

## **RASTREAMIENTO VISUAL CON FILTRO DE PARTÍCULAS: MUESTREO HÍBRIDO, UN ABORDAJE PARA MEJORAR LA ROBUSTEZ EN ENTORNOS CON OCCLUSIÓN Y FONDOS SATURADOS**

Recibido: 02-03-2018 / Revisado: 20-03-2018 /

Aceptado: 15-06-2018

Diego Antonio Legarda Córdoba  
Universidad de Boyacá – Colombia

Revista UTEPSA Investiga

[dalegarda@uniboyaca.edu.co](mailto:dalegarda@uniboyaca.edu.co)

Karen Viviana Pérez Lujan, Universidad de Brasilia

Revista UTEPSA Investiga

[kperezlujan@gmail.com](mailto:kperezlujan@gmail.com)

Augusto Bimberto Suarez Parra  
Universidad de Boyacá- Colombia

Revista UTEPSA Investiga

[augustosuares@uniboyaca.edu.co](mailto:augustosuares@uniboyaca.edu.co)

Carlos Ramírez Martín,  
Universidad de Boyacá,- Colombia

Revista UTEPSA Investiga

[cramirez@uniboyaca.edu.co](mailto:cramirez@uniboyaca.edu.co)

## **RESUMEN**

La oclusión y los entornos saturados representan desafíos reales para métodos de rastreamiento visual. Con el objetivo de incrementar la robustez en estas situaciones, este artículo presenta un método de rastreamiento visual, usando el filtro de partículas con muestreo híbrido. La propuesta emplea un filtro de partículas para estimar el estado del objeto rastreado; la inercia de las partículas y la información de actualización son usadas en el estado de muestreo. El método propuesto es testado usando una base de datos pública y los resultados son comparados con otros algoritmos de rastreo. Estos resultados muestran que la propuesta tiene un mejor desempeño en ambientes saturados, así como también en situaciones con oclusiones parciales o totales.

## **PALABRAS CLAVE**

Rastreamiento visual, filtro de partículas, muestreo híbrido, oclusión, entornos saturados

## **ABSTRACT**

Occlusions and cluttered environments represent real challenges for visual tracking methods. In order to increase robustness in such situations this article presents a method for visual tracking using a Particle Filter with Hybrid Resampling. Our approach consists of using a particle filter to estimate the state of the tracked object, and both particles' inertia and update information are used in the resampling stage. The proposed method is tested using a public benchmark and the results are compared with other tracking algorithms. The results shows that our approach performs better in cluttered environments, as well as in situations with total or partial occlusions.

## **KEYWORDS**

Visual tracking, particle filter, hybrid sampling, occlusions, cluttered environments

## INTRODUCCIÓN

El rastreamiento visual de objetos representa un importante problema en el área de visión computacional, por la cantidad de aplicaciones envueltas y su grado de complejidad (Alper Yilmaz, Javed, & Shah, 2006). Ejemplos de estas aplicaciones pueden ser descritas desde tareas en robótica móvil, medicina, automatización de procesos industriales (Chang & Lie, 2012) hasta aplicaciones tradicionales como vigilancia (Xiang, 2011), (Weina Ge, Robert T. Collins, & Ruback, 2012) y monitoreo de tráfico (Guolin Wang *et al.*, 2008). A pesar del éxito en este campo activo de investigación, aun es difícil hacerle frente a cambios de apariencia complicados, causados por fondos desorganizados, cambios de iluminación, variación de escala, deformación, rotaciones y oclusiones (Li *et al.*, 2013).

En las propuestas de rastreamiento visual usando filtros estocásticos, el proceso de rastreamiento es tratado como un problema de precisión en la estimación de la posición actual de un objeto, a partir de observaciones aplicando un modelo de distribución estocástica (Chen, 2003). Con el incremento de la capacidad computacional y mejoras en las metodologías probabilísticas, como el filtro de Kalman (MacCormick & Isard, 2000), Filtro de Partículas (Vidal, Cordoba, Zagherro, & Koike, 2014), Cadenas de Markov (Chen, 2003), entre otras; hacen del rastreamiento visual un área de gran interés y fuertes avances en términos de robustez, precisión y respuesta en el tiempo de las metodologías.

El filtro de partículas es considerado una buena alternativa para ser usada en rastreamiento visual, debido a su respuesta para sistemas multimodales no lineales, comparada con métodos basados en el método de Monte Carlo (Hastings, 2007). Recientemente, en el campo de los modelos estocásticos, muchas metodologías pueden ser encontradas en la literatura. Por ejemplo, en el trabajo de Imtiaz *et al.* (Imtiaz, Roy, Huang, Shah, & Jampana, 2006), configura una representación muy dispersa, con la adición de información espacial en cada división del modelo. En la propuesta presentada en (Nieto, Cortés, Otaegui, Arróspide, & Salgado, 2016), se utiliza una combinación de un filtro de partículas (Arulampalam, Maskell, Gordon, & Clapp, 2002) con un filtro de Kalman (Erik Cuevas, Daniel Zaldivar, & Rojas, 2005); para alterar la estructura de la imagen, apoyado por el filtro de Kalman, el modelo de movimiento del rastreamiento es mejorado.

En el trabajo presentado por Zhou y Li. (Zhou, Zhou, & Li, 2016), un filtro de partículas presenta un comportamiento híbrido, con una representación muy dispersa del objeto y del entorno. Esto hace posible que se obtenga una información global y una información local para generar el modelo de movimiento. En (Iswanto & Li, 2017), el algoritmo *mean-shift* es combinado con los filtros de Kalman y de partículas, en los momentos cuando no existe oclusión, el *mean-shift* toma el control del rastreamiento; la combinación de los filtros de Kalman y de Partículas actúa estimando el movimiento del objeto cuando se presenta una oclusión.

Cuando se aplica el filtro de partículas en rastreamiento visual, la ocurrencia de una oclusión puede causar la desviación de las partículas hacia una región errada en la imagen. Como resultado, el estado de muestreo genera un gran impacto en la robustez del algoritmo de rastreamiento visual empleando el filtro de partículas.

En el presente trabajo, se propone el uso de un filtro de partículas asociado con la estrategia de muestreo híbrido, como una respuesta robusta y precisa frente a diferentes escenarios de rastreamiento visual. Este artículo está estructurado de la siguiente forma: inicialmente se discute sobre el filtro de partículas basado en color. A continuación, son introducidos los detalles del método de rastreamiento propuesto. Posteriormente, se presentan los resultados experimentales y; finalmente, se enuncian las conclusiones y trabajos futuros.

### Filtro de partículas basado en color

El filtro de partículas es una poderosa y flexible técnica de estimación para aplicaciones no lineales. De acuerdo a (Kennedy & Eberhart, 1995), el filtro de partículas está basado en simulación y – usualmente– es aplicada la estimación por modelos bayesianos, donde todas las variables son conectadas a través de cadenas de Markov. La idea central es obtener una representación aproximada de la función de distribución *a posteriori* usando un conjunto de muestras con pesos asociados.

Sea  $\{f_k^i, w_k^i\}$  para  $\{i = 0: N_s\}$  un conjunto de medidas que describen una función de probabilidad *a posteriori*.  $N_s$  es el número de muestras.  $p(x_k^i | y_k)$ , donde  $x_k$  es un set de puntos de soporte con pesos asociados  $w_k^i$ . El vector de estado  $x_k$  es el set de todos los estados al tiempo  $k$ . El vector de observaciones  $y_k$  es el set de todas las medidas al tiempo  $k$ . Los pesos son normalizados por  $\sum_{i=1}^{N_s} w_i = 1$  obtenida a partir de las observaciones del estado en el tiempo  $k$ .

$$p(x_k | y_k) \approx \sum_{i=1}^{N_s} w_k^i \delta(x_k - x_k^i) \quad 1$$

La técnica de muestreo por importancia asegura que se puede construir un estimador de cada  $x_j^i$  y el peso de las muestras es calculado de acuerdo a las ecuaciones 2 y 3, como sigue:

$$x_j^i \propto q(x_k^i | x_{k-1}^i, y_k^i) \quad 2$$

$$w_k^i \propto w_{k-1}^i \frac{p(y_k | x_k^i) p(x_k | x_{k-1}^i)}{q(x_k^i | x_{k-1}^i, y_k^i)} \quad 3$$

La distribución  $q(x_k^i | x_{k-1}^i, y_k^i)$  es llamada densidad de importancia. Una buena elección de esta distribución puede ser definida como  $q(x_k^i | x_{k-1}^i, y_k^i) = p(x_k | x_{k-1}^i)$ ; entonces, la ecuación 3 puede ser simplificada como:

$$w_k^i \propto w_{k-1}^i p(y_k | x_k^i) \quad 4$$

Un problema común con el filtro de partículas es el efecto de la degeneración, como es explicado en (M. Sanjeev Arulampalam, Simon Maskell, Neil Gordon, & Clapp, 2002). Este efecto produce un conjunto en donde unas pocas partículas dominan al resto de las partículas con sus pesos. Esto significa que la estimación obtenida podría perder precisión y tener grandes valores de desviación. Con el objetivo de resolver este inconveniente, se puede estimar el número efectivo de muestras según la ecuación:

$$\widehat{Neff} = \frac{1}{\sum_{i=1}^{N_s} (w_k^i)^2} \quad 5$$

### Remuestreo

El proceso de muestreo elimina las partículas con poco peso. Este grupo de partículas es reemplazado por otras con más alto peso, que define otro set de muestras con una mejor representación discretizada:

$$p(x_k|y_k) \approx \sum_{i=1}^{N_s} w_k^i \delta(x_k - x_k^i) \quad 6$$

El resultado del proceso de remuestreo es un nuevo set de partículas con peso uniforme  $1/N_s$ , con  $N_s$  como el número total de partículas.

### METODOLOGÍA

En esta sección se expondrá de forma detallada el método de rastreamiento. Inicialmente, se considera que el objeto es reconocido y diferenciado por el modelo de descriptores. Los cambios del estado del objeto en cuadros secuenciales son suaves y estimados como un comportamiento inercial. La propuesta usa el muestreo híbrido, asegurando la predicción del movimiento del objeto. En la Figura 1 se expone el diagrama de bloques de la metodología de rastreamiento propuesta (FPAH).

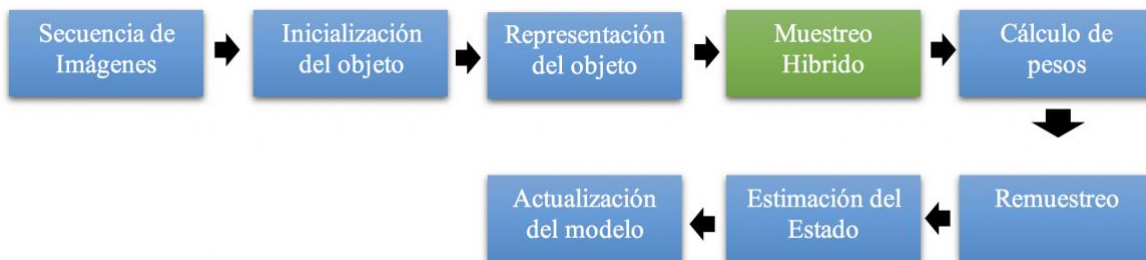


Figura 1. Diagrama de bloques de la metodología propuesta.

Fuente: Elaboración propia

### Secuencia de imágenes

La secuencia de imágenes es cargada para realizar el proceso de rastreamiento. El rastreamiento se realiza independientemente de la naturaleza del video.

### Inicialización del objeto

El objeto se encuentra demarcado por un rectángulo de forma manual en el inicio de cada secuencia de rastreamiento. El vector de estado está definido como  $x = (x, y, H_x, H_y)$ , donde  $x$  y  $y$  representan la posición del objeto;  $H_x$  y  $H_y$  son el ancho y el alto del rectángulo.

### Representación del objeto

Para el rastreamiento visual es empleado un modelo del objeto basado en color para incrementar la robustez en caso de objetos no rígidos, rotaciones y oclusiones parciales en el dominio de la imagen. En la propuesta se ha escogido el modelo de color HSV sobre el modelo RGB, por representar una mejor estabilidad bajo cambios de iluminación. Un descriptor es empleado, basado en un histograma de color con 10 clases para cada canal de saturación (S) y matiz (H), como entrada en la etapa de observación para el esquema del filtro de partículas.

### Muestreo híbrido

En este trabajo el proceso híbrido es usado en la etapa de muestreo. El proceso de rastreo inicia asumiendo que el objeto no presenta alguna oclusión y el filtro de partículas propuesto usa el modelo de movimiento discreto. propuesto como:

$$\mathbf{x}'_k = \mathbf{x}_{k-1} + \mathbf{r}_K \quad 7$$

$$\mathbf{x}''_K = \mathbf{x}' + \mathbf{I}_{k-1} \quad 8$$

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k, \mathbf{s}_k) \quad 9$$

El vector de estado  $\mathbf{x}_k$  estima la posición vertical y horizontal del objeto en el dominio de la imagen, obtenida de un rectángulo que encierra al objeto rastreado. El vector de estado  $\mathbf{x}'$  y  $\mathbf{x}''$  son las derivadas, (primer y segundo orden. respectivamente) de la posición de objeto. Las variables aleatorias  $\mathbf{r}_K$  y  $\mathbf{s}_k$  son mutuamente independientes, modeladas por funciones gaussianas; ellas describen el ruido en el proceso y en las mediciones. respectivamente.  $h(\cdot)$  es una función que representa el estado de las observaciones.  $\mathbf{I}_{k-1}$  es el factor inercial, responsable de proveer el movimiento inercial de las partículas y es obtenido a partir de una distribución gaussiana de los pesos por la velocidad  $\mathbf{v}_i$  de las partículas. Considerando que la velocidad del objeto rastreado es uniforme entre cada cuadro de la secuencia, entonces esta velocidad puede ser evaluada como:

$$\mathbf{v}_i = \mathbf{x}'_k - \mathbf{x}'_{k-1} \quad 10$$

la expresión para la transición de probabilidades, está definida como:

$$\mathbf{p}(\mathbf{x}_k | \mathbf{y}_k) = \mathit{argmax}\{\boldsymbol{\pi}(\mathbf{x}_k)\} \quad 11$$

$$\mathbf{p}(\mathbf{x}_k | \mathbf{x}_{k-1}) = \mathbf{p}(\mathbf{x}_k | \mathbf{r}_k \mathbf{I}) \quad 12$$

$$\mathbf{p}(\mathbf{y}_k | \mathbf{x}_k) = \mathbf{N}(\mathbf{Y}_k | \mathbf{h}(\mathbf{x}_k), \mathbf{s}_k) \quad 13$$

$\mathbf{p}(\mathbf{x}_k | \mathbf{y}_k)$  es una distribución normal  $\mathbf{N}(\cdot)$   $\boldsymbol{\pi}(\mathbf{x}_k^i)$  es la función de distribución *a posteriori* del estado de las muestras  $\mathbf{x}_k$ , definido por la ecuación 14 y restringido por la ecuación 15.

$$\boldsymbol{\pi}(\mathbf{x}) = \mathbf{p}(\mathbf{y}_k | \mathbf{x}_k) \left[ \sum_{i=1}^{\rho} \mathbf{p}(\mathbf{x}'_k | \mathbf{x}'_{k-1}) + \sum_{i=\rho}^{Ns} \mathbf{p}(\mathbf{x}''_k | \mathbf{x}''_{k-1}) \right] \quad 14$$

$$\sum_{i=1}^{\rho} p(x'_k | x'_{k-1}) + \sum_{i=\rho}^{Ns} p(x''_k | x''_{k-1}) = 1 \quad 15$$

Donde  $\rho$  es una parte del conjunto total de muestras  $Ns$  en el filtro.

Cuando el objeto no puede ser observado en la escena (por ejemplo, a causa de una oclusión), el estado de transición para cada grupo de partículas es modificado. El primer grupo (primera sumatoria de la ecuación 14) cambia de una distribución normal a una distribución uniforme alrededor de la última estimación  $\hat{x}_{k-1}$  antes de la oclusión, descrito en la ecuación:

$$x' = \hat{x}_{k-1} + r_k \quad 16$$

El vector de estado  $\hat{x}_{k-1}$  describe el tiempo antes de la oclusión y  $r_k$  muestra el valor evaluado desde una distribución uniforme  $U(u|l_k, u_k)$ . Los límites superior e inferior cambian durante los cuadros restantes. El otro vector de estado  $x''$ , tiene un comportamiento de acuerdo a la última actualización de la velocidad estimada del vector de estado  $x'$  antes de la oclusión. Siguiendo estas restricciones, la estimación del objeto es posible, cuando ocurre una oclusión o cuando existe un fondo de la escena altamente confusa. En el momento en que el objeto reaparece, o la oclusión termina, el estado de las partículas es actualizado de acuerdo con la ecuación 9.

### Cálculo de pesos

Para cada partícula generada en cada cuadro, el histograma de la región de interés a ser rastreada  $H_i$ , es evaluado; se emplea la distancia Battacharyya  $d_{H_0-H_i}$ , (Straka & Šimandl, 2006) entre el histograma del candidato  $H_i$  y el histograma del objeto rastreado  $H_0$ , como se muestra en la siguiente ecuación:

$$MB = \sum_r \sqrt{H_{i_r}} \sqrt{H_{0_r}} \quad 17$$

$$d_{H_0-H_i} = \sqrt{1 - MB} \quad 18$$

Este valor es usado para calcular el peso de cada partícula, de acuerdo a la ecuación 9:

$$w^i = \exp(-\gamma d_{H_0-H_i}^2) \quad 19$$

Donde  $\gamma$  es igual a 20. Esta expresión asegura que los candidatos con histogramas muy similares al objeto rastreado tengan grandes pesos; si la correspondencia es mínima, entonces los pesos son pequeños.

### Remuestreo

Este proceso de remuestreo de las partículas sólo se lleva a cabo si el número efectivo de las partículas Neff (Ecuación 5), está por debajo de un umbral. Esto se hace para evitar la pérdida de representación de los estados posibles del objeto, cuando el remuestreo reduce el número de estados a sólo aquellos que tienen un alto peso.

### Estimación del filtro

La estimación del estado del objeto  $\hat{x}_k$  en cada cuadro, es estimado de la serie de pesos de cada partícula  $\{x_k^i, w_k^i\}_{i=0}^{N_s}$  con el máximo *a posteriori* (MAP):

$$\hat{x}_k = \max_{x_k} p(x_k | y_k) = \max_{x_k} w_k^i \quad 20$$

### Actualización del modelo del objeto

La propuesta sigue la propuesta de actualización del modelo presentada en (Iain Matthews, Takahiro Ishikawa, & Simon Baker, 2004), donde el histograma del objeto  $H_k^o$  es actualizado según el histograma del objeto en el cuadro anterior  $H_{k-1}^o$ , combinado con el histograma de la posición estimada  $H_k^{\hat{x}}$ , lo que proporciona un factor  $\alpha$  llamado factor de actualización, siguiendo la ecuación:

$$H_k^o = (1 - \alpha)H_{k-1}^o + \alpha H_k^{\hat{x}} \quad 21$$

La actualización del histograma del objeto sólo es efectuada cuando la media de los pesos en cada cuadro, durante el rastreamiento, supera un límite  $\delta$ . Este factor es escogido de manera empírica y permanece constante durante todo el proceso de rastreamiento. Con esta consideración, se evitan los efectos del *drift*, que ocurren cuando el modelo es alimentado con información en su mayoría del entorno del objeto, lo que degrada poco a poco el histograma de comparación y produce –como consecuencia– la pérdida del objeto.

Este valor de  $\delta$ , a su vez, permite la detección de oclusiones durante el rastreamiento y, como consecuencia, durante los cuadros de oclusión no existiría una actualización del modelo del objetivo.

## RESULTADOS

Con el objetivo de evaluar el método propuesto, se aplica el algoritmo a una serie de secuencias de imágenes disponibles en la base de datos pública Bonn Benchmark on Tracking (Bobot)<sup>10</sup>. La base de datos Bobot incluye varias secuencias con muchos tipos de objetos y personas para rastrear, con una anotación completa de las posiciones y escalas de los objetivos (Ground Truth).

En los cuadros donde se presenta una oclusión, el valor de las posiciones y escala son iguales a cero. Todas las secuencias disponibles tienen una resolución de 320 x 250 píxeles a una frecuencia de 25 fps.

El FPAH descrito en la sección anterior emplea 200 partículas, así como el filtro de partículas con muestreo por importancia (SIR) empleada para la comparación de desempeño. Además, se utiliza un algoritmo determinístico de rastreamiento Windows Matching (WM) para establecer una base de comparación entre las metodologías determinísticas y estocásticas.

<sup>10</sup> Disponible en <https://archive.is/UBw37>



Todas estas técnicas fueron implementadas usando el lenguaje de programación c++ y la librería *opencv* (Bradski, 2000) en un computador con procesador core i7 con 8 gb de memoria RAM y sistema operativo *Ubuntu linux*.

El algoritmo de rastreamiento es ejecutado en seis secuencias de la base de datos mencionada. Aquí se presentan algunos de los resultados para tres secuencias de Bobot (resultados adicionales se pueden observar en la tabla).

La primera secuencia muestra muchas características de escenarios saturados o desordenados; en la segunda se muestra una secuencia en un entorno cerrado con varios objetos que presentan mucha semejanza con el objeto que está siendo rastreado, y las oclusiones totales ocurren en más de una ocasión. La tercera secuencia muestra una situación con muchas oclusiones totales para el objeto, así como cambio de iluminación a lo largo de la secuencia.

### Secuencia con escenario saturado

Esta secuencia presenta muchos cambios de fondo, movimiento de la cámara y transformación de escala del objeto. La figura 2 muestra algunos cuadros relevantes de la secuencia.



**Figura 2. Secuencia con fondo de escenario saturado. FPAH, SIR y WM.**

Fuente: Elaboración propia




Figura 3. Comparación de la estimación de la posición normalizada en el eje x y en el eje y, en la secuencia con entorno saturado, para cada rastreador: FPAH, SIR y WM.

Fuente: Elaboración propia


Se observan muchos errores de estimación del algoritmo WM durante el rastreo del objeto, especialmente cuando objetos de apariencia similar aparecen cerca de la imagen. El algoritmo estándar SIR, tiene una respuesta adecuada con respecto a la posición espacial del objeto rastreado, pero el tamaño de la estimación está errado con respecto a la forma del vaso. Por otro lado, el FPAH presenta un mejor trabajo en el momento de estimar el estado del objeto a lo largo de toda la secuencia.

### Secuencias al aire libre con oclusión total

En esta secuencia se muestra una persona que es el objetivo a rastrear, caminando al aire libre, donde muchas personas se cruzan en la trayectoria del objetivo, generando la oclusión de la persona rastreada. Entre las oclusiones, la escala de la persona, cambia; se presentan, además, rotaciones y traslaciones durante la secuencia.

El algoritmo WM pierde a la persona rastreada después de la oclusión y cuando existen objetos con apariencia similar al objetivo. El SIR también pierde al objeto después de la oclusión y falla en el momento de estimar la escala correcta de la imagen de la persona. Cuando una oclusión persiste, la

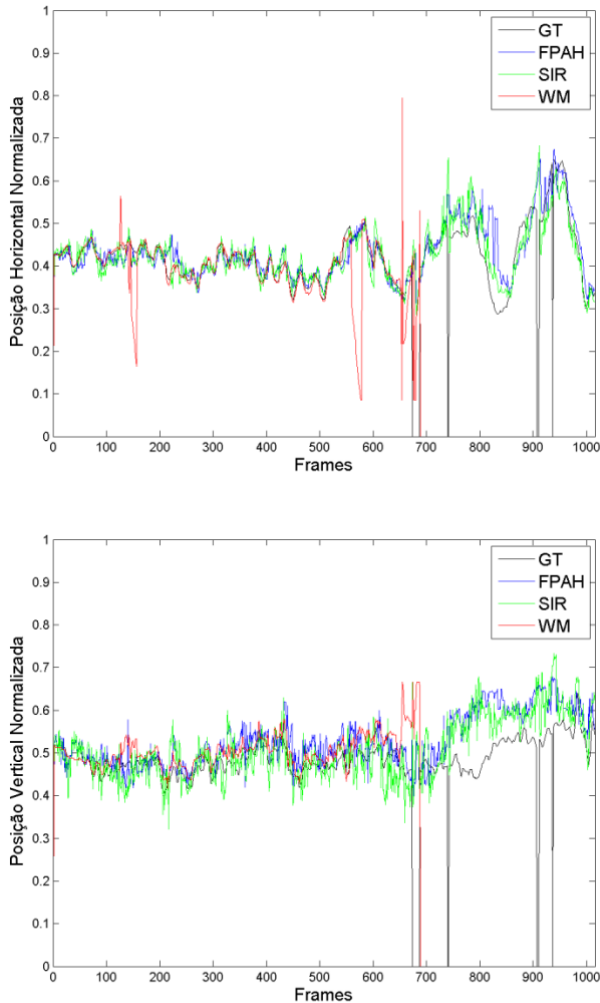
estrategia del FPAH consiste en evaluar la distribución *a posteriori* del vector de estado  $x$  de la ecuación 16, incluyendo valores del modelo dinámico en el dominio de la imagen. Específicamente, para esta situación de oclusión, se puede establecer el número de partículas de primer orden y segundo orden del modelo de movimiento. Estos valores son escogidos empíricamente para obtener el mejor desempeño para el proceso de rastreamiento.



**Figura 4. Secuencia al aire libre con oclusiones totales. FPAH, SIR y WM.**

*Fuente: Elaboración propia*

Como se puede observar en la parte baja de la figura 4, WM no tiene la capacidad de rastrear a la persona, mientras que SIR consigue hacer el seguimiento, pero con grandes desplazamientos horizontales y verticales respecto a la posición de la persona rastreada, como se muestra en los resultados en la figura 5. El FPAH sigue a la persona con pequeños errores y, después de la oclusión, unos cuadros después –con pequeñas oscilaciones– el algoritmo recobra el objetivo.




**Figura 5. Comparación de la estimación de la posición normalizada en el eje x y en el eje y, en la secuencia al aire libre con oclusiones totales, para cada rastreador: FPAH, SIR y WM.**

*Fuente: Elaboración propia*


### **Secuencias en el interior con oclusión total**

En esta secuencia, un hombre está caminando en un corredor interior, mientras que la cámara lo acompaña a un lado. Durante esta caminata, entre la cámara y la persona aparecen columnas que realizan la oclusión. La robustez de la metodología es probada para muchas situaciones de oclusión, demostrando la versatilidad y estabilidad del modelo propuesto, así como del muestreo híbrido en el proceso de rastreamiento global del objetivo.

El algoritmo WM pierde a la persona rastreada después de la oclusión, como se muestra en la figura 6. El SIR también pierde al objeto después de una oclusión que no le permite estimar el estado del objetivo. La estrategia propuesta consigue realizar el rastreamiento de la persona antes y después de las oclusiones.



**Figura 6.** Secuencia en el interior con oclusiones totales. **FPAH**, **SIR** y **WM**.  
Fuente: Elaboración propia






Figura 7. Comparación de la estimación de la posición normalizada en el eje  $x$  y en el eje  $y$ , en la secuencia en el interior con oclusiones totales, para cada rastreador: FPAH, SIR y WM.

Fuente: Elaboración propia

### Evaluación del desempeño del rastreamiento

Para evaluar adecuadamente el algoritmo de rastreo, se debe tener en cuenta la estimación del tamaño del objeto, como es propuesto en (Fei Yin, Dimitrios Makris, & Velastin, 2007). Esto consiste en medir la sobreposición entre el *Ground* y el área estimada, definida según la ecuación:

$$A(GT, ST) = \frac{\text{Area}(GT \cap ST)}{\text{Area}(GT \cup ST)} \quad 22$$

Donde GT representa el área del *Ground Truth* y ST representa el área obtenida de la estimación del algoritmo. De acuerdo con (Fei Yin et al., 2007), si esta razón es superior al 50%, entonces se considera como un verdadero positivo. La tabla 1 muestra el resultado en porcentaje de los verdaderos positivos sobre el total de cuadros, en cada una de las secuencias en donde el objeto es rastreado de manera eficaz, para los tres métodos testados. Se puede observar que el FPAH tiene un alto porcentaje de efectividad, en comparación con los algoritmos WM y SIR, para todas las secuencias.

Tabla 1 Datos de los porcentajes de verdaderos positivos

	FPAH	SIR	WM
Escenarios Saturados	97,60	95,21	82,93
Aire libre con oclusiones totales	93,79	90,18	70,07
Cambios de fondo	97,60	95,21	82,93
Variaciones de escala	92,30	94,96	33,90
Cambios de trayectoria	95,67	76,87	87,18
Interior con oclusiones totales	88,93	86,06	30,08
<b>Promedio</b>	<b>94,75</b>	<b>89,74</b>	<b>64,51</b>

Fuente: Elaboración propia

## **DISCUSIÓN Y CONCLUSIONES**

En este trabajo se presentó un nuevo abordaje para el rastreamiento visual, empleando un filtro de partículas con la estrategia de muestreo híbrido, con el objetivo de mejorar la robustez. Los test muestran que el algoritmo propuesto (FPAH) consigue mejores resultados cuando es comparado con técnicas clásicas como WM y SIR; especialmente, cuando ocurren oclusiones y en escenarios saturados.

El enfoque presente puede mejorar el proceso de rastreamiento, dado el hecho que es independiente del tipo de movimiento, (por ejemplo, trayectorias aleatorias); o de la forma del objeto. El algoritmo también ofrece flexibilidad en situaciones donde no existe información previa del objeto a ser rastreado. Este trabajo sigue un continuo desarrollo que incluye la implementación del algoritmo para un lenguaje de bajo nivel de programación, con el objetivo de permitir su ejecución en tiempo real, incluyendo el tiempo de análisis. El siguiente paso es realizar continuas comparaciones con las últimas técnicas de rastreamiento para mejorar la propuesta actual.



**BIBLIOGRAFÍA**

Arulampalam, M. S., Maskell, S., Gordon, N., & Clapp, T. (2002). A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking. *IEEE Transactions on Signal Processing* 50, (2), 174-188

Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal of Software Tools*.

Chang, C. Y., & Lie, H. W. (2012). Real-Time Visual Tracking and Measurement to Control Fast Dynamics of Overhead Cranes. *IEEE INDUSTRIAL ELECTRONICS* 59, 1640-1649

Chen, Z. H. E. (2003). Bayesian Filtering: From Kalman Filters to Particle Filters, and Beyond. *Statistics*, 182, (1), 1-69

Cuevas, E., Zaldivar, D. & Rojas, R. (2005). *Kalman filter for vision tracking*. Technical Report B, Fachbereich Mathematikund Informatik, Freie Universitat Berlin

Fei Y., Dimitrios M. & Velastin, S. (2007). Performance Evaluation of Object Tracking Algorithms. *Proceeding Tenth IEEE International Workshop on Performance Evaluation of Tracking and Surveillance*.

Hastings, W. K. (2007). Monte Carlo Sampling Methods Using Markov Chains and Their Applications, *Biometrika* 57, (1), 97-109

Imtiaz, S. A., Roy, K., Huang, B., Shah, S. L., & Jampana, P. (2006). Estimation of States of Nonlinear Systems using a Particle Filter. *2006 IEEE International Conference on Industrial Technology*, 2432-2437

Iswanto, I. A., & Li, B. (2017). Visual Object Tracking Based on Mean-shift and Particle-Kalman Filter. *Procedia Computer Science* 116, 587-595

Kennedy, J., & Eberhart, R. C. (1995). Particle Swarm Optimization. In *IEEE International Conference on Neural Networks* (pp. 1942–1948). Perth, Australia.

Li, X., Hu, W., Shen, C., Zhang, Z., Dick, A., & Hengel, A. (2013). A survey of appearance models in visual object tracking. *ACM Transactions on Intelligent Systems and Technology* 4, (4), 1-48

MacCormick, J., & Isard, M. (2000). Partitioned Sampling, Articulated Objects, and Interface-quality Hand Tracking. *Computer Vision—ECCV 2000*, 3-19

Matthews, I., Ishikawa, T. & Baker, S. (2004). *The Template Update Problem*. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 26, 810-815

Nieto, M., Cortés, A., Otaegui, O., Arróspide, J., & Salgado, L. (2016). Real-time lane tracking using Rao-Blackwellized particle filter. *Journal of Real-Time Image Processing* 11, (1), 179-191



Sanjeev M., Maskell, S., Gordon, N. & Clapp, T. (2002). A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking. *IEEE Transactions on Signal Processing* 50, (2), 174-188

Straka, O., & Šimandl, M. (2006). Using the Bhattacharyya distance in functional sampling density of particle filter. In *Proceedings of the 16th IFAC World Congress 1*, 1006-1011

Vidal, F. D. B., Cordoba, D. A. L., Zagheto, A., & Koike, C. M. C. (2014). Improving visual tracking robustness in cluttered and occluded environments using particle filter with hybrid resampling. VISAPP 2014 - Proceedings of the 9th International Conference on Computer Vision Theory and Applications. 3.

Wang, G. Deyun X. & Gu, J. (2008). Review on vehicle detection based on video for traffic surveillance. *2008 IEEE International Conference on Automation and Logistics*, 2961-2966

Weina, G., Collins, R. T. & Ruback, R. B. (2012). Vision-Based Analysis of Small Groups in Pedestrian Crowds. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE* 34, 1003-1016

Xiang, X. (2011). A Brief Review on Visual Tracking Methods. *Intelligent Visual Surveillance*, 41-44

Yilmaz, A., Javed, O., & Shah, M. (2006). Object Tracking: A Survey. *ACM Computing Surveys* 38, (4), Article 13, 45

Zhou, Z., Zhou, M., & Li, J. (2016). Object tracking method based on hybrid particle filter and sparse representation. *Multimedia Tools and Applications*, 1-15