

Filtro de Partículas Metaheurístico para el Seguimiento en Secuencias de Imágenes

Juan José Pantrigo, Ángel Sánchez, Antonio S. Montemayor, Abraham Duarte

Resumen— El Filtro de Partículas Metaheurístico (MPF) es una metodología que permite el desarrollo de algoritmos de optimización dinámica mediante la hibridación de métodos de estimación secuencial y métodos de optimización aproximados. Su aplicación natural engloba la familia de problemas de optimización dinámica. El problema del seguimiento en secuencias de imágenes asistido por modelos puede considerarse un problema de optimización dinámica. En este trabajo, se propone la aplicación de algoritmos MFP a problemas de seguimiento y el modelado de estos problemas para que sean tratables desde el punto de vista de MPF.

Palabras clave— filtros de partículas, metaheurísticas, seguimiento en secuencias de imágenes, optimización, adaptación, predicción.

I. INTRODUCCIÓN

La localización o determinación de la configuración de un objeto conocido (móvil y/o deformable) es un problema importante en visión computacional [1]. La palabra objeto hace referencia a un objeto físico dado, por ejemplo, un sujeto como el que se muestra en la figura 4. Este problema ha sido abordado desde diferentes puntos de vista. Uno de los más populares en los últimos años ha sido el enfoque probabilístico basado en el algoritmo del filtro de partículas. Este algoritmo fue propuesto por Gordon et al. en 1993 para la resolución del problema de la estimación secuencial cuando la evolución del sistema está descrito por una función de distribución no lineal y no gaussiana [2]. Se basa en representaciones discretas de las funciones de densidad de probabilidad que dirigen la evolución temporal del sistema [3]. A cada una de esas muestras se les denomina partícula. Cada partícula i posee la representación de un estado \mathbf{x}_i^t en cada instante t y una medida π_i^t denominada peso, proporcional a la probabilidad de que el estado del sistema sea ése. Este algoritmo comenzó a aplicarse con éxito al seguimiento de objetos en secuencias de imágenes hacia mediados de los 90 [4]. Como resultado, propusieron el algoritmo CONDENSATION [5], que permite realizar seguimiento de contornos sobre secuencias de imágenes y que hoy día conforma la base de la mayoría de los algoritmos de seguimiento basados en la propagación de la densidad condicional.

El enfoque propuesto por Isard y Blake no logra buenos resultados cuando se enfrenta a problemas de seguimiento más complejos, como el seguimiento de objetos articulados o el seguimiento de múltiples objetos. En estos casos, ya no basta con encontrar la posición de un objeto en una imagen (que consiste en la estimación de sólo dos variables $\mathbf{x}_i^t = (x, y)_i^t$), sino que hay que describir la configuración del objeto. Por ejemplo, en el problema

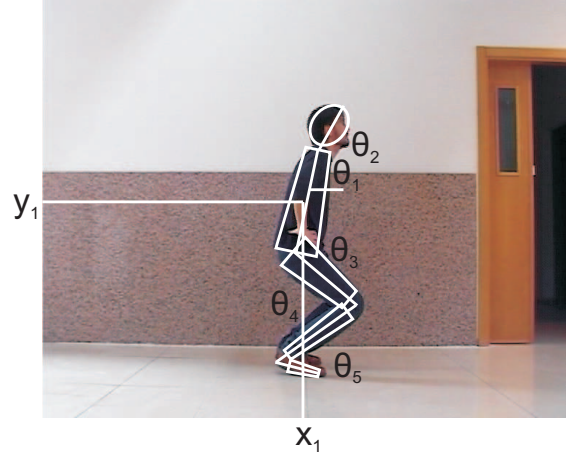


Fig. 1. Seguimiento de movimiento articulado.

de seguimiento ilustrado en la secuencia de la figura ?? se pretende seguir un objeto cuya estructura interna viene descrita por 5 segmentos. Por lo tanto, para determinar la configuración del objeto en cada instante, es necesario establecer la posición global del objeto y la orientación relativa de cada uno de los segmentos. En este caso, la configuración viene descrita por un vector de 7 componentes en total:

$$(x_1, y_1, \theta_1, \theta_2, \theta_3, \theta_4, \theta_5) \quad (1)$$

donde x_1, y_1 representa la posición del segmento principal (en este caso el tronco), θ_1 su orientación y $\theta_2, \theta_3, \theta_4, \theta_5$ la orientación relativa del resto de segmentos: cabeza, muslo, pierna y pie, respectivamente. En este tipo de problemas, los filtros de partículas necesitan un número muy grande, incluso, a veces impracticable, de partículas para lograr describir fielmente el estado del sistema.

A principios de la década actual, Deutscher desarrolló el algoritmo *Annealed Particle Filter* (APF) [6]. APF fue uno de los primeros algoritmos basados en el filtro de partículas que podían abordar el seguimiento de movimiento articulado con éxito, y el primero que propone la combinación entre estrategias procedentes de los filtros de partículas y las metaheurísticas. Sin embargo, en él aún no se considera la posibilidad de que las partículas colaboren entre sí. Otro enfoque que hibrida técnicas de predicción y de optimización es el *Local Search N Interacting Particle System* (LS-N-IPS) [7], que propone la aplicación de una búsqueda local a cada partícula para mejorar su calidad individual. En él, tampoco se explota

la posibilidad de que las partículas compartan información. Existen varios algoritmos basados en la hibridación de filtros de partículas y algoritmos genéticos [?][9]. Pero fue en [10] donde se propone el primer algoritmo basado en el filtro de partículas que propone la inclusión de una etapa en la que las partículas comparten información para construir partículas mejores. En definitiva, se trata de aplicar una etapa de optimización metaheurística basada en poblaciones al conjunto de partículas. En [10] se utilizó la metaheurística Path Relinking, pero no es la única posibilidad. En el trabajo [11] se utilizó Scatter Search para implementar la tarea de colaboración entre partículas. Como culminación de esta línea, en [12] se propone una metodología general de construcción de estos algoritmos, denominada Filtro de Partículas Metaheurístico (MPF). MPF propone un método general para el desarrollo de algoritmos híbridos entre filtros de partículas y metaheurísticas.

II. EL PROBLEMA DE LA ESTIMACIÓN SECUENCIAL Y LOS FILTROS DE PARTÍCULAS

El problema de la estimación secuencial, desde un punto de vista bayesiano, consiste en el cálculo recursivo, con un cierto grado de confianza, del estado del sistema \mathbf{x}_t en el instante t , dadas las observaciones $\mathbf{z}_{1:t} = \{\mathbf{z}_1, \dots, \mathbf{z}_t\}$. Para ello, es necesario calcular la pdf $p(\mathbf{x}_t | \mathbf{z}_{1:t})$. La pdf inicial $p(\mathbf{x}_0 | \mathbf{z}_0) \equiv p(\mathbf{x}_0)$ se asume conocida. Así, la pdf a posteriori $p(\mathbf{x}_t | \mathbf{z}_{1:t})$ se puede calcular en dos etapas:

1. **Predicción:** supóngase que se dispone de la pdf $p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1})$ en el instante $t-1$. La etapa de predicción implica el uso del modelo del sistema para obtener de manera recursiva la pdf a priori $p(\mathbf{x}_t | \mathbf{z}_{1:t-1})$ en el instante siguiente t , mediante la ecuación de Chapman-Kolmogorov:

$$p(\mathbf{x}_t | \mathbf{z}_{1:t-1}) = \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} \quad (2)$$

2. **Evaluación:** En el instante t , se dispone de una nueva medida (\mathbf{z}_t) que se puede utilizar durante la actualización del estado del sistema mediante el uso del teorema de Bayes:

$$p(\mathbf{x}_t | \mathbf{z}_{1:t}) = \frac{p(\mathbf{z}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{z}_{1:t-1})}{p(\mathbf{z}_t | \mathbf{z}_{1:t-1})} \quad (3)$$

Las ecuaciones (2) y (3) conforman la base de la solución bayesiana óptima. Esta propagación recursiva de la densidad a posteriori es únicamente un resultado conceptual, puesto que, en general, no se puede determinar analíticamente [15]. Por esta razón, se encuentra en la literatura un número significativo de trabajos que presentan modelos aproximados de esas funciones de distribución.

El algoritmo de filtro de partículas (PF) es una técnica para implementar filtros recursivos bayesianos [15], cuya idea clave consiste en representar la pdf a posteriori por un conjunto de muestras discretas con pesos asociados y calcular los estimados basándose en esas muestras




Fig. 2. Esquema general del filtro de partículas.

y pesos [13]. Cuando el número de muestras es lo suficientemente grande, esta representación se convierte en equivalente a la descripción funcional de la pdf a posteriori [13]. La figura 2 muestra una representación gráfica del funcionamiento de PF. Inicialmente, se genera una población de partículas utilizando una pdf conocida. En este momento se reciben nuevas medidas y se calcula el peso para cada partícula, utilizando la ecuación (3). El resultado es un conjunto de partículas con pesos asociados que constituyen una aproximación discreta de la pdf a posteriori. A continuación, se lleva a cabo el paso de remuestreo. En esta etapa, se seleccionan las partículas “más importantes” (es decir, con mayor peso) para aproximar la pdf a priori en el instante siguiente aplicando sobre este conjunto la regla de predicción dada por la ecuación (2).

III. PROBLEMAS DE OPTIMIZACIÓN Y METAHEURÍSTICAS

Un problema de optimización (OP) se puede definir como la mejora (minimización o maximización) de una función objetivo $f: S \rightarrow \mathbb{R}$ sujeta a una serie de restricciones [?]. Formalmente,

$$OP = \begin{cases} \text{optimizar } f(\mathbf{x}) \\ \text{sujeto a } \mathbf{x} \in F \end{cases} \quad (4)$$

donde S es con un conjunto de soluciones, en general: $S \subseteq \mathbb{R}$, $f: S \rightarrow \mathbb{R}$ es una función de coste que asigna a cada solución candidata ($\mathbf{x} \in S$) un valor numérico ($f(\mathbf{x}) \in \mathbb{R}$) y F determina el conjunto de soluciones factibles $\mathbf{x} \in F \subseteq S$.

Existe una colección importante de problemas de optimización interesantes para la que no se dispone de algoritmos exactos que permitan encontrar la solución óptima en tiempos razonables. Una alternativa consiste en diseñar algoritmos aproximados que encuentren soluciones de alta calidad en un tiempo razonable. De entre todos los métodos aproximados, destacan las metaheurísticas por su eficiencia, efectividad y flexibilidad. Las metaheurísticas combinan métodos heurísticos básicos en un marco de trabajo de más alto nivel con el objetivo de mejorar




Fig. 3. Esquema general de una metaheurística poblacional.

la exploración sistemática del espacio de búsqueda del problema. Las metaheurísticas se han aplicado con éxito a una gran variedad de problemas de optimización. Este tipo de métodos combinan ideas que provienen de cuatro campos de investigación bien distintos: las técnicas de diseño de algoritmos (resuelven una colección de problemas), algoritmos específicos (dependientes del problema que se quiere resolver), fuentes de inspiración (del mundo real) y métodos estadísticos.

En una primera aproximación, se pueden clasificar las metaheurísticas en dos grandes bloques [16][17]: trayectoriales y poblacionales. Las metaheurísticas trayectoriales manejan en todo momento una sola solución y deben su nombre a que el proceso de búsqueda que desarrollan se caracteriza por una trayectoria en el espacio de soluciones. Es decir, partiendo de una solución inicial, generan un camino en el espacio de búsqueda mediante operaciones de movimiento. Dentro de estas metaheurísticas se pueden destacar por su interés la Búsqueda Tabú (*Tabu Search*), Procedimiento Aleatorio y Adaptativo de Búsqueda Miope (*Greedy Randomized Adaptive Search Procedure - GRASP*) o Recocido Simulado (*Simulated Annealing - SA*). Las metaheurísticas poblacionales implementan el proceso de búsqueda manteniendo simultáneamente un conjunto de soluciones. Los Algoritmos Evolutivos (*Evolutionary Algorithms*), la Búsqueda Dispersa (*Scatter Search*), el Reencadenamiento de Trayectorias (*Path Relinking*) y los Algoritmos de Estimación de la Distribución (*Estimation Distribution Algorithms*) son ejemplos de este tipo de metaheurísticas. Las metaheurísticas poblacionales son de especial interés para nuestra propuesta de hibridación, puesto que encajan perfectamente en el marco de trabajo del filtro de partículas, cuyo carácter es eminentemente poblacional. En la figura 3 se representa gráficamente el esquema de funcionamiento general de una metaheurística poblacional. Inicialmente, se parte de soluciones generadas aleatoriamente. En una segunda etapa, se seleccionan aquellas que poseen una mayor calidad para generar otras mediante combinación. A las soluciones generadas, se les puede aplicar una etapa de mutación y otra de mejora, con el objetivo de dotar a la población de diversidad o calidad,




Fig. 4. Seguimiento basado en modelos

respectivamente. Este proceso se repite hasta que se alcanza una condición de parada establecida previamente.

IV. EL FILTRO DE PARTÍCULAS METAHEURÍSTICO

El Filtro de Partículas Metaheurístico (MPF) es una metodología de desarrollo de algoritmos híbridos entre filtros de partículas y metaheurísticas (o heurísticas), para la resolución de problemas de optimización dinámica. Se debe distinguir entre el ámbito de la metodología del MPF y el de los algoritmos que se derivan de su aplicación.

La metodología MPF se aplica a algoritmos de estimación secuencial basados en filtros de partículas y en metaheurísticas. El propósito de esta metodología es el diseño de algoritmos de optimización dinámica mediante la hibridación de métodos de ambas familias. Es importante notar que los algoritmos resultantes son de propósito general en cuanto que los algoritmos de partida lo son, de modo que se pueden aplicar a un conjunto amplio de problemas dinámicos, pero son específicos en cuanto que están especializados en optimización dinámica.

A. Los elementos de la metodología MPF

En esta sección se introduce el conjunto de definiciones necesarias para describir los elementos que componen el marco de trabajo de MPF. Gran parte de estos elementos son heredados de los algoritmos de filtros de partículas y de las metaheurísticas.

Una **solución** ($\mathbf{x} \in S \equiv \mathbb{R}^D$) constituye la información necesaria y suficiente para representar una posible respuesta al problema de optimización.

Una **medida** ($\mathbf{z} \in \mathbb{R}^M$) es un conjunto de datos recogidos en un instante de tiempo, utilizando el proceso de medida (usualmente $M > D$). En el ámbito del seguimiento de objetos estas medidas son el resultado de la extracción de las características de la imagen que representan al objeto que se sigue.

Dado un espacio de soluciones S y una medida \mathbf{z} , la **función de ponderación** ($f : S \times \mathbb{R}^M \rightarrow \mathbb{R}$) es un operador que establece una relación entre el espacio de soluciones ($\mathbf{x} \in S$) y las medidas (\mathbf{z}). El objetivo es asignar una medida de calidad a la solución

Dadas una solución \mathbf{x} , una medida \mathbf{z} y una función de ponderación f , se denomina **peso** de la solución \mathbf{x}^i , y se

denota ω , al resultado de aplicar f sobre \mathbf{x}^i y \mathbf{z} , es decir: $\omega^i = f(\mathbf{x}^i, \mathbf{z})$

Se define un **individuo** como la dupla formada por una solución \mathbf{x}^i y su peso ω^i , y se denota como: (\mathbf{x}^i, ω^i) .

En el marco PF, el par formado por una solución y un peso es conocido como *partícula*. Sin embargo, en el ámbito de las metaheurísticas, recibe diferentes nombres dependiendo del método. Por ejemplo, este elemento es conocido como *individuo* en GA, MA y EDA, mientras que en el contexto de SS y PR se llama *solución*.

El **conjunto soporte** (*SupportSet*) es el formado por N_s individuos que evolucionan en el tiempo guiados por un algoritmo de estimación secuencial.

En PF, *SupportSet* equivale al conjunto de partículas. En el contexto de los algoritmos de optimización, *SupportSet* juega el papel del conjunto inicial de soluciones.

El **conjunto mejorado** (*ImprovedSet*) es un subconjunto del conjunto soporte, formado por N_s individuos que forman el conjunto inicial para la etapa de optimización.

Un **Algoritmo de Estimación Secuencial Montecarlo (PF)** es un procedimiento que determina la evolución temporal de *SupportSet*, entendiéndola como una representación discreta de una *pdf* utilizando las etapas generales de predicción y actualización.

Una **Metaheurística (M)** es un algoritmo aproximado de optimización basado en poblaciones que dirige la combinación de soluciones de *ImprovedSet* para obtener otras de mayor calidad, en el contexto MPF.

El procedimiento de **Selección del conjunto mejorado (Select)** permite seleccionar adecuadamente un conjunto de individuos de *SupportSet* para formar *ImprovedSet*, siguiendo un determinado criterio.

El procedimiento de **sustitución en el conjunto soporte (Replace)** permite que los individuos que forman parte del conjunto mejorado en el momento en el que finaliza el proceso de optimización, pasen a formar parte del conjunto soporte.

El procedimiento de **Estimación (Estimate)** establece una estimación de la mejor solución que describe al sistema en cada instante, basándose en una combinación adecuada de los individuos que forman parte del conjunto mejorado.

B. Metodología de hibridación

MPF proporciona un método general de combinación de algoritmos de estimación secuencial (basados en filtros de partículas) con métodos metaheurísticos. Los algoritmos derivados de la aplicación de MPF están orientados a resolver problemas de optimización dinámica. MPF proporciona un método sistemático para la implementación de algoritmos híbridos que se puede resumir en la siguiente secuencia de pasos:

1. *Elegir un PF e identificar las etapas de inicialización, predicción y actualización.* La labor de las estrategias extraídas de PF consisten en inicializar y mantener el conjunto soporte de individuos *SupportSet* a lo largo del tiempo. Desde el punto de vista de M, el filtro de par-

tículas juega el papel de inicializador de soluciones de la metaheurística (o generador de soluciones diversas), en cada instante temporal.

2. *Elegir una M e identificar las etapas de inicialización y optimización.* Esta etapa del algoritmo tiene como objetivo mejorar el conjunto de individuos *ImprovedSet* en cada instante temporal. Desde el punto de vista del PF, la metaheurística poblacional es un procedimiento de corrección de la estimación. Se debe recordar que PF posee sus propias estrategias para la corrección de la estimación.

3. *Diseñar el procedimiento de selección.* El procedimiento de selección del conjunto mejorado debe elegir N_i individuos de *SupportSet* para formar el conjunto *ImprovedSet*, siguiendo un determinado criterio.

4. *Diseñar un procedimiento de sustitución.* El procedimiento de sustitución se utiliza para añadir los individuos del conjunto mejorado *ImprovedSet* en *SupportSet*. Como el tamaño de *SupportSet* (N_s) debe permanecer constante (ya que el número de partículas en los algoritmos PF se mantiene constante a lo largo del proceso de estimación), la incorporación de nuevos individuos implica forzosamente que otros deben ser descartados.

5. *Elegir un procedimiento de estimación del estado del sistema.* El procedimiento de estimación calcula un estimado del estado del sistema en cada instante, que constituye la salida del algoritmo.

6. *Organizar los elementos utilizando la plantilla MPF.* Una vez que se han obtenido los diferentes elementos descritos, se organizan utilizando la plantilla MPF, que se muestra en la parte central de la figura 5. Las etapas encajan como piezas independientes en la plantilla para diseñar un algoritmo híbrido. El color de las cajas contenedoras indica la procedencia del procedimiento.

C. Resolución de problemas dinámicos mediante la metodología MPF

Para resolver un problemas dinámicos mediante la metodología MPF hay que considerar los siguientes pasos:

1. Determinar si el problema estacionario existe. En este caso:

a) Estudiar los métodos metaheurísticos que han sido aplicados con éxito a este problema

b) Elegir uno de ellos para ser hibridado con un filtro de partículas

si no

a) Estudiar el problema dinámico desde el punto de vista de los filtros de partículas

b) Elegir una metaheurística o procedimiento heurístico adecuado en función de la dificultad del problema

2. Hibridar ambos métodos utilizando la metodología MPF

3. Determinar los parámetros adecuados mediante experimentación

Por lo tanto, para obtener el máximo rendimiento de esta metodología, es necesario, en primer lugar, estudiar el problema dinámico y también su versión estacionaria si existe. El estudio del problema debe orientarse a responder a preguntas como si es un problema difícil, si es necesario el concurso de una metaheurística o basta con

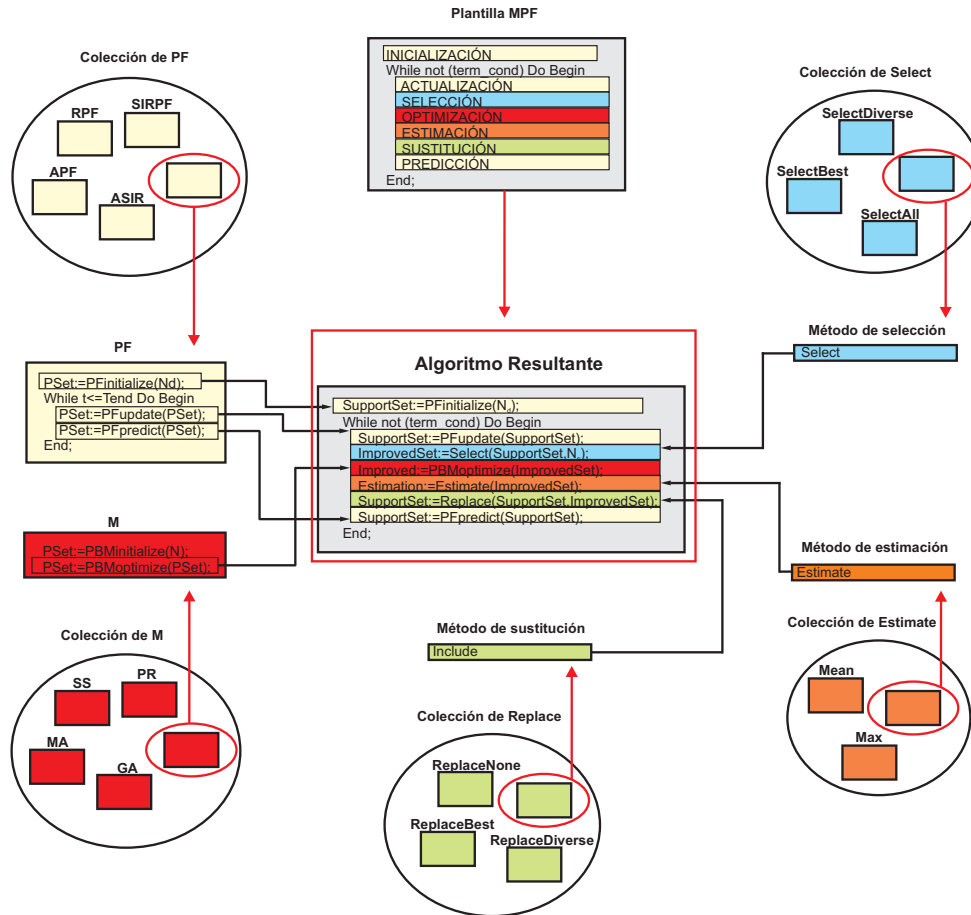


Fig. 5. Esquema general del Filtro de Partículas Metaheurístico.

una heurística, si prima la calidad de las soluciones o tiene restricciones severas de tiempo, etc.

D. Generalizaciones

La aplicación de la metodología MPF a diferentes problemas de optimización dinámica, ha revelado el potencial de esta metodología. Además, se ha aprendido y se han superado limitaciones inicialmente detectadas. En esta sección se presentan algunas de estas ideas empleadas en la generalización de MPF.

- Modificación de la función objetivo entre PF y M**
 Puede ocurrir que, en un determinado problema, sea conveniente utilizar una función de ponderación diferente cada una de las etapas (PF y PBM). Por ejemplo, en un problema de seguimiento, puede ser más conveniente utilizar una medida basada en regiones para el PF y una medida basada en bordes para la etapa M. La idea de cambiar la función de ponderación en un algoritmo de estimación secuencial ha sido aplicada anteriormente con éxito en problemas de seguimiento visual [19].

- Modificación de la topología del espacio de estados entre PF y M**

Esta idea subyace en algunos enfoques metaheurísticos, como el algoritmo de Búsqueda en Vecindad Variable

[18]. En el contexto de MPF puede ser útil cambiar el espacio de estados utilizado en la etapa de PF por otro cuando se aborde la etapa M. Por ejemplo, en el problema de seguimiento de objetos deformables, puede ser de utilidad seguir al objeto con una ventana de tamaño fijo, es decir, considerando un estado (x, y) para los individuos en la etapa PF, y ajustar el tamaño de esa ventana durante la etapa de optimización, es decir, considerar un estado (x, y, l_x, l_y) en la etapa M.

- Empleo de metaheurísticas trayectoriales o de heurísticas en la etapa M**

Cuando los problemas no son demasiado complejos, puede bastar con el uso de una etapa heurística que complementa a la etapa PF. De la misma forma, no hay ninguna limitación relacionada con el uso de metaheurísticas trayectoriales sobre uno o varios individuos durante la etapa PBM. En cualquier caso, la elección del algoritmo de optimización adecuado, dependerá de las características particulares del problema y el conocimiento del que se disponga.

- Empleo de metaheurísticas constructivas y de otros algoritmos de predicción**

Esta es una propuesta que puede revolucionar el marco MPF descrito en este trabajo. Actualmente, los algorit-




Fig. 6. imagen original (a), piel (b), movimiento (c) y bordes (d).

mos MPF manipulan individuos que son soluciones completas al problema. Sin embargo, si disponemos de conocimiento sobre la evolución de componentes de soluciones y no soluciones completas, sería posible relajar el concepto de individuo al de componente de una solución. Además es necesario buscar otros métodos de predicción o estimación secuencial que permitan el uso de componentes de soluciones o, incluso, reformular la plantilla MPF para incluir otros procedimientos de predicción más generales.

V. MODELADO DEL PROBLEMA DE SEGUIMIENTO PARA MPF

El seguimiento de objetos en secuencias de imágenes tiene por objetivo determinar el valor de las magnitudes cinemáticas que definen el estado del objeto en cada instante. Para formular este problema desde el punto de vista de MPF, es necesario el concurso de tres modelos diferentes: modelo de individuo, modelo de medida y modelo geométrico.

A. Modelo de individuo

Por ejemplo, el estado de un objeto en una secuencia de imágenes 2D viene determinado por un vector de componentes (x, y) , donde x representa la posición horizontal e y la vertical. Sin embargo, existen problemas de seguimiento en lo que es necesario determinar los valores de un número mayor de magnitudes. Por ejemplo, el seguimiento de varios objetos exige la determinación de un vector de componentes $(x_1, y_1, \dots, x_N, y_N)$, para N objetos. También existen problemas de seguimiento en los que el objeto posee una estructura interna: bien es un objeto articulado, bien es deformable. En estos casos, el estado del objeto también puede describirse a través del cálculo del valor de las componentes de un vector de múltiples componentes. Por ejemplo, en un problema de seguimiento de movimiento articulado de 5 segmentos, el conjunto de variables que definen el estado del sistema viene determinado por el vector $(x_1, y_1, \theta_1, \theta_2, \theta_3, \theta_4, \theta_5)$. Denominaremos a todos éstos, problemas de seguimiento multidimensional. Más concretamente, un problema

de seguimiento multidimensional es aquel en el que el estado del sistema está descrito por un vector de varias componentes.

Los problemas de seguimiento se suelen abordar a través de modelos. Desde el punto de vista del *model-based visual tracking*, los ejemplos de seguimiento presentados anteriormente no difieren demasiado: Los modelos tendrán un nivel de complejidad variable, pero al final el estado del sistema vendrá determinado por un vector de valores reales o enteros. La longitud y componentes de estos vectores coincide con los grados de libertad de los modelos especificados. El problema entonces, consiste en ajustar de la manera más fiel posible, el modelo al objeto. Para ello, es necesario extraer de la imagen una o varias características que nos indiquen el estado del sistema, utilizando el modelo de medida.

B. Modelo de medida

El modelo de medida tiene por objeto la extracción de las características que discriminan al objeto seguido del resto de la escena. Usualmente, convierten la imagen color en una matriz binaria que, para nuestros objetivos, resulta mucho más práctica y fácil de tratar que la imagen original. Existen diferentes características que pueden utilizarse. Las más usuales son:

- Detección de movimiento: calcula la diferencia entre dos imágenes consecutivas y devuelve una matriz binaria en la que los píxeles etiquetados a 1 corresponden a aquéllos que han sufrido movimiento.
- Sustracción de fondo: esta medida calcula la imagen diferencia entre una imagen del fondo y el fotograma actual. El resultado es una imagen binaria en la que los píxeles etiquetados a 1 son los que no pertenecen al fondo.
- Detección de bordes: devuelve una imagen binaria en la que los píxeles etiquetados como 1 corresponden a bordes en la imagen original.
- Detección de color: devuelve una imagen binaria en la que los píxeles etiquetados como 1 corresponden a píxeles del color buscado en la imagen original.

En la figura 6 se muestran algunos ejemplos de medidas sobre una imagen. También es usual utilizar combinaciones de medidas. Por ejemplo, en el seguimiento de movimiento articulado, se suelen utilizar medidas de bordes combinadas con medidas de sustracción de fondo o detección de color.

C. Modelo geométrico

El modelo geométrico consiste en uno o un conjunto de segmentos que describen la geometría del sistema. Por ejemplo, para el movimiento articulado, éste consistirá en una cadena cinemática 2D compuesta por diferentes segmentos articulados entre sí, que representan la forma del objeto observado. Este modelo se genera *a priori*, es decir, es necesario conocer previamente las dimensiones de cada uno de los segmentos en la imagen. Esta representación almacena parámetros independientes del tiempo, que describen las características geométricas de los segmentos del objeto articulado. En la figura 7 se ilustra




Fig. 7. Modelo geométrico




Fig. 8. Seguimiento utilizando (a) PF y (b) PRPF.

el modelo propuesto para el seguimiento del hemisferio superior del cuerpo humano. Con ayuda de este modelo geométrico u otro similar es posible crear imágenes 2D sintéticas de siluetas y bordes para diferentes valores de los ángulos relativos entre segmentos. Dicho de otra forma, es posible obtener la representación en forma de imagen bidimensional de la solución propuesta por cada individuo. Estas imágenes se comparan o se utilizan para generar una medida. Es importante notar que en este modelo destacan su sencillez de uso y su facilidad para extenderlo, modificarlo y aplicarlo al seguimiento de diferentes objetos.

VI. RESULTADOS

En esta sección se presentan resultados de diferentes problemas de seguimiento: objetos articulados y varios objetos

A. Seguimiento de objetos articulados: movimiento humano

La mayoría de los estudios en análisis de movimiento humano están basados en modelos articulados para describir la postura. Cuando se utilizan modelos articulados para el seguimiento, el problema principal es la gran dimensionalidad del espacio de estados que se generan y el alto grado de esfuerzo computacional [6]. Además, en el enfoque PF, el número de partículas necesarias crece exponencialmente con el tamaño del espacio de estados, como se demuestra en [20]. Desafortunadamente, la estimación proporcionada por PF en espacios de esta-



Fig. 9. Seguimiento utilizando: (a) PF y (b) SSPF.

do de dimensionalidad alta es de muy baja calidad [?]. Para abordar esta dificultad, se han propuesto diferentes algoritmos que optimizan el marco PF, como se vio en la sección I.

En [10] [21], se presentó un Filtro de Partículas con Reencadenamiento de Trayectorias (*Path Relinking Particle Filter*, PRPF) para su aplicación al problema de la estimación de la postura en 2D. Los resultados experimentales permitieron concluir que PRPF mejora apreciablemente el rendimiento de diferentes implementaciones de PF (ver figura 8). Además, PRPF mejora también el rendimiento de PF en lo que respecta a tiempo de ejecución.

B. Seguimiento de varios objetos: interacción persona-ordenador

La Interacción persona-ordenador (*Human-Computer Interaction*, HCI) tiende hacia dispositivos libre de contacto físico, utilizando interfaces multimodales y perceptivas. Esto significa que el sistema permite al usuario interactuar con la máquina sin contacto físico entre ellos, utilizando únicamente voz y/o reconocimiento de gestos [?]. El seguimiento de gestos a través de visión monocular es un campo de gran importancia para el desarrollo de estos sistemas. Para localizar las regiones de interés, esta clase de sistemas requieren un proceso previo de seguimiento. Enfoques recientes han utilizado el enfoque PF. Sin embargo, este método falla en espacios de estado de alta dimensionalidad.

Se ha desarrollado un sistema de seguimiento de caras y manos en 2D basado en el Filtro de Partículas con Búsqueda Dispersa (*Scatter Search Particle Filter*, SSPF) [11]. La captura en tiempo real de las imágenes se ha llevado a cabo utilizando el API de *Microsoft DirectShow*. En concreto, los algoritmos han sido implementados como un filtro de transformación de *DirectShow*. El sistema desarrollado opera en tiempo real (28 Hz) sobre imágenes color de 320x240. La figura 9 muestra el rendimiento de los algoritmos PF y SSPF en este problema. El sistema basado en SSPF mejora el rendimiento de PF, reduciendo el número necesario de evaluaciones de la función de ponderación sin afectar a la calidad de la estimación. Como resultado, el sistema de seguimiento se comporta correctamente en tiempo real sobre un PC convencional.

VII. CONCLUSIONES Y TRABAJOS FUTUROS

En este trabajo se presenta un método de hibridación entre estos métodos, denominado *Filtro de Partículas Metaheurístico* (MPF). De su aplicación, se obtienen algoritmos que heredan las características más sobresalientes de cada método considerado: la capacidad de predicción y adaptación de los filtros de partículas y las estrategias de optimización de las metaheurísticas. Este método híbrido es fácil e intuitivamente extensible y generalizable a otras metodologías tanto de predicción como de optimización, algunas de las cuales se han propuesto en este trabajo.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto TIN2005-08943-C02-02 del Plan Nacional de I+D+I 2005-2008 del Ministerio de Educación y Ciencia de España.

REFERENCIAS

- [1] J. MacCormick. Stochastic Algorithm for visual tracking. Springer (2002).
- [2] N.J. Gordon and D.J. Salmond and A.F.M. Smith. Novel approach to nonlinear/non-Gaussian Bayesian state estimation. Radar and Signal Processing, IEE Proceedings F. 140:2 (1993) 107-113
- [3] J. Carpenter, P. Clifford, P. Fearnhead. Building robust simulation-based filters for evolving data sets. Technical Report, University of Oxford. Dept. of Statistics (1999).
- [4] M. Isard and A. Blake. Visual tracking by stochastic propagation of conditional density. In proc 4th European Conf. Computer Vision (1996) 343-356
- [5] M. Isard and A. Blake. Condensation – conditional density propagation for visual tracking. International Journal of Computer Vision 29:1 (1998) 5-28.
- [6] J. Deutscher, A. Blake and I. Reid. Articulated Body Motion Capture by Annealed Particle Filtering. Proc. of the IEEE Conf. on CVPR Vol 2 (2000) 126-133.
- [7] Torma, P. and Szepesvári, C. LS-N-IPS: An Improvement of Particle Filters by means of Local Search. Proc. of the Non-linear Control Systems (2001)
- [8] Kwok, N.M., Gu Fang and Zhou, W. Evolutionary particle filter: re-sampling from the genetic algorithm perspective. IEEE/RSJ International Conference on Intelligent Robots and Systems (2005) 2935-2940
- [9] Deutscher, J. and Reid, I. Articulated body motion capture by stochastic search. Int. J. of Computer Vision, 61(2):185-205, 2005.
- [10] J.J. Pantrigo, A. Sánchez, K. Gianikellis and A. Duarte. Path Relinking Particle Filter for Human Body Pose Estimation. LNCS 3138 (2004) 653-661.
- [11] J.J. Pantrigo, A.S. Montemayor and R. Cabido. Scatter Search Particle Filter to for 2D Real-Time Hands and Face Tracking. International Conference on Image Analysis and Processing (2005) 953-960.
- [12] J.J. Pantrigo, A. Sánchez. Hybridizing Particle Filters and Population-Based Metaheuristics for Dynamic Optimization Problems. In proceedings of the Fifth International Conference on Hybrid Intelligent Systems - HIS'05 (2005) 41-46.
- [13] S. Arulampalam, S. Maskell, N. Gordon, T. Clapp. A Tutorial on Particle Filters for On-line Nonlinear/Non-Gaussian Bayesian Tracking. IEEE Tr. on Sig. Proc. 50: 2 (2002) 174-188.
- [14] M. Gendreau, J. Potvin. Metaheuristics in Combinatorial Optimization. Annals of Operations Research 140 (2005) 189-213.
- [15] Doucet, A., Godsill, S., Andrieu, C.: On sequential Monte Carlo sampling methods for Bayesian filtering. Statistics and Computing, 10:3 (2000) 197 - 208
- [16] Blum, C., Roli, A.: Metaheuristics in combinatorial optimization: Overview and conceptual comparison. ACM Computing Surveys 35:3 (2003) 268-308
- [17] Gendreau, M.: An Introduction to Tabu Search. In F. Glover, G. A. Kochenberger editors, Handbook of Metaheuristic. Kluwer Academic Publishers (2003) 37-54
- [18] Mladenovic, N., Hansen, P.: Variable Neighborhood Search. Computers Operations Research, 24 (1997) 1097-1100
- [19] Deutscher, J., Reid, I., Davidson, A.: Automatic Partitioning of High Dimensional Search Spaces associated with Articulated Body Motion Capture. Proc. of the IEEE Conf. on CVPR, vol. 2 (2001) 8-14
- [20] J. MacCormick and A. Blake. Partitioned sampling, articulated objects and interface-quality hand tracking. Proc. of the 7th ECCV, vol. 2, (2000) pp 3-19
- [21] Pantrigo, J.J., Sánchez, A., Gianikellis, K., Montemayor, A.S.: 2D Human Tracking by Efficient Model Fitting Using a Path Relinking Particle Filter. LNCS 3179 (2004) 202-213