

**Comparación de métodos para reducir el ruido en señales emitidas por
delfines Tursiops truncatus.**

Camila Concha Londoño

**Universidad Tecnológica de Pereira
Facultad de Ingenierías
Ingeniería Electrónica
Pereira
2015**

**Comparación de métodos para reducir el ruido en señales emitidas por
delfines Tursiops truncatus.**

Camila Concha Londoño

**Proyecto de Grado para optar al título de
Ingeniera Electrónica**

Director

PhD. Mauricio Alexander Álvarez López

Universidad Tecnológica de Pereira

Facultad de Ingenierías

Ingeniería Electrónica

Pereira

2015

CONTENIDO:

RESUMEN

AGRADECIMIENTOS

INTRODUCCIÓN

OBJETIVOS

JUSTIFICACIÓN

1. FILTRO DE PARTÍCULAS

1.1. Introducción

1.2. Marco de trabajo del filtro de partículas

1.2.1. Selección del modelo y de la función de importancia

1.2.2. Filtro de partículas SIS

1.2.3. Implementación del algoritmo SIS

1.2.4. Degeneración de los pesos y remuestreo

1.2.5. Filtro de partículas SIR y su implementación

2. DETECTOR DE BORDES BASADO EN UMBRALIZACIÓN

2.1. Introducción

2.2. Suavizado Gaussiano

2.2.1. Selección del kernel Gaussiano

2.3. Umbralización

2.3.1. Selección del umbral

2.3.2. Binarización

2.4. Características adicionales

2.4.1. Segmentación y etiquetado

2.4.2. Orientación y longitud del eje mayor

2.5. Algoritmo de detección

3. METODOLOGÍA

3.1. Base de datos

3.1.1. Banco de grabaciones de señales emitidas por delfines

Tursiops truncatus

3.1.2. Selección de muestras

3.2. Implementación del filtro de partículas

3.3. Implementación del detector de bordes basado en umbralización

3.4. Calculo de Relación Señal a Ruido (SNR)

3.5. Pruebas con diferentes muestras del banco de señales

3.5.1. Pruebas con filtro de partículas y detector de bordes en señales con ruido real

4. RESULTADOS Y DISCUSIÓN

4.1. SNR obtenida con filtro de partículas y detector de bordes basado en umbralización

4.2. Tiempo de ejecución de los algoritmos

4.3. Comparación de resultados con base en las SNR obtenidas.

BIBLIOGRAFÍA

APÉNDICE

A. La bioacústica marina

B. El espectrograma

AGRADECIMIENTOS

Les agradezco a mis padres y hermana por el apoyo incondicional. Al profesor Mauricio Alexander Álvarez por su disposición y colaboración. A Juliana Curcio Valencia por la suministración de la base de datos empleada.

RESUMEN

La constante búsqueda de metodologías de filtrado y procesamiento de señales biológicas como las emitidas por delfines *Tursiops truncatus*, se debe a que cada vez es de mayor interés estudiar las especies en peligro de extinción o con la intención de conocer y entender su comportamiento. Aplicaciones como el censo de la especie, identificación de individuos aislados y reconocimiento de patrones en la comunicación, son solo algunas de las posibles investigaciones que podrían utilizar como base un procesamiento previo basado en el filtrado de las señales mencionadas.

En el presente trabajo se presentan la implementación y comparación de dos metodologías, empleadas para extraer los contornos generados por los whistles de delfines *Tursiops truncatus* en un espectrograma. Las metodologías empleadas son: filtro de partículas y detección de bordes basado en umbralización. El filtro de partículas utilizado, es el "Secuencial Importance Resampling (SIR)", el cual simplifica la selección del modelo a emplear y remuestrea en algunas iteraciones para descartar bajas probabilidades de detección de la señal. Para el caso del detector de bordes basado en umbralización, la implementación se basa en el espectrograma de la señal, tratando la señal como una imagen y haciendo uso del Toolbox de Matlab para el procesamiento de imágenes. Se utiliza un suavizado Gaussiano y la umbralización de la imagen seccionada, para la detección del contorno generado por los whistles. La comparación de los resultados obtenidos por ambos métodos, se basa en la Relación Señal a Ruido (SNR) obtenida en cada caso.

INTRODUCCIÓN

Las señales acústicas se propagan mejor que cualquier otro tipo de señal en el medio acuático. Esto ha posibilitado el desarrollo de sistemas de sonar o navegación por sonido, con fines como la detección de objetivos y la comunicación subacuática, utilizados en aplicaciones militares, civiles y científicas [4].

Una gran gama de animales marinos utilizan ondas de sonido para su ubicación, comunicación e interacción con el medio. Estos sistemas han sido estudiados en diversas especies incluyendo los Cetáceos, quienes cuentan con tres tipos de emisión de sonido: silbidos (“whistles”), chasquidos de ecolocalización (“click series”) y ráfagas de pulsos (“Burst-pulses”). Los chasquidos de ecolocalización son utilizados para el reconocimiento del entorno y caza, las ráfagas de pulsos se generan en algunas interacciones sociales sin descartar otros posibles propósitos de ambas emisiones. Finalmente, los whistles, que son el objetivo de estudio de este proyecto, se producen en situaciones de interacción social y se cree que es una forma de reconocimiento individual [5].

Para avanzar en el estudio de los whistles, con el fin de llegar a una profunda comprensión de la cognición del delfín Nariz de botella (*Tursiops truncatus*), es necesario separar los silbidos capturados del ruido subacuático presente en las grabaciones, el cual puede ser generado por ellos mismos con sus pulsos de ecolocalización, fuentes de sonido externas como salpicaduras de agua u otras fuentes de ruido ambiental [5].

El propósito de este trabajo es comparar dos algoritmos para la extracción del ruido presente en las grabaciones disponibles, las cuales contienen emisiones de delfines *Tursiops truncatus* en condiciones de cautiverio, que se encuentran en el Oceanario Ceiner de las Islas del Rosario Colombia.

Las técnicas que se emplearán son escogidas debido a que representan un compromiso entre cuatro características fundamentales para aplicaciones basadas en la detección de señales o pistas haciendo uso del espectrograma [1]. Las pistas, son los contornos generados por una señal en su correspondiente espectrograma. La eficiencia de los algoritmos en cuanto a la variabilidad del ruido, al nacimiento/muerte de pistas, al procesamiento de múltiples pistas o pistas simultáneas y a una alta variabilidad de la pista, son las características consideradas para la selección apropiada de técnicas [1]. Al analizar estas propiedades, se determina trabajar sobre dos metodologías: Filtros de partículas (Tracking) y detección de bordes y umbralización (Procesamiento digital de imágenes). En este sentido, el objetivo es realizar la comparación entre los resultados de ambos métodos usando como parámetro la relación señal a ruido de la señal (SNR).

Al generar algoritmos que se pueden usar sobre diferentes señales disponibles en la base de datos, se contribuye en investigaciones y aplicaciones que requieran de éstas. Como pueden ser la clasificación y comprensión de patrones de comportamiento [10], identificación de individuos [11] y censado de poblaciones [18] que tengan como base las señales acústicas que emiten estos animales. También pueden ser usados en trabajos que requieran la eliminación del ruido presente en señales emitidas por otros tipos de cetáceos y mamíferos acuáticos, como ballenas y otras especies de delfines [3].

OBJETIVOS

Objetivo general

Comparar los resultados obtenidos con los métodos filtrado de partículas y detección de bordes para determinar cuál genera una mejor Relación Señal a Ruido en las señales emitidas por delfines *Tursiops truncatus* del Oceanario Ceiner, en las Islas del Rosario, Colombia.

Objetivos específicos

- I) Implementar un método de filtrado basado en un sistema de espacio de estados y un filtro de partículas, para disminuir el ruido presente en las señales disponibles.
- II) Implementar un método de procesamiento de imágenes basado en detección de bordes y umbralización, para disminuir el ruido presente en las señales disponibles.
- III) Validar los resultados de los métodos, empleando diferentes muestras de un banco de grabaciones de delfines *Tursiops truncatus* del Oceanario Ceiner, Islas del Rosario, Colombia.
- IV) Determinar cuál de los métodos es más eficiente para esta aplicación con base en el parámetro Relación Señal a Ruido (SNR) obtenido a partir de los resultados.

JUSTIFICACIÓN

Los métodos aquí propuestos serán de aplicación general en los estudios de bioacústica que involucren señales provenientes tanto de entornos acuáticos como aéreos y terrestres. Se pretende generar una solución práctica al problema de ruido que está presente en las grabaciones de emisiones animales que se generan en el medio acuático en particular, contribuyendo con una base de datos con señales de delfines con alta relación señal a ruido (SNR) y los algoritmos utilizados para su obtención.

Con el desarrollo de este proyecto se podría reducir el tiempo en el desarrollo de investigaciones y aplicaciones en el área de bioacústica de delfines. Esto al disponerse de dos métodos depurados y comparados, implementados para la sustracción del ruido en las señales que sirven como base para este tipo de investigaciones.

Con base en los beneficios expuestos, se busca aportar en proyectos con propósitos como el análisis de patrones de vocalizaciones en situaciones determinadas, el censado de la especie y otros estudios con base en emisiones acústicas de delfines *Tursiops truncatus*. Debido a que en la mayoría de los casos, las señales deberán tener un procesamiento previo para la disminución de ruido.

El desarrollo de este proyecto, aporta conocimiento y afianzamiento de técnicas de procesamiento de señales obtenidas en entornos que añaden grandes componentes de ruido como el océano. De este modo, se puede observar la utilidad de la electrónica en los diferentes campos del saber, en este caso se observa una relación con la biología marina, puesto que, la necesidad de la cual se desprende la investigación, es aportar avances que sirvan como referencia para la comprensión y conservación de la especie.

Este tipo de estudios son de gran importancia para la comprensión y conocimiento de la biodiversidad en Colombia. Según la literatura revisada, en el país no se han generado muchos aportes en el área de bioacústica de Cetáceos en comparación con los avances a nivel internacional, a pesar de la gran cantidad de delfines que habitan en nuestros mares. Con el desarrollo de este proyecto se pretende aportar en el área de bioacústica marina a nivel nacional.

1. FILTRO DE PARTÍCULAS

1.1. Introducción

El filtro de partículas (FDP) general, fue desarrollado por N. Gordon, D. Salmond y A. Smith en 1993 para implementar filtros Bayesianos recursivos haciendo uso del método de Monte Carlo. El FDP También es conocido como Filtro Bootstrap o SIS (Sequential Importance Sampling) [7].

El FDP es un método utilizado para predecir o estimar el estado de un sistema que cambia con el tiempo. Básicamente, el FDP consta de un conjunto de muestras o partículas, extraídas del vector de estados del sistema y unos pesos asociados a ellas. Estos pesos, representan la función de densidad de probabilidad (p.d.f) del estado a posteriori, dadas unas observaciones [7].

El algoritmo general del filtro de partículas consta de cuatro etapas generales:

- Etapa de inicialización.
Para el seguimiento de un objetivo sobre una imagen o señal, primero se deben “arrojar” un conjunto de puntos sobre ella (partículas). Esto puede ser mediante un estado al azar o basados en características conocidas del objetivo, tales como, posición aproximada, tamaño del objeto, rango de frecuencias o energía de la señal en el caso de señales [7].
- Etapa de actualización.
Aquí, se tiene en cuenta la similitud del estado actual de cada partícula con el estado de referencia o vector de observaciones, para asignar los valores o pesos a cada una de ellas [7] [3].
- Etapa de estimación.

En esta etapa, se crea un nuevo conjunto de partículas basado en los pesos establecidos en la etapa anterior, este conjunto será la estimación a priori del estado en el instante siguiente [7] [3].

- Etapa de predicción.

La etapa final, consiste en formar una estimación del vector de parámetros, a partir del conjunto de partículas obtenido en la etapa de estimación [3].

Al finalizar la etapa de predicción, se genera un nuevo conjunto de partículas, las cuales deberán introducirse nuevamente al ciclo partiendo de la etapa de actualización [7]. El número de veces que esto sucede es determinado por la cantidad de muestras y la aplicación particular. A medida que el número de partículas crece, la f.d.p a posteriori es exacta y así el filtro de partículas genera una estimación Bayesiana óptima.

Se plantea el filtro de partículas para realizar el seguimiento de los contornos generados por los whistles de delfines *Tursiops truncatus* en el espectrograma de la señal que los contiene. La implementación del filtro, se basa en el modelo de espacio de estados del sistema que se describe en la sección 1.2.

1.2. Marco de trabajo del Filtro de Partículas

El filtro de partículas tiene como base el vector de estados del sistema, el cual contiene la información relevante para su descripción. En problemas de seguimiento de objetivos estas características podrían estar relacionadas con las extraídas de la imagen, tales como, área, perímetro, color, posición, entre otros [7].

El modelo general utilizado en filtros de partículas, se basa en una ecuación que describe la evolución del estado del sistema en el tiempo, ésta se denomina “ecuación de estados o de movimiento”. Además, se debe conocer una ecuación

que relacione el estado del sistema con las medidas u observaciones, ésta es conocida como “ecuación de observación o verosimilitud” las cuales se describen respectivamente a continuación [7].

$$x_n = f(x_{n-1}) + W_n \quad (1)$$

$$z_n = h(x_n) + V_n \quad (2)$$

Donde f es la función del sistema y h la de observación, generalmente son funciones no lineales. W_n y V_n son los procesos de ruido del sistema y de la observación respectivamente y se asumen conocidos [12].

La probabilidad de transición, $p(x_n|x_{n-1})$ es utilizada para actualizar el estado del sistema. La distribución posterior de interés es proporcional a la probabilidad en (3) [12].

$$p(x_n | z_n) \propto p(z_n | x_n) \quad (3)$$

En problemas de seguimiento de componentes frecuenciales, existen algunos modelos usados como ecuación de observaciones, tales como, la Transformada de Fourier de tiempo corto (STFT) [15] y la Transformada Fraccional de Fourier de tiempo corto (STFrFT) [3]. Para este tipo de problemas también es posible hacer uso de un modelo simple de armónicos de frecuencia (4) como ecuación de observaciones [16] [12].

$$g(t) = B_1 \cos(2\pi ft) + B_2 \text{sen}(2\pi ft) \quad (4)$$

Donde B_1 y B_2 , contienen la amplitud y fase de la señal y f es la frecuencia.

Siendo consecuentes con el planteamiento del modelo, la ecuación de observaciones puede ser escrita adicionando un ruido Gaussiano a la ecuación (4) como sigue.

$$z(t) = g(t) + v(t) \quad (5)$$

Donde:

$$v(t) \sim \mathcal{N}(0, \sigma_v^2) \quad (6)$$

Donde σ_v^2 corresponde a la varianza del ruido de las observaciones y se asume conocido.

Para la descripción del sistema es necesario contar con la ecuación de estado del sistema. Para el caso de la extracción de whistles sobre un espectrograma, el estado oculto es la frecuencia fundamental del whistles más un ruido Gaussiano (7). Con lo que se completa el modelo de espacio de estados que describe el sistema.

$$x(t) = f(t) + w(t) \quad (7)$$

Donde:

$$w(t) \sim \mathcal{N}(0, \sigma_w^2) \quad (8)$$

Donde σ_w^2 corresponde a la varianza del ruido del proceso y se asume conocido.

Existen casos en los que la implementación del Filtro de Partículas, se realiza sobre ventanas de análisis sucesivas de la señal de entrada [3]. Para la utilización de las ventanas, se definen los siguientes parámetros: L como la longitud de la ventana y P como el traslape entre ventanas. Cuando el traslape entre ventanas (P) aumenta, la respuesta del filtro se optimiza, debido al incremento del número de iteraciones que el filtro opera sobre la señal.

1.2.1. Selección del modelo y de la función de importancia

El modelo del sistema incluye la ecuación de estados (7) y la ecuación de observaciones (5). Para la inicialización del modelo del sistema, se fijan un conjunto de valores (partículas) con pesos aleatorios, los cuales se actualizan tras cada iteración, logrando finalmente la estimación del parámetro deseado. Se define $z_t = \{z(t-L+P), \dots, z(t)\}$ como el vector de observaciones de longitud L [12].

A continuación se define la función de probabilidad, que sirve como base para realizar el seguimiento de los componentes de frecuencia, fase y amplitud de una señal, mediante el uso del modelo de armónicos de frecuencia en (4).

$$p(z_t | B_1, B_2, f, \sigma_v^2) = \prod_{i=t-L+P}^t \left\{ \frac{1}{\sqrt{2\pi\sigma_v^2}} \exp \left[-\frac{\{z(i) - g(i)\}^2}{2\sigma_v^2} \right] \right\} \\ \propto \sigma_v^{-L} \exp \left[-\frac{1}{2\sigma_v^2} \sum_{i=t-L+P}^t \{z(i) - g(i)\}^2 \right] \quad (9)$$

En problemas de seguimiento de frecuencia, cuando los parámetros de fase y magnitud no son relevantes, estos pueden ser marginalizados. En estos casos, la función de probabilidad de interés se convierte en $p(z_t | f, \sigma_v^2)$.

La marginalización de la fase y la amplitud B_1 y B_2 respectivamente, se realiza con base en el planteamiento de Bettrost [16], partiendo de la ecuación de armónicos de frecuencia $g(t)$ descrita en (4) [12]. Se asume que la longitud del vector de observación $L \gg 1$ con el fin de generar la distribución marginalizada, la cual se describe a continuación.

$$p(z_t | f, \sigma_v^2) \propto \sigma_v^{-L+2} \exp \left[-\frac{L}{2\sigma_v^2} \left\{ \overline{z_t^2} - \frac{2C(f)}{L} \right\}^2 \right] \quad (10)$$

Donde:

$$\overline{z_t^2} = \frac{1}{L} \sum_{i=t-L+P}^t z(i)^2$$

Y $C(f)$ es el periodograma de Schuster definido como [12]:

$$C(f) = \frac{1}{L} \left\{ \left[\sum_{i=t-L+P}^t z(i) \cos(2\pi fi) \right]^2 + \left[\sum_{i=t-L+P}^t z(i) \text{sen}(2\pi fi) \right]^2 \right\}$$

La probabilidad en (10) $p(z_t|f, \sigma_v^2)$, también puede ser escrita como $p(z_t|x_t)$, asumiendo que f es estado oculto del sistema y se incluye a σ_v^2 como la varianza del ruido de las observaciones.

Con la marginalización de los parámetros no relevantes en la aplicación de seguimiento de whistles, se obtiene una forma más simple de determinar la probabilidad de interés (10). La cual, sirve como base para generar los pesos de las partículas o muestras de la señal de interés.

La función de importancia $q(\cdot)$, que se observa en (11), es la que proporciona el peso a cada partícula. Se define n como el dominio de tiempo discreto y S como el número de partículas determinado por la aplicación.

$$w_n^S = w_{n-1}^S \frac{p(z_n|x_n^S) * p(x_n^S|x_{n-1}^S)}{q(x_n^S|x_{n-1}^S, z_n)} \quad (11)$$

La selección más común para la función de importancia, se genera aproximando la densidad de importancia a la condicional a priori como sigue [2] [17].

$$q(x_n^S|x_{n-1}^S, z_n) \approx p(x_n^S|x_{n-1}^S) \quad (12)$$

En este sentido, reemplazando (12) en (11) se llega a una función de importancia reducida (13) para la actualización de los pesos [2] [17].

$$w_n^s = w_{n-1}^s * p(z_n | x_n^s) \quad (13)$$

1.2.2. Filtro de partículas SIS

El algoritmo SIS (Secuencial Importance Sampling), es la base de todos los desarrollos en filtros de partículas de las últimas décadas [13]. La idea general del filtro, es representar la función de densidad (f.d.p.) posterior requerida, por medio de un conjunto de muestras aleatorias con pesos asociados. Para lograrlo, se debe realizar una estimación adecuada con base en la actualización iterativa de estas muestras y pesos [13]. Mientras el número de partículas crece, el filtro SIS genera un resultado aproximado a la estimación Bayesiana óptima [13].

Para especificar la dinámica del algoritmo, es necesario denotar x_n^s como el conjunto de muestras tomadas del vector de estados, las cuales caracterizan la f.d.p. posterior del estado, $p(x_n | z_n)$. También se definen los pesos asociados a cada una de las muestras como w_n^s . Dichos pesos son normalizados en el algoritmo de manera que $\sum_{s=1}^S w_s = 1$ [7].

Con base en el modelo planteado en el apartado anterior, el algoritmo del filtro de partículas SIS se describe con el pseudocódigo descrito en el siguiente subcapítulo.

1.2.3. Implementación del algoritmo SIS

Algoritmo 1: Filtro de Partículas SIS

For $n = 1$: Número de ventanas

- For $s = 1:S$, Asignar pesos: $w_n^s = S^{-1}$, $n = 1$

- For $s = 1:S$,

$$\text{Calcular: } x_n^s = \begin{cases} p(x_n), & n = 1 \\ p(x_n|x_{n-1}), & n > 1 \end{cases}$$

$$\text{Calcular: } w_n^s = w_{n-1}^s * p(z_n|x_n^s)$$

- For $s = 1:S$,

$$\text{Normalizar los pesos: } \tilde{w}_n^s = \frac{w_n^s}{\sum_{m=1}^S w_n^m}$$

End

Donde S es el número de partículas, el cual es determinado por la aplicación y x es la señal en estudio.

1.2.4. Degeneración de los pesos y remuestreo

Un problema común con el filtro de partículas SIS, es el fenómeno de degeneración de los pesos, en el cual, a medida que se ejecutan las iteraciones, la mayoría de las partículas tendrán pesos despreciables. Esto ocurre, debido a que se está muestreando en un espacio de dimensiones muy altas [17]. Este es un fenómeno imposible de evadir, debido a que la varianza de los pesos solo puede crecer a medida que las iteraciones avanzan. Este problema de degeneración, implica un gran esfuerzo computacional para actualizar partículas que no podrán contribuir en la estimación de $p(x_n^s|z_n)$ [13].

Para solucionar este problema de degeneración de los pesos, se plantea una etapa adicional llamada remuestreo. Existen varios algoritmos de remuestreo (remuestreo multinomial, remuestreo residual, remuestreo sistemático). Esta etapa de

remuestreo, se encarga de eliminar partículas con pesos despreciables y replicar un número de veces proporcional a su peso, las partículas que posean pesos importantes. Una explicación gráfica de la etapa de remuestreo se muestra en la figura 1.

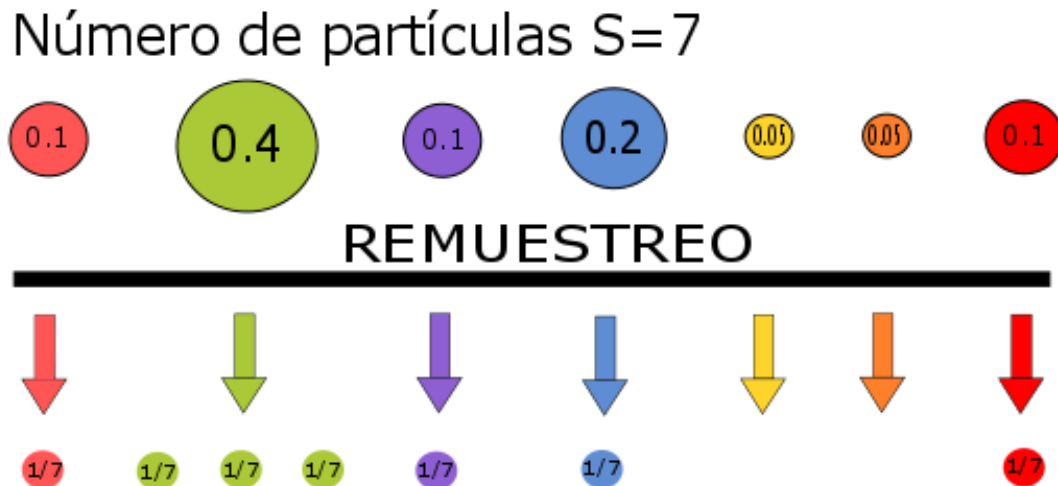


Figura 1. Esquema gráfico de Remuestreo.

A continuación se explicará una técnica de remuestreo comúnmente empleada, debido a la simpleza de su implementación. Esta técnica es denominada como remuestreo multinomial [17]. Para su uso, es necesario determinar un umbral mínimo, el cual determinará en cuales iteraciones se realizará la etapa de remuestreo. Esto es debido a que a pesar de que el remuestreo soluciona el problema de degeneración de los pesos, puede causar problemas por sí mismo. Un problema ocurre cuando las partículas con pesos altos son elegidas una y otra vez, produciendo una pérdida en la diversidad entre las partículas con pesos asociados [17].

En este sentido, se realiza el cálculo del grado de degeneración de los pesos (14), para tener el punto de referencia que habilita o no, la etapa de remuestreo en cada iteración.

$$S_{eff} = \frac{1}{\sum_{s=1}^S (w_n^s)^2} \quad (14)$$

El umbral S_{min} , que determina si el proceso de remuestreo se realiza en la presente iteración, se establece de manera experimental. Para ello, se realizan pruebas con valores aleatorios y se observa el comportamiento del filtro. La condición para la realización de la etapa de remuestreo, es que el grado de degeneración de los pesos S_{eff} , sea menor que el umbral mínimo determinado S_{min} . A continuación se define un vector aleatorio con distribución multinomial, con un tamaño de muestra igual al número de partículas (S) empleado y a lo largo de un vector de probabilidades de S posiciones, que en este caso son los pesos calculados para cada iteración.

Seguido a esto, se toman las posiciones del vector generado, donde los valores sean diferentes de cero, ya que allí es donde se encuentran los pesos con probabilidades relevantes. Los pesos son replicados un número de veces proporcional al valor entregado por el vector de distribución multinomial alrededor de la posición en que se encuentra dicho peso. De esta manera, se genera el nuevo conjunto de partículas para introducir en la siguiente iteración. Finalmente el vector de pesos es reinicializado como $1/S$ donde S es el número de partículas usado en la aplicación.

1.2.5. Filtro de partículas SIR y su implementación

El filtro de partículas SIR es una extensión del filtro SIS mostrado en el apartado anterior. El cual añade una etapa de remuestreo al algoritmo SIS solucionando el problema de degeneración de los pesos.

Algoritmo 2: Filtro de Partículas SIR

For n = 1: Número de ventanas

- For s = 1:S, Asignar pesos: $w_n^s = S^{-1}$, $n = 1$

- For s = 1:S,

$$\text{Calcular: } x_n^s = \begin{cases} p(x_n), & n = 1 \\ p(x_n | x_{n-1}), & n > 1 \end{cases}$$

$$\text{Calcular: } w_n^s = w_{n-1}^s * p(z_n | x_n^s)$$

- For s = 1:S,

$$\text{Normalizar los pesos: } \tilde{w}_n^s = \frac{w_n^s}{\sum_{m=1}^S w_n^m}$$

- Etapa de remuestreo multinomial:

$$\text{Calcular: } S_{eff} = \frac{1}{\sum_{s=1}^S (w_n^s)^2}$$

If $S_{eff} < S_{min}$

$$(K_1, \dots, K_s) \sim Mu(w_n^1, \dots, w_n^s)$$

$$\pi = \text{indices}(K)$$

$$z_n = z_n^\pi$$

$$w_n^s = \frac{1}{S}$$

End

Para mostrar visualmente el proceso de filtrado de partículas en espectrogramas de whistles en general, se generó una señal sintética del tipo *chirp* en Matlab y se le añadió ruido blanco Gaussiano. Las señales del tipo *chirp*, se caracterizan por tener una frecuencia fundamental variable con el tiempo, dicha frecuencia puede tener un comportamiento lineal, cuadrático o logarítmico. Entonces, las señales de tipo *chirp* pueden tener rasgos similares a los de los whistles de delfines *Tursiops truncatus* en un espectrograma. En la figura 2, se muestra el espectrograma de la señal sintética mencionada, sobrepuesta con el seguimiento que realiza el filtro de partículas SIR.




Figura 2. Filtro de partículas SIR sobre el espectrograma de un whistle sintético generado en Matlab.

Como se observa en la figura 2, el filtro de partículas (línea azul) sigue a la perfección el recorrido de la señal sintética de interés. Para este ejemplo se utilizó una señal tipo *chirp* cuadrática.

2. DETECTOR DE BORDES BASADO EN UMBRALIZACIÓN

2.1. Introducción

En el área de procesamiento digital de imágenes, existen algunos métodos que son usados regularmente para procesar señales de audio, debido a que se pueden representar en forma de imagen con el uso del espectrograma. El método de detección de bordes, ha sido utilizado en algunos proyectos con objetivos similares al de este proyecto, que es la detección de whistles en un espectrograma. Proyectos como, los sonidos producidos por un humano al dormir [8], la detección del habla [9], la detección de los llamados de la ballena franca [10], entre otros.

La umbralización, es un método muy utilizado en el procesamiento de imágenes, puesto que proporciona información sobre la intensidad de luz en cada punto o pixel de una imagen, a dicha información se accede con la conversión a escala de grises. La binarización es un caso particular de umbralización y consiste en dejar en cero los pixeles que estén por debajo de un umbral definido. Dicho umbral puede ser fijo o global, es decir, que es único para toda la imagen; también puede ser variable o local, en el cual, se considera la vecindad de cada pixel para determinar el umbral local. La binarización es comúnmente utilizada para separar o segmentar objetos de interés dentro de una imagen.

Para mostrar visualmente el proceso de binarización en espectrogramas de whistles en general, se generó una señal sintética del tipo *chirp* lineal en Matlab y se le añadió ruido blanco Gaussiano. En la figura 3 se muestra el espectrograma de la señal sintética mencionada.




Figura 3. Espectrograma señal sintética con ruido aleatorio.

2.2. Suavizado Gaussiano

Existen algunas técnicas de suavizado en procesamiento digital de imágenes, tales como, el filtro de media y el filtro Gaussiano. En general, la idea del suavizado es reducir la intensidad de variaciones en el color entre píxeles cercanos. El filtro Gaussiano, usa un kernel que da prioridad al píxel central y realiza un proceso de convolución entre este kernel y la matriz de la imagen. Es por esto que el filtro Gaussiano, genera un suavizado uniforme.

El algoritmo de suavizado (Smoothing) previo a la detección, tiene como objetivo evitar que el detector reaccione frente a bordes o contornos sutiles e innecesarios, no pertenecientes a whistles o silbidos emitidos por delfines. Esto, gracias al difuminado que el algoritmo genera en la imagen.

2.2.1. Selección del kernel Gaussiano

Existen múltiples máscaras o kernels con distribución Gaussiana que pueden ser útiles en aplicaciones de detección de bordes. A mayor desviación estándar para

dicha distribución, mayor es el suavizado que el kernel genera. Una característica general de las máscaras empleadas en filtros Gaussianos, es que poseen simetría rotacional, es decir, genera el mismo efecto en cualquier dirección alrededor del pixel central. El kernel Gaussiano siempre le da mayor peso al pixel central y menos peso a los pixeles más alejados del centro, esto para generar el difuminado del centro hacia afuera. Generalmente al aplicarle un algoritmo de suavizado a una imagen, se pierde resolución, es por esto, que el kernel no debe ser demasiado grande [10].

$$G = \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix} \quad (15)$$

El suavizado Gaussiano es utilizado con frecuencia en problemas de detección de bordes como un procesamiento previo para mejorar la detección.

2.3. Detección de bordes basado en umbralización

La detección de bordes sobre una imagen, se puede realizar utilizando un detector de umbral simple. Dicho detector, también es conocido como método de umbralización. Consiste en comparar cada pixel de la imagen con un umbral definido, con el objetivo de detectar secciones u objetos que posean diferentes intensidades de color en la imagen [10]. Para determinar el umbral, se tienen en cuenta las variaciones en la intensidad de color en cada pixel de la imagen. La umbralización se puede realizar con base en un umbral global o local de acuerdo a lo planteado en la introducción de este capítulo.

Una forma sencilla de implementar un umbral "local", con base en técnicas de umbralización global dada su simplicidad, es seccionando la imagen en ventanas de determinada área. Sobre cada ventana se calcula un umbral global, el cual será diferente para cada ventana, constituyendo un umbral local para cada una de ellas.

2.3.1. Selección del umbral

Para la selección del umbral, existen algunas técnicas, por ejemplo, en las globales se pueden relacionar los siguientes: el método del mínimo, el método de la entropía de Shannon, el método del triángulo y el método de Otsu [14]. Por otro lado, algunas técnicas locales son: técnica del promedio, de la media, máximo y mínimo, técnica de Niblack y técnica de Sauvola [14]. Como se mencionó anteriormente, una forma sencilla de mejorar la respuesta del detector, es implementando una técnica global sobre ventanas de análisis sucesivas de la imagen original.

La técnica de Otsu es comúnmente empleada debido a la óptima respuesta que presenta ante situaciones del mundo real, como imágenes ruidosas y mal iluminadas. Otra ventaja notable, es que no necesita pre procesamiento y es totalmente automatizable.

Esta técnica, parte de la imagen en escala de grises con lo que asume a su histograma como bimodal. La selección del umbral adecuado, se determina cuando la varianza entre las dos clases es máxima pero a su vez la varianza dentro de cada clase, es mínima. En este caso, las clases son los dos segmentos en que queda dividida la imagen, una para cada sección del histograma bimodal.

Para el cálculo de la varianza entre clases (16), es necesario calcular la varianza entre pixeles dentro de cada clase (17), para lo cual, se recorre el histograma de la imagen calculando la varianza de pesos en cada una de ellas para cada valor posible de 0 a 255 [14]. Los pesos son la intensidad de cada pixel reflejado en el histograma. El rango de intensidades de grises es de 0 a 255 y el umbral deseado es el punto en el que se forma un valle entre los dos picos del histograma bimodal.

$$\sigma_w^2(t) = P_1(t)\sigma_1^2(t) + P_2(t)\sigma_2^2(t) \quad (16)$$

Donde la probabilidad de ocurrencia de los pixeles en cada clase están dadas por:

$$P_1(t) = \sum_{i=0}^t p(i) \quad P_2(t) = \sum_{i=t+1}^{255} p(i)$$

Donde $p(i)$ es la probabilidad de ocurrencia del valor de gris entre 0 y 255, y t es el umbral deseado.

Las varianzas de cada clase se calculan como sigue:

$$\sigma_1^2(t) = \sum_{i=0}^t [i - \mu_1(t)]^2 \frac{p(i)}{p_1(t)} \quad \sigma_2^2(t) = \sum_{i=t+1}^{255} [i - \mu_2(t)]^2 \frac{p(i)}{p_2(t)} \quad (17)$$

Y las intensidades medias de cada clase se calculan así:

$$\mu_1(t) = \frac{\sum_{i=0}^t i * p(i)}{p_1(t)} \quad \mu_2(t) = \frac{\sum_{i=t+1}^{255} i * p(i)}{p_2(t)}$$

Para conseguir que la varianza dentro de cada clase sea lo más pequeña posible, y la varianza entre las dos clases sea lo más grande, se utiliza el cociente entre estas dos variables, la varianza entre clases sobre la suma de las varianzas de cada clase. A continuación, se busca el valor de umbral entre 0 y 255 para el cual este cociente sea máximo. Con este procedimiento, se consigue un valor de umbral óptimo, que sirve como base fundamental para el proceso de umbralización.

2.3.2. Binarización

Finalmente, la binarización consta de actualizar el valor de cada pixel según el umbral determinado. Si el pixel tiene un valor por debajo de dicho umbral, el pixel se fija en cero y si el valor del pixel está por encima, se fija en uno.

En la figura 4, se muestra la binarización de un espectrograma con y sin suavizado Gaussiano previo.




Figura 4. (a) Binarización con suavizado Gaussiano. (b) Binarización sin suavizado.

2.4. Características adicionales

Dado el comportamiento aleatorio del ruido presente en señales provenientes de la naturaleza, es necesario complementar el proceso de detección. Esto se logra, haciendo uso de algunas características que resultan útiles a la hora de identificar y descartar segmentos de la imagen (espectrograma) no pertenecientes a la señal de interés. Lo anterior, es posible debido a que los segmentos del espectrograma que representan ruido y que son detectados como un borde, cumplen con ciertos parámetros comunes de tamaño y forma que se pueden aprovechar para su eliminación [14].

En el área de procesamiento digital de imágenes, es muy común la utilización de características como área, perímetro, orientación, longitud de los ejes, entre otras. Estas características, pueden ser utilizadas para la identificación de parámetros en objetos aislados dentro de una imagen para un proceso posterior de clasificación [7]. Para el aislamiento de los objetos presentes en una imagen, se emplea un método de segmentación y etiquetado. Como su nombre lo indica, la segmentación sirve para separar individualmente cada objeto que no esté relacionado con otro dentro de la imagen. El etiquetado se encarga de especificar un nombre o valor para

cada uno de esos objetos y así poder manipular cada uno de forma individual. Para la extracción de características y aplicación de los métodos descritos, es necesario que la imagen sea binaria [14].

2.4.1. Segmentación y etiquetado

El proceso de segmentación y etiquetado, se utiliza para separar y tener acceso a los diferentes objetos presentes en una imagen. Esto se consigue, identificando todos los píxeles conectados dentro de una imagen y se asigna un valor o etiqueta única para todos los píxeles en el mismo grupo. Se habla de píxeles conectados, cuando un píxel o grupo de píxeles que tienen valor uno, son vecinos inmediatamente de otro u otros también con valor uno. Es por esto, que la imagen a intervenir debe estar en forma binaria [14]. Finalmente, cada segmento separado en la imagen tendrá una etiqueta con la cual se podrá acceder a cada objeto de forma individual.

2.4.2. Orientación y longitud del eje mayor

La propiedad de orientación, se encarga de medir el ángulo que hay entre el eje mayor de la elipse que encierra el objeto y la horizontal [14]. Los segmentos de ruido que se observan sobre el espectrograma, son en su mayoría, visualmente perpendiculares a la horizontal. A diferencia de los contornos de whistles generalmente detectados, los cuales tienen un ángulo menor con respecto a la horizontal. Entonces, el objetivo de medir la orientación de los objetos segmentados y etiquetados dentro del espectrograma, es descartar los segmentos que tienen esa perspectiva perpendicular característica del ruido.

La característica longitud del eje mayor, mide, como su nombre lo indica, el tamaño del eje mayor de la elipse que encierra el objeto aislado dentro de la imagen

(espectrograma) [14]. Dado que los segmentos de ruido presentan una longitud mucho menor que la de los whistles, esta característica es de gran utilidad para eliminar los que estén fuera de un umbral determinado. Dicho umbral puede ser seleccionado de manera heurística, observando los resultados al variar su valor. De la misma manera, puede ser fijado el umbral de la característica orientación.

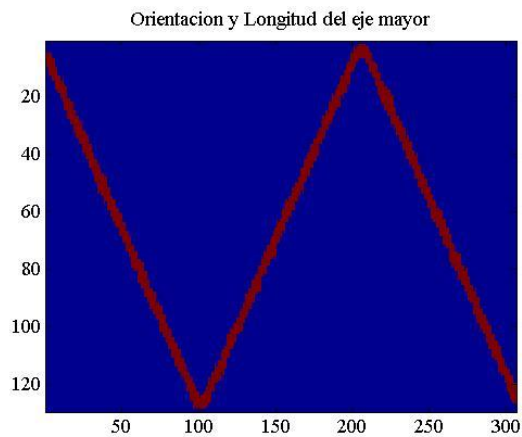


Figura 5. Uso de características: orientación y longitud del eje mayor.

En la figura 5, se muestra un ejemplo de la eliminación de ruido que se logra al utilizar la orientación y longitud del eje mayor. El uso de estas características es implementado sobre la binarización del espectrograma con suavizado previo, mostrado con anterioridad en la figura 4.




Figura 6. Espectrograma señal resultante del procesamiento de detección de bordes basado en umbralización.

En la figura 6, se observa que el resultado del detector de bordes basado en umbralización, es óptimo para el seguimiento de la señal sintética generada.

2.5. Implementación del algoritmo de detección

A continuación, se muestra el pseudocódigo que describe el proceso de detección de bordes basado en umbralización y suavizado previo. Donde x es la señal original.

Algoritmo 3: Detección de bordes y Umbralización

$X = \text{STFT de } x$

$S = \text{Suavizado Gaussiano a } X$

For $i = 0$, pasos de 50, hasta columnas de S % Binarizada por enventanamiento

 Imagen Binarizada = Umbralización OTSU

End

[Segmentos, Número de segmentos] = Segmentación de Imagen Binarizada

For $i = 1$, hasta número de segmentos

$O = \text{Orientación del segmento } i$

$L = \text{Longitud del eje mayor del segmento } i$

If $O < \theta \ \& \ L > l$

$I = \text{guardar segmento } i$

end

End

Imagen final = $I \cdot X$

Señal resultante = ISTFT de Imagen final

3. METODOLOGÍA

El objetivo general de este proyecto, es comparar los resultados obtenidos con los métodos filtrado de partículas y detección de bordes para determinar cuál genera una mejor Relación Señal a Ruido en las señales emitidas por delfines *Tursiops truncatus* del Oceanario Ceiner, en las Islas del Rosario, Colombia. El desarrollo de este proyecto se genera con la intención de aportar un método confiable, que permita a los investigadores optimizar los desarrollos y avances basados en este tipo de señales. Para lograrlo, es necesario seguir una metodología que sirva de guía para cumplir cada uno de los objetivos específicos que se definieron en el presente trabajo.

Para la implementación de los algoritmos, se utilizó el toolbox de procesamiento de imágenes y el de procesamiento de señales de Matlab R2012a, y algunos comandos adicionales integrados al software.

Las señales de interés originales, son muestreadas a 44100 Hz. Para la representación del espectrograma de la señal, se empleó una ventana de Hamming con longitud de 256 muestras con un traslape de 255 entre ventanas [10]. Estos parámetros son rigurosamente considerados en la reconstrucción de la señal en el tiempo, puesto que cualquier cambio podría terminar en la degeneración de la señal.

3.1. Base de datos

3.1.1. Banco de grabaciones de señales emitidas por delfines Tursiops truncatus

Para el desarrollo de este trabajo, se cuenta con una base de datos de señales de delfines sobre las cuales se realizó el procesamiento. Ésta fue generada a partir de

la utilización de un hidrófono omnidireccional capaz de obtener señales de hasta 22.050 Hz, conectado a una grabadora Sony IC Recorder mp3 3.1.2 con rango de frecuencia de 1 Hz hasta 22 kHz y tasa de muestreo de 44.100 Hz. Dada la naturaleza de los whistles, los cuales constan de una frecuencia fundamental entre 1 Hz y 24 kHz, con armónicos hasta de 150 kHz, el equipo de grabación es el apropiado para la obtención de la base de datos [11]. El banco de señales fue obtenido y proporcionado por Juliana Curcio Valencia, MSc. Instrumentación Física, Universidad Tecnológica de Pereira.

3.1.2. Selección de muestras

Para seleccionar las muestras de una manera adecuada, es de suma importancia tener en cuenta parámetros como la energía y presencia prolongada de whistles en la señal, duración de la pista y si es necesario ajustarla. Con esto se pretende lograr la óptima ejecución de los algoritmos, al contar con señales de entrada que contienen la información deseada.

3.2. Implementación del filtro de partículas

Para cumplir con el objetivo de implementar un método de filtrado basado en un sistema de espacio de estados y un filtro de partículas, para disminuir el ruido presente en las señales disponibles, se realizó el procedimiento descrito a continuación.

Inicialmente, se determinó el uso de la Transformada de Fourier de tiempo corto (STFT) de la señal original para tener acceso a una imagen (espectrograma) y así, observar el comportamiento final del filtro. Esto se logra, sobreponiendo el vector de frecuencias estimado por el filtro de partículas, en dicha imagen. Además, el cálculo de la STFT genera el vector de tiempo, que se usa para determinar el número de

iteraciones que el filtro de partículas realiza para obtener el parámetro deseado, la frecuencia.

A continuación, se inicializaron los parámetros del filtro. El número de partículas, se fijó en un valor aleatorio, a medida que los resultados mejoraban, utilizando diferentes valores, se determinó el uso de 300 partículas (S). Dichas partículas se inicializaron con valores aleatorios generados en un rango de 0 a 1. Para la inicialización de los pesos asociadas a ellas, se generó un vector de S posiciones para el cual, el valor asociado a cada una fue de $1/S$ [2].

Para la implementación del algoritmo del filtro de partículas, se realizó el enventanado de la señal original, tomando muestras de tamaño L con un traslape P entre ventanas. El tamaño de la ventana L, se varió experimentalmente entre 50 y 200 en pasos de 50 para observar el comportamiento del filtro, el cual fue óptimo al fijarlo en 100. Para la determinación del traslape entre ventanas, se estableció un valor de 99, debido a que este valor genera el paso más pequeño posible entre ventanas y así, obtener la mayor cantidad de información posible de la señal inicial. El número de iteraciones que el filtro realiza, fue determinado por la longitud del vector de tiempo generado al enventanar la señal original.

La ejecución del algoritmo como tal, se basa en una estimación inicial de las partículas, las cuales, al finalizar las iteraciones determinadas, contienen el vector de frecuencias resultante. Dicha estimación inicial, se generó usando una distribución Gaussiana que tiene como media el vector de inicialización de las partículas en la primera iteración y en las siguientes, la media es el nuevo conjunto de partículas generado en la iteración anterior. En ambos casos la distribución se fijó con un valor de varianza igual a 1. Este valor de varianza se modificó experimentalmente en un rango de 0.001 a 1, concluyendo que con 1 se obtienen resultados más precisos. Esto, debido a que al aplicar una alteración o ruido a la estimación, se genera una mejor predicción en el instante siguiente.

A continuación, se realizó el cálculo de los pesos mediante el uso de la ecuación (13), la cual incluye la función de observaciones descrita en (10). Paso seguido, se calculó el grado de degeneración de los pesos (S_{eff}), utilizando la ecuación (14). El cual, al compararse con el umbral mínimo (S_{min}), determina si el proceso de remuestreo se llevará a cabo en la presente iteración. Dicho umbral mínimo fue fijado en 300 de acuerdo con la experimentación.

La etapa de remuestreo, se efectúa mientras que S_{eff} sea menor que S_{min} . Dado el caso en el que se cumpla esta condición, se realiza el proceso de remuestreo multinomial explicado en la sección 1.3.2. Cuando este proceso finaliza, se genera un nuevo conjunto de partículas y se inicializan sus pesos nuevamente con un valor de $1/S$. Si el remuestreo no se ejecuta en la iteración presente, las partículas y los pesos no son alterados. Cuando el proceso de remuestreo no es ejecutado, es debido a que la totalidad de las partículas cuenta con pesos significativos, entonces no es recomendable eliminar partículas que podrían ser de utilidad para la predicción.

Finalmente, al concluir con el total de iteraciones, el vector de frecuencias resultante z , contiene la información deseada. Para observar el comportamiento del filtro, se realiza la gráfica del vector resultante sobre el espectrograma de la señal como se observa en la figura 7.




Figura 7. Comportamiento del filtro de partículas sobre señal real.

En la figura 7, se observa el seguimiento que realiza el filtro al armónico fundamental, ya que es el que posee un mayor contenido de energía. También, se puede ver como el filtro toma unos instantes para estabilizarse entre un rango aproximado de 0 y 0.01 en el eje del tiempo. Se observa que la inicialización de las partículas efectivamente ocurre en valores muy cercanos a cero, ascendiendo rápidamente al punto donde se encuentra el whistle de interés.

En el proceso de extracción de la señal de interés, se empleó una técnica empírica, que consta de multiplicar la matriz del espectrograma por una matriz de ceros y unos, generada a partir de las posiciones donde el vector resultante posee valores con respecto a los mismos. De esta manera, se genera una matriz que contiene los valores del espectrograma en los puntos determinados por el vector resultante. Este proceso, habilita la realización de una transformación inversa (ISTFT) para obtener la señal de interés en función del tiempo.

Debido a que el vector resultante genera un solo valor para cada posición, la matriz resultante representa una línea muy delgada en la imagen binaria generada, la cual no alcanza a representar todo el espesor del whistle dentro del espectrograma. Para dar solución a este problema, se planteó el uso de una etapa de dilatación previa a la multiplicación entre matrices. De esta manera, la matriz que resulta del filtro de partículas, contiene una imagen binaria dilatada que es función del vector resultante. Con esto, se logra una mejor extracción de la señal al realizar la multiplicación punto a punto entre dicha matriz y la del espectrograma, como se explicó anteriormente.

El proceso de dilatación tiene la función de expandir o agrandar cada sección que contenga unos dentro de la imagen o matriz resultante. El objetivo principal de esta acción, es abarcar más espacio justo en los puntos donde se detectó señal. Con esto, se logra una recuperación más óptima de la señal de interés. En la figura 8, se muestra la diferencia entre la matriz generada inicialmente a partir del vector resultante y su análoga dilatada.




Figura 8. Matriz generada a partir del vector resultante. (a) Original. (b) Dilatada.

Finalmente, se realizó un ajuste en el tamaño de la matriz generada mostrada en la figura 8 con respecto a la del espectrograma, figura 7, igualándolas de tal forma que

la multiplicación punto a punto se pudiese realizar. A continuación se realizó la Transformada inversa de Fourier de tiempo corto y así se generó la señal resultante, la cual se observa en la figura 9, en un contraste con la señal original.

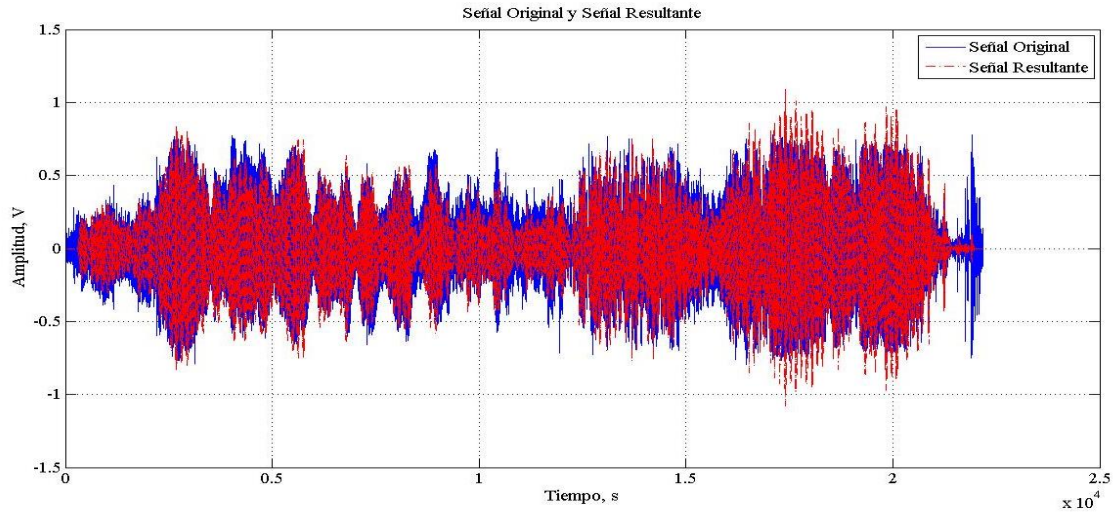


Figura 9. Señal original y señal resultante en función del tiempo.

En la figura 9, se observa que las variaciones de amplitud coinciden en ambas señales.

3.3. Implementación del detector de bordes basado en umbralización

En esta sección, se pretende explicar paso a paso, el procedimiento realizado para el cumplimiento del objetivo específico II. El cual es, implementar un método de procesamiento de imágenes basado en detección de bordes y umbralización, para disminuir el ruido presente en las señales disponibles.

Para la implementación del detector de bordes, se tomó como punto de partida, la imagen que genera el espectrograma a partir de la señal de interés. Esto facilita la detección, debido a que los silbidos (whistles) de los delfines, son representados en el espectrograma por segmentos de mayor intensidad en el color, debido a su alto

contenido de energía. Dichos silbidos, pueden ser interpretados como bordes o contornos en la imagen.

Para dar solución al problema planteado, se utilizó un kernel Gaussiano de 3X3 definido en (15) y planteado en [10]. Se realizó la convolución entre la matriz de la imagen del espectrograma y dicho kernel. Con esto, se genera un suavizado en la imagen, que permite al algoritmo evadir bordes no pertenecientes al contorno a detectar. Esta convolución, se realiza mediante el uso del comando *imfilter* del toolbox de procesamiento de imágenes de Matlab, el cual recibe dos parámetros. El primero de ellos, es el valor absoluto de la matriz del espectrograma generado, y el segundo es el kernel utilizado. Este comando, realiza la convolución descrita y entrega la matriz de la imagen suavizada.

La detección de los contornos generados por los whistles en los espectrogramas, es realizada utilizando un detector de umbral simple. Dicho detector, también es conocido como método de umbralización. Se consigue comparando cada punto del espectrograma con un umbral definido [10]. Cada punto y el umbral se basan en la STFT de la señal, debido a que ésta, contiene información de su energía en cada punto del espectrograma. Se espera que la energía del whistle sea más alta que la del ruido, con lo que el detector reacciona sobre él.

En este sentido, se realizó el proceso de umbralización, el cual genera una matriz binaria que contiene ceros en los puntos que están por debajo del umbral definido, y unos en los puntos por encima de él. Dicho umbral es seleccionado con la técnica de Otsu descrita en la sección 2.3.1, la cual es implementada por el comando *graythresh* de Matlab. A continuación, el umbral obtenido, es usado como parámetro para aplicar la binarización, la cual se realizó con el comando *im2bw*, quien recibe como parámetros la imagen del espectrograma suavizado y el umbral hallado. Este procedimiento entrega la imagen del espectrograma binarizada. En el caso del presente trabajo, la umbralización se realiza seccionando la imagen

(espectrograma) en ventanas de 100 puntos en el eje del tiempo, para no limitar el proceso a un solo umbral global, como se planteó en la sección 2.3.

En la mayoría de los casos, la etapa de binarización entrega el contorno del armónico fundamental del whistle detectado por completo. Esto es debido a que generalmente dichos armónicos, son representados en el espectrograma, como secciones mucho más oscuras que las generadas por el ruido, lo que facilita su detección.

El paso siguiente, se efectúa para reducir trozos de ruido detectados erróneamente. Estas detecciones erróneas, suceden cuando el ruido supera o iguala los niveles de energía característicos de la señal de interés. Para suprimirlas, primero se realiza un proceso de segmentación y etiquetado, para posteriormente realizar mediciones sobre segmentos aislados en la imagen. Particularmente, los whistles tienen en su mayoría, un comportamiento continuo y horizontal. Esto permitió el uso de la característica “longitud del eje mayor” para suprimir contornos de tamaños despreciables, los cuales en su mayoría pertenecen a secciones de ruido detectadas por error.

Otra característica que ayudó en la eliminación de ruido no deseado, fue la orientación del eje mayor en cada segmento. Esto fue debido a la particularidad de los segmentos del ruido que en su mayoría son verticales. Para determinar si se desprecian segmentos de acuerdo a las características descritas, se fijaron umbrales de manera experimental, realizando pruebas con diferentes valores y observando los resultados.

Para la recuperación de la señal de interés, se realizó la multiplicación punto a punto entre la matriz de la imagen resultante del procesamiento y la matriz del espectrograma original. A continuación, se realizó la ISTFT (Transformada inversa de Fourier de tiempo corto) al espectrograma final, con lo que se obtuvo la señal filtrada en el dominio del tiempo, figura 10.

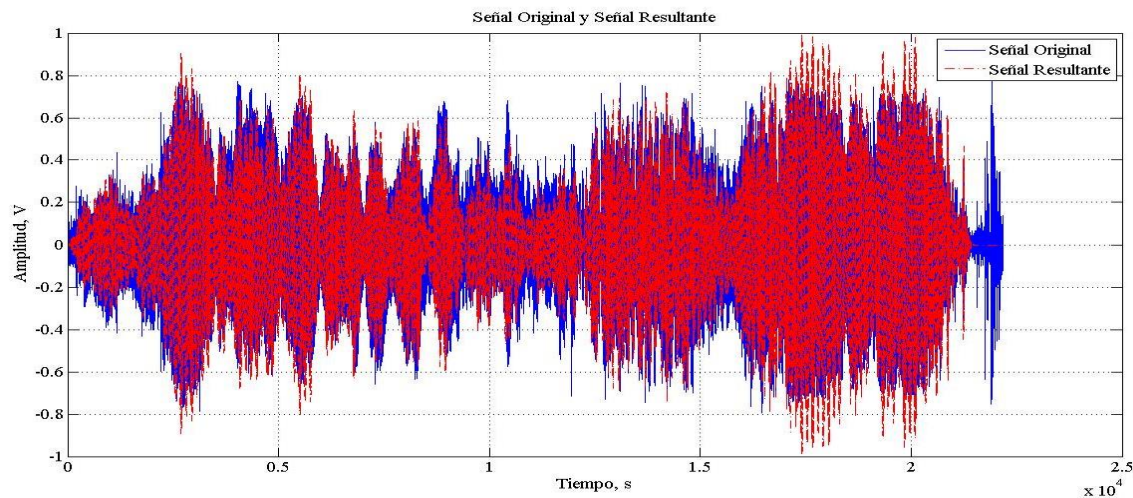


Figura 10. Señal original y señal resultante en función del tiempo.

3.4. Cálculo de Relación Señal a Ruido (SNR)

Para el cálculo de la SNR, se utilizó una señal real, la cual fue filtrada manualmente hasta obtener el armónico fundamental totalmente limpio. A continuación, se utilizó el ruido extraído en el paso anterior, para realizar un muestreo sobre él, utilizando el comando *fitdist* del toolbox de procesamiento de señales de Matlab. Dicho comando recibe como entrada dos parámetros, el primero es la matriz del ruido mencionado y el siguiente es la distribución de probabilidad del muestreo que se desea realizar. En el caso de este proyecto, la distribución de probabilidad del ruido es desconocida, por lo que se fija este parámetro como “kernel”, el cual genera un muestreo con distribución no paramétrica que utiliza un kernel de suavizado. De esta manera, se obtiene una distribución del ruido suavizada, la cual no interfiere en la detección de ambos métodos.

En este sentido, se realiza un proceso de adición del ruido muestreado a la señal filtrada manualmente. De esta manera, se obtiene la señal con ruido, que posteriormente fue introducida a los dos filtros desarrollados. Para el cálculo de la SNR se utilizó el comando *snr* del toolbox de procesamiento de señales de Matlab.

El cual recibe como parámetros la señal de interés (s) y el ruido (n) en función del tiempo. Para el cálculo de SNR inicial, s , fue la señal filtrada manualmente y n , el ruido que fue adicionado a ella. Para la SNR resultante, los parámetros de entrada son s , la señal resultante del filtro en estudio y n , la resta entre dicha señal resultante y la señal filtrada manualmente. Dicha resta da como resultado el ruido neto que el método no suprime de la señal.

A continuación, se muestran los espectrogramas de la señal empleada para el cálculo de SNR, generados a partir del proceso descrito en esta sección. Para lograr diferentes niveles de ruido en la señal seleccionada, se multiplica la matriz del ruido obtenida, por un factor que en el caso de este proyecto osciló entre 0.2 y 3 en pasos de 0.2. Con lo cual se obtuvieron los resultados de SNR antes y después de los métodos implementados. Se incrementó el factor multiplicativo del ruido muestreado hasta 3, para observar el comportamiento de los métodos en casos en los que el ruido posee una energía demasiado alta. Para efectos de reducir la cantidad de imágenes resultantes en esta sección, se muestran las imágenes en el rango de 0.4 a 2.8 en pasos de 0.4 del factor que multiplica el ruido.

La primera imagen que se muestra en este capítulo, es la del espectrograma de la señal filtrada manualmente, figura 11. La cual se utilizó como base para todo el proceso de medición del parámetro SNR.

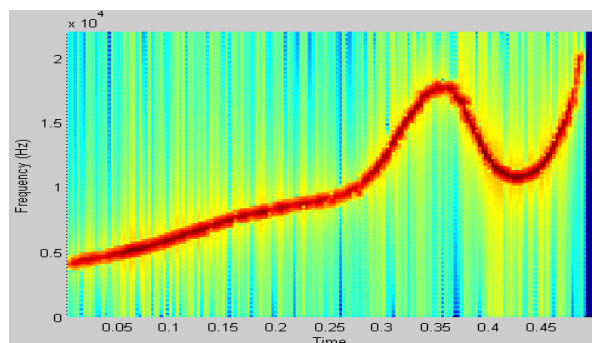




Figura 11. Señal seleccionada para el proceso de medición del parámetro SNR.

12 (a)



12 (b)



12 (c)






Figura 12. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 0.4. (b) Espectrograma de señal seleccionada filtrada con detector de bordes. (c) Espectrograma de señal seleccionada filtrada con filtro de partículas.

13 (a)



13 (b)



13 (c)






Figura 13. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 0.8. **(b)** Espectrograma de señal seleccionada filtrada con detector de bordes. **(c)** Espectrograma de señal seleccionada filtrada con filtro de partículas.

14 (a)



14 (b)



14 (c)





Figura 14. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 1.2. **(b)** Espectrograma de señal seleccionada filtrada con detector de bordes. **(c)** Espectrograma de señal seleccionada filtrada con filtro de partículas.

15 (a)





15 (b)**15 (c)**

Figura 15. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 1.6. **(b)** Espectrograma de señal seleccionada filtrada con detector de bordes. **(c)** Espectrograma de señal seleccionada filtrada con filtro de partículas.






16 (a)**16 (b)****16 (c)**

Figura 16. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 2. **(b)** Espectrograma de señal seleccionada filtrada con detector de bordes. **(c)** Espectrograma de señal seleccionada filtrada con filtro de partículas.

17 (a)



17 (b)



17 (c)






Figura 17. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 2.4. (b) Espectrograma de señal seleccionada filtrada con detector de bordes. (c) Espectrograma de señal seleccionada filtrada con filtro de partículas.

18 (a)



18 (b)



18 (c)




Figura 18. (a) Espectrograma de señal seleccionada con ruido muestreado multiplicado por un factor de 2.8. **(b)** Espectrograma de señal seleccionada filtrada con detector de bordes. **(c)** Espectrograma de señal seleccionada filtrada con filtro de partículas.

En la secuencia de imágenes mostrada en este capítulo, figura 12 hasta figura 18, se observa claramente que cuando la SNR de la señal a filtrar se hace muy baja, el filtro de partículas tiene un comportamiento más uniforme que el del detector de bordes. Del detector de bordes se puede observar, que cuando no hay presencia de whistles en determinadas secciones del espectrograma, como en el tramo final desde el tiempo 0.48 aproximadamente, el método detecta al ruido con mayor energía como parte de su objetivo y a medida que la SNR inicial disminuye, este problema se hace más notable. Este problema también está presente en los resultados con filtro de partículas, pero de una manera más sutil como se observa a partir de la figura 17. Otro detalle allí, es la inicialización del filtro de partículas, el cual toma unos instantes para identificar el primer tramo de la señal lo que genera una pérdida en la SNR resultante por este método.


3.5. Pruebas y validación

En esta sección, se pretenden contrastar los resultados obtenidos usando los métodos de filtrado de partículas y detección de bordes basado en umbralización sobre señales reales con ruido real.


Para obtener resultados confiables, es necesario realizar múltiples pruebas usando los dos métodos implementados. Esto, debido a que los resultados en ambos casos dependen de las características de la señal de interés. Es por esto, que se determinó efectuar cinco pruebas con cinco señales seleccionadas usando los criterios descritos en la sección 3.1.2.

3.5.1. Pruebas con filtro de partículas y detector de bordes en señales con ruido real.

19 (a)



19 (b)



19 (c)






Figura 19. (c) Espectrograma de señal 1 original. **(b)** Espectrograma de señal 1 filtrada con detector de bordes. **(c)** Espectrograma de señal 1 filtrada con filtro de partículas.

En la figura 19, se observa como el detector de bordes (a) reacciona parcialmente frente los armónicos secundarios y completamente sobre el armónico fundamental. El filtro de partículas (c), reacciona exclusivamente frente el armónico fundamental, que generalmente es el armónico de mayor energía. Adicionalmente, se observa en el resultado del filtro de partículas (c), su inicialización en el instante de 0 a 0.02 aproximadamente, en donde la estimación del filtro empieza en cero y asciende hasta alcanzar el objetivo.

20 (a)



20 (b)



20 (c)






Figura 20. (c) Espectrograma de señal 2 original. **(b)** Espectrograma de señal 2 filtrada con detector de bordes. **(c)** Espectrograma de señal 2 filtrada con filtro de partículas.

En el caso de la figura 20, se observa como el filtro de partículas (c), sigue de manera precisa el armónico fundamental de la señal, con solo dos pequeñas desviaciones que ocurren debido al alto contenido de energía del ruido en los instantes entre 0.11 y 0.85 aproximadamente. El detector de bordes (b) presenta el seguimiento de un fragmento de uno de los armónicos secundarios y del armónico fundamental. En ambos casos se observa que en el tiempo 0.5, ocurre un cambio abrupto de frecuencia, el cual es detectado a la perfección.

21 (a)



21 (b)



21 (c)






Figura 21. (a) Espectrograma de señal 3 original. **(b)** Espectrograma de señal 3 filtrada con detector de bordes. **(c)** Espectrograma de señal 3 filtrada con filtro de partículas.

En la figura 21, se observa un comportamiento muy similar entre el filtro de partículas (c) y el detector de bordes (b). La diferencia radica en el rango de tiempo comprendido entre 0.65 y 0.7 aproximadamente, donde el detector de bordes sigue al armónico fundamental y parte de un armónico secundario y el filtro de partículas se desvía detectando parte del armónico secundario y ruido que se traslapan con el armónico fundamental. El otro punto de análisis, está comprendido entre los tiempos 0.95 y 1, donde el detector de bordes detecta el armónico fundamental y el filtro de partículas se pierde debido al alto contenido de energía que posee el ruido y baja energía de la señal en esos instantes.

22 (a)



22 (b)



22 (c)






Figura 22. (a) Espectrograma de señal 4 original. **(b)** Espectrograma de señal 4 filtrada con detector de bordes. **(c)** Espectrograma de señal 4 filtrada con filtro de partículas.

En la figura 22, se observa que en el rango de tiempo comprendido entre 1.5 y 1.8, ambos algoritmos se desvían del objetivo en unos pequeños lapsos, esto se debe a que la energía del armónico fundamental se ve disminuida y el ruido u armónicos secundarios son detectados como el objetivo. Otra observación, es en el instante 0.6 aproximadamente, donde hay una terminación del armónico fundamental y posterior continuación con una frecuencia mucho mas baja. Allí, el filtro de partículas toma al ruido y parte de un armónico secundario como objetivo, hasta que encuentra nuevamente el armónico de mayor energía. En este caso, el detector de bordes, realiza la detección de manera abrupta, resultando mejor en cuanto a la eliminación del ruido en ese instante.

23 (a)



23 (b)



23 (c)




Figura 23. (a) Espectrograma de señal 5 original. **(b)** Espectrograma de señal 5 filtrada con detector de bordes. **(c)** Espectrograma de señal 5 filtrada con filtro de partículas.

En el caso de la figura 23, la observación más notoria, es la detección del detector de bordes (b) del armónico secundario debido a su alto contenido de energía. También se observa en (b) la detección de un segmento de ruido en el instante de tiempo 1.4, debido también a su alto contenido de energía. En el filtro de partículas (c) ocurre una buena detección del armónico fundamental, hay algunas desviaciones como en los instantes 0.2 al 0.3 y cerca al 1.2, debido al problema que genera un alto contenido de energía por parte del ruido.

4. RESULTADOS Y DISCUSIÓN

4.1. SNR obtenida con filtro de partículas y con detector de bordes basado en umbralización

En la tabla 1, se muestran los resultados de SNR obtenidos usando el filtro de partículas y el detector de bordes basado en umbralización, sobre la señal seleccionada con el ruido añadido, como se explicó en la sección 3.4. El factor por el cual se multiplicó dicho ruido, osciló entre 0.2 y 3 en pasos de 0.2 para observar más detalladamente el comportamiento de los dos métodos. La medición se realizó en decibelios, debido a que proporciona una medida dimensional que resulta útil al momento de comparar los resultados. El gráfico 1, es el que relaciona la SNR después de que la señal es procesada por el filtro de partículas y por el detector de bordes.

RELACION DE RUIDO	SNR ANTES (dB)	SNR DESPUES DB (dB)	SNR DESPUES FP (dB)
0,2*RUIDO	19,0406	44,2323	41,3669
0,4*RUIDO	13,5048	30,8117	34,4543
0,6*RUIDO	10,1155	24,8248	29,5704
0,8*RUIDO	7,5699	26,8765	27,7735
RUIDO	5,652	25,8567	24,6006
1,2*RUIDO	3,9858	21,3223	22,4661
1,4*RUIDO	2,7026	21,0997	21,3248
1,6*RUIDO	1,6477	18,1739	20,4446
1,8*RUIDO	0,4414	16,4784	18,7508
2*RUIDO	-0,4026	15,4949	16,4246
2,2*RUIDO	-1,2413	13,035	17,4284
2,4*RUIDO	-2,0987	11,3875	13,936
2,6*RUIDO	-2,5879	10,1557	14,6476
2,8*RUIDO	-3,1248	7,8174	12,8011
3*RUIDO	-3,1853	7,425	11,6959

Tabla 1. SNR obtenida con filtro de partículas y con detector de bordes basado en umbralización.

En la tabla 1, SNR antes, es la relación señal a ruido de la señal con el ruido añadido, antes de ser procesada por los filtros. SNR después DB, es la relación señal a ruido de la señal después de ser procesada por el detector de bordes. Finalmente, SNR después FP, es la relación señal a ruido de la señal después de ser procesada por el filtro de partículas.




Gráfico 1. Comportamiento de la SNR obtenida usando Filtro de partículas y Detector de Bordes.

Analizando un poco el grafico 1 y la tabla 1, se observa que en la medición número 1, resulta un mejor resultado para el detector de bordes. Esto ocurre debido a que cuando la SNR de la señal inicial es muy alta, el detector de bordes y el filtro de partículas funcionan de manera óptima; pero el filtro de partículas sufre el problema de la inicialización de las partículas, lo que genera una pérdida constante en las SNR obtenidas usando este método.

Para continuar con el análisis, la caída del detector de bordes en las mediciones 2 y 3 refleja la sensibilidad del método para detectar secciones de ruido cuando no hay presencia de armónicos en alguna sección del espectrograma, figura 13 y 14.

Entre las mediciones 4 y 6, figuras 15 y 16, ambos métodos muestran un comportamiento similar, esto es debido a que la sensibilidad ante el ruido del detector de bordes es compensada por el problema de inicialización del filtro de partículas. A partir de la medición 7, el detector de bordes empieza a tener un comportamiento por debajo del filtro de partículas. Esto ocurre, debido a que cuando la SNR de la señal inicial disminuye, el detector de bordes se vuelve propenso a reaccionar frente a bordes o contornos que no pertenecen al objetivo. A diferencia del filtro de partículas, el cual muestra resultados más estables.

Otra observación en la tabla 1, es que los últimos 6 datos de SNR antes del procesamiento, toman valores negativos. Esto se debe a que los valores de energía de la señal y del ruido son muy similares, entonces generan una SNR muy baja en amplitud, más específicamente en un rango entre 0 y 1 de amplitud, lo que se traduce en decibelios negativos.

4.2. Tiempo de ejecución de los algoritmos

El tiempo de ejecución de los algoritmos, es una variable importante a considerar. Es por ello, que se presenta a continuación una tabla que muestra los tiempos tomados por cada uno de los algoritmos para realizar el procesamiento. Estos tiempos varían en función de la longitud de la señal muestreada como se observa en la tabla 2.

SEÑAL	Longitud de la señal muestreada	Tiempo de ejecución FP (s)	Tiempo de ejecución DB (s)
1	22181	670,64	0,48
2	40943	1265,97	0,84
3	51833	1763,37	0,93
4	87880	2824,99	2,67
5	62505	2533,28	1,35

Tabla 2. Tiempo de ejecución de los algoritmos.

4.3. Comparación de resultados con base en las SNR obtenidas y el tiempo de ejecución de los algoritmos

- El detector de bordes tiene un comportamiento esperado con base en los resultados de SNR obtenidos. Dicha SNR medida al finalizar el procesamiento, disminuye a medida que el ruido aumenta. Se puede observar en la tabla 1, que para señales con SNR alta y media el detector genera resultados confiables. La desventaja de este método es notable, cuando la SNR de la señal a procesar, es baja. En este caso, el detector reacciona ante bordes o contornos indeseados, debido a que el ruido en ocasiones iguala o sobrepasa los niveles de energía de la señal, lo que genera secciones más coloreadas en el espectrograma.
- A diferencia del detector de bordes, el filtro de partículas genera resultados más estables a medida que la SNR de la señal inicial disminuye. Esto ocurre, debido a que la estimación del armónico fundamental se realiza de manera probabilística, lo que evita que el detector se pierda ante pequeños trozos de ruido con alta energía en la señal. Con esto, se puede concluir, que el filtro de partículas es un método más robusto para la estimación del armónico fundamental de las señales emitidas por delfines *Tursiops truncatus*.
- Una ventaja del detector de bordes, es que en la mayoría de ocasiones, éste genera también la detección de armónicos no fundamentales de la señal de interés. Lo que ayuda en gran medida, a no perder características propias de las vocalizaciones de cada individuo.
- El detector de bordes posee un costo computacional mucho más bajo que el filtro de partículas, según lo observado en la tabla 2. Esto lo hace ideal para el procesamiento de bancos de señales demasiado grandes. Este método puede ser utilizado eficientemente, realizando una selección visual o auditiva que genere señales con una SNR alta, con lo cual se optimiza su ejecución.
- El filtro de partículas posee un costo computacional mucho más alto según la tabla 2. Es por esto, que a pesar de su precisión a la hora de realizar la

detección, es poco útil al momento de procesar bancos de señales demasiado grandes.

APÉNDICE

A) La bioacústica marina

La bioacústica marina, puede ser definida como el uso de la acústica, para el estudio de factores de interés en animales marinos. En la actualidad, la bioacústica es una de las formas más comunes empleadas para el estudio de especies en el medio marino a través de sus emisiones acústicas. Los animales subacuáticos emplean el sonido como medio de comunicación, ubicación y diferentes interacciones sociales o con el propio medio. Esto se debe a que la energía acústica se propaga en el agua más eficientemente que otras formas de energía, tales como, la energía electromagnética, térmica y la luz [6].

En el área de bioacústica, el tema central de interés está asociado a la recepción y emisión del sonido en animales. Cuando se habla del medio marino, se deben tener en cuenta factores como la densidad del medio, la cual es mayor en este ambiente. Debido a esto, los animales marinos han desarrollado sistemas auditivos de características muy diferentes a las de los animales terrestres. En consecuencia a que su medio de comunicación e interacción con el entorno se basa en la transmisión y recepción de sonido y no en la visión, como la mayoría de animales terrestres, estos animales poseen sistemas auditivos de mayor complejidad [6].

B) El espectrograma

Un espectrograma es un gráfico de frecuencia versus tiempo que contiene información de la energía de una señal. Éste usa diversos colores que representan

la cantidad de energía que la señal tiene a determinada frecuencia y en un tiempo particular, usando para ello la Transformada de Fourier de tiempo corto (STFT). Es generalmente utilizado en proyectos de procesamiento de señales de voz y en general de señales de audio, pueden presentarse en escala de grises o de colores. En el área de bioacústica, es común emplear espectrogramas para el análisis de señales. Esto es debido a que es una representación visual del sonido que contiene información fundamental en la STFT y es graficada en función de dos parámetros fundamentales para este tipo de aplicaciones, el tiempo y la frecuencia.

Para la implementación del espectrograma de una señal, hay que tener en cuenta algunos parámetros fundamentales. El primero es la longitud de la ventana en la cual se realiza la STFT, esta ventana puede ser rectangular o una ventana de Hamming dependiendo de la aplicación. El siguiente parámetro a tener en cuenta, es el traslape entre ventanas para el cálculo de la STFT, en este caso se pueden utilizar valores que no igualen o sobrepasen la longitud de dicha ventana. El último parámetro a fijar, es la longitud de la FFT (Transformada rápida de Fourier), para la cual, Matlab recomienda fijar en un valor igual a la longitud de la ventana seleccionada. Finalmente, se tiene en cuenta la frecuencia de muestreo de la señal, la cual es automáticamente generada al muestrear la señal con Matlab.

BIBLIOGRAFÍA

[1] Thomas A. Lampert and O'KEEFE Simon E.M. A survey of spectrogram track detection algorithms. University of York, Heslington, York YO10 5DD, UK. Páginas 6-32, 2009.

[2] Yu Shi and Eric Chang. Spectrogram-based formant tracking via particle filters. Microsoft Research Asia. Páginas 1-4, 2003.

[3] P. R. White and M. L. Hadley. Introduction to particle filters for tracking applications in the passive acoustic monitoring of cetaceans. Signal Processing and Control Group, Institute of Sound and Vibration Research (ISVR), Highfield, Southampton SO17 1BJ, UK. Páginas 1-4, 2008.

[4] Jones, J.C. Dolphin vocalisation analysis using an ADSP 21020. Acoust. & Sonar Group, Birmingham Univ. Páginas 1-10, 1997.

[5] Seramani, S., Taylor, E.A., Seekings, P.J. and Yeo, K.P. Wavelet De-noising with Independent Component Analysis for Segmentation of Dolphin Whistles in a Noisy Underwater Environment. Nat. Univ. of Singapore, Singapore. Páginas 1-7, 2007.

[6] Whitlow W.L. Au and Mardi .C. Hastings. Principles of marine bioacoustics. New York. Hawaii Institute of Marine Biology, Kaneohe, HI, USA and Pennsylvania State University, State College, PA, USA. Páginas 3-5, 2008.

[7] Álvaro Rodríguez Moya. Estudio del Filtro de Partículas aplicado al seguimiento de objetos en secuencias de imágenes. Trabajo de grado (ing. telecomunicación especialidad sonido e imagen). Universidad Carlos III de Madrid. Madrid, 2009

[8] Bor-Shing Lin, Bor-Shyh Lin, Huey-Dong Wu, Fok-Ching Chong and Sao-Jie Chen; Wheeze recognition based on 2D bilateral filtering of spectrogram. Department and Graduate Institute of Electrical Engineering, National Taiwan University, Taipei, Taiwan. Páginas 31-35, 2006.

[9] Minami, K., Akutsu, A., Hamada, H. and Tonomura, Y. Video handling with music and speech detection. MultiMedia, IEEE (Volume:5 , Issue: 3). Páginas 17-25, 1998.

[10] Douglas Gillespie. Detection and classification of right whale calls using an 'edge' detector operating on a smoothed spectrogram. Song of the Whale Research Team, International Fund for Animal Welfare 87-90 Albert Embankment London, SE1 7UD UK. Páginas 39-46, 2004.

[11] Juliana Curcio Valencia. Bioacústica: Métodos de tratamiento de señales aplicados a la vocalización de delfines. Trabajo de grado (Maestría en instrumentación física). Universidad Tecnológica de Pereira. Facultad de ciencias básicas. Pereira, 2014.

[12] Sharad Nagappa, James R. Hopgood. Frequency tracking of biological waveforms. Institute for digital communications, University of Edinburg, Edinburg, 2006.

[13] M. Sanjeev Arulampalam, Simon Maskell, Neil Gordon, and Tim Clapp. A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking. IEEE transactions on signal processing, vol. 50, no. 2. Páginas 174-181, 2002.

[14] Msc. Jimmy Alexander Cortés. Diapositivas de clase: umbralización, etiquetado y características. Universidad Tecnológica de Pereira. Procesamiento digital de imagines. Semestre I, 2014.

[15] Corentin Dubois, Manuel Davy and J'erome Idier. Tracking of Time Frequency components using Particle Filter. Cita científica, 59651 Villeneuve d'Ascq Cedex. Páginas 9 – 11, Francia.

[16] G. Larry Bettrost. Bayesian Spectrum Analysis and Parameter Estimation. Department of Chemistry, Campus Box 1134, Washington University. St. Louis, Missouri, 1988.

[17] Kevin P. Murphy. Machine Learning, a probabilistic perspective. The MIT press, Cambridge, Massachusetts, London, England. Páginas 823-82, 2012.

[18] Deanna K. Dawson and Murray G. Effor. Bird population density estimated from acoustic signals. Journal of Applied Ecology. Volumen 46, Issue 6, Páginas 1201-1209, 2009.