

Instituto Tecnológico de Costa Rica
Escuela de Ingeniería Electrónica



**Diseño de un detector de sonidos de motosierra con bajo
consumo energético.**

Informe de Proyecto de Graduación para optar por el título de
Ingeniero en Electrónica con el grado académico de Licenciatura

Andrey David Villegas Li

Cartago, 25 de febrero de 2013

Declaro que el presente Proyecto de Graduación ha sido realizado enteramente por mi persona, utilizando y aplicando literatura referente al tema e introduciendo conocimientos propios.

En los casos en que he utilizado bibliografía he procedido a indicar las fuentes mediante las respectivas citas bibliográficas. En consecuencia, asumo la responsabilidad total por el trabajo de graduación realizado y por el contenido del correspondiente informe final.

A handwritten signature in black ink, appearing to read "Andrey David Villegas Li". The signature is stylized and somewhat cursive, with the first name "Andrey" being the most prominent part.

Andrey David Villegas Li


Cartago, 25 de febrero de 2013

Céd: 5-0341-0047

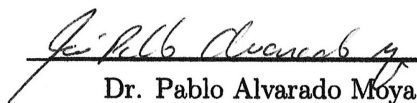
Instituto Tecnológico de Costa Rica
Escuela de Ingeniería Electrónica
Proyecto de Graduación
Tribunal Evaluador

Proyecto de Graduación defendido ante el presente Tribunal Evaluador como requisito para optar por el título de Ingeniero en Electrónica con el grado académico de Licenciatura, del Instituto Tecnológico de Costa Rica.

Miembros del Tribunal



Dr. Alfonso Chacón Rodríguez
Profesor Asesor



Dr. Pablo Alvarado Moya
Profesor Lector

Los miembros de este Tribunal dan fe de que el presente trabajo de graduación ha sido aprobado y cumple con las normas establecidas por la Escuela de Ingeniería Electrónica.

Cartago, 21 de febrero de 2013

Resumen

Con el objetivo de resguardar las zonas protegidas localizadas en el territorio nacional contra la caza y tala ilegal, es necesario proveer a las instituciones encargadas de la administración y cuidado de estas áreas de conservación con mecanismos de detección automatizada de sonidos de disparos y motosierras. Para esto se pretende mediante la herramienta LabVIEW[®] comprobar alguno de los algoritmos disponibles para realizar la detección de periodicidad, característica presente en sonidos generados por máquinas de combustión interna como lo son los motores de automóviles y los motores presentes de las motosierras.

Palabras clave: Detector de motosierra, procesamiento digital de señales, función de autocorrelación, medición de periodicidad, sistema de reconocimiento de patrones acústicos.

Abstract

With the objective to safeguard protected areas located in our national lands against the illegal hunting and logging, it is necessary to provide the institutions in charge the management and care of these conservation areas with detection mechanisms automated of sounds of gunfire and chainsaws. For this, some algorithms intended for the detection of periodicity are tested using the LabVIEW software suit. Periodicity is a sound characteristic common to internal combustion engines such as cars and chainsaws.

Keywords: Chainsaw detector, digital signal processing, autocorrelation function, periodicity measurement, SIRPA .

A Dios por todas las bendiciones recibidas a lo largo de toda mi vida. A mis padres quienes con su apoyo y oraciones me dieron la fortaleza necesaria para seguir adelante.

Agradecimientos

Primeramente a Dios por permitirme culminar con éxito este proyecto y por todas las bendiciones recibidas. Al Instituto Tecnológico de Costa Rica, por ser mi casa de enseñanza durante todos estos años y por permitir mi realización profesional. A mi profesor Dr. Ing. Alfonso Chacón Rodríguez, por todo su apoyo durante todas las fases del proyecto, como también al Profesor Dr. Ing. Pablo Alvarado Moya por toda la colaboración brindada durante la investigación. A mi novia Kristy Vanessa Reyes Aparicio, por apoyarme en todo momento y por sus palabras de aliento, que me permitieron seguir adelante. Y a todas las personas que de alguna u otra manera me ayudaron desinteresadamente, mil gracias...

Andrey David Villegas Li

Cartago, 25 de febrero de 2013

Índice general

Índice de figuras	iii
Índice de tablas	v
1 Introducción	1
1.1 Entorno del proyecto	1
1.2 Definición del problema	3
1.3 Objetivos del proyecto	4
1.3.1 Meta	4
1.3.2 Objetivo general	4
1.3.3 Objetivos específicos	4
2 Marco teórico	5
2.1 Estimador de máxima verosimilitud (MLE)	5
2.2 Función de autocorrelación (ACF)	6
2.3 Medición de periodicidad (PM)	8
2.4 Análisis de la característica operativa del receptor (curva ROC)	9
2.5 Herramientas de diseño	13
3 Enfoque de la solución	14
3.1 Selección del método apropiado para la detección	15
3.1.1 Transformada de onditas	15
3.1.2 Medición por periodicidad	16
4 Análisis de Resultados	18
4.1 Medición de periodicidad mediante el estimador de máxima verosimilitud	18
4.2 Propuesta de filtro para el paso de armónicas fundamentales	21
4.3 Cálculo de autocorrelación y medición de periodicidad	24
4.4 Detector de sonidos incluyendo filtro y submuestreador	28
4.5 Eficiencia del algoritmo detector de periodicidad mediante curvas ROC	32
4.5.1 Eficiencia obtenida para el algoritmo con diferentes ventanas	33
4.5.2 Eficiencia obtenida en punto fijo para la ventana seleccionada	36
5 Conclusiones	41

Bibliografía	43
A Diagrama de bloques funcionales	44
B Tutorial para el uso de programación gráfica en LabVIEW	47
B.1 Estructuras importantes utilizadas en el Software LabVIEW	47
B.2 Bloques y variables importantes utilizadas en el algoritmo	50

Índice de figuras

1.1	Red inalámbrica para la detección de disparos y motosierras [1].	2
1.2	Diagrama de bloques para detector de sonidos de disparos y motosierras. . .	3
2.1	Análisis de autocorrelación para sonido de motosierra en el bosque.	8
2.2	Medición de periodicidad para señal de sonido de motosierra.	9
2.3	Matriz de contingencia para un clasificador de dos estados.	11
2.4	Curva ROC para la detección de sonidos de motosierra.	12
4.1	Estimación de periodicidad para grabación de sonido de motosierra.	19
4.2	Estimación de periodicidad para grabación de sonido de lluvia.	21
4.3	Análisis de autocorrelación para sonido de motosierra.	25
4.4	Análisis de autocorrelación para sonido de lluvia.	25
4.5	Análisis de autocorrelación para disparo de arma R38.	25
4.6	Análisis medición de periodicidad para sonido de motosierra.	26
4.7	Análisis medición de periodicidad para sonido disparo de arma calibre 38. .	27
4.8	Matriz de detecciones para sonido de motosierra.	27
4.9	Matriz de detecciones para sonido disparo de arma calibre 38.	28
4.10	Análisis ROC para diferentes distancias con una una ventana de análisis de 100 muestras. a)Distancia de 30m, eficiencia de 61.3%. b)Distancia de 90m, eficiencia de 62.7%. c)Distancia de 250m, eficiencia de 55.8%. d)Distancia de 600m, eficiencia de 51.1%	34
4.11	Análisis ROC para diferentes distancias con una ventana de análisis de 250 muestras. a)Distancia de 30m, eficiencia de 86.8%. b)Distancia de 90m, eficiencia de 90.02%. c)Distancia de 250m, eficiencia de 80%. d)Distancia de 600m, eficiencia de 74.5%.	35
4.12	Análisis ROC para diferentes distancias con una ventana de análisis de 400 muestras. a)Distancia de 30m, eficiencia de 84.7%. b)Distancia de 90m, eficiencia de 88.9%. c)Distancia de 250m, eficiencia de 79.6%. d)Distancia de 600m, eficiencia de 75.1%.	36
4.13	Análisis ROC para diferentes distancias con 16 bits de longitud de palabra. a)Distancia de 30m, eficiencia de 86.8%. b)Distancia de 90m, eficiencia de 90.02%. c)Distancia de 250m, eficiencia de 80%. d)Distancia de 600m, eficiencia de 74.5%.	37

4.14	Análisis ROC para diferentes distancias con 10 bits de longitud de palabra. a)Distancia de 30m, eficiencia de 87%. b)Distancia de 90m, eficiencia de 90.2%. c)Distancia de 250m, eficiencia de 78.3%. d)Distancia de 600m, eficiencia de 73.9%.	38
4.15	Análisis ROC para diferentes distancias con 8 bits de longitud de palabra. a)Distancia de 30m, eficiencia de 77.8%. b)Distancia de 90m, eficiencia de 74.1%. c)Distancia de 250m, eficiencia de 65.3%. d)Distancia de 600m, eficiencia de 62.2%.	39
4.16	Análisis ROC para diferentes distancias con 6 bits de longitud de palabra. a)Distancia de 30m, eficiencia de 45.8%. b)Distancia de 90m, eficiencia de 47.2%. c)Distancia de 250m, eficiencia de 47.1%. d)Distancia de 600m, eficiencia de 47.7%.	40
A.1	Diagrama de bloques funcional para el diseño desarrollado.	46
B.1	Front y Block Panel para un proyecto en LabVIEW	48
B.2	Blucle while utilizado para el análisis de los sonidos periódicos.	48
B.3	Blucle For utilizado para el análisis de los sonidos periódicos.	48
B.4	Registros de desplazamiento para los bloques iterativos.	49
B.5	Representación gráfica de la estructura secuencial.	49
B.6	Bloques subVIs creados para cálculo de medición de periodicidad y seleccionador de grabaciones.	50

Indice de tablas

4.1	Conversión de periodo para las estimaciones de periodicidad obtenidas de la grabación de sonidos de motosierra de la figura 4.1	20
4.2	Armónicas fundamentales para sonidos de motosierra obtenidas con funciones de procesamiento digital de señales.	22
4.3	Armónicas fundamentales obtenidas para sonidos de lluvia, viento, aviones y disparos de diferentes tipos de armas a variadas distancias y ángulos de adquisición.	23
4.4	Detecciones obtenidas para umbral seleccionado de $1E^{-5}$	28
4.5	Detecciones obtenidas para las grabaciones a una distancia de 30 y 90 metros en función del umbral de detección.	30
4.6	Detecciones obtenidas para las grabaciones a una distancia de 250 y 600 metros en función del umbral de detección.	31

Capítulo 1

Introducción

1.1 Entorno del proyecto

Costa Rica es uno de los países con mayor porcentaje de biodiversidad en el planeta, a pesar de tener un territorio muy pequeño comparado con otros a nivel mundial. Durante décadas Costa Rica ha desarrollado políticas de conservación y protección del ambiente que nos a llevado a tener una gran cantidad de áreas protegidas, que suman alrededor de un 25.1% del total del territorio nacional. A pesar que somos uno de los pocos países que ha puesto en marcha este tipo de políticas, la cantidad de recursos proporcionados por el gobierno son insuficientes para solventar tanto las necesidades económicas, como también la parte logística de control y administración de estas zonas.

Entre algunos puntos problemáticos tenemos la caza furtiva, los incendios y la tala ilegal en las reservas forestales costarricenses, que son amenazas para las especies protegidas y los ecosistemas de nuestra región. Las zonas protegidas en general tienen amplias longitudes, lo que implica que el monitoreo y la protección se hacen complicadas para la cantidad limitada de guardaparques que a su vez tienen asignadas esta y otras tareas para poder mantener en funcionamiento las zonas en protección.

Para solventar este inconveniente que poseen las instituciones que se encargan de velar por el cuidado de las áreas protegidas, la Escuela Electrónica del Instituto Tecnológico de Costa Rica ha tenido la iniciativa de proponer proyectos de investigación para la creación de detectores de sonidos de disparos o motosierras y con estos poder realizar monitoreos en amplias regiones de las zonas en problema. Estos dispositivos poseerán módulos de conexión inalámbrica y paneles solares para que presenten un gran tiempo de funcionamiento sin necesidad de un mantenimiento constante. En la figura 1.1 se muestra un diagrama de cómo se conformará la red de sensores en un bosque. Estos se conectan entre sí hasta enviar la información a la central de datos para su posterior manipulación.

Una vez diseñados y colocados los detectores, se podrán localizar con mayor exactitud en lugares donde se están dando posibles eventos de caza o tala de árboles y de esta manera poder desplazar a los guardaparques a esos lugares específicos. Con este mecanismo se

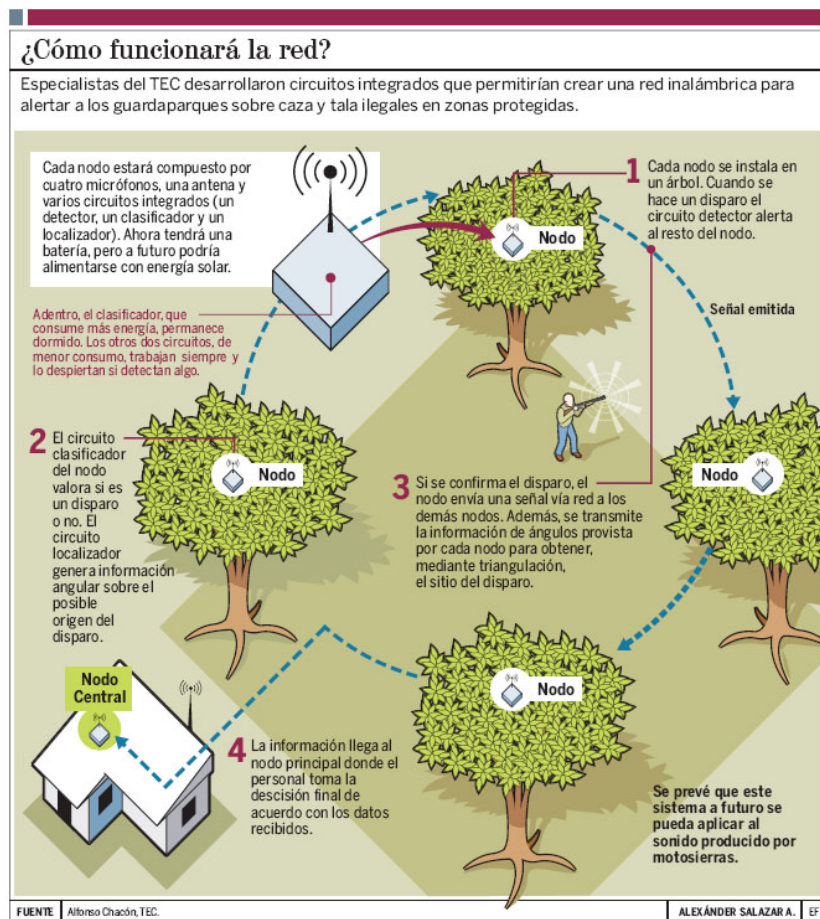


Figura 1.1: Red inalámbrica para la detección de disparos y motosierras [1].

puede hacer un mejor uso del personal ya que no es necesario mantenerlos realizando constantes recorridos por toda la zona.

Para resolver el problema de la detección de los sonidos de motosierras será necesario realizar un análisis matemático de señales grabadas de estos sonidos particulares para así poder encontrar un patrón posiblemente en el dominio de la frecuencia. Con estos patrones se puede proceder al diseño de filtros encargados de obtener las componentes importantes de un posible sonido de motosierra y de esta manera enviar una señal de alerta de los módulos a la central de datos y monitoreo.

1.2 Definición del problema

Dado que existen grandes problemas en la protección de las áreas protegidas en el territorio nacional, el Instituto Tecnológico de Costa Rica se ha dado a la tarea de desarrollar un proyecto en la detección de sonidos de disparos y motosierras, mediante módulos inalámbricos de muy bajo consumo de energía que se conectan entre sí y a la vez con la central de datos. Los módulos están compuestos por varios bloques que determinan si ha ocurrido una posible alerta compuesta por disparos de un arma o sonidos de motosierra en un bosque y con esto poder evitar tanto la caza ilegal como la tala de árboles protegidos.

El proyecto a desarrollar consiste en diseñar un submódulo de bajo consumo de potencia que detecte posibles sonidos de motosierra y que proporcione una salida de alerta que será analizada por un módulo primario llamado SIRPA (Sistema de reconocimiento de patrones acústicos), que tiene como tarea el análisis mediante procesamiento digital de señales del sonido obtenido en el momento que se dio la alarma que envió el submódulo a diseñar.

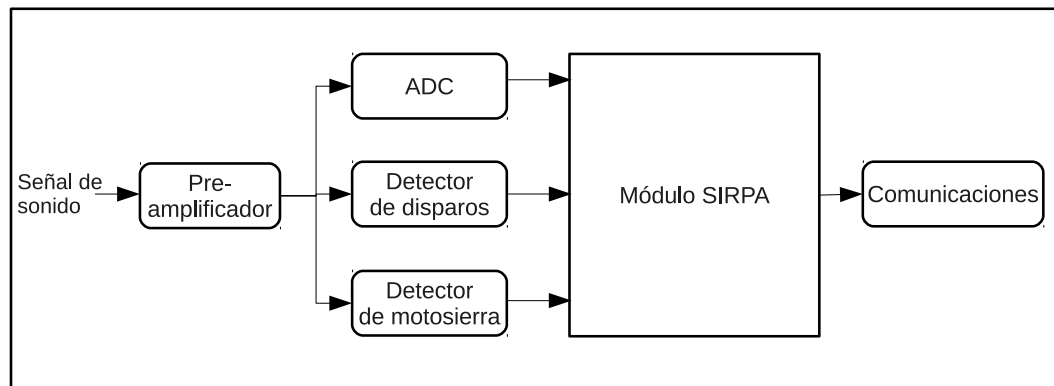


Figura 1.2: Diagrama de bloques para detector de sonidos de disparos y motosierras.

Es importante que exista este bloque de pre-detección ya que como el módulo SIRPA consume más energía, se hace indispensable que antes de activarse exista una detección previa. De esta manera el SIRPA no tiene que estar en funcionamiento todo el tiempo y así se produce un ahorro de energía en la totalidad del dispositivo de detección y comunicaciones. En la figura 1.2 se presenta un diagrama general de los bloques del dispositivo completo, conteniendo los bloques de detección de sonidos de disparos, motosierras y su interconexión con el módulo principal.

1.3 Objetivos del proyecto

1.3.1 Meta

- Proteger y conservar los ecosistemas naturales y áreas protegidas mediante la detección de actividades ilegales como la tala de árboles, utilizando sistemas electrónicos de monitoreo para evitar el uso excesivo de recursos o falta de acción por escasez de ellos.

1.3.2 Objetivo general

- Diseñar un detector de sonidos de motosierra con la menor complejidad posible, para su posterior fabricación en tecnología CMOS.

1.3.3 Objetivos específicos

1. Determinar el tipo de tecnología más apropiado, analógico o digital, para la generación de un diseño simplificado mediante tecnología CMOS.
2. Analizar y seleccionar el algoritmo más apropiado para la interpretación de los espectros característicos de los sonidos de motosierra, que simplifiquen la detección electrónica de los mismos.
3. Desarrollar y optimizar el algoritmo seleccionado para diseño del detector de motosierras, generando si es posible una comprobación real mediante el uso de una FPGA con la ayuda de un reproductor digital de sonidos.

Capítulo 2

Marco teórico

Gracias a los diferentes avances en el campo de la física y de la matemática, se han podido realizar investigaciones que tratan de facilitar las tareas en el diseño de productos de ingeniería aplicada. Por esto a continuación se detallarán los procesos matemáticos utilizados para poder realizar esta investigación y corroborar que con los algoritmos utilizados se pueden llegar a obtener detecciones de sonidos de motosierra y además diferenciarlos de otro tipo de señales que podrían ser o no periódicas.

2.1 Estimador de máxima verosimilitud (MLE)

El estimador de máxima verosimilitud se utiliza en este proyecto para el cálculo de las posibles periodicidades presentes en las grabaciones hechas en el bosque. Vectores generados mediante la grabación de sonidos con equipo especializado son convertidos en formato “.mat” para su fácil análisis en Matlab[®].

Una señal se puede descomponer como una parte periódica más otra de ruido tal que:

$$x[k] = s[k] + n[k] \quad (2.1)$$

donde:

$s[k]$: Señal periódica.

$n[k]$: Ruido.

La señal $s[k]$ se puede considerar con una repetición de un subsegmento $q[k]$ que depende de los valores de periodicidad a los que se les realizará el análisis.

La función que porta la periodicidad está compuesta por los segmentos $q[k]$ para los diferentes valores de periodicidad como se muestra a continuación:

$$s[k] = q[k \bmod P] \quad (2.2)$$

Para cada valor de “P” se obtiene.

$$q_P[k] = \frac{1}{L} \sum_{l=0}^{L-1} x[k + lP] \quad (2.3)$$

con $L = K/P$. De esta manera cuando se obtienen los diferentes valores $q_P[k]$, se analizan los vectores que maximizan la energía mediante (2.4) para cada P .

$$\mathcal{E}_x(P) = L \sum_{k=0}^{P-1} (q_P[k])^2 \quad (2.4)$$

De esta manera con el valor de periodicidad que maximizó la energía en (2.4), se procede a el cálculo de la estimación de máxima verosimilitud.

$$\mathcal{P}_{MLE} = \frac{\mathcal{E}_S}{\mathcal{E}_N} = \frac{\sum_{k=0}^{K-1} (s[k])^2}{\sum_{k=0}^{K-1} (x[k] - s[k])^2} \quad (2.5)$$

Donde K es la cantidad de muestras a analizar y el vector $s[k]$ es el que contiene las muestras con el valor P determinado por la máxima energía en (2.4).

Este método presentado conlleva un arduo procesamiento de computación, ya que es necesario procesar una gran variedad de valores de periodicidad para así poder calcular el P que maximiza la energía en el cálculo con las muestras. De esta manera, será necesario utilizar algún algoritmo alternativo para poder realizar un diseño más sencillo que determine los datos con menos poder de procesamiento. Para esto se exponen los temas siguientes.

2.2 Función de autocorrelación (ACF)

La correlación es generalmente utilizada para realizar comparaciones entre dos diferentes funciones o secuencia de datos. De esta se deriva la autocorrelación que opera una secuencia real con ella misma pero con un índice de desplazamiento o retardo de tiempo para analizar la similitud de sus mismos datos. La correlación es similar a la operación de la convolución, solo que sin realizar el paso de reflexión de alguna de las señales, pero sí la secuencia producto del traslape y luego la suma de los resultados de los productos anteriores.

Como se menciona en [2], si las dos señales a correlacionar son las mismas, entonces se calcularía la autocorrelación de la señal o secuencia de datos, que vendría definida por (2.6) para valores reales y con energía infinita.

Si $y(t) = x(t)$ para convertir la correlación en una autocorrelación, entonces:

$$r_{xx}(n) = \sum_{k=-\infty}^{\infty} x(k)x(k+n) \quad (2.6)$$

Si se utiliza una señal causal infinita de longitud N , la autocorrelación se expresa de la siguiente manera:

$$r_{xx}(n) = \sum_{k=\max\{n,0\}}^{N+\min\{0,n\}} x(k)x(k-n) \quad (2.7)$$

Una de las propiedades más importantes de la autocorrelación se establece que:

$$|r_{xx}(n)| \leq r_{xx}(0) = \mathcal{E}_x \quad (2.8)$$

Esto quiere decir que la autocorrelación alcanza su valor máximo para el retardo cero cuando la señal es idéntica a si misma. Luego para los diferentes retardos los valores picos irán decayendo dependido de cuantas sumas de productos queden por calcular y dependiendo de las intensidades que son multiplicadas en cada momento con determinado retardo.

Una buena práctica para el análisis de la autocorrelación es normalizar para producir valores entre -1 y 1. Para llevar acabo la normalización es necesario dividir los resultados entre la energía presente en cada momento de cálculo de autocorrelación.

$$\rho_{xx}(n) = \frac{r_{xx}(n)}{r_{xx}(0)} \quad (2.9)$$

Cuando las señales son de potencia en vez de energía, así como las grabación obtenidas de sonidos, se puede re-ajustar las ecuaciones para que tenga la propiedad de encontrar periodicidades en señales físicas que están combinadas con interferencias aleatorias como lo serían sonidos del río, bosque, pájaros. Este cambio se presenta en [3] y con esto tenemos:

$$r_{xx}(n) = \frac{1}{N} \sum_{k=0}^{N-1} x(k)x(k-n) \quad (2.10)$$

donde N es el número de muestras total de la señal.

Si la señal analizada presenta periodicidad, entonces la gráfica de autocorrelación presentará un comportamiento con picos periódicos cada n cantidad de muestras.

La figura 2.1 presenta una curva característica de autocorrelación cuando se realiza una análisis a una señal periódica que contiene sonidos de motosierra. Se puede observar los picos presentados cada cierta cantidad de muestras y su caída de valores conforme se

introdujo mayor retardo al cálculo de la sumatoria de productos. Donde se presentan los picos más pronunciados es donde se localizan los valores de periodo presentes en la señal.




Figura 2.1: Análisis de autocorrelación para sonido de motosierra en el bosque.

2.3 Medición de periodicidad (PM)

Ya que por medio de algoritmo de estimación de máxima verosimilitud se requiere una gran carga de computación al estimar los valores de periodicidad p para determinar los puntos donde se maximiza la energía de la señal, es necesario tener otra alternativa de medición de periodicidad que se pueda calcular mediante métodos menos extenuantes para un hardware de bajo consumo de potencia. Para esto se utilizará el método de cálculo de autocorrelación presentada en la sección anterior, más un algoritmo de medición de periodicidad que cuantifique la energía para diferentes valores de retrasos.

Cuando se calcula la autocorrelación para un sonido con baja periodicidad, hay bajos niveles cuando se utilizan altos valores de retrasos; en cambio, si se presentan señales con múltiples valores de periodicidad se detectan altos niveles de energía con valores altos de retrasos y ventanas de cálculos relativamente grandes. Sabiendo esto, se puede formular una alternativa de medición de periodicidad que cuantifique estos niveles.

Como primera aproximación se presenta una sumatoria de los cuadrados de valores obtenidos por el algoritmo de autocorrelación, en la ecuación representada a continuación:

$$\mathcal{P}_{alt} = \sum_{n=N_{min}}^{N_{max}} (\bar{R}_{xx}[n])^2 \quad (2.11)$$

De esta manera, se puede decir que la potencia de estimación de la señal está relacionada con los valores picos la función de autocorrelación que ocurren para cada p muestras.

Para utilizar (2.11) es necesaria una señal estacionaria, donde no ocurran fluctuaciones en baja frecuencia que introduzcan picos adicionales a la función de autocorrelación. Estos pico producen un *offset* en el cálculo de autocorrelación, generando un error que

no permite la detección de periodicidad en la señal. Por esto es necesario realizar una modificación a la ecuación de medición de periodicidad planteada anteriormente, realizando una derivación en el tiempo y calculando luego la suma de cuadrados. Así:

$$\mathcal{P}_{alt} = \sum_{n=N_{min}}^{N_{max}-1} (\bar{R}_{xx}[n+1] - \bar{R}_{xx}[n])^2 \quad (2.12)$$

Para determinar si existe cierto nivel de periodicidad, se debe seleccionar un valor umbral de detección, para que cuando se sobrepase ese umbral se esté en presencia de cierta periodicidad en la señal analizada. El umbral a escoger estará determinado por la periodicidad que se desea encontrar. La figura 2.2 muestra una señal de medición de periodicidad para una detección de sonidos de motosierra que posee componentes de señal periódico alrededor de los 150Hz.

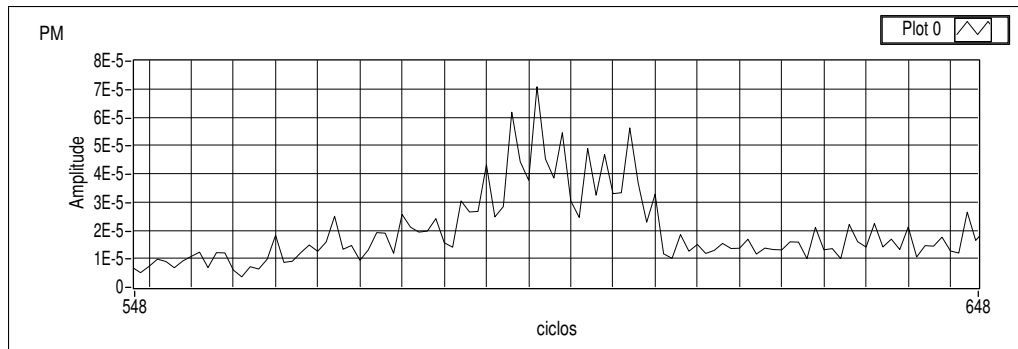


Figura 2.2: Medición de periodicidad para señal de sonido de motosierra.

2.4 Análisis de la característica operativa del receptor (curva ROC)

El estudio de las curvas ROC, o análisis ROC es una técnica para visualizar, organizar y seleccionar algoritmos o procedimientos basados en el rendimiento. Es una representación de la razón de verdaderos positivos frente a la razón de falsos positivos. La razón cambia conforme se varíe el umbral de discriminación que es el valor a partir del cual decidimos que un caso es un positivo.

Este análisis proporciona herramientas para seleccionar los modelos posiblemente óptimos y descartar modelos menos óptimos, independientemente del coste de la distribución de las dos clases sobre las que se decide.

La curva ROC se desarrolló por ingenieros eléctricos para medir la eficacia en la detección de objetos enemigos en campos de batalla mediante pantallas de radar, a partir de lo cual se desarrolla la Teoría de Detección de Señales (TDS). El análisis ROC se aplicó posteriormente en medicina, radiología, psicología y otras áreas durante varias décadas.

El análisis ROC se obtiene mediante la comparación de dos funciones a las que se les aplica un punto de corte y este se varía en secciones donde las funciones se traslapan. En nuestro caso estos puntos de corte se presentan donde al realizarse una medición de detección de sonidos de motosierra, empiezan a disminuir la cantidad de detecciones de los sonidos buscados y aumentan las detecciones los demás sonidos que no son de interés ya que no representan patrones característicos de motosierra.

Cuando se tiene un algoritmo clasificador binario, así como en la detección de sonidos de motosierra, en una ventana determinada de cálculo con datos discretos de la señal de sonido adquirida, las posibles detecciones se clasifican en dos clases diferentes definidas como “positivas” y “negativas”. Para estas dos clases tenemos cuatro diferentes resultados:

1. Verdadero positivo (VP).
2. Falso positivo (FP).
3. Verdadero negativo (VN).
4. Falso negativo (FN).

Un verdadero positivo (VP) es aquel valor que se detectó como positivo y que en la función característica es positivo también. Por el contrario un falso positivo (FP) es un valor que se detectó como positivo pero que en realidad es negativo. Un verdadero negativo (VN) consiste en un valor negativo que en realidad si es negativo y un falso negativo (FN) es un valor positivo que fue detectado como negativo. Se busca obtener en el análisis ROC la mayor cantidad de verdaderos positivos para que la tendencia en la gráfica sea a presentar la mayor área bajo la curva. Los valores menos deseados son los presentados por los falsos negativos, ya que estos serían valores verdaderos detectados como si fuesen negativos, por lo que en nuestro caso no serían detecciones de los sonidos de motosierra.

Con los resultados que se obtienen en un análisis, se puede formular una tabla de contingencia en donde se localizan los resultados en diferentes posiciones clasificados por los cuatro posibles valores mencionados anteriormente. La tabla de contingencia se presenta en la figura 2.3 y se utiliza para facilitar la interpretación de la curva ROC.

Con esta tabla se construye una representación de las disposiciones del conjunto de instancias producidas con el análisis de los sonidos de motosierra y otros sonidos de los que se quiere discernir. Esta matriz conforma la base para varias métricas necesarias para la generación de la curva ROC.

Para la construcción de la curva ROC se conforma de un gráfico de dos dimensiones que tiene como eje y la razón de verdaderos positivos o sensibilidad. En el eje x tenemos la razón de falsos positivos o especificidad. Los dos ejes van desde un valor mínimo de “0” hasta un máximo de “1” para así tener un valor de eficiencia del análisis generado. Las ecuaciones para poder obtener los pares (puntos de la curva) producidos por los diferentes puntos de corte y de esta manera generar la curva ROC se presentan a continuación.

		Valor en la realidad		Total
		<i>P</i>	<i>N</i>	
Predicción	<i>p'</i>	Verdaderos Positivos	Falsos Positivos	<i>P'</i>
	<i>n'</i>	Falsos Negativos	Verdaderos Negativos	<i>N'</i>

Figura 2.3: Matriz de contingencia para un clasificador de dos estados.

$$\text{Razón verdaderos positivos} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos negativos}} \quad (2.13)$$

donde:

$$\text{Razón verdaderos positivos} = \text{Sensibilidad} \quad (2.14)$$

Por el lado del eje x tenemos que la razón de falsos positivos se describen con las siguientes ecuaciones:

$$\text{Razón falsos positivos} = \frac{\text{Falsos positivos}}{\text{Falsos positivos} + \text{Verdaderos negativos}} \quad (2.15)$$

donde:

$$\text{Razón falsos positivos} = 1 - \text{Especificidad} \quad (2.16)$$

Mediante (2.13) y (2.15) se construye la curva ROC para diferentes puntos de corte. Un ejemplo de los puntos generados a diferentes valores de umbral de detección para sonidos de motosierra se presenta en la figura 2.4.

Una vez generada la curva se procede a calcular el área bajo la curva para obtener la eficiencia de detección del procedimiento utilizado en determinar si se presentan sonidos de motosierra, o si no existe patrón que contengan dichos sonidos. En el caso del análisis presentado para la figura 2.4 se obtuvo un valor de área bajo la curva de 0.91 equivalente a 91% de efectividad en la detección de sonidos de motosierra.

El algoritmo para la generación de las curvas ROC se presenta en el Listado 2.1 obtenido de [4].




Figura 2.4: Curva ROC para la detección de sonidos de motosierra.

Listado 2.1: Algoritmo simplificado para la generación de curvas ROC

```

1 for t = min to max by increment do
2   FP ← 0
3   TP ← 0
4   for i ∈ L do
5     if f(i) ≥ t then /* Control del umbral */
6       if i is a positive example then
7         TP ← TP + 1
8       else
9         FP ← FP + 1
10      end if
11    end if
12  end for
13  Add point ( FP/N , TP/P ) to ROC curve
14 end for
15 end

```

donde:

L : Es el conjunto de instancias.

$f(i)$: Clasificador de probabilidad para una detección positiva.

N : Cantidad de muestras positivas.

P : Cantidad de muestras negativas.

De esta manera se utilizará igualmente el algoritmo en el listado 2.1 para generar las curvas ROC para nuestro análisis.

2.5 Herramientas de diseño

Para la realización de las diferentes pruebas y análisis que son necesarias para llevar a cabo la investigación, se utilizarán los programas MATLAB[®] y LabVIEW[®]. Ambas herramientas serán usadas para el análisis de las grabaciones que se poseen de sonidos de motosierras, disparos, lluvia, etc. Principalmente LabVIEW se utilizará para realizar los procedimientos de autocorrelación y medición de periodicidad para así generar un diseño que simule el hardware para la detección de los sonidos.

MATLAB es un lenguaje de alto nivel y un entorno interactivo para el cálculo, la visualización y programación numérica. Mediante este software es posible analizar datos, desarrollar algoritmos y crear modelos o aplicaciones.

LabVIEW es una plataforma y entorno de desarrollo para diseñar sistemas, con un lenguaje de programación visual gráfico. Recomendado para sistemas hardware y software de pruebas, control y diseño, simulado o real y embebido.

Capítulo 3

Enfoque de la solución

Para la ejecución de la solución del sub-módulo pre-detectores de sonidos de motosierra se necesitará de un análisis de los patrones de sonidos obtenidos de grabaciones previamente realizadas. Para el análisis de estas señales se utilizarán herramientas matemáticas como Matlab[®], ayudadas con métodos de procesamiento digital de señales para poder obtener los respectivos patrones en frecuencia para cada señal de sonido analizada. Para esto será necesario el estudio de teoría de procesamiento digital de señales con respecto a los filtros como los de HAAR o el I^2R que descomponen las señales mediante una transformada para su posterior análisis. Entre las posibles soluciones de análisis para las señales tenemos dos opciones:

- Descomposición de ondas de HAAR.
- Análisis de periodicidad.

La descomposición por ondas es un método para saber a cuáles frecuencias y en qué intervalos de tiempo la señal tiene más energía y de esta manera poder determinar en dónde se encuentra la mayoría de la señal en sus bandas de frecuencia características, presente en [5]. En cuanto al método de la periodicidad tenemos que los sonidos de motosierra tienen cierta periodicidad por estar generados por un motor con una determinada velocidad en RPM (revoluciones por minuto). Estos períodos se pueden analizar para determinar el patrón correspondiente a esos sonidos. De entre estos se tendrá que realizar un pequeño análisis previo para la selección de cuál se adapta mejor con el diseño y resultado deseado para el proyecto. Estos métodos para desarrollar el diseño son maneras posibles dentro de la tecnología digital. También se podría atacar el problema con tecnología analógica, que posee la ventaja de una solución con posibilidades de obtener más eficiencia en lo que respecta a disminución de consumo de potencia, pero con la desventaja de presentar un procedimiento complicado y mayor probabilidad a fallos.

Una vez que se ha determinado la tecnología y el algoritmo a utilizar, entonces se procederá a encontrar los patrones en frecuencia de los diferentes sonidos teóricos y experimentales para las motosierras. Estos análisis dan como resultado los parámetros necesarios para poder generar filtros específicos para el diseño del detector mediante técnicas en el

procesamiento digital de señales.

Si se selecciona el algoritmo mediante Wavelets, se buscará la onda madre para tratar de asimilar lo mayor posible a la ondas entrantes de los sonidos. Si más bien se utiliza la detección por medio de análisis de periodicidad, se programarán algoritmos de autocorrelación y medición de periodicidad para obtener detecciones.

3.1 Selección del método apropiado para la detección

Se proponen inicialmente para la posible detección de sonidos de motosierra.

1. Detección por transformada de onditas.
2. Detección por análisis de periodicidad.

Los sonidos de motosierra son generados por motores eléctricos o de combustión interna, por lo que presentan patrones periódicos cuando se están utilizando. Los periodos de los sonidos pueden variar a diferentes velocidades de la motosierra.

Primero se analiza la opción de detección por onditas.

3.1.1 Transformada de onditas

La transformada de onditas constituye una técnica relativamente nueva que ha sido propuesta por los investigadores como una herramienta en el análisis sobre el comportamiento de una señal. Esta transformada utiliza una función ventana que encuadra una señal dentro de un intervalo y focaliza el análisis sólo en ese pequeño segmento de la señal por ser analizado.

Esta transformada intenta expresar una señal $x(k)$ con K muestras en total, mediante una expansión de términos o coeficientes proporcionales al producto interno entre la señal y diferentes versiones escaladas y trasladadas de una función prototipo ψ más conocida como *ondita madre*. Para asemejar la onditas madre al segmento de la señal analizada se producen traslaciones enteras y escalamientos de una única función onditas ψ [6].

Entre las familias de onditas generadoras tenemos:

- Haar.
- Daubechies.
- Biorthogonal.
- Coiflets.
- Symlets.
- Morlet.
- Mexican Hat.

- Meyer.

Como principal uso para la utilización de la transformada de onditas tenemos que se utilizan para la detección de transiciones abruptas, ya que estas producen coeficientes de onditas grandes centradas en las discontinuidad de la señal. En la detección de señales periódicas suaves se pueden detectar algunas características pero no de manera sencilla, ya que los coeficientes producidos no son de gran magnitud; además que hay que utilizar una ondita generadora específica para cada caso que se desee analizar. La detección de un disparo mediante la transformada de onditas es relativamente eficiente ya que el disparo se presenta como una cambio abrupto de la señal, además de que presenta altos niveles energéticos. Como se menciona en análisis previos realizados a sonidos de disparos en [7]. Para señales periódicas este proceso complicado, por lo que una transformada de onditas no es práctico para analizar ondas de este tipo.

Finalmente en el análisis por transformada de onditas se obtiene un banco de filtros que serán los que detecten la señal para la cual fueron configurados.

3.1.2 Medición por periodicidad

El método de medición de periodicidad consiste en poder analizar una señal $x(k)$ con diferentes valores de periodicidad P , para así obtener cuales valores contiene la señal.

Una vez que se conoce los valores de las posibles periodicidades a detectar, se puede diseñar un detector que analice las señales y encuentre un aproximado al valor de periodicidad principalmente de la onda fundamental para determinado sonido. Ya que los motores de combustión interna generan sonidos periódicos por causa de sus mecanismos internos, el análisis de periodicidad es un método eficiente para realizar detecciones para estos sonidos y diferenciarlos de muchos otros que poseen señales con periodicidad variable o con total falta de este. Para este análisis se podrían utilizar algoritmos como el de autocorrelación que tiene como función la búsqueda de similitud entre los mismos datos de una señal utilizando un índice de desplazamiento o retado de tiempo. Una vez obtenidas las relaciones de autocorrelación, se analiza el resultado mediante el algoritmo de periodicidad para detectar niveles bajos o altos de energía dentro de las muestras. Cuando se utilizan altos niveles en los valores para los retrasos de prueba en el algoritmo para medir periodicidad, se pueden obtener valores altos o bajos como resultado. Si existen niveles altos en el cálculo, estaríamos en presencia de niveles periódicos en la señal de entrada analizada, en cambio cuando se obtienen niveles bajos en el algoritmo supondremos que no tenemos presencia de muestras periódicas en esa porción de señal. La ecuación a utilizar para esta medición es la (2.12).

De esta manera al tener un nivel cuando se detectan o no valores de periodicidad en la señal, se puede determinar un umbral de detección para cuando existe cierto nivel en el resultado de medición de periodicidad.

Con el método de medición de periodicidad el análisis se produce de manera más sencilla ya

que la forma de cálculo funciona donde se detectan los niveles de la armónica fundamental que posee valores altos con respecto a las demás armónicas y valores de ruido ambiente presentes en la grabación.

De este modo se selecciona el método por medición de periodicidad para comprobar el algoritmo y determinar los posibles rangos de las variables a utilizar, para poder seleccionar un diseño del detector con un buen porcentaje de confiabilidad y que además sea lo más simplificado posible para poder generarse en otra investigación futura, un hardware minimizado con el menor consumo energético.

Capítulo 4

Análisis de Resultados

Para evaluar los algoritmos se usaron las grabaciones localizadas en medio del bosque natural, con sonidos presentes como el viento, la lluvia, canto de los pájaros, truenos, etc; los sonidos que se extraen de ese ambiente pueden llegar a ser complejos a la hora de detectar ciertos detalles únicos. Ya que se requieren realizar detecciones de sonidos de motosierra en un ambiente como el bosque, será necesario discernir estos sonidos de lo que se encuentran generalmente en la selva. Estos sonidos podrían ocasionar errores en las detecciones, produciendo falsas alarmas en el sistema y provocando desperdicio de energía a la hora de despertar en módulo SIRPA.

Los análisis que se expondrán a continuación serán los encargados de generar un diseño capaz de realizar las detecciones de sonidos de motosierra y de enviar una señal de detección al módulo SIRPA para que este realice un estudio más detallado de la señal sonora entrante en ese preciso momento. El diagrama de bloques para este módulo a producir se presenta en la figura 1.2 como el “*detector de motosierra*”.

Para el análisis de los algoritmos a utilizar, se usaron herramientas como Matlab[®] y LabVIEW[®]. Estas herramientas de análisis y diseño se encuentran disponibles para su uso en la Escuela de Ingeniería Electrónica del Instituto Tecnológico de Costa Rica.

Entre los objetivos del proyecto se encuentra el seleccionar la manera más apropiada de realizar las detecciones de sonidos de motosierra. Para esto se presenta la sección a continuación.

4.1 Medición de periodicidad mediante el estimador de máxima verosimilitud

Como primer paso para el análisis que se va a generar sobre la detección de sonidos de motosierra, fue necesario medir los valores de periodicidad presente en algunas grabaciones hechas en un ambiente natural del bosque con los sonidos de motosierras, disparos, viento, lluvia, etc. La grabaciones se han almacenado en vectores “.mat” para ser manipulados

mediante el programa Matlab[®].

Los vectores que contienen las muestras de las grabaciones con los sonidos a distinguir han sido muestreados a 48kHz. De esta manera para el análisis de los periodos presentes en estos vectores se utilizaran bloques de 48000 muestras que equivalen a 1 segundo.

Realizando un barrido de valores de periodicidad utilizando las ecuaciones anteriormente mostradas, empezando de 1 hasta 250 para unos pocos segundos en los sectores donde se distinguen perfectamente los sonidos de motosierra y de lluvia, de manera separada, se buscarán esos valores donde la energía se maximiza para los determinados valores de periodicidad analizados. Una vez que se tienen los vectores cuando se producen de los cálculos a realizar, se procede a generar una gráfica de tres dimensiones que presenta en una matriz de dos dimensiones, diferentes tonalidades en escala de grises. Las tonalidades claras representan una alta periodicidad de las muestras para cada valor P analizado, así como tonalidades oscuras presentan baja estimación de periodicidad. Color blanco corresponde a valores alrededor de 5dB y los negros corresponden de -30dB.

Las figuras obtenidas se muestran a continuación. La figura 4.1 muestra un análisis de estimación de máxima verosimilitud para una grabación con sonido de motosierra con una duración de 21 segundos. La figura 4.2 presenta el mismo análisis para la grabación de sonido de lluvia con una duración de 14 segundos.




Figura 4.1: Estimación de periodicidad para grabación de sonido de motosierra.

Analizando la figura 4.1 se pueden encontrar ciertos patrones de líneas color claro y que son horizontales que representan alta estimación de periodicidad para cada sector de 1 segundo de longitud. Por ejemplo para un valor P de aproximadamente 150, se puede ver que presenta uno de estos patrones alrededor de los 22 segundos analizados de la vector con sonido de motosierra. Analizando la totalidad de la gráfica, obtenemos los valores de periodicidad en unidades de muestras, con valores de 60, 105, 125, 155, 180, 210 y 240.

Si transformamos estos valores a unidades en Hertz, tenemos los valores de las armónicas representativas de los sonidos de motosierra y de esta manera se sabe en qué sector del espectro se localizan estos. Para obtener estos valores es necesario (4.1).

$$P(Hz) = \frac{1}{P_N \frac{1}{48000}} \quad (4.1)$$

donde P_N es el periodo obtenido del gráfico de estimación de periodicidad presentado en la figura 4.1.

Con los valores obtenidos, se tabulan los resultados para los diferentes valores P analizados. Estos datos se muestran en la Tabla 4.1.

Tabla 4.1: Conversión de periodo para las estimaciones de periodicidad obtenidas de la grabación de sonidos de motosierra de la figura 4.1

Estimación de periodicidad [Muestras]	Periodo [Hz]
60	800.0
105	457.1
125	384.0
155	309.7
180	266.7
210	228.6
240	200.0
250	176.0

Mediante la ecuación (4.1) se construye la tabla 4.1 donde se muestra la equivalencia de periodo en unidades de muestras con periodos pero en unidades de Hertz. Estos valores representan ondas que poseen características de periodicidad en los sonidos de motosierra definidos y estos se pueden utilizar para su posible reconocimiento en rangos de frecuencia específicos.

Para la gráfica de la figura 4.2, no se puede ver a simple vista un patrón de líneas de color horizontales durante la mayoría de tiempo de la porción de grabación analizada. Los bloques de colores se encuentran dispersos y desordenados a diferencia de los resultados obtenidos para la grabación con sonidos de motosierra, por lo que se puede inferir que los sonidos de lluvia no poseen dentro del espectro de frecuencia un patrón definido de señales periódicas.

Con los resultados de este análisis, se puede llegar a la conclusión que es factible poder detectar la señales periódicas incluidas en los sonidos de motosierra y además es posible diferenciarlos de todos los sonidos que se pueden encontrar en la naturaleza.

No obstante, el algoritmo utilizado para realizar la estimación de periodicidad conlleva ecuaciones avanzadas y de alto cálculo computacional, por lo que posiblemente no son aptas para el propósito de un hardware sencillo y de un consumo bajo de potencia. Por esto será necesario utilizar otro algoritmo que utilice menor capacidad de procesamiento computacional.




Figura 4.2: Estimación de periodicidad para grabación de sonido de lluvia.

4.2 Propuesta de filtro para el paso de armónicas fundamentales

Para poder diseñar un detector con un buen porcentaje de eficiencia para algún sonido determinado, es importante la creación de un filtro que no deje pasar las partes de la señal capturada que no interesan y permitir el paso principalmente la armónica fundamental de los sonidos periódicos producidos por los motores de las motosierras. Dentro de la base de datos con la que se cuenta, existen varias grabaciones capturadas en un ambiente de bosque. Entre los sonidos grabados tenemos sonidos de motosierra, lluvia, viento, disparos y voces humanas. Para cada una de estas grabaciones, se realizaron grabaciones paralelas con ángulos de 90 y 180 grados con respecto a la dirección normal del micrófono, además de la grabación principal a 0.

De esta manera se obtuvieron las armónicas fundamentales de todas las grabaciones con sonidos de motosierra y algunos tonos donde se puede corroborar que entre estos tonos se presentan también las armónicas fundamentales antes mencionadas. Los resultados obtenidos para los sonidos de motosierra se presentan en la Tabla 4.2.

La nomenclatura para los nombres de la Tabla 4.2 representan la distancia a la que fueron hechas cada una de las grabaciones, además del ángulo con respecto a dirección normal en la que se posicionó el micrófono del grabador digital. El número posicionado después de la “D” mayúscula representa la distancia del micrófono a la motosierra. El número al final del nombre representa el ángulo con el que se hizo la grabación.

Las frecuencias de las armónicas fundamentales para los sonidos de motosierra para distancias de 250 y 600 metros a diferentes ángulos presentan un gran cambio con respecto a las frecuencias para distancias de 30 y 90 metros. Esto se debe a que a distancias largas

Tabla 4.2: Armónicas fundamentales para sonidos de motosierra obtenidas con funciones de procesamiento digital de señales.

Sonido	Frecuencia de armónica fundamental [Hz]
D030m_Saw_000	125.34
D030m_Saw_090	127.13
D030m_Saw_180	139.68
D090m_Saw_000	148.42
D090m_Saw_090	140.59
D090m_Saw_180	147.82
D250m_Saw_000	20.76
D250m_Saw_090	20.16
D250m_Saw_180	17.89
D600m_Saw_000	22.13
D600m_Saw_090	21.21
D600m_Saw_180	19.31

los sonidos se distinguen menos y se confunden o esconden dentro de los sonidos de ruido generados por el bosque.

Los resultados para las armónicas fundamentales de los demás sonidos se presentan en la Tabla 4.3.

Analizando las frecuencias de la armónica fundamental obtenidas para sonidos que no son de motosierra, se puede observar que la mayoría se mantienen en las frecuencias cercanas al valor de los 20Hz. Algunas otras presentan valores cercanas a 500Hz y 1kHz como lo son las grabaciones para las armas C22 a 30 metros, la R38 a 30m y la Pi9 a 90m. Esto se puede dar por razones variadas, como el ángulo de llegada de las ondas producidas por las armas, así como el eco producido por estas en el medio ambiente del bosque.

Una vez analizados los resultados de la Tabla 4.2 y 4.3, es posible proponer un filtro digital que deje pasar las frecuencias de las armónicas fundamentales de los sonidos de motosierra y que bloquee los demás sonidos que no nos interesan y que podrían causar alguna falsa detección en los bloques de análisis para encontrar las señales periódicas de las que se componen los sonidos de motosierra. Un punto importante es que las grabaciones utilizadas se realizaron con un grabador digital que presenta en su configuración una frecuencia de muestreo de 48kHz. Este valor produce grabaciones de alta calidad pero con gran cantidad de muestras por segundo (48000), que son difíciles de procesar para un hardware limitado, por lo cual se ha propuesto realizar un submuestreo de las grabaciones de 48kHz a 1kHz para sobrellevar este inconveniente. Al tratar de realizar este submuestreo es necesario tener en cuenta que para realizarlo se debe de cumplir con el teorema de muestreo o muestreo de Nyquist. Según este teorema, es posible evitar una señal si se utiliza como frecuencia de muestreo al menos el doble de la frecuencia máxima encontrada en la señal, como se denota en (4.2). [2]

$$F_s > 2F_c + B \quad (4.2)$$

Tabla 4.3: Armónicas fundamentales obtenidas para sonidos de lluvia, viento, aviones y disparos de diferentes tipos de armas a variadas distancias y ángulos de adquisición.

Sonido	Frecuencia de armónica fundamental [Hz]
A_Birds_001	20.74
A_Plane_001	87.13
A_Rain_001	21.32
A_Wind_001	20.42
D030m_C22_000	956.57
D030m_C22_090	1540.00
D030m_C22_180	20.24
D030m_Pi9_000	20.75
D030m_Pi9_090	20.06
D030m_Pi9_180	20.68
D030m_R32_000	21.52
D030m_R32_090	20.92
D030m_R32_180	19.99
D030m_R38_000	21.08
D030m_R38_090	455.70
D030m_R38_180	19.36
D090m_C22_000	18.85
D090m_C22_090	18.57
D090m_C22_180	18.97
D090m_Pi9_000	478.77
D090m_Pi9_090	19.27
D090m_Pi9_180	25.51
D090m_R32_000	22.53
D090m_R32_090	19.83
D090m_R32_180	23.71
D090m_R38_000	18.40
D090m_R38_090	18.84
D090m_R38_180	20.07

donde:

F_s : Frecuencia de muestreo.

F_c : Frecuencia central.

B : Ancho de banda.

Así se puede concluir que la mayor frecuencia que se puede contener en una grabación muestreada a 1kHz es de 500Hz como máximo. Como las frecuencias de las armónicas fundamentales de los sonidos de motosierra se encuentran entre los valores de 100-200Hz, es posible albergar el conjunto de señales que nos interesan y discriminar el ruido con un filtro.

De esta manera se propone un filtro digital pasa banda de respuesta de impulso finita (FIR), que deje pasar como ya se mencionó las frecuencias entre 100 y 250Hz, seguido de un submuestreador que pase de 48kHz a 1kHz en las muestras de las grabaciones a analizar. Con este filtro propuesto se realizarán los cálculos y análisis que se presentan en los apartados siguientes.

4.3 Cálculo de autocorrelación y medición de periodicidad

Como primera aproximación mediante la herramienta LabVIEW se procederá a leer los vectores de MATLAB que se convirtieron de las grabaciones reales realizadas en el bosque y que son de formato “.wav”. Una vez agregados los valores de los vectores “.mat” a un formato de vector de LabVIEW, se procede a realizar lecturas de los vectores pero en secciones, o sea, en ventanas con diferentes tamaños para el análisis en porciones de las grabaciones. Esto se realiza de esta manera ya que para un futuro diseño compacto para este análisis, es necesario que el hardware procese una cantidad mínima de datos para que este no se vuelva grande y complicado.

Para introducir los vectores “.mat” al software de LabVIEW, fue necesario instalar un complemento para que el bloque “Open Data Storage” pueda realizar la lectura. A este bloque funcional se le tiene que introducir la ruta donde se encuentran los archivos a leer, así como el nombre de actual vector de MATLAB. Para realizar el desplazamiento de las ventanas sobre los datos del vector a analizar, se colocó un lazo *while* que vaya realizando las lectura de los datos desplazando el índice de la ventana para cada iteración, mediante un registro que almacenes el valor para cada corrida. El ciclo *while* termina cuando el índice de la siguiente ventana se haya salido del tamaño del vector que está siendo utilizado.

El primer análisis que se realiza para la detección de sonidos de motosierra es la autocorrelación.

Se procedió a realizar el análisis de periodicidad para las grabaciones de sonidos de motosierra, lluvia y disparos. La autocorrelación presentada para cada figura fue obtenida para una ventana característica donde el sonido es el esperado, con una ventana de 5000 datos de longitud que representa una fracción de segundo en la grabación real. Las gráficas se presentan en las figuras 4.3, 4.4 y 4.5.

Realizando un análisis a las figuras presentadas anteriormente, tenemos que para la figura 4.3 se puede apreciar una forma regular periódica y que por su naturaleza aleatoria va tendiendo a cero conforme se realizaron los cálculos con índices de retraso más grandes. En el centro de la gráfica se presenta un impulso CD a la frecuencia de cero y luego conforme se van dando los picos en la onda, se van encontrando valores de periodo con unidades de muestras. En esta gráfica observamos varias periodicidades, como por ejemplo los valores 200, 400 y 700 aproximadamente. Esta forma en la gráfica obtenida de




Figura 4.3: Análisis de autocorrelación para sonido de motosierra.




Figura 4.4: Análisis de autocorrelación para sonido de lluvia.




Figura 4.5: Análisis de autocorrelación para disparo de arma R38.

autocorrelación nos muestra que es posible detectar valores de periodicidad en señales físicas originales que contienen alteraciones con interferencias aleatorias o lo que sería ruido ambiente.

En la ecuación (4.3) se describe la forma clásica para el cálculo de la medición de periodicidad que consiste en la sumatoria de cada uno de los valores producidos por el paso de autocorrelación.

$$\mathcal{P}_{alt} = \sum_{n=N_{min}}^{N_{max}} (\bar{R}_{xx}[n])^2 \quad (4.3)$$

Como se menciona en [3], para utilizar la ecuación (4.3) es necesaria una señal estacionaria, donde no ocurran fluctuaciones en baja frecuencia que introduzcan picos adicionales a la función de autocorrelación. Estos picos producen un offset en el cálculo de autocorrelación, generando un error que no permite la detección de periodicidad en la señal. Por esto es necesario realizar una modificación a la ecuación de medición de periodicidad planteada anteriormente, realizando una derivación en el tiempo y calculando luego la suma de cuadrados.

Así mediante esta última ecuación se reproducen las grabaciones enteras analizándolas con autocorrelación y pasando los resultados por la ecuación. De esta manera se obtienen gráficos para el sonido de motosierra y el disparo de arma calibre 38. Estos se presentan en las figuras 4.6 y 4.7. Para el sonido de lluvia no se presenta gráfico de medición de periodicidad ya que los valores obtenidos están muy por debajo de los valores utilizados para la detección en los demás sonidos.

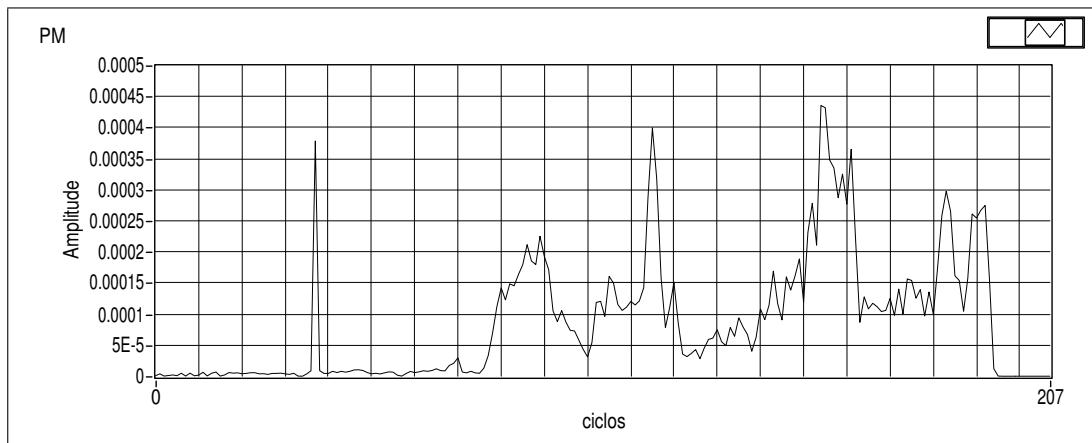


Figura 4.6: Análisis medición de periodicidad para sonido de motosierra.

En la figura 4.6 se presenta la medición de periodicidad para la grabación de sonido de motosierra. Se observa que cuando el nivel de periodicidad es alto por medio del cálculo de autocorrelación de los datos para las ventanas analizadas, se obtiene un nivel alto en la medición de periodicidad. De esta manera es posible determinar un nivel fijo de detección para generar un señal alarma de detección de señales periódicas. En la figura 4.7




Figura 4.7: Análisis medición de periodicidad para sonido disparo de arma calibre 38.

se observa una medición de periodicidad solo en el preciso momento que se produce el disparo. Tiene un valor alto en ese sector donde se produce el pico ya que la posición central del resultado de la autocorrelación contiene también un valor alto, pero como se nota después decae fuertemente hasta un valor cercano a cero.

En este punto; con los vectores generados para el cálculo de la medición de periodicidad, se puede establecer un valor umbral para discernir cuando existe y cuando no una detección de periodicidad. Para una prueba se propone un valor de $1E^{-5}$ después de haber analizado cuáles son los valores promedios que se obtuvieron con el proceso de anterior. Las figuras 4.8 y 4.9 representan la matriz de detección según la localización de las muestras analizadas que depende estrictamente de los resultados obtenidos en las figuras 4.6 y 4.7. Cada impulso que se presentan en estas dos gráficas representa una detección en la ventana procesada de los sonidos de motosierra y del arma calibre 38. Para el sonido de lluvia, como no se obtuvieron valores significativos en la gráfica de medición de periodicidad, entonces no presentaremos tampoco la gráfica de matriz de detecciones.




Figura 4.8: Matriz de detecciones para sonido de motosierra.

Los sonidos de disparo producen alta periodicidad pero en un lapso de tiempo muy corto a diferencia de los sonidos de motosierra, que mantienen altas periodicidades por un tiempo más largo. De esta manera se podría determinar cuándo existe sonidos de motosierra




Figura 4.9: Matriz de detecciones para sonido disparo de arma calibre 38.

relacionando el tiempo que se presentan los altos valores en la medición de periodicidad.

Para esta prueba en particular se presenta la tabla 4.4 con la cantidad de detecciones.

Tabla 4.4: Detecciones obtenidas para umbral seleccionado de $1E^{-5}$.

Sonido	Detecciones
Motosierra	121
Disparo R38	3
Lluvia	0

Con estos resultados provisionales se puede concluir que los algoritmos utilizados son aptos para nuestro interés de detectar sonidos generados por motosierras y poder discernirlos del ruidos ambiente que se presenta en el bosque y de otros sonidos generados por el hombre como lo son los disparos, voces humanas, aviones, etc.

Ahora en la siguiente sección se realizarán análisis más específicos de cómo utilizar los métodos utilizados en este apartado, utilizando una gran variedad de sonidos a disposición, además de incluir filtros y submuestreadores para generar una forma más sencilla y exacta de realizar las detecciones.

4.4 Detector de sonidos incluyendo filtro y submuestreador

Trabajar con una cantidad de 48000 muestras por segundo presupone un hardware capaz de procesar esta cantidad de información. Para nuestros propósitos este gran flujo de información es grande para un diseño sencillo de detección de sonidos de motosierra ya que como habíamos mencionado, los 48kHz solo se utilizan para obtener la mejor calidad posible a la hora de obtener las grabaciones y de ahí podemos realizar pruebas con diferentes frecuencias de muestreo, mediante la utilización de algún software especializado en edición de archivos musicales o con el uso de algoritmos en el momento de realizar los análisis propios de las detecciones. En este caso se utilizaron algoritmos incluidos en

LabVIEW ya que se contaba con licencias autorizadas para su uso en el laboratorio. Para tratar de obtener un análisis con resultados similares a los obtenidos en la investigación en [3] y que además nos permita disminuir el posible hardware a diseñar.

El filtro seleccionado es uno pasa banda, con una banda pasante de entre 100-250Hz y con una supresora de banda de $-\infty$ hasta 80Hz y de 300Hz a $+\infty$ con una atenuación del 99% fuera de la banda pasante. Como ya se analizó en la sección 4.2 de este filtro, esta propuesta cumple con el teorema de muestreo o muestreo de Nyquist para la cambio de muestreo de 48kHz a 1kHz.

Después de tomar en cuenta estos dos puntos, se procedió añadir al diseño algorítmico utilizado en la sección 4.3 los bloques funcionales que realizaran el trabajo para el submuestreador y el filtro propuesto.

Los bloques nuevos utilizados para el trabajo de filtrado y submuestreo ya se encuentran incluidos en el software LabVIEW. Se presentan en la categoría de procesamiento digital de señales que se encuentra disponible en las computadoras de la escuela. Los bloques utilizados se llaman “DFD Filtering” para el proceso de filtrado y “Resample” para el submuestreador.

Para este nuevo diagrama de bloques se realizaron varios procedimientos obteniéndose mediante los cálculos de autocorrelación y medición de periodicidad las cantidades de detecciones producidas por el algoritmo, para todas la grabaciones disponibles. Ya que a la hora de obtener la medición de periodicidad se presenta un nivel que depende del cálculo de periodicidad encontrado con ayuda del análisis de autocorrelación, es posible definir umbrales de detección para esos niveles en la medición. De esos nivel dependerá la cantidad de detecciones obtenido después del estudio realizado para cada una de las grabaciones. Los resultados para las grabaciones utilizadas a 30 y 90 metros se presentan en la Tabla 4.5. Los resultados para las grabaciones de 250 y 600 metros se encuentran en la Tabla 4.6.

Analizando estas dos tablas podemos ver que existe alta cantidad de detecciones de periodicidad en los sonidos de motosierra, con una máximo de 96 en el sonido “D090m_Saw_000b” que fue generado a 90 metros y con un ángulo de 0° con respecto al grabador digital. También se presenta una cantidad de detecciones considerables en los sonidos de aeroplanos y del arma S12 para todas las distancias estudiadas en este caso particular. El sonido “A_Plane_002” de aeroplano número dos presenta una cantidad máxima de 20 detecciones cuando se utiliza una umbral de medición de $20E^{-9}$ y $60E^{-9}$. Estas falsas detecciones se producen posiblemente por la naturaleza del sonido, el eco que puede producir en el medio ambiente de bosque. El sonido de aeroplano es generado por un motor similar al de una motosierra, por lo que resulta lógico que sea detectado porque además de ser motores muy fuertes, el sonido no presenta bloqueos desde el aire, por lo que las ondas sonoras llegan sin mucho obstáculo. Para los sonidos de arma S12 no existen grabaciones a los 90 metros, además de no existir tampoco con un ángulo de 180° para los 600 metros, es por eso que no se colocó el análisis de estos sonidos en las tablas de esta sección.

Tabla 4.5: Detecciones obtenidas para las grabaciones a una distancia de 30 y 90 metros en función del umbral de detección.

<i>Sonido</i>	Umbral de detección [E^{-9}]										
	20	60	120	180	240	300	360	420	480	540	600
<i>A_Birds_001</i>	0	0	0	0	0	0	0	0	0	0	0
<i>A_Birds_002</i>	0	0	0	0	0	0	0	0	0	0	0
<i>A_Birds_003</i>	0	0	0	0	0	0	0	0	0	0	0
<i>A_Plane_001</i>	5	5	4	4	4	3	3	2	1	0	0
<i>A_Plane_002</i>	20	20	19	15	12	10	5	1	0	0	0
<i>A_Rain_001</i>	0	0	0	0	0	0	0	0	0	0	0
<i>A_Rain_002</i>	42	13	5	1	1	0	0	0	0	0	0
<i>A_Wind_001</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D030m_C22_000</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D030m_C22_090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D030m_C22_180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D030m_Pi9_000</i>	2	2	2	1	1	0	0	0	0	0	0
<i>D030m_Pi9_090</i>	3	2	1	1	0	0	0	0	0	0	0
<i>D030m_Pi9_180</i>	1	1	0	0	0	0	0	0	0	0	0
<i>D030m_R32_000</i>	2	1	1	1	0	0	0	0	0	0	0
<i>D030m_R32_090</i>	1	1	0	0	0	0	0	0	0	0	0
<i>D030m_R32_180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D030m_R38_000</i>	2	2	2	1	0	0	0	0	0	0	0
<i>D030m_R38_090</i>	1	1	1	0	0	0	0	0	0	0	0
<i>D030m_R38_180</i>	1	0	0	0	0	0	0	0	0	0	0
<i>D030m_S12_000</i>	6	6	5	3	3	2	2	2	2	1	1
<i>D030m_S12_090</i>	9	9	7	6	6	6	5	5	4	3	3
<i>D030m_S12_180</i>	7	7	6	6	5	4	3	2	1	1	1
<i>D030m_Saw_000</i>	91	90	88	86	86	84	77	66	51	48	38
<i>D030m_Saw_090</i>	69	67	65	62	60	55	52	45	20	8	3
<i>D030m_Saw_180</i>	60	57	53	47	33	12	0	0	0	0	0
<i>D090m_C22_000</i>	1	1	1	1	0	0	0	0	0	0	0
<i>D090m_C22_090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D090m_C22_180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D090m_Pi9_000</i>	3	3	2	1	1	1	1	1	0	0	0
<i>D090m_Pi9_090</i>	2	2	1	1	0	0	0	0	0	0	0
<i>D090m_Pi9_180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D090m_R32_000</i>	1	1	0	0	0	0	0	0	0	0	0
<i>D090m_R32_090</i>	1	1	0	0	0	0	0	0	0	0	0
<i>D090m_R32_180</i>	1	0	0	0	0	0	0	0	0	0	0
<i>D090m_R38_000</i>	2	1	0	0	0	0	0	0	0	0	0
<i>D090m_R38_090</i>	1	0	0	0	0	0	0	0	0	0	0
<i>D090m_R38_180</i>	1	1	0	0	0	0	0	0	0	0	0
<i>D090m_Saw_000a</i>	72	72	72	71	70	70	69	67	59	53	48
<i>D090m_Saw_000b</i>	96	96	96	96	96	96	94	82	59	51	3
<i>D090m_Saw_090</i>	60	57	46	37	30	19	11	2	0	0	0
<i>D090m_Saw_180</i>	43	39	36	31	27	26	14	3	1	0	0

En función de la distancia se puede realizar la comparación de resultados entre las tablas 4.5 y 4.6, donde se presentan muchos menos detecciones verdaderas así como detecciones falsas en general para todas la grabaciones a distancias de 250 y 600 metros con respecto

Tabla 4.6: Detecciones obtenidas para las grabaciones a una distancia de 250 y 600 metros en función del umbral de detección.

<i>Sonido</i>	Umbral de detección [E^{-9}]										
	20	60	120	180	240	300	360	420	480	540	600
<i>D250m.C22.000</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.C22.090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.C22.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.Pi9.000</i>	2	0	0	0	0	0	0	0	0	0	0
<i>D250m.Pi9.090</i>	1	0	0	0	0	0	0	0	0	0	0
<i>D250m.Pi9.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.R32.000</i>	1	0	0	0	0	0	0	0	0	0	0
<i>D250m.R32.090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.R32.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.R38.000</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.R38.090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.R38.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D250m.S12.000</i>	5	4	4	4	3	3	2	1	1	0	0
<i>D250m.S12.090</i>	5	5	4	4	4	2	2	1	1	0	0
<i>D250m.S12.180</i>	5	4	4	4	2	1	0	0	0	0	
<i>D250m.Saw.000</i>	17	7	0	0	0	0	0	0	0	0	0
<i>D250m.Saw.090</i>	14	2	0	0	0	0	0	0	0	0	0
<i>D250m.Saw.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.C22.000</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.C22.090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.C22.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.Pi9.000</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.Pi9.090</i>	1	1	1	1	0	0	0	0	0	0	0
<i>D600m.Pi9.180</i>	1	1	0	0	0	0	0	0	0	0	0
<i>D600m.R32.000</i>	1	1	1	0	0	0	0	0	0	0	0
<i>D600m.R32.090</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.R32.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.R38.000</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.R38.090</i>	1	0	0	0	0	0	0	0	0	0	0
<i>D600m.R38.180</i>	0	0	0	0	0	0	0	0	0	0	0
<i>D600m.S12.000</i>	5	5	4	4	4	4	3	2	2	1	0
<i>D600m.S12.090</i>	3	3	2	2	2	2	0	0	0	0	0
<i>D600m.Saw.000</i>	5	5	3	3	1	1	0	0	0	0	0
<i>D600m.Saw.090</i>	7	0	0	0	0	0	0	0	0	0	0
<i>D600m.Saw.180</i>	8	6	1	0	0	0	0	0	0	0	0

a las grabaciones realizadas a las distancias más cercanas de 30 y 90 metros. Es conocido que mientras sea mayor distancia las ondas sonoras además de atenuarse, se distorsionan por la combinación de otras señales, como lo es el eco que se genera por ellas mismas en el choque con obstáculos o por algún otro sonido generado cerca del sonido que se quiere analizar. Por estas razones es que hay detecciones cuando se aumenta la distancia entre la fuente de sonido y el receptor. Se puede notar en la Tabla 4.6 que las detecciones de motosierras a 600 metros se degradan en gran manera ya que a esa distancia el ruido ambiente produce interferencia con el sonido periódico que se trata de discernir. Esto producirá en los análisis una disminución de la efectividad del algoritmo para realizar

detecciones certeras, por lo que hay que tener en cuenta los límites que nuestro sistema tienen en cuanto a la distancia.

Los resultados se obtuvieron utilizando una ventana entera de 250 muestras, por ser la que mejor cantidad de detecciones produjo con la menor cantidad de muestras en las grabaciones analizadas. También se realizaron análisis con desplazamientos de media, tercio y cuarto de ventana, produciéndose cantidad de detecciones similares y de parecida calidad. La utilización desplazamientos no enteros de la ventana en las muestras de las grabaciones, genera la necesidad de un hardware más veloz y robusto por lo que no es beneficioso para el resultado que se quiere obtener con este estudio.

En este punto y de manera rápida se puede proponer una manera de detección de sonidos que trabaje en función de las cantidades de detecciones obtenidas en cierta cantidad de tiempo. De esta manera se obviarían las detecciones falsas que se producen esporádicamente cuando el algoritmo detecta alguna señal periódica que se encuentre dentro del rango de frecuencias, permitido por el filtro pasa banda colocado para los análisis que reflejan los resultados de las tablas.

Como conclusión final se puede corroborar que se obtienen mejores resultados para las detecciones de sonidos hasta los 90 metros de distancia, cuando se realiza la comparación entre la Tablas 4.5 y 4.6. En la siguiente sección se estudiará como influye esas diferencias de distancia en la eficiencia del algoritmo utilizado mediante los análisis ROC.

4.5 Eficiencia del algoritmo detector de periodicidad mediante curvas ROC

En esta sección se presentarán los resultados obtenidos en cuanto a la eficiencia obtenida con las grabación que se encuentran a disposición, así como algunas pruebas con tamaño de ventanas. También se realizará un análisis de los resultados de las curvas ROC cuando se utiliza el sistema de cálculo digital de punto fijo. Las curvas ROC variarán dependiendo de la exactitud que se puede obtener con determinada cantidad de bits en la sección decimal.

Para generar los análisis que se detallan en esta sección, se hizo uso de la herramienta LabVIEW ya que partes de los módulos utilizados en las secciones anteriores 4.3 y 4.4 son útiles nuevamente para la generación de los análisis ROC. El bloque algorítmico de más a la derecha representa la sección cálculo de los datos para luego generar la gráfica ROC. En esta sección también se agrega el bloque funcional ya proporcionado por el software para el cálculo del área bajo la curva, es para poder analizar la eficiencia que presenta el algoritmo de detección utilizado.

Al realizar estos análisis es necesario tener en cuenta la teoría de como es necesario acomodar los datos y utilizar las ecuaciones que se describieron en la sección del marco teórico 2.4. Las ecuaciones se presentan en el marco teórico de 2.13 a 2.16.

Cuando se obtiene la matriz de detecciones cuando se calcula la autocorrelación y la medición de periodicidad, se calcula la tasa de verdaderos positivos y tasa de falsos positivos mediante (2.13) y (2.16) respectivamente, construyendo otra matriz que contiene estos resultados para cada uno de los umbrales utilizados y así obtener las detecciones para la diferentes grabaciones.

Una vez obtenido los resultados utilizando el código presentado en el listado 2.1, debe de realizarse un reacomodo más apropiado mediante la manipulación de los vectores generados por el algoritmo presentado.

Para el análisis de la eficiencia del algoritmo utilizado es necesario llevar a cabo varias pruebas que comprueben la veracidad de las resultados obtenidos y de esta manera presentar el valores de las variables utilizadas en las conclusiones más eficientes para nuestro caso.

4.5.1 Eficiencia obtenida para el algoritmo con diferentes ventanas

Los resultados que se presentan a continuación representan los análisis ROC producidos para las grabaciones de 30, 90, 250 y 600 metros. Cuando se analizan las grabaciones de 90 metros estas incluyen también las de 30 metros; igual sucede con grabaciones a 600 metros ya que todas las demás distancias están incluidas dentro de esa cifra. El algoritmo utilizado es el que se presentó en la Sección 4.5 anterior más los análisis de autocorrelación y periodicidad antes mencionados en los demás apartados.

Se presentarán una serie de figuras que contienen los cuatro diferentes cálculos para detecciones realizadas, donde se exponen las curvas ROC generadas para ventanas de análisis de 100, 250 y 400 muestras para incluir algunas. Estas se presentan en las figuras 4.10, 4.11 y 4.12 respectivamente.

Para las curvas obtenidas con la ventana que contiene 100 muestras se presentaron resultados alrededor del 62% para sonidos obtenidos a 30 y 90 metros como se puede corroborar en las gráficas 4.10a y 4.10b contenidas en la figura 4.10. Para distancias de 250 y 600 metros se obtuvieron resultados más bajos de 55.8% y 51% respectivamente, que se presentan en las gráficas 4.10c y 4.10d. Esto se debe a que los sonidos a esas distancias son de muy baja intensidad y se confunden con los sonidos generados por el medio ambiente. Por estas razones la tasa de verdaderos positivo en comparación a la tasa de falsos positivos baja, generando valores de área bajo la curva menores y produciendo una efectividad del algoritmo menor para estas distancias.

Con una ventana de 250 muestras para el cálculo de medición de periodicidad se obtuvieron mejores valores de área bajo la curva con respecto a la ventana de 100 muestras. Los resultados se puede ver en las gráficas de la figura 4.11. Para una distancia de 30 metros se obtuvo una eficiencia del 86.8% y para 90 metros fue de 90.02%. Estos valores son bastante superiores con respecto a los resultados obtenidos para una ventana

de 100 muestras. Para las distancias de 250 y 600 metros se tienen resultados de 80% y 74.5% respectivamente. Como ya se mencionó para las distancias más alejadas la tasa de verdaderos positivos baja por la incapacidad del algoritmo de detectar periodicidades en señales con baja intensidad y presencia general de ruido. Es interesante ver que para una ventana de 250 muestras los resultados generales obtenidos son bastante buenos y manejar una pila de 250 muestras es razonable.

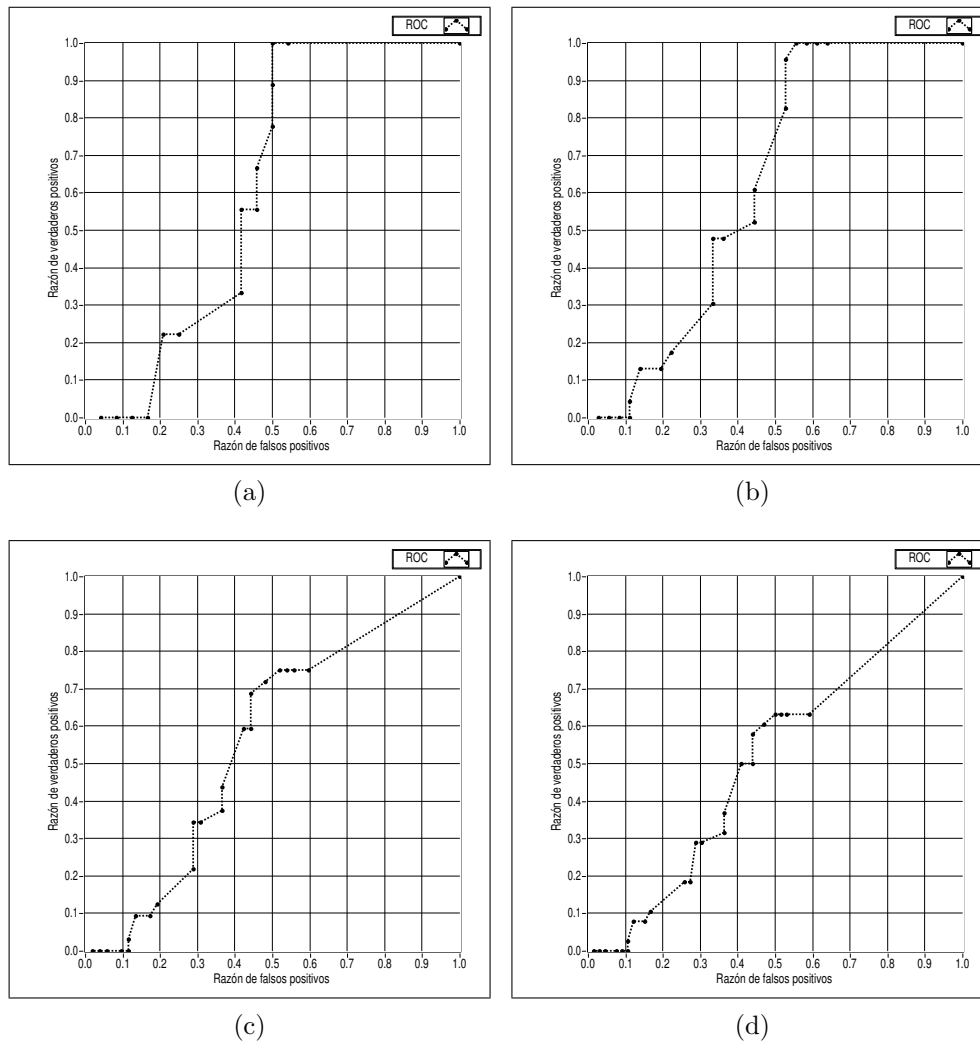


Figura 4.10: Análisis ROC para diferentes distancias con una ventana de análisis de 100 muestras. a) Distancia de 30m, eficiencia de 61.3%. b) Distancia de 90m, eficiencia de 62.7%. c) Distancia de 250m, eficiencia de 55.8%. d) Distancia de 600m, eficiencia de 51.1%

Los resultados para una ventana de 400 muestras se presentan en la figura 4.12. También se tienen buenos resultados con esta ventana pero es interesante como no se llegó a los valores obtenidos para la ventana de 250 muestras. Estos resultados tal vez se deban a que las grabaciones están recortadas justo donde se presentan los sonidos de interés y algunas son de muy pocos segundos. Al realizar un submuestreo de 44.1kHz a 1kHz, la cantidad de muestras que presentan las grabaciones al final son de pocos valores por lo

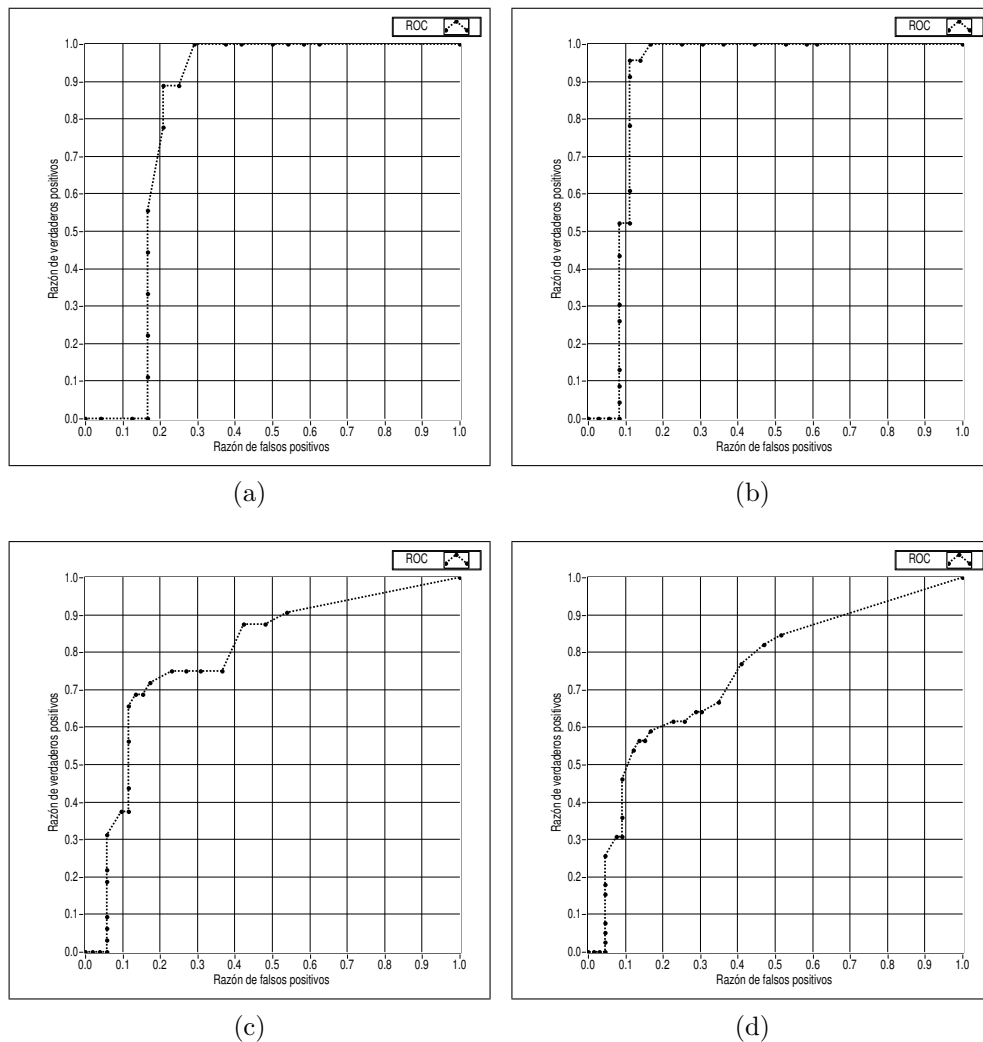


Figura 4.11: Análisis ROC para diferentes distancias con una ventana de análisis de 250 muestras. a) Distancia de 30m, eficiencia de 86.8%. b) Distancia de 90m, eficiencia de 90.02%. c) Distancia de 250m, eficiencia de 80%. d) Distancia de 600m, eficiencia de 74.5%.

que los cálculos realizados con ventanas muy grandes producen resultados menos exactas por la particularidad de que algunas muestras no se analizan por que las ventanas no caben, generalmente al final de las grabaciones.

Con los resultados analizados anteriormente se llega a la conclusión de utilizar para el procedimiento de detección de sonidos periódicos de motosierra, un hardware de cálculo para los algoritmos de autocorrelación y medición de periodicidad con una longitud de ventana de 250 muestras, que procese principalmente sonidos que provengan de distancias no mayores de 100 metros con respecto a el micrófono a utilizar y permitiéndose variar el ángulo de llegada de las ondas sonoras con respecto a la normal del mismo micrófono.

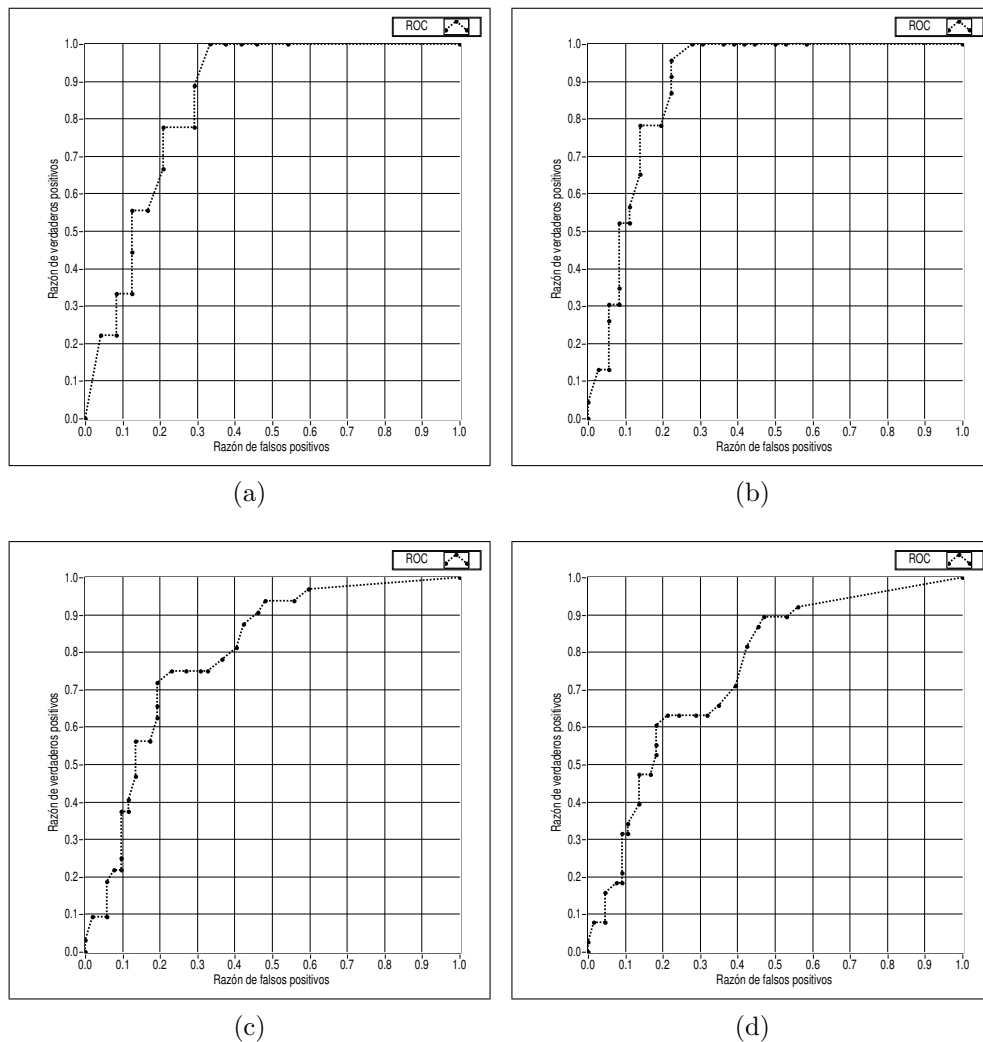


Figura 4.12: Análisis ROC para diferentes distancias con una ventana de análisis de 400 muestras. a) Distancia de 30m, eficiencia de 84.7%. b) Distancia de 90m, eficiencia de 88.9%. c) Distancia de 250m, eficiencia de 79.6%. d) Distancia de 600m, eficiencia de 75.1%.

4.5.2 Eficiencia obtenida en punto fijo para la ventana seleccionada

Una vez presentados los resultados obtenidos en la Sección 4.5.1, donde se escogió una ventana de 250 muestras por sus buenos resultados y conveniente tamaño, se procedió a realizar pruebas de cómo cambian los resultados para los análisis ROC cuando se recorta la cantidad de bits de precisión con el sistema digital de cálculo en punto fijo. El punto fijo se compone de una sección del entero, una sección si se desea utilizar un bit de signo y la parte de bits de precisión para la parte decimal. Se realizaron varias pruebas donde se documentarán a continuación con variables de ancho de palabra de 16, 10, 8 y 6 bits.

Para todas las pruebas se utilizó 1 bit de longitud para la cifra entera y 1 bit para la

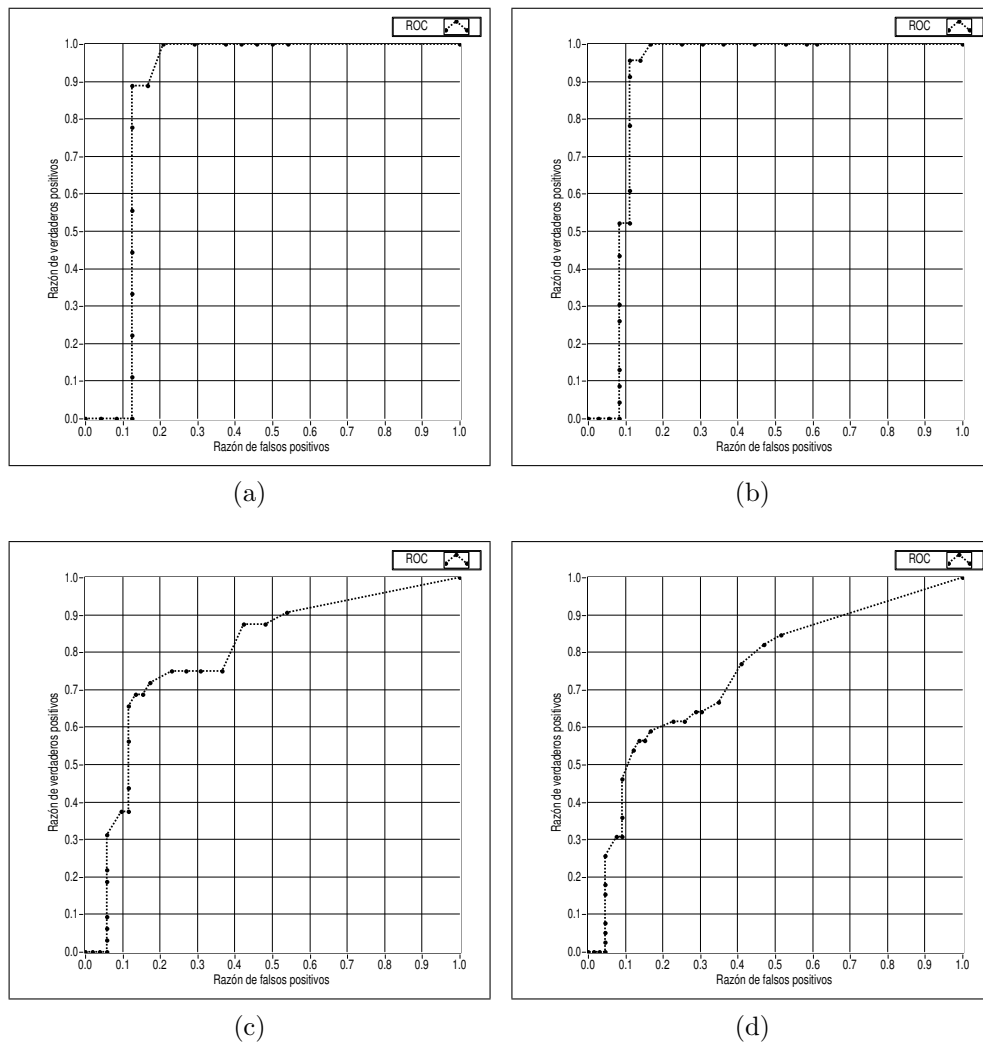


Figura 4.13: Análisis ROC para diferentes distancias con 16 bits de longitud de palabra. a) Distancia de 30m, eficiencia de 86.8%. b) Distancia de 90m, eficiencia de 90.02%. c) Distancia de 250m, eficiencia de 80%. d) Distancia de 600m, eficiencia de 74.5%.

representación del signo que llevan las muestras leídas provenientes de las grabaciones puestas a prueba. El resto de los bits se agregarían para la representación de la parte decimal. En las figuras 4.13, 4.14, 4.15 y 4.16 se presentan los resultados de las pruebas para diferentes valores en punto fijo. En la figura 4.13 de 16 bits de palabra, la sección decimal está representada por 14 bits de precisión. De esta manera para 10, 8 y 6 bits la parte decimal quedaría representada por 8, 6 y 4 bits respectivamente.

Primero, para la figura 4.13, como es la prueba con más bits de precisión, es la que contiene resultados con mejores valores. Esta figura 4.11 es igual a la presentada en 4.13 ya que de igual manera se realizaron los análisis con 16 bit de longitud de palabra. Cuando se disminuye la cantidad de bit de precisión para los análisis, se produce una decaimiento de la efectividad del algoritmo utilizado ya que no es posible representar las magnitudes tan pequeñas que poseen las señales sonoras captadas por el grabador digital utilizado.

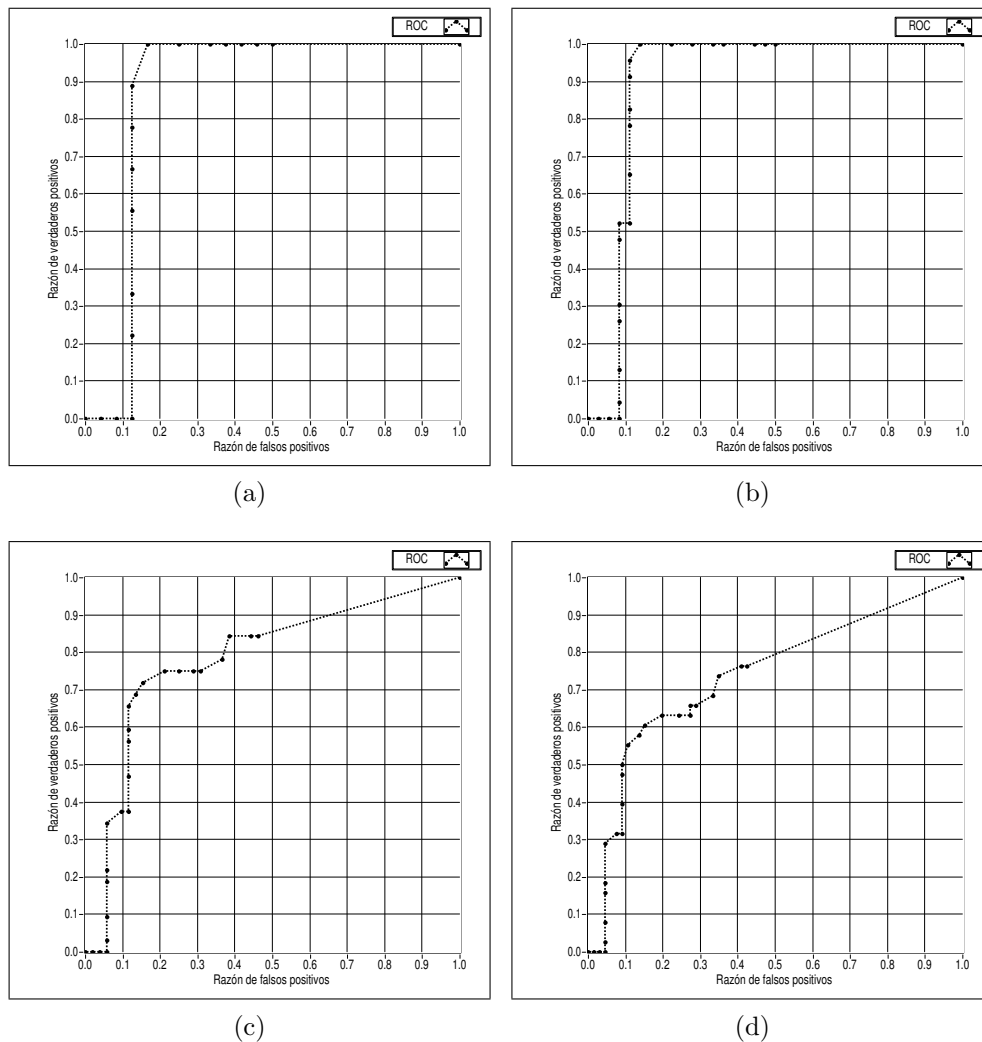


Figura 4.14: Análisis ROC para diferentes distancias con 10 bits de longitud de palabra. a) Distancia de 30m, eficiencia de 87%. b) Distancia de 90m, eficiencia de 90.2%. c) Distancia de 250m, eficiencia de 78.3%. d) Distancia de 600m, eficiencia de 73.9%.

Las gráficas para las demás pruebas se presentan en las figuras 4.14, 4.15 y 4.16 para longitudes de palabra de 10, 8 y 6 bits respectivamente. Se puede notar la disminución que se presenta en el área bajo la curva de los análisis ROC cuando se disminuye mucho los bits. Cuando se tiene una cantidad de 4 bits para representar los decimales, se obtiene un resultado muy malo en la detección de sonidos periódicos, además de su representación en la curva ROC. Lo antes mencionado se puede corroborar en la figura 4.16.

Como conclusión tenemos que para obtener buenos resultados en la detección de los sonidos periódicos será necesario la utilización de por lo menos un sistema digital en punto fijo de 9 bits de longitud de palabra. Eso quiere decir que se destina 1 bit para representar el signo y 8 bits para la representación decimal de los datos. Como la sección del entero siempre es cero, se puede obviar su inclusión en el ancho total de la palabra. De esta manera que cuenta con 8 bits netos para almacenar la sección decimal de los valores

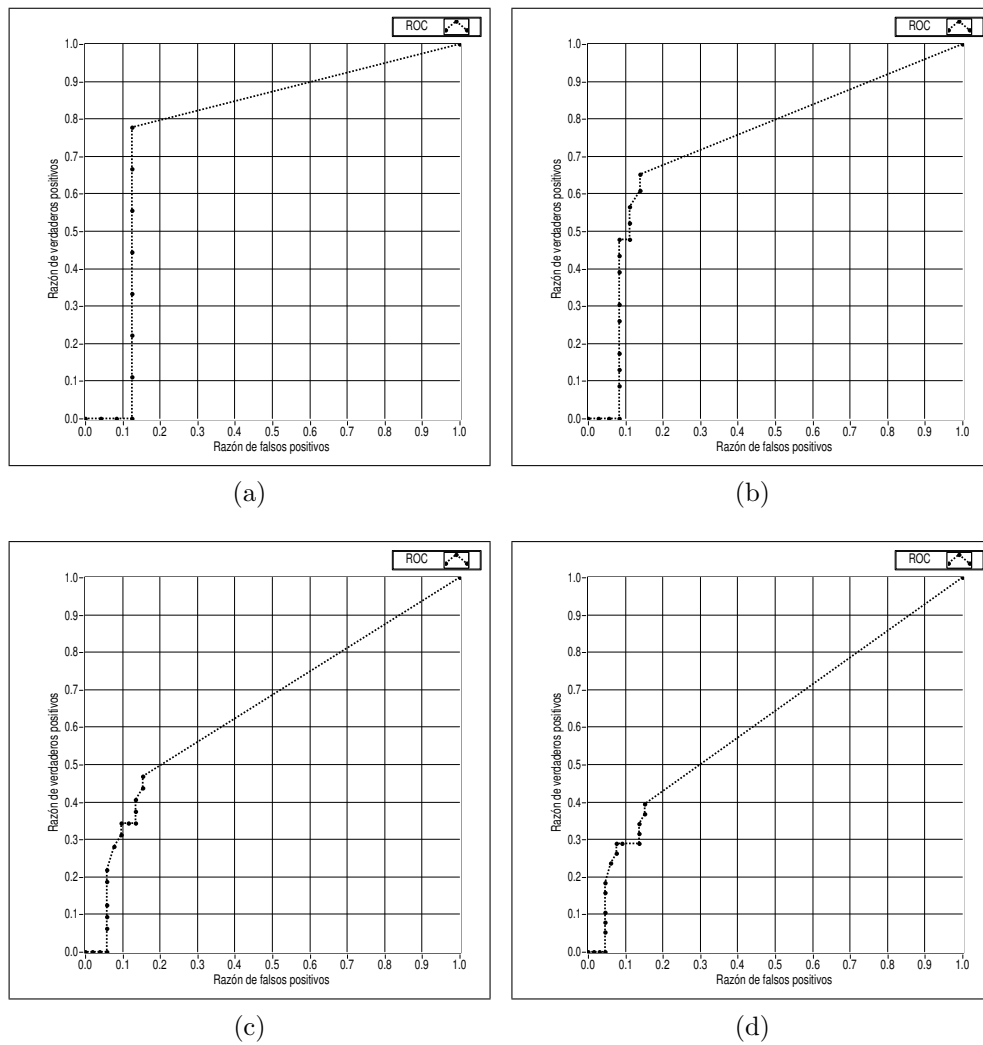


Figura 4.15: Análisis ROC para diferentes distancias con 8 bits de longitud de palabra. a) Distancia de 30m, eficiencia de 77.8%. b) Distancia de 90m, eficiencia de 74.1%. c) Distancia de 250m, eficiencia de 65.3%. d) Distancia de 600m, eficiencia de 62.2%.

obtenidos en la conversión digital del sistema captador de sonidos, con la que se tiene una precisión de $2E^{-3}$ o 0.002 Volts entre cada paso de valor representable en el sistema digital con los bits que se han proporcionado.

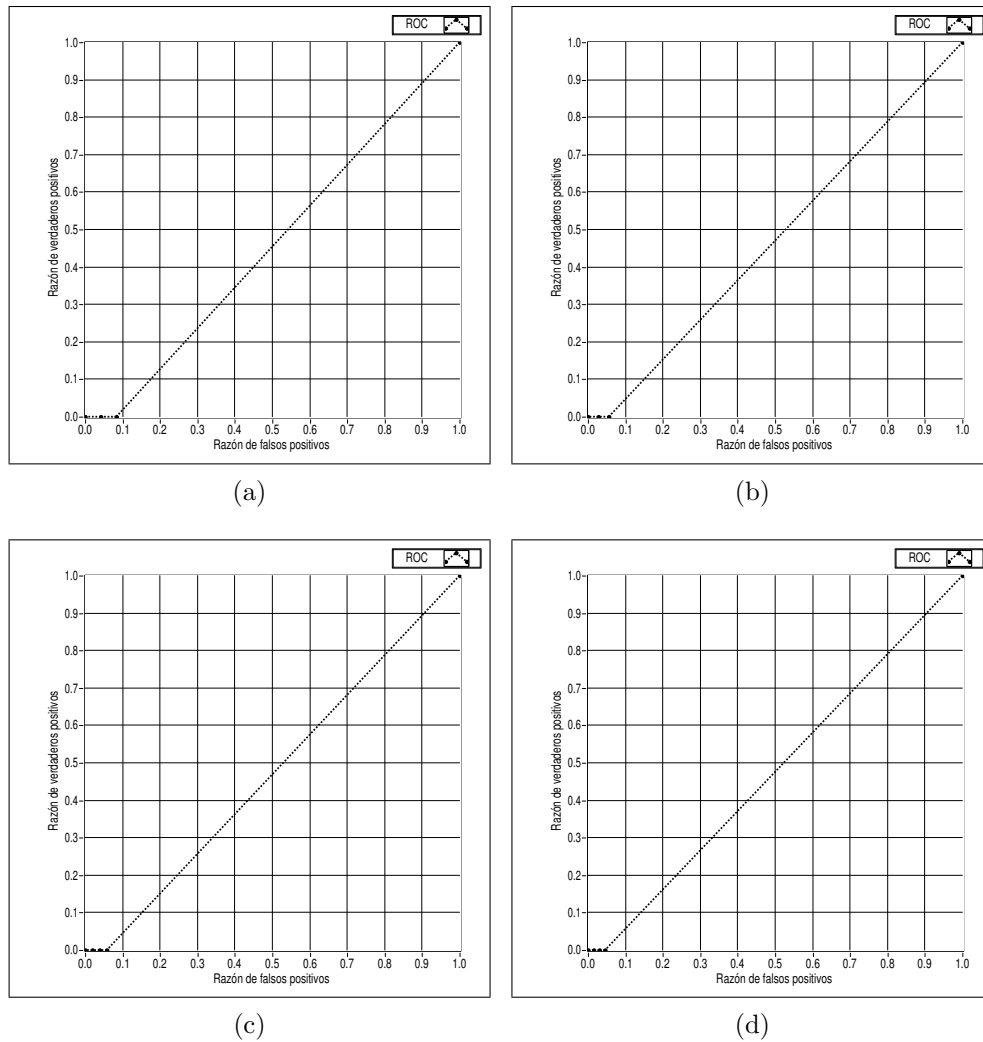


Figura 4.16: Análisis ROC para diferentes distancias con 6 bits de longitud de palabra. a) Distancia de 30m, eficiencia de 45.8%. b) Distancia de 90m, eficiencia de 47.2%. c) Distancia de 250m, eficiencia de 47.1%. d) Distancia de 600m, eficiencia de 47.7%.

Capítulo 5

Conclusiones

A continuación, se desglosan los principales aportes y conclusiones de este trabajo, así como también se comentan las posibles mejoras y agregados que se pueden producir para su optimización posterior.

Se logró obtener un diseño detector de sonidos de motosierra, cuyos sonidos tienen la particularidad de poseer un comportamiento periódico característico en la señal que proviene del aire capturada por el micrófono.

Mediante la selección del algoritmo de medición de periodicidad en la Sección 3.1 y como lo demuestra la Sección 4.3 en el momento de obtener resultados reales, fue necesario utilizar el método de tecnología digital, ya que el algoritmo hace uso de ecuaciones matemáticas que con sistema analógico serían más complicadas de realizar.

Se obtuvieron las frecuencias fundamentales que presentan los sonidos utilizados, principalmente las que poseen las grabaciones de sonidos de motosierra. Presentados los resultados en la Sección 4.2 se destaca que una aproximación del rango de frecuencias en las que se encuentran estos sonidos periódicos es entre 100Hz y los 250Hz, esto para sonidos de motosierra a diferentes distancias. Este resultado se utilizó para generar un filtro pasa banda que atenúe las frecuencias que se encuentren fuera de este rango.

Una vez creado el algoritmo mediante la programación gráfica por medio de bloques funcionales, éste se pudo optimizar, reconociendo que no es necesario o no se obtienen resultados mejorados si se realizan los análisis de las ventanas de muestras de sonidos, de manera que se produzcan desplazamientos menores a la cantidad fijada de muestras por ventana cuando se va estudiar la siguiente ventana. Esto produce un menor uso de recursos a la hora de ejecutar los cálculos en un hardware de bajo consumo de potencia. A la vez se hizo el análisis por medio de las curvas ROC en la Sección 4.5.1, que cuando se utiliza solo el 80% final de los datos producidos por el cálculo de autocorrelación localizados en el vector resultante, el algoritmo de medición de periodicidad tendrá una eficiencia mayor en la detección de sonidos de motosierra. Esto es debido a la característica impulsiva muy alta que se produce al inicio del cálculo de autocorrelación en los sonidos no deseados, como lo son los disparos, que produce valores elevados en el algoritmo de autocorrelación

y que queda reflejado en el vector resultante.

Se confirmó mediante las figuras de autocorrelación presentadas en la página 25, que cuando se analizan señales periódicas de motosierra se obtiene en el resultado de autocorrelación ondas más distinguibles, con periodos de alrededor de 250 muestras y con altas magnitudes en sus picos después de la muestra inicial en 0. A diferencia de los resultados para motosierras, en sonidos de lluvia presenta poca periodicidad; como lo demuestra las magnitudes bajas en sus valores pico y su forma de onda resultante del cálculo de autocorrelación. Para el resultado en sonidos de arma, la onda tiene altísima frecuencia pero poca magnitud en los valores. Esto presupuso una ventaja para detectar los sonidos de motosierra y diferenciarlo de los demás sonidos que pueden existir en el entorno.

Los resultados obtenidos a los que se llegaron para el análisis de autocorrelación y medición de periodicidad en las detecciones de sonidos periódicos están dados al utilizar una ventana de muestras de sonidos entrantes de 250 valores, con 8 bits de resolución para la precisión decimal, además de 1 bit para la representación del signo. Mediante esta configuración se obtuvieron resultados de eficiencia del algoritmo por medio de las curvas ROC de hasta un 90.02% cuando se utilizan sonidos de alrededor de 90 metros de distancia, siendo esta la mejor de las eficiencias, como también un 74.5% para sonidos de hasta 600 metros.

También se ha demostrado que el re-muestreo a 1kHz de la señal entrante de 48kHz en las que se encontraban grabados los sonidos utilizados es posible, y que la pérdida de calidad para el caso del análisis en la medición de periodicidad es casi nula. Con esto se obtiene un diseño más reducido en futuro hardware para los cálculos llevados a cabo, produciéndose una reducción en área, como también en consumo energético.

Como resultado se obtuvieron eficiencias con valores del 90% para grabaciones con distancias menores a 90 metros, cuando se utiliza ventanas de 250 muestras y 8 bits de precisión. Para sonidos de más de 600 metros, la máxima eficiencia que se obtuvo es de 73.9%.

Mediante la programación generada para realizar los análisis propuestos, se llega a la conclusión que mediante tecnología digital en un hardware relativamente sencillo se pueden realizar los cálculos necesarios en obtener los resultados de autocorrelación y medición de periodicidad para generar las detecciones presentes en los sonidos. El sistema podría estar compuesto por una máquina de estado, una pila de registros y una ALU que realice los cálculos matemáticos.

También se sugiere realizar pruebas mediante una FPGA utilizando LabVIEW. Algunas FPGAs son compatibles con el software de National Instruments mediante la configuración de drivers específicos proporcionados. De esta manera se puede utilizar el software generado en esta investigación para realizar pruebas reales, ya que estos dispositivos poseen el rendimiento suficiente para llevar a cabo este tipo de tareas. Adicionalmente es posible optimizar el algoritmo en la detección de los sonidos trabajando directamente sobre programación orientada a hardware.

Bibliografía

- [1] C. Ruiz, “Caza ilegal sería detectada”, junio 2010, En línea, http://www.elfinancierocr.com/ef_archivo/2010/junio/20/.
- [2] J.P. Alvarado, *Procesamiento Digital de Señales*, Instituto Tecnológico de Costa Rica, 2011, Notas de clase.
- [3] D.H. Goldberg, A.G. Andreou, P. Julián, P.O. Pouliquen, L. Riddle, and R. Rosasco, “A wake-up detector for an acoustic surveillance sensor network: Algorithm and vlsi implementation”, 2004.
- [4] T. Fawcett, “ROC Graphs: Notes and practical considerations for researchers”, *Machine Learning*, vol. 31, pp. 1–38, 2004.
- [5] M.G. Sáenz, *Reconocimiento de patrones acústicos para la protección del ambiente utilizando wavelets y Modelos Ocultos de Markov.*, PhD thesis, Instituto Tecnológico de Costa Rica. Escuela de Ingeniería Electrónica., 2006.
- [6] E. Salas, *Reconocimiento en tiempo real de patrones acústicos de motosierras y disparos por medio de una implementación en FPGA de Modelos Ocultos de Markov*, PhD thesis, Escuela de Ingeniería Electrónica, ITCR, Cartago, Costa Rica, 2010.
- [7] A. Zúñiga, *Diseño de un circuito microelectrónico para la detección de disparos mediante filtros digitales.*, PhD thesis, Escuela de Ingeniería Electrónica, ITCR, Cartago, Costa Rica, 2012.
- [8] C.L. Clark, *LabVIEW Digital Signal Processing: and Digital Communications*, New York: McGraw-Hill, 2005.
- [9] N. Kehtarnavaz, *Digital Signal Processing System Design: LabVIEW-based Hybrid Programming*, Academic Press, 2008.

Apéndice A

Diagrama de bloques funcionales

Por medio de los resultados obtenidos en las anteriores secciones del Capítulo 4, se procederá a proponer un diagrama de bloques funcional con el que se posea un boceto preliminar y un punto de partida para la elaboración de un diseño físico para llevar a cabo la tarea de la detección de sonidos de motosierra. Aquí se detalla el diagrama de bloques funcionales, pero el diseño final en hardware será postergado para una futura investigación donde se utilicen herramientas avanzadas en la utilización de tecnología CMOS para su fabricación.

Para el diseño de los bloques funcionales se ha tenido que tomar muy en cuenta los bloques utilizados en la programación gráfica utilizada en LabVIEW, donde para poder realizar las pruebas con los grabaciones disponibles. Se toma en cuenta el algoritmo utilizado con las diferentes rutas o flujos para llegar al resultado con las detecciones encontradas. Entre los principales pasos para llegar a los resultados deseados se presentan las siguientes:

1. Submuestreo de 48kHz a 1kHz.
2. Pila de muestras.
3. Cálculo de autocorrelación.
4. Omisión del primer 20% de resultado de autocorrelación.
5. Medición de periodicidad.
6. Comparador de nivel.
7. Contador a 3 detecciones continuas.

En cuanto al primer punto es necesario el acondicionamiento de la información capturada por el micrófono a una cantidad manejable de datos o muestras que tendrán que almacenarse por un periodo corto de tiempo. Estos datos si son demasiados se tendría que poseer un hardware con cantidad de registros digitales muy grande cuando se trabaja con una

frecuencia de muestreo de 48kHz. Seguidamente existirá una lógica que selecciona una porción de las muestras para ir realizando el algoritmo de autocorrelación por partes. Otro de los bloques necesarios es la autocorrelación entre los datos capturados recientemente y que se encuentran relacionados en posición con respecto a las periodicidades seleccionadas a buscar. Después del cálculo de autocorrelación se utilizará cierta cantidad de datos del resultado anterior (80% final) para realizar la medición de periodicidad. Una vez obtenido el cálculo de medición de periodicidad se hará pasar el resultado de valor real por un comparador de nivel que determinará si se presentó una detección válida dependiendo del valor introducido previamente del nivel a comparar. cuando se produce una detección, se incrementará un contador que cuando se llega a 3, produce una señal de detección. Esto se realiza así para evitar detecciones esporádicas producidas por sonidos como disparos o interferencias que no son sonidos de motosierra, ya que por el comportamiento de los sonidos de motores se producen varias detecciones seguidas, a diferencia de los demás sonidos. Cuando no existen tres detecciones seguidas, el contador se reinicializa y de esta manera no existirán detecciones que no sean estables. Finalmente se prosigue a volver a cargar datos recientes capturados por el micrófono para así analizar una nueva ventana y realizar los pasos discutidos anteriormente.

El diagrama de bloques funcionales se presenta en la figura [A.1](#) y representa un boceto preliminar para su posterior diseño final.

Estos bloques funcionales se procesan digitalmente por lo que será necesario su diseño mediante compuertas digitales con transistores, para obtener un diseño eficiente en el tamaño como también su uso energético.

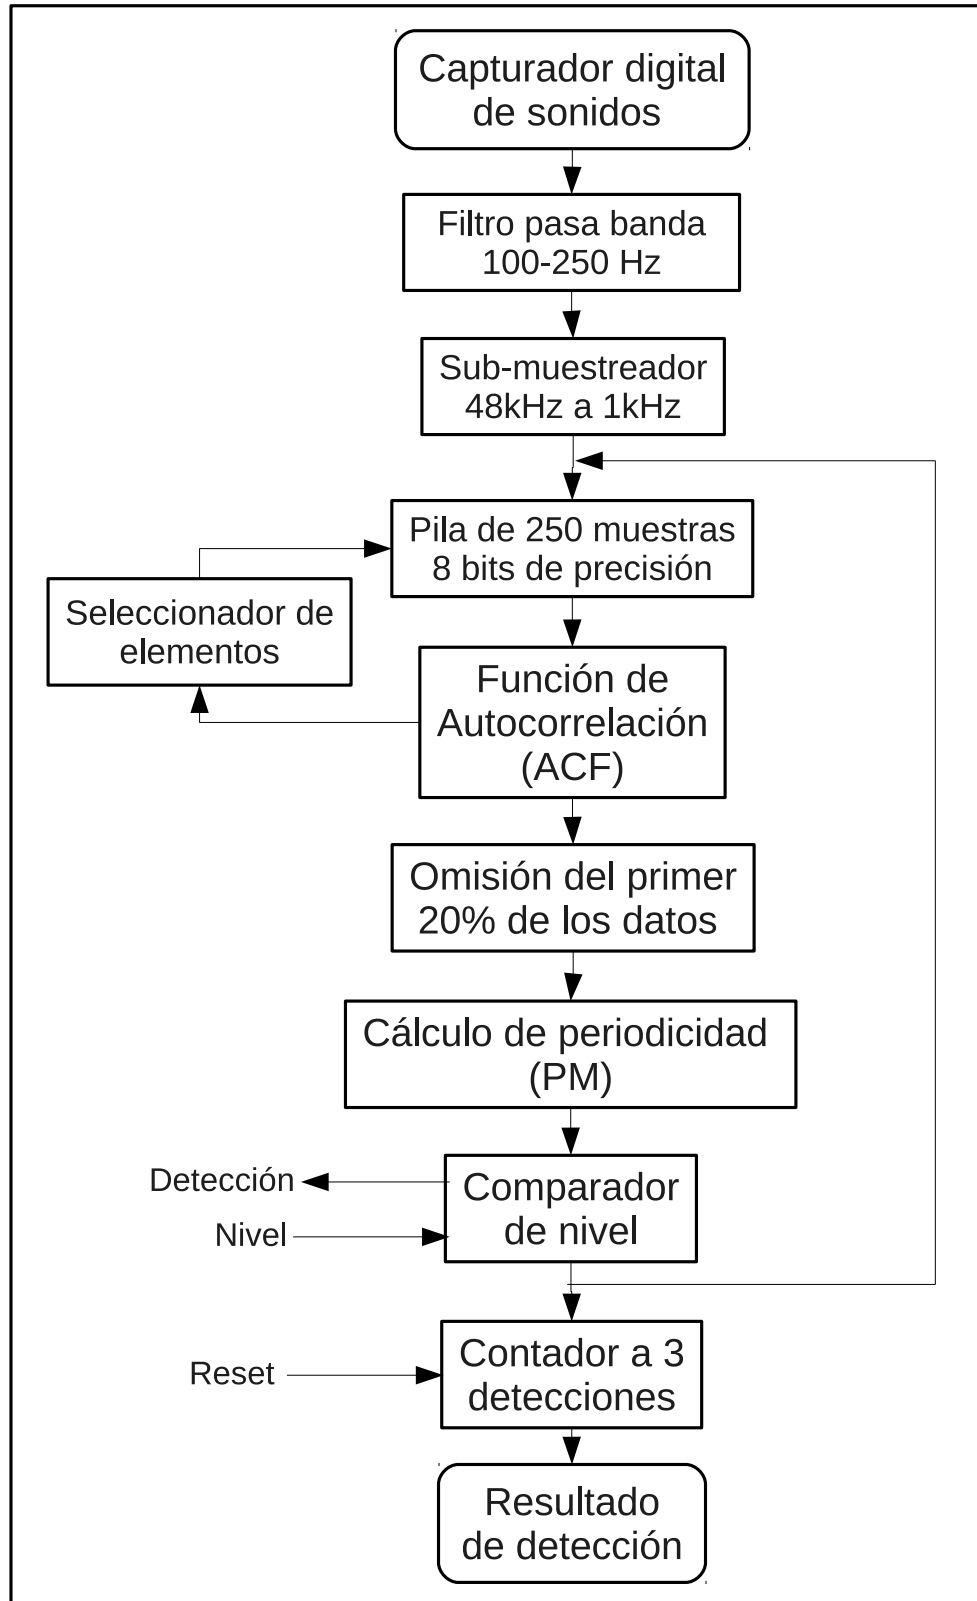


Figura A.1: Diagrama de bloques funcional para el diseño desarrollado.

Apéndice B

Tutorial para el uso de programación gráfica en LabVIEW

En la presente sección se detallará el modo de uso del software generado para los análisis realizados en el estudio en la detección de sonidos periódicos característicos de las motosierras. También se explicarán algunos de los módulos utilizados propios de LabVIEW para la programación gráfica mediante bloques funcionales.


Además de los bloques funcionales para realizar los análisis, es necesario la explicación de varias estructuras que permiten el flujo de los datos y la prioridad de funciones en la programación gráfica generada. Las figuras presentes a continuación fueron obtenidas de la documentación de software LabVIEW, en [8], [9].

B.1 Estructuras importantes utilizadas en el Software LabVIEW

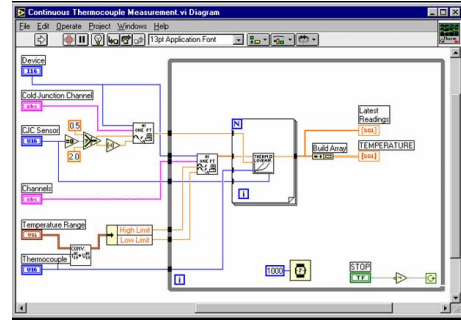
Primeramente hay que comentar la manera en como se trabaja con los “VI” o instrumentos virtuales. Al crear un VI se generan dos ventanas de trabajo, una llamada “Front Panel” y otra llamada “Block Panel”. El Front Panel se utiliza para el diseño de la interfaz gráfica con la que se controlará el software producido. El Block Panel es la ventana donde se trabajan los algoritmos principales de lo que se quiere realizar con su diseño. En la figura B.1 se presenta estos dos áreas de trabajo mencionados con ejemplos posibles de como se puede planear el diseño.

Entre las estructuras utilizadas se encuentran los lazos o bucles, importantes para el cálculo de procesos iterativos donde se almacenan también algunas variables para el siguiente la continuación de la siguiente iteración. Los lazos más utilizados en este estudio son los “*While Loop*” y “*For Loop*”. En la figura B.2 se presenta el icono y el bloque funcional de el lazo *while*.

El bucle iterativo *while* presenta una variable donde se puede obtener el número de ite-




(a) Front Panel




(b) Block Panel

Figura B.1: Front y Block Panel para un proyecto en LabVIEW



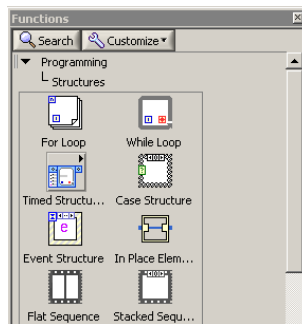
(a) Función While Loop



(b) Bloque While Loop

Figura B.2: Bucle while utilizado para el análisis de los sonidos periódicos.

ración que se está realizando en ese preciso momento. También el bucle trae incorporado un botón “físico” que se agrega al área de trabajo Front Panel, que es de tipo booleano y que controla el final del bucle. En nuestro caso se eliminó el botón y se utilizó un control que depende de la cantidad de ventanas a analizar o cantidad de grabaciones por leer.



(a) Función For Loop



(b) Bloque For Loop

Figura B.3: Bucle For utilizado para el análisis de los sonidos periódicos.

Para el bloque funcional del bucle *For* que se presentan en la figura B.3, se puede también

encuentra en la categoría de bucles y como se puede ver en b) presenta igual que el bloque *while* una variable que muestra en número de iteración actual, además de presentar una entrada para definir la cantidad de veces que se va a ejecutar el código que contenga el lazo. El lazo *for* por su forma de funcionar no presenta el característico botón a realizar la salida del lazo, pero es posible introducir un algoritmo de reconocimiento de excepción para poder salir cuando se existe un error o determinada situación.

A cada uno de estos bucles es necesario para poder mantener valores importantes usados por el algoritmo durante cada una de las iteraciones, la creación de registros de de desplazamiento. Estos registros se tienen que inicializar con un tipo de valor, como por ejemplo booleano o entero y así se mantendrán hasta que llegue el fin del bucle. De esta manera se puede generar a salida del resultado que se obtienen del algoritmo introducido en el recuadro iterativo. En la figura B.4 se presenta una imagen de como se muestran estos registros en el marco o “*frame*” de los diferentes lazos.




Figura B.4: Registros de desplazamiento para los bloques iterativos.

También es importante mencionar una estructura utilizada para controlar mejor el orden de como las diferentes secciones algorítmicas se van desarrollando durante el tiempo. Esta estructura se identifica con la figura de un marco tipo rollo de película antigua y permite controlar el flujo de datos cuando se presentan varias secciones de programación en las que se dependa los resultados obtenidos de una sección, para continuar con otro bloque funcional y así llevar a cabo el algoritmo completo de manera secuencial. En la figura B.5 se muestra la forma en que se representa el marco de esta estructura. La estructura en el software LabVIEW se identifica con el nombre de “Flat Sequence Structure”.




Figura B.5: Representación gráfica de la estructura secuencial.

B.2 Bloques y variables importantes utilizadas en el algoritmo

Cuando se realizó el diseño de la programación gráfica mediante bloques funcionales, se crearon variables y “subVIs” para la reutilización de bloques y facilidad de configuración para cada una de las pruebas realizadas a las grabaciones con diferentes sonidos.

Como principales subVIs que se crearon para la aproximación final del proyecto tenemos el que realiza el cálculo de medición de periodicidad llamado “PM” y el bloque que contiene las rutas para todas las grabaciones que son utilizadas para el análisis ROC. Para el desarrollo final de la aplicación se utilizaron las grabaciones en formato “.wav” recortadas en las partes importantes de las grabaciones donde el sonido era característico. En la figura B.6 se muestran los iconos de los subVIs mencionados anteriormente.




Figura B.6: Bloques subVIs creados para cálculo de medición de periodicidad y selector de grabaciones.

A lo que respecta a el bloque que realiza la medición de periodicidad “PM”, se introduce el vector de datos obtenido por el cálculo de autocorrelación como también el conteo final de los datos que equivalente a la cantidad de muestras del vector de autocorrelación que se quiera analizar. De esta manera se pudieron realizar varios análisis que llevaron a la solución con mayor eficiencia en la cantidad de detecciones producidas para las grabaciones de motosierra.

Para el bloque seleccionador de grabaciones .wav se diseño el icono que se muestra en B.6b. Este subVI contiene la rutas donde se encuentran las grabaciones a utilizar. Es importante mencionar que estas rutas están configuradas para la estación de trabajo utilizada para realizar el proyecto, por lo que si fuese necesario el traslado del software a otro computador para corroborar resultados o hacer nuevas pruebas como actualización del algoritmo detector de las señales periódicas, será necesario el cambio manual de las rutas hacia la nueva localización de las grabaciones en formato .wav. Este bloque está compuesto por una estructura case que presenta 106 casos que representan cada una de las grabaciones utilizadas. El bloque contiene una entrada seleccionadora de el caso a escoger o grabación, como también tiene dos salidas, una con una variable booleana pre-configurada que determina si la grabación seleccionada es o no un sonido de motosierra, con el fin de tener una manera de saber si las detecciones de periodicidad encontradas pertenecen a un verdadero positivo de motosierra o a un falso positivo que provienen de una detección errónea de un sonido con características periódicas. La segunda salida

del bloque es la ruta del archivo seleccionado con el que será leído por un otro bloque llamado “Sound File Read Simple” que tienen como tarea leer el archivo, además de tener que configurarlo para que realice una lectura total de la grabación o solo una porción de interés.

Además de estos bloques funcionales mencionados anteriormente, existen varias variables importantes utilizadas para realizar los análisis. Dentro de estas se encuentran las principales como la cantidad de datos por ventana, la cantidad de grabaciones a analizar, el umbral inicial para las detecciones, la cantidad de umbrales a analizar. Estas variables se encuentran en el Front Panel donde se presenta la interfaz gráfica de diseño generado en LabVIEW.

Existen otras variables de entrada además de las ya mencionadas de uso general que tienen el objetivo de realizar pequeñas modificaciones a los datos que se obtienen de los resultados de bloques que recientemente estuvieron activos en el flujo de datos del programa. Estas variables son la de “Desplazamiento de ventana”, “Porción de autocorrelación”, “FXP” y la de “Paso de umbral”. En cuanto a la variable de desplazamiento de ventana tiene como tarea la configuración de cuanto va a ser el desplazamiento que se produce después de analizar una ventana para proseguir con la siguiente ventana dentro de una misma grabación, esto quiere decir que se puede analizar ventanas diferentes sin que sus muestras se vuelvan a utilizar, como también se puede analizar una ventana y la siguiente tendrá una porción de la anterior utilizada. Un ejemplo sería configurar la variable en 0.5 con lo que produciría que después del estudio de una ventana, se desplaza media ventana en el vector de la grabación seleccionada, por lo que la siguiente ventana tendría un 50% de las muestras de la primera ventana otra vez en el análisis. Se podría realizar esta tarea también con un cuarto de ventana. La variable se configura con valores entre 0 y 1. Para la variable “porción de autocorrelación” se utiliza para tomar en cuenta todo o solo una porción final del vector resultante del algoritmo de autocorrelación. Esto se hizo así ya que dentro de los resultados obtenidos en la Sección 4.5 se corroboró que la eficiencia obtenida en las curvas ROC mejoraba si se tomaba en cuenta solo una porción del resultado de la autocorrelación y no tomar todo el vector en cuenta donde el inicio contiene valores de alta intensidad que producen falsas detección principalmente con los sonidos que contienen disparos en distancias cercanas. Esta variable se configura de 0 a 1, siendo 1 el 100% de las muestras del vector obtenido. Para el “Paso de umbral” se configura sencillamente el valor que existe entre cada umbral analizado. El último umbral usado fue de $2E^{-8}$.

Finalmente para el sistema de punto fijo se utilizó el la variable FXP donde al seleccionarla con clic derecho, se puede ingresar al área de configuración de la variable. En esa sección se configura cuantos bits se le permite a las partes de bit de signo, valor entero, y a la parte decimal. Es importante mencionar que esta variable no se le coloca ningún valor numérico, si no que solo se configura para su uso en punto fijo.

De esta manera con este tutorial y los pasos detallados anteriormente se podrá hacer uso de la programación generada y realizar futuras modificaciones para algoritmos nuevos.