

A Distributed Localization Algorithm for Wireless Sensor Networks Based on Robust Statistic

I. Faudoa, J. Cota, B. Mederos, R. González, and J. Díaz

Abstract—This research presents a distributed and low-complexity algorithm for range-based localization in wireless sensor networks (WSNs), which is an extension of the Distributed Spatially Constrained Local (DSCL) algorithm. The proposed method uses robust functions suitable to avoid outliers derived from corrupted estimated distances among sensor nodes, where the estimated distances are generated under two well known range-estimation techniques. The accuracy of the proposed algorithm was tested using a set of 10 distributed WSNs with noisy distance measurements between sensor nodes, deployed arbitrarily on a 2-D area of 100 m x 100 m. Regarding to the DSCL algorithm, the proposed approach DSCL/Smooth- l_1 reduces, in average, around 57% the error on position estimates under the RSSI model. On the other hand, the scheme DSCL/Cauchy-Lorentzian greatly outperforms the original one in the presence of outliers in distance estimates.

Index Terms—Optimization, Localization, WSNs, Robust Functions.

I. INTRODUCCIÓN

Las redes inalámbricas de sensores (WSNs, por sus siglas en inglés) han evolucionado favorablemente con el pasar de los años. Básicamente una red inalámbrica de sensores se conforma de la unión de dos o más nodos sensores los cuales mantienen comunicaciones mediante enlaces inalámbricos [1]. Típicamente un sensor es conocido como un dispositivo electrónico capaz de convertir una magnitud física en una magnitud eléctrica. Sin embargo, en las WSNs un sensor toma una nueva connotación, ya que no solo tiene la función de realizar mediciones, sino que también cuentan con memoria, fuente de alimentación limitada, capacidad de realizar procesamiento y radiotransmisores para compartir su información con otros sensores de manera centralizada o distribuida [2].

I. Faudoa, Departamento de Ingeniería Eléctrica y Computación, UACJ, Ciudad Juárez, Chihuahua, México, al164086@alumnos.uacj.mx.

B. Mederos, Departamento de Ingeniería Eléctrica y Computación, UACJ, Ciudad Juárez, Chihuahua, México, borismadrado@gmail.com.

J. Cota, Departamento de Ingeniería Eléctrica y Computación, UACJ, Ciudad Juárez, Chihuahua, México, jcota@uacj.mx.

R. González, Departamento de Ingeniería Eléctrica y Computación, UACJ, Ciudad Juárez, Chihuahua, México, rafael.gonzalez@uacj.mx.

J. Díaz, Departamento de Ingeniería Eléctrica y Computación, UACJ, Ciudad Juárez, Chihuahua, México, david.roman@uacj.mx.

Las WSNs tienen la capacidad de realizar diferentes tareas una vez que han sido desplegadas en un área determinada. Dentro de las aplicaciones más comunes se encuentran: monitoreo ambiental [3], aplicaciones médicas [4], internet de las cosas [5], vigilancia [6], entre otras. En dichas aplicaciones es importante saber cuándo y dónde se detectó un evento, por lo que la localización o posición geográfica de los sensores forma parte de una tarea fundamental en aplicaciones de WSNs.

La localización es un proceso imprescindible en la mayoría de las tareas de las WSNs, la cual consiste en calcular las coordenadas físicas de un sensor, grupo de sensores o la relación espacial entre ellos, con la finalidad de estimar dónde y cuándo ocurrió un evento [7]. Existen diversas técnicas y mecanismos que permiten a los sensores obtener su ubicación tales como: sistemas de posicionamiento global (GPS, por sus siglas en inglés), conectividad, rangos estimados, entre otros.

Comúnmente el proceso de localización geográfica de los sensores es descrito en coordenadas cartesianas (2D) o esféricas (3D), y las técnicas para el análisis en ambos esquemas son similares, con la diferencia en la integración u omisión de una dimensión, según sea el caso [7]. Usualmente, para resolver el problema de localización se suelen emplear sistemas de posicionamiento global en los sensores. De esta forma, gracias a la precisión con la que cuentan estos sistemas, determinar la ubicación de un sensor se vuelve una tarea fácil. Esta solución es factible si solo se considera un grupo pequeño de nodos, sin embargo, si la red incrementa considerablemente el número de sensores, desde el punto de vista espacio-costos, esta opción deja de ser atractiva para su implementación. Las WSNs se caracterizan por ser compactas, auto-configurables y robustas [8], además de tener un consumo de energía reducido, por lo que es importante el uso de técnicas o métodos de localización de sensores dentro de la red que no comprometan las características antes mencionadas.

Una alternativa que permite maximizar la relación espacio-costos en el problema de localización consiste en equipar con tecnología GPS del 5% al 10% del número total de los sensores de la red para que puedan obtener su posición geográfica. En una WSN, a este tipo de sensores con GPS se les denomina sensores de referencia, (ya que pueden calcular su ubicación de forma automática y precisa); al resto de los sensores se les denomina sensores desconocidos [9]. Estos últimos, deben utilizar métodos locales provenientes del medio inalámbrico e información de los sensores de referencia para poder estimar su

ubicación.

Para que un sensor desconocido pueda estimar su ubicación requiere de al menos tres datos: la estimación de la distancia con al menos tres sensores de referencia, la ubicación de los sensores de referencia y un algoritmo de localización para poder estimar su posición inicial.

Las técnicas para poder estimar la distancia entre sensores desconocidos y sensores de referencia, se pueden clasificar en dos tipos: conectividad y rangos estimados. La localización por conectividad o rango-libre no requiere de la medición de las distancias y/o ángulos entre sensores debido a que se basa en el rango de alcance de los sensores, como lo es la técnica DV-Hop, la cual utiliza el conteo de saltos entre sensores [10], [11]. Por otro lado, la localización basada en rangos estimados determina las posiciones de los sensores desconocidos por diferentes métodos tales como: potencia de la señal recibida (RSSI, por sus siglas en inglés), tiempos diferenciales de llegada (TDoA, por sus siglas en inglés), tiempos de llegada (ToA, por sus siglas en inglés) y ángulos de llegada (AoA, por sus siglas en inglés) [12-15]. Una ventaja de esta técnica de estimación de distancias con respecto a métodos basados en conectividad es que ayudan a obtener una mejor estimación de las posiciones.

En este trabajo se presenta un algoritmo de localización distribuido basado en rangos estimados, el cual es robusto a mediciones atípicas provenientes de las estimaciones de distancias entre sensores. Este algoritmo utiliza como base la metodología empleada en el algoritmo DSCL descrito en [22], el cual utiliza la norma l_1 como norma de minimización de los errores en las distancias estimadas entre sensores. En la presente investigación se plantea el uso de estadística robusta aplicado al algoritmo DSCL con el objetivo de tener un mejor desempeño en la estimación de las posiciones en presencia de grandes errores en la estimación de distancias de sensores. El algoritmo propuesto RDSCL (Robust Distributed Spatially Constrained Local, por sus siglas en inglés) se evalúa bajo dos modelos de estimación de distancias y se compara con otros algoritmos de localización. Los resultados obtenidos bajo el esquema propuesto demuestran que es posible obtener buenas estimaciones aún en presencia de mediciones atípicas.

Este trabajo de investigación se encuentra estructurado de la siguiente manera: La sección II se enfoca en la descripción de las técnicas existentes para la estimación de distancias entre sensores. La sección III contempla el análisis de las funciones robustas utilizadas en algoritmos de optimización. Por otra parte, en las secciones IV y V se enfocan en la descripción del problema de localización y la descripción del algoritmo RDSCL respectivamente. En la sección VI se analiza y describe los esquemas de las redes inalámbricas de sensores propuestas. En la sección VII se analizan y discuten los resultados obtenidos y finalmente la sección VIII presenta las conclusiones de este trabajo de investigación.

II. TÉCNICAS DE ESTIMACIÓN DE DISTANCIAS

Uno de los requisitos fundamentales para poder estimar las posiciones mediante los algoritmos de localización se basa en la medición de las distancias. Esta es llevada a cabo por el

intercambio de señales entre dos sensores, las cuales se basan principalmente en cuatro señales inalámbricas: radiofrecuencia, infrarrojo, ultrasonido y señales acústicas [16]. Las técnicas de ToA y TDoA se basan principalmente en la medición del tiempo; los sensores intercambian las señales entre sí y miden el tiempo entre que una señal es transmitida y llega a su destino. Una primera aproximación ideal para la medición de la distancia es midiendo el tiempo de vuelo t_{ij} (Time of Flight, por sus siglas en inglés) entre un sensor s_i y s_j . Una vez determinado el t_{ij} y conociendo la velocidad de propagación V_p de la señal se puede estimar la distancia verdadera entre ambos sensores como:

$$d_{ij} = t_{ij} \cdot V_p. \quad (1)$$

Sin embargo, el tiempo de vuelo puede ser considerado como una variable aleatoria $\tilde{t}_{ij} = (t_{ij} + \delta)$, donde δ representan los efectos que generan el ruido ambiental, señales de trayectoria múltiple, atenuación, retardos, desfasamiento en los relojes, entre otras más. Por lo que la distancia entre sensores quedará definida como

$$\begin{aligned} r_{ij} &= \tilde{t}_{ij} \cdot V_p \\ &= t_{ij} \cdot V_p + \delta \cdot V_p = d_{ij} + e_{ij}, \end{aligned} \quad (2)$$

donde r_{ij} representa una distancia estimada con error entre los sensores s_i y s_j , y e_{ij} es el error introducido por la técnica de medición. Una desventaja de esta técnica de estimación de distancia es que requiere de hardware adicional en los sensores incrementando el costo, espacio y consumo de energía en ellos.

En la técnica de AoA, la medición del ángulo de llegada de la señal es obtenida mediante arreglos múltiples de antenas colocadas estratégicamente en los sensores. Posteriormente se le aplica un procesamiento para extraer el ángulo. Cada antena del arreglo requiere calibración periódica y la resolución de los ángulos se puede ver limitada por el tamaño de la antena. La implementación de esta técnica es de alta precisión [17]. Sin embargo, los algoritmos de procesamiento y las implementaciones comúnmente encontradas en la literatura son costosas y muy lentas para la estimación de la distancia [18].

Otra técnica muy utilizada para la estimación de distancia entre dos sensores, a la cual se le ha dado mucho énfasis en WSNs, es la potencia de la señal recibida. Esta técnica tiene como principal atributo el no requerir hardware extra, sino únicamente un radio transmisor/receptor (comúnmente embebido en nodos sensores como: XBee, MicaZ, TelosB, Rene node, por mencionar algunos), donde su principal debilidad se debe a la generación de grandes errores de distancias estimadas, debido a su alta susceptibilidad a factores ambientales [19].

La técnica RSSI se basa en la medición de la potencia recibida en el sensor s_j de la señal proveniente de s_i para poder estimar la distancia. El modelo matemático comúnmente utilizado para la estimación de distancias usando RSSI es el de la ecuación (3) [21].

$$P_{ij} = P_0(d_0) - 10\eta_\rho \log_{10} \left(\frac{d_{ij}}{d_0} \right), \quad (3)$$

donde P_{ij} es la potencia ideal esperada en el sensor s_j proveniente del sensor s_i (medido en dBm) y $P_0(d_0)$ es una potencia de referencia a una distancia d_0 del transmisor s_i y η_ρ es dependiente de factores ambientales y su valor practico fluctua entre 2 y 4 [20].

En condiciones reales, la potencia recibida por el sensor s_j es afectada por diversos factores como el desvanecimiento por obstáculos o errores de medición, quedando expresada como se muestra en la ecuación (6):

$$\tilde{P}_{ij} = P_{ij} + X_\sigma, \quad (4)$$

donde X_σ es una variable aleatoria con distribución Gaussiana (media cero y una desviación estándar σ) y \tilde{P}_{ij} es la potencia ruidosa recibida (en dBm). De la ecuación (5) se puede determinar la distancia verdadera d_{ij} como:

$$d_{ij} = d_0 10^{\frac{P_0(d_0) - P_{ij}}{10\eta_\rho}}. \quad (5)$$

Ahora, si consideramos el contexto ruidoso, la ecuación (5) se puede expresar como:

$$r_{ij} = d_0 10^{\frac{P_0(d_0) - \tilde{P}_{ij}}{10\eta_\rho}}, \quad (6)$$

$$r_{ij} = d_0 \left(10^{\frac{P_0(d_0) - P_{ij}}{10\eta_\rho}} \cdot 10^{\frac{-X_\sigma}{10\eta_\rho}} \right) = d_{ij} \cdot e_{ij},$$

donde r_{ij} representa la distancia estimada con ruido entre los sensores s_i y s_j . Como puede observarse en la ecuación (6), esta técnica de medición introduce ruido multiplicativo, el cual puede ser expresado como se observa en la ecuación (7) considerando $d_0 = 1$ m.

$$r_{ij} = d_{ij} + d_{ij} \left(10^{\frac{-X_\sigma}{10\eta_\rho}} - 1 \right) \quad (7)$$

$$= d_{ij} + d_{ij} \cdot Y_\sigma, \quad (8)$$

donde Y_σ es una variable aleatoria.

III. ESTADÍSTICA ROBUSTA

Tradicionalmente al determinar estadísticamente un parámetro μ se asume que los datos $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ son independientes con distribución normal y se usa la técnica de máxima verosimilitud MLE (Maximum Likelihood Estimator, por sus siglas en inglés) en la estimación de μ .

$$\hat{\mu} = \arg \max f(\mathbf{X}, \mu), \quad (9)$$

donde

$$f(\mathbf{X}, \mu) = \prod_{i=1}^n e^{-\frac{(x_i - \mu)^2}{\sigma^2}}, \quad (10)$$

es la función de densidad conjunta de los datos. Con el objetivo de facilitar el cálculo del estimador $\hat{\mu}$ se determina $-\ln f(\mathbf{X}, \mu)$, que puede ser vista como una función de costo, lo cual conlleva al siguiente problema:

$$\hat{\mu} = \arg \min -\ln f(\mathbf{X}, \mu) \\ = \arg \min \sum_{i=1}^n e_i^2, \quad (11)$$

que no es más que la suma de los errores $e_i = x_i - \mu, i = 1, 2, \dots, n$ al cuadrado. Sin embargo, al usar la función cuadrática en la función de costo se evidencia que al evaluarla en errores de datos atípicos (*outliers*) produce una amplificación de estos. Lo que conlleva a que la estimación sea muy susceptible a los *outliers*.

Con el objetivo de ilustrar la influencia de los *outliers*, asumamos el siguiente caso particular en el que x_j y x_k son *outliers*, y reescribamos (11) como:

$$\hat{\mu} = \arg \min e_j^2 + e_k^2 + \sum_{i \neq j, k} e_i^2. \quad (12)$$

Los errores e_j y e_k tienen una magnitud grande que es amplificada por la función cuadrática, consecuentemente se estima un $\hat{\mu}$ muy alejado del valor verdadero de μ . Por otra parte, si en lugar de la función cuadrática empleamos una función ρ , entonces se obtendrá un nuevo estimador $\bar{\mu}$ de la siguiente manera:

$$\bar{\mu} = \arg \min \sum_{i=1}^n \rho(e_i) \\ = \arg \min \rho(e_j) + \rho(e_k) + \sum_{i \neq j, k} \rho(e_i). \quad (13)$$

Si la función ρ cumple la siguiente propiedad

$$\lim_{x \rightarrow \infty} \frac{\rho(x)}{x^2} = 0, \quad (14)$$

que significa que $\rho(x)$ crece mucho mas lento que x^2 cuando x toma valores grandes, entonces conlleva a que $\rho(e_j) + \rho(e_k) \ll e_j^2 + e_k^2$. Consecuentemente e_j y e_k tienen menos influencia en (13) que en (12). Por lo tanto, el problema (13) es menos influenciado a la presencia de *outliers*, dando mayor robustez a la estimación de μ .

Recalcamos que una función ρ positiva con $\rho(0) = 0$, simétrica, satisfaciendo (14) se denomina robusta [22][23]. Además, puede ser deseable que ρ tenga un comportamiento cuadrático cerca del origen, esto es:

$$\lim_{x \rightarrow 0} \frac{\rho(x)}{x^2} = M, \quad \text{donde } M \in (0, \infty). \quad (15)$$

Para más detalles ver [23]. Lo anterior sugiere que una posible manera de mitigar el efecto de los datos atípicos es utilizar potenciales robustos. Ejemplos de funciones de costo robustas son: Huber, norma l_1 , Lorentzian, Geman-McClure, Welsch y Tukey's Biweight entre otras [22]. Vale la pena recalcar que la estadística robusta se aplica en reconocimiento de patrones, procesamiento de imágenes y visión computacional, entre otras [24].

En [27] se propone una función robusta general con la cual se pueden representar diferentes normas y funciones robustas como las mencionadas anteriormente. Esta función se representa como:

$$h(x; \alpha, c) = \frac{|2 - \alpha|}{\alpha} \left(\left(\frac{\left(\frac{x}{c}\right)^2}{|2 - \alpha|} + 1 \right)^{\alpha/2} - 1 \right), \quad (16)$$

donde α es un parámetro que determina la forma de la función robusta h , y c es un factor de escalamiento ajustable. Por ejemplo, si el valor de $\alpha \rightarrow 2$ se obtiene una función cuadrática o norma l_2 :

$$h(x; 2, c) = \frac{1}{2} \left(\frac{x}{c}\right)^2. \quad (17)$$

Cuando $\alpha \rightarrow 0$, h tiende a la función de Lorentzian:

$$\log \left(1/2 \left(\frac{x}{c}\right)^2 + 1 \right). \quad (18)$$

Con $\alpha = -2$, se obtiene el potencial robusto de Geman-McClure:

$$\frac{2 \left(\frac{x}{c}\right)^2}{\left(\frac{x}{c}\right)^2 + 4}. \quad (19)$$

Por último, con $\alpha \rightarrow -\infty$ se obtiene la función robusta de Welsch:

$$1 - \exp \left(-\frac{1}{2} \left(\frac{x}{c}\right)^2 \right). \quad (20)$$

En la tabla 1, se resumen las diferentes funciones que se pueden representar con la función de la ecuación (16) variando el parámetro α .

IV. DESCRIPCIÓN DEL PROBLEMA

Como se describe en el trabajo de investigación [25], el problema de localización en WSNs puede ser definido de la siguiente manera.

Se tiene un conjunto de N sensores $\mathbf{S} = \{s_1, s_2, \dots, s_N\}$, donde cada uno de ellos es colocado en un área específica

arbitrariamente, donde las posiciones se desconocen y deben ser estimadas.

TABLA 1
REPRESENTACIÓN DE LAS DIFERENTES FUNCIONES ROBUSTAS GENERADAS A PARTIR DE LA ECUACIÓN (16)

Parámetro	Función	Ecuación
$\alpha = 1$	l_1 suavizada	(16)
$\alpha = 2$	l_2	(17)
$\alpha = 0$	Cauchy/Lorentzian	(18)
$\alpha = -2$	Geman-McClure	(19)
$\alpha = -\infty$	Welsch	(20)

En un espacio en dos dimensiones (2D), se considerará a $\mathbf{z}_i = [z_{x_i}, z_{y_i}]^T$ como la posición real pero a la vez desconocida del sensor s_i , y se asumirá $\mathbf{p}_i = [p_{x_i}, p_{y_i}]^T$ como su posición estimada. Por otro lado, se toma en cuenta un número de M sensores de referencia $\mathbf{A} = \{a_1, a_2, \dots, a_M\}$ que también son colocados en la misma área y tienen tecnología GPS para determinar automáticamente su posición, la cual se considera como verdadera. La ubicación del sensor de referencia a_k se simboliza por las coordenadas $\mathbf{q}_k = [q_{x_i}, q_{y_i}]^T$. Para efectos prácticos, se tiene que $M \ll N$ con $M > 2$.

En este trabajo de investigación se considera que cada sensor tiene la capacidad de estimar su distancia con otros sensores que están dentro de su área de cobertura mediante técnicas como ToA, RSSI o AoA. Por lo que la distancia estimada entre un sensor s_i y un sensor s_j puede ser denotada como:

$$r_{ij} = r_{ji} = d_{ij} + e_{ij}, \quad (21)$$

donde $d_{ij} = \|\mathbf{z}_i - \mathbf{z}_j\|$, $\|\cdot\|$ es la distancia euclidiana y e_{ij} representa el error introducido por diversos factores. De la misma forma, la estimación de la distancia entre un sensor s_i y un sensor de referencia a_k puede ser definida como:

$$R_{ik} = R_{ki} = d_{ik} + e_{ik}, \quad (22)$$

donde $d_{ik} = \|\mathbf{z}_i - \mathbf{q}_k\|$. También se asume que todos los sensores tienen un número limitado de sensores vecinos delimitados por el radio de cobertura γ en la vecindad de s_i . Así que:

$$\mathbf{S}_i = \{j \mid \|\mathbf{z}_i - \mathbf{z}_j\| < \gamma\}, \quad (23)$$

define el conjunto de índices de los sensores con distancias al sensor s_i menores al radio de cobertura γ . De la misma manera:

$$\mathbf{A}_i = \{k \mid \|\mathbf{z}_i - \mathbf{q}_k\| < \rho\}, \quad (24)$$

define el conjunto de índices de los sensores de referencia que tienen una distancia al sensor s_i limitados por un radio de cobertura ρ .

De esta forma, el problema de localización consistirá en la estimación de la posición \mathbf{p}_i para cada sensor s_i , de tal manera que la distancia euclidiana de dichas posiciones se minimicen con las correspondientes distancias estimadas para cada r_{ij} y R_{ik} . Una vez que todos los sensores han actualizado sus

posiciones, estas se retransmiten para iniciar la siguiente iteración del algoritmo. El problema de localización puede ser formulado matemáticamente como se muestra en la siguiente ecuación:

$$\min_{\mathbf{L}} \sum_{i \in \mathcal{S}} \left(\sum_{j \in \mathcal{S}_i} \|\mathbf{p}_i - \mathbf{p}_j\| - r_{ij} \right) + \sum_{k \in \mathcal{A}_i} \|\mathbf{p}_i - \mathbf{q}_k\| - R_{ik}, \quad (25)$$

donde $\mathbf{L} = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N\}$ representa el conjunto de posiciones a ser encontradas que minimicen la función objetivo descrita en (25). La ecuación (25) describe un problema no lineal y no convexo el cual comúnmente es resuelto por medio de algoritmos optimizados e iterativos.

V. DESCRIPCIÓN DEL ALGORITMO RDSCL

El algoritmo de localización por funciones locales (DSCL, por sus siglas en inglés), es un algoritmo dentro del estado del arte considerado como un método de refinamiento distribuido e iterativo por tener la característica de minimizar un problema de programación no lineal de manera local (26) restringido a un conjunto Ω^ℓ .

$$\mathbf{p}_i^{\ell+1} = \arg \min_{\mathbf{p} \in \Omega_i^\ell} \left(\sum_{j \in \mathcal{S}_i} \alpha_{ij}^\ell(\mathbf{p}) + \sum_{k \in \mathcal{A}_i} \beta_{ik}^\ell(\mathbf{p}) \right), \quad (26)$$

donde Ω_i^ℓ es una vecindad cuadrada centrada en \mathbf{p}_i^ℓ compuesta de 25 posiciones igualmente espaciadas como se puede observar en la Fig. 1.




Fig. 1. Área discreta de búsqueda Ω_i^ℓ generada por el sensor s_i , centrada en su posición actual \mathbf{p}_i^ℓ [25].

Las funciones de error usadas en (26) se definen a continuación:

$$\alpha_{ij}^\ell(\mathbf{p}) = |r_{ij} - \|\mathbf{p} - \mathbf{p}_j^\ell\||, \quad (27)$$

$$\beta_{ik}^\ell(\mathbf{p}) = |R_{ik} - \|\mathbf{p} - \mathbf{q}_k\||, \quad (28)$$

con $\alpha_{ij}^\ell(\mathbf{p})$ representando el valor absoluto del error entre r_{ij} y la distancia euclidiana de la posición \mathbf{p} (que se desea

determinar) del sensor s_i a la posición estimada \mathbf{p}_j^ℓ del sensor s_j en la iteración ℓ ; de manera similar $\beta_{ik}^\ell(\mathbf{p})$ representa el valor absoluto del error entre distancias, pero en este caso solo se involucran distancias con los sensores de referencia a_k . La posición \mathbf{p} que minimiza el problema (26) se considera como la nueva posición $\mathbf{p}_i^{\ell+1}$ que será retransmitida por el sensor s_i hacia sus sensores vecinos para que se inicie una nueva iteración.

Es importante mencionar que el algoritmo DSCL no requiere el cálculo de la primera o segunda derivada como en los métodos de optimización de primer y segundo orden. A esta clase de algoritmo se le puede denominar de derivada-libre [26].

La principal contribución del algoritmo propuesto RDSCL (Robust DSCL) consiste en aplicar una función robusta general h (descrita en la ecuación (16) de la sección III) a los errores:

$$\varphi_{ij}^\ell(\mathbf{p}) = r_{ij} - \|\mathbf{p} - \mathbf{p}_j^\ell\|, \quad (29)$$

$$\psi_{ik}^\ell(\mathbf{p}) = R_{ik} - \|\mathbf{p} - \mathbf{q}_k\|, \quad (30)$$

a diferencia del método DSCL clásico que aplica solamente la norma l_1 , a los errores (29) y (30).

La clase de funciones robustas definidas en (16) se evalúa en (29) y (30) para obtener un error para cada vecindad \mathcal{S}_i y \mathcal{A}_i respectivamente como se describe a continuación:

$$\xi_i^\ell(\mathbf{p}) = \sum_{j \in \mathcal{S}_i} h(\varphi_{ij}^\ell(\mathbf{p}), \alpha, c), \quad (31)$$

$$\varpi_i^\ell(\mathbf{p}) = \sum_{k \in \mathcal{A}_i} h(\psi_{ik}^\ell(\mathbf{p}), \alpha, c). \quad (32)$$

A partir de las ecuaciones anteriores (31) y (32), se plantea una función de costo global:

$$D(\mathbf{p}_1, \dots, \mathbf{p}_N) = \sum_{i \in \mathcal{S}} H(\mathbf{p}_i), \quad (33)$$

en la cual $H(\mathbf{p}_i)$ representa el error total entre el sensor s_i y sus vecindades \mathcal{S}_i y \mathcal{A}_i

$$H(\mathbf{p}_i) = \xi_i^\ell(\mathbf{p}_i) + \varpi_i^\ell(\mathbf{p}_i). \quad (34)$$

Cuando se intenta encontrar, en la iteración ℓ , el conjunto de posiciones $\mathbf{L}^\ell = \{\mathbf{p}_1^\ell, \dots, \mathbf{p}_N^\ell\}$ que minimice globalmente (33), el problema de optimización suele ser difícil y en algunas ocasiones intratable. Sin embargo, esta puede ser separada en una serie de funciones locales donde cada sensor actualiza su posición $\mathbf{p}_i^{\ell+1}$ localmente dentro de una región de búsqueda discreta Ω_i^ℓ para el sensor s_i , como se muestra en la Fig. 1, con tamaño δ_i^ℓ de la región de búsqueda:

$$\delta_i^\ell = \frac{H(\mathbf{p}_i^\ell)}{T_i}, \quad (35)$$

donde T_i representa el número de elementos de \mathbf{S}_i . El valor de δ_i^ℓ depende directamente del error de la distancia total del sensor s_i con sus sensores vecinos, el cual varía entre iteraciones.

Por lo tanto, el problema (26) se modifica de acuerdo a las funciones robustas, como se muestra en la siguiente ecuación:

$$\mathbf{p}_i^{\ell+1} = \arg \min_{\mathbf{p} \in \Omega_i^\ell} \xi_i^\ell(\mathbf{p}) + \varpi_i^\ell(\mathbf{p}). \quad (36)$$

Una vez que el sensor s_i ha recibido la posición actualizada de todos sus vecinos, este recalcula su nueva posición $\mathbf{p}_i^{\ell+1}$. Si $\|\mathbf{p}_i^{\ell+1} - \mathbf{p}_i^\ell\| \leq e$, donde e representa un error de parada, se asume que el algoritmo converge y el sensor s_i envía su última posición que deberá ser utilizada por sus vecinos en sus iteraciones posteriores. En caso contrario, si la distancia $\|\mathbf{p}_i^{\ell+1} - \mathbf{p}_i^\ell\| > e$, se continúa con una siguiente iteración si no se ha llegado a un número máximo preestablecido de iteraciones. El anterior procedimiento iterativo se comienza con un conjunto de posiciones iniciales \mathbf{p}_i^0 , $i = 1, \dots, N$ estimadas mediante la técnica de multilateración, la cual se basa en el método de mínimos cuadrados LS (Least Square, por sus siglas en inglés) descrita en [30].

VI. DISEÑO DE LA RED INALÁMBRICA DE SENSORES

Para comprobar la eficiencia del algoritmo de localización presentado en este trabajo, se utilizan dos modelos de estimación de rangos ampliamente aceptados en el análisis de algoritmos de localización en WSNs, los cuales serán descritos a continuación.

Para la experimentación del algoritmo propuesto, se simuló en MATLAB un conjunto de 10 WSNs con las siguientes características:

- Cada red contiene 100 sensores de los cuales 96 son sensores desconocidos y los restantes 4 son sensores de referencia no colineales.
- Los sensores son desplegados con una distribución uniforme en un área delimitada de 100 m x 100 m.
- Todos los sensores desplegados de la red son fijos durante el proceso de localización.
- Se asume que todos los sensores de referencia y sensores desconocidos tienen conectividad limitada, con un radio de 30 m, generando un patrón de radiación circular (isotrópico), como se plantea en la ecuación (23) y (24).
- Las estimaciones iniciales de los sensores desconocidos se obtienen por medio del algoritmo DV-Hop [11] y multilateración.

El primer enfoque se basa en la técnica RSSI descrito en la sección II, donde a partir de las distancias $\{d_{ij}\}$ entre las posiciones verdaderas, se obtienen las potencias ideales de

recepción $\{P_{ij}\}$ respectivas mediante la ecuación (3). Posteriormente se agrega ruido gaussiano a las potencias de recepción de acuerdo a la ecuación (4). Una vez obtenidas las potencias contaminadas, se utiliza la ecuación (6) para determinar las distancias con error $\{r_{ij}\}$.

Para determinar la potencia de referencia $P_0(d_0)$ usada en la ecuación (3) para calcular las potencias ideales, se utiliza la fórmula de Friis [21]

$$P_0(d_0) = \frac{P_T G_T G_R \lambda^2}{L(4\pi d_0)^2}, \quad (37)$$

donde se asume que $L = G_T = G_R = 1$, $d_0 = 1$ m y una frecuencia de operación de $f = 2.4$ GHz (considerando dispositivos XBee), por lo que $\lambda = c/f = 0.125$ m, tal como se indica en [25]. Para la estimación de distancias entre sensores, se utilizó un $P_T = 1$ mW, típico de la tecnología XBee, con un $P_0(d_0) = -22.2$ dBm [29].

Para la simulación de un entorno práctico con respecto a las potencias, se consideró un factor de atenuación $\eta_\rho = 4.7$ [32]. Para tener una mejor estimación de las distancias r_{ij} y R_{ik} entre sensores se utilizó el promedio de 10 mediciones con el objetivo de disminuir la influencia del ruido gaussiano.

El segundo modelo consiste en agregar una componente de ruido con distribución gaussiana a las distancias verdaderas entre sensores de la siguiente manera:

$$r_{ij} = \|\mathbf{z}_i - \mathbf{z}_j\| \times N_s, \quad (38)$$

y

$$R_{ik} = \|\mathbf{z}_i - \mathbf{q}_k\| \times N_s, \quad (39)$$

con

$$N_s = \max[0, 1 + E_{ij} \times n f_d], \quad (40)$$

donde E_{ij} es una variable aleatoria con distribución normal (media cero y desviación estándar de uno) la cual representa el ruido; el parámetro $n f_d \in [0, 1]$ es un factor de ruido agregado a las distancias entre sensores [33]. En este esquema se agrega aleatoriamente un porcentaje de mediciones atípicas las cuales emulan un mal funcionamiento del hardware, efectos de multitrayectoria y ataques maliciosos [34][35].

Para la evaluación del algoritmo se usarán distintos tipos de funciones robustas parametrizadas por las constantes α y c descritas en la sección III.

Para comparar la precisión de las posiciones estimadas por el algoritmo propuesto se utiliza la métrica de la raíz del error cuadrático medio RMSE (Root Mean Square Error, por sus siglas en inglés).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \|\mathbf{p}_i^\ell - \mathbf{z}_i\|^2}, \quad (41)$$

donde \mathbf{p}_i^ℓ representa la estimación de la posición del sensor S_i .

Para evaluar el desempeño del algoritmo RDSCL se eligieron los siguientes algoritmos para su análisis y comparación: DSCL [25], y Levenberg-Mardquardt LM [30][31], donde cada uno de estos parten de las mismas condiciones iniciales \mathbf{p}_i^0 (obtenidas mediante la combinación DV-Hop y LS) y se ejecutan 100 iteraciones como máximo. El algoritmo propuesto que se presenta a continuación es ejecutado de manera distribuida para cada sensor:

Algoritmo RDSCL	
1.	Entrada: $\alpha, c, \epsilon, \ell_{max}, \{q_k\}_{k \in A_i}, \{R_{ik}\}_{k \in A_i}, \mathcal{Y} \{r_{ij}\}_{j \in S_i}$
2.	Calcular \mathbf{p}_i^0 mediante multilateración (DV-Hop y LS)
3.	$\ell = 0$
4.	Repetir
5.	Determinar Ω_i^ℓ
6.	Resolver
	$\mathbf{p}_i^{\ell+1} = \arg \min_{\mathbf{p} \in \Omega_i^\ell} \xi_i^\ell(\mathbf{p}) + \omega_i^\ell(\mathbf{p})$
7.	$\ell = \ell + 1$
8.	Hasta que: $\ \mathbf{p}_i^\ell - \mathbf{p}_i^{\ell-1}\ < \epsilon$ o $\ell \leq \ell_{max}$
9.	Salida: \mathbf{p}_i^ℓ

VII. RESULTADOS

En esta sección se presentan los resultados de la experimentación con distintos parámetros de la función h descrita en (16) correspondientes a diferentes funciones de pérdida, tales como: norma l_1 suavizada, Welsch, norma l_2 , Cauchy/Lorentzian y Geman-McClure.

Para el primer enfoque (técnica RSSI), el diseño de la prueba consiste en evaluar los algoritmos tomando en cuenta un conjunto de 10 redes independientes. Para cada red, se contaminan individualmente las distancias entre sensores con ruido Gaussiano (media cero y σ entre 1 y 4 dB). Posteriormente, se obtienen las posiciones iniciales de cada uno de los sensores desconocidos s_i , utilizando las distancias estimadas entre sensores desconocidos y sensores de referencia bajo el método DV-Hop y LS. Con el objetivo de mejorar las posiciones iniciales, se evalúan los algoritmos a un máximo de 100 iteraciones, donde por cada iteración se evalúa el RMSE. Por último, se promedia el RMSE de las posiciones estimadas de cada algoritmo considerando las 10 redes independientes.

Para un parámetro de ruido $\sigma = 2$ dB, se evalúa el desempeño en la precisión de las posiciones estimadas de los algoritmos usando la métrica RMSE como lo muestra la Fig. 2. Se puede apreciar que los algoritmos evaluados presentan un comportamiento exponencial decreciente conforme aumenta el número de iteraciones, a excepción de la función l_2 y Welsch. También se puede notar que las funciones robustas que presentan mejor desempeño son la Cauchy/Lorentzian y la norma l_1 suavizada, mostrando un error al final de 100 iteraciones de 4.97 m y 2.34 m, respectivamente. De igual manera se puede ver que el algoritmo LM provee un resultado aceptable de 2.82 m al término de 100 iteraciones.




Fig. 2. Desempeño del algoritmo RDSCL con diferentes funciones robustas utilizando un factor de atenuación de $\eta_p = 4.7$ y un $\sigma = 2$ dB.

Al incrementar el ruido en las distancias estimadas entre sensores ($\sigma = 4$ dB), como se aprecia en la Fig. 3, la función robusta con la que el algoritmo obtuvo el mejor desempeño correspondió a la norma l_1 suavizada. Este arrojó un RMSE de 2.81 m seguido del algoritmo LM con 4.09 m. Con la función Cauchy/Lorentzian se obtuvo un error de 4.88 m en contraste con 13.31 m y 13.14 m de las funciones l_2 y Welsch respectivamente.




Fig. 3. Desempeño del algoritmo RDSCL en la estimación de distancias entre sensores, con diferentes funciones robustas usando un factor de atenuación de $\eta_p = 4.7$ y un $\sigma = 4$ dB para la generación del ruido.

En la Tabla 2 se resume el desempeño del algoritmo considerando 10 redes las cuales fueron contaminadas con un mismo nivel de ruido; este proceso se repitió para cuatro niveles de ruido generando cuatro conjuntos de datos. Para cada conjunto se ejecutó el algoritmo para diferentes valores del parámetro α de la función h y se calculó el RMSE promedio al final de 100 iteraciones. Se puede observar que, para los diferentes niveles de ruido, los algoritmos robustos con mejor desempeño fueron los que utilizan la norma l_1 suavizada y Cauchy/Lorentzian, superando la estimación conseguida por el algoritmo DSCL.

TABLA II

DESEMPEÑO DE LOS ALGORITMOS CON DIFERENTES NIVELES DE RUIDO σ							
σ (dB)	l_1 suavizada	Cauchy/ Lorentzian	l_2	Welsch	Geman- McClure	DSCL	LM
1	3.13 m	5.20 m	13.01 m	12.60 m	9.36 m	6.12 m	3.40 m
2	2.34 m	4.97 m	13.67 m	13.05 m	8.91 m	5.78 m	2.82 m
3	1.97 m	4.81 m	13.84 m	13.09 m	9.26 m	5.65 m	2.23 m
4	2.81 m	4.88 m	13.31 m	13.14 m	9.44 m	5.88 m	4.09 m

En el segundo enfoque, se evalúa el comportamiento de los algoritmos bajo condiciones de mediciones atípicas en la estimación de distancia entre sensores. Para esto se realiza el siguiente procedimiento: tomando en cuenta el conjunto de las 10 redes independientes, se generan para cada red las distancias corruptas entre los sensores con un factor nf_d (según las ecuaciones (38) y (39)) variando del 10% al 40%. Para cada una de las redes contaminadas con un nf_d específico, se generan 10 contaminaciones aleatorias de *outliers* con un mismo porcentaje de mediciones atípicas que van desde 10% a 40% (con incrementos de 10%). A partir de esto, se obtienen las posiciones iniciales de igual manera a lo descrito en el primer enfoque. Una vez calculada la primera estimación de la posición de cada sensor desconocido, se ejecutan los algoritmos iterativos. Por último, se promedia el RMSE de los algoritmos en cada iteración considerando las 10 redes independientes, donde básicamente el desempeño de los métodos evaluados estará en función de los factores nf_d y el porcentaje de *outliers* agregados a cada red.

Por ejemplo, la Fig. 4 muestra los resultados para un $nf_d = 10\%$ y un porcentaje de *outliers* de 20%. Para esta prueba todos los algoritmos parten de un RMSE promedio inicial de 13.77 m. Como se puede apreciar, después de cierto número iteraciones se evidencia que solo dos algoritmos son lo suficientemente robustos para mitigar el efecto de los errores atípicos y mejorar las posiciones iniciales: Geman-McClure y Cauchy/Lorentzian llegando a reducir el error a 9.97 m y 6.47 m, respectivamente.




Fig. 4. Desempeño del algoritmo RDSCL con diferentes funciones robustas usando un factor de ruido $nf_d = 10\%$ y un porcentaje de valores atípicos del 20%.

Por otra parte, se puede ver cómo el algoritmo Levenberg-Marquardt, el cual es un método basado en la resolución iterativa de un sistema de ecuaciones no lineales dependiendo

de una matriz jacobiana, muestra un mal desempeño, lo cual puede ser causado por un mal condicionamiento de la matriz debido a la presencia de *outliers*.

Por otra parte, al aumentar el porcentaje de *outliers* y el factor de ruido a un 30% para ambos, se pueden apreciar (ver Fig. 5) cómo los mismos algoritmos que mostraron buen desempeño bajo condiciones no tan severas de ruido y *outliers* siguen presentando el mejor resultado, mientras que el resto de los algoritmos no alcanzan incluso a mejorar las posiciones iniciales. El algoritmo con Cauchy/Lorentzian mejora de 13.77 m a 7.84 m el error de las posiciones estimadas, mientras que al emplear la función Geman-McClure se observa una ligera mejora de 13.77 m a 11.22 m.

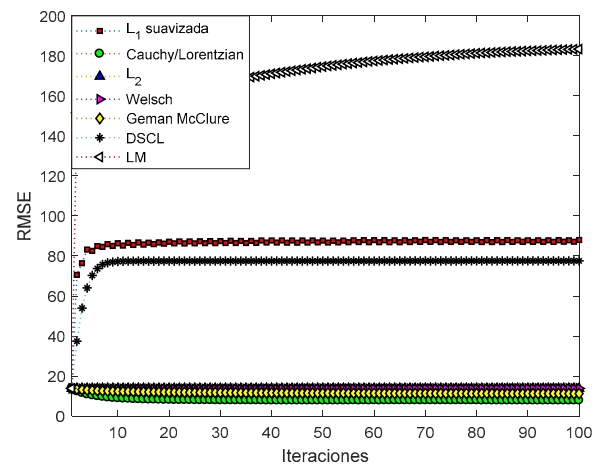


Fig. 5. Desempeño del algoritmo RDSCL con diferentes funciones robustas usando un factor de ruido $nf_d = 30\%$ y un porcentaje de valores atípicos del 30%.

La Tabla 3 resume el desempeño del algoritmo RDSCL con sus diferentes funciones robustas de minimización. Se presenta el valor final promedio de las 10 redes usando la métrica RMSE. Claramente se puede apreciar que el algoritmo RDSCL con Cauchy/Lorentzian es más robusto a mediciones atípicas que el resto de las funciones. También se observa que los algoritmos DSCL y LM presentan un bajo desempeño conforme aumenta el porcentaje de *outliers*.

VIII. CONCLUSIÓN

Las aplicaciones de las funciones robustas permiten ser usadas ampliamente en el área de procesamiento de imágenes para tratar los errores o valores atípicos que pueden presentar los píxeles en una imagen. Por otro lado, en el área de WSNs el usar este tipo de funciones ayuda a mejorar considerablemente la estimación de las posiciones de los sensores en presencia de errores atípicos obtenidos en las mediciones de distancias entre estos. En este trabajo de investigación se presenta una extensión del algoritmo DSCL utilizando estadística robusta para la minimización del error de distancias entre sensores, el cual fue denominado RDSCL.

TABLA III

DESEMPEÑO DE LOS ALGORITMOS A DIFERENTES NIVELES DE RUIDO Y PORCENTAJE DE VALORES ATÍPICOS UTILIZANDO UN RMSE INICIAL DE 13.77 m	

Outlier	RDSCL + funciones robustas						
	l_1 suavizada	Cauchy/ Lorentzian	l_2	Welsch	Geman McClure	D_SCL	LM
Nfd=10%							
10%	13.36 m	5.54 m	13.75 m	13.07 m	9.53 m	11.53 m	88.19 m
20%	24.63 m	6.47 m	13.78 m	13.52 m	9.97 m	21.03 m	135.9 m
30%	86.77 m	7.23 m	13.78 m	13.88 m	10.38 m	75.18 m	184.9 m
40%	205.0 m	7.48 m	13.77 m	14.53 m	10.85 m	167.9 m	226.0 m
Nfd=20%							
10%	14.45 m	5.71 m	13.76 m	13.15 m	9.69 m	12.72 m	89.23 m
20%	26.88 m	6.55 m	13.78 m	13.75 m	9.99 m	23.92 m	137.6 m
30%	85.95 m	7.13 m	13.76 m	14.05 m	10.51 m	76.50 m	188.2 m
40%	199.8 m	8.18 m	13.77 m	14.17 m	11.34 m	167.4 m	225.9 m
Nfd=30%							
10%	13.69 m	6.46 m	13.76 m	13.40 m	10.10 m	11.91 m	88.25 m
20%	26.83 m	6.85 m	13.77 m	13.50 m	10.53 m	24.34 m	137.9 m
30%	87.96 m	7.84 m	13.76 m	13.84 m	11.22 m	77.53 m	183.3 m
40%	209.2 m	8.19 m	13.77 m	14.26 m	11.71 m	170.3 m	227.2 m
Nfd=40%							
10%	13.82 m	6.64 m	13.76 m	13.51 m	10.63 m	12.08 m	88.22 m
20%	26.11 m	7.22 m	13.77 m	13.76 m	11.02 m	22.76 m	137.6 m
30%	89.72 m	8.12 m	13.77 m	14.77 m	11.64 m	79.55 m	188.2 m
40%	208.1 m	8.81 m	13.77 m	14.17 m	12.45 m	170.1 m	232.2 m

Una característica relevante de esta propuesta es el bajo costo computacional y la no dependencia de la derivada de la función objetivo de minimización en comparación con métodos de optimización basados en gradientes.

Dicho algoritmo propuesto fue comparado con otros algoritmos bajo diferentes condiciones de ruido y mediciones atípicas utilizando dos modelos independientes. Los resultados muestran que, en presencia de mediciones atípicas, la función de pérdida Cauchy\ Lorentzian presenta mejor desempeño que el resto de las funciones y algoritmos evaluados. Por otra parte, sin la influencia de valores atípicos en la medición de distancia entre sensores, la norma l_1 suavizada generó una mejor estimación de las posiciones.

En resumen, el uso de las funciones robustas que generen un mejor resultado estará en función de la exactitud de las mediciones estimadas. Es decir, si se conoce "a priori" el entorno en el que la WSNs serán desplegadas, se puede elegir la técnica de minimización adecuada para la obtención de una mejor estimación de las posiciones.

REFERENCIAS

[1] Chen y Y. Peiqiang, "Research on hierarchical mobile wireless sensor network architecture with mobile sensor nodes," 3rd International Conference on Biomedical Engineering and Informatics, Yantai, pp. 2863-2867, 2010.

[2] B. Krishnamachari, Networking Wireless Networks, New York: Cambridge University Press, 2005.

[3] L. Shkurti, X. Bajrami, E. Canhasi, B. Limani, S. Krrabaj y A. Hulaj, "Development of ambient environmental monitoring system through wireless sensor network (WSN) using NodeMCU and WSN monitoring," 6th Mediterranean Conference on Embedded Computing (MECO), pp. 1-5, 2017.

[4] N. Dessart, H. Fouchal, P. Hunel y C. Rabat, "Simulation of large scale WSN for medical care," The IEEE symposium on Computers and Communications, pp. 1115-1120, 2010.

[5] S. Huertas, O. J. Salcedo y B. S. Reyes, "IoT application of WSN on 5G infrastructure," International Symposium on Networks, Computers and Communications (ISNCC), pp. 1-6, 2017.

[6] Y. S. Dohare, T. Maity, P. S. Paul y P. S. Das, "Design of surveillance and safety system for underground coal mines based on low power WSN," International Conference on Signal Propagation and Computer Technology (ICSPCT 2014), pp. 116-119, 2014.

[7] Huang S, Wu Z, Misra A. "A Practical, Robust and Fast Method for Location Localization in Range-Based Systems". Sensors (Basel). 2017;17(12):2869. Published 2017 Dec 11. doi:10.3390/s17122869

[8] W. Dargie y C. Poellabauer, Fundamentals of wireless sensor networks: Theory and practice, United Kingdom: Wiley, 2010.

[9] L. Cheng, C. Wu, Y. Zhang, H. WU, M. Li y C. Maple, "A Survey of Localization in Wireless Sensor Network," International Journal of Distributed Sensor Networks, Vol. 2012, p. 12, 2012.

[10] C.-C. Chen, C.-Y. Chang y Y.-N. Li, "Range-Free Localization Scheme in Wireless Sensor Networks Based on Bilateralation," International Journal of Distributed Sensor Networks, Vol. 2013, pp. 10, 2013.

[11] D. Niculescu y B. Nath, "Ad hoc positioning system (APS)," Global Telecommunications Conference, GLOBECOM '01, Vol. 5, pp. 2926-2931, 2001.

[12] Bergström, G. Hendeby, F. Gunnarsson y F. Gustafsson, "TOA estimation improvements in multipath environments by measurement error models," IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC), pp. 1-7, 2017.

[13] De Angelis, A. Moschitta y A. Comuniello, "TDoA based positioning using ultrasound signals and wireless nodes" International Instrumentation and Measurement Technology Conference (I2MTC), pp. 1-6, 2017.

[14] F. Kong, J. Wang, N. Zheng, G. Chen y J. Zheng, "A robust weighted intersection algorithm for target localization using AOA measurements," IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), Xi'an. pp. 23-28, 2016.

[15] R. Pereira Pires, G. Gracioli, L. Wanner and A. Augusto Medeiros Frohlich, "Evaluation of an RSSI-based Location Algorithm for Wireless Sensor Networks," in IEEE Latin America Transactions, Vol. 9, no. 1, pp. 830-835, March 2011.

[16] Y. Liu y Z. Yang, Location, localization and localizability: location-awareness technology for wireless networks, Springer, 2011.

[17] M. Bal, M. Liu, W. Shen y H. Ghenniwa, "Localization in cooperative Wireless Sensor Networks: A review," 13th International Conference on Computer Supported Cooperative Work in Design, pp. 438-443, 2009.

[18] Y. S. Lee, J.-M. Lee, S. S. Yeo, J. H. Park y L. Barolli, "A Study on the Performance of Wireless Localization System Based on AoA in WSN Environment," Third International Conference on Intelligent Networking and Collaborative Systems, Fukuoka, pp. 184-187, 2011.

[19] A. Espinoza Ruiz, E. Reyes Cruz, M. d. J. Tapia Urrea, E. C. Ruiz Ibarra, J. Ruiz Ibarra and J. Cortez Gonzalez, "Performance comparison between simulated and real case scenario of RSSI-Based localization algorithms on a WSN," in IEEE Latin America Transactions, Vol. 14, no. 1, pp. 115-121, Jan. 2016.

[20] N. Patwari, J. N. Ash, S. Kyperountas, A. O. Hero, R. L. Moses y N. S. Correal, "Locating the nodes: cooperative localization in wireless sensor networks," IEEE Signal Processing Magazine, Vol. 22, pp. 54-69, 2005.

[21] T. Rappaport, Wireless Communication: Principles and Practice. United states of America, 2002, pp. 104.

[22] M. J. Black y A. Rangarajan, "On the unification of line processes, outlier rejection, and robust statistics with applications in early vision" International Journal of Computer Vision, Vol. 19, pp. 57-91, 1996.

[23] R. Marona, R. Martin & V. Yohai. Robust Statistics: Theory and Methods. Wiley, 2006.

[24] V. Belagiannis, C. Rupprecht, G. Carneiro y N. Navab, "Robust Optimization for Deep Regression," International Conference on Computer Vision (ICCV), p. 9, 2015.

[25] J. Cota, J. Rosiles, P. Rivas y E. Sifuentes, "A distributed localization algorithm for wireless sensor networks based on the solutions of spatially-constrained local problems," IEEE Sensors Journal, Vol. 13, pp. 2181-2191, 2013.

[26] R. Conn, K. Scheinberg y L. N. Vicente, Introduction to Derivative-Free Optimization, USA: Society for Industrial and Applied Mathematics, 2009.

[27] J. T. Barron. (2017). "A general and adaptive robust loss function." [Online]. Available: <https://arxiv.org/abs/1701.03077>

[28] G. Zhou, T. He, S. Krishnamurthy y J. A. Stankovic, "Models and solutions for radio irregularity in wireless sensor networks," ACM Transactions on Sensor Networks (TOSN), pp. 221-262, 2006.

[29] Digi International Inc. Mayo 2018. [online]. Available: <http://www.sparkfun.com/datasheets/Wireless/Zigbee/XBee-Datasheet.pdf>.

[30] J. Cota, J. Rosiles, E. Sifuentes y P. Rivas, "A Low-Complexity Geometric Bilateralation Method for Localization in Wireless Sensor

Networks and Its Comparison with Least-Squares Methods," *Sensors*, pp. 839-862, 2012.

- [31] J. E. Dennis and R. B. Schnabel, *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*. Philadelphia, PA, USA: SIAM, 1996.
- [32] Elechi, Promise & Paul O., Otasowie. "Determination of Path Loss Exponent for GSM Wireless Access in Rivers State using Building Penetration Loss". *Mediterranean Journal of Electronic and Communication*. pp. 822-830, 2015.
- [33] S. Srirangarajan, A. H. Tewfik and Z. Luo, "Distributed sensor network localization using SOCP relaxation," in *IEEE Transactions on Wireless Communications*, Vol. 7, no. 12, pp. 4886-4895, December 2008.
- [34] Z. Yang, L. Jian, C. Wu, and Y. Liu, "Beyond triangle inequality: Sifting noisy and outlier distance measurements for localization," *ACM Trans. Sensor Netw.*, Vol. 9, no. 2, Mar. 2013, Art. no. 26.
- [35] F. Xiao, W. Liu, Z. Li, L. Chen and R. Wang, "Noise-Tolerant Wireless Sensor Networks Localization via Multinorms Regularized Matrix Completion," in *IEEE Transactions on Vehicular Technology*, Vol. 67, no. 3, pp. 2409-2419, March 2018.



Ivan Faudoa received his degree in digital systems and communications from the Autonomous University of Ciudad Juárez in 2014. He was head on maintenance and electrical support department at Hanon Systems. He is currently a student of the master's degree in electrical engineering at the Autonomous University of Ciudad Juárez. He has presented conferences and articles in different congresses of national level. His main areas of focus are wireless sensor networks, VLSI circuit design and embedded systems.



Juan Cota received his Ph.D. in Electrical and Computer Engineering at the University of Texas at El Paso (UTEP), in 2011. Currently, he works as a full research professor at the Autonomous University of Ciudad Juarez (UACJ) Mexico, since 2003. He has national and international publications on the fields of electrical engineering, and he is holder of a national patent. His current research interests include Wireless Sensor Networks, Smart Sensors, Numerical Optimization, and Control.



Boris Jesus Mederos Madrazo received the B.S from the Universidad Central Marta Abreu de las Villas, Santa Clara, Cuba, the M.Sc. and Ph.D. degree in Mathematics from the Instituto Nacional de Matemática Pura e Aplicada (IMPA), Rio de Janeiro, Brazil. From 2005 to 2006, he was a post-doc at the Computer Science Department of the University of California at Davis (UC Davis). Dr. Mederos is currently with the Department of Física y Matemáticas at the Universidad Autónoma de Ciudad Juárez. His current teaching and research interests include pattern recognition, machine learning, medical image processing, image restoration, and surface reconstruction.



Rafael González received the Engineer in Electronics degree in 1997 from the Rafael Belloso Chacín University, Maracaibo, Venezuela, and the Ph.D. in Biomedical Engineering degree in 2008 from the Universitat Politècnica de Catalunya, Barcelona, Spain. He has been Associated Professor at the Francisco de Miranda University, Coro, Venezuela, since 1999, teaching courses in analog electronic and biomedical sensors. Currently he is working at the Department of Computer and Electrical Engineering, UACJ (Universidad Autónoma de Ciudad Juárez), Mexico. His current research areas include biomedical sensors and analog signal processing, noise and interference in electronic circuits and noninvasive physiological measurement.



José Díaz was born in Venezuela in 1976. He got an Electronic Engineer degree at the Polytechnic Institute of the National Armed Forces (Maracay, Venezuela) in 1997. He received his Ph.D degree in 2008 from Simón Bolívar University (Caracas, Venezuela). Between 1998 and 2016 he was part of the Electromedicine - Biomedical Engineering Program of the National Experimental University Francisco de Miranda in Coro, Venezuela. He is currently Professor attached to the Department of Electrical Engineering and Computing of the Autonomous University of Ciudad Juárez, Chihuahua, Mexico. His interest in teaching and research includes: Electronic and Biomedical Instrumentation, Analog and Digital Signal Processing, and Artificial Intelligence as a classification and prediction tool.