

Tipo de artículo: Artículo original

Algoritmo metaheurístico GWO-GAUSS_NEWTON aplicado a problemas de localización

Metaheuristic algorithm GWO-GAUSS_NEWTON applied to localization problems

Marcelino Sánchez Posada¹ , <https://orcid.org/0000-0001-8906-1149>

Alian Ernesto Matos Rodríguez² , <https://orcid.org/0000-0001-7333-7411>

¹ Centro de Investigación y Desarrollo Naval (CIDNAV). Calle Estrada Palma No.13, Casablanca, Regla, Cuba. Correo electrónico: {msanchez82, aematos}@nauta.cu

* Autor para correspondencia: msanchez82@nauta.cu

Resumen

En la actualidad existen varios algoritmos metaheurísticos que son ampliamente empleados para resolver problemas de optimización. El GWO (*Grey Wolf Optimizer*) es un nuevo algoritmo que presenta resultados competitivos con respecto al estado del arte de las técnicas metaheurísticas. Sobre la base del GWO y el método de Gauss-Newton, se propone un nuevo algoritmo híbrido GWO-Gauss_Newton con el objetivo de mejorar el balance entre las fases de exploración y explotación en el algoritmo GWO. Este algoritmo híbrido es aplicado en el problema de localización en Redes de Sensores Inalámbricas (RSI). Para evaluar el proceso se realizó un estudio comparativo con el GWO original y el algoritmo BAT. La solución minimizó el error de localización de los nodos, demostrando mejores desempeños con respecto a los otros dos algoritmos en términos de precisión, número de nodos localizados y costo de tiempo computacional.

Palabras clave: metaheurística; optimización; localización, Gauss_Newton; GWO

Abstract

Recently many meta-heuristic algorithms are widely used to resolve optimization problems. Grey Wolf Optimizer (GWO) is a new introduced algorithm which has competitive results respect to the other state-of-art of the meta-heuristic techniques. Based on GWO and Gauss_Newton method, we propose a new hybrid Grey Wolf Optimizer-Gauss Newton algorithm in order to improve the balance between exploration and exploitation phases on Grey Wolf algorithm. This hybrid algorithm is applied in Wireless Sensor Networks (WSN) localization problem. To evaluate the propose work, a comparative study is done with the original GWO and the BAT algorithm. The result applied to minimize error of localization nodes, the propose algorithm outperform the two other algorithm in term of accuracy, number of localized nodes and computational cost time.

Keywords: metaheuristic; optimization; localization; Gauss_Newton; GWO

Recibido: 05/12/2022

Aceptado: 30/01/2023

En línea: 02/02/2023

Introducción

En la actualidad, las redes de sensores inalámbricos son ampliamente empleadas en diferentes escenarios, ambientes industriales, domésticos, militares, salud, entre otros. (Ian et al.,2001). Una RSI es una red interconectada de múltiples nodos que se comunican unos con otros, teniendo la capacidad de explorar parámetros relacionados a su ambiente. Estos sensores tienen la habilidad de medir parámetros físicos, procesar la información y comunicarla a otros sensores a través de un canal de radio. Los nodos que conforman la RSI tienen un enlace de baja potencia, por lo que el área de cobertura es relativamente pequeña buscando economizar energía, a su vez, es necesario administrar mecanismos de enrutamiento multi-saltos, lo cual permite comunicación con nodos fuera de la distancia de comunicación de un nodo específico. El uso de estas redes se ha ampliado considerablemente por la posibilidad de suministrar información crítica y que en muchas de sus aplicaciones está involucrada la necesidad de un control permanente de parámetros de su ambiente. Frecuentemente muchas de estas aplicaciones requieren precisión en la información acerca de la localización de los nodos. Una vez que los sensores han sido desplegados en un área dada, la localización geográfica se convierte en una tarea importante, ya que esta permite determinar la ubicación de un evento y responder oportunamente. Además, con el conocimiento de la posición exacta de los nodos en la red, es posible mejorar muchos servicios como el enrutamiento de la información, control de la topología, cobertura, etc.

El proceso de localización física del sensor es conocido como localización, es un proceso que permite al sensor determinar su ubicación geográfica (Dargie et al.,2010). Una primera solución propuesta para resolver este problema es utilizando dispositivos GPS (*Global Positioning System*) en cada sensor. La incorporación de un GPS en cada sensor proporciona buena precisión, pero incrementa el tamaño del sensor, costo, consumo de energía y el desempeño disminuye para escenarios en interiores (Bakhouya et al., 2013). Esto justifica que en la práctica puedan diferenciarse dos tipos de sensores: nodos bases con posición adquirida vía GPS, empleados en pequeños números como nodo referencia y los nodos desconocidos sin información de la localización.

Para estimar la posición de los nodos desconocidos, existen dos técnicas principales de localización: *based-distance* y *free-distance* (Ian et al.,2001). La primera calcula la distancia a la coordenada del nodo desconocido basado en algunos parámetros como la fortaleza de la señal recibida, el ángulo de arribo y la diferencia de tiempo de arribo. Estos algoritmos están caracterizados por una muy alta precisión de la posición, pero necesitan información adicional de periféricos con un alto costo. Sin embargo, basados en la conectividad de la red, la segunda técnica no necesita dispositivos adicionales, pero proporciona menos precisión, como el algoritmo comúnmente empleado DV-Hop y el algoritmo del Centroide. El problema de localización en RSI es tratado como un problema de optimización. Los métodos analíticos de optimización como la programación lineal son aprovechados para resolverlos, pero el tiempo de cálculo y la complejidad se incrementa en la proporción en que se incrementa el problema (Kulkarni, 2010). Como una solución, los algoritmos metaheurísticos se han

convertido en muy populares en la última década, ya que pueden ser simplemente ajustados a los frecuentes cambios del ambiente, tienen una mayor eficiencia, son robustos y efectivos (Meza et al., 2015, Kulkarni et al., 2009). En problemas de localización, muchos algoritmos de optimización como el PSO (*Particle Swarm Optimization*) (Gopakumar, 2008), FA (*Firefly Algorithm*) (Harikrishnan et al., 2016, Arora, 2013), GA (*Genetic Algorithm*) (Zhang et al., 2008), GWO (*Grey Wolf Optimization*) (Rajakumar et al., 2017), BA (*Bat Algorithm*) (Sharawi et al., 2014), han sido aplicados para minimizar el error de la estimación de la posición de los nodos desconocidos. Estos algoritmos inspirados por la naturaleza se desempeñan bien en problemas de localización (Yang, 2010). La principal contribución de esta investigación es un nuevo algoritmo híbrido GWO-Gauss_Newton que mejora el balance entre las fases de exploración y explotación en el algoritmo GWO. Este algoritmo híbrido es aplicado en el problema de localización en Redes de Sensores Inalámbricas (RSI).

Materiales y métodos

El problema de localización en RSI consiste en estimar la ubicación de n nodos desconocidos basado en la información acerca de la posición de m nodos bases y la distancia entre nodos desconocidos y bases (Mao et al., 2007). Se asume que (x_i, y_i) son las coordenadas del nodo base i donde $x_i = [x_i, \dots, x_m]$ y $y_i = [y_i, \dots, y_m]$ y las coordenadas del nodo desconocido a ser estimada son (x_j, y_j) donde $x_j = [x_j, \dots, x_n]$ y $y_j = [y_j, \dots, y_n]$. La distancia entre ellos es:

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (1)$$

El impacto en la medición es simulado como un ruido blanco Gaussiano. Como resultado, la distancia estimada entre el nodo base i y el sensor j es:

$$\hat{d}_{ij} = d_{ij} + n_i \quad (2)$$

Donde n_i es el ruido adicionado. Este ruido tiene una distribución uniforme y el rango de variación para \hat{d}_{ij} es $\left[d_{ij} - d_{ij} \cdot \left(\frac{P_n}{100} \right), d_{ij} + d_{ij} \cdot \left(\frac{P_n}{100} \right) \right]$, donde P_n es el porcentaje de ruido. Cada nodo base estima la distancia entre sí mismo y cada nodo desconocido mediante (2). Es entonces calculado un error promedio para cada sensor:

$$E_i = \frac{1}{m} \sum_{j=1}^m \left(\sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} - (\hat{d}_{ij}) \right)^2 \quad (3)$$

En localización, se quiere reducir el error presentado en la ecuación (3) en orden de obtener las coordenadas lo más precisas para todos los sensores en la RSI. Entonces, el problema de localización es un problema de

optimización y la función de error puede ser considerada como una función objetivo sujeta a minimización y puede ser descrita como:

$$f(x, y) = \frac{1}{M} \sum_{j=1}^M \left(\sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} - (\hat{d}_{ij}) \right)^2 \quad (4)$$

Donde M es el número de nodos bases o de referencia vecinos (nodos bases dentro de la distancia de comunicación del nodo desconocido) y la condición para realizar la triangulación $M \geq 3$. Existen algunos algoritmos de optimización empleados en problemas de localización de RSI (Yun et al., 2009) tales como las técnicas de optimización metaheurísticas. Esta clase de técnica de optimización fue propuesta primero por Glover (Glover, 1986) y es cada vez más aplicada por las siguientes razones:

- Están basadas en un concepto simple y comportamientos naturales, adaptables y con una estructura flexible que puede ser empleada sin necesidad de cambiarla. Son como una caja negra donde solo se tiene que introducir los parámetros de entrada/salida.
- En contraste con las técnicas de optimización basadas en gradiente, la mayoría de los métodos metaheurísticos no necesitan realizar cálculos complejos para obtener la solución óptima. Lo que justifica su amplio uso en resolver problemas de funciones objetivo de la vida real usualmente caracterizadas por parámetros desconocidos y deducciones complejas.
- el proceso de búsqueda está compuesto de dos fases: exploración y explotación (Olorunda, 2008), la metaheurística se desempeña muy bien en resolver problemas de óptimo local debido a su naturaleza estocástica.

Algoritmo metaheurístico de optimización Grey Wolf

Propuesto por Mirjalili en 2014 (Mirjalili et al., 2014) el algoritmo GWO ha tenido éxito al ser empleado en muchos problemas de optimización (Yusof et al., 2015, Elfergany et al., 2015, Kamboj et al., 2016). El GWO es una técnica de inteligencia colectiva. Este constituye el primer enfoque inspirado en el comportamiento de los lobos en la naturaleza. Este imita la jerarquía de liderazgo de los lobos y sus estrategias durante la caza. Los lobos son clasificados en la escala alta de depredadores que viven usualmente en manadas compuestas de 5 a 12 miembros; son caracterizados por una jerarquía estricta dominante y un grupo de caza. La jerarquía social puede ser clasificada en cuatro niveles: el líder puede ser macho o hembra nombrado Alfa (α); en el segundo nivel los lobos Beta (β) asistentes del Alfa; los lobos Omega (ω) en el tercer nivel, subordinados de Alfa y Beta; y en el cuarto nivel los lobos Delta (δ) que son el resto de la manada. El grupo de cacería, resume las diferentes fases del GWO en: seguimiento de la presa; persecución y sitiarse a la presa mientras se detiene y el ataque a la presa. Los dos primeros pasos de la caza del lobo son usados para la fase de exploración en el GWO ya que se encarga

de buscar la solución en el espacio de búsqueda global. Sin embargo, la explotación en el GWO es asegurada por la última fase que es buscar la presa en el espacio de búsqueda local. (Muro et al., 2011)

Modelo matemático del algoritmo GWO

En el modelo matemático del GWO, el Alfa (α) es considerado como la mejor solución, la segunda es Beta (β) y la última es Delta (δ). (Mirjalili et al., 2014)

Rodeando a la presa: En esta fase, durante la caza, después de localizar a la presa, los lobos la rodean. El modelo matemático de este comportamiento es descrito por las siguientes ecuaciones:

$$\vec{D} = \|\vec{C} \cdot \vec{X}_p(i) - \vec{X}(i)\| \quad (5)$$

$$\vec{X}(i+1) = \vec{X}_p(i) - \vec{A} \cdot \vec{D} \quad (6)$$

Donde i es el número de iteración, \vec{A} y \vec{C} son los coeficientes de los vectores, \vec{X}_p y \vec{X} son el vector posición de la presa y el vector posición del lobo, respectivamente. El cálculo de \vec{A} y \vec{C} es asegurado por la siguiente ecuación:

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a}, \quad \vec{C} = 2\vec{r} \quad (7)$$

Donde \vec{a} disminuye linealmente desde 2 a 0 en función de las iteraciones y \vec{r} es un vector aleatorio entre $[0,1]$.

\vec{A} y \vec{C} son ajustados para proporcionar a cada agente de búsqueda la mejor posición de la presa en cualquier localización aleatoria.

- 1) **Cazando a la presa:** para modelar la estrategia de caza de los lobos, Mirjalili supuso que α , β y δ son los mejores agentes de búsqueda y todos los lobos de la manada ω tienen que ajustar su posición de acuerdo a la posición de estos tres. Este comportamiento es ilustrado por:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (8)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (9)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (10)$$

Donde \vec{D}_α , \vec{D}_β y \vec{D}_δ son los vectores distancia entre el α , β y δ ; los otros lobos usan los tres vectores coeficiente \vec{C}_1 , \vec{C}_2 y \vec{C}_3 respectivamente en ajustar esta distancia.

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \quad (11)$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \quad (12)$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \quad (13)$$

Donde \vec{X}_1 , \vec{X}_2 y \vec{X}_3 son el nuevo vector posición para las localizaciones de α , β y δ , respectivamente. Entonces, empleando la suma promedio de estas tres nuevas posiciones presentadas por las ecuaciones (11), (12) y (13); una nueva posición es obtenida y es ilustrada por la ecuación (14):

$$\vec{X}(i+1) = \frac{\sum_{j=1}^k \vec{X}_j}{k} \quad (14)$$

Donde $k = 3$ representa los tres lobos α , β y δ .

- 2) **Ataque a la presa:** Esta etapa es considerada como la fase de explotación en técnica de optimización. Mediante la variación aleatoria de \vec{A} en el rango $[-2a, 2a]$, la búsqueda local es realizada y cuando el parámetro \vec{C} varía en el intervalo $[0, 2]$ ayuda a encontrar el óptimo local y busca la mejor solución en el área de búsqueda local. El pseudocódigo del GWO es ilustrado a continuación:

Inicializar la población de los lobos $W_i(1, 2, \dots, n)$

Inicializar a, A, C

Calcula los ajustes de cada agente de búsqueda

W_α = el mejor agente de búsqueda

W_β = el segundo mejor agente de búsqueda

W_δ = el tercer mejor agente de búsqueda

While ($j \leq$ Máximo número iteraciones)

For cada agente de búsqueda actualiza la posición del agente de búsqueda actual

End For

Actualiza a, A, C

Calcula el ajuste de todos los agentes de búsqueda

Actualiza W_α , W_β y W_δ .

$j = j + 1$

End while

Return W_α

Método de Gauss-Newton

Sobre la base del método de Newton, el método de Gauss-Newton se desempeña muy bien en resolver problemas de mínimos cuadrados no lineales (Madsen et al., 2004). Aplicando un enfoque iterativo, este minimiza la suma de valores de la función cuadrática. Este proceso lo realiza para buscar el valor mínimo de una función $f(x_k)$ sin necesidad de calcular derivadas de funciones complejas. En este método, la idea principal es aproximar el problema de mínimos cuadrados no lineales a un problema de mínimos cuadrados lineales y entregar una solución con una aproximación determinada (Fasino et al., 2018). Los diferentes pasos del algoritmo de Gauss-Newton son:

- *paso 1: inicialización x_0 , tolerancia $\varepsilon > 0$ y $k = 0$*
- *paso 2: calcular el gradiente g_k , si $\|g_k\| \leq \varepsilon$ parar*
- *paso 3: usando*

$$s_k = -\left(J(x_k)\right)^T \left(J(x_k)\right)^T f(x_k) \quad (15)$$

s_k es calculada

- *paso 4: configurar $x_{k+1} = x_k + s_k$; $k = k + 1$ y retorna al paso 1.*

Algoritmo híbrido de localización GWO-Gauss_Newton

La técnica de optimización híbrida metaheurística es el resultado de combinar dos o más algoritmos de optimización metaheurísticos y métodos de optimización con el objetivo de encontrar la mejor solución y reducir la complejidad del problema; basado en las ventajas de cada método (Niknam et al., 2009). Destinados a lograr nuevos algoritmos competitivos (Niknam et al., 2010), estos métodos metaheurísticos combinados tienen muchos campos de aplicación como el problema de la localización en RSI. Como ejemplo se puede citar como referencia a (Szykiewicz et al., 2009), donde es introducido un híbrido combinando los algoritmos genéticos y de las hormigas. En este trabajo el error de localización de los nodos es minimizado basado en el método de trilateración o triangulación. GWO fue recientemente introducido en los problemas de localización de RSI por R. Rajakumar y J. Amudhavel en 2017 (Rajakumar et al., 2017). GWO-LPWSN proporciona un buen resultado en la localización de los nodos desconocidos e incrementar la precisión.

¿Por qué combinar los algoritmos GWO y Gauss-Newton?

Cada algoritmo metaheurístico está compuesto de dos fases, exploración y explotación. La primera consiste en entregar muchas soluciones a partir de investigar el espacio de búsqueda en una amplia escala. El proceso de



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Grupo Editorial “Ediciones Futuro” Universidad de las Ciencias Informáticas. La Habana, Cuba seriecientifica@uci.cu

explotación es responsable de perseguir la mejor solución en una región local. Un equilibrio eficiente entre estos dos componentes asegura encontrar el óptimo. Sin embargo, el algoritmo GWO presenta pobre convergencia en la fase de explotación (Saremi et al., 2015, Mahdad et al., 2015). Esto justifica la necesidad de buscar una solución para mejorar esta habilidad de búsqueda local. Existen estudios que prueban que el GWO proporciona mejores resultados en hibridación metaheurística con técnicas de búsqueda local (Zhang et al., 2015). Por lo que en esta investigación se propone emplear el método de Gauss-Newton para resolver el problema de búsqueda local del GWO. Reduciendo el costo computacional y disminuyendo el tiempo de convergencia, el método de Gauss-Newton es una mejora del método de Newton. No obstante, este requiere de buenos valores iniciales para dar una estimación precisa y rápida convergencia (Gerstoftat, 1995, GAO et al., 2013); sino, existe el riesgo de quedarse estancado en cualquier mínimo local o diverge. Esto explica el por qué se escoge el método de Gauss-Newton como un complemento en la fase de explotación del GWO. El método de Gauss-Newton se emplea en la búsqueda local para proporcionar las mejores soluciones y su valor inicial será la mejor solución del algoritmo GWO. Con ambas técnicas se logra el equilibrio entre las fases de exploración y explotación.

Algoritmo Híbrido GWO-Gauss_Newton aplicado a localización de sensores

Los diferentes pasos de la simulación del algoritmo propuesto para el problema de localización en RSI se muestran en la figura 1. Estos son:

- 1) *Fase de inicialización*: Aleatoriamente se despliega m nodos bases y n nodos desconocidos en un área determinada. Se asume que todos los nodos tienen la misma distancia de comunicación R .
- 2) Empleando las coordenadas de los nodos bases, los nodos desconocidos calculan su posición. Al menos tres nodos bases son necesarios para calcular la posición del nodo desconocido. La estimación de las coordenadas de los nodos es calculada por un algoritmo libre en distancia (DV-Hop).
- 3) La distancia entre cada sensor y nodos bases es calculada por (2). En orden de simular el error causado por el límite del dispositivo y las consideraciones del ambiente, un valor de ruido blanco Gaussiano es aplicado:

$$\hat{d}_{ij} = d_{ij} + n_i \quad (16)$$

Donde i es un nodo base, j representa el nodo desconocido.

- 4) *Configuración de los parámetros del algoritmo*: La función objetivo es definida por (4). El número de variables, la cantidad de agentes de búsqueda, los límites superiores e inferiores y el número máximo de iteraciones, son definidas.

5) *Se aplica el GWO.*

- La posición inicial de los agentes de búsqueda es aleatoriamente generada dentro de los límites configurados del espacio de búsqueda.
- La función objetivo es evaluada para cada posición de los agentes de búsqueda y la solución estimada para cada uno de ellos.
- Los valores de a , \vec{A} y \vec{C} son inicializados. Las posiciones de los lobos α , β y δ son reajustadas. El algoritmo es configurado de acuerdo al valor de ajuste y el valor del óptimo actual x_{opt} es salvado.
- Si se alcanza el número máximo de iteraciones, la mejor posición global es entregada y continúa al próximo paso; sino es retornada al paso 3.

6) Se configura x_{opt} a la posición inicial del algoritmo Gauss-Newton para encontrar la posición de los nodos. Cuando la condición se cumple, el algoritmo finaliza y entrega la solución para la mejor localización, la cual es la coordenada para el nodo desconocido en análisis.

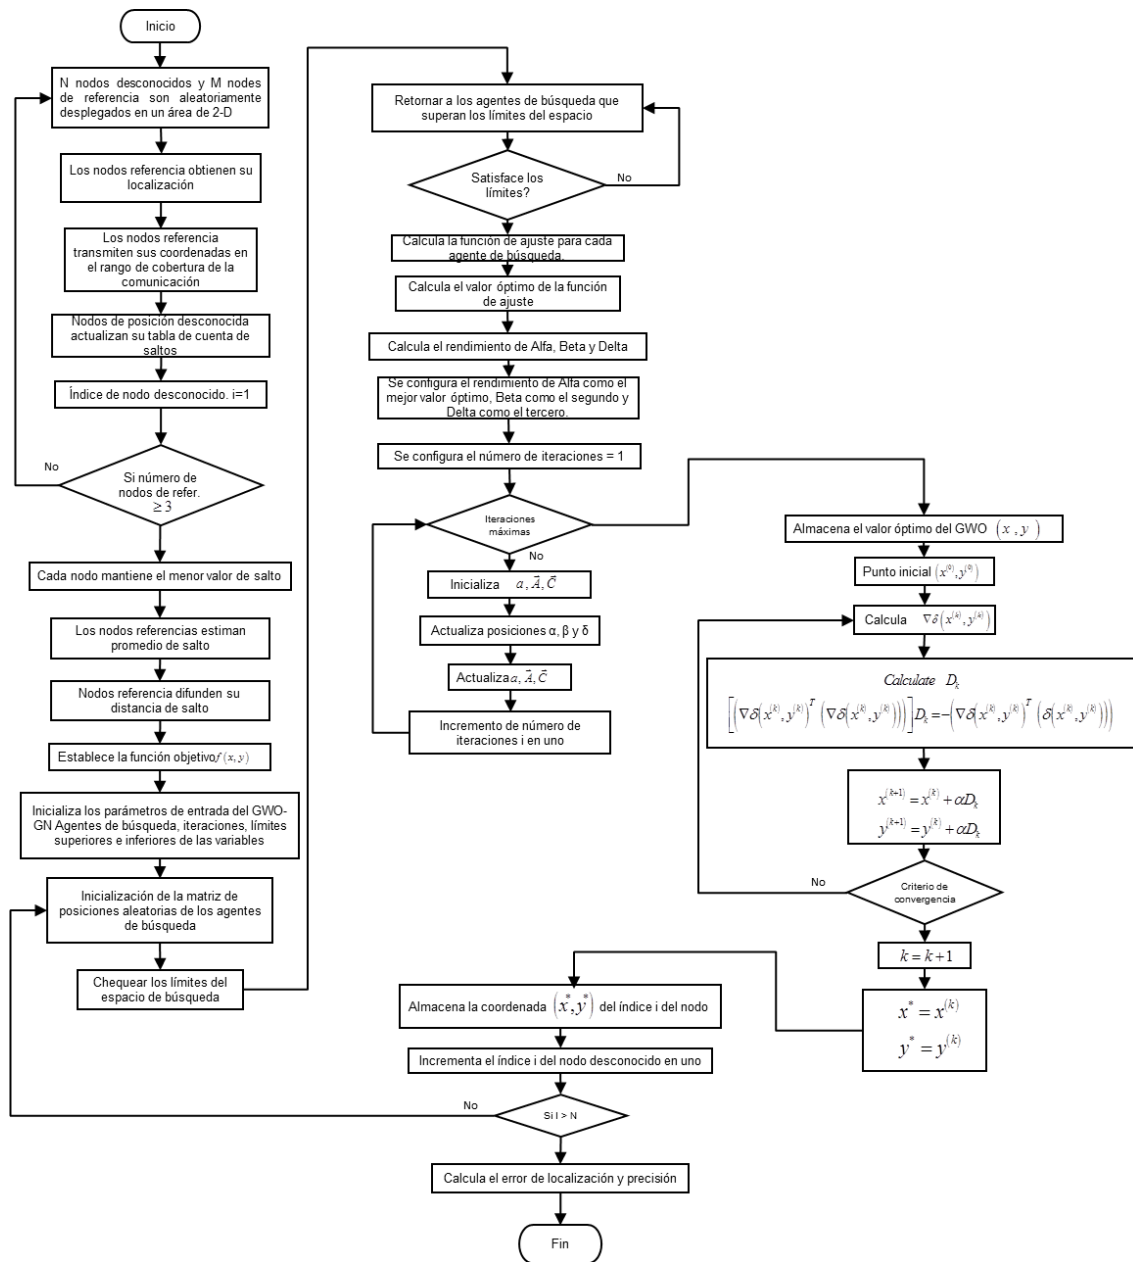


Figura 1. Diagrama de flujo del algoritmo de localización empleando GWO-Gauss_Newton

Resultados y discusión

En esta sección, se discute la eficiencia del algoritmo propuesto. Se realizó un estudio comparativo con otros dos algoritmos: versión original del GWO y el algoritmo BAT con buen desempeño en problemas de localización. Los tres algoritmos son aplicados al problema de localización en RSI. Para cada algoritmo de optimización, se configura los parámetros de control. En el GWO, el número de agentes de búsqueda es 30 y el número máximo de iteraciones 100. En el algoritmo BAT (Goyal et al., 2015), se ajusta el tamaño de la población a 20, número de generaciones 1000, bajos en 0.5 y relación de pulsos en 0.5.



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Grupo Editorial "Ediciones Futuro" Universidad de las Ciencias Informáticas. La Habana, Cuba seriecientifica@uci.cu

La RSI tiene como parámetro el área donde 100 sensores son distribuidos aleatoriamente. El parámetro de ruido en la medición se ajustó a 0.2. Para evaluar el desempeño del algoritmo híbrido, tres criterios son empleados: error medio de localización, número de nodos localizados y tiempo computacional.

La figura 2 muestra un ejemplo del resultado de la simulación de los tres algoritmos. En este escenario solo 10 nodos son desplegados en un área de $100 \times 100 m^2$ con el fin de visualizar su distribución.




Figura 2. Ejemplo de localización de nodos

El primer criterio en el análisis es el error medio de localización (MLE). Este se muestra en la figura 3. Incrementando el número de sensores de 10 a 100, el valor medio de MLE calculado para cada uno de los rangos de nodo es 4.550m, 13.28m, 15.41m para el GWO-Gauss_Newton, GWO y BAT respectivamente. Resulta evidente que el GWO-Gauss_Newton resuelve con buen desempeño el problema del óptimo local y lo mejora casi en 3 veces con respecto al original. La figura 4 presenta el error de localización mínimo para los tres algoritmos, el algoritmo híbrido muestra una característica más suavizada y con menor error con respecto a los analizados.




Figura 3. Error de localización.




Figura 4. Error de localización mínimo.

El segundo escenario consiste en calcular los valores de MLE respecto a la relación de ruido en la medición, figura 5. Para comprobar el algoritmo propuesto, se supone que la técnica de cálculo de la distancia genera un error de 10 al 60%; entonces la MLE es calculada para cada valor en este rango. Cuando el híbrido GWO-Gauss_Newton, el GWO y el BAT son aplicados en este escenario, la precisión disminuye respectivamente. Independientemente de la precisión del algoritmo de cálculo de la distancia, el algoritmo GWO-Gauss_Newton es

más eficiente para minimizar el error introducido y mostrar un buen desempeño en problemas de localización en RSI.




Figura 5. Error de localización medio

El número de nodos localizados es una métrica para evaluar el trabajo de cualquier algoritmo empleado en localización de RSI. En este caso, un nodo es considerado localizado cuando el valor de error entre la posición real y la estimada es menor a un valor umbral. El umbral está configurado a 20m. El resultado de los tres algoritmos se muestra en la figura 6.

El algoritmo GWO-Gauss_Newton logra mejores resultados por la identificación de número de nodos localizados cuando se compara con su original GWO y el BAT. La cantidad de nodos localizados en el algoritmo híbrido supera el 90%. Por ejemplo, para 100 sensores desplegados, GWO-Gauss_Newton localiza 96 nodos, GWO localiza 84 nodos y para el algoritmo BAT 80 nodos localizados. Esto se explica debido a la habilidad del algoritmo híbrido en lograr un buen equilibrio entre las fases de explotación y exploración. Este resultado demuestra que el algoritmo híbrido GWO-Gauss_Newton supera a la versión original del GWO y el BAT. Como se ilustra en la figura 7, esta propuesta mejora en la precisión y localiza mayor cantidad de sensores con un mínimo de incremento del costo de tiempo computacional. Esto es consecuencia de la rápida convergencia del algoritmo GWO por un lado y la buena inicialización de los parámetros del método de Gauss-Newton por el otro.




Figura 6. Nodos localizados.




Figura 7. Tiempo de cálculo

Conclusiones

Las técnicas metaheurísticas inspiradas en la naturaleza han tenido éxito en resolver problemas de optimización en muchos campos. Implementado en el 2014, el algoritmo metaheurístico GWO es comúnmente empleado por proporcionar buenos resultados en problemas de optimización. Para mejorar la fase de explotación (habilidad de

búsqueda local), se obtuvo un algoritmo híbrido combinando el GWO y el método de Gauss-Newton. Cuando es aplicado en el problema de localización de RSI, este algoritmo logra buenos desempeños en precisión e identificación de nodos. Comparado con la versión original GWO y el BAT, el algoritmo híbrido GWO-Gauss_Newton supera significativamente a estos.

Conflictos de intereses

Los autores autorizan la distribución y uso de su artículo.

Contribución de los autores

1. Conceptualización: Marcelino Sánchez Posada.
2. Curación de datos: Alian Ernesto Matos Rodríguez
3. Análisis formal: Marcelino Sánchez Posada
4. Investigación: Marcelino Sánchez Posada y Alian Ernesto Matos Rodríguez
5. Metodología: Marcelino Sánchez Posada
6. Administración del proyecto: Marcelino Sánchez Posada
7. Recursos: Marcelino Sánchez Posada
8. Software: Marcelino Sánchez Posada y Alian Ernesto Matos Rodríguez
9. Supervisión: Marcelino Sánchez Posada
10. Validación: Marcelino Sánchez Posada
11. Visualización: Alian Ernesto Matos Rodríguez
12. Redacción – borrador original: Marcelino Sánchez Posada y Alian Ernesto Matos Rodríguez
13. Redacción – revisión y edición: Alian Ernesto Matos Rodríguez

Financiamiento

La investigación no requirió fuente de financiamiento externa.

Referencias

- IAN F.AKYILDIZ, WEI SU. Wireless sensor networks: a survey. *Computer Networks*. Vol.38, no.4, 2001, p. 393-422.
- DARGIE W., C.POELLABAUER. *Fundamentals of wireless sensors networks: Theory and practice*. Wiley. ISBN:978-0-470-97568-8. 2010. p. 336.
- BAKHOUYA; NAIT-SIDI-MOH. Geopositioning and mobility. *Iste ltd and john wiley and sons Inc Networks and Telecommunications Serie*, vol. 2, no. 1, 2013, p. 272.
- KULKARNI H. Bio inspired algorithms for autonomous deployment and localization of sensor nodes *IEEE Signal Processing Magazing*, vol. 40, no. 6, 2010, p. 663–675.
- MEZA J., H.ESPITIA. Statistical analysis of a multiobjective optimization algorithm based on a model of particles with vorticity behavior. *Soft Computing*, 2015, p. 1–16.
- KULKARNI, VENAYAGAMOORTHY. Bio inspired node localization in wireless sensor networks. 2009, p. 205–210.
- GOPAKUMAR J. Localization in wireless sensor networks using particle swarm optimization. 2008, p. 227–230.
- HARIKRISHNAN, KUMAR. Firefly algorithm approach for localization in wireless sensor networks. 2016, p. 209– 214.
- ARORA S. A conceptual comparison of firefly algorithm, bat algorithm and cuckoo search. 2013, p. 1–4.
- ZHANG Q., J. WANG. Genetic algorithm based wireless sensor network localization vol. 1, 2008, p. 608–613.
- RAJAKUMAR R., J. AMUDHAVEL ,T. VENGATTARAMAN. Gwolphsn: Grey wolf optimization algorithm for node localization problem in wireless sensor networks. *Computer Networks and Communications*, 2017, vol. 2017, p.227.
- SHARAWI M., E.EMARY. Flower pollination optimization algorithm for wireless sensor network lifetime global optimization. *International Journal of Soft Computing and Engineering*, vol. 4, no. 3, 2014, p. 54–59.
- YANG X. *Nature inspired metaheuristic algorithms*. Luniver Press. ISBN-10: 1905986289. 2010. p. 75.
- MAO , O. ANDERSON. Wireless sensor network localization techniques. *Journal of Computer Research and Development*, vol. 51, no. 10, 2007, p. 2529–2553.
- YUN S., J. LEE , S. KIM. A soft computing approach to localization in wireless sensor networks. *Expert Systems with Applications*. vol. 36, no. 4, 2009, p. 7552–7561.

- GLOVER F. Future paths for integer programming and links to artificial intelligence. *Computer and Operations Research*. Vol.13, 1986, p. 533–549.
- OLORUNDA L. Measuring exploration exploitation in particle swarms using swarm diversity. *IEEE Congress on Evolutionary Computation*. 2008, pp. 1128–1134.
- MIRJALILI S. , A. LEWIS. Grey wolf optimizer. *Advances in Engineering Software*, vol. 69, 2014, pp. 46–61.
- YUSOF Y, Z. MUSTAFFA. Time series forecasting of energy commodity using grey wolf optimizer. *International Multi Conference of Engineers and Computer Scientists (IMECS'15)*, Hong Kong, March 2015, 2015.
- ELFERGANY A., M. HASANIEN. Single and multiobjective optimal power flow using grey wolf optimizer and differential evolution algorithms. *Electric Power Components and Systems*. vol. 43, no. 13, 2015, p. 1548–1559.
- KAMBOJ K. , S. DHILLON. Solution of nonconvex economic load dispatch problem using greywolf optimizer. *Neural Computing and Applications*. vol. 27, no. 8, 2016, p. 1301–1316.
- MURO R., C. ESCOBEDO. Wolf pack (canis lupus) hunting strategies emerge from simple rules in computational simulations. *Behavioral Process*. vol. 88, 2011, p. 192–197.
- MADSEN K. , O. TINGLEFF. *Methods for non linear least squares problems 2nd Edition*. Informatics and Mathematical Modelling technical University of Denmark. 2004. p. 30.
- FASINO D., A. FAZZI, “A Gauss–Newton iteration for total least squares problems. *Bit Numer Math*. Vol.58, 2018, p. 281-299.
- NIKNAM T., B. AMIRI. An efficient hybrid evolutionary optimization algorithm based on PSO and SA for clustering. *Journal of Zhejiang University Science A*., vol. 10, no. 4, 2009, p. 512–519.
- NIKNAM T., B. AMIRI. An efficient hybrid approach based on PSO, ACO and K means for cluster analysis. *Applied Soft Computing Journal*. vol. 10, no. 1, 2010, p. 183–197.
- SZYNKIEWICZ N. , M. MARKS. Optimization schemes for wireless sensor network localization. *International Journal of Applied Mathematics and Computer Science*. vol. 19, no. 2, 2009, p. 291–302.
- GOYAL S., S. PATTERH. Modified bat algorithm for localization of wireless sensor network. *Wireless Personal Communications*. vol. 86, 2015, p. 657–670.
- SAREMI S., S. MIRJALILI. Evolutionary population dynamics and grey wolf optimizer. *Neural Computing and Applications*. vol. 26, no. 5, 2015, p. 1257–1263.

- MAHDAD B., K.SRAIRI. Blackout risk prevention in a smart grid based flexible optimal strategy using grey wolf pattern search algorithms. *Energy Conversion and Management*. vol. 98, no. 5, 2015, p. 411–429.
- ZHANG S., Y. ZHOU. Grey wolf optimizer based on powell local optimization method for clustering analysis. *Journal of Computer Networks and Communications. Discrete Dynamics in nature and Society*. vol. 2015, Article ID 481360, 2015, p. 17.
- GERSTOFAT P. Inversion of acoustic data using a combination of genetic algorithms and the Gauss Newton approach. *J. Acoust S. oc.A m.*, vol. 97, no. 4, 1995, p. 195-200.
- GAO F., L. HUANG, A novel artificial bee colony algorithm with Powell's method. *Applied Soft Computing*, vol. 13, no. 9, 2013, p. 3763–3775.