

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



PROYECTO FIN DE CARRERA

SISTEMA PREVENTIVO DE FALLOS EN BOMBA DE AGUA MEDIANTE SEÑALES DE AUDIO Y VIBRACIÓN

Titulación: Ingeniería de Telecomunicación
Autor: Garoé M. Gómez Bolaños.
Tutores: D. Jesús B. Alonso Hernández.
Dña. Patricia Henríquez Rodríguez.
Fecha: Junio 2015.

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



PROYECTO FIN DE CARRERA

SISTEMA PREVENTIVO DE FALLOS EN BOMBA DE AGUA MEDIANTE SEÑALES DE AUDIO Y VIBRACIÓN

HOJA DE FIRMAS

Alumno/a

Fdo.: Garoé M. Gómez Bolaños

Tutor/a

Tutor/a

Fdo.:D. Jesús B. Alonso Hernández. Fdo.: Dña. Patricia Henríquez Rodríguez

Fecha: Junio 2015.

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



PROYECTO FIN DE CARRERA

SISTEMA PREVENTIVO DE FALLOS EN BOMBA DE AGUA MEDIANTE SEÑALES DE AUDIO Y VIBRACIÓN

HOJA DE EVALUACIÓN

Calificación: _____

Presidente

Fdo.:

Vocal

Fdo.:

Secretario/a

Fdo.:

Fecha: Junio 2015

Agradecimientos

Gracias a mis tutores Jesús y Patricia, por la paciencia, ayuda y consejos que me han brindado durante todo este tiempo.

Gracias a mis amigos y familiares que siempre me han mostrado interés y ánimo por terminar este trabajo, en especial a mis padres Juan Luis y Ana, por su infinita paciencia y aliento.

Gracias al IDETIC, por prestar sus instalaciones para la elaboración del presente proyecto y gracias a todos los que en más o menos medida me han ayudado a finalizar este proyecto.

Garóé Marcial Gómez Bolaños.

INDICE

MEMORIA	5
Capítulo 1. Introducción a la Monitorización	7
1.1 Introducción	7
1.2 Motivación	9
1.3 Antecedentes	10
1.4 Objetivos	12
1.5 Metodología	13
Capítulo 2. Base de datos	15
2.1 Introducción	15
2.2 Base de datos a realizar	15
2.2.1 Clases para la base de datos implementada	17
2.2.1.1 Pruebas de normalidad	18
2.2.1.2 Pruebas de anormalidad (Rotura de álabes)	20
2.2.1.3 Pruebas de anormalidad (Elementos en agua)	22
2.2.2 Características de la señal grabada, etiquetas y duración	24
2.2.3 Estructura de carpetas de la base de datos	24
2.3 Medios para la elaboración de la Base de Datos	25
2.3.1 Hardware	26
2.3.2 Software	27
2.4 Metodología	27
2.5 Base de datos obtenida	30
2.5.1 Fallos producidos en la base de datos	35
Capítulo 3: Parametrización	39
3.1. Evolución en la parametrización	39
3.2. La transformada Wavelet	40
3.2.1. Usos	42
3.3. Transformada wavelet discreta	43

3.3.1.	Wavelet Packet transform -----	44
3.3.2.	Elección del nivel de descomposición y número de nodos para cada sensor -----	46
3.3.3.	Familias usadas -----	47
3.3.4.	Parámetros estadísticos -----	48
3.4.	Metodología-----	51
Capítulo 4: Clasificador-----		55
4.1.	Introducción -----	55
4.2.	Clasificadores SVM-----	56
4.2.1.	SVM: Funciones Kernel -----	58
4.3.	LS-SVM-----	61
4.4.	Metodología.-----	63
Capítulo 5. Metodología del estudio -----		65
5.1	Introducción -----	65
5.2	Extracción de características -----	66
5.3	Experimentación -----	66
5.3.1	Sistema “OFF-LINE” -----	67
5.3.2	Sistema ON-LINE-----	70
5.3.3	Primer experimento -----	71
5.3.4	Segundo experimento-----	73
5.3.5	Tercer y Cuarto experimento-----	73
Capítulo 6: Resultados-----		77
6.1	Análisis de prestaciones -----	78
6.1.1	Matriz de confusión -----	78
6.2.	Primera aproximación-----	81
6.3.	Resultado según tamaño de la trama -----	84
6.4.	Sistema emulador (entrenamiento y testeo) -----	90
6.4.1.	Metodología-----	90
Capítulo 7. Simulador-----		97

7.1.	GUI desarrollado -----	97
7.1.1.	Menú interfaz -----	98
7.1.2.	Funcionamiento -----	98
7.2.	Organigrama-----	101
Capítulo 8. Conclusiones y futuros proyectos -----		103
8.1.	Conclusiones -----	103
8.2.	Líneas de trabajo futuro -----	104
Bibliografía -----		107
PLANOS Y PROGRAMAS-----		111
Planos y Programas -----		113
	Algoritmos para GUIs-----	113
	Algoritmos para extracción de parámetros-----	114
	Algoritmos para el clasificador-----	114
PLIEGO DE CONDICIONES-----		117
Pliego De Condiciones-----		119
1.	Pliego de Condiciones Técnicas-----	119
1.1	Requisitos del sistema-----	119
1.2	Instalación y ejecución del software-----	120
1.2.1.	Herramientas “Proyectogaroe” -----	120
1.2.2.	Herramienta “Proyectogaroe”-----	120
2.	Pliego de condiciones legales -----	121
2.1.	Concesión de licencia-----	121
2.2.	Derechos de autor-----	121
2.3.	Restricciones-----	121
2.4.	Garantía-----	122
2.5.	Limitación de responsabilidad-----	122
2.6.	Actividades de alto riesgo -----	122
2.7.	Varios-----	123

PRESUPUESTO-----	125
Presupuesto-----	127
P1. Trabajo tarifado por tiempo empleado-----	127
P2. Amortización del inmovilizado material-----	129
P3. Costes de material fungible-----	131
P4. Redacción del proyecto-----	131
P5. Derechos de visado-----	132
P6. Gastos de tramitación y envío-----	133
P7. Presupuesto antes de impuestos-----	133
P8. Presupuesto después de impuestos-----	134

MEMORIA

Capítulo 1. Introducción a la Monitorización

1.1 Introducción

En la actualidad el mantenimiento de equipamientos industriales singulares se ha convertido en un aspecto estratégico en las políticas de empresas relacionadas con el incremento de la productividad y reducción de costes. Esta estrategia ha dado lugar a que exista un significativo incremento en el desarrollo de nuevas estrategias de mantenimiento basadas en el conocimiento, siendo aplicadas en sistemas como subestaciones eléctricas o aerogeneradores.

La monitorización continua y la detección temprana de averías (MCDTA) es una solución fiable y barata ante los fallos que puede sufrir la maquinaria de mayor o menor tamaño, más aún, cuando estos son sistemas que se encuentran en ubicaciones aisladas o remotas, en los que es difícil disponer de los medios materiales y humanos para una correcta funcionalidad de las mismas. Mediante la estrategia MCDTA se puede obtener una “firma” del funcionamiento de la maquinaria a partir de sensores y detectar comportamientos anormales en su estado incipiente.

Las ventajas del MCDTA son evidentes:

1. Se reducen los costes de mantenimiento debido al hecho de que se detectan fallos incipientes y se evita que dichos fallos crezcan y se conviertan en un grave problema que cueste mucho dinero.

2. Reduce la probabilidad de fallos destructivos que afecten a la calidad del suministro y a la seguridad de las personas.
3. Reduce la gravedad de cualquier fallo producido y elimina o reduce las consecuentes actividades de reparación.
4. Se puede identificar la raíz de las causas de los fallos.
5. Puede dar información sobre el ciclo de vida de la planta mediante la monitorización integrada de todos los equipos eléctricos importantes.

Algunos ejemplos de estas ventajas están reflejados en la tabla 1.

Ventajas de los sistemas de monitorización de máquinas eléctricas	
Costes de mantenimiento	Reducción del 50% al 80%
Daños en los equipos	Reducción del 50% al 60%
Partes redundantes	Reducción del 20% al 30%
Tiempo de vida del equipo	Reducción del 50% al 80%
Gatos en horas extras	Reducción del 20% al 50%
Esperanza de vida de la máquina	Incremento del 50% al 60%
Productividad total	Incremento del 20% al 30%
Beneficio	Incremento del 25% al 60%

Tabla 1: Ventajas de los sistemas de monitorización de máquinas eléctricas [1]

En cuanto a la fiabilidad de la maquinaria podemos observar en la tabla 2, sus mejoras.

Rango de velocidad (721-1800rpm)	% Fiabilidad sin ayuda de monitorización (1 año)	% Fiabilidad con ayuda de monitorización(1año)
201-500 HP	92.6	96.8
501-5000 HP	91.1	96.5
>5000 HP	90.7	95.5

Tabla 2: Mejora de fiabilidad esperada utilizando sistemas de monitorización [2].

Existen varias fuentes de información para obtener la “firma” del funcionamiento de una máquina: sensores de Venturi, de presión, de corriente, de voltaje, etc..., no obstante, las fuentes más utilizadas son las basadas en sensores de vibración: en los que mediante acelerómetros (de desplazamiento, de velocidad y de aceleración) obtenemos los datos. No tan extendido es el uso de señales acústicas captadas con micrófonos, que al igual que las medidas de vibración obtenidas con acelerómetros, son una forma no invasiva de monitorización, incluso, menos invasiva que los acelerómetros ya que no necesitan estar en contacto con la maquinaria para caracterizar el funcionamiento de la misma.

En este proyecto se busca estudiar la caracterización del funcionamiento de la maquinaria a partir de señales de audio y vibración obtenidas mediante sensores no invasivos. Se pretende, aplicar técnicas de inteligencia artificial con el fin de evaluar el comportamiento normal o anormal de la máquina que se esté monitorizando. Con el fin de realizar la experimentación se utilizará una bomba de agua en circuito cerrado. Finalmente se implementará una aplicación que permita monitorizar los estados de funcionamiento de la máquina.

1.2 Motivación

La principal motivación para este proyecto es realizar un estudio y desarrollar una herramienta capaz de detectar anomalías en maquinarias de forma no invasiva,

mediante sensores que no necesitan una especial adaptación y además que sean una herramienta software portable.

En este sentido existen sensores capaces de detectar mediante vibración las posibles fallas, el presente proyecto pretende estudiar audio y vibración y determinar cuál es el más óptimo para el objetivo deseado.

Las ventajas del mismo son claras: portabilidad, simplicidad y desarrollo de sistemas de captación y procesado de señales.

1.3 Antecedentes

A lo largo de la historia se han utilizado diferentes técnicas de mantenimiento de la maquinaria. En general, las técnicas utilizadas se pueden dividir:

- **Mantenimiento correctivo:** En esta técnica se toman las medidas oportunas sólo en el caso de que se produzca un fallo de la maquinaria. Dichas medidas pueden ser o bien arreglar inmediatamente el fallo o bien posponer su arreglo según necesidades.
- **Mantenimiento preventivo** puede dividirse a su vez en dos:
 - Mantenimiento preventivo determinado o periódico: En esta técnica se repara la maquina antes de que se produzca fallo. Se realizan revisiones de la máquina a intervalos periódicos de tiempo sin tener en cuenta el “estado de salud” de la máquina en cuestión.
 - Mantenimiento Basado en la Condición (MBC) (condition-based maintenance). [3]: En esta técnica se evita tareas de mantenimiento innecesarias, actuando solo cuando sea necesario ante comportamientos anormales de la maquinaria. Este es por tanto más eficiente con respecto a los costes.

Un sistema MBC puede realizar tanto diagnóstico como pronóstico y en ambos casos se sigue el esquema de la figura 1. Los tres pasos básicos de un sistema MBC mostrados en la figura son [4]:

1. Adquisición de los datos: consiste en la recolección de información para obtener los datos relevantes del estado de salud del sistema. Se podrían adquirir señales de audio, vibración, temperatura, presión, corriente, según el campo de aplicación que se esté estudiando, de esta manera se consigue la firma característica de la máquina en estudio.
2. Procesado de los datos: se trata de la extracción de características a partir de las señales adquiridas en el paso anterior para la caracterización del funcionamiento de la máquina.
3. Sistema de ayuda a la toma de decisión de mantenimiento: Permiten obtener una valoración del estado de la máquina basada en sistemas inteligentes. En este bloque existen diferentes experiencias en el estado de la técnica en las que o bien se obtienen el diagnóstico del fallo (detección del fallo o incluso del tipo de fallo y el grado de degradación del elemento que se esté monitorizando) o bien el pronóstico (cuánto tiempo queda para que se produzca un fallo).




Figura 1: Esquema de los pasos básicos seguidos en un sistema de monitorización

Algunos trabajos realizados sobre la monitorización en maquinaria son:

- Sistema electrohidráulico [16], en el que se monitoriza un motor DC y se fuerzan todos los fallos posible (fase, degradación del cojinete, cavitación de la bomba y sobrecalentamiento del motor). Para ello, usan sensores de: corriente, acelerómetros, temperatura y de velocidad, en el que se concluye que hay una reducción del 30% en los costes de mantenimiento.

- Sistema experto de máquinas rotativas [17], en el que se utiliza monitorización on-line mediante tres bases de datos (información de los componentes y configuración de la máquina, espectros de la máquina en estado normal y desviaciones de espectros).

Una de las partes claves en la monitorización de la maquinaria es la extracción de características a partir de la señal o señales adquiridas. En la literatura científica, los trabajos realizados en el campo de la monitorización usando vibraciones son mucho más numerosos que los realizados usando señales de audio. Los trabajos que utilizan audio y/o vibraciones se centran en diferentes componentes de la maquinaria como por ejemplo: cojinetes, engranajes, motores, álabes (de bombas de agua, por ejemplo). En general, se extraen características en diferentes dominios de la señal: en el dominio temporal [5] [8], en el dominio frecuencial [6][11][12][13] y en el dominio tiempo-frecuencia [7][8] entre otros.

Dentro de la División de Procesado Digitales de Señales del IDeTIC existe una amplia experiencia en sistemas de reconociendo biométrico, procesado de video y particularmente en lo que respecta a este PFC en procesado de secuencias temporales. Dentro de esta línea de trabajo, existen experiencias a nivel de investigación y PFC en el procesado de señales de diferentes ámbitos entre los cuales se encuentran la señales de voz, señales biomédicas como la electrocardiograma o electroencefalograma [17]-[24]. La división tiene cierta experiencia en el campo del mantenimiento predictivo de maquinaria a nivel de investigación [25]-[27], siendo este PFC el primero que desarrolla la División en esta temática, con la singularidad de resultar novedosa la utilización de señales de audio y vibraciones simultáneamente.

1.4 Objetivos

El objetivo general de este PFC es la detección del estado de anormalidad y degradación en las piezas de una bomba de agua usando señales de vibración y audio mediante técnicas de procesado de señal basadas en análisis espectral [5] y sistema de

inteligencia artificial avanzadas. Para la consecución de los objetivos generales se pretenden conseguir los siguientes objetivos parciales:

1. Obtener un repositorio de grabaciones de audio y vibraciones de una bomba de agua en circuito cerrado. El repositorio tendrá grabaciones de la bomba en un régimen de normalidad, anormalidad, de degradación de su funcionamiento. Para la obtención de las anormalidades y de la degradación se procederá a la simulación real de averías. Las grabaciones se realizarán en una cámara acústica.
2. Estudio de la utilidad de la información contenida en las señales de audio y vibración, tanto a nivel de datos, de características y de decisión.
3. Estudio la estrategia óptima para la extracción de características mediante análisis en dominios como el espectral.
4. Estudio de técnicas de toma de decisión óptimas para el problema que se plantea.
5. Hacer un activo experimental en Matlab que permita registrar un canal de audio y otro de vibración, mostrando el resultado del análisis predictivo.

1.5 Metodología

Los pasos a realizar para elaborar este proyecto serán:

- **Estado del arte de sistemas de monitorización de la condición aplicado a bombas de agua.**

Lectura de libros y artículos con información relativa a la monitorización de maquinaria [1]-[11] , análisis espectral (transformada Wavelet... [13][14]). Los artículos se obtendrán de los buscadores Scopus y el sistema IEEExplore de IEEE.

- **Adquisición base datos.**

Usando los sensores de audio (micrófonos) y vibración (acelerómetros) se adquirirán los datos de normalidad, anormalidad y degradación de una bomba de agua, en una cámara acústica.

Se preparan los casos de estudio en rotura y anormalidad.

➤ **Implementación de la parametrización usando análisis espectral.**

Esta tarea consiste en la extracción de características basadas en análisis espectral, más específico para determinar su grado de discriminación entre estado normal y anormal, así como para determinar su utilidad a la hora de seguir la evolución de la degradación de la bomba de agua.

➤ **Estudio de clasificador multiclases.**

Estudiaremos las características necesarias para encontrar un sistema clasificador de rápida respuesta, con fiabilidad y fidelidad.

➤ **Estudio del desempeño del sistema.**

Se estudia en esta tarea el grado de discriminación de las características implementadas. Para ello se utilizará un clasificador del tipo SVM, en particular del LS-SVM.

➤ **Implementación de un demostrador en Matlab.**

Se implementará en Matlab un archivo GUI experimental que utilice un canal de audio o de vibración y que analice dichas señales usando la parametrización propuesta y determine en qué estado se encuentra la bomba de agua: normal, anormal, rotura...

➤ **Redacción de la memoria.**

Se realizará una memoria técnica que explique los métodos y resultados obtenidos del mismo que se desarrollan en 7 capítulos:

1. **Monitorización:** antecedentes del proyecto, historia del arte....
2. **Base de datos:** Metodología, usada y casos de estudio
3. **Parametrización:** Extracción de parámetros para clasificación, tiempo de tramas,..
4. **Clasificador:** Tipos de clasificadores, LS-SVM, desarrollo, modelos...
5. **Resultados:** Desempeño del sistema, probabilidad de acierto y error, confusión del sistema.
6. **Simulador:** Herramienta GUI para clasificar muestras de audio, según sensor.
7. **Líneas futuras:** Futuras líneas de investigación y desarrollo.

Capítulo 2. Base de datos

2.1 Introducción

Para el entreno y testeo de un clasificador de patrones, es necesario tener una base de datos con suficientes muestras y diferentes clases para el estudio del mismo. Es por ello que en el presente PFC se realiza la adquisición de muestras tanto de audio como de vibración de una bomba de agua en estado normal de funcionamiento (sin fallos) y en estado anormal de funcionamiento (con diferentes tipos de fallos). De esta forma tendremos una base de datos con la que trabajar.

2.2 Base de datos a realizar

Para la realización de este proyecto necesitaremos una base de datos que constará de una serie de grabaciones en varias situaciones, que representan las clases o estados en los que puede estar la bomba de agua y para ello hemos definido los siguientes estados o clases:

- Normalidad: bomba en estado normal, sin ningún defecto.
- 1aspa: Se parte 1 aspa del álabe de la bomba.
- 2aspa: Se parten 2 aspas del álabe de la bomba.
- 3aspa: Se parten 3 aspas del álabe de la bomba.

- Arena: Se añade arena en el agua, la bomba impulsa con arena.
- Bolas: Se añade bolas de PVC que giran en el cuerpo de bomba, aunque tupirán los álabes.

Estos estados serán clasificados por un número, si bien, podemos añadir y de hecho existen grabados más estados o clases, pero no los tendremos en cuenta, por acotar el proyecto.



Figura 2: Colocación de acelerómetros



Figura 3: Colocación de micrófonos

Para la base de datos usaremos tres micrófonos y tres acelerómetros, colocados estratégicamente para captar el sonido tanto a la entrada como a la salida y cuerpo de bomba, así como también las vibraciones en los tres ejes como se ven en las fotos.

De forma esquemática el proceso es tal como se muestra en la figura:

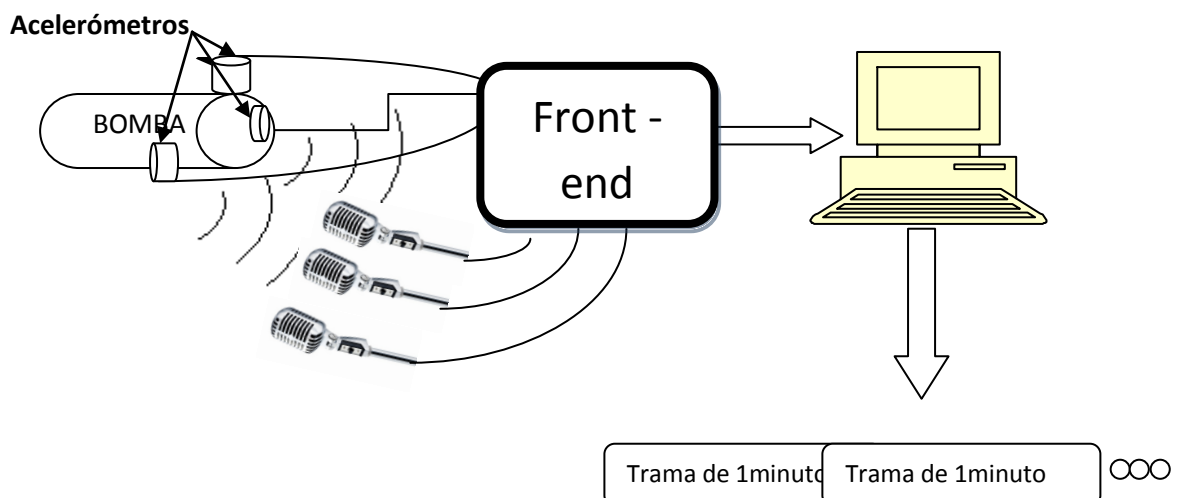


Figura 4: Esquema de captura de datos.

2.2.1 Clases para la base de datos implementada

Para realizar la base de datos de la bomba de agua, empezaremos con la bomba trabajando de forma normal, más tarde se le añadirá una carga que consistirá en una tela metálica mallada que tratará de impedir la evacuación del agua. Una vez realizadas esta carga, se procederá a añadir otra carga o impedimento, que consistirá en una tela de algodón que se superpondrá a la malla metálica. El resultado visible será el aumento de la presión en el manómetro, debido a las cargas y al esfuerzo que se somete a la bomba.

Realizadas estas pruebas de esfuerzo o fatigas, empezaremos a romper el álabe de la bomba arrancándole pedazos de las aspas, con lo que empezaremos a oír un sonido distinto del anterior.

Cuando ya se terminen las pruebas de normalidad, carga y anormalidad (rotura del álabe), empezaremos con las pruebas de rotura, con las que, añadiendo arena al depósito u objetos sólidos, intentaremos emular situaciones que tienden a romper la bomba de agua y registrarlo.

Resumiendo haremos las siguientes pruebas:

- **Pruebas de normalidad y carga:**
 - Sin carga.
 - Con malla metálica.
 - Con malla y tela.
- **Pruebas de anormalidad**
 - Con una aspa rota
 - Con dos aspas rotas
 - Con 3 aspas rotas
- **Pruebas de rotura de bomba.**
 - Con arena
 - Virutas de metal
 - Piedras

- Bolas de PVC
- Vegetación

Una observación a comentar será que tanto en normalidad como anormalidad, le añadiremos cargas a la salida de la manguera de expulsión del agua, todas las observaciones, problemas e incidencias son guardados en un Excel como hoja de control a modo de diario de experimentación.

2.2.1.1 Pruebas de normalidad

Normalidad: bomba en estado normal, sin ningún defecto.

En esta clase se ha probado con diversas cargas, entendiendo cargas como poner a la salida obturadores de tela o mallas metálicas a la salida de la manguera, lo cual aumenta la presión marcada por el manómetro y crea un sonido más agudo según más obturación exista.

- **Sin carga:** La manguera de expulsión del agua se dejará libre de obstáculos, el manómetro no marca presión. Haremos mínimo de 10 ensayos con tipos de arranque distintos.
- **Con carga:**
 - Malla metálica: Pondremos a la salida una malla metálica como se ve en la foto, a la que añadiremos cinta americana para sujetarle y una brida, ya que de lo contrario la presión tirará la carga hacia el fondo del tanque.



Figura5 : Malla metálica como carga.

- Tela y malla metálica: Pondremos a la salida una malla metálica y una tela como se ve en la foto, a la que añadiremos cinta americana para sujetarle y una brida o dos ya que de lo contrario la presión tirará la carga hacia el fondo del tanque.




Figura 6: Vista delantera de la carga.



Figura 7: Vista trasera de la carga.

Una vez realizadas las pruebas, también se ha ensayado con una cinta americana, no obstante, tanto en presión como en sonido no difiere mucho de las anteriores y el agua normalmente consigue abrirla y liberarse de la cinta. Por eso, no se tiene en cuenta.




Figura 8: Manguera con tela para obturar la salida y aumentar la presión.

2.2.1.2 Pruebas de anomalía (Rotura de álabes)

Empezamos con las grabaciones en anomalía, con las aspas rotas para ello, abrimos la bomba y partimos un aspa por la cara interna del álabe como se aprecia en la foto.

- **1aspa:** Se parte 1 aspa del álabe de la bomba.

Partimos un aspa del álabe:




Figura 9: Fractura de un aspa.

A priori, podemos esperar un sonido distinto, cosa que se producirá, al arrancarlo por primera vez, no hay un aumento de presión y se realizarán las mismas pruebas que en caso de normalidad, el resultado es un visible cambio en amplitud y frecuencia en la señal auditiva.

El resultado más evidente es que baja el caudal y aparecen vibraciones. La señal presenta una forma diferente de la normalidad.

- **2aspa:** Se parten 2 aspas del álabe de la bomba.




Figura 10: Fractura de dos aspas

El resultado será parecido al anterior: baja el caudal, así como genera un ruido característico, cambiarán los parámetros y cada vez que se partan más aspas será más difícil arrancar la bomba.

- **3aspa:** Se parten 3 aspas del álabe de la bomba.





Figura 11: Fractura de tres aspas.

Como antes, baja el caudal, así como genera un ruido característico.

2.2.1.3 Pruebas de anormalidad (Elementos en agua)

- **Arena:** Se añade arena en el tanque de agua, la bomba impulsa el agua con arena.

Añadimos al tanque de agua arena de playa, el rozamiento de la misma con el rotor, crea un sonido estridente audible.



Figura 12: Tanque con arena.

- **Bolas:** Se añade bolas de PVC que giran en el cuerpo de bomba, aunque tupirán los álabes.

Al añadir las bolas de PVC, emulamos la entrada de objetos sólidos. El sonido del golpeo de bolas contra la centrífuga, se hace presente con mayor intensidad que los anteriores.



Figura 13: Bolas de PVC

2.2.2 Características de la señal grabada, etiquetas y duración

La señal de grabación será de una duración de entre 10 a 15 minutos, ya que el software para la toma de datos tiene una restricción de tiempo de 20 minutos como máximo. La señal resultante será cortada en secciones de 60 segundos. Estas serán etiquetadas con su fecha, sesión, (cada sesión será una grabación de 10 a 20 minutos) sensor y minuto de la grabación, descrito de la siguiente manera:

21-Jul-2011_1m1_parte1_2.

Fecha: 21-Jul-2011

Sesión: 1

Sensor: m1

Minuto: parte1_2 → parteX_Y = X(1)*5 min+Y(2) → minuto 7.

En definitiva, minuto 7 de la primera sesión del día 21 de Julio.

La forma de etiquetar cada minuto grabado facilita la búsqueda y automatización a la hora de simular, así como también a la hora de trabajar con la hoja de control de las grabaciones.

2.2.3 Estructura de carpetas de la base de datos

Para el entreno y testeo de las clases creamos carpetas con todas las clases.

La distribución de las mismas será primeramente por clase, seguidamente de sensor y finalmente por número de sensor, ej. :





Figura 14: Esquema de clasificación por carpetas.

Matriz de ensayo → Clase (bola, arena...) → Sensor (Acelerómetro, micro) → Número (1, 2,3)



Tras depurar las señales, tenemos una carpeta resultante de un mínimo de 10 archivos de sonido por sensor y por clase. Haciendo un mínimo de 360 minutos de grabación, para la realización de la clasificación.

2.3 Medios para la elaboración de la Base de Datos

La elaboración de la base de datos se ha realizado en las instalaciones del IDETIC, en concreto en la sala acústica del mismo. Las características de esta sala son las siguientes:

Para la realización del mismo se ha utilizado la sala acústica del IDETIC, con estas características:

- Dimensiones: 2 m x 3.4 m
- Características Acústicas:

- 29 dB de aislamiento acústico respecto a ruido aéreo.




Figura 15: Sala Acústica.

2.3.1 Hardware

Para la realización de la base de datos adquirida para este proyecto, hemos usado:

- 3 micrófonos MX025: sensibilidad (1kHz) : 50mV/Pa -8/+5mV/Pa
- 3 acelerómetros:
 - 1 AC003 de margen frecuencial: 0,35-2600hz y sensibilidad de 1000mV/g.
 - 2 AC001 de margen frecuencial: 0,7hz-10kHz y sensibilidad de 100mV/g.
- 1 front-end de ocho canales con un ancho de banda de 0,3 a 20000Hz.
- Tarjetas de sonidos.
- 1 ordenador de sobremesa con Matlab y programas de audio.
- 1 ordenador portátil Acer.

- 1 bomba de agua ALP800 de 2925rpm y potencia nominal: 0.37 kW, de 0,6 a
- 8,4 m³/h con altura de elevación de hasta 21 metros.
- 1 tanque de agua de 250 litros.



Figura 16: Sensores de captura de audio y vibración y front-end.

2.3.2 Software

Para la adquisición de las señales de audio y vibración usaremos un programa desarrollado en un PFC de la División de Procesado de la Señal del IDETIC.

- Programa captador por front-end, del proyecto final de carrera, división de la IDETIC.

2.4 Metodología

Para la grabación de esta base de datos se ha realizado un circuito cerrado como se ve en la siguiente figura:




Figura 17: Esquema y tanque en circuito cerrado.

Una vez instalada la bomba, y colocado los sensores, en la sala acústica, ponemos la bomba en marcha, para evitar ruidos externos, se ha dejado la bomba encendida y se activa la grabación desde fuera de la habitación acústica, tras 15 minutos aproximadamente, se ha parado la grabación. El programa utilizado para la captura de datos nos graba en estéreo la señal. Teniendo 3 tarjetas para la captura de datos, con doble entrada, permitiendo así captar los 6 sensores, como se ve en la figura 4.

Una vez realizada una sesión de grabación y segmentada la señal grabada en archivos de 1 minuto de duración, se escuchan las grabaciones realizadas para evitar fallos o ruidos indeseados en las mismas procedentes de apertura de la puerta, entrada de personas, etc. Recalcar que esta tarea ha sido ardua pero necesaria para obtener muestras de calidad que luego puedan ser procesadas adecuadamente.

Antes de cada sesión se ha determinado los micros “cantándolos” a principio de cada sesión, es decir, tocamos el sensor nombrándolo en voz alta y luego, mediante el programa Audacity, iremos asociando cada sensor a la salida del front-end, de esta forma sabemos si es un micrófono o acelerómetro lo que estamos escuchando. Esta comprobación se hace necesaria pues la tarjeta puede hacer variar las entradas de los acelerómetros y micrófonos, en la figura 18 podemos observar los valores:

En normalidad			En rotura		
ACELEROMETROS	1	T3B	ACELEROMETROS	1	T1
	2	T3		2	T1B
	3	T2B		3	T2
MICROFONOS	1	T2	MICROFONOS	1	T2B
	2	T1B		2	T3
	3	T1		3	T3B

Figura 18: Salidas de cada sensor.

Para hacer más exhaustiva la tabla, vamos a capturar los arranques y paradas de la bomba, grabaremos la detención y arranque de la misma para ver si es posible dictaminar desde el arranque cualquier anomalía en la bomba, por lo que se marcará aquellas grabaciones con arranque en frío, o arranque y parada.

La disposición de los tres micrófonos se realiza en el mismo plano y con una separación entre ellos y los acelerómetros colocados en cada eje de la bomba. Para su sujeción se ha usado cinta americana y elásticos, con los que se fijan los sensores, como se ve en la siguiente figura:



Figura 19: Sistema captador de audio y vibraciones.

2.5 Base de datos obtenida

Una vez realizadas las pruebas y eliminadas las muestras erróneas podemos ver las grabaciones obtenidas, tanto para la normalidad como para la rotura, en las que es visible una señal periódica registrada en al menos dos micros (2 y 3), en cuanto los acelerómetros el más sensible será el acelerómetro 1 colocado justo en la entrada de agua.

En las siguientes figuras vemos la respuesta temporal.




Figura 20: Micrófonos en normalidad y sin rotura de álabe




Figura 21: Acelerómetros en normalidad y sin rotura de álabe




Figura 22: Micrófonos con rotura de álabe.




Figura 23: Acelerómetros con rotura de álabe

Para apreciar mejor los resultados se ha pasado al análisis espectral, donde se observa las frecuencias donde más energía se produce. Mirando los gráficos obtenidos:




Figura 24: acelerómetro a3 normal.




Figura 25: Acelerómetro 3 con aspas rotas




Figura 26: Acelerómetro 2 en estado normal.




Figura 27: Acelerómetro 2 con aspas rotas.




Figura 28: Acelerómetro 1 en estado normal.

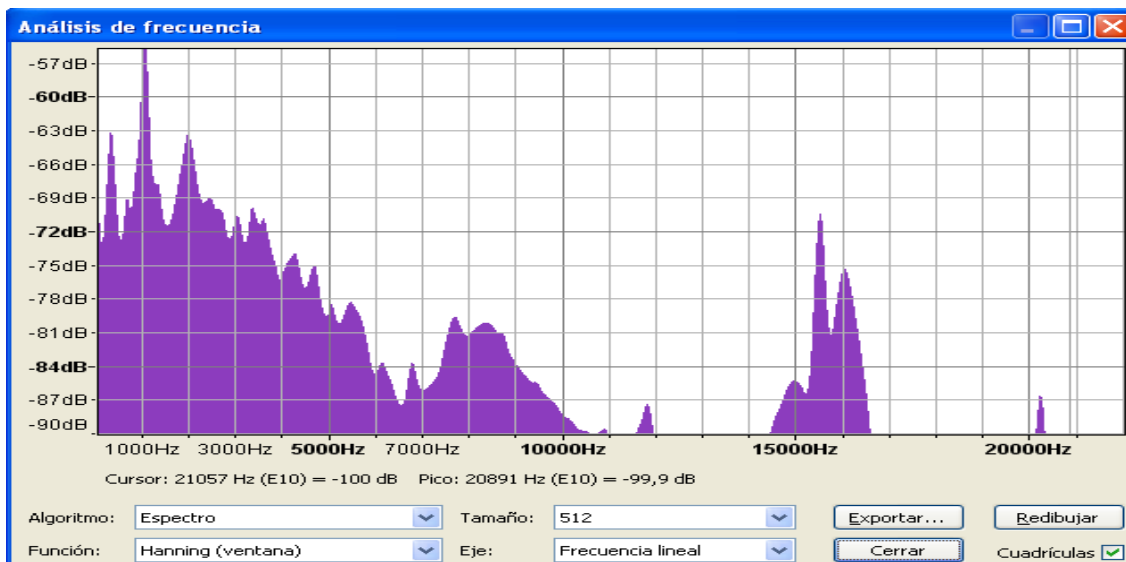


Figura 29: Acelerómetro 1 con aspas rotas.

Como se puede ver en los espectros se presentan tonos y variación de la energía en lóbulos de altas frecuencia, en las roturas.

Al terminar toda la experimentación para la creación de esta base de datos se ha llegado a un total de 208 sesiones, o 52 horas de grabaciones, repartidas en clases de tal manera:

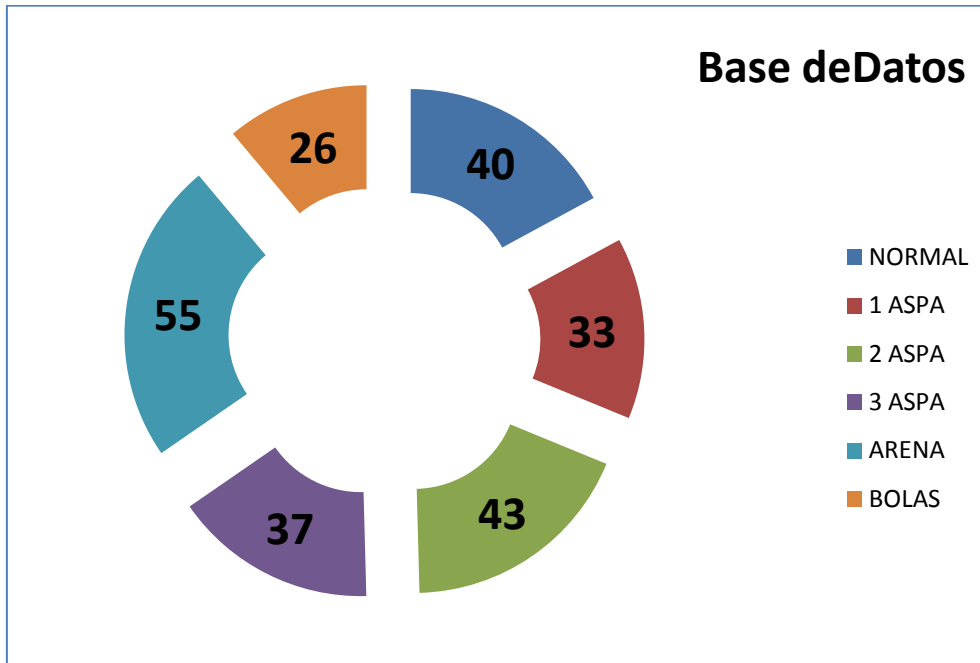


Figura 30: Sesiones por clase.

2.5.1 Fallos producidos en la base de datos

Las grabaciones se han realizado en una cámara acústica, no obstante, durante las grabaciones se han producido fallos. Estos fallos pueden ser detectados al escuchar o ver el espectro de la señal de forma inmediata, como se ve en la Figura 31. Normalmente un golpe en el micrófono o el sonido de pisadas es audible y visible en el espectro, además en un acelerómetro es más fácil de observar, una caída accidental del acelerómetro, ya que se ve una disminución de la amplitud de la señal. Para eliminar estos problemas se revisa cada grabación y se anota cualquier incidencia en la hoja de control

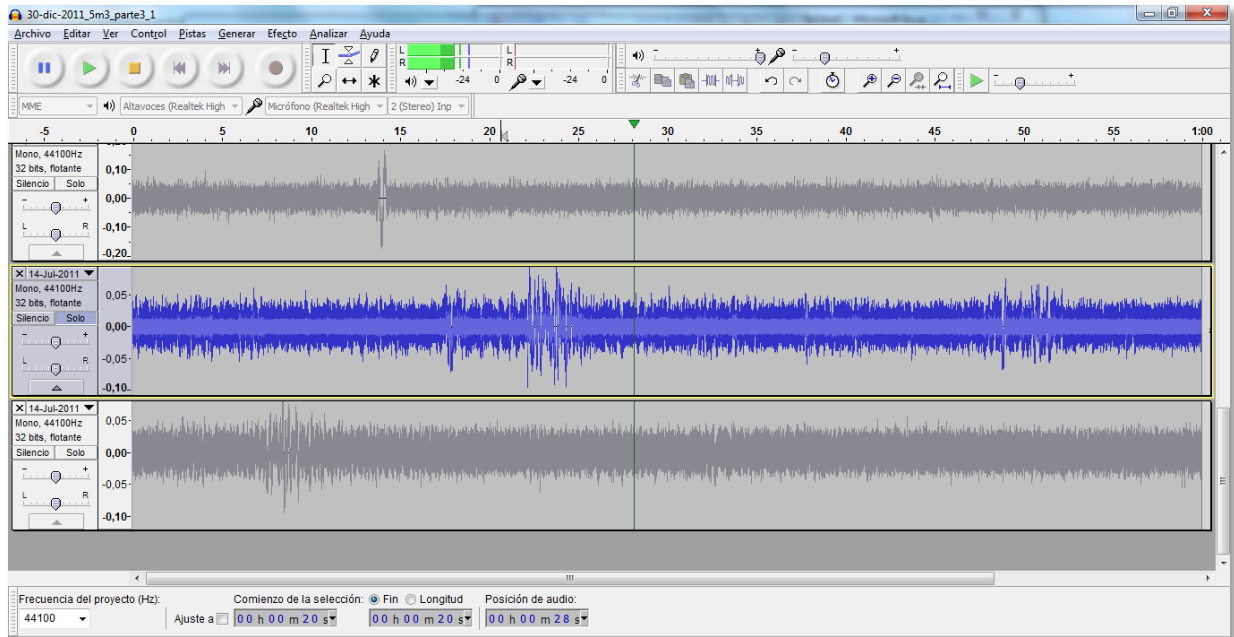


Figura 31: Señales con pequeñas anomalías.

Así pues podemos distinguir estos problemas:

- **El viento:** producido por la bomba al girar su alabe crea un sonido característico audible podemos atenuarlo separando el micrófono de la bomba. O variando el ángulo de apuntamiento a la bomba.
- **Vibraciones por caídas o impactos:** El acelerómetro al caer contra el suelo o impactar contra la bomba quedándose colgado, produce un aumento de energía en un punto determinado, prácticamente un delta y posteriormente la señal se atenúa. Al terminar la grabación se comprueba que el acelerómetro esta caído. A veces elementos como cables o cintas por el viento golpetean produciendo una agrupación de deltas, las cuales se detectan rápidamente viendo la señal.
- **Cintas sueltas,** las cintas americanas usadas para adherir los acelerómetros pueden soltarse en las aristas, con el aire generado por las aspas estas aristas producen sonidos y golpes en los acelerómetros que desvirtúan la señal.

- Otro efecto relacionado puede ser que el acelerómetro **no se pegue bien** a la superficie, como por ejemplo, el acelerómetro situado a la entrada del agua paralelo al plano del suelo, al ver su espectro, podemos ver como la señal se desinfla, se reduce el área por lo que se sabe que el acelerómetro ha perdido contacto con la superficie.
- **Otros ruidos:** aunque el aula acústica se presuponga insonorizada las paredes pueden introducir ruidos de golpes, alarmas, etc.



Figura 32: Bomba en grabación.

Capítulo 3: Parametrización

Para el reconocimiento de patrones se hace necesaria la extracción de parámetros para la distinción de clases. Por ello una vez creada la base de datos, pasamos a la parametrización de la misma, donde extraemos los valores que nos aporten información.

Como ya ha sido mencionado, en este PFC, se usa una bomba de agua circuladora de la cual se obtienen señales de vibración y de audio.

En diagnóstico de fallos en maquinaria y en especial en bombas de agua, se han extraído diversos parámetros de la señal en el tiempo, usando técnicas de transformada de Fourier, espectrogramas. En concreto, para nuestro proyecto usaremos la transformada de wavelet, donde cabe el análisis de multiresolución y a partir de los coeficientes que nos da tomaremos valores estadísticos como la media, Curtosis y varianza.

3.1. Evolución en la parametrización

Para el tratamiento de señales normalmente se suele utilizar la transformada de Fourier con buenos resultados si estamos tratando con señales periódicas y regulares. Siendo la función a descomponer una señal dependiente del tiempo, las funciones de la base de Fourier son de duración infinita en el tiempo, pero locales en frecuencia. De

esta forma, la transformada de Fourier detecta la presencia de una determinada frecuencia pero no brinda información acerca de la evolución en el tiempo de las características espectrales de la señal. Muchos aspectos temporales de la señal, tales como el comienzo y el fin de una señal finita y el instante de aparición de una singularidad en una señal transitoria, no pueden ser analizados adecuadamente por el análisis de Fourier.[30].

Para los casos de señales no estacionarias y transitorias se utiliza generalmente la transformada de Fourier con Ventana, que realiza un análisis espectral dependiente del tiempo. Consiste en dividir una señal no estacionaria en una serie de segmentos de tiempo en los cuales la señal puede ser considerada cuasi-estacionaria y aplica la transformada de Fourier a cada segmento local de la señal. Gabor, en 1940, fue el primero en introducir la transformada de Fourier de tiempo corto, conocida como la transformada de Fourier con Ventana Deslizante. Con ello se logra una mejor localización de la aparición de una singularidad en una señal. Pero solo se conocerá en qué intervalo de tiempo se produce la singularidad, debido a que la localización depende del ancho de la ventana. Además, los eventos no podrán ser resueltos si aparecen muy cerca unos de otros, ya que no será posible distinguir diferentes comportamientos dentro de una misma amplitud de ventana.

A mediados de los años 80 se empieza a desarrollar una herramienta matemática que permite resolver estos problemas, es la transformada Wavelet. [30.] Este tipo de transformada es capaz de concentrarse en fenómenos transitorios y de alta frecuencia mejor que la transformada de Fourier con Ventana ya que la transformada Wavelet tiene un tamaño de ventana adaptado a las frecuencias.

3.2. La transformada Wavelet

La transformada wavelet es una herramienta para el tratamiento de señales donde se producen fenómenos puntuales, consiguiendo una resolución ajustable y en la que se tiene en cuenta el tiempo y la frecuencia.

La cualidad para poder barrer más espectros así como señales no periódicas le dota de una capacidad amplia para el estudio de fenómenos irregulares.

Para la transformada wavelet tenemos un grupo de familias, llamadas madres, que servirán de patrón. Entre ellas están: Haar, Mexican hat, Daubechies, Morlet, Symmlet... estas combinadas con la señal original consiguen estudiar la señal bajo estudio con multiresolución.

Su representación continua es:

$$Cwt(a, b) = \frac{1}{\sqrt{|a|}} \int h\left(\frac{x-b}{a}\right) \cdot f(x) \cdot dx; a, b \in R, a \neq 0 \quad Ecu.1$$

Donde a es la escala y b la traslación, ambos números reales y $f(x)$ es la función a analizar. La variable de escala a puede ser vista como $a = f/f_0$, donde f_0 , denota la frecuencia central de la wavelet.

Una forma sencilla de comprender el modo de operación de la transformada wavelet es pensar que la señal en base de tiempo es pasado por varios filtros pasabajos y pasoaltos, los cuales permiten separar trozos de señal de alta frecuencia de las de baja frecuencia.

Este procedimiento se repite cada vez sobre trozos de señal que han sido sacadas de la señal original.

De forma gráfica podemos ver en la siguiente figura 33, que hace la wavelet.

La Wavelet avanza por la señal y va tomando los coeficientes, que dan el grado de similitud de la wavelet con la sección de señal en observación, cuanto más alto valor de "C" mayor similitud. Una vez procesada la señal se repite los pasos anteriores pero variando la escala.

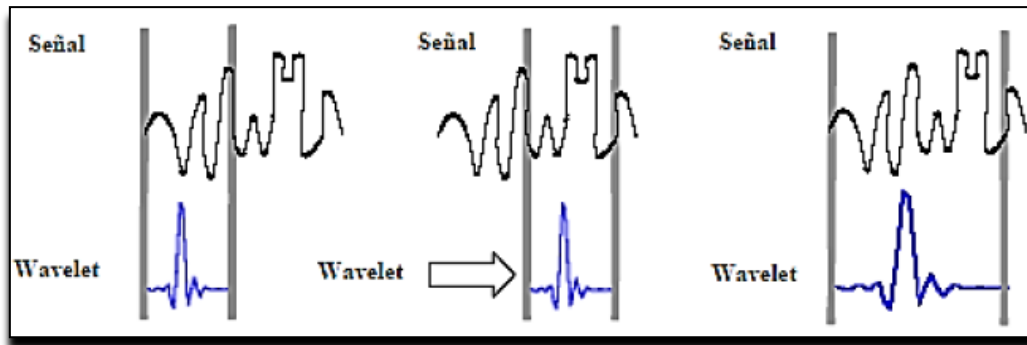


Figura 33: Proceso de obtención de coeficientes de wavelet.

Dentro de las familias madre encontramos muchas como se ha mencionado anteriormente pero para nuestro proyecto, usaremos las 'db' (Debauchies) y 'sym'(Symlets) , de orden 2, 6 y 9 respectivamente, estudiaremos las de mayor acierto, para realizar finalmente una herramienta lo más rápida posible en clasificar las señales de entrada y con los mejores resultados.




Figura 34: Wavelets más utilizadas.

3.2.1. Usos

Dentro de los usos de esta herramienta podemos nombrar, además del análisis local de señales no estacionarias, el análisis de señales electrocardiográficas, sísmicas, de sonido, de radar, así como también es utilizada para la compresión y procesamiento de imágenes y reconocimiento de patrones. Además tiene usos de anulación de ruidos, control de procesos. [28] [29] [30].

3.3. Transformada wavelet discreta

Para aplicar la transformada wavelet a una serie de datos, aplicamos la transformada discreta. Fue desarrollada por Mallat en 1988, quien diseñó un algoritmo basado en un banco de filtro que permite obtener una transformada Wavelet en forma instantánea a partir de los datos de interés.[31].

Filtros de un nivel

En una señal, las componentes de baja señal suelen ser la que más información de la misma tiene, mientras que sus componentes en alta le dan características más particulares. Por lo que se dividen las componentes de una señal en dos categorías:

- Aproximaciones: (baja frecuencia).
- Detalles: (alta frecuencia).

De tal forma que quedaría.




Figura 35: Diagrama de descomposición de señales.

Donde “**S**” es la señal de estudio, “**A**” los coeficientes de aproximación y “**D**” los de detalles. La suma de la salida de A y D, es “**S**” los filtros deben ser diseñados para que no se pierda la información. La única desventaja de este proceso es que se aumenta al doble el número de datos originales, lo que conlleva un costo computacional y matemático, por lo que se obliga a un proceso de submuestreo, como se ve en la figura 37.

Filtros multiniveles

Para señales de mayor complejidad, no basta con dos banda de frecuencias, por lo que iteramos el proceso de filtrado de forma tal como se ve en la figura.

Teniendo la parte de más baja frecuencia la cA_3 , y la cD_1 la de más alta frecuencia. Al descomponer en más bandas de frecuencia se posee una información más detallada acerca de S , por lo que esta forma se conoce como multiresolución.




Figura 36: Árbol de descomposición de wavelet.

3.3.1. Wavelet Packet transform

Es una variación de la Transformada Wavelet Discreta (DWT). Con la DWT se descompone la señal analizada en una serie de señales restringidas a ciertas bandas de frecuencia que forman una base del espacio de funciones, cumpliendo con propiedades como ortogonalidad, tamaño, localización y suavidad. La DWT busca obtener una representación tiempo-escala de una señal discreta. La descomposición se realiza a partir de funciones más complejas, en las cuales no se varía la frecuencia sino su posición y su escala temporal.

La transformada de wavelet por paquetes, descompone iterativamente no solo los coeficientes de aproximación de la etapa anterior sino que también los de detalles, lo que da lugar a una estructura de árbol, como se ve en la figura 38.

Está claro que la utilización de los paquetes Wavelet propicia información que con la DWT no estaba disponible, información que puede incluir características discriminantes y facilite labores de clasificación. El contar con un mayor volumen de información también representa una desventaja frente a la Transformada Wavelet Discreta, porque se incrementa el costo computacional. Para disminuir los efectos de este fenómeno, se utilizan el algoritmo del *Mejor Árbol (Best Tree)*, el cual identifica los nodos que contienen la información más relevante, valorando la entropía en cada uno de ellos con funciones o parámetros de cálculo.

Partiendo de una señal, dos grupos de coeficientes son analizados: de aproximación y de detalle. Esos vectores son obtenidos convolucionando con filtros pasos bajos y altos como se ve en la figura 37:

más precisamente el primer paso es:

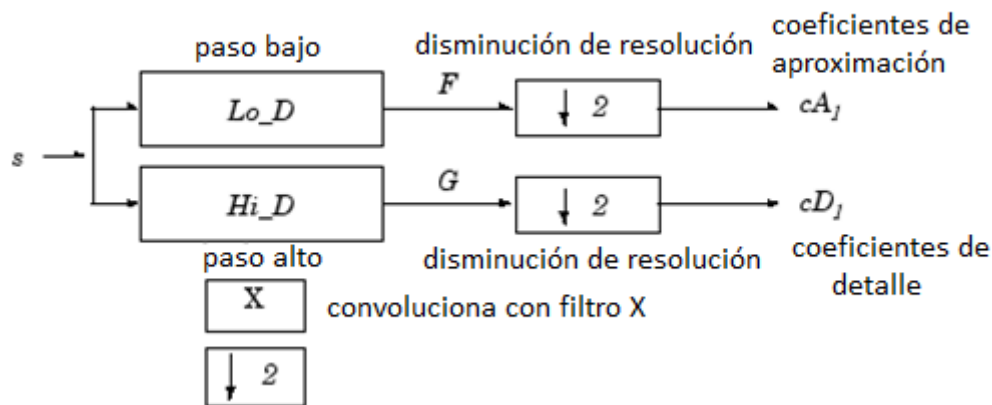


Figura 37: Esquema del algoritmo usado.

Cada nivel de descomposición tiene la mitad del ancho de banda del nivel anterior y este ancho de banda está distribuido entre la señal de salida del filtro pasabajos y la señal de salida del filtro pasa alto, teniendo en cada nodo coeficientes de aproximación y de detalle.

De forma recursiva se va sacando los valores que formarán el árbol.

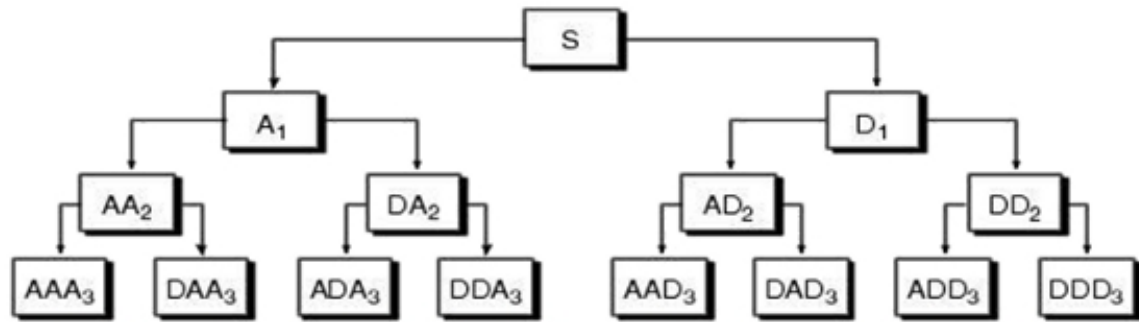


Figura 38: Árbol de descomposición de coeficientes wavelet hasta nivel 3.

El programa Matlab cuenta con una herramienta propia: wavefun, una GUI que nos da un menú de selección de distintas madres, niveles de descomposición, etc... ; No obstante, no es objetivo de este proyecto la parametrización de wavelet a fondo, pero de forma testimonial representamos la descomposición del árbol de una señal de muestra, de un minuto. En la figura 40 se aprecian los coeficientes de aproximación y de detalle.

3.3.2. Elección del nivel de descomposición y número de nodos para cada sensor

Antes de empezar a descomponer debemos hacer un estudio de nuestras necesidades para la elección de los nodos [31].

Para bajar el volumen de datos se submuestra realizando un diezmado de factor 2

La bomba trabaja a 2925 rpm, por lo que la frecuencia del rotor es 48.75 Hz. Por lo tanto la frecuencia de rotación de las aspas es $48.75 \times 7 \text{ aspas} = 341.25 \text{ Hz}$.

En la tabla se muestra diferentes niveles de descomposición y el número de nodos asociado a cada nivel, el rango de frecuencias que tiene cada nodo (el ancho de banda A.B.) teniendo en cuenta que la frecuencia de muestro es 22050 Hz y por lo tanto la frecuencia de máxima a la que llegará el último nodo es hasta 11025Hz (el ancho de banda que es capaz de captar un muestreo hecho a 22050Hz). Al final de la tabla se muestra el último nodo con información teniendo en cuenta los diferentes anchos de banda de los sensores.

Nivel descomposición	Número de nodos	A.B. nodos	Último nodo con información		
	(2^nivel descomposición)	(fs=22050 Hz, fn = 11025Hz)	Micrófonos	Acelerómetros tipo 1	Acelerómetro tipo 2
			(hasta 20000Hz pero diezmo y me quedo con 11025Hz)	(hasta 10kHz)	(hasta 2.6kHz)
5	32 (2 ⁵)	344.5313 Hz	32 (11025Hz)	32 (11025Hz)	8 (2756, 25045Hz) 7 (2411,7191Hz)
6	64	172.2656 Hz	64 (11025Hz)	64 (11025Hz)	16 (2756,4965Hz) 15 (2583,9841Hz)
7	128	86.1328 Hz	128 (11025Hz)	128 (11025Hz)	32 (2756,4965Hz) 30(2583,984Hz)
8	256	43.0664 Hz	256 (11025Hz)	256 (11025Hz)	64 (2756.2496Hz) 60 (2583.984Hz)
9	512	21.5332 Hz	512 (11025Hz)	512 (11025Hz)	128 (2756.2496Hz) 120 (2583.984Hz)

Tabla 3: Selección de nodos.

Se elige el nivel de descomposición 8 (que tiene 256 nodos en total), en el cual los nodos tienen un A.B. de unos 43 Hz (similar a la frecuencia de rotación de las aspas). Se cogerían los 256 nodos completos para el caso de los micrófonos y del acelerómetro tipo 1 y 64 nodos en el caso del acelerómetro tipo 2 puesto que la información que capta este acelerómetro llega hasta los 2.6kHz.

3.3.3. Familias usadas

Para la realización de este proyecto usaremos las wavemadres, Symlets y las Daubechies, 3 ,6 y 9 respectivamente:




Figura 39: Wavelets utilizadas.

A medida que el número de la wavelet es más alto vemos como tiene un comportamiento menos suave presentando más picos y oscilaciones.




Figura 40: Nodos extraídos de una muestra.

3.3.4. Parámetros estadísticos

Una vez tomados estos coeficientes, tomamos valores estadísticos de los mismos coeficientes, para su posterior estudio y entrenamiento, entre los que inicialmente tenemos:

- Media: El promedio de todos los números, calculado como la sumatoria de todos los valores dividido por el número de muestras. En este trabajo, su valor se obtiene a través de la función *mean()* de Matlab.

$$\tilde{x} = \frac{\sum_0^N(x_i)}{N} \quad \text{Ecu.2}$$

Donde N es el número total de muestras y x cada muestra.

- Varianza: La varianza es la media aritmética del cuadrado de las desviaciones respecto a la media de una distribución estadística. En este trabajo, su valor se obtiene a través de la función *var()* de Matlab.

$$\sigma^2 = \frac{\sum_1^n(x_i - \tilde{x})^2}{N} \quad \text{Ecu.3}$$

- Curtosis: Este parámetro analiza el grado de concentración que presentan los valores alrededor de la zona central de la distribución. Se obtiene a partir de la fórmula: En este trabajo, su valor se obtiene a través de la función *kurtosis()* de Matlab.

$$\beta_2 = \frac{\mu_4}{\sigma^4} \quad \text{Ecu.4}$$

$$g_2 = \frac{\frac{1}{n} * \sum(x_i - \tilde{x})^4 * n_i}{(\frac{1}{n} * \sum(x_i - \tilde{x})^2 * n_i)^2} - 3 \quad \text{Ecu.5}$$

- Desviación Estándar: La desviación estándar o desviación típica es la raíz cuadrada de la varianza. Es decir, la raíz cuadrada de la media de los cuadrados de las puntuaciones de desviación. La desviación estándar se representa por σ . Es una medida de dispersión para variables de razón (variables cuantitativas o cantidades racionales) y de intervalo. Se define

como la raíz cuadrada de la varianza de la variable. En este trabajo, su valor se obtiene a través de la función *std()* de Matlab.

$$\sigma = \sqrt{\frac{\sum_{1}^{N} x^2 - \tilde{x}}{N}} \quad \text{Ecu.6}$$

- **RMS(Raíz De La Media Al Cuadrado):** Se define como la raíz cuadrada de la media aritmética de los elementos al cuadrado. La media cuadrática (RMS) es ampliamente utilizada para el cálculo de la media de un conjunto de números con las alternancias de cantidades con valores positivos y negativos. Una de las aplicaciones de los valores RMS es con las alternancias de las corrientes y tensiones. Otro uso común es la medida de potencia de equipos de audio. En este trabajo, su valor se obtiene a través de la función *RMS()* de Matlab.

$$X_{RMS} = \sqrt{\frac{\sum_{0}^{N} (xi)^2}{N}} \quad \text{Ecu.7}$$

- **Factor De Cresta:** es igual a la amplitud del pico de la forma de onda dividida por el valor RMS. El propósito del cálculo del factor cresta es dar al analista una rápida idea de que tanto impacto está ocurriendo en la forma de onda.

$$F.C. = \frac{1}{X_{RMS}} \quad \text{Ecu.8}$$

- **Máximo:** Valor máximo de la señal.
- **Mínimo:** Valor mínimo de la señal
- **Asimetría:** Para obtener información acerca de la simetría de la distribución, calculamos el coeficiente de asimetría de Pearson, que es una medida de los datos alrededor de la media. Si tiene valor negativo, los datos se distribuyen más

hacia la izquierda de la media. Si es positivo, los datos se distribuyen más hacia la derecha de la media. En una distribución normal o en cualquier distribución perfectamente simétrica este valor es cero. Se obtiene a partir de la fórmula:

$$\gamma_1 = \frac{\mu^3}{\sigma^3} \quad \text{Ecu.9}$$

$$g_1 = \frac{\frac{1}{n} * \sum(x_i - \tilde{x})^3 * n_i}{\left(\frac{1}{n} * \sum(x_i - \tilde{x})^2 * n_i\right)^{\frac{3}{2}}} \quad \text{Ecu.10}$$

Las ecuaciones anteriores hacen referencia a la definición de coeficiente de asimetría de Fisher y su estimador, respectivamente. En este trabajo, su valor se obtiene a través de la función *skewness()* de Matlab.

- Factor Impulso: definido como el máximo de la señal entre la media.

$$F.I. = \frac{Max(x)}{\tilde{x}} \quad \text{Ecu.11}$$

- Factor Shape: definido como el valor RMS entre la media.

$$F.S. = \frac{X_{RMS}}{\tilde{x}} \quad \text{Ecu.12}$$

3.4. Metodología

Para nuestro proyecto contaremos con el paquete de Matlab “Wavelet Toolbox”, de donde sacaremos unos parámetros de estudio, evidentemente no usaremos la transformada de wavelet continua sino la discreta que viene a ser una versión muestreada de la continua. En concreto, la wavelet packet transform.

En nuestro proyecto nos hemos basado en una función del programa Matlab, mediante la llamada “*wpdec*”; en la que le se ha pasado la señal bajo estudio, el nivel de descomposición que deseamos y la wavelet madre con la que la se va a analizar. El resultado es el árbol de coeficientes descompuestos en N niveles (en nuestro caso 8).

De tal forma que tras la descomposición de un archivo de audio en árbol tenemos:

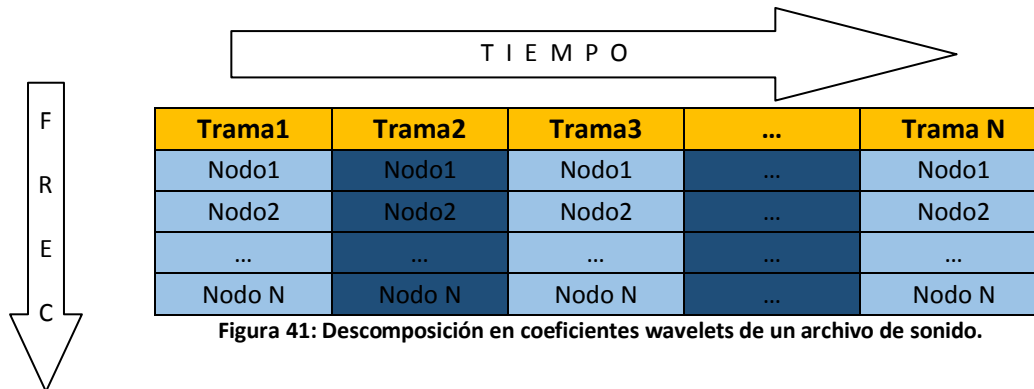


Figura 41: Descomposición en coeficientes wavelets de un archivo de sonido.

Donde N es la última trama, este valor viene determinado por el solape y el tiempo de ventana. Cada nodo contiene los coeficientes de wavelets, a los que se le aplica una función estadística.

Trama1	Trama2	Trama3	...	Trama N
E(Nodo1)	E(Nodo1)	E(Nodo1)	...	E(Nodo1)
Var(Nodo1)	Var(Nodo1)	Var(Nodo1)	...	Var(Nodo1)
Curtosis(nodo1)	Curtosis(nodo1)	Curtosis(nodo1)	...	Curtosis(nodo1)
...
E(Nodo1)	E(Nodo1)	E(Nodo1)	...	E(Nodo1)
Var(Nodo1)	Var(Nodo1)	Var(Nodo1)	...	Var(Nodo1)
Curtosis(nodo1)	Curtosis(nodo1)	Curtosis(nodo1)	...	Curtosis(nodo1)

Figura 42: Descomposición en funciones estadísticas de un archivo de audio

Como se explicará en el capítulo de la metodología del estudio, inicialmente se cuenta con 17 parámetros, que serán reducidos a 3, a pesar del acierto entorno al 80-90%, en los estudios preliminares.

Y los parámetros a considerar serán:

- Media.
- Varianza.

- Curtosis

Lo que consigue reducir el tiempo de creación de matrices de coeficientes, dejando matrices más manejables, tanto en tamaño, tiempo de computación, entreno de modelos y testeo de los mismos.

Por lo que tomando la varianza de cada nodo, siendo estos 256 y 3 parámetros por cada nodo nos salen un vector de $3 \times 256 = 768$ parámetros.

Más adelante en el capítulo de simulador, bajaremos a un solo parámetro para facilitar el testeo de modelos, necesario para dar una respuesta rápida a la petición de clasificación.

Capítulo 4: Clasificador

4.1. Introducción

Una vez extraídos los parámetros que caracterizan al sistema, pasamos a la creación de un **clasificador** que nos permitirá estimar la relación: entre el modelo y las señales captadas por los sensores. Esta semejanza se toma del “score” que se obtiene al realizar una comparación entre el modelo y la señal de entrada. El esquema de obtención del mismo es tal como sigue en la figura.

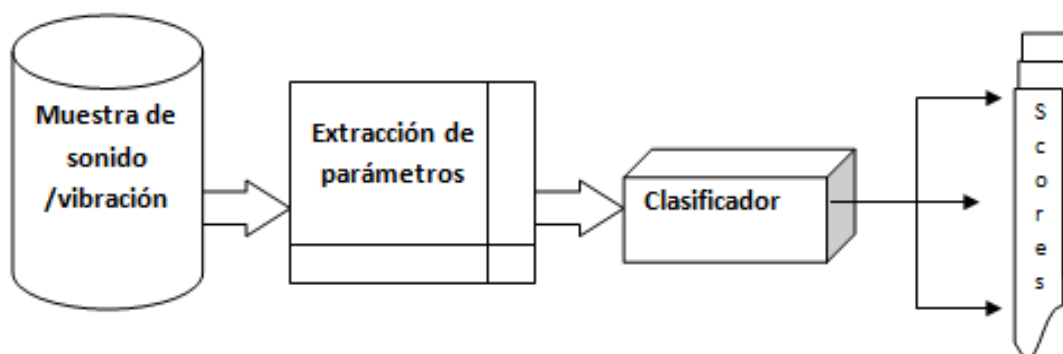


Figura 43: Esquema de un Clasificador.

No obstante, para crear este clasificador hará falta crear los modelos que lo componen, los cuales serán a partir de un proceso de entrenamiento como veremos.

Para nuestro proyecto usamos clasificadores de máquinas de vectores de soporte, las cuales son algoritmos de aprendizaje supervisado, es decir, los resultados finales son sabidos, por los que se les entrena, sabiendo a priori, que resultado queremos. Su uso

está motivado por la capacidad de crear un clasificador multiclase, mediante la combinación de varias biclase y la sencillez de su implementación. [36].

4.2. Clasificadores SVM

Las Maquinas de Vectores Soporte, en inglés, Support Vectors Machine, fueron desarrolladas inicialmente por V.C.Vapnik para el problema de la clasificación de datos separable. Más tarde se mejoraron para manejar datos no separables y para resolver el problema de la regresión.[39]

Si dado un conjunto de puntos (D), en el que hay varios subconjuntos de dos posibles categorías, estos puntos se pueden separar como un plano, la SVM busca un hiperplano que separa ambas categorías, no obstante, pueden existir varios hiperplanos, la pregunta sería cual es el mejor.

Surge aquí el concepto de margen, que sería la distancia que hay entre los puntos de las distintas categorías y el hiperplano que los separa.

La idea esencial, intuitiva, de las SVM es elegir el hiperplano que tenga el mayor margen M entre las dos clases. En otras palabras, la distancia de los ejemplares de entrenamiento más cercanos de cada clase al hiperplano de máximo margen (en adelante, simplemente el hiperplano) es la mayor posible (y es la misma para la dos clases. La definición de estos planos creados por puntos que separan las clases son llamados vectores de soporte. Estos se representan así:

$$h(x) = W^T \cdot x + b = 0$$

Ecu.13

Donde W es un vector perpendicular al plano $w, x \in \mathbb{R}^d, b \in \mathbb{R}$




Figura 44: Conjunto de puntos de dos clases y vectores de soporte.

Como se busca un hiperplano que clasifique correctamente a todos los ejemplares $x_i \in D$, se pueden definir las siguientes restricciones.

$$\forall x_i \in D : \begin{cases} h(x_i) > 0 & \text{si } y_i = 1 \\ h(x_i) < 0 & \text{si } y_i = -1 \end{cases} \quad \text{Ecu.14}$$

Como el signo de y_i , indica el tipo de desigualdad, se pueden combinar ambos casos como:

$$\forall x_i \in D \quad h(x_i) y_i > 0 \quad \text{Ecu.15}$$

De manera informal, se puede especificar el problema asumiendo una función $M =$ margen que calcule el tamaño del margen entre un hiperplano y un conjunto de ejemplares D . Este margen puede ser menos riguroso o más (márgenes suaves o duros) según queramos “perdonar” pequeños fallos cuando linealmente no son separables los puntos.

Parece una forma simple de separar los grupos pero normalmente los puntos no suelen estar tan separados, sobre todo cuando hay más de una clase en el sistema.




Figura 45: Representación de dos parámetros de la bomba de agua.

4.2.1. SVM: Funciones Kernel

Como se ve en la figura 44, a priori parece que la separación mediante una línea es la más fácil, pero: ¿y qué pasa cuando no se puede separar, como en la figura 45?.




Figura 46: Clasificadores no lineales y transformación a lineal.

En este punto surge el concepto de kernel, éste es una función ϕ , que puede llevar el problema a un espacio donde los puntos sean linealmente separables y clasificables utilizando el hiperplano SVM.

Tal kernel puede ser:

- Lineal: Este kernel es una transformación lineal del tipo: $K(x_i, x_j) = \|x_i - x_j\|$.
- Polinomial-homogénea: $K(x_i, x_j) = (x_i \cdot x_j)^n$
- Funciones de Base Radial o gaussiano: $K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / \sigma^2)$
- Sigmoide: $K(x_i, x_j) = \tanh(x_i - x_j - \theta)$

Donde solo cambia la función de transformación de un espacio a otro, según el tipo de problema.




Figura 47: Transformación a otro espacio con Kernel RBF o gaussiano.




Figura 48: Datos inseparables en 2-D y separables en 3-D.




Figura 49: Función sigmoidea.

Dentro de las SVM hay varios tipos según busquemos la clasificación (SVC) o regresión (SVR).

Las SVC ataca el problema de clasificación no separable relajando el concepto de margen, para lo que introduce variables ε_i , en la restricción del error.

Dentro de las SVC tenemos:

- Multiclase:
 - Uno contra uno:
 - Se construyen $k(k-1) / 2$ clasificadores cada uno entrena datos de dos clases diferentes.
 - Se usa la estrategia de votación para clasificar: cada clasificador binario se considera.
 - Uno contra el resto:
 - Se entrenan k clasificadores (una clase es la positiva y el resto la negativa).
 - Se predice la clase para todos los clasificadores.
 - La clase asignada es aquella con la que se consiguió mayor margen (en el caso en que se clasifique como positiva en más de un clasificador).

La SVR parte de los mismos principios que la máquina de vectores soporte para clasificación. En este caso, se trataría de estimar una función lo más sencilla posible que aproxime los datos de entrenamiento con el menor error. La función de coste propuesta originalmente para el problema de regresión mediante máquinas de vectores soporte es la conocida como ε -Vapnik o ε -insensible. Esta función de coste admite, sin ninguna penalización, una desviación máxima ε de la función $f(x)$ respecto a los datos de entrenamiento.

4.3. LS-SVM

El método de **Mínimos Cuadrados SVM**, es una forma alternativa de la SVM [38] para identificación; la ventaja que tiene en comparación con los métodos ϵ insensitive y cuadrático es que la solución del problema se realiza a través de un conjunto de ecuaciones. Este método puede tratar una cantidad más considerable de datos de entrenamiento y presenta muchos usos.[32][33][39][40].

Dado un conjunto de entrenamiento $\{x_i, y_i\}$ con $i=1\dots n$, $x \in \mathbb{R}^n$, $y \in \mathbb{R}$. Como decíamos antes si tomamos el modelo de la SVM como:

$$f(x) = \sum_{i=1}^n w_i \phi_i(x) + b \quad \text{Ecu.16}$$

Donde ϕ es la función que transporta el espacio de los valores a otro superior.

En el método LS-SVM se plantea el siguiente problema de minimización [39]:

$$\text{mín } J(w, \varepsilon) = \frac{1}{2} \|w\|^2 + \frac{c}{2} \sum_{i=0}^l \varepsilon_i^2 \quad \text{Ecu.17}$$

Con: $y_i - \langle w \cdot \phi(x_i) \rangle = \varepsilon_i$

El Lagrangiano está dado por:

$$L(w, b, \alpha, \varepsilon) = \frac{1}{2} \|w\|^2 + \frac{c}{2} \sum_{i=0}^l \varepsilon_i^2 - \sum_{i=0}^l \alpha_i^2 \langle w \cdot \phi(x_i) \rangle + b + \varepsilon_i - y_i \quad \text{Ecu.18}$$

Donde α_i son los multiplicadores de Lagrange. Calculando las derivadas parciales del Lagrangiano, con respecto de todas las variables e igualando a cero podemos obtener las condiciones de optimización, esto es debido a que la función es convexa.

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{i=1}^l \alpha_i \phi(x_i) \quad \text{Ecu.17}$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow w = \sum_{i=1}^l \alpha_i = 0 \quad \text{Ecu.18}$$

$$\frac{\partial L}{\partial \varepsilon} = 0 \rightarrow \alpha_i = C \varepsilon_i \quad \text{Ecu.19}$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow y_i = \langle w \cdot \phi(x_i) \rangle + b + \varepsilon_i \quad \text{Ecu.20}$$

Eliminando w y ε y utilizando la función kernel, obtenemos el siguiente sistema de ecuaciones lineales:

$$y_i = \sum_{i=1}^l \alpha_i \phi(x_i) \phi(x_i) + b + \frac{\alpha_i}{C} \quad \text{Ecu.21}$$

$$\sum_{i=1}^l \alpha_i = 0 \quad \text{Ecu.22}$$

$$\begin{bmatrix} 0 & 1^T \\ 1 & K + \frac{1}{C} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad \text{Ecu.23}$$

Donde $y = [y_1 \dots, y_l]^T$, K la matriz del kernel, y b y α los valores estimados. Entonces el vector $1 = [1; \dots 1]^T$. Dado este sistema de ecuaciones 23, el modelo utilizado por el método LS-SVM se expresa de la siguiente forma:

$$\hat{f}(x) = K(x, x_i) \alpha + b \quad \text{Ecu.24}$$

Nótese que este método no requiere de la determinación del parámetro de precisión ϵ el cual esta relacionado con la función de costo ϵ -insensitive del método propuesto por Vaptnik [41]. La gran desventaja de este método es que las soluciones α_i se desvanecen en la solución óptima, por ende el modelo depende de todos los datos de entrenamiento [37].

4.4. Metodología.

Para nuestro proyecto nos apoyaremos en un paquete de programas de Matlab, "LSSVMlabv1_8" para el desarrollo del clasificador.

Deberemos dividir la tarea a realizar en dos:

- **Entrenamiento:** Se ha tomado los vectores de características y les añadimos los scores que corresponden, para el aprendizaje supervisado, estos crean un modelo de forma óptima con los umbrales mejores para la detección del mismo.
- **Testeo:** Se ha tomado archivos no usados en el entreno para lanzarlos contra el modelo de forma que el modelo determina el score.

Este clasificador será del modo uno contra todos, para las 6 clases definidas anteriormente y las funciones a usar:

- Initlssvm.
- Tunelssvm.
- Trainlssvm.
- Simlssvm.

Que serán las encargadas de preparar el modelo, entrenarlo y simularlo.

Su proceso consiste en los siguientes pasos:

1. Se inicia la estructura de objeto orientado que representan el modelo Ls-SVM.
2. Se ajustan los hiperparámetros del modelo con respecto a la medida del rendimiento dado.
3. Se entrena los vectores de características y el sesgo del LS-SVM para la clasificación.
4. Se simula con el modelo entrenado.

Su esquema será:

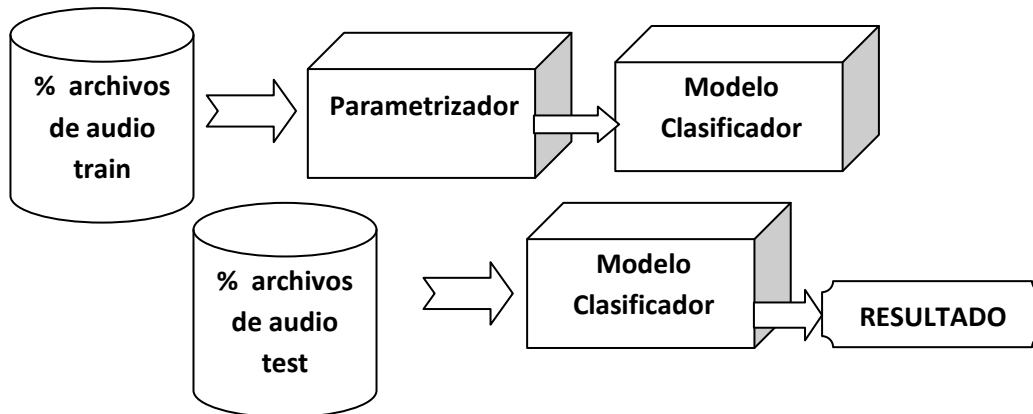


Figura 50: Esquema de clasificación: Entrenamiento/Test.

En el proceso de clasificación cada entrada se compara con cada clase dando un vector de salida con valores positivos y negativos. La clase que el modelo nos da será aquella con el valor positivo más alto.

Por ejemplo, si tuviéramos un archivo de audio de clase 5 (bolas) a la entrada de nuestro clasificador ya entrenado, el resultado de la clasificación sería:

Ytest:

-0.7455	-0.4340	-1.1310	-0.7578	-0.8878	0.145
<i>Clase 0</i>	<i>Clase 1</i>	<i>Clase 2</i>	<i>Clase 3</i>	<i>Clase 4</i>	Clase 5

Donde 0,145 es el valor positivo más alto. En caso de que todos los valores sean negativos, el modelo dirá que no es clasificable el vector dando como resultado el valor –“Inf”.

Ytest:

-0.8114	-0.3623	-0.9477	-0.9475	-0.9378	-0.9876
<i>Clase 0</i>	<i>Clase 1</i>	<i>Clase 2</i>	<i>Clase 3</i>	<i>Clase 4</i>	Clase 5

Los resultados de las clasificaciones están en el capítulo de resultados y dan un sistema fiable y robusto, como también se ve en [34][35][36].

Capítulo 5. Metodología del estudio

5.1 Introducción

Para la realización de este proyecto se ha realizado una experimentación con la bomba de agua al objeto de tener un repositorio de grabaciones con las que diseñar un modelo y un clasificador.

El estudio realizado en este proyecto ha consistido en el procesado de los valores, recogidos por los sensores, su parametrización, la creación de un modelo y por último lograr un clasificador que discrimine las clases que se le han caracterizado.



Figura 51: Tanque de experimentación. Bomba de experimentación y sensores.

Para la experimentación contamos, como se ve en las figuras anteriores, con una bomba en circuito cerrado, unos sensores: micros, acelerómetros y un sistema de captación de audio y vibraciones (fig.15).

5.2 Extracción de características

La extracción de características o parametrización consiste en la transformación de la señal, bajo estudio, en un conjunto de vectores de características.

El objetivo de esta transformación es obtener una nueva representación que sea más compacta, menos redundante y más adecuada para posteriormente aplicarle el modelo estadístico y para el cálculo de resultados o scores.

En el presente proyecto realizaremos una experimentación para obtener un clasificador óptimo, que cuente con un gran acierto, en torno al 90% o más y que sea rápido, veraz y gran exactitud.

En los siguientes apartados se explican los métodos usados hasta encontrar un sistema con respuesta inmediata.

5.3 Experimentación

Los experimentos realizados están enfocados en primer lugar a determinar que parámetros y familias son las que generan una mejor respuesta.; en segundo lugar, a determinar qué tiempo de ventana da una mejor respuesta y por último a desarrollar un sistema que según reciba los archivos de audio, tome tramas del mismo y clasifique el sistema con un modelo pre-cargado dando una respuesta inmediata (sistema ON-LINE).



Figura 52: Experimentación y búsqueda de modelo óptimo.

5.3.1 Sistema “OFF-LINE”

Un sistema **Off-Line** es un sistema de clasificación en varias etapas donde la entrada no da una respuesta inmediata a la salida, sino que lo hace en varios pasos.

En primer lugar se **parametriza** los archivos de audio para obtener unos **vectores de características**, seguidamente se guardan para **una posterior creación de modelo** estadístico y por último se determina el desempeño del **clasificador** realizado con el modelo anterior.

Para nuestro proyecto, en la parametrización tendremos en cuenta las siguientes características:

- Ventana De Tiempo: 500ms, 400ms, 200ms.
- Familias: db2, db6, db9, sym2, sym6, sym9.
- Parámetros estadísticos: Esperanza, varianza,...

Donde la ventana de tiempo es el tamaño de trama que se toma del archivo de audio a la entrada; las familias son las distintas wavelet utilizadas en el presente proyecto y los parámetros estadísticos son los valores que se toman de los coeficientes wavelet de cada nodo.

Hay que tener en cuenta que el modelo es sensible a todas estas características, ya que, **el tamaño de ventana** del entrenamiento, *creará más tramas* en el vector de

características resultante y **las familias** evidentemente afectan a *los coeficientes C* de correlación con la señal, como se ve en el capítulo de parametrización.

Los pasos en este sistema serán:

1. Tomar un porcentaje de los archivos de audio para entrenar un modelo y el resto para testeo del sistema, 70% para entreno, 30% Testeo.
2. Tomar tramas del tamaño de ventana definido y parametrizar mediante la familia wavelet designada, en vectores de características.
3. Crear el modelo con los vectores de características destinadas al entreno, a los que se le añade el resultado (score) esperado. El modelo resultante será un clasificador multinivel con una base radial de kernel, con una validación cruzada (entendiendo ésta como una forma de evaluar independientemente del orden en que se tomen los datos) y un sistema de entreno para nuestro caso uno contra todos.
4. Preparar los vectores de características para testear el sistema y lanzarlos contra el modelo; esta vez, no añadiremos los resultados esperados ya que el clasificador será quien nos dé el resultado.

Todos estos pasos se realizan de forma escalonada.

El proceso se describe gráficamente en la siguiente figura:

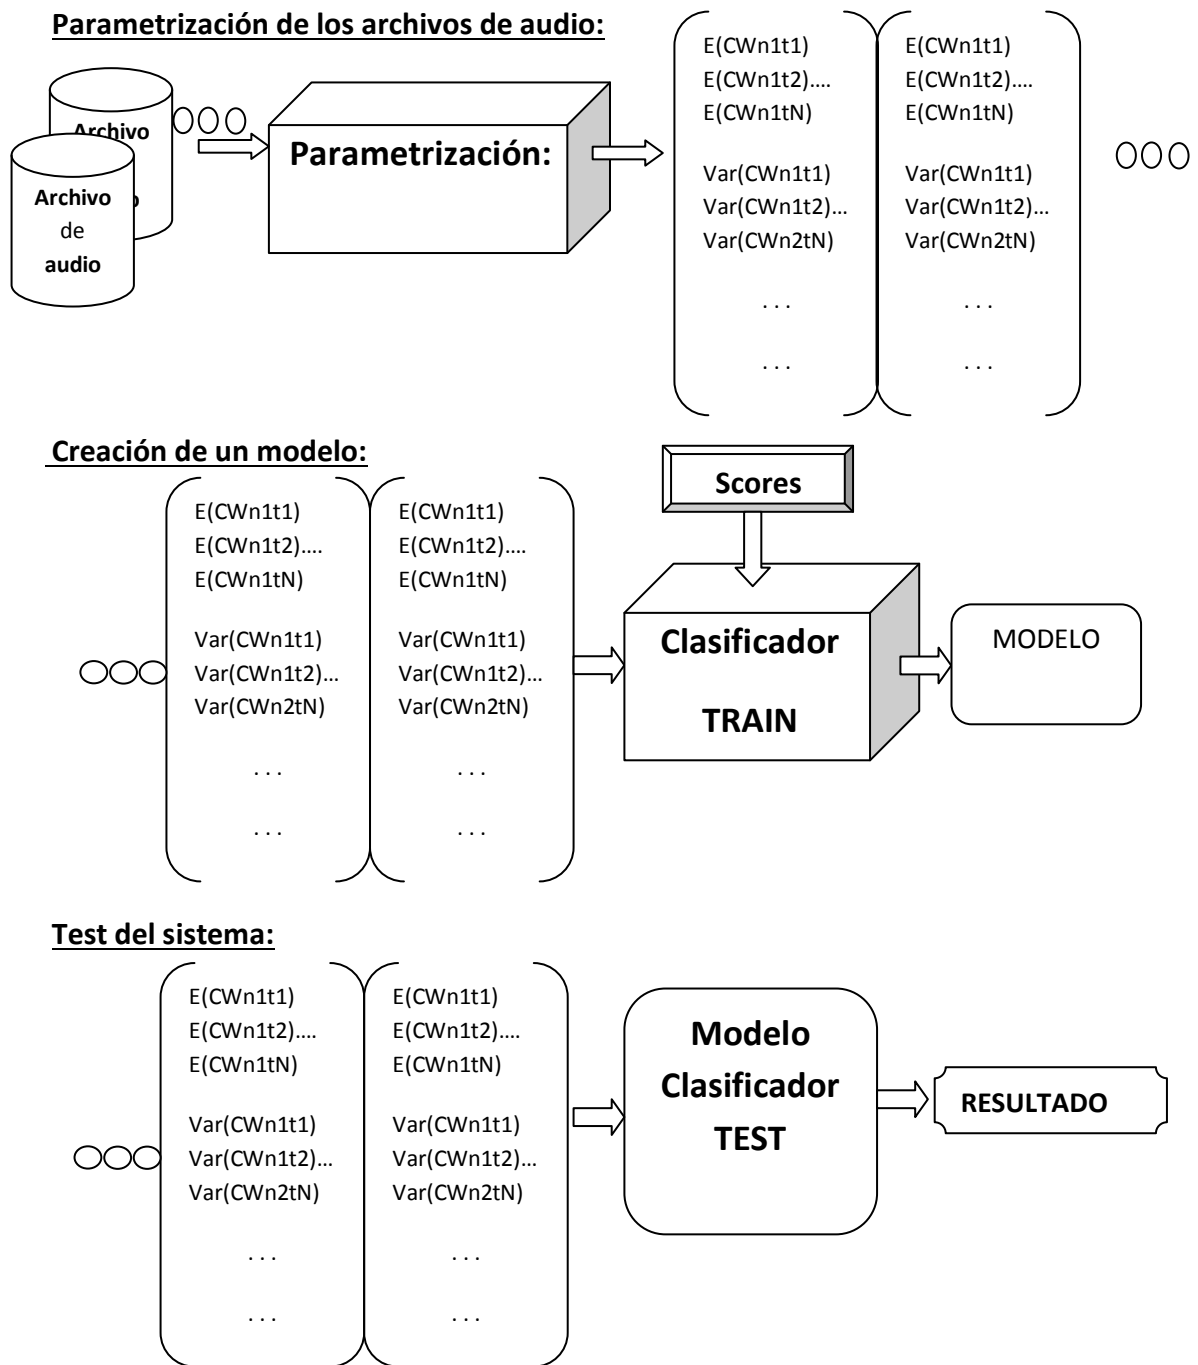


Figura 53: Esquema de experimentación OFF-Line.

El desempeño y resultados se muestran en el capítulo de resultados del presente proyecto

5.3.2 Sistema ON-LINE

Un sistema ON-LINE, es un sistema que nos da una respuesta inmediata (un valor de clasificación), cuando le damos un valor de entrada. Este sistema será el utilizado en el clasificador que se ha desarrollado en un GUI en este proyecto.

Las características de este sistema son:

- Tiempo de ventana=200ms.
- Familia='db2'.
- Parámetros estadísticos: Varianza.
- Escucha directa a clasificación.

El sistema ON-LINE, emula la captación del sonido de la bomba de agua por los sensores de entrada. Para ello, lanzaremos por la tarjeta de sonido del ordenador las grabaciones y la recapturamos por la misma.

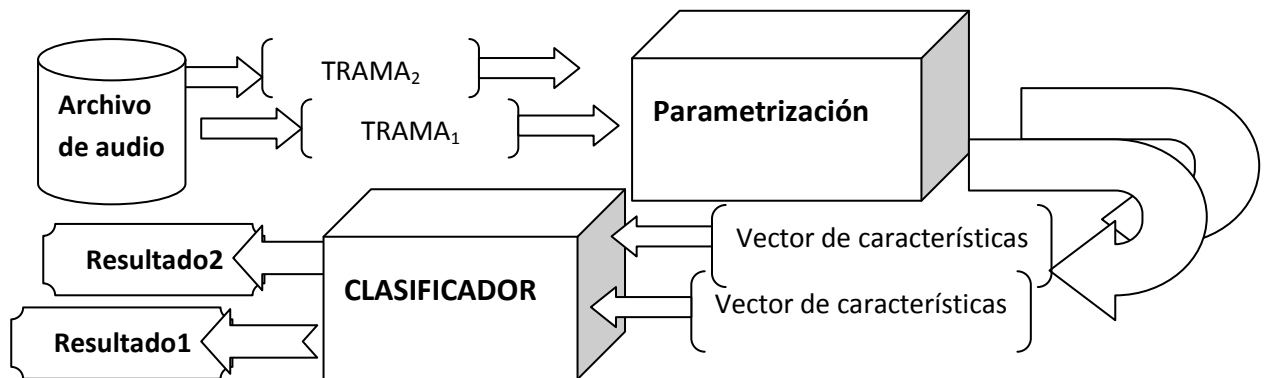


Figura 54: Esquema del sistema ON-LINE

Cada archivo de audio **es segmentado en tramas** y parametrizado y con vector de características se lanza directamente contra el modelo obtenido, dándonos un resultado inmediato. Una vez dado el valor de clasificación el sistema vuelve a leer de la tarjeta de entrada de sonido y se repite el proceso.

5.3.3 Primer experimento

Como se ha comentado antes, buscamos qué parámetros y familias wavelet son las que prestan mejores resultados.

Para ello se ha optado por tomar 17 parámetros estadísticos (explicados en el tema de parametrización) de los coeficientes wavelets resultantes de cada nodo, es decir, una vez obtenidos los coeficientes de wavelet de cada trama, tomamos su varianza, esperanza, curtosis, etc... y estos valores se guardan en un archivo para su posterior uso en el modelo de clasificación. El proceso se detalla como se ve en la siguiente figura:

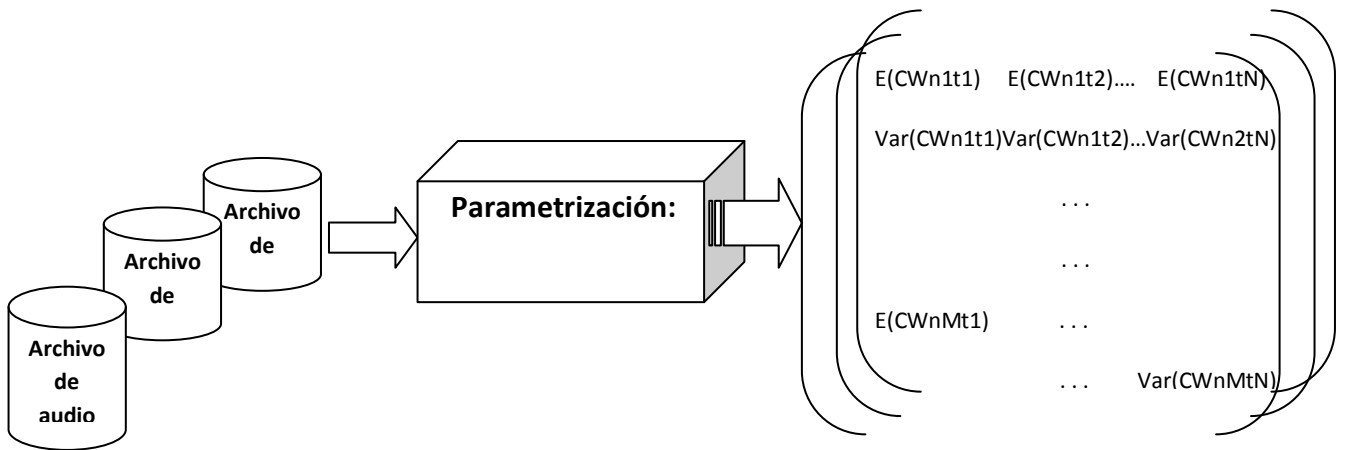


Figura 55: Metodología en la parametrización

Donde el archivo resultante, ha tomado de cada nodo " n ", (donde $n=1..M$) y de cada trama " t ", (donde $t=1..N$), el valor de cada función estadística ($E(x)$, Var , ...).

La forma en la que se ha dividido los archivos de audio para parametrizar se hará según el tamaño de ventana que se determine. Para un primer caso, se ha tomado unos 500ms así como el solape entre trama que se ha determinado en un 50 %. Su esquema es tal como el que se describe en la figura 56:

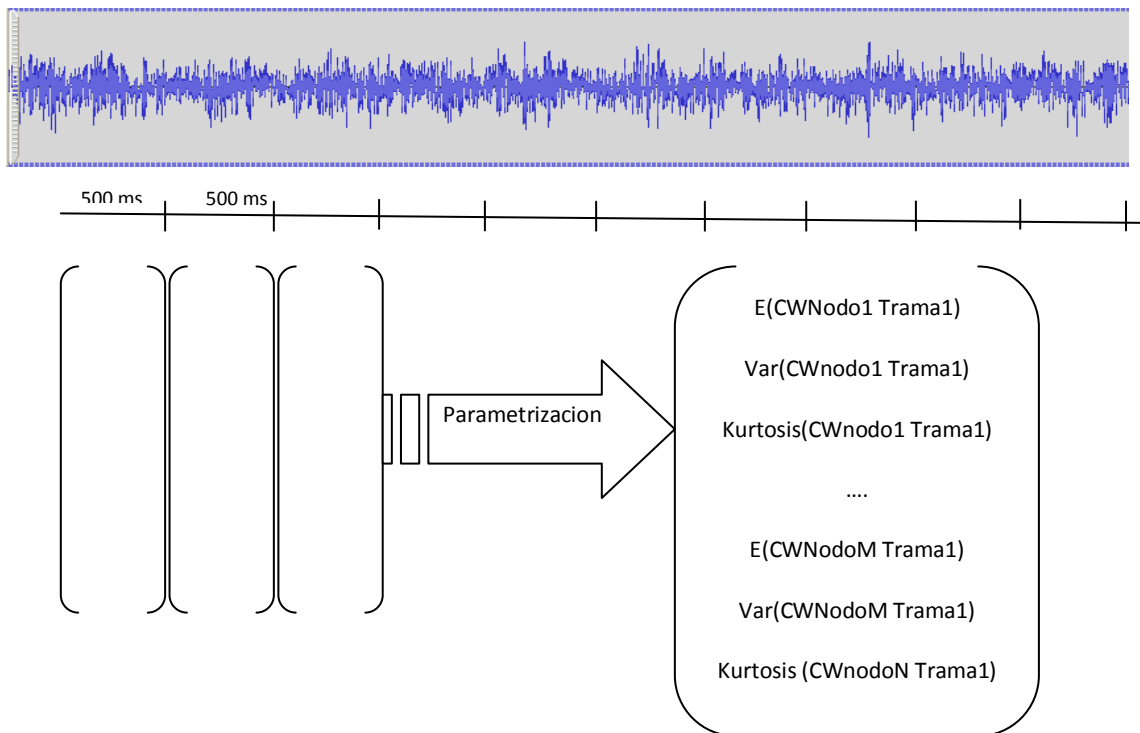


Figura 56: Segmentación de archivo de audio y Parametrización de trama.

En el primer experimento con 17 parámetros se ha concluido que el coste computacional y el tiempo de cálculo sobrepasan las dimensiones de este proyecto, por lo que hemos valorado usar solo 3 parámetros, a pesar de que los resultados preliminares han dado unos valores entorno a los 80%-90% de acierto según la familia.

Tales parámetros serán:

- Esperanza.
- Varianza.
- Curtosis.

Los resultados de esta experimentación se recogen en el capítulo de resultados, tabla 3.

Las características de este experimento son:

- Tiempo de ventana=500ms.
- Solapamiento=50%.
- 3 parámetros estadísticos.

5.3.4 Segundo experimento

Una vez calculado las familias y determinado en 3, los parámetros a medir, se ha pasado al cálculo de mejor tiempo de ventana. Para ello usaremos distintos tiempos de ventanas:

- 500ms.(ya realizada)
- 400ms.
- 200ms.

El resultado se expone en el capítulo de resultados, tabla 4. En donde se puede observar una media de acierto global del 91,9% de acierto.

De este experimento se puede dictaminar el tamaño más pequeño que podemos usar, sobre todo para aumentar la velocidad de respuesta de nuestro clasificador, **200ms**.

Las características de este experimento son:

- Tiempo de ventana=400ms-200ms.
- Solapamiento=50%.
- 3 parámetros estadísticos.

5.3.5 Tercer y Cuarto experimento

Una vez se ha experimentado con los distintos tiempos de ventana, buscamos más velocidad de respuesta en la clasificación, por lo que usamos la ventana de tiempo más corta (200ms) y además pasaremos de tres parámetros a uno (la varianza).

Seguidamente buscamos el modelo con el que clasificar un sistema ON-LINE.

Para una emulación de un sistema real, sacaremos el sonido de audio o vibración por la tarjeta de sonido del ordenador y lo recibimos por la entrada de micro del mismo ordenador, emulando la captación de los sonidos de forma externa.

Queda por saber qué cantidad de vectores de entrenamiento son necesarios para crear un modelo con una alta prestación. La determinación del mismo se consigue tras experimentar con varias cantidades de vectores de entrenamiento.

	10	30	50	70	100
c0	96,819	99,528	99,385	99,311	99,826
c1	85,814	96,629	98,313	98,586	99,226
c2	88,92	97,64	98,364	99,295	99,437
c3	96,156	98,853	99,41	99,684	99,69
c4	95,292	98,706	99,462	99,622	99,784
c5	99,271	99,36	99,605	99,643	99,158

Figura 57: Porcentaje de acierto según aumento de vectores de entrenamiento.

La tabla anterior se ha probado con el acelerómetro a2, donde en las columnas tenemos el acierto por clase y en fila la cantidad de vectores de entrenamiento usados.

Se determina que el número necesario de vectores será 100, tomando así en este experimento el 5% de tramas de los archivos de audio para entrenar y el resto para testeo.

Los pasos para la elaboración de este experimento han sido:

- Tomar 40 segundos de cada archivo de sonido, segmentados en tramas de 200ms.
- Extraer los parámetros wavelet y de estos la varianza.
- Entrenar un modelo con solo 100 muestras.
- Una vez tomados los vectores de entrenamiento tomamos el resto para testear y repetimos 10 veces el proceso desde el principio cuyos resultados son mostrados en el capítulo de resultados, tabla 5.

Las características de este experimento son:

- Tiempo de ventana=200ms.
- Solapamiento=0%.
- 1 parámetros estadísticos: varianza.

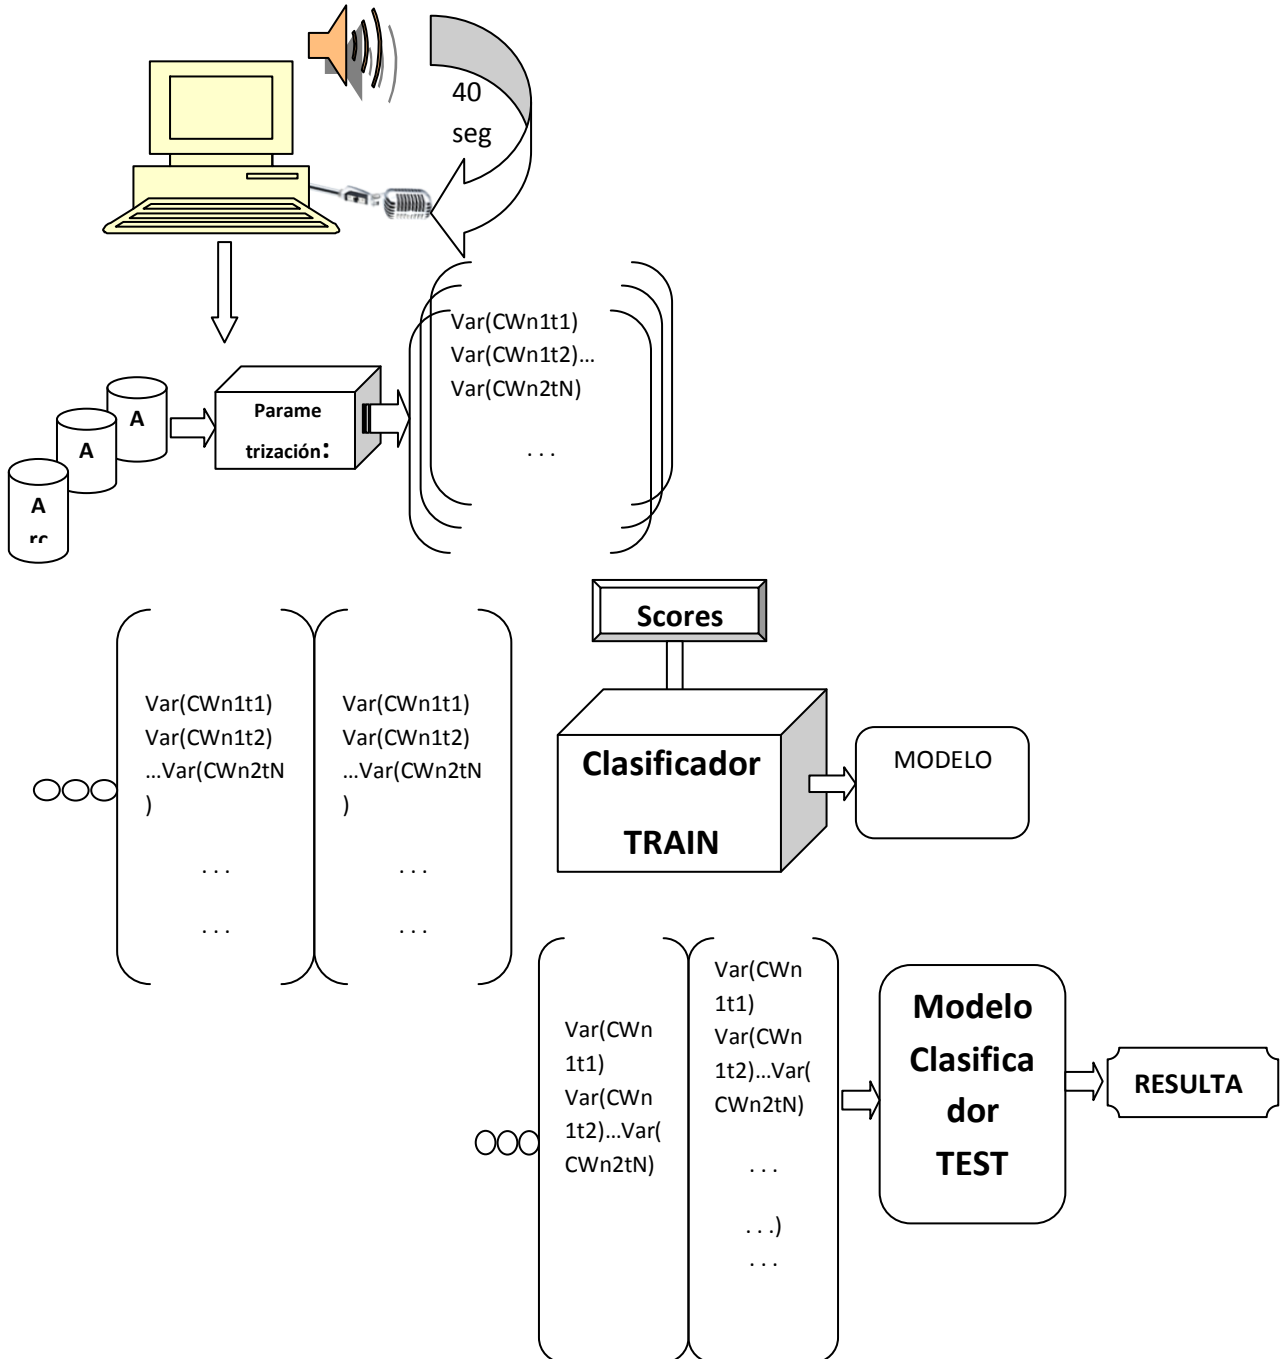


Figura 58: Experimentación previa al sistema ON-LINE

En este último experimento se ha realizado en el sistema **ON-LINE**, con el que posteriormente se ha realizado el GUI descrito en este proyecto.

Los modelos usados serán los obtenidos en el experimento anterior, a los que se les pondrá a prueba con los archivos de sonido de la base de datos. La diferencia con el anterior será que en este clasificamos trama a trama y no archivo a archivo.

El esquema será como el descrito en la siguiente figura:

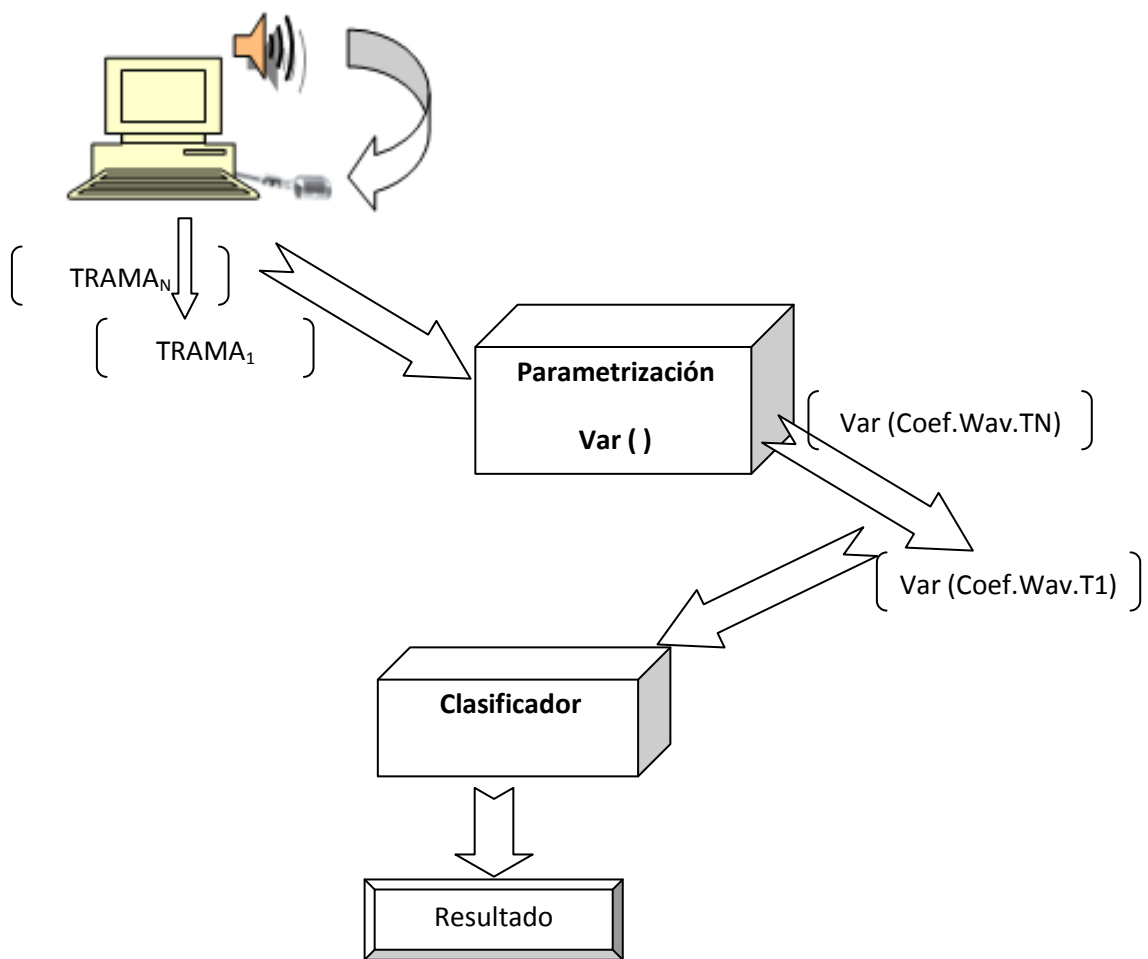


Figura 59: Esquema ON-LINE, sistema clasificador.

Como se ve en el gráfico, el sistema captura los archivos de sonido y toma una trama del mismo que parametriza y la lanza contra el modelo clasificador y así de forma iterativa hasta que se pida al sistema dejar de clasificar. El resultado de la clasificación será la clase que ha dictaminado el clasificador, sus valores son expuestos en el capítulo de resultados, tabla 6.

Capítulo 6: Resultados

Como se comento en capítulos anteriores, los pasos a seguir para este proyecto han sido:




Figura 60: Esquema de experimentación

Las primeras experimentaciones que se han hecho, han sido desestimadas ya que su tiempo de cómputo sobrepasaba los fines de este proyecto. A modo informativo, advertir que los vectores resultantes de estos experimentos, superaban 750.000 valores, no obstante, los primeros resultados arrojaban valores de entre 78 y 98 %. Pero para una herramienta rápida en respuesta, no es viable este sistema con tal cantidad de información.

Si bien, cabe recordar la selección de clases como:

Clase 0	Clase 1	Clase2	Clase3	Clase4	Clase5
Normal	1 aspa	2 aspa	3 aspa	Arena	Bolas

Para una evaluación del sistema debemos buscar las prestaciones del mismo:

6.1 Análisis de prestaciones

Una vez creado el modelo de clasificador, presentamos el análisis de prestaciones del mismo, explicando la metodología usada.

6.1.1 Matriz de confusión

Una matriz de confusión es una herramienta de visualización utilizada en aprendizaje supervisado. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real. Uno de los beneficios que presenta el uso de las matrices de confusión es que facilitan ver si el sistema está confundiendo o no las clases.

		Salidas		TOTAL
		Clase 1	Otras Clases	
Entradas	Clase 1	TP	FP	Total casos positivos (TP)
	Otras clases	FN	TN	Total casos Negativos (TN)
	TOTAL	Total positivos detectados(PD)	Total negativos detectados (ND)	Número de comparaciones (N)

Figura 61: Matriz de confusión.

TP (True Positive) indica el número de scores que, siendo su entrada un dato de la clase 1, ha sido clasificado como de clase 1. Asimismo, TN (True Negative) indica el número de datos que siendo de la otras clases se ha clasificado como de la clase correspondiente. FP (False Positive) indica el número de datos que siendo de otra clase, han sido clasificados como de clase 1. Este parámetro es también conocido como error de tipo 1. Por último, FN (False Negative) indica el número de datos que siendo de la clase 1 han sido clasificados como de otra clase.

A partir de estos valores, podemos extraer información que nos indique como de eficiente es el modelo de clasificador basado LS-SVM que hemos desarrollado.

- Sensibilidad o Tasa de Verdadero Positivo (TPR en inglés): Este parámetro hace referencia a la habilidad del test para identificar correctamente las clases, su ecuación es:

$$TPR = TP/P = TP / (TP + FN) \quad \text{Ecu.25}$$

- Especificidad o Tasa de Verdadero Negativo (TNR en inglés): Este parámetro hace referencia a la habilidad del test para excluir correctamente una clase. Su ecuación es:

$$SPC = TN/N = TN/(TN + FP) \quad \text{Ecu.26}$$

- Valor Predictivo Positivo (del inglés Positive Predictive Value, PPV): Medida de la probabilidad de que un resultado positivo lo sea de verdad. Su ecuación es :

$$PPV = TP / (TP + FP) \quad \text{Ecu.27}$$

- Valor Predictivo Negativo (del inglés Negative Predictive Value, NPV): Proporción de resultados negativos que son verdaderos negativos. Su ecuación es:

$$NPV = TN / (TN + FN) \quad \text{Ecu. 28}$$

- Tasa de Falso Positivo (del inglés False Positive Rate, FPR): Proporción de resultados negativos que son clasificados como positivos. Su ecuación es:

$$FPR = \frac{FP}{TN + FP} = 1 - SPC \quad \text{Ecu. 29}$$

- Tasa de Falso Negativo (del inglés False Negative Rate, FNR): Proporción de resultados positivos que son clasificado como negativos. Su ecuación es:

$$FNR = \frac{FN}{(TP + FN)} = 1 - TPR \quad \text{Ecu. 30}$$

- Tasa de Falso Descubrimiento (del inglés False Discovery Rate, FDR): Proporción de resultados positivos que son falsos positivos. Su ecuación es:

$$FDR = \frac{FP}{TP + FP} = 1 - PPV \quad \text{Ecu. 31}$$

- Precisión (del inglés Accuracy, ACC): Es una medida del grado de cercanía entre la medida de una cantidad y el valor real de dicha cantidad. Su ecuación es:

$$ACC = (TP + TN)/(TP + TN)$$

Ecu. 32

Siendo TP el número total de muestras clasificadas como positivas y TN el número total de muestras clasificadas como negativas.

6.2. Primera aproximación

Como se ha explicado en el capítulo anterior, la experimentación es:

- Tiempo de ventana=500ms.
- Familias Wavelet: db y sym (2,6,9).
- 20 Iteraciones.

Para el **modelo** del sensor del **micrófono 1** los valores han sido:

M1 (%)	db2	db6	db9	sym2	sym6	sym9
acierto	97,2	94,2	98,6	98,9	95,3	95,8
c0	0,05	0,033	0	0	0,15	0,017
c1	0	0,05	0	0	0	0,05
c2	0,017	0,05	0	0	0,017	0,067
c3	0,067	0,117	0,033	0,017	0,083	0,067
c4	0,017	0,067	0,017	0,033	0	0
c5	0,017	0,033	0,033	0,017	0,033	0,05

Tabla 4: Porcentaje de acierto y error por clase, del modelo sensor micro1.

Donde tenemos la probabilidad de acierto en la primera fila por familia y debajo tenemos el porcentaje de error cometido por cada clase, como se puede ver de la gráfica, la mejor familia es la “sym2” y la clase con menor error la **clase1** (1 aspa rota) y la peor la **clase 3** (3 aspapas rotas).

Para el **modelo** del sensor del **micrófono 2**, los valores han sido:

M2 (%)	db2	db6	db9	sym2	sym6	sym9
Acierto	94,2	95,3	98,3	96,4	97,2	96,1
c0	0,067	0,033	0	0,017	0	0
c1	0	0	0	0,017	0	0,033
c2	0,017	0,05	0	0,067	0,1	0
c3	0,183	0,1	0,033	0,067	0,033	0,117
c4	0	0	0,033	0	0	0,017
c5	0,083	0,1	0,033	0,05	0,033	0,067

Tabla 5: Porcentaje de acierto y error por clase, del modelo sensor micro2.

La mejor familia para este modelo es la “db9” y la clase con menor error la clase 1 (1 aspa rota) y la peor la clase 3 (3 aspas rota).

Para el **modelo** del sensor del **micrófono 3**, los valores han sido:

M3 (%)	db2	db6	db9	sym2	sym6	sym9
Acierto	97,8	96,9	90,8	96,1	95,3	93,9
c0	0,033	0,05	0,083	0,033	0	0
c1	0	0,017	0	0,05	0,05	0,067
c2	0	0	0,133	0	0,1	0,05
c3	0,083	0,067	0,15	0,067	0,067	0,133
c4	0,017	0,033	0,1	0,017	0	0,033
c5	0	0,017	0,083	0,067	0,067	0,083

Tabla 6: Porcentaje de acierto y error por clase, del modelo sensor micro3.

La mejor familia para este modelo es la “db2” y la clase con menor error la clase 1 (1 aspa rota) y la peor la clase 3 (3 aspas rota).

Para el **modelo** del sensor del **acelerómetro 1**, los valores han sido:

A1 (%)	db2	db6	db9	sym2	sym6	sym9
acierto	92,5	92,8	95,3	94,7	93,9	97,5
c0	0	0,067	0,033	0,033	0,083	0,017
c1	0,033	0,033	0,017	0,1	0,1	0
c2	0,133	0,1	0,15	0,033	0,033	0
c3	0,117	0,133	0,05	0,067	0,067	0,083
c4	0	0,05	0	0	0,017	0,033
c5	0,167	0,05	0,033	0,083	0,067	0,017

Tabla 7: Porcentaje de acierto y error por clase del modelo sensor acelerómetro 1.

La mejor familia para este modelo es la “sym9” y la clase con menor error la clase 1 (1 aspa rota) y la peor la clase 3 (3 aspapas rota).

Para el **modelo** del sensor del **acelerómetro 2**, los valores han sido:

A2 (%)	db2	db6	db9	sym2	sym6	sym9
Acierto	97,8	94,2	93,6	95,8	95,6	95,3
c0	0,05	0,05	0,05	0,017	0,05	0,017
c1	0	0,017	0	0,017	0,033	0,033
c2	0	0,067	0,033	0,033	0,05	0,033
c3	0,05	0,067	0,133	0,1	0,05	0,1
c4	0	0,05	0,067	0	0,033	0,05
c5	0,033	0,1	0,1	0,083	0,05	0,05

Tabla 8: Porcentaje de acierto y error por clase del modelo sensor acelerómetro 2.

La mejor familia para este modelo es la “db2” y la clase con menor error la clase 1 (1 aspa rota) y la peor la clase 3 (3 aspapas rota).

Para el **modelo** del sensor del **acelerómetro 3**, los valores han sido:

A3 (%)	db2	db6	db9	sym2	sym6	sym9
Acierto	97,8	94,2	93,6	95,8	95,6	95,3
c0	0,05	0,05	0,05	0,017	0,05	0,017
c1	0	0,017	0	0,017	0,033	0,033
c2	0	0,067	0,033	0,033	0,05	0,033
c3	0,05	0,067	0,133	0,1	0,05	0,1
c4	0	0,05	0,067	0	0,033	0,05
c5	0,033	0,1	0,1	0,083	0,05	0,05

Tabla 9: Porcentaje de acierto y error por clase del modelo sensor acelerómetro 3.

La mejor familia para este modelo es la “db2” y la clase con menor error la clase 5 (bolas) y la peor la clase 3 (3 aspas rota).

De los datos obtenidos en la tabla anterior podemos ver como la clase más difícil de clasificar es la clase 3 y las de más acierto la clase uno, en las demás casillas podemos ver el error que se comete por familia y clase, quedando por orden de acierto de clasificación:

1 aspa, arena, normalidad, 2 aspas, bolas, 3 aspas.

De las familias wavelet podemos separar las de más éxitos según sensores:

Micros: sym2, db9, sym6, db2, db6, sym9

Acelerómetros: db2, sym9, sym2, db9, db6, sym6.

Para una posible fusión de datos la db2 y la sym2 presentan un mejor resultado global.

6.3. Resultado según tamaño de la trama

Si bien, una valoración de los resultados podría ser cuanto varía el acierto de las familias según las clases, para ello nos valemos de la varianza de la media de acierto, ya que una varianza grande de los resultados nos darían que una familia determinada

es muy buena para una clase (tipo de fallo) pero muy mala para otra, por lo que no es un clasificador óptimo.

Además en búsqueda de una aplicación de respuesta rápida, reduciremos el tiempo de trama, ya que podemos tomar muestras más pequeñas que nos den una clasificación.

Con esta valoración tomamos la siguiente tabla retomando los datos de las anteriores clasificaciones de 500ms y añadiremos las de 400ms y 200ms. Como antes los valores serán tomando **7 archivos de sonidos como entreno y 3 para testeo de forma aleatoria**, en 20 iteraciones.

Donde tenemos en la cabecera el sensor bajo estudio y la ventana de tiempo. Como resultado tenemos por fila la media del acierto, por familia y la varianza del acierto en las iteraciones.

Los valores según sensor, familia y tiempo de trama son:

MICROFONOS

M1-200ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,939	0,9222	0,9639	0,9472	0,972	0,955	0,941
Varianza	0,034	0,0092	0,0056	0,0063	0,0021	0,006	0,006

Tabla 10: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 1 con ventana de 200ms

Donde se observa que la familia óptima para esta venta es la “sym6”.

M2-200ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,9222	0,9528	0,9611	0,9556	0,9667	0,9167	0,959
Varianza	0,0073	0,0069	0,0043	0,0031	0,0027	0,0067	0,004

Tabla 11: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 2 con ventana de 200ms

Donde se observa que la familia óptima para esta venta es la “sym6”.

M3-200ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,9889	0,9528	0,95	0,95	0,9778	0,3389	0,859
varianza	0,0005	0,0053	0,0042	0,0123	0,0024	0,1835	0,003

Tabla 12: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 3 con ventana de 200ms

Donde se observa que la familia óptima para esta venta es la “db2”.

ACELEROMETROS:

A1-200ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,963	0,958	0,95	0,95	0,961	0,93	0,949
Varianza	0,007	0,003	0,0035	0,003	0,002	0,008	0,003

Tabla 13: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 1 con ventana de 200ms

Donde se observa que la familia óptima para esta venta es la “db2”.

A2-200ms	db2	db6	db9	sym2	sym6	sym9	media
Acierto	0,9583	0,8972	0,9722	0,9667	0,9583	0,9389	0,947
varianza	0,0045	0,018	0,0067	0,0034	0,0042	0,0042	0,006

Tabla 14: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 1 con ventana de 200ms

Donde se observa que la familia óptima para esta venta es la “db9”.

A3-200ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,9583	0,9444	0,9083	0,9583	0,9639	0,9167	0,95
varianza	0,0042	0,0065	0,0176	0,0035	0,0017	0,0073	0,004

Tabla 15: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 1 con ventana de 200ms

Donde se observa que la familia óptima para esta venta es la “db2”.

Para la ventana de tiempo de 200 ms tenemos mejor respuesta según el sensor con las familias:

Micros: sym6, sym2, db9, db2, db6, sym9

Acelerómetros: db2, sym6, sym2, db9, db6, sym9.

Para una **ventana de 400ms:**

MICROFONOS

M1-400ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,929	0,922	0,9556	0,956	0,961	0,936	0,941
Varianza	0,009	0,007	0,0034	0,005	0,006	0,006	0,006

Tabla 16: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 1 con ventana de 400ms

Donde se observa que la familia óptima para esta ventana es la “sym6”.

M2-400ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,978	0,942	0,956	0,971	0,944	0,972	0,959
Varianza	0,002	0,011	0,004	0,006	0,005	0,003	0,004

Tabla 17: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 2 con ventana de 400ms

Donde se observa que la familia óptima para esta venta es la “db2”.

M3-400ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,975	0,961	0,969	0,958	0,969	0,947	0,963
varianza	0,0018	0,006	0,002	0,003	0,002	0,004	0,003

Tabla 18: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 3 con ventana de 400ms

Donde se observa que la familia óptima para esta venta es la “db2”.

ACELEROMETROS:

A1-400ms	db2	Db6	db9	sym2	sym6	sym9	Media
Acierto	0,964	0,928	0,9556	0,947	0,961	0,942	0,949
Varianza	0,002	0,007	0,0031	0,007	0,002	0,006	0,003

Tabla 19: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 1 con ventana de 400ms

Donde se observa que la familia óptima para esta venta es la “sym2”.

A2-400ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,969	0,933	0,914	0,964	0,964	0,942	0,947
Varianza	0,004	0,01	0,012	0,003	0,008	0,008	0,006

Tabla 20: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 2 con ventana de 400ms

Donde se observa que la familia óptima para esta venta es la “db2”.

A3-400ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,964	0,942	0,971	0,9583	0,944	0,925	0,95
varianza	0,003	0,009	0,002	0,0042	0,004	0,014	0,004

Tabla 21: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 3 con ventana de 400ms

Donde se observa que la familia óptima para esta venta es la “db2”.

Para la ventana de tiempo de 400 ms tenemos mejor respuesta según el sensor con las familias:

Micros: db2, db9, sym6, sym2, sym9, db6.

Acelerómetros: db2, sym6, db9, sym2, sym9, db6.

Para una **ventana de 500ms**:

MICROFONOS

M1-500ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,972	0,942	0,9861	0,989	0,953	0,958	0,966
Varianza	0,023	0,004	0,0009	0,003	0,004	0,005	0,003

Tabla 22: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 1 con ventana de 500ms

Donde se observa que la familia óptima para esta venta es la “sym2”.

M2-500ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,942	0,953	0,983	0,964	0,972	0,961	0,962
Varianza	0,011	0,007	0,002	0,005	0,002	0,004	0,004

Tabla 23: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 2 con ventana de 500ms

Donde se observa que la familia óptima para esta venta es la “db9”.

M3-500ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,961	0,969	0,908	0,9778	0,953	0,939	0,951
varianza	0,006	0,002	0,01	0,0008	0,002	0,003	0,002

Tabla 24: Media de acierto y varianza de acierto en 20 iteraciones para micrófono 3 con ventana de 500ms

Donde se observa que la familia óptima para esta venta es la “sym2”.

ACELEROMETROS:

A1-500ms	db2	Db6	db9	sym2	sym6	sym9	Media
Acierto	0,925	0,928	0,9528	0,947	0,939	0,975	0,944
Varianza	0,006	0,006	0,004	0,007	0,018	0,002	0,004

Tabla 25: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 1 con ventana de 500ms

Donde se observa que la familia óptima para esta venta es la “sym9”.

A2-500ms	db2	db6	db9	sym2	sym6	sym9	Media
----------	-----	-----	-----	------	------	------	-------

Acierto	0,978	0,942	0,936	0,958	0,956	0,953	0,954
Varianza	0,003	0,008	0,007	0,002	0,005	0,008	0,004

Tabla 26: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 2 con ventana de 500ms

Donde se observa que la familia óptima para esta venta es la “db2”.

A3-500ms	db2	db6	db9	sym2	sym6	sym9	Media
Acierto	0,975	0,953	0,958	0,9611	0,925	0,942	0,952
varianza	0,004	0,003	0,005	0,002	0,011	0,007	0,004

Tabla 27: Media de acierto y varianza de acierto en 20 iteraciones para acelerómetro 3 con ventana de 500ms

Donde se observa que la familia óptima para esta venta es la “db2”.

Para la ventana de tiempo de 500 ms tenemos mejor respuesta según el sensor con las familias:

Micros: sym9, sym6, sym2, db9, db6, db2.

Acelerómetros: db2, sym9, db9, sym2, db6, sym6.

Concluimos que la mejor familia para el sistema emulador será la “Db2”.

6.4. Sistema emulador (entrenamiento y testeo)

Para una última aproximación emulamos la entrada de sonido, sacando el sonido por la tarjeta de audio y lo recibimos por el micro del pc de forma que se simula la captación de los sonidos de forma externa. Estas entradas se parametrizan para crear un modelo mediante entrenamiento. Creado este modelo ya se puede pasar a un sistema ON-LINE, desarrollado en el siguiente proyecto.

6.4.1. Metodología

Se toman 40 segundos de un archivo de sonido, segmentados en secuencias de 200ms, sacamos los parámetros wavelet, de estos, tomamos tan sólo un valor, la varianza (para aumentar la velocidad y comprobar si es suficiente uno solo); con estos valores entrenamos un modelo con solo el 5% de muestras de las que tenemos y el 95% de test, repitiendo el proceso 10 veces, dando los siguientes resultados mostrados en la siguientes tablas.

MICRÓFONOS:

		SALIDA						Error	
M1		C0	C1	C2	C3	C4	C5	ND	FALLO
ENTRADAS	C0	99,15	0,00	0,10	0,00	0,00	0,00	0,75	0,10
	C1	0,00	97,30	0,35	0,00	0,00	0,00	2,35	0,35
	C2	0,00	0,00	99,20	0,00	0,00	0,00	0,80	0,00
	C3	0,00	0,00	0,00	98,50	0,00	0,00	1,50	0,00
	C4	0,00	0,00	0,00	0,00	99,65	0,00	0,35	0,00
	C5	0,00	0,00	0,00	0,00	0,00	98,80	1,20	0,00

Tabla 28: Media de acierto en 10 iteraciones y medida de la confusión micrófono 1.

En las tablas de resultados vemos como el acierto sigue siendo alto (99%), podemos observar la matriz de **Error** tendremos la suma de los fallos cometidos por el sistema, divididos en dos:

- Columna **ND** tenemos el porcentaje que no ha sido capaz de detectar el modelo, nótese que hay más casos de **ND** que de **error** lo que nos viene a dar un sistema más fiable, ya que no determina una clase antes que dar un falso positivo.
- Columna **FALLO**: Suma de los falsos positivos.

Las prestaciones del micrófono 1 son:

Clase	Exactitud	Sensibilidad	Especificidad	VPP: Valor Predictivo Positivo
0	0,99961 ±2,36E-07	0,99963 ±4,97E-07	0,9996 ±2,76E-07	VPN: Valor Predictivo Negativo. TFP: Tasa de Falso Positivo TFD: Tasa Falso Descubrimiento.
1	0,999214 ±6,68E-07	0,999841 ±6,53E-08	0,99909 ±9,47E-07	
2	0,998209 ±4,92E-06	1 ±0	0,99786 ±6,97E-06	
3	0,997347 ±6,07E-07	0,99771 ±6,24E-07	0,99727 ±1,01E-06	
4	0,999664 ±6,89E-08	0,999894 ±4,93E-08	0,99961 ±1,05E-07	
5	0,997795 ±2,52E-06	0,999947 ±2,8E-08	0,99737 ±3,61E-06	
Clase	VPP	VPN	TFP	TFD
0	0,998053 ±6,77E-06	0,999925 ±2,00E-08	0,000393 ±2,76E-07	0,000393 ±2,76E-07
1	0,995474 ±2,34E-05	0,999968 ±2,63E-09	0,000909 ±9,47E-07	0,00091 ±9,47E-07
2	0,989316 ±0,00017	1 ±0	0,00214 ±6,97E-06	0,00214 ±6,97E-06
3	0,986421 ±2,56E-05	0,999544 ±2,53E-08	0,002723 ±1,01E-06	0,002724 ±1,01E-06
4	0,998105 ±2,59E-06	0,999978 ±1,99E-09	0,000381 ±1,05E-07	0,000382 ±1,05E-07
5	0,986895 ±9,10E-05	0,999989 ±1,12E-09	0,002626 ±3,61E-06	0,002627 ±3,61E-06

Tabla 29: Análisis de prestaciones micrófono 1.

Para el micrófono 2 tenemos:

		SALIDA						Error	
M2		C0	C1	C2	C3	C4	C5	ND	FALLO
ENTRADAS	C0	99,05	0,00	0,25	0,00	0,00	0,00	0,70	0,25
	C1	0,00	87,95	5,05	0,00	0,00	0,00	7,00	5,05
	C2	0,00	0,00	98,50	0,05	0,00	0,00	1,45	0,05
	C3	0,00	0,00	0,00	97,50	0,00	0,00	2,50	0,00
	C4	0,00	0,00	0,05	0,00	99,40	0,00	0,55	0,05
	C5	0,00	0,00	0,00	0,00	0,00	100,00	0,00	0,00

Tabla 30: Media de acierto en 10 iteraciones y medida de la confusión micrófono2.

Cuyas prestaciones son:

Clase	Exactitud		Sensibilidad		Especificidad		VPP: Valor Predictivo Positivo VPN: Valor Predictivo Negativo. TFP: Tasa de Falso Positivo TFD: Tasa Falso Descubrimiento
0	0,999493	±4,439E-07	1	±0	0,999391	±6,4E-07	
1	0,998951	±4,059E-07	1	±0	0,998741	±5,84E-07	
2	0,996315	±1,685E-06	0,99919686	±9,66E-07	0,995749	±2,51E-06	
3	0,996173	±1,159E-06	0,99454282	±2,37E-05	0,996507	±1,38E-06	
4	0,995706	±3,685E-06	0,99631998	±2,72E-05	0,995609	±8,25E-06	
5	0,99811	±5,982E-07	0,99941686	±4,02E-07	0,99785	±9,59E-07	
Clase	VPP		VPN		TFP		TFD
0	0,997	±1,557E-05	1	±0	0,000609	±6,4E-07	0,000609 ±6,4E-07
1	0,993789	±1,420E-05	1	±0	0,0012592	±5,84E-07	0,001259 ±5,84E-07
2	0,978895	±6,269E-05	0,99983989	±3,88E-08	0,0042506	±2,51E-06	0,004251 ±2,51E-06
3	0,982684	±3,425E-05	0,99890227	±9,67E-07	0,0034931	±1,38E-06	0,003493 ±1,38E-06
4	0,978158	±0,0002066	0,99925475	±1,12E-06	0,0043906	±8,25E-06	0,004391 ±8,25E-06
5	0,989368	±2,356E-05	0,99988246	±1,64E-08	0,0021502	±9,59E-07	0,00215 ±9,59E-07

Tabla 31: Análisis de prestaciones micrófono 2.

Para el micrófono 3 tenemos:

		SALIDA						Error	
M3		C0	C1	C2	C3	C4	C5	ND	FALLO
ENTRADAS	C0	98,10	0,00	0,35	0,00	0,00	0,00	1,55	0,35
	C1	0,00	98,80	0,05	0,00	0,00	0,00	1,15	0,05
	C2	0,00	0,00	98,90	0,10	0,00	0,00	1,00	0,10
	C3	0,00	0,00	0,25	98,60	0,00	0,00	1,15	0,25
	C4	0,00	0,00	0,00	0,05	99,80	0,00	0,15	0,05
	C5	0,00	0,00	0,00	0,00	0,05	99,95	0,00	0,05

Tabla 32: Media de acierto en 10 iteraciones y medida de la confusión micrófono3.

Cuyas prestaciones son:

Clase	Exactitud		Sensibilidad		Especificidad		VPP: Valor Predictivo Positivo VPN: Valor Predictivo Negativo. TFP: Tasa de Falso Positivo TFD: Tasa Falso Descubrimiento
0	0,999519	±7,104E-07	0,997657	±2,35E-05	0,999904	±2,65E-08	
1	0,999236	±7,941E-07	0,999894	±4,92E-08	0,999105	±1,18E-06	
2	0,998121	±3,536E-07	0,999044	±1,11E-06	0,997938	±4,64E-07	
3	0,996075	±1,294E-06	0,996707	±1,52E-05	0,995959	±2,32E-06	
4	0,996621	±3,703E-06	0,995963	±1,14E-05	0,99676	±5,08E-06	
5	0,99739	±9,317E-07	0,999787	±1,38E-07	0,99692	±1,4E-06	
Clase	VPP		VPN		TFP		TFD
0	0,999526	±6,4327E-07	0,99951835	±1,00434E-06	9,61E-05	±2,65E-08	9,61E-05 ±2,65E-08
1	0,995579	±2,876E-05	0,99997869	±2,01906E-09	0,00089482	±1,18E-06	0,000895 ±1,18E-06
2	0,989789	±1,14E-05	0,99980787	±4,5364E-08	0,00206168	±4,64E-07	0,002062 ±4,64E-07
3	0,979895	±5,779E-05	0,99934098	±6,22015E-07	0,00404137	±2,32E-06	0,004041 ±2,32E-06
4	0,983895	±0,00012651	0,99919167	±4,66041E-07	0,00324018	±5,08E-06	0,00324 ±5,08E-06
5	0,984737	±3,4287E-05	0,99995749	±5,52741E-09	0,00307601	±1,4E-06	0,003076 ±1,4E-06

Tabla 33: Análisis de prestaciones micrófono 3.

ACELEROMETROS:

Para el Acelerómetro 3 tenemos:

A3		SALIDA						Error	
		C0	C1	C2	C3	C4	C5	ND	FALLO
ENTRADAS	C0	99,40	0,00	0,00	0,00	0,00	0,00	0,60	0,00
	C1	0,00	99,60	0,00	0,32	0,00	0,00	0,40	0,32
	C2	0,00	0,00	99,95	0,00	0,00	0,00	0,05	0,00
	C3	0,00	0,00	0,00	98,75	0,00	0,00	1,25	0,00
	C4	0,00	0,00	0,00	0,00	99,60	0,20	0,20	0,20
	C5	0,00	0,00	0,00	0,00	0,10	99,45	0,45	0,10

Tabla 34: Media de acierto en 10 iteraciones y medida de la confusión acelerómetro3.

Cuyas prestaciones son:

Clase	Exactitud		Sensibilidad		Especificidad		VPP: Valor Predictivo Positivo	
0	0,99882	±4,967E-07	0,999894	±1,108E-07	0,998608	±7,618E-07	Predictivo Positivo	
1	0,999366	±9,440E-08	0,998684	±1,914E-06	0,999504	±7,692E-08	VPN: Valor Predictivo Negativo.	
2	0,998847	±1,211E-06	0,999947	±2,775E-08	0,99863	±1,756E-06	TFP: Tasa de Falso Positivo	
3	0,999559	±2,109E-07	1	±0	0,999471	±3,034E-07	TFD: Tasa Falso Descubrimiento.	
4	0,999568	±4,568E-07	0,999737	±6,910E-07	0,999535	±6,458E-07		
5	0,999348	±5,939E-07	1	±0	0,999219	±8,516E-07		
Clase	VPP		VPN		TFP		TFD	
0	0,999526	±6,4327E-07	0,99951835	±1,00434E-06	9,61E-05	±2,65E-08	9,61E-05	±2,65E-08
1	0,995579	±2,876E-05	0,99997869	±2,01906E-09	0,00089482	±1,18E-06	0,000895	±1,18E-06
2	0,989789	±1,14E-05	0,99980787	±4,5364E-08	0,00206168	±4,64E-07	0,002062	±4,64E-07
3	0,979895	±5,779E-05	0,99934098	±6,22015E-07	0,00404137	±2,32E-06	0,004041	±2,32E-06
4	0,983895	±0,00012651	0,99919167	±4,66041E-07	0,00324018	±5,08E-06	0,00324	±5,08E-06
5	0,984737	±3,4287E-05	0,99995749	±5,52741E-09	0,00307601	±1,4E-06	0,003076	±1,4E-06

Tabla 35: Análisis de prestaciones acelerómetro 3.

Para el Acelerómetro 2 tenemos:

		SALIDA						Error	
A2		C0	C1	C2	C3	C4	C5	ND	FALLO
ENTRADAS	C0	100	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	C1	0,00	95,65	0,00	0,00	0,00	0,00	4,35	0,00
	C2	0,00	0,00	99,30	0,00	0,00	0,00	0,70	0,00
	C3	0,00	0,00	0,00	99,85	0,00	0,00	0,15	0,00
	C4	0,00	0,00	0,00	0,00	98,60	0,00	1,40	0,00
	C5	0,00	0,00	0,00	0,00	0,00	99,85	0,15	0,00

Tabla 36: Media de acierto en 10 iteraciones y medida de la confusión acelerómetro2.

Cuyas prestaciones son:

Clase	Exactitud		Sensibilidad		Especificidad		VPP: Valor Predictivo Positivo	
0	0,999709	±2,786E-08	0,999526	±3,35E-07	0,999746	±5,8E-08	Predictivo Positivo	
1	0,999435	±2,332E-07	1	±0	0,999323	±3,35E-07	VPN: Valor Predictivo Negativo.	
2	0,998863	±4,681E-06	0,999631	±9,85E-07	0,998717	±6,75E-06	TFP: Tasa de Falso Positivo	
3	0,998328	±1,218E-06	0,999788	±4,46E-07	0,99804	±1,82E-06	TFD: Tasa Falso Descubrimiento	
4	0,998897	±1,580E-06	1	±0	0,998679	±2,26E-06		
5	0,999612	±2,116E-07	1	±0	0,999535	±3,04E-07		
Clase	VPP		VPN		TFP		TFD	
0	0,998737	±1,428E-06	0,9999046	±1,35811E-08	0,0002541	±5,8E-08	0,000254	±5,8E-08
1	0,996632	±8,261E-06	1	±0	0,000677	±3,35E-07	0,000677	±3,35E-07
2	0,993579	±0,0001699	0,9999256	±4,03595E-08	0,0012829	±6,75E-06	0,001283	±6,75E-06
3	0,990211	±4,550E-05	0,9999577	±1,7841E-08	0,0019595	±1,82E-06	0,00196	±1,82E-06
4	0,993421	±5,603E-05	1	±0	0,0013208	±2,26E-06	0,001321	±2,26E-06
5	0,997684	±7,583E-06	1	±0	0,0004645	±3,04E-07	0,000465	±3,04E-07

Tabla 37: Análisis de prestaciones acelerómetro 2.

Para el Acelerómetro 1 tenemos:

		SALIDA					Error		
		C0	C1	C2	C3	C4	C5	ND	FALLO
A1									
ENTRADAS	C0	99,95	0,00	0,00	0,00	0,00	0,00	0,05	0,00
	C1	0,00	99,70	0,00	0,00	0,00	0,00	0,30	0,00
	C2	0,00	0,00	99,45	0,00	0,00	0,00	0,55	0,00
	C3	0,00	0,00	0,00	100	0,00	0,00	0,00	0,00
	C4	0,00	0,00	0,00	0,00	99,25	0,10	0,65	0,10
	C5	0,00	0,00	0,00	0,00	0,00	100	0,00	0,00

Tabla 38: Media de acierto en 10 iteraciones y medida de la confusión acelerómetro1.

Cuyas prestaciones son:

Clase	Exactitud		Sensibilidad		Especificidad		VPP: Valor Predictivo Positivo	
0	0,999609	±1,786E-08	0,999323	±2,15E-06	0,999531	±2,52E-08	Predictivo Positivo	
1	0,999235	±1,232E-07	1	±0	0,999123	±3,35E-07	VPN: Valor Predictivo Negativo.	
2	0,995863	±2,681E-07	0,999301	±7,85E-07	0,997717	±4,55E-07	TFP: Tasa de Falso Positivo	
3	0,996328	±2,318E-06	0,998738	±5,06E-07	0,997414	±1,32E-06	TFD: Tasa Falso Descubrimiento	
4	0,997897	±3,180E-06	0,999235	±1,256E-07	0,997679	±3,15E-06		
5	0,998612	±1,212E-07	1	±0	0,999135	±3,04E-07		
Clase	VPP		VPN		TFP		TFD	
0	0,998737	±1,428E-06	0,9999046	±1,35811E-08	0,000469	±5,8E-08	0,00047	±5,8E-08
1	0,996632	±8,261E-06	1	±0	0,000877	±3,35E-07	0,000876	±3,35E-07
2	0,993579	±0,0001699	0,9999256	±4,03595E-08	0,002283	±6,75E-06	0,00228	±6,75E-06
3	0,990211	±4,550E-05	0,9999577	±1,7841E-08	0,002586	±1,82E-06	0,00258	±1,82E-06
4	0,993421	±5,603E-05	1	±0	0,002321	±2,26E-06	0,00232	±2,26E-06
5	0,997684	±7,583E-06	1	±0	0,000865	±3,04E-07	0,000865	±3,04E-07

Tabla 39: Análisis de prestaciones acelerómetro 1.

Capítulo 7. Simulador

Como se explico anteriormente en este capítulo se ha realizado un clasificador basado en modelos LS-SVM, que podrá tanto testar modelos. Dando una respuesta inmediata del sonido que se reproduzca.

Sera un sistema **on-line**, ya que emulará la entrada de datos y obtendrá de forma directa el resultado de la clasificación.

Para tal fin se ha desarrollado un GUI donde cargar el archivo de audio que queremos estudiar, el sensor deseado y un botón para dictaminar la clase que se está escuchando.

7.1. GUI desarrollado

La aplicación GUI (Graphical User Interface) ha sido desarrollado en la en el programa MATLAB R2010a. En concreto, en la utilidad para el diseño de aplicaciones gráficas GUIDE. Esta es una representación, mediante gráficos, botones, combos... en definitiva objetos gráficos para la interacción del usuario con el sistema.

7.1.1. Menú interfaz

El GUI (Graphical User Interface) desarrollado consta de 3 botones y un combo selector que son:

- Botón “Cargar fichero”: Carga el archivo de audio para estudiar.
- Botón “Clasificar”: Clasifica el sonido que se está reproduciendo.
- Botón “Reproducir”: Reproduce el archivo de audio.
- Selector “sensor”: Escoge el modelo clasificador del sensor.




Figura 62: Menú de selección.

7.1.2. Funcionamiento

El funcionamiento del GUI para el demostrador es el siguiente:

Donde:

Se carga el sonido de una carpeta donde está el sonido de la bomba bajo estudio.

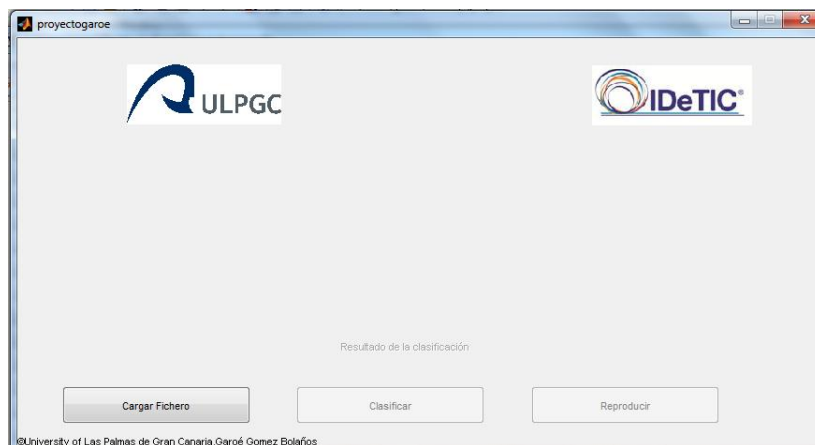


Figura 63: Pantalla inicial

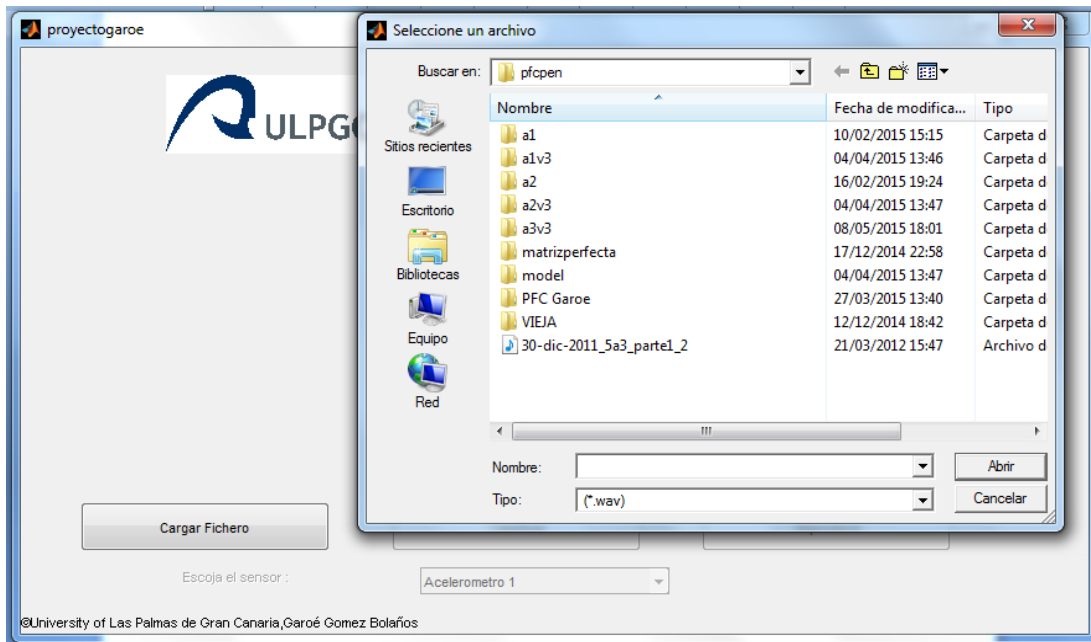


Figura 64: Selección del archivo a testear.

- Se escoge un archivo el cual se representa en la pantalla.

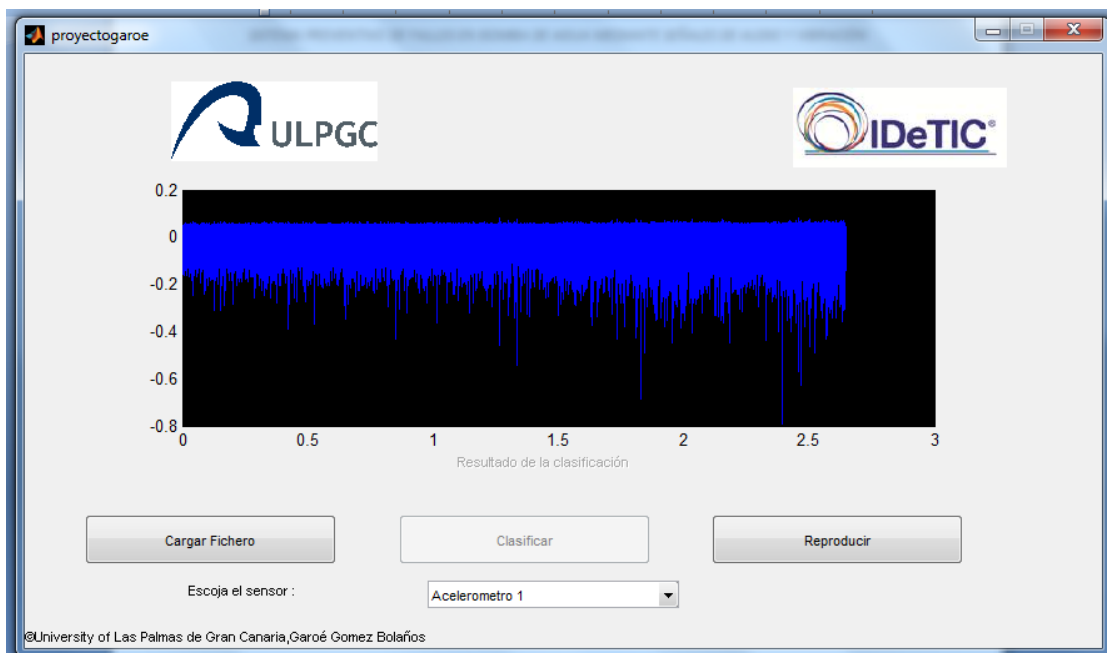


Figura 65: Carga del fichero bajo estudio.

- Se selecciona el modelo del sensor a testear y se pulsa el botón de reproducir para escuchar el audio.

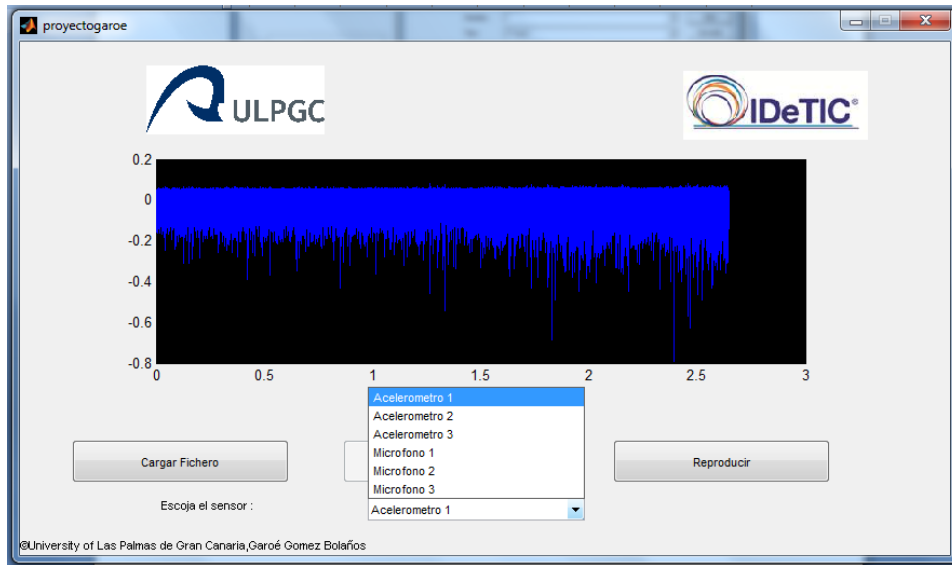


Figura 66: Selección del modelo de sensor bajo estudio.

- Se pulsa el botón de clasificar para obtener la clase que se está escuchando.

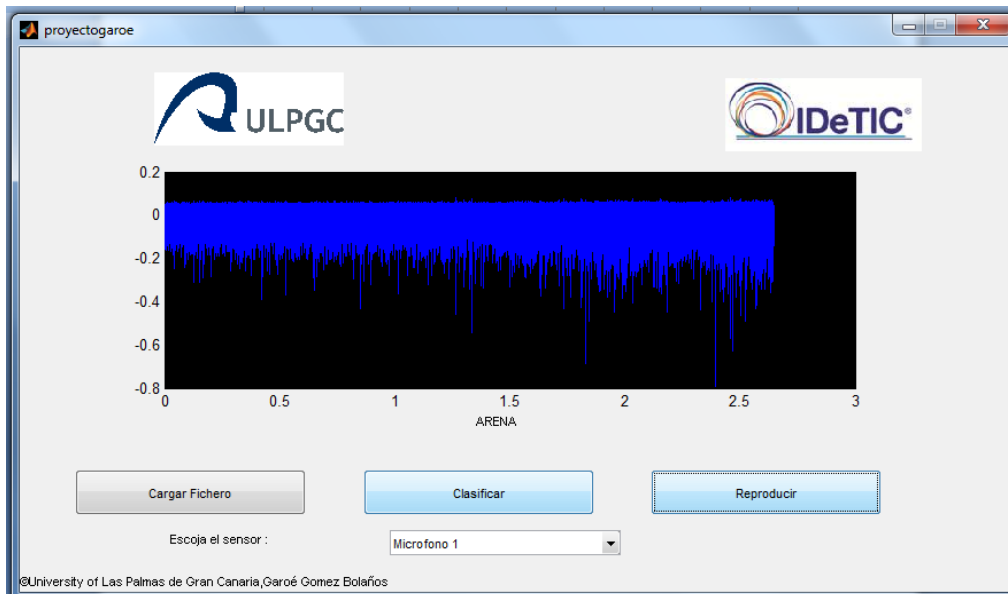


Figura 67: Clasificación.

El resultado del clasificador aparece debajo de la gráfica, como vemos en la figura 67. (ARENA).

Este detector de clases como se comento antes es ON-LINE, toma una muestra y lanza contra el modelo. De la observación en el desarrollo de las anteriores simulaciones se

observa que el sistema de adquisición de datos, puede hacer cometer errores al detector, es decir, es sensible a variaciones de volumen y a ruidos del sistema, por lo que se ha optado por usar el propio Matlab para lanzar el sonido mediante el comando soundsc, ya que el sonido sale escalado y no depende de si el volumen en el que se encuentre el programa de audio(VLC) es el indicado.

7.2. Organigrama

El organigrama de este GUI es el que sigue:

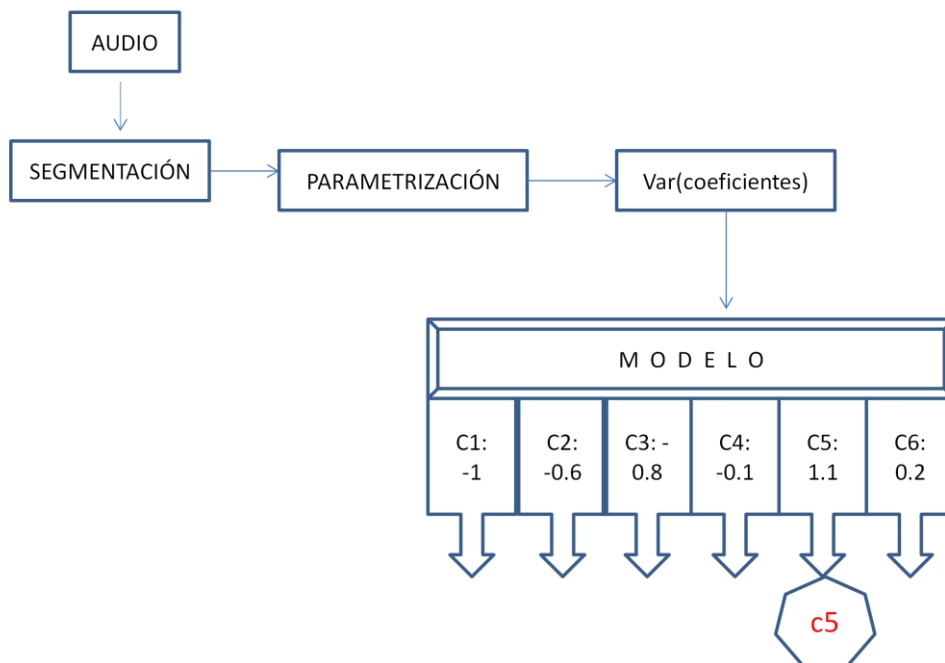


Figura 68: Organigrama del GUI.

Se segmenta un archivo de audio, se toman los parámetros deseados y se testean con el modelo, el cual da un valor de aproximación a la clase asociada. El valor más alto será la clase que detecta el modelo.

Capítulo 8. Conclusiones y futuros proyectos

8.1. Conclusiones

El presente proyecto de detección de anomalías en una bomba de agua pretende ser una primera aproximación a la detección de anomalías de maquinarias rotativas, en particular, una bomba de agua mediante dos tipos de sensores micrófonos y acelerómetros. Ambas formas de captación de datos son no invasivas, lo que hace que nuestro sistema sea portable, incluso puede ser acoplado al sistema con telecontrol para lanzar una señal de alarma; si bien, para este caso, una bomba de agua pequeña, puede resultar excesivo, pero para un motor o una bomba de gran caudal puede suponer un ahorro en costes más que razonable para su uso.

La base de datos se ha hecho extensa (más de 200 horas grabadas) y por razones obvias se ha acotado en el proyecto, pero son válidas para siguientes líneas como los transitorios en los arranques o el cambio de presiones y otras cargas puestas a la salida, para un cálculo indirecto si se desea de la presión.

La **parametrización** ha sido obtenida mediante **transformadas de wavelet**, donde su multiresolución examina ampliamente todos las bandas de frecuencias y estudiado en [4], lo cual también hace extrapolable el sistema a cualquier máquina. Los parámetros a usar han sido los más comunes **esperanza, varianza y media, los cuales han demostrado un acierto 95%**.

En el capítulo de resultados se observa la alta capacidad de discriminación y una tasa de éxito mayor del 95% de acierto, **independientemente del tamaño de trama estudiados.**

El clasificador LS-SVM, da una respuesta satisfactoria tanto en acierto, como en el tiempo de respuesta. Además es de resaltar que el **clasificador discrimina y da un porcentaje de falso positivo del 0.1%**, lo cual anima a continuar el estudio por esta línea.

De los captadores usados siempre **dan sensiblemente resultados mejores en los acelerómetros**, si bien, los micrófonos no han dado mal resultado, estos son más sensibles a ruidos externos que no tienen que ver con la maquinaria como pueden ser golpes externos, vientos, voces... lo cual haría necesario o cribar en una frecuencia o limpiar de ruido la señal de entrada.

Tanto el software desarrollado Off-Line, como el On-Line presentan un acierto **superior al 95%**.

8.2. Líneas de trabajo futuro

El desarrollo de este proyecto en Matlab permite un análisis en las simulaciones de forma cómoda pero puede ser extrapolada a otros software de cálculos, e incluso a otras plataformas y lenguajes como VHDL, Verilog, C++, pudiendo acoplar FPGA diseñadas para la detección de anomalías, o pequeños microprocesadores o controladores "in situ" como parte de una red de sensores y telecontrol.

Este sistema está diseñado para una bomba de agua, la aplicación de este mismo clasificador para otras maquinarias podría ser de interés para otras líneas de investigación sobre prevención. El estudio de parámetros determinantes en la misma o según la maquinaria a usar.

Si bien, la herramienta diseñada es de respuesta rápida, pero podría mejorarse adaptándolo a tiempo real, esto mediante el estudio de los valores más determinantes de los parámetros pueden optimizar el sistema.

El estudio del desempeño con otros sensores, como pueden ser fotos térmicas, nuevas clases como por ejemplo el trabajo en vacío que aumenta la temperatura de la bomba llegando incluso a quemar el bobinado, dejando inútil la bomba.

Otras líneas puede ser el estudio de sistemas que no necesiten aprendizaje, tan sólo valorar patrones de normalidad y determinar un umbral que hagan dictaminar el mal funcionamiento de la maquinaria.

Bibliografía

- [1] Vilela, R., J. C. Metrolho, and J. C. Cardoso. "Machine and industrial monitorization system by analysis of acoustic signatures." Electrotechnical Conference, 2004. MELECON 2004. Proceedings of the 12th IEEE Mediterranean. Vol. 1. IEEE, 2004.
- [2] Basak, Debasmita, Arwind Tiwari, and S. P. Das. "Fault diagnosis and condition monitoring of electrical machines-A Review." Industrial Technology, 2006. ICIT 2006. IEEE International Conference on. IEEE, 2006.
- [3] Sun, Qiao, et al. "Pattern recognition for automatic machinery fault diagnosis." Journal of vibration and acoustics 126.2 (2004): 307-316.
- [4] Jardine, Andrew KS, Daming Lin, and Dragan Banjevic. "A review on machinery diagnostics and prognostics implementing condition-based maintenance." Mechanical systems and signal processing 20.7 (2006): 1483-1510.
- [5] Samanta, B., and K. R. Al-Balushi. "Artificial neural network based fault diagnostics of rolling element bearings using time-domain features." Mechanical systems and signal processing 17.2 (2003): 317-328.
- [6] Fu, Lihui, Hui Li, and Yaning Wang. "Application of Bi-cepstrum analysis to gear fault detection and diagnosis." 2009 International Conference on Measuring Technology and Mechatronics Automation. Vol. 1. 2009.
- [7] Rafiee, J., et al. "A novel technique for selecting mother wavelet function using an intelligent fault diagnosis system." Expert Systems with Applications 36.3 (2009): 4862-4875.
- [8] Zhang, Yongxiang, and R. B. Randall. "Rolling element bearing fault diagnosis based on the combination of genetic algorithms and fast kurtogram." Mechanical Systems and Signal Processing 23.5 (2009): 1509-1517
- [9] Albarbar, A., et al. "Acoustic monitoring of engine fuel injection based on adaptive filtering techniques." Applied Acoustics 71.12 (2010): 1132-1141.
- [10] Devi, S., et al. "A comparative study between vibration and acoustic signals in HTC cooling pump and chilling pump." Int. J. Eng. Technol 2.3 (2010): 273-277.S.

- [11] Al Thobiani, Faisal, Fengshou Gu, and Andrew Ball. "The monitoring of cavitation in centrifugal pumps based on the analysis of vibro-acoustic measurements." (2010).
- [12] Vachtsevanos, G. E. O. R. G. E., et al. "Intelligent fault diagnosis and prognosis for engineering systems, 2006." Usa 454p Isbn 13: 978-0.
- [13] Sakthivel, N. R., V. Sugumaran, and S. Babudevasenapati. "Vibration based fault diagnosis of monoblock centrifugal pump using decision tree." *Expert Systems with Applications* 37.6 (2010): 4040-4049.
- [14] Peng, Z. K., and F. L. Chu. "Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography." *Mechanical systems and signal processing* 18.2 (2004): 199-221.
- [15] E.P.Serrano "Introducción a la transformada wavelet y sus aplicaciones al procesamiento de señales de emisión acústica" Escuela de Ciencia y Tecnología - Universidad Nacional de General San Martín.
- [16] Chidambaram, Bala, Daniel D. Gilbertson, and Kirby Keller. "Condition-based monitoring of an electro-hydraulic system using open software architectures." *Aerospace Conference, 2005 IEEE. IEEE, 2005.*
- [17] Amendola, L. "Sistemas Expertos Monitoreo de Condiciones en Máquinas Rotativas." Universidad Politécnica de Valencia, España.
- [18] Henríquez, Patricia, et al. "Characterization of healthy and pathological voice through measures based on nonlinear dynamics." *Audio, Speech, and Language Processing, IEEE Transactions on* 17.6 (2009): 1186-1195.
- [19] Díaz-de-Maria, Fernando, Travieso, Carlos M., Alonso, Jesús B. and Ferrer Miguel A. "Optimal Size Time Window in Nonlinear Features for Voice Quality Measurement", *Lecture Notes in Computer Science LNCS (on line), Springer-Verlag GmbH ,Vol 3817 / 2006 ,pp 206-217, Berlín, Feb. 2006.*
- [20] Godino-Llorente, Juan Ignacio, et al. "Support vector machines applied to the detection of voice disorders." *Nonlinear Analyses and Algorithms for Speech Processing. Springer Berlin Heidelberg, 2005. 219-230.*
- [21] Morales, Aythami, et al. "Contact-free hand biometric system for real environments." *Proceedings of the 16th European Signal Processing Conference (EUSIPCO). 2008.*

- [22] Vargas, J., et al. "Off-line signature verification based on high pressure polar distribution." ICFHR08. Montreal (2008).
- [23] Cabrera, J., Alonso, J., Travieso, C., and Ferrer, Miguel A. 'A Spanish Tool for Biomedical Signals Processing', in International Technology, Education, and Development Conference INTED 2008, pp.320, Valencia March 3rd-5th 2008
- [24] Corsino, Jorge, Travieso, Carlos M. , Alonso, Jesús B. and Ferrer, Miguel A. "Improving an Automatic Arrhythmias Recogniser based in ECG Signals", in International Conference on Bio-inspired Systems and Signal Processing 2008, pp. 453-457, Funchal, Madeira, Portugal, 28-31 January 2008.
- [25] Henríquez, Patricia, et al. "Advances in automatic detection of failures in electric machines using audio signals." system 584.112 (2007): 114.
- [26] Henríquez, Patricia,. Alonso, Jesús B, Travieso, Carlos M. and Ferrer, Miguel A. "HESPERIA: homeland security technologies for security in public spaces and infrastructures ",41st Annual IEEE International Carnahan Conference on Security Technology 2007, pp. 221-226, 8-11 October, 2007.
- [27] Henríquez, Patricia,. Alonso, Jesús B, Travieso, Carlos M. and Ferrer, Miguel A. "Application of Higher Order Statistics of Teager-Kaiser Transformed Vibration Signal for Bearing Fault Diagnosis," 24th International Congress on Condition Monitoring and Diagnostics Engineering Management (COMADEM 2011), pp. 265-274, 30 May-1June, Stavanger, Norway.
- [28] Santamaría, Francisco, Camilo A. Cortés, and Francisco J. Román. "Uso de la Transformada de Ondeletas (Wavelet Transform) en la Reducción de Ruidos en las Señales de Campo Eléctrico producidas por Rayos." Información tecnológica 23.1 (2012): 65-78.
- [29] Castro, Liliana Raquel, and Silvia Mabel Castro. "Wavelets y sus Aplicaciones. " I Congreso Argentino de Ciencias de la Computación. 1995.).
- [30] de Señales, Apuntes de Teoría. "Introducción a la Transformada Wavelet."Departamento de Señales y sistemas. Universidad de Navarra (2006). Web. Revisado día 30 de junio 2012.<<http://www.exa.unicen.edu.ar/escuelapav/cursos/wavelets/apunte.pdf>>
- [31] Ordoñez, A. J., C. Castejón, and J. C. García-Prada. "Selección del nivel de descomposición WPT mediante el análisis de la sensibilidad de la energía relativa Wavelet."

- [32] Salgado, D. Rodríguez, et al. "Estudio comparativo de dos sistemas de monitorización del desgaste de la herramienta y de la rugosidad superficial basados en LS-SVM y redes neuronales."
- [33] Acuña, G., and J. González. "Desarrollo de Modelos de Caja Gris utilizando Máquinas de Vectores de Soporte." XXIII Encuentro Chileno de Computación (ECC) (2011).
- [34] Bernal-de Lázaro, José M., et al. "Estudio comparativo de clasificadores empleados en el diagnóstico de fallos de sistemas industriales." *Ingeniería Mecánica* 14.2 (2011): 87-98.
- [35] Rubio, Ginés, et al. "Efficient optimization of the parameters of LS-SVM for regression versus cross-validation error." *Artificial Neural Networks–ICANN 2009*. Springer Berlin Heidelberg, 2009. 406-415.
- [36] Suárez, Enrique J. Carmona. "Tutorial sobre Máquinas de Vectores Soporte (SVM)."
- [37] Resendiz, Juan A. *Las máquinas de vectores de soporte para identificación en línea*. Diss. Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional. 2006.
- [38] Samui, Pijush. "Application of least square support vector machine (LSSVM) for determination of evaporation losses in reservoirs." *Engineering* 3.04 (2011): 431.
- [39] López-Sarmiento, Danilo A., Héctor C. Manta-Caro, and Nelson E. Vera-Parra. "Clasificador Basado en una Máquina de Vectores de Soporte de Mínimos Cuadrados Frente a un Clasificador por Regresión Logística ante el Reconocimiento de Dígitos Numéricos." *Tecno Lógicas* 31 (2013): 37-51.
- [40] Muñoz-Bedoya, Luis A., Luis E. Mendoza, and Hernando J. Velandia-Villamizar. "Segmentación de Imágenes de Resonancia Magnética IRM utilizando LS-SVM y Análisis Multiresolución Wavelet." *Tecno Lógicas* (2013): 681-693.
- [41] Suykens, J. A. K., et al. "Least squares support vector machine classifiers: a large scale algorithm." *European Conference on Circuit Theory and Design, ECCTD*. Vol. 99. 1999.

PLANOS Y PROGRAMAS

Planos y Programas

A continuación se detallan los algoritmos desarrollados, implementados y/o utilizados en la aplicación informática. Estos se dividen en las siguientes categorías:

- Algoritmos para GUIs
- Algoritmos para extracción de parámetros.
- Algoritmos para el clasificador.

En cada apartado se expone la cabecera y la relación de los algoritmos con el resto de funciones, así como una pequeña descripción sobre su utilidad. Para más información se puede consultar en el CD-ROM adjunto a este documento se encuentra el código completo de todos los algoritmos empleados ya listos para su ejecución en Matlab de acuerdo a las especificaciones del Manual de Usuario.

Cada GUI de MATLAB está definida por dos funciones: una de extensión .fig que contiene la descripción del diseño de la GUI y sus componentes y otra de extensión .m con el código que la controla.

Algoritmos para GUIs

`function varargout = proyectogaroe(varargin)`

proyectogaroe.m: M-file para la ventana principal del programa.

Controla el archivo portada.fig, el cual da la bienvenida al paciente.

Subrutinas y funciones internas:

function cargarfichero_Callback(hObject, eventdata, handles)

Función que carga el fichero bajo estudio.

function reproducir_Callback(hObject, eventdata, handles)

Reproducción del sonido seleccionado.

function clasificador_Callback(hObject, eventdata, handles)

Botón para clasificar el sonido que se está escuchando.

function acelerometro_Callback(hObject, eventdata, handles)

Selecciona el modelo del sensor bajo estudio.

Algoritmos para extracción de parámetros

function [parameters] = parametroswavelet;

parametroswavelet : M-file para el cálculo de los parámetros de los archivos de sonido que se escucha, su salida son matrices con los parámetros wavelet.

Algoritmos para el clasificador

function [parameters] = modelado;

modelado : M-file para el cálculo de los modelos para testear el sistema. Toma las tramas wavelet y las entrena para la obtención de un modelo.

function[parameters]=Test_clasificador;

Test_clasificador.m : M-file para testeo del modelo.

Testea el modelo ante un sonido a la entrada con un modelo cargado.

`function(parameters)=Testeo_clases;`

Testeo_clases.m : M-file para evaluación de resultados.

Da la medida de acierto del modelo frente a un grupo de matrices aleatorias de distintas clases.

PLIEGO DE CONDICIONES

Pliego De Condiciones

Este apartado se divide en dos partes. En la primera, conocida como Pliego de Condiciones Técnicas, se exponen los datos necesarios para llevar a cabo la instalación y ejecución de la aplicación. En la segunda, el llamado Pliego de Condiciones Legales, se aportan los acuerdos de licencia del programa.

1. Pliego de Condiciones Técnicas

1.1 Requisitos del sistema

Hardware:

- Pentium IV, o superior, Intel Core i3 AMD Athlon, Athlon XP, Athlon MP.
- 1 GB de RAM. Recomendado (4 GB).
- Un mínimo de 20 GB de espacio libre en disco.
- Dispositivos de captura de audio.

Software:

- Uno de los siguientes sistemas operativos: Windows 2000 (Service Pack 3 o 4), Windows 2003 Server, Windows XP (Service Pack 1 o 2), Windows Vista o superior.
- Matlab 2009 o superior. Librerías LSSVMIabv1_8.

1.2 Instalación y ejecución del software

1.2.1. Herramientas “Proyectogaroe”

Es recomendable copiar el archivo ejecutable de la herramienta en el escritorio del terminal en el que se va a instalar. Si el terminal no tiene instalada la herramienta Matlab, se ha de instalar el componente MCR (Matlab Compiler Runtime) que permite que el programa se ejecute correctamente.

Una vez instalado, se recomienda copiar la carpeta “files” a la raíz C: para la correcta visualización de los videos e imágenes de los que la herramienta hace uso. Además, se recomienda también copiar la carpeta “Modelo” a la raíz C: en el caso del programa Sistema, lo que permitirá que la herramienta Sistema funcione de forma correcta.

1.2.2. Herramienta “Proyectogaroe”

Se recomienda crear una carpeta en el directorio raíz C: llamada “GRABACIONES DE AUDIO”, que a su vez contendrá en su interior seis carpetas que contengan las clases: “normal”, “1 aspa”, “2 aspa”, “3 aspa”, “arena”, “bolas”, estas a su vez divididas en seis más según el sensor que se utilice: “a1”, “a2”, “a3”, “m1”, “m2”, “m3”.

Los ficheros de audio que han de utilizarse deben tener extensión “.wav” y su nombre: “grabación_fecha_sensor+numero” donde fecha no es relevante pero si el sensor y su número.

2. Pliego de condiciones legales

2.1. Concesión de licencia

Esta aplicación es propiedad de la Universidad de Las Palmas de Gran Canaria y todos los usuarios deben estar de acuerdo en obligarse por los términos y condiciones establecidas en esta licencia, aceptando todas sus cláusulas. El uso de este programa o de una copia será bajo la autorización expresa del autor, tutores del proyecto y de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria.

2.2. Derechos de autor

Este programa y la documentación adjunta están protegidos por las leyes de la propiedad intelectual que les sean aplicables, así como las disposiciones de los tratados internacionales. En consecuencia, el programa debe ser utilizado como cualquier producto protegido por derechos de autor. Sin embargo, el usuario podrá usar una copia y utilizar los códigos fuente de la programación y la documentación siempre bajo la autorización del autor, los tutores y de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria.

2.3. Restricciones

El usuario no podrá realizar ingeniería inversa, de compilación o desensamblado del programa. El usuario podrá transferir el programa a un tercero, siempre que no tenga copias del programa, incluyendo posibles actualizaciones o retener material escrito adicional que acompañe al programa.

2.4. Garantía

El autor garantiza que la aplicación funcionará correctamente siempre que la instalación se realice de acuerdo con lo especificado en los requisitos informáticos. Asimismo, se garantiza que el soporte en el cual está grabado el programa no contendrá defectos en el momento de la adquisición del mismo.

La única excepción de lo expuesto en el párrafo anterior es que el programa está creado sin garantías de ninguna clase. El autor no asegura, garantiza, o realiza ninguna declaración respecto al uso o los resultados derivados de la utilización del programa o de la documentación.

2.5. Limitación de responsabilidad

En ningún caso serán el autor ni los tutores, ni la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de las Palmas de Gran Canaria responsables de los perjuicios directos, indirectos incidentales o consiguientes, gastos, lucro cesante, pérdida de ahorros, interrupción de negocios, pérdida de información comercial o de negocio, o cualquier otra pérdida que resulte del uso o de la incapacidad de usar el programa o la documentación. El usuario conoce y acepta que los derechos de licencia reflejan esta asignación de riesgo como el resto de cláusulas y restricciones. El autor rechaza cualquier otra garantía que no haya sido indicada anteriormente.

2.6. Actividades de alto riesgo

El programa no está exento de errores y no ha sido diseñado ni proyectado para ser utilizado en entornos peligrosos que requieran un funcionamiento con protección ante errores, incluyendo, pero no limitándose a: operaciones en instalaciones nucleares, sistemas de comunicación o navegación aérea, control del tráfico aéreo, sistemas de

armamento o equipos de protección vital, en las cuales el fallo de cualquier aplicación podría ser causa directa de muerte, lesiones o daños físicos o daños a la propiedad graves (en general, “Actividades de Alto Riesgo”). El autor del software rechaza expresamente cualquier garantía explícita o implícita de adecuación para Actividades de Alto Riesgo.

2.7. Varios

En el supuesto de que cualquier disposición de esta licencia sea declarada total o parcialmente inválida, la cláusula afectada será modificada convenientemente de manera que sea ejecutable una vez modificada, plenamente eficaz, permaneciendo el resto de este contrato en vigencia.

Este Contrato se rige por las leyes de España. El usuario acepta la jurisdicción exclusiva de los tribunales de este país en relación con cualquier disputa que pudiera derivarse de la presente licencia.

PRESUPUESTO

Presupuesto

En este apartado se presentarán los gastos estimados generados por este PFC. El presupuesto del presente proyecto se ha obtenido según precios de mercado actual e indicaciones del COITT (Colegio Oficial de Ingenieros Técnicos de Telecomunicación) y la Asociación Española de Ingenieros de Telecomunicación para los derechos de visado en el 2010.

Se incluirán los siguientes conceptos:

- Trabajo tarifado por tiempo empleado.
- Amortización del inmovilizado material.
- Redacción del proyecto.
- Derechos de visado del COITT.
- Gastos de tramitación y envío.

P1. Trabajo tarifado por tiempo empleado

Siguiendo las recomendaciones del COIT, se obtiene una aproximación el importe de las horas empleadas en la realización del proyecto. Los honorarios totales se calculan en base a la siguiente expresión:

$$H = (74,88 \cdot H_n \cdot C_T) + (96,72 \cdot H_e \cdot C_T)€$$

Dónde:

- H son los honorarios por tiempo.
- H_n son las horas trabajadas dentro de la jornada laboral.
- H_e son las horas especiales trabajadas.

- C_T es un factor de corrección en función del número de horas trabajadas.

Para la realización del presente Proyecto Fin de Carrera, se estima que se ha trabajado 1340 horas laborales (8 horas x 5 días x 33,5 semanas). El COIT establece el valor del coeficiente según las horas trabajadas de acuerdo con la siguiente tabla.

HORAS TRABAJADAS	FACTOR DE CORRELACIÓN C_T
Hasta 36 horas	1,0
De 36 a 72 horas	0,90
De 72 a 108 horas	0,80
De 108 a 144 horas	0,70
De 144 a 180 horas	0,65
De 180 a 360 horas	0,60
De 360 a 540 horas	0,55
De 540 a 720 horas	0,50
De 720 a 1080 horas	0,45
Más de 1080 horas	0,40

Tabla 40: Relación entre horas trabajadas y factor de corrección.

Como el número de horas trabajadas es superior a 1080 horas, se aplica un factor de corrección C_T de 0,40. Mediante la fórmula anterior se obtienen los honorarios totales por las horas dedicadas al proyecto.

$$H=74,88 \cdot 1340 \cdot 0,40 = 40135,68 \text{ €}$$

La tarifa por tiempo de ejecución es de CUARENTA MIL CIENTO TREINTA Y CINCO EUROS CON SESENTA Y OCHO CÉNTIMOS.

P2. Amortización del inmovilizado material

En este apartado consideraremos los gastos de equipos informáticos, maquinaria, derivados y licencias de software. Se estipula el coste de amortización para un período de 3 años, utilizando un sistema de amortización lineal o constante. En este sistema, se supone que el inmovilizado material se deprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula haciendo uso de la fórmula:

$$\text{Cuota de amortización anual} = \frac{\text{Valor de adquisición} - \text{Valor residual}}{\text{Nº de años de vida útil}}$$

Siendo el valor residual el valor teórico que se supone tendrá el elemento en cuestión después de su vida útil, teniendo en cuenta los índices de depreciación actual.

Puesto que la elaboración del proyecto ha supuesto ocho meses de trabajo y el cálculo del coste de amortización se estipula en un período de 3 años, los costes serán calculados como los derivados del primer año. En la tabla 1 se muestra el material necesario para la realización del proyecto, indicando en cada elemento su valor de adquisición, valor residual y coste de amortización.

Equipo	Valor de adquisición	Valor residual	Coste de amortización
Ordenador Acer Procesador Intel i3 M-370	400 €	150 €	200 €
1 bomba de agua ALP800	153 €	90 €	51 €
Mangueras y codos	35 €	0 €	12 €
Discos	24 €	0 €	8 €
Manometro			
Impresora laser	180 €	45 €	45 €
disco duro externo	99,95 €	50 €	33 €
TOTAL			349,32€

Tabla 41: Gastos de amortización del inmovilizado material.

Por tanto, el coste total del hardware empleado asciende a TRESCIENTOS CUARENTA Y NUEVE CON TREINTA Y DOS CÉNTIMOS.

Software	Valor de adquisición	Valor residual	Coste de amortización
Microsoft Windows 7 Home Edition	105 €	0 €	35 €
Microsoft Office 2010	129,99 €	0 €	43,33 €
Matlab R2010a	3900 €	0 €	1300 €
TOTAL			1378,33 €

Tabla 42. Gastos de amortización del inmovilizado inmaterial.

Por tanto, el coste total del software empleado es MIL TRESCIENTOS SETENTA Y OCHO CON TREINTA Y TRES CÉNTIMOS.

P3. Costes de material fungible

Además de los recursos hardware y software, en este proyecto se han empleado otros materiales que se especifican como material fungible a continuación:

Concepto	Coste
Papel de impresión	18,25 €
Tinta de impresión negra	29,90 €
Encuadernación	15 €
DVD-R de 4,7 GB	2 €
TOTAL	65,15 €

Tabla 43. Costes del material fungible

El importe total del material fungible asciende a la cantidad de SESENTA Y CINCO EUROS CON QUINCE CÉNTIMOS.

P4. Redacción del proyecto

El valor monetario asociado a la redacción de la memoria de proyecto será un 5% del presupuesto de ejecución, con lo que se determina como:

$$R = 0,05 * P * Ch$$

Donde P es el presupuesto de ejecución del proyecto y C_h un coeficiente de ponderación en función del presupuesto

El valor de P se halla sumando los costes de las secciones anteriores correspondientes al trabajo tarifado por tiempo empleado y a la amortización del inmovilizado material e inmaterial. Este será:

$$P = (40135,68 + 349,32 + 1378,33 + 65,15) = 41928,48€$$

El valor del coeficiente de ponderación viene estipulado por el COIT, cuyo valor para proyectos menores a 42.070,70 € está fijado en 0,5.

Teniendo en cuenta el presupuesto calculado en la tabla anterior, se tiene que:

$$R=0,07 \cdot P \cdot C_h=0,07 \times 41928,48 \times 0,5=1467,49\text{€}$$

Por lo tanto el importe final de redacción de proyecto asciende a la cantidad de MIL CUATROCIENTOS SESENTA Y SIETE EUROS Y CUARENTA Y NUEVE CENTIMOS.

P5. Derechos de visado

El COIT establece que para la redacción de proyectos y trabajos en general, los derechos de visado se calculan de acuerdo con la siguiente ecuación:

$$V = 0.006 * P * C$$

Dónde:

- P es el presupuesto total.
- C el coeficiente reductor en función del presupuesto.

El presupuesto total se obtiene de la suma de las secciones anteriores correspondientes al trabajo tarifado por tiempo empleado, la amortización del inmovilizado material y la redacción del proyecto, como se observa en la tabla.

Concepto	Coste
Trabajo tarifado por tiempo empleado	40135,68 €
Amortización del inmovilizado material	349,32€
Amortización del inmovilizado inmaterial	1378,33 €
Coste de material fungible	65,15 €
Redacción del proyecto	1467,49 €
TOTAL	43.395,97 €

Tabla 44.Derechos de visado.

En función del presupuesto obtenido, se extrae el valor del coeficiente reductor del presupuesto C, que según el COIT, para presupuestos de más de 30.050€ y menos de 90.150€ viene definido con un valor de 0,90.

Por tanto:

$$V = 0,006 * 43.395,97 * 0,90 = 234,34 \text{ €}$$

Finalmente, los costes por derecho de visado del proyecto ascienden a DOSCIENTOS TREINTA Y CUATRO EUROS Y TREINTA Y CUATRO CENTIMOS.

P6. Gastos de tramitación y envío

Los gastos de tramitación y envío son fijos y se estipulan por el COIT en 6,01€ por cada documento en un visado digital.

De este modo, los gastos de tramitación y envío ascienden a SEIS EUROS CON UN CÉNTIMO.

P7. Presupuesto antes de impuestos

Sumando todos los conceptos calculados hasta el momento, se obtiene el total del presupuesto previo a la aplicación de impuestos:

Concepto	Coste
Trabajo tarifado por tiempo empleado	40135,68 €
Amortización del inmovilizado material	349,32 €
Amortización del inmovilizado inmaterial	1378,33 €
Redacción del proyecto	1467,49€
Material Fungible	65,15
Derechos de visado del COIT	234,34 €
Gastos de tramitación y de envío	6,01 €
TOTAL	43.636,32 €

Tabla 45. Presupuesto antes de impuestos.

El presupuesto calculado antes de impuestos asciende a CUARENTA Y TRES MIL SEISCIENTOS TREINTA Y SEIS EUROS CON SETENTA Y DOS CÉNTIMOS.

P8. Presupuesto después de impuestos

Al subtotal anterior habrá que incluir un 7% de IGIC.

$$Total = \frac{7 * 43636,32}{100} + 43636,32 = 46690.86 \text{ €}$$

El presupuesto total ascenderá pues a CUARENTA Y SEIS MIL SEISCIENTOS NOVENTA EUROS CON TREINTA Y DOS CÉNTIMOS.

Las Palmas de Gran Canaria, a 15 de JUNIO de 2015

Fdo. Garoé M. Gómez Bolaños