

SEGUIMIENTO DE ARTEFACTOS NAVALES

ING. MILTON OSWALDO GONZALEZ FUQUENE

**TRABAJO DE INVESTIGACIÓN PARA OPTAR POR EL TÍTULO DE MAGISTER
EN INGENIERIA ELECTRÓNICA**

DIRECTOR

ING CARLOS ALBERTO PARRA RODRÍGUEZ, Ph.D.

**PONTIFICIA UNIVERSIDAD JAVERIANA
FACULTAD DE INGENIERÍA ELECTRÓNICA
DEPARTAMENTO DE ELECTRÓNICA
BOGOTA DC, 2013**

**PONTIFICIA UNIVERSIDAD JAVERIANA
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA ELECTRÓNICA**

RECTOR MAGNÍFICO:

PADRE JOAQUÍN EMÍLIO SANCHEZ GARCIA S.J.

DECÁNO ACADÉMICO:

ING. JORGE LUÍS SÁNCHEZ TELLEZ

DECANO DEL MEDIO UNIVERSITARIO:

PADRE ANTONIO JOSÉ SARMIENTO NOVOA SJ

DIRECTOR DE LA MAESTRÍA DE INGENIERÍA ELECTRÓNICA

ING. CESAR LEONARDO NIÑO BARRERA Ph.D.

DIRECTOR DEL PROYECTO:

ING. CARLOS ALBERTO PARRA RODRIGUEZ, Ph.D.

ARTICULO 23 DE LA RESOLUCIÓN No. 13 DE JUNIO DE 1946

—La Universidad no se hace responsable de los conceptos emitidos por sus alumnos en sus proyectos de grado.

Solo velará porque no se publique nada contrario al dogma y a la moral católica y por que los trabajos no contengan ataques o polémicas puramente personales. Antes bien, que se vea en ellos el anhelo de buscar la verdad y la justicia.

TABLA DE CONTENIDO

SEGUIMIENTO DE ARTEFACTOS NAVALES	I
1. INTRODUCCIÓN	1
2. MARCO TEÓRICO	4
2.1. Momentos estadísticos	4
2.2. Análisis de histograma	5
2.3. Transformada de Fourier	6
2.4. Detección de bordes	8
2.5. Código de cadena	8
2.6. Máquina de soporte vectorial	9
3. ESPECÍFICACIONES	10
4. DESARROLLOS	12
4.1. Descripción general y diagrama de bloques	12
4.2. Momentos de Hu	12
4.3. Histograma	14
5. DESARROLLO TEÓRICO	17
5.1. Planteamiento	17

5.2.	Vector de características.....	18
5.2.1.	Histograma HSV y momentos de Hu (Histograma & Hu).....	18
5.2.2.	Cadena de píxeles	19
5.2.3.	Filtros de imagen con la Transformada de Fourier y bordes (Fourier & Canny).....	19
5.3.	Clasificación	21
5.3.1.	Clasificación	21
6.1.	Histograma &Hu.....	23
6.2.	Cadena de píxeles	24
6.3.	Fourier & Canny.....	26
6.4.	Tiempo de extracción de características.....	28
6.4.1.	Histograma & Hu.....	29
6.4.2.	Cadena de píxeles	29
6.4.3.	Transformada de Fourier y bordes de Canny	30
7.	SEGUIMIENTO	32
7.1.	Selección del ROI	32
7.2.	Métrica de decisión para la selección de la ventana de seguimiento.....	32
7.3.	Determinación de similitud de características	33
7.4.	Método de búsqueda de ventanas.....	35

7.4.1. Ventanas cercanas	35
7.4.2. Ventanas aleatorias	36
8. ANÁLISIS Y RESULTADOS	38
8.1. Características de los videos	39
8.1.1. Video complejo.....	39
8.1.2. Video simple	39
8.2. Tamaño del ROI.....	40
8.3. Tiempo de procesamiento.....	40
8.4. Resultados	40
8.4.1. ROI grande método aleatorio sobre video complejo	40
8.4.2. ROI grande método aleatorio sobre video simple	42
8.4.3. ROI grande método secuencial sobre video complejo	44
8.4.4. ROI grande método secuencial sobre video simple	45
8.4.5. ROI pequeño método aleatorio sobre video complejo	46
8.4.6. ROI pequeño método aleatorio sobre video simple.	47
8.4.7. ROI pequeño método secuencial sobre video complejo.	49
8.4.8. ROI pequeño método secuencial sobre video simple.	50
9. CONCLUSIONES Y TRABAJOS FUTUROS	53
9.1. Conclusiones.....	53

9.2. Trabajos futuros	56
10. BIBLIOGRAFÍA	57

LISTADO DE FIGURAS

Ilustración 1 Transformada de Fourier a diferentes frecuencias	6
Ilustración 2 Transformada de Fourier a diferentes frecuencias	6
Ilustración 3 Filtros pasabajo de la transformada de Fourier y su imagen inversa...	7
Ilustración 4 Filtro pasabajo ampliado de la transformada de Fourier y su imagen inversa	7
Ilustración 5 Bordos del artefacto naval	8
Ilustración 6 Borde ideal y conectividad 8.....	9
Ilustración 7 Lanchas	13
Ilustración 8 Filtros usados con la transformada de Fourier	20
Ilustración 9 Imágenes no clasificadas clase lancha, con Histograma & Hu.....	23
Ilustración 10 Imágenes no clasificadas clase mar	24
Ilustración 11 Imagen no clasificada clase lancha, cadena de píxeles.	25
Ilustración 12 Muestra imagen no clasificada clase mar, cadena de píxeles.	26
Ilustración 13 Imágenes no clasificadas clase lancha, transformada de Fourier y bordes Canny	27
Ilustración 14 Imágenes no clasificadas clase mar, transformada de Fourier y bordes Canny	27
Ilustración 15 Divisiones del análisis de seguimiento	38

LISTADO DE TABLAS

Tabla 1 Semántica de bins del histograma	5
Tabla 2 Clasificación de metales según Ariza.....	15
Tabla 3 Resultado clasificación según Kurdthongmee	16
Tabla 4 Clasificación con Histograma & Hu	23
Tabla 5 Clasificación con cadena de píxeles	25
Tabla 6 Clasificación con Fourier & Canny	26
Tabla 7 Tiempo de extracción de características.....	28
Tabla 8 Seguimiento aleatorio ROI grande video complejo	40
Tabla 9 Seguimiento aleatorio ROI grande video simple	42
Tabla 10 Seguimiento secuencial ROI grande video complejo	44
Tabla 11 Seguimiento secuencial ROI grande video simple.....	45
Tabla 12 Seguimiento aleatorio ROI pequeño video complejo	46
Tabla 13 Seguimiento aleatorio ROI pequeño video simple	47
Tabla 14 ROI pequeño método secuencial sobre video complejo	49
Tabla 15 ROI pequeño método secuencial sobre video simple.	50
Tabla 16 Tiempo promedio de determinación de ventana de seguimiento.....	53
Tabla 17 Pérdida de seguimiento.	54

LISTADO DE ECUACIONES

Ecuación 1 Momentos de Hu	4
Ecuación 2 Distancia de las características de la ventana al ROI	34
Ecuación 3 Máximos de cada características	34
Ecuación 4 Vector de pesos de cada característica por ventana.....	34
Ecuación 5 Peso asociado a cada ventana	35
Ecuación 6 Búsqueda de la mejor ventana.....	35

1. INTRODUCCIÓN

Una de las funciones de la Armada Nacional es la protección de la soberanía, para ello requiere el uso de unidades a flote. La construcción de estas Unidades refleja el desarrollo tecnológico de una nación. COOTECMAR¹ realizó el diseño estructural y mecánico del primer buque oceánico OPV (OffShore Patrol Vessel) la integración de los sistemas de armas se encuentra en proceso de desarrollo por parte de DARET². Dicha dependencia desarrolló también el sistema de control de fuego “Barracuda”³, el cual cuenta con una cámara de características militares que posee visión diurna a color e infrarroja en escala de grises (ZOOM de 8X); la integración de los dos subsistemas, cámaras y control de fuego, hace que sea posible y necesario el seguimiento de un artefacto naval.

El seguimiento de artefactos navales, es de vital importancia, tanto para la seguridad física del mismo buque como para la toma de decisiones en el uso de las armas, así como la Búsqueda y Rescate (BYR) en el mar en labores de salvamento. Sin el debido seguimiento del blanco los sistemas de armas como los cañones perderían su utilidad abordo de las unidades navales.

El seguimiento de imágenes es comúnmente usado en sistemas de vigilancia con usos comerciales, militares, aplicaciones de seguridad humana en escenarios de transporte público [1], entre otras. En la literatura no se encuentra reportado el seguimiento de artefactos navales en comparación en escenarios complejos. En [2], se analiza la comparación de imágenes de parte de la nave pero no el seguimiento donde se pueda confundir con el fondo, es decir mucho más controlado. En [3], se realiza seguimiento en mar abierto y a pesqueros en el área

¹ Corporación de Ciencia y Tecnología para el desarrollo de la Industria Naval Marítima y Fluvial
<http://www.cotecmar.com>

² Departamento de Armas y Electrónica

³ Sistema de Armas desarrollado para la integración de los cañones de la OPV, liderado por DARET.

de zona de siembra de pescado, razón por la cual se abre un espacio interesante de trabajo, al realizar una comparación entre escenarios y ventanas de búsqueda.. La identificación y seguimiento de artefactos navales en el mar es de fundamental importancia para la localización, traqueo⁴ y posterior clasificación de las unidades navales que se puedan divisar en una operación.

El seguimiento de objetos en vídeo, es muy estudiado alrededor del mundo, en especial en el seguimiento de peatones y tráfico vehicular [4], haciendo uso de diferentes técnicas para el seguimiento, realizando tratamiento de imágenes desde diferentes aproximaciones.

El trabajo en imágenes está siendo estudiado para múltiples usos, es así como google, se encuentra diseñando un buscador de imágenes para clasificarlas⁵. Se trabaja en reconstrucción de imágenes [5] y [6], en navegación de vehículos autónomos [7]. en reconocimiento de rostros [8] y [9], en extracción de datos de documentos manuscritos [10] en clasificación de suelos [11]. Dentro de los métodos para el seguimiento reportados se encuentran diferentes aproximaciones, entre otras seguimiento mediante redes neurales [12], el filtro de partículas [13], [14] y [15] SIFT (escala invariante transformada de características) [16] detección de las transiciones de vídeo usando los Modelos Ocultos de Markov [17] detección de movimiento por flujo óptico.

Es así como el desarrollo de seguimiento de imágenes se encuentra en auge, el trabajo planteado presenta un análisis, para realizar una futura implementación en hardware que sea un desarrollo significativo para el desarrollo del proyecto “Integración del Sistema de Control de Fuego Barracuda y algoritmos de seguimiento de imágenes basado en FPGA⁶” donde la Armada Nacional desea

⁴ Palabra usada para el seguimiento militar de blancos navales

⁵ Tomado de <http://googleblog.blogspot.com/2010/07/ooh-ahh-google-images-presents-nicer.html>

⁶ Proyecto de desarrollo conjunto con la Pontificia Universidad Javeriana y la Armada Nacional, para el seguimiento de imágenes bajo arquitectura FPGA

realizar el seguimiento para uso militar e integrarlo en el sistema de armas que se está desarrollando para sus nuevas unidades navales, por lo cual dentro del trabajo se limita a los artefactos navales tipo lanchas.

El propósito del trabajo es realizar el seguimiento automático de una lancha mediante visión por computador, efectuando la definición de un conjunto de características que se puedan extraer y ser evaluadas por un clasificador, para posteriormente ser buscadas dentro del video, generando el seguimiento.

El análisis y el uso de clasificadores abren posibilidades para ser usados en la identificación de objetos, para el caso de la Armada Nacional, lanchas de narcotráfico, identificación de características inherentes a los buques de guerra, como son frecuencia de los radares, rotación de antena, frecuencia de repetición de pulso del radar, bandas de comunicaciones, firmas de sonido de los buques, que podrían ser usados para identificación de este tipo.

En el presente trabajo en el Capítulo 2 se establece el marco teórico para la extracción de características, en el Capítulo 3 se plasman las especificaciones para realizar los experimentos, en el Capítulo 4 los características de momentos de Hu e Histograma en espacio de color son ampliadas de acuerdo a trabajos realizados anteriormente. El Capítulo 5 se plantean los tres vectores de características así como los pasos para realizar su extracción y el método de clasificación. Las métricas para la evaluación y los resultados en la clasificación son mostrados en el Capítulo 6, como también el análisis de los tiempos de extracción.

El seguimiento es abordado en el Capítulo 7, donde se determina la similitud de las características, las ecuaciones para evaluar la mejor ventana de seguimiento, se plantean métodos de búsqueda, en el Capítulo 8 se realizan los análisis y resultados estableciendo las características a videos a probar, los tamaño del ROI, arrojando tablas de seguimiento y pérdida del objeto, para las especificaciones realizadas de evaluación, las conclusiones son presentadas en el Capítulo 9 así como los trabajos futuros.

2. MARCO TEÓRICO

En este Capítulo se presentan de manera breve los principales conceptos usados en este proyecto para la extracción de características, con el fin de formar un conjunto de características, que posteriormente se probarán para verificar su aporte en la clasificación.

2.1. Momentos estadísticos

Los momentos estadísticos son usados en imágenes con el fin de realizar la codificación de la imagen, describiendo su contenido (su distribución) con respecto a sus ejes, los cuales son obtenidos de los datos geométricos de la información de la imagen [18].

Los momentos de Hu descritos en [19] son invariables al tamaño de la imagen, rotación y reflexión excepto en el séptimo momento según lo presentado en [20].

Ecuación 1 Momentos de Hu

$$hu[0] = n_{20} + n_{02}$$

$$hu[1] = (n_{20} - n_{02})^2 + 4n_{11}^2$$

$$hu[2] = (n_{30} - 3n_{12})^2 + (3n_{21} - n_{03})^2$$

$$hu[3] = (n_{30} + n_{12})^2 + (n_{21} - n_{03})^2$$

$$hu[4] = (n_{30} - 3n_{12})(n_{30} - n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2] \\ + (3n_{21} - n_{03})(n_{21} - n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2]$$

$$hu[5] = (n_{20} - n_{02})[(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] + 4n_{11}(n_{30} + n_{12})(n_{21} + n_{03})$$

$$hu[6] = (3n_{21} - n_{03})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] \\ - (n_{30} - 3n_{12})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2]$$

Donde n_{ij} representa *Moments* :: nu_{ij}

2.2. Análisis de histograma

El análisis de histograma permite determinar características de color de acuerdo con lo planteado en [21] y según [22] el histograma es comúnmente usado para representación de composición global de las características de una imagen. Esta es invariante a translación y rotación de la imagen y la normalización del histograma conduce a la invariancia de la escala.

Si se determina un número adecuado de bin para calcular las características, se hace computacionalmente eficiente. Si se toman menos de veinte bins, se tienen grandes ventajas en la implementación según lo expresado en [22], como complemento en la determinación de características, se procesar otras características de la imagen como por ejemplo detección de bordes.

Tomando en este caso la composición del histograma como lo muestra la Tabla No 1, donde la semántica del histograma para el caso usado [22] es de catorce bins, seis de color, cinco de luminancia y tres de bordes.

Tabla 1 Semántica de bins del histograma


Índice de Histograma	Semántica del bin
H[1]	Magenta
H[2]	Blue
H[3]	Cyan
H[4]	Green
H[5]	Yellow
H[6]	Red
H[7]	Black
H[8]	Dark Gray
H[9]	Gray
H[10]	Light Gray
H[11]	White
H[12]	Vertical Edge
H[13]	Horizontal Edge
H[14]	Complex Edge

Fuente: D. K. Park, Y. S. Jeon, C. S. Won, S. Park, and S. Yoo, "A Composite Histogram for Image Retrieval," vol. 00, no. c, pp. 355–358, 2000

2.3. Transformada de Fourier

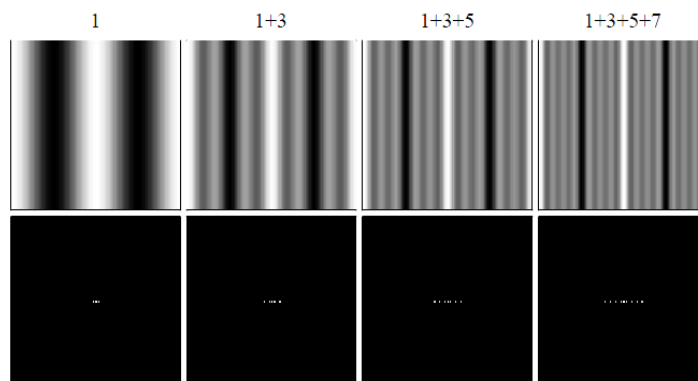
La teoría de Fourier para imágenes hace que las bajas frecuencias sean representadas en el centro de la imagen, y las altas frecuencias se ubiquen hacia la parte externa de la imagen como lo muestra la Ilustración 1 y 2. Lo cual permite determinar la distribución de frecuencia de una imagen.

Ilustración 1 Transformada de Fourier a diferentes frecuencias



Fuente: S. Lehar, “An Intuitive Explanation of Fourier Theory,” pp. 1–9, 2010


Ilustración 2 Transformada de Fourier a diferentes frecuencias



Fuente: Ibid


En lo expresado en [23] se realiza filtrado de Fourier mediante una plantilla que realiza una selección de las frecuencias deseadas como lo muestra la Ilustración 3 y Ilustración 4.

Ilustración 3 Filtros pasabajo de la transformada de Fourier y su imagen inversa



Fuente: Ibid.

Ilustración 4 Filtro pasabajo ampliado de la transformada de Fourier y su imagen inversa




Fuente: Ibid

Esto permite realizar una selección de características de frecuencias de la imagen para realizar una caracterización de estas, arrojando información que puede ser usada para la clasificación de la imagen.

2.4. Detección de bordes

La detección de bordes es complementaria a la selección de las otras características, estos son usados para mejorar la clasificación, como lo muestra [24]. Para el caso se usa la detección de bordes de Canny el cual es mejor debido a que permite detectar bordes delgados y es menos sensible al ruido[25]. Es por esto que se toma como complemento a las características, arrojando el borde como lo muestra la Ilustración 5.

Ilustración 5 Bordes del artefacto naval



Fuente: Detección de bordes imagen del repositorio de trabajo clase lancha


2.5. Código de cadena

El código de cadena permite identificar los límites en una imagen en un segmento de línea especificando un largo y dirección, es un código que típicamente describe la conectividad de la imagen en 4 u 8 vecinos de conectividad ejemplo mostrado en la Ilustración 6, en este caso la conectividad está asociada a la determinación de la línea de la proa⁷. Esta conexión de puntos puede arrojar un buen determinante para la clasificación de las imágenes como lo presentado en [26].

Esto con el fin de encontrar una conexión de píxeles dentro de las imágenes de lanchas, siendo una característica que no tiene el mar, por no poseer bordes normalmente conectados.

⁷ Parte anterior de los artefactos navales.

Ilustración 6 Borde ideal y conectividad 8.



2.6. Máquina de soporte vectorial

Las máquinas de soporte vectorial (SVM) realizan un aprendizaje para definir la superficie de decisión entre dos puntos de entrada, generando después del aprendizaje una frontera de decisión, que posteriormente es usada para determinar la clasificación de los puntos. Esta frontera es mapeada por medio de un Kernel, el cual dependiendo del número de características busca un espacio dimensional más alto para determinar la mejor selección de la frontera buscando la mayor separación entre las clases [27].

En [28] se usa para extraer los blancos a seguimiento multiblanco, lo cual demuestra las bondades del uso de este clasificador, adicionalmente en [24] es usado para la detección de bordes y el ruido asociado a la imagen.

3. ESPECÍFICACIONES

El seguimiento de artefactos navales, posee particularidades dentro de las cuales se encuentra los cambios del entorno o del medio ambiente, por lo cual se restringió el desarrollo del proyecto debido a la determinación de las características del objeto. Los artefactos navales se clasifican de manera amplia entre los que se encuentran los buques containeros, buques de pasajeros, buques de guerra, veleros, catamaranes, motos acuáticas, buques pesqueros y artefactos artesanales, para limitar el proyecto se analizan los artefactos navales tipo lanchas con el fin de limitar los artefactos navales.

Para realizar una adecuada selección de las particularidades de la imagen, se realizó un algoritmo que ejecuta la extracción de las características y mediante un método de clasificación y entrenamiento determina la efectividad de este, mediante la métrica propuesta. Posteriormente al seleccionar el desempeño, se analiza las causas de los objetos no clasificados.

Para continuar con el proceso de seguimiento, en el cual el usuario realiza la selección del artefacto naval a seguir, este será el ROI, que determina las características a buscar, y posteriormente realiza la estrategia de búsqueda de estas características en el frame siguiente. Realizando análisis de las pérdidas de seguimiento.

Para el proyecto se ha escogido el uso de las librerías de OPENCV 2.4.6. Aprovechándolas en la implementación del algoritmo, el cual se realiza sobre el sistema operativo Linux para hacerlo mas ágil en el procesamiento.

Los requerimientos del video son los siguientes:

- Solo debe encontrarse un objeto móvil.
- El objeto a seguir debe ser claramente diferenciable y no tener ocultamientos durante su recorrido.

- El fondo debe estar conformado por el escenario que se encuentra al realizar seguimiento por parte de las Unidades de la Armada Nacional, la lancha, mar y cielo. Para el análisis en video sencillo.
- Fondo con partes de la imagen que tengan características similares al objeto a seguir, para verificar el seguimiento como video complejo.

Requerimientos de la selección a seguir:

- La región de interés (ROI) a seguir debe tener un tamaño mínimo de 1000 píxeles.
- El máximo ROI debe incorporar la totalidad del objeto a seguir.

4. DESARROLLOS

4.1. Descripción general y diagrama de bloques

El proyecto está concebido con el propósito que el operario del sistema realice la selección del objeto a seguir en este caso la lancha, se realiza la extracción de las características para ser seguidas en los diferentes frame del video.

Para llegar a determinar el vector de características se realiza una selección de imágenes segmentadas del objeto deseado, conformando un repositorio de clase lanchas y otro repositorio de imágenes segmentadas del mar componiendo el repositorio mar.

Figura 1 Flujo de trabajo selección de características.



4.2. Momentos de Hu

Para la escogencia de las características se tomaron características de color en el espacio HSV y momentos de Hu. Se establece la Máquina de Soporte Vectorial (SVM), para realizar la clasificación de las imágenes y realizar la

métrica de acuerdo a los parámetros de evaluación descritos en la propuesta del proyecto. Dentro de este proceso solo se trabajan dos clases, este clasificador proporciona la ventaja de estar diseñado para dos clases, permitiendo el diseño del proyecto.

Tomando los siete momentos de Hu de acuerdo con los presentado en [29], donde se trabaja con símbolos parecidos que son rotados con cambios de escala realizando una mejora en la eficiencia para su clasificación, esto contribuye debido a los cambios presentados por la lancha en el afectando su forma y escala como se observa en la Ilustración 7.


Ilustración 7 Lanchas



Fuente: Repositorio de imágenes clase lancha

La Figura 2 tomada de [29] muestra 10 objetos con discriminación de características para realizar la clasificación. El planteamiento para solución es tomar las características de los momentos de Hu y adicionar otras para lograr la discriminación de clases.

Figura 2 Discriminación de clases



Fuente: X. Bai, F. Zhou, and B. Xue, "Discrimination ability improvement of invariant moment based on multi-scale mathematical morphology," *Opt. - Int. J. Light Electron Opt.*, vol. 124, no. 12, pp. 1314–1319, Jun. 2013

4.3. Histograma

En lo presentado en [30] se toma el espacio de color Hue Saturation Value (HSV) con el fin de realizar el seguimiento del algoritmo CAMSHIFT. En [31] se usa el espacio de color HSV como característica principal para la clasificación de tipos de metales, realizando un proceso de oxidación donde se reporta un 96 % de clasificación tomando la principal característica el canal H. Se presentan los resultados de acuerdo a la Tabla 2 para la clasificación de metales con muy buenos resultados. Estas características son usadas para la clasificación en el espacio HSV del tipo de imágenes trabajadas.


En otro trabajo [32] se toma igual el valor del canal H con el fin de realizar la clasificación de piezas de madera en Tailandia, esto arroja los resultados en la Tabla 3. Demostrando que este espacio de color es una buena característica a extraer, acuerdo a lo observado en la Figura 3

Tabla 2 Clasificación de metales según Ariza

Metal	Data	PP (%)	PN (%)	NN (%)	NP (%)	Mean Error (log(c. M))	Max. Error (Log(c. M))	S.D. of Error (Log(c. M))
Zn(II)	Training	99.07	0.93	97.62	2.38	0.06	0.68	0.10
	Test	100	0	100	0	0.08	0.29	0.08
	Validation	87.50	12.50	100	0	0.05	0.20	0.06
Cu(II)	Training	98.36	1.64	100	0	0.05	0.48	0.07
	Test	100	0	100	0	0.04	0.16	0.05
	Validation	100	0	88.89	11.11	0.04	0.15	0.05
Ni(II)	Training	97.47	2.53	97.32	2.68	0.02	0.10	0.02
	Test	95	5	95.24	4.76	0.02	0.11	0.02
	Validation	94.12	5.88	91.67	8.33	0.02	0.16	0.04

Fuente: [1]M. Ariza-Avidad, M. P. Cuellar, a Salinas-Castillo, M. C. Pegalajar, J. Vuković, and L. F. Capitán-Vallvey, “Feasibility of the use of disposable optical tongue based on neural networks for heavy metal identification and determination.,” *Anal. Chim. Acta*, vol. 783, pp. 56–64, Jun. 2013.

Figura 3 media de histograma HSV de 30 imágenes con 10 colores



Fuente : W. Kurdthongmee, “Colour classification of rubberwood boards for fingerjoint manufacturing using a SOM neural network and image processing,” *Comput. Electron. Agric.*, vol. 64, no. 2, pp. 85–92, Dec. 2008.

De acuerdo a lo presentado el Histograma en el espacio de color HSV y los momentos de Hu, son espacios de características que deben aportar para realizar una buena clasificación de las clases lanchas y mar.

Tabla 3 Resultado clasificación según Kurdthongmee

Index of group of images for testing	Validation results (%)	
	Correct	Incorrect (completely incorrect)
1	84	16 (7)
2	87	13 (9)
3	81	19 (10)
4	95	5 (2)
5	86	14 (6)
Average	86.6	13.4

Fuente: Ibid.

5. DESARROLLO TEÓRICO

Para el desarrollo del trabajo se establecieron comparación de diferentes vectores de características, de acuerdo a lo analizado en los capítulos dos y cuatro. Para ello se realizan los siguientes pasos.

- Extracción de características de las imágenes de repositorio.
- Entrenamiento de la máquina de soporte vectorial con el 70% de las imágenes del repositorio.
- Clasificación de las imágenes totales del repositorio.
- Tiempos en la clasificación de los repositorios.
- Análisis de las imágenes no clasificadas.

Posteriormente se verifica si este vector de características cumple con las expectativas, evaluando varios vectores para llevar a cabo el análisis.

5.1. Planteamiento

Realizar la extracción de cada imagen del repositorio para determinar el vector de características de esta y así sucesivamente dejando las características en un arreglo que permita realizar el entrenamiento de la máquina de soporte vectorial, el sistema propuesto es el siguiente:

Aprendizaje supervisado.

Para cada repositorio, el cual representa una clase.

- Se lee cada imagen del repositorio.
- Extracción de las características de la imagen.
- Guardar el vector de características de la imagen en el arreglo general.
- Realizar etiqueta de la clase 0 ó 1 para el entrenamiento

Realizar con el arreglo de características de cada clase el entrenamiento de la máquina vectorial.

Clasificación

Para cada repositorio, el cual representa una clase.

- Se lee cada imagen del repositorio.
- Extracción de las características de la imagen.
- Guardar el vector de características de la imagen en el arreglo general.
- Realizar la clasificación basado en el entrenamiento.
- Medición de tiempos en clasificación de cada clase.

5.2. Vector de características

5.2.1. Histograma HSV y momentos de Hu (Histograma & Hu).

En este planteamiento se usan para el análisis del histograma el espacio de color HSV con 12 bins en el canal H y 10 bins en el canal S, lo cual nos arroja para cada imagen un vector de 120 características del histograma, adicionalmente a esto se usan los siete momentos de Hu planteados en la sección 2.1 en los canales H y S, con lo cual se tienen 14 características adicionales a las anteriores.

Se realizan los siguientes pasos que se repiten en cada imagen de entrenamiento, para realizar el arreglo de características del repositorio.

- Lectura de la imagen
- Paso de espacio de color RGB a HSV.
- Guardar el valor del bin en el arreglo en los canales H y S..
- Hallar los momentos de Hu en los canales H y S y colocarlos en el arreglo.

5.2.2. Cadena de píxeles

Analizando que uno de los repositorios corresponde a imágenes del mar, que no poseen un borde determinado, se realiza binarización de la imagen, búsqueda de bordes con el algoritmo de Canny, se normaliza la imagen para realizar el conteo de los píxeles que se encuentran unidos de acuerdo a conectividad ocho.

Este vector solo entrega una característica que es el valor de los píxeles que se encuentran conectados, sumando todos los segmentos que cumplan la condición.

Se colocan en un arreglo el valor de la característica, generando un arreglo con el tamaño de las imágenes a extraer.

5.2.3. Filtros de imagen con la Transformada de Fourier y bordes (Fourier & Canny).

Con el análisis de la Transformada de Fourier planteada en la sección 2.3 se generan 5 filtros de la imagen con el fin de dejar las frecuencia de interés para la clasificación, de cada imagen resultante se toma la media y desviación estándar como característica, para un total de 10. Las imágenes del repositorio no son escalizadas al mismo tamaño, solo son reescalizados los filtros.


Adicionalmente a estas características se toma la media y desviación estándar a la imagen de bordes con Canny, para completar el vector. Quedando el vector de 12 características.

Para ello se debe realizar el siguiente procedimiento:

- Lectura de la imagen.
- Transformada de Fourier de la imagen.
- Hallar bordes con Canny
- Lectura de los filtros y redimensionarlos.
- Multiplicación de cada filtro con la transformada de Fourier de la imagen.

- Hallar media y desviación estándar de la imagen filtrada.
- Hallar media y desviación estándar de la imagen de bordes
- Colocar en el arreglo las 10 características de los filtros (5 medias y cinco desviaciones estándar) y las dos de bordes (media y desviación estándar de la imagen de bordes con Canny).

Ilustración 8 Filtros usados con la transformada de Fourier



5.3. Clasificación

5.3.1. Clasificación

Para la clasificación se toman los vectores de características de entrenamiento compuestas por la lectura del 70% del repositorio de imágenes de la clase lanchas y la clase mar, así como las etiquetas para entrenamiento de la máquina de soporte vectorial, se generan los vectores de soporte.

Usando los parámetros de clasificación de máquina de soporte vectorial n-clases con posibles imperfecciones en la separación. El parámetro en el rango de 0 a 1, que a lo largo hace más suave la frontera de decisión.

Kernel de función básica radial, con un valor de grado de 10, un valor de gamma de 10, el coeficiente de función del kernel de 1, parámetro C de optimización de 1000, parámetro γ de 0.5, parámetro ϵ para optimización del problema de 0.1, peso de las clases nulo, el criterio que se pare el algoritmo luego de hacerse menor que ϵ con un máximo de interacciones de 1000 y una precisión requerida de ϵ .

Estos parámetros fueron tomados del ejemplo del clasificador mediante máquina de soporte vectorial [33], se evaluaron otros parámetros para comparar los resultados, encontrando que estos fueron los que mejor desempeño obtuvieron en la clasificación.

6. PRUEBAS DE CALIDAD Y DESARROLLO DEL SISTEMA

Basados en lo mencionado en el capítulo 2, se toman las diferentes vectores de características de la sección 5.2 se realiza la clasificación con la máquina de soporte vectorial, tomando la siguiente métrica de evaluación de acuerdo con [34].

Buena Clasificación, **BC** = para la clase deseada. (Número de ocurrencias en la clase de los resultados)

Falsa Clasificación, **FC** = para la clase deseada. (Número de ocurrencias en la clase de los resultados)

Perdida de Clasificación, **PC** = objetos físicos no clasificados.

Objetos Clasificados, **OC = BC + FC** : todas las clasificaciones.

Objetos de Referencia, **OR = BC + PC** : todas los objetos de referencia.

$$\textit{Precisión} = \frac{\# \textit{ de BC}}{\# \textit{ de OC}}$$

$$\textit{Sensibilidad} = \frac{\# \textit{ de BC}}{\# \textit{ de OR}}$$

Una vez definidas las métricas, se evalúa la mejor mediante la siguiente fórmula

$$\textit{Resultado} = \frac{2 * \textit{presicion} * \textit{sensibilidad}}{(\textit{presicion} + \textit{sensitividad})}$$

En la siguiente sección se presentan las tablas de resultados de la clasificación con cada uno de los vectores de características e imágenes no clasificadas así como algún análisis que documenta los errores.

6.1. Histograma &Hu

Tabla 4 Clasificación con Histograma & Hu

HISTOGRAMA Y MOMENTOS_HU CON SVM								
CLASE	BC	FC	PC	OC	OR	Precisión	Sensibilidad	Resultado
ENTRENAMIENTO								
Lanchas	407	3	0	410	407	0,993	1,000	0,996
Mar	287	7	0	294	287	0,976	1,000	0,988
CLASIFICACION								
Lanchas	584	3	0	587	584	0,995	1,000	0,997
Mar	413	7	0	420	413	0,983	1,000	0,992

En la Tabla 4 Clasificación con Histograma & Hu se muestra la medición para determinar el funcionamiento del vector de características, tanto en la fase de entrenamiento como en la parte de clasificación, concluyendo que tiene un buen desempeño en la clasificación.


Ilustración 9 Imágenes no clasificadas clase lancha, con Histograma & Hu



Haciendo el análisis de las imágenes de Ilustración 9 tomando el vector de características, se comparó con las imágenes del repositorio donde se encuentra que estas imágenes no poseen la cantidad de luminancia y brillantes para la selección de los canales H y S, lo cual afecta al final la clasificación,

debido a que el histograma y los momentos de Hu están basados en estos canales para establecer el vector de características.

Ilustración 10 Imágenes no clasificadas clase mar



Analizando el repositorio de la clase mar con las imágenes de la

Ilustración 10, se destaca que la mayor parte de la imagen está compuesta por la estela, es decir el color blanco que se aprecia, debido al paso de los motores de la lancha en el mar, alterando la congruencia con las otras imágenes del repositorio, el caso de estudio se basa en Histograma & Hu el cual es basado en el espacio de color HSV, alterando las características de estas imágenes con respecto a las otras del repositorio

6.2. Cadena de píxeles

Se toma como vector de características lo enunciado en la sección 5.2.2 con los siguientes resultados

En la Tabla 5 se analiza que la precisión es de un 99% para la clase lanchas, por lo que clasificación es muy buena, debido a que estas poseen una conexión de píxeles, muy coherente para este tipo de imágenes, pero al comparar la Ilustración 11 de la lancha, esta es borrosa lo cual no permite

determinar un buen borde y como consecuencia un mal conteo de los píxeles encadenados.

Tabla 5 Clasificación con cadena de píxeles

CADENA DE PÍXELES								
CLASE	BC	FC	PC	OC	OR	Precisión	Sensibilidad	Resultado
ENTRENAMIENTO								
Lanchas	409	1	0	410	409	0,998	1,000	0,999
Mar	215	79	0	294	215	0,731	1,000	0,845
CLASIFICACIÓN								
Lanchas	586	1	0	587	586	0,998	1,000	0,999
Mar	226	194	0	420	226	0,538	1,000	0,700

Ilustración 11 Imagen no clasificada clase lancha, cadena de píxeles.



Analizando la Ilustración 12, en este espacio de características se toma es la conexión de los píxeles luego de hallar bordes con Canny, en este caso la diferencia es muy grande, debido a que en algunas de las imágenes se encuentran bordes, mientras que en otras no, haciendo que la característica no sea un buen factor para la clasificación en la clase mar.

Ilustración 12 Muestra imagen no clasificada clase mar, cadena de píxeles.



6.3. Fourier & Canny.

Tabla 6 Clasificación con Fourier & Canny

FOURIER & CANNY								
CLASE	BC	FC	PC	OC	OR	Precisión	Sensibilidad	Resultado
ENTRENAMIENTO								
Lanchas	410	0	0	410	410	1,000	1,000	1,000
Mar	271	23	0	294	271	0,922	1,000	0,959
CLASIFICACIÓN								
Lanchas	583	4	0	587	583	0,993	1,000	0,997
Mar	383	37	0	420	383	0,912	1,000	0,954

Fourier & Canny presentan una muy buena precisión tanto en el entrenamiento como en la clasificación como lo muestra la Tabla 6

Ilustración 13 Imágenes no clasificadas clase lancha, transformada de Fourier y bordes Canny



Las imágenes 1,2,4 de la Ilustración 13 están compuestas mayormente por la lancha, las imágenes originales de 1 y 2 muestran que no hay un borde consistente, originando diferencia entre los objetos de la clase lancha, la tercera imagen presenta un cambio drástico del fondo en comparación con las anteriores, hace que se distorsione tanto el borde como la información en frecuencia, en la cuarta haciendo comparación con las imágenes del repositorio esta se presenta en un tamaño mayor y con contraste diferente, lo cual arroja un borde e información en frecuencia diferente.

Ilustración 14 Imágenes no clasificadas clase mar, transformada de Fourier y bordes Canny



Analizando las imágenes de la clase mar que no fueron clasificadas Ilustración 14 , estas no poseen información para poder realizar la extracción de bordes y la información de la transformada de Fourier no es la adecuada para realizar la distinción entre las imágenes.

6.4. Tiempo de extracción de características

El análisis del tiempo de extracción de características se realizó con las siguientes especificaciones, procesador AMD Turion (tm) X2 Dual Core Mobile RM 72 2,10 Ghz, RAM 4 Gb, sistema operativo Linux distribución Ubuntu 10.04.4 LTS, librería Opencv 2.4.6 con QT.

Tabla 7 Tiempo de extracción de características

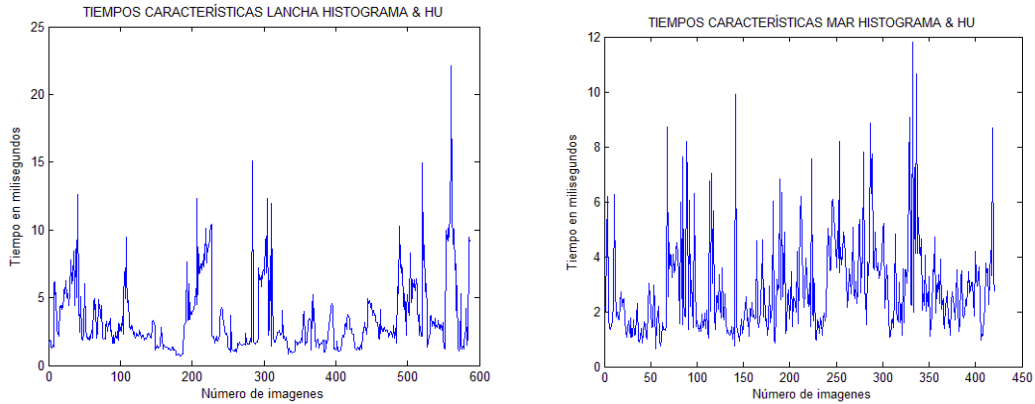
Características	Tiempo promedio en ms.		Tiempo total en ms.	
	<i>Lanchas</i>	<i>Mar</i>	<i>Lanchas</i>	<i>Mar</i>
Histograma HSV y momentos de Hu	3,56	3,05	2092,04	1283,83
Cadena de píxeles	6,54	4,54	3839,13	1909,63
Transformada de Fourier y bordes Canny	38,92	35,25	14807,60	22848,90

Fuente: Tiempos en milisegundos tomados dentro de la extracción de características.

La Tabla 7 muestra como al realizar la transformada de Fourier el tiempo de procesamiento aumenta considerablemente, debido a la complejidad, mientras que al usar como características el histograma HSV y los momentos de Hu, es el que menor tiempo requiere. El conteo de píxeles hace que se aumente el tiempo al realizar la búsqueda de píxeles blancos y su conexión con otros píxeles blancos.

6.4.1. Histograma & Hu.

Figura 4 Tiempos características Histograma & Hu.

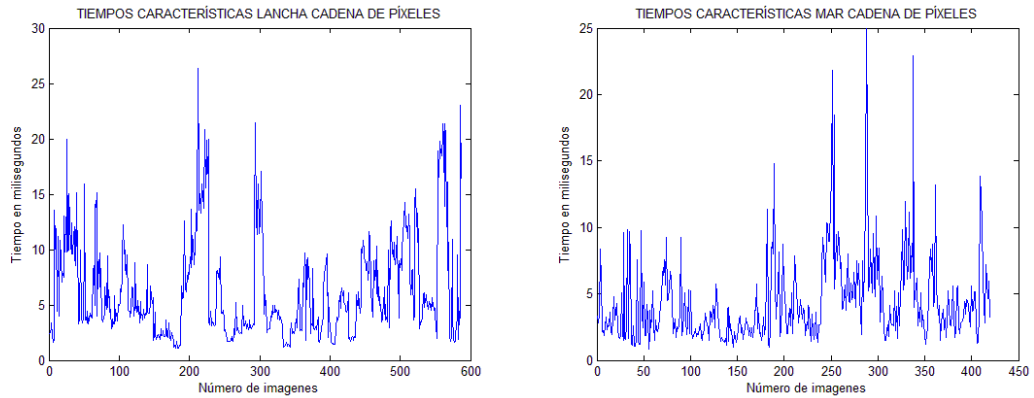


De la Figura 4, dentro de la extracción de las características se nota como la clasificación de clase buque es mucho más pesada para la clase mar debido a la complejidad de la imagen.

6.4.2. Cadena de píxeles

La Figura 5 muestra claramente como en la extracción de la clase lanchas se tiene mayor tiempo de procesamiento al encontrar mayores bordes o líneas de continuidad de la imagen, las últimas imágenes de la clase tipo mar se destaca la aparición de la estela que deja la lancha al desplazarse en el mar, lo cual genera una región que al realizar la búsqueda de borde encuentra gran cantidad de píxeles unidos, de allí la falla en la clasificación en el tipo mar.

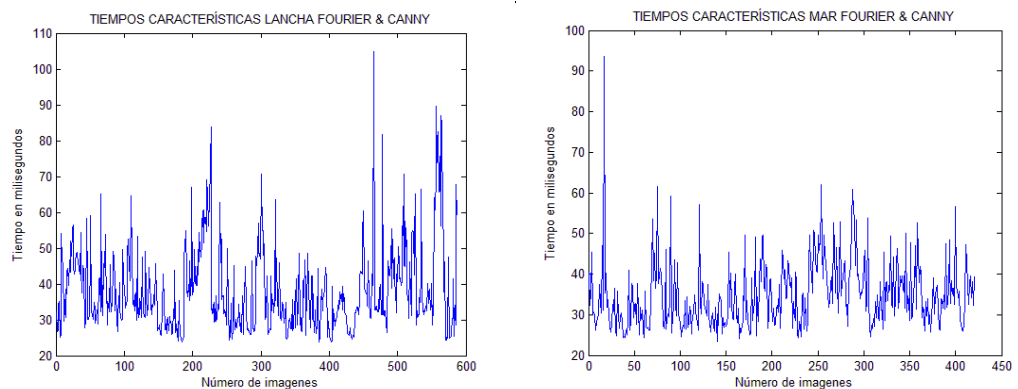
Figura 5 Tiempos características cadena de pixeles.



6.4.3. Transformada de Fourier y bordes de Canny

Al realizar la extracción de características usando la transformada de Fourier y los bordes de Canny, el tiempo final de clasificación es mucho mayor debido a la complejidad matemática de la transformada en comparación con los otros dos vectores de características, como lo demuestra la Figura 6.

Figura 6 Tiempos características Fourier & Canny



Comparando los resultados de precisión en la clasificación las mejores características son las de Histograma & Hu, y por último Cadena de píxeles, en cuanto a los tiempos arrojados en la clasificación se observa como las características de Histograma & Hu es el más rápido y el de Fourier & Canny es el más lento, por lo cual hay que observar cual será el desempeño de los vectores de características en el seguimiento.

7. SEGUIMIENTO

Dentro del proceso de seguimiento el usuario establece un área a seguir, este es el ROI al cual se le extraen las características para ser buscadas dentro del frame siguiente, usando los vectores de características presentados en la sección 5.2.

7.1. Selección del ROI

Se analiza la teoría para decisión del mejor ROI, del cual se extraen las características, el planteamiento se basa en la búsqueda de ventanas con las mismas dimensiones del ROI, extraer las características, realizar la evaluación de los diferentes vectores de características asociados a una ventana, estableciendo una métrica de evaluación y de selección.

7.2. Métrica de decisión para la selección de la ventana de seguimiento.

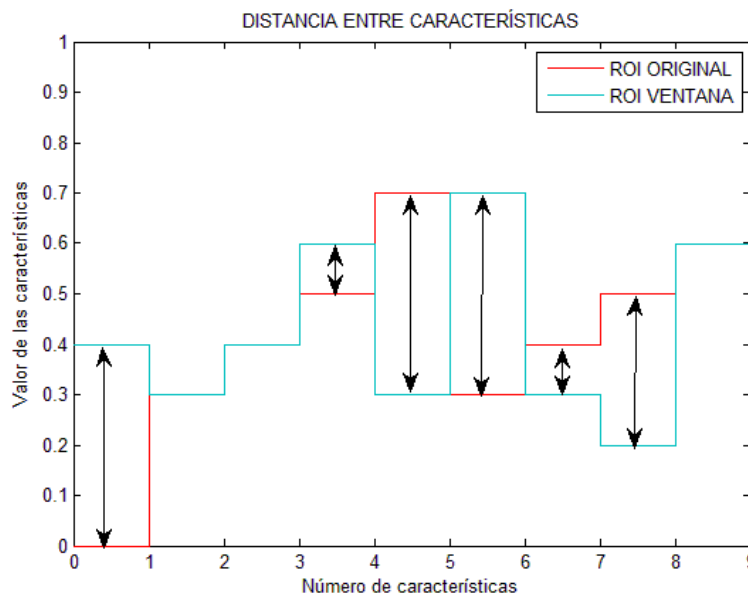
En la literatura se encuentra la distancia Hausdorff, con el fin de establecer una medida de igualdad de un conjunto de valores, los cuales pueden representar, imágenes, sonidos, señales de sensores electrónicos [35], donde las características son usadas como un factor de selección, comparándolas con una origen para hallar la similitud de esta con un patrón, en imágenes esta es usada en imágenes binarias, realizando la comparación de distancias entre los puntos de la imagen origen con la muestra, en [36] se discuten tres métodos para hallar la distancia Hausdorff, un primer método muy parecido a la correlación y la convolución, un segundo método que permite comparar una porción del modelo y una porción de la imagen y un tercero mejorando los dos métodos anteriores estableciendo unas reglas para hallar la posición de la imagen.

En [35] se realiza la comparación de dos triángulos donde se busca la distancia de cada vértice del triángulo A, a los vértices del triángulo B, para determinar la distancia de Hausdorff. En el caso esta no es una solución porque el planteamiento es la búsqueda de las características y no directamente de la imagen seleccionada por la ROI.

7.3. Determinación de similitud de características

Analizando la forma como se realiza la distancia de Hausdorff, se pasan a un plano las características del ROI y la ventana a evaluar como lo muestra la Figura 7. En donde las flechas dobles son la distancia entre las características del ROI seleccionado y las características de la ventana a comparar, entre menor sea la distancia más similitud tendrán los dos vectores.

Figura 7 Distancia entre ROI seleccionado y ROI ventana



Se toman 10 características como ejemplo.

Cada ventana tiene asociado un vector de características, que se transforma en distancias absolutas al vector de características del ROI, haciendo uso de la Ecuación 2.

$A =$ vector de características del ROI.

$B =$ vector de características de la ventana.

$n =$ número de ventana.

$m =$ número de características.

$C =$ vector con las diferencias entre ROI y ventana.

Ecuación 2 Distancia de las características de la ventana al ROI

$$C_n = \{|A_1 - B_{n1}|, |A_2 - B_{n2}|, \dots, |A_{nm} - B_{nm}|\}$$

Cada ventana tiene un vector de características y esta una distancia al vector del ROI, se define la siguiente métrica para evaluar cada característica así:

- Haciendo uso de la Ecuación 3 se realiza búsqueda del valor máximo de distancia por cada característica dentro de todas las ventanas.

Ecuación 3 Máximos de cada características

$$E = \max((C_1^1, \dots, C_1^n), (C_2^1, \dots, C_2^n), \dots, (C_m^1, \dots, C_m^n))$$

- Con la Ecuación 4 se determina el vector con los pesos de cada característica asociada a la ventana

Ecuación 4 Vector de pesos de cada característica por ventana

$$D_n = \left\{ \left(\frac{C_1^n}{E_1} \right), \left(\frac{C_2^n}{E_2} \right), \dots, \left(\frac{C_m^n}{E_m} \right) \right\}$$

- En la Ecuación 5 se determina la sumatoria de todos los pesos de las características de la ventana.

Ecuación 5 Peso asociado a cada ventana

$$F_n = \sum_1^m D_m$$

- Con la Ecuación 6 se establece la máxima similitud a la ventana con el valor mínimo.

Ecuación 6 Búsqueda de la mejor ventana

- $\min (F_1, F_2, \dots, F_n)$.

La búsqueda de la mejor ventana para el seguimiento depende del valor mínimo de F y la distancia de la ventana al ROI, que se halla por la distancia euclidiana, se toman las 10 ventanas con mayor similitud para escoger la más cercana por el método de ventanas aleatorias que se explica en la siguiente sección.

7.4. Método de búsqueda de ventanas.

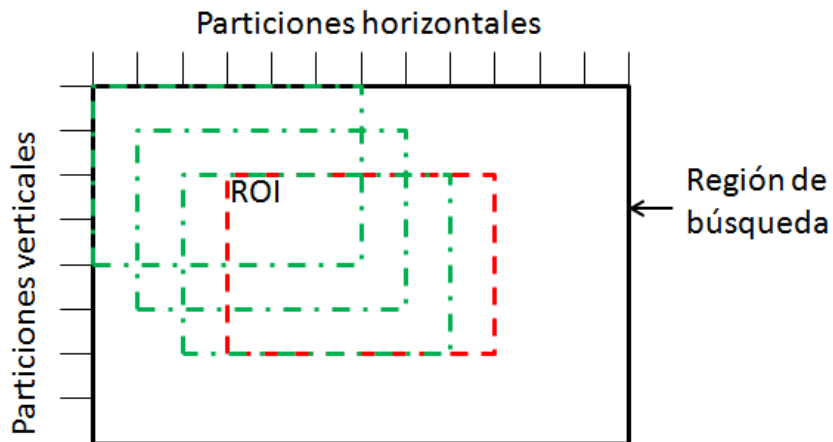
Se establecen dos estrategias de búsqueda de ventanas dentro del frame para realizar las comparaciones, la primera haciendo una búsqueda basada en saltos de la ventana de acuerdo a las divisiones del tamaño del ROI y la segunda usando búsqueda aleatoria dentro del frame.

7.4.1. Ventanas cercanas

Se define una región para búsqueda centrada en el ROI pero tomando una región de cuatro veces su tamaño, posteriormente la búsqueda se realiza dividiendo esta región en las particiones horizontal y vertical, para un total de ventanas asociado a la multiplicación de las dos particiones.

El problema del seguimiento depende del tamaño del ROI, si es muy grande hace que las ventanas de la región de búsqueda estén muy separadas afectando el seguimiento, como se puede evidenciar en la Figura 8.

Figura 8 Particiones búsqueda de ventana



7.4.2. Ventanas aleatorias

Se establece un número de ventanas que son generadas por un valor aleatorio en X y Y, realizando los siguientes pasos

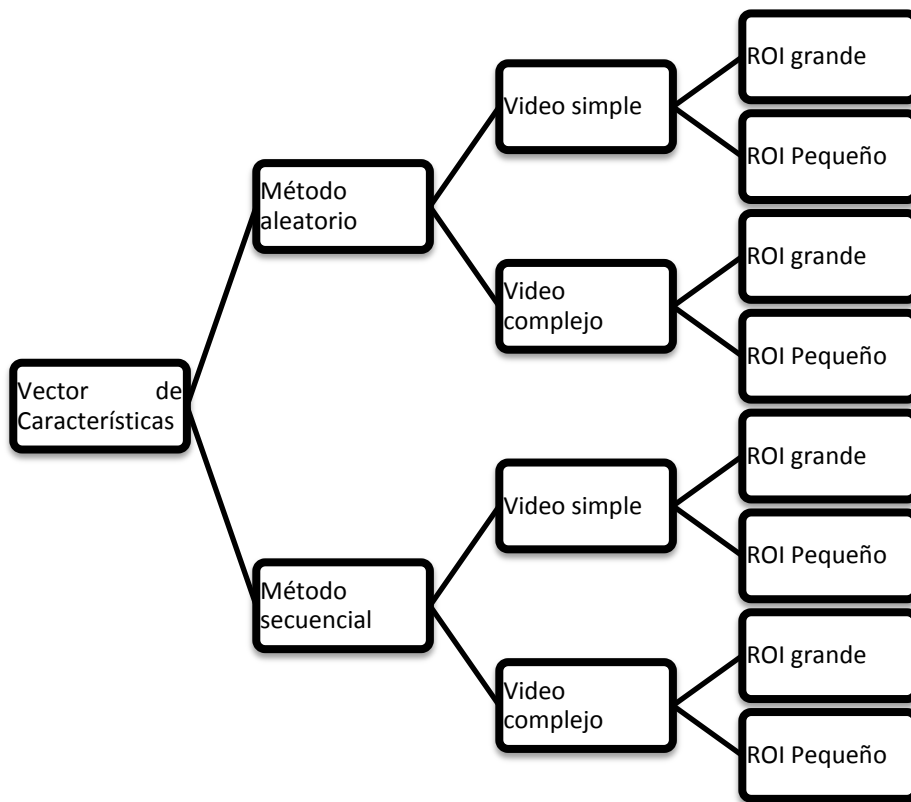
- Determinar la similitud de características.
- Establecer las 10 mejores.
- Evaluar la distancia euclidiana entre las ventanas seleccionadas y la ventana de seguimiento, escoger la ventana con menor distancia.
- Determinar umbral para determinar el valor mínimo de buen seguimiento, este depende del peso de cada ventana.
- Si está por encima del umbral mantiene la misma ventana de seguimiento del frame anterior.

Con la determinación de similitud de características y los métodos de búsqueda, se quiere realizar un mejor acercamiento de la ventana de seguimiento al objeto a seguir, haciendo una métrica de valoración que permita determinar la mejor ventana a escoger, mediante varias formas para evaluar la mejor.

8. ANÁLISIS Y RESULTADOS

Para presentar los resultados y hacer su análisis se plantearon los siguientes escenarios para el seguimiento como lo muestra la Ilustración 15. Se establecieron dos videos el primero complejo por la composición del video y el segundo simple donde solo está el objeto a seguir rodeado de mar y cielo. Dentro de estos se realizó el seguimiento en dos categorías, uno con ROI pequeño que tiene las características de una parte de la lancha y el otro con ROI con la totalidad de la imagen de la lancha al comenzar el video. Se establece como seguimiento positivo cuando la ventana de seguimiento se mantenga sobre la imagen de la lancha en un 10%.

Ilustración 15 Divisiones del análisis de seguimiento



8.1. Características de los videos

8.1.1. Video complejo

Posee partes que puede confundir el seguimiento de la lancha debido a que el fondo está compuesto por edificios, palmeras y otros objetos que poseen características similares a las del objeto a seguir. La lancha se encuentra con tres personas en su interior que realizan el desplazamiento de manera lenta sin generar mucha estela en el agua, esporádicamente se pierde la calidad de la imagen debido al sensor con el cual se extrajo el video fue adquirido por el autor en la bahía de Cartagena mediante una videocámara casera. Las características del video son las siguientes:

- Ancho fotograma 720 píxel.
- Alto fotograma 480 píxel.
- Velocidad de fotogramas 30 cuadros por segundo

8.1.2. Video simple

Se considera simple o un video con restricciones, siendo este caso un escenario probable en alta mar porque el fondo es mar, horizonte y cielo, restringiendo que se encuentren características similares dentro de la imagen, si bien por esta razón es simple, la lancha tiene mayor movimiento debido a que se encuentra desplazándose a alta velocidad, generando que al entrar al agua se esconda parte de la lancha y al salir se visualice la parte inferior de está.

Los movimientos bruscos pueden inducir a un mal seguimiento, dependiendo de la estrategia de seguimiento. El video posee las siguientes características:

- Ancho fotograma 480 píxel.
- Alto fotograma 360 píxel.
- Velocidad de fotogramas 25 cuadros por segundo.

8.2. Tamaño del ROI

Depende de la estrategia usada puede ayudar al seguimiento o genera pérdida. El ROI grande posee mayor información de la imagen para realizar el seguimiento, al contrario el ROI pequeño limita el espacio de información para extraer las características.

8.3. Tiempo de procesamiento

En la sección 6.4 se establece la comparación de tiempos en la extracción de características en cada vector, el tiempo de procesamiento es el de extracción de características y este se multiplica por la cantidad de ventanas a evaluar en el frame más la determinación de la ventana de seguimiento. Es directamente proporcional al tamaño del ROI.

8.4. Resultados

Para el análisis se toma el tamaño del ROI, las características usadas, el método de seguimiento y el video sobre el cual se prueba el algoritmo, tomando los tiempos, tasa de pérdida de seguimiento y el análisis del seguimiento.

8.4.1. ROI grande método aleatorio sobre video complejo

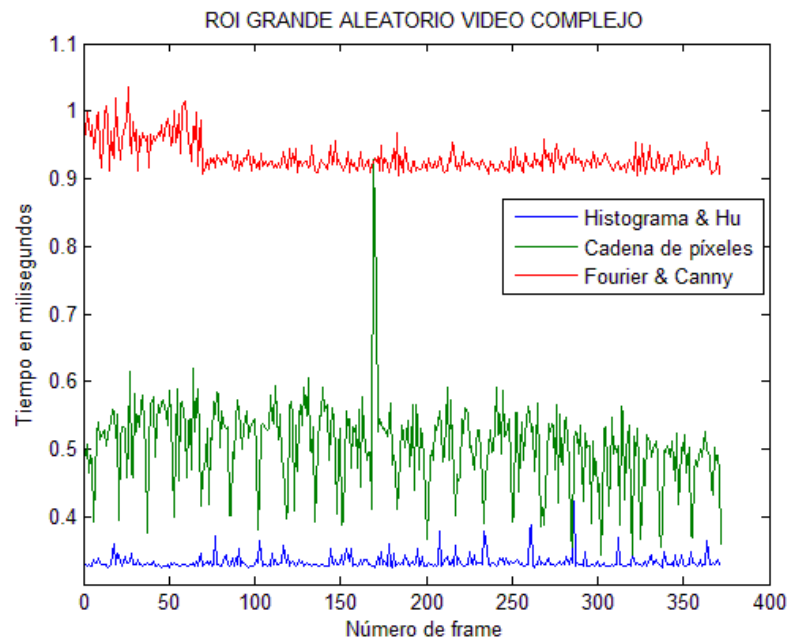
Tabla 8 Seguimiento aleatorio ROI grande video complejo

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu	Totalidad	Ninguna
Cadena píxeles	Totalidad	Ninguna
Fourier & Canny	Aleatorio	Totalmente

Analizando la Tabla 8 la prueba del algoritmo en las características de Histograma & Hu y cadena de píxeles realiza el seguimiento total, con Fourier & Canny se pierde el seguimiento.

Esto es debido a que al usar la transformada de Fourier se analizan las ventanas en escala de grises, causando que la información se encuentre en otras partes del escenario en especial donde se encuentran varios elementos en el fondo, que pueden tener similares características que el ROI, adicional a esto el método es aleatorio es decir que las ventanas para evaluación pueden estar sobre la totalidad de la imagen.

Figura 9 Tiempos método aleatorio ROI grande video complejo



Dentro de los tiempos el más complejo para su procesamiento se realiza con el vector de características de Fourier & Canny, teniendo un pésimo desempeño tanto en el seguimiento como en el tiempo de procesamiento como lo evidencia la Tabla 8 y la Figura 9. Así mismo el pico del vector de características Cadena de píxeles, debió haber pasado al quedar las

ventanas a evaluar sobre partes de la imagen con bordes, lo cual adicionó tiempo de procesamiento, lo cual es muy probable por ser el análisis sobre el video complejo y el ROI grande.

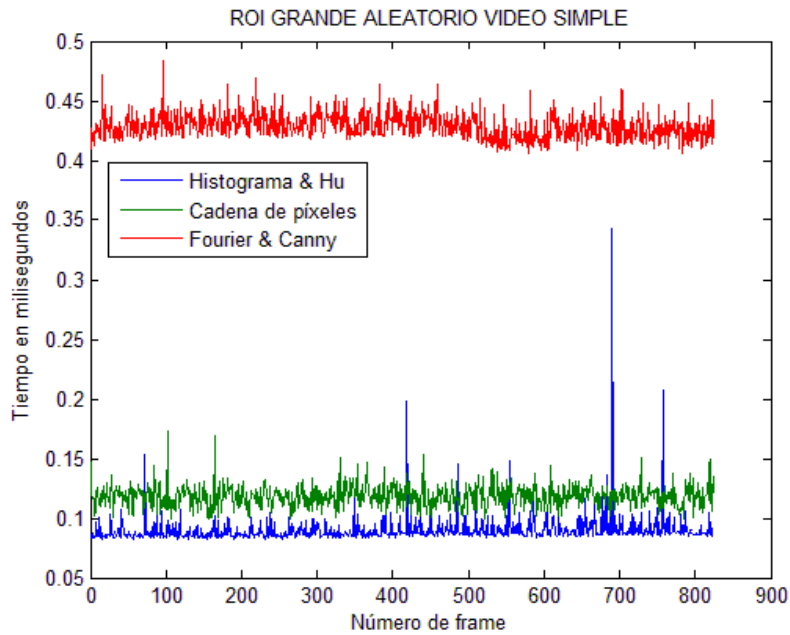
8.4.2. ROI grande método aleatorio sobre video simple

Tabla 9 Seguimiento aleatorio ROI grande video simple

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu	Totalidad	Ninguna
Cadena píxeles	Parcial	< 5 fps
Fourier & Canny	Parcial	< 3 fps

En el caso de la Tabla 9 al realizar la prueba del algoritmo sobre un video sin información en el escenario que sea confundida con las características del ROI, hace que se mantenga el seguimiento. Al realizar el seguimiento en cadena de píxeles, se confunde con la estela dejada por la lancha debido que esta genera bordes que son confundidos con el objeto seguido.

Figura 10 Tiempos método aleatorio ROI grande video simple



Analizando los tiempos de procesamiento entre la Figura 9 y la Figura 10, al poseer un video simple que tiene un procesamiento más sencillo, por que el ROI grande del video complejo ocupa una octava parte de la imagen, mientras que el ROI grande del video simple ocupa una cincuentava parte, adicional a ello el tamaño del fotograma del video complejo es el doble que el video simple, generando mayor tiempo de procesamiento en el video complejo.


8.4.3. ROI grande método secuencial sobre video complejo

Tabla 10 Seguimiento secuencial ROI grande video complejo

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu	Totalidad	Ninguna
Cadena píxeles	Totalidad	Ninguna
Fourier & Canny	Totalidad	Ninguna

En el seguimiento secuencial se encuentran saltos sobre el objeto sin dejar de seguirlo como lo muestra la Tabla 10, estos saltos están asociados a las particiones horizontales y verticales mostrados en la sección 7.4.1 que dan un intervalo entre las posibles ventanas de seguimiento y es directamente proporcional al ROI. Al usar la características de cadena de píxeles, estas busca píxeles unidos que se generan de los bordes en las ventanas, al realizar el seguimiento el borde de la lancha es confundido en parte por el borde que genera la estela sin perder el seguimiento.

Figura 11 Tiempos método secuencial ROI grande video complejo.



El procesamiento de extracción de características con Fourier & Canny es excesivamente lento como se observa en Figura 11, es proporcional al número de ventanas que se evalúan y al tamaño del ROI en este caso hay mas ventanas a evaluar, y el ROI es grande lo que genera que se tenga mayor información a evaluar.

8.4.4. ROI grande método secuencial sobre video simple

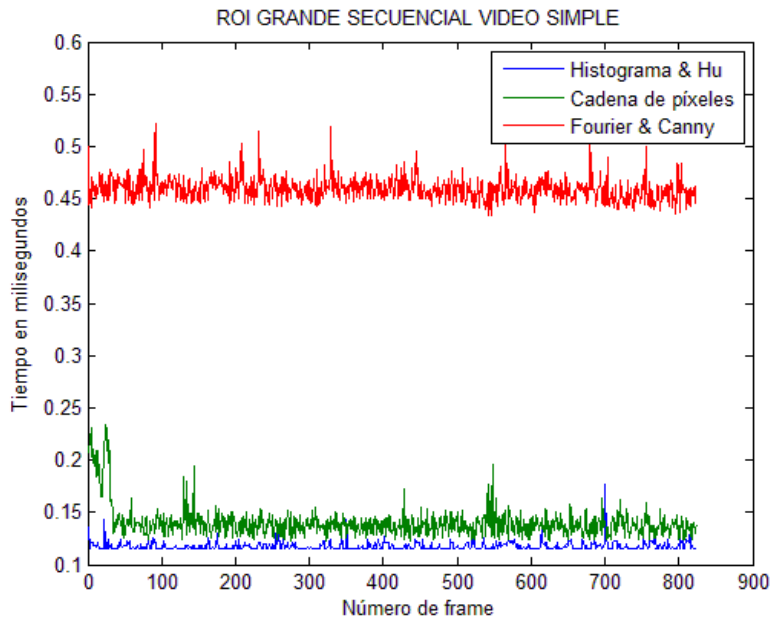
Tabla 11 Seguimiento secuencial ROI grande video simple

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu	Totalidad	Ninguna
Cadena píxeles	Parcial	Total
Fourier & Canny	Parcial	< 7 fps

Al realizar el seguimiento sobre las características de píxeles, hace que se confunda con el horizonte y al salirse la lancha de la región de búsqueda se pierde totalmente como lo evidencia la Tabla 11.

Debido a que en este video, los fotogramas son más pequeños se reduce el procesamiento en comparación con el video complejo como se observa al comparar la Figura 11 y la Figura 12 Tiempos método secuencial ROI grande video simple..

Figura 12 Tiempos método secuencial ROI grande video simple.



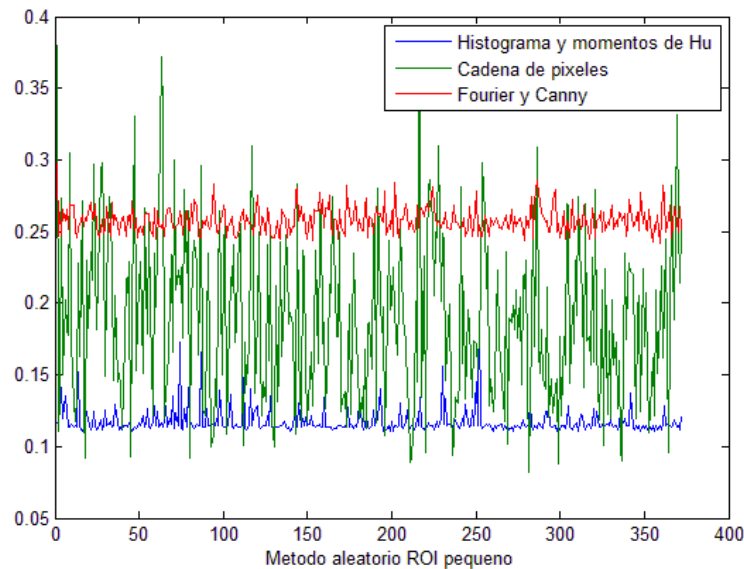
8.4.5. ROI pequeño método aleatorio sobre video complejo

Tabla 12 Seguimiento aleatorio ROI pequeño video complejo

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu	Parcial	< 5 fps
Cadena píxeles	Perdida	Total
Fourier & Canny	Perdida	Total

En el seguimiento con un ROI pequeño y ventanas de búsqueda aleatorias hace que la probabilidad de realizar el seguimiento baje, debido a que en este video el fondo puede tener las mismas característica buscadas. Es aquí donde el mejor vector de características usado en la clasificación realiza el seguimiento, el cual fue Histograma y momentos de Hu.

Figura 13 Tiempos método aleatorio ROI pequeño video complejo.



En la Figura 13 se muestra que el menor procesamiento es realizado por las características de histograma y momentos de Hu.

8.4.6. ROI pequeño método aleatorio sobre video simple.

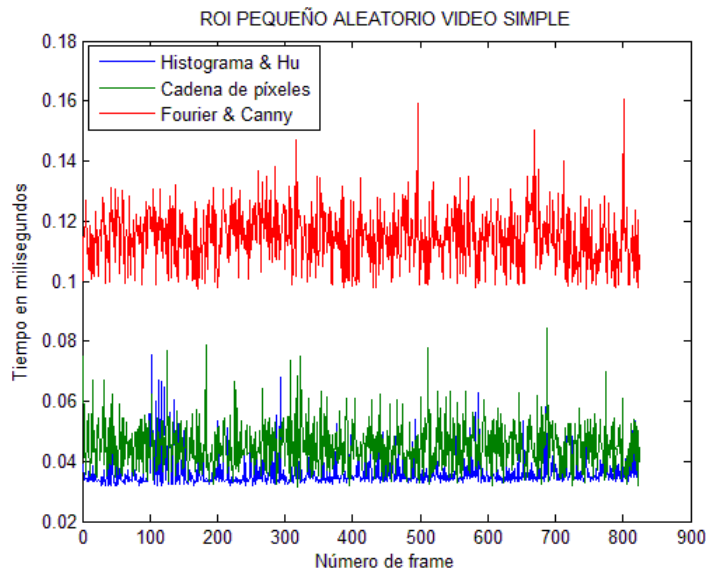
Tabla 13 Seguimiento aleatorio ROI pequeño video simple

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu	Totalidad	Ninguna
Cadena píxeles	Parcial	Perdida al final
Fourier & Canny	Parcial	< 5 fps.

Las características de histograma & Hu realizan el seguimiento independiente de los movimientos bruscos de la lancha, debido a la

búsqueda aleatoria y la consistencia de las características. En el caso de Fourier & Canny, se mantiene el seguimiento porque en el escenario no hay partes de la imagen que posean la misma información de frecuencia para la transformada de Fourier. En la cadena de píxeles se termina perdiendo por el horizonte o la estela debido a que producen un borde que es contada como cadena de píxeles.

Figura 14 Tiempos método aleatorio ROI pequeño video simple.



Como lo evidencia la Figura 14 el tiempo es mucho mayor nuevamente para la Fourier & Canny manteniéndose como las características con menor tiempo de procesamiento Histograma & momentos Hu.

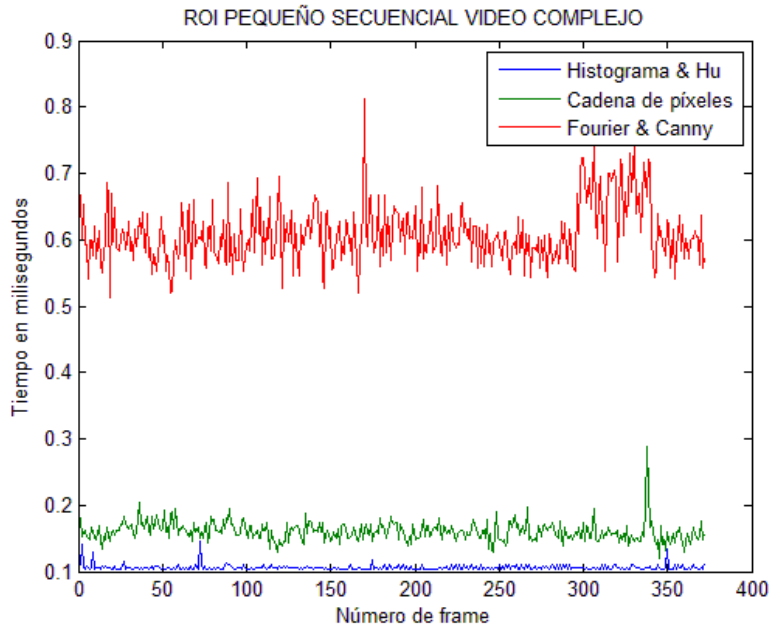
8.4.7. ROI pequeño método secuencial sobre video complejo.

Tabla 14 ROI pequeño método secuencial sobre video complejo

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu.	Totalidad	Ninguna
Cadena píxeles	Totalidad	Ninguna
Fourier & Canny	Totalidad	Ninguna


El seguimiento al ser realizado de manera secuencial como lo muestra la Tabla 14, con un video donde no hay cambios bruscos de dirección, y con una región de búsqueda pequeña relacionada con el ROI, permite un buen desempeño. Al mantenerse la región de búsqueda sobre el objeto.

Figura 15 Tiempos método secuencial ROI pequeño video complejo.



En la Figura 15, es de analizar como al disminuir el tamaño del ROI se decrementa el tiempo de procesamiento, en especial para el vector de Histograma & Hu, como lo demuestra la Figura 16

Figura 16 Tamaño ROI vs tiempo de procesamiento



8.4.8. ROI pequeño método secuencial sobre video simple.

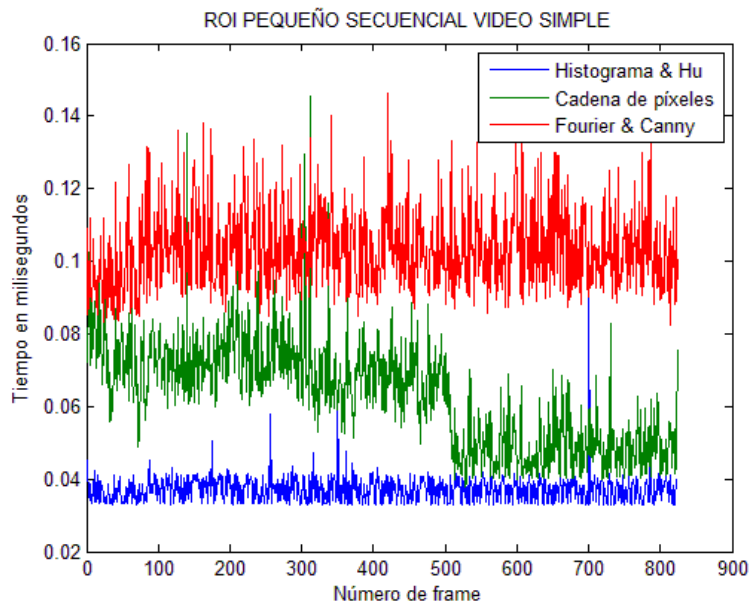
Tabla 15 ROI pequeño método secuencial sobre video simple.

CARACTERÍSTICAS	SEGUIMIENTO	PÉRDIDA
Histograma & Hu.	Parcial	>10 fps.
Cadena píxeles	Parcial	Total al final
Fourier & Canny	Parcial	Total al final

En las condiciones establecidas por el video simple tiene mayor probabilidad de pérdida del seguimiento evidenciado en la Tabla 15, debido a que la región de búsqueda es pequeña y la lancha tiene movimientos bruscos de dirección en el mar. A medida que aumenta el ROI la región de búsqueda aumenta pero se ve sacrificada por la discriminación del objeto,

al aumentar el espacio entre las ventanas de comparación. En el caso de estudio por tener mayor movimiento la lancha en dirección vertical entre más alta sea el área del ROI mejor desempeño tiene el seguimiento. Al usar la cadena de píxeles el seguimiento se sale de la lancha perdiéndose totalmente. La cadena de píxeles es continua en toda la lancha, lo que hace que la ventana de seguimiento se desplace sobre la imagen de la lancha hasta la estela, que genera borde continuo como característica para la clasificación.

Figura 17 Tiempos método secuencial ROI pequeño video simple.



El procesamiento es mucho más constante en las características de histograma & Hu, demostrando que es el que mejor desempeño tiene a nivel de tiempo de ejecución. Al reducir el ROI y tomar un video con fotogramas más pequeños el procesamiento se reduce

Se analizaron los métodos teniendo en cuenta la relación entre el ROI y el tiempo de procesamiento es proporcional, la pérdida de seguimiento depende de las variables del video y del ROI, pero es constante cuando se usa el ROI grande, pero el seguimiento se ve afectado por el tiempo de procesamiento.

9. CONCLUSIONES Y TRABAJOS FUTUROS

9.1. Conclusiones

En el caso de estudio se establecen las Tabla 16 Tiempo promedio de determinación de ventana de seguimiento y Tabla 17 Pérdida de seguimiento. para realizar las conclusiones finales.

Tabla 16 Tiempo promedio de determinación de ventana de seguimiento

Tiempos promedio determinación ventana de seguimiento				
Característica	Histograma HSV & momentos Hu			
Método	Aleatoria		Secuencial	
Tipo ROI	V. Complejo	V. Simple	V. Complejo	V. Simple
Pequeña	0,1173	0,0362	0,1061	0,0372
Grande	0,3329	0,0898	0,3837	0,1176
Característica	Cadena de pixeles			
Pequeña	0,1889	0,0452	0,1602	0,0628
Grande	0,5044	0,1184	0,6804	0,1402
Característica	Fourier & Canny			
Pequeña	0,2578	0,1145	0,609	0,1033
Grande	0,9315	0,4287	1,911	0,4592

El menor tiempo de procesamiento es el que se realiza sobre el video simple, debido a que este posee los fotogramas más pequeños, haciendo que el procesamiento sea menor, observándose claramente en las Figura 9 Tiempos método aleatorio ROI grande video complejo y Figura 10 Tiempos método aleatorio ROI grande video simple, y en la Tabla 16 donde el menor tiempo de

procesamiento lo tiene el ROI pequeño con el video simple con un valor de 0.0362, teniendo el mejor desempeño en tiempo.

Tabla 17 Pérdida de seguimiento.

Pérdida de seguimiento				
Característica	Histograma HSV & momentos Hu			
Método	Aleatoria		Secuencial	
Tipo ROI	V. Complejo	V. Simple	V. Complejo	V. Simple
Pequeña	< 5 fps.	Ninguna	Ninguna	> 5 fps
Grande	Ninguna	Ninguna	Ninguna	Ninguna
Característica	Cadena de pixeles			
Pequeña	Total	Al final	Ninguna	Total
Grande	Ninguna	< 5 fps	Ninguna	Total
Característica	Fourier & Canny			
Pequeña	Total	< 5 fps.	Ninguna	Total
Grande	Total	< 3 fps.	Ninguna	< 7 fps.

El seguimiento secuencial genera una región de búsqueda que es directamente proporcional al ROI, dando saltos al seguimiento por los intervalos entre las ventanas, posee ventaja al realizar el seguimiento cuando el escenario tiene partes de la imagen que pueden ser confundidas con las características del ROI. Al limitar la región de búsqueda evitando que tome las partes de la imagen con similares características. En especial cuando se complementa con un ROI grande como lo demuestra la Tabla 17, exceptuando las características de píxeles que al aumentar la ventana de seguimiento lo pierde debido a encontrar bordes en la estela o el horizonte.

El seguimiento usando el vector de características de histograma & momentos de Hu, presenta la desviación estándar más baja, esto se confirma en la comparación de los tiempos en las figuras de la sección 8.4 donde se comparan los diferentes tamaños de ROI, métodos de seguimiento y clases de video.

En la Tabla 17 se analiza como el vector de características de histograma & momentos de Hu, tiene el mejor desempeño y el menor tiempo de determinación de la ventana de seguimiento de acuerdo a la Tabla 16, así como realiza un buen seguimiento de la forma aleatoria con ROI pequeño porque son características que demostraron buen desempeño en la etapa de clasificación.

La extracción de las características de Fourier & Canny es demasiado lento, el tiempo dependen del número de ventanas a evaluar para determinar la similitud con el ROI, produciendo lentitud extrema en el seguimiento como se muestra en la Tabla 17, donde el mayor tiempo de determinación de la ventana de seguimiento es 1.911 milisegundos, dándose en el video complejo con ROI grande en secuencia de ventanas, debido a que en este método de seguimiento se evalúan 25 particiones horizontales y 15 verticales, generando 375 ventanas a evaluar, en el caso de el método aleatorio se analizan 300 ventanas. Coherente con lo analizado en la extracción de características en la Tabla 7, donde observa el mayor tiempo de procesamiento.

La cadena de píxeles como vector de características es susceptible a encontrar las mismas características en el frame, por lo cual al usar el método de seguimiento aleatorio tiende a perderse.

El mejor desempeño en el seguimiento por tiempo, lo da el ROI pequeño con las características de histograma & momentos de Hu sobre el vídeo complejo, pero este seguimiento recorre toda la lancha no manteniéndose en un solo lugar de la imagen.

El mejor desempeño por mantener siempre la lancha en la ventana de seguimiento son las características de histograma & momentos de Hu, con un ROI grande pero este se ve afectado por el tiempo de procesamiento lo que hace que se dificulte realizarlo en tiempo real.

Al probar los algoritmos de seguimiento en otros videos, seguramente el de mejor desempeño será con Histograma & Hu con el método secuencial, escogiendo un ROI que ocupe una cuarta parte del objeto a seguir, esto se deduce de los análisis anteriores de métodos de búsqueda de ventana, tamaño del ROI y vector de características.

9.2. Trabajos futuros

Establecer el valor óptimo de ventanas para cada uno de los métodos de seguimiento planteados, para mejorar el rendimiento al reducir el procesamiento de las ventanas a evaluar.

Realizar el ajuste del ROI al objeto a seguir, que sea variable al tamaño de la lancha, para seguirla en todo momento.

Analizar si es posible reducir características en el seguimiento que estén gastando tiempo de procesamiento, desmejorando el rendimiento del algoritmo.

Realizar los ajustes en número de ventanas a evaluar tanto en el método de ventanas aleatorias y secuenciales, optimizar el número de características y establecer un ROI adecuado con el fin de buscar el seguimiento en tiempo real.

10. BIBLIOGRAFÍA

- [1] S. Velipasalar, L. M. Brown, and A. Hampapur, "Detection of user-defined, semantically high-level, composite events, and retrieval of event queries," *Multimed. Tools Appl.*, vol. 50, no. 1, pp. 249–278, Mar. 2010.
- [2] S. Fefilatyeu, D. Goldgof, M. Shreve, and C. Lembke, "Detection and tracking of ships in open sea with rapidly moving buoy-mounted camera system," *Ocean Eng.*, vol. 54, pp. 1–12, Nov. 2012.
- [3] W.-C. Hu, C.-Y. Yang, and D.-Y. Huang, "Robust real-time ship detection and tracking for visual surveillance of cage aquaculture," *J. Vis. Commun. Image Represent.*, vol. 22, no. 6, pp. 543–556, Aug. 2011.
- [4] D. Roth, E. Koller-Meier, and L. Van Gool, "Multi-object tracking evaluated on sparse events," *Multimed. Tools Appl.*, vol. 50, no. 1, pp. 29–47, Sep. 2009.
- [5] Y. Lu and Z.-N. Li, "Automatic object extraction and reconstruction in active video," *Pattern Recognit.*, vol. 41, no. 3, pp. 1159–1172, Mar. 2008.
- [6] Z. Wang and F. Qi, "Analysis of multiframe super-resolution reconstruction for image anti-aliasing and deblurring," *Image Vis. Comput.*, vol. 23, no. 4, pp. 393–404, Apr. 2005.
- [7] S. Y. Choi and J. M. Lee, "Applications of moving windows technique to autonomous vehicle navigation," *Image Vis. Comput.*, vol. 24, no. 2, pp. 120–130, Feb. 2006.
- [8] C. Tenllado, J. I. Gómez, J. Setoain, D. Mora, and M. Prieto, "Improving face recognition by combination of natural and Gabor faces," *Pattern Recognit. Lett.*, vol. 31, no. 11, pp. 1453–1460, Aug. 2010.
- [9] W. Zou and P. C. Yuen, "Discriminability and reliability indexes: Two new measures to enhance multi-image face recognition," *Pattern Recognit.*, vol. 43, no. 10, pp. 3483–3493, Oct. 2010.
- [10] J.-L. Chen and H.-J. Lee, "Field data extraction for form document processing using a gravitation-based algorithm," *Pattern Recognit.*, vol. 34, no. 9, pp. 1741–1750, Sep. 2001.

- [11] D. J. Abel and R. Recio, "Técnicas de extracción de características y clasificación de imágenes orientada a objetos aplicadas a la actualización de bases de datos de ocupación del suelo," 2009.
- [12] N. D. Doulamis, "Coupled multi-object tracking and labeling for vehicle trajectory estimation and matching," *Multimed. Tools Appl.*, vol. 50, no. 1, pp. 173–198, Sep. 2009.
- [13] D. E. Imágenes, E. B. Raigal, T. Juan, and J. Pantrigo, "Aplicación del filtro de partículas al seguimiento de objetos en secuencias de imágenes.," 2003.
- [14] A. Doulamis, "Dynamic tracking re-adjustment: a method for automatic tracking recovery in complex visual environments," *Multimed. Tools Appl.*, vol. 50, no. 1, pp. 49–73, Sep. 2009.
- [15] L. S. Silva and J. Scharcanski, "Video segmentation based on motion coherence of particles in a video sequence.," *IEEE Trans. Image Process.*, vol. 19, no. 4, pp. 1036–49, Apr. 2010.
- [16] W. Wolf, "Hidden Markov model parsing of video programs," *1997 IEEE Int. Conf. Acoust. Speech, Signal Process.*, vol. 4, pp. 2609–2611, 1997.
- [17] G. Unal, A. Yezzi, and H. Krim, "Efficient Incorporation of Optical Flow into Visual Motion Estimation in Tracking," vol. 202, no. ii, pp. 167–202, 2005.
- [18] J. U. of E. Shutler, "Statistical moments - An introduction," *University of Edinburgh*, 2013. [Online]. Available: http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/SHUTLER3/node1.html.
- [19] M. K. Hu, "Visual Pattern Recognition By Moment Invariant," *IRE Trans. Inf. THEORY*, vol. 8, no. Moment Invariant, pp. 66–70, 1962.
- [20] OPENCV, "Hu moments." [Online]. Available: [http://docs.opencv.org/modules/imgproc/doc/structural_analysis_and_shape_descriptors.html?highlight=cvgethumoments#void_cvGetHuMoments\(CvMoments* moments, CvHuMoments* hu_moments\)](http://docs.opencv.org/modules/imgproc/doc/structural_analysis_and_shape_descriptors.html?highlight=cvgethumoments#void_cvGetHuMoments(CvMoments* moments, CvHuMoments* hu_moments)).
- [21] C. Chavarrias, S. M. Ieee, J. J. Vaquero, S. Member, A. Sisniega, M. Ieee, A. Rodriguez-ruano, M. L. Soto-montenegro, and M. Desco, "Validation of a retrospective respiratory gating method for small-animal CT scanners," pp. 4303–4305, 2008.

- [22] D. K. Park, Y. S. Jeon, C. S. Won, S. Park, and S. Yoo, "A Composite Histogram for Image Retrieval," vol. 00, no. c, pp. 355–358, 2000.
- [23] S. Lehar, "An Intuitive Explanation of Fourier Theory," pp. 1–9, 2010.
- [24] X.-Y. Wang, H.-Y. Yang, Y. Zhang, and Z.-K. Fu, "Image denoising using SVM classification in nonsubsampling contourlet transform domain," *Inf. Sci. (Ny)*, vol. 246, pp. 155–176, Oct. 2013.
- [25] F. Deboeverie, K. Teelen, P. Veelaert, and W. Philips, "Vehicle Tracking Using Geometric Features," pp. 506–515, 2009.
- [26] R. C. Gonzalez, R. E. Woods, and P. Hall, *Digital Image Processing*. .
- [27] G. (Universidad T. de C. Betancour, "LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs)," *Sci. Tech. Año XI, No 27, Abril 2005*, no. 27, pp. 67–72, 2005.
- [28] J. Xue, N. Zheng, J. Geng, and X. Zhong, "Tracking multiple visual targets via particle-based belief propagation.," *IEEE Trans. Syst. Man. Cybern. B. Cybern.*, vol. 38, no. 1, pp. 196–209, Feb. 2008.
- [29] X. Bai, F. Zhou, and B. Xue, "Discrimination ability improvement of invariant moment based on multi-scale mathematical morphology," *Opt. - Int. J. Light Electron Opt.*, vol. 124, no. 12, pp. 1314–1319, Jun. 2013.
- [30] G. R. Bradski, S. Clara, and I. Corporation, "Computer Vision Face Tracking For Use in a Perceptual User Interface," *Intel Technol. J.*, 1998.
- [31] M. Ariza-Avidad, M. P. Cuellar, a Salinas-Castillo, M. C. Pegalajar, J. Vuković, and L. F. Capitán-Vallvey, "Feasibility of the use of disposable optical tongue based on neural networks for heavy metal identification and determination.," *Anal. Chim. Acta*, vol. 783, pp. 56–64, Jun. 2013.
- [32] W. Kurdthongmee, "Colour classification of rubberwood boards for fingerjoint manufacturing using a SOM neural network and image processing," *Comput. Electron. Agric.*, vol. 64, no. 2, pp. 85–92, Dec. 2008.
- [33] F. Carlderón, "Clasificador por SVM," *SVM*, 2010. [Online]. Available: <http://opencvjaveriana.wikispaces.com/SVM>.
- [34] I. T. Note and M. Definition, "Internal Technical Note Metrics Definition," pp. 1–18.

- [35] H. Arguello, "Comparación de Huellas Dactilares Usando la Distancia Hausdorff," pp. 35–42, 2008.
- [36] D. P. Huttenlocher, G. a Klanderma, and W. J. Rucklidge, "Comparing images using the Hausdorff distance," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 15, no. 9, pp. 850–863, 1993.