

# WSNの長期間運用を目的とした特殊ノードの 設置ロケーション候補を探索する改良 PSO

熊本 紋子<sup>†</sup> 江 政道<sup>†</sup> 宇谷 明秀<sup>‡</sup> 山本 尚生<sup>‡</sup>  
 武蔵工業大学大学院工学研究科<sup>†</sup> 武蔵工業大学知識工学部<sup>‡</sup>

## 1. はじめに

無線センサネットワーク(WSN)の利用に注目が集まっている。WSNでは電源容量などのリソースに制約のある無線センサノードから構成されることが前提となる。したがって、長期間領域を観測するためには、各ノードの電力消費を抑えた効率的なデータ収集を行う必要がある。本研究では、WSNの長期間運用のための方策として、電源容量などのリソースに制約のない(限られた数の)中継専用特殊ノードを観測領域に効果的に設置(追加散布)し、この特殊ノードが周囲のセンサノードの計測データを集約してシンクノードへ転送することで、各センサノードの転送処理負荷を低減することを考える。

本稿では、特殊ノードの効果的なロケーションを求めるための手法として、群知能アルゴリズムの1つであるParticle Swarm Optimization(PSO)[1]を拡張発展させたPSO for Decent Solutions(DSPSO)を提案する。WSNの実際の利用環境では、自然条件などの要因により、特殊ノードを求めたロケーションに設置できない場合や状況の変化により初期状態では効果的であったロケーションがそうではなくなる場合が考えられる。よって本研究では1つの最適解ではなく、複数の最良解(Decent Solutions)を探索するDSPSOを提案することによって、複数のロケーション候補を求めることを考えた。シミュレーション実験によって、DSPSOの有効性を検証した。

## 2. PSO (Particle Swarm Optimization)

PSOとは群れ状の粒子が情報を共有しながら多次元解空間を探索し、個々の粒子が持つ最良解情報(*pbest*)と群れ全体で共有する最良解情報(*gbest*)を利用して解を探索する群知能アルゴリズムの1つである。

各粒子は1ステップ前の移動ベクトル  $v^k$ , *pbest*, *gbest*の線形結合として新たな移動ベクトル  $v^{k+1}$ を生成し、次の位置  $x^{k+1}$ まで移動する。ここで、 $k$ は反復計算回数である。 $k+1$ ステップのある粒子の移動ベクトル、及び位置ベクトルは式(1)により求められる。

$$\begin{aligned} v_i^{k+1} &= \omega \cdot v_i^k + c_1 \cdot \text{rand}_1() \cdot (pbest_i^k - x_i^k) \\ &\quad + c_2 \cdot \text{rand}_2() \cdot (gbest^k - x_i^k) \\ x_i^{k+1} &= x_i^k + v_i^{k+1} \end{aligned} \quad (1)$$

ただし、 $\text{rand}_1(), \text{rand}_2()$ は0~1の一様乱数、 $\omega$ は粒子の慣性力、 $c_1, c_2$ は学習係数である。

Improved particle swarm optimization for locating relay-dedicated nodes in wireless sensor networks

<sup>†</sup>Ayako KUMAMOTO and Seido KOH, Graduate School of Engineering, Musashi Institute of Technology

<sup>‡</sup>Akihide UTANI and Hisao YAMAMOTO, Faculty of Knowledge Engineering, Musashi Institute of Technology

## 3. 自律適応型 PSO

PSOでは、一般に局所解に陥り易い。それを改善する方法として自律適応型 PSO[2]が提案されている。これはPSOのパラメータを探索の過程で自律適応的に調整することによって、より良い解を求める方法である。

自律適応型 PSOでは、効率的な最適解探索への指針として、「*gbest*を可能な限り更新すること」を探索の成功と仮定し、*gbest*を更新した粒子のパラメータ( $c_1, c_2$ )を目標パラメータ( $cbest_1, cbest_2$ )と設定する。式(2)を用いてこの目標パラメータ値に近づけることにより、各粒子のパラメータの自律調整を行う。ただし、この自律調整は*gbest*を更新した粒子が自身よりも更新頻度が高い場合のみ行う。ここで、 $N$ は粒子数、 $T_{max}$ は総反復回数である。

$$\begin{aligned} c_{1i}^{k+1} &= c_{1i}^k + \alpha (cbest_{1i}^k - c_{1i}^k), i=1,2,\dots,N \\ c_{2i}^{k+1} &= c_{2i}^k + \alpha (cbest_{2i}^k - c_{2i}^k), i=1,2,\dots,N \\ \alpha &= 1/T_{max} \end{aligned} \quad (2)$$

## 4. 調査実験

本稿で想定する実験環境下で、PSOと自律適応型 PSO (Autonomous Adaptive PSO; AAPSO)との比較を行った。Table1,2はそのシミュレーション設定である。ここで、本実験における評価関数はネットワーク全体での総ホップ数である。これは全センサノードからシンクノードへのデータ送信に要した(最短)ホップ数の総和である。なお、シンクノードは実験領域の中央下に設置し、各特殊ノードの初期配置は(通信範囲+200)以内に他特殊ノードが配置されていないことを前提としている。本実験において、特殊ノードを配置しない場合のネットワーク全体での総ホップ数は約16000、特殊ノードの初期配置状態では平均5900であった。

Table1 Condition of the simulations

Simulation size	4500 × 4500
The Number of sensor nodes	1024
The Number of relay-dedicated nodes	5
Range of radio wave	250
The Number of particles ( $N$ )	10
Total number of iterations ( $T_{max}$ )	100

Table2 Initial value of Parameters

	PSO	AAPSO
$\omega$	0.8	0.8
$c_1, c_2$	$c_1 = 0.9, c_2 = 1.1$	$0 < c_1 + c_2 \leq 3.0$




Fig.1 Average total hops

Fig.1 は探索過程を比較したグラフである。ネットワーク全体での総ホップ数は両手法においてほとんど差異はなく、収束速度も同程度である。この結果より、本稿の実験環境は、同程度の最良解がいくつも存在する解空間になっていると考えられる。複数回のシミュレーションの結果、ネットワーク全体での総ホップ数が同程度でも、特殊ノードの配置が大きく異なる解が複数存在することが確認されている。

## 5. 提案手法

本稿では1つの最適解ではなく、複数の最良解を探索する DSPSO を提案する。複数のロケーション候補を求めることによって、特殊ノードの設置に関する多様な手段を提供することができる。

PSO は全粒子で1つの解 ( $g_{best}$ ) を探索するアルゴリズムであるが、DSPSO は初期段階では全粒子で1つの解 ( $g_{best_1}$ ) を探索し、収束し始めると  $g_{best_1}$  を探索する粒子と新たな解 ( $g_{best_2}$ ) を探索する粒子に分け、順に複数の解を求めていくというアルゴリズムである。

調査実験により、このロケーション探索問題の解は複数存在することが確認できたので、本稿では1回の実験で  $m$  個の解 ( $g_{best_l}, l=1, \dots, m$ ) を順に求めることを目的とする。DSPSO に導入した処理は以下の通りである。

### 1) $g_{best_l}$ と各粒子の $p_{best_l}$ 間の総距離算出

$g_{best_l}$  と各粒子の  $p_{best_l}$  ( $i=1, \dots, N$ ) の特殊ノードのロケーションに関する類似性を確認するため、特殊ノード間の総距離を算出する。1つの粒子が  $p$  個の特殊ノードで構成される場合、総距離  $distance_{g_{best_l}, p_{best_l}}$  は式(3)により求めることができる。

$$distance_{g_{best_l}, p_{best_l}} = \sum_{q=1}^p \sqrt{(X_{g_{best_l}, q} - X_{p_{best_l}, q})^2 + (Y_{g_{best_l}, q} - Y_{p_{best_l}, q})^2} \quad (3)$$

### 2) 類似性の判定

各粒子  $i$  は総距離が短いほど、 $g_{best_l}$  と特殊ノードのロケーションに類似性があると判断できる。総距離が閾値  $T_{affinity\_g_{best_l}}$  より短い粒子が  $N/m$  個以上ある場合、総距離の短い上位  $N/m$  個の粒子は引き続き  $g_{best_l}$  の探索を続ける。他の粒子は一樣乱数によって生成した粒子に交換する。このとき、新たに生成した粒子と  $g_{best_l}$  との総距離を式(3)により計算し、閾値より長いことを確認する。なお、総距離が閾値より短い粒子が  $N/m$  個より少ない場合には、 $g_{best_l}$  の探索を続ける。

PSO に対し、上記1), 2)の処理を導入することにより、

限られた数の粒子で複数の最良解(ロケーション候補)を効率良く求めることができる。




Fig.2 Decent solutions by DSPSO

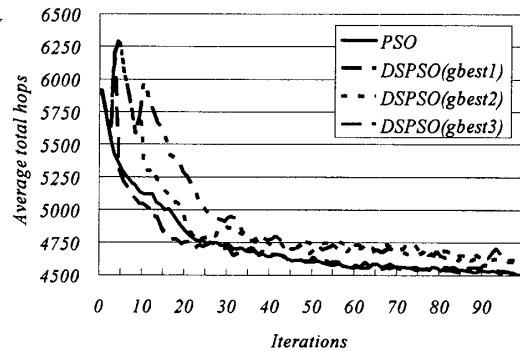


Fig.3 Average total hops

## 6. シミュレーション実験

### 6.1 シミュレーション設定

4章の調査実験と同環境で DSPSO の有効性検証を行った。本実験では3つの最良解 ( $m=3$ ) を求めることとした。ここで、粒子数  $N$  は30とし、類似性の判定で使用する閾値には式(4)を用いた。また、各パラメータの設定値は Table2 と同じである。

$$T_{affinity\_g_{best_l}} = \frac{\max(distance_{g_{best_l}, p_{best_l}}; i=1, \dots, N)}{2} \quad (4)$$

### 6.2 結果及び考察

Fig.2 は DSPSO によって求められた3つの最良解であり、各特殊ノードのロケーションが表してある。PSO では、既に述べたように1つの準最適解しか求めることができないが、DSPSO では特殊ノードのロケーション候補を3つ求めることができた。さらに、PSO と DSPSO の探索過程を比較した結果、同程度の精度の解が得られていることが確認できた (Fig.3)。

## 7. まとめ

本稿では、無線センサネットワークの長期間運用を目的とした特殊ノードの複数のロケーション候補を探索する PSO for Decent Solutions (DSPSO) を提案し、その有効性をシミュレーション実験によって確認した。

## 文献

- [1] J.Kennedy and R.C.Eberhart : Swarm Intelligence, Morgan Kaufmann Publishers, 2001.
- [2] 山口, 岩崎, 安田 : 最良解情報をういた適用型 Particle Swarm Optimization, 電学論 C, vol.126, no.2, pp.270-276, 2006.