

Ant Colony Optimizationに関する基礎的研究

BASIC RESERCH ON ANT COLONY OPTIMIZATION

阿部淳一^{*}，杉本博之^{**}

Junichi ABE & Hiroyuki SUGIMOTO

^{*}工修 北海学園大学大学院 工学研究科建設工学専攻（〒064-0926 札幌市中央区南 26 条西 11 丁目）

^{**}工博 北海学園大学教授 工学部社会環境工学科（同上）

Ant Colony Optimization (abbreviated as ACO after) is studied. Ant colony seeks their food exchanging the information with other ants by setting the pheromone on the routes. ACO is an optimization technique applying this mass action of ant colony. Generally ACO has been applied to the scheduling problem like Traveling Salesman Problem. In this paper, it is tried to apply ACO to structural optimization problem (combinatorial problem). For this purpose, several numerical techniques are proposed and the proposed method is applied to the simple problem of structural design successfully.

Key Words: ant colony optimization, swarm intelligence, structural optimization

1. まえがき

虫や鳥などは、単体としては単純な行動原理に従っているが、群れを成すと時として効率的な行動をとることがある。このような虫や鳥などの群行動のパターンは、群知能（Swarm Intelligence）¹⁾としてモデル化される。その研究の一つに、蟻の群衆が餌を探す行動をモデル化し、最適化手法に取り入れたAnt Colony Optimization（以下、ACO）がある²⁾。

蟻の群衆が餌を探し巣に持ち帰る時、最初はランダムに行動するが、やがて餌と巣の最短経路を発見し行列を作る。この時、他の蟻との情報交換の手段としてフェロモンを使用する。蟻は通過した経路にフェロモンを分泌し、餌と巣の経路が短いほど多くのフェロモンを分泌する。フェロモンが多い箇所に蟻が集まり、そして多くの蟻が選択した経路にフェロモンが多く分泌される。ACOはこのような群集行動を最適化に取り入れたものである。

ACOは、これまで多くの研究がされているが、基本となるのは、Dorigoらによって提案された、Ant System（以下、AS）²⁾である。このASは巡回セールスマン問題（以下、TSP）³⁾を解くための手法として提案されている。

一方、群知能を構造最適設計に応用した例としては、北山らがParticle Swarm Optimization（以下、PSO）を用いて研究し発表されている⁴⁾。ここではPSOを圧力器の最適設計問題に適用し、良好な結果が得られている。しかし、同じ群知能を最適化手法に取り入れたACOを用いて、構造最適設計に応用した例は現状では無いと考えられる。

そこで本論文では、構造最適設計へのACOの拡張を行い、いくつかの数値計算を行う。そして計算結果から得られる考察を基に、いくつかの改良を加え検討を行う。

2. ACOの概要

ACOは、餌を探す時の蟻の群行動をモデルとした最適化手法である。蟻は他の蟻との情報交換としてフェロモンを使用し、フェロモンを基に次に行くための経路を決定する。そして決定した経路にフェロモンを付着する。このフェロモンを数値モデル化し、経路の決定を確率的な方法でモデル化することにより、最適化手法に取り入れたものがACOである。ここでは、ACOのアルゴリズムと、確率的な経路の選択方法、フェロモンの数値モデル化について、ACOの基本となるASを基に説明する。

(1) ACOのアルゴリズム

ACOのフローチャートを図-1に示す。図の各STEPについて以下で説明する。本論文では以降、蟻をエージェントと表記する。

STEP1：初期フェロモン情報を全ての経路に付与し、各エージェントの初期位置をランダムに配置する。

STEP2：各エージェントがフェロモン情報とヒューリスティック情報から確率的に経路を選択する。

STEP3：STEP2において各エージェントが選択した経路の集合（巡回路）の総距離を算定する。

STEP4：STEP3の巡回路の総距離を基に、巡回路の各経路にフェロモン情報を付着させる。同時に全ての経路に付着されているフェロモンが一定量蒸発する。

STEP5：探索回数が最大回数以下ならSTEP2に戻る。最大回数を満足していれば、終了となる。

ACOのアルゴリズムは上述のように簡単なものであり、必要とするのは確率的な経路の選択方法、ヒューリス

ティック情報，フェロモン情報になる．以下に，これらを具体的に説明する．

(2) 確率的な経路の選択方法

ACOによる確率的な経路選択は，経路に蓄積されているフェロモン情報と，ヒューリスティック情報から決定される． k 番目のエージェントが i から j にいく経路を選択する確率 P_{ij}^k は，以下の式により算定される．

$$P_{ij}^k(t) = \frac{\tau_{ij}(t)^\alpha \cdot \eta_{ij}^\beta}{\sum_{l \in C} \tau_{ij}(t)^\alpha \cdot \eta_{ij}^\beta} \quad (1)$$

ここで， $\tau_{ij}(t)$ はフェロモン情報， t は時間， η_{ij} はヒューリスティック情報， α はフェロモン情報に対する乗数， β はヒューリスティック情報に対する乗数， C は i から経路を選択することが可能な経路の集合である．

(3) ヒューリスティック情報

ヒューリスティック情報 η_{ij} は，一般的には経路の距離の逆数を使用する．よって， η_{ij} は経路の距離を d_{ij} とすると，以下の式で定義される

$$\eta_{ij} = \frac{1}{d_{ij}} \quad (2)$$

ヒューリスティック情報は，エージェントが経路を選択する時，巡回路の総距離に関係無く，一つ先のより短い経路を選択しようとする情報となる．

(4) フェロモン情報

フェロモン情報は経路に蓄積される情報で，エージェントが選択した巡回路の各経路に付着させる．この時，巡回路の総距離が短いほど，フェロモン情報の値は高くなる．また付着したフェロモン情報は時間の経過に伴い減少する．ACOにおけるフェロモン情報の特徴は，このような時間的な変化を考慮している点である．

ある時間 t における経路 $(i-j)$ の経路に蓄積されているフェロモン情報 $\tau_{ij}(t)$ は， $t+1$ において ρ の割合で蒸発する．そして新たに全てのエージェントによって追加されるとする．つまり， $t+1$ におけるフェロモン情報 $\tau_{ij}(t+1)$ は以下の式より算定される．


$$\tau_{ij}(t+1) = (1-\rho) \cdot \tau_{ij}(t) + \sum_{k=1}^n \Delta \tau_{ij}^k(t) \quad (3)$$

ここで， n はエージェント数， $\Delta \tau_{ij}^k(t)$ は k 番目のエージェントにより追加されるフェロモン情報である．追加されるフェロモン情報は，巡回路の総距離が短いほど高い値とする．そのため，エージェントが選択した巡回路の総距離から，追加されるフェロモン情報は以下の式より算定される．


$$\Delta \tau_{ij}^k(t) = \frac{1}{L^k} \quad (4)$$

ここで， L^k は k 番目のエージェントによって選択された巡回路の総距離である．


フェロモン情報が時間的に蒸発することにより，最近



図－1 ACOのフローチャート



図－2 タイプ I



図－3 タイプ II

の行動を重視し局所解に陥ることを回避し，大域的な解の探索を可能にする．

3. 組み合わせ問題への応用

ACOによる最適化は，エージェントが通る経路にフェロモンを付着させ，そのフェロモンを基に最適化を行う．2. に示したACOのアルゴリズムはTSPを前提とし，各都市を結ぶ経路にフェロモンを置くことで最適化を行った．しかし，一般的な組み合わせ問題の場合には経路という概念は存在しない．そのため，本研究では設計変数間の各組み合わせを経路と考え，一般的な組み合わせ問題へACOの適用を試みた．本研究ではこの一般的な組み合わせ問題へのACOの適用を，2つの方法で検討を試みた．

(1) 直列的選択方法

本提案の1つは，仮想の始点から設計変数を順番に選択することにより，直列に巡回路を構成する方法である．この方法の概念図を x_1, x_2 の2変数問題を例に図－2に示す． x_1 の候補値の数を n_1 ， x_2 の候補値の数を n_2 とする．仮想の始点を設定し，まず x_1 を選択するための経路が n_1 存在する．さらに x_1 から x_2 を選択するための経路が $n_1 \times n_2$ 存在することになる．仮想の始点から x_1, x_2 をそれぞれ選択し巡回路を生成することは，1設計解を選択したことになる．以降，これをタイプ I とする．

(2) 並列的選択方法

本提案の2つめは、仮想の始点を中心に、各設計変数を個々に選択し、巡回路を構成する方法である。この方法の概念図を図-1と同様に2変数問題を例に図-3に示す。仮想の始点を中心に設定し、まず x_1 を選択するための経路が n_1 存在する。同様に始点から x_2 を選択するための経路が n_2 存在する。 x_1, x_2 を選択して仮想の始点を中心に巡回路を生成する。以降、これをタイプIIとする。

(3) フェロモン情報の定式化

2. で示したように、ACOはフェロモン情報とヒューリスティック情報から式(1)により確率的に経路の選択を行う。ASにおけるフェロモン情報は、巡回路の総距離の逆数としている。これは、一般的な組み合わせ問題において、1設計解の評価関数に対応していると考えられる。そこで本研究では、フェロモン情報は目的関数値を用いることとした。つまり本論文では、制約条件付き問題を前提とし、式(4)を以下の式に置き換えた。

$$\Delta \tau_{ij}^k(t) = \frac{Q}{F^k} \quad (5)$$

ここで、 F^k は k 番目のエージェントのペナルティー関数を用いて無制約化した目的関数値である。また、ペナルティー関数 F^k は以下の式により与えられる。

$$F^k = OBJ^k \left\{ 1 + \gamma \sum_{j=1}^m (\max(g_j^k, 0)) \right\} \quad (6)$$

ここで、 OBJ^k は k 番目のエージェントによる設計解の目的関数値、 γ はペナルティー係数、 m は制約条件の数、 g_j^k は k 番目のエージェントによる設計解の j 番目の制約条件値である。

(4) ヒューリスティック情報の定式化

前節に示したヒューリスティック情報は、式(4)より経路の距離の逆数としている。つまり、確率的に解を選択する時、エージェントが1設計解である巡回路の総距離に関係無く、一つ先の短い経路を選択しようとする情報である。これは、一般的な組み合わせ問題においては、より小さい設計変数を選択するための情報に対応すると考えた。よって本研究ではヒューリスティック情報は、設計変数の値の逆数を用いることとした。しかし、設計変数の値を直接ヒューリスティック情報に用いた場合、設計空間によって値が大きく異なる。そのため、本研究ではヒューリスティック情報に代入する設計変数を以下の式で線形変換を行った。

$$z_{ij} = \frac{0.9}{x_{j\max} - x_{j\min}} (x_{ij} - x_{j\min}) + 0.1 \quad (7)$$

ここで、 z_{ij} は設計変数 j の変換した設計変数、 $x_{j\max}$ は設計変数 j の最大値、 $x_{j\min}$ は設計変数 j の最小値である。式

(7)によって設計変数は最小値を0.1、最大値を1.0として線形変換される。設計変数を線形変換した式(7)より、式(2)は以下の式となる。




図-4 最適設計問題




図-5 設計空間

$$\eta_{ij} = \frac{1}{z_{ij}} \quad (8)$$

一般的にこのような線形変換を行う場合、0.0~1.0とするのが妥当である。しかし、 z_{ij} の最小値を0とすると式(8)より、0で割ることによる数値計算上の不具合が生じるため、最小値を0.1とした。

4. 構造最適設計問題

3. に示した構造最適設計問題に拡張したACOを用いて、ここでは簡単な構造最適設計問題に応用を試みる。以下に本研究が対象とした設計問題について具体的に説明をする。

対象としたのは図-4に示すようなクロスバーの最適設計問題である。図中の A_i は i 部材の断面積、 q_i は i 部材の分布荷重、 P は集中荷重、 l_i は i 部材のスパン長である。設計変数は A_1, A_2 の2変数で離散量として扱う。目的関数は構造全体の総容積、制約条件は各部材の最大応力が許容応力以下とする。以下に目的関数、制約条件式を示す。

$$OBJ = \sum_{i=1}^2 A_i l_i \quad (9)$$

$$g_j = \frac{|\sigma_{imax}|}{20} - 1 \leq 0 \quad (j=1 \sim 2) \quad (10)$$

ここで、 σ_{imax} は最大応力である。

設計変数 A_1 、及び A_2 の候補値を1~32とし、設計条件を $l_1=100, l_2=120, q_1=q_2=1.0, p=0.0$ とした場合の設計空間を図-5に示す。図中の線は許容領域と非許容領域の境界

線, ●は局所解である。局所解は3点あり, 設計変数を (A_1, A_2) と表すと, $(6, 26)$, $(13, 19)$, $(24, 8)$ である。このうち大域的最適解は $(24, 8)$ で, 目的関数値は3360である⁵⁾。

5. 数値計算例

ここでは, 4. の構造最適設計問題に対して, 3. に示した2タイプの方法を用い数値解析を行った結果について示す。

(1) タイプ別の計算結果

各タイプの計算結果について示す。検討のため, 5種類のランダムシーズを用いて計算を試みた。ACOのパラメータは $\alpha=1.0$, $\beta=1.0$, $\rho=0.5$ とした。エージェントの数 (n) を5~30まで5ずつ増加させた場合の設計結果を表-1, 2に示す。表中の数字は目的関数と設計変数を表している。また図-6には, 各エージェント数において得られた目的関数値の平均値を示す。タイプIとタイプIIを比較すると, エージェント数が比較的少ない $n=5\sim15$ ではタイプIIによる手法が良好な結果を示している。一方, エージェント数が比較的多い $n=20\sim30$ では両タイプの目的関数の差は小さく, 同程度の性能であると考えられる。

以上の結果は, 各タイプのフェロモン情報の違いによると本研究では考えた。フェロモン情報は2. に示したように, 経路に付着される。タイプIの場合, 仮定の始点からA1を選択するために32の経路があり, A1からA2を選択するための経路が $32 \times 32 = 1024$ あるため, 計1056経路となる。一方タイプIIの場合, 仮定の始点からそれぞれ A_1, A_2 を選択するため, $32+32=64$ 経路となる。

タイプIでは1056の経路に対してフェロモン情報を付着しなければならないため, エージェント数が少ない場合には全経路に対するフェロモン情報の付着領域が少なく, 良好な結果を得ることができなかったと考えられる。一方タイプIIでは64経路であるため, エージェント数が少なくとも全経路に対するフェロモン情報の付着領域がタイプIに比べ広範囲となる。そのため, タイプIに比べ良好な結果が得られていたと考えられる。これらの結果から, タイプIIによる経路選択が比較的良好であると考えられる。しかし, 表-1, 2における最適設計解の設計変数からも明白であるが, 両手法において安定的に大域的最適解の探索を行うには, 多くのエージェント数が必要であり, これは多くの解析回数を必要とすることである。そこで次に, エージェント数が少なくても良解が得られるように, いくつかの改良を加える。

(2) フェロモン情報の範囲付着

前節の考察から, ACOによる良質な解の選択は, 全経路に対するフェロモン情報の付着領域を多くすることであると考えられる。そこで, 各エージェントに対して広範囲にフェロモン情報を付着させることを考えた。これまでの方法では, エージェントが選択した経路のみに

表-1 タイプI最適設計結果

ランダムシーズ	エージェント数					
	5	10	15	20	25	30
1	3454	3454	3454	3393	3393	3360
	(23, 7)	(23, 7)	(23, 7)	(23, 8)	(23, 8)	(24, 8)
2	3454	3424	3424	3424	3424	3424
	(23, 7)	(23, 9)	(23, 9)	(23, 9)	(23, 9)	(23, 9)
3	3770	3720	3680	3393	3360	3360
	(22, 12)	(6, 26)	(14, 19)	(23, 8)	(24, 8)	(24, 8)
4	3393	3393	3393	3393	3393	3393
	(23, 8)	(23, 8)	(23, 8)	(23, 8)	(23, 8)	(23, 8)
5	3800	3500	3393	3393	3393	3393
	(22, 8)	(23, 10)	(23, 8)	(23, 8)	(23, 8)	(23, 8)
平均	3574	3498	3469	3399	3393	3386

表-2 タイプII最適設計結果

ランダムシーズ	エージェント数					
	5	10	15	20	25	30
1	3454	3454	3454	3393	3393	3360
	(23, 7)	(23, 7)	(23, 7)	(23, 8)	(23, 8)	(24, 8)
2	3424	3424	3424	3424	3424	3360
	(23, 9)	(23, 9)	(23, 9)	(23, 9)	(23, 9)	(24, 8)
3	3715	3720	3360	3360	3360	3360
	(7, 25)	(6, 26)	(24, 8)	(24, 8)	(24, 8)	(24, 8)
4	3393	3393	3393	3393	3393	3360
	(23, 8)	(23, 8)	(23, 8)	(23, 8)	(23, 8)	(24, 8)
5	3580	3424	3393	3393	3393	3393
	(13, 19)	(23, 9)	(23, 8)	(23, 8)	(23, 8)	(23, 8)
平均	3513	3483	3405	3393	3393	3367




図-6 目的関数比較

フェロモン情報を付着したが, 本研究ではエージェントが選択した経路とその周辺の経路に対してもフェロモン情報を付着させる。ここで, 周辺の経路とは経路 $(i-j)$ を2次元の座標系 (i, j) に置き換える。そして, エージェントが選択した経路の座標系 (i_c, j_c) との距離を算定し, 一定の範囲 ϕ_L 以下であれば, これを周辺の経路と考える。フェロモンの範囲付着は, 選択した経路から一定の範囲 ϕ_L に対して正規分布的に減少したフェロモンを付着することを考える。つまり, k 番目のエージェントが付着するフェロモン情報を以下の式で与える。

$$\Delta \tau_{ij}^k(t) = \begin{cases} \frac{Q}{F^k} \cdot \exp\left(-\frac{\phi_{ij}}{\phi_L}\right) & \text{if } (\phi_L - \phi_{ij}) \geq 0 \\ 0 & \text{if } (\phi_L - \phi_{ij}) < 0 \end{cases} \quad (11)$$

ここで、 ϕ_{ij} は経路(i-j)とエージェントが選択した経路($i_c - j_c$)を2次元の座標系に変換して求めた距離で、以下の式から算定する。

$$\phi_{ij} = \sqrt{(i - i_c)^2 + (j - j_c)^2} \quad (12)$$

(3) 範囲付着効果の検討

ここでは、上記に示したフェロモン情報の範囲付着を行った場合の計算結果について示す。n=5, $\sigma=5$ とし、5種類のランダムシーズで計算した結果を表-3に示す。範囲付着を行った場合、前節の範囲付着を行わない場合の平均目的関数と比べ、両タイプでn=15~25における設計解と同程度の効果が得られたと考えられる。設計変数は、タイプIでは大域的最適解を2つのランダムシーズで算定し、その他のランダムシーズ大域的最適解周辺を算定している。一方、タイプIIでは1つのランダムシーズで大域的最適解を算定し、3つのランダムシーズで大域的最適解周辺を算定しているが、ランダムシーズ5では局所解に陥っている。これらの結果から、より範囲付着の効果が大きいのはタイプIである。これは、前節に示したように、タイプIIに比べフェロモン情報が細分化されているタイプIに対して、広範囲にフェロモン情報を付着できたためであると考えられる。

次に解の収束性を確認するため、タイプIにおいて大域的最適解を算定したランダムシーズ3の目的関数の推移を図-8に示す。図は太線が目的関数の推移で、細線が大域的最適解である目的関数3360の線である。繰り返し回数をtとすると、最初に大域的最適解を算定したのは、t=36であった。その後、t=38で大域的最適解を算定したが以降算定されず、目的関数が4000程度で収束したと考えられる。そこで、最初に大域的最適解を算定したt=36、次に大域的最適解を算定したt=38、最大繰り返し回数であるt=100、t=36とt=100の間になると考えられるt=70のフェロモン濃度について検討を行う。

図-9に各繰り返し回数のフェロモン濃度を示す。各繰り返し回数の図は、上が仮定の始点からA₁を選択するためのフェロモン濃度、下がA₁からA₂を選択するためのフェロモン濃度である。A₁からA₂を選択するためのフェロモン濃度は横軸にA₁、縦軸にA₂とした。図は色が黒に近づくほど、フェロモン情報が高い箇所となる。図を比較すると、t=36のフェロモン濃度は、大域的最適解である(24,8)付近が最も高くなっている。同様に、t=38でも大域的最適解付近が高くなっている。一方、t=70のフェロモン濃度は、局所解である(13,19)付近が最も高くなり、繰り返し回数が多くなるとエージェントがこれまで算定してきた最良解に対して解を探索していないことが確認できる。

エージェントの解の探索は、式(2)により確率的に決定される。この時、フェロモン情報は、良い設計解ほど高い値となる。一方、ヒューリスティック情報は解の

表-3 範囲付着結果

ランダムシーズ	タイプI		タイプII	
1	3424	(23, 9)	3393	(23, 8)
2	3560	(26, 8)	3393	(23, 8)
3	3360	(24, 8)	3360	(24, 8)
4	3360	(24, 8)	3393	(23, 8)
5	3393	(23, 8)	3580	(13,19)
平均	3419	—	3424	—




図-8 目的関数の推移




図-9 フェロモン濃度

良し悪しに関わらず、各設計変数が小さくなるほど高い値となる。繰り返し回数が少ない場合は、広範囲にフェロモン情報が分泌されているため、各エージェントが大域的に探索を行う。さらにヒューリスティック情報からより設計変数の小さい設計解を探索しようとするため、結果的に大域的な探索能力と局所的な探索能力のバランスを保ち、良質な解の探索を行うことになる。しかし、比較的良質な解が得られると、解付近のフェロモン情報

が高くなり、ここに各エージェントが集中することになる。これにより大域的な探索能力を失い、各エージェントは局所的に設計変数の小さい設計解の探索をするため、徐々に最良解に対して設計解の探索を行わず、収束性が悪くなったと考えられる。そこで、これまでの探索において得られた最良解のフェロモン情報を、最良解が更新されない限り蒸発させないモデルを考えた。このモデルをタイプⅢとした。次節にタイプⅢによる計算結果について示す。

(4) タイプⅢの計算結果

タイプⅢを用いて行った計算結果を示す。図-9にタイプⅠ、及びタイプⅢの目的関数の推移を示す。図中の灰色の実線がタイプⅠ、黒の実線がタイプⅢ、細い実線が大域的最適解(3360)である。タイプⅡでは大域的最適解を2回算定し、その後目的関数が4000程度の箇所まで収束したのに比べ、タイプⅢでは $n=15$ で最初に大域的最適解を算定し、その後も連続して大域的最適解を算定できている。また、前述したようにタイプⅢでは、 $n=15$ で最初に大域的最適解を算定している。タイプⅡで最初に大域的最適解を算定したのは、 $n=54$ であったことから、タイプⅢは解の収束性だけでなく、解の探索過程においても良好な結果を得ることができたと考えられる。

6. まとめ

蟻の集団行動を基にした最適化手法であるACOを、構造最適設計に応用するための手法を提案した。その上で、簡単な構造最適設計問題を例にし、数値計算的な考察を試みた。さらに数値計算の結果から、本手法に対していくつかの改良を加えて検討を行った。以下に、本文により得られた結果を箇条書きで示す。

(1) ACOの基本はTSPを解くための手法である。各エージェントが、都市と都市を結ぶ経路にフェロモン情報を付着し、このフェロモン情報を基に最適解の探索を行う。そのため、ACOを用いて構造最適設計を行う場合、経路という概念が存在しないため、直接応用することはできない。そこで、仮想の出発点を構築し、各設計変数の組み合わせを経路と考えた。これにより、一設計解を選択することは、TSPにおける一巡回路を選択したことに置き換えられる。

(2) (1)の概念のもとで、2種類の巡回路構築方法を提案した。1つは仮想の出発点から1つめの設計変数を選択し、選択した設計変数から2つめの設計変数を選択する。このような作業を設計変数の数だけ繰り返す、直列的な解の構築方法である。これをタイプⅠとした。もう1つの概念は、仮想の出発点から全ての設計変数の選択する、並列的な解の構築方法である。これをタイプⅡとした。

(3) タイプⅠ、タイプⅡの方法を、クロスバーの最適設計問題に応用を試みた。5種類のランダムサイズと6種




図-9 タイプⅢ目的関数の推移

類のエージェント数で検討した結果、エージェント数が比較的多い場合には良好な結果が得られたが、少ないエージェント数では局所解に陥るなど、良い結果は得られなかった。

(4) 少ないエージェント数でも良解を求められるように、改良を行った。ACOではエージェントが選択した経路にのみフェロモン情報を分泌する。そのため、エージェント数が少ない場合、フェロモン情報の付着領域が少なく、良解の探索が行えないと考えた。そこで、フェロモン情報を、選択した経路と選択した経路周辺に対して付着を行う、範囲付着の論理を追加した。その結果、タイプⅠ、タイプⅡ共に、エージェント数が2~4倍と同程度の効果が得られた。特にタイプⅠではフェロモン情報が細分化されているため、この効果が顕著に得られた。

(4) 範囲付着効果が多く得られたタイプⅠのモデルに対して、解の収束状況を確認した。大域的最適解は繰返し回数100回のうち、2回しか得られておらず、収束性が低いことが確認された。さらに最大繰返し回数のフェロモン情報を確認すると、これまでに得られたの良解とは異なる箇所のフェロモン濃度が高くなっていた。そこで、「過去に得られたフェロモン情報は、最良解が更新されない限り蒸発しない」というモデルを提案し、これをタイプⅢとした。

(5) タイプⅢにおける計算結果は、大域的最適解で収束し、収束性が改良された。さらに、タイプⅠに比べ、大域的最適解を算定する繰返し回数も減少したことから、解の探索過程においても良い結果が得られた。

参考文献

- 1) James Kennedy, Russell Eberhart and Yuhui Shi: Swarm Intelligence, Morgan Kaufmann Publishers, 2001
- 2) Marco Dorigo, Thomas Stutzle: Ant Colony Optimization, Bradford Books, 2003
- 3) 山川宏 編: 最適設計ハンドブックー基礎・戦略・応用ー, 朝倉書店, 2004
- 4) 北山哲士・荒川雅生・山崎光悦: Particle Swarm Optimizationの基礎的研究と混合変数問題への適用, 機会学会論文集A, 2005
- 5) 山田善一・大久保貞二 監訳: 最適構造設計ー概念・方法・応用ー, 丸善株式会社, 1983