



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

IDENTIFICACIÓN AUTÓNOMA DE FALLAS EN SISTEMAS MONITOREADOS BASADO  
EN REDES ADVERSARIAS GENERATIVAS (GANS)

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL MECÁNICO

CRISTÓBAL NICOLÁS GARRIDO CÁCERES

PROFESOR GUÍA:

ENRIQUE ANDRÉS LÓPEZ DROGUETT

MIEMBROS DE LA COMISIÓN:

MARCOS EDUARDO ORCHARD CONCHA

VIVIANA ISABEL MERUANE NARANJO

SANTIAGO DE CHILE

2018

## **RESUMEN DE LA MEMORIA PARA OPTAR**

**AL TÍTULO DE:** Ingeniero Civil Mecánico

**POR:** Cristóbal Nicolás Garrido Cáceres

**FECHA:** 08/01/2018

**PROFESOR GUÍA:** Enrique Andrés López Droguett

### **IDENTIFICACIÓN AUTÓNOMA DE FALLAS EN SISTEMAS MONITOREADOS BASADO EN REDES ADVERSARIAS GENERATIVAS (GANS)**

El presente trabajo propone y valida un procedimiento para clasificación de fallas usando señales de vibraciones mecánicas en rodamientos con fallas inducidas.

Este procedimiento consiste en obtener imágenes tiempo-frecuencia para entrenar una Red Adversaria Generativa (GAN). Luego mediante algoritmos de clustering aplicados a salidas de su arquitectura, se obtienen los grupos con fallas de iguales síntomas y características. Para esto se ensayan diversas configuraciones considerando dos tipos de imágenes (espectrogramas y escalogramas), cuatro arquitecturas GAN (DCGAN, InfoGAN, MRGAN y Wasserstein GAN) y dos algoritmos de clustering (K-means y spectral clustering).

En primera instancia se repasan los fundamentos de las fallas en rodamientos: sus síntomas y metodologías usadas para su diagnóstico; luego se presentan los antecedentes respecto a los diversos componentes del procedimiento y los criterios de evaluación.

Para su validación se usan sets de datos de vibraciones mecánicas con fallas ya clasificadas (MFPT y CWRU). Mediante indicadores se comparan la clasificación real con la obtenida, resaltando las mejores configuraciones para el procedimiento.

Los ensayos muestran que las arquitecturas GAN InfoGAN y MRGAN junto al algoritmo K-means poseen un comportamiento más estable en el procedimiento. Es más, mediante el estudio de la función de costos es posible determinar si el entrenamiento resulta efectivo o no, proponiéndose un estudio más acabado respecto a un criterio de identificación para obtener mejores desempeños.

Además se realiza un análisis entre las clasificaciones obtenidas y las reales teniendo consistencia entre los resultados obtenidos por el procedimiento propuesto y los entregados por los métodos de diagnóstico usados actualmente, ya sea mediante el estudio de los mismo o consultando bibliografía.

También se incorpora un set de ensayo de degradación continua. Usando la mejor configuración de las pruebas anteriores se logran detectar estados de falla. Sin embargo el diagnóstico no puede ser concluyente ya que aparecen nuevos fenómenos en estos datos como fallas multimodales, no consideradas inicialmente.

Finalmente se proponen algunas extensiones a fin de poder estudiar de manera correcta este último caso que resulta ser más cercano a las aplicaciones que los dos primeros, como considerar la secuencia de las mediciones o determinar anteriormente los modos de fallas presentes en los datos.

*A todos los que me han acompañado por este camino,  
En especial a mis padres por haberme soportado*

## **Agradecimientos.**

El presente trabajo representa la culminación de un ciclo comenzado allá por el 2011, por lo cual es necesario en primera instancia agradecer a todos los que han participado en este proceso.

En primera instancia pido disculpas a mi familia, por haberlos postergado más de alguna vez en favor de mis estudios, en particular hago memoria mis abuelos Samuel y Francisco que lamentablemente no sobrevivieron para estar en este momento, por lo cual en este trabajo me doy la licencia de honrar su memoria. A los demás espero que esta investigación sea digna de los sacrificios realizados para el resto de mis familiares.

Especialmente agradezco a mis padres Angélica y Jorge (a quienes dedico en especial este trabajo), que siempre me han dado el apoyo y el ejemplo con su trabajo. Han sido el aliento en más de alguna ocasión a lo largo de estos 6 o 7 años. Mención especial también a mi tío René que ha sabido suplir muchas veces este rol dando también esas palabras que a veces son tan necesarias. Finalmente agradezco a mi hermano Felipe que (casi) siempre ha estado dispuesto a escucharme y discutir conmigo diversas ideas y tópicos aunque a veces no quiera.

Me corresponde también expresar mi gratitud a todas las amistades y amigos que he formado a lo largo de este ciclo, especialmente a Felipe Toledo y Manuel Durán cuya amistad ha trascendido lo profesional y espero que continúe así por muchos años más. También debo hacer mención a los miembros del laboratorio SPEL que han sido una parte importante en mi estancia en la universidad.

Entrando de lleno en el trabajo corresponde a agradecer a los miembros de la comisión por la confianza y libertad otorgada para el desarrollo del presente trabajo. A mi profesor guía por tenerme paciencia más de alguna vez y a todos por las recomendaciones que han hecho de este documento algo significativamente mejor.

También agradezco a los académicos y compañeros de la universidad que en alguna ocasión me han dado algún dato o recomendación (a veces sin ni siquiera saberlo) para este trabajo por haber contribuido a su elaboración.

Finalmente es mi deber corresponder a los académicos y administrativos principalmente de los departamentos de Ingeniería Mecánica e Ingeniería Eléctrica de la universidad de Chile; a mis compañeros a lo largo de estos años por haber compartido junto a mí este ciclo, así como a la gente del Instituto Nacional por la preparación dada para llegar a este lugar.

Por segunda instancia debo disculparme de haber no mencionado a alguien en este agradecimiento, pero si siente haber contribuido a esto, considérese también dentro del grupo.

Por último, dejo una declaración de intenciones parafraseando a Winston Churchill (aunque fuera de contexto respecto a la original), ya que si bien este trabajo representa el final de un ciclo, pero... *Nahh, este no es el final, no es ni siquiera el principio del final. Puede ser, más bien, el final del principio.*

## Tabla de Contenido

1. Introducción.....	1
2. Motivación.....	2
3. Objetivos.....	3
3.1. Objetivos específicos.....	3
4. Alcances.....	4
5. Antecedentes y discusión bibliográfica.....	5
5.1. Diagnóstico y pronóstico de fallas en rodamientos o cojinetes.....	5
5.1.1. Diagnóstico de fallas en rodamientos.....	5
5.1.2. Pronostico de fallas en sistemas rotativos.....	8
5.1.3. Fases de deterioro de un rodamiento.....	9
5.2. Redes Adversarias Generativas (GANs).....	9
5.2.1. Equilibrio de Nash.....	11
5.2.2. Redes Profundas Convolucionales Adversarias Generativas (DCGAN).....	11
5.2.3. Redes Adversarias Generativas con Información Mutua InfoGAN.....	12
5.2.4. Redes Adversarias Generativas con Regularización de Modos (MRGAN).....	12
5.2.5. Redes Adversarias Generativas Wasserstein (Wasserstein GAN o WGAN).....	13
5.3. Algoritmos de agrupamiento o clustering.....	14
5.3.1. Algoritmo K-means.....	14
5.3.2. Algoritmo Spectral Clustering.....	15
6. Metodología.....	16
6.1. Procedimiento propuesto.....	16
6.2. Sets de datos utilizados.....	17
6.2.1. MFPT.....	17
6.2.2. CWRU.....	20
6.2.3. FEMTO-ST.....	21
6.3. Procesamiento de datos a usar para el entrenamiento.....	22
6.3.1. Análisis de datos.....	22
6.3.2. Análisis de Fourier por intervalos (SFFT).....	22
6.3.3. Transformada de Wavelet.....	23
6.3.4. Kurtograma Rápido.....	23
6.4. Extracción de características.....	24

6.4.1.	DCGAN.....	24
6.4.2.	InfoGAN.....	25
6.4.3.	MRGAN.....	26
6.4.4.	Wasserstein GAN.....	27
6.5.	Criterios de Evaluación.....	28
6.5.1.	Adjusted Rand Index (ARI).....	28
6.5.2.	Información Mutua Normalizada (NMI).....	29
6.5.3.	Pureza de los clústeres.....	30
7.	Resultados.....	31
7.1.	Procedimiento completo: SFFT y WL, GAN y clustering para señales de vibración sin preprocesamiento.....	31
7.1.1.	MFPT.....	33
7.1.2.	CWRU.....	37
7.2.	Hallazgos y mejoras al procedimiento.....	42
7.2.1.	Análisis del costo del discriminador.....	42
7.3.	Entrenamiento con análisis de envolvente.....	57
7.3.1.	MFPT.....	57
7.3.2.	CWRU.....	60
7.4.	Extensión a vibraciones con rodamiento bajo degradación continua.....	61
7.4.1.	FEMTO-ST.....	61
8.	Discusión de resultados.....	66
8.1.	Consideraciones generales.....	66
8.1.1.	Datos procesados.....	66
8.1.2.	Modelos GANs.....	68
8.1.3.	Algoritmo de Clustering.....	69
8.2.	MFPT.....	71
8.3.	CWRU.....	74
8.4.	FEMTO-ST.....	75
9.	Conclusiones.....	77
10.	Bibliografía.....	80
11.	Anexos.....	82
11.1.	Tablas de resultados diversas arquitecturas.....	82

11.1.1. MFPT.....	82
11.1.2. CWRU.....	86
11.2. Tablas de resultados para distintas épocas.....	90
11.2.1. MFPT.....	90
11.2.2. CWRU.....	95
11.3. Gráficos de clasificación v/s tiempo en FEMTO-ST.....	102
11.3.1. Set de entrenamiento.....	102
11.3.2. Set de validación.....	105

## Índice de tablas.

Tabla 6.1: Frecuencias de resonancia calculadas, rodamiento datos MFPT .....	19
Tabla 6.2: Frecuencias de resonancia calculadas, rodamiento Drive End (DE) datos CWRU .....	21
Tabla 7.1: Resumen de indicadores obtenidos por las arquitecturas usadas para el caso MFPT con transformada de wavelets y SFFT .....	33
Tabla 7.2: Resumen de indicadores obtenidos por las arquitecturas usadas para el caso MFPT con transformada de wavelets y SFFT .....	37
Tabla 7.3: Iteraciones dónde se ha obtenido el costo máximo del discriminador .....	43
Tabla 7.4: Iteraciones dónde se ha obtenido el costo máximo del discriminador .....	44
Tabla 7.5: Matriz de contingencia MRGAN DIS/KM época 1 303, datos de entrenamiento MEFPT .....	48
Tabla 7.6: Matriz de contingencia MRGAN DIS/KM época 1 303, datos de validación MFPT..	48
Tabla 7.7: Matriz de contingencia InfoGAN DIS/KM época 213, datos de entrenamiento CWRU .....	55
Tabla 7.8: Matriz de contingencia InfoGAN DIS/KM época 213, datos de validación CWRU...	56
Tabla 7.9: Indicadores obtenidos por la arquitectura MRGAN para el caso MFPT con transformada de wavelets sobre envolventes de las señales.....	58
Tabla 7.10: Matriz de contingencia MRGAN DIS/KM iteración 35 565, datos de entrenamiento, set MFPT con wavelets de las señales envolventes.....	59
Tabla 7.11: Matriz de contingencia MRGAN DIS/KM iteración 35 565, datos de validación, set MFPT con wavelets de las señales envolventes .....	60
Tabla 7.12: Resumen de secuencia seguida por las muestras para cada rodamiento en el set FEMTO-ST usando imágenes de transformada de wavelets procesadas por una MRGA y un algoritmo K-means en la penúltima capa del discriminador (set de entrenamiento) .....	65
Tabla 7.13: Resumen de secuencia seguida por las muestras para cada rodamiento en el set FEMTO-ST usando imágenes de transformada de wavelets procesadas por una MRGA y un algoritmo K-means en la penúltima capa del discriminador .....	65
Tabla 8.1: Comparación indicadores arquitecturas MRGAN DIS/KM usando transformada de wavelets y SFFT, caso MFPT.....	67
Tabla 8.2: Comparación indicadores arquitecturas MRGAN DIS/SC usando transformada de wavelets y SFFT, caso CWRU .....	67



## Índice de ilustraciones.

Figura 5.1: Partes de un rodamiento.....	5
Figura 5.2: ejemplos de señales de vibración.....	6
Figura 5.3: Espectro esperado para un rodamiento con falla en la pista exterior.....	7
Figura 5.4: Espectro esperado para un rodamiento con falla en la pista interior .....	7
Figura 5.5: Espectro esperado para un rodamiento con falla en el elemento rodante .....	7
Figura 5.6: Espectro esperado para un rodamiento con falla en jaula .....	8
Figura 5.7: Fases de deterioro de un rodamiento.....	9
Figura 5.8: Esquema del modelo de GAN.....	11
Figura 5.9: Ejemplo de arquitectura de red convolucional para el generador .....	11
Figura 5.10: Arquitectura InfoGAN .....	12
Figura 5.11: Arquitectura MRGAN.....	13
Figura 5.12: Arquitectura Wasserstein GAN .....	14
Figura 6.1: Estructura del procedimiento de identificación propuesto.....	16
Figura 6.2: Espectros para las tres condiciones presentadas por la base MFPT .....	19
Figura 6.3: Montaje de generación de datos CWRU .....	20
Figura 6.4: Montaje para la prueba de rodamientos del set de datos FEMTO-ST .....	21
Figura 6.5: Arquitectura DCGAN usada .....	24
Figura 6.6: Arquitectura InfoGAN usada .....	25
Figura 6.7: Arquitectura MRGAN usada .....	26
Figura 6.8: Arquitectura WGAN usada.....	27
Figura 7.1: Ejemplos de imágenes obtenidas a partir de señales de vibraciones mecánicas .....	31
Figura 7.2: Ejemplos de imágenes generadas para el caso MFPT considerando el entrenamiento con wavelets .....	33
Figura 7.3: PCA para los puntos de salida del discriminador DCGAN para el caso MFPT (wavelets).....	35
Figura 7.4: PCA para los puntos a la salida del discriminador en MRGAN (wavelets) .....	36
Figura 7.5: Ejemplos de imágenes generadas para el caso CWRU considerando el entrenamiento con wavelets .....	37
Figura 7.6: PCA para los puntos a la salida del discriminador en DCGAN para el casos CWRU (wavelets).....	39
Figura 7.7: PCA para los puntos a la salida del discriminador en InfoGAN para el caso CWRU (wavelets).....	40

Figura 7.8: PCA para los puntos a la salida del discriminador en MRGAN para el caso CWRU (wavelets).....	41
Figura 7.9: Funciones de costo para el discriminador en MFPT (wavelets) de las GANs usadas	43
Figura 7.10: Funciones de costo para el discriminador en CWRU (wavelets) de las GANs usadas .....	44
Figura 7.11: Indicadores obtenidos para MRGAN DIS/LM en el casos MFPT para varios puntos del entrenamiento .....	46
Figura 7.12: indicadores obtenidos para DCGAN DIS/KM en el caso MFPT para varios puntos del entrenamiento .....	47
Figura 7.13: PCA MRGAN DIS/KM para la iteración con mejores indicadores (época 1 303) ..	48
Figura 7.14: Indicadores obtenidos para InfoGAN DIS/KM en el caso CWRU para varios puntos del entrenamiento .....	52
Figura 7.15: indicadores obtenidos para MRGAN DIS/KM en el caso CWRU para varios puntos del entrenamiento .....	53
Figura 7.16: PCA InfoGAN DIS/KM para la iteración con los mejores indicadores (época 213)	54
Figura 7.17: Ejemplo de transformadas de wavelets usando las envolventes de las señales de vibraciones mecánicas .....	57
Figura 7.18: Función de costos MRGAN DIS/KM usando wavelets para el caso MFPT con la envolvente de las señales .....	57
Figura 7.19: PCA MRGAN DIS/KM para la iteración 35 365 usando escalogramas para la envolvente de las señales .....	59
Figura 7.19: Ejemplo de imágenes del set FEMTO-ST usadas para el entrenamiento del modelo .....	61
Figura 7.20: Clasificación de muestras rodamiento Bearing 3_2 (set de entrenamiento FEMTO-ST) .....	63
Figura 7.21: Clasificación de muestras rodamiento Bearing 3_2 (set de entrenamiento FEMTO-ST) .....	64
Figura 8.1: PCA para los puntos a la salida del discriminador en InfoGAN para el caso MFPT (wavelets).....	70
Figura 8.2: Ejemplos de muestras erróneamente clasificadas en MFPT (mejor resultado) .....	71
Figura 8.4: PCAs MFPT configuración MRGAN WL DIS/KM.....	73
Figura 8.5: Espectro para la envolvente de las señales en pista exterior clasificadas erróneamente como línea base .....	74
Figura 8.6: Comparación de muestras entre MFPT y FEMTO-ST .....	76

## 1. Introducción.

La masificación de sensores, sistemas de adquisición, proceso y almacenamiento de datos ha permitido la proliferación de información en el último tiempo. Actualmente es posible monitorear sistemas como maquinas rotatorias de manera continua. Sin embargo, la identificación del estado de salud de un sistema resulta imposible de analizar usando toda esa información mediante los métodos clásicos como el procesamiento de señales y el análisis de un experto. La inteligencia artificial, en particular el aprendizaje profundo son una herramienta de utilidad para hacer le uso de esta información para este fin.

El presente trabajo que lleva por nombre *Identificación autónoma de fallas en sistemas monitoreados basado en Redes Adversarias Generativas (GANs)* propone una metodología basada en redes adversarias generativas y algoritmos de agrupamiento (clustering) para la identificación no supervisada de fallas usando datos masivos. En particular, se estudia el caso de señales de vibraciones mecánicas en rodamientos para validar el procedimiento de identificación.

Las redes adversarias generativas (GANs por sus siglas en inglés) son un modelo generativo de aprendizaje, que actualmente dispone una activa área de investigación en el área de las ciencias de la computación y también importantes aplicaciones.

El objetivo principal de este trabajo es desarrollar y evaluar un procedimiento para identificar fallas (tipos o estados de fallas) de forma completamente autónoma en sistemas bajo monitoreo. Para esto el procedimiento posee tres etapas: primero, las señales de vibración son procesadas para generar diagramas tiempo-frecuencia. Segundo, un modelo basado en GANs para procesar estas imágenes y extraer las características de la señal procesada. Y por último, la aplicación de un algoritmo de clustering para separar las señales por tipo de falla que presentan.

Los sets de datos considerados para la evaluación son:

- Society of machinery Failure Prevention Technology<sup>1</sup> (MFPT).
- Case Western Reserve University<sup>2</sup> (CWRU).
- Franche-Comté Electronics Mechanics Thermal Science and Optics Sciences and Technologies (FEMTO-ST)<sup>3</sup>.

En la primera parte se presentan las motivaciones que inspiran el desarrollo de este trabajo. Luego los objetivos y alcances del mismo. Después, se hace una revisión de los antecedentes y bibliografía a considerar para las partes posteriores. El siguiente capítulo presenta la metodología usada, acto seguido se presentan los resultados y hallazgos del estudio. A continuación se realiza el análisis y la discusión de los resultados. En la última parte se establecen las conclusiones relevantes de la investigación.

La intención de este trabajo es aproximar el procedimiento propuesto hacia el monitoreo de sistemas continuos, identificando sus fortalezas como debilidades en este posible uso.

---

<sup>1</sup> <https://www.mfpt.org/FaultData/FaultData.htm>

<sup>2</sup> <https://csegroups.case.edu/bearingdatacenter/pages/download-data-file>

<sup>3</sup> <http://www.femto-st.fr/en/Research-departments/AS2M/Research-groups/PHM/IEEE-PHM-2012-Data-challenge.php>

## 2. Motivación.

El mantenimiento de maquinaria como actividad no genera valor a los procesos productivos o una estructura de servicios. Por ejemplo, un avión genera ingresos por transportar pasajeros y no por estar en el hangar en reparaciones. Por lo tanto, para los intereses de los dueños e inversionistas las tareas de mantenimiento deben ser reducidas al mínimo posible; pero a la vez garantizar el funcionamiento de la maquinaria.

Los sistemas de monitoreo permiten evaluar in situ el estado de salud de los diversos componentes. Los cuales, bajo el paradigma anterior deben ser usados lo máximo posible mientras garanticen el funcionamiento de los sistemas.

El problema es que la cantidad de información recolectada por los sensores hace intratable la identificación del estado de salud de estos equipos mediante el análisis de un experto. Por ejemplo, si se considera un sensor de vibraciones con una frecuencia de muestreo de 48 000 muestras por segundo y 12 bits por muestra se tendrían 6,22 Gb de mediciones para analizar en 24 horas. El desafío es aún mayor si se considera que usualmente no se tiene un solo sensor y por lo general se requiere el análisis de salud de una flota completa de equipos (que puede variar desde unas decenas a cientos de ellos).

Las herramientas basadas en aprendizaje profundo (Deep Learning en inglés) representan un aporte a la resolución de este tipo de problemas porque trabajan con gran cantidad de datos. En particular son de interés los métodos de aprendizaje no supervisado, ya que debido a la masividad de información se hace imposible clasificar a priori las características de un grupo para entrenar algún modelo supervisado. Las Redes Adversarias Generativas resultan atractivas porque cumplen con las propiedades anteriormente mencionadas.

Una de las desventajas de las GANs es que al estar aún en estudio no se han propuesto métodos de clasificación sin incluir algoritmos adicionales como los de agrupamiento (clustering). Estos procedimientos permiten separar puntos en grupos basándose en algún criterio, por ejemplo su cercanía. Otra desventaja importante es que en la fase de entrenamiento estos modelos tienen un comportamiento inestable por lo cual resulta complejo determinar cuando están bien ajustados.

Por otro lado, los rodamientos o cojinetes son piezas usuales a remplazar en la realización de un mantenimiento. Estos están presentes prácticamente en cualquier maquina rotatoria y están sujetos a los efectos de fatiga y corrosión, siendo de interés su monitoreo y diagnóstico de fallas. En primera instancia para determinar su estado y luego vida útil remanente (RUL por sus siglas en inglés).

Estas problemáticas y realidades hacen interesante el proponer un modelo que se base en GANs y algoritmos de agrupamiento para identificar autónomamente fallas en rodamientos, ya sea para poder realizar pronósticos en base al modo de falla hallado o bien intentar realizarlo con los mismos datos recolectados.

### **3. Objetivos.**

El objetivo principal de este trabajo es desarrollar un procedimiento para identificar fallas (tipos de fallas o estado de salud) de forma autónoma (sin clasificación de fallas previa) que pueda ser aplicable a sistemas bajo monitoreo en un futuro usando como elemento de extracción de características las Redes Adversarias Generativas.

#### **3.1.Objetivos específicos.**

- Estudio de técnicas de análisis tiempo-frecuencia y uso de algunas de ellas (escalogramas y espectrogramas) en las señales de vibración a utilizar.
- Estudio, búsqueda y/o adaptación de algoritmos GANs (DCGAN, InfoGAN, MRGAN y Wasserstein GAN) para ser entrenados con los datos del punto anterior.
- Estudio y selección de los algoritmos de clustering a utilizar para la extracción de características de los datos procesados por la GAN.
- Obtención de las mejores configuraciones mediante el análisis de los resultados obtenidos para los sets datos disponibles: Society of machinery Failure Prevention Technology (MFPT), Case Western Reserve University (CWRU). En particular mediante la revisión de los indicadores y el estudio en detalle de las configuraciones con mejor desempeño.
- Determinar si las configuraciones obtenidas logran la clasificación e identificación de fallas. Identificar sus limitaciones.
- Estudiar el comportamiento de la mejor configuración en datos de degradación continua en sistemas monitoreados usando el set Franche-Comté Electronics Mechanics Thermal Science and Optics Sciences and Technologies (FEMTO-ST).

#### **4. Alcances.**

Los alcances de este trabajo incluyen: el estudio del estado del arte respecto a las herramientas a utilizar. Esto es, la búsqueda y/o generación de las herramientas para resolver el problema (códigos por ejemplo). La aplicación de estas herramientas a los datos mencionados anteriormente, en particular los sets MFPT y CWRU y la evaluación de los resultados. Además, se pueden incluir algunos hallazgos y/o extensiones en la medida que aporten a la mejora o el entendimiento del procedimiento y su comportamiento, o bien se relacionen con las motivaciones del trabajo como es el caso del conjunto de datos FEMTO-ST que no busca cumplir con los objetivos del trabajo (identificar fallas de manera autónoma), sino que mostrar las ventajas y dificultades que posee el modelo propuesto en una aplicación que representa un acercamiento respecto a la problemática que motiva este estudio, dando posibilidades de profundizar en el modelo aquí tratado y avanzar hacia la solución del problema de identificación de fallas en sistemas monitoreados continuamente en base a lo expuesto en este estudio.

No forma parte del alcance el evaluar datos que no corresponden a señales de vibraciones en rodamiento. Tampoco, realizar análisis de carácter estadístico ni comparar el método propuesto con las herramientas clásicas ni otros modelos, que pueden ser usados como ayuda para validar la funcionalidad del procedimiento propuesto; mas no realizar una comparación exhaustiva con el fin de determinar cuál es el mejor método.

El alcance principal es mostrar que el procedimiento propuesto permite tanto la clasificación (tipos de fallas) como la identificación autónoma (tipo de falla y severidad) y determinar cuál o cuáles de las configuraciones tratadas son las más convenientes.

## 5. Antecedentes y discusión bibliográfica.

En esta sección se presentan las diversas herramientas y conocimientos requeridos para la comprensión del procedimiento desarrollado. En la primera parte se revisan la teoría detrás del diagnóstico y pronóstico de fallas enfocándose en rodamientos. En la segunda parte se ahonda en la estructura y propiedades de las redes adversarias generativas (GANs), detallando las redes usadas en el estudio. La última parte de los antecedentes se dedica a presentar los algoritmos de agrupamiento o clustering a utilizar en el trabajo.

### 5.1. Diagnóstico y pronóstico de fallas en rodamientos o cojinetes.

Las fallas en rodamientos se caracterizan por un daño en alguno de los componentes del rodamiento, la Figura 5.1 muestra las diferentes partes de un rodamiento.




Figura 5.1: Partes de un rodamiento (tomado de [2])

#### 5.1.1. Diagnóstico de fallas en rodamientos.

Cada componente tiene una frecuencia de resonancia particular, la cual puede ser estimada por las siguientes fórmulas dependientes de las dimensiones geométricas del rodamiento y la velocidad de rotación del mismo.

- Frecuencia de deterioro de pista exterior (BPFO)

$$BPFO = \frac{nf_r}{2} \left(1 - \frac{d}{D} \cos(\phi)\right) \quad (1)$$

- Frecuencia de deterioro de pista interior (BPFI)

$$BPFI = \frac{nf_r}{2} \left(1 + \frac{d}{D} \cos(\phi)\right) \quad (2)$$

- Frecuencia de deterioro de elementos rodantes o bolas (BSF o RSF)

$$BSF(RSF) = \frac{D}{2d} \left( 1 - \left( \frac{d}{D} \cos(\phi) \right)^2 \right) \quad (3)$$

- Frecuencia fundamental de tren o deterioro de jaula (FTF)

$$FTF = \frac{f_r}{2} \left( 1 - \frac{d}{D} \cos(\phi) \right) \quad (4)$$

En donde  $D$  es el diámetro medio del rodamiento y  $d$  el diámetro de los elementos rodantes (bolas o rodillos del rodamiento),  $f_r$  es la frecuencia de giro rodamiento,  $n$  el número de elementos rodantes presentes y  $\phi$  el ángulo de carga desde el plano radial o ángulo de contacto; correspondiente al ángulo que forma el elemento rodante con las pistas.

Cuando una falla ocurre en alguno de estos elementos, se excitan las frecuencias de resonancia del mismo; es más, cada falla posee un comportamiento particular en el espectro relacionándose con las frecuencias de giro del rodamiento o bien con frecuencias de resonancia de otros elementos. La Figura 5.2 presenta ejemplos de cómo varían las señales de vibración en el dominio del tiempo para fallas en algunos elementos, también se muestra la envolvente de estas señales, lo que será explicado con mayor detalle en la sección de técnicas para el diagnóstico de fallas.




Figura 5.2: Ejemplos de señales de vibración (superior izquierda: falla en pista exterior, superior derecha: fallo en pista interior, inferior: fallo en elementos rodantes) (tomado [3])

En lo que sigue, se detalla el comportamiento en el dominio de la frecuencia para las fallas de cada elemento de un cojinete.



### 5.1.1.1. Fallo en pista exterior.

El fallo en la pista exterior se caracteriza por un aumento de energía de la señal en la frecuencia de deterioro de la pista exterior (BPFO) y sus armónicos, como se muestra en la Figura 5.3.




Figura 5.3: Espectro esperado para un rodamiento con falla en la pista exterior (tomado de [2])

### 5.1.1.2. Fallo en pista interior.

Cuando falla en un rodamiento la pista interior aumentan los niveles de energía en la frecuencia de deterioro de la pista interior (BPFI); pero a diferencia de la pista exterior, esta pista usualmente se encuentra girando junto con el eje que sustenta, por lo cual la frecuencia de giro y sus armónicos son señales moduladoras (lo que se aprecia en el espectro como bandas laterales.), mientras que la BPFI funciona como portadora, teniéndose espectros operados como el de la Figura 5.4.




Figura 5.4: Espectro para un rodamiento con falla en la pista interior (tomado de [2])

### 5.1.1.3. Fallo en elemento rodante

Para este tipo de falla se obtienen espectros similares al caso de fallo en pista interior, con la frecuencia de deterioro de elementos rodantes (BSF) y sus armónicas actuando como portadoras, y la frecuencia fundamental de tren o jaula (FTF) actúa de moduladora junto a sus armónicas. La Figura 5.5 muestra el espectro esperado.




Figura 5.5: Espectro esperado para un rodamiento con falla en el elemento rodante (tomado de [2])

#### 5.1.1.4. Falla en jaula.

En el caso de falla en jaula, simplemente se presentan aumento en energía de la señal de vibraciones en la frecuencia fundamental de tren (FTF) y sus armónicas, como se muestra en la Figura 5.6.




Figura 5.6: Espectro esperado para un rodamiento con falla en jaula (tomado de [2])

#### 5.1.1.5. Análisis de envoltura para el diagnóstico de fallas.

El análisis de envoltura es el método de referencia actual para el diagnóstico de fallas en cojinetes. Se fundamenta en que las frecuencias de falla de los elementos se encuentran moduladas por altas frecuencias debido a las resonancias estructurales [3]; por lo cual, aplicando un filtro pasa-bandas a la señal en una banda de interés (donde la potencia de la señal se concentre, esto se puede determinar por ejemplo usando un kurtograma.) y luego desmodulando asíncronamente (tomado la envoltura de la señal filtrada.) es posible extraer la información requerida para realizar el diagnóstico de la o las fallas presentes en el rodamiento.

Para fines de este trabajo es de interés comparar el procedimiento de identificación autónoma entre las señales brutas y procesadas mediante el análisis de envoltura considerando que el diagnóstico será realizado por el modelo aprendizaje profundo propuesto. También de ser necesario se puede comparar el diagnóstico de fallas por este método y el que se estudia en esta investigación.

#### 5.1.2. Pronóstico de fallas en sistemas rotativos.

Los métodos de pronóstico de fallas resultan la herramienta más poderosa del monitoreo más allá de la identificación y diagnóstico de fallas. El pronóstico puede ser dividido principalmente en dos categorías [3]: basados en física, donde se busca un modelo matemático del modo de falla para determinar el estado del sistema a partir de mediciones que determinen el deterioro en el modo, y los basados en datos, que usan procesamiento estadístico de casos históricos. También es posible tener enfoques mixtos.

Esta sección explica grosso modo algunas extensiones que pudiese tener el procedimiento propuesto en este trabajo para pronóstico de fallas.

##### 5.1.2.1. Modelos basados en la física del problema.

Ejemplos de estos modelos son el modelamiento del crecimiento de una grieta basados en la ley de Paris [4]. Por ejemplo el conocer el modo de falla en un rodamiento permite estimar el tamaño de la grieta que lo ocasiona y es posible desarrollar un modelo de pronóstico basado en la física de este modo: el crecimiento de la grieta hasta la fractura.

##### 5.1.2.2. Modelos basados en datos

El más simple de este tipo de enfoque corresponde el análisis de tendencia, por ejemplo el nivel de vibraciones en una banda del espectro, algún componente del cepstro, la kurtosis, etc. Entran en esta categoría de pronóstico los modelos basados en redes neuronales o aprendizaje profundo, ya que permiten un modelamiento de fenómenos no lineales y complejos.

### 5.1.3. Fases de deterioro de un rodamiento.

Durante la operación de un rodamiento es posible distinguir el avance del deterioro de un rodamiento a partir de sus datos de vibración, a continuación se presentan las 4 fases de deterioro de un rodamiento:

- **Fase 1:** Inicio del funcionamiento del rodamiento, no hay presencia de fallas y es apreciable la frecuencia de giro y sus armónicos.
- **Fase 2:** aparecen lecturas de vibración muestran presencia de altas frecuencias producto de pequeños defectos que existen: las frecuencias naturales de las pistas de rodadura. Esta es la primera muestra de deterioro.
- **Fase 3:** Aparecen las frecuencias naturales de los defectos en el rodamiento, según lo visto anteriormente aumentando la magnitud de estas frecuencias según el daño.
- **Fase 4:** Fase final del rodamiento aparece el ruido de fondo de la señal, disminuyen o desaparecen las frecuencias de daño y aumentan la frecuencia de giro y sus armónicos.

La Figura 5.7 presenta espectros esquemáticos de las 4 fases de deterioro de un rodamiento.

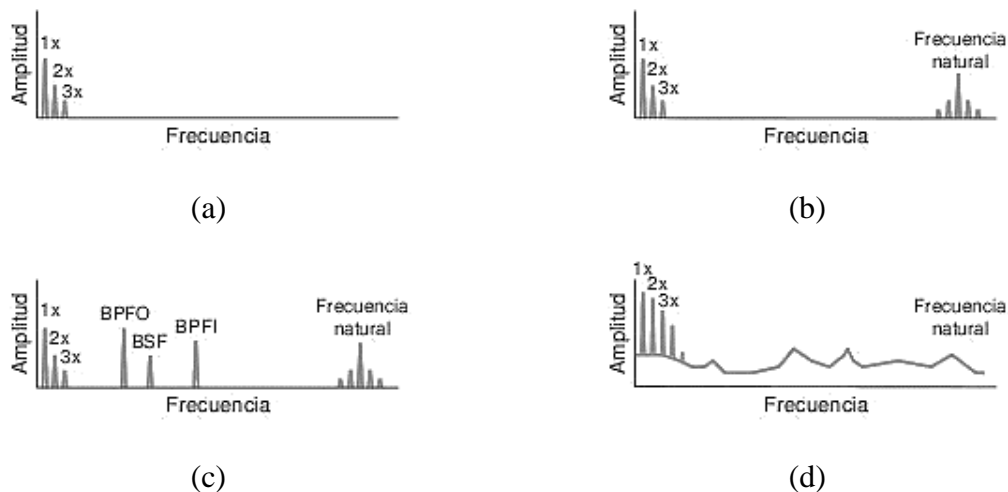


Figura 5.7: Fases de deterioro de un rodamiento, (a) Fase 1, (b) Fase 2, (c) Fase 3 y (d) Fase 4 (tomado de [2]).

### 5.2. Redes Adversarias Generativas (GANs).

Las Redes Neuronales Generativas (GANs por sus siglas en inglés) corresponden a un modelo de aprendizaje profundo. Se consideran dentro de los modelos generativos, ya que son capaces de sintetizar los datos que alimentan el modelo, es decir, crean información diferente a las que se usa en su entrenamiento, pero del mismo tipo. El entrenamiento de este modelo consiste en dos redes compitiendo en un juego no cooperativo (entrenamiento adversario). Un ejemplo de juego no cooperativo es una partida de ajedrez, donde cada jugador busca derrotar a su contendor.

Las GANs han sido propuestas por [5]. La primera red (primer jugador), llamada generador  $G(z)$  tiene como objetivo sintetizar datos que sean irreconocibles a los datos de entrenamiento. Para corroborar esto existe una segunda red conocida como discriminador  $D(x)$  la cual posee como

objetivo diferenciar los datos de entrenamiento con los sintetizados por el generador. Para esto, su estructura busca dar una alta probabilidad a los datos reales y una baja a los sintetizados. En [5] ambas redes están compuestas por perceptrones multicapa.

En términos formales, la función objetivo de este juego corresponde a un juego minimax con una función de costos  $V(D, G)$  regida por la Fórmula (5).

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (5)$$

En este caso  $D(x)$  representa al discriminador y  $G(z)$  al generador,  $x$  a los datos reales,  $p_{data}(x)$  a la distribución de estos,  $z$  es ruido con el cual se alimenta al generador para sintetizar los datos y  $p_z(z)$  su distribución. Además, se define  $p_g(z)$  como la distribución de los datos generados.

[5] demuestra que este modelo tiene un óptimo global cuando  $p_g = p_{data}$  (alcanzando un equilibrio de Nash.) en el dominio de las funciones. Además, propone un algoritmo para alcanzar este óptimo, bajo el supuesto de que los modelos tienen suficiente capacidad y tiempo de entrenamiento el cual se presenta a continuación.

Algoritmo 1: entrenamiento propuesto por [5] para las GANs,  $k$  es el número de pasos a entrenar el discriminador.

**For** numero de pasos **do**

**For**  $k$  pasos **do**

- Extraer una muestra de  $m$  ejemplos  $\{z^{(1)}, \dots, z^{(m)}\}$  como entrada de ruido para  $p_g(z)$
- Extraer una muestra de  $m$  ejemplos  $\{x^{(1)}, \dots, x^{(m)}\}$  como datos generadores para la distribución  $p_{data}(x)$
- Actualizar el discriminador ascendiendo su gradiente estocástico:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m [\log D(x^{(i)}) + \log(1 - D(G(z^{(i)})))]$$

**End for**

- Extraer una muestra de  $m$  ejemplos  $\{z^{(1)}, \dots, z^{(m)}\}$  como entrada de ruido para  $p_g(z)$
- Actualizar el generador descendiendo su gradiente estocástico:

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m [\log(1 - D(G(z^{(i)})))]$$

**End for**

Finalmente, la Figura 5.8 presenta un modelo esquemático de la GAN propuesta por [5] a fin de comprender los modelos explicados a continuación.




Figura 5.8: Esquema del modelo de GAN propuesto por [7]

### 5.2.1. Equilibrio de Nash.

Al ser el entrenamiento modelado como un juego. El objetivo es alcanzar un equilibrio de Nash (de conocer todas las jugadas posibles), aquí simplemente se recuerda la definición más simple de un equilibrio de Nash correspondiente a la situación que para cualquier jugador (en este caso nuestras redes) cambiar la estrategia no mejora su beneficio. Por lo tanto las redes son entrenadas, pudiendo o no alcanzar este equilibrio; es más, no existen antecedentes para que este sea único, por lo cual se debe analizar la evolución de las funciones de costos para ver si en algún instante se alcanza este equilibrio y los efectos que tiene el alcanzarlo o no.

Además como se explica en [6] la demostración de convergencia está hecha en el espacio de las funciones, mientras que los cambios de las redes ocurren en el espacio de parámetros, por lo cual en la práctica la red puede no necesariamente converger ni mucho menos alcanzar el equilibrio de Nash.

### 5.2.2. Redes Profundas Convolucionales Adversarias Generativas (DCGAN).

Este modelo propuesto por [7] propone reemplazar los perceptrones multicapas del primer modelo [5] por redes convolucionales para ambas redes (generador y discriminador). Se argumenta una mayor estabilidad en el entrenamiento, buena representación en los datos generados y la posibilidad de realizar aprendizaje no supervisado aplicando algoritmos de clustering a los datos obtenidos de capas del discriminador, aunque también muestra problemas como la pérdida de modos (generación de solo algunos de los tipos de datos presentados) o el colapso de modos (imposibilidad de generar datos coherentes). El modelo es idéntico al presentado en la Figura 5.8, salvo porque ahora cada red se estructura como muestra la Figura 5.9.




Figura 5.9: Ejemplo de la arquitectura de red convolucional para el generador, el discriminador posee una estructura similar, pero los datos fluirían de derecha a izquierda (tomado de [7])

### 5.2.3. Redes Adversarias Generativas con Información Mutua InfoGAN.

InfoGAN, propuesta por [8] realiza modificaciones a la arquitectura de la figura 5.8 agregando la información mutua entre unos nuevos parámetros llamados código latente  $c$  y el generador, teniendo el primero como entrada adicional al generador aparte de  $z$ .

La información mutua se define como “la cantidad de información” aprendida del conocimiento de la variable aleatoria  $Y$  sobre otra variable aleatoria  $X$ , lo que se puede expresar como una diferencia entre entropías como muestra la Fórmula (6):

$$I(X; Y) = H(X) - H(Y|X) = H(Y) - H(Y|X) \quad (6)$$

Dónde  $H$  representa la entropía de la información. Con este nuevo elemento se propone un cambio en la función objetivo del juego como sigue:

$$\min_G \max_D V_I(D, G) = V(D, G) - \lambda I(c; G(z, c)) \quad (7)$$

La información mutua en este caso es difícil de maximizar ya que requiere la probabilidad a posteriori  $P(c|x)$  para calcular la información mutua. Por esto [8] define una cota inferior definiendo una distribución auxiliar  $Q(c|x)$  para aproximar  $P(c|x)$ . Luego se define  $L_1(G, Q)$ .

$$L_1(G, Q) = \mathbb{E}_{c \sim P(c), x \sim G(z, c)} [\log Q(c|x)] + H(c) \leq I(c; G(z, c)) \quad (8)$$

En términos esquemáticos, la Figura 5.10 presenta la arquitectura de una InfoGAN, mientras que la Fórmula (9) la función del juego.




Figura 5.10: Arquitectura de InfoGAN propuesta por [8].

$$\min_{G, Q} \max_D V_{InfoGAN}(D, G, Q) = V(D, G) - \lambda L_1(G, Q) \quad (9)$$

En la sección de metodología se ahonda más respecto de la formulación de la información mutua, ya que se usa para definir un parámetro (NMI) de evaluación de la calidad de un algoritmo de agrupamiento respecto a la clasificación real.

### 5.2.4. Redes Adversarias Generativas con Regularización de Modos (MRGAN).

[9] introduce MRGAN con la intención de reducir los efectos de la pérdida de modos, para esto se agrega una señal de entrenamiento supervisado al generador, agregando un Encoder (Regularizador de modos) a la entrada del generador, de forma que el costo de este sea penalizado en el entrenamiento al alejarse de los modos de datos que pretende generar.

La Figura 5.11 muestra el esquema de esta arquitectura. En la práctica el Encoder tiene la misma topología que el discriminador, salvo por la última capa correspondiente a la entrada del generador, que posee la dimensionalidad del ruido usado para generar los datos.




Figura 5.11: Arquitectura MRGAN propuesta por [9]

Las Fórmulas (10) y (11) muestran los cambios en la función objetivo del generador y la del Encoder respectivamente.

$$T_G = -\mathbb{E}_z[\log D(G(z))] + \mathbb{E}_{x \sim p_{data}}[\lambda_1 d(x, G \circ E(x)) + \lambda_2 D(G \circ E(x))] \quad (10)$$

$$T_E = \mathbb{E}_{x \sim p_{data}}[\lambda_1 d(x, G \circ E(x)) + \lambda_2 D(G \circ E(x))] \quad (11)$$

En este caso  $d()$  representa una medida de distancia, [9] usa la distancia de pixel-wise  $L^2$ , mientras que  $\lambda_1$  y  $\lambda_2$  son ponderadores de importancia para las componentes de la función de costos. La ventaja de esta arquitectura es que permite penalizar al generador cuando no se producen ciertos modos o se aleja de los datos discriminados, mejorando la estabilidad y el desempeño del generador, lo cual [9] demuestra empíricamente.

### 5.2.5. Redes Adversarias Generativas Wasserstein (Wasserstein GAN o WGAN).

[10] propone Wasserstein GAN como propuesta para mejorar la convergencia del modelo. Se basa en que el modelo original de GAN intenta maximizar la verosimilitud del discriminador. El autor demuestra que esto es equivalente a minimizar la divergencia KL. Además, expone diversas distancias como alternativa. En particular, la distancia de Earth-Move o Wasserstein-1 (Fórmula (12)). Mediante ejemplificaciones muestra algunas secuencias de probabilidad que son capaces de converger bajo la distancia de Wasserstein, mas no bajo otras distancias como la divergencia KL. Por lo cual, propone remplazar el entrenamiento del discriminador por la distancia de Wasserstein-1. Lamentablemente, esta resulta muy difícil de computar, aunque es posible resolver el problema dual gracias a la dualidad de Kantorovich-Rubinstein (Fórmula (13)), dónde el supremo es tomado de las funciones 1-Lipschitz (condición para poder aplicar la dualidad). En la práctica esto aún es intratable, pero puede ser aproximado por la Fórmula (14), dónde  $\{f_w\}_{w \in W}$  es una familia parametrizada de funciones de todas las K-Lipshitz para algún  $K$ .

- Distancia de earth-Move o Wasserstein 1

$$W(P_{data}, P_g) = \inf_{\gamma \in \Pi(P_{data}, P_g)} \mathbb{E}_{(x,y) \sim \gamma} [\|x - y\|] \quad (12)$$

- Dualidad Kantorovich-Rubinstein

$$W(P_{data}, P_g) = \sup_{\|f\|_L \leq 1} \mathbb{E}_{x \sim P_{data}}[f(x)] - \mathbb{E}_{x \sim P_g}[f(x)] \quad (13)$$

- Aproximación a la dualidad para su resolución práctica

$$W(P_{data}, P_g) \max_{w \in W} \mathbb{E}_{x \sim P_{data}} [f_w(x)] - \mathbb{E}_{x \sim P_g} [f_w(x)] \quad (14)$$

Este cambio implica un cambio en el algoritmo de entrenamiento de la GAN así como un cambio en la noción probabilística del discriminador. Se pasa de asignar una probabilidad a usar un indicador o *critic* como menciona [10], asignando valores positivos a datos falsos y negativos a los reales, quedando un esquema como el de la Figura 5.12. Clip es una condición de limitación en la salida que permite aplicar la dualidad de Kantorovich-Rubinstein para el entrenamiento de la red.




Figura 5.12: Arquitectura Wasserstein GAN propuesta por [10]

### 5.3. Algoritmos de agrupamiento o clustering.

En esta sección se presentan los algoritmos de agrupamiento o clustering seleccionados para para el procedimiento, se han seleccionado en base a al desempeño que tiene respecto al números de grupos a conseguir (pocos grupos según se ha mostrado en la sección de diagnóstico de fallas y estado de un rodamiento). Se explica brevemente el funcionamiento de cada uno a fin de tener la comprensión mínima necesaria para las siguientes secciones del trabajo.

Las explicaciones dadas se basan en la documentación de [11] y tienen como objetivo presentar las bases definitorias de los algoritmos a usar.

#### 5.3.1. Algoritmo K-means.

Este algoritmo divide un set de  $n$  puntos en  $k$  grupos de igual varianza, para esto minimiza la distancia de cada punto respecto a un punto característico llamado centroide, como muestra la Función Objetivo (15)

$$\sum_{i=0}^k \min_{\mu_j \in C} (\|x_j - \mu_i\|^2) \quad (15)$$

Dónde  $x_j$  son los puntos agrupar,  $\mu_j$  es la media de los puntos en el clúster (centroide) y  $C$  el conjunto de los centroides correspondientes a cada clúster.

Para lograr el agrupamiento, este algoritmo pide a priori el número de clústeres a usar. Luego, selecciona aleatoriamente los centroides iniciales, separa los puntos dejando en un mismo clúster aquellos que se encuentran más cercanos a un centroide y luego calcula el nuevo centroide de todos los puntos agrupados en ese clúster. El algoritmo se detiene cuando los grupos no varían o varían muy poco. Este algoritmo siempre converge, pero lo hace en un mínimo local.



### 5.3.2. Algoritmo Spectral Clustering.

Este algoritmo aplica K-means a una proyección (valores propios) del laplaciano normalizado (matriz laplaciana normalizada). Es decir, asume los puntos como un grafo, del cual obtiene la matriz laplaciana normalizada, de esta obtiene los valores propios y a esos aplica el algoritmo de K-means.

La matriz laplaciana normalizada es una representación matricial de un grafo (otra forma es la matriz de adyacencia donde los nodos conectados se marcan con un 1 y los que no con un cero) definida como  $\mathcal{L} := (\hat{\ell}_{i,j})_{n \times n}$  donde:

$$\ell_{i,j} := \begin{cases} 1 & \text{si } i = j \neq 0 \\ -\frac{1}{\sqrt{k_i k_j}} & \text{si } i \neq j \text{ y } n_i \text{ es adyacente a } n_j \\ 0 & \text{otro caso} \end{cases} \quad (16)$$

En la Fórmula (16)  $n_i$  representa al nodo  $i$  y  $k_i$  al costo de arcos asociados al nodo  $n_i$ .

## 6. Metodología.

La metodología propuesta consiste en alimentar con datos de vibración en rodamientos una secuencia de GAN; seguida por un algoritmo de clustering en las diversas capas de salida posibles (según el modelo GAN) con el objetivo de obtener grupos donde predomine un tipo de falla en particular (para el caso de identificación de fallas), o bien representen un estado de deterioro de un rodamiento en operación (caso FEMTO-ST). Como extensión para cada caso se debiese poder diseñar modelos de pronóstico en base a el modelo físico en el caso de identificación de falla o basados en datos para ensayos de degradación.

El esquema de la estructura propuesta se presenta en la figura 6.1.

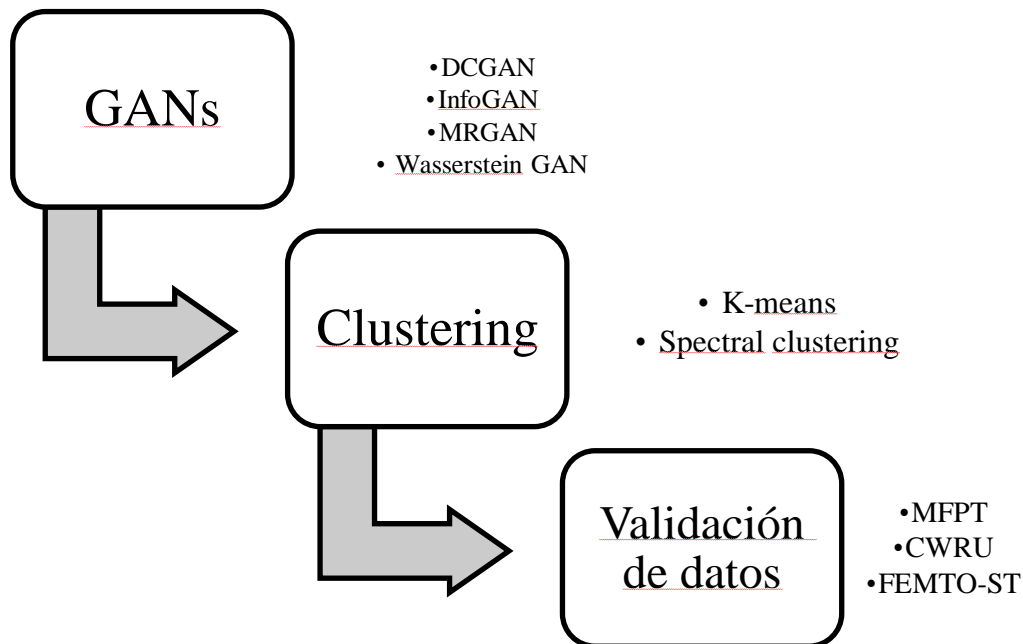


Figura 6.1: Estructura del procedimiento de identificación propuesto.

### 6.1. Procedimiento propuesto.

El procedimiento tiene por objetivo el identificar tipos de falla o estados de daños en rodamientos. Para esto, es requerida una secuencia de actividades a fin de completar el procedimiento. Lo cual se detalla a continuación explicándose posteriormente algunas características:

1. Procesamiento de datos, por ejemplo\*:
  - a. Análisis de Fourier por intervalos (SFFT o espectrograma).
  - b. Transformada de Wavelet (WT o escalograma).
  - c. SFFT a la envolvente de las señales de vibración.
  - d. WT a la envolvente de las señales de vibración.
  - e. Kurtograma rápido (para identificación de estados).

2. Separación de datos de entrenamiento (80% de las muestras) y datos de validación (20% de las muestras) (excepto FEMTO-ST, ya que los datos han sido divididos por ensayos de entrenamiento y validación).
3. Entrenamiento de Red Adversaria Generativa (GAN).
4. Entrenamiento de clustering con datos de entrenamiento usando alguna salida de la GAN del paso anterior.
5. Clasificación de datos de validación pasando por la GAN y luego agrupados por el algoritmo de clustering entrenado.
6. Evaluación de clasificación realizada:
  - a. Adjusted Rand Index (ARI).
  - b. Información Mutua Normalizada (NMI).
  - c. Pureza de los clústeres.
  - d. Matriz de contingencia.
  - e. Clúster respecto al tiempo de operación (sólo para identificación de estados).

\*Respecto a cada paso cabe destacar que sólo se ahondará en los datos que arrojen mejores resultados. Por ejemplo, el paso 1 sólo se hace revisión de SFFT o WL para la envolvente de las señales, según el caso con mayor éxito para señales puras y siempre cuando este se justifique considerando que se requiere de un procesamiento adicional.

A continuación, se presentan los set de datos utilizados, sus características y clasificaciones disponibles. Luego, se presentan las diversas técnicas de procesamiento de señales usadas en esta investigación y finalmente las secciones de las GANs propuestas a partir de donde se aplica el algoritmo de clustering.

## **6.2.Sets de datos utilizados.**

Las bases de datos utilizados usados son las siguientes:

- Society of Machinery Failure Prevention Technology (MFPT) Bearing Data.
- Case Western Reserve University (CWRU) Bearing Data.
- IEEE PHM 2012 Data Challenge, desarrollado por la Franche-Comté Electronics Mechanics Thermal Science and Optics Sciences and Technologies (FEMTO-ST).

### **6.2.1. MFPT.**

Base de datos que presenta datos de vibraciones desarrollada por la Society of Machinery Failure Prevention Technology [12]. Se compone de datos de vibraciones mecánicas en rodamientos bajo tres condiciones (generadas artificialmente): caso base, falla en pista exterior y falla en pista interior. En el caso de señales con fallas también se ejercen variaciones en la carga existente en el rodamiento. Las condiciones de las muestras son las siguientes:

- 3 muestras de condiciones base:
  - 270 lb de carga
  - Velocidad de giro de 25 Hz
  - Frecuencia de muestreo de 95 656 sps (muestras por segundo)
  - Duración de 6 segundos
- 3 muestras de falla en pista exterior:
  - 270 lb de carga
  - Velocidad de giro de 25 Hz
  - Frecuencia de muestreo de 95 656 sps
  - Duración de 6 segundos
- 7 muestras de falla en pista exterior:
  - Cargas de 25, 50, 100, 150, 200, 250 y 300 lbs
  - Velocidad de giro de 25 Hz
  - Frecuencia de muestreo de 48 828 sps
  - Duración de 3 segundos
- 7 muestras de falla en pista interior:
  - Cargas de 0, 50, 100, 150, 200, 250 y 300 lbs
  - Velocidad de giro de 25 Hz
  - Frecuencia de muestreo de 48 828 sps
  - Duración de 3 segundos

Datos del rodamiento:

- Diámetro de elementos rodantes  $d = 0,235$
- Diámetro medio  $D = 1.245$
- Número de elementos rodantes  $n = 8$
- Angulo de contacto  $\phi = 0^\circ$

Para esta base en particular se han calculado las frecuencias de resonancia de cada elemento (Tabla 6.1). También, se ha hecho el análisis de envolvente a fin de verificar el cumplimiento de las señales de vibración con la fallas como se muestra en la Figura 6.2.

Tabla 6.1: Frecuencias de resonancia calculadas, rodamiento datos MFPT.

<i>Elemento</i>	<i>Frecuencia de resonancia</i>
<i>Pista exterior</i>	$BPFO = 81,1245 [Hz]$
<i>Pista interior</i>	$BPFI = 118,8755 [Hz]$
<i>Frecuencia fundamental del tren (velocidad de la jaula)</i>	$FTF = 10,1406 [Hz]$
<i>Elemento rodante</i>	$BDF(RSF) = 127,7279 [Hz]$

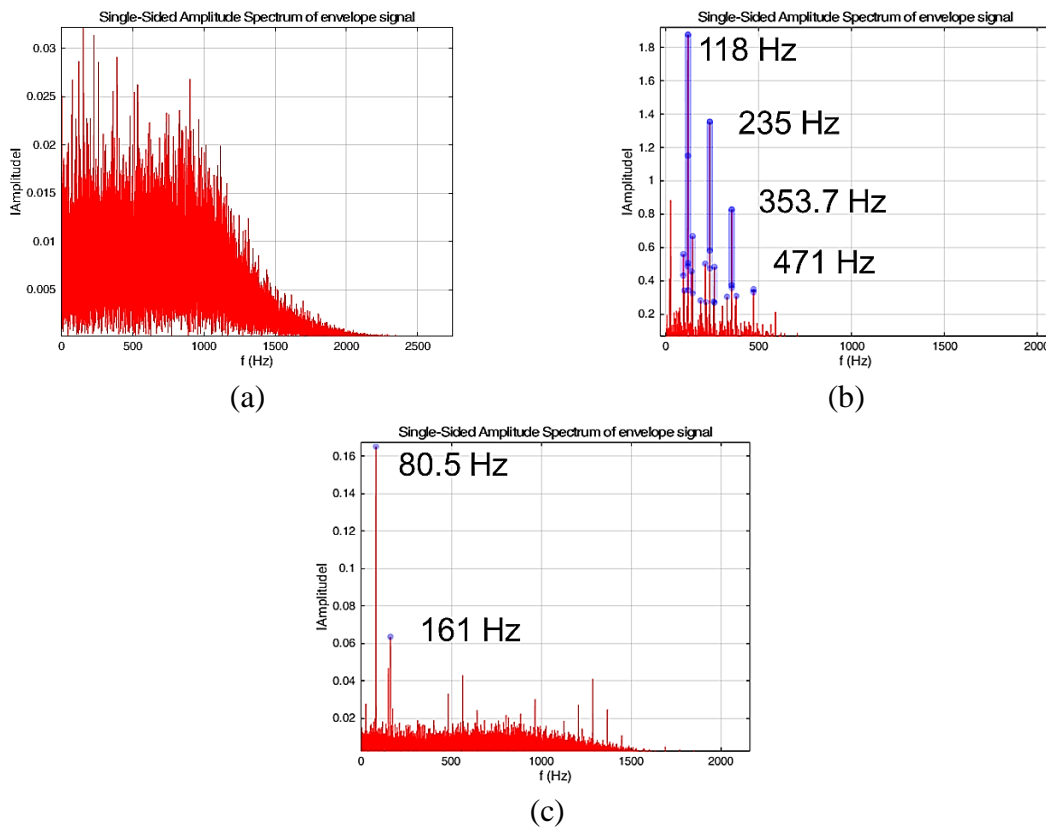


Figura 6.2: Espectros para las tres condiciones presentadas por la base MFPT, (a) condiciones base, (b) falla en pista interior y (c) falla en pista exterior, nótese la cercanía en las frecuencias calculadas en la tabla 6.1 con los picos obtenidos en el espectro.

### 6.2.2. CWRU.

Colección de muestras que presenta señales de vibraciones para diversas condiciones y tipos de falla (generados artificialmente por electro-descarga). Considera dos rodamientos (marcas, diámetros y posición en el montaje diferentes), cuatro velocidades de giro y cuatro cargas. Además, el montaje de pruebas dispone de dos posiciones para realizar las pruebas en los rodamientos. En este documento se presentan los antecedentes fundamentales de esta base, pudiéndose hallar más detalles en su página web. La siguiente figura muestra el detalle del montaje.




Figura 6.3: Montaje de generación para el set de datos CWRU (Adaptado de [13])

Para nuestros ensayos se pretende identificar las fallas del rodamiento en la posición Drive End y con una frecuencia de muestreo de 12 000 sps.

- Frecuencia de muestreo: 12 000 sps
- Tipos de falla: Condiciones base, falla en pista interior, falla en pista exterior y falla en elementos rodantes (bolas).
- Cargas del motor: 0, 1, 2 y 3 HP
- Velocidades del motor: 1 797 RPM, 1 772 RPM, 1 750 RPM y 1 730 RPM
- Diámetros de la falla: 0,007’’; 0,014’’; 0,021’’ y 0,028’’
- Las fallas de pista exterior se ubican en tres posiciones respecto a la zona de carga (6, 3 y 12 en punto respecto al reloj).

Las Tabla 6.2 presentan las frecuencias de resonancia naturales para el rodamiento en estudio de esta base.

Tabla 6.2: Frecuencias de resonancia calculadas, rodamiento Drive End (DE) datos CWRU (obtenido de [13]).

<i>Elemento</i>	<i>Frecuencia de resonancia</i>
<i>Pista exterior</i>	$BPFO = 3,5848 \times Hz$
<i>Pista interior</i>	$BPFI = 5,4152 \times Hz$
<i>Frecuencia fundamental del tren (velocidad de la jaula)</i>	$FTF = 0,39828 \times Hz$
<i>Elemento rodante</i>	$BDF(RSF) = 4,7135 \times Hz$

Donde  $Hz$  es la velocidad de giro del rodamiento en [Hz].

### 6.2.3. FEMTO-ST.

Este set de datos fue presentado para el desafío de la PHM Society del año 2012 [14]. Consiste en pruebas de degradación acelerada para rodamientos (hasta la falla). Está dividida en tres grupos (entrenamiento, validación incompleta y validación completa (disponible después de los resultados del concurso)). Los datos disponibles corresponden a señales de vibración en dos ejes (x e y) y señales de temperatura. En nuestro caso sólo se considera la señal de vibración más importante (x) junto a los datos de entrenamiento y validación completa. Más antecedentes pueden ser encontrados en su página web.

La figura 6.4 presenta el montaje del experimento.




Figura 6.4: Montaje para la prueba de rodamientos del set de datos FEMTO-ST (tomador de [15])

Las características de las muestras son las siguientes:

- Frecuencia de muestreo: 25,6 [kHz]
- Duración de cada muestra: 1/10 [s], tomadas cada 10 [s]
- Ejemplos por muestra: 2 560 ejemplos
- Condiciones de operación:
  - Condición de operación 1: Velocidad de giro de 1 800 [RPM] y carga de 4 000 [N]
  - Condición de operación 2: Velocidad de giro de 1 650 [RPM] y carga de 4 200 [N]
  - Condición de operación 3: Velocidad de giro de 1 500 [RPM] y carga de 5 000 [N]

### **6.3. Procesamiento de datos a usar para el entrenamiento.**

Por lo general el uso de GANs ha sido estudiado para la generación y procesos de imágenes, por lo cual en este trabajo se usan imágenes como datos de entrada para el modelo generativo.

Para presentar los datos al procedimiento se usan dos representaciones de análisis en tiempo-frecuencia, correspondientes al análisis de Fourier por intervalos (SFFT o espectrograma) y las transformadas de Wavelet (WL o escalograma). Además, por la diferencia que presenta el set de datos FEMTO-SC respecto a los otros dos también se considera el kurtograma rápido como entrada de alimentación de datos.

#### **6.3.1. Análisis de datos.**

Una de las dificultades para el análisis de datos por medio de GANs para las bases MFPT y CWR es el largo de las muestras (entre 3 y 6 segundos). Los métodos basados en aprendizaje profundo exigen un alto volumen de datos para su entrenamiento, por lo cual cada una de estas señales se divide en secciones y a partir de estas se obtienen las imágenes para entrenar el modelo. Esto presenta algunos deterioros en el análisis, como es el caso la transformada de Fourier donde la resolución de frecuencias depende directamente del largo de las muestras; luego, una muestra más corta tiene menos resolución en frecuencia, lo que distorsiona los síntomas de las fallas. La segmentación ha consistido en tomar muestras de 2,5 revoluciones del eje, aceptando un traslape de un 50%, es decir para una muestra de 5 revoluciones se pueden extraer 3 imágenes completar por método (de 0 a 2,5 revoluciones de 1,25 a 3,75 revoluciones y de 2,5 a 5 revoluciones.). En el caso del set FEMTO-SC las muestras ya están separadas por lo cual no es necesario este proceso. Ejemplos de muestras obtenidas se presentan en la sección de resultados.

#### **6.3.2. Análisis de Fourier por intervalos (SFFT)**

El análisis de Fourier por intervalos consiste en dividir la señal en segmentos, permitiendo traslape entre estos y luego calcular la transformada de Fourier para cada intervalo. Estos resultados se grafican en tres dimensiones (tiempo, frecuencia, amplitud) [3], teniéndose una imagen como forma de representación. Lo descrito anteriormente es mostrado por la siguiente fórmula:

$$S(f; \tau) = \int_{-\infty}^{\infty} x(t)w(t - \tau) e^{-j2\pi ft} dt \quad (17)$$



Donde  $x(t)$  es la señal a transformar,  $w(t)$  es una ventana que se desliza a través de la señal. Usualmente se grafica  $|S(f; \tau)|^2$  en el diagrama de tiempo-frecuencia conocido como espectrograma. Una importante desventaja de este análisis es la pérdida de resolución entre las frecuencias al computarse discretamente la transformada de Fourier para un largo de muestras menor al total, mientras que como ventaja permite detectar ciertas frecuencias estacionarias en la señal a través del tiempo.

### 6.3.3. Transformada de Wavelet.

Existe otra manera de descomponer una señal por frecuencias como el caso de la transformada de Wavelet. Este método convoluciona la señal con una serie de filtros (wavelets) pudiendo separar las componentes de frecuencia en el tiempo. La fórmula de la transformada de wavelet es la siguiente [3]:

$$W(\sigma; \mu) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left( \frac{t - \mu}{\sigma} \right) dt \quad (18)$$

Donde  $\psi(t)$  es la wavelet madre, trasladada por  $\mu$  y dilatada por  $\sigma$ , este último término es un factor de escala y representa la frecuencia logarítmica. Esta transformada posee una mejor ubicación temporal para las altas frecuencias y ha sido usada anteriormente para detectar fallas locales en rodamientos. También, existen distintos tipos de wavelets; en este caso se han usado wavelets tipo bump con parámetros  $\mu$  y  $\sigma$  descritos por la fórmula siguiente (en el dominio de Laplace).

$$\hat{\psi}(s\omega) = e^{\left(1 - \frac{1}{1 - \frac{(s\omega - \mu)^2}{\sigma^2}}\right)} 1_{[(\mu - \sigma)/s, (\mu + \sigma)/s]} \quad (19)$$

Donde  $1_{[(\mu - \sigma)/s, (\mu + \sigma)/s]}$  es el indicador de la función para el intervalo  $[\frac{\mu - \sigma}{s} \leq \omega \leq \frac{\mu + \sigma}{s}]$ .

### 6.3.4. Kurtograma Rápido.

El kurtograma es un gráfico tridimensional que se calcula a partir de la kurtosis para cada frecuencia obtenida de la SFFT (kurtosis espectral) variando el tamaño del intervalo. Los ejes son (frecuencia, kurtosis espectral, largo del intervalo de la SFFT) y ha sido usado para obtener las frecuencias optimas de filtrado para detectar severidad [16]. El cálculo de la kurtosis espectral para una señal gaussiana se calcula según la Fórmula (20) [3]:

$$K(f) = \frac{\langle H^4(t, f) \rangle}{\langle H^2(t, f) \rangle^2} - 2 \quad (20)$$

Donde  $H(t, f)$  es la amplitud de SFFT obtenido para una ventana en particular y su cuadrado representa la potencia del espectro para cada posición.

Además [17] propone un método para tener una computación más rápida del kurtograma, basándose en una serie de filtros digitales en vez que la SFFT. Esta consiste en ir dividiendo las bandas de frecuencia (recomendablemente dividiendo cada banda de frecuencia en tres para la siguiente etapa) y tomando la kurtosis de la banda, el resultado de esto es el kurtograma rápido.

## 6.4.Extracción de características.

Para extraer las características de las imágenes procesadas de señales de vibración en rodamientos, se procede a aplicar los algoritmos de clustering presentados en este trabajo a las salidas de algunas capas de proceso de las redes discriminadoras o generadoras (esto último sólo en el caso de la MRGAN). Usualmente se usaran los valores de salida de la penúltima capa del discriminador, esto es, la capa de proceso anterior a la salida de probabilidad de si la imagen ingresada es real o generada por el generador.

La principal justificación para elegir las arquitecturas aquí estudiadas es en primera instancia el potencial que posee este tipo de modelo para la extracción de características (DCGAN). Por otro lado, tanto InfoGAN como MRGA son mejoras que busca un mejor desempeño del modelo, ya sea en las imágenes generadas como en prevenir otras desventajas de DCGAN. Por ultimo Wasserstein GAN presenta un atractivo desde el punto de vista de la estabilidad del modelo en su entrenamiento.

En lo que sigue se detallan las arquitecturas implementadas en este trabajo así como las salidas a utilizar para realizar la extracción de características mediante los algoritmos de agrupamiento. Se ha procurado mantener los parámetros de estas idénticas a las de sus referencias, salvo por la dimensión de los filtros utilizados.

### 6.4.1. DCGAN.

En esta configuración se extraen las características de la penúltima capa del discriminador, el detalle de la arquitectura se presenta en la Figura 6.5.

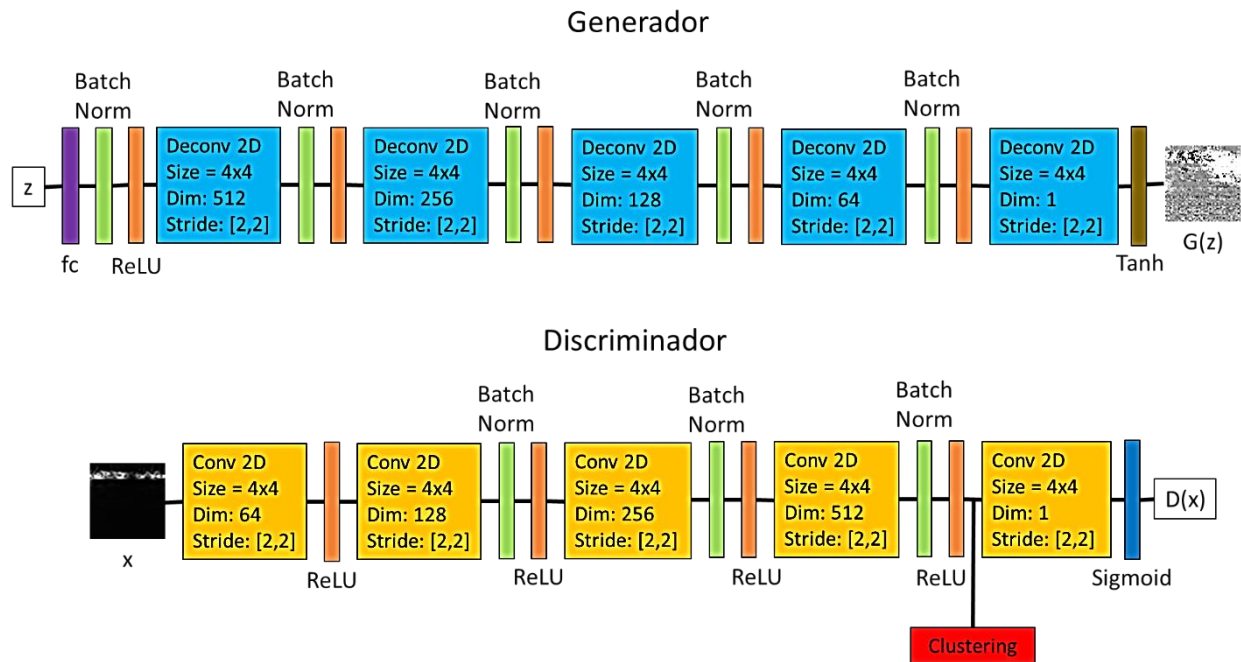


Figura 6.5: Arquitectura DCGAN usada, se resalta en rojo la capa de donde se extraerán los puntos para aplicar los algoritmos de clustering.

### 6.4.2. InfoGAN.

Para este modelo es posible usar la misma parte del modelo que el caso de la DCGAN; pero se incorpora como alternativa la red formada por la parte compartida del discriminador y la salida  $Q(c|x)$ . La Figura 6.6, resume la arquitectura y las zonas dónde es posible aplicar los algoritmos de agrupamiento.

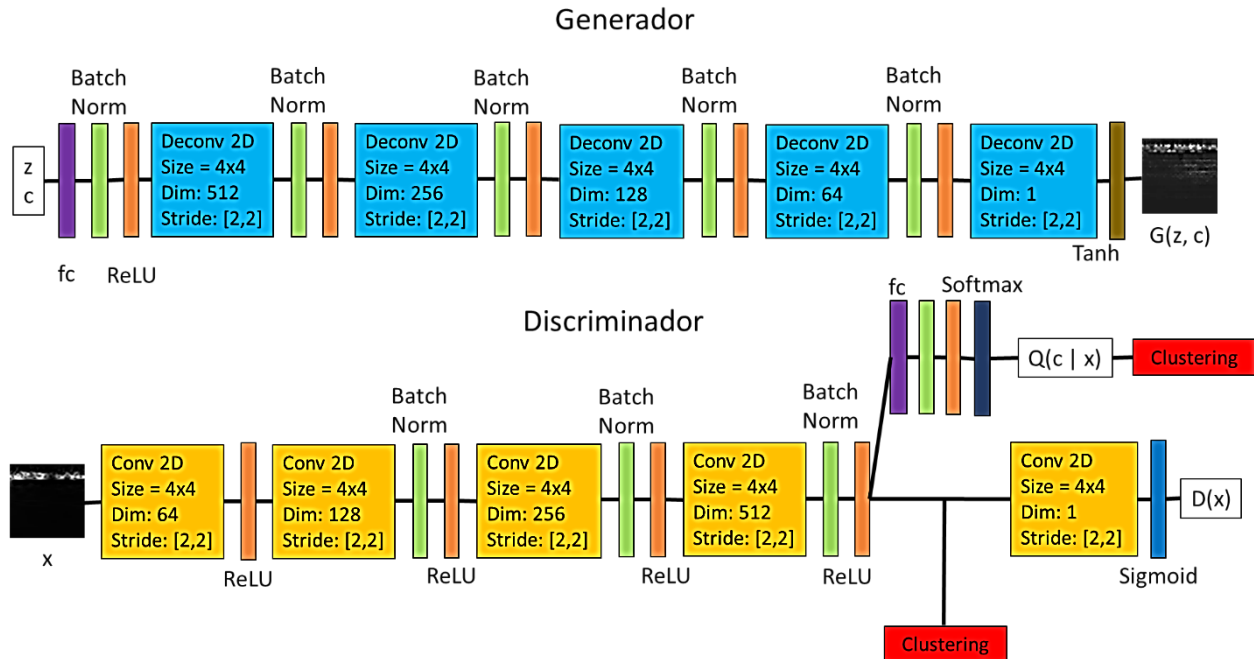


Figura 6.6: Arquitectura InfoGAN usada, se resalta en rojo la capa de donde se extraerán los puntos para aplicar los algoritmos de clustering.

### 6.4.3. MRGAN.

Al igual que los casos anteriores una primera arquitectura a usar es la salida de la penúltima capa del discriminador al igual el modelo DCGAN. También, es posible usar la salida del encoder para estos fines y realizar el clustering en el espacio de  $z$  según se presenta en la Figura 6.7.

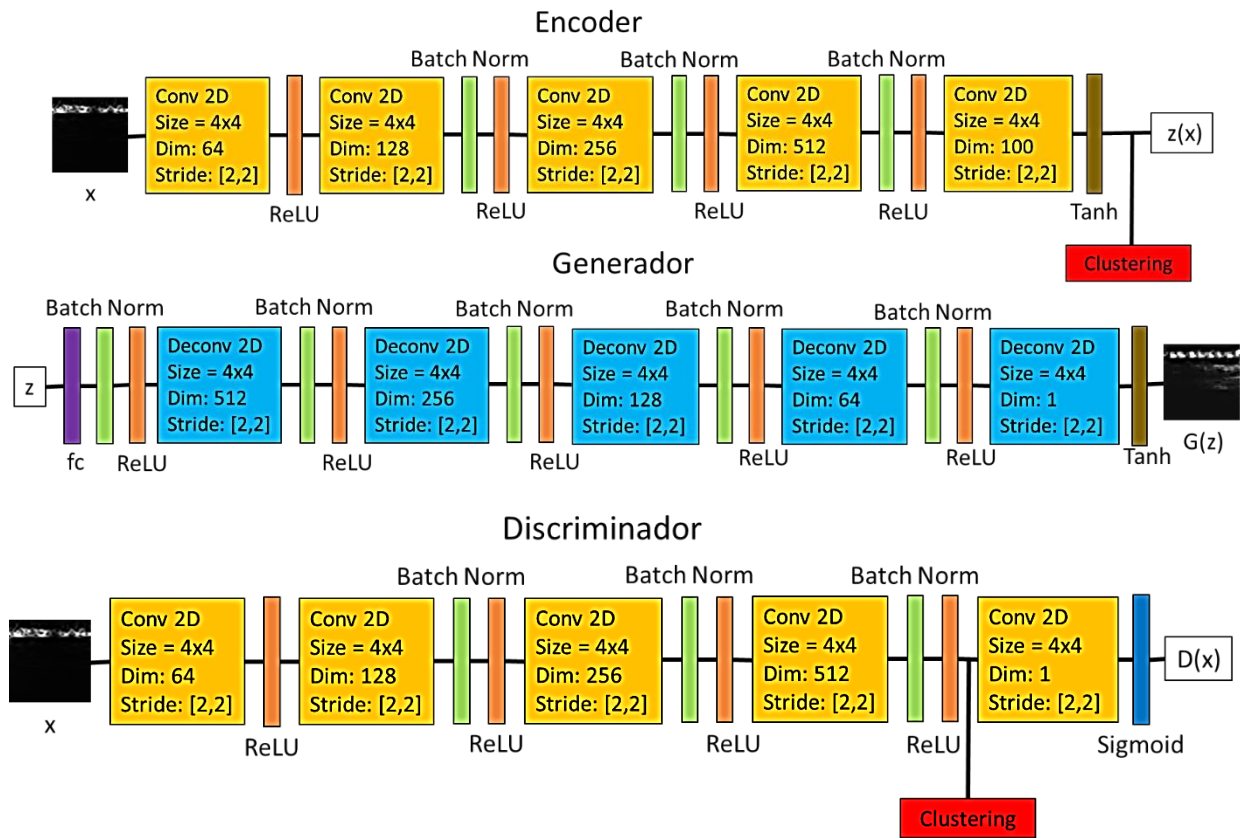


Figura 6.7: Arquitectura MRGAN usada, se resalta en rojo la capa de donde se extraerán los puntos para aplicar los algoritmos de clustering.

#### 6.4.4. Wasserstein GAN.

Al ser un modelo que sólo varía las condiciones de entrenamiento, se usa la Critic tomado como entrada las imágenes y salida la penúltima capa de esta red similarmente al caso de la DCGAN, como se presenta en la Figura 6.8.

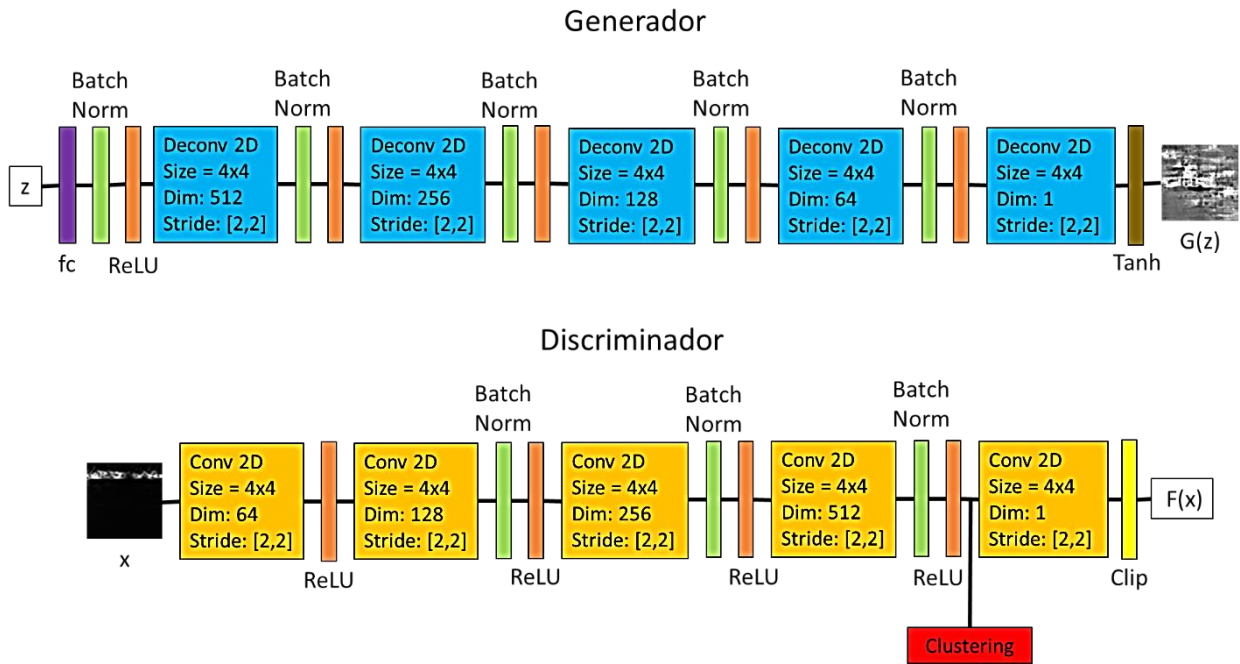


Figura 6.8: Arquitectura WGAN usada, se resalta en rojo la capa de donde se extraerán los puntos para aplicar los algoritmos de clustering.

### 6.5. Criterios de Evaluación.

El objetivo de este trabajo es identificar las fallas para las bases MFPT y CWR; mientras que el caso de la base FEMTO-SC la intención es poder identificar el estado del rodamiento a lo largo de su operación.

Para evaluar el primer caso se usan algunos indicadores como el Adjusted Rand Index (ARI), la Información Mutua Normalizada (NMI) y la pureza de los clústeres. Además, se requiere una tabla de contingencia para comparar tanto cualitativamente como cuantitativamente el resultado del proceso de identificación. En el segundo caso, la evaluación resulta más compleja ya que no se disponen de datos o antecedentes para comparar los resultados; por lo cual se limita a realizar un análisis cualitativo, donde se revisa simplemente la presencia de fallas en las señales y una relación entre los clústeres relacionada en el tiempo (transición de clústeres a medida que el rodamiento se va degradando). La información detallada de los dos primeros indicadores se encuentra en la documentación de la librería que posee los algoritmos de clustering [11].

Desde el punto de vista de la metodología, los indicadores permiten identificar rápidamente los buenos resultados de los malos, pudiéndose centrar un análisis más acabado en los primeros y descartar del trabajo rápidamente los últimos.

#### 6.5.1. Adjusted Rand Index (ARI)

Este índice mide la similaridad entre dos asignaciones (clasificaciones reales y estimadas por el algoritmo de clustering), ignorando las permutaciones y con posibilidad de normalización. Sus rangos van desde -1 a 1 (clasificación perfecta). Como ventajas a destacar para una diferencia aleatoria entre dos particiones (agrupamientos) tiene un ARI cercano a cero y el hecho de que no se hacen suposiciones respecto a la estructura de cada clúster o partición.

Para su cálculo se considera un conjunto de datos  $S = \{\sigma_1, \sigma_2, \dots, \sigma_N\}$  y dos particiones  $C = \{C_1, C_2, \dots, C_m\}$  el agrupamiento real y  $K = \{K_1, K_2, \dots, K_n\}$  el agrupamiento considerado por el algoritmo de clustering. Se considera la siguiente tabla de contingencia (no confundir con una matriz de confusión):

$K/C$	$K_1$	$K_2$	...	$K_n$	Sumas
$C_1$	$n_{11}$	$n_{12}$	...	$n_{1n}$	$a_1$
$C_2$	$n_{21}$	$n_{22}$	...	$n_{2n}$	$a_2$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$C_m$	$n_{m1}$	$n_{m2}$	...	$n_{mn}$	$a_m$
Sumas	$b_1$	$b_2$	...	$b_n$	$N$

Dónde  $n_{ij}$  es el número de elementos que pertenecen a  $C_i$  y  $K_j$ . Se define el ARI como presenta la siguiente fórmula:

$$ARI = \frac{\sum_{ij} \binom{n_{ij}}{2} - \frac{[\sum_i \binom{a_i}{2} \sum_j \binom{b_j}{2}]}{\binom{N}{2}}}{\frac{1}{2} [\sum_i \binom{a_i}{2} + \sum_j \binom{b_j}{2}] - \frac{[\sum_i \binom{a_i}{2} \sum_j \binom{b_j}{2}]}{\binom{N}{2}}} \quad (21)$$

### 6.5.2. Información Mutua Normalizada (NMI).

La información mutua es una función que mide la concordancia entre dos asignaciones. Este indicador ignora las permutaciones. Para una clasificación perfecta, su valor es 1, mientras que una mala asignación tendrá valores cercanos a 0. Se basa en la información mutua, explicada conceptualmente en la sección de antecedentes y que a continuación se presenta en su formulación matemática.

Consideramos nuevamente las particiones  $C$  y  $K$  del conjunto  $S$  compuestos de igual manera que en la sección anterior. Ahora bien, la entropía del conjunto de asignaciones  $C$  que viene dada por:

$$H(C) = - \sum_{i=1}^m P(i) \ln(P(i)) \quad (22)$$

Donde  $P(i) = |C_i|/N$  es la probabilidad de que un elemento seleccionado de  $C$  pertenezca a la partición  $C_i$ .

De igual forma para  $K$  se tiene:

$$H(K) = - \sum_{j=1}^n P'(j) \ln(P'(j)) \quad (22)$$

Donde  $P(j) = |K_j|/N$  es la probabilidad de que un elemento seleccionado de  $K$  pertenezca a la partición  $K_j$ .

Luego la información mutua entre  $C$  y  $K$  se formula según (23), donde  $P(i, j) = |C_i \cap K_j|/N$ .

$$I(C, K) = \sum_{i=1}^m \sum_{j=1}^m P(i, j) \ln \left( \frac{P(i, j)}{P(i)P'(j)} \right) = \sum_{i=1}^m \sum_{j=1}^m \frac{|C_i \cap K_j|}{N} \ln \left( \frac{N|C_i \cap K_j|}{|C_i||K_j|} \right) \quad (23)$$

Luego la información mutua normalizada se define como:

$$NMI = \frac{I(C, K)}{\sqrt{H(C)H(K)}} \quad (24)$$

Este indicador no se encuentra ajuntado, por lo cual tiende a incrementar cuando la cantidad de particiones (clústeres) aumenta, independiente de la cantidad de “información mutua” entre los dos conjuntos de partición.

### 6.5.3. Pureza de los clústeres.

La pureza de los clústeres es una medida simple de evaluación de la calidad de una partición. Se caracteriza por representar la cantidad más grande de elementos que pertenecen dos particiones (una en cada conjunto partición) por la cantidad de elementos totales del conjunto. Conservando la notación anterior se define como sigue [19]:

$$pureza(C, K) = \frac{1}{N} \sum_j \max_i |C_i \cap K_j| \quad (24)$$

Las ventajas de este indicador son su simpleza. Sin embargo, de tener la partición real diferencias muy grandes de tamaño entre cada partición podría elevarse la pureza sin la necesidad de tener una buena clasificación  $K$ , es decir, no es ajustado.



## 7. Resultados.

El trabajo desarrollado ha consistido en la elaboración de los códigos de identificación de fallas a partir de las arquitecturas de GANs y algoritmos de clustering presentadas anteriormente. Por otro lado, a partir del comportamiento observado se han estudiado algunas características de interés para mejorar el desempeño de las configuraciones de identificación autónoma o bien que merecen un estudio para verificar su comportamiento. A continuación, se presentan los principales resultados: En primera instancia, se muestran los resultados obtenidos a partir de la ejecución simple de la metodología (según la Figura 6.1) y algunas características obtenidas de esta. En la siguiente parte partir de los resultados obtenidos, se ejecutan algunas modificaciones para estudiar mejoras al procedimiento. En la última parte se detallan resultados para las envolventes de las señales. Finalmente se exponen los resultados para el set de datos FEMTO-ST.

Para todos los experimentos y modelos se ha usado un computador con una CPU Intel i7-4770K 16 Gb de memoria RAM y una GPU Nvidia GTX 1070. Los algoritmos han sido programados en Python usando las librerías tensorflow 1.2 y scikit learn v 0.19.1. Para el pre-procesamiento de datos se ha usado MATLAB 2017a.

### 7.1. Procedimiento completo: SFFT y WL, GAN y clustering para señales de vibración sin pre-procesamiento.

Como expone en el procedimiento propuesto (Figura 6.1), se procede a generar imágenes a partir de las señales de vibraciones mecánicas. También como se ha expuesto, para los sets de datos MFPT y CWRU se evalúan en primera instancia los casos de identificación usando espectrogramas (SFFT) y escalogramas (WL). La Figura 7.1 muestra algunas imágenes generadas para el entrenamiento de las GANs.




Figura 7.1: Ejemplos de imágenes obtenidas a partir de señales de vibraciones mecánicas, (a) WL MFPT, (b) SFFT MFPT (fallas de izquierda a derecha en ambos casos: línea base, pista interior, pista exterior y pista exterior), (c) WL CWRU y (d) SFFT CWRU (fallas de izquierda a derecha en ambos casos: línea base, pista interior, elemento rodante y pista exterior).

Para el caso MFPT se ha obtenido un set con 1 540 muestras (1 228 para entrenamiento y 312 para validación), mientras que en CWRU esta cantidad es de 18 592 (14 851 para entrenamiento y 3 746 para muestras)

Dada las grandes cantidades de información a presentar se procede a introducir una nomenclatura para entender la selección de resultados que se presenta a continuación:

- IMG: Imagen, se comparan los resultado con el caso dónde las imágenes no son procesadas por la arquitectura GAN.
- DIS: Salida del discriminador en alguna arquitectura GAN.
- Q: Salida  $Q(c|x)$  para la arquitectura InfoGAN.
- ENC: Salida del encoder en la arquitectura MRGAN.
- KM: Aplicación del algoritmo K-means.
- SC: Aplicación del algoritmo Spectral Clustering.
- KUR: Kurtograma rápido.

### 7.1.1. MFPT

Para el caso de MFPT se han ocupado 32 muestras por iteración y 50 000 iteraciones, esto es 1 303 épocas (un época ocurre cuando se han procesado todos los datos del set de entrenamiento). La Figura 7.2 muestra ejemplos de imágenes sintetizadas por el generador al final de este proceso para cada arquitectura estudiada.




Figura 7.2: Ejemplos de imágenes generadas para el caso MFPT considerando el entrenamiento con wavelets, (a) DCGAN, (b) InfoGAN, (c) MRGAN y (d) Wasserstein GAN.

De esta figura se aprecia que solo InfoGAN y MRGAN generan imágenes comparables con las de la Figura 7.1 (datos reales). Por otro lado, si bien en DCGAN se aprecian ciertas características de los datos usados en Wasserstein GAN no.

Los tiempos de entrenamiento aproximados por época (cuando se usan todos los datos de entrenamiento) son los siguientes:

- DCGAN: 2,75 segundos/ época
- InfoGAN: 3,59 segundos/ época
- MRGAN: 5,53 segundos/ épocas
- Wasserstein GAN: 8,73 segundos/ época

Como se ha mencionado, los indicadores permiten identificar con rapidez las arquitecturas con mayor éxito de las que no. Así es posible destacar dentro de las 96 configuraciones posibles; considerando imagen tiempo-frecuencia, arquitectura GAN, salida dónde aplicar el algoritmo de clustering. Las con mejor desempeño son expuestas en la Tabla 7.1, pudiéndose hallar el detalle de todas las configuraciones usadas y sus resultados se presentan en los anexos de este documento.


Tabla 7.1: Resumen de indicadores obtenidos por las arquitecturas usadas para el caso MFPT con transformada de wavelets y SFFT (los mejores indicadores se destacan en color oro, los segundos en plata y los terceros en bronce.).

<i>Indicador/ Arquitectura</i>	<i>DCGAN WL DIS/KM</i>	<i>MRGAN WL DIS/KM</i>	<i>MRGAN SFFT DIS/KM</i>
<i>ARI Entrenamiento</i>	0,683	0,683	0,5736
<i>ARI Validación</i>	0,682	0,682	0,5831
<i>NMI Entrenamiento</i>	0,6972	0,6972	0,6193
<i>NMI Validación</i>	0,6967	0,6967	0,6307
<i>Pureza Entrenamiento</i>	88,52%	88,52%	83,39%
<i>Pureza Validación</i>	88,46%	88,46%	83,97%

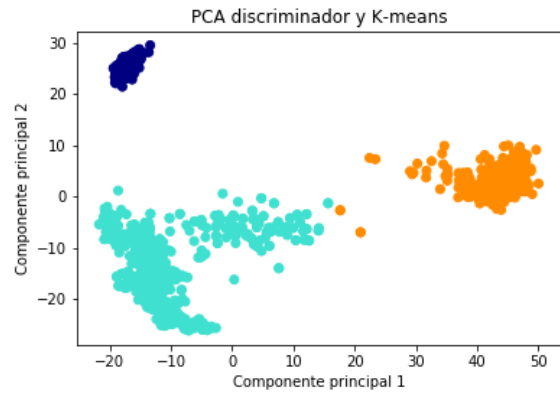
De la tabla anterior, los indicadores muestran que las mejores arquitecturas usadas para este caso, son DCGAN y MRGAN, en ambos casos siendo la salida de la penúltima capa del discriminador para usar el algoritmo de clustering, teniéndose mejores resultados con el algoritmo K-means y un mejor desempeño usando escalogramas en vez de espectrogramas.

A modo de comparación la configuración MRGAN WL DIS/SC tiene una pureza de 50% usando datos de validación contra 88,46% usando K-means, en el caso DCGAN la diferencia es de 73,08% contra 88,46%. También, la configuración MRGAN SFFT DIS/SC posee una pureza de 72,76% frente al 83,97%. A priori, la mejor configuración para este caso tanto por indicadores como por imágenes generadas es MRGAN WL DIS/KM.

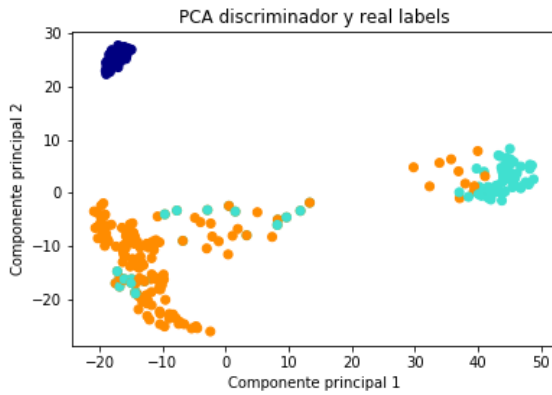
El Análisis de componentes principales (PCA por siglas en inglés) es una técnica para reducir la dimensionalidad de un set de datos, en este caso la salida del discriminador tiene 8 192 dimensiones, por lo cual su visualización es imposible. Por este motivo se ha usado el PCA para reducir la dimensionalidad de los sets de entrenamiento y validación y así observar cómo se han separado las muestras por características. Lo que se muestra en las Figuras 7.3 y 7.4.




(a)



(b)



(c)



(d)

Figura 7.3: PCA para los puntos a la salida del discriminador en DCGAN para el caso MFPT (wavelets). Los colores muestran los clústeres obtenidos sin relación entre sí. (a) Clasificación real (entrenamiento) (azul: línea base, turquesa: falla en pista interior, naranja: falla en pista exterior), (b) clasificación K-means (entrenamiento), (c) clasificación real (validación) (azul: línea base, turquesa: falla en pista interior, naranja: falla en pista exterior) y (d) clasificación K-means (validación).

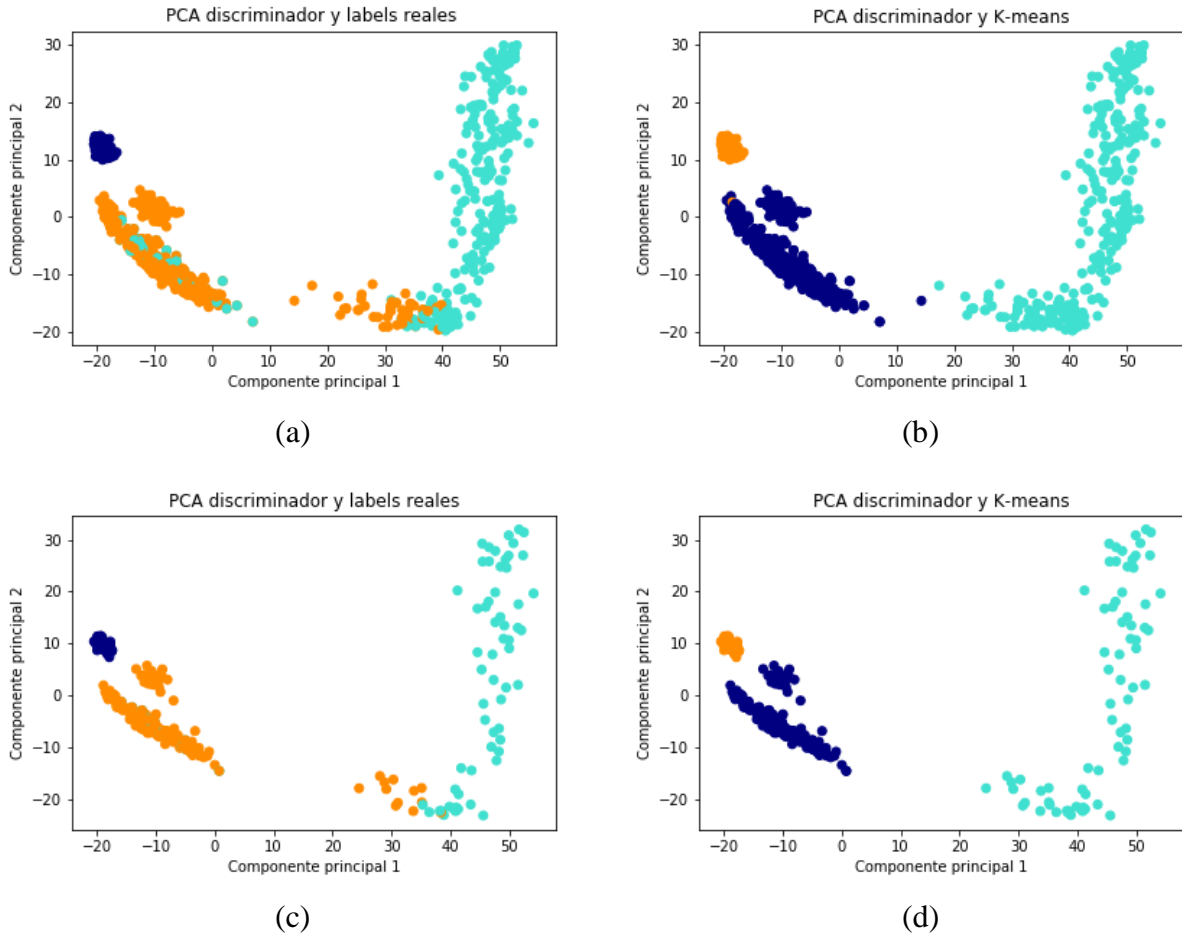


Figura 7.4: PCA para los puntos a la salida del discriminador en MRGAN para el caso MFPT (wavelets). Los colores muestran los clústeres obtenidos sin relación entre sí. (a) Clasificación real (entrenamiento) (azul: línea base, turquesa: falla en pista interior, naranja: falla en pista exterior), (b) clasificación K-means (entrenamiento), (c) clasificación real (validación) (azul: línea base, turquesa: falla en pista interior, naranja: falla en pista exterior) y (d) clasificación K-means (validación).

De las figuras anteriores se aprecia, al menos visualmente, como las arquitecturas con mejores indicadores logran identificar entre los distintos tipos de falla separándolas espacialmente.

### 7.1.2. CWRU

En este caso se han usado 64 muestras por iteración considerado al igual que el caso anterior 50 000 iteraciones, lo que se traduce en 232 épocas aproximadamente. La figura 7.5 presenta ejemplos de las imágenes generadas por cada arquitectura para el caso de entrenamiento usando la transformada de wavelets.




Figura 7.5: Ejemplos de imágenes generadas para el caso CWRU considerando el entrenamiento con wavelets, (a) DCGAN, (b) InfoGAN, (c) MRGAN y (d) Wasserstein GAN.

De la figura anterior, al igual que el caso MFPT se tiene que InfoGAN y MRGAN generan imágenes de mejor calidad en referencia a las de la figura 7.1. Mientras que para DCGAN y Wasserstein GAN, no logran apreciarse indicios ni semejanzas visibles con los datos de entrenamiento.

Los tiempos de entrenamiento aproximados por época (cuando se usan todos los datos de entrenamiento) son los siguientes:

- DCGAN: 27,63 segundos/ época
- InfoGAN: 35,94 segundos/ época
- MRGAN: 56,72 segundos/ épocas
- Wasserstein GAN: 88,1 segundos/ época

Nuevamente se han seleccionado las configuraciones que presentan los mejores indicadores (al igual que el caso anterior hay 96 configuraciones con 6 indicadores cada una), lo cual se expone en la tabla 7.2, pudiéndose hallar todas las configuraciones consideradas y sus respectivos indicadores en el anexo de este documento.

Tabla 7.2: Resumen de indicadores obtenidos por las arquitecturas usadas para el caso MFPT con transformada de wavelets y SFFT (los mejores indicadores se destacan en color oro, los segundos en plata y los terceros en bronce).

<i>Indicador/ Arquitectura</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MRGAN</i>	<i>DCGAN</i>	<i>MRGAN</i>
	<i>WL DIS/SC</i>	<i>WL DIS/SC</i>	<i>WL DIS/KM</i>	<i>SFFT DIS/SC</i>	<i>SFFT DIS/SC</i>
<i>ARI Entrenamiento</i>	0,5783	0,6365	0,6508	0,4105	0,459
<i>ARI Validación</i>	0,5851	0,4961	0,6466	0,4063	0,4221
<i>NMI Entrenamiento</i>	0,7977	0,8392	0,7395	0,748	0,6667
<i>NMI Validación</i>	0,8208	0,795	0,7359	0,6838	0,591
<i>Pureza Entrenamiento</i>	76,03%	81,15%	73,30%	67,68%	62,06%
<i>Pureza Validación</i>	79,57%	79,27%	73,18%	66,20%	58,80%

Los colores indican a diferencia de MFPT que los mejores indicadores se encuentran divididos entre tres configuraciones: DCGAN, InfoGAN y MRGAN; todas aplicando el algoritmo de clustering en la penúltima capa del discriminador. Aquí los indicadores NMI y pureza han sido mejores para configuraciones que usan el algoritmo de spectral clustering; aunque existen diferencias significativas entre los indicadores de entrenamiento y validación (ver configuraciones DCGAN WL DIS/SC e InfoGAN WL DIS/SC), mientras que las configuraciones con K-means son más estables (MRGAN WL DIS/KM). Por último, el único indicador ajustado ARI otorga el mejor desempeño a esta configuración.

Al igual que el caso MFPT las Figuras 7.6, 7.7 Y 7.8 exponen los PCAs de las configuraciones que han obtenido los mejores indicadores. Por comodidad primero se definen a continuación los colores usados en este documento para identificar las clasificaciones reales para todos los PCAs de CWRU.

- Azul marino: Línea base.
- Turquesa: Falla en pista interior de diámetro 0,007''
- Naranja: Falla en pista interior de diámetro 0,014''
- Orquídea: Falla en pista interior de diámetro 0,021''
- Verde: Falla en pista interior de diámetro 0,028''
- Oro: Falla en elemento rodante de diámetro 0,007''
- Damasco: Falla en elemento rodante de diámetro 0,014''
- Cardo: Falla en elemento rodante de diámetro 0,021''
- Verde azulado: Falla en elemento rodante de diámetro 0.028''
- Caqui: Falla en pista exterior de diámetro 0,007''
- Gris: Falla en pista exterior de diámetro 0,014''
- Azul piedra: Falla en pista exterior de diámetro 0,021''

Se recuerda que los clústeres obtenidos y por el procedimiento en estudio son asignados por el algoritmo y varían a lo largo del documento, debiéndose hacer una caracterización de los datos a posteriori para caracterizarlos.



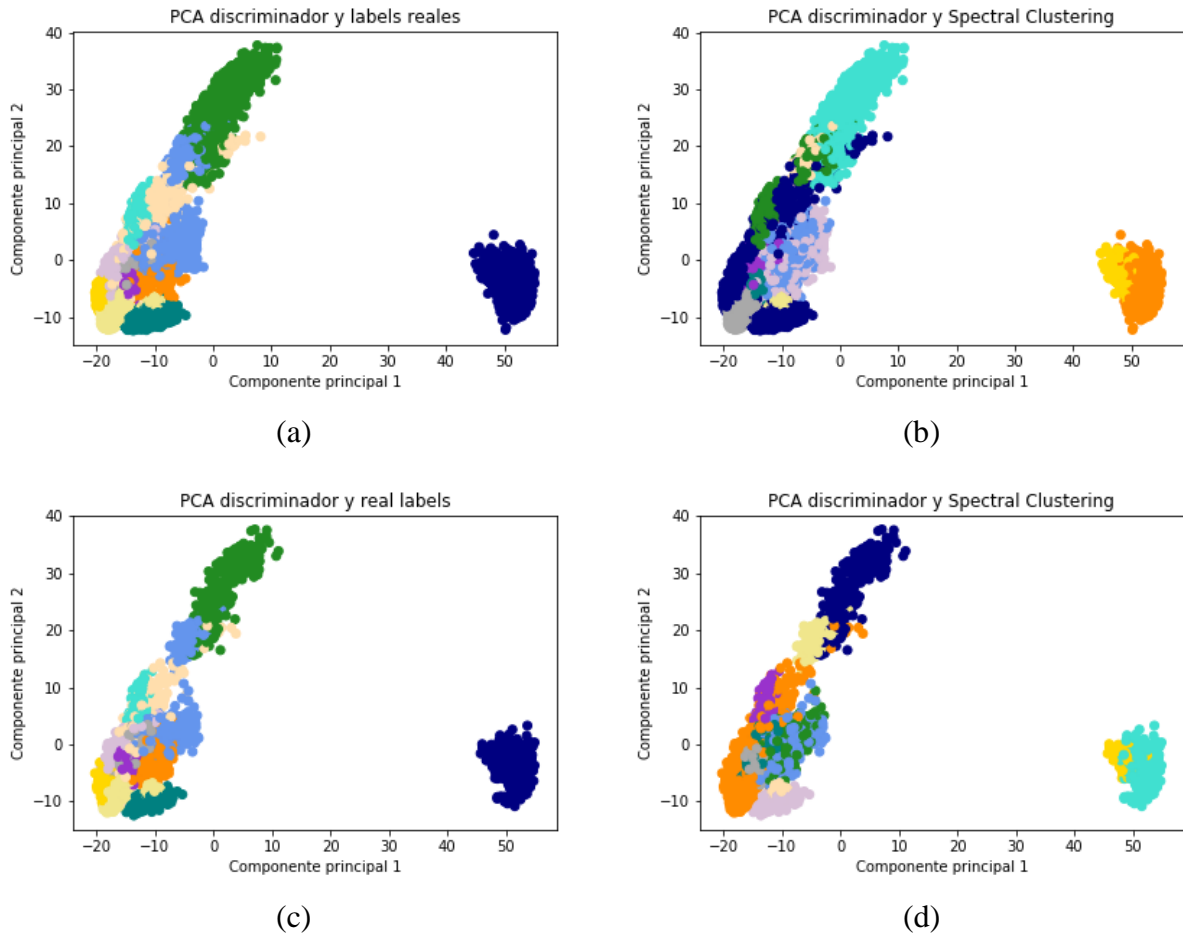

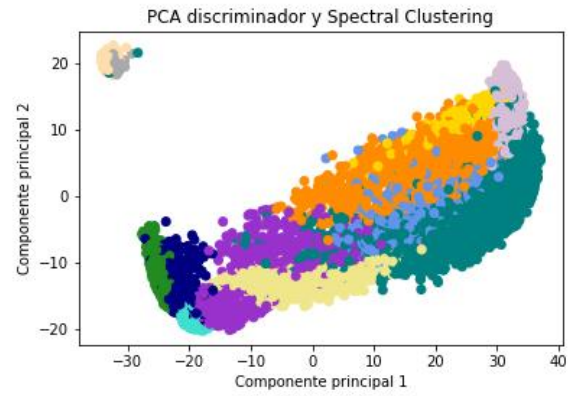


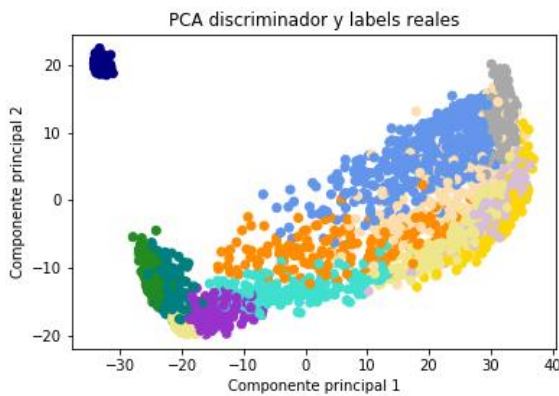
Figura 7.6: PCA para los puntos a la salida del discriminador en DCGAN para el caso CWRU (wavelets), los colores muestran los clústeres obtenidos (no hay relación entre ellos). (a) Clasificación real (entrenamiento), (b) clasificación spectral-clustering (entrenamiento), (c) clasificación real (validación) y (d) clasificación spectral-clustering (validación).




(a)



(b)



(c)



(d)

Figura 7.7: PCA para los puntos a la salida del discriminador en InfoGAN para el caso CWRU (wavelets), los colores muestran los clústeres obtenidos (no hay relación entre ellos). (a) Clasificación real (entrenamiento), (b) clasificación spectral-clustering (entrenamiento), (c) clasificación real (validación) y (d) clasificación spectral-clustering (validación).

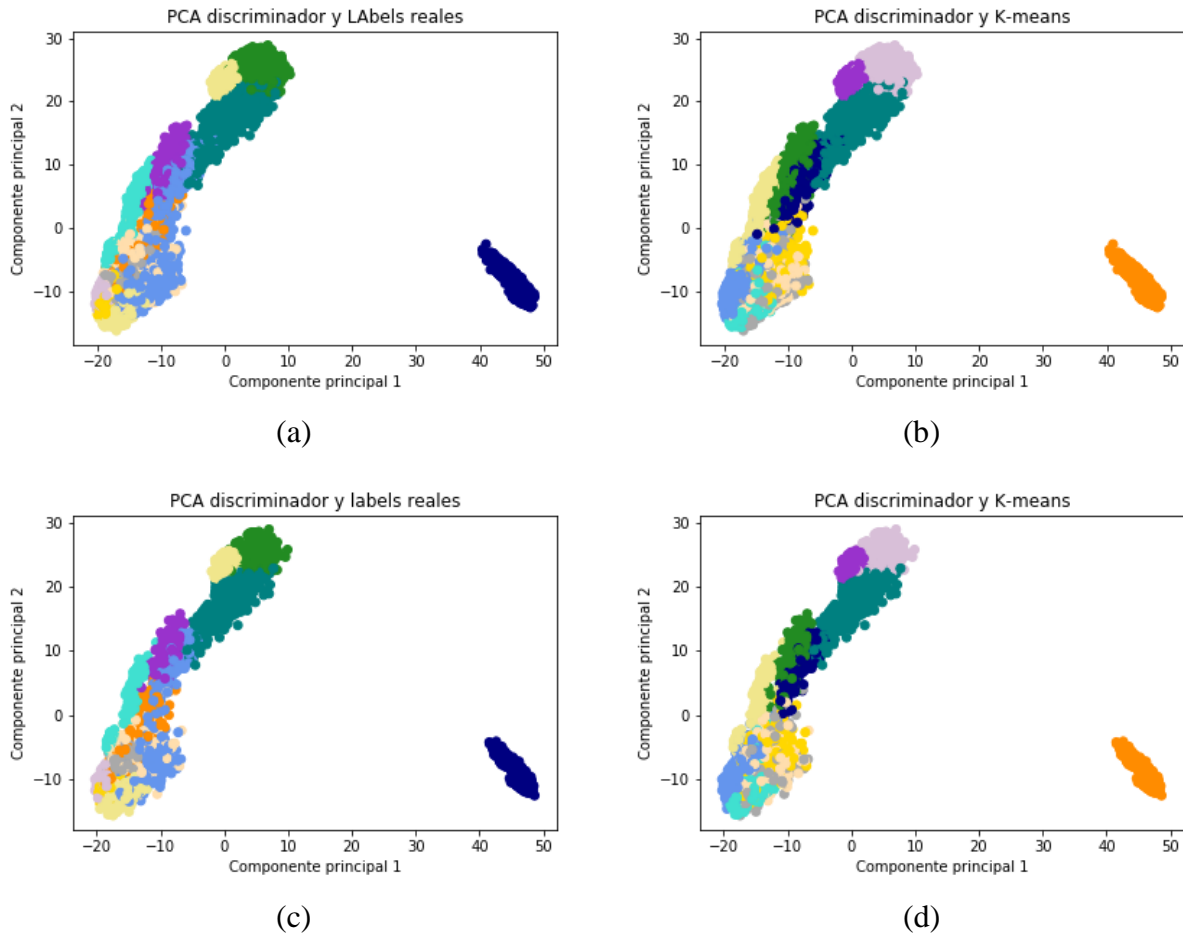


Figura 7.8: PCA para los puntos a la salida del discriminador en MRGAN para el caso CWRU (wavelets), los colores muestran los clústeres obtenidos por K-means (no hay relación entre ellos). (a) Clasificación real (entrenamiento), (b) clasificación K-means (entrenamiento), (c) clasificación real (validación) y (d) clasificación k-means (validación).

De las tres figuras anteriores se aprecia que existe una clara separación entre la línea base y las fallas en el PCA. Mientras estas últimas se hallan cercanas en el espacio haciendo que los algoritmos de clustering no puedan separarles de manera apropiada a diferencia del caso MFPT (Figuras 7.3 y 7.4) donde la separación visualmente es clara. También se observa una mayor regularidad en la Figura 7.8, que en las anteriores, donde aparecen nuevos colores en los datos de validación. En particular se observa que las configuraciones que usan spectral-clustering no logran posicionar en los mismos clústeres los datos de entrenamiento y validación (Figuras 7.6 y 7.7 (b) y (d)), pues los colores se aprecian en diferentes áreas. Teniéndose altos valores en los indicadores, pero siendo inconsistentes entre entrenamiento y validación.

En las próximas secciones se ahondará en la composición de cada clúster para ambos sets de datos.

## **7.2. Hallazgos y mejoras al procedimiento**

En la sección anterior se ha estudiado el comportamiento de las diversas configuraciones del procedimiento. Esto ha permitido detectar las más prometedoras, es decir, las que entregan mejores indicadores. Sin embargo, aún existen elementos que no han sido estudiados, como la evolución de los indicadores a medida que se avanza en iteraciones. Se recuerda, que todos los resultados de la sección anterior han sido a iteraciones fijas. Tampoco, se ha ahondado en la estructura misma de clústeres. En esta sección se realizan estos análisis sobre las configuraciones con mejores indicadores halladas en la sección anterior.

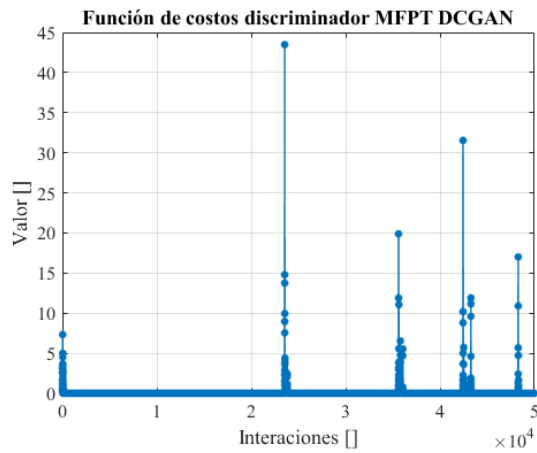
En primera instancia se analiza cómo influye la función de costos del discriminador en el aprendizaje de la red usada, esto es, comparando los indicadores cuando la función de costos toma valores relevantes. En particular, es de interés entender cómo se comportan después de un aumento considerable en la función de costos; ya que intuitivamente esto significa que el generador logra engañar al discriminador, por lo cual el primero debe aprender a diferenciar las imágenes reales y generadas para reducir su función de costos, logrando así la mejora en la extracción de características deseada. En la segunda parte, se presentan las tablas de contingencia para la mejor configuración obtenida en este estudio, tanto para los datos de entrenamiento como los de evaluación a fin de comparar como los clústeres están formados, respecto a las fallas reales. Para estos experimentos se dedican una sub sección para cada set de datos tratado.

### **7.2.1. Análisis del costo del discriminador**


En esta prueba, se han considerado solamente las redes que han tenido los mejores resultados en la sección anterior, esto es DCGAN, InfoGAN y MRGAN. Para ambos sets de datos se han evaluado los indicadores para 5 puntos en el procesos de entrenamiento: la que presenta el mayor costo del discriminador después de las primeras 10 000 iteraciones (ya que existen inestabilidades en el entrenamiento al inicio), 50 iteraciones posteriores (a este máximo), 1 000 iteraciones posteriores, 1 500 iteraciones posteriores y a las 50 000 iteraciones.

Las Figuras 7.9 y 7.10 muestran la evaluación de las funciones de costo para las arquitecturas ensayadas en ambos sets de datos, cabe destacar que cada arquitectura presenta una forma particular de comportamiento para el costo. Así los costos de la arquitectura DCGAN presentan picos puntuales donde el costo se dispara y luego vuelve en pocas iteraciones a valores en torno a cero. InfoGAN presenta un comportamiento más inestable, sin embargo existen periodos de iteraciones donde el costo se estabiliza, pudiendo relacionarse con el alcance de un equilibrio de Nash. Finalmente MRGAN presenta una evolución del costo similar a DCGAN, pero con un decaimiento más lento. No se considera Wasserstein GAN, pues no ha obtenido buenos indicadores en la sección anterior.

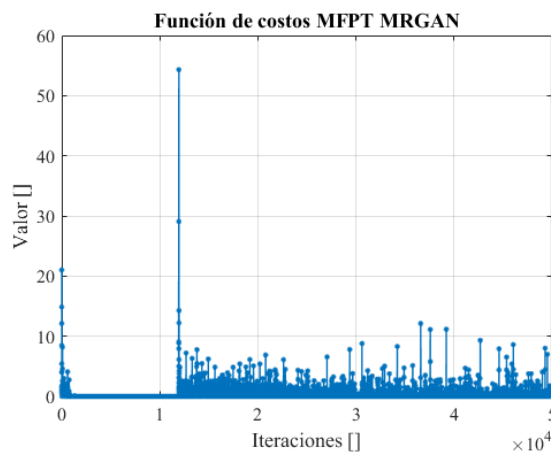
El objetivo esto es examinar como estos cambios en la función de costos del discriminador afectan los indicadores de desempeño del algoritmo de clustering. En los tres casos se presenta un máximo en la función antes de experimentar el comportamiento característico, por lo cual se evalúan algunas iteraciones posteriores a este evento para su agrupamiento y observar los cambios en los indicadores. Las Tablas 7.3 y 7.4 presentan los valores de costo máximo sobre el cual (junto a sus valores posteriores) se evalúa el entrenamiento de la red, esto es las iteraciones sobre las cuales se aplica el algoritmo de clustering para observar la evolución de los indicadores. Resultados presentados en las dos sub-secciones siguientes.



(a)



(b)



(c)

Figura 7.9: Funciones de costo para el discriminador en MFPT (wavelets) de las GANs usadas: (a) DCGAN, (b) InfoGAN y (c) MRGAN.

Tabla 7.3: Iteraciones dónde se ha obtenido el costo máximo del discriminador (después de 10 000 iteraciones), set MFPT (wavelets).

<i>Arquitectura</i>	<i>Iteración (época) máximo costo usada</i>	<i>Iteraciones (épocas) a evaluar indicadores</i>
<i>DCGAN</i>	23 546 (614)	23 546 (614)/ 23 596 (615)/ 24 596 (640)/ 25 096 (653)/50 000 (1 303)
<i>InfoGAN</i>	42 512 (1 107)	42 512 (1 107)/ 42 562 (1 109)/ 43 512 (1 133)/ 44 012 (1 147)/50 000 (1 303)
<i>MRGAN</i>	11 944 (311)	11 944 (311)/ 11 994 (313)/ 12 944 (337)/ 13 444 (350)/ 50 000 (1 303)

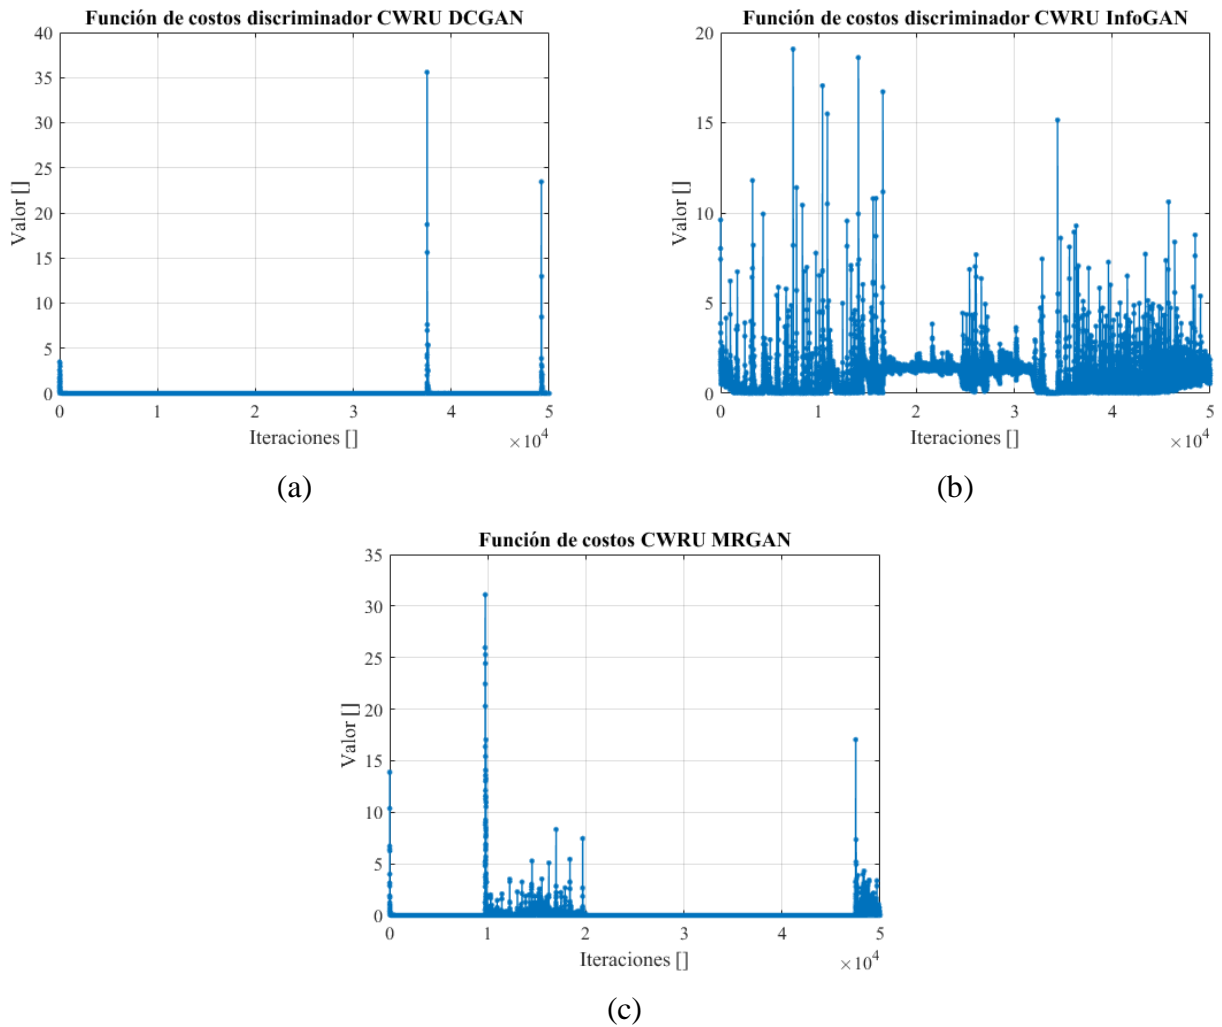


Figura 7.10: Funciones de costo para el discriminador en CWRU (wavelets) de las GANs usadas: (a) DCGAN, (b) InfoGAN y (c) MRGAN.

Tabla 7.4: Iteraciones dónde se ha obtenido el costo máximo del discriminador (después de 10 000 iteraciones), set CWRU (wavelets).

<i>Arquitectura</i>	<i>Iteración (época) máximo costo usada</i>	<i>Iteraciones (épocas) a evaluar indicadores</i>
<i>DCGAN</i>	37 529 (162)	37 529 (162) / 37 579 (162) / 38 529 (166) / 39 029 (168) / 50 000 (213)
<i>InfoGAN</i>	14 068 (60)	14 068 (60) / 14 118 (64) / 15 068 (64) / 15 568 (66) / 50 000 (213)
<i>MRGAN</i>	47 513 (202)	47 513 (202) / 47 563 (202) / 48 513 (206) / 49 013 (209) / 50 000 (213)

### 7.2.1.1.MFPT

Para el caso MFPT se presentan los indicadores para las dos arquitecturas con los indicadores más altos de las tres probadas. Las Figuras 7.11 y 7.12 presentan los valores obtenidos tanto para los datos de entrenamiento como los de validación en ambas arquitecturas, mientras la Figura 7.13 muestra los PCA para la arquitectura MRGAN que es la que obtiene un mejor resultado en esta prueba. Finalmente las Tablas 7.5 y 7.6 presentan los resultados exactos de esta última clasificación.

Considerando la Figura 7.10 (c) se observa que a partir del máximo el discriminador de la MRGAN comienza a tener un costo inestable, de igual manera los indicadores mejoran a medida que avanzan las iteraciones, por lo tanto el generador como el discriminador están compitiendo.


En el caso DCGAN, en las dos primeras iteraciones consideradas (el máximo y 50 iteraciones posteriores), el costo del discriminador aún está decayendo (Figura 7.10 (a)), aun así se aprecia una semejanza en los indicadores, al igual que entre las épocas 640 y 653, entre las cuales no existe ningún aumento repentino en el costo. A diferencia que en MRGAN se aprecia como el NMI va subiendo según las iteraciones.

En resumen cambios en la función de costos parecen generar efecto en algunos indicadores como es el NMI o la pureza.


Por otro lado, los PCAs de la Figura 7.13 muestran como las fallas son prácticamente separadas en el espacio.

Las Tablas 7.5 y 7.6 corroboran lo anterior. Estas matrices comparan las muestras con su clasificación real (filas) junto a la clasificación obtenida (columnas) no teniendo relaciones ambas clasificaciones. Como los indicadores presentan, en los grupos formados predomina un tipo de falla. Se logra un clúster que solo posee muestras de línea base. La única anomalía son algunas muestras de falla en pista interior que se clasifican en un clúster que posee todas las fallas en la pista exterior. Esto que se discute en más detalle en la sección dedicada a ello, examinándose las muestras mal clasificadas.

De ambas tablas se establecen dos evidencias importantes. Por un lado se logra una alta identificación en los datos, esto es, los clústeres presentan un alto porcentaje de fallas de un mismo tipo (poca dispersión en filas). Mientras que por el otro, se logra una división de los tipos de falla con los clústeres (particiones con el predominio de una sola clasificación real, o sea, poca dispersión en columnas).




(a)




(b)

Figura 7.11: Indicadores obtenidos para MRGAN DIS/KM en el caso MFPT para varios puntos del entrenamiento: (a) datos de entrenamiento y (b) datos de validación.





(a)



(b)

Figura 7.12: Indicadores obtenidos para DCGAN DIS/KM en el caso MFPT para varios puntos del entrenamiento: (a) datos de entrenamiento y (b) datos de validación.

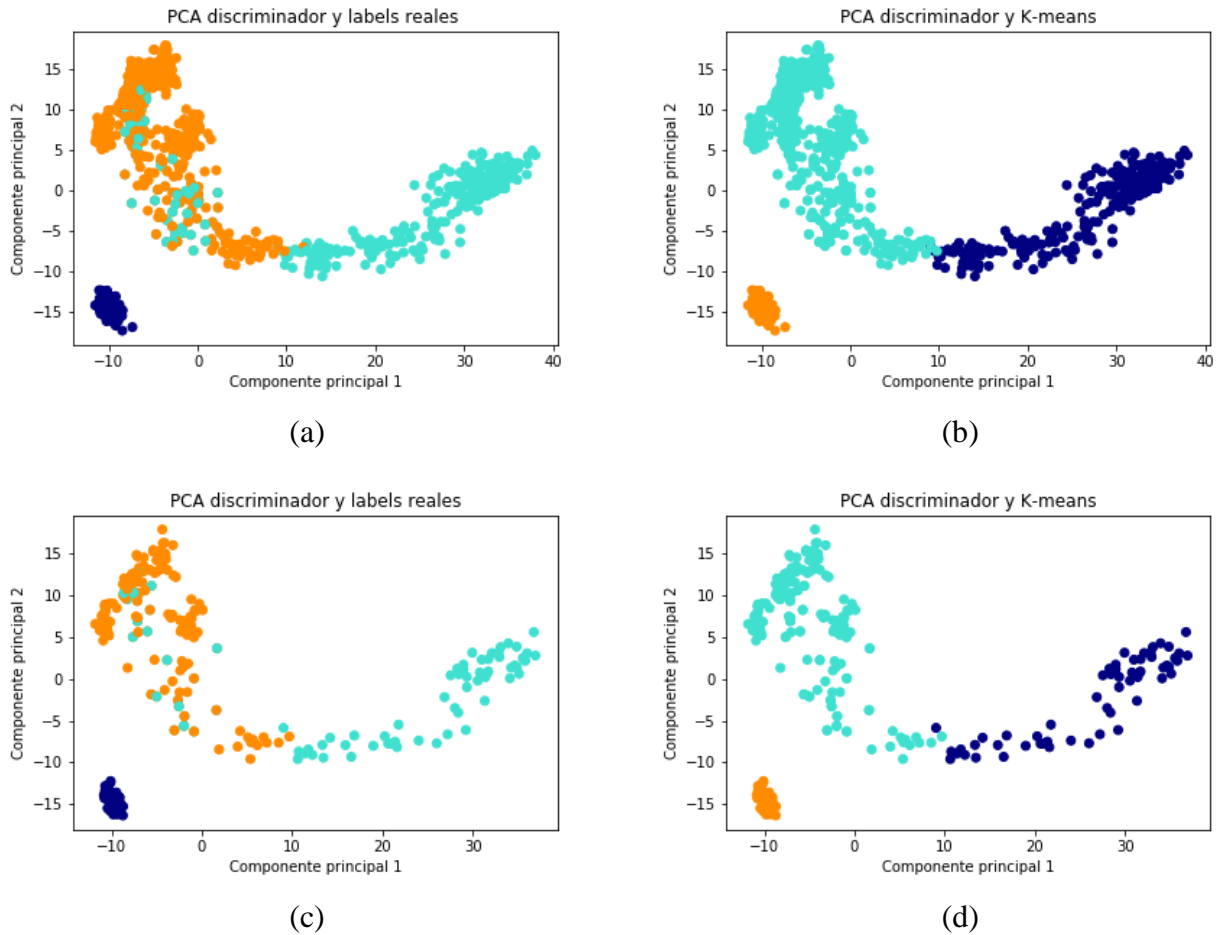


Figura 7.13: PCA MRGAN DIS/KM para la iteración con los mejores indicadores (época 1 303) (Labels reales: Azul: línea base, turquesa: falla en pista interior, naranja: falla en pista exterior. En la aplicación de K-means los colores solo representan clústeres y no tiene relación entre sí).

Tabla 7.5: Matriz de contingencia MRGAN DIS/KM época 1 303, datos de entrenamiento MEFPT.

<i>Muestras / Porcentaje</i>	<i>0</i>	<i>1</i>	<i>2</i>
<i>0 Línea Base</i>	0 / 0,0%	0 / 0,0%	285 / 100,0%
<i>1 Falla en pista interior</i>	235 / 71,4%	94 / 28,6%	0 / 0,0%
<i>2 Falla en pista exterior</i>	1 / 0,2%	613 / 99,8%	0 / 0,0%

Tabla 7.6: Matriz de contingencia MRGAN DIS/KM época 1 303, datos de validación MFPT.

<i>Muestras / Porcentaje</i>	<i>0</i>	<i>1</i>	<i>2</i>
<i>0 Línea Base</i>	0 / 0,0%	0 / 0,0%	72 / 100,0%
<i>1 Falla en pista interior</i>	60 / 71,4%	24 / 28,6%	0 / 0,0%
<i>2 Falla en pista exterior</i>	0 / 0,0%	156 / 100,0%	0 / 0,0%

### 7.2.1.2.CWRU

En este caso los mejores resultados se han obtenido con las arquitecturas InfoGAN y MRGAN, ambas con el algoritmo de clustering aplicado a la penúltima capa del discriminador. Las Figuras 7.14 y 7.15 muestran los indicadores, la Figura 7.16 muestra el PCA para InfoGAN en la iteración 213, mientras las Tablas 7.7 y 7.8 corresponden a las matrices de contingencia obtenidas en esa última configuración.

De la Figura 7.14, no transcurren muchas épocas entre las iteraciones consideradas, salvo que al final se tienen muchos mejores indicadores que en los puntos máximos. La figura 7.10 (b) muestra que las primeras épocas se encuentran en un momento donde el costos tienen un comportamiento muy inestable, mientras que en la última parte este ha pasado ya por una zona de equilibrio y se encuentra nuevamente aumentado, es decir las redes parecen estar compitiendo, por lo cual la identificación se logra de mejor manera.

La Figura 7.15 presenta disparidad en sus indicadores ente los datos de entrenamiento (a) y los de validación (b), similarmente a lo que se ha observado cuando de consideran configuraciones con spectral clustering. Sin embargo, los indicadores también parecen mejorar después del máximo detectado. Un detalle a considerar es que según la Figura 7.10 (c) el máximo considerado corresponde al segundo (cercano al termino de las iteraciones), pues el primero ocurre antes de las 10 000 iteraciones, por lo cual se ve la evolución del conto en unas pocas épocas, probable causa de la variabilidad.

Para las tablas 7.7 y 7.8, los números en la primera columna representan los siguientes grupos a clasificar:

- 0: Línea base.
- 1: Falla en pista interior de diámetro 0,007''
- 2: Falla en pista interior de diámetro 0,014''
- 3: Falla en pista interior de diámetro 0,021''
- 4: Falla en pista interior de diámetro 0,028''
- 5: Falla en elemento rodante de diámetro 0,007''
- 6: Falla en elemento rodante de diámetro 0,014''
- 7: Falla en elemento rodante de diámetro 0,021''
- 8: Falla en elemento rodante de diámetro 0.028''
- 9: Falla en pista exterior de diámetro 0,007''
- 10: Falla en pista exterior de diámetro 0,014''
- 11: Falla en pista exterior de diámetro 0,021''


Sobre estos clústeres se establecen las siguientes consideraciones respecto a la composición de las muestras obtenidas para la arquitectura InfoGAN que ha obtenido los mejores resultados para este caso:

- 0 - Línea base: 100% de las muestras en un mismo clúster (1) en tanto en entrenamiento como en validación.
- 1 - Falla en pista interior de diámetro 0,007'': 92% de los datos clasificados en entrenamiento y 93% validación, el resto es considerado fallo en pista exterior.
- 2 - Falla en pista interior de diámetro 0,014'': el 61% (entrenamiento) 58% (validación) de las muestras se confunde con fallas en elementos rodantes (0), el resto con fallas en pista exterior (2 y 6).
- 3 - Falla en pista interior de diámetro 0,021'': 100% de las muestras clasificadas en un mismo clúster (5) en tanto en entrenamiento como en validación.
- 4 - Falla en pista interior de diámetro 0,028'': 100% de las muestras clasificadas en un mismo clúster (4) en tanto en entrenamiento como en validación.
- 5 - Falla en elemento rodante de diámetro 0,007'': 99% en ambos sets en un mismo clúster (0).
- 6 - Falla en elemento rodante de diámetro 0,014'': 80% (entrenamiento) – 79% (validación) en un mismo clúster (0), el resto se confunde con fallas en pista exterior (2 y 6).
- 7 - Falla en elemento rodante de diámetro 0,021'': 97% (entrenamiento) – 95% (validación) en un mismo clúster (0), el resto se confunde con fallas en pista exterior (2 y 6).
- 8: Falla en elemento rodante de diámetro 0.028'': 100% de las muestras clasificadas en un mismo clúster (3) en tanto en entrenamiento como en validación.
- 9 - Falla en pista exterior de diámetro 0,007'': asigna distintos clústeres según la posición de la falla: opuesta (0, 2 y 6), centrada (8) y ortogonal (11), en los 2 últimos los clúster se componen principalmente de estas muestras
- 10: Falla en pista exterior de diámetro 0,014'': 100% de las muestras clasificadas en un mismo clúster (7) en tanto en entrenamiento como en validación.
- 11: Falla en pista exterior de diámetro 0,021'': asigna distintos clústeres según la posición de la falla: centrada (0, 2), centrada y opuesta (6) y ortogonal (10), el ultimo los clúster se compone principalmente de estas muestras.


En términos generales los casos de línea base, falla en pista exterior de diámetro 0,007''; 0,021'' y 0,028''; falla en elemento rodante de diámetro 0,028'' y falla en pista exterior de diámetro 0,014'' presentan buenos índices de identificación del tipo de falla (gran parte de los datos en un mismo clúster o poca dispersión en filas), así como clasificación (las particiones presentan principalmente elementos de un tipo de falla).

Respecto a los elementos restante se aprecian dos fenómenos de interés: por un lado las fallas en elementos rodantes no mencionadas anteriormente presentan un alto nivel de identificación del tipo de falla, sin embargo no pueden ser diferenciadas, pues todas han sido clasificadas dentro de la misma partición. A este clúster se le agrega buena parte de las muestras de falla en la pista exterior de diámetro 0,021''. Ante esto, la causa probable de esto es la presencia de elementos ajenos a los síntomas de falla. En particular [21] expone a partir de la observación de estas señales la presencia de interferencia electro-magnética (EMI por sus siglas en inglés), por lo cual puede entenderse que la característica identificada podría no ser la de la falla.

El otro grupo lo componen las fallas en la pista exterior de diámetros 0,014'' y 0,021''. Estos casos presentan una mala identificación del tipo de falla y de clasificación. Sin embargo, se debe considerar que estas fallas poseen grupos diferentes (según la posición donde estas se ubican). Al realizar el análisis de trazabilidad se observa que los elementos de cada clasificación comparten elementos de la posición de la falla sobre el tamaño de la grieta. Por ejemplo los clústeres 2 y 6 solo tienen muestras con fallas ubicadas a las 12 y a las 6 (centrada y opuesta). El 8 solo posee fallas centradas y los clústeres 10 y 11 solo fallas ortogonales. Pudiéndose considerar algún grado de caracterización respecto a estas consideraciones mecánicas más allá de los síntomas de falla.




(a)

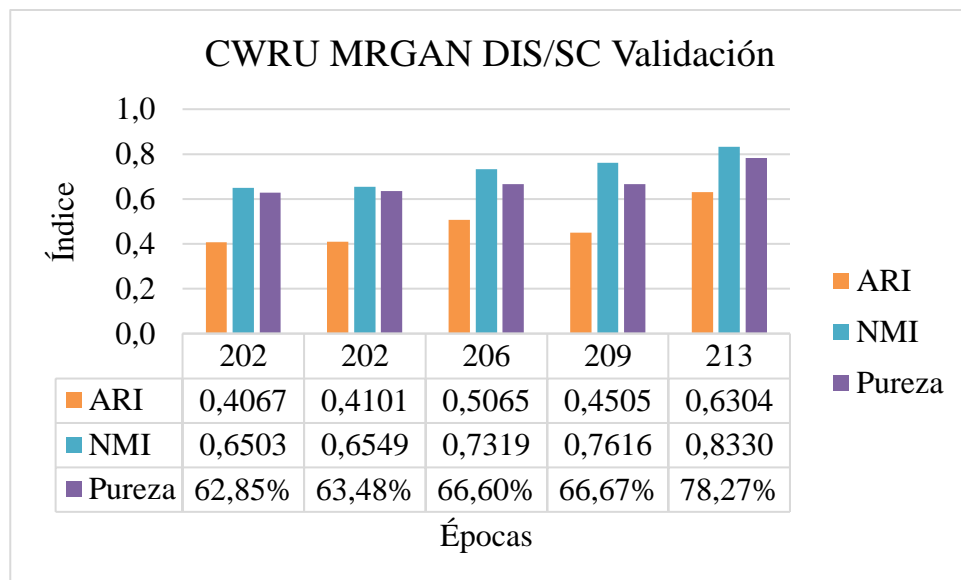


(b)

Figura 7.14: Indicadores obtenidos para InfoGAN DIS/KM en el caso CWRU para varios puntos del entrenamiento: (a) datos de entrenamiento y (b) datos de validación.



(a)



(b)

Figura 7.15: Indicadores obtenidos para MRGAN DIS/KM en el caso CWRU para varios puntos del entrenamiento: (a) datos de entrenamiento y (b) datos de validación.

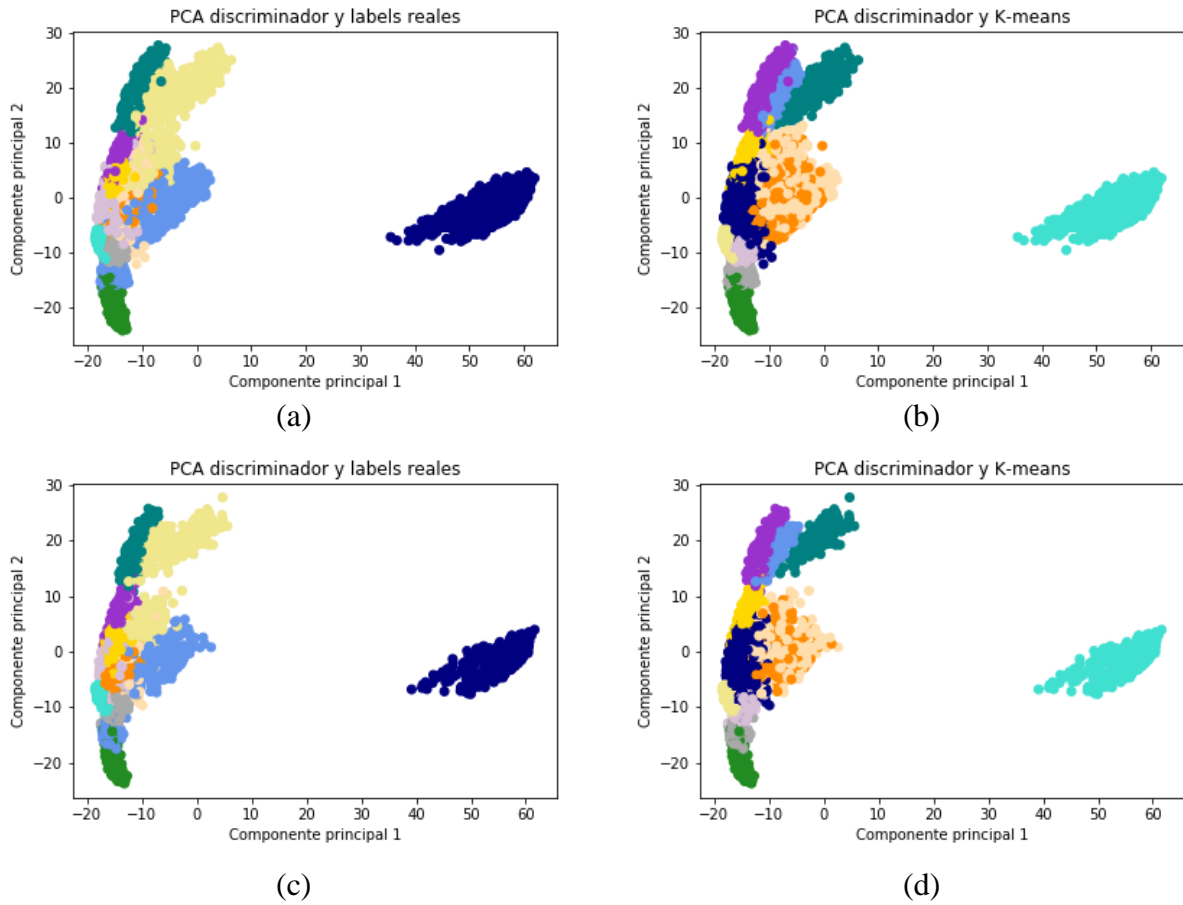


Figura 7.16: PCA InfoGAN DIS/KM para la iteración con los mejores indicadores (época 213) (PCAs con Labels reales: coloración según la expuesta en la sección 7.1.2. PCAs con K-means los colores solo representan clústeres y no tiene relación entre sí).



Tabla 7.7: Matriz de contingencia InfoGAN DIS/KM época 213, datos de entrenamiento CWRU, columnas clústeres reales, filas clústeres hallados.

	0	1	2	3	4	5	6	7	8	9	10	11
0	2659 /											
	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
1										759 /		66 /
	0%	0%	0%	0%	0%	0%	0%	0%	0%	92%	8%	0%
2	462 /		137 /			152 /		4 /	3 /			
	61%	0%	18%	0%	0%	0%	20%	1%	0%	0%	0%	0%
3	759 /											
	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%
4	1259 /										3 /	
	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
5	753 /		2 /			1 /	1 /					
	99%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
6	608 /		69 /			18 /	63 /					
	80%	0%	9%	0%	0%	2%	8%	0%	0%	0%	0%	0%
7	739 /		11 /			3 /	6 /					
	97%	0%	1%	0%	0%	0%	1%	0%	0%	0%	0%	0%
8	1258 /										2 /	
	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
9	143 /		259 /			356 /		762 /		759 /		
	6%	0%	11%	0%	0%	0%	16%	0%	33%	0%	0%	33%
10	758 /											
	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%
11	66 /		691 /			1 /	759 /				566 /	
	3%	0%	33%	0%	0%	0%	36%	0%	0%	0%	27%	0%

Superior: Número de muestras.

Inferior: Porcentaje de las muestras del clúster real.

Tabla 7.8: Matriz de contingencia InfoGAN DIS/KM época 213, datos de validación CWRU, columnas clústeres reales, filas clústeres hallados.

	0	1	2	3	4	5	6	7	8	9	10	11
0	668 /											
	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
1										192 /		15 /
	0%	0%	0%	0%	0%	0%	0%	0%	0%	93%	7%	0%
2	111 /	40 /			39 /			1 /	1 /			
	58%	0%	21%	0%	0%	0%	20%	1%	0%	1%	0%	0%
3						192 /						
	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%
4					317 /							
	0%	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%
5	189 /	1 /			1 /							
	99%	0%	1%	0%	0%	0%	1%	0%	0%	0%	0%	0%
6	151 /	21 /			1 /		19 /					
	79%	0%	11%	0%	0%	1%	10%	0%	0%	0%	0%	0%
7	182 /	4 /			2 /		4 /					
	95%	0%	2%	0%	0%	1%	2%	0%	0%	0%	0%	0%
8				316 /								
	0%	0%	0%	100%	0%	0%	0%	0%	0%	0%	0%	0%
9	43 /	71 /			0%		78 /	191 /			191 /	
	7%	0%	12%	0%	0%		14%	0%	33%	0%	0%	33%
10								192 /				
	0%	0%	0%	0%	0%	0%	0%	100%	0%	0%	0%	0%
11	15 /	0%	178 /		0%	0%	0%	191 /	0%	0%	0%	144 /
	3%		34%					36%				27%

Superior: Número de muestras.

Inferior: Porcentaje de las muestras del clúster real.

### 7.3. Entrenamiento con análisis de envolvente.

En esta sección se realiza el procedimiento usando las envolventes de la señales de vibración para formar la imagen. En el caso MFPT dado los resultados anteriores obtenidos, sólo considera la arquitectura que ha tenidos los mejores resultados. Esto es, MRGAN usando escalogramas y clasificando mediante el algoritmo k-means en la penúltima capa del discriminador. Para la sección dedicada al set CWRU [21] presentan algunos antecedentes que restan interés a la clasificación usando análisis de envolvente, puesto que existen algunas muestras no identificables mediante este procedimiento. Sin embargo esta información es un aporte para la discusión de los resultados que se realiza en la siguiente sección.

#### 7.3.1. MFPT.

Ejemplos de imágenes usadas para el entrenamiento son presentados en la Figura 7.17. La figura 7.18 muestra la función de costos durante el entrenamiento de la red. Luego la Tabla 7.9 presenta los mejores indicadores obtenidos que en este caso han ocurrido 1 500 iteraciones después del máximo costo (iteración 34 065). Finalmente la Figura 7.19 presenta le PCA obtenido y las tablas 7.10 y 7.11 son las matrices de contingencia de este experimento.




Figura 7.17: Ejemplo de transformada de wavelets usando las envolventes de las señales de vibraciones mecánicas, (a) línea base, (b) fallo en pista interior y (c) fallo en pista exterior MFPT.

Las muestras presentadas en la figura anterior son fácilmente identificables, es más en el caso de la fallas en pista interior se aprecian líneas más dispersas que en el caso de las fallas en pista exterior, debido a las bandas laterales de la frecuencia de giro.




Figura 7.18: Función de costos MRGAN DIS/KM usando wavelets para el caso MFPT con la envolvente de las señales.

Si se consideran los análisis de la sección anterior, la Figura 7.18 muestra que la red mejora hacia el final. Es más, el mejor resultado se obtiene en la parte dónde el costo es cercano a cero.

Tabla 7.9: Indicadores obtenidos por la arquitectura MRGAN para el caso MFPT con transformada de wavelets sobre envolventes de las señales (elaboración propia).

<i>Indicador/ Arquitectura</i>	<i>MRGAN WL ENV DIS/SC</i>
<i>ARI Entrenamiento</i>	0,3738
<i>ARI Validación</i>	0,3644
<i>NMI Entrenamiento</i>	0,5239
<i>NMI Validación</i>	0,5207
<i>Pureza Entrenamiento</i>	71,58%
<i>Pureza Validación</i>	70,83%

Comparando los resultados de la Tabla 7.9 con los de la Tabla 7.1 se tiene que los indicadores son peores que cuando se usan señales puras, la función de costos puede indicar que el entrenamiento ha sido pobre como una de las posibles causas.

Por otro lado la Figura 7.19 (a) y (c) expone que las fallas en pista exterior se encuentran especialmente unidas a las de línea base. Las Tablas 7.10 y 7.11 muestran que el algoritmo de clustering clasifica varias de las fallas en pista exterior como línea base, una posible causa de esto es que con el cálculo de la envolvente al considerar una muestra del largo aquí usado se pierde mucha energía del modo de falla confundiendo con la línea base. Estas ideas serán revisadas en la sección de discusiones.

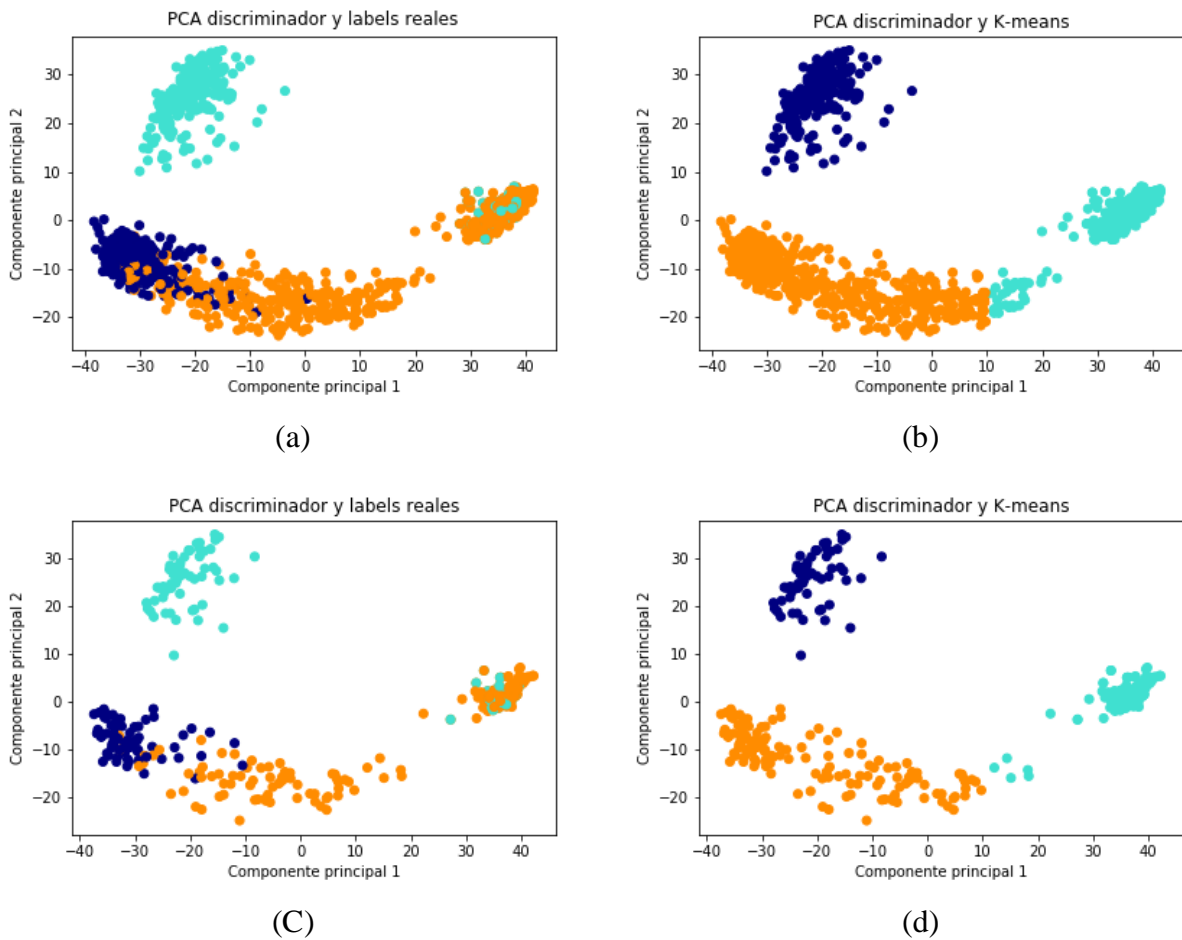


Figura 7.19: PCA MRGAN DIS/KM para la iteración 35 565 usando escalogramas para la envolvente de las señales (los colores solo representan clústeres y no tiene relación entre sí).

Tabla 7.10: Matriz de contingencia MRGAN DIS/KM iteración 35 565, datos de entrenamiento, set MFPT con wavelets de las señales envolventes.

<i>Muestras / Porcentaje</i>	<i>0</i>	<i>1</i>	<i>2</i>
<i>0 Línea Base</i>	0 / 0,0%	0 / 0,0%	285 / 100,0%
<i>1 Falla en pista Interior</i>	235 / 71,4%	94 / 28,6%	0 / 0,0%
<i>2 Falla en pista exterior</i>	0 / 0,0%	329 / 53,6%	285 / 46,4%

Tabla 7.11: Matriz de contingencia MRGAN DIS/KM iteración 35 565, datos de validación, set MFPT con wavelets de las señales envolventes.

<i>Muestras / Porcentaje</i>	<i>0</i>	<i>1</i>	<i>2</i>
<i>0 Línea Base</i>	0 / 0,0%	0 / 0,0%	72 / 100,0%
<i>1 Falla en pista Interior</i>	60 / 71,4%	24 / 28,6%	0 / 0,0%
<i>2 Falla en pista exterior</i>	0 / 0,0%	84 / 53,8%	72 / 46,2%

### 7.3.2. CWRU.

Para el caso MFPT, la motivación principal para realizar una clasificación con las envolventes de las señales es que tal como se expone en la sección 6.2.1 y como se presenta en [20] resulta simple apreciar los síntomas clásicos (sección 5.1.1.) de las fallas originalmente clasificadas para este set. Sin embargo, como se detalla en [21] para el caso CWRU esto no es tan simple ya que en algunas muestras hasta los métodos no automatizados (que consideran el análisis de envolvente simple y con filtrado de bandas) tienen problemas, por lo cual realizar una clasificación con estas señales resulta contraproducente desde una perspectiva de análisis. En primera instancia debido a que corresponde a una identificación más compleja que MFPT con 12 categorías. En segundo lugar, el objetivo de este ensayo es verificar si es posible mejorar los resultados anteriores usando un pre procesamiento que permite hacer evidente la presencia de fallas según lo expuesto en la sección 5.1.1. y como se presenta en la Figura 6.2 para el caso MFPT. El hecho de que [21] muestre que algunas muestras no son identificables por análisis de envolvente trunca el objetivo de esta prueba.

En esta parte se resumen los hallazgos obtenidos en [21] a fin de poder comparar con los resultados obtenidos para las señales puras obtenidos en la sección 7.2.1. en la siguiente parte del documento.

Características obtenidas por [21] para el set de datos CWRU, drive end 12 K:

- Fallas de pista interior fácilmente identificables por análisis de envolvente para la señal pura, salvo un grupo de fallas de diámetro 0,014'' que ha requerido usar métodos de filtrado para lograr su diagnóstico. Además las señales con falla de diámetro 0,028'' no corresponden al mismo tipo de rodamiento que el resto de las muestras.
- La fallas en elementos rodantes no han podido ser identificables por ninguna de las metodologías, salvo las de diámetro 0,028'', algunas señales muestran presencia de síntomas de otros tipos de falla como de pista interior o exterior.
- La fallas en pista exterior con carga centrada has podido ser identificadas salvo las de diámetro 0,014'', se algunas modulaciones anómalas y perdidas mecánicas representadas por una alta potencia las frecuencias de la velocidad de giro y sus armónicas.
- Fallas en pista exterior con carga ortogonal fácilmente diagnosticables.
- Fallas en pista exterior con carga opuesta en teoría no debiesen ser detectadas pero resultan identificables.

En [21] es posible encontrar el detalle del diagnóstico mediante métodos no automáticos y bien estudiados, aquí solamente se han resumido las características generales para los datos de interés.

#### 7.4. Extensión a vibraciones con rodamiento bajo degradación continua.

El set de datos FEMTO-ST es una serie de pruebas en rodamientos de degradación acelerada donde se toman muestras desde que el rodamiento está nuevo hasta su destrucción. Este set está dividido en dos grupos; uno de entrenamiento y otro de validación. En la siguiente sección se usan dos tipos de imágenes; los kurtogramas rápidos y las transformadas de wavelets o escalogramas. El interés de esta sección es estudiar cómo se comporta la arquitectura que ha tenido los mejores resultados en las pruebas anteriores, comprender que es lo que ocurre ante esta nueva situación y qué consideraciones hay que tener en un caso más cercano al propuesto inicialmente como motivación.

En la siguiente sección se presentan las imágenes usadas para el entrenamiento y los resultados obtenidos. Cabe recordar que este set no tiene ninguna clasificación a priori por lo cual no es posible comparar los resultados del procedimiento cuantitativamente. Por lo cual, aquí se exponen resultados que son revisados y analizados cualitativamente en la sección siguiente.

##### 7.4.1. FEMTO-ST.

La Figura 7.19 presenta lagunas muestras de imágenes usadas para el entrenamiento del modelo y evaluación del modelo. Cada recuadro corresponde a un mismo rodamiento, siendo progresivas de izquierda a derecha (la primera corresponde al 12,5 % de la duración del ensayo, la segunda al 37,5%, la tercera al 62,5 y la última al 87,5 % de la duración del ensayo). A simple vista son notorios manifestaciones de distintos modos de falla para rodamientos diferentes, en particular con los escalogramas que son comparables con otros sets como MFPT. Así la Figura 7.19 (c) presenta un esquema de degradación distinto a la Figura 7.19 (d), es más comparando con muestras de MFPT (c) podría corresponder a una falla en pista interior, mientras que (d) a una en la pista exterior, lamentablemente el tamaño de las muestras no permite tener un buen análisis de envolvente.




Figura 7.19: Ejemplo de imágenes del set FEMTO-ST usadas para el entrenamiento del modelo, (a) KUR rodamiento de entrenamiento, (b) KUR entrenamiento de validación, (c) WL rodamiento de entrenamiento y (d) WL rodamiento de validación.

En lo que sigue, las Figuras 7.20 y 7.21 muestran la clasificación realizada con el algoritmo K-means para las arquitecturas MRGAN (el tiempo de entrenamiento por época es de 22,96 segundos aproximadamente) entrenadas con kurtogramas rápidos y con escalogramas ordenadas temporalmente para un rodamiento de entrenamiento Bearing 3\_2. En ellas se aprecia que solo la transformada de wavelets consigue un ordenamiento temporal usando los datos de la penúltima capa del discriminador en la Figura 7.21 (b) (esto ocurre en todas las muestras tanto de entrenamiento como de validación), es decir mediante el procedimiento aquí expuesto es posible agrupar muestras siguiendo un ordenamiento temporal, cosa que como se expone en la Figura 7.21


(a) no es posible hacer directamente, mientras que de la Figura 7.20 no se concluye ninguna relación entre las muestras. Luego las Tablas 7.12 y 7.13 muestran las secuencias de particiones o clústeres seguidas temporalmente por todos los rodamientos del set, separado los usados para entrenamiento como los de validación.

Lo primero que se ha de destacar es que todas las muestras iniciales se encuentran en un mismo clúster (0), luego al degradarse el rodamiento las muestras son clasificadas en otras agrupaciones, a priori no siguiendo un flujo claro, algunos rodamiento cambias desde el estado 0 al 2, otros al 3, otros del 0 al 2 y luego al 3, etc. Por lo cual, en la siguiente sección se estudian muestras particulares para comprender los fenómenos que en este tipo de ensayo ocurre.


En este set no resulta conveniente el uso del análisis de envolvente debido a la poca longitud de sus muestras (un décimo de segundo).

No se ha realizado el análisis usando kurtograma rápido para los datos de evaluación, dado su mal desempeño. En los anexos se encuentran el resto de los resultados.






(a)




(b)

Figura 7.20: Clasificación de muestras rodamiento Bearing 3\_2 (set de entrenamiento FEMTO-ST), (a) clasificación usando imágenes de kurtogramas rápidos y (b) clasificación usando la arquitectura MRGAN entrenada para la clasificación.



(a)



(b)

Figura 7.21: Clasificación de muestras rodamiento Bearing 3\_2 (set de entrenamiento FEMTO-ST), (a) clasificación usando imágenes de transformada de wavelets y (b) clasificación usando la arquitectura MRGAN entrenada para la clasificación.

Tabla 7.12: Resumen de secuencia seguida por las muestras para cada rodamiento en el set FEMTO-ST usando imágenes de transformada de wavelets procesadas por una MRGAN y un algoritmo K-means en la penúltima capa del discriminador (set de entrenamiento).

<i>Rodamiento</i>	<i>Velocidad de giro [RPM]</i>	<i>Carga [N]</i>	<i>Secuencia de Clústeres</i>
<i>Bearing 1_1</i>	1 800	4 000	0 – 2 – 3
<i>Bearing 1_2</i>	1 800	4 000	0 – 3
<i>Bearing 2_1</i>	1 650	4 200	0 – 3
<i>Bearing 2_2</i>	1 650	4 200	0 – 3
<i>Bearing 3_1</i>	1 500	5 000	0 – 2 – 3
<i>Bearing 3_2</i>	1 500	5 000	0 – 2 – 3

Tabla 7.13: Resumen de secuencia seguida por las muestras para cada rodamiento en el set FEMTO-ST usando imágenes de transformada de wavelets procesadas por una MRGA y un algoritmo K-means en la penúltima capa del discriminador (set de validación).

<i>Rodamiento</i>	<i>Velocidad de giro [RPM]</i>	<i>Carga [N]</i>	<i>Secuencia de Clústeres</i>
<i>Bearing 1_3</i>	1 800	4 000	0 – 1 0 – 2
<i>Bearing 1_5</i>	1 800	4 000	0 – 2 0 – 3
<i>Bearing 1_6</i>	1 800	4 000	0 – 2
<i>Bearing 1_7</i>	1 800	4 000	0 – 2 – 3
<i>Bearing 2_3</i>	1 650	4 200	0 – 2
<i>Bearing 2_4</i>	1 650	4 200	0 – 2 (Pocas muestras en clúster 2)
<i>Bearing 2_5</i>	1 650	4 200	0 – 1 – 2 0 – 3
<i>Bearing 2_6</i>	1 650	4 200	0 – 2 (Pocas muestras en clúster 2)
<i>Bearing 2_7</i>	1 650	4 200	0 – 2 – 1 (Pocas muestras en clúster 1)
<i>Bearing 3_3</i>	1 500	5 000	0 – 3 (también pocas muestras en clúster 2)

## **8. Discusión de resultados.**

En la presente sección se presenta la discusión de los resultados obtenidos. En primera instancia se realizan algunos comentarios generales sobre el procedimiento estudiado en este trabajo, describiendo de manera cualitativa la funcionalidad del procedimiento. Después, mediante comparación entre los indicadores obtenidos para las configuraciones con los mejores resultados se detallan las ventajas del procedimiento. En la siguiente parte se procede a discutir en comparativamente las características de los resultados usando las matrices de contingencia mostradas en la sección anterior; comparando estos resultados con los métodos tradicionales de diagnóstico de falla. La diferencia es que mientras nuestro procedimiento busca dejar el mismo tipo de falla en una partición única y sin otros tipos de falla, los métodos basados en el análisis de envolvente deben ser capaces de realizar el diagnóstico de las fallas que componen este clúster. Finalmente se hace referencia a los logros obtenidos en el caso FEMTO-ST y las dificultades que aborda el procedimiento para la aplicación de sistemas monitoreados según lo propuesto en la motivación de este trabajo.

### **8.1.Consideraciones generales.**

En términos generales, el procedimiento de usar imágenes procesadas, entrenar una arquitectura GAN y usar algoritmos de clustering en alguna de sus capas tiene éxito en algunas de sus configuraciones (Tablas 7.1 y 7.2, Figuras 7.20 y 7.21). Respecto al tipo de imagen que debe usarse se tienen los mejores resultados con escalogramas que con espectrogramas o kutogramas rápidos. En las arquitecturas sólo la Wasserstein GAN tiene un desempeño inferior al resto de las estudiadas, aunque el resto tienen diferencias principalmente en la forma de aprendizaje la predicción para obtener un buen entrenamiento y la calidad de las imágenes generadas.

A continuación se discute en detalle los resultados de cada sección del procedimiento.

#### **8.1.1. Datos procesados.**

Respecto a los datos procesados, claramente se obtienen mejores resultados usando la transformada de wavelet sobre los otros dos tipos de imágenes usados. Así es como para el caso MFPT, usando una arquitectura MRGAN entrenado con escalogramas y clasificando mediante K-means en el discriminador se tienen indicadores mejores, a diferencia cuando la misma arquitectura se entrena con espectrogramas. Esto es cuantificado en la tabla 8.1 que presenta las diferencias que se presentan al usar como datos de entrada los escalogramas y los espectrogramas, En general todos los resultados obtenidos siguen esta tendencia. La explicación más apropiada es que el uso de imágenes que requieren usar la transformada de Fourier como el espectrograma, generan pérdida de resolución de acuerdo al largo de las muestras y la frecuencia de muestreo.

Tabla 8.1: Comparación indicadores arquitecturas MRGAN DIS/KM usando transformada de wavelets y SFFT, caso MFPT (elaboración propia).

<i>Indicador/ Arquitectura</i>	<i>MRGAN WL DIS/KM</i>	<i>MRGAN SFFT DIS/KM</i>	<i>Variación</i>
<i>ARI Entrenamiento</i>	0,683	0,5736	0,1094
<i>ARI Validación</i>	0,682	0,5831	0,0989
<i>NMI Entrenamiento</i>	0,6972	0,6193	0,0779
<i>NMI Validación</i>	0,6967	0,6307	0,066
<i>Pureza Entrenamiento</i>	88,52%	83,39%	5,13%
<i>Pureza Validación</i>	88,46%	83,97%	4,49%

Algo similar ocurre si comparamos las arquitecturas MRGAN y spectral clustering en el caso CWRU (tabla 8.2).

Tabla 8.2: Comparación indicadores arquitecturas MRGAN DIS/SC usando transformada de wavelets y SFFT, caso CWRU (elaboración propia).

<i>Indicador/ Arquitectura</i>	<i>MRGAN WL DIS/SC</i>	<i>MRGAN SFFT DIS/SC</i>	<i>Variación</i>
<i>ARI Entrenamiento</i>	0,5783	0,459	0,1193
<i>ARI Validación</i>	0,5851	0,4221	0,163
<i>NMI Entrenamiento</i>	0,7977	0,6667	0,131
<i>NMI Validación</i>	0,8208	0,591	0,2298
<i>Pureza Entrenamiento</i>	76,03%	62,06%	13,97%
<i>Pureza Validación</i>	79,57%	58,80%	20,77%

Cabe destacar también que el NMI en CWRU es mayor al caso MFPT debido a que son más particiones o clústeres y este indicador no es ajustado a diferencia del ARI como se ha mencionado en la sección 6.5.3. La principal causa probable de esta diferencia de desempeño es la resolución que se logra con SFFT, que depende del largo de la muestra que se tome. Como en todos los casos estas son muy cortas, el espectrograma no logra capturar las características fenomenológicas de la falla. Esto es, las frecuencias de falla y sus armónicos, teniéndose pérdidas en la calidad de información que esta imagen entrega.

Para el caso FEMTO-ST basta comparar las Figuras 7.20 y 7.21 y notar que mientras al entrenar la red con imágenes usando escalogramas se logra una agrupación temporal a diferencia del caso donde se usan kurtogramas rápidos. Las Tablas 7.12 y 7.13 presentan como esta tendencia ocurre en cada rodamiento probado en el set.

El caso del uso de la envolvente respecto a la señal pura (sección 7.3) se detalla con más atención en las secciones siguientes.

Resumiendo, se recomienda el uso de escalogramas como parte de la configuración para tener un buen desempeño en el procedimiento propuesto.

### **8.1.2. Modelos GANs.**

De los cuatro modelos GAN estudiados, Wasserstein GAN ha sido el que posee un peor desempeño (las tablas comparativas se encuentran en los anexos, sección 11.1). Las posibles causas de estos resultados se fundamentan en dos aspectos: en primera instancia esta arquitectura es muy susceptible a la tasa de aprendizaje. También es más lenta en su entrenamiento, lo cual desincentiva su estudio en este trabajo. Otra posible causa es que el uso de un limitador a la salida de la critic (discriminador si consideramos las otras arquitecturas GAN) a fin de poder usar la condición de Kantorovich-Rubinstein resulta una condición demasiado severa para el tipo de datos usado en el entrenamiento, ya que los valores de la critic están acotados, dificultando la optimización durante el entrenamiento.

Por otro lado, en el caso MFPT ha tenido mejores resultados con las arquitecturas DCGAN y MRGAN. En primera instancia (sección 7.1.1.) con indicadores idénticos (Tabla 7.1) y en una segunda instancia (sección 7.2.1.1.) con una ventaja para para la última arquitectura (Figuras 7.11 y 7.12). En el caso CWRU, InfoGAN parece tener un mejor desempeño, seguido de cerca por MRGAN, claro que en primer caso requiere el algoritmo K-means, mientras en el otro se usa spectral clustering y existen menos diferencias entre los indicadores de entrenamiento y de validación (ver Figuras 7.14 y 7.15).

En particular estas dos redes (MRGAN e InfoGAN) poseen un aprendizaje más regulado en el sentido que la función de costo es más variable que el caso DCGAN (Figuras 7.9 y 7.10). En la Figura 7.12 es posible ver como los indicadores no varían mucho entre las épocas 640 y 653, mientras que la figura 7.9 (a) muestra que entre esas iteraciones el costo del discriminador no ha variado significativamente. También, en MRGAN para el caso MFPT (Figura 7.11) los indicadores mejoran mientras avanzan las épocas. Comparando nuevamente con el costo del discriminador (Figura 7.9 (c)) se aprecia como este se encuentra variando durante todo el proceso lo que permite asociar el aprendizaje con el costo del discriminador, pudiéndose estudiar un criterio de detención del entrenamiento en base a este costo. En el caso CWRU no se tienen buenos puntos de entrenamiento guardados como para apoyar esta evidencia.

El hecho de que la función de costos del discriminador tenga relación con su aprendizaje tiene sentido, ya que un costo alto está asociado a que las imágenes del generador logran engañar al

discriminador por lo cual los gradientes del primero deben enfocarse en minimizar el costo de las imágenes generadas y maximizar el de las reales, teniendo que aprender a diferenciarlas.

MRGAN presenta un comportamiento de esta función un poco más suave (en términos de decaimiento), al igual que InfoGAN. Mientras en DCGAN se tiene picos de aprendizaje asociados al aumento en el costo del discriminador. De todas maneras entre InfoGAN y MRGAN, esta última parece tener un comportamiento más estable en la caída del costo, mientras InfoGAN parece menos tratable como criterio de convergencia, aunque en algunas iteraciones parece alcanzar un equilibrio de Nash (parte plana de las curvas presentadas en las Figuras 7.9 y 7.10 (b)).

Un último aspecto a destacar de MRGAN e InfoGAN es la calidad de las imágenes generadas (véase las Figuras 7.2 y 7.5) que resultan más realistas que las otras dos arquitecturas GAN estudiadas.

En resumen se tiene un aprendizaje más dinámico en redes con retroalimentación (parte de la información del discriminador es entregada al generador como en InfoGAN y MRGAN) que redes lazo abierto (DCGAN y Wasserstein GAN). Además, el costo del discriminador parece tener una mayor relación con el proceso de aprendizaje que la calidad de la imagen, según los indicadores presentados (ver Figura 7.2 junto a Tabla 7.1 y Figura 7.5 junto a tabla), esto es que la revisión de la función de costos puede dar un mejor indicio de la calidad de la clasificación que observar la calidad de las imágenes en ese punto del entrenamiento.

Por lo anterior, se recomienda las arquitecturas MRGAN e InfoGAN como parte de la configuración que tendría un mejor desempeño.

### **8.1.3. Algoritmo de Clustering**

La pregunta de por qué InfoGAN tiene los mejores resultados para el caso CWRU y no para MFPT radica en que en el último caso la partición real no posee la forma correcta para hacer una buena clasificación con los algoritmos de clustering usados, la Figura 8.1 muestra los PCAs de este caso para ser comparados las Figuras 7.3, 7.4 y 7.13. Por otro lado, K-means resulta más estable al comparar los indicadores de entrenamiento y validación (la Tabla 7.2 ejemplifica esto), probablemente por dificultades en la construcción del grafo para poder aplicar el algoritmo de spectral clustering en el espacio de trabajo. Este mismo análisis puede ser aplicado para las arquitecturas DCGAN y MRGAN, para lo cual se debe realizar un análisis similar con las tablas presentadas en anexos.

Otro aspecto a destacar es los que se observa desde las Figuras 7.6 y 7.7, en ambos casos el algoritmo de spectral clustering presenta buenos indicadores de estudio (según la Tabla 7.2), sin embargo las zonas de igual partición no coinciden entre los datos de entrenamiento y los de validación, creándose artefactos si es que solo se hubiese estudiado el comportamiento de los indicadores, las razones más probables son las expuestas en el párrafo anterior.

En resumen, se tienen resultados más estables usando K-means que spectral clustering. Pero también, la forma de los clústeres obtenida después que los datos ingresan a la GAN resulta importante en el resultado final ya que los algoritmos deben ser capaces de recuperar estas clasificaciones más allá que la GAN logre separar las características, al ser aprendizaje no supervisado.

Finalmente, de la discusión sobre cada componente del procedimiento se establece que las configuraciones que obtienen mejores desempeños para identificar fallas son las que usan escalogramas como datos de entradas. La GAN corresponde a una arquitectura MRGAN o InfoGAN y se usa el algoritmo de K-means en la penúltima capa del discriminador para su clasificación.

A continuación se discute el detalle de los resultados obtenidos para cada set de datos desde la perspectiva fenomenológica de las fallas en estudio.

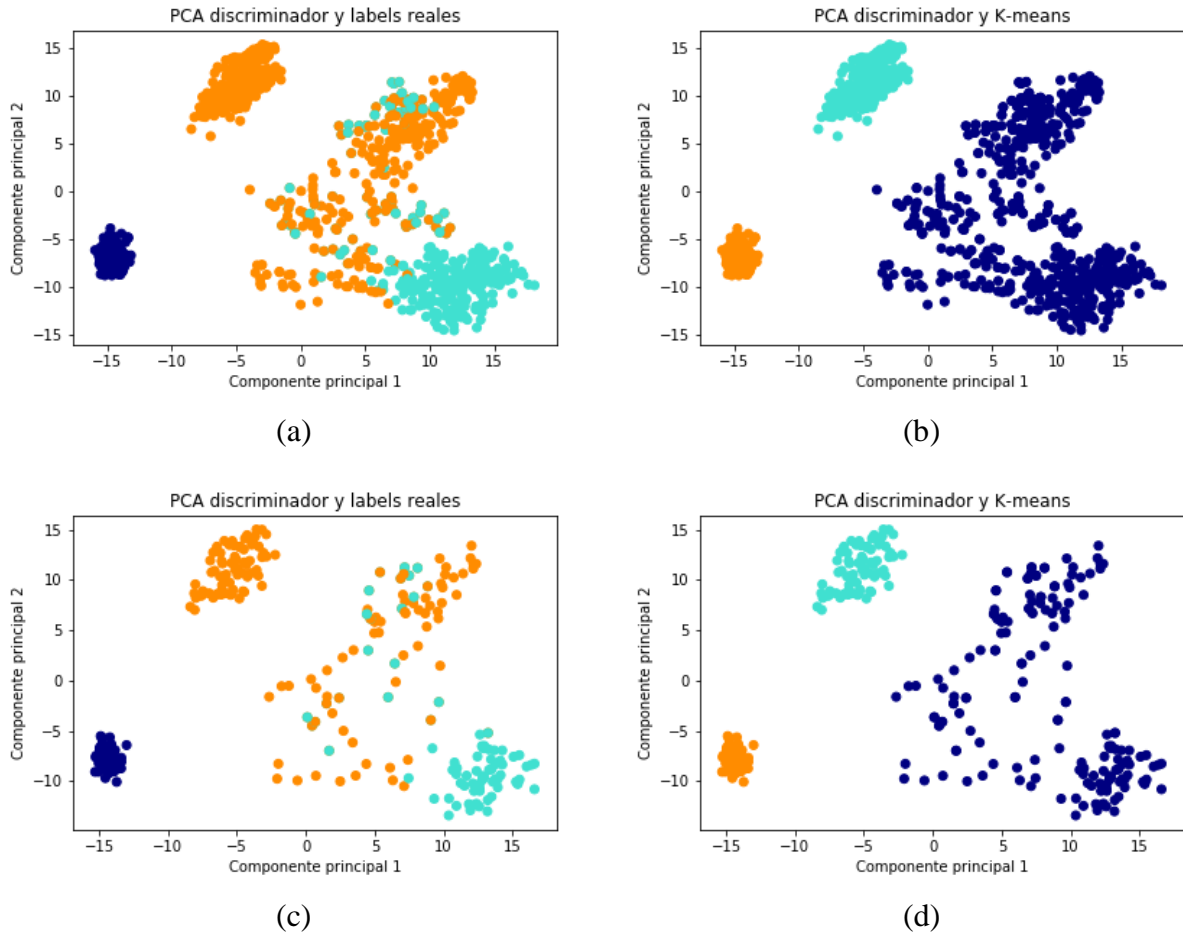


Figura 8.1: PCA para los puntos a la salida del discriminador en InfoGAN para el caso MFPT (wavelets) (en (a) y (c), azul: línea base, turquesa: falla en pista interior y naranja: falla en pista exterior. En (b) y (d) los colores solo diferencian los clústeres). (a) Clasificación real (entrenamiento), (b) clasificación K-means (entrenamiento), (c) clasificación real (validación) y (d) clasificación k-means (validación).



## 8.2.MFPT

Respeto a los resultados particulares para este set de datos en esta parte se discuten los resultados presentados por las Tablas 7.5, 7.6, 7.10 y 7.11, todos los casos consideran una arquitectura MRGAN DIS/KM con escalogramas (transformada de wavelet), al ser la que posee sistemáticamente un mejor desempeño.

Respeto a las dos primeras pruebas que usan señales puras en su resultado se tiene un grupo de fallas en pista interior que se clasifica erróneamente como fallo en pista exterior. Realizando un análisis de trazabilidad para estos datos se determina que corresponden a vibraciones de baja carga (100 y 200 lb). Una causa probable de este error es que los síntomas de falla interior no presentan grandes bandas laterales (para el tamaño de muestra considerado), por lo cual podrán ser considerados como una falla en pista exterior. La Figura 8.2 compara las muestras usadas para MFPT, en particular clasificadas erróneamente con las de falla en pista exterior.




Figura 8.2: Ejemplos de muestras erróneamente clasificadas en MFPT (mejor resultado), (a) fallo en pista interior con carga de 100 lb (erróneo), (b) fallo en pista interior con carga de 200 lb (erróneo) y (c) fallos en pista exterior (correcto).

Otra causa probable es una mala clasificación, ambas pueden ser corroboradas mediante un análisis de envolvente a las muestras mal clasificadas teniéndose figuras similares a las mostradas en la Figura 6.2.

Por lo anterior se ha realizado el análisis de envolvente para muestras de estos dos grupos de falla, teniéndose los resultados que se presentan en la Figura 8.3.







Figura 8.3: (a) y (b) análisis de envolvente para muestras erróneamente clasificadas, se aprecian claramente síntomas de falla en pista exterior. (c) y (d) muestras reprocesadas de las clasificadas erróneamente, nótese la diferencia con las de la figura 8.2.

La Figura anterior muestra que las señales supuestamente mal clasificadas por el procedimiento en estudio han sido erróneamente catalogadas al momento de preparar tanto los datos de entrenamiento y validación, ya que no presentan coincidencia alguna con las de la Figura 8.2. Por esto se ha vuelto a ejecutar el procedimiento con el set corregido teniéndose los PCAs mostrados en la figura 8.4. Con esta corrección ahora la clasificación es perfecta. Esto es,  $ARI = NMI = 1,0$  y una pureza del 100 % tanto en los sets de entrenamiento como de validación.

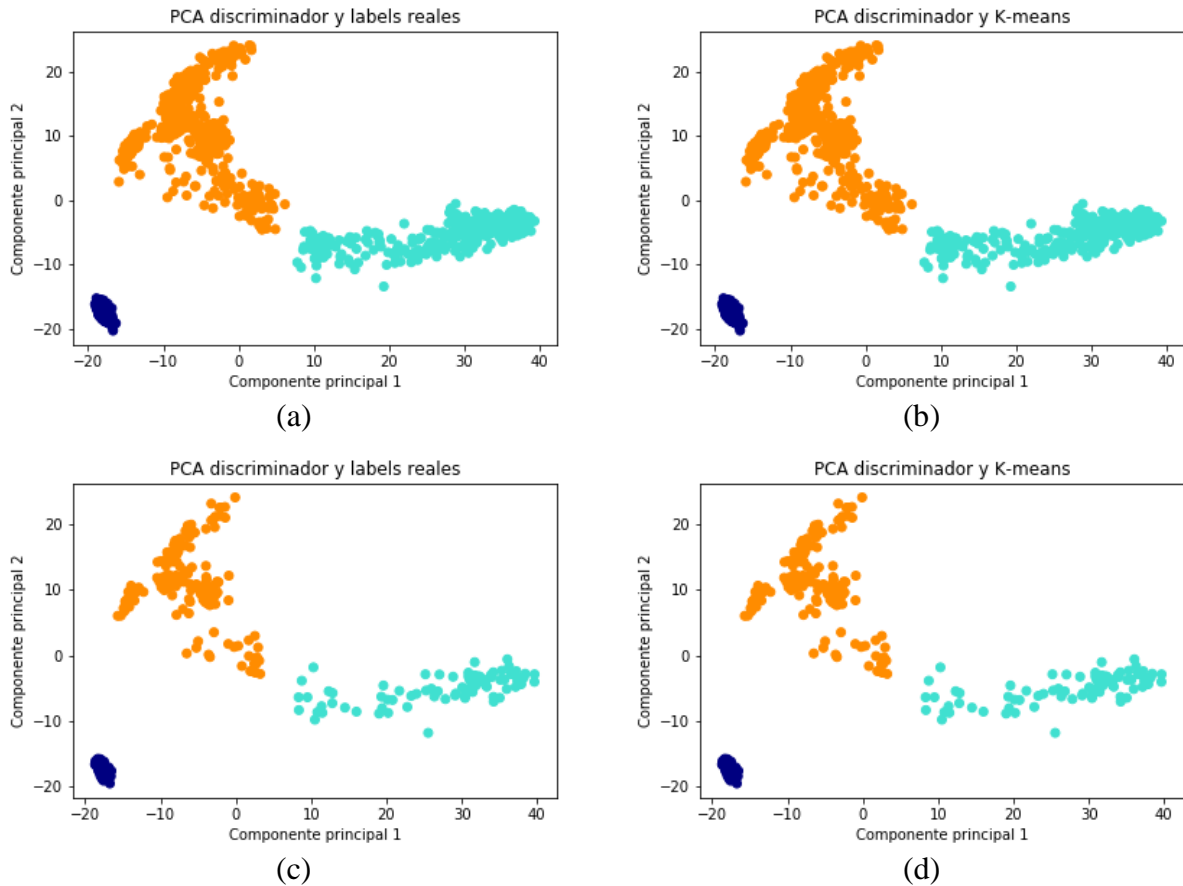


Figura 8.4: PCAs MFPT configuración MRGAN WL DIS/KM. (a) clasificación real (entrenamiento), (b) clasificación K-means (entrenamiento), (c) clasificación real (validación) y (d) clasificación K-means (validación). (En (a) y (c) el color azul: línea base, turquesa: falla en pista interior y naranja: falla en pista exterior. En (b) y (d) solo identifican los diferentes clústeres).

Por otro lado, para el uso de la envolvente de la señal, los indicadores muestran un menor desempeño. A los datos mal clasificados anteriormente se agregan los correspondientes a fallas en la pista exterior con una carga de 270 lb que son consideradas como línea base. La principal causa puede ser que el tamaño del defecto es muy pequeño y los síntomas del defecto no son visibles para una muestra del tamaño usado por lo cual la envolvente no logra mostrar con claridad que este existe. Además, estas señales son adquiridas bajo iguales condiciones que las de la línea base.

La Figura 8.5 presenta el espectro de estas muestras. Se aprecia como en (a) que considera toda la señal es claramente visible la frecuencia de falla en pista exterior y su primer armónico. Sin embargo, en (b) que solo considera una de las muestras, apenas es distinguible esta frecuencia. Si se realiza un espectrograma, la potencia en estas frecuencias disminuye aún más al tener una ventana de tiempo más pequeña. Esto prueba que la causa expuesta en el párrafo anterior es altamente factible.

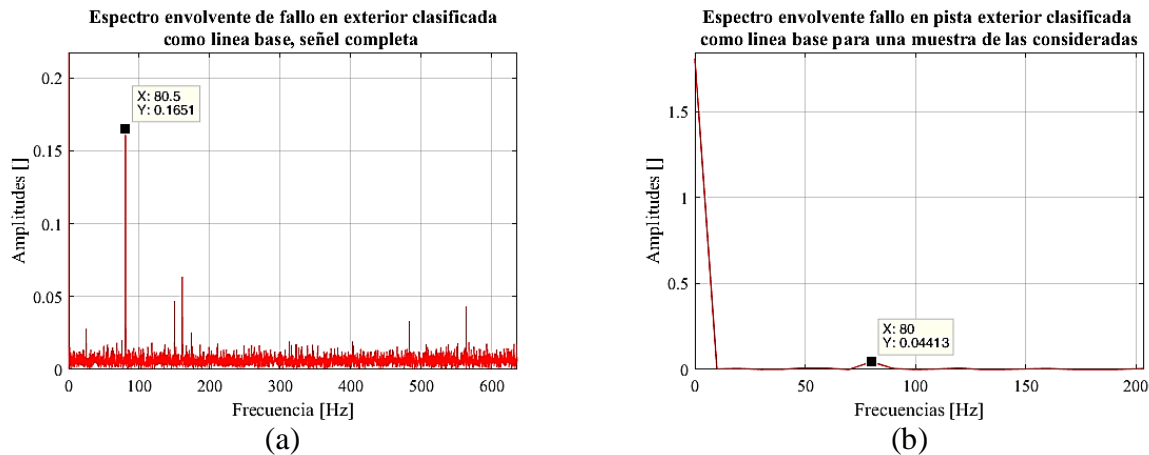


Figura 8.5: Espectro para la envolvente de las señales en pista exterior clasificadas erróneamente como línea base (a) señal completa, (b) una muestra.

En resumen, la configuración que usa escalogramas de la señal bruta, pura o sin procesar, la arquitectura MRGAN y el algoritmo K-means aplicado al final de la penúltima capa del discriminador logran separar completamente las fallas presentes en el set. Es más, se ha descubierto errores en la clasificación real de los datos en el proceso de la generación de imágenes.

### 8.3. CWRU.

En la sección 7.2.1.2 se ha descrito la composición de cada clúster logrado con la mejor configuración en esa prueba. Por otro lado en 7.3.2 se resumen los hallazgos hechos en [21] que mediante los mismos datos y usando el análisis de envolvente con diferentes configuraciones, presenta algunas consideraciones a tener, como datos no clasificables por estos métodos por presencia de ruidos externos y debido a la banda de frecuencias en estudio.

Para este caso se comparan los resultados presentados en ambas secciones a fin de establecer semejanzas entre ambos hallazgos.

Comparando con los resultados de [21] se tienen elementos en común, en primera instancia no se logran clasificar los fallos en elementos rodantes salvo el de diámetro de 0,028". También, se experimentan problemas con las muestras de fallo en pista interior con diámetro de 0,014". La principal causa de esto puede ser la interferencia electro-magnética (EMI) propuesta por [21]. En nuestro caso son separadas en un solo clúster.

Respecto a al resto de las fallas en pista exterior, el procedimiento logra clasificar en un clúster las muestras ortogonales, que según [21] son diagnosticables. El resto de las fallas son mezcladas en un grupo de clústeres (0, 2y 6) probablemente identificando las pérdidas mecánicas que determina [21] por sobre los síntomas de falla.

En resumen los resultados de la clasificación muestran concordancia con las técnicas de diagnóstico de fallas no automatizadas como los resultados presentados en [21]. Teniéndose que el procedimiento en la configuración InfoGAN WL DIS/KM separa las fallas sintomáticamente, aunque es susceptible a factores externos en su resultado. Es decir, el proceso de aprendizaje no

supervisado puede aprender características distintas a síntomas de falla de estar presentes en mayor medida en los datos a estudiar.

#### **8.4.FEMTO-ST**

Este caso es expuesto aquí como una proyección para determinar tanto las dificultades, como las ventajas que posee el procedimiento desarrollado en este documento. Por lo cual, el análisis de los resultados expuestos es de carácter cualitativo.

Para este set se han probado las tres arquitecturas más prometedoras y ambos algoritmos de clustering estudiados. Tanto para kurtogramas rápidos como escalogramas. Se tiene una clasificación concordante con el tiempo en la arquitectura MRGAN WL DIS/KM en nuestra nomenclatura. La cual se expone en este documento en la Figura 7.21 y las Tablas 7.12 y 7.13 que resumen las figuras en los anexos (sección 11.3).

De estos resultados se determina en primera instancia que es posible determinar un estado base (clúster 0) de donde comienza todo rodamiento antes de degradarse. El resto de las particiones resulta más compleja de analizar, principalmente porque no existen antecedentes del modo de falla presente en cada rodamiento. Es más, mediante la inspección de las muestras es posible identificar evidencia de fallas. Sin embargo, pueden ser desde múltiples fallas de uno o más tipos en una misma muestra por lo cual entender la clasificación de fallas que se tiene cuando las muestras del rodamiento transitan del clúster 0 es complejo.

La Figura 8.6 presenta algunas comparaciones cualitativas entre las muestras de MFPT y algunas del set FEMTO-ST. Además muestra imágenes de rodamiento probados para este set de datos.




Figura 8.6: Comparación de muestras entre MFPT y FEMTO-ST: (a) falla en pista interior MFPT (izquierda), a la derecha (FEMTO-ST) parece haber 2 fallas de pista interior, (b) falla en pista exterior MFPT (izquierda) y lo que parece ser una falla en pista exterior en FEMTO-ST y (c) muestras FEMTO-ST a la izquierda parece haber una falla en pista exterior, mientras que unas muestras después parece haber 2 fallas en la pista interior. (d) rodamientos probados (tomado de [15])

La Figura 8.6 (d) permite observar la presencia de múltiples fallas en la pista interior de uno de los rodamiento probados, como se intuye de los escalogramas presentados en la Figura 8.6 (a).

Lo que se establece de este análisis es que si bien el procedimiento propuesto es capaz de separar fallas en rodamientos tanto del caso sin fallas como entre sí. Desde el punto de vista aplicado se presentan complejidades relacionadas con la presencia de múltiples modos de falla, así como en CWRU donde las señales pueden tener interferencias por elementos ajenos como pérdidas mecánicas, ruido electromagnético u otros por lo cual se requieren elementos adicionales como pre-filtrado de señales.

Además, para sistemas monitoreados el tiempo (secuencia de mediciones) el procedimiento propuesto puede otorgar información valiosa por lo cual se propone como extensión del trabajo considerar herramientas de regresión para realizar pronóstico o bien considerar arquitectura de redes neuronales recurrentes como parte de la arquitectura GAN, como se presenta en [22].

En resumen, el procedimiento propuesto logra la identificación de fallas en el set FEMTO-ST. Sin embargo, su análisis cuantitativo no resulta posible debido a la falta de conocimiento sobre los modos de falla presentes en cada rodamiento, pudiéndose tener múltiples modos de falla como presenta la evidencia expuesta. Se proponen algunas consideraciones y mejoras al modelo a fin de tener un mejor desempeño para este caso.

## 9. Conclusiones.

Esta tesis ha investigado la factibilidad de disponer de un procedimiento de identificación autónomo de fallas basado en Redes Adversarias Generativas (GANs) y algoritmos de agrupamiento.

Para esto se han estudiado los elementos fenomenológicos describen las fallas en rodamiento tanto desde el diagnóstico hasta su deterioro en el tiempo. También se han revisado cuatro tipos de GANs: DCGAN, InfoGAN, MRGAN y Wasserstein GAN, junto con dos algoritmos de clustering: K-means y spectral clustering.

El procedimiento propuesto ha consistido en entrenar cada una de las GANs revisadas mediante imágenes de escalogramas y espectrogramas de señales de vibración mecánica. Luego, se clasifican alguna de las salidas de estas redes para lograr la clasificación que permita diagnosticar el grupo de cada partición.

Para verificar la funcionalidad de este procedimiento se han usado dos sets de datos: MFPT y CWRU. En estos han probado todas las configuraciones posibles con los elementos revisados, teniéndose una partición asociada a cada salida. Para evaluar el desempeño a priori de las configuraciones se han usado tres indicadores: ARI, NMI y la pureza de los clústeres.

En referencia a los objetivos específicos se establecen las siguientes consideraciones generales:

En todas las pruebas el alimentar la Red Adversaria Generativa en línea con los algoritmos de clustering entrega mejores resultados usando escalogramas contra los espectrogramas. Las principales desventajas de estos últimos son el que hacen uso de ventanas de tiempo. Esto tiene dos efectos: primero el usar una cantidad de datos en un tiempo más corto reduce la potencia en el espectrograma de las frecuencias de interés. Por otro lado, la reducción en los puntos utilizados para calcular la transformada discreta de Fourier reduce la resolución de las frecuencias distorsionando los efectos que producen las fallas en los espectros (en particular los armónicos). Esto no ocurre en el caso de los escalogramas que consideran todos los puntos de las muestras para sus cálculos en frecuencia.

Respecto a todas las salidas de las GAN utilizadas, la que presenta sistemáticamente los mejores resultados son las de la penúltima capa del discriminador, siendo ahí donde los resultados presentan mejores indicadores.

Al considerar los algoritmos de clustering utilizados, K-means presenta mejores resultados respecto a los indicadores estudiados así como la regularidad entre estos al ser calculados tanto para los datos de entrenamiento como los de validación. La principal dificultad del algoritmo de spectral clustering es el grafo que requiere formar para su ejecución, teniendo grandes variaciones entre los sets de datos. Además el solo uso de indicadores para evaluar la calidad de los resultados resulta insuficiente para una correcta conclusión, ya que en los casos donde las disposiciones con spectral clustering tienen buen desempeño en base al ARI, NMI o pureza las particiones entre los datos de validación y entrenamiento no coinciden.

Dentro de las arquitecturas GAN probadas: MRGAN, InfoGAN y DCGAN presentan buenos indicadores bajo las consideraciones anteriormente señaladas. Siendo las dos primeras las con

mejores resultados respecto a indicadores. También son las que generan las mejores imágenes. En las pruebas desarrolladas con más detalle se determina que estas alcanzan mejores indicadores.

Para el set de datos MFPT la mejor configuración ha sido escalogramas, MRGAN, y K-means sobre la penúltima capa del discriminador. En primera instancia se ha obtenido una pureza inicial de un 88,46% en los datos de validación, en una prueba posterior el valor ha alcanzado el 92,31% bajo los mismos criterios. Con esta, se ha desglosado el resultado descubierto que originalmente los datos que la red clasifica erróneamente, en realidad están mal etiquetados. Corregido esto, el último resultado obtenido muestra coincidencia perfecta la clasificación con las fallas presentes en este set.

También, se ha realizado el procedimiento usando como entrada los escalogramas de las envolventes de las señales de vibración, teniéndose un desempeño peor que los casos anteriores (pureza en validación de un 70,83 %). Se detalla en las discusiones, que esto es producto de la pérdida de energía en las frecuencias de interés al ejecutar el procesamiento de las señales.

Para el caso CWRU, la mejor configuración según los indicadores es la que considera escalogramas, InfoGAN y K-means en la penúltima capa del discriminador, con un 78,73% de pureza en datos de validación, se considera esta configuración por sobre las que usan spectral clustering dada la variación importante que existe entre los indicadores para los datos de entrenamiento y los de validación. Del desglose de estos resultados por clúster, se establece que existen relaciones con lo que se presenta en [21]. En particular, la agrupación de datos no identificables mediante análisis de envolvente en un mismo clúster, y la clasificación priorizando pérdidas mecánicas por sobre la severidad de la falla. También, existe concordancia entre las particiones más puras y las que son identificables mediante el estudio de la envolvente.

Además, se ha estudiado la función de costo del discriminador en las redes más exitosas encontrándose una relación entre la calidad de la clasificación y la variación de esta función. Específicamente, DCGAN posee picos claramente identificables que determinan si la red ha aprendido, mientras que en MRGAN estos picos presentan un decaimiento más lento. En ambos casos, se ha visto una mejora en los indicadores relacionada con la variación de esta función considerando un número importante de iteraciones. InfoGAN presenta un comportamiento del costo más extraño pero parece alcanzar un equilibrio de Nash en algunas de sus iteraciones. Se establece que la función de costos del discriminador es un mejor indicador que la calidad de las imágenes como se ha mostrado al contrastar las imágenes generadas con los resultados, en particular para la DCGAN. Sin embargo, para las arquitecturas MRGAN e InfoGAN la calidad de imágenes generada suele ser buena respecto a las otras dos.

En resumen, el uso de la técnica de análisis tiempo-frecuencia de transformada de wavelet para señales de vibración, el uso de una disposición MRGAN o InfoGAN, junto a un algoritmo k-means en la penúltima capa del discriminador de la GAN, logra clasificar fallas (MFPT) e identificarlas (CWR) siempre cuando los síntomas de las fallas sean observables en los datos y no exista otro tipo de síntomas presentes en los datos, ya que el aprendizaje no supervisado puede considerarlos en el proceso.

En la última parte se estudia el caso de degradación continua de un rodamiento usando el set FEMTO-ST. Bajo la misma configuración que el caso MFPT (ya que los escalogramas generados tiene ciertas semejanzas.). Se establece de modo cualitativo que los escalogramas son capaces de realizar agrupamientos con relación temporal. Es así como los rodamientos nuevos caen en una



misma clase la cual cambia al irse degradando. Sin embargo, mediante la exploración de las imágenes usadas, se determina la posible presencia de múltiples modos de falla que parecen ser representados por las clasificaciones obtenidas, y que fotografías de los cojinetes ensayados muestran. En resumen, el procedimiento da indicios de ser útil para el caso de sistemas monitoreados desde el punto de vista de la extracción de características de los datos. Sin embargo se requiere una investigación más detallada tanto de los datos usados como del procedimiento.

Como trabajos futuros se propone el uso de otra información más allá de las vibraciones como la secuencia de muestras. También se hace interesante considerar la obtención de señales de vibración en bandas de frecuencia más altas usando sensores de vibración de mayor frecuencia de muestreo o bien emisión acústica. También se puede considerar un procesos de filtrado de señales [3] u otras técnicas que requieren muestras de mayor duración como el análisis cepstral, los mismos escalogramas o espectrogramas que ha prestado dificultades en su desarrollo principalmente debido a la disponibilidad de datos para este estudio, dado que se requieren datos masivos.

Finalmente y en base a lo anterior se ha dado cumplimiento al objetivos principal del trabajo, se han seleccionado las configuraciones de mejores resultados, presentando nuevas evidencias y se propuesto futuras expansiones de este trabajo para mejorar el procedimiento aquí estudiado.

## 10. Bibliografía.

- [1] Vittal Premachandran, Alan Yuille. *Unsupervised Learning Using Generative Adversarial Training and Clustering*. 2016.
- [2] "Sinais ingenieria", *Sinais.es*, 2017. [Online]. Available: <http://www.sinais.es/Recursos/Curso-vibraciones/rodamientos/rodamientos.html>. [Accessed: 13- Oct- 2017].
- [3] R. Randall, *Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace*. John Wiley & Sons, 2011.
- [4] Paris, P.C. and Ergodon, F. (1963) A pitting model for rolling contact fatigue. *ASME Transactions, Journal of Basic Engineering*, 85, 528-534
- [5] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, et al. Generative adversarial nets. In NIPS, 2014.
- [6] Goodfellow, I. (2016). NIPS 2016 Tutorial: Generative Adversarial Networks. *arXiv preprint arXiv:1701.00160*.
- [7] Alec Radford, Luke Metz, and Soumith Chintala. *Unsupervised representation learning with deep convolutional generative adversarial networks*. arXiv:1511.06434, 2015.
- [8] Xi Chen, Yan Duan, Rein Houthoofd, John Schulman, Ilya Sutskever. *InfoGAN: Interpretable Representation Learning by Information Maximizing*. arXiv:1606.03657, 2016
- [9] Tong Che, Li Yanran, Athul Paul Jacob, Yoshua Bengio Wenjie Li. *Mode Regularized Generative Adversarial Networks*. arXiv:1612.02136, 2016
- [10] Martin Arjovsky, Soumith Chintala, Léon Bottou. *Wasserstein GAN*. arXiv:1701.07875, 2017
- [11] "Clustering", *Scikit-learn.org*, 2017. [Online]. Available: <http://scikit-learn.org/stable/modules/clustering.html>. [Accessed: 13- Oct- 2017].
- [12] "MFPT Society - Prognostics, PHM, Failure Prevention, Condition Monitoring", *Mfpt.org*, 2017. [Online]. Available: <http://www.mfpt.org/faultdata/faultdata.htm>. [Accessed: 07- Dec- 2017].
- [13] "Case Western Reserve University Bearing Data Center Website | Bearing Data Center", *Csegroups.case.edu*, 2017. [Online]. Available: <http://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-university-bearing-data-center-website>. [Accessed: 07- Dec- 2017].
- [14] "IEEE PHM 2012 Data Challenge", *Femto-st.fr*, 2017. [Online]. Available: <http://www.femto-st.fr/en/Research-departments/AS2M/Research-groups/PHM/IEEE-PHM-2012-Data-challenge.php>. [Accessed: 07- Dec- 2017].

- [15] "IEEE PHM 2012 Prognostic challenge Outline, Experiment, Scoring of results, Winners", *Femto-st.fr*, 2017. [Online]. Available: <http://www.femto-st.fr/f/d/IEEEPHM2012-Challenge-Details.pdf>. [Accessed: 07- Dec- 2017].
- [16] Jérôme Antoni. *The spectral kurtosis: a useful tool for characterising non-stationary signals*. Mechanical Systems and Signal Processing, 2006, vol. 20, no 2, p. 282-307.
- [17] Jérôme Antoni. *Fast computation of the kurtogram for the detection of transient faults*. Mechanical Systems and Signal Processing, 2007, vol. 21, no 1, p. 108-124.
- [18] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. 2016. MIT Press.
- [19] "Evaluation of clustering", *Nlp.stanford.edu*, 2017. [Online]. Available: <https://nlp.stanford.edu/IR-book/html/htmledition/evaluation-of-clustering-1.html>. [Accessed: 06- Dec- 2017].
- [20] Bechhoefer, E. (2016). A quick introduction to bearing envelope analysis. Available: <http://www.mfpt.org/faultdata/MFPT%20Bearing%20Envelope%20Analysis.pdf>. [Accessed: 06- Dec- 2017].
- [21] Smith, W. and Randall, R. (2015). Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study. *Mechanical Systems and Signal Processing*, 64-65, pp.100-131.
- [22] Mogren, O. (2016). *C-RNN-GAN: Continuous recurrent neural networks with adversarial training*. arXiv: 1611.09904

## 11. Anexos.

### 11.1. Tablas de resultados diversas arquitecturas.

#### 11.1.1. MFPT.

Tabla 11.1 AMI base MFPT usando wavelets y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4245	0,4245	0,4245	0,4245
<i>DIS / KM</i>	0,683	0,072	0,683	0,2215
<i>Q o ENC / KM</i>	-	0,2195	0,2237	-
<i>IMG / SC</i>	0,4326	0,4326	0,4326	0,4326
<i>DIS / SC</i>	0,4976	0,3122	0,4976	0,3249
<i>Q o ENC / SC</i>	-	0,1812	0,2382	-

Tabla 11.2 NMI base MFPT usando wavelets y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4727	0,4727	0,4727	0,4727
<i>DIS / KM</i>	0,6972	0,3047	0,6972	0,3007
<i>Q o ENC / KM</i>	-	0,3115	0,2964	-
<i>IMG / SC</i>	0,6499	0,6499	0,6499	0,6499
<i>DIS / SC</i>	0,5283	0,4699	0,5283	0,4818
<i>Q o ENC / SC</i>	-	0,3056	0,2978	-

Tabla 11.3 Pureza base MFPT usando wavelets y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	77,36%	77,36%	77,36%	77,36%
<i>DIS / KM</i>	88,52%	60,26%	88,52%	65,88%
<i>Q o ENC / KM</i>	-	64,90%	67,75%	-
<i>IMG / SC</i>	73,21%	73,21%	73,21%	73,21%
<i>DIS / SC</i>	80,78%	60,77%	80,78%	66,53%
<i>Q o ENC / SC</i>	-	64,82%	67,43%	-

Tabla 11.4 AMI base MFPT usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4238	0,4238	0,4238	0,4238
<i>DIS / KM</i>	0,6802	0,0769	0,6802	0,2297
<i>Q o ENC / KM</i>	-	0,3142	0,2843	-
<i>IMG / SC</i>	0,4294	0,4294	0,4294	0,4294
<i>DIS / SC</i>	0,423	-0,0595	-0,0595	0,2917
<i>Q o ENC / SC</i>	-	-0,0025	0,2016	-

Tabla 11.5 NMI base MFPT usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4663	0,4663	0,4663	0,4663
<i>DIS / KM</i>	0,6967	0,3056	0,6967	0,3135
<i>Q o ENC / KM</i>	-	0,3142	0,2843	-
<i>IMG / SC</i>	0,6493	0,6493	0,6493	0,6493
<i>DIS / SC</i>	0,6355	0,1618	0,1645	0,4322
<i>Q o ENC / SC</i>	-	0,1267	0,2837	-

Tabla 11.6 Pureza base MFPT usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	77,56%	77,56%	77,56%	77,56%
<i>DIS / KM</i>	88,46%	60,90%	88,46%	66,35
<i>Q o ENC / KM</i>	-	65,06%	67,63%	-
<i>IMG / SC</i>	73,08%	73,08%	73,08%	73,08%
<i>DIS / SC</i>	73,08%	46,43%	50,00%	64,42
<i>Q o ENC / SC</i>		53,53%	67,63%	-

Tabla 11.7 AMI base MFPT usando SFFT y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,3904	0,406	0,3904	0,398
<i>DIS / KM</i>	0,5269	0,1503	0,5736	0,223
<i>Q o ENC / KM</i>	-	0,0058	0,1519	-
<i>IMG / SC</i>	-0,0249	-0,0249	-0,0249	-0,0249
<i>DIS / SC</i>	0,4253	0,094	0,4253	0,4816
<i>Q o ENC / SC</i>	-	0,036	0,3377	-

Tabla 11.8 NMI base MFPT usando SFFT y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4609	0,4644	0,4609	0,4641
<i>DIS / KM</i>	0,5975	0,2231	0,6193	0,2895
<i>Q o ENC / KM</i>	-	0,1538	0,2493	-
<i>IMG / SC</i>	0,123	0,123	0,132	0,123
<i>DIS / SC</i>	0,6306	0,2057	0,6306	0,5179
<i>Q o ENC / SC</i>	-	0,176	0,3865	-

Tabla 11.9 Pureza base MFPT usando SFFT y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	74,43%	75,73%	74,43%	75,00%
<i>DIS / KM</i>	80,86%	59,93%	83,39%	65,31%
<i>Q o ENC / KM</i>	-	50,00%	61,97%	-
<i>IMG / SC</i>	51,55%	51,55%	51,55%	51,55%
<i>DIS / SC</i>	73,13%	54,87%	73,13%	79,80%
<i>Q o ENC / SC</i>	-	51,30%	68,73%	-

Tabla 11.10 AMI base MFPT usando SFFT y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4094	0,4225	0,4094	0,4126
<i>DIS / KM</i>	0,5040	0,1545	0,5831	0,2116
<i>Q o ENC / KM</i>	-	0,0007	0,1671	-
<i>IMG / SC</i>	0,0773	0,0773	0,0773	0,0773
<i>DIS / SC</i>	0,4174	0,2333	0,4174	0,3707
<i>Q o ENC / SC</i>	-	0,4174	0,3706	-

Tabla 11.11 NMI base MFPT usando SFFT y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4737	0,4783	0,4738	0,4733
<i>DIS / KM</i>	0,5833	0,2276	0,6302	0,2802
<i>Q o ENC / KM</i>	-	0,1584	0,2636	-
<i>IMG / SC</i>	0,1823	0,1823	0,1823	0,1823
<i>DIS / SC</i>	0,6172	0,2745	0,6171	0,4535
<i>Q o ENC / SC</i>	-	0,1774	0,2768	-

Tabla 11.12 Pureza base MFPT usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	75,96%	76,92%	75,96%	76,28%
<i>DIS / KM</i>	79,49%	60,26%	83,97%	64,74%
<i>Q o ENC / KM</i>	-	50,00%	62,18%	-
<i>IMG / SC</i>	57,37%	57,37%	57,37%	57,37%
<i>DIS / SC</i>	72,76%	66,33%	72,76	73,72%
<i>Q o ENC / SC</i>	-	50,00%	59,29%	-

### 11.1.2. CWRU.

Tabla 11.13 AMI base CWRU usando wavelets y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MRGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4653	0,4942	0,4704	0,4519
<i>DIS / KM</i>	0,5511	0,5340	0,6508	0,3963
<i>Q o ENC / KM</i>	-	0,5640	0,2942	-
<i>IMG / SC</i>	0,3944	0,3316	0,332	0,332
<i>DIS / SC</i>	0,5783	0,6365	0,5222	0,521
<i>Q o ENC / SC</i>	-	0,5709	0,5106	-

Tabla 11.14 NMI base CWRU usando wavelets y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MRGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,7167	0,7449	0,7209	0,7076
<i>DIS / KM</i>	0,7	0,7163	0,7395	0,6267
<i>Q o ENC / KM</i>	-	0,5873	0,5419	-
<i>IMG / SC</i>	0,7346	0,7132	0,7163	0,7163
<i>DIS / SC</i>	0,7977	0,8392	0,7781	0,7885
<i>Q o ENC / SC</i>	-	0,7459	0,5995	-

Tabla 11.15 Pureza base CWRU usando wavelets y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MRGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	68,60%	69,50%	66,52%	58,57%
<i>DIS / KM</i>	68,83%	68,94%	73,30%	62,49%
<i>Q o ENC / KM</i>	-	62,58%	55,35%	-
<i>IMG / SC</i>	68,22%	68,06%	68,18%	68,18%
<i>DIS / SC</i>	76,03%	81,15%	67,58%	73,61%
<i>Q o ENC / SC</i>	-	71,89%	65,12%	-



Tabla 11.16 AMI base CWRU usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,4687	0,4857	0,4653	0,3439
<i>DIS / KM</i>	0,5501	0,5335	0,6466	0,3487
<i>Q o ENC / KM</i>	-	0,5596	0,2936	-
<i>IMG / SC</i>	0,5618	0,5618	0,5618	0,3499
<i>DIS / SC</i>	0,5851	0,4961	0,4544	0,2663
<i>Q o ENC / SC</i>	-	0,6014	0,4868	-

Tabla 11.17 NMI base CWRU usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,7202	0,7407	0,7186	0,4739
<i>DIS / KM</i>	0,7019	0,7189	0,7359	0,5027
<i>Q o ENC / KM</i>	-	0,5851	0,5418	-
<i>IMG / SC</i>	0,7929	0,7929	0,7929	0,5855
<i>DIS / SC</i>	0,8208	0,795	0,7461	0,5445
<i>Q o ENC / SC</i>	-	0,7286	0,5887	-

Tabla 11.18 Pureza base CWRU usando wavelets y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	68,69%	69,44%	66,22%	68,83%
<i>DIS / KM</i>	68,77%	68,90%	73,18%	70,20%
<i>Q o ENC / KM</i>	-	62,03%	55,56%	-
<i>IMG / SC</i>	74,25%	72,00%	74,25%	72,56%
<i>DIS / SC</i>	79,47%	79,27%	64,42%	68,80%
<i>Q o ENC / SC</i>	-	75,21%	61,48%	-

Tabla 11.19 AMI base CWRU usando SFFT y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,3768	0,3839	0,3837	0,3918
<i>DIS / KM</i>	0,3398	0,2415	0,4136	0,4021
<i>Q o ENC / KM</i>	-	0,2225	0,2271	-
<i>IMG / SC</i>	0,3081	0,3080	0,3081	0,3081
<i>DIS / SC</i>	0,4105	0,2759	0,4590	0,2745
<i>Q o ENC / SC</i>	-	0,2231	0,2372	-

Tabla 11.20 NMI base CWRU usando SFFT y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,5612	0,5551	0,5708	0,5754
<i>DIS / KM</i>	0,5177	0,3844	0,4583	0,5018
<i>Q o ENC / KM</i>	-	0,3054	0,4602	-
<i>IMG / SC</i>	0,5972	0,5971	0,5971	0,5972
<i>DIS / SC</i>	0,748	0,5609	0,6667	0,6656
<i>Q o ENC / SC</i>	-	0,4065	0,5929	-

Tabla 11.21 Pureza base CWRU usando SFFT y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	57,55%	56,84%	59,57%	63,02%
<i>DIS / KM</i>	55,73%	41,47%	47,11%	52,84%
<i>Q o ENC / KM</i>	-	38,58%	49,04%	-
<i>IMG / SC</i>	54,50%	51,27%	51,82%	54,50%
<i>DIS / SC</i>	69,68%	50,83%	62,06%	59,96%
<i>Q o ENC / SC</i>	-	45,78%	55,11%	-

Tabla 11.22 AMI base CWRU usando SFFT y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,3717	0,379	0,379	0,3858
<i>DIS / KM</i>	0,3385	0,2377	0,4079	0,4011
<i>Q o ENC / KM</i>	-	0,2192	0,2249	-
<i>IMG / SC</i>	0,2718	0,2823	0,3093	0,2850
<i>DIS / SC</i>	0,4063	0,2519	0,4221	0,2961
<i>Q o ENC / SC</i>	-	0,2485	0,1988	-

Tabla 11.23 NMI base CWRU usando SFFT y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	0,5631	0,5568	0,5691	0,5793
<i>DIS / KM</i>	0,5181	0,3828	0,4512	0,5078
<i>Q o ENC / KM</i>	-	0,3080	0,4566	-
<i>IMG / SC</i>	0,4997	0,4884	0,5012	0,4915
<i>DIS / SC</i>	0,6838	0,4995	0,5910	0,6254
<i>Q o ENC / SC</i>	-	0,3979	0,5657	-

Tabla 11.24 Pureza base CWRU usando SFFT y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>DCGAN</i>	<i>InfoGAN</i>	<i>MORGAN</i>	<i>WGAN</i>
<i>IMG / KM</i>	57,20%	56,67%	59,01%	32,73%
<i>DIS / KM</i>	55,32%	41,90%	46,56%	53,17%
<i>Q o ENC / KM</i>	-	38,34%	48,15%	-
<i>IMG / SC</i>	54,55%	54,24%	54,39%	53,18%
<i>DIS / SC</i>	66,20%	49,30%	58,80%	60,80%
<i>Q o ENC / SC</i>	-	44,52%	55,61%	-

## 11.2. Tablas de resultados para distintas épocas.

### 11.2.1. MFPT.

Tabla 11.25: ARI base MFPT usando WLR, arquitectura InfoGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 1108</i>	<i>E 1109</i>	<i>E 1134</i>	<i>E 1147</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4245	0,4245	0,4245	0,4245	0,4245
<i>DIS / KM</i>	0,5145	0,5536	0,5619	0,5349	0,4339
<i>Q o ENC / KM</i>	0,1605	0,1427	0,1207	0,1755	0,1052
<i>IMG / SC</i>	0,4326	0,4326	0,4326	0,4326	0,4326
<i>DIS / SC</i>	0,7796	0,2462	0,2462	0,12	-0,0219
<i>Q o ENC / SC</i>	0,2241	0,2071	0,0357	0,0736	0,1261

Tabla 11.26: NMI base MFPT usando WLR, arquitectura InfoGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 1108</i>	<i>E 1109</i>	<i>E 1134</i>	<i>E 1147</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4726	0,4726	0,4726	0,4726	0,4726
<i>DIS / KM</i>	0,6051	0,6217	0,5667	0,5493	0,6506
<i>Q o ENC / KM</i>	0,2056	0,1959	0,1400	0,1808	0,1307
<i>IMG / SC</i>	0,6499	0,6499	0,6499	0,6499	0,6499
<i>DIS / SC</i>	0,8085	0,4184	0,4184	0,2718	0,2314
<i>Q o ENC / SC</i>	0,3288	0,2764	0,0373	0,2258	0,1627

Tabla 11.27: Pureza base MFPT usando WLR, arquitectura InfoGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 1108</i>	<i>E 1109</i>	<i>E 1134</i>	<i>E 1147</i>	<i>E 1303</i>
<i>IMG / KM</i>	77,36%	77,36%	77,36%	77,36%	77,36%
<i>DIS / KM</i>	80,37%	82,57%	83,31%	82,17%	73,21%
<i>Q o ENC / KM</i>	61,56%	59,45%	56,27%	58,31%	53,26%
<i>IMG / SC</i>	73,21%	73,21%	73,21%	73,21%	73,21%
<i>DIS / SC</i>	90,53%	69,14%	69,14%	57,82%	50,00%
<i>Q o ENC / SC</i>	63,68%	62,21%	50,24%	55,05%	57,57%

Tabla 11.28: ARI base MFPT usando WLR, arquitectura InfoGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 1108</i>	<i>E 1109</i>	<i>E 1134</i>	<i>E 1147</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4238	0,4238	0,4238	0,4238	0,4238
<i>DIS / KM</i>	0,5103	0,5529	0,5459	0,5309	0,4294
<i>Q o ENC / KM</i>	0,1827	0,1698	0,0998	0,1767	0,1158
<i>IMG / SC</i>	0,4294	0,4294	0,4294	0,4294	0,4294
<i>DIS / SC</i>	0,2452	0,2452	0,2452	0,2452	-0,0242
<i>Q o ENC / SC</i>	0,1783	0,1835	0,0356	0,2625	0,0239

Tabla 11.28: NMI base MFPT usando WLR, arquitectura InfoGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 1108</i>	<i>E 1109</i>	<i>E 1134</i>	<i>E 1147</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4663	0,4663	0,4663	0,4663	0,4663
<i>DIS / KM</i>	0,5915	0,6227	0,5629	0,5551	0,6494
<i>Q o ENC / KM</i>	0,2245	0,2095	0,1346	0,1881	0,1650
<i>IMG / SC</i>	0,6494	0,6494	0,6494	0,6494	0,6494
<i>DIS / SC</i>	0,4186	0,4186	0,4186	0,4186	0,2310
<i>Q o ENC / SC</i>	0,2892	0,2997	0,0589	0,2303	0,0634

Tabla 11.29: Pureza base MFPT usando WLR, arquitectura InfoGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 1108</i>	<i>E 1109</i>	<i>E 1134</i>	<i>E 1147</i>	<i>E 1303</i>
<i>IMG / KM</i>	77,56%	77,56%	77,56%	77,56%	77,56%
<i>DIS / KM</i>	80,45%	82,69%	82,69%	82,05%	73,08%
<i>Q o ENC / KM</i>	63,46%	59,29%	55,13%	58,65%	51,28%
<i>IMG / SC</i>	73,08%	73,08%	73,08%	73,08%	73,08%
<i>DIS / SC</i>	61,90%	69,23%	69,23%	69,23%	50,00%
<i>Q o ENC / SC</i>	62,82%	60,90%	52,88%	65,38%	54,17%

Tabla 11.30: ARI base MFPT usando WLR, arquitectura MRGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 311</i>	<i>E 313</i>	<i>E 337</i>	<i>E 350</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4245	0,4245	0,4245	0,4245	0,4245
<i>DIS / KM</i>	0,204	0,0954	0,6386	0,6329	0,7774
<i>Q o ENC / KM</i>	0,0507	0,0422	0,0129	0,0037	-0,0264
<i>IMG / SC</i>	0,4326	0,4326	0,4326	0,4326	0,4326
<i>DIS / SC</i>	0,4153	0,111	0,4262	0,3617	0,4862
<i>Q o ENC / SC</i>	0,3613	0,3897	0,0083	0,1035	0,0576

Tabla 11.31: NMI base MFPT usando WLR, arquitectura MRGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 311</i>	<i>E 313</i>	<i>E 337</i>	<i>E 350</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4726	0,4726	0,4726	0,4726	0,4726
<i>DIS / KM</i>	0,3044	0,2361	0,6526	0,7256	0,8030
<i>Q o ENC / KM</i>	0,2279	0,2264	0,0994	0,1614	0,0428
<i>IMG / SC</i>	0,6499	0,6499	0,6499	0,6499	0,6499
<i>DIS / SC</i>	0,6044	0,3111	0,6363	0,4405	0,5487
<i>Q o ENC / SC</i>	0,4268	0,4526	0,0588	0,2041	0,1089

Tabla 11.32: Pureza base MFPT usando WLR, arquitectura MRGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 311</i>	<i>E 313</i>	<i>E 337</i>	<i>E 350</i>	<i>E 1303</i>
<i>IMG / KM</i>	77,36%	77,36%	77,36%	77,36%	77,36%
<i>DIS / KM</i>	63,52%	57,49%	84,61%	85,34%	92,26%
<i>Q o ENC / KM</i>	57,98%	57,90%	50,65%	55,37%	50,00%
<i>IMG / SC</i>	73,21%	73,21%	73,21%	73,21%	73,21%
<i>DIS / SC</i>	72,09%	60,42%	73,21%	73,05%	73,21%
<i>Q o ENC / SC</i>	66,69%	68,24%	50,00%	53,83%	54,15%

Tabla 11.33: ARI base MFPT usando WLR, arquitectura MRGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 311</i>	<i>E 313</i>	<i>E 337</i>	<i>E 350</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4238	0,4238	0,4238	0,4238	0,4238
<i>DIS / KM</i>	0,1988	0,0879	0,6349	0,6294	0,7774
<i>Q o ENC / KM</i>	0,0652	0,0521	0,0293	0,0049	-0,0299
<i>IMG / SC</i>	0,4294	0,4294	0,4294	0,4294	0,4294
<i>DIS / SC</i>	0,023	0,0561	0,4231	0,4038	0,7774
<i>Q o ENC / SC</i>	0,5177	0,0550	0,0572	0,0929	0,0005

Tabla 11.34: NMI base MFPT usando WLR, arquitectura MRGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 311</i>	<i>E 313</i>	<i>E 337</i>	<i>E 350</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4663	0,4663	0,4663	0,4663	0,4663
<i>DIS / KM</i>	0,307	0,238	0,6542	0,7243	0,8077
<i>Q o ENC / KM</i>	0,2433	0,2365	0,1042	0,1593	0,047
<i>IMG / SC</i>	0,6494	0,6494	0,6494	0,6494	0,6494
<i>DIS / SC</i>	0,1537	0,1147	0,6355	0,5989	0,8077
<i>Q o ENC / SC</i>	0,5546	0,2391	0,0989	0,2296	0,077

Tabla 11.34: Pureza base MFPT usando WLR, arquitectura MRGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 311</i>	<i>E 313</i>	<i>E 337</i>	<i>E 350</i>	<i>E 1303</i>
<i>IMG / KM</i>	77,56%	77,56%	77,56%	77,56%	77,56%
<i>DIS / KM</i>	63,46%	58,01%	84,62%	85,26%	92,31%
<i>Q o ENC / KM</i>	58,97%	58,65%	52,24%	55,45%	50,00%
<i>IMG / SC</i>	73,08%	73,08%	73,08%	73,08%	73,08%
<i>DIS / SC</i>	51,32%	50,00%	73,08%	72,44%	92,31%
<i>Q o ENC / SC</i>	79,17%	58,97%	54,17%	55,45%	50,00%

Tabla 11.35: ARI base MFPT usando WLR, arquitectura DCGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 614</i>	<i>E 615</i>	<i>E 640</i>	<i>E 653</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4245	0,4245	0,4245	0,4245	0,4245
<i>DIS / KM</i>	0,1243	0,1251	0,4527	0,4487	0,6833
<i>IMG / SC</i>	0,4326	0,4326	0,4326	0,4326	0,4326
<i>DIS / SC</i>	-0,0284	0,0408	0,4262	0,4262	0,6833

Tabla 11.36: NMI base MFPT usando WLR, arquitectura DCGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 614</i>	<i>E 615</i>	<i>E 640</i>	<i>E 653</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4726	0,4726	0,4726	0,4726	0,4726
<i>DIS / KM</i>	0,2787	0,2730	0,4625	0,4626	0,6979
<i>IMG / SC</i>	0,6499	0,6499	0,6499	0,6499	0,6499
<i>DIS / SC</i>	0,1596	0,1658	0,6363	0,6363	0,6979

Tabla 11.37: Pureza base MFPT usando WLR, arquitectura DCGAN y el set de entrenamiento (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 614</i>	<i>E 615</i>	<i>E 640</i>	<i>E 653</i>	<i>E 1303</i>
<i>IMG / KM</i>	77,36%	77,36%	77,36%	77,36%	77,36%
<i>DIS / KM</i>	60,34%	60,02%	77,28%	77,20%	88,52%
<i>IMG / SC</i>	73,21%	73,21%	73,21%	73,21%	73,21%
<i>DIS / SC</i>	50,00%	53,91%	73,21%	73,21%	88,52%

Tabla 11.38: ARI base MFPT usando WLR, arquitectura DCGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 614</i>	<i>E 615</i>	<i>E 640</i>	<i>E 653</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4238	0,4238	0,4238	0,4238	0,4238
<i>DIS / KM</i>	0,1278	0,128	0,4292	0,4398	0,6802
<i>IMG / SC</i>	0,4294	0,4294	0,4294	0,4294	0,4294
<i>DIS / SC</i>	0,0504	0,0559	0,4231	0,3095	0,4231



Tabla 11.39: NMI base MFPT usando WLR, arquitectura DCGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 614</i>	<i>E 615</i>	<i>E 640</i>	<i>E 653</i>	<i>E 1303</i>
<i>IMG / KM</i>	0,4663	0,4663	0,4663	0,4663	0,4663
<i>DIS / KM</i>	0,2831	0,2776	0,4485	0,4583	0,6967
<i>IMG / SC</i>	0,6494	0,6494	0,6494	0,6494	0,6494
<i>DIS / SC</i>	0,1733	0,1784	0,6355	0,4697	0,6355

Tabla 11.40: Pureza base MFPT usando WLR, arquitectura DCGAN y el set de validación (elaboración propia).

<i>Salida/ Clustering</i>	<i>E 614</i>	<i>E 615</i>	<i>E 640</i>	<i>E 653</i>	<i>E 1303</i>
<i>IMG / KM</i>	77,56%	77,56%	77,56%	77,56%	77,56%
<i>DIS / KM</i>	60,58%	60,26%	76,28%	76,92%	88,46%
<i>IMG / SC</i>	73,08%	73,08%	73,08%	73,08%	73,08%
<i>DIS / SC</i>	53,85%	54,17%	73,08%	65,38%	73,08%

### 11.2.2. CWRU.

Tabla 11.41: ARI base CWRU usando WLR, arquitectura InfoGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 60</i>	<i>E 60</i>	<i>E 64</i>	<i>E 66</i>	<i>E 213</i>
<i>IMG / KM</i>	0,4775	0,4964	0,4517	0,5214	0,5511
<i>DIS / KM</i>	0,3374	0,3224	0,2367	0,2004	0,6451
<i>Q o ENC / KM</i>	0,2135	0,2225	0,1156	0,1525	0,4691
<i>IMG / SC</i>	0,4498	0,332	0,450	0,332	0,4498
<i>DIS / SC</i>	0,6142	0,5258	0,4387	0,4387	0,5004
<i>Q o ENC / SC</i>	0,2954	0,2833	0,2511	0,2512	0,3060

Tabla 11.42: NMI base CWRU usando WLR, arquitectura InfoGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 60</i>	<i>E 60</i>	<i>E 64</i>	<i>E 66</i>	<i>E 213</i>
<i>IMG / KM</i>	0,7241	0,7569	0,7294	0,7516	0,7644
<i>DIS / KM</i>	0,5236	0,5256	0,4537	0,4482	0,791
<i>Q o ENC / KM</i>	0,4309	0,4434	0,3858	0,3905	0,5743
<i>IMG / SC</i>	0,7788	0,7163	0,779	0,7163	0,7788
<i>DIS / SC</i>	0,8085	0,7583	0,6239	0,6239	0,7649
<i>Q o ENC / SC</i>	0,4741	0,4833	0,3932	0,3932	0,6415

Tabla 11.43: Pureza base CWRU usando WLR, arquitectura InfoGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 60</i>	<i>E 60</i>	<i>E 64</i>	<i>E 66</i>	<i>E 213</i>
<i>IMG / KM</i>	69,68%	69,56%	66,59%	68,20%	70,86%
<i>DIS / KM</i>	52,68%	57,40%	50,31%	50,56%	78,72%
<i>Q o ENC / KM</i>	47,53%	49,79%	44,64%	47,77%	62,27%
<i>IMG / SC</i>	75,10%	67,40%	71,10%	68,67%	63,24%
<i>DIS / SC</i>	70,85%	73,82%	64,63%	60,97%	66,32%
<i>Q o ENC / SC</i>	49,91%	48,99%	45,32%	47,34%	59,47%

Tabla 11.44: ARI base CWRU usando WLR, arquitectura InfoGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 60</i>	<i>E 60</i>	<i>E 64</i>	<i>E 66</i>	<i>E 213</i>
<i>IMG / KM</i>	0,4719	0,4857	0,4428	0,5177	0,5466
<i>DIS / KM</i>	0,3309	0,3164	0,2352	0,1981	0,6419
<i>Q o ENC / KM</i>	0,2146	0,2253	0,1165	0,152	0,4651
<i>IMG / SC</i>	0,5618	0,5618	0,5618	0,5618	0,5618
<i>DIS / SC</i>	0,4649	0,4579	0,3213	0,3214	0,5129
<i>Q o ENC / SC</i>	0,2752	0,3082	0,2636	0,2635	0,2876

Tabla 11.45: NMI base CWRU usando WLR, arquitectura InfoGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 60</i>	<i>E 60</i>	<i>E 64</i>	<i>E 66</i>	<i>E 213</i>
<i>IMG / KM</i>	0,723	0,751	0,7236	0,7511	0,7641
<i>DIS / KM</i>	0,5186	0,526	0,4537	0,4481	0,7881
<i>Q o ENC / KM</i>	0,4323	0,447	0,3835	0,3903	0,5728
<i>IMG / SC</i>	0,7929	0,7929	0,7929	0,7929	0,7929
<i>DIS / SC</i>	0,7207	0,7209	0,5616	0,5614	0,7705
<i>Q o ENC / SC</i>	0,4574	0,491	0,3935	0,3942	0,6108

Tabla 11.46: Pureza base CWRU usando WLR, arquitectura InfoGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 60</i>	<i>E 60</i>	<i>E 64</i>	<i>E 66</i>	<i>E 213</i>
<i>IMG / KM</i>	69,49%	69,31%	66,35%	68,03%	70,65%
<i>DIS / KM</i>	51,77%	56,85%	49,79%	50,86%	78,73%
<i>Q o ENC / KM</i>	47,87%	50,21%	45,02%	47,45%	61,98%
<i>IMG / SC</i>	76,52%	74,25%	74,25%	74,27%	70,82%
<i>DIS / SC</i>	70,77%	69,34%	58,26%	58,28%	65,47%
<i>Q o ENC / SC</i>	53,02%	51,69%	48,08%	47,93%	65,65%

Tabla 11.47: ARI base CWRU usando WLR, arquitectura MRGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 202</i>	<i>E 202</i>	<i>E 206</i>	<i>E 209</i>	<i>E 213</i>
<i>IMG / KM</i>	0,4765	0,463	0,4202	0,477	0,4973
<i>DIS / KM</i>	0,3584	0,3656	0,4230	0,4981	0,6039
<i>Q o ENC / KM</i>	0,3658	0,3443	0,2906	0,2998	0,3274
<i>IMG / SC</i>	0,3741	0,3325	0,4493	0,332	0,4297
<i>DIS / SC</i>	0,4153	0,3919	0,5491	0,5243	0,5355
<i>Q o ENC / SC</i>	0,2023	0,2791	0,2688	0,2318	0,2037

Tabla 11.48: NMI base CWRU usando WLR, arquitectura MRGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 202</i>	<i>E 202</i>	<i>E 206</i>	<i>E 209</i>	<i>E 213</i>
<i>IMG / KM</i>	0,7311	0,716	0,7102	0,7241	0,7314
<i>DIS / KM</i>	0,5495	0,5653	0,5476	0,6336	0,71784
<i>Q o ENC / KM</i>	0,5815	0,5855	0,5601	0,5682	0,59214
<i>IMG / SC</i>	0,7345	0,7169	0,778	0,7163	0,75224
<i>DIS / SC</i>	0,7074	0,6929	0,768	0,7838	0,79
<i>Q o ENC / SC</i>	0,4949	0,5093	0,465	0,5191	0,466

Tabla 11.49 Pureza base CWRU usando WLR, arquitectura MRGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 202</i>	<i>E 202</i>	<i>E 206</i>	<i>E 209</i>	<i>E 213</i>
<i>IMG / KM</i>	69,05%	68,28%	66,72%	67,98%	68,75%
<i>DIS / KM</i>	58,66%	57,22%	56,49%	61,02%	66,42%
<i>Q o ENC / KM</i>	58,92%	59,81%	51,70%	57,71%	52,67%
<i>IMG / SC</i>	68,01%	68,09%	74,36%	64,69%	67,56%
<i>DIS / SC</i>	67,02%	63,98%	72,48%	64,61%	70,55%
<i>Q o ENC / SC</i>	52,86%	50,14%	44,76%	52,63%	43,41%

Tabla 11.50: ARI base CWRU usando WLR, arquitectura MRGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 202</i>	<i>E 202</i>	<i>E 206</i>	<i>E 209</i>	<i>E 213</i>
<i>IMG / KM</i>	0,4756	0,4684	0,416	0,4714	0,4944
<i>DIS / KM</i>	0,3555	0,3651	0,4189	0,492	0,5992
<i>Q o ENC / KM</i>	0,3625	0,3415	0,2883	0,2965	0,3281
<i>IMG / SC</i>	0,5618	0,5618	0,5618	0,5618	0,5618
<i>DIS / SC</i>	0,4067	0,4101	0,5069	0,4506	0,6304
<i>Q o ENC / SC</i>	0,4459	0,3829	0,3434	0,3406	0,1864

Tabla 11.51: NMI base CWRU usando WLR, arquitectura MRGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 202</i>	<i>E 202</i>	<i>E 206</i>	<i>E 209</i>	<i>E 213</i>
<i>IMG / KM</i>	0,7319	0,7198	0,7073	0,7219	0,7321
<i>DIS / KM</i>	0,5465	0,563	0,5467	0,626	0,7128
<i>Q o ENC / KM</i>	0,5836	0,5855	0,557	0,5679	0,5962
<i>IMG / SC</i>	0,7929	0,7929	0,7929	0,7929	0,7929
<i>DIS / SC</i>	0,6503	0,6549	0,7319	0,7616	0,833
<i>Q o ENC / SC</i>	0,6078	0,5837	0,5145	0,5689	0,5005

Tabla 11.52: Pureza base CWRU usando WLR, arquitectura MRGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 202</i>	<i>E 202</i>	<i>E 206</i>	<i>E 209</i>	<i>E 213</i>
<i>IMG / KM</i>	69,16%	68,42%	66,50%	67,68%	68,56%
<i>DIS / KM</i>	58,31%	57,01%	56,87%	60,95%	66,03%
<i>Q o ENC / KM</i>	58,94%	59,58%	51,36%	57,61%	52,84%
<i>IMG / SC</i>	74,27%	74,27%	74,25%	72,55%	74,25%
<i>DIS / SC</i>	62,85%	63,48%	66,60%	66,67%	78,27%
<i>Q o ENC / SC</i>	59,15%	53,91%	54,50%	52,55%	45,95%

Tabla 11.53: ARI base CWRU usando WLR, arquitectura DCGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 160</i>	<i>E 160</i>	<i>E 164</i>	<i>E 166</i>	<i>E 213</i>
<i>IMG / KM</i>	0,4479	0,464	0,4476	0,4637	0,507
<i>DIS / KM</i>	0,5233	0,3367	0,3515	0,3918	0,472
<i>IMG / SC</i>	0,4297	0,4498	0,3944	0,3312	0,5419
<i>DIS / SC</i>	0,4873	0,5866	0,562	0,5451	0,4725

Tabla 11.54: NMI base CWRU usando WLR, arquitectura DCGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 160</i>	<i>E 160</i>	<i>E 164</i>	<i>E 166</i>	<i>E 213</i>
<i>IMG / KM</i>	0,7391	0,7164	0,7391	0,7176	0,7462
<i>DIS / KM</i>	0,7335	0,6126	0,5975	0,6076	0,5799
<i>IMG / SC</i>	0,7522	0,7788	0,7346	0,7097	0,7945
<i>DIS / SC</i>	0,7903	0,7897	0,8072	0,7966	0,7667

Tabla 11.55: Pureza base CWRU usando WLR, arquitectura DCGAN y set de entrenamiento (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 160</i>	<i>E 160</i>	<i>E 164</i>	<i>E 166</i>	<i>E 213</i>
<i>IMG / KM</i>	68,29%	67,70%	63,82%	68,07%	68,96%
<i>DIS / KM</i>	69,57%	54,02%	61,85%	62,69%	59,72%
<i>IMG / SC</i>	71,17%	69,08%	67,95%	64,39%	70,87%
<i>DIS / SC</i>	75,63%	73,70%	73,35%	72,51%	66,32%

Tabla 11.56: ARI base CWRU usando WLR, arquitectura DCGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 160</i>	<i>E 160</i>	<i>E 164</i>	<i>E 166</i>	<i>E 213</i>
<i>IMG / KM</i>	0,4415	0,4683	0,4415	0,4588	0,5016
<i>DIS / KM</i>	0,5185	0,336	0,3468	0,3887	0,4717
<i>IMG / SC</i>	0,5618	0,5618	0,5618	0,5618	0,5618
<i>DIS / SC</i>	0,6112	0,5365	0,5602	0,426	0,4133

Tabla 11.57: NMI base CWRU usando WLR, arquitectura DCGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 160</i>	<i>E 160</i>	<i>E 164</i>	<i>E 166</i>	<i>E 213</i>
<i>IMG / KM</i>	0,7356	0,7196	0,7355	0,7135	0,7428
<i>DIS / KM</i>	0,7319	0,6120	0,5938	0,6062	0,5785
<i>IMG / SC</i>	0,7929	0,7929	0,7929	0,7929	0,7929
<i>DIS / SC</i>	0,8402	0,7417	0,8106	0,7447	0,6898

Tabla 11.58: Pureza ARI base CWRU usando WLR, arquitectura DCGAN y set de validación (elaboración propia)

<i>Salida/ Clustering</i>	<i>E 160</i>	<i>E 160</i>	<i>E 164</i>	<i>E 166</i>	<i>E 213</i>
<i>IMG / KM</i>	68,12%	67,92%	63,80%	67,93%	68,96%
<i>DIS / KM</i>	69,47%	54,27%	61,52%	62,61%	59,31%
<i>IMG / SC</i>	74,95%	74,88%	72,02%	74,95%	72,02%
<i>DIS / SC</i>	75,61%	71,81%	77,72%	67,45%	69,32%

### 11.3. Gráficos de clasificación v/s tiempo en FEMTO-ST.

#### 11.3.1. Set de entrenamiento.




Figura 11.1: Clasificación de muestras rodamiento Bearing 1\_1 (set de entrenamiento FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)

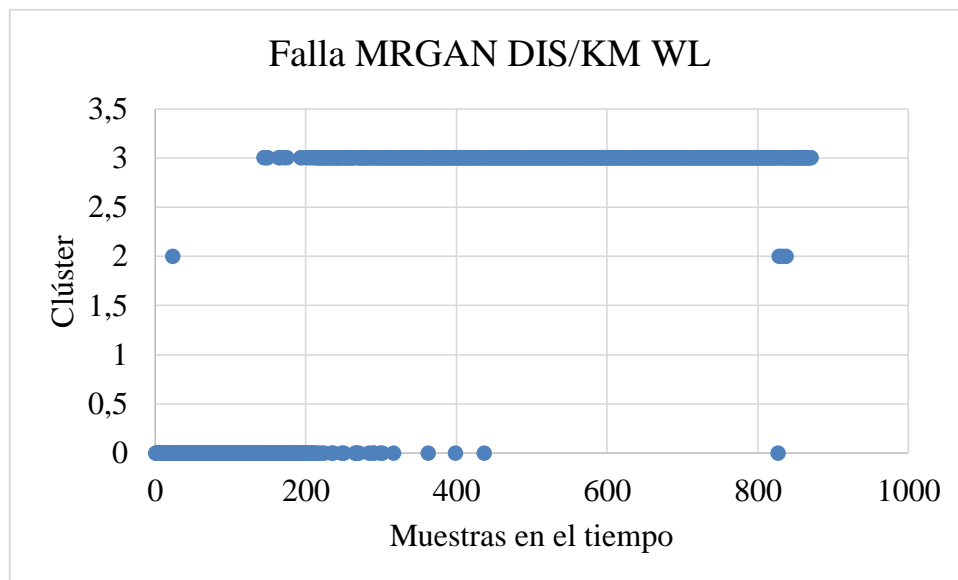


Figura 11.2: Clasificación de muestras rodamiento Bearing 1\_2 (set de entrenamiento FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)






Figura 11.3: Clasificación de muestras rodamiento Bearing 2\_1 (set de entrenamiento FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.4: Clasificación de muestras rodamiento Bearing 2\_2 (set de entrenamiento FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.5: Clasificación de muestras rodamiento Bearing 3\_1 (set de entrenamiento FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.6: Clasificación de muestras rodamiento Bearing 3\_2 (set de entrenamiento FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)

### 11.3.2. Set de validación.




Figura 11.7: Clasificación de muestras rodamiento Bearing 1\_3 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.8: Clasificación de muestras rodamiento Bearing 1\_5 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.9: Clasificación de muestras rodamiento Bearing 1\_6 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.10: Clasificación de muestras rodamiento Bearing 1\_5 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.11: Clasificación de muestras rodamiento Bearing 2\_3 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.12: Clasificación de muestras rodamiento Bearing 2\_4 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.13: Clasificación de muestras rodamiento Bearing 2\_5 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.14: Clasificación de muestras rodamiento Bearing 2\_6 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.15: Clasificación de muestras rodamiento Bearing 2\_7 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)




Figura 11.16: Clasificación de muestras rodamiento Bearing 3\_3 (set de validación FEMTO-ST) usando transformada de wavelets y la arquitectura MRGAN con K-means en la penúltima capa del discriminador (elaboración propia)