

F-045

多様性維持を目的とした Particle Swarm Optimization の改良

Improvement of Particle Swarm Optimization for Maintaining Diversity

松井 丈弥†

Takeya MATSUI

能登 正人†

Masato NOTO

1. はじめに

近年、システムの大規模化、複雑化が進んでおり、様々な制約条件の下でシステムの高効率化、高信頼化の実現が求められている。ある制約条件の下で目的とするものを最小化(最大化)するような変数を決定する問題は最適化問題と呼ばれており、システム的设计、運用を行う際には様々な最適化問題を解く必要がある。

最適化問題の解法の一つにメタヒューリスティクスがある。メタヒューリスティクスとは、最適性の保障はないが十分精度の高い解を探索可能な手法である[1]。メタヒューリスティクスの代表的な手法として、生物の進化を模倣した Genetic Algorithm (GA)、山登り法を改良して既に通過した解に戻ることを避けるためタブーリストと呼ばれるメモリを利用する Tabu Search (TS)、鉄の焼き鈍しのアナロジーに基づく Simulated Annealing (SA)、アリの採餌行動を模倣した Ant Colony Optimization (ACO) などがあるが、特に「群れ」の挙動からヒントを得た Particle Swarm Optimization (PSO) がアルゴリズムの簡単さと汎用性の高さから注目を集めている。

PSO は GA に代わるものとして 1995 年に J. Kennedy と R. Eberhart によって開発された、非線形最適化問題を解くための有力な手法の一つである[2]。PSO の基本原理は、鳥や魚などの群が餌を探す際の行動を研究することによって導かれた「情報を群全体で共有する」という仮説に基づいている。PSO では、複数の探索点 (Particle) がそれぞれ位置と速度の情報を持っており、これらの情報を群の中で交換し、最良解の情報を共有しながら探索を行う。PSO のアルゴリズムは基本的な算術演算の繰り返しから構成された、非常にシンプルなものである。そのため、非線形関数最適化問題に適用した場合、他のメタヒューリスティクスと比べて高速に解くことができると報告されている[3]。PSO は電力システム、制御系設計システム、ニューラルネットワークなど様々な問題に対して適用され、その有効性が確認されている。電力システムについては、文献[4]で電圧無効電力制御問題への適用が報告されている。また、制御系設計システムについては、文献[5]で PID ゲインの最適化問題への適用が報告されている。更に、ニューラルネットワークについては、文献[6]で顔画像検出への適用が報告されて

いる。

PSO の代表的な情報交換形態として Gbest モデルと Lbest モデルがある。Gbest モデルは、群全体で発見した最良解を *gbest* として群全体で共有する PSO の最も基本的なモデルである。Gbest モデルでは、*gbest* が更新されると各 Particle は急速に *gbest* 付近に集まり更なる解の探索を行うため、解の収束は早い。一方、Lbest モデルは、群をいくつかのグループに分割し、それぞれのグループで発見した最良解を *lbest* としてグループ内で共有するモデルである。Lbest モデルでは、解の収束は遅いが、グループごとに互いに異なる範囲で探索が行えるため、大域的探索能力が高いとされている。

PSO の改良に関する研究としては以下のようなものがある。文献[7]では、PSO に GA の突然変異の概念を取り入れることで大域的な探索を実現した Evolutionary PSO (EPSO) が提案されている。文献[8]では、Particle をツリー状の階層に配置することで *gbest* への解の収束を遅らせる Hierarchical PSO (HPSO) が提案されている。文献[9]では、*gbest* の挙動に応じて探索性能を変化させる新型 PSO が提案されている。また、PSO の安定性解析に関する研究も多数行われている[10]。文献[11]では、PSO の安定性解析に基づき、PSO のパラメータを決定する Constriction Factor Method (CFM) が提案されている。これらの手法はいずれも群の共有情報が *gbest* のみであり、突然変異の概念、Particle の階層配置、パラメータの調整などを従来の PSO に加えることによって局所解に捕まりやすいという PSO の欠点を改善している。

本論文では、局所解に捕まりやすいという PSO の欠点を改善するため、Gbest モデルと Lbest モデルを組み合わせ、群の共有情報として *gbest* と *lbest* の 2 つを用いるハイブリッドな PSO アルゴリズムを提案する。具体的には、探索の初期は大域的探索能力が高い Lbest モデルを用いることによって探索の多様性を維持し、探索の終盤に Gbest モデルによる探索に切り替えることで探索の集中化を行う。また、大域的最適解付近を探索しているにもかかわらず、共有情報が更新されて局所解に捕まってしまうことを防ぐため、ある一定反復回数群の共有情報の更新を行わず、その付近を念入りに探索する方式を導入する。評価に際しては、ベンチマーク問題を用いて数値シミュレーション実験を行い、提案手法の有

†神奈川大学大学院工学研究科電気電子情報工学専攻, Graduate School of Electrical, Electronics and Information Engineering, Kanagawa University

効性について議論する。

本論文の構成は以下のとおりである。2.では、PSOの概要について簡単に紹介する。3.では、提案手法の詳細なアルゴリズムについて述べる。4.では、提案手法の有効性を評価するために行ったベンチマーク問題を用いたシミュレーション実験について説明し、従来手法及び提案手法の評価をする。5.では、本研究で得られた結論、及び今後の課題について述べる。

2. Particle Swarm Optimization (PSO)

2.1 最適化問題と PSO

本論文では、以下で定式化される n 次元の上下制限条件付最適化問題

$$\begin{aligned} \min_{\mathbf{x}} \quad & f(\mathbf{x}) \\ \text{subj. to} \quad & p_i \leq x_i \leq q_i, \quad i = 1, 2, \dots, n \end{aligned} \quad (1)$$

を考える。ここで、 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T \in R^n$ は決定変数、 $f(\mathbf{x}) : R^n \rightarrow R^1$ は目的関数とする。また、制約条件 $p_i \leq x_i \leq q_i$ は、探索領域・解候補の有限性を仮定するために、大域的最適解を含むように設定した条件である。この場合、式(1)は制約条件のない無制約問題と本質的に等価であることに注意されたい。

PSOは、式(1)のような非線形最適化を解くのに有効な手法である。PSOでは、目的関数値のみを用いて評価を行うため、勾配などの情報を利用せず、不連続関数や微分不可能関数にも適用可能である。

2.2 Gbest モデル

PSOの最も基本的なモデルはGbestモデルである。 n 次元の最適化問題において、群を形成する各Particle(探索点)はそれぞれ状態空間における現在の位置 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{ij}, \dots, x_{in})^T$ と速度 $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{ij}, \dots, v_{in})^T$ を持っている。ここで、 i はParticle番号、 x_{ij} 、 v_{ij} はそれぞれ i 番目のParticleの位置、速度の j 次元要素である。また、各Particleはこれまでの探索での自身の最良の位置情報 $\mathbf{pbest}_i = (pbest_{i1}, pbest_{i2}, \dots, pbest_{ij}, \dots, pbest_{in})^T$ とその評価値 $f(\mathbf{pbest}_i)$ を記憶している。更に、群全体で共有する最良の位置情報 $\mathbf{gbest} = (gbest_1, gbest_2, \dots, gbest_j, \dots, gbest_n)^T$ とその評価値 $f(\mathbf{gbest})$ を記憶している。Gbestモデルでは、各Particleが \mathbf{pbest}_i および \mathbf{gbest} を用いて速度を修正し、位置を更新していくことで、最適化したい目的関数の最適解を目指して状態空間の探索を行う。

各Particleは現在の位置 \mathbf{x}_i^k (k は反復回数)から、現在の速度 (\mathbf{v}_i^k)、自身が記憶している最良解へ向かうベクトル ($\mathbf{pbest}_i^k - \mathbf{x}_i^k$)、群全体で共有している最良解へ向かうベクトル ($\mathbf{gbest}^k - \mathbf{x}_i^k$) の重み付き線形結合として速度を更新 (\mathbf{v}_i^{k+1}) し、次の位置 \mathbf{x}_i^{k+1} に移動する(図1)。各Particleの速度と位置の更新式は以下の通りである。




図1: GbestモデルにおけるParticleの移動




図2: Gbestモデル

$$\mathbf{v}_i^{k+1} = w\mathbf{v}_i^k + c_1\text{rand}_1(\mathbf{pbest}_i^k - \mathbf{x}_i^k) + c_2\text{rand}_2(\mathbf{gbest}^k - \mathbf{x}_i^k) \quad (2)$$

$$\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1} \quad (3)$$

ここで、 w 、 c_1 、 c_2 はそれぞれの項に対する重みパラメータ、 rand_1 、 rand_2 は0~1の一樣乱数である。Gbestモデルの概念図を図2に示す。

一般的なPSO(Gbestモデル)のアルゴリズムを以下に示し、フローチャートを図3に示す。

Step 0. Particleの数 m 、重みパラメータ w 、 c_1 、 c_2 、および最大反復回数 T_{\max} を与え、 $k = 0$ とおく。

Step 1. 各Particleの初期位置 \mathbf{x}_i^0 と初期速度 \mathbf{v}_i^0 を与える。初期位置 \mathbf{x}_i^0 は実行可能領域内にランダムに与え、初期速度 \mathbf{v}_i^0 はランダムに与える。また、 $\mathbf{pbest}_i^0 = \mathbf{x}_i^0$ とおく。更に、 $\mathbf{gbest}^0 = \mathbf{pbest}_{i_g}^0$ とおく。ただし、 $i_g = \arg \min_i f(\mathbf{pbest}_i^0)$ である。

Step 2. 式(2)で速度 \mathbf{v}_i^k を更新し、式(3)で位置 \mathbf{x}_i^k を更新する。

Step 3. 各Particleの現在の評価値 $f(\mathbf{x}_i^{k+1})$ と過去の最良値 $f(\mathbf{pbest}_i^k)$ を比較し、 $f(\mathbf{x}_i^{k+1}) < f(\mathbf{pbest}_i^k)$ ならば $\mathbf{pbest}_i^{k+1} = \mathbf{x}_i^{k+1}$ 、そうでないならば $\mathbf{pbest}_i^{k+1} = \mathbf{pbest}_i^k$ とする。また、

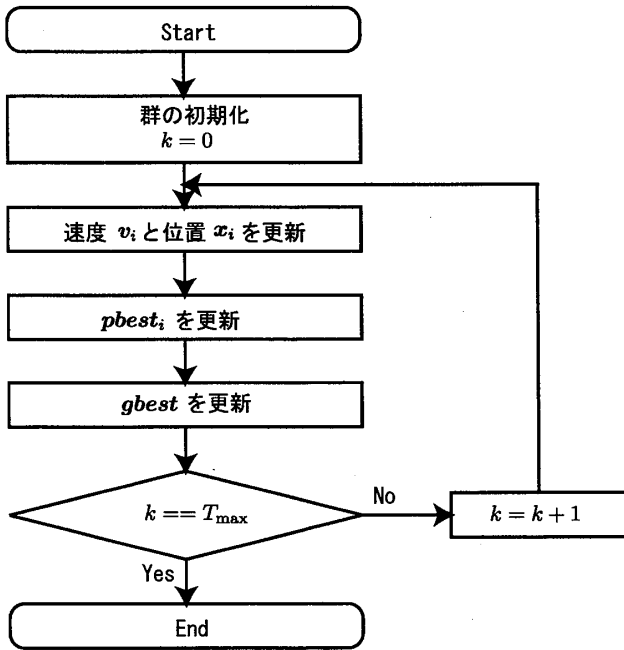


図 3: PSO (Gbest モデル) のフローチャート

$gbest^{k+1} = pbest_{i_g}^{k+1}$ とおく。ただし、 $i_g = \arg \min_i f(pbest_i^{k+1})$ である。

Step 4. 反復回数 k が最大反復回数 T_{max} に到達したならば、最適解を $gbest^{k+1}$ 、最適値を $f(gbest^{k+1})$ として終了。さもなければ、 $k = k + 1$ として Step 2. へ行く。

2.3 Lbest モデル

Lbest モデルは、式 (2) での $gbest$ の代わりに、自身と近傍の Particle から構成されるグループの中での最良の位置情報を $lbest$ として、群全体ではなくそのグループ内のみで情報を共有するモデルである。Lbest モデルでは、 $pbest_i$ および $lbest$ を用いて以下の式 (4) で速度を更新する。なお、位置の更新式は Gbest モデルと同じ式 (3) を用いる。

$$v_i^{k+1} = wv_i^k + c_1 \text{rand}_1(pbest_i^k - x_i^k) + c_2 \text{rand}_2(lbest^k - x_i^k) \quad (4)$$

Lbest モデルの概念図を図 4 に示す。Lbest モデルでは、Particle は群全体ではなく、グループを構成する少数の Particle 間のみで情報を共有することになる。また、各グループは互いに異なった領域を探索することになるが、各 Particle は重なり部分を持ってグループ化されるため、群全体での情報の共有が全くないわけではなく、最終的には $lbest$ の中で最良値 ($gbest$) に収束していく。そのため、Lbest モデルは Gbest モデルと比べて解の収束は遅くなるが、最適解を見つける可能性が高いとされている [12]。




図 4: Lbest モデル

2.4 群の活性度

メタヒューリスティクスにおいて探索性能の向上には探索過程における多様化・集中化がどの程度実現されているかを把握することが重要である。PSO における探索の状況を定量的に把握するための指標として群の活性度が提案されている [13]。群の活性度は、各 Particle が持つ速度の二乗平均として式 (5) により定義される。

$$Act^k = \sqrt{\frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (v_{ij}^k)^2} \quad (5)$$

ここで、 k は反復回数、 m は Particle の数、 n は問題の次元、 v_{ij}^k は k 回目の反復における i 番目の Particle の速度の j 次元要素 ($j = 1, 2, \dots, n$) である。群の活性度を用いると群全体の活動の状況を知ることができ、探索の発散 (活性度が大きいとき) や収束 (活性度が小さいとき) を判断することが可能となる。また、活性度が一定の範囲に収まっている場合は、各 Particle の速度が一定値となっていることを示しており、群の活性度で PSO の安定性を評価することも可能である。

3. 提案手法

本研究では、局所解に捕まりやすいという PSO の欠点を改善するため、Gbest モデルと Lbest モデルを組み合わせたハイブリッドな PSO アルゴリズムを提案する。探索の初期段階では、群をいくつかのグループに分割して探索を行う Lbest モデルを適用することによって大域的な探索を行い、探索の多様性を維持する。一方、PSO は「良い解同士は何らかの似通った構造を持っている」という Proximate Optimality Principle (POP) に基づいた最適化手法であり、最適解は局所解付近に存在する可能性が高いと考えられる。しかし、Lbest モデルでは局所的探索能力が低いため、最適解の発見精度が低いと考えられる。そこで、群の活性度を用いて探索の多様性を観測し、活性度が閾値 Act_{th} よりも小さくなった時点で Gbest モデルによる探索に切り替えることで探索の集中化を行い、最適解の発見精度向上を図る。更に、共有情報の最低反復回数 T_{stop} を導入し、群の共有情報が更新されてから T_{stop} までの間は共有情報の更なる更新を

行わず、最適候補付近を念入りに探索することで、大域的最適解付近を探索しているにもかかわらず、共有情報が更新されて局所的最適解(局所解)に捕まってしまうことを防ぐ。

提案手法のアルゴリズムを以下に示し、フローチャートを図5に示す。

Step 0. Particle の数 m , 重みパラメータ w, c_1, c_2 , 探索モデル切り替えのための活性度の閾値 Act_{th} , 共有情報の最低反復回数 T_{stop} , および最大反復回数 T_{max} を与え, $k = 0$ とおく。

Step 1. 群の初期化を行う。

1. 各 Particle の初期位置 x_i^0 と初期速度 v_i^0 を与える。初期位置 x_i^0 は実行可能領域内にランダムに与え, 初期速度 v_i^0 はランダムに与える。また, $pbest_i^0 = x_i^0$ とおく。
2. 自身と近傍の Particle から構成されるグループ内において $lbest^0 = pbest_{i_g}^0$ とおく。ただし, $i_g = \arg \min_i f(pbest_i^0)$ である。
3. $gbest^0 = pbest_{i_g}^0$ とおく。ただし, $i_g = \arg \min_i f(pbest_i^0)$ である。
4. 共有情報の最低反復回数 T_{stop} を設定する。

Step 2. 速度 v_i^k を更新する。式(5)で群の活性度 Act^k を算出し, $Act^k \geq Act_{th}$ ならば Lbest モデルの速度更新式(式(4))で更新し, $Act^k < Act_{th}$ ならば Gbest モデルの速度更新式(式(2))で更新する。

Step 3. 式(3)で位置 x_i^k を更新する。

Step 4. 各 Particle の現在の評価値 $f(x_i^{k+1})$ と過去の最良値 $f(pbest_i^k)$ を比較し, $f(x_i^{k+1}) < f(pbest_i^k)$ ならば $pbest_i^{k+1} = x_i^{k+1}$, そうでないならば $pbest_i^{k+1} = pbest_i^k$ とする。

Step 5. T_{stop} が 0 ならば共有情報の更新を行う。

1. 自身と近傍の Particle から構成されるグループ内において $lbest^{k+1} = pbest_{i_g}^{k+1}$ とおく。ただし, $i_g = \arg \min_i f(pbest_i^{k+1})$ である。
2. $gbest^{k+1} = pbest_{i_g}^{k+1}$ とおく。ただし, $i_g = \arg \min_i f(pbest_i^{k+1})$ である。
3. 共有情報の最低反復回数 T_{stop} を再設定する。

$T_{stop} > 0$ ならば共有情報の更新を行わず, T_{stop} を 1 減らす。

Step 6. 反復回数 k が最大反復回数 T_{max} に到達したならば, 最適解を $gbest^{k+1}$, 最適値を $f(gbest^{k+1})$ として終了。さもなければ, $k = k + 1$ として Step 2. へ行く。

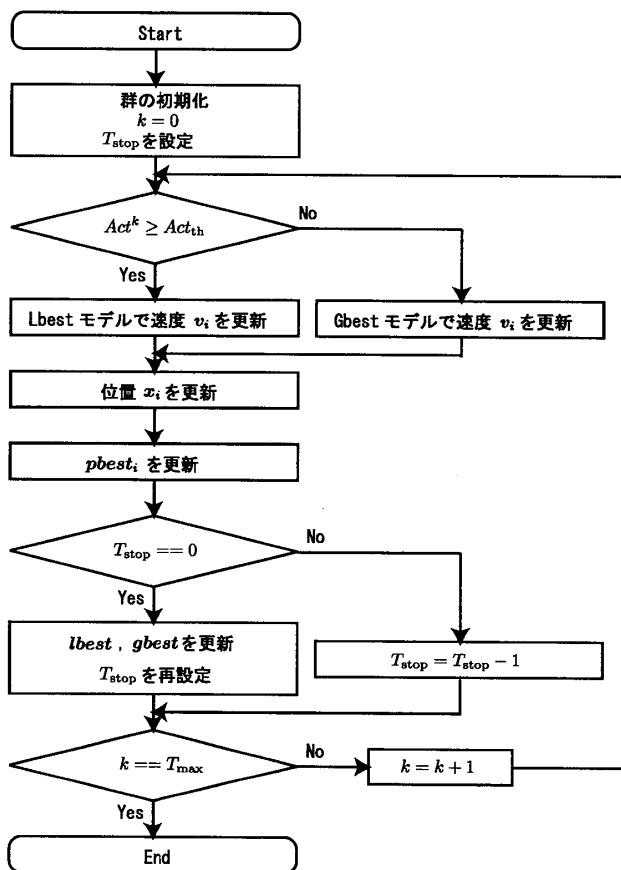


図5: 提案手法のフローチャート

4. シミュレーション実験

4.1 ベンチマーク問題

提案手法の有効性を確認するため、非線形最適化問題のベンチマーク問題を用いてシミュレーション実験を行った。今回シミュレーション実験に用いた関数は、大域的最適化手法の検証にしばしば利用される代表的なベンチマーク関数である以下の2つである (x^* は大域的最適解である) [1]。

a) 2^n minima 関数

$$\min_x f(x) = \sum_{i=1}^n (x_i^4 - 16x_i^2 + 5x_i) \quad (6)$$

subj. to $-5.0 \leq x_i \leq 5.0$
 $x^* = (-2.90, \dots, -2.90), f(x^*) = -78n$

b) Rastrigin 関数

$$\min_x f(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10) \quad (7)$$

subj. to $-5.0 \leq x_i \leq 5.0$
 $x^* = (0.0, \dots, 0.0), f(x^*) = 0.0$

式(6)の 2^n minima 関数は n 個の決定変数に対して 2^n 個の最適解を有し、決定変数間に依存を持たない多峰性

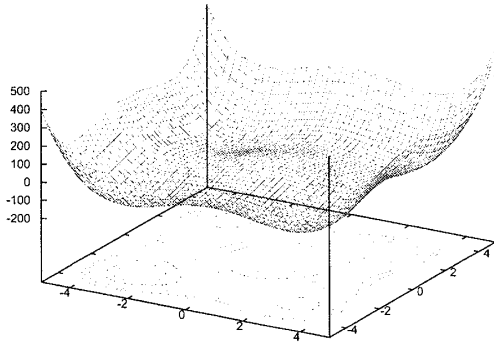


図 6: 2^n minima 関数




図 7: Rastrigin 関数

関数である。 $n = 2$ の場合の式 (6) の概形を図 6 に示す。この場合、式 (6) は原点の周辺に 4 つの最適解を持つ多峰性関数である。一方、式 (7) の Rastrigin 関数は格子状に多数の局所的最適解を持ち、決定変数間に依存関係を持たない多峰性関数である。 $n = 2$ の場合の式 (7) の概形を図 7 に示す。この場合、式 (7) は原点で最小値 0 (大域的最適解) をとり、その周辺に格子状に複数の局所的最適解を持つ多峰性関数である。

以下のシミュレーション実験では PSO の各種のパラメータ値は各手法共通で、Particle の数は $m = 20$ 、重みパラメータは文献 [11] の CFM に基づいて $w = 0.729$ 、 $c_1 = c_2 = 1.4955$ とした。これは、PSO のパラメータを弱い安定領域に設定する手法である。

4.2 実験 1

提案手法で導入したパラメータ Act_{th} 、 T_{stop} の有効性を確認するため、Gbest モデル、Lbest モデル、提案手法の各手法について $n = 10$ の場合の 2^n minima 関数に適用して比較を行った。提案手法については Gbest モデルと Lbest モデルの切り替えのみを行った手法 (提案手法 1: $Act_{th} = Act^0/4$, $T_{stop} = 0$)、Lbest モデルに T_{stop} を

表 1: シミュレーション結果 (実験 1)

Gbest モデル	平均値	-735.2585
	最良値	-783.3233
	最悪値	-641.9561
Lbest モデル	平均値	-749.9607
	最良値	-783.3233
	最悪値	-698.5030
提案手法 1	平均値	-750.3506
	最良値	-783.3233
	最悪値	-641.9561
提案手法 2	平均値	-747.6988
	最良値	-783.3233
	最悪値	-670.2296
提案手法 3	平均値	-762.5679
	最良値	-783.3233
	最悪値	-698.5030

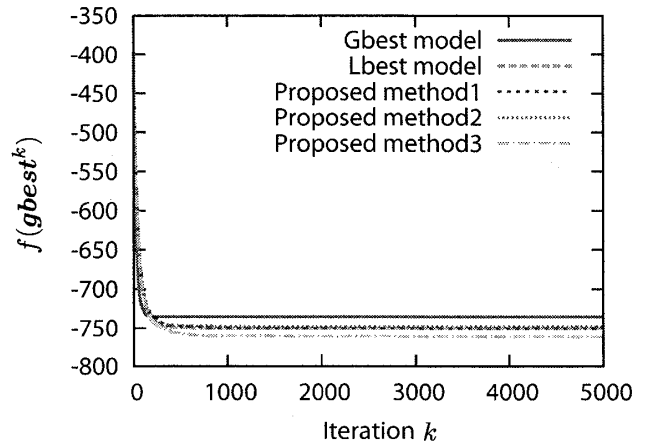



図 8: 最良値の推移 (2^n minima 関数, $n = 10$)

導入した手法 (提案手法 2: $Act_{th} = 0$, $T_{stop} = 10$)、その 2 つを用いた提案手法 (提案手法 3: $Act_{th} = Act^0/4$, $T_{stop} = 10$) の 3 つの手法で比較を行った。なお、 Act_{th} 、 T_{stop} の値については予備実験の結果から決定した。

5000 回探索 ($T_{max} = 5000$) を 100 回試行した場合のシミュレーション結果を表 1 に示す。なお、表中の太字は、5 つの手法の中で最も良い値を示している。また、最良値の推移と活性度の推移を、それぞれ図 8、図 9 に示す。

表 1 および図 8 より、 Act_{th} と T_{stop} の 2 つの改良点を用いた提案手法 3 は Gbest モデル、Lbest モデルと比較して高い探索能力を有していることが分かる。一方、Gbest モデルと Lbest モデルの切り替えのみを行った提案手法 1、Lbest モデルに T_{stop} を導入した提案手法 2 に関しては、Gbest モデルと比較すると良い結果が得られているが、Lbest モデルと比較すると同等の結果となっている。また、図 9 を見ると、提案手法 1~3 は Gbest

図 9: 活性度の推移 (2^n minima 関数, $n = 10$)

モデル, Lbest モデルと比較して群の活性度を最後まで維持していることが確認できる. 更に, 提案手法の中でも提案手法 3 が最も高い活性度を維持している. 以上より, Act_{th} と T_{stop} の 2 つの改良点を組み合わせることによる有効性が確認できる.



4.3 実験 2

次に, Gbest モデル, Lbest モデル, 提案手法 3 (以下, 提案手法とする) の 3 つの手法を $n = 30, 50$ の場合の 2^n minima 関数および $n = 10$ の場合の Rastrigin 関数に適用して比較を行った. 提案手法では予備実験の結果より, 2^n minima 関数の場合は $Act_{th} = Act^0/4$, $T_{stop} = 10$, Rastrigin 関数の場合 $Act_{th} = Act^0/5$, $T_{stop} = 10$ とした.

5000 回探索 ($T_{max} = 5000$) を 100 回試行した場合のシミュレーション結果を表 2 に示す. なお, 表中の太字は, それぞれのケースにおいて 3 つの手法の中で最も良い値を示している. また, 2^n minima 関数 ($n = 30, 50$) の場合の最良値の推移を, それぞれ図 10, 図 11 に示す. 同様に, 2^n minima 関数 ($n = 30, 50$) の場合の活性度の推移を, それぞれ図 12, 図 13 に示す. 更に, Rastrigin 関数 ($n = 10$) の場合の最良値の推移と活性度の推移を, それぞれ図 14, 図 15 に示す.

表 2 より, 提案手法は 2^n minima 関数 ($n = 30, 50$), Rastrigin 関数 ($n = 10$) の全ての場合において優れた結果が得られている. また, 図 12, 図 13 および図 15 を見ると, 提案手法は 2^n minima 関数, Rastrigin 関数のどちらの場合においても Gbest モデル, Lbest モデルと比較して群の活性度を最後まで維持していることが確認できる. これは, 提案手法が活性度がある程度小さくなるまでは Lbest モデルを用いてグループごとに異なる範囲を探索することで, 探索の多様性が長く維持されているためと考えられる.

一方, 図 10, 図 11 および図 14 を見ると, 提案手法は Gbest モデルと比較すると解の収束が遅くなってしまっ

図 10: 最良値の推移 (2^n minima 関数, $n = 30$)図 11: 最良値の推移 (2^n minima 関数, $n = 50$)

ている. これは, 提案手法が探索の初期段階で収束性の悪い Lbest モデルを用いていると共に, T_{stop} を導入して解の収束を遅らせているためと考えられる. しかし, Lbest モデルと比較すると解の収束性に大きな差は見られない. これは, 提案手法では探索の終盤で Lbest モデルによる探索から Gbest モデルによる探索に切り替えて探索の集中化を図ったことによって, 探索の終盤での解の収束性を高めたためと考えられる.

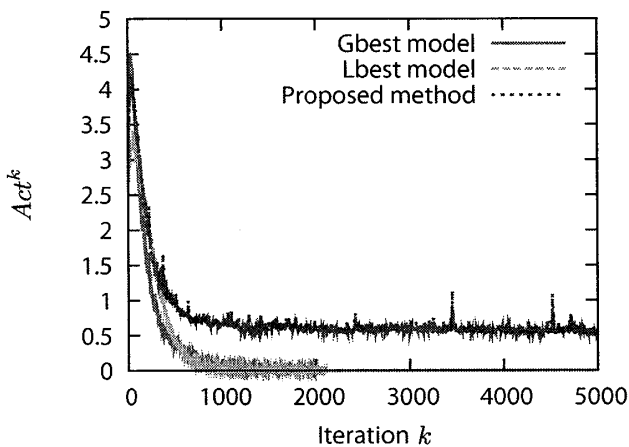

以上より提案手法についてまとめると, 探索の初期段階では Lbest モデルを用いて各 Particle が一部に集中して探索を行うことなく分散して大域的な探索を行い, 探索の終盤では Gbest モデルを用いて局所的探索を行うことで解の収束性を高めており, 探索の多様化と集中化の融合を実現することで, 大域的最適解の発見精度の向上を実現していると考えられる.

5. おわりに

本論文では, 局所解に捕まりやすいという PSO の欠点を改善するため, Gbest モデルと Lbest モデルを組み

表 2: シミュレーション結果 (実験 2)

		2^n minima		Rastrigin
		$n = 30$	$n = 50$	$n = 10$
Gbest モデル	平均値	-2046.5960	-3346.3406	8.9745
	最良値	-2208.6028	-3633.8822	1.9899
	最悪値	-1869.3215	-3011.8665	26.8639
Lbest モデル	平均値	-2057.0478	-3356.5198	7.7748
	最良値	-2236.8762	-3633.8822	0.9950
	最悪値	-1841.0480	-3096.6869	39.5371
提案手法	平均値	-2057.1757	-3372.3003	6.3008
	最良値	-2264.3224	-3657.5843	4.2763E - 10
	最悪値	-1873.0771	-3115.5613	19.7182

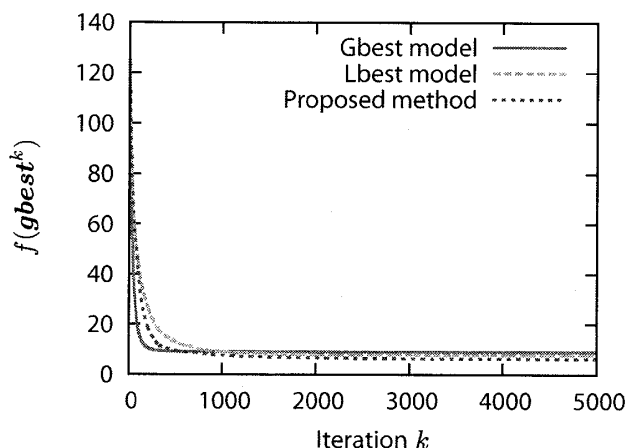

図 12: 活性度の推移 (2^n minima 関数, $n = 30$)図 13: 活性度の推移 (2^n minima 関数, $n = 50$)

合わせ、探索の初期は大域的探索能力が高い Lbest モデルを用いることによって探索の多様性を維持し、探索の終盤で Gbest モデルに切り替えることで探索の集中化を行うハイブリッドな手法を提案した。ベンチマーク問題を用いたシミュレーション実験の結果より、提案手法は Gbest モデル、Lbest モデルと比較して優れた探索能力を有していることが確認できた。また、本論文では、PSO の重みパラメータは文献 [11] の CFM に基づいて設定したが、PSO のパラメータ設定に関しては様々な研究が行われており、CFM 以外の代表的な研究としては以下のものが挙げられる [14]。

1. Random Inertia Weight Method (RIWM) : $c_1 = c_2 = 1.4955$ とし、 w は $0.5 \leq w \leq 1.0$ の間でイテレーションごとにランダムに決定する手法。
2. Linearly Decreasing Inertia Weight Method (LDIWM) : $c_1 = c_2 = 2.0$ とし、 w はイテレーションの増加につれて $w = 0.9$ から $w = 0.4$ へ線形に減少させる手法。
3. Linearly Decreasing Vmax Method (LDVM) : Par-

ticle に速度上限 V_{\max} を設定し、 V_{\max} をイテレーションの増加に伴って線形に減少させる手法。

これらは全てパラメータの調整を行った手法であり、共有情報の情報交換形態には関係しないため、提案手法はこれらの手法においても適用可能であると考えられる。今後の課題としては、まず提案手法で新たに導入したパラメータである Act_{th} 、 T_{stop} の最適化が挙げられる。今回のシミュレーション実験では T_{stop} は探索全体を通して一定値としたが、Gbest モデルに切り替えた後の局所的探索においては T_{stop} の影響によって **gbest** が更新できず、大域的最適解の発見精度が抑えられている可能性がある。そこで、 T_{stop} を一定値とするのではなく、イテレーションの増加に伴って減少させることで、大域的最適解発見精度と解の収束性の更なる向上が期待できると考えられる。また、探索モデル切り替えのための活性度の閾値である Act_{th} についても、今回のシミュレーション実験では Act^0 を用いて設定したが、 Act^0 はランダムに決定した初期速度 v_i^0 を基に算出される値である。活性度の推移に関する結果を見ると、探索開始直後の活性度は不安定な状態であることが分かるため、 Act_{th} に

図 14: 最良値の推移 (Rastrigin 関数, $n = 10$)図 15: 活性度の推移 (Rastrigin 関数, $n = 10$)

Act^0 を用いることが適切であるかどうかについては今後検討する必要があると考えられる。この他、様々なベンチマーク問題での評価、実システムでの有効性の検証などを行っていく。

参考文献

- [1] 相吉英太郎, 安田恵一郎: メタヒューリスティクスと応用, 電気学会 (2007).
- [2] Kennedy, J. and Eberhart, R.: Particle Swarm Optimization, *Proc. of The 1995 IEEE International Conference on Neural Networks*, Vol. 4, pp. 1942–1948 (1995).
- [3] Kennedy, J. and Eberhart, R.: *Swarm Intelligence*, Morgan Kaufmann (2001).
- [4] Yoshida, H., Kawata, K., Fukuyama, Y., Takayama, S. and Nakanishi, Y.: A Particle Swarm Optimization for Reactive Power and Voltage Control Considering Voltage Security Assessment, *IEEE Transactions on Power Systems*, Vol. 15, No. 4, pp. 1232–1239 (2000).
- [5] Gaing, Z. L.: A Particle Swarm Optimization Approach for Optimum Design of PID Controller in AVR System, *IEEE Transactions on Energy Conversion*, Vol. 19, No. 2, pp. 384–391 (2004).
- [6] Sugisaka, M. and Fan, X.: An Effective Search Method for Neural Network Based Face Detection Using Particle Swarm Optimization, *IEICE Transactions on Information and Systems*, Vol. E88–D, No. 2, pp. 214–222 (2005).
- [7] Miranda, V. and Fonseca, N.: EPSO–Evolutionary Particle Swarm Optimization, a New Algorithm with Applications in Power Systems, *Proc. of IEEE/PES Transmission and Distribution Conference and Exhibition 2002*, Vol. 2, pp. 745–750 (2002).
- [8] Janson, S. and Middendorf, M.: A Hierarchical Particle Swarm Optimizer and Its Adaptive Variant, *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, Vol. 35, No. 6, pp. 1272–1282 (2005).
- [9] 増田和明, 栗原謙三: 全体最良解更新状況に応じた探索特性調節機構をもたせた新型 Particle Swarm Optimization モデル, 電気学会論文誌 C, Vol. 130, No. 4, pp. 573–579 (2010).
- [10] Clerc, M.: *Particle Swarm Optimization*, ISTE (2006).
- [11] Clerc, M. and Kennedy, J.: The Particle Swarm–Explosion, Stability, and Convergence in a Multidimensional Complex Space, *IEEE Transactions on Evolutionary Computation*, Vol. 6, No. 1, pp. 58–73 (2002).
- [12] Mendes, R., Kennedy, J. and Neves, J.: The Fully Informed Particle Swarm: Simpler, Maybe Better, *IEEE Transactions on Evolutionary Computation*, Vol. 8, No. 4, pp. 204–210 (2004).
- [13] Iwasaki, N., Yasuda, K. and Ueno, G.: Particle Swarm Optimization: Dynamic Parameter Adjustment Using Swarm Activity, *Proc. of The 2008 IEEE International Conference on Systems, Man and Cybernetics*, pp. 2634–2639 (2008).
- [14] 石亀篤司, 安田恵一郎: 群の知能: Particle Swarm Optimization, 知能と情報, Vol. 20, No. 6, pp. 829–839 (2008).