

Estimación de Estado Distribuida Basado en Agentes Líderes: Aplicación al Seguimiento de Objetivo

Diego González Dondo

Centro de Investigación en Informática para la Ingeniería
Universidad Tecnológica Nacional, Facultad Regional Córdoba - Argentina
dgonzalez@scdt.frc.utn.edu.ar
<http://ciiii.frc.utn.edu.ar>

Abstract. En el trabajo se presentan simulaciones de la implementación de una estimación de estado en forma distribuida en una red de inalámbrica de sensores para el seguimiento de objetivos móviles basado en un esquema de un filtro de partículas en forma distribuida en nodos líderes. Estos son seleccionados en forma dinámica de acuerdo al desplazamiento del objetivo. En particular se evalúa el uso de un modelo de medición de ángulo de orientación relativo del objetivo a seguir, para la estimación en tiempo real de la velocidad y trayectoria del mismo a través de una región bajo la supervisión de la red.

Keywords: estimación distribuida · seguimiento de objetos · filtro de partículas

1 Introducción

Una red de agentes consiste de un conjunto de dispositivos que comparten un entorno e interactúan entre sí. Estos sistemas suelen ser usados para solucionar problemas que son difíciles o imposibles para un agente individual [7]. Un ejemplo de red de agentes son las redes inalámbricas de sensores, que consisten en un conjunto de dispositivos generalmente idénticos, llamados nodos, desplegados sobre un región geográfica de interés, que se usa para la medición y monitoreo de diversos fenómenos físicos, o para la detección y seguimiento de eventos, en forma cooperativa y coordinada [1]. Tales nodos poseen capacidad de comunicación con los nodos vecinos y de procesamiento de la información.

Un ejemplo típico de aplicación usando procesamiento cooperativo de la información en redes inalámbricas de sensores puede ser localización y seguimiento de objetos móviles en forma colaborativa. En este contexto la formulación del problema implica la medición y observación del estado del evento, cuya evolución temporal/espacial puede ser modelada como un proceso estocástico, que dependiendo de los sensores a utilizar, puede ser no lineal y no gaussiano. Los sensores utilizados en tales aplicaciones son generalmente cámaras (sensores de imágenes). Un modelo válido para las observaciones es el empleo de mediciones

angulares relativas del objetivo a seguir, respecto de la posición de cada nodo, lo implica una ecuación no lineal en la observación y una distribución de probabilidad a posteriori no gaussiana. Bajo estas consideraciones la estimación de estado puede ser realizada mediante técnicas de filtrado bayesianos, más específicamente implementaciones secuenciales de Monte Carlo, como filtro de partículas [2].

Desde el punto de vista de la información a intercambiar entre los nodos, el procesamiento distribuido se puede discriminar en dos grandes clases: los que transmiten las mediciones sin procesamiento (en crudo) y en los que se intercambian datos procesados. A su vez, este último se puede dividir en base al conjunto de nodos que realizan la estimación del estado en: estimación distribuida basada en nodos líderes, donde un solo nodo es el encargado de la tarea de estimación y estimación distribuida basada en consenso, donde todos los nodos procesan los datos simultáneamente.

En este trabajo, consideramos a una red descentralizada de cámaras para realizar tareas de estimación a través de procesamiento y comunicaciones locales basados en la distribución del procesamiento en nodos líderes. La contribución de este trabajo es la implementación simple de un filtro de partículas en forma distribuida para realizar tareas de estimación de las posiciones de un objeto en movimiento utilizando sensores de imagen.

El trabajo está organizado de la siguiente manera: Primero se presenta una descripción del filtro de partículas en la sección 2, luego la formulación del problema de seguimiento de un móvil mediante una red de sensores, así como su descripción matemática, es el objeto de la Sección 3. En la Sección 4 se analiza los problemas de inicialización de la red de sensores y de transferencia de liderazgo, dentro del contexto de métodos de filtrado de partículas adaptados a una red distribuida. Los resultados de diversas simulaciones numéricas se describen en la Sección 5. Finalmente, las conclusiones se exponen en la Sección 6.

2 Filtro de partículas

El Filtro de Partículas es un método de Monte Carlo aplicado a la estimación bayesiana en forma secuencial. Los filtros bayesianos secuenciales son métodos recursivos que permiten estimar el estado de un sistema. Considere un vector de estado \mathbf{x}_k que se desarrolla de acuerdo a al modelo de sistema

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \boldsymbol{\nu}_k) \quad (1)$$

donde $f(\cdot)$ es conocida y $\boldsymbol{\nu}_k$ es ruido blanco que es independiente de los estados pasados y presentes y cuya función de densidad de probabilidad (fdp) es conocida. Al tiempo k , un vector de medición \mathbf{y}_k es observado, el cual esta relacionado a \mathbf{x}_k a través del modelo de medición

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k, \boldsymbol{\omega}_k) \quad (2)$$

donde $h(\cdot)$ es conocida y $\boldsymbol{\omega}_k$ es ruido blanco de medición y cuya fdp es conocida. El conjunto de las ecuaciones (1) y (2) junto con sus hipótesis estadísticas forman el modelo probabilístico del sistema.

El estado que no se puede observar $\{\mathbf{x}_k; k \in \mathbb{N}\}$ es modelado como un proceso de Markov con una distribución de probabilidad inicial $p(\mathbf{x}_0) \sim \mathcal{N}(M_0, \Sigma_0)$ y una probabilidad de transición $p(\mathbf{x}_k|\mathbf{x}_{k-1})$. Se asume que las observaciones $\{\mathbf{y}_k; k \in \mathbb{N}\}$ son condicionalmente independientes en el tiempo dado el proceso \mathbf{x}_k y la función de verosimilitud $p(\mathbf{y}_k|\mathbf{x}_k)$ [5]. El enfoque bayesiano consiste en calcular la fdp a posteriori $p(\mathbf{x}_k|\mathbf{y}_{1:k})$. Se puede demostrar que fdp a posteriori se puede calcular en forma secuencial desde una fdp previa $p(\mathbf{x}_{k-1}|\mathbf{y}_{1:k-1})$ y el vector de medición \mathbf{y}_k .

$$p(\mathbf{x}_k|\mathbf{y}_{1:k-1}) = \int p(\mathbf{x}_k|\mathbf{x}_{k-1}) p(\mathbf{x}_{k-1}|\mathbf{y}_{1:k-1}) d\mathbf{x}_{k-1} \quad (3)$$

$$p(\mathbf{x}_k|\mathbf{y}_{1:k}) = \frac{p(\mathbf{y}_k|\mathbf{x}_k) p(\mathbf{x}_k|\mathbf{y}_{1:k-1})}{p(\mathbf{y}_k|\mathbf{y}_{1:k-1})} \quad (4)$$

El objetivo principal es la estimación instantánea del valor de expectación del estado actual.

Soluciones analíticas son, en la mayoría de los casos, imposibles de lograr e implementaciones numéricas involucra la computación de integrales multidimensionales. Una excepción importante es el caso especial de sistemas lineales y gaussianos.

Los filtros de partículas pueden manejar las no-linealidades. El filtro propuesto aquí es una simple implementación del filtro de partícula del tipo muestreo de importancia y remuestreo, descrito en [2, 6]. La función básica del filtro es aproximar la densidad a posteriori del estado del móvil, dadas todas las mediciones, por un conjunto de P puntos, $\{\mathbf{x}_k^p; p \in P\}$, llamados partículas, con sus correspondientes pesos, ω_k^p . Lo que implica una discretización de $p(\mathbf{x}_k|\mathbf{y}_{1:k})$:

$$p(\mathbf{x}_k|\mathbf{y}_{1:k}) \approx \sum_{i=1}^P \omega_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (5)$$

donde δ denota la función delta de Dirac. Las partículas y sus pesos son actualizados recursivamente a medida de que se disponen de nuevas mediciones. Las partículas se actualizan usando la ecuación de estado en tiempo discreto (9) distribuida de acuerdo a la densidad de transición:

$$\mathbf{x}_k^i \sim p(\mathbf{x}_k|\mathbf{x}_{k-1}^i, \mathbf{y}_k) \quad (6)$$

Para solucionar el problema de degeneración de las partículas se utiliza un esquema de remuestreo. Esto elimina muestras con bajos pesos de importancia y replica muestras con alto peso. El resultado son muestras independientes idénticamente distribuidas uniformemente $\{\mathbf{x}_k^i, \omega_k^p\} \rightarrow \{\hat{\mathbf{x}}_k^i, \hat{\omega}_k^i\}, \hat{\omega}_k^i = 1/P$. Por lo tanto la estimación del estado se obtiene por el cálculo de la expectación:

$$\hat{\mathbf{x}}_k = E\{\mathbf{x}_k|\mathbf{y}_k\} = \sum_{i=1}^P \hat{\omega}_k^i \hat{\mathbf{x}}_k^i \quad (7)$$

3 Planteamiento del problema

Comenzamos asumiendo que N nodos están desplegados aleatoriamente sobre una área, con posiciones preestablecidas $(x_s^i, y_s^i), i \in \{1..N\}$. Cada uno de estos nodos está equipado con un sensor de imágenes omnidireccional de modo tal que pueden captar objetos en cualquier posición angular pero dentro de un radio determinado por la resolución de la cámara. Es decir, el alcance de cada nodo sensor es finito, y asumido idéntico para todos los nodos. A su vez, los nodos poseen limitaciones en el rango de comunicación. Esto determina que solo pueden transferir información a nodos que están a su alcance de capacidad de transmisión (nodos vecinos). Se asume además un procesamiento previo de las imágenes como los presentados en [4, 8], para realizar la detección del objeto y la determinación de la posición angular del mismo en relación a la posición del nodo.

Suponemos también que existe un objeto en movimiento dentro del área de cobertura que en todo instante está siendo monitoreado por al menos un nodo sensor.

3.1 Modelo dinámico

En el contexto de móviles maniobrando lentamente, consideramos un modelo de velocidad casi constante [6] [3].

El vector de estado \mathbf{x} representa las coordenadas (x, y) y las velocidades (\dot{x}, \dot{y}) del móvil en el plano 2-D para un tiempo de muestreo δ entre observaciones.

$$\mathbf{x} \doteq [x \ y \ \dot{x} \ \dot{y} \ \delta]^T \quad (8)$$

Donde el vector de velocidad es típicamente constante por periodos cortos. La ecuación de estado en tiempo discreto asociada en el instante de tiempo k es

$$\mathbf{x}_{k+1} = \mathbf{F}\mathbf{x}_k + \mathbf{\Gamma}\boldsymbol{\nu}_k \quad (9)$$

donde \mathbf{F} es la matriz de movimiento y $\mathbf{\Gamma}$ es la matriz de ruido de transición para un intervalo de muestreo δ_k . $\boldsymbol{\nu}_k \sim \mathcal{N}(0, Q)$ es el vector 3×1 del ruido de proceso, donde la última componente es el ruido asociado a los errores de sincronización entre las observaciones.

3.2 Modelo de medición

Las observaciones disponibles en el instante k son mediciones de ángulos provenientes de un conjunto formado por M_k nodos cercanos al móvil.

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k) + \boldsymbol{\omega}_k \quad (10)$$

donde $\boldsymbol{\omega}_k$ es un ruido gaussiano independiente con media cero con varianza σ_θ^2 , siendo el modelo de observación de cada nodo como sigue:

$$h(\mathbf{x}_k)^{i_k} = \arctan(y_k - y_s^{i_k} / x_k - x_s^{i_k}) \quad (11)$$

es el verdadero ángulo dirección azimutal.

4 Distribución del procesamiento basado en nodos líderes

Inicialmente el movimiento o presencia de un objeto activa el mecanismo de detección en los nodos. El primer nodo que detecta el movimiento es usualmente el más cercano a él. Este nodo es llamado nodo líder. En cada instante k , el líder junto con otros nodos (quizás ninguno), que observan el móvil determinan un conjunto. Este conjunto es llamado clúster y se conforma alrededor o en las cercanías del objeto. Cada nodo realiza observaciones y se las transmite al líder, quien las colecta para llevar a cabo una estimación del estado actual del móvil. La estimación es realizada usando un filtro de partículas que corre en cada nodo líder.

4.1 Inicialización del filtro

Después de que la primera detección es realizada por el clúster, el líder ejecuta la inicialización del filtro. Esto se lleva a cabo porque la distribución inicial $p(\mathbf{x}_0)$ del estado debe ser conocida, bien determinada como información previa. En muchas aplicaciones esto no es una suposición válida y las partículas deben ser inicializadas a partir de la primera información disponible u otra información a priori. Asumiendo que la distribución del estado inicial es Gaussiana $p(\mathbf{x}_0) \sim \mathcal{N}(M_0, \Sigma_0)$ entonces solo es necesario estimar sus parámetros es decir la media M_0 y varianza Σ_0 . Un posible enfoque para realizar la estimación es usar una estrategia de mínimos cuadrados donde el objetivo es determinar la distancia r_i desde el nodo i al móvil. El sistema comienza con observaciones de ángulos (θ_i) desde los primeros K nodos que pueden detectar al objeto, cuya posición inicial es (x_0, y_0) . Las variables están relacionadas trigonométricamente siguiendo la siguiente ecuación:

$$r_i \tan \theta_i = (x_0 - x_s^i) / (y_0 - y_s^i) \quad (12)$$

para todo los sensores $1 \leq i \leq K$. Luego de operar nos queda un sistema sobredeterminado por lo que no existe una solución única. Por lo tanto podemos encontrar una solución por mínimos cuadrados que minimice el error cuadrático de la determinación de las distancias \hat{r}_i , quedando las estimaciones de las coordenadas del objeto:

$$\hat{X}_i = (\hat{r}_i \cos \theta_i + x_s^i, \hat{r}_i \sin \theta_i + y_s^i) \quad (13)$$

Con lo que solo resta estimar la media M_0 y la varianza Σ_0 para obtener los parámetros de la distribución inicial.

4.2 Transferencia del liderazgo

Se asume que el nodo más cercano al objeto móvil puede medir con mejor precisión que el resto. Como así también que cada nodo posee el conocimiento de su propia ubicación geográfica y la de sus vecinos. Dado la estimación actual

de la posición del móvil, se desea incrementalmente actualizar esta información transfiriendo el liderazgo a un nodo mas adecuado para llevar a cabo la tarea de filtrado [9].

La decisión de la selección del nuevo líder se realiza sin el conocimiento explícito de las mediciones que este pueda aportar sino en base a su ubicación con respecto a la estimación de la posición. De esta manera, el nuevo líder es determinado en base a su posición relativa a la estimación. A causa del movimiento del objeto el líder mas apropiado tiene que ser también una función del tiempo. Por lo tanto, en cada instante k , el líder utiliza su estimación de la distribución a posteriori para elegir un nuevo nodo líder al tiempo $k + 1$ de acuerdo a su ubicación.

Sea $A(l)$ el conjunto de nodos vecinos al nodo líder l que pueden comunicarse directamente con el en un solo lazo. Sea $(\hat{x}_{k+1}, \hat{y}_{k+1}, \hat{z}_{k+1})$ la ubicación predicha del móvil en el instante k . Entonces se elige al nodo mas cercano a esta ubicación como el nuevo líder. Esto es, el nuevo nodo líder l^* es dado por:

$$l^* = \arg \min_{i \in A(l)} [(x_s^i - \hat{x}_{k+1})^2 + (y_s^i - \hat{y}_{k+1})^2] \quad (14)$$

Donde (x_s^i, y_s^i) es la coordenada del sensor i . El líder puede elegirse a si mismo como nuevo líder; pero si no este debe propagar las partículas de la distribución a posteriori hacia el nuevo líder. En la Fig. 1 se puede observar el mecanismo de transferencia del líder, donde el próximo líder es el mas cercano a la estimación de la posición.

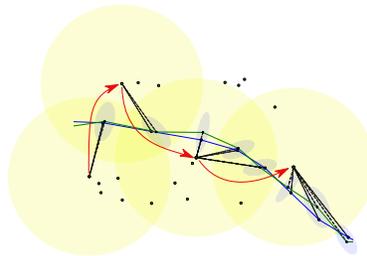


Fig. 1: Transferencia del liderazgo hacia el nodo mas cercano a la estimación de la posición

5 Simulaciones

En esta sección, presentamos los resultados obtenidos de la aplicación del filtro de partículas con la utilización de un modelo de observación angular para el seguimiento de un objeto dentro de una red de sensores. Para ello se llevo a cabo una representación de una red de sensores distribuidos aleatoriamente sobre una

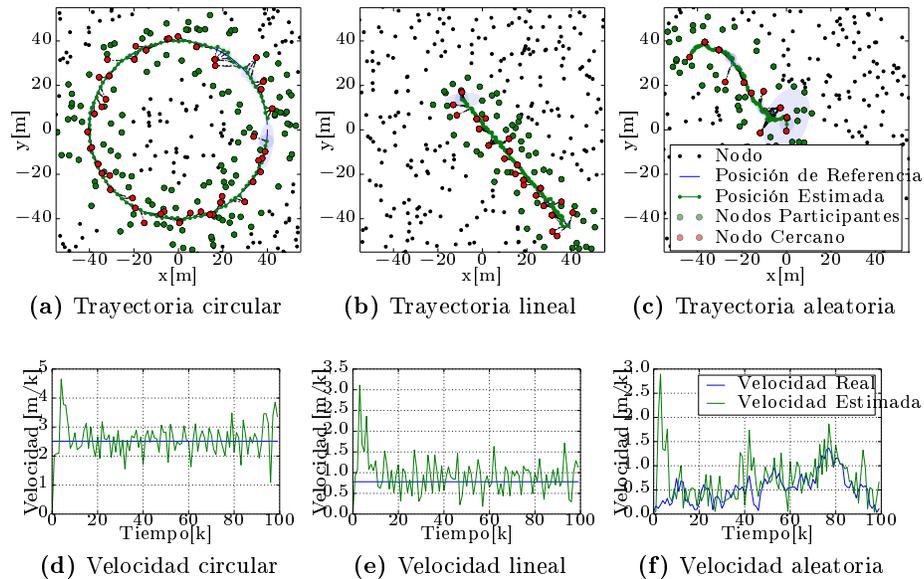


Fig. 2: Trayectorias evaluadas junto con las estimaciones de posición velocidad correspondientes.

región rectangular, con una densidad de cobertura de 1 nodo cada $10m^2$. El esquema propuesto es aplicado al seguimiento de un objeto en movimiento. El ensayo se realizó generando en forma artificial y controlada, diferentes tipos de trayectorias para el objeto: trayectoria circular, lineal y aleatoria, donde el periodo de simulación para cada una de ellas fue de $T = 100$. En la figura 2 podemos ver una ilustración de las tres trayectorias analizadas realizadas por el objeto dentro de la red, como así también las estimaciones de velocidad correspondientes.

Para medir el desempeño se generaron $n = 100$ corridas de Monte Carlo para cada trayectoria con idénticos estados iniciales y parámetros del modelo para medir la performance del filtro de partículas. Se propuso un $N = 200$ como cantidad de partículas para el filtro. Para cada corrida de simulación y para cada salto de tiempo k , cuando una estimación fue obtenida, se cálculo el error en términos de la distancia euclídea entre la posición estimada y la real posición del objetivo. En las figuras 3 se observan las medias del error cuadrático medio en la estimación y su desviación para la estimación de la posición, para cada trayectoria analizada para 100 corridas de simulaciones. Analizando ambas figuras se puede ver una rápida convergencia del filtro y un bajo error de estimación. Los resultados cualitativos demuestran que la estimaciones realizadas siguen al objetivo para diferentes trayectorias.

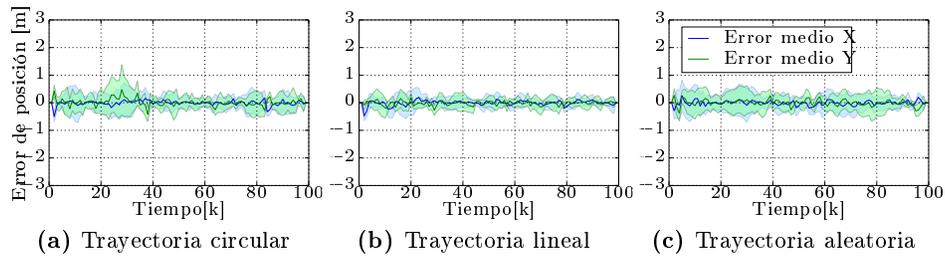


Fig. 3: Media y desviación estándar de los errores en la estimación de la posición para diferentes trayectorias con 100 iteraciones independientes cada una.

6 Conclusión

En el trabajo descrito se presentó un esquema de filtro de partículas distribuido en nodos líderes de una red de sensores. Estos últimos fueron seleccionados en forma dinámica de acuerdo a la trayectoria del objeto a seguir. Para la evaluación del mismo se llevaron a cabo simulaciones de una red de inalámbrica de sensores para el seguimiento de objetos móviles. En particular se evaluó el uso de sensores de ángulo de orientación donde el objetivo es la estimación en línea de la velocidad y trayectoria de un objeto a través de una región bajo la supervisión de la red. Se observó la capacidad del esquema para diferentes tipos de trayectorias.

References

- [1] Akyildiz, I., Su, W., Sankarasubramaniam, Y., Cayirci, E.: A survey on sensor networks. *Communications Magazine*, IEEE 40(8), 102–114 (aug 2002)
- [2] Arulampalam, M., Maskell, S., Gordon, N., Clapp, T.: A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking. *Signal Processing*, IEEE Transactions on 50(2), 174–188 (feb 2002)
- [3] Bar-Shalom, Y., Kirubarajan, T., Li, X.R.: *Estimation with Applications to Tracking and Navigation*. John Wiley & Sons, Inc., New York, NY, USA (2002)
- [4] Jalal, A.S., Singh, V.: The state-of-the-art in visual object tracking. *Informatica (Slovenia)* 36(3), 227–248 (2012)
- [5] Jazwinski, A.H.: *Stochastic Processes and Filtering Theory*. Dover Books on Electrical Engineering, Dover Publications (2013)
- [6] Ristic, B., Arulampalam, S., Gordon, N.: *Beyond the Kalman filter : particle filters for tracking applications*. Artech House, Boston, London (2004), <http://opac.inria.fr/record=b1102164>
- [7] Woolridge, M., Wooldridge, M.J.: *Introduction to Multiagent Systems*. John Wiley & Sons, Inc., New York, NY, USA (2001)
- [8] Yilmaz, A., Javed, O., Shah, M.: Object tracking: A survey. *ACM Computing Surveys* 38(4), 13–es (Dec 2006)
- [9] Zhao, F., Shin, J., Reich, J.: Information-driven dynamic sensor collaboration. *Signal Processing Magazine*, IEEE 19(2), 61–72 (Mar 2002)