

FILTRO DE PARTÍCULAS ACOTADO PARA FUSIÓN DE DATOS EN REDES DE SENSORES

Silvana Sañudo, Favio Masson

*Departamento de Ingeniería Eléctrica, Universidad Nacional del Sur
Av. Alem 1253 – (8000) Bahía Blanca- ARGENTINA
e-mail: silvana79@gmail.com*

Resumen: En este trabajo se presenta un estimador Bayesiano para el problema de localización en redes de sensores. El algoritmo de fusión se basa en un filtro de partículas pero que en lugar de transmitir partículas entre nodos transmite cotas donde estas tienen mayor probabilidad. De esta forma, el método es ideal para aplicaciones donde se descentralice el proceso de fusión en nodos que tienen baja capacidad de transmisión de datos y donde los modelos de observación sean no Gaussianos, como en el caso de sensores de rango solamente.

Palabras Claves: Filtro de Partículas, Redes de Sensores, Fusión de Datos

1. INTRODUCCIÓN

Una de las aplicaciones típicas de redes de sensores es la detección y localización de eventos o fuentes donde las estimaciones de los estados se basan en medidas ruidosas aportadas por los sensores y en la información obtenida a priori. Generalmente los sistemas incluyen modelos no lineales y ruidos no Gausseanos en su dinámica (Arulampalan *et al.*, 2002; Daum, 2005).

Por ejemplo si se utiliza un sensor de rango solamente para ubicar un objetivo de interés, la actualización resultante es claramente no Gaussiana. Lo mismo vale para el caso de sensores de ángulo solamente. La utilización de un filtro que supone distribuciones Gaussianas lleva indefectiblemente a inconsistencias. Algunas formas de solucionar este problema es retrasando la actualización hasta obtener información suficiente. En el ejemplo del sensor de rango solamente, con al menos tres medidas de distintos sensores no ubicados en el mismo lugar, sería posible obtener una estimación prácticamente Gaussiana. Este problema es conocido en aplicaciones de robótica como el SLAM (Durrant-Whyte, H. & Bailey T., 2006). Otra cuestión importante es si las incertidumbres de las estimaciones a priori son

grandes y se produce una actualización muy precisa comparada con esta. Si se utilizan filtros basados en linealizaciones como el Filtro Extendido de Kalman se viola la suposición común de linealizar cerca del punto de operación, llevando a resultados catastróficos.

El algoritmo de Filtro de Partículas (PF por su nombre en inglés) proporciona una forma simple y efectiva de modelar procesos estocásticos con funciones de distribución de probabilidad (pdf por su nombre en inglés) y modelos de propagación arbitrarios. Se basan para esto en métodos secuenciales de Monte Carlo (Carpenter *et al.*, 1999). Para representar la densidad de probabilidades se utilizan puntos mäsicos (“partículas”) que son estados posibles del proceso, distribuidas sobre su espacio de estados.

Cuando se obtiene una medida, el PF utiliza éstos puntos mäsicos para aproximar la distribución a posteriori. Para obtener una buena aproximación se requiere un número significativo de partículas lo que implica gran capacidad de almacenamiento y comunicación. Un algoritmo que permite la utilización de esta representación de las distribuciones para estimar un estado de interés es

el método Bayesiano de Muestreo Secuencial por Importancia (SIR por su nombre en Inglés; Gordon et al., 1990).

El Filtro de Partículas Gausseano (GPF por su nombre en Inglés) es un caso especial del PF que aproxima las distribuciones posteriores con distribuciones Gausseanas simples (Kotecha et al., 2003) y para la actualización utiliza la media y la varianza de los estados, junto con la nueva medida del sensor.

En este trabajo se presenta un Algoritmo que utiliza partículas para la representación de las distribuciones y acota la pdf a posteriori a una región de alta probabilidad de los estados teniendo en cuenta la incertidumbre del sensor y su modelo. La propagación del espacio de estados estimado se basa en la selección de partículas por comparación de sus respectivos pesos con un valor adaptivo de éste; cuyo procesamiento es muy simple y anula la probabilidad de empobrecimiento de muestras en lo sucesivo.

La aplicación presentada es la localización de una fuente sonora sobre un espacio de estados de dos dimensiones (X e Y) midiendo su potencia. En este caso la pdf tomaría una forma anular. En este trabajo se presenta una aproximación acotando la pdf con rectángulos que son los que se propagan de nodo a nodo. La potencialidad del PF presentado se refiere al bajo requerimiento de comunicación y procesamiento de datos del algoritmo de fusión resultante pero que no supone ningún tipo de característica a priori de la pdf. Además, esta solución se puede extender en forma directa a todos aquellos sensores que miden rango en cualquier aplicación de localización o seguimiento.

El presente trabajo se organiza de la siguiente manera, en la Sección 2 se describe el algoritmo del *filtro de partículas acotado*. En la Sección 3 se presenta un ejemplo de aplicación y se muestran los resultados de simulación. Finalmente en la Sección 4 se presentan conclusiones y las mejoras futuras del filtro propuesto.

2. FILTRO DE PARTÍCULAS ACOTADO

2.1 Algoritmo general

El algoritmo comienza con una distribución inicial de partículas en un nodo líder de la red. Luego de actualizar su estimación con su medida, este nodo le comunica a otro su estimación bajo la forma de una cota. La elección del nodo está fuera del propósito de este trabajo; un método posible de selección es elegir el vecino que más aporte en términos de información a la estimación (Masson et al., 2004). El nodo que recibe la cota genera una distribución de partículas dentro de la región recibida y procede con la predicción y actualización.

Luego se propone como distribución a priori en cada nodo N partículas distribuidas sobre una grilla regular con un peso asignado $w_i=1/N$. Con esta distribución se realiza la predicción utilizando para ello el modelo de estados

$$\tilde{\mathbf{x}}_{k|k-1}^i = \mathbf{f}[\tilde{\mathbf{x}}_{k-1|k-1}^i] + \mathbf{v}_k^i \quad (1)$$

donde $\tilde{\mathbf{x}}_{k|k}^i$ es cada una de las partículas, $\mathbf{f}[\cdot]$ es la función, probablemente no lineal, que propaga los estados en el tiempo y \mathbf{v}_k^i es una muestra de un ruido aditivo con una distribución arbitraria.

Sobre esta nueva distribución se calcula la media y los autovalores y autovectores de la matriz de covarianza. Con estos elementos se trasladan las partículas al origen y rotan en la dirección de los ejes principales. Allí se calculan los nuevos pesos incorporando la medición. Para esto cada nuevo peso se calcula como

$$w_i = \frac{p(z_k | \tilde{\mathbf{x}}_{k|k-1}^i)}{\sum_{j=1}^R p(z_k | \tilde{\mathbf{x}}_{k|k-1}^j)} \quad (2)$$

donde z_k es la observación. Para obtener los pesos es necesario obtener la función de verosimilitud $p(z_k | \tilde{\mathbf{x}}_k^i)$. Si la medida es Gaussiana con varianza conocida R , esta probabilidad queda como

$$w_i = \frac{e^{\left(\frac{-(z - \mathbf{h}[\tilde{\mathbf{x}}_{k|k-1}^i])^2}{2R} \right)}}{\sqrt{2\pi R}} \quad (3)$$

Se define luego una cota P_c que puede ser general para todos los nodos o adaptarse conforme al número de partículas mínimo que se considera representativo del estado. Con esta cota se seleccionan aquellas partículas con pesos mayores a esta: $w_i > P_c$. Una vez seleccionadas las partículas con mayor probabilidad, se extraen las cotas en el espacio de estado que delimita la zona de mayor probabilidad y que una vez vueltas a rotar y trasladar se comunican al siguiente nodo.

2.2 Implementación práctica.

Lo presentado en la sección anterior es el algoritmo propuesto en su forma más general. En este trabajo se adoptaron algunas simplificaciones prácticas con el fin de hacer un análisis funcional del algoritmo propuesto.

Inicialmente se distribuyen N partículas sobre el espacio de estados a cubrir (total), equi-espaciadas por estado (ejes x e y); a ésta distribución la denominaremos grilla.

Se adopta además una forma de fusión centralizada en lugar de una distribuida. Así, el nodo líder funciona como nodo base y el resto de los nodos

comunican sus resultados a este. El esquema propuesto es el que se muestra en la figura 1. Allí R es la incertidumbre del sensor, $CotaP$ la cota de comparación de peso para la selección de las partículas, X_s la posición del sensor, $Media$ el promedio de cada estado y $MatR$ la matriz de rotación. En la base se calculan las matrices de rotación y cotas que se envían a cada nodo donde son usadas para generar las partículas, hacer la actualización y las nuevas cotas que son vueltas a transmitir a la base. La racionalidad de este esquema se basa en que los nodos tienen baja capacidad de cálculo que es descargado en la base (Sadler, 2005) y que se está tratando de localizar una fuente fija.




Fig. 1: Distribución de las tareas del algoritmo entre la base o nodo central y los nodos sensores.

Con cada una de las medidas obtenidas por cada nodo, el conjunto de partículas se irá ubicando sobre zonas restringidas del espacio de estados total (se contará con un sub-espacio diferente según sea el sensor y su posición), es por ello que se torna imprescindible trasladarlas a un espacio común a la totalidad de los sensores para el procesamiento; un espacio con media cero y en el que los rectángulos que contienen las partículas se encuentren alineados al espacio de estados. Esto se logra utilizando como se dijo, la matriz de covarianza y la media.

Para fusionar todas las medidas, se intersectan todos los sub-espacios de estados; en (Isler & Bajcsy, 2005) se puede ver un ejemplo de aplicación de éste principio. Una vez lograda la intersección, se extraen las cotas mínima y máxima por estado y se forma un rectángulo; se esparcen partículas dentro, equi-espaciadas por eje, se calcula la media, se traslada al origen, se comunican a los sensores las cotas y las medias y se adopta el nuevo sub-espacio como punto de partida para una nueva corrida, que permitirá una mejor estimación. Es decir, el espacio total para cada sensor ahora será el sub-espacio estimado, trasladado al origen.

3. SIMULACIONES Y RESULTADOS

Para el ejemplo se utilizaron cuatro nodos sensores, dos de ángulo y dos de rango (Masson *et al.*, 2004; Puschini *et al.*, 2004); y un nodo base para la cobertura de un espacio de estados de veinte por veinte metros. Las ecuaciones (4) representan el modelo de cada sensor (ángulo y rango); donde v es

la incertidumbre del modelo; x e y son medidas de distancia en cada variable de estado.

$$z = a \tan\left(\frac{y}{x}\right) + v \quad (4)$$

$$z = \log\left(\frac{1}{\sqrt{x^2 + y^2}} + v\right)$$

En (5) se muestran las ecuaciones para el cálculo de la predicción de la observación sobre cada partícula.

$$h_i = a \tan\left(\frac{y}{x}\right) \quad (5)$$

$$h_i = -\log(\max(x, y)) - \log\left(\left(\frac{\min(x, y)}{\max(x, y)}\right)^2 + 1\right)$$

El logaritmo es utilizado para comprimir el rango dinámico de las medidas, facilitando luego la elección de $CotaP$. Finalmente los pesos se calculan con (3), teniendo en cuenta, para el caso del sensor de rango, que los valores de R , z y h_i deben expresarse en logaritmo base diez.

En la simulación se ubicaron los sensores y la fuente como muestra la Fig. 2. Los sensores de ángulo se representan con rectángulos y se encuentran en $[-10 \ 0]$ y $[0 \ -10]$; perpendiculares uno respecto del otro. Los sensores de rango se encuentran ubicados en $[-5 \ 5]$ y $[5 \ 5]$. La fuente a detectar se ubica en $[4 \ 0]$. Se adoptó $N=500$.

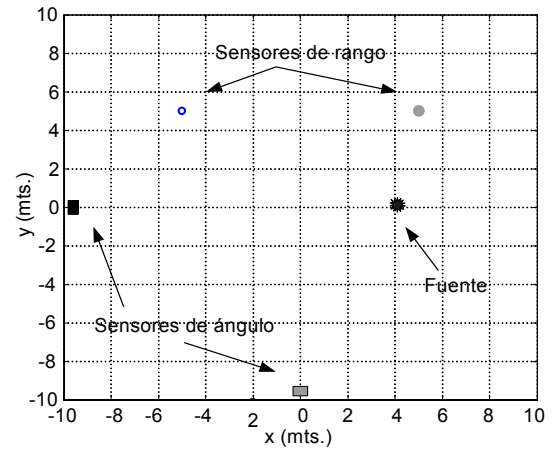


Fig. 2: Esquema de la ubicación de los nodos y la fuente para el ejemplo simulado.

En las Fig. 3, Fig.4 y Fig.5 se pueden apreciar las partículas elegidas y los rectángulos que las encierran formados en la base con las cotas recibidas y llevados a la ubicación correspondiente en el espacio de estados real. Se debe recordar que la base solo recibe las cotas, las partículas se muestran solo a modo ilustrativo para la simulación. En la práctica, si se debieran comunicar las partículas se requeriría de gran capacidad de comunicación que se quiere evitar.

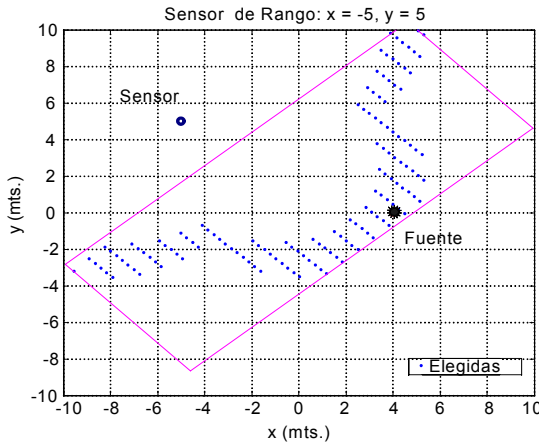


Fig. 3: Rectángulo resultante del sensor de rango ubicado en $[-5\ 5]$.

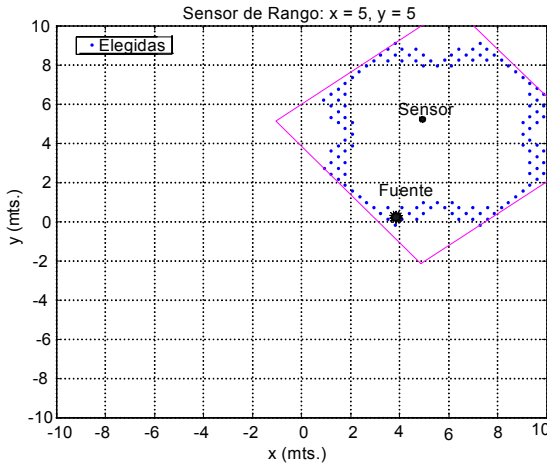


Fig. 4: Rectángulo resultante del sensor de rango ubicado en $[5\ 5]$.

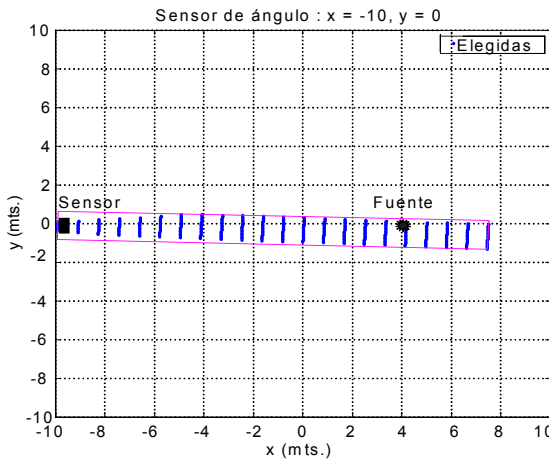


Fig. 5: Rectángulo resultante del sensor de ángulo ubicado en $[-10\ 0]$.

El número de partículas elegidas y la forma del espacio en que se encuentran dependen de la incertidumbre del sensor y la cota de los pesos; si bien R está dado por el sensor, la cota se debe elegir de modo que siempre se seleccione un mínimo de partículas para no obrar de sobre-confidente y en simulación se puede observar que

la fuente se halla entre ellas. En el caso presentado la cota se eligió basándose en un número determinado de partículas supervivientes. La cota así elegida resultaba en una distinta para cada nodo.

En la Fig. 5 se observa que las partículas se encuentran distribuidas en un sub-espacio del espacio total, esto se debe a que se realizan varias medidas y estimaciones dentro de cada sensor antes de enviar el resultado a la base. Esto es conveniente solo en la primera iteración, cuando el espacio de estados común equivale al espacio total, ya que al no tener información previa se logra reducir el sub-espacio aún midiendo sobre un mismo nodo, pero cuando ya se tiene información previa, no se obtienen cambios significativos en las sucesivas iteraciones.

Una vez realizada la medición y extraídas las cotas, éstas son comunicadas a la base o centro de fusión, donde se arman y trasladan los rectángulos para luego obtener un espacio de estados menor que representa el estimado deseado.

El nuevo espacio de estados es trasladado al espacio común de media $[0\ 0]$ y de allí comunicado en forma de cotas a los sensores, para que nuevamente tomen una medida y procedan de igual forma que la detallada anteriormente.

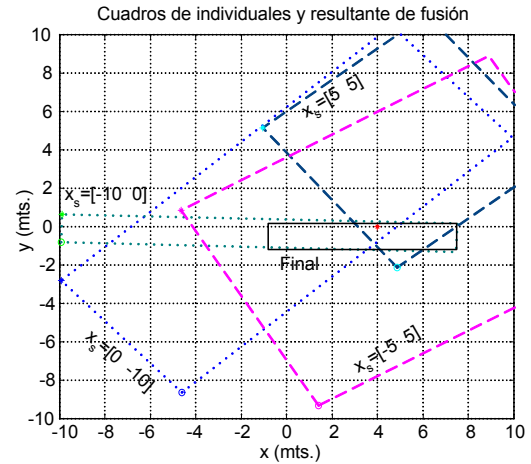


Fig. 6: Espacio de estados resultante de la fusión de los rectángulos armados con las cotas aportadas por los sensores.

Si bien en cada sensor se esparcen las partículas equi-espaciadas por eje y con igual peso, la información de las medidas anteriores de todos los sensores estará presente en los límites del espacio de estados recibido desde la base.

En la Fig. 7 se ve el resultado luego de la segunda iteración; es decir, luego de que la base manda el espacio de estados resultante de la primera iteración.

El espacio estimado se reduce notablemente en la primera y segunda iteración, pero luego se mantendrá, ya que se ha llegado a la mejor

aproximación que la red es capaz de dar sin alteraciones del sistema.

En la Fig. 8 se ven los resultados sucesivos graficados sobre el estado total inicial; se ve que la fuente queda cercada por los estimados. En el caso del último estimado, la incertidumbre de la localización es muy pequeña respecto al espacio total a cubrir.

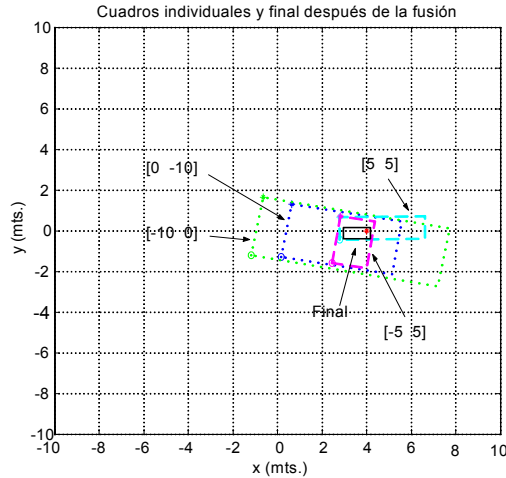


Fig. 7: Espacio de estados resultante de la fusión de los rectángulos armados con las cotas aportadas por los sensores luego de la segunda iteración.




Fig. 8: Espacios de estados estimado resultado de las sucesivas iteraciones.

Es importante destacar que los resultados fueron obtenidos utilizando una fusión por intersección muy básica, intersectando los rectángulos rectos que contienen los subespacios resultantes de cada sensor. Agregando procesamiento se puede llegar a resultados altamente más satisfactorios en la primera iteración. En la Fig. 9 se ve el resultado de una fusión por intersección levemente mas trabajada, donde se intersectan directamente los subespacios resultantes de cada sensor.

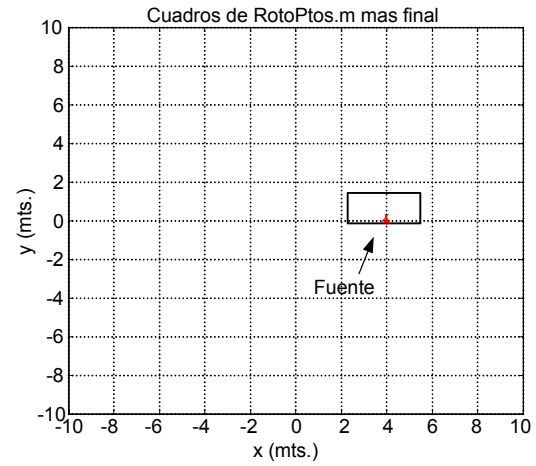


Fig. 9: Espacios de estados estimado resultado de primer iteración con un método de fusión por intersección de datos con mayor procesamiento.

4. CONCLUSIONES

Como se pudo apreciar en las simulaciones, el espacio de estados estimado resultante depende de muchos factores, algunos modificables y otros no. De las observables, la incertidumbre es un elemento propio del sensor utilizado, sin embargo la *CotaP* y *N* son elementos de diseño del algoritmo de fusión.

El algoritmo general presentado en la sección 2 ha sido simplificado en las secciones subsiguientes con el fin de mostrar su funcionamiento. Lo que queda para trabajos posteriores es diseñar una cota general para seleccionar partículas y que tenga en cuenta las incertidumbres asociadas en la medición y el proceso. Luego, trabajar sobre la definición de las regiones luego de la elección de partículas con alta probabilidad. En ese caso se utilizaron rectángulos. Sin embargo parece natural pensar en zonas anulares para el caso de medidas de rango. En ese caso, una transformación del problema a coordenadas polares sería suficiente. Finalmente se trabajará sobre la implementación experimental del algoritmo junto con un protocolo de selección de nodos para descentralizar el problema de localización.

Otra cuestión para seguir analizando es la generación de las partículas en las regiones acotadas. Las alternativas, además de la presentada, son: generar una distribución uniforme sobre la región o, si se transmite algún tipo de información adicional como la probabilidad en distintas zonas, generar una pdf a priori más aproximada a la real. Por ejemplo, si de la cota surgieran dos *islas* de partículas, se podría transmitir si media individual.

La simplificación presentada aquí tiene sin embargo un objetivo no vano. Se está trabajando para implementar este algoritmo a un circuito integrado de bajo consumo que permita sumarlo a la electrónica de un nodo.

Es interesante recalcar que el problema de localización de una fuente fija no es una abstracción que no tiene consecuencia práctica. Este tipo de problemas es común cuando se intenta por ejemplo descubrir la localización desde donde se realizó una detonación como un disparo. La aplicación a problemas de seguridad de las redes de sensores es una de las más activas en la actualidad.

5. AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por la Universidad Nacional del Sur (PGI 24/ZK12) y la Agencia Nacional de Promoción Científica y Tecnológica (PICT Nro. 14628)

REFERENCIAS

- Arulampalan, M. S., Maskell, S., Gordon, N., Clapp, T. (2002) *A Tutorial on Particle Filters for Online Nonlinear/non-Gaussian Bayesian tracking*, Special Issue of IEEE Transactions on Signal Processing, Vol. 50, 2.
- Carpenter, J., P. Clifford, P. Fearnhead (1999). *Improved Particle Filter for Nonlinear Problems*, Radar, Sonar and Navigation, IEE Proceedings, Vol. 146, Issue 1.
- Daum, F. (2005). *Nonlinear Filters: Beyond the Kalman Filter*, IEEE A&E Systems Magazine, Vol. 20, No. 8, Part. 2:Tutorials.
- Durrant-Whyte, H. & Bailey T. (2006). *Simultaneous localization and mapping: part I*. IEEE Robotics & Automation Magazine, Vol. 13, No. 2, June 2006, 99 – 108, ISSN 1070-9932.
- Gordon N. J., Salmond D. J. and Simth A. F. M. (1993) *Novel approach to nonlinear/non-Gaussian Bayesian state estimation*, IEE Proceedings-F, Vol 140, No 2, pp.107-113, Abril, 1993.
- Isler V., Bajcsy R. (2005), *The sensor selection problem for bounded uncertainty sensing models*, Fourth International Conference on Information Processing in Sensor Networks, IPSN 2005.
- Kotecha, J. H., P.M. Djuric (2003). *Gaussian Particle Filter*, IEEE Transactions on Signal Processing, Vol.51, No. 10.
- Masson, F., Puschini, D.,Crocce, P., Arlengui, L., Mandolesi, P. S., Julian, P.,Andreou, A. G. (2004) *Hybrid Sensor Network and Fusion Algorithm for Sound Source Localization*, Int. Symp. Circuits and Systems (ISCAS).
- Puschini, D., Masson, F., Mandolesi, P. S., Julian, P., Gutierrez, H. (2004). *Red Inalámbrica de Oídos Inteligentes para la Detección y Localización de Eventos Sonoros*, Reunión Ciencia, Tecnología y Sociedad, Buenos Aires.
- Sadler, B. (2005). *Fundamentals of Energy-Constrained Sensor Network Systems*, IEEE A&E Systems Magazine, Vol. 20, No. 8, Part. 2:Tutorials