													
	NORMAL				1				2				3				4													
	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC					
INDIVIDUOS POR CLASE	27	3	0	0	0	0	28	2	0	0	0	0	9	21	0	0	0	0	0	30	0	0	0	0	30	0				
CLASIFICADOR																														
% CLASIFICADOR	99%	99%	0%	0%	0%	0%	93%	7%	0%	0%	0%	0%	30%	70%	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	100%	0%				
INDIVIDUOS POR CLASE	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC
CLASIFICADOR																														
% CLASIFICADOR	30	0	0	0	0	3	0	27	0	0	0	0	0	30	0	0	0	8	22	0	0	0	26	4	0	0	0	0	0	0
INDIVIDUOS POR CLASE	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC
CLASIFICADOR																														
% CLASIFICADOR	100%	0%	0%	0%	0%	7%	93%	0%	0%	0%	100%	0%	0%	0%	0%	0%	27%	73%	0%	0%	0%	0%	87%	13%	0%	0%	0%	87%	13%	0%
INDIVIDUOS POR CLASE	P1	P4	P5	P6	GAD-NIC	P1	P4	P5	P6	GAD-NIC	P1	P4	P5	P6	GAD-NIC	P1	P4	P5	P6	GAD-NIC	P1	P4	P5	P6	GAD-NIC	P1	P4	P5	P6	GAD-NIC
CLASIFICADOR																														
% CLASIFICADOR	0%	0%	4%	23%	3%	2%	0%	0%	17%	11%	0%	0%	22%	8%	0%	0%	0%	0%	0%	19%	11%	1%	0%	0%	22%	7%				
INDIVIDUOS POR CLASE	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC	P1	P5	P6	P7	GAD-NIC
CLASIFICADOR																														
% CLASIFICADOR	0%	0%	93%	7%	0%	0%	0%	0%	100%	0%	0%	0%	0%	100%	0%	0%	0%	17%	0%	83%	0%	0%	57%	3%	40%	0%				
INDIVIDUOS POR CLASE	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC	P1	P8	P9	P10	GAD-NIC
CLASIFICADOR																														
% CLASIFICADOR	0%	8%	22%	0%	0%	0%	0%	15%	7%	8%	0%	30%	0%	0%	0%	0%	0%	0%	20%	10%	0%	0%	0%	16%	14%	0%				
INDIVIDUOS POR CLASE	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC
CLASIFICADOR																														
% CLASIFICADOR	0%	27%	73%	0%	0%	0%	0%	50%	23%	27%	0%	100%	0%	0%	0%	0%	0%	0%	67%	33%	0%	0%	0%	53%	47%	0%				

Figura 3.29: Tabla de resultados del clasificador que presentó el valor mas alto de los GAD para las clases de los grupos de severidades entrenadas para grieta en piñon

Finalmente se generó una tabla de resumen de todos los datos clasificados en cada clase. Estas tablas serán mostradas y explicadas en el Capítulo 4.

# Capítulo 4

## Análisis de resultados

El presente capítulo contiene la información detallada del análisis de los resultados obtenidos aplicando el marco metodológico del capítulo 3, usando ANOVA y la métrica  $CDbw$  para la selección de los mejores atributos estadísticos, y el algoritmo LAMDA HAD para la clasificación de los diferentes modos de fallas y grados de severidades en las bases de datos estudiadas para CR y CE. También se analiza la capacidad del algoritmo LAMDA HAD de clasificar nuevos patrones de datos de fallas desconocidos para cada clasificador.

### 4.1. Análisis de resultados de la selección de atributos

#### 4.1.1. Resultados en el CR

En la fase de selección de los mejores atributos estadísticos para el CR, luego de aplicar ANOVA para todos los atributos estadísticos en tiempo y frecuencia nos queda la tabla mostrada en la figura 3.14, en la cual se puede observar que los 10 primeros mejores atributos son los del dominio del tiempo, esto es, fueron los que presentaron mayor diferencia entre las medias de los grupos de atributos estadísticos. Con este primer resultado se seleccionaron los mejores grupo de atributos con base en la métrica  $CDbw$ , ver sección 2.4.2. Los resultados de los mejores grupos de atributos estadísticos se muestran en las tablas de la figura 4.1.



Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	#feature	N	Time, Frecuencia FFT & PSD	#feature	N	Time, Frecuencia FFT & PSD	#feature	N	Time, Frecuencia FFT & PSD	#feature
1	'time.NNML_3_1'	103	1	'time.NNML_3_1'	103	1	'time.NNML_3_1'	103	1	'time.NNML_3_1'	103
2	'time.WI_3_1'	190	2	'time.WI_3_1'	190	2	'time.WI_3_1'	190	2	'time.WI_3_1'	190
3	'time.TM_5_1'	189	3	'time.mean_3_1'	1	3	'time.PI_3_1'	70	3	'time.PI_3_1'	70
			4	'time.TM_5_1'	189	4	'time.mean_3_1'	1	4	'time.mean_5_1'	3
						5	'time.TM_5_1'	189	5	'time.mean_3_1'	1
									6	'time.TM_5_1'	189

Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	#feature	N	Time, Frecuencia FFT & PSD	#feature	N	Time, Frecuencia FFT & PSD	#feature	N	Time, Frecuencia FFT & PSD	#feature
1	'time.NNML_3_1'	103	1	'time.NNML_3_1'	103	1	'time.NNML_3_1'	103	1	'time.NNML_3_1'	103
2	'time.WI_3_1'	190	2	'time.WI_3_1'	190	2	'time.PI_3_1'	70	2	'time.WI_3_1'	190
3	'time.PI_3_1'	70	3	'time.PI_3_1'	70	3	'time.TM_5_1'	189	3	'time.PI_3_1'	70
4	'time.MDR_5_1'	78	4	'time.TM_3_1'	187	4	'time.MDR_5_1'	78	4	'time.TM_3_1'	187
5	'time.mean_5_1'	3	5	'time.MDR_5_1'	78	5	'time.mean_5_1'	3	5	'time.MDR_5_1'	78
6	'time.mean_3_1'	1	6	'time.mean_5_1'	3	6	'time.sf_5_1'	33	6	'time.mean_5_1'	3
7	'time.TM_5_1'	189	7	'time.mean_3_1'	1	7	'time.NNML_4_1'	104	7	'time.sf_5_1'	33
			8	'time.TM_5_1'	189	8	'time.mean_3_1'	1	8	'time.NNML_4_1'	104
						9	'time.TM_5_1'	189	9	'time.mean_3_1'	1
									10	'time.TM_5_1'	189

Figura 4.1: Tabla de resultados de los mejores atributos estadísticos aplicando ANOVA y la métrica  $CDBw$  en CR

A continuación se muestran la estructuras de grupos (clusters) de datos usando la técnica de visualización TSNE en 4.2, 4.3 y 4.4, las cuales corresponden a los resultados de los mejores atributos de las combinaciones 3 de 10, 7 de 10 y 10 de 10 que se mostraron en la tabla de la figura 4.1. Esto es con el fin de identificar el grupo de atributos que forman un mejor conglomerado desde el punto de vista de la separabilidad.




Figura 4.2: Gráfica TSNE de los 3 mejores atributos estadísticos en CR




Figura 4.3: Gráfica TSNE de los 7 mejores atributos estadísticos en CR




Figura 4.4: Gráfica TSNE de los 10 mejores atributos estadísticos en CR

De la tabla mostrada en la figura 4.1 se va a seleccionar el grupo de 3 atributos estadísticos, y estos serán usados para aplicarlos en el algoritmo [LAMDA HAD](#), ya que como se puede observar en la figura 4.2 es la que presenta mejor separación y agrupación de los datos de los atributos, con respecto a los mostrados en las figuras 4.3 y 4.4. En la figura 4.5 se puede observar el agrupamiento de los datos de los tres mejores atributos estadísticos para CR en 3 dimensiones, los mismos que corresponden a la gráfica TSNE 4.2 y a las celdas sombreadas de color amarillo en la tabla de la figura 4.1.




Figura 4.5: Gráfica de resultados de los 3 mejores atributos estadísticos aplicando ANOVA y la métrica  $CD_{bw}$  en CR

#### 4.1.2. Resultados en CE con atributos de tiempo y frecuencia

Para la selección de los mejores atributos estadísticos para la CE en tiempo y frecuencia se tienen 4 modos de fallas y con 4 grupos de severidades siendo estos N-1-2-3, N-4-5-6 y N-7-8-9, donde N denota la clase normal y 1 a 9 denota los diferentes niveles de severidad de cada modo de falla. De la tabla de resultados de ANOVA se seleccionan los 10 primeros atributos estadísticos de los cuales se realizarán combinaciones de 3, 4 hasta considerar 10 atributos. A continuación se presentan los resultados para cada uno de los modos de fallas.

##### Modo de falla: Diente roto en piñón

En las pruebas realizadas con el modo de falla de diente roto para todos los atributos en tiempo y frecuencia en los diferentes grupos de severidades, se aplica ANOVA y la métrica  $CD_{bw}$ , y se obtienen los resultados mostrados en las tablas de las figuras 4.6, 4.10 y 4.14.

GEAR BOX TIME AND FREQUENCY NORMAL 1-2-3 (BROKEN)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.wL_2_T	191	1	time.NNWL_3_T	103	1	time.mean_1_T	1	1	time.mean_1_T	1
2	time.PL_2_T	71	2	time.wL_3_T	190	2	time.if_3_T	36	2	time.if_3_T	36
3	time.mean_2_T	2	3	time.PL_3_T	70	3	time.if_2_T	35	3	time.if_2_T	35
			4	time.TM_3_T	187	4	time.sf_3_T	33	4	time.sf_3_T	33
						5	time.sf_2_T	32	5	time.sf_2_T	32
									6	time.sf_1_T	31
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mean_1_T	1	1	time.wL_2_T	191	1	time.wL_2_T	191	1	time.mean_1_T	1
2	time.mean_2_T	2	2	time.PL_2_T	71	2	time.PL_2_T	71	2	time.wL_2_T	191
3	time.if_3_T	36	3	time.mean_2_T	2	3	time.mean_2_T	3	3	time.PL_2_T	71
4	time.if_2_T	35	4	time.if_3_T	36	4	time.NNWL_1_T	103	4	time.mean_2_T	2
5	time.sf_3_T	33	5	time.if_2_T	35	5	time.if_3_T	36	5	time.NNWL_1_T	103
6	time.sf_2_T	32	6	time.if_3_T	33	6	time.if_2_T	35	6	time.if_3_T	36
7	time.sf_1_T	31	7	time.sf_2_T	32	7	time.sf_3_T	33	7	time.if_2_T	35
			8	time.sf_1_T	31	8	time.sf_2_T	32	8	time.sf_3_T	33
						9	time.sf_1_T	31	9	time.sf_2_T	32
									10	time.sf_1_T	31

Figura 4.6: Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla de diente roto

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.7, 4.8 y 4.9, las cuales corresponden a los resultados de los mejores combinaciones de 3, 7 y 10 atributos que se mostraron en las tablas de la figura 4.6.




Figura 4.7: Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-1-2-3 de diente roto en CE




Figura 4.8: Gráfica TSNE de los 7 mejores atributos estadísticos para el grupo de severidad N-1-2-3 de diente roto en CE




Figura 4.9: Gráfica TSNE de los 10 mejores atributos estadísticos para el grupo de severidad N-1-2-3 de diente roto en CE

GEAR BOX TIME AND FREQUENCY NORMAL 4-5-6 (BROKEN)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mesa_1_f'	1	1	time.mean_1_f'	1	1	time.mesa_1_f'	1	1	time.mesa_1_f'	1
2	time.wL_2_f'	191	2	time.wL_2_f'	191	2	time.wL_2_f'	191	2	time.PL_2_f'	70
3	time.mesa_2_f'	2	3	time.mesa_2_f'	2	3	time.mesa_2_f'	2	3	time.wL_2_f'	191
			4	time.PL_2_f'	71	4	time.PL_2_f'	71	4	time.mesa_2_f'	2
						5	time.sf_2_f'	32	5	time.PL_2_f'	71
									6	time.if_3_f'	36
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mesa_1_f'	1	1	time.mean_1_f'	1	1	time.mesa_1_f'	1	1	time.mean_1_f'	1
2	time.PL_1_f'	70	2	time.PL_1_f'	70	2	time.PL_1_f'	70	2	time.PL_1_f'	70
3	time.wL_2_f'	191	3	time.wL_2_f'	191	3	time.wL_2_f'	191	3	time.wL_2_f'	191
4	time.mesa_2_f'	2	4	time.NNWL_1_f'	103	4	time.mesa_2_f'	2	4	time.mesa_2_f'	2
5	time.PL_2_f'	71	5	time.PL_2_f'	71	5	time.PL_2_f'	71	5	time.wL_1_f'	190
6	time.if_3_f'	36	6	time.if_3_f'	36	6	time.NNWL_1_f'	103	6	time.NNWL_1_f'	103
7	time.sf_3_f'	33	7	time.sf_3_f'	33	7	time.if_3_f'	36	7	time.PL_2_f'	71
			8	time.sf_2_f'	32	8	time.sf_3_f'	33	8	time.if_3_f'	36
						9	time.sf_2_f'	32	9	time.sf_3_f'	33
									10	time.sf_2_f'	32

Figura 4.10: Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla de diente roto

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.11, 4.12 y 4.13, las cuales corresponden a los resultados de los mejores



3, 7 y 10 atributos de las combinaciones que se mostraron en las tablas de la figura 4.10.




Figura 4.11: Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-4-5-6 de diente roto en CE




Figura 4.12: Gráfica TSNE de los 7 mejores atributos estadísticos para el grupo de severidad N-4-5-6 de diente roto en CE




Figura 4.13: Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-4-5-6 de diente roto en CE

GEAR BOX TIME AND FREQUENCY NORMAL 7-8-9 (BROKEN)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mean_1_T	1	1	time.mean_1_T	1	1	time.mean_1_T	1	1	time.mean_1_T	1
2	time.wL_2_T	191	2	time.wL_2_T	191	2	time.wL_2_T	191	2	time.PL_2_T	70
3	time.mean_2_T	2	3	time.mean_2_T	2	3	time.mean_2_T	2	3	time.wL_2_T	191
			4	time.PL_2_T	71	4	time.PL_2_T	71	4	time.mean_2_T	2
						5	time.sf_2_T	32	5	time.if_3_T	36
									6	time.sf_3_T	33
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mean_1_T	1	1	time.mean_1_T	1	1	time.mean_1_T	1	1	time.mean_1_T	1
2	time.PL_1_T	70	2	time.PL_1_T	70	2	time.PL_1_T	70	2	time.PL_1_T	70
3	time.wL_2_T	191	3	time.wL_2_T	191	3	time.wL_2_T	191	3	time.wL_2_T	191
4	time.mean_2_T	2	4	time.NNWL_1_T	103	4	time.mean_2_T	2	4	time.mean_2_T	2
5	time.PL_2_T	71	5	time.PL_2_T	71	5	time.NNWL_1_T	103	5	time.wL_1_T	190
6	time.if_3_T	36	6	time.if_3_T	36	6	time.PL_2_T	71	6	time.NNWL_1_T	103
7	time.sf_3_T	33	7	time.if_3_T	33	7	time.if_3_T	36	7	time.PL_2_T	71
			8	time.sf_2_T	32	8	time.sf_3_T	33	8	time.if_3_T	36
						9	time.sf_2_T	32	9	time.sf_3_T	33
									10	time.sf_2_T	32

Figura 4.14: Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla de diente roto

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.15, 4.16 y 4.17, las cuales corresponden a los resultados de los mejores

3, 7 y 10 atributos de las combinaciones que se mostraron en las tablas de la figura 4.14.




Figura 4.15: Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-7-8-9 de diente roto en CE




Figura 4.16: Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-7-8-9 de diente roto en CE




Figura 4.17: Gráfica TSNE de los 3 mejores atributos estadísticos para el grupo de severidad N-7-8-9 de diente roto en CE

En las gráficas TSNE mostradas para el modo de falla de diente roto en piñon, correspondientes a los 3 grupos de severidades se puede apreciar que los grupos (clústers) datos generados con 10 atributos estadísticos se ven mejor agrupados y separados entre si. También se puede observar que estos 10 atributos son los mismos para los grupos de fallas N-4-5-6 y N-7-8-9, como se muestra en la tabla 4.18. Por otro lado, los 10 atributos para el grupo de severidad N-1-2-3 solo difieren en 2 atributos con respecto a los otros grupos de severidades. Con el fin de utilizar los mismos atributos para los tres grupos de severidades, se van a seleccionar los atributos del grupo de severidad N-1-2-3, que corresponden a los atributos sombreados de color amarillo, los cuales serán los que van a ser usados en el algoritmo [LAMDA HAD](#).

DIENTE ROTO EN PIÑÓN								
N-1-2-3			N-4-5-6			N-7-8-9		
Combinación de 10 de 10			Combinación de 10 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mean_1_1'	1	1	time.mean_1_1'	1	1	time.mean_1_1'	1
2	time.wL_2_1'	131	2	time.PL_1_1'	70	2	time.PL_1_1'	70
3	time.PL_2_1'	71	3	time.wL_2_1'	131	3	time.wL_2_1'	131
4	time.mean_2_1'	2	4	time.mean_2_1'	2	4	time.mean_2_1'	2
5	'time.NNML_1_1'	103	5	time.wL_1_1'	190	5	time.wL_1_1'	190
6	time.if_3_1'	36	6	'time.NNML_1_1'	103	6	'time.NNML_1_1'	103
7	time.if_2_1'	35	7	time.PL_2_1'	71	7	time.PL_2_1'	71
8	time.sf_3_1'	33	8	time.if_3_1'	36	8	time.if_3_1'	36
9	time.sf_2_1'	32	9	time.sf_3_1'	33	9	time.sf_3_1'	33
10	time.sf_1_1'	31	10	time.sf_2_1'	32	10	time.sf_2_1'	32

Figura 4.18: Tablas de resultados de los 10 de 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica *CD<sub>bw</sub>* para diente roto en CE

**Modo de falla: Grieta en piñón**

En las pruebas realizadas con el modo de falla de grieta en el diente del piñón para todos los atributos en tiempo y frecuencia con todos los grupos de severidades, se aplica ANOVA y la métrica *CD<sub>bw</sub>* y se obtienen los resultados mostrados en las tablas de las figuras 4.19, 4.23 y 4.27.

GEAR BOX TIME AND FREQUENCY NORMAL 1-2-3 [CRACK]											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	'time.mcan_3_1'	3	1	'time.mcan_3_1'	3	1	'time.mcan_3_1'	3	1	'time.WL_3_1'	192
2	'time.NNML_3_1'	105	2	'time.WL_3_1'	192	2	'time.WL_3_1'	192	2	'time.MDR_3_1'	78
3	'time.WL_2_1'	191	3	'time.NNML_3_1'	105	3	'time.NNML_3_1'	105	3	'time.NNML_3_1'	105
			4	'time.PL_2_1'	71	4	'time.PL_2_1'	71	4	'time.TM_3_1'	189
						5	'time.mcan_2_1'	2	5	'time.WL_2_1'	191
									6	'time.mcan_2_1'	2
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	'time.mcan_3_1'	3	1	'time.mcan_3_1'	3	1	'time.mcan_3_1'	3	1	'time.mcan_3_1'	3
2	'time.WL_3_1'	192	2	'time.WL_3_1'	192	2	'time.WL_3_1'	192	2	'time.WL_3_1'	192
3	'time.MDR_3_1'	78	3	'time.PL_3_1'	72	3	'time.PL_3_1'	72	3	'time.PL_3_1'	72
4	'time.NNML_3_1'	105	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78
5	'time.TM_3_1'	189	5	'time.NNML_3_1'	105	5	'time.NNML_3_1'	105	5	'time.NNML_3_1'	105
6	'time.WL_2_1'	191	6	'time.TM_3_1'	189	6	'time.TM_3_1'	189	6	'time.TM_3_1'	189
7	'time.mcan_2_1'	2	7	'time.WL_2_1'	191	7	'time.WL_2_1'	191	7	'time.WL_2_1'	191
			8	'time.mcan_2_1'	2	8	'time.PL_2_1'	71	8	'time.PL_2_1'	71
						9	'time.mcan_2_1'	2	9	'time.TM_1_1'	187
									10	'time.mcan_2_1'	2

Figura 4.19: Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla grieta en un diente del piñón

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.20, 4.21 y 4.22, las cuales corresponden a los resultados de los mejores 3, 7 y 10 atributos que se mostraron en las tablas de la figura 4.19.




Figura 4.20: Gráfica TSNE de los 3 mejores atributos estadísticos en el grupo de severidades N-1-2-3 para grieta en el diente de CE




Figura 4.21: Gráfica TSNE de los 7 mejores atributos estadísticos en el grupo de severidades N-1-2-3 para grieta en el diente de CE




Figura 4.22: Gráfica TSNE de los 10 mejores atributos estadísticos en el grupo de severidades N-1-2-3 para grieta en el diente de CE

GEAR BOX TIME AND FREQUENCY NORMAL 4-5-6 (CRACK)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mesn_3_1'	3	1	time.mesn_3_1'	3	1	time.mesn_3_1'	3	1	time.WL_3_1'	192
2	'time.NNWL_3_1'	105	2	'time.WL_3_1'	192	2	'time.WL_3_1'	192	2	'time.MDR_3_1'	78
3	time.WL_2_1'	191	3	'time.NNWL_3_1'	105	3	'time.NNWL_3_1'	105	3	'time.NNWL_3_1'	105
			4	time.mesn_2_1'	2	4	time.TM_3_1'	189	4	time.TM_3_1'	189
						5	'time.mesn_2_1'	2	5	time.WL_2_1'	191
									6	'time.mesn_2_1'	2
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mesn_3_1'	3	1	time.mesn_3_1'	3	1	time.mesn_3_1'	3	1	time.mesn_3_1'	3
2	time.PL_3_1'	72	2	time.WL_3_1'	192	2	time.WL_3_1'	192	2	time.WL_3_1'	192
3	'time.MDR_3_1'	78	3	time.PL_3_1'	72	3	'time.PL_3_1'	72	3	time.PL_3_1'	72
4	'time.NNWL_3_1'	105	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78
5	time.TM_3_1'	189	5	'time.NNWL_3_1'	105	5	'time.NNWL_3_1'	105	5	'time.NNWL_3_1'	105
6	time.WL_2_1'	191	6	time.TM_3_1'	189	6	time.TM_3_1'	189	6	time.TM_3_1'	189
7	time.PL_2_1'	71	7	time.WL_2_1'	191	7	time.WL_2_1'	191	7	time.WL_2_1'	191
			8	'time.mesn_2_1'	2	8	time.PL_2_1'	71	8	time.PL_2_1'	71
						9	'time.mesn_2_1'	2	9	time.TM_1_1'	187
									10	'time.mesn_2_1'	2

Figura 4.23: Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla grieta en piñón

A continuación se muestran los grupos de datos visualizados con TSNE en las



figuras 4.24, 4.25 y 4.26, las cuales corresponden a los resultados de los mejores 3, 7 y 10 atributos mostrados en las tablas de la figura 4.23.




Figura 4.24: Gráfica TSNE de los 3 mejores atributos estadísticos en el grupo de severidades N-4-5-6 para grieta en el diente de CE




Figura 4.25: Gráfica TSNE de los 7 mejores atributos estadísticos en el grupo de severidades N-4-5-6 para grieta en el diente de CE




Figura 4.26: Gráfica TSNE de los 10 mejores atributos estadísticos en el grupo de severidades N-4-5-6 para grieta en el diente de CE

GEAR BOX TIME AND FREQUENCY NORMAL 7-8-9 (CRACK)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mean_3_1'	3	1	time.mean_3_1'	3	1	time.mean_3_1'	3	1	time.WL_3_1'	192
2	'time.NNWL_3_1'	105	2	'time.WL_3_1'	192	2	'time.WL_3_1'	192	2	'time.MDR_3_1'	78
3	time.WL_2_1'	191	3	'time.NNWL_3_1'	105	3	'time.NNWL_3_1'	105	3	'time.NNWL_3_1'	105
			4	time.mean_2_1'	2	4	time.TM_3_1'	189	4	time.TM_3_1'	189
						5	'time.mean_2_1'	2	5	time.WL_2_1'	191
									6	'time.mean_2_1'	2
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	time.mean_3_1'	3	1	time.mean_3_1'	3	1	time.mean_3_1'	3	1	time.mean_3_1'	3
2	time.PL_3_1'	72	2	time.WL_3_1'	192	2	time.WL_3_1'	192	2	time.WL_3_1'	192
3	'time.MDR_3_1'	78	3	time.PL_3_1'	72	3	time.PL_3_1'	72	3	time.PL_3_1'	72
4	'time.NNWL_3_1'	105	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78
5	time.TM_3_1'	189	5	'time.NNWL_3_1'	105	5	'time.NNWL_3_1'	105	5	'time.NNWL_3_1'	105
6	time.WL_2_1'	191	6	time.TM_3_1'	189	6	time.TM_3_1'	189	6	time.TM_3_1'	189
7	time.PL_2_1'	71	7	time.WL_2_1'	191	7	time.WL_2_1'	191	7	time.WL_2_1'	191
			8	'time.mean_2_1'	2	8	time.PL_2_1'	71	8	time.PL_2_1'	71
						9	'time.mean_2_1'	2	9	time.TM_1_1'	187
									10	'time.mean_2_1'	2

Figura 4.27: Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla grieta en el diente del piñón

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.28, 4.29 y 4.30, las cuales corresponden a los resultados de los mejores

3, 7 y 10 atributos de las combinaciones que se mostraron en las tablas de la figura 4.27.




Figura 4.28: Gráfica TSNE de los 3 mejores atributos estadísticos en el grupo de severidades N-7-8-9 para grieta en el diente de CE




Figura 4.29: Gráfica TSNE de los 7 mejores atributos estadísticos en el grupo de severidades N-7-8-9 para grieta en el diente de CE




Figura 4.30: Gráfica TSNE de los 10 mejores atributos estadísticos en el grupo de severidades N-7-8-9 para grieta en el diente de CE

En las gráficas de visualización TSNE mostradas para el modo de falla de grieta en piñon, correspondientes a los 3 grupos de severidades se puede apreciar que, en general, todos los grupos (clústers) de datos presentan una apropiada agrupación y separación. Sin embargo, se va a optar por el conjunto de 10 atributos, los cuales son mostrados en las gráficas 4.22, 4.26 y 4.30, dado que se puede observar que estos 10 atributos los mismos en los 3 grupos de fallas como se muestra en la tabla de la figura 4.31, y sombreados de color amarillo, los cuales serán los que va a ser aplicados en el algoritmo [LAMDA HAD](#).

GRIETA EN PIÑÓN								
N-1-2-3			N-4-5-6			N-7-8-9		
Combinación de 10 de 10			Combinación de 10 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	'time.mean_3_1'	3	1	'time.mean_3_1'	3	1	'time.mean_3_1'	3
2	'time.wL_3_1'	192	2	'time.wL_3_1'	192	2	'time.wL_3_1'	192
3	'time.PL_3_1'	72	3	'time.PL_3_1'	72	3	'time.PL_3_1'	72
4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78	4	'time.MDR_3_1'	78
5	'time.NNML_3_1'	105	5	'time.NNML_3_1'	105	5	'time.NNML_3_1'	105
6	'time.TM_3_1'	189	6	'time.TM_3_1'	189	6	'time.TM_3_1'	189
7	'time.wL_2_1'	191	7	'time.wL_2_1'	191	7	'time.wL_2_1'	191
8	'time.PL_2_1'	71	8	'time.PL_2_1'	71	8	'time.PL_2_1'	71
9	'time.TM_L_1'	187	9	'time.TM_L_1'	187	9	'time.TM_L_1'	187
10	'time.mean_2_1'	2	10	'time.mean_2_1'	2	10	'time.mean_2_1'	2

Figura 4.31: Tablas de resultados de los 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica  $Cdbw$  para grieta en el diente del piñón en CE

### Modo de falla: Picadura en piñón

En las pruebas realizadas con el modo de falla de picadura en piñón para todos los atributos en tiempo y frecuencia con todos los grupos de severidades, se aplica ANOVA y la métrica  $Cdbw$  y se obtienen los resultados mostrados en las tablas de las figuras 4.32, 4.36 y 4.40.

GEAR BOX TIME AND FREQUENCY NORMAL 1-2-3 [PITTING]											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.MNML_3_1"]	105	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.VL_3_1"]	192	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105
3	["time.mean_1_1"]	1	3	["time.mean_1_1"]	1	3	["time.VL_3_1"]	192	3	["time.VL_3_1"]	192
			4	["time.MDR_3_1"]	78	4	["time.mean_1_1"]	1	4	["time.PL_3_1"]	72
						5	["time.MDR_3_1"]	78	5	["time.mean_1_1"]	1
									6	["time.MDR_3_1"]	78
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105
3	["time.VL_3_1"]	192	3	["time.VL_3_1"]	192	3	["time.PL_3_1"]	72	3	["time.VL_3_1"]	192
4	["time.PL_3_1"]	72	4	["time.PL_3_1"]	72	4	["time.MDR_3_1"]	78	4	["time.PL_3_1"]	72
5	["time.mean_1_1"]	1	5	["time.MDR_3_1"]	78	5	["time.VL_3_1"]	192	5	["time.mean_1_1"]	1
6	["time.VL_2_1"]	191	6	["time.PL_2_1"]	71	6	["time.mean_1_1"]	1	6	["time.MDR_3_1"]	78
7	["time.mean_2_1"]	2	7	["time.VL_2_1"]	191	7	["time.VL_2_1"]	191	7	["time.PL_2_1"]	71
			8	["time.mean_2_1"]	2	8	["time.PL_2_1"]	71	8	["time.VL_2_1"]	191
						9	["time.mean_2_1"]	2	9	["time.mean_2_1"]	2
									10	["time.TM_3_1"]	183

Figura 4.32: Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla picadura en piñón

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.33, 4.34 y 4.35, las cuales corresponden a los resultados de los mejores atributos en las combinaciones de 3, 7 10 que se mostraron en las tablas de la figura 4.32.




Figura 4.33: Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-1-2-3 para picadura en diente de CE




Figura 4.34: Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-1-2-3 para picadura en diente de CE




Figura 4.35: Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-1-2-3 para picadura en diente de CE

GEAR BOX TIME AND FREQUENCY NORMAL 4-5-6 [PITTING]											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.WL_3_1"]	192	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.NNINL_3_1"]	105	2	["time.WL_3_1"]	192	2	["time.WL_3_1"]	192	2	["time.WL_3_1"]	192
3	["time.mean_1_1"]	1	3	["time.NNINL_3_1"]	105	3	["time.NNINL_3_1"]	105	3	["time.PI_3_1"]	72
			4	["time.mean_1_1"]	1	4	["time.mean_1_1"]	1	4	["time.NNINL_3_1"]	105
						5	["time.MDR_3_1"]	78	5	["time.mean_1_1"]	1
									6	["time.MDR_3_1"]	78
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.WL_3_1"]	192	2	["time.WL_3_1"]	192	2	["time.WL_3_1"]	192	2	["time.WL_3_1"]	192
3	["time.PI_3_1"]	72	3	["time.PI_3_1"]	72	3	["time.PI_3_1"]	72	3	["time.PI_3_1"]	72
4	["time.NNINL_3_1"]	105	4	["time.NNINL_3_1"]	105	4	["time.NNINL_3_1"]	105	4	["time.NNINL_3_1"]	105
5	["time.mean_2_1"]	2	5	["time.MDR_3_1"]	78	5	["time.mean_1_1"]	1	5	["time.mean_1_1"]	1
6	["time.WL_2_1"]	191	6	["time.mean_2_1"]	2	6	["time.MDR_3_1"]	78	6	["time.MDR_3_1"]	78
7	["time.PI_2_1"]	71	7	["time.WL_2_1"]	191	7	["time.mean_2_1"]	2	7	["time.TM_3_1"]	183
			8	["time.PI_2_1"]	71	8	["time.WL_2_1"]	191	8	["time.mean_2_1"]	2
						9	["time.PI_2_1"]	71	9	["time.WL_2_1"]	191
									10	["time.PI_2_1"]	71

Figura 4.36: Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla picadura en piñón

A continuación se muestran los grupos de datos visualizados con TSNE en las figuras 4.37, 4.38 y 4.39, las cuales corresponden a los resultados de los mejores



atributos de las combinaciones 3, 7 y 10 que mostraron en las tablas de la figura 4.36.




Figura 4.37: Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-4-5-6 para picadura en diente de CE




Figura 4.38: Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-4-5-6 para picadura en diente de CE




Figura 4.39: Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-4-5-6 para picadura en diente de CE

GEAR BOX TIME AND FREQUENCY NORMAL 7-8-9 [PITTING]											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# featur	N	Time, Frecuencia FFT & PSD	# featur	N	Time, Frecuencia FFT & PSD	# featur	N	Time, Frecuencia FFT & PSD	# featur
1	["time.WI_3_1"]	192	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.NNINL_3_1"]	105	2	["time.WI_3_1"]	192	2	["time.WI_3_1"]	192	2	["time.WI_3_1"]	192
3	["time.mean_1_1"]	1	3	["time.NNINL_3_1"]	105	3	["time.NNINL_3_1"]	105	3	["time.PI_3_1"]	72
			4	["time.mean_1_1"]	1	4	["time.mean_1_1"]	1	4	["time.NNINL_3_1"]	105
						5	["time.MDR_3_1"]	78	5	["time.mean_1_1"]	1
									6	["time.MDR_3_1"]	78
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# featur	N	Time, Frecuencia FFT & PSD	# featur	N	Time, Frecuencia FFT & PSD	# featur	N	Time, Frecuencia FFT & PSD	# featur
1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.WI_3_1"]	192	2	["time.WI_3_1"]	192	2	["time.WI_3_1"]	192	2	["time.WI_3_1"]	192
3	["time.PI_3_1"]	72	3	["time.PI_3_1"]	72	3	["time.PI_3_1"]	72	3	["time.PI_3_1"]	72
4	["time.NNINL_3_1"]	105	4	["time.NNINL_3_1"]	105	4	["time.NNINL_3_1"]	105	4	["time.NNINL_3_1"]	105
5	["time.mean_2_1"]	2	5	["time.MDR_3_1"]	78	5	["time.mean_1_1"]	1	5	["time.mean_1_1"]	1
6	["time.WI_2_1"]	191	6	["time.mean_2_1"]	2	6	["time.MDR_3_1"]	78	6	["time.MDR_3_1"]	78
7	["time.PI_2_1"]	71	7	["time.WI_2_1"]	191	7	["time.mean_2_1"]	2	7	["time.TM_3_1"]	183
			8	["time.PI_2_1"]	71	8	["time.WI_2_1"]	191	8	["time.mean_2_1"]	2
						9	["time.PI_2_1"]	71	9	["time.WI_2_1"]	191
									10	["time.PI_2_1"]	71

Figura 4.40: Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla picadura en piñón

A continuación se muestra la visualización TSNE de los grupos de datos en las

figuras 4.41, 4.42 y 4.43, los cuales corresponden a los mejores atributos de las combinaciones 3 , 7 y 10 que se mostraron en las tablas de la figura 4.40.




Figura 4.41: Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-7-8-9 para picadura en diente de CE




Figura 4.42: Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-7-8-9 para picadura en diente de CE




Figura 4.43: Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-7-8-9 para picadura en diente de CE

En las gráficas mostradas para el modo de falla de picadura en piñon, correspondientes a los 3 grupos de severidades se puede apreciar que los grupos de datos (clústers) para 3 y 7 atributos no son apropiados, siendo los agrupaciones para 10 atributos lo que presentan una mejor estructura de grupos, según las figuras 4.35, 4.39 y 4.43. También se puede observar que estos 10 atributos son los mismos en los 3 grupos de fallas como se muestra en la tabla de la figura 4.44, por lo tanto se van a seleccionar estos atributos, sombreados de color amarillo, para aplicar el algoritmo LAMDA HAD.

PICADURA EN PIÑÓN								
N-1-2-3			N-4-5-6			N-7-8-9		
Combinación de 10 de 10			Combinación de 10 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3	1	["time.mean_3_1"]	3
2	["time.NNML_3_1"]	105	2	["time.WL_3_1"]	192	2	["time.WL_3_1"]	192
3	["time.WL_3_1"]	192	3	["time.PL_3_1"]	72	3	["time.PL_3_1"]	72
4	["time.PL_3_1"]	72	4	["time.NNML_3_1"]	105	4	["time.NNML_3_1"]	105
5	["time.mean_1_1"]	1	5	["time.mean_1_1"]	1	5	["time.mean_1_1"]	1
6	["time.MDR_3_1"]	78	6	["time.MDR_3_1"]	78	6	["time.MDR_3_1"]	78
7	["time.PL_2_1"]	71	7	["time.TM_3_1"]	189	7	["time.TM_3_1"]	189
8	["time.WL_2_1"]	191	8	["time.mean_2_1"]	2	8	["time.mean_2_1"]	2
9	["time.mean_2_1"]	2	9	["time.WL_2_1"]	191	9	["time.WL_2_1"]	191
10	["time.TM_3_1"]	189	10	["time.PL_2_1"]	71	10	["time.PL_2_1"]	71

Figura 4.44: Tablas de resultados de los 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica  $CD_{bw}$  para picadura en CE

### Modo de falla: Rayadura en piñón

En las pruebas realizadas con el modo de falla de rayadura en piñón para todos los atributos en tiempo y frecuencia con todos los grupos de severidades, se aplica ANOVA y la métrica  $CD_{bw}$ , y se obtienen los resultados mostrados en las tablas de las figuras 4.45, 4.49 y 4.53.

GEAR BOX TIME AND FREQUENCY NORMAL 1-2-3 (SCUFFING)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_1_1"]	1	1	["time.mean_1_1"]	1	1	["time.mean_1_1"]	1	1	["time.mean_1_1"]	1
2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105
3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3
			4	["time.if_2_1"]	35	4	["time.WL_3_1"]	192	4	["time.PL_3_1"]	72
						5	["time.if_2_1"]	35	5	["time.WL_3_1"]	192
									6	["time.sf_2_1"]	32
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_1_1"]	1	1	["time.mean_1_1"]	1	1	["time.mean_1_1"]	1	1	["time.mean_1_1"]	1
2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105	2	["time.MNML_3_1"]	105
3	["time.mean_3_1"]	3	3	["time.MDF_3_1"]	78	3	["time.MDF_3_1"]	78	3	["time.MDF_3_1"]	78
4	["time.PL_3_1"]	72	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3
5	["time.WL_3_1"]	192	5	["time.mean_2_1"]	2	5	["time.mean_2_1"]	2	5	["time.MNML_1_1"]	103
6	["time.if_2_1"]	35	6	["time.PL_3_1"]	72	6	["time.PL_3_1"]	72	6	["time.mean_2_1"]	2
7	["time.sf_2_1"]	32	7	["time.WL_3_1"]	192	7	["time.WL_3_1"]	192	7	["time.PL_3_1"]	72
			8	["time.if_2_1"]	35	8	["time.if_2_1"]	35	8	["time.WL_3_1"]	192
						9	["time.sf_2_1"]	32	9	["time.if_2_1"]	35
									10	["time.sf_2_1"]	32

Figura 4.45: Resultados de los mejores atributos estadísticos para el grupo de severidad N-1-2-3 para CE en tiempo y frecuencia para el modo de falla rayadura en piñón

A continuación se muestra la visualización de los grupos de datos usando TSNE en las figuras 4.46, 4.47 y 4.48, las cuales corresponden a los resultados de los mejores 3, 7 y 10 atributos que se mostraron en las tablas de la figura 4.45.




Figura 4.46: Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-1-2-3 para rayadura en el diente de piñón de CE




Figura 4.47: Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-1-2-3 para rayadura en el diente de piñón de CE




Figura 4.48: Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-1-2-3 para rayadura en el diente de piñón de CE

GEAR BOX TIME AND FREQUENCY NORMAL 4-5-6 (SCUFFING)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_1_1"]	1	1	["time.NNINL_3_1"]	105	1	["time.NNINL_3_1"]	105	1	["time.NNINL_3_1"]	105
2	["time.mean_3_1"]	3	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1
3	["time.PI_3_1"]	72	3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3
			4	["time.if_3_1"]	36	4	["time.PI_3_1"]	72	4	["time.PI_3_1"]	72
						5	["time.if_3_1"]	36	5	["time.WI_3_1"]	192
									6	["time.if_3_1"]	36
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.NNINL_3_1"]	105	1	["time.NNINL_3_1"]	105	1	["time.NNINL_3_1"]	105	1	["time.NNINL_3_1"]	105
2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1
3	["time.mean_3_1"]	3	3	["time.MDR_3_1"]	78	3	["time.MDR_3_1"]	78	3	["time.MDR_3_1"]	78
4	["time.PI_3_1"]	72	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3
5	["time.WI_3_1"]	192	5	["time.mean_2_1"]	2	5	["time.mean_2_1"]	2	5	["time.mean_2_1"]	2
6	["time.if_2_1"]	35	6	["time.PI_3_1"]	72	6	["time.PI_3_1"]	72	6	["time.NNINL_1_1"]	103
7	["time.if_3_1"]	36	7	["time.WI_3_1"]	192	7	["time.WI_3_1"]	192	7	["time.PI_3_1"]	72
			8	["time.if_2_1"]	35	8	["time.if_2_1"]	35	8	["time.WI_3_1"]	192
						9	["time.if_3_1"]	36	9	["time.if_2_1"]	35
									10	["time.if_3_1"]	36

Figura 4.49: Resultados de los mejores atributos estadísticos para el grupo de severidad N-4-5-6 para CE en tiempo y frecuencia para el modo de falla rayadura en piñón

A continuación se muestra la visualización de los grupos de datos usando TSNE



en la figuras 4.50, 4.51 y 4.52, las cuales corresponden a los resultados de los mejores atributos de las combinaciones 3, 7 y 10 que se mostraron en la tabla 4.49.




Figura 4.50: Gráfica TSNE de agrupación de datos con los mejores 3 atributos estadísticos en los niveles de severidad N-4-5-6 para rayadura en el diente de piñón de CE




Figura 4.51: Gráfica TSNE de agrupación de datos con los mejores 7 atributos estadísticos en los niveles de severidad N-4-5-6 para rayadura en el diente de piñón de CE




Figura 4.52: Gráfica TSNE de agrupación de datos con los mejores 10 atributos estadísticos en los niveles de severidad N-4-5-6 para rayadura en el diente de piñón de CE

GEAR BOX TIME AND FREQUENCY NORMAL 7-8-9 (SCUFFING)											
Combinación de 3 de 10			Combinación de 4 de 10			Combinación de 5 de 10			Combinación de 6 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_1_1"]	1	1	["time.MNML_3_1"]	105	1	["time.MNML_3_1"]	105	1	["time.MNML_3_1"]	105
2	["time.mean_3_1"]	3	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1
3	["time.PL_3_1"]	72	3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3	3	["time.mean_3_1"]	3
			4	["time.if_3_1"]	36	4	["time.PL_3_1"]	72	4	["time.PL_3_1"]	72
						5	["time.if_3_1"]	36	5	["time.VL_3_1"]	192
									6	["time.if_3_1"]	36
Combinación de 7 de 10			Combinación de 8 de 10			Combinación de 9 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.MNML_3_1"]	105	1	["time.MNML_3_1"]	105	1	["time.MNML_3_1"]	105	1	["time.MNML_3_1"]	105
2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1
3	["time.mean_3_1"]	3	3	["time.MDR_3_1"]	78	3	["time.MDR_3_1"]	78	3	["time.MDR_3_1"]	78
4	["time.PL_3_1"]	72	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3
5	["time.VL_3_1"]	192	5	["time.mean_2_1"]	2	5	["time.mean_2_1"]	2	5	["time.mean_2_1"]	2
6	["time.if_2_1"]	35	6	["time.PL_3_1"]	72	6	["time.PL_3_1"]	72	6	["time.MNML_1_1"]	103
7	["time.if_3_1"]	36	7	["time.VL_3_1"]	192	7	["time.VL_3_1"]	192	7	["time.PL_3_1"]	72
			8	["time.if_2_1"]	35	8	["time.if_2_1"]	35	8	["time.VL_3_1"]	192
						9	["time.if_3_1"]	36	9	["time.if_2_1"]	35
									10	["time.if_3_1"]	36

Figura 4.53: Resultados de los mejores atributos estadísticos para el grupo de severidad N-7-8-9 para CE en tiempo y frecuencia para el modo de falla rayadura en piñón

A continuación se muestran las gráficas TSNE de agrupación de datos en las figuras 4.54, 4.55 y 4.56, las cuales corresponden a los resultados de los mejores 3, 7 y 10 atributos mostrados en las tablas de la figura 4.53.




Figura 4.54: Gráfica TSNE de agrupación de datos con los 3 mejores atributos estadísticos en los niveles de severidades N-7-8-9 para rayadura en el diente del piñón de CE




Figura 4.55: Gráfica TSNE de agrupación de datos con los 7 mejores atributos estadísticos en los niveles de severidades N-7-8-9 para rayadura en el diente del piñón de CE




Figura 4.56: Gráfica TSNE de agrupación de datos con los 10 mejores atributos estadísticos en los niveles de severidades N-7-8-9 para rayadura en el diente del piñón de CE

En las gráficas mostradas para el modo de falla de rayadura en piñón, correspondientes a los 3 grupos de severidades se puede apreciar que la agrupación de datos considerando 3 atributos es bastante apropiada, en tanto que para 7 atributos se observa un superposición de datos de clases diferentes. Por otro lado, los grupos para 10 atributos están también apropiados, ver figuras 4.48, 4.52 y 4.56, con la característica adicional de ser los mismos para todos los niveles de severidad, como se aprecia en la tabla de la figura 4.57. Por lo tanto, se van a seleccionar, estos 10 atributos, sombreados de color amarillo, para aplicar el algoritmo LAMDA HAD.

RAYADURA EN PIÑÓN								
N-1-2-3			N-4-5-6			N-7-8-9		
Combinación de 10 de 10			Combinación de 10 de 10			Combinación de 10 de 10		
N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature	N	Time, Frecuencia FFT & PSD	# feature
1	["time.mean_1_1"]	1	1	["time.NNML_3_1"]	105	1	["time.NNML_3_1"]	105
2	["time.NNML_3_1"]	105	2	["time.mean_1_1"]	1	2	["time.mean_1_1"]	1
3	["time.MDR_3_1"]	78	3	["time.MDR_3_1"]	78	3	["time.MDR_3_1"]	78
4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3	4	["time.mean_3_1"]	3
5	["time.NNML_1_1"]	103	5	["time.mean_2_1"]	2	5	["time.mean_2_1"]	2
6	["time.mean_2_1"]	2	6	["time.NNML_1_1"]	103	6	["time.NNML_1_1"]	103
7	["time.PL_3_1"]	72	7	["time.PL_3_1"]	72	7	["time.PL_3_1"]	72
8	["time.WL_3_1"]	132	8	["time.WL_3_1"]	132	8	["time.WL_3_1"]	132
9	["time.if_2_1"]	35	9	["time.if_2_1"]	35	9	["time.if_2_1"]	35
10	["time.sf_2_1"]	32	10	["time.if_3_1"]	36	10	["time.if_3_1"]	36

Figura 4.57: Tablas de resultados de los 10 mejores atributos estadísticos para los 3 grupos de severidades aplicando ANOVA y la métrica *CDbw* para rayadura en CE

### 4.1.3. Resultados en CE con atributos de Wavelets

En la fase de selección de los mejores atributos para CE referentes a la energía de los coeficientes de la descomposición en paquetes de Wavelets, se hicieron pruebas con y sin la aplicación de la correlación de Pearson, previamente a la aplicación de ANOVA y la métrica *CDbw*. Los resultados obtenidos aplicando la correlación de Pearson se muestra en la tabla de la figura 4.58 para los 4 modos de fallas.

BROKEN TOOTH						
N	Severidad N-123	# feature	Severidad N-456	# feature	Severidad N-789	# feature
1	'wavelet.db7_3_1'	3	'wavelet.db7_1_1'	1	'wavelet.db7_3_1'	3
2	'wavelet.db7_1_1'	1	'wavelet.db7_3_1'	3	'wavelet.db7_1_1'	1
3	'wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2
PITTING SPUR						
N	Severidad N-123	# feature	Severidad N-456	# feature	Severidad N-789	# feature
1	'wavelet.db7_1_1'	1	wavelet.db7_3_1'	3	'wavelet.db7_1_1'	1
2	'wavelet.db7_3_1'	3	wavelet.db7_1_1'	1	wavelet.db7_3_1'	3
3	'wavelet.db7_2_1'	2	wavelet.db7_2_1'	2	wavelet.db7_2_1'	2
CRACK SPUR						
N	Severidad N-123	# feature	Severidad N-456	# feature	Severidad N-789	# feature
1	'wavelet.db7_3_1'	3	'wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2
2	'wavelet.db7_2_1'	2	wavelet.db7_3_1'	3	'wavelet.db7_1_1'	1
3	'wavelet.db7_1_1'	1	'wavelet.db7_1_1'	1	'wavelet.db7_3_1'	3
SCUFFING SPUR						
N	Severidad N-123 4-3	# feature	Severidad N-123 4-4	# feature		
1	'wavelet.db7_1_1'	1	'wavelet.db7_1_1'	1		
2	'wavelet.db7_1_2'	4	wavelet.db7_3_1'	3		
3	'wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2		
			'wavelet.db7_1_2'	4		
N	Severidad N-456 5-3	# feature	Severidad N-456 5-4	# feature	Severidad N-456 5-5	# feature
1	'wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2
2	'wavelet.db7_1_1'	1	'wavelet.db7_1_1'	1	wavelet.db7_3_1'	3
3	'wavelet.db7_2_2'	5	wavelet.db7_3_1'	3	'wavelet.db7_1_1'	1
			'wavelet.db7_2_2'	5	'wavelet.db7_2_2'	5
					'wavelet.db7_1_2'	4
N	Severidad N-456 5-3	# feature	Severidad N-456 5-4	# feature	Severidad N-456 5-5	# feature
1	wavelet.db7_2_1'	2	wavelet.db7_2_1'	2	'wavelet.db7_2_1'	2
2	'wavelet.db7_1_1'	1	'wavelet.db7_3_1'	3	'wavelet.db7_3_1'	3
3	'wavelet.db7_2_2'	5	'wavelet.db7_1_1'	1	'wavelet.db7_1_1'	1
			'wavelet.db7_2_2'	5	'wavelet.db7_2_2'	5
					'wavelet.db7_1_2'	4

Figura 4.58: Tabla de resultados de los mejores atributos estadísticos aplicando ANOVA y la métrica  $CD_{bw}$  para los 4 modos de fallos en CE con Wavelets con la correlación de Pearson

En la tabla de la gráfica 4.58 se puede observar que para los modos de falla de diente roto, grieta y picadura en piñon aplicando la correlación de Pearson quedaron solamente 3 atributos no correlacionados para los tres grupos de severidades de cada uno de ellos. En el modo de falla de rayadura en piñon para el grupo de severidad N-1-2-3 quedaron 4 atributos estadísticos, para lo cual

se realizó una combinación de 3 de 4 con la métrica  $CDbw$ . También se puede observar que para el grupo de severidad N-4-5-6 quedaron 5 atributos para lo cual se realizó una combinación de 3 de 5, de 4 de 5 con la métrica  $CDbw$ , de igual manera para el grupo de severidad N-6-7-8.

A continuación se muestran las gráficas mas representativas de los resultados vistos en la tabla 4.58 para cada modo de falla.




Figura 4.59: Gráfica de los mejores 3 atributos estadísticos de Wavelets para los niveles de severidad N-1-2-3 para diente roto en CE, previa aplicación de la correlación de Pearson






Figura 4.60: Gráfica de los mejores 3 atributos estadísticos de Wavelets para los niveles de severidad N-1-2-3 para grieta en el piñón en CE, previa aplicación de la correlación de Pearson




Figura 4.61: Gráfica de los mejores 3 atributos estadísticos de Wavelets para los niveles de severidad N-1-2-3 para rayadura en el diente del piñón en CE, previa aplicación de la correlación de Pearson




Figura 4.62: Gráfica de los mejores atributos estadísticos para N-1-2-3 aplicando ANOVA y la métrica  $CDbw$  para rayadura en piñon en CE con Wavelets con la correlación de Pearson

Las gráficas de las figuras 4.59, 4.60, 4.61 y 4.62 pertenecen a los 3 mejores atributos como resultado de la métrica  $CDbw$  para los 4 modos de fallas, los grupos de datos no se encuentran apropiadamente agrupados uno de los otros. Debido a que el algoritmo **LAMDAHAD** esta basado en agrupamiento, no es posible aplicarlo a estos resultados.

Para el caso de los resultados de la prueba ANOVA y la métrica  $CDbw$  para CE con Wavelets sin aplicar la correlación de Pearson, se eligieron 10 de los mejores atributos estadísticos, para cada grado de severidad en los 4 modos de fallos, como se muestra en la tabla de la figura 4.63.

BROKEN TOOTH						
N	Severidad N-123	#feature	Severidad N-456	#feature	Severidad N-789	#feature
1	wavelet.coif4_3_6'	114	wavelet.sym5_1_9'	73	wavelet.sym5_1_9'	73
2	wavelet.rbior68_3_6'	210	wavelet.db7_1_9'	25	wavelet.db7_1_9'	25
3	wavelet.db7_3_6'	18	wavelet.rbior68_3_9'	217	wavelet.rbior68_3_9'	217
4	wavelet.bior68_3_6'	162	wavelet.bior68_1_9'	169	wavelet.bior68_1_9'	169
5	wavelet.coif4_1_12'	130	wavelet.coif4_1_9'	121	wavelet.coif4_1_9'	121
6	wavelet.bior68_2_6'	161	wavelet.coif4_3_6'	114	wavelet.coif4_3_6'	114
7	wavelet.coif4_2_6'	113	wavelet.coif4_1_8'	118	wavelet.coif4_1_8'	118
8	wavelet.db7_2_6'	17	wavelet.db7_1_8'	22	wavelet.db7_1_8'	22
9	wavelet.sym5_2_6'	65	wavelet.rbior68_1_8'	214	wavelet.rbior68_1_8'	214
10	wavelet.rbior68_2_6'	209	wavelet.bior68_1_8'	166	wavelet.bior68_1_8'	166

PITTING SPUR						
N	Severidad N-123	#feature	Severidad N-456	#feature	Severidad N-789	#feature
1	wavelet.coif4_3_6'	114	wavelet.rbior68_1_12'	226	wavelet.rbior68_1_12'	226
2	wavelet.rbior68_3_6'	210	wavelet.coif4_1_12'	130	wavelet.coif4_1_12'	130
3	wavelet.rbior68_1_12'	226	wavelet.coif4_3_6'	114	wavelet.coif4_3_6'	114
4	wavelet.db7_1_12'	34	wavelet.rbior68_3_6'	210	wavelet.rbior68_3_6'	210
5	wavelet.db7_3_6'	18	wavelet.db7_3_6'	18	wavelet.db7_3_6'	18
6	wavelet.coif4_1_12'	130	wavelet.rbior68_1_13'	229	wavelet.rbior68_1_13'	229
7	wavelet.bior68_3_6'	162	wavelet.db7_3_6'	162	wavelet.db7_3_6'	162
8	wavelet.bior68_1_12'	178	wavelet.bior68_3_11'	177	wavelet.bior68_3_11'	177
9	wavelet.bior68_2_6'	161	wavelet.coif4_3_11'	129	wavelet.coif4_3_11'	129
10	wavelet.db7_2_6'	17	wavelet.db7_3_11'	33	wavelet.db7_3_11'	33

CRACK SPUR						
N	Severidad N-123	#feature	Severidad N-456	#feature	Severidad N-789	#feature
1	wavelet.bior68_1_1'	145	wavelet.coif4_2_1'	98	wavelet.coif4_2_1'	98
2	wavelet.coif4_1_1'	97	wavelet.bior68_1_1'	145	wavelet.bior68_1_1'	145
3	wavelet.coif4_1_1'	1	wavelet.coif4_1_1'	97	wavelet.coif4_1_1'	97
4	wavelet.sym5_1_1'	49	wavelet.coif4_1_1'	1	wavelet.coif4_1_1'	1
5	wavelet.rbior68_1_1'	193	wavelet.sym5_1_1'	49	wavelet.sym5_1_1'	49
6	wavelet.rbior68_2_3'	200	wavelet.rbior68_1_1'	193	wavelet.rbior68_1_1'	193
7	wavelet.sym5_2_3'	56	wavelet.bior68_2_3'	200	wavelet.rbior68_2_3'	200
8	wavelet.db7_2_3'	8	wavelet.sym5_2_3'	56	wavelet.sym5_2_3'	56
9	wavelet.coif4_2_3'	104	wavelet.db7_2_3'	8	wavelet.db7_2_3'	8
10	wavelet.bior68_2_3'	152	wavelet.coif4_2_3'	104	wavelet.coif4_2_3'	104

SCUFFING SPUR						
N	Severidad N-123	#feature	Severidad N-456	#feature	Severidad N-789	#feature
1	wavelet.coif4_1_12'	130	wavelet.coif4_1_12'	130	wavelet.coif4_1_12'	130
2	wavelet.rbior68_1_12'	226	wavelet.rbior68_1_12'	226	wavelet.rbior68_1_12'	226
3	wavelet.db7_1_12'	34	wavelet.db7_1_12'	34	wavelet.db7_1_12'	34
4	wavelet.bior68_1_12'	178	wavelet.bior68_1_12'	178	wavelet.bior68_1_12'	178
5	wavelet.coif4_3_6'	114	wavelet.coif4_3_6'	114	wavelet.coif4_3_6'	114
6	wavelet.bior68_3_6'	162	wavelet.bior68_3_6'	162	wavelet.bior68_3_6'	162
7	wavelet.db7_3_6'	18	wavelet.db7_3_6'	18	wavelet.db7_3_6'	18
8	wavelet.rbior68_3_6'	210	wavelet.rbior68_3_6'	210	wavelet.rbior68_3_6'	210
9	wavelet.sym5_1_12'	82	wavelet.sym5_1_12'	82	wavelet.sym5_1_12'	82
10	wavelet.bior68_2_6'	161	wavelet.bior68_2_6'	161	wavelet.bior68_2_6'	161

Figura 4.63: Tabla de resultados de los 10 mejores atributos estadísticos para los 4 modos de fallos en CE con Wavelets sin la correlación de Pearson

A continuación se muestran las gráficas de visualización de los grupos de datos usando TSNE, de los de los resultados mostrados en la tabla de la figura 4.63.




Figura 4.64: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para diente roto de piñon en CE, sin aplicar correlación de Pearson




Figura 4.65: Gráfica TSNE de los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para diente roto de piñon en CE, sin aplicar correlación de Pearson




Figura 4.66: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para diente roto de piñon en CE, sin aplicar correlación de Pearson




Figura 4.67: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para grieta en diente del piñon de CE, sin aplicar correlación de Pearson




Figura 4.68: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para grieta en diente del piñon de CE, sin aplicar correlación de Pearson




Figura 4.69: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para grieta en diente del piñon de CE, sin aplicar correlación de Pearson




Figura 4.70: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para picadura de diente en el piñon de CE, sin aplicar la correlación de Pearson




Figura 4.71: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para picadura de diente en el piñón de CE, sin aplicar la correlación de Pearson




Figura 4.72: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para picadura de diente en el piñón de CE, sin aplicar la correlación de Pearson






Figura 4.73: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-1-2-3 para rayadura en el diente de piñón de CE, sin aplicar la correlación de Pearson




Figura 4.74: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-4-5-6 para rayadura en el diente de piñón de CE, sin aplicar la correlación de Pearson




Figura 4.75: Gráfica TSNE usando los 10 mejores atributos de Wavelets en los niveles de severidad N-7-8-9 para rayadura en el diente de piñón de CE, sin aplicar la correlación de Pearson

Como se puede observar de estos resultados, para los 10 mejores atributos para cada grupo de severidad y para los 4 modos de fallos, no se obtuvo una buena agrupación y separación de los grupos de datos, por tal motivo no van a ser considerados para trabajar con el algoritmo [LAMDA HAD](#).

Se concluye entonces, de la fase de selección de atributos extraídos de los coeficientes de la descomposición de Wavelets, que:

1. Usando la correlación de Pearson, la mayor parte de los atributos presentan una alta correlación entre sí, y los grupos de datos no son compactos ni separables.
2. Usando los mejores 10 atributos según el análisis [ANOVA](#), tampoco se obtiene una apropiada agrupación de datos por nivel de severidad.
3. Por lo expuesto, el algoritmo [LAMDA HAD](#) no se va a aplicar para estos atributos.

## 4.2. Análisis de resultados de la aplicación del algoritmo LAMDA HAD en compresores recíprocos y cajas de engranajes

En esta sección se presentan los resultados de clasificación de fallos en las maquinarias rotativas bajo estudio, una vez seleccionados los atributos más informativos de cada caso. Los análisis consideraron la variación del parámetro  $\alpha$  ajustable en la ecuación (2.34) de la sección 2.5.1. Para ello se usaron los datos de prueba de cada clase considerada en el entrenamiento, y el rendimiento se valoró de acuerdo a la precisión en la clasificación.

Posteriormente, y específicamente en el caso de cajas de engranaje, donde se ajustaron clasificadores por grupos de severidades, se evaluó la capacidad de cada clasificador de asignar a las clases  $NIC_k$  a las muestras de fallas diferentes a las usadas en el entrenamiento. Adicionalmente, se valoró también esta capacidad, a través de la comparación del valor de los GAD calculados con cada clasificador. Este análisis permitió concluir acerca de las debilidades detectadas en el algoritmo LAMDA HAD para los casos de estudio de este trabajo.

### 4.2.1. Resultados de la clasificación de fallos en CR

En las pruebas realizadas con CR con los atributos de la combinación de 3 de 10 mostrados en la tabla de la figura 4.1 en el algoritmo LAMDA HAD se obtuvieron valores de precisión del clasificador, como se muestra en la tabla de la figura 4.76. Se observa que los valores de precisión del clasificador fueron más altos cuando se usó un alfa de 0.3 a 0.7, siendo estos los sombreados de color amarillo. Como ejemplo, esto se mostró en la figura 3.20, de prueba de entrenamiento 3.21 y la matriz de confusión 3.22 cuando se usó un alfa de 0.3, en el capítulo 3.

Alfa	Exactitud Test_Train
Alfa 0	0,7
Alfa 0.1	0,8
Alfa 0.2	0,8
Alfa 0.3	0,9
Alfa 0.4	0,9
Alfa 0.5	0,9
Alfa 0.6	0,9
Alfa 0.7	0,9
Alfa 0.8	0,85
Alfa 0.9	0,85
Alfa 1	0,85

Figura 4.76: Tabla de resultados de exactitud del clasificador LAMDA HAD en CR

#### 4.2.2. Resultados de la clasificación de fallos en CE

En los experimentos realizadas en CE se obtuvo varias tablas de resultados que indican los valores de precisión del clasificador para los 4 modos de fallas con los 3 grupos de severidades usando de 3 hasta 10 atributos estadísticos. A continuación se presentan varias tablas de resultados para cada modo de falla.

##### **Modo de falla: Diente roto en piñon**

En la gráfica de la figura 4.77 se muestran las tablas de resultados para los 3 grupos de severidades con 3 atributos estadísticos para el modo de falla de diente roto en piñon.

N-1-2-3-3features			N-4-5-6-3features			N-7-8-9-3features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	35,83%	66,11%	Alfa 0	45,00%	5,56%	Alfa 0	61,67%	2,78%
Alfa 0.1	45,83%	59,44%	Alfa 0.1	46,67%	2,78%	Alfa 0.1	62,50%	0,56%
Alfa 0.2	50,83%	41,11%	Alfa 0.2	46,67%	1,11%	Alfa 0.2	62,50%	0,00%
Alfa 0.3	55,83%	24,44%	Alfa 0.3	46,67%	0,56%	Alfa 0.3	62,50%	0,00%
Alfa 0.4	56,67%	18,89%	Alfa 0.4	47,50%	0,00%	Alfa 0.4	62,50%	0,00%
Alfa 0.5	55,83%	12,78%	Alfa 0.5	47,50%	0,00%	Alfa 0.5	61,67%	0,00%
Alfa 0.6	54,17%	12,22%	Alfa 0.6	47,50%	1,11%	Alfa 0.6	61,67%	0,00%
Alfa 0.7	54,17%	8,89%	Alfa 0.7	45,83%	1,11%	Alfa 0.7	62,50%	0,00%
Alfa 0.8	51,67%	9,44%	Alfa 0.8	45,83%	1,11%	Alfa 0.8	62,50%	0,00%
Alfa 0.9	51,67%	7,78%	Alfa 0.9	45,83%	1,11%	Alfa 0.9	63,33%	0,00%
Alfa 1	31,67%	3,89%	Alfa 1	46,67%	1,11%	Alfa 1	64,17%	6,11%

Figura 4.77: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.78 se muestran las tablas de resultados para los 3 grupos de severidades con 4 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3-4features			N-4-5-6-4features			N-7-8-9-4features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	41,67%	23,89%	Alfa 0	56,67%	0,00%	Alfa 0	50,00%	12,78%
Alfa 0.1	42,50%	21,67%	Alfa 0.1	58,33%	0,00%	Alfa 0.1	49,17%	11,11%
Alfa 0.2	45,00%	22,78%	Alfa 0.2	58,33%	0,00%	Alfa 0.2	48,33%	9,44%
Alfa 0.3	45,00%	21,67%	Alfa 0.3	55,83%	0,00%	Alfa 0.3	49,17%	9,44%
Alfa 0.4	47,50%	20,56%	Alfa 0.4	57,50%	0,00%	Alfa 0.4	49,17%	8,89%
Alfa 0.5	47,50%	20,00%	Alfa 0.5	57,50%	0,00%	Alfa 0.5	55,00%	9,44%
Alfa 0.6	49,17%	16,11%	Alfa 0.6	60,83%	0,00%	Alfa 0.6	65,00%	7,78%
Alfa 0.7	50,83%	13,33%	Alfa 0.7	68,33%	0,00%	Alfa 0.7	63,33%	5,56%
Alfa 0.8	54,17%	11,11%	Alfa 0.8	63,33%	1,11%	Alfa 0.8	62,50%	3,89%
Alfa 0.9	40,00%	7,22%	Alfa 0.9	62,50%	1,11%	Alfa 0.9	60,00%	3,33%
Alfa 1	31,67%	3,89%	Alfa 1	61,67%	1,11%	Alfa 1	60,00%	10,00%

Figura 4.78: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.79 se muestran las tablas de resultados para los 3 grupos de severidades con 5 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3-5features			N-4-5-6-5features			N-7-8-9-5features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	33,33%	18,89%	Alfa 0	53,33%	0,00%	Alfa 0	50,00%	12,78%
Alfa 0.1	35,83%	18,89%	Alfa 0.1	55,83%	0,00%	Alfa 0.1	49,17%	11,11%
Alfa 0.2	35,83%	18,33%	Alfa 0.2	55,83%	0,00%	Alfa 0.2	48,33%	9,44%
Alfa 0.3	40,00%	19,44%	Alfa 0.3	56,67%	0,00%	Alfa 0.3	49,17%	9,44%
Alfa 0.4	45,00%	18,33%	Alfa 0.4	55,83%	0,00%	Alfa 0.4	49,17%	8,89%
Alfa 0.5	46,67%	17,78%	Alfa 0.5	58,33%	0,00%	Alfa 0.5	55,00%	0,00%
Alfa 0.6	46,67%	16,11%	Alfa 0.6	61,67%	0,00%	Alfa 0.6	65,00%	0,00%
Alfa 0.7	49,17%	12,22%	Alfa 0.7	70,00%	0,00%	Alfa 0.7	63,33%	5,56%
Alfa 0.8	47,50%	8,33%	Alfa 0.8	65,83%	1,11%	Alfa 0.8	62,50%	3,89%
Alfa 0.9	43,33%	6,11%	Alfa 0.9	64,17%	1,11%	Alfa 0.9	60,00%	3,33%
Alfa 1	31,67%	3,89%	Alfa 1	62,50%	1,11%	Alfa 1	60,00%	10,00%

Figura 4.79: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.80 se muestran las tablas de resultados para los 3 grupos de severidades con 6 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3-6features			N-4-5-6-6features			N-7-8-9-6features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	31,67%	19,44%	Alfa 0	55,00%	4,44%	Alfa 0	40,00%	10,00%
Alfa 0.1	33,33%	21,11%	Alfa 0.1	52,50%	7,22%	Alfa 0.1	40,00%	10,00%
Alfa 0.2	26,67%	17,78%	Alfa 0.2	55,00%	7,22%	Alfa 0.2	40,83%	7,78%
Alfa 0.3	36,67%	14,44%	Alfa 0.3	55,00%	8,89%	Alfa 0.3	41,67%	7,22%
Alfa 0.4	39,17%	11,11%	Alfa 0.4	52,50%	11,67%	Alfa 0.4	40,00%	5,56%
Alfa 0.5	37,50%	6,67%	Alfa 0.5	49,17%	14,44%	Alfa 0.5	38,33%	3,33%
Alfa 0.6	36,67%	1,11%	Alfa 0.6	52,50%	17,78%	Alfa 0.6	40,83%	2,22%
Alfa 0.7	38,33%	0,00%	Alfa 0.7	62,50%	16,67%	Alfa 0.7	45,00%	1,67%
Alfa 0.8	40,00%	0,00%	Alfa 0.8	64,17%	16,11%	Alfa 0.8	47,50%	1,67%
Alfa 0.9	49,17%	0,00%	Alfa 0.9	63,33%	14,44%	Alfa 0.9	48,33%	2,22%
Alfa 1	50,83%	0,00%	Alfa 1	60,83%	16,67%	Alfa 1	49,17%	2,22%

Figura 4.80: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.81 se muestran las tablas de resultados para los 3 grupos de severidades con 7 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3--7features			N-4-5-6--7features			N-7-8-9--7features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	31,67%	19,44%	Alfa 0	55,00%	4,44%	Alfa 0	38,33%	9,44%
Alfa 0.1	33,33%	21,11%	Alfa 0.1	52,50%	7,78%	Alfa 0.1	40,00%	10,00%
Alfa 0.2	26,67%	17,22%	Alfa 0.2	55,00%	7,22%	Alfa 0.2	40,83%	7,78%
Alfa 0.3	37,50%	14,44%	Alfa 0.3	55,00%	8,33%	Alfa 0.3	41,67%	7,22%
Alfa 0.4	37,50%	11,11%	Alfa 0.4	53,33%	11,67%	Alfa 0.4	40,00%	5,56%
Alfa 0.5	38,33%	6,67%	Alfa 0.5	49,17%	13,89%	Alfa 0.5	38,33%	3,33%
Alfa 0.6	36,67%	1,11%	Alfa 0.6	52,50%	17,22%	Alfa 0.6	40,83%	2,22%
Alfa 0.7	38,33%	0,00%	Alfa 0.7	62,50%	17,22%	Alfa 0.7	45,00%	1,67%
Alfa 0.8	40,83%	0,00%	Alfa 0.8	63,33%	16,11%	Alfa 0.8	47,50%	1,67%
Alfa 0.9	48,33%	0,00%	Alfa 0.9	63,33%	14,44%	Alfa 0.9	48,33%	2,22%
Alfa 1	50,83%	0,00%	Alfa 1	60,83%	17,22%	Alfa 1	49,17%	2,22%

Figura 4.81: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.82 se muestran las tablas de resultados para los 3 grupos de severidades con 8 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3--8features			N-4-5-6--8features			N-7-8-9--8features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	31,67%	19,44%	Alfa 0	55,00%	4,44%	Alfa 0	38,33%	9,44%
Alfa 0.1	33,33%	21,11%	Alfa 0.1	52,50%	7,78%	Alfa 0.1	40,00%	10,00%
Alfa 0.2	26,67%	17,22%	Alfa 0.2	55,00%	7,78%	Alfa 0.2	40,83%	7,78%
Alfa 0.3	37,50%	14,44%	Alfa 0.3	55,00%	8,89%	Alfa 0.3	41,67%	7,22%
Alfa 0.4	37,50%	11,11%	Alfa 0.4	53,33%	12,22%	Alfa 0.4	40,00%	6,11%
Alfa 0.5	38,33%	6,67%	Alfa 0.5	49,17%	13,89%	Alfa 0.5	39,17%	3,89%
Alfa 0.6	36,67%	1,11%	Alfa 0.6	52,50%	17,22%	Alfa 0.6	43,33%	2,22%
Alfa 0.7	38,33%	0,00%	Alfa 0.7	62,50%	17,22%	Alfa 0.7	45,00%	1,67%
Alfa 0.8	40,83%	0,00%	Alfa 0.8	63,33%	16,11%	Alfa 0.8	47,50%	1,67%
Alfa 0.9	48,33%	0,00%	Alfa 0.9	63,33%	14,44%	Alfa 0.9	47,50%	2,22%
Alfa 1	50,83%	0,00%	Alfa 1	60,83%	17,22%	Alfa 1	49,17%	2,22%

Figura 4.82: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.83 se muestran las tablas de resultados para los 3 grupos de severidades con 9 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3-9features			N-4-5-6-9features			N-7-8-9-9features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	31,67%	19,44%	Alfa 0	55,00%	4,44%	Alfa 0	38,33%	9,44%
Alfa 0.1	33,33%	21,11%	Alfa 0.1	52,50%	7,78%	Alfa 0.1	40,00%	10,00%
Alfa 0.2	26,67%	17,22%	Alfa 0.2	55,00%	7,78%	Alfa 0.2	40,83%	7,78%
Alfa 0.3	37,50%	14,44%	Alfa 0.3	55,00%	8,89%	Alfa 0.3	41,67%	7,22%
Alfa 0.4	37,50%	11,11%	Alfa 0.4	53,33%	12,22%	Alfa 0.4	40,00%	6,11%
Alfa 0.5	38,33%	6,67%	Alfa 0.5	49,17%	13,89%	Alfa 0.5	39,17%	3,89%
Alfa 0.6	36,67%	1,11%	Alfa 0.6	52,50%	17,78%	Alfa 0.6	40,83%	2,22%
Alfa 0.7	38,33%	0,00%	Alfa 0.7	62,50%	17,22%	Alfa 0.7	45,00%	1,67%
Alfa 0.8	40,83%	0,00%	Alfa 0.8	63,33%	16,11%	Alfa 0.8	47,50%	1,67%
Alfa 0.9	48,33%	0,00%	Alfa 0.9	63,33%	14,44%	Alfa 0.9	48,33%	2,22%
Alfa 1	50,83%	0,00%	Alfa 1	60,83%	17,22%	Alfa 1	49,17%	2,22%

Figura 4.83: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla diente roto en piñón

En la gráfica de la figura 4.84 se muestran las tablas de resultados para los 3 grupos de severidades con 10 atributos estadísticos para el modo de falla de diente roto en piñón.

N-1-2-3-10features			N-4-5-6-10features			N-7-8-9-10features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	31,67%	19,44%	Alfa 0	55,00%	4,44%	Alfa 0	38,33%	9,44%
Alfa 0.1	33,33%	21,11%	Alfa 0.1	52,50%	7,78%	Alfa 0.1	40,00%	10,00%
Alfa 0.2	26,67%	17,22%	Alfa 0.2	55,00%	7,78%	Alfa 0.2	40,83%	7,78%
Alfa 0.3	37,50%	14,44%	Alfa 0.3	55,00%	8,89%	Alfa 0.3	41,67%	7,22%
Alfa 0.4	37,50%	11,11%	Alfa 0.4	52,50%	12,22%	Alfa 0.4	40,00%	6,11%
Alfa 0.5	38,33%	6,67%	Alfa 0.5	49,17%	13,89%	Alfa 0.5	39,17%	3,89%
Alfa 0.6	36,67%	1,11%	Alfa 0.6	52,50%	17,78%	Alfa 0.6	41,67%	2,78%
Alfa 0.7	38,33%	0,00%	Alfa 0.7	60,83%	17,22%	Alfa 0.7	45,00%	2,22%
Alfa 0.8	40,83%	0,00%	Alfa 0.8	63,33%	16,11%	Alfa 0.8	47,50%	2,78%
Alfa 0.9	48,33%	0,00%	Alfa 0.9	63,33%	14,44%	Alfa 0.9	48,33%	2,22%
Alfa 1	50,83%	0,00%	Alfa 1	60,83%	17,22%	Alfa 1	49,17%	2,22%

Figura 4.84: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 10 atributos estadísticos para el modo de falla diente roto en piñón

Se concluye que el uso de las señales de corriente para la detección de severidad de fallo de diente roto en piñón no es apropiado, obteniéndose apenas un 70% de precisión usando 5 atributos, solo en el grupo de severidades N-4-5-6, para las muestras de las clases de entrenamiento. Se observa que para las muestras de fallas no usadas en el entrenamiento, el clasificador no tiene la capacidad de asignarlas a las clases  $NIC_k$ .



**Modo de falla: Grieta en piñon**

En la gráfica de la figura 4.85 se muestran las tablas de resultados para los 3 grupos de severidades con 3 atributos estadísticos para el modo de falla de grieta en piñon.

N-1-2-3--3features			N-4-5-6--3features			N-7-8-9--3features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	82,50%	11,11%	Alfa 0	63,33%	27,78%	Alfa 0	41,67%	7,78%
Alfa 0.1	81,67%	11,67%	Alfa 0.1	65,83%	28,33%	Alfa 0.1	50,00%	7,78%
Alfa 0.2	85,00%	14,44%	Alfa 0.2	78,33%	19,44%	Alfa 0.2	61,67%	5,00%
Alfa 0.3	86,67%	15,56%	Alfa 0.3	86,67%	17,78%	Alfa 0.3	67,50%	5,56%
Alfa 0.4	87,50%	10,56%	Alfa 0.4	89,17%	17,78%	Alfa 0.4	77,50%	5,00%
Alfa 0.5	85,83%	5,56%	Alfa 0.5	88,33%	21,67%	Alfa 0.5	86,67%	1,11%
Alfa 0.6	85,00%	3,33%	Alfa 0.6	85,00%	19,44%	Alfa 0.6	90,83%	0,00%
Alfa 0.7	83,33%	2,78%	Alfa 0.7	79,17%	22,78%	Alfa 0.7	90,83%	0,00%
Alfa 0.8	82,50%	1,67%	Alfa 0.8	77,50%	23,89%	Alfa 0.8	89,17%	0,00%
Alfa 0.9	80,83%	0,00%	Alfa 0.9	76,67%	24,44%	Alfa 0.9	85,83%	0,00%
Alfa 1	80,83%	0,00%	Alfa 1	78,33%	18,89%	Alfa 1	85,83%	0,00%

Figura 4.85: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla grieta en piñon

En la gráfica de la figura 4.86 se muestran las tablas de resultados para los 3 grupos de severidades con 4 atributos estadísticos para el modo de falla de grieta en piñon.

N-1-2-3--4features			N-4-5-6--4features			N-7-8-9--4features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	74,17%	0,00%	Alfa 0	74,17%	3,89%	Alfa 0	57,50%	0,56%
Alfa 0.1	75,00%	0,00%	Alfa 0.1	75,00%	2,22%	Alfa 0.1	57,50%	0,00%
Alfa 0.2	76,67%	0,00%	Alfa 0.2	76,67%	0,00%	Alfa 0.2	57,50%	0,00%
Alfa 0.3	75,83%	0,00%	Alfa 0.3	76,67%	0,00%	Alfa 0.3	58,33%	0,00%
Alfa 0.4	76,67%	0,00%	Alfa 0.4	76,67%	0,00%	Alfa 0.4	58,33%	0,00%
Alfa 0.5	76,67%	0,00%	Alfa 0.5	75,83%	0,00%	Alfa 0.5	58,33%	0,00%
Alfa 0.6	77,50%	0,00%	Alfa 0.6	73,33%	0,00%	Alfa 0.6	60,83%	0,00%
Alfa 0.7	78,33%	0,00%	Alfa 0.7	75,83%	0,00%	Alfa 0.7	60,83%	0,00%
Alfa 0.8	80,83%	0,00%	Alfa 0.8	75,83%	0,00%	Alfa 0.8	61,67%	0,00%
Alfa 0.9	82,50%	0,00%	Alfa 0.9	75,83%	0,00%	Alfa 0.9	62,50%	2,78%
Alfa 1	83,33%	0,00%	Alfa 1	75,83%	0,00%	Alfa 1	64,17%	5,56%

Figura 4.86: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla grieta en piñon

En la gráfica de la figura 4.87 se muestran las tablas de resultados para los 3 grupos de severidades con 5 atributos estadísticos para el modo de falla de grieta

en piñon.

N-1-2-3-5features			N-4-5-6-5features			N-7-8-9-5features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	79,17%	0,00%	Alfa 0	75,00%	0,00%	Alfa 0	60,00%	3,33%
Alfa 0.1	80,00%	0,00%	Alfa 0.1	75,83%	0,00%	Alfa 0.1	60,83%	0,00%
Alfa 0.2	80,00%	0,00%	Alfa 0.2	77,50%	0,00%	Alfa 0.2	60,83%	0,00%
Alfa 0.3	80,00%	0,00%	Alfa 0.3	77,50%	0,00%	Alfa 0.3	60,83%	0,00%
Alfa 0.4	79,17%	0,00%	Alfa 0.4	77,50%	0,00%	Alfa 0.4	61,67%	0,00%
Alfa 0.5	79,17%	0,00%	Alfa 0.5	79,17%	0,00%	Alfa 0.5	61,67%	0,00%
Alfa 0.6	79,17%	0,00%	Alfa 0.6	77,50%	0,00%	Alfa 0.6	62,50%	0,56%
Alfa 0.7	78,33%	0,00%	Alfa 0.7	74,17%	0,00%	Alfa 0.7	62,50%	2,22%
Alfa 0.8	80,00%	0,00%	Alfa 0.8	75,00%	0,00%	Alfa 0.8	61,67%	3,89%
Alfa 0.9	82,50%	0,00%	Alfa 0.9	75,83%	0,00%	Alfa 0.9	62,50%	3,89%
Alfa 1	81,67%	0,00%	Alfa 1	75,83%	0,00%	Alfa 1	64,17%	5,56%

Figura 4.87: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla grieta en piñon

En la gráfica de la figura 4.88 se muestran las tablas de resultados para los 3 grupos de severidades con 6 atributos estadísticos para el modo de falla de grieta en piñon.

N-1-2-3-6features			N-4-5-6-6features			N-7-8-9-6features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	77,50%	4,44%	Alfa 0	75,00%	0,00%	Alfa 0	55,00%	21,67%
Alfa 0.1	84,17%	1,67%	Alfa 0.1	76,67%	0,00%	Alfa 0.1	57,50%	11,67%
Alfa 0.2	85,83%	0,00%	Alfa 0.2	77,50%	0,00%	Alfa 0.2	63,33%	7,22%
Alfa 0.3	86,67%	0,00%	Alfa 0.3	77,50%	0,00%	Alfa 0.3	65,00%	5,00%
Alfa 0.4	86,67%	0,00%	Alfa 0.4	80,00%	0,00%	Alfa 0.4	65,00%	5,00%
Alfa 0.5	87,50%	0,00%	Alfa 0.5	80,83%	0,00%	Alfa 0.5	65,00%	6,11%
Alfa 0.6	86,67%	0,00%	Alfa 0.6	78,33%	0,00%	Alfa 0.6	65,00%	7,22%
Alfa 0.7	85,83%	0,00%	Alfa 0.7	75,83%	0,00%	Alfa 0.7	65,00%	7,22%
Alfa 0.8	86,67%	0,00%	Alfa 0.8	75,00%	0,00%	Alfa 0.8	65,83%	6,67%
Alfa 0.9	85,83%	0,00%	Alfa 0.9	75,83%	0,00%	Alfa 0.9	64,17%	6,11%
Alfa 1	83,33%	0,00%	Alfa 1	78,33%	0,00%	Alfa 1	64,17%	6,11%

Figura 4.88: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla grieta en piñon

En la gráfica de la figura 4.89 se muestran las tablas de resultados para los 3 grupos de severidades con 7 atributos estadísticos para el modo de falla de grieta en piñon.

N-1-2-3--7features			N-4-5-6--7features			N-7-8-9--7features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	78,33%	9,44%	Alfa 0	79,17%	0,00%	Alfa 0	58,33%	13,89%
Alfa 0.1	83,33%	8,89%	Alfa 0.1	80,83%	0,00%	Alfa 0.1	66,67%	10,56%
Alfa 0.2	85,00%	7,22%	Alfa 0.2	81,67%	0,00%	Alfa 0.2	70,83%	9,44%
Alfa 0.3	84,17%	5,56%	Alfa 0.3	83,33%	0,00%	Alfa 0.3	80,00%	8,33%
Alfa 0.4	85,00%	4,44%	Alfa 0.4	84,17%	0,00%	Alfa 0.4	85,83%	7,22%
Alfa 0.5	87,50%	0,00%	Alfa 0.5	84,17%	0,00%	Alfa 0.5	87,50%	7,22%
Alfa 0.6	87,50%	0,56%	Alfa 0.6	83,33%	0,00%	Alfa 0.6	87,50%	6,67%
Alfa 0.7	87,50%	0,56%	Alfa 0.7	84,17%	0,00%	Alfa 0.7	87,50%	3,89%
Alfa 0.8	87,50%	1,11%	Alfa 0.8	80,00%	2,78%	Alfa 0.8	88,33%	0,56%
Alfa 0.9	87,50%	3,89%	Alfa 0.9	80,00%	4,44%	Alfa 0.9	88,33%	0,00%
Alfa 1	87,50%	3,89%	Alfa 1	80,00%	6,67%	Alfa 1	87,50%	1,67%

Figura 4.89: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla grieta en piñon

En la gráfica de la figura 4.90 se muestran las tablas de resultados para los 3 grupos de severidades con 8 atributos estadísticos para el modo de falla de grieta en piñon.

N-1-2-3--8features			N-4-5-6--8features			N-7-8-9--8features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	78,33%	9,44%	Alfa 0	79,17%	0,00%	Alfa 0	57,50%	13,89%
Alfa 0.1	83,33%	8,33%	Alfa 0.1	80,00%	0,00%	Alfa 0.1	66,67%	10,56%
Alfa 0.2	85,00%	6,67%	Alfa 0.2	81,67%	0,00%	Alfa 0.2	70,83%	9,44%
Alfa 0.3	84,17%	5,56%	Alfa 0.3	83,33%	0,00%	Alfa 0.3	80,00%	8,33%
Alfa 0.4	85,83%	5,00%	Alfa 0.4	84,17%	0,00%	Alfa 0.4	85,83%	7,22%
Alfa 0.5	85,83%	0,56%	Alfa 0.5	84,17%	0,00%	Alfa 0.5	87,50%	7,22%
Alfa 0.6	88,33%	0,56%	Alfa 0.6	85,00%	0,00%	Alfa 0.6	87,50%	6,67%
Alfa 0.7	87,50%	0,56%	Alfa 0.7	85,83%	0,00%	Alfa 0.7	87,50%	3,33%
Alfa 0.8	87,50%	0,56%	Alfa 0.8	80,83%	2,78%	Alfa 0.8	88,33%	0,56%
Alfa 0.9	87,50%	2,78%	Alfa 0.9	80,83%	4,44%	Alfa 0.9	88,33%	0,00%
Alfa 1	87,50%	3,89%	Alfa 1	80,00%	6,67%	Alfa 1	87,50%	1,11%

Figura 4.90: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla grieta en piñon

En la gráfica de la figura 4.91 se muestran las tablas de resultados para los 3 grupos de severidades con 9 atributos estadísticos para el modo de falla de grieta en piñon.

N-1-2-3-9features			N-4-5-6-9features			N-7-8-9-9features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	55,00%	18,33%	Alfa 0	73,33%	8,89%	Alfa 0	53,33%	16,67%
Alfa 0.1	65,83%	17,22%	Alfa 0.1	80,83%	6,67%	Alfa 0.1	65,00%	11,67%
Alfa 0.2	75,00%	13,89%	Alfa 0.2	82,50%	2,22%	Alfa 0.2	67,50%	10,56%
Alfa 0.3	80,83%	11,67%	Alfa 0.3	85,00%	0,00%	Alfa 0.3	75,83%	8,89%
Alfa 0.4	80,00%	8,89%	Alfa 0.4	86,67%	0,00%	Alfa 0.4	85,00%	7,78%
Alfa 0.5	79,17%	6,11%	Alfa 0.5	86,67%	0,00%	Alfa 0.5	85,00%	6,67%
Alfa 0.6	82,50%	3,33%	Alfa 0.6	90,83%	0,00%	Alfa 0.6	85,83%	3,89%
Alfa 0.7	84,17%	1,67%	Alfa 0.7	89,17%	0,00%	Alfa 0.7	83,33%	0,56%
Alfa 0.8	85,00%	0,00%	Alfa 0.8	86,67%	0,00%	Alfa 0.8	80,83%	0,00%
Alfa 0.9	88,33%	0,00%	Alfa 0.9	85,83%	0,00%	Alfa 0.9	80,00%	0,00%
Alfa 1	86,67%	0,00%	Alfa 1	80,83%	0,56%	Alfa 1	80,83%	0,56%

Figura 4.91: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla grieta en piñón

En la gráfica de la figura 3.28 se muestran las tablas de resultados para los 3 grupos de severidades con 10 atributos estadísticos para el modo de falla de grieta en piñón.

Se concluye que el uso de las señales de corriente para la detección de severidad de fallo grieta en el diente del piñón puede lograr precisiones sobre el 85 %. Específicamente, para el caso de 10 atributos en la figura 3.28, se obtuvo una precisión sobre el 95% para el grupo de severidades N-4-5-6, y sobre el 88% para los otros grupos de severidades. También se observa que el clasificador para el grupo de severidades N-1-2-3 puede enviar poco mas del 21% de las muestras de otros fallos a las clases  $NIC_k$ . Los otro clasificadores no tienen esta habilidad, o es muy baja.

**Modo de falla: Picadura en piñón**

En la gráfica de la figura 4.92 se muestran las tablas de resultados para los 3 grupos de severidades con 3 atributos estadísticos para el modo de falla de picadura en piñón.

N-1-2-3--3features			N-4-5-6--3features			N-7-8-9--3features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	50,83%	11,67%	Alfa 0	51,67%	7,22%	Alfa 0	62,50%	7,22%
Alfa 0.1	54,17%	10,56%	Alfa 0.1	55,00%	8,33%	Alfa 0.1	65,00%	5,00%
Alfa 0.2	55,00%	9,44%	Alfa 0.2	55,83%	8,89%	Alfa 0.2	67,50%	2,22%
Alfa 0.3	55,83%	3,89%	Alfa 0.3	58,33%	9,44%	Alfa 0.3	68,33%	0,00%
Alfa 0.4	58,33%	1,67%	Alfa 0.4	60,00%	10,00%	Alfa 0.4	65,83%	0,00%
Alfa 0.5	58,33%	0,56%	Alfa 0.5	61,67%	7,22%	Alfa 0.5	65,83%	0,00%
Alfa 0.6	60,83%	0,00%	Alfa 0.6	62,50%	6,67%	Alfa 0.6	65,00%	0,00%
Alfa 0.7	60,83%	0,00%	Alfa 0.7	64,17%	6,11%	Alfa 0.7	63,33%	0,00%
Alfa 0.8	59,17%	0,00%	Alfa 0.8	65,00%	6,11%	Alfa 0.8	65,83%	0,00%
Alfa 0.9	56,67%	0,00%	Alfa 0.9	65,83%	6,67%	Alfa 0.9	67,50%	0,00%
Alfa 1	57,50%	0,00%	Alfa 1	64,17%	5,56%	Alfa 1	70,83%	0,00%

Figura 4.92: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla picadura en piñon

En la gráfica de la figura 4.93 se muestran las tablas de resultados para los 3 grupos de severidades con 4 atributos estadísticos para el modo de falla de picadura en piñon.

N-1-2-3--4features			N-4-5-6--4features			N-7-8-9--4features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	48,33%	10,00%	Alfa 0	50,00%	1,67%	Alfa 0	64,17%	0,00%
Alfa 0.1	48,33%	5,56%	Alfa 0.1	49,17%	1,67%	Alfa 0.1	68,33%	0,00%
Alfa 0.2	50,83%	0,56%	Alfa 0.2	51,67%	2,22%	Alfa 0.2	69,17%	0,00%
Alfa 0.3	52,50%	0,00%	Alfa 0.3	51,67%	2,22%	Alfa 0.3	69,17%	0,00%
Alfa 0.4	53,33%	0,00%	Alfa 0.4	53,33%	1,11%	Alfa 0.4	70,00%	0,00%
Alfa 0.5	52,50%	0,00%	Alfa 0.5	59,17%	0,56%	Alfa 0.5	70,83%	0,00%
Alfa 0.6	53,33%	0,00%	Alfa 0.6	65,00%	0,00%	Alfa 0.6	71,67%	0,00%
Alfa 0.7	55,00%	0,00%	Alfa 0.7	64,17%	0,00%	Alfa 0.7	73,33%	0,00%
Alfa 0.8	55,00%	0,00%	Alfa 0.8	63,33%	0,00%	Alfa 0.8	75,00%	0,00%
Alfa 0.9	55,83%	0,00%	Alfa 0.9	61,67%	0,00%	Alfa 0.9	75,00%	0,00%
Alfa 1	55,83%	0,00%	Alfa 1	62,50%	0,56%	Alfa 1	75,00%	0,00%

Figura 4.93: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla picadura en piñon

En la gráfica de la figura 4.94 se muestran las tablas de resultados para los 3 grupos de severidades con 5 atributos estadísticos para el modo de falla de picadura en piñon.

N-1-2-3--5features			N-4-5-6--5features			N-7-8-9--5features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	45,00%	12,22%	Alfa 0	53,33%	3,33%	Alfa 0	61,67%	8,89%
Alfa 0.1	47,50%	10,56%	Alfa 0.1	54,17%	3,33%	Alfa 0.1	65,83%	5,00%
Alfa 0.2	50,83%	8,89%	Alfa 0.2	55,83%	3,33%	Alfa 0.2	70,00%	0,56%
Alfa 0.3	54,17%	4,44%	Alfa 0.3	59,17%	4,44%	Alfa 0.3	70,00%	0,00%
Alfa 0.4	56,67%	2,78%	Alfa 0.4	61,67%	6,11%	Alfa 0.4	70,00%	0,00%
Alfa 0.5	58,33%	1,67%	Alfa 0.5	65,83%	4,44%	Alfa 0.5	70,83%	0,00%
Alfa 0.6	60,83%	0,00%	Alfa 0.6	67,50%	3,89%	Alfa 0.6	71,76%	0,00%
Alfa 0.7	60,83%	0,00%	Alfa 0.7	70,83%	3,33%	Alfa 0.7	72,50%	0,00%
Alfa 0.8	61,67%	0,00%	Alfa 0.8	69,17%	5,00%	Alfa 0.8	74,17%	0,00%
Alfa 0.9	62,50%	0,00%	Alfa 0.9	69,17%	4,44%	Alfa 0.9	75,00%	0,00%
Alfa 1	61,67%	0,00%	Alfa 1	71,67%	5,56%	Alfa 1	75,83%	0,00%

Figura 4.94: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla picadura en piñon

En la gráfica de la figura 4.95 se muestran las tablas de resultados para los 3 grupos de severidades con 6 atributos estadísticos para el modo de falla de picadura en piñon.

N-1-2-3--6features			N-4-5-6--6features			N-7-8-9--6features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	45,83%	13,33%	Alfa 0	54,17%	3,33%	Alfa 0	61,67%	8,89%
Alfa 0.1	46,67%	11,67%	Alfa 0.1	55,83%	3,33%	Alfa 0.1	65,83%	4,44%
Alfa 0.2	50,00%	10,00%	Alfa 0.2	57,50%	3,33%	Alfa 0.2	70,00%	0,56%
Alfa 0.3	52,50%	5,00%	Alfa 0.3	59,17%	4,44%	Alfa 0.3	70,00%	0,00%
Alfa 0.4	55,83%	2,78%	Alfa 0.4	60,00%	6,11%	Alfa 0.4	70,00%	0,00%
Alfa 0.5	58,33%	1,11%	Alfa 0.5	61,67%	4,44%	Alfa 0.5	70,00%	0,00%
Alfa 0.6	60,83%	0,56%	Alfa 0.6	63,33%	4,44%	Alfa 0.6	70,83%	0,00%
Alfa 0.7	60,83%	0,00%	Alfa 0.7	67,50%	3,33%	Alfa 0.7	71,76%	0,00%
Alfa 0.8	61,67%	0,00%	Alfa 0.8	70,00%	4,44%	Alfa 0.8	70,83%	0,00%
Alfa 0.9	62,50%	0,00%	Alfa 0.9	68,33%	4,44%	Alfa 0.9	71,76%	0,00%
Alfa 1	62,50%	0,00%	Alfa 1	70,83%	5,00%	Alfa 1	72,50%	0,00%

Figura 4.95: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla picadura en piñon

En la gráfica de la figura 4.96 se muestran las tablas de resultados para los 3 grupos de severidades con 7 atributos estadísticos para el modo de falla de picadura en piñon.

N-1-2-3--7features			N-4-5-6--7features			N-7-8-9--7features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	43,33%	10,00%	Alfa 0	64,17%	3,89%	Alfa 0	61,67%	16,11%
Alfa 0.1	46,67%	7,78%	Alfa 0.1	68,33%	4,44%	Alfa 0.1	61,67%	13,33%
Alfa 0.2	50,83%	7,78%	Alfa 0.2	72,50%	3,33%	Alfa 0.2	62,50%	3,89%
Alfa 0.3	54,17%	3,89%	Alfa 0.3	75,83%	3,89%	Alfa 0.3	63,33%	0,00%
Alfa 0.4	56,67%	4,44%	Alfa 0.4	76,67%	1,67%	Alfa 0.4	65,83%	0,00%
Alfa 0.5	57,50%	3,33%	Alfa 0.5	76,67%	1,67%	Alfa 0.5	66,67%	0,00%
Alfa 0.6	58,33%	0,56%	Alfa 0.6	77,50%	1,11%	Alfa 0.6	69,17%	0,00%
Alfa 0.7	58,33%	1,11%	Alfa 0.7	76,67%	1,11%	Alfa 0.7	72,50%	0,00%
Alfa 0.8	59,17%	2,78%	Alfa 0.8	75,83%	0,56%	Alfa 0.8	76,67%	0,00%
Alfa 0.9	61,67%	2,78%	Alfa 0.9	75,83%	1,67%	Alfa 0.9	77,50%	0,00%
Alfa 1	62,50%	3,89%	Alfa 1	72,50%	1,67%	Alfa 1	76,67%	0,56%

Figura 4.96: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla picadura en piñon

En la gráfica de la figura 4.97 se muestran las tablas de resultados para los 3 grupos de severidades con 8 atributos estadísticos para el modo de falla de picadura en piñon.

N-1-2-3--8features			N-4-5-6--8features			N-7-8-9--8features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	43,33%	10,00%	Alfa 0	63,33%	3,89%	Alfa 0	60,83%	16,67%
Alfa 0.1	46,67%	7,78%	Alfa 0.1	69,17%	4,44%	Alfa 0.1	61,67%	13,89%
Alfa 0.2	50,83%	7,78%	Alfa 0.2	72,50%	3,33%	Alfa 0.2	62,50%	3,89%
Alfa 0.3	54,17%	3,89%	Alfa 0.3	75,83%	3,89%	Alfa 0.3	61,67%	0,00%
Alfa 0.4	56,67%	4,44%	Alfa 0.4	75,83%	1,67%	Alfa 0.4	65,83%	0,00%
Alfa 0.5	57,50%	2,78%	Alfa 0.5	75,83%	1,67%	Alfa 0.5	66,67%	0,00%
Alfa 0.6	58,33%	0,56%	Alfa 0.6	75,83%	1,11%	Alfa 0.6	68,33%	0,00%
Alfa 0.7	57,50%	1,11%	Alfa 0.7	75,00%	1,11%	Alfa 0.7	70,83%	0,00%
Alfa 0.8	60,00%	2,78%	Alfa 0.8	74,17%	0,56%	Alfa 0.8	75,83%	0,00%
Alfa 0.9	62,50%	3,89%	Alfa 0.9	74,17%	1,11%	Alfa 0.9	77,50%	0,00%
Alfa 1	62,50%	3,33%	Alfa 1	72,50%	1,67%	Alfa 1	76,67%	0,56%

Figura 4.97: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla picadura en piñon

En la gráfica de la figura 4.98 se muestran las tablas de resultados para los 3 grupos de severidades con 9 atributos estadísticos para el modo de falla de picadura en piñon.

N-1-2-3-9features			N-4-5-6-9features			N-7-8-9-9features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	62,50%	1,11%	Alfa 0	65,83%	3,89%	Alfa 0	53,33%	22,78%
Alfa 0.1	65,00%	1,11%	Alfa 0.1	65,83%	3,33%	Alfa 0.1	51,67%	19,44%
Alfa 0.2	68,33%	0,00%	Alfa 0.2	65,83%	2,78%	Alfa 0.2	51,67%	13,33%
Alfa 0.3	65,83%	0,00%	Alfa 0.3	65,83%	5,56%	Alfa 0.3	51,67%	7,78%
Alfa 0.4	65,83%	0,00%	Alfa 0.4	67,50%	5,00%	Alfa 0.4	50,83%	1,11%
Alfa 0.5	64,17%	0,00%	Alfa 0.5	70,83%	5,00%	Alfa 0.5	50,83%	0,00%
Alfa 0.6	63,33%	0,00%	Alfa 0.6	75,00%	5,56%	Alfa 0.6	50,83%	0,00%
Alfa 0.7	61,67%	0,56%	Alfa 0.7	76,67%	4,44%	Alfa 0.7	50,83%	0,00%
Alfa 0.8	60,00%	3,33%	Alfa 0.8	81,67%	3,89%	Alfa 0.8	57,50%	0,00%
Alfa 0.9	60,83%	4,44%	Alfa 0.9	79,17%	3,89%	Alfa 0.9	58,33%	0,00%
Alfa 1	60,83%	6,67%	Alfa 1	70,83%	3,89%	Alfa 1	59,17%	0,00%

Figura 4.98: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla picadura en piñón

En la gráfica de la figura 4.99 se muestran las tablas de resultados para los 3 grupos de severidades con 10 atributos estadísticos para el modo de falla de picadura en piñón.

N-1-2-3-10features			N-4-5-6-10features			N-7-8-9-10features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	60,83%	0,00%	Alfa 0	65,83%	0,56%	Alfa 0	50,00%	22,22%
Alfa 0.1	61,67%	0,00%	Alfa 0.1	65,83%	1,67%	Alfa 0.1	50,83%	19,44%
Alfa 0.2	65,83%	0,00%	Alfa 0.2	65,83%	1,67%	Alfa 0.2	50,00%	12,78%
Alfa 0.3	65,83%	0,00%	Alfa 0.3	65,83%	5,00%	Alfa 0.3	50,00%	8,33%
Alfa 0.4	65,00%	0,00%	Alfa 0.4	67,50%	5,00%	Alfa 0.4	50,00%	5,56%
Alfa 0.5	66,67%	0,00%	Alfa 0.5	74,17%	3,89%	Alfa 0.5	50,83%	0,00%
Alfa 0.6	60,00%	0,00%	Alfa 0.6	76,67%	5,00%	Alfa 0.6	52,50%	0,00%
Alfa 0.7	59,17%	0,00%	Alfa 0.7	77,50%	3,89%	Alfa 0.7	53,33%	0,00%
Alfa 0.8	59,17%	3,33%	Alfa 0.8	81,67%	3,33%	Alfa 0.8	60,83%	0,00%
Alfa 0.9	59,17%	3,89%	Alfa 0.9	79,17%	3,89%	Alfa 0.9	65,00%	0,00%
Alfa 1	59,17%	7,22%	Alfa 1	70,83%	3,89%	Alfa 1	67,50%	0,00%

Figura 4.99: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 10 atributos estadísticos para el modo de falla picadura en piñón

En los resultados obtenidos, de nuevo se observa que la señal de corriente presenta niveles de precisión, en algunos casos, sobre el 75 %, para los niveles de severidad N-4-5-6. Los grupos de severidades presentan niveles bajos, apenas sobre el 60 % de precisión. El mejor resultado, globalmente hablando, se logra con 7 atributos, obteniendo sobre el 62 % de precisión para el grupo de severidades N-1-2-3, 77 % y 76 % de precisión para los grupos N-4-5-6 y N-7-8-9,



respectivamente. De nuevo se nota la incapacidad del clasificador de asignar las muestras de las fallas no usadas en el entrenamiento a las clases  $NIC_k$ .

### Modo de falla: Rayadura en piñón

En la gráfica de la figura 4.100 se muestran las tablas de resultados para los 3 grupos de severidades con 3 atributos estadísticos para el modo de falla de rayadura en piñón.

N-1-2-3--3features			N-4-5-6--3features			N-7-8-9--3features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	66,67%	5,56%	Alfa 0	63,33%	23,89%	Alfa 0	64,17%	8,89%
Alfa 0.1	70,00%	1,11%	Alfa 0.1	64,17%	23,33%	Alfa 0.1	70,00%	0,00%
Alfa 0.2	73,33%	0,00%	Alfa 0.2	65,00%	17,22%	Alfa 0.2	70,00%	0,00%
Alfa 0.3	73,33%	0,00%	Alfa 0.3	70,83%	2,22%	Alfa 0.3	71,67%	0,00%
Alfa 0.4	78,33%	0,00%	Alfa 0.4	76,67%	0,00%	Alfa 0.4	71,67%	0,00%
Alfa 0.5	85,83%	0,00%	Alfa 0.5	80,83%	0,00%	Alfa 0.5	77,50%	0,00%
Alfa 0.6	87,50%	1,67%	Alfa 0.6	85,00%	2,78%	Alfa 0.6	86,67%	0,00%
Alfa 0.7	91,67%	5,56%	Alfa 0.7	85,83%	3,89%	Alfa 0.7	75,00%	0,00%
Alfa 0.8	91,67%	7,78%	Alfa 0.8	86,67%	4,44%	Alfa 0.8	76,67%	0,56%
Alfa 0.9	92,50%	10,56%	Alfa 0.9	87,50%	5,00%	Alfa 0.9	76,67%	1,11%
Alfa 1	92,50%	11,11%	Alfa 1	86,67%	5,56%	Alfa 1	77,50%	1,67%

Figura 4.100: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 3 atributos estadísticos para el modo de falla rayadura en piñón

En la gráfica de la figura 4.101 se muestran las tablas de resultados para los 3 grupos de severidades con 4 atributos estadísticos para el modo de falla de rayadura en piñón.

N-1-2-3--4features			N-4-5-6--4features			N-7-8-9--4features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	59,17%	10,56%	Alfa 0	63,33%	26,11%	Alfa 0	67,50%	1,11%
Alfa 0.1	65,00%	10,00%	Alfa 0.1	64,17%	26,11%	Alfa 0.1	72,50%	0,00%
Alfa 0.2	67,50%	11,67%	Alfa 0.2	65,00%	26,67%	Alfa 0.2	75,83%	0,00%
Alfa 0.3	72,50%	12,78%	Alfa 0.3	69,17%	22,22%	Alfa 0.3	78,33%	0,00%
Alfa 0.4	78,33%	10,00%	Alfa 0.4	71,67%	20,00%	Alfa 0.4	75,83%	0,00%
Alfa 0.5	85,83%	8,33%	Alfa 0.5	73,33%	20,00%	Alfa 0.5	84,17%	0,00%
Alfa 0.6	87,50%	8,89%	Alfa 0.6	74,17%	15,00%	Alfa 0.6	78,33%	0,00%
Alfa 0.7	87,50%	8,89%	Alfa 0.7	75,83%	9,44%	Alfa 0.7	79,17%	0,00%
Alfa 0.8	88,33%	9,44%	Alfa 0.8	77,50%	7,22%	Alfa 0.8	80,00%	0,00%
Alfa 0.9	92,50%	10,56%	Alfa 0.9	77,50%	7,22%	Alfa 0.9	76,67%	0,00%
Alfa 1	92,50%	11,11%	Alfa 1	78,33%	6,67%	Alfa 1	76,67%	0,00%

Figura 4.101: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 4 atributos estadísticos para el modo de falla rayadura en piñón

En la gráfica de la figura 4.102 se muestran las tablas de resultados para los 3 grupos de severidades con 5 atributos estadísticos para el modo de falla de rayadura en piñón.

N-1-2-3--5features			N-4-5-6--5features			N-7-8-9--5features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	66,67%	13,33%	Alfa 0	63,33%	23,33%	Alfa 0	63,33%	2,78%
Alfa 0.1	67,50%	14,44%	Alfa 0.1	64,17%	20,56%	Alfa 0.1	70,00%	1,67%
Alfa 0.2	71,67%	16,11%	Alfa 0.2	68,33%	18,33%	Alfa 0.2	80,00%	0,56%
Alfa 0.3	75,00%	16,11%	Alfa 0.3	70,00%	15,00%	Alfa 0.3	77,50%	0,00%
Alfa 0.4	80,00%	10,56%	Alfa 0.4	73,33%	13,89%	Alfa 0.4	78,33%	0,00%
Alfa 0.5	83,33%	6,67%	Alfa 0.5	74,17%	13,89%	Alfa 0.5	77,50%	0,00%
Alfa 0.6	85,83%	8,33%	Alfa 0.6	76,67%	12,78%	Alfa 0.6	75,83%	0,00%
Alfa 0.7	87,50%	7,78%	Alfa 0.7	75,83%	7,22%	Alfa 0.7	75,83%	0,00%
Alfa 0.8	91,67%	9,44%	Alfa 0.8	77,50%	7,22%	Alfa 0.8	75,83%	0,00%
Alfa 0.9	91,67%	10,56%	Alfa 0.9	75,83%	7,78%	Alfa 0.9	75,83%	0,00%
Alfa 1	92,50%	10,56%	Alfa 1	79,17%	6,67%	Alfa 1	76,67%	0,00%

Figura 4.102: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 5 atributos estadísticos para el modo de falla rayadura en piñón

En la gráfica de la figura 4.103 se muestran las tablas de resultados para los 3 grupos de severidades con 6 atributos estadísticos para el modo de falla de rayadura en piñón.

N-1-2-3--6features			N-4-5-6--6features			N-7-8-9--6features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	65,83%	20,56%	Alfa 0	58,33%	30,56%	Alfa 0	73,33%	5,55%
Alfa 0.1	67,50%	22,22%	Alfa 0.1	62,50%	25,56%	Alfa 0.1	76,67%	6,11%
Alfa 0.2	64,17%	21,67%	Alfa 0.2	69,17%	20,00%	Alfa 0.2	77,50%	7,78%
Alfa 0.3	70,83%	19,44%	Alfa 0.3	74,17%	12,22%	Alfa 0.3	77,50%	11,11%
Alfa 0.4	78,33%	16,11%	Alfa 0.4	78,33%	6,67%	Alfa 0.4	79,17%	10,00%
Alfa 0.5	83,33%	15,56%	Alfa 0.5	80,00%	11,67%	Alfa 0.5	78,33%	8,33%
Alfa 0.6	85,00%	12,78%	Alfa 0.6	79,17%	13,33%	Alfa 0.6	76,67%	7,78%
Alfa 0.7	86,67%	11,11%	Alfa 0.7	80,83%	11,67%	Alfa 0.7	78,33%	21,67%
Alfa 0.8	87,50%	11,67%	Alfa 0.8	82,50%	4,44%	Alfa 0.8	78,33%	30,56%
Alfa 0.9	89,17%	11,11%	Alfa 0.9	80,83%	5,00%	Alfa 0.9	78,33%	40,56%
Alfa 1	89,17%	8,89%	Alfa 1	82,50%	5,00%	Alfa 1	80,00%	43,33%

Figura 4.103: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 6 atributos estadísticos para el modo de falla rayadura en piñón

En la gráfica de la figura 4.104 se muestran las tablas de resultados para los 3 grupos de severidades con 7 atributos estadísticos para el modo de falla de rayadura en piñón.

N-1-2-3--7features			N-4-5-6--7features			N-7-8-9--7features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	65,83%	15,00%	Alfa 0	58,33%	28,33%	Alfa 0	65,00%	25,55%
Alfa 0.1	66,67%	17,78%	Alfa 0.1	60,00%	22,78%	Alfa 0.1	70,83%	31,11%
Alfa 0.2	65,83%	17,22%	Alfa 0.2	65,83%	16,67%	Alfa 0.2	73,33%	31,67%
Alfa 0.3	70,00%	15,00%	Alfa 0.3	70,83%	3,89%	Alfa 0.3	72,50%	33,89%
Alfa 0.4	77,50%	13,89%	Alfa 0.4	75,00%	0,56%	Alfa 0.4	75,00%	32,77%
Alfa 0.5	84,17%	15,56%	Alfa 0.5	76,67%	5,00%	Alfa 0.5	75,83%	37,22%
Alfa 0.6	85,00%	11,67%	Alfa 0.6	78,33%	9,44%	Alfa 0.6	78,33%	44,44%
Alfa 0.7	85,83%	10,56%	Alfa 0.7	75,83%	7,78%	Alfa 0.7	84,17%	54,44%
Alfa 0.8	87,50%	9,44%	Alfa 0.8	76,67%	2,78%	Alfa 0.8	80,00%	58,89%
Alfa 0.9	87,50%	10,00%	Alfa 0.9	75,83%	4,44%	Alfa 0.9	78,33%	65,55%
Alfa 1	89,17%	7,78%	Alfa 1	79,17%	5,00%	Alfa 1	80,00%	71,11%

Figura 4.104: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 7 atributos estadísticos para el modo de falla rayadura en piñón

En la gráfica de la figura 4.105 se muestran las tablas de resultados para los 3 grupos de severidades con 8 atributos estadísticos para el modo de falla de rayadura en piñón.

N-1-2-3--8features			N-4-5-6--8features			N-7-8-9--8features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	65,83%	15,00%	Alfa 0	58,33%	28,33%	Alfa 0	65,00%	25,55%
Alfa 0.1	66,67%	17,78%	Alfa 0.1	60,00%	22,78%	Alfa 0.1	71,67%	31,11%
Alfa 0.2	65,83%	17,22%	Alfa 0.2	65,83%	16,67%	Alfa 0.2	73,33%	31,67%
Alfa 0.3	70,00%	15,56%	Alfa 0.3	70,83%	3,89%	Alfa 0.3	73,33%	33,89%
Alfa 0.4	77,50%	13,89%	Alfa 0.4	75,00%	0,56%	Alfa 0.4	74,17%	34,44%
Alfa 0.5	84,17%	15,00%	Alfa 0.5	76,67%	4,44%	Alfa 0.5	75,00%	40,00%
Alfa 0.6	85,00%	11,11%	Alfa 0.6	78,33%	9,44%	Alfa 0.6	78,33%	45,56%
Alfa 0.7	85,83%	10,56%	Alfa 0.7	75,83%	7,78%	Alfa 0.7	83,33%	55,00%
Alfa 0.8	87,50%	9,44%	Alfa 0.8	75,83%	2,78%	Alfa 0.8	80,00%	58,33%
Alfa 0.9	87,50%	10,00%	Alfa 0.9	77,50%	4,44%	Alfa 0.9	78,33%	66,67%
Alfa 1	89,17%	7,78%	Alfa 1	79,17%	5,00%	Alfa 1	80,00%	73,33%

Figura 4.105: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 8 atributos estadísticos para el modo de falla rayadura en piñon

En la gráfica de la figura 4.106 se muestran las tablas de resultados para los 3 grupos de severidades con 9 atributos estadísticos para el modo de falla de rayadura en piñon.

N-1-2-3--9features			N-4-5-6--9features			N-7-8-9--9features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	58,33%	24,44%	Alfa 0	54,17%	24,44%	Alfa 0	54,17%	12,78%
Alfa 0.1	64,17%	23,89%	Alfa 0.1	59,17%	21,67%	Alfa 0.1	60,00%	16,67%
Alfa 0.2	71,67%	23,89%	Alfa 0.2	75,83%	5,00%	Alfa 0.2	64,17%	17,78%
Alfa 0.3	72,50%	23,89%	Alfa 0.3	75,83%	4,44%	Alfa 0.3	65,00%	16,67%
Alfa 0.4	77,50%	23,33%	Alfa 0.4	82,50%	3,89%	Alfa 0.4	70,83%	18,33%
Alfa 0.5	75,00%	34,44%	Alfa 0.5	86,67%	6,67%	Alfa 0.5	71,67%	21,11%
Alfa 0.6	80,83%	36,67%	Alfa 0.6	90,00%	11,67%	Alfa 0.6	71,67%	32,78%
Alfa 0.7	85,83%	33,89%	Alfa 0.7	90,00%	7,78%	Alfa 0.7	69,17%	38,89%
Alfa 0.8	86,67%	33,33%	Alfa 0.8	85,83%	5,00%	Alfa 0.8	70,83%	41,67%
Alfa 0.9	86,67%	36,67%	Alfa 0.9	77,50%	6,11%	Alfa 0.9	70,83%	47,77%
Alfa 1	85,00%	36,11%	Alfa 1	74,17%	5,56%	Alfa 1	74,17%	49,44%

Figura 4.106: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 9 atributos estadísticos para el modo de falla rayadura en piñon

En la gráfica de la figura 4.107 se muestran las tablas de resultados para los 3 grupos de severidades con 10 atributos estadísticos para el modo de falla de rayadura en piñon.

N-1-2-3--10features			N-4-5-6--10features			N-7-8-9--10features		
Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados	Alfa	Exactitud Test_Train	Exactitud test datos no entrenados
Alfa 0	58,33%	24,44%	Alfa 0	54,17%	24,44%	Alfa 0	54,17%	12,22%
Alfa 0.1	64,17%	23,89%	Alfa 0.1	58,33%	21,67%	Alfa 0.1	60,00%	16,67%
Alfa 0.2	72,50%	23,89%	Alfa 0.2	75,00%	5,00%	Alfa 0.2	63,33%	17,78%
Alfa 0.3	72,50%	24,44%	Alfa 0.3	75,83%	4,44%	Alfa 0.3	63,33%	16,67%
Alfa 0.4	75,83%	23,33%	Alfa 0.4	82,50%	3,89%	Alfa 0.4	70,83%	18,33%
Alfa 0.5	75,00%	34,44%	Alfa 0.5	86,67%	6,67%	Alfa 0.5	71,67%	21,11%
Alfa 0.6	80,83%	37,22%	Alfa 0.6	90,00%	11,67%	Alfa 0.6	71,67%	31,67%
Alfa 0.7	85,00%	33,89%	Alfa 0.7	90,00%	7,78%	Alfa 0.7	69,17%	38,89%
Alfa 0.8	86,67%	33,33%	Alfa 0.8	85,83%	5,00%	Alfa 0.8	70,83%	41,11%
Alfa 0.9	86,67%	36,67%	Alfa 0.9	77,50%	6,11%	Alfa 0.9	70,83%	48,33%
Alfa 1	85,00%	36,11%	Alfa 1	74,17%	5,56%	Alfa 1	74,17%	48,89%

Figura 4.107: Tabla de resultados de exactitud del clasificador LAMDA HAD en CE para los tres grupos de severidades con 10 atributos estadísticos para el modo de falla rayadura en piñon

En los resultados obtenidos, se puede observar que con el uso de la señal de corriente se pueden lograr niveles de precisión, para diferentes valores de  $\alpha$  y número de atributos, sobre el 90 % para el grupo de severidades N-1-2-3, con el uso de 3 atributos, y N-4-5-6 con 9 atributos. Para el grupo de severidades N-7-8-9, se puede lograr niveles de precisión sobre el 85 %. Específicamente, para el caso del uso de 3 atributos, se logra 92.5 %, 87,5 % y 86.6 % de precisión, para los grupos de severidades N-1-2-3, N-4-5-6 y N-7-8-9, respectivamente. Considerando que solo se usan 3 atributos, este resultado es aceptable. Nuevamente, se nota que la capacidad de los clasificadores para asignar a las clases  $NIC_k$  las muestras de fallas no usadas en los clasificadores, es baja.

### 4.2.3. Resultados de la evaluación para la clasificación de las clases desconocidas usando los valores de GAD

Una vez obtenidos los resultados de precisión de las pruebas realizadas con el clasificador LAMDA HAD que corresponden a todas las tablas mostradas en la sección 4.2.2, se seleccionan los tres grupos de severidades con los valores mas altos de exactitud con los datos de prueba de las clases entrenadas para 3 de los 4 modos de fallas que corresponden a las tablas 3.28, 4.96 y 4.100. El modo de falla de grieta en piñon no se usará en la evaluación final ya que los valores de precisión del clasificador no fueron los esperados, estos no tuvieron una buena clasificación para las pruebas realizadas con los datos de entrenamiento.

La estrategia que se desea probar ha sido indicada al final del capítulo 3. Como se indicó, lo que se espera verificar en este análisis, es que el mayor GAD provenga del clasificador que fue entrenado con la clase a la que pertenece la muestra  $\bar{X}$ . Los resultados de este procedimiento se muestran en las tablas de las figuras 3.29, 4.108 y 4.109, donde se evaluaron cada grupo de 30 muestras de cada nivel de severidad de fallas, en cada uno de los clasificadores. Con base en el mayor valor de GAD, se hizo la asignación a cada clase.

CLASES	INDIVIDUOS CLASIFICADOS PARA PITTING																					
	NIVEL 1				2				3				4									
	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC	P1	P2	P3	P4	GAD-NIC		
INDIVIDUOS POR CLASE	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
% CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
INDIVIDUOS POR CLASE	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
% CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
INDIVIDUOS POR CLASE	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
% CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
INDIVIDUOS POR CLASE	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
% CLASIFICADOR	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%

Figura 4.108: Tabla de resultados del clasificador que presentó el valor mas alto de los GAD para las clases de los grupos de severidades para picadura en piñon

En la tabla de la figura 4.108 se muestra, por ejemplo, que el grupo de datos de prueba de la falla P1(N) 15 fueron correctamente asignadas a su clase de acuerdo al valor del GAD que asignó cada clasificador. En este caso, efectivamente, el mayor GAD correspondiente a su clase, lo generó el clasificador N-1-2-3. Sin embargo, para 9 muestras de las clase P1(N), el mejor GAD lo propuso el clasificador del grupo N-4-5-6, y para 6 muestras de las clase P1(N), el mejor GAD lo propuso el clasificador del grupo N-7-8-9. Siguiendo este análisis, se resalta que el mejor caso fue para las muestras de la falla P5(4) donde de las 30 muestras 26 fueron correctamente asignadas a su clase en el clasificador de l grupo N-4-5-6. Le sigue en mejor resultado el conjunto de muestras del nivel P2(1) con 24 muestras clasificadas en su clase en el clasificador del grupo N-1-2-3. Los peores resultados son para la clasificación de las muestras de P6(5) en adelante.







# Capítulo 5

## Conclusiones y Recomendaciones

### 5.1. Conclusiones

- A partir de la investigación experimental exhaustiva realizada para este trabajo fue posible conocer mediante el estado del arte las distintas técnicas para el análisis de la señal de la corriente eléctrica del motor, siendo el MCSA de gran interés ya que es una técnica de diagnóstico no intrusiva y de bajo coste.
- La correcta comprensión de las bases de datos de atributos de señales de corriente asociadas a cajas de engranajes y compresores recíprocos provistas por el grupo de investigación GIDTEC de la UPS-Cuenca y la posterior identificación de los atributos informativos extraídos del dominio del tiempo y del tiempo-frecuencia ayudan a producir estructuras de agrupamiento de forma adecuada mejorando así el proceso de diagnóstico de fallas.
- Se muestra el desempeño de la métrica de selección de atributo  $CDbw$ , para producir agrupamientos de datos útiles para la detección de nuevas condiciones de severidad de fallos.
- En el presente trabajo se lograron diferentes modelos de aprendizaje automático LAMDA-HAD basado en el algoritmo de clasificación LAMDA basado en similaridad difusa. Así mismo, se muestra el desempeño de cada modelo de clasificación obtenido, usando los atributos seleccionados con la métrica  $CDbw$

- La aplicación de la métrica  $CDbw$  para determinar la mejor combinación de atributos en tiempo y en frecuencia en la base de datos CR, usado para ajustar el clasificador LAMDA-HAD, fue apropiado usado sólo 3 atributos y logrando un precisión del 90 % para clasificar 4 modos de fallas diferentes.
- La aplicación de la métrica  $CDbw$  para determinar la mejor combinación de atributos en la base de datos de CE con atributos de tiempo-frecuencia extraídos de los coeficientes de la descomposición de paquetes de Wavelets, mostró que no es posible seleccionar atributos que generen una adecuada agrupación por lo cual no se consideró ajustar un clasificador basado en LAMDA-HAD, el cual depende fuertemente de la estructura de grupo de los datos.
- El desempeño en la clasificación de la fallas usando atributos de tiempo y de frecuencia en la CE fue valorado, en general, con precisiones sobre el 80 %, alcanzando el 95.8 %, por ejemplo para el grupo de severidades N-4-5-6 del modo de fallo grieta en el piñón. Esto se logró con modelos usando diferentes atributos seleccionados según la métrica  $CDbw$ .
- De acuerdo con los resultados de clasificación obtenidos mediante la aplicación del algoritmo LAMDA-HAD, con rendimiento de clasificación sobre el 80 % en la fase de prueba del algoritmo, se considera que es una técnica fiable para el diagnóstico de severidad de fallos de engranajes, además de ser simple y fácil de implementar computacionalmente.
- Los resultados obtenidos mediante el modelo de clasificación propuesto, establecen que es factible el uso de la señal eléctrica de corriente para el diagnóstico de severidad de fallos en engranajes y compresores.
- Finalmente, la capacidad del algoritmo LAMDA-HAD para diagnosticar nuevos patrones de fallas que no son conocidos por el clasificador, no pudo ser demostrado contundentemente. Esto deja abierto investigaciones futuras en las mejoras por realizar en el algoritmo LAMDA-HAD. Sin embargo la condición Normal es predicha por todos los clasificadores en un 100 %, lo que resalta la capacidad como detector de fallas de esta propuesta, cualquiera sea el nivel de severidad que se presente.

## 5.2. Recomendaciones

- Aunque los resultados con la aplicación de la métrica  $CDbw$  son aceptables se recomienda futuras investigaciones con el fin de proponer un rango más amplio de métricas de agrupamiento que puedan ser compatibles con el algoritmo LAMDA HAD.
- Se recomienda futuras investigaciones en torno al algoritmo LAMDA HAD para lograr validar su utilidad y eficacia en cuanto a la detección de fallas en otros tipos de máquinas rotativas.
- Es favorable al área de estudio tratado en este documento enfocar futuros trabajos en la estandarización del método presentado en el presente estudio, específicamente en la mejora de detectar nuevos patrones de fallas que puedan ser enviados a las clases desconocidas  $NIC_k$ .

# Glosario

- ANOVA** En estadística este análisis sirve para probar la hipótesis de que dos o mas medias de una población determinada, son iguales.
- AV** Es una técnica clasificada dentro del mantenimiento predictivo o mantenimiento basado en condición que sirve para realizar diagnósticos des estado de las maquinas rotativas tomando como datos señales de vibraciones mediante acelerómetros para luego ser procesadas por una tarjeta de adquisición de datos y analizarlas en el dominio de tiempo, frecuencia o tiempo frecuencia.
- CE** Maquina rotatoria que contiene varios trenes de engranes para reducir o elevar velocidades y pares mecánicos.
- CR** Es una maquina que comprime algún tipo de gas a una determinada presión para luego elevarla a una mayor, es un tipo de compresor de desplazamiento positivo y cuenta con un mecanismo biela y pistón.
- DPW** Es una derivada o variante de la transformada de Wavelet que consiste en descomponer interactivamente no solo los coeficientes de aproximación obtenidos de la etapa anterior, sino también la de los detalles dando como resultado una estructura de doble árbol.
- FDT** Es una transformación matemática que nos permite transformar señales periódicas y continuas en el espacio de representación del tiempo al de la frecuencia y viceversa.
- FFT** Sirve para analizar matemáticamente señales periódicas en el dominio de la frecuencia, pertenece a las familias de las transformada discreta de Fourier.

- GIDTEC** Es un grupo conformado por investigadores e ingenieros que pertenecen a la Universidad Politécnica Salesiana sede Cuenca.
- K-means** Es una técnica usada para agrupamiento de datos, tiene como alcance descomponer un conjunto de  $n$  individuos en  $k$  clases, en los que cada individuo debe pertenecer a una clase cuyo valor medio es el más próximo.
- KNN** Es un tipo de algoritmo de clasificación de la familia del machine learning de aprendizaje supervisado.
- LAMDA** Algoritmo de aprendizaje para análisis de datos multivariantes.
- LAMDA HAD** Algoritmo de aprendizaje para análisis de datos multivariantes modificado o mejorado.
- LD** Es una técnica matemática que tiene como alcance la representación matemática de la inferencia humana, proporcionando herramientas formales para su desarrollo..
- MCSA** Es una técnica de mantenimiento basado en condición, se toman datos de la corriente eléctrica del motor para luego ser procesada y analizada en el dominio de la frecuencia como espectro en la cual se evalúan las señales de diferentes armónicos pertenecientes a distintos tipos de fallas.
- MI** Es un tipo de máquina rotativa que transforma la energía eléctrica en energía mecánica mediante inducción electromagnética existen varios tipos de motor de inducción de jaula de ardilla y de rotor bobinado, los de jaula de ardilla son los más utilizados en la industria por su bajo costo y alto par de arranque.
- ML** Es el subcampo de las ciencias de la computación y una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permitan que las computadoras aprendan..
- MR** Máquina rotatoria mecánica que es accionada mediante un motor eléctrico, de combustión o algún tipo de turbina.
- PSD** Es una función matemática que nos informa de cómo está distribuida la potencia o la energía de dicha señal sobre las distintas frecuencias de la que está formada..

**TW** Es una técnica matemática que sirve para representar señales en el dominio del tiempo y la frecuencia al mismo tiempo.

# Bibliografía

- [1] D. Chingal, V. Sánchez, D. Cabrera, M. Cerrada, R. Vásquez, and U. P. Salesiana, “Comparison of vibration and current signals for the detection of the severity of faults in gears,” *Revista de la Facultad de Ciencias Básicas*.2019.17(1):187-195 Vol. 17, Núm. 1 (2019), pp. 187–195, 2019.
- [2] F. Cajas and T. Cristian, “Acquisition of acoustic and vibration signals for fault diagnosis in a double stage reciprocating compressor,” Universidad Politécnica Salesiana, Universidad Politécnica Salesiana, Tech. Rep., 2018, B.S. Thesis.
- [3] M. Cerrada, G. Zurita, D. Cabrera, R. V. Sánchez, M. Artés, and C. Li, “Fault diagnosis in spur gears based on genetic algorithm and random forest,” *Mechanical Systems and Signal Processing Volumes 70–71, March 2016, Pages 87-103*, pp. 87–103, 2016.
- [4] M. Peña, M. Cerrada, X. Alvarez, D. Jadán, P. Lucero, B. Milton, R. Guamán, and R. V. Sánchez, “Feature engineering based on ANOVA, cluster validity assessment and KNN for fault diagnosis in bearings,” *Journal of Intelligent & Fuzzy Systems, vol. 34, no. 6, pp. 3451-3462, 2018*, pp. 3451–3462, 2018.
- [5] X. Li, G. Bin, and B. S. Dhillon, “Reliability Analysis of an Integrated and Multifunctional Vibration Signal Measuring Instrument for Rotary Machine,” *2009 8th International Conference on Reliability, Maintainability and Safety*, pp. 978–981, 2009.
- [6] M. Cerrada, R.-v. Sánchez, C. Li, F. Pacheco, and D. Cabrera, “A review on data-driven fault severity assessment in rolling bearings,” *Mechanical Systems and Signal Processing Volume 99, 15 January 2018, Pages 169-196*, pp. 169–196, 2018.

- [7] N. Alonso, R. García-Martín, and P. Fernández, “Determination of the bending strength geometry factor J for the calculation of stress in parallel-axis gears as a function of the reference correction and slope angle of the gear tooth,” *International Journal of Mechanical Engineering and Automation*, pp. 27–33, 2016.
- [8] A. Bahramighahnavieh, P. Mosaddegh, and S. Akbarzadeh, “Investigation of the hertzian stress distribution on the surface of the straight bevel gear,” *Applied Mechanics and Materials*, vol. 307, Trans Tech Publications, pp. 304–307, 2013.
- [9] H. Öztürk, M. Sabuncu, and I. Yesilyurt, “Early detection of pitting damage in gears using mean frequency of scalogram,” *JVC / Journal of Vibration and Control*, vol. 14, pp. 469–484, 2008.
- [10] L. Zhang, G. Xiong, L. Liu, and Q. Cao, “Gearbox health condition identification by neuro-fuzzy ensemble,” *Journal of Mechanical Science and Technology*, pp. 603–608, 2013.
- [11] B. Lamrini, M. V. Le Lann, A. Benhammou, E. K. Lakhal, J. Lin, and M. J. Zuo, “Gearbox fault diagnosis using adaptive wavelet filter,” *Mechanical Systems and Signal Processing*, Volume 17, Issue 6, pp. 1259–1269, 2003.
- [12] A. Cubillo, S. Perinpanayagam, and M. Esperon-Miguez, “A review of physics-based models in prognostics: Application to gears and bearings of rotating machinery,” *Advances in Mechanical Engineering*, Volume: 8 issue: 8, pp. 1–21, 2016.
- [13] M. Amarnath, S. Chandramohan, and S. Seetharaman, “Experimental investigations of surface wear assessment of spur gear teeth,” *JVC / Journal of Vibration and Control*, Volume: 18 issue: 7, page(s): 1009-1024, pp. 1009–1024, 2012.
- [14] R.-V. Sánchez and M. Cerrada, “A comparative feature analysis for gear pitting level classification by using acoustic emission, vibration and current signals,” *IFAC-PapersOnLine* Volume 51, Issue 24, 2018, Pages 346-352, pp. 346–352, 2018.
- [15] M. Cerrada, J. C. Macancela, D. Cabrera, E. Estupiñan, R. V. Sánchez, and R. Medina, “Reciprocating compressor multi-fault classification using



- symbolic dynamics and complex correlation measure,” *Applied Sciences (Switzerland)* 2020, 10(7), 2512, pp. 1–21, 2020.
- [16] D. Cabrera, A. Guamán, S. Zhang, M. Cerrada, R. V. Sánchez, J. Cevallos, J. Long, and C. Li, “Bayesian approach and time series dimensionality reduction to LSTM-based model-building for fault diagnosis of a reciprocating compressor,” *Neurocomputing, Volume 380, 7 March 2020, Pages 51–66*, pp. 51–66, 2020.
- [17] A. Gear, O. C. Ahmida, I. Congress, O. Access, and M. Rights, “Gear Wear Process Monitoring Using Acoustic,” *21st International Congress on Sound and Vibration, 13th - 17th July, 2014, Beijing, China.*, pp. 1–9, 2014.
- [18] P. Henriquez, J. B. Alonso, M. A. Ferrer, and C. M. Travieso, “Review of automatic fault diagnosis systems using audio and vibration signals,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 44, no. 5, pp. 642–652, May 2014.*, pp. 642–652, 2014.
- [19] Y. H. Ali and S. M. Ali, “Acoustic Emission and Artificial Intelligent Methods in Condition Monitoring of Rotating Machine – A Review,” *The National Conference for Postgraduate Research 2016, Universiti Malaysia Pahang*, pp. 212–219, 2016.
- [20] S. Ulus and S. Erkaya, “An experimental study on gear diagnosis by using acoustic emission technique,” *International Journal of Acoustics and Vibration*, no. 1, pp. 103–111, 2016.
- [21] Y. Qu, D. He, J. Yoon, B. Van Hecke, E. Bechhoefer, and J. Zhu, “Gearbox tooth cut fault diagnostics using acoustic emission and vibration sensors - A comparative,” *Sensors*, vol. 14, no. 1, pp. 1372–1393, 2014.
- [22] P. Boshkoski and A. Urevc, “Monitoring pitting gear faults using electrical current and sound emissions,” *9th International PhD Workshop on Systems and Control: Young Generation Viewpoint*, pp. 1–6, 2008.
- [23] S. Al-Arbi, C. Talbot, T. Wang, F. Gu, and A. Ball, “Characterization of vibration transmission paths for gearbox condition monitoring,” *39th International Congress on Noise Control Engineering 2010, INTER-NOISE 2010*, pp. 5572–5581, 2010.

- [24] R. Bajrić, D. Sprečić, and N. Zuber, “Review of vibration signal processing techniques towards gear pairs damage identification,” *International Journal of Engineering & Technology IJET-IJENS Vol: 11 No: 04*, pp. 124–128, 2011.
- [25] C. Li, R. V. Sanchez, G. Zurita, M. Cerrada, D. Cabrera, and R. E. Vásquez, “Gearbox fault diagnosis based on deep random forest fusion of acoustic and vibratory signals,” *Mechanical Systems and Signal Processing Volumes 76–77, August 2016, Pages 283-293*, pp. 283–293, 2016.
- [26] C. Hu, W. A. Smith, R. B. Randall, and Z. Peng, “Development of a gear vibration indicator and its application in gear wear monitoring,” *Mechanical Systems and Signal Processing Volumes 76–77, August 2016, Pages 319-336*, pp. 319–336, 2016.
- [27] C. Verucchi, G. Bossio, J. Bossio, and G. Acosta, “Fault detection in gear box with induction motors: An experimental study,” *IEEE Latin America Transactions, vol. 14, no. 6, pp. 2726-2731*, pp. 2726–2731, 2016.
- [28] C. Kar and A. R. Mohanty, “Monitoring gear vibrations through motor current signature analysis and wavelet transform,” *Mechanical Systems and Signal Processing Volume 20, Issue 1, January 2006, Pages 158-187*, pp. 158–187, 2006.
- [29] A. R. Mohanty and C. Kar, “Fault detection in a multistage gearbox by demodulation of motor current waveform,” *IEEE Transactions on Industrial Electronics, vol. 53, no. 4, pp. 1285-1297, June 2006*, pp. 1285–1297, 2006.
- [30] S. H. Kia, H. Henao, and G. A. Capolino, “Gear tooth surface damage fault detection using induction machine stator current space vector analysis,” *IEEE Transactions on Industrial Electronics, vol. 62, no. 3, pp. 1866-1878, March 2015*, pp. 1866–1878, 2015.
- [31] B. Corne, B. Vervisch, C. Debruyne, J. Knockaert, and J. Desmet, “Comparing MCSA with Vibration Analysis in order to detect Bearing Faults - A Case Study,” *IEEE International Electric Machines & Drives Conference (IEMDC), Coeur d’Alene, ID, USA, 2015, pp. 1366-1372*, pp. 1–7, 2015.
- [32] N. P. Sakhalkar and P. Korde, “Fault detection in induction motors based on motor current signature analysis and accelerometer,” *2017 Internatio-*

- nal Conference on Energy, Communication, Data Analytics and Soft Computing, ICECDS 2017*, pp. 363–367, 2018.
- [33] B. Corne, C. Debruyne, P. D. Baets, and J. Desmet, “Stator Current Measurements as a Condition Monitoring Technology - The-State-of-the-Art,” *International Conference on Electrical Machines (ICEM), Berlin, Germany, 2014*, pp. 1659–1665, pp. 1659–1665, 2014.
- [34] N. G. Lo, A. Soualhi, M. Frini, and H. Razik, “Gear and bearings fault detection using motor current signature analysis,” *Proceedings of the 13th IEEE Conference on Industrial Electronics and Applications, ICIEA 2018*, pp. 900–905, 2018.
- [35] S. Singh and N. Kumar, “Detection of Bearing Faults in Mechanical Systems using Stator Current Monitoring,” *IEEE Transactions on Industrial Informatics*, vol. 13, no. 3, pp. 1341–1349, June 2017, pp. 1–9, 2016.
- [36] S. H. Kia, H. Henao, and G. A. Capolino, “Mechanical transmission and torsional vibration effects on induction machine stator current and torque in railway traction systems,” *2009 IEEE Energy Conversion Congress and Exposition, ECCE 2009*, pp. 3182–3187, 2009.
- [37] B. Choi, H. Kim, D. Gu, and H. Kim, HyoJung; Jeong, “Diagnosis of Cryogenic Pump-Motor Systems Using Vibration and Current Signature Analysis,” *Journal of Mechanical Science and Technology (KSME Int. J.)*, Vol. 20, No. 7, pp. 972–980, 2006, pp. 1–9, 2006.
- [38] R. Medina, M. Cerrada, D. Cabrera, R.-V. Sanchez, C. Li, and J. V. D. Oliveira, “Deep Learning-Based Gear Pitting Severity Assessment Using Acoustic Emission, Vibration and Currents Signals,” *2019 Prognostics and System Health Management Conference (PHM-Paris)*, pp. 210–216, 2019.
- [39] S. Jokic, N. Cincar, and B. Novakovic, “The analysis of vibration measurement and current signature in motor drive faults detection,” *2018 17th International Symposium INFOTEH-JAHORINA (INFOTEH), East Sarajevo, Bosnia and Herzegovina, 2018*, pp. 1–6, pp. 21–23, 2018.
- [40] W. T. Thomson, “Current Signature Analysis for condition monitoring of cage induction motors: Industrial Application and Case Histories,” *Hoboken, NJ: Wiley-IEEE Press, 2017*. - 397 p., pp. 79–118, 2017.

- [41] L. Eren and M. J. Devaney, "Bearing Damage Detection via Wavelet Packet Decomposition of the Stator Current," *IEEE Transactions on Instrumentation and Measurement*, vol. 53, no. 2, pp. 431-436, April 2004, pp. 431-436, 2004.
- [42] X. Zhao, "A Method of Gear Fault Detection based on Wavelet Transform," *International Conference on Business Intelligence and Financial Engineering, Beijing, China, 2009*, pp. 648-651, 2009.
- [43] S. Seker, "Transfer Function Approach Based Upon Wavelet Transform for Bearing Damage Detection in Electric Motors," *IEEE International Symposium on Industrial Electronics, Cambridge, UK, 2008*, pp. 749-752, pp. 749-752, 2008.
- [44] R. M. Vasant and K. Narendra, "Comparative Analysis of DWT and WPT for Current Signal Analysis," *IEEE 7th Power India International Conference (PIICON), Bikaner, 2016*, pp. 1-6, pp. 1-6, 2016.
- [45] S. R. Kapoor, N. Khandelwal, and P. Pareek, "Bearing Fault Analysis by Signal Energy Calculation Based Signal Processing Technique in Squirrel Cage Induction Motor," *International Conference on Signal Propagation and Computer Technology (ICSPCT 2014), Ajmer, India, 2014*, pp. 33-38, pp. 33-38, 2014.
- [46] A. Jacop, H. V. Khang, K. G. Robbersmyr, and A. J. M. Cardoso, "Bearing Fault Detection for Drivetrains using Adaptive Filters based Wavelet Transform," *20th International Conference on Electrical Machines and Systems (ICEMS), Sydney, NSW, 2017*, pp. 1-6, pp. 1-6, 2017.
- [47] F. B. Abid, S. Zgarni, and A. Braham, "Bearing Fault Detection of Induction Motor Using SWPT and DAG Support Vector Machines," *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, Florence, Italy, 2016*, pp. 1476-1481, pp. 1476-1481, 2016.
- [48] K. Teotrakool, M. J. Devaney, and L. Eren, "Adjustable Speed Drive Bearing Fault Detection via Wavelet Packet Decomposition," *IEEE Transactions on Instrumentation and Measurement*, vol. 58, no. 8, pp. 2747-2754, Aug. 2009, pp. 22-25, 2006.
- [49] Z. Huo, Y. Zhang, P. Francq, L. Shu, and J. Huang, "Incipient Fault Diagnosis of Roller Bearing using Optimized Wavelet Transform based Multi-speed

- Vibration Signatures,” *IEEE Access*, vol. 5, pp. 19442-19456, 2017, pp. 1–14, 2017.
- [50] M. I. Balleteros Csmcho, F. J. Cadena Villalba, and A. A. Jaramillo Matta, “Signal Processing Techniques Used for the Analysis of Harmonic Distortion Generated by Frequency Variators in Induction Motors,” *Redes de Ingeniería ISSN: 2248–762X Vol. 6, No. 1 (ene-jun 2015)*. pp. 72-84, p. 72, 2015.
- [51] R. P. Monteiro, M. Cerrada, D. R. Cabrera, R. V. Sánchez, and C. J. Bastos-Filho, “Using a Support Vector Machine Based Decision Stage to Improve the Fault Diagnosis on Gearboxes,” *Computational Intelligence and Neuroscience*, vol. 2019, Article ID 1383752, 13 pages, 2019, p. 13, 2019.
- [52] R. Monteiro, C. Bastos-Filho, M. Cerrada, D. Cabrera, and R. V. Sanchez, “Convolutional Neural Networks Using Fourier Transform Spectrogram to Classify the Severity of Gear Tooth Breakage,” *Proceedings - 2018 International Conference on Sensing, Diagnostics, Prognostics, and Control, SDPC 2018*, pp. 490–496, 2019.
- [53] D. Cabrera, F. Sancho, C. Li, M. Cerrada, R. V. Sánchez, F. Pacheco, and J. V. de Oliveira, “Automatic feature extraction of time-series applied to fault severity assessment of helical gearbox in stationary and non-stationary speed operation,” *Applied Soft Computing Volume 58, September 2017, Pages 53-64*, pp. 53–64, 2017.
- [54] R. V. Sanchez, P. Lucero, J. C. Macancela, M. Cerrada, R. E. Vasquez, and F. Pacheco, “Multi-fault diagnosis of rotating machinery by using feature ranking methods and SVM-based classifiers,” *Proceedings - 2017 International Conference on Sensing, Diagnostics, Prognostics, and Control, SDPC 2017*, pp. 105–110, 2017.
- [55] Y. Li, K. Ding, G. He, and H. Lin, “Vibration mechanisms of spur gear pair in healthy and fault states,” *Mechanical Systems and Signal Processing Volume 81, 15 December 2016, Pages 183-201*, pp. 183–201, 2016.
- [56] F. Pacheco, J. Valente de Oliveira, R. V. Sánchez, M. Cerrada, D. Cabrera, C. Li, G. Zurita, and M. Artés, “A statistical comparison of neuroclassifiers and feature selection methods for gearbox fault diagnosis under realistic conditions,” *Expert Systems with Applications Volume 71, 1 April 2017, Pages 69-86*, pp. 192–206, 2016.

- [57] C. Li, R. V. Sanchez, G. Zurita, M. Cerrada, D. Cabrera, and R. E. Vásquez, "Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis," *Neurocomputing Volume 168*, 30 November 2015, Pages 119-127, pp. 119–127, 2015.
- [58] C. Li, J. V. De Oliveira, M. Cerrada, D. Cabrera, R. V. Sanchez, and G. Zurita, "A Systematic Review of Fuzzy Formalisms for Bearing Fault Diagnosis," *IEEE Transactions on Fuzzy Systems*, vol. 27, no. 7, pp. 1362-1382, July 2019, pp. 1362–1382, 2019.
- [59] M. Cerrada, C. Li, R. V. Sánchez, F. Pacheco, D. Cabrera, and J. Valente de Oliveira, "A fuzzy transition based approach for fault severity prediction in helical gearboxes," *Fuzzy Sets and Systems Volume 337*, 15 April 2018, Pages 52-73, pp. 52–73, 2018.
- [60] C. Li, J. Valente De Oliveira, M. Cerrada, F. Pacheco, D. Cabrera, V. Sanchez, and G. Zurita, "Observer-biased bearing condition monitoring: From fault detection to multi-fault classification," *Engineering Applications of Artificial Intelligence Volume 50*, April 2016, Pages 287-301, pp. 287–301, 2016.
- [61] C. Li, L. Ledo, M. Delgado, M. Cerrada, F. Pacheco, D. Cabrera, R. V. Sánchez, and J. Valente de Oliveira, "A Bayesian approach to consequent parameter estimation in probabilistic fuzzy systems and its application to bearing fault classification," *Knowledge-Based Systems Volume 129*, 1 August 2017, Pages 39-60, pp. 39–60, 2017.
- [62] C. Li, M. Cerrada, D. Cabrera, R. V. Sanchez, F. Pacheco, G. Ulutagay, and J. Valente De Oliveira, "A comparison of fuzzy clustering algorithms for bearing fault diagnosis," *Journal of Intelligent & Fuzzy Systems*, vol. 34, no. 6, pp. 3565-3580, 2018, pp. 3565–3580, 2018.
- [63] C. Li, M. Cerrada, R. V. Sánchez, D. Cabrera, L. Ledo, M. Delgado, and J. V. De Oliveira, "GKFP: A new fuzzy clustering method applied to bearings diagnosis," *Proceedings - 2018 Prognostics and System Health Management Conference, PHM-Chongqing 2018*, pp. 1295–1300, 2019.
- [64] R. V. Sánchez, P. Lucero, R. E. Vásquez, M. Cerrada, J. C. Macancela, and D. Cabrera, "Feature ranking for multi-fault diagnosis of rotating machinery by using random forest and KNN," *Journal of Intelligent & Fuzzy Systems*, vol. 34, no. 6, pp. 3463-3473, 2018, pp. 3463–3473, 2018.

- [65] F. Pacheco, M. Cerrada, R. V. Sánchez, D. Cabrera, C. Li, and J. Valente de Oliveira, "Attribute clustering using rough set theory for feature selection in fault severity classification of rotating machinery," *Expert Systems with Applications Volume 71, 1 April 2017, Pages 69-86*, pp. 69–86, 2017.
- [66] M. Cerrada, R. V. Sánchez, F. Pacheco, D. Cabrera, G. Zurita, and C. Li, "Hierarchical feature selection based on relative dependency for gear fault diagnosis," *Springer Science Appl Intell 44, 687–703 (2016)*, pp. 687–703, 2016.
- [67] M. Cerrada, R. V. Sánchez, and D. Cabrera, "A semi-supervised approach based on evolving clusters for discovering unknown abnormal condition patterns in gearboxes," *Journal of Intelligent & Fuzzy Systems, vol. 34, no. 6, pp. 3581-3593, 2018*, pp. 3581–3593, 2018.
- [68] M. Cerrada, J. Aguilar, J. Altamiranda, and R. V. Sánchez, "A hybrid heuristic algorithm for evolving models in simultaneous scenarios of classification and clustering," *Springer Science Knowl Inf Syst 61, 755–798 (2019)*, 2019.
- [69] I. C, K. T, A. Martin J, and G. A, "Qualitative Data Classification using LAMDA and Other Soft Computer Methods," *Recent Advances in Artificial Intelligence Research and Development*, 2004.
- [70] L. Morales, H. Lozada, J. Aguilar, and E. Camargo, "Applicability of LAMDA as classification model in the oil production," *Springer Science Artif Intell Rev 53, 2207–2236 (2020)*, 2019.
- [71] V. Krivanek, "Application LAMDA algorithm for Fault Detection and Isolation," *Proceedings of 14th International Conference on Mechatronics, MECHATRONIKA 2011*, pp. 46–51, 2011.
- [72] B. Lamrini, M. V. Le Lann, and E. K. Benhammou, Ahmed Lakhel, "Detection of functional states by the 'LAMDA' classification technique: Application to a coagulation process in drinking water treatment," *Comptes Rendus Physique Volume 6, Issue 10, December 2005, Pages 1161-1168*, pp. 1161–1168, 2005.
- [73] A. Heng, S. Zhang, A. C. Tan, and J. Mathew, "Rotating machinery prognostics: State of the art, challenges and opportunities," *Mechanical Sys-*

- tems and Signal Processing Volume 23, Issue 3, April 2009, Pages 724-739, pp. 724–739, 2009.*
- [74] R. Yan, R. X. Gao, and X. Chen, “Wavelets for fault diagnosis of rotary machines: A review with applications,” *Signal Processing Volume 96, Part A, March 2014, Pages 1-15*, pp. 1–15, 2014.
- [75] F. A. Ruiz, C. V. Isaza, A. F. Agudelo, and J. R. Agudelo, “A new criterion to validate and improve the classification process of LAMDA algorithm applied to diesel engines,” *Engineering Applications of Artificial Intelligence Volume 60, April 2017, Pages 117-127*, pp. 117–127, 2017.
- [76] U. Haba, K. Brethee, O. Hassin, F. Gu, and A. D. Ball, “Detection and diagnosis of reciprocating compressor faults based on modulation signal bispectrum analysis of vibrations,” *30th Conference on Condition Monitoring COMADEM 2017, University of Central Lancashire, UK and Diagnostic Engineering Management*, 2017.
- [77] A. Naid, F. Gu, Y. Shao, S. Al-Arbid, and A. Ball, “Bispectrum analysis of motor current signals for fault diagnosis of reciprocating compressors,” *Key Engineering Materials*, pp. 505–511, 2009.
- [78] Y. Lei, Z. He, and Y. Zi, “A new approach to intelligent fault diagnosis of rotating machinery,” *Expert Systems with Applications Volume 35, Issue 4, November 2008, Pages 1593-1600*, pp. 1593–1600, 2008.
- [79] O. Cardona Morales, “Análisis tiempo-frecuencia de señales de vibraciones mecánicas para la detección de fallos en máquinas rotativas,” Master’s thesis, Universidad Nacional de Colombia, Manizales, Colombia, 2011.
- [80] J. Lin and M. J. Zuo, “Gearbox fault diagnosis using adaptive wavelet filter,” *Mechanical Systems and Signal Processing Volume 17, Issue 6, November 2003, Pages 1259-1269*, pp. 1259–1269, 2003.
- [81] A. H. Bahmani, S. K. Shekofteh, M. Naghibzadeh, and H. Deldari, “Parallel algorithms for automatic database normalization,” *2010 The 2nd International Conference on Computer and Automation Engineering, ICCAE 2010*, pp. 157–1619, 2010.
- [82] L. Friedman and O. V. Komogortsev, “Assessment of the Effectiveness of Seven Biometric Feature Normalization Techniques,” *IEEE Transactions*



*on Information Forensics and Security, vol. 14, no. 10, pp. 2528-2536, Oct. 2019, pp. 2528–2536, 2019.*

- [83] W. J. Wu and Y. Xu, “Correlation analysis of visual verbs’ subcategorization based on Pearson’s correlation coefficient,” *2010 International Conference on Machine Learning and Cybernetics, ICMLC 2010*, pp. 2042–2046, 2010.
- [84] N. Sapkota, A. Alsadoon, P. W. C. Prasad, A. Elchouemi, and A. K. Singh, “Data Summarization Using Clustering and Classification : Spectral Clustering Combined with k-Means Using NFPH,” *International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), Faridabad, India, 2019, pp. 146-151, pp. 146–151, 2019.*
- [85] L. Morales, J. Aguilar, D. Chávez, and C. Isaza, “Lamda-had, an extension to the lamda classifier in the context of supervised learning,” *International Journal of Information Technology & Decision Making VOL. 19, NO. 01, 2020.*

# Anexos A

## Atributos estadísticos en el dominio del tiempo y la frecuencia

### A.1. Atributos estadísticos en el dominio del tiempo

Tabla A.1: Atributos estadísticos en el dominio del tiempo

ítem	Nombre Características	Fórmula
1	Mean	$T1 = \frac{1}{N} \sum_{i=1}^N X_i$
2	Variance	$T2 = \frac{1}{N} \sum_{i=1}^N (X_i - T1)^2$
3	Standard desviation (STD)	$T3 = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - T1)^2}$
4	Root mean square (RMS)	$T4 = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i)^2}$
5	Max value	$T5 = \max (X_i)$
6	Kurtosis	$T6 = \frac{N \sum_{i=1}^N (X_i - T1)^4}{[\sum_{i=1}^N (X_i - T1)^2]^2}$
7	Skewness	$T7 = \frac{N \sum_{i=1}^N (X_i - T1)^3}{T3^3}$
8	Energy operator (EO)	$T8 = \frac{N^2 \sum_{i=1}^N (\Delta y_i - \Delta \bar{y})^4}{[\sum_{i=1}^N (\Delta y_i - \Delta \bar{y})^2]^2}$

ANEXOS A. ATRIBUTOS ESTADÍSTICOS EN EL DOMINIO DEL TIEMPO Y LA FRECUENCIA 194

		$\Delta_{\bar{y}} = \text{mean of } \Delta_y$ $\Delta_{\bar{y}i} = X_{i+1}^2 - X_i^2$
9	Mean of absolute values (Mean abs)	$T_9 = \frac{1}{N} \sum_{i=1}^N  X_i $
10	Square root amp. value (SRAV)	$T_{10} = \left( \frac{\sum_{i=1}^N \sqrt{ X_i }}{N} \right)^2$
11	Shape factor (SF)	$T_{11} = \frac{T_4}{T_9}$
12	Impulse factor (IF)	$T_{12} = \frac{T_5}{T_9}$
13	Crest factor	$T_{13} = \frac{T_5}{T_4}$
14	Clearance factor	$T_{14} = \frac{T_5}{\frac{1}{N} \sum_{i=1}^N (X_i)^2}$
15	CPT1	$T_{15} = \frac{\sum_{i=1}^N \log( X_i +1)}{N * \log(T_3+1)}$
16	CPT2	$T_{16} = \frac{\sum_{i=1}^N \exp(X_i)}{N * \exp(T_3)}$
17	CPT3	$T_{17} = \frac{\sum_{i=1}^N \sqrt{ X_i }}{N * (T_2)}$
18	MSE	$T_{18} = \frac{1}{N} \sum_{i=1}^N (X_i - T_1)^2$
19	Log-log ratio (LLR)	$T_{19} = \frac{1}{\log(T_3)} \sum_{i=1}^N \log( X_i  + 1)$
20	SDIF	$T_{20} = \frac{T_3}{T_9}$
21	5th statistical moment (FIFTHM)	$T_{21} = \sum_{i=1}^N (x_i - T_1)^5$
22	6th statistical moment (SIXTHM)	$T_{22} = \sum_{i=1}^N (x_i - T_1)^6$

23	5th norm. moment (NM)	$T23 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - T_1)^5}{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (x_i - T_1)^2\right)^5}}$
24	Kth central moment (KTHCM)	$T24 = \text{mean} [(x_i - T_1)^k]$ <i>k is set to 3</i>
25	Pulse indicators (PI)	$T25 = \frac{T_5}{T_1}$
26	Margin index (MI)	$T26 = \left(\frac{T_5}{\frac{1}{N} \sum_{i=1}^N \sqrt{x_i}}\right)^2$
27	MDR	$T27 = \frac{T_1}{T_3}$
28	Difference absolute variance value	$T28 = \frac{1}{N-2} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2$
29	Min value	$T29 = \text{mean}(x_i)$
30	Peak value	$T30 = \frac{1}{2} [T_5 - T_{29}]$
31	Peak to peak	$T31 = T_5 - T_{30}$
31	Hist lower bound (Hist LB)	$T31 = T_{29} - \frac{1}{2} \frac{T_5 - T_{30}}{N-1}$
32	Hist upper bound (Hist UB)	$T32 = T_5 - \frac{1}{2} \frac{T_5 - T_{30}}{N-1}$
34	Latitude factor (LF)	$T34 = \frac{\max( x_i )}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i }\right)^2}$
35	Norm. N. Neg Likelihoog (NNNL)	$T35 = \ln \frac{T_3}{T_4}$
36	Waveforms indicator (WI)	$T36 = \frac{T_4}{T_1}$
37	Shannon entropy (WI)	$T37 = - \sum_{i=1}^N x_i^2 * \log(x_i^2)$
38	Log energy entropy (LEE)	$T38 = \sum_{i=1}^N \log(x_i^2)$

		where $\log(0) = 0$
39	Threshold entropy	$T39 =$ $\text{Threshold} \begin{cases} 1, & \text{if }  x_i  > p, \text{ and} \\ 0, & \text{elsewhere} \end{cases}$ <p><i>p is set to 0,2</i></p>
40	Sure entropy	$T40 = n - \#\{i \text{ such that }  x_i  \leq p\}$ $+ \sum_i \min(x_i^2, p^2)$ <p><i>p is set to 0,2</i></p>
41	Norm entropy	$T41 = \sum_{i=1}^N  x_i ^p$ <p><i>p is set to 0,2</i></p>
42	Slope sign change (SSC)	$T42 = \sum_{i=2}^N f[(x_i - x_{i-1})$ $* (x_i - x_{i+1})]$
43	Zero Crossing (ZC)	$T43 = \sum_{i=1}^N \text{step}[$ $\text{sign}(-x_i * x_{i+1})]$ $\text{step} \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{if } x = 0 \\ -1, & \text{if } x < 0 \end{cases}$ $\text{step} \begin{cases} 1, & \text{if } x > 0 \\ \frac{1}{2}, & \text{if } x = 0 \\ 0, & \text{if } x < 0 \end{cases}$
44	Wilson amplitude	$T44 = \sum_{i=1}^N f[ (x_i - x_{i+1})  - T$

ANEXOS A. ATRIBUTOS ESTADÍSTICOS EN EL DOMINIO DEL TIEMPO Y LA FRECUENCIA 197

		$\text{Threshold} \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{if } x < 0 \end{cases}$ <p>T = Threshold set to 0,2</p>
45	Miopulse percentage rate (MYOP)	$T45 = \frac{1}{N} \sum_{i=1}^N [f (x_i) ];$ $\text{Threshold} \begin{cases} 1, & \text{if } x > \\ & \text{threshold} \\ 0, & \text{otherwise} \end{cases}$ <p>The Threshold set to 0,2</p>
46	Wavelength	$T46 = \sum_{i=1}^N  x_{i+1} - x_i $
47	Log detector	$T47 = e^{\frac{1}{N} \sum_{i=1}^N \log x_i}$
48	Mean of amplitude (MA)	$T48 = \sum_{i=1}^N  x_{i-1} - x_i $
49	Energy	$T49 = \sum_{i=1}^N  x_i ^2$
50	Integrated signal	$T50 = \sum_{i=1}^N  x_i $
51	Modified mean absolute value 1	$T51 = \frac{1}{N} W_i  x_i $ $W_i = 1; \text{ if } 0,25N \leq n \leq 0,75N$ $W_i = 0,5; \text{ otherwise}$
52	Modified mean absolute value 2	$T52 = \frac{1}{N} W_i  x_i $ $W_i = 1; \text{ if } 0,25N \leq n \leq 0,75N$ $\frac{4}{N}; \text{ if } n \leq 0,25N$ $\frac{4(n-N)}{N}; \text{ if } n > 0,75N$

ANEXOS A. ATRIBUTOS ESTADÍSTICOS EN EL DOMINIO DEL TIEMPO Y LA FRECUENCIA 198

53	Mean absolute value slope (MVASLP)	$T53 = T9_{i+1} - T9_i$
54	Delta RMS (DRMS)	$T54 = T4_{i+1} - T4_i$
55	Root sum of square (RSSQ)	$T55 = \sqrt{\sum_{i=1}^N  x_i ^2}$
56	Weighted SSR absolute (WSSRA)	$T56 = \frac{1}{N} (\sum_{i=1}^N \sqrt{ x_i })^2$
57	Log RMS	$T57 = \log(T4)$
58	Conduction velocity of signal (CVS)	$T58 = (\frac{1}{N-1} \sum_{i=1}^N x_i)^2$
59	Average amplitude change (AAC)	$T59 = \frac{1}{N} \sum_{i=1}^{N-1}  x_{i+1} - x_i $
60	Weibull negative log-likelihood (WNLL)	$T60 = -\sum_{i=1}^N \log \left[ (T11 * \eta)^{-T1} *  x_i ^{T1-1} \exp \frac{ x_i ^{T1}}{\eta} \right]$ <p><i>where <math>\eta</math> is scale factor</i></p>
61	V-ORDER 3	$T61 = \sqrt[3]{\frac{1}{N} \sum_{i=1}^N  x_i ^3}$
62	Maximun fractal Lenght (MFL)	$T62 = \log_{10} \sqrt{\frac{1}{N} \sum_{i=1}^{N-1} ( x_i  - x_{i+1})^2}$
63	Difference abosulte STD (DASDV)	$T63 = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} ( x_{i+1}  - x_i)^2}$
64	Higher order temp. moments (TM)	$T64 =  \frac{1}{N} \sum_{i=1}^N x_i^m $ <p><i>where <math>m</math> is set to 3 as default</i></p>

## A.2. Atributos estadísticos en el dominio de la frecuencia

Tabla A.2: Atributos estadísticos en el dominio de la Frecuencia

ítem	Nombre Características	Fórmula
1	Mean Frequency	$F1 = \frac{\sum_{k=1}^K X_k}{K}$
2	Variancef	$F2 = \frac{\sum_{k=1}^K (X_k - F1)^2}{K-1}$
3	Skewnessf	$F3 = \frac{\sum_{k=1}^K (X_k - F1)^3}{(X_k - F1)^3 K (\sqrt{F2})^3}$
4	Kurtosisf	$F4 = \frac{\sum_{k=1}^K (X_k - F1)^4}{K (F2)^4}$
5	Central Frequency	$F5 = \frac{\sum_{k=1}^K f_k X(k)}{\sum_{k=1}^K X(k)}$
6	STDF	$F6 = \sqrt{\frac{\sum_{k=1}^K (f_k - F5)^2 X(k)}{\sum_{k=1}^K X(k)}}$
7	RMSF	$F7 = \sqrt{\frac{\sum_{k=1}^K f_k^2 X(k)}{\sum_{k=1}^K X(k)}}$
8	CP1	$F8 = \frac{\sum_{k=1}^K (f_k - F5)^3 X(k)}{K (F6)^3}$
9	CP2	$F9 = \frac{F6}{F5}$
10	CP3	$F10 = \frac{\sum_{k=1}^K (f_k - F5)^{\frac{1}{2}} X(k)}{K \sqrt{F6}}$
11	CP4	$F11 = \frac{\sum_{k=1}^K (f_k - F5)^3 X(k)}{F6^2 K}$
12	CP5	$F12 = \sqrt{\frac{\sum_{k=1}^K f_k^4 X(k)}{\sum_{k=1}^K f_k^2 X(k)}}$



ANEXOS A. ATRIBUTOS ESTADÍSTICOS EN EL DOMINIO DEL TIEMPO Y LA FRECUENCIA 200

13	Spectral centroid	$F13 = \frac{\sum_{k=1}^K kX(k)}{\sum_{k=1}^K X(k)}$
14	Spectral spread	$F14 = \sqrt{\frac{\sum_{k=1}^K (K-F13)^2 X(k)}{\sum_{k=1}^K X(k)}}$
15	Spectral entropy	$F15 = -\sum_{k=1}^{K-1} P_n(k) \log_2[P_n(k)]$ <p><i>where <math>P_n</math> is the normalized total spectral energy</i></p> $P_n(k) = \frac{X(k)}{\sum_{k=1}^K X(k)}$
16	Total power	$F16 = \sum_{k=1}^M P(k)$
17	Median frequency	$F17 = \frac{1}{2} \sum_{k=1}^M P(k)$
18	Peak frequency	$F18 = \max(P(k)), k = 1, \dots, M.$
19	First spectral moment	$F19 = \sum_{k=1}^M P(k) f_k$
20	Second spectral moment	$F20 = \sum_{k=1}^M P(k) f_k^2$
21	Third spectral moment	$F21 = \sum_{k=1}^M P(k) f_k^3$
22	Fourth spectral moment	$F22 = \sum_{k=1}^M P(k) f_k^4$
23	Variance of central frequency (VCF)	$F23 = \frac{F20}{F16} - \left(\frac{F19}{F16}\right)^2$
24	Frequency deformation	$F24 = \frac{\sqrt{\frac{F20}{F16}}}{\frac{F19}{F16}}$
25	Frequency ratio (FR)	$F25 = \sum_{LLC=f_{min}}^{ULC=f_{max}/2} P_k /$

ANEXOS A. ATRIBUTOS ESTADÍSTICOS EN EL DOMINIO DEL TIEMPO Y LA FRECUENCIA 201

$$\sum_{LHC=f_{max/2+1}^{UHC=f_{max}} P_k$$

*where m is set to 3 as default*