

# $\lambda$ -branching factor により 解の多様性を維持する蟻コロニー最適化

芳賀 光瑠<sup>1,a)</sup> 加藤 昇平<sup>1,b)</sup>

概要：巡回セールスマン（TSP）のような NP 困難な問題は現実社会で数多く存在し、これらの問題は計算量が莫大なため現在の計算機の処理能力を持ってもすべての組合せを計算することは不可能である。しかし、現実社会では長い時間をかけて最も良い解（最適解）を求める必要は少なく、短時間に最適解に十分近い準最適解の方が必要とされることが多い。そこで、本稿では収束速度を速めながら他の手法と比較し同質またはそれ以上の解を求めることを目的とする ASwide を提案する。ASwide とは蟻同士が分泌するフェロモンによりコミュニケーションを行い餌への経路を最適化する一連の行動をモデル化した蟻コロニー最適化のフェロモン分泌式の部分を改良した手法である。その有効性を確認するために、巡回セールスマン問題のベンチマーク問題を用いて、複数の蟻コロニー最適化の類似手法と比較実験を行い、その有効性を確認する。また、解の探索中に局所解に陥ってしまうのを回避するため蟻コロニー最適化の終了判定に多く用いられる  $\lambda$ -branching factor の値により解に多様性を持たせる手法の提案も行う。こちらも上記実験と同様、巡回セールスマン問題のベンチマーク問題を用いた実験により、従来手法よりも解の質と収束速度が向上したことを確認する。

## 1. はじめに

近年、計算機工学や分散処理の発展は目覚しく計算機の処理能力は年々高速化されているが組み合わせ最適化問題 (Combinatorial Optimization Problem) はその処理能力を持ってしても大規模な問題の場合現実的な時間内で最適解を求めることは極めて困難である。しかし、現実社会ではスケジューリング問題や半導体などの設計に不可欠である LSI 設計問題などで複雑な組み合わせ最適化問題を解くことは必要不可欠である。現実的な時間内に最適解を求めることが一番であるが、それには莫大なコストと時間がかかるため現実では最適解よりも十分精度の高い近似解が求められるというニーズが高い。そのため、最適解を求めるのではなく現実的な時間内に最適解に準ずる有用な解を求めるためにメタヒューリスティクスや近似解法に関する研究が多く行われている [8], [9], [13].

その中でも、蟻の採餌行動から発想を得てモデル化された Ant Colony Optimization (ACO) は、巡回セールスマン

ン問題 (TSP) やネットワークルーティング問題、二次割り当て問題など多くの組み合わせ最適化問題に適用され、その有効性が多数確認されている [1], [6], [15], [17]. しかし、このようなメタヒューリスティクスを用いたアルゴリズムでは収束性を促進させる解の集中化と解の精度を向上させる多様性のバランスが解の精度と速度にとって極めて重要となる。解の多様性を持たせる方法の1つとしてランダム選択を取り入れて解の多様性を持たせる研究が多く行われているが適切なランダム選択率は問題によって大きく異なり、その決定は極めて困難である [16], [18].

そこで、本稿ではカーナビゲーションやネットワークルーティングなど実社会での応用のため現実的な時間内に良質な解を導き出すことを目的とする ASwide を提案する。ASwide は ACO のフェロモン分泌にシステムが今までに得た最も良い解である最良解とその時点での経路長との比により重み付けを加えた手法である。また、解の多様性を維持させながら収束速度を早めるために  $\lambda$ -branching factor を用いた収束判定後にランダム選択を行う手法も提案し、実験を行った。本稿ではまず2章で ACO とその類似手法の説明を行い、3章、4章ではそれぞれ集中化と解の多様性の観点から、評価実験により従来手法と比較と考察を行う。最後に5章で本稿のまとめを行う。

<sup>1</sup> 名古屋工業大学大学院工学研究科情報工学専攻  
Nagoya Institute of Technology Dept. of Computer Science  
and Engineering, Graduate School of Engineering, Nagoya  
Institute of Technology, Gokiso-chou, Showa-ku, Nagoya-shi,  
466-8555

a) haga@katolab.nitech.ac.jp

b) shohey@katolab.nitech.ac.jp

## アルゴリズム 1 一般的な ACO のアルゴリズム

- すべての蟻エージェントとフェロモンの初期化
- while** 終了条件が未成立 **do**
  1. 各蟻エージェントに対して、フェロモンとヒューリスティックな情報に基づいて確率的に解を選択
  2. 各蟻エージェントが分泌するフェロモンを計算
  3. フェロモン情報の更新
- end while**
- 最も良い成績を持つ蟻エージェントの解を出力

## 2. ACO の概要

生物の行動や習性、特に社会性昆虫の集団において創発される群知能 (Swarm Intelligence) の研究が盛んに行われている [8], [9], [13]. その典型的な例として、蟻がフェロモンを分泌しながら他の蟻とコミュニケーションをとり、餌までの行列を生成する行動をモデル化した ACO があげられる。

蟻は求餌の際、最初はランダムに行動し、餌を見つけると通ってきた経路を辿りコロニー (巣) へと戻る。その際、他の蟻に餌の情報を伝えるためフェロモンを分泌しながらフェロモンコミュニケーションを行う。他の蟻がそのフェロモンを感知すると蟻はランダムに行動するのを止めてフェロモンに従う。また、その跡を辿り始め、餌を見つけると経路を補強しながらコロニーへと戻る。しかし、フェロモンの痕跡は時間と共に揮発するため、蟻は時間が経過するにつれてフェロモンを感知しにくくなる。したがって、餌までの経路が長いほど移動時間を要するために蟻はフェロモンを感知しにくくなる。これに対して、経路が短ければ短いほど餌までの移動時間は短くなり、フェロモンが揮発するよりも早く経路が補強されるためフェロモン濃度は高いまま保たれる。したがって、ある蟻がコロニーから餌までのより短い経路を見つけると、他の蟻もその経路を辿る可能性は高くなり、正のフィードバックによって最終的にはすべての蟻が1つの経路を辿ることになる。

最も基本的な ACO は Dorigo らによって TSP を解くために考案された [3]. 現在研究されている ACO のほとんどは Dorigo らが提案した拡張系である [2], [4], [5], [10]. ACO アルゴリズムの概要をアルゴリズム 1 に示す。TSP とは代表的な NP 困難な問題の1つであり、都市の集合と各2都市間の移動コストが与えられたとき、すべての都市を丁度一度ずつ巡り出発地に戻る総移動コストが最小な巡回路を求める問題である。

まず、すべての蟻エージェントをランダムにそれぞれ都市に配置し、すべてのフェロモン値を非負である同一の値に初期化する。次にユーザーが定義した終了条件を満たすまで都市の選択、フェロモン分泌量の計算、フェロモン情報の更新を行う。終了条件を満たした場合、それまでに得た最も良い巡回路を持つ蟻エージェントの解をアルゴリ

ズムの結果として出力する。それぞれの処理を以下に説明する。

### 2.0.1 都市の選択

各蟻エージェントは確率的に次に進む都市を決定する。 $p_{ij}^k$  を蟻エージェント  $k$  が都市  $i$  から都市  $j$  に進む確率とすると、その確率は式 (1) のように示される。

$$p_{ij}^k = \begin{cases} \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum_{h \in \Omega} [\tau_{ih}]^\alpha [\eta_{ih}]^\beta} & \text{if } j \in \Omega \\ 0 & \text{else} \end{cases} \quad (1)$$

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

ここで、 $\tau_{ij}$  は都市  $i$  から都市  $j$  までの間に蓄積されてるフェロモン量、 $\eta_{ij}$  は都市  $i$  から都市  $j$  までの間のヒューリスティック値、 $\Omega$  はまだ訪問していない都市の集合とする。 $\alpha$  と  $\beta$  はフェロモン値、ヒューリスティック値どちらを優先させるかを決定するパラメータである。また、ヒューリスティック値  $\eta_{ij}$  については都市  $i$  と  $j$  の距離の逆数とする。都市  $i$  から  $j$  への距離を  $d_{ij}$  とした場合の  $\eta_{ij}$  は式 (2) のようになる。ここで、すでに訪問している都市に進む確率は0であるが、まだ訪問していない都市については僅かながらも必ず進む確率が存在することに留意する。これにより、局所解に陥ってしまうことを防いでいる。

### 2.0.2 フェロモン分泌量の計算

すべての蟻エージェントの巡回が完了したとき、すなわち、 $\Omega$  が空集合となると各蟻エージェントが分泌するフェロモン量が計算される。蟻エージェント  $k$  が  $t$  巡回した時、都市  $i, j$  に分泌するフェロモン量を  $\Delta\tau_{ij}^k$  とし、その計算式は式 (3) のように示される。

$$\Delta\tau_{ij}^k(t) = \begin{cases} \frac{Q}{L_k(t)} & \text{if } (i, j) \in T^k(t) \\ 0 & \text{else} \end{cases} \quad (3)$$

ここで、蟻エージェント一匹が一巡回の間に分泌できる最大フェロモン分泌量は  $Q$ 、蟻エージェント  $k$  が巡回  $t$  において得た最短距離を持つ巡回路は  $T^k(t)$  とし、その経路長は  $L_k(t)$  とする。すなわち、巡回路の経路長が短いものに対してはより多くのフェロモンが分泌され、他の蟻エージェントも短い経路長を持つ巡回路を確率的に通やすくなる。

### 2.0.3 フェロモン情報の更新

すべての蟻エージェントに対してフェロモン分泌量の計算が完了すると、フェロモン情報の更新が行われる。巡回  $(t+1)$  においてエッジ  $(i, j)$  に更新されるフェロモン量を  $\tau_{ij}(t+1)$  とすると、その更新式は式 (4) のように示される。

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \sum_{k=1}^m \Delta\tau_{ij}^k(t) \quad (4)$$

ここで、 $\rho(0 < \rho \leq 1)$  は時間が経つにつれてフェロモン

濃度を薄くしていく揮発率であり、 $m$  は蟻エージェントの総数である。

## 2.1 ASelite

ASelite[4] のフェロモン更新式と巡回  $t$  でのフェロモン分泌量  $\Delta\tau_{ij}^*(t)$  を式 (5) と式 (6) に示す。一般的な ACO との違いはフェロモン更新式に  $\Delta\tau_{ij}^*$  が存在することである。この違いにより、ASelite は巡回  $t$  までに発見した最良巡回路に対してフェロモン量を追加で分泌することで、群全体としてその最良巡回路周辺を集中的に探索するという特徴を持つ。

$$\tau_{ij}(t+1) = \rho\tau_{ij}(t) + \sum_{k=1}^m \Delta\tau_{ij}^k(t) + \Delta\tau_{ij}^* \quad (5)$$

$$\Delta\tau_{ij}^*(t) = \begin{cases} \sigma \frac{Q}{L^*(t)} & \text{if } (i,j) \in T^*(t) \\ 0 & \text{else} \end{cases} \quad (6)$$

ここで、 $\sigma$  は重み付けの定数であり、 $L^*(t)$  は巡回  $t$  までにシステム全体が得た最短の経路長、 $T^*(t)$  は巡回  $t$  までの最良の巡回路である。

## 2.2 ASrank

ASrank は Bullnheimer らによって提案されたアルゴリズムである [2]。ASelite と同様、巡回  $t$  までに発見した最良巡回路に対してフェロモン量を追加で分泌するが、各蟻エージェントの巡回路に経路長によりランク付けし、ある一定のランク以上の蟻エージェントをエリート蟻と呼ぶ。ASrank ではフェロモン分泌はエリート蟻のみで行う。ASrank のフェロモン更新式と巡回  $t$  でのフェロモン分泌量  $\Delta\tau_{ij}^\mu$  を式 (7) と式 (8) に示す。

$$\tau_{ij}(t+1) = \rho\tau_{ij}(t) + \sum_{\mu=1}^{\sigma-1} \Delta\tau_{ij}^\mu(t) + \Delta\tau_{ij}^* \quad (7)$$

$$\Delta\tau_{ij}^\mu = \begin{cases} (\sigma - \mu) \frac{Q}{L_\mu(t)} & \text{if } (i,j) \in T^\mu(t) \\ 0 & \text{else} \end{cases} \quad (8)$$

ここで、 $\mu$  は巡回路の経路長によってランキングされたエリート蟻の順位、 $\sigma$  はエリート蟻の総数に 1 を加えた値、 $L_\mu(t)$  は巡回  $t$  において  $\mu$  番目のエリート蟻の巡回路の経路長、 $T^\mu(t)$  は巡回  $t$  において  $\mu$  番目の蟻エージェントの巡回路である。

## 3. ASwide: 集中化の効果の確認

ASrank ではエリート蟻の順位に応じてフェロモン分泌量に  $(\sigma - \mu)$  倍の重み付けを行なっている。さらに、最大フェロモン分泌量と蟻エージェント自身の経路長との比を

表 1 eil51.tsp で 10000 巡回時の比較 (最適解:426)

	ACO	ASelite	ASrank	ASwide
最良解	435	<b>426</b>	429	431
誤差率 (%)	2.07	<b>0.00</b>	0.67	1.16
平均値	453.1	<b>431.5</b>	444.6	440.4
誤差率 (%)	5.98	<b>1.27</b>	4.18	3.27
最悪解	464	<b>436</b>	472	451
標準偏差	6.96	<b>3.49</b>	9.43	5.98

表 2 qa194.tsp で 10000 巡回時の比較 (最適解:9352)

	ACO	ASelite	ASrank	ASwide
最良解	11179	10802	9883	<b>9855</b>
誤差率 (%)	16.34	13.42	5.37	<b>5.10</b>
平均値	11577.5	11198.6	10159.4	<b>10099.0</b>
誤差率 (%)	19.22	16.49	7.95	<b>7.40</b>
最悪解	11776	11520	10653	<b>10307</b>
標準偏差	154.91	203.43	227.47	<b>133.24</b>

表 3 eil51.tsp で 300 巡回時の比較 (最適解:426)


	ACO	ASelite	ASrank	ASwide
最良解	450	437	<b>429</b>	431
誤差率 (%)	5.33	2.52	<b>0.67</b>	1.16
平均値	474.2	458.9	444.6	<b>440.4</b>
誤差率 (%)	10.16	7.17	4.18	<b>3.27</b>
最悪解	487	475	472	<b>451</b>
標準偏差	9.73	11.86	9.39	<b>5.98</b>

表 4 qa194.tsp で 300 巡回時の比較 (最適解:9352)


	ACO	ASelite	ASrank	ASwide
最良解	11814	11392	9883	<b>9855</b>
誤差率 (%)	20.84	17.91	5.37	<b>5.10</b>
平均値	12134.0	11838.5	10171.9	<b>10124.4</b>
誤差率 (%)	22.93	21.00	8.06	<b>7.63</b>
最悪解	12373	12187	10656	<b>10463</b>
標準偏差	<b>161.09</b>	229.03	227.95	162.61

取り入れることにより解の質に応じて重み付けが行われる。そのため、すべてのエリート蟻の巡回路の経路長の評価が悪い場合でもフェロモン分泌量に  $(\sigma - \mu)$  の重み付けされてしまい解の探索に悪影響を与えてしまうと考えられる。

そこで、提案手法の ASwide では ASrank と同様、エリート蟻の順位に応じた重み付けに加えて、これまでの探索で得た最良解とエリート蟻の経路長との比による重み付けを行う。これにより評価の悪いエリート蟻が存在した場合、エリート蟻の順位に応じた重み付けにより適切にペナルティ (負の重み付け) や報酬 (正の重み付け) が付与されると考える。また、今までの最良解を更新した場合はより多くのフェロモンが分泌される。そのため、ASwide は解の質に応じて重み付けが行われ、探索に反映することが可能である。ASwide のフェロモン分泌量  $\Delta\tau_{ij}^\mu$  を式 (9) に示す。

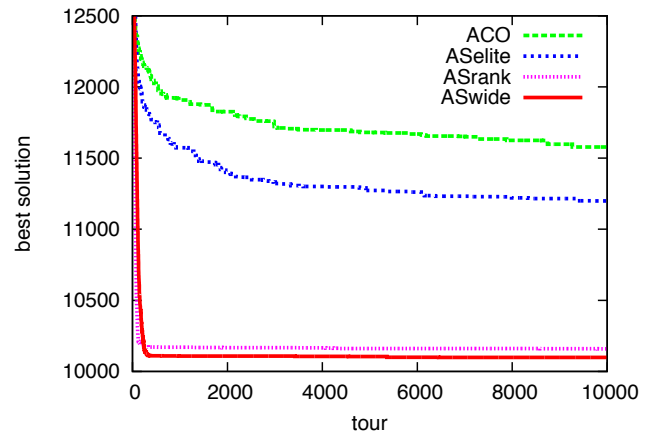


(a) 10000 巡回までに得た最良解の推移




(b) 300 巡回までに得た最良解の推移

図 1 eil51.tsp で得た最良解の推移



(a) 10000 巡回までに得た最良解の推移



(b) 300 巡回までに得た最良解の推移

図 2 qa194.tsp で得た最良解の推移

$$\Delta\tau_{ij}^{\mu} = \begin{cases} (\sigma - \mu) \frac{Q \cdot L^*}{(L_{\mu}(t))^2} & \text{if } (i, j) \in T^{\mu}(t) \\ 0 & \text{else} \end{cases} \quad (9)$$

ここで、 $\mu$  は巡回路の経路長によってランキングされたエリート蟻の順位、 $\sigma$  はエリート蟻の総数に 1 を加えた値、 $L^*$  はシステムが今までに得た最短経路長、 $L_{\mu}(t)$  を巡回  $t$  において  $\mu$  番目のエリート蟻の巡回路の経路長、 $Q$  は最大フェロモン分泌量、 $T^{\mu}(t)$  を巡回  $t$  において  $\mu$  番目の蟻エージェントの巡回路である。

### 3.1 実験

ASwide の有効性を確認するため、この章での実験は集中化のみに着目し複数の巡回セールスマン問題において比較実験を行う。実験には巡回セールスマン問題のベンチマーク問題を提供している TSPLIB[11] に含まれる 51 都市の eil51.tsp と The Traveling Salesman Problem[12] に含まれる 194 都市の qa194.tsp を用いた。また、比較手法として同じ解の集中化を促進する ACO, ASelite, ASrank の合計 3 種類の手法を用いた。都市数  $x$  に対して、蟻エージェント数は  $x-1$ 、エリート数は  $x/10$  とし、各手法のパラメー

タは  $(\alpha, \beta) = (1, 1)$ ,  $Q = 100$ ,  $\rho = 0.005$  に設定した。一試行 10000 巡回とし、それぞれの結果を表 1 と表 2 に示す。本稿では、実用的な計算時間を 300 巡回と設定し、300 巡回時点までの探索性能も考察する。それぞれの問題における 300 巡回での結果を表 3 と表 4 に示す。表においての最良解、最悪解、平均値、標準偏差は実験を 20 試行行うことで得られた値であり、誤差率は 51 都市 (eil51.tsp) の最適解 426 と 194 都市 (qa194.tsp) の最適解 9352 に対する誤差である。誤差率は以下の式を用いて求めたものである。

$$\text{誤差率} = \frac{(\text{得られた最良解}) - (\text{最適解の経路長})}{(\text{最適解の経路長})} \quad (10)$$

また、図 1 と図 2 に 10000 巡回までのそれぞれの最良解の平均値の推移と初期段階の収束速度を確認するために 300 巡回までの推移を拡大したグラフを示す。

表 1 から確認できるように ASelite が最良解、平均値ともに最も良い結果が確認された。これは、51 都市と比較的小さい都市数では探索空間が狭く、最良解のみを集中的に探索するため、良い結果が得られているのではないかと考える。また、図 1 より ASelite はエリート蟻だけでなくす

すべての蟻エージェントがフェロモン分泌を行うことから収束速度は遅くなっているが、解の多様性が提案手法と比べると維持されていると考えられる。

表2と図2から都市数が大きい場合でASwideがすべての項目において他の手法より良い結果を示すことが確認された。これは、提案手法では評価の悪い蟻エージェントに対して適切に重み付けがされ、それにより適切なフェロモン分泌が行われるためと考えられる。また、最良解と平均値が最も良く、標準偏差が最も低いことから提案手法は他の手法と比較して安定して良質な解を出力していると考えられる。

最後に図1(b)と図2(b)から300巡回と探索初期段階でASrankとASwideの収束速度が早いことが確認できる。これは、ASrankとASwideはエリート蟻のみに対してフェロモン分泌が行われているためであると考えられる。また、提案手法であるASwideは収束初期段階の300巡回目において他の手法と比べて良い解を出力していることが確認できる。

以上のことから、提案手法ASwideはフェロモン分泌式に最良解とエリート蟻自身の巡回路の経路長との比という要素を加えただけで収束が早まったことだけでなく、より安定的に良質な解を出力することが確認された。

#### 4. 多様性の調整

ACOにおける探索は、探索途中の結果をフェロモン値として蓄積して次の探索に用いることによって成り立っている。しかし、その欠点として探索終盤で局所解に陥ってしまいほとんど探索が行われなれないといった問題が存在する。そのため、解の多様性を持たせることはACOの性能向上に必要不可欠なことであり、ランダム選択を用いて解に多様性を持たせる研究が多く行われている[16], [18], [19], [20]。しかし、最適なランダム選択率は問題によってそれぞれ異なりあらかじめ決定することが困難である。そこで、本稿では一般的に行われている探索初期から一定確率でランダム選択を行う方法とは別に解の収束判定後にランダム選択を導入しその有効性を確認する。

##### 4.1 ランダム選択の導入

ランダム選択は蟻エージェントが無作為に都市を選択することで解の多様性を維持することが可能である。都市のランダム選択とはつまりフェロモン濃度やヒューリスティック値を利用せず、まだ訪問していない都市集合 $\Omega$ からすべて等確率でランダムに選択するというものである。 $N_\Omega$ を未訪問都市集合 $\Omega$ の要素数とした場合、巡回 $t$ で蟻エージェント $k$ が都市 $j$ を選択する確率 $p_{ij}^k$ は以下のようになる。

$$p_{ij}^k = \begin{cases} \frac{1}{N_\Omega} & \text{if } j \in \Omega \\ 0 & \text{else} \end{cases} \quad (11)$$

上記のランダム選択は中道らの場合、探索初期状態から行われているが、本稿では収束判定後にランダム選択を導入する。今回は解の収束判定方法として、Dorigoらが提案したフェロモンの偏り具合を求める $\lambda$ -branching factorを用いた[7]。

ここで、式(1)に従わず式(11)のようにランダムに経路を選択する蟻エージェントの母集団に占める割合をランダム選択率とする。

##### 4.2 $\lambda$ -branching factor

本稿では収束判定としてDorigoらが提案した $\lambda$ -branching factorを用いる[7]。 $\lambda$ -branching factorとは都市 $i$ から都市 $j$ への経路上のフェロモンが、パラメータにより設定された閾値を超えている都市の平均個数を求めることによりフェロモンの偏り具合を求めるACOの収束性を調べることを可能にする手法である。時点 $t$ で閾値を超えている都市の個数の平均値を $\Lambda(t)$ とした時その値は式(12)のように示される。

$$\Lambda(t) = \frac{1}{n} \sum_{1 \leq i \leq n} \sum_{1 \leq j \leq n, j \neq i} \epsilon_{ij}(t) \quad (12)$$

ここで、 $n$ は総都市数、 $\epsilon_{ij}(t)$ は $t$ 時点での都市 $i$ から都市 $j$ への経路が閾値を超えているかを求める関数であり、式(13)のように示される。

$$\epsilon_{ij}(t) = \begin{cases} 1 & \text{if } \tau_{ij}(t) > \lambda(\tau_i^{max}(t) - \tau_i^{min}(t)) + \tau_i^{min}(t) \\ 0 & \text{else} \end{cases} \quad (13)$$

ここで、 $\tau_{ij}(t)$ は都市 $i$ から都市 $j$ までの間に蓄積されているフェロモン量、 $\lambda$ は収束判定をどの程度厳しく行うかを定める( $0 \leq \lambda \leq 1$ )を満たす定数、 $\tau_i^{max}(t)$ は $t$ 時点で都市 $i$ から出て行く経路のフェロモン値の最大値であり、 $\tau_i^{min}(t)$ は $t$ 時点で都市 $i$ から出て行く経路のフェロモン値の最小値である。 $\tau_i^{max}(t)$ と $\tau_i^{min}(t)$ はそれぞれ以下の式で示される。

$$\tau_i^{max}(t) = \max\{\tau_{il}(t) | 1 \leq l \leq n \wedge l \neq i\} \quad (14)$$

$$\tau_i^{min}(t) = \min\{\tau_{il}(t) | 1 \leq l \leq n \wedge l \neq i\} \quad (15)$$

##### 4.3 ランダム選択による感度実験

ASrank<sub>RS</sub>として中道らが提案したASrankに探索初期から一定確率で式(11)のランダム選択を導入する手法、

表 5 ASwide $\lambda$  の  $\Lambda$  とランダム選択率の違いによる結果

ランダム 選択率 (%)	$\Lambda$ の閾値									
	2.2	2.4	2.6	2.8	3.0	3.2	3.4	3.6	3.8	4.0
0.1	9982.8	9976.9	10010.2	9981.3	9985.4	<b>9968.0</b>	10019.4	9973.0	9987.6	10011.9
0.2	9989.3	9933.0	<b>9924.2</b>	9969.7	9973.1	9967.6	9984.9	9984.4	9957.8	9991.3
0.3	9949.9	9982.1	9967.4	9983.7	9984.7	9985.6	9960.6	9988.9	<b>9931.0</b>	9947.8
0.4	9996.5	9979.0	9976.6	10033.8	9961.1	9971.1	9977.8	9974.1	<b>9952.2</b>	9961.9
0.5	10001.1	9957.8	9976.1	9953.9	9941.2	9908.8	9888.4	9870.3	9907.8	<b>9855.2</b>
0.6	9960.4	9982.5	9974.7	9939.4	9890.0	9890.6	9851.0	9868.5	<b>9846.5</b>	9867.5
0.7	9996.0	9996.7	9986.2	9974.4	9911.4	9894.1	9863.5	9893.6	<b>9822.7</b>	9904.8
0.8	9964.4	9946.5	9949.6	9892.6	9891.1	9859.2	9888.2	<b>9845.2</b>	9859.8	9854.2
0.9	9966.0	9928.4	9984.6	9928.2	9918.5	9877.3	9905.0	9873.7	9876.2	<b>9867.1</b>
1.0	9954.0	9961.3	9933.4	9921.8	9909.3	9883.6	9870.1	9893.0	9895.2	<b>9831.5</b>
2.0	10091.5	10113.1	10049.4	10058.0	<b>10025.1</b>	10117.7	10115.1	10077.6	10073.8	10202.5
3.0	10041.6	10100.7	10054.0	10099.6	10149.8	10172.0	<b>10017.2</b>	10110.8	10104.8	10107.0
4.0	10043.7	10029.3	10133.7	10082.9	10069.3	10156.4	10129.7	10160.8	10100.3	<b>10162.3</b>
5.0	10040.5	10170.8	10050.6	<b>10016.7</b>	10178.4	10141.1	10093.7	10106.5	10188.3	10163.2

表 6 ASrank<sub>RS</sub> と ASwide $\lambda$  の比較

ランダム 選択率 (%)	ASrank <sub>RS</sub>				ASwide $\lambda$				
	最良解	誤差率 (%)	平均値	標準偏差	$\Lambda$ 値	最良解	誤差率 (%)	平均値	標準偏差
0.1	9722	3.81	9976.2	130.00	3.2	9640	<b>2.99</b>	9968.0	156.14
0.2	9800	4.57	9975.6	175.86	2.6	9695	3.54	9924.2	143.48
0.3	9752	4.10	9913.5	163.76	3.8	9650	3.01	9931.0	142.26
0.4	9710	3.69	9862.6	104.06	3.8	9696	3.55	9952.2	174.18
0.5	9674	3.33	9812.1	102.16	4.0	9624	<b>2.83</b>	9855.2	131.98
0.6	9661	3.20	9812.9	115.21	3.8	<b>9495</b>	<b>1.51</b>	9846.5	150.39
<b>0.7</b>	9656	3.15	9909.7	155.72	3.8	9599	<b>2.57</b>	<b>9822.7</b>	107.69
<b>0.8</b>	9649	3.08	<b>9797.8</b>	141.36	3.6	9626	<b>2.85</b>	9845.2	118.44
0.9	9651	3.10	9900.6	244.43	4.0	9612	<b>2.70</b>	9867.1	144.55
1.0	<b>9640</b>	<b>2.99</b>	9846.7	144.54	4.0	9647	3.06	9831.5	97.54
2.0	10086	7.28	10358.3	169.50	3.0	9785	4.43	10025.1	181.76
3.0	11076	15.57	11811.4	342.32	3.4	9613	<b>2.72</b>	10017.2	250.01
4.0	12090	22.65	12722.7	325.32	4.0	9775	4.33	10029.3	181.52
5.0	12521	25.31	13166.0	368.56	2.8	9803	4.60	10016.7	160.98

ASwide $\lambda$  として ASwide に  $\lambda$ -branching factor である閾値を満たしてからランダム選択を導入する手法を用意した。また、それぞれの最適なランダム選択率を決定するために上記 2 つの手法のランダム選択率を 0.1% から 1.0% まで 0.1% 間隔、1.0% から 5.0% までを 1% 間隔でそれぞれ変化させ、最も良い結果を出力するランダム選択率やパラメータを決定するために感度解析を行った。パラメータはすべて 3 章で行った実験と同じパラメータを用い、 $\lambda$ -branching factor の収束判定の厳しさを決める  $\lambda$  はすべて 0.001 に設定して実験を行った。また、最適な閾値  $\Lambda$  を決定するため、ASwide $\lambda$  の閾値  $\Lambda$  を 2.2 から 4.0 までの 0.2 間隔で実験を行いそれぞれ 20 回実験を行った結果を表 5 に示す。なお、それぞれのランダム選択率において平均値が最も良かった結果の値を太字で表示してある。ま

た、表 5 の ASwide $\lambda$  で最も平均値が良かった太字の結果と ASrank<sub>RS</sub> の結果をまとめたものを表 6 に示す。最も結果の良かった解と平均値、誤差率が 3.00% 以下の結果は太字で示す。なお、実験結果は qa194.tsp を用いてすべて 20 試行での最良解、最良解の誤差率、標準偏差である。また、表 6 のランダム選択率ごとの ASrank<sub>RS</sub> と ASwide $\lambda$  の平均値をグラフ化したのも最良解をグラフ化したものを図 3 と図 4 に示す。

まず、表 5 より ASwide $\lambda$  の最適な閾値  $\Lambda$  は 3.8 と 4.0 に集中していることが確認できる。これは、閾値  $\Lambda$  が低い場合はフェロモン値が極めて偏った状態で局所解に陥ってしまっていると考えられる。このことにより、ランダム選択を導入するタイミングが解の質に極めて大きな影響を与えることが確認できる。

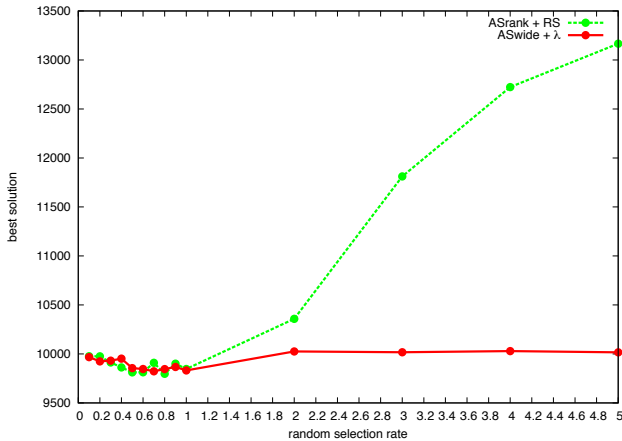


図 3 平均値でのランダム率感度実験

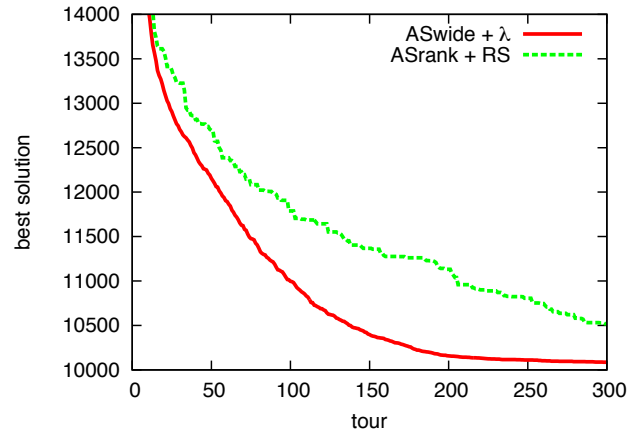


図 5 300 巡回までに得た最良解の推移




図 4 最良解でのランダム率感度実験

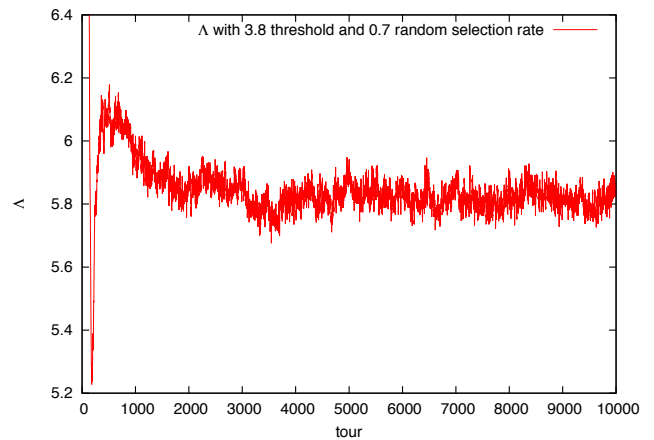


図 6  $\lambda$  値の推移

また、表 6 より  $ASrank_{RS}$  はランダム選択率は 0.8% の時、 $ASwide_{\lambda}$  はランダム選択率が 0.7% の時に最も良い平均値を出していることが確認できる。両手法の最良解、平均値から  $ASwide_{\lambda}$  は  $ASrank_{RS}$  より良い性能を示し、ランダム選択を導入しても  $ASwide_{\lambda}$  は解の集中化である重み付けと解の多様性であるランダム選択の効果が比較手法と比較してより有効であることが確認された。また、これらの結果を 3 章の実験と比較してもランダム率の導入は提案手法に関わらず解に多様性を持たせ、全体的に良質な解が生成され精度の高い解へ探索が行われていると考えられる。そのことから、今後他の ACO 類似手法に  $\lambda$ -branching factor によるランダム選択を導入しても有効ではないかと考える。

図 3 と図 4 より、ランダム選択率が 2.0% を超えた場合特に  $ASrank_{RS}$  の結果を確認すると、解の質が著しく低下していることがわかる。これは、解に多様性を探索初期段階から持たせすぎたため解探索の集中化が行われなくなったためだと考えられる。これにより、探索初期からランダム選択を導入する  $ASrank_{RS}$  はランダム選択率が最適である場合良い方向に解探索が進むが、不適切である場合解の質の低下につながることを確認できる。すなわち、探索に

おいてランダム選択を用いる場合、ランダム選択を用いるタイミングとランダム選択率が極めて重要と結論付けることができる。

収束判定後にランダム選択を導入する場合ランダム選択率が最良解に与える影響は少ないことが表 6 と図 3、図 4 から確認できる。これにより、収束判定後にランダム選択を導入することで探索初期にランダム選択を導入する場合と比べ高コストで細密なランダム選択感度実験を用いずほとんど 4% 以下の誤差を持つ解を出力できることが結果から確認される。

収束速度と初期段階の探索状況を確認するために表 6 における平均値が最も良かったランダム率すなわち、 $ASrank_{RS}$  ではランダム選択率 0.8 と  $ASwide_{\lambda}$  ではランダム選択率 0.7 を用いて探索した結果の 300 巡回までグラフ化したものを図 5 に示す。

図 5 より  $ASwide_{\lambda}$  は  $ASrank_{RS}$  に比べて重み付けによって良質な解を出力できるだけでなく、 $ASrank_{RS}$  と比べて早く収束していることが確認できる。これは、ランダム選択により評価の悪い経路長を持つエリート蟻を提案手法では重み付けにより適切にペナルティを与えているからではないかと考える。また、適切なタイミングでランダム選択

を導入されたことにより解の集中化と多様性の維持がバランスよく取れていることも結果の違いの要因の一つではないかと考えられる。

図6にASwide $\lambda$ の平均値が最も良かった結果(閾値 $\Lambda$ が3.8でランダム選択率0.7%)の $\Lambda$ の推移を示す。この結果より、平均して100巡回前後の辺りにランダム選択が導入されたことが確認できる。また、その後は $\Lambda$ 値は5.8辺りにあることからフェロモンの偏りは少なく解の多様性が維持され適切に探索が継続していることがこのグラフから示される。

また、eil51.tspについてもqa194.tspと同様に感度実験を行った結果ASrank<sub>RS</sub>とASwide $\lambda$ 両手法とも最適解の426を求めることができた。さらに、収束速度や10000巡回後の結果などはqa194.tspと類似する性質が実験により得られた。

## 5. おわりに

本稿ではASrankに最良解とエリート蟻自身の巡回路の経路長との比を用いた重み付けを行うASwideを提案した。TSPによるベンチマーク実験でASwideは適切な報酬とペナルティをフェロモン分泌に付与することにより探索初期段階に関わらず探索終盤で十分に精度の高い解を求めることが可能なことが確認された。また、特に都市数が大きい場合に有効であることが確認された。

また、提案手法に $\lambda$ -branching factorを用いたASwide $\lambda$ では最良解が3%以内と極めて良質な解を多く出力出来ることを確認した。また、中道らが提案した探索初期段階からランダム選択を導入する場合よりも解の精度の向上も確認した。また、その上に $\lambda$ -branching factorを用いた場合、解の多様性を維持しながら収束速度の向上が行えたことを確認した。

今後は $\lambda$ -branching factorを他のACO類似手法に適用、他の収束判定を用いた場合の検討、多くのパラメータを要する問題点の改善が必要であると考え。また、ランダム選択率の動的な変更や $\Lambda$ 値に応じてランダム選択の有無の切り替えや更に大規模なベンチマーク問題での実験を今後検討する。さらに、MMAS (MAX-MIN Ant System)[10]やACS(Ant Colony System)[5]など他のACO類似手法とも比較を行う。

## 参考文献

- [1] Arora, T. and Moses, M.E.: Ant Colony Optimization for power efficient routing in manhattan and non-manhattan VLSI architectures, *Swarm Intelligence Symposium, 2009. SIS '09. IEEE*, pp.137-144 (2009)
- [2] Bullnheimer, B. and Hartl, R.F. and Strauss, C.: A new rank based version of the Ant System. A computational study, *Central European Journal for Operations Research and Economics*, pp.25-38 (1997)
- [3] Dorigo, M.: Optimization, Learning and Natural Algo-

- ritms, *Ph.D. Thesis, Politecnico di Milano*, (1992)
- [4] Dorigo, M. and Maniezzo, V. and Colomni, A.: Ant system: optimization by a colony of cooperating agents, *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, Vol.26, No.1, pp.29-41 (1996)
- [5] Dorigo, M. and Gambardella, L.M.: Ant colony system: a cooperative learning approach to the traveling salesman problem, *Evolutionary Computation, IEEE Transactions on*, Vol.1, No.1, pp.53-66 (1997)
- [6] Dorigo, M. and Gambardella, L.M.: Ant Algorithms for Discrete Optimization, *Artificial Life*, Vol.5, No.2, pp.137-172 (1999)
- [7] Dorigo, M. and Stützle, T.: *Ant Colony Optimization, The MIT Press*, (2004)
- [8] Rabanal, P. and Rodríguez, I. and Rubio, F.: Using river formation dynamics to design heuristic algorithms, *Unconventional Computation*, pp.163-177 (2007)
- [9] Shah-Hosseini, H.: The intelligent water drops algorithm: a nature-inspired swarm-based optimization algorithm *International Journal of Bio-Inspired Computation*, Vol.1, No.1, pp.71-79 (2009)
- [10] Stützle, Thomas and Hoos, Holger H.: MAX-MIN Ant system *Future Gener. Comput. Syst.*, Vol.16, No.9, pp.889-914 (2000)
- [11] TSPLIB:  
<http://comopt.ifl.uni-heidelberg.de/software/TSPLIB95/>
- [12] Traveling Salesman Problem:  
<http://www.tsp.gatech.edu/index.html>
- [13] Li-Pei Wong and Low, M.Y.H and Chin Soon Chong.: A Bee Colony Optimization Algorithm for Traveling Salesman Problem *Modeling Simulation, 2008. AICMS 08. Second Asia International Conference on*, pp.818-823 (2008)
- [14] 飯村 伊智郎, 石橋 賢, 中山 茂: ランダムウォークと局所解を導入したMMASによる虹割り当て問題の実験的検討 第8回情報技術学術フォーラム, F-016 (2009)
- [15] 奥本 泰久, 春名 基仁: アントコロニー法を用いた溶接・切断トーチの経路最適化, *日本船舶海洋工学会論文集*, No.7, pp.73-79 (2008)
- [16] 下村 将, 杉本 雅樹, 原口 卓, 松下 春奈, 西尾 芳文: 敏感なアリと鈍いアリによるアントコロニー最適化, *電子情報通信学会技術研究報告*, Vol.110, No.83, pp.157-160 (2010)
- [17] 辻 康孝, 黒田 真弘, 井本 善敬, 近藤 英二: S1401-1-1 複数コロニーを用いたアントコロニー最適化法による旅客鉄道の車両運用計画, *年次大会講演論文集: JSME annual meeting*, Vol.2012, No.4, pp.275-276
- [18] 中道 義之, 有田 隆也: ACOにおけるランダム選択に基づく多様性調整の効果, *情報処理学会論文誌*, Vol.43, No.9, pp.2939-2947 (2002)
- [19] 芳賀 光昭, 加藤 昇平: 最良解との比較を取り入れた蟻コロニー最適化の改良手法, *平成24年度電気関係学会東海支部連合大会*, D3-6 (2012)
- [20] 芳賀 光昭, 加藤 昇平: 最良解との比によるペナルティを導入したACOの改良手法, *合同エージェントワークショップ&シンポジウム* (2012)