

複数の優良解を用いてフェロモン濃度を更新する Max-Min Ant System

Max-Min Ant System Updating Pheromone Concentration with Multiple Decent Solutions

二村 厚思^{*1} 加藤 昇平^{*1*2}
Atsushi Futamura Shohei Kato

^{*1}名古屋工業大学大学院工学研究科情報工学専攻

Department of Computer Science and Engineering Graduate School of Engineering, Nagoya Institute of Technology

^{*2}名古屋工業大学情報科学フロンティア研究院

Frontier Research Institute for Information Science, Nagoya Institute of Technology

Ant Colony Optimization (ACO) is a method for finding an approximate solution of a combinatorial optimization problem like the traveling salesman problem (TSP). Max-Min Ant System (MMAS) is a representative ACO algorithm. In MMAS, pheromone concentration is updated with only the best solution for each generation, but in this research we propose a method to update pheromone concentration with multiple decent solutions. We compare the proposed method and MMAS by using TSP benchmark.

1. はじめに

世の中には非常に多くの NP 困難な問題が存在し、NP 困難な問題の有効的な解法の一つとして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には様々な種類が存在するが、共通する点としてランダム性や汎用性があり、現実世界の現象をモデル化しているアルゴリズムが多い。近年、群知能をモデル化したメタヒューリスティクスが活発に研究されており、その中のひとつとして蟻コロニー最適化 (ACO) がある。本研究は群知能の最適化手法の中で、組合せ最適化問題を中心に研究が行われている ACO について行っていく。ACO は、蟻の採餌行動をモデル化したメタヒューリスティクスであり、最初の ACO として Ant System [Dorigo 96] がある。Ant System は組み合わせ最適化問題の一つである巡回セールスマン問題を対象に提案されたが、他の最適化手法と比べて性能が良いものではなかった。しかし、その性能を改善しようと様々な ACO が提案されている。特に性能が良い ACO として MAX-MIN Ant System (MMAS) [Stützle 00] と Ant Colony System (ACS) [Dorigo 96] が有名であり、これら二つに関連する研究が盛んに行われている。

本研究では、性能の向上を目的に ACO の中でも代表的なアルゴリズムである MMAS におけるフェロモン濃度更新の改良手法を提案する。そして、ACO アルゴリズムの性能評価としてよく用いられる巡回セールスマン問題による提案手法と MMAS の比較検証を行う。

2. 巡回セールスマン問題

巡回セールスマン問題は代表的な組み合わせ最適化問題の一つであり、NP 困難な問題としてよく知られている。巡回セールスマン問題は与えられた都市とその都市間の距離から総移動距離が最小となる巡回路を求める問題である。一般的に巡回セールスマン問題は式 1 であらわせる。ここで d_{ij} は都市 i, j 間の距離をあらわし、 X は巡回路をあらわす。

最初に提案された ACO である Dorigo らの AS が巡回

セールスマン問題を対象に考案されたもの [Dorigo 96] であるため、多くの改良型 ACO アルゴリズムの基本形が巡回セールスマン問題に準拠したものとなっており、MMAS もその一つである。

$$\min_X f(X) = \min_X \sum_{(i,j) \in X} d_{ij} \quad (1)$$

3. 蟻コロニー最適化

蟻コロニー最適化は蟻の採餌行動を基に考案された組み合わせ最適化問題の解の探索を行うアルゴリズムである。

実際の蟻の採餌行動ではまずはじめに偵察蟻が巣からそれぞれの方向に向けて探索に出発し、餌を発見するまで探索範囲を広げていく。偵察蟻が餌を発見した場合、餌を巣まで運んで帰るが、その際、帰り道にフェロモンを地面に分泌しながら巣まで帰ってくる。そして、巣の近くの蟻が分泌されたフェロモンを感知した場合、フェロモン濃度の濃いほうに進む蟻の性質によって、発見した餌場へとたどり着くことができる。また、その蟻が餌を探しにいく際にもフェロモンを分泌していく。しかしフェロモンには蒸発する性質があるため時間が経過するごとにフェロモン濃度が薄くなっていく。そのため餌場コロニーまでの経路が短いほど蟻の移動時間も短くなるためフェロモン濃度が高い状態で保たれる。また、餌場コロニーまでの経路が長いほど蟻の移動時間も長くなり、付与されるフェロモンの量も減るためフェロモン濃度は短い経路に比べて次第に薄くなっていく。このようにして蟻は協調行動をすることで巣から餌場コロニーまでの最短経路を見つけ、効率的に採餌を行っている。蟻コロニー最適化はこの採餌行動から着想を得たアルゴリズムであり、その蟻コロニー最適化の中で代表的なアルゴリズムとして MMAS がある。

4. MAX-MIN Ant System

MMAS は T. Stützle が提案した ACO アルゴリズムである。巡回セールスマン問題を解く際の MMAS の処理の流れを Algorithm1 に示す。MMAS の処理は大きく分けて「フェロ

連絡先: 加藤 昇平, 名古屋工業大学, 愛知県名古屋市昭和区御器所町, 052-735-5625, shohey@katolab.nitech.ac.jp

Algorithm 1 Max-Min Ant System

- 1: フェロモン・パラメータの設定
 - 2: **while** 終了条件 **do**
 - 3: 蟻エージェントの探索による解の生成
 - 4: フェロモン濃度の更新
 - 5: **end while**
 - 6: 最良解の出力
-

モン・パラメータの設定, 「蟻エージェントによる解の探索」, 「フェロモン濃度の更新」の3つの処理に分けられる。

「フェロモン・パラメータの設定」では蟻エージェントが探索を行うために巡回セールスマン問題におけるそれぞれの都市間に初期フェロモンを付与していく。そのフェロモン付与方法は式2のようになっている。ここで τ_{ij} は都市 i, j 間のフェロモン濃度値をあらわし, ρ はフェロモンの蒸発係数を表している。 L_{NN} は Nearest Neighbor 法 [Applegate 06] によって求められた近似解の巡回路長である。

$$\tau_{ij} = \frac{1}{\rho \cdot L_{NN}} \quad (2)$$

「蟻エージェントの探索による解の生成」では設定したフェロモンやパラメータにしたがって蟻エージェントが確率的に経路の選択を行う。まず蟻エージェントが最初に出発する都市をランダムに選択する。そして、以下の式3に基づいて次に移動する都市を確率的に選択していく。

p_{ij}^k は都市 i にいる蟻エージェント k が都市 j を選択する確率を意味し, $\tau_{ij}(t)$ が t 回目のループにおける都市 i, j 間のフェロモン濃度を表し, $J_k(i)$ は都市 i にいる蟻エージェント k がまだ訪れていない都市の集合を表し, s はその訪れていない都市を表している。 η_{ij} はヒューリスティックによるバイアスで一般的には都市 i, j 間の距離の逆数が用いられる。 α, β は $\tau_{ij}(t), \eta_{ij}$ を調整するためのパラメータである。都市 i, j 間に付与されているフェロモン濃度値が大きく, 都市間の距離が小さい都市ほど蟻エージェントが次に移動する都市として選択する確率が高くなる。

このような式を用いて確率的に都市を選択していき, すべての蟻エージェントが巡回路を生成したら解の探索を終了する。

$$p_{ij}^k = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_{s \in J_k(i)} [\tau_{is}(t)]^\alpha \cdot [\eta_{is}]^\beta}, & \text{if } j \in J_k(i) \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

「フェロモン濃度の更新」では蟻エージェントの探索結果を基に次の世代で使用するフェロモンを更新する。MMASでは蟻エージェントの探索結果のうち最良解のみを用いて更新する。本研究では3つの処理のうち「フェロモン濃度の更新」に着目した提案手法を述べる。

5. 提案手法

MMASでは、フェロモン濃度の更新を最良解のみで行うため、一つの経路にフェロモンが集中して付加されてしまい解の探索時にフェロモンが集中した経路以外を選択する可能性が低下し、局所解に陥りやすい傾向がある。そのため、本研究ではフェロモン濃度の更新の際、最良解だけでなく上位複数個の優良解を用いることで解の探索時に多様性をもたらす。一般的に

最良解付近、すなわち上位いくつかの解にも最適解に含まれる有力な経路が含まれていると考えられるため、多様性をもたらすことによって精度の良い解が求められると考えられる。

巡回セールスマン問題を解く際の提案手法におけるツアー t 回目のフェロモン情報の更新を式(4), 式(5), 式(6)に示す。

ここで, $\tau_{ij}(t)$ はツアー t 回目の経路 ij 間のフェロモン濃度, ρ は蒸発係数, T_n は上位 n 番目の巡回路, L_n は巡回路 T_n の長さ, τ_{max}, τ_{min} はフェロモンの上限値・下限値である。上位 N 番目の解までに含まれる経路にはその解の長さ C_n にしたがってフェロモンを追加するように更新する。

$$\tau_{ij}(t+1) = \left[\rho \cdot \tau_{ij}(t) + \frac{1}{N} \sum_{n=1}^N \delta \tau_{ij}^n \right]_{\tau_{min}}^{\tau_{max}} \quad (4)$$

$$\delta \tau_{ij}^n = \begin{cases} \frac{1}{L_n}, & \text{if } (i, j) \in T_n \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

$$[x]_{\tau_{min}}^{\tau_{max}} = \begin{cases} \tau_{max}, & \text{if } x > \tau_{max} \\ \tau_{min}, & \text{if } x < \tau_{min} \\ x, & \text{otherwise} \end{cases} \quad (6)$$

6. 実験

6.1 実験設定

実験は巡回セールスマン問題を用いて行う。使用する問題は巡回セールスマン問題のベンチマークとして TSPLIB*¹ で公開されている問題の中から, d198, kroA200 の小規模な問題と pr1002, pcb1173 の比較的大規模な問題の計4つを選択した。なお, それぞれの問題名中に含まれる数字が問題における都市の数を表している。それぞれの問題における都市の配置状況を図1から4に示す。図1より, d198の問題は部分的に都市が密集しており, 反対に図2より kroA200の問題ではそれぞれの都市が散乱した配置となっている。図3より, pr1002の問題では部分的に似た都市の配置構造がいくつか存在するような問題となっている。図4より, pcb1173の問題では, グリッド上に都市が並ぶような配置となっている。同規模の都市数においても都市の構造が異なるような問題を使用して提案手法と MMAS の性能について確認する。

それぞれの問題における1試行における蟻エージェントの探索ステップ数は d198, kroA200 問題では 4000 ステップとし, pr1002, pcb1173 問題では 20000 ステップとした。また, 提案手法に用いる優良解の個数は 2 から 10 までの場合それぞれについて実験を行う。ひとつの問題における提案手法, MMAS の試行回数は 20 試行とし, その結果を示していく。

6.2 実験結果

試行回数 20 回における解の最小値, 最大値, 平均値, 最適解と平均値の誤差率(%)をそれぞれ表1, 2, 3, 4に示す。表1を見てみると d198 問題では $N = 7$ のときに最大値と誤差率が, $N = 5$ のとき最小値が最も良い解を示しているのが確認できる。最大値, 最小値, 誤差率いずれの場合においてもすべての N の値の場合ではないが MMAS よりも提案手法のほ

*1 <https://www.iwr.uni-heidelberg.de/groups/comopt/software/TSPLIB95/>




図 1: d198 問題の都市配置




図 2: kroA200 問題の都市配置




図 3: pr1002 問題の都市配置




図 4: pcb1173 問題の都市配置

うが精度の良い解を求めている。続いて、表 2 を見てみると kroA200 問題では d198 問題とは違い、最大値、誤差率の値において提案手法のほうが MMAS よりも精度の悪い解を示しているのが確認できる。しかし、最小値に関しては提案手法のほうが良い解を示している。d198 問題と kroA200 問題の結果から、提案手法では、kroA200 問題の散乱したような都市配置の巡回セールスマン問題を解くには優れていないと考えられるが、d198 のような部分的に密集したところがある問題には比較的 MMAS よりも得意であると考えられる。

表 3 を見てみると、pr1002 問題では $N = 9$ のときに最大値と誤差率が、 $N = 8$ のとき最小値が MMAS よりも良い解を示しているのが確認できる。また、そのほかの N の場合における最大値、最小値、誤差率の値をみても MMAS よりも提案手法のほうが良い解を多く示している。次に、表 4 を見てみると、pcb1173 問題では $N = 10$ のとき最大値が、 $N = 4$ のとき最小値が、 $N = 8$ のとき誤差率が最も良い解を示しているのが確認できる。また pr1002 問題のとき同様そのほかの N の場合における最大値、最小値、誤差率の値をみても MMAS よりも提案手法のほうが優れていることが確認できる pr1002 問題、pcb1173 問題ともに MMAS よりも提案手法のほうが良い結果を示していることから、これらの二つの問題のような都市配置では MMAS よりも提案手法のほうが得意であると考えられる。また、d198 問題、kroA200 問題のような規模の小さな問題と比較すると、提案手法は大規模な問題においてより効果を発揮することが示唆される。

次に、d198、pr1002 の巡回セールスマン問題において誤差率が最も良い値を示しているときの N の場合の提案手法と MMAS の各ステップごとの平均誤差率の推移を示したグラフを示す。d198 問題では $N = 7$ のときの提案手法と MMAS に

おける 1000 ステップまでに得られた最良解と最適解との 20 試行における平均誤差率の推移を図 5 に示す。図 5 を見てみると MMAS よりも提案手法のほうがグラフが下回っているのが確認でき、提案手法における有効性が確認できる。pr1002 問題では $N = 9$ のときの提案手法と MMAS における 5000 ステップまでに得られた最良解と最適解との 20 試行における平均誤差率の推移を図 6 に示す。図 6 を見てみると 1000 ステップあたりまでは MMAS のほうが誤差率が下回っているが、それ以降は提案手法のほうが誤差率が下回っている。提案手法により探索初期における解の精度は下がってしまうが、探索中盤や終盤の解の精度にいい影響を与えていることが考えられる。

7. 考察

実験結果より、d198 問題では提案手法の効果が確認できたが、kroA200 問題では提案手法の効果があまり確認できなかった。また、pr1002、pcb1173 といった大規模な問題では提案手法の有効性が示唆された。小規模な問題では、大規模な問題に比べて問題自体が簡単であるため最良解のみの更新でもある程度精度の良い解が求められるため、提案手法による効果が薄くなった可能性がある。また、問題における都市の配置状況によっても提案手法の効果に影響を与えようと考えられるため、提案手法と巡回セールスマン問題の性質との関連性を正確に調査していく必要がある。大規模な問題についても用いる優良解の個数によっては最小値の値が MMAS の値よりも悪くなっていたため、多様性を考慮しながら適切な優良解の個数を調整する必要があると考えられる。また、用いる優良解の個数は必要以上に多くなると良い解の影響だけでなく、悪い解の影響も加味されるようになってしまうと考えられるため、探索途中に

表 1: d198 の実験結果

	平均	最大	最小	誤差率 (%)
MMAS	16001	16075	15955	1.401
提案手法 (N=2)	16056.15	16286	15924	1.750
提案手法 (N=3)	16042.65	16202	15906	1.664
提案手法 (N=4)	16023.05	16396	15891	1.540
提案手法 (N=5)	16001.4	16415	15827	1.403
提案手法 (N=6)	15983.25	16075	15861	1.288
提案手法 (N=7)	15961.6	16064	15847	1.151
提案手法 (N=8)	15976.25	16082	15854	1.244
提案手法 (N=9)	15981.45	16098	15861	1.277
提案手法 (N=10)	15992.7	16075	15887	1.348

表 2: kroA200 の実験結果

	平均	最大	最小	誤差率 (%)
MMAS	29535.7	29750	29406	0.571
提案手法 (N=2)	29756.2	30161	29511	1.322
提案手法 (N=3)	29672.2	29988	29487	1.036
提案手法 (N=4)	29681.25	29952	29416	1.067
提案手法 (N=5)	29664.75	30086	29409	1.010
提案手法 (N=6)	29743.3	30166	29530	1.278
提案手法 (N=7)	29709.4	29977	29477	1.162
提案手法 (N=8)	29679.65	30219	29428	1.061
提案手法 (N=9)	29700.2	30014	29531	1.131
提案手法 (N=10)	29674.3	29889	29394	1.043

おいて解の状況が悪くなっている場合に用いる優良解の個数を制御するような構造にするとより安定して精度のいい解を求められる可能性がある。

8. おわりに

本研究では、MMAS のフェロモン濃度更新法を最良解だけでなく、複数の優良解を用いて更新を行うことで解の探索時に多様性を持たせる手法を提案した。これにより pr1002, pcb1173 といった比較的規模の大きな巡回セールスマン問題では MMAS より精度の良い解を得ることができたが、kroA200 といった規模の小さな問題ではあまり良い効果が得られなかった。

今後の課題として解の収束度合いにしたがって更新に使用する優良解の数を動的に変化させることがあげられる。これにより本研究における提案手法よりも精度の良い解が得られると考えられる。本手法を用いて別の組み合わせ最適化問題への適用やより実環境に即した問題への応用なども今後の課題として考えている。

参考文献

- [Dorigo 96] Dorigo, M., Maniezzo, V. and Colorni, A.: Ant System: Optimization by a colony of cooperating agents, IEEE Trans. on Systems, Man, and Cybernetics: Part B, Vol. 26, No. 1, pp. 29-41 (1996)
- [Stützle 00] Stützle, T. and Hoos, H. H.: MAX-MIN Ant System, Future Generation Computer System, Vol. 16, No. 8, pp. 889-914 (2000).
- [Dorigo 96] Dorigo, M. and Gambardella, L. M.: A study of some properties of Ant-Q, Proc. 4th International Conference on Parallel Problem Solving from Nature (PPSN IV), Lecture Notes in Computer Science, Vol. 1141, pp. 656-665 (1996).
- [Applegate 06] Applegate, D. L., Bixby, R. E., Chvatal, V. and Cook, W. J.: The Traveling Salesman Problem: A Computational Study, Princeton University Press (2006).

表 3: pr1002 の実験結果

	平均	最大	最小	誤差率 (%)
MMAS	268917.3	277712	266366	3.811
提案手法 (N=2)	267472.75	270919	265531	3.253
提案手法 (N=3)	266617.9	271296	264116	2.923
提案手法 (N=4)	266469.45	268004	264654	2.866
提案手法 (N=5)	266018.15	269119	263988	2.692
提案手法 (N=6)	265926.5	269670	263830	2.656
提案手法 (N=7)	265940.05	268389	263742	2.662
提案手法 (N=8)	265965	271001	263240	2.671
提案手法 (N=9)	265788.15	267754	263837	2.603
提案手法 (N=10)	265921.9	268631	263262	2.655

表 4: pcb1173 の実験結果

	平均	最大	最小	誤差率 (%)
MMAS	58789.65	59404	58180	3.336
提案手法 (N=2)	58732.8	59213	58222	3.236
提案手法 (N=3)	58645.35	59392	58075	3.082
提案手法 (N=4)	58472.8	58988	57821	2.779
提案手法 (N=5)	58464.35	58809	57854	2.764
提案手法 (N=6)	58451.05	58669	58152	2.740
提案手法 (N=7)	58441.95	58696	58194	2.724
提案手法 (N=8)	58420.25	58792	58224	2.686
提案手法 (N=9)	58441.85	58796	58198	2.724
提案手法 (N=10)	58463.9	58691	58246	2.763




図 5: d198 問題でのステップごとの誤差率の推移




図 6: pr1002 問題でのステップごとの誤差率の推移