

Fusión de sensores multispectrales para la detección y seguimiento de Objetivos usando cámaras móviles.

Luis D. López Gutiérrez

Departamento de Ciencias computacionales, Instituto Nacional de Astrofísica Óptica y Electrónica
Puebla, Puebla, C.P. 72840 México

y

Leopoldo Altamirano Robles

Departamento de Ciencias computacionales, Instituto Nacional de Astrofísica Óptica y Electrónica
Puebla, Puebla, C.P. 72840 México

RESUMEN

En este trabajo se presenta un método para la detección y seguimiento automático de múltiples objetivos que hace uso de secuencias de imágenes multispectrales.

El método propuesto consiste de 3 módulos (estimación, detección y fusión). En el primer módulo se estima el movimiento de la cámara seleccionando regiones de interés y determinando su movimiento en el tiempo.

El segundo módulo se extraen los objetivos móviles de las secuencias visible e infrarroja. En la secuencia en visible se utiliza la información del movimiento para extraer los objetivos; dicho movimiento es encontrado calculando los vectores de flujo óptico. Los objetivos móviles en la secuencia de imágenes infrarrojas son detectados determinando el fondo y restándose a la imagen original, la cual ha sido preprocesada para eliminar el movimiento de la cámara. El fondo se obtiene usando un modelo de mezclas Gaussianas para la clasificación de píxeles.

En el módulo de fusión, los resultados individuales de los sistemas de detección son combinados usando un método de votación ponderada "k de N".

Los resultados experimentales muestran que el sistema detecta el 97% de los barcos en la escena, mientras que en el bloque de fusión se eliminan el 80% de las falsas detecciones.

Palabras Claves: Fusión de sensores, Cámara móvil, Mezclas Gaussianas, Flujo Óptico.

1. INTRODUCCIÓN

La tarea de detectar y seguir objetivos automáticamente es un problema fundamental en el área de visión por computadora, estos sistemas tienen una gran importancia en aplicaciones militares, médicas, y de vigilancia entre otras. A pesar de la gran cantidad de trabajo desarrollado, la tarea de detectar objetivos con bajo contraste en ambientes con fondo dinámico, continúa siendo una tarea difícil de realizar. Esto es originado por una gran cantidad de factores, que en general se pueden clasificar en dos categorías:

Problemas originados por los sensores: los sistemas de detección automática que obtienen información de un sensor

manifiestan las limitantes del sensor en el desempeño del algoritmo.

Problemas originados por los algoritmos: los algoritmos de seguimiento tienen un buen desempeño en ambientes restringidos con condiciones de iluminación y de visibilidad controlados, pero sufren ante variaciones en la iluminación, ante el cambio de tamaño del objetivo originado por el movimiento con respecto al plano de la imagen. Asimismo, la mayoría de estos algoritmos están especializados hacia un dominio en particular, lo que origina que no obtengan los resultados esperados al implementarlos en dominios distintos.

Uno de los factores más críticos de cualquier sistema de detección automático es encontrar un compromiso aceptable entre la probabilidad de detección y el número de falsas alarmas. Entre estos dos tipos de errores se pueden generar falsos rechazos (FR: que corresponde a perder el objetivo) y las admisiones falsas (FA: el caso donde no hay objetivos, pero el sistema detecta algo). En un sistema de detección con un sensor es bien conocido que si se reduce un tipo de error se incrementa el otro tipo. Una forma para resolver este problema es usar más de un sensor y combinar la información obtenida de los distintos "expertos", esta combinación o fusión de datos puede realizarse en más de un nivel. En este artículo se propone un método para resolver el problema de detección y seguimiento de barcos usando fusión a nivel decisión, el sistema creado ha sido probado con secuencia de imágenes obtenidas de sensores montados en plataformas marítimas móviles.

Las secciones del artículo se distribuyen de la siguiente manera: En la sección 2 se proporciona una breve introducción sobre las técnicas usadas. En la sección 3 se muestran los bloques del sistema propuesto. Las secciones 4, 5, 6, y 7 entran en detalle sobre la implementación de los modelos usados en cada bloque. Posteriormente se muestran los resultados obtenidos y las conclusiones realizadas.

2. MARCO TEORICO

Flujo Óptico

El flujo óptico representa el campo de movimiento 2-D resultado de la proyección de las velocidades de los puntos tridimensionales, correspondientes a las superficies de una

escena, sobre el plano visual del sensor [1,2], el conocimiento preciso sobre el flujo óptico en una secuencia temporal de imágenes nos puede aportar gran cantidad de información sobre la escena que la ha generado, por lo que su gama de aplicación resulta muy variado: interpretación de escenas, compresión de video, estimación del movimiento del observador, sistemas automáticos de navegación, vigilancia automática, entre otras.

Si bien, recientes estudios [3] integran la contribución de los fenómenos radiométricos como punto de partida para medir el flujo óptico, la hipótesis más común empleada en la actualidad tiene un origen puramente geométrico, propuesta inicialmente por Horn y Schunck, esta hipótesis supone que las estructuras de intensidad presentes en la imagen, a nivel local, se mantienen aproximadamente constantes a lo largo del tiempo.

Formalmente, si $\mathbf{Int}(x,y,t)$ representa la intensidad de la imagen en un punto (x,y) en una imagen al tiempo t , y si se mueve ese punto a $\mathbf{Int}(x+dx, y+dy)$ al tiempo $t+dt$, se obtiene la relación:

$$\mathbf{Int}(x, y, t) = \mathbf{Int}(x + dx, y + dy, t + dt) \quad (1)$$

Usando una expansión de Taylor para resolver (1)

$$\mathbf{Int}(x,y,t) = \mathbf{Int}(x,y,t) + \mathbf{Int}_x(x,y,t) dx + \mathbf{Int}_y(x,y,t) dy + \mathbf{Int}_t(x,y,t) dt + \epsilon \quad (2)$$

Donde:

$$\mathbf{Int}_x = \frac{\partial I}{\partial x}, \mathbf{Int}_y = \frac{\partial I}{\partial y}, \mathbf{Int}_t = \frac{\partial I}{\partial t}, \epsilon \text{ es el conjunto de términos de orden 2 y superiores.}$$

Si se asume que $\epsilon \approx 0$ entonces se desprecian estos términos obteniendo la Ec. (3)

$$\mathbf{Int}_x u + \mathbf{Int}_y v + \mathbf{Int}_t = 0. \quad (3)$$

Donde:

$$u = \frac{dx}{dt}, v = \frac{dy}{dt}, (u, v) \text{ representa el vector de flujo en cada punto.}$$

La Ec. (3) representa la restricción para el cálculo del flujo óptico. Debido a que solo se dispone de una ecuación para estimar dos variables, el cálculo del flujo óptico constituye un problema mal-definido, por lo que es necesario añadir conocimiento adicional para estimarlo.

Segmentación del movimiento

La segmentación del movimiento también es conocida como segmentación espacio-temporal (SET) explota la información espacial y temporal que contienen las secuencias de imágenes para extraer el fondo y los objetos con movimiento independiente, las dimensiones espaciales y temporales pueden ser tratadas separadamente o de forma simultánea. Estas técnicas tratan de resolver el problema de sobre-segmentación, y los problemas de sensibilidad e inexactitud originada por el ruido en la imagen. La información sobre el movimiento de la cámara y los objetos con movimiento independiente pueden ser calculados usando alguno de los algoritmos para estimar el flujo óptico en la imagen. La eficiencia en las regiones encontradas se limita a la exactitud del flujo óptico encontrado. La SET se clasifica en 3 categorías [4]:

Segmentación con prioridad espacial, este grupo de técnicas se centra en la segmentación espacial de cada imagen en la secuencia. Los grupos espacio-temporales son obtenidos como la extensión en el tiempo de los segmentos espaciales.

Segmentación por agrupamiento de trayectorias, este grupo de técnicas realizan un agrupamiento temporal, realizando el seguimiento de características discretas con el objetivo de extraer sus trayectorias. Las trayectorias que pertenezcan al mismo objeto se agrupan espacialmente usando segmentación de movimiento.

Segmentación conjunta espacial y temporal, este grupo elimina la preferencia por alguna dimensión (espacial o temporal). Estos métodos definen criterios de agrupación usando información simultáneamente en el espacio y en el tiempo. Altun-basak [5] realiza la segmentación estimando el movimiento de la imagen usando modelos polinomiales paramétricos, posteriormente combina la segmentación del movimiento, la asignación de etiquetas a los píxeles y los parámetros del modelo paramétrico.

Mezclas Gaussianas

Los modelos probabilísticos son un tipo de modelo de densidad los cuales comprenden a un número de funciones componentes, usualmente Gaussianas. Estas funciones componentes se combinan para generar una función de densidad multimodal [10]. La idea principal de modelar el fondo es mantener un modelo estadístico evolutivo del fondo, que se adapte a cambios en la escena. Existen dos tipos de modelos del fondo:

Modelo unimodal, en el que cada píxel es modelado con una sola distribución de probabilidad estadística $\eta(X, \mu_t, \Sigma_t)$, donde X es el valor del píxel en la posición (x,y) , μ_t y Σ_t son el valor medio y la matriz de covarianza respectivamente de la distribución en la imagen al tiempo t . Los píxeles cuyo valor es cercano a la distribución del fondo se clasifican como puntos del fondo, mientras que aquellos que están alejados se toman como puntos del primer plano, el valor de la distribución Gaussiana se encuentra usando la Ec. (4).

$$\eta(X_t, \mu, \Sigma) = \frac{1}{(2\pi)^{n/2} |\sigma|^{0.5}} e^{-0.5(X_t - \mu_t)^T \sigma^{-1} (X_t - \mu_t)} \quad (4)$$

Modelo multimodal, en donde es necesario mezclar k distribuciones independientes para modelar cada píxel. A cada distribución se le asigna un peso que representa su prioridad. Un píxel se clasifica como un punto del fondo si su valor concuerda con una de las distribuciones del fondo. Si ninguna de las distribuciones concuerda con el valor del píxel se puede crear una nueva distribución en el modelo del fondo, en un modelo multimodal la probabilidad de observar el valor actual del píxel esta dado por:

$$P(X_t) = \sum_{i=1}^K \pi_{i,t} * \eta(X_t, \mu_{i,t}, \Sigma_{i,t}) \quad (5)$$

Donde $\pi_{i,t}$ es el peso asignado a la distribución i .

Fusión de información

La fusión de información se define como el proceso de integrar información de múltiples fuentes para producir información unificada más específica y comprensiva sobre una entidad, actividad o evento [6].

La fusión de datos y sensores tienen una gran cantidad de aplicaciones, entre las que se encuentran el monitoreo, control de tráfico vehicular, clasificación y seguimiento de objetivos militares, entre otros.

Los procesos para la fusión se clasifican como fusión a nivel bajo, medio y alto [6], dependiendo de la etapa de procesamiento en la que se realiza la fusión.

Fusión a bajo nivel, también llamada fusión de datos usa la información de los píxeles de un conjunto de imágenes para generar una nueva imagen que contiene los datos más relevantes. Típicamente, imágenes que presentan varias bandas del espectro electromagnético de la misma escena se fusionan para producir una nueva imagen que idealmente contiene en un solo canal la mayoría de la información disponible en el conjunto de imágenes.

Fusión a nivel intermedio, también llamada fusión de características, en esta etapa se combinan características obtenidas de varias fuentes de información, o de la misma fuente usando distintas técnicas de extracción de información. Los métodos de fusión de características incluyen el análisis de componentes principales (PCA) y Perceptrones multi-capas (MLP) entre otros.

Fusión de alto nivel, también llamada fusión de decisiones, en esta etapa se combinan las decisiones tomadas por varios expertos. Estos métodos incluyen, métodos de votación, métodos estadísticos, métodos basados en lógica difusa, y métodos de aprendizaje automático.

3. MÉTODO PROPUESTO

La figura 1 muestra el diagrama a bloques del método propuesto para la detección automática de objetivos. La arquitectura consiste de tres módulos independientes: estimación del movimiento de la cámara, detección de los objetivos móviles y fusión de resultados individuales. Este método fue evaluado usando secuencias de imágenes multiespectrales que contienen dos tipos de movimientos, el movimiento originado por los objetivos y el movimiento causado por la cámara.

La secuencia de imágenes en visible fue capturada mediante un sensor a color DFK4003 con resolución de 640x480 y zoom de 8-108 mm. La secuencia de imágenes en infrarrojo fue capturada mediante un sensor Puma2, que opera en la región de 7 a 14 μm del espectro electromagnético con una lente de 100 mm con resolución 640x480; ambas secuencias fueron digitalizadas usando el canal de información gris (valor del píxel de 0 a 255), mediante dos Frame Grabbers DFG/LC1.

La figura 2 muestra imágenes de la secuencia "Lancha" esta secuencia contiene un escenario marítimo en donde están presentes el movimiento de la cámara, el movimiento de la plataforma móvil en donde se encuentra montado el sistema de cámaras, el movimiento de la lancha y además cuenta con la complejidad del movimiento del mar.

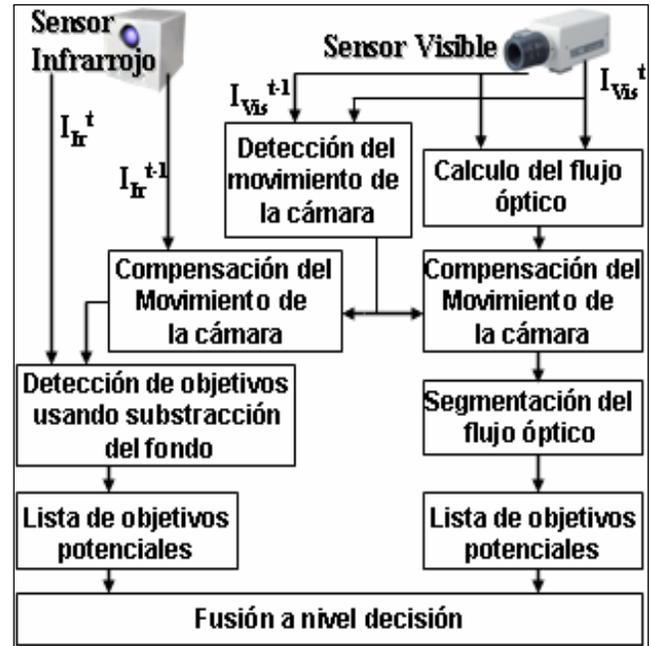


Figura 1. Arquitectura Propuesta.

La figura 3 muestra imágenes de la secuencia "Podadora" esta secuencia contiene un escenario terrestre en donde la cámara permanece estática, por lo que el único movimiento presente es de los objetivos que se desplazan de derecha a izquierda en la escena.

El movimiento de la cámara se estima seleccionando N características en la imagen en visible al tiempo t (I_t), determinando el desplazamiento de estas características en la imagen al tiempo $t+1$ (I_{t+1}) se estima el movimiento en la imagen originado por la cámara.

Los objetivos en la secuencia infrarroja se detectan mediante un método probabilístico basado en la detección que los píxeles que pertenecen al fondo.

Los objetivos en la secuencia en visible se detectan usando un método de segmentación espacio-temporal, donde como paso previo se debió detectar el vector de flujo óptico en la imagen.

Cada parte de los dos métodos de detección descritos anteriormente son considerados "expertos", que indican la posible presencia de objetivos móviles en la escena. La fusión a nivel de decisión es usada en la última etapa para combinar los resultados individuales usando un método estadístico.



a) Secuencia visible a $t=0$

b) Secuencia visible a $t=150$



c) Secuencia infrarroja a t=0 d) Secuencia infrarroja a t=150
 Figura 2. Secuencias de imágenes “Lancha”.



a) Secuencia visible a t=0 b) Secuencia visible a t=150



c) Secuencia infrarroja a t=0 d) Secuencia infrarroja a t=150
 Figura 3. Secuencias de imágenes “Podadora”.

4. ESTIMACIÓN DEL MOVIMIENTO DE LA CÁMARA

Las entradas al sistema son secuencias de imágenes multispectrales con dos tipos de movimiento: el movimiento originado por los objetivos, y el causado por el movimiento de la cámara. Dado que estos dos movimientos se encuentran combinados en las imágenes, se debe determinar el movimiento de la cámara, para poder obtener el movimiento originado solo por los objetivos móviles.

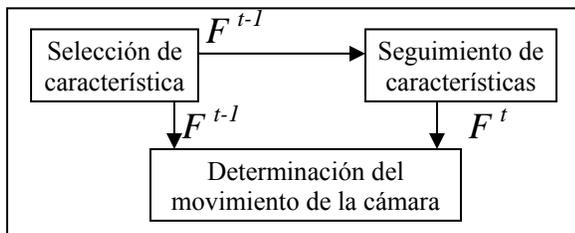


Figura 4. Detección del movimiento de la cámara

El movimiento de la cámara se estima seleccionando un conjunto de características (F_{t-1}) en la imagen al tiempo t-1, y obteniendo la posición de cada elemento del conjunto en la siguiente imagen (F_t). Una vez que la correspondencia entre los elementos de F_{t-1} y F_t son conocidos, el movimiento de la cámara se estima usando un modelo estadístico, estos procesos se muestran gráficamente en la figura 4.

Selección de características

El algoritmo adoptado para la selección de características esta basado en el método de Tomasi-Kanade[7,8]. El proceso para la selección de características es como sigue:

1. Se realiza un filtrado Gaussiano para eliminar el ruido en la imagen.
2. Se calcula la primera derivada, obteniendo las matrices que contienen a los gradientes x, y.
3. Usando los gradientes obtenidos en el paso anterior se crea la matriz simétrica Z, por píxel

$$Z_{ij} = \begin{bmatrix} g_x^2 & g_y g_x \\ g_x g_y & g_y^2 \end{bmatrix} \quad (6)$$

4. Se calculan los eigenvalores de la matriz Z.
5. Usando una función de distancia se rechazan los máximos locales.
6. Se rechazan los píxeles cuyo eigenvalor mínimo sea menor que un umbral.

Seguimiento de características

El seguimiento de características se basa en el método propuesto por Lucas-Kanade [9] este algoritmo determina la posición de las características (f_{t-1}) en la siguiente imagen (I_t), obteniendo su correspondiente conjunto de características (f_t). Los procesos necesarios para realizar el seguimiento son los siguientes:

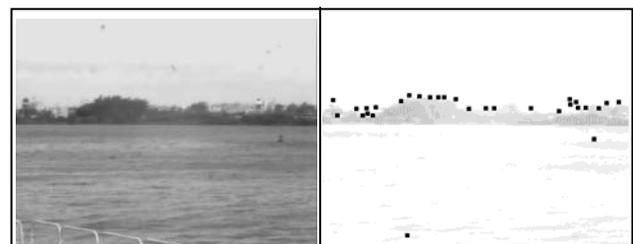
1. Construir una imagen piramidal.
2. Estimar el desplazamiento en el nivel más bajo.
3. Iterar hasta el nivel más alto.

Determinación del movimiento de la cámara

Debido a que los movimientos de las características varían de acuerdo a la profundidad y a la perdida de características en el tiempo, el desplazamiento varía en cada elemento del conjunto de características.

Se diseñó un modelo estadístico para estimar el movimiento real de la cámara, este modelo obtiene la media μ y la desviación estándar σ^2 de los desplazamientos. Se usó un método de mínimos cuadrados de nivel cero (recta) que minimice el cuadrado de las diferencias. Debido a que un valor que se aleje de la media de los datos puede desplazar la recta obtenida significativamente, se valida que la desviación estándar no sea mayor que un umbral predefinido, en caso contrario se eliminan los datos que estén fuera de 0.75 sigmas, y se obtiene un promedio de los valores.

La figura 5.b muestra las características obtenidas por el método. En la figura 6 se muestra el seguimiento de las características en distintos tiempos.



a) Imagen original b) Características extraídas
 Figura 5. Resultado de la selección de características.

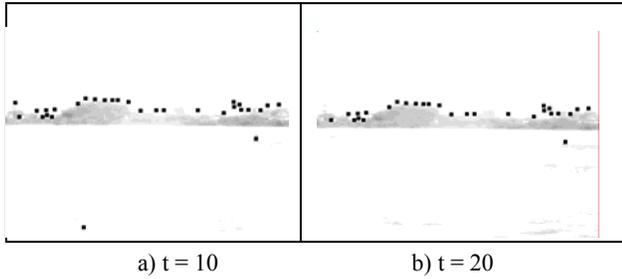


Figura 6. Seguimiento de características en el tiempo.

5. DETECCIÓN DE OBJETIVOS EN LA SECUENCIA EN VISIBLE

Los procesos para detectar objetivos móviles en la secuencia de imágenes en visible se muestran gráficamente en la figura 7.

Los vectores de movimiento en la imagen se determinan usando el algoritmo propuesto por Horn y Schunk [2]. Este algoritmo genera un vector que contiene la información sobre el desplazamiento de los objetos en la escena.

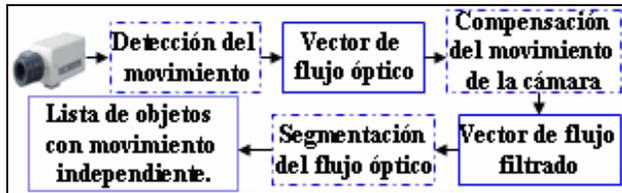
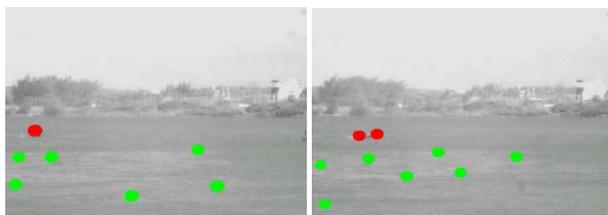


Figura 7. Procesos para detectar objetivos en la secuencia en visible.

Los efectos que el movimiento de la cámara producen al vector de flujo óptico se compensan restando el vector de desplazamiento de la cámara obtenido en el bloque anterior al vector de flujo en cada píxel de la imagen; Este proceso genera un vector de flujo reducido, que solo contiene el movimiento originado por los objetivos móviles.

El vector de flujo reducido se procesa para encontrar grupos disjuntos, donde cada grupo representa un objetivo. Este proceso es similar a la implementación realizada en [11] para segmentar el vector de flujo óptico.

El resultado final de estos procesos es una lista que contiene información sobre los objetivos en movimiento como es el tamaño, área, centro, y velocidad.



a) Secuencia lancha en t=0. b) Secuencia lancha en t=150



c) Secuencia podadora en t=0 d) Secuencia podadora en t=150

Figura 8 Detección de objetivos en la secuencia en visible.

6. DETECCIÓN DE OBJETIVOS EN LA SECUENCIA INFRARROJA

Los objetivos móviles en la secuencia de imágenes infrarrojas se detectan usando un modelo probabilístico que determina la región de la imagen que pertenece al fondo, donde cada píxel es modelado usando una mezcla de distribuciones Gaussianas que son descritas en la sección 2.

Compensación del movimiento de la cámara

Usando el vector de desplazamiento de la cámara, se compensa este movimiento en la imagen I_t usando un modelo de transformación donde para cada píxel $X = (x,y)$:

$$I_c(x, y) = I_t(x - v_x, y - v_y) \quad (7)$$

Donde v_x, v_y es el desplazamiento obtenido por la cámara.

Detección del fondo

Las mezclas Gaussianas clasifican cada píxel de la imagen como perteneciente al fondo o a un objetivo usando un conjunto de modelos probabilísticas [10], usando un método en línea para actualizar los modelos, en cada imagen se evalúan los píxeles para determinar su clase, el modelo del fondo se adapta de forma distinta a los píxeles del primer plano, píxeles estáticos, y a los píxeles del fondo, permitiendo de esta forma que el modelo se adapte a cambios en el fondo y detectando de forma robusta a los objetos móviles. Los pasos que se realizan para detectar objetivos móviles son:

Inicialización de los modelos: en la inicialización se determinan los valores estadísticos válidos para los píxeles en la primera imagen de la secuencia. Cada píxel $X = (x; y)$ es considerado como una mezcla de 3 distribuciones normales como se muestra en la Ec. (8).

$$X \approx \sum_1^3 \pi_i * \eta(\mu_i, \Sigma) \quad (8)$$

Donde $\sum \pi = 1$.

Estimación del fondo: en la estimación del fondo se realizan los siguientes procesos:

1. Se ordenan las distribuciones existentes usando el valor del peso asignado a cada distribución entre la varianza de la distribución (π / σ).

2. Se seleccionan las distribuciones cuyo peso sea mayor a un umbral predeterminado, las distribuciones seleccionadas son consideradas como elementos del fondo, mientras que las restantes pertenecen al primer plano.

- Se verifica la pertenencia de los píxeles a las distribuciones seleccionadas.
- Se actualizan las distribuciones basados en la pertenencia de cada distribución. Donde si una distribución no modela ningún píxel entonces es reemplazada con una nueva.

La figura 9 muestra los resultados obtenidos por el método de detección de barcos en la secuencia de imágenes infrarrojas.

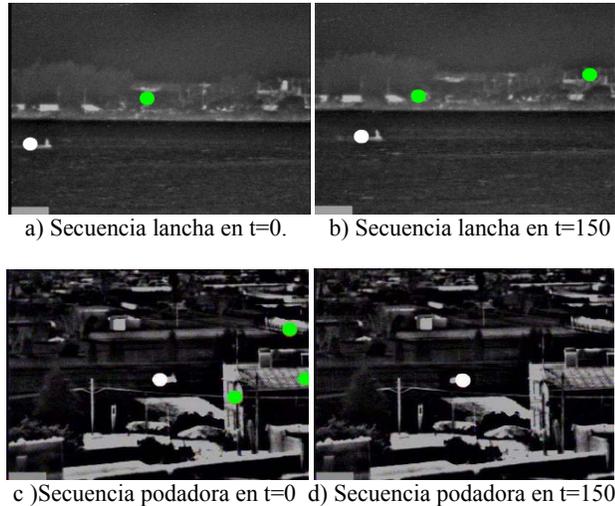


Figura 9 Detección de objetivos en la secuencia infrarroja.

7. FUSIÓN DE DECISIONES

Los algoritmos de detección automática en la secuencia visible e infrarroja son considerados como expertos, estos algoritmos indican la posible posición de los barcos presentes en la escena. La decisión final sobre las regiones en las que se encuentran los objetivos se realiza fusionando los resultados de estos expertos. Debido a que cada experto proporciona solo una decisión binaria en la que se indica si un barco se encuentra o no, la fusión de decisión se implemento como un sistema de votación pesada “K de N” [12-13].

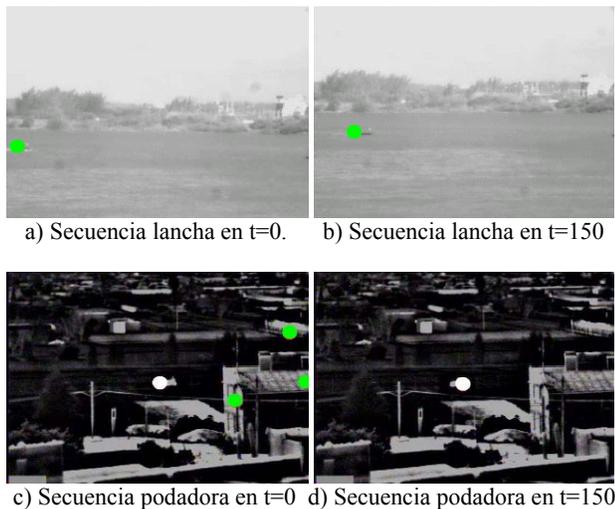


Figura 10 Detección de objetivos después de la fusión.

Las figuras 10.a y 10.b muestran gráficamente los resultados obtenidos usando la fusión a nivel decisión en la secuencia “Lancha”, mientras que en las figuras 10.c y 10.d se muestran los resultados en la secuencia “Podadora”, en estas imágenes se despliega un círculo por cada detección asociada con la ruta del objetivo. Estos resultados se presentan de forma numérica en la tabla 3.

8. RESULTADOS

Los resultados en la detección automática de objetivos usando segmentación espacio-temporal han sido agrupados de acuerdo al tipo de experimento realizado. Las imágenes que se muestran en la figura 8.a y 8.b corresponden a la evaluación de los resultados usando la secuencia “lancha”, mientras que las imágenes 8.c y 8.d corresponden a los resultados obtenidos usando la secuencia “Podadora”. Con el fin de ilustrar la trayectoria los objetos detectados y el desempeño del algoritmo de detección en cada imagen se despliega un rectángulo alrededor del centro del objeto detectado. Los falsos objetivos se muestran en color gris, mientras que las detecciones correctas muestran en color negro.

Los resultados en la detección automática de objetivos usando modelos probabilísticos se muestran en la figura 9. Las imágenes 9.a y 9.b corresponden a la evaluación de los resultados usando la secuencia “Lancha”, mientras que las imágenes 9.c y 9.d corresponden a los resultados obtenidos usando la secuencia “Podadora”.

La tabla 2 muestra los resultados experimentales obtenidos en las secuencias de imágenes visible e infrarroja, la tercera columna de la tabla “T. de P.” representa el tiempo de procesamiento requerido para procesar un par de imágenes, la cuarta columna muestra la probabilidad de detección, este valor es obtenido dividiendo las detecciones realizadas por el método entre el total de objetivos, finalmente la columna “No. de F.D.” muestra el número promedio de falsas detecciones obtenido por imagen.

Sensor	Tipo de secuencia	Tamaño	Objetivos	Imágenes
VIS	Real	640 x 480	1	500
FLIR	Real	640 x 480	1	500

Tabla 1 Características de las secuencias usadas.

Secuencia	Sensor	T. de P.	P.D.	No. F.D.
Podadora	Visible	0.7 Seg.	98 %	1.3
	Infrarrojo	0.4 Seg.	99%	0.5
Lancha	Visible	0.9 Seg.	97 %	6.3
	Infrarrojo	0.4 Seg.	99%	0.5

Tabla 2 Resultados de la detección por sensor

En la tabla 3 se muestran los resultados después de la fusión, en esta tabla se puede observar que la probabilidad de detectar objetivos se conserva con respecto al mejor resultado individual, y la cantidad de falsos objetivos es reducida en un 80%.

Secuencia	T. de P.	Detección (%)	Falsos objetivos
Podadora	1.3 Seg.	100	0.6
Lancha	1.5 Seg.	99	0.8

Tabla 3 Resultados de la detección usando fusión

9. CONCLUSIONES

En este artículo se presenta un método para la detección automática de barcos usando secuencias de imágenes multispectrales.

El algoritmo desarrollado consta de tres módulos. En el primer modulo se detecta el movimiento de la cámara, representado por vectores de desplazamiento en x y. En el segundo modulo se compensa el movimiento de la cámara encontrado en el primer modulo, y se detectan los objetivos presentes en la escena; Usando segmentación de flujo óptico para la secuencia de imágenes en visible, y usando un modelo Gaussiano probabilístico del fondo en la secuencia infrarroja. Ambos algoritmos de segmentación se consideran expertos, e indican la presencia de barcos y su posición. La decisión final del sistema se realiza fusionando las decisiones tomadas por estos expertos. Debido a que la información a ser fusionada es binaria, la fusión de decisión se basa en reglas de votación pesadas "k de N". El método desarrollado ha demostrado robustez ante cambios en las condiciones atmosféricas, y ante cambios en la iluminación.

10. REFERENCIAS

- [1] R. Jain, R. Kasturi, B. Schunck, **Machine Vision**, McGraw-Hill 1995.
- [2] Horn B., Schunck B. **Determining optical flow**, Artificial Intelligence Vol. 17, 1981, pp 185-204.
- [3] S. Beauchemin, J. Barron, **The Computation of Optical Flow**, ACM Computing Surveys, Vol. 27, No. 3, pp433-467, Sept 1995.
- [4] Galic and S. Loncaric, **Spatio-temporal image segmentation using optical flow and clustering algorithm**, Proceedings of the First Int. Workshop on Image and Signal Processing and Analysis, pp. 63-68, Pula, Croatia, 2000.
- [5] Megret R., DeMenthon D, **A Survey of Spatio-temporal Grouping Techniques**, Algorithms and Hardware Technology for Image Recognition, University of Maryland TR4403. August 2002.
- [6] E. Waltz and J. Llinas, **Handbook of Multisensor data fusion**, CRC Press LLC, 2001.
- [7] Jianbo S, Tomasi C. **Good Features to Track**, IEEE Conference on computer Vision and Pattern Recognition, Seattle, June 1994.
- [8] Tomasi C., Kanade T. **Detection and Tracking of Point Features**, CMU-CS-91-132. April 1991.
- [9] Lucas B, Kanade T. **An iterative Image Registration Technique with an Application to Stereo Vision**, Proceedings of Imaging Understanding Workshop, pp 121-130 (1981).
- [10] C. Stauffer, W. E. L. Grimson, **Learning patterns of activity using real time tracking**, IEEE trans. PAMI, vol 22, no. 8, pp 747-757, Aug, 2000.
- [11] D. Zhang, G. Lu, **Segmentation of Moving Objects in Image Sequence**, Circuits, Systems and Signal Processing, No. 20, Vol. 2 2001, pp 143-183.
- [12] Dasarthy, **Decision Fusion**, IEEE Computer Society Press, 1994.
- [13] G. Girija et al, **Tracking filter and multi-sensor data fusion**, Sadhana, Vol 25, Part 2, april 2000, pp 159-167.