

Sistema de seguimiento de objetos usando múltiples cámaras y estimación bayesiana

Diego González Dondo, Javier Redolfi, Guillermo Steiner

Universidad Tecnológica Nacional, Facultad Regional Córdoba, Córdoba, Argentina.
CIII - Centro de Investigación en Informática para la Ingeniería
dgonzalez@scdt.frc.utn.edu.ar, jredolfi@frc.utn.edu.ar

Resumen— In the current work we present simulations of a wireless sensors network for target tracking based on the implementation of a particle filter in a distributed way. In particular, we evaluate the use of bearing-only sensors where the objective is the online estimation of the trajectory and velocity of a object through a region under surveillance of the network. Furthermore, we analyzed the use of a initiation scheme to enhance the filter performance.

Palabras Clave— Wireless Sensor Network, Particle Filter, Target Tracking

1. INTRODUCCIÓN

Una red de sensores consiste de 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. Los nodos que conforman la red pueden estar interconectados entre sí mediante una estructura de malla, o bien siguiendo un esquema jerárquico del tipo arborescente con nodos cabecera que reciben la información sensorial de varios otros nodos, información que luego remiten hacia un nodo central para el procesamiento de la misma [1, 2, 3, 4].

Los eventos a medir pueden ser del tipo extendido, como por ejemplo cuando se desea analizar la temperatura, humedad, o radiación solar en toda una región de interés, o ser localizados, como en el caso en que se busca determinar la aparición o evolución de eventos móviles dentro del área de cobertura de la red. Este segundo tipo de situaciones son de gran interés en diversas aplicaciones, tales como el control demográfico de especies animales, detección temprana y seguimiento de situaciones de riesgo ambiental (por ejemplo el monitoreo de focos de incendios forestales), monitoreo de tráfico urbano, etcétera.

El procesamiento de la información sensorial puede realizarse genéricamente de dos maneras: centralizada o distribuida. En una red centralizada los nodos (fuentes) solamente proveen información que es transmitida a una unidad de procesamiento central (sumidero). Por el contrario, en el procesamiento distribuido los nodos no sólo proveen la información sensorial sino que también realizan parte del procesamiento de la misma en forma coope-

rativa, usando el poder computacional de cada nodo. La suposición básica es que cada nodo en la red puede explotar la información recibida para optimizar las futuras acciones de censado y manejar los limitados recursos de procesamiento y comunicación eficientemente.

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. Los nodos desplegados geoespacialmente colectan señales desde un objetivo en movimiento u otra entidad dentro de su área de cobertura y comunica la información sobre el mismo con otros nodos vecinos para ubicar al objeto. Dependiendo del campo de aplicación el objeto a seguir puede ser animales, vehículos, o personas. Los sensores utilizados en tales aplicaciones son generalmente cámaras (sensores de imágenes).

En aplicaciones de seguimiento, 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 [5, 6, 7]. 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 [8].

La utilización de cámaras pueden expandir el horizonte tradicional de aplicaciones de monitoreo a través de un aumento del campo de visión [4], en donde es posible percibir el entorno desde diferentes y dispares puntos de vista. El solapamiento de observaciones simultáneas puede ayudar al mejoramiento del monitoreo del entorno.

En este trabajo, consideramos a una red descentralizada de cámaras para realizar tareas de estimación a través de procesamiento y comunicaciones locales. 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: 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 ?? En la Sección 3.1 se analiza los problemas de inicialización de la red de sensores y de transferencia de liderazgo del clúster de seguimiento, 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 4. Finalmente, las conclusiones se exponen en la Sección 6.

2. TRABAJOS RELACIONADOS

3. MÉTODO PROPUESTO

En este trabajo se propone resolver el seguimiento de objetivos usando múltiples sensores y una posterior fusión de las mediciones usando estimación bayesiana.

A continuación se describe el algoritmo de fusión propuesto, los modelos dinámicos y de observación utilizados.

3.1. Fusión de las mediciones

Para la estimación del estado del objeto se emplea un filtro de partículas el cual es un método de Monte Carlo que permite la estimación bayesiana en forma secuencial.

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 [9, 10], 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.

3.1.1. Modelo dinámico

En el contexto de móviles maniobrando lentamente, consideramos un modelo de velocidad casi constante [11] [12].

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.

$$\mathbf{x} \doteq [x \ y \ \dot{x} \ \dot{y} \ \delta]^T \quad (1)$$

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

$$\mathbf{x}_{k+1} = \mathbf{F}\mathbf{x}_k + \mathbf{\Gamma}\boldsymbol{\nu}_k \quad (2)$$

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.

3.1.2. 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.

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k) + \boldsymbol{\omega}_k \quad (3)$$

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:

$$h(\mathbf{x}_k)^{i_k} = \arctan(y_k - y_s^{i_k} / x_k - x_s^{i_k}) \quad (4)$$

es el verdadero ángulo dirección azimutal.

3.2. Filtro de partículas

El filtro propuesto aquí es una simple implementación del filtro de partícula del tipo muestreo de importancia y remuestreo, descrito en [8, 11]. 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 $p(\mathbf{y}_k | \mathbf{x}_k)$ [13]. El objetivo principal es la estimación instantánea del valor de expectación del estado actual. 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 (2) 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:

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

En la Fig. 1 se ilustra 200 muestras (partículas) obtenidas desde la densidad a posteriori de la estimación de la posición en un gráfico de dispersión. En el mismo se puede observar trayectoria estimada (verde) por la red de sensores y la real (azul) para diferentes instantes de tiempo. Las líneas que parten desde los nodos líderes indican las observaciones de ángulo (línea a trazos) y las posiciones estimadas (las líneas continuas.)

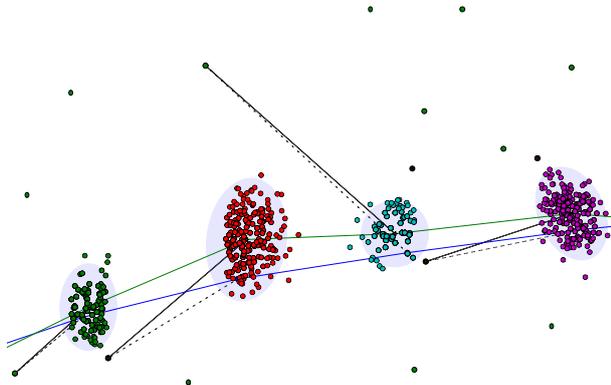


Figura 1: Muestras de la distribución de densidad a posteriori en la estimación de la posición de un objeto para diferentes instantes de tiempo.

3.3. 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 más adecuado para llevar a cabo la tarea de filtrado [14].

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 más 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 $\Lambda(l)$ 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 más cercano a esta ubicación como el nuevo líder. Esto es, el nuevo nodo líder l^* es dado por:

$$l^* = \arg \min_{i \in \Lambda(l)} [(x_s^i - \hat{x}_{k+1})^2 + (y_s^i - \hat{y}_{k+1})^2 + (z_s^i - \hat{z}_{k+1})^2] \quad (8)$$

Donde (x_s^i, y_s^i, z_s^i) es la coordenada del sensor i . El líder puede elegirse a sí mismo como nuevo líder; pero

si no este debe propagar las partículas de la distribución a posteriori hacia el nuevo líder. En la Fig. 2 se puede observar el mecanismo de transferencia del líder, donde el próximo líder es el más cercano a la estimación de la posición.

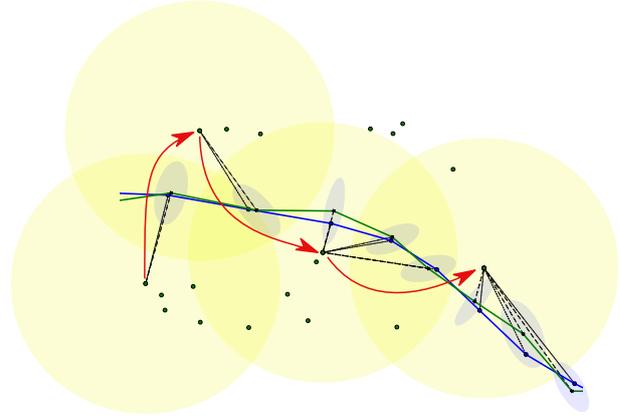
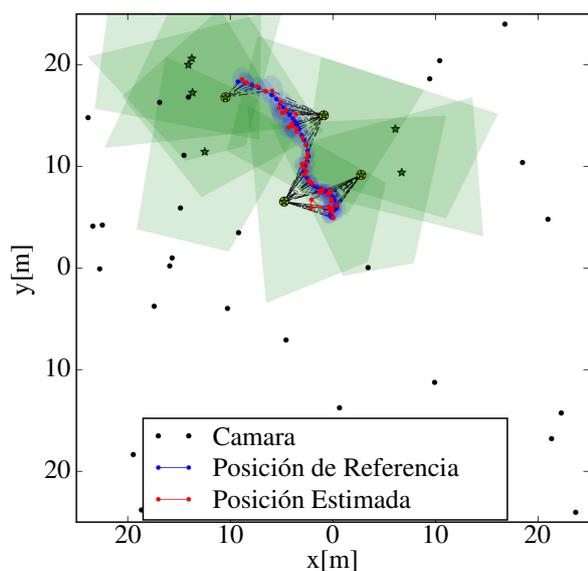


Figura 2: Transferencia del liderazgo hacia el nodo más cercano a la estimación de la posición

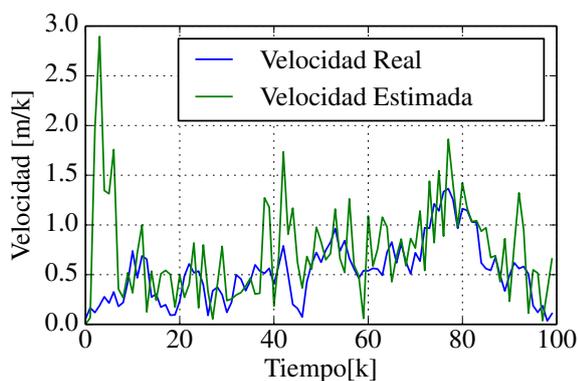
4. SIMULACIONES

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 llevó a cabo una representación de una red de sensores distribuidos aleatoriamente sobre una región rectangular, con una densidad de cobertura de 1 nodo cada $10 m^2$. 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 3 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 calculó el error en términos de la distancia euclídea entre la posición estimada y la real posición del objetivo. En las figuras 4 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.



(a) Trayectoria aleatoria



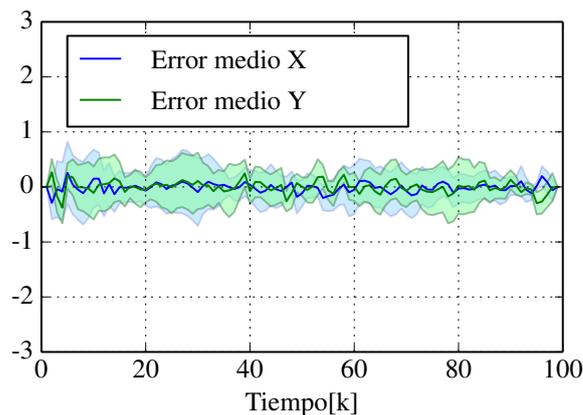
(b) Velocidad aleatoria

Figura 3: Trayectorias evaluadas junto con las estimaciones de posición velocidad correspondientes.

5. RESULTADOS EXPERIMENTALES

Después de validar el funcionamiento del método con simulaciones, se decidió montar una red de 3 cámaras del tipo IP en el laboratorio de experimentación de robótica del CIII¹ para realizar el seguimiento de un robot móvil. Específicamente se utilizó la plataforma ROMAA[15], la cual posee una PC de a bordo, una cámara y sensores de odometría en las ruedas. Las cámaras utilizadas como sensores son las TL-SC3230N de la firma TP-LINK, que cuentan con una resolución máxima de 1,3 Mega-píxel (1280x1024), un ángulo de visión horizontal de 47° y conectividad Wi-Fi. Las dimensiones del laboratorio son de aproximadamente 8x4m, de tal manera que para cubrir la mayor área posible se ubicaron las cámaras a una distancia de 4m entre ellas, colocadas a una altura de 3,3m

¹Centro de Investigación en Informática para la Ingeniería, FRC, UTN. URL: <http://ciiu.frc.utn.edu.ar>



(a) Trayectoria aleatoria

Figura 4: Media y desviación estándar de los errores en la estimación de la posición para diferentes trayectorias con 100 iteraciones independientes cada una.

y apuntando hacia el suelo.

En este experimento se generó una trayectoria con el ROMAA para luego comparar el resultado de la odometría del robot con la estimación de la posición obtenida con el filtro.

5.1. Obtención de las mediciones

Como se explicó anteriormente, el filtro estima el estado de la plataforma basado en las observaciones del estado realizadas por cada sensor. Para el caso de cámaras, se necesita conocer la posición del ROMAA en el plano de la imagen de esta. Las cámaras fueron configuradas para obtener una imagen cada 100ms y luego sobre esta secuencia de imágenes se aplicó un algoritmo de tracking, el cual nos devuelve las coordenadas de un recuadro en donde es más probable que se encuentre el robot. De este recuadro, se tomó el centro como posición del robot en la imagen. El algoritmo de tracking utilizado es CMT [16], el cual combina técnicas de tracking basadas en apariencia y búsqueda de correspondencias entre descriptores de características basado en consenso para realizar el seguimiento de objetos en secuencias largas de imágenes. Para la inicialización del CMT se necesita un recuadro inicial del objeto a seguir, el cual es obtenido con un detector de movimiento [?].

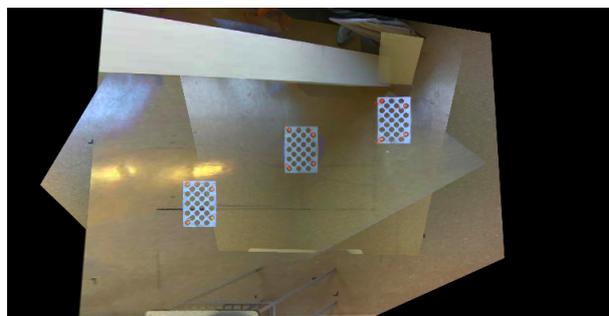


Figura 5: Área de cobertura de las cámaras

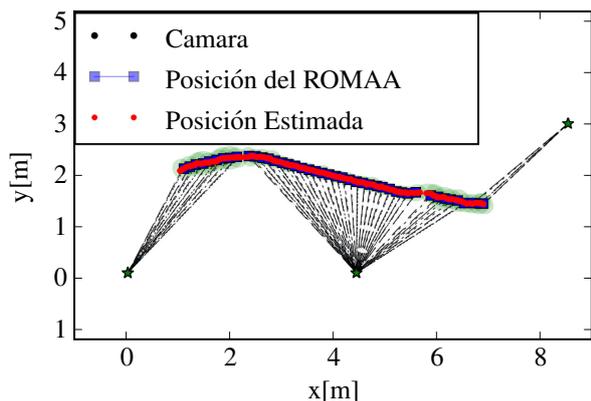


Figura 6: Camara switch

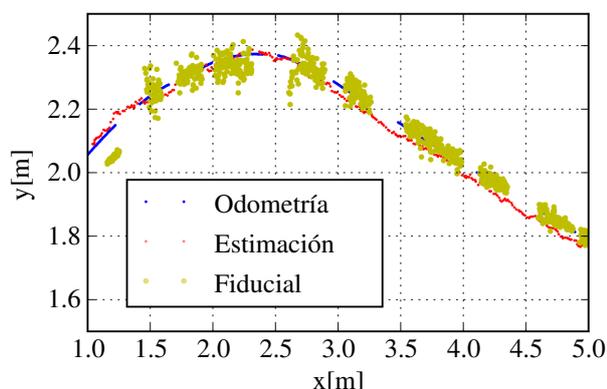


Figura 7: Resultados de la estimación de posición en comparaciones con odometría encoder y fiducial

6. CONCLUSIONES

REFERENCIAS

[1] I. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci, "A survey on sensor networks," *Communications Magazine, IEEE*, vol. 40, no. 8, pp. 102–114, aug 2002.

[2] J. Yick, B. Mukherjee, and D. Ghosal, "Wireless sensor network survey," *Computer Networks*, vol. 52, no. 12, pp. 2292–2330, 2008.

[3] R. Kulkarni, A. Foerster, and G. Venayagamoorthy, "Computational intelligence in wireless sensor networks: A survey," *Communications Surveys Tutorials, IEEE*, vol. 13, no. 1, pp. 68–96, quarter 2011.

[4] I. F. Akyildiz, T. Melodia, and K. R. Chowdhury, "A survey on wireless multimedia sensor networks," *Computer Networks*, vol. 51, no. 4, pp. 921–960, 2007.

[5] A. Mohammadi and A. Asif, "A consensus/fusion based distributed implementation of the particle filter," in *Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP), 2011 4th IEEE International Workshop on*, dec. 2011, pp. 285–288.

[6] O. Hlinka, O. Sluciak, F. Hlawatsch, P. Djuric, and M. Rupp, "Likelihood Consensus and Its Application to Distributed Particle Filtering," *Signal Processing, IEEE Transactions on*, vol. PP, no. 99, p. 1, 2012.

[7] A. Chiuso, F. Fagnani, L. Schenato, and S. Zampieri, "Gossip Algorithms for Simultaneous Distributed Estimation and Classification in Sensor Networks," *Selected Topics in Signal Processing, IEEE Journal of*, vol. 5, no. 4, pp. 691–706, aug. 2011.

[8] M. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, "A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking," *Signal Processing, IEEE Transactions on*, vol. 50, no. 2, pp. 174–188, feb 2002.

[9] A. S. Jalal and V. Singh, "The state-of-the-art in visual object tracking," *Informatica (Slovenia)*, vol. 36, no. 3, p. 227–248, 2012.

[10] A. Yilmaz, O. Javed, and M. Shah, "Object tracking: A survey," *ACM Computing Surveys*, vol. 38, no. 4, pp. 13–es, Dec. 2006.

[11] B. Ristic, S. Arulampalam, and N. c. Gordon, *Beyond the Kalman filter : particle filters for tracking applications*. Boston, London: Artech House, 2004. [Online]. Available: <http://opac.inria.fr/record=b1102164>

[12] Y. Bar-Shalom, T. Kirubarajan, and X.-R. Li, *Estimation with Applications to Tracking and Navigation*. New York, NY, USA: John Wiley & Sons, Inc., 2002.

[13] A. H. Jazwinski, *Stochastic Processes and Filtering Theory*, ser. Dover Books on Electrical Engineering. Dover Publications, 2013.

[14] F. Zhao, J. Shin, and J. Reich, "Information-driven dynamic sensor collaboration," *Signal Processing Magazine, IEEE*, vol. 19, no. 2, pp. 61–72, Mar 2002.

[15] G. Perez Paina, R. Araguas, D. Gaydou, G. Steiner, and L. R. Canali, "Romaa-ii, an open architecture mobile robot," *Latin America Transactions, IEEE (Revista IEEE America Latina)*, vol. 12, no. 5, pp. 915–921, 2014.

[16] G. Nebehay and R. Pflugfelder, "Consensus-based matching and tracking of keypoints for object tracking," in *Applications of Computer Vision (WACV), 2014 IEEE Winter Conference on*. IEEE, 2014, pp. 862–869.