

推薦論文

アントコロニー最適化における モデル化に依存する探索バイアスの抑制

大谷 隆浩^{†1} 越野 亮^{†2} 木村 春彦^{†1}

本論文ではアントコロニー最適化 (Ant Colony Optimization: ACO) における, 探索バイアスを抑制するフェロモン量更新ルールを提案する. ACO は自然界の蟻が行う食料採集行動に着想を得たメタヒューリスティクスであり, 様々な組合せ最適化問題において高い性能を示している. ACO の探索傾向には, 解の生成確率を決定するフェロモンパラメータのモデル化と解の生成に用いる処理手順に依存したバイアスが生じることがあり, 性能低下を引き起こす場合がある. バイアスを抑制する方法としては, フェロモンパラメータの設計を改善する方法とフェロモン量を更新するルールを改善する方法の 2 つが考えられるが, 本論文では更新ルールを改善する方法について検討する. ジョブショップスケジューリング問題を用いて提案手法の性能評価を行った結果, 提案する更新ルールは探索バイアスを抑制することができ, 従来の更新ルールに比べ高い探索性能を示すことが分かった.

Inhibition of Modeling-dependent Search Bias in Ant Colony Optimization

TAKAHIRO OTANI,^{†1} MAKOTO KOSHINO^{†2}
and HARUHIKO KIMURA^{†1}

This paper proposes a novel pheromone update rule which inhibits a search bias in Ant Colony Optimization (ACO). The ACO is a meta-heuristics which has been inspired by the foraging behavior of real ant colonies, and it shows better accuracy than the other methods in the various combinatorial optimization problems. The search process in ACO is sometimes biased by algorithm features such as the pheromone model and the solution construction process. Sometimes this bias is harmful and results in a decrease in algorithm performance over time. There are two approaches to inhibiting this bias. One is to improve the pheromone model and the solution construction process, and the other is to improve the process of the pheromone update which is dealt with

in this paper. The proposed update rule is evaluated by its application to job shop scheduling problems. Experimental results show that the proposed rule can inhibit the harmful bias and outperforms previous pheromone update rules.

1. はじめに

アントコロニー最適化 (Ant Colony Optimization: ACO)¹⁾ は自然界の蟻が行う, フェロモンと呼ばれる揮発性物質を利用した食料採集行動に着想を得たメタヒューリスティクスであり, 組合せ最適化問題を効率的に解く手法として注目されている. ACO には様々なバージョンがあり, AS (Ant System)²⁾ に始まり, ACS (Ant Colony System)³⁾, AS_{rank} (Rank based Ant System)⁴⁾, MMAS (MAX-MIN Ant System)⁵⁾ などが提案されている. また, これまでに巡回セールスマン問題 (TSP)⁵⁾, 2 次割当て問題 (QAP)⁵⁾, 配送計画問題 (VRP)⁶⁾ など様々な組合せ最適化問題に応用され, これまでのメタヒューリスティクスを上回る精度が得られている^{7),8)}.

このように ACO は様々な問題において高い性能を示しているが, 特定の制約付き最適化問題においては, 解の生成確率を決定するフェロモンパラメータのモデル化に依存した探索バイアスが生じることが知られている. この探索バイアスによる性能低下は 2 次騙し (second order deception) 効果と呼ばれる^{9),10)}. 文献 11) では k-部分木問題 (KCT) において AS を適用する場合, 探索を続けるごとに生成される解の評価値が減少していくことが示されている. さらに, 文献 9), 10), 12), 13) ではスケジューリング問題においても, 文献 14) ではナップサック問題や一般化割当て問題においても同様の現象が発生することを示している.

2 次騙し効果を抑制する方法としては次の 2 つが考えられる. 1 つは 2 次騙し効果が発生しないように適切なフェロモンのモデルを用いることである. 文献 9) においてはジョブショップスケジューリング問題 (JSS) において適切なモデル化を行うことで, 2 次騙し効果を抑制することに成功している. また, 文献 14) では各種の組合せ最適化問題における

^{†1} 金沢大学大学院自然科学研究科
Graduate School of Natural Science, Kanazawa University

^{†2} 石川工業高等専門学校電子情報工学科
Department of Electronics and Information Engineering, Ishikawa National College of Technology
本論文の内容は 2009 年 9 月の FIT2009 第 8 回情報科学技術フォーラムにて報告され, 同プログラム委員長により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である.

適切なフェロモンのモデルを示している。しかしながら、これらの方法では問題ごとに適切なフェロモンのモデルを設計しなければならず、また設計したモデルは他の問題においても有効であるとは限らない。

2 つ目に考えられる方法は、2 次騙し効果を抑制するようなフェロモン量更新ルールを用いる方法である。しかしながら、こちらの方法についてはこれまでに十分な研究がなされているとはいいがたい。KCT においては、1 回の反復内で見つかった最良解のみがフェロモン量増加に寄与するような更新ルールを用いればこの効果を抑制することができる¹¹⁾。しかしながら、JSS においてはこのルールを用いたとしても、効果的な探索が行えないことが分かっている^{9),10)}。

本研究では 2 次騙し効果を抑制するための、新しいフェロモン量更新ルールを提案する。この更新ルールは任意の制約付き組合せ最適化問題に対して容易に適用することが可能である。そして、2 次騙しの効果が発生することが知られているジョブショップスケジューリング問題に適用し、提案手法の性能を評価する。

2. アントコロニー最適化 (ACO)

ACO は組合せ最適化問題に対するメタヒューリスティック手法の一種である¹⁾。ACO の処理手順は文献によって異なった表記によって説明されているが、ここでは文献 9), 10) の表記に従って説明する。

2.1 組合せ最適化問題のモデル化

まず、本研究で対象とする組合せ最適化問題のモデルを次のように定義する。この定義は文献 9), 10), 15) などを用いられているものと同等である。

定義 1. 組合せ最適化問題のモデル $\mathcal{P} = (S, \Omega, f)$ は次に示す要素で構成される。

- 離散的な決定変数の有限集合で定義される探索空間 S と変数間の制約の集合 Ω
- 最小化する目的関数 $f: S \rightarrow \mathbb{R}^+$

実行可能解 $s \in S$ は n 個の決定変数 $X_i, i = 1, \dots, n$ からなり、制約集合 Ω に含まれるすべての制約を満たす。決定変数 X_i のとりうる値 (ドメインと呼ぶ) は $D_i = \{v_i^1, \dots, v_i^{|D_i|}\}$ で与えられる。制約集合 Ω が空集合であれば、決定変数 X_i には他の変数の値に依存せず、ドメイン D_i の中から任意の値を割り当てられる。この場合、 \mathcal{P} を制約なしの問題モデルと呼び、そうでない場合は制約ありの問題モデルと呼ぶ。実行可能解 $s^* \in S$ が $f(s^*) \leq f(s), \forall s \in S$ である場合、これを大域的最適解と呼ぶ。大域的最適解の集合は $S^* \subseteq S$ で表される。

組合せ最適化問題のモデルに基づき、次のようにフェロモンパラメータのモデル化を行う。まず決定変数 X_i とその値 $v_i^j \in D_i$ の組合せを、解を構成するコンポーネントと呼び、 c_i^j と表す。ここで、コンポーネント c_i^j に対応するフェロモンパラメータを T_i^j と定義する。フェロモンパラメータ T_i^j の値をフェロモン量と呼び、 τ_i^j と表す。また、すべてのフェロモンパラメータの集合を \mathcal{T} と表す。

2.2 ACO アルゴリズムの構成

基本的な ACO アルゴリズムの構成を図 1 に示す。各反復において、 n_a 個の解をフェロモンパラメータに基づく確率的な構築処理によって生成する。その後、必要であれば生成された解を局所探索によって改善する。最後に、次の反復が開始する前に、生成されたいくつかの解を用いてフェロモン量の更新を行う。以下ではこれらの処理の詳細について説明する。

InitializePheromoneValues(\mathcal{T})。アルゴリズムの開始時にフェロモン量を定数 $c > 0$ に設定する。

ConstructSolution(\mathcal{T})。コンポーネントの有限集合 \mathcal{C} から順にコンポーネントを取り出し、部分解 s^P に追加していくことで解を構築する。まず、 $s^P = \langle \rangle$ とし、その後 s^P に実行可能なコンポーネントを追加していく。このとき追加されるコンポーネントは、解の構築手法によって定義される集合 $\mathfrak{N}(s^P) \subseteq \mathcal{C} \setminus s^P$ の要素である。この処理によって生成される解の集合を \mathcal{S} とする。

部分解 s^P に追加するコンポーネントの選択は確率的に行われる。多くの ACO アルゴリ

```

input: モデル  $\mathcal{P} = (S, \Omega, f)$  の具体例  $P$ 
InitializePheromoneValues( $\mathcal{T}$ )
 $s_{bs} \leftarrow \text{NULL}$ 
while 終了条件が満たされない do
   $\mathcal{S}_{iter} \leftarrow \emptyset$ 
  for  $j = 1, \dots, n_a$  do
     $s \leftarrow \text{ConstructSolution}(\mathcal{T})$ 
     $s \leftarrow \text{LocalSearch}(s)$  {optional}
    if ( $f(s) < f(s_{bs})$ ) or ( $s_{bs} = \text{NULL}$ ) then  $s_{bs} \leftarrow s$ 
     $\mathcal{S}_{iter} \leftarrow \mathcal{S}_{iter} \cup \{s\}$ 
  end for
  ApplyPheromoneUpdate( $\mathcal{T}, \mathcal{S}_{iter}, s_{bs}$ )
end while
output:  $s_{bs}$ 

```

図 1 ACO アルゴリズム

Fig. 1 The scheme of ACO algorithm.

ズムではコンポーネント c_i^j の選択確率は次式で定義している．

$$p(c_i^j | s^P) = \frac{[\tau_i^j]^\alpha \cdot [\eta(c_i^j)]^\beta}{\sum_{c_k^l \in \mathfrak{N}(s^P)} [\tau_k^l]^\alpha \cdot [\eta(c_k^l)]^\beta} \quad (1)$$

ここで、 η は適用する問題に関するヒューリスティック情報に基づいて、選択確率に重み付けを行う関数である． $\alpha \geq 0$ と $\beta \geq 0$ はフェロモン情報とヒューリスティック情報の重要性を決めるパラメータである．この式により、フェロモン量が多くかつヒューリスティック情報の重みが大きいコンポーネントほど高い確率で選択されることになる．

ApplyPheromoneUpdate(\mathcal{T} , \mathfrak{S}_{iter} , s_{bs})．生成されたいくつかの解を用いて、フェロモン量の更新を行う．多くの ACO アルゴリズムは次のようなフェロモン量更新ルールを用いている．右辺の第 1 項は残存するフェロモンの減少を表し、第 2 項は新たなフェロモンの増加を表す．

$$\tau_i^j \leftarrow (1 - \rho) \cdot \tau_i^j + \frac{\rho}{n_a} \cdot \sum_{\{s \in \mathfrak{S}_{upd} | c_i^j \in s\}} F(s) \quad (2)$$

ただし、 $i = 1, \dots, n$, $j \in \{1, \dots, |D_i|\}$ である． $\rho \in (0, 1]$ は蒸発率と呼ばれるパラメータである． $F: \mathfrak{S} \mapsto \mathbb{R}^+$ は評価関数と呼ばれる関数であり、 $f(s) < f(s') \Rightarrow F(s) \geq F(s')$ とする． \mathfrak{S}_{upd} はフェロモン量の更新処理に用いる解の集合であり、 $\mathfrak{S}_{iter} \cup \{s_{bs}\}$ の部分集合である．ただし、 \mathfrak{S}_{iter} は 1 回の反復中に生成された解の集合であり、 s_{bs} はアルゴリズムの実行中に見つかった最良の解である．

2.3 フェロモン量更新処理に用いる解集合の設定法

フェロモン量の更新処理に用いる解の集合 \mathfrak{S}_{upd} の設定法によって、様々な更新ルールが定義できる．たとえば AS²⁾ で用いられている更新ルール (AS-更新ルールと呼ぶ) では

$$\mathfrak{S}_{upd} \leftarrow \mathfrak{S}_{iter} \quad (3)$$

とする．実用上よく用いられるルールは

$$\mathfrak{S}_{upd} \leftarrow \operatorname{argmax}\{F(s) | s \in \mathfrak{S}_{iter}\} \quad (4)$$

とするものである．これは、1 回の反復中に見つかった最良の解を \mathfrak{S}_{upd} に設定することを意味する (IB-更新ルールと呼ぶ)．IB-更新ルールは AS-更新ルールに比べて良い解を見つけやすいが、初期収束に陥る危険性が高まる．

3. アントコロニー最適化における騙し

ACO においては探索を続けるごとに、1 回の反復中に生成される解の平均評価値が上昇することが望まれる．ACO がそのように振る舞うか調べるために、文献 9), 10), 15) では以下に説明する ACO のモデルを用いて解析を行っている．このモデルでは蟻の数 n_a を無限大と仮定することでモデルの簡略化を行っている．なお、より実際的なモデルは文献 16) などに示されている．

モデルの振舞いは反復ごとに生成される解の期待評価値の変化によって明らかにする．以下ではこの期待評価値を $W_F(T)$ 、または $W_F(T|t)$ と表す．ただし、 $t > 0$ は反復回数である．期待評価値 $W_F(T)$ は次式で与えられる．

$$W_F(T) = \sum_{s \in \mathfrak{S}} F(s) \cdot p(s|T) \quad (5)$$

ただし、 $p(s|T)$ は、解 s が発生する確率である．

さらに、 $n_a = \infty$ と仮定することで、AS-更新ルールは以下ようになる．

$$\tau_i^j(t+1) \leftarrow (1 - \rho) \cdot \tau_i^j(t) + \rho \cdot \sum_{\{s \in \mathfrak{S} | c_i^j \in s\}} F(s) \cdot p(s|T) \quad (6)$$

ただし、 $i = 1, \dots, n$, $j = 1, \dots, |D_i|$ であり、 t は反復回数である．以下ではこのようにして得られる更新ルールを期待更新ルールと呼ぶ．

ACO における 1 次、および 2 次騙しは文献 10) で定義されている．1 次騙しは進化的計算における騙し構造による局所最適解への収束に対応し、2 次騙しは解の表現や構築方法に依存した探索バイアスに対応する．それぞれの定義は、次に示す局所最適化手法 (*local optimizer*) の定義に基づいている．

定義 2. 組合せ最適化問題のモデル \mathcal{P} が与えられ、 \mathcal{P} の具体例 P に ACO のモデルを適用したとする．このとき任意の初期フェロモン量の設定に対して、期待更新ルールによるフェロモン量の更新が $W_F(T|t+1) \geq W_F(T|t)$, $\forall t \geq 0$ となるように行われる場合、この ACO のモデルを局所最適化手法 (*local optimizer*) と呼ぶ．

なお、制約なしの問題モデルに ACO を適用する場合、局所最適化手法となることが証明されている^{10), 15)}．この定義に基づいて、1 次騙し系が定義される．

定義 3. 組合せ最適化問題のモデル \mathcal{P} が与えられ、 \mathcal{P} の具体例 P に局所最適化手法を適用したとき、大域的最適解に収束しないことが見込まれるような初期フェロモン量の設定が

存在する場合、この局所最適化手法を1次騙し系 (*First order deceptive system: FODS*) と呼ぶ。

これはACOが局所最適化手法であったとしても、複数の不動点を持つ問題に適用された場合は1次騙し系となることを意味する。

次に、2次騙し系は次のように定義される。

定義 4. 組合せ最適化問題のモデル \mathcal{P} が与えられ、 \mathcal{P} の具体例 P にACOのモデルを適用したとする。このとき、期待評価値の変化の中に、 $W_F(T|t+1) < W_F(T|t)$ 、 $\forall t \in \{i, \dots, i+l-1\}$ となるような時間窓 $[i, i+l]$ ($i > 0, l > 0$) がある場合、このACOのモデルを2次騙し系 (*Second order deceptive system: SODS*) と呼ぶ。これは、もし P に対するACOのモデルが局所最適化手法とならなければ、その2つの組合せが2次騙し系であることを意味する。

2次騙し効果の例は文献 11)–13), 16) などに示されている。文献 16) では、置換問題に対して簡略化したACOのモデルを適用すると2次騙し効果が発生することが示されている。文献 11) では、k-部分木問題において2次騙し効果が発生することが示されている。しかしながら、この場合はAS-更新ルールを用い、かつ局所探索を行わない場合のみこの現象が見てとれる。文献 12), 13) ではジョブショップスケジューリング問題での例が示されている。この問題においては、IB-更新ルールを用い、局所探索を行ったとしても2次騙し効果が発生する。

4. ジョブショップスケジューリング問題

4.1 問題定義

本研究では2次騙し効果が発生することが知られているジョブショップスケジューリング問題 (JSS) を用いてアルゴリズムの性能評価を行う。この問題では、工程 $\mathcal{O} = \{o_1, \dots, o_n\}$ が与えられ、この工程は部分集合の集合 $\mathcal{M} = \{\mathcal{M}_1, \dots, \mathcal{M}_{|\mathcal{M}|}\}$ に分割される。 $\mathcal{M}_i \in \mathcal{M}$ 内の工程は同じ機械で処理される。 \mathcal{O} は別の集合 $\mathcal{J} = \{\mathcal{J}_1, \dots, \mathcal{J}_{|\mathcal{J}|}\}$ にも分割され、工程の集合 $\mathcal{J}_j \in \mathcal{J}$ をジョブと呼ぶ。さらに、処理時間 $p(o) \in \mathbb{N}$ が各工程 $o \in \mathcal{O}$ に対して与えられる。また、各ジョブ $\mathcal{J}_j \in \mathcal{J}$ に対して順列 $\pi^{\mathcal{J}_j}$ が与えられる。この順列は同一ジョブ内の工程の処理順序 (技術的順序と呼ばれる) を決定する。以下では順列 π が与えられたとき、 $\pi(l)$ を π の l 番目の位置にある工程とする。2つの工程 $o_i = \pi(l)$ と $o_j = \pi(k)$ について $l < k$ であるとき、 $o_i \preceq o_j$ と書く。工程 $o_i \in \mathcal{O}$ の先行工程は次式で与えられる。

$$\text{pred}(o_i) \leftarrow \{o_j \in \mathcal{O} | o_j \preceq o_i\} \quad (7)$$

各機械は同時に複数の工程を処理することはできないものとし、また、工程の割込みは発生しないものとする。さらに、同じジョブに属する工程は技術的順序を守って処理しなければならない。

解 $s = (\pi^{\mathcal{M}_1}, \dots, \pi^{\mathcal{M}_{|\mathcal{M}|}})$ は $\mathcal{M}_i, \forall i \in \{1, \dots, |\mathcal{M}|\}$ 内の工程の順列 $\pi^{\mathcal{M}_i}$ によって与えられる。これらの順列は各機械 \mathcal{M}_i における工程の処理順序を決定する。なお、特定の順列においては処理順序の循環が生じるため、実行可能解にならない順列も存在する。

解のコストを評価するにはいくつかの基準があるが、本研究ではメイクスパンの最小化を目的とする。解 s に対して、すべての工程 $o \in \mathcal{O}$ に最早開始時刻 $t_{es}(o, s)$ が定義される。すべてのジョブは時刻0から開始できるとする。解 s に対して、工程 $o \in \mathcal{O}$ の最早完了時刻 $t_{ec}(o, s)$ は $t_{es}(o, s) + p(o)$ と定義される。このとき、解 s の目的関数値は次式で定義される。

$$f(s) \leftarrow \max \{t_{ec}(o, s) | o \in \mathcal{O}\} \quad (8)$$

4.2 モデル化

すべての工程の順列を考えると、そのうちいくつかはJSSの解を表現する。これは、そのような順列には機械ごとの順列も含まれているからである^{*1}。Colormiらはこの表現に基づき、以下のようなモデル $\mathcal{P}_{\text{JSS}}^{\text{SUC}}$ を提案している¹⁷⁾。まず、工程の集合 \mathcal{O} に処理時間が0のダミー工程 o_0, o_{n+1} を加える。工程 o_0 はすべてのジョブの起点となり、工程 o_{n+1} は終点となる。よって、工程の集合は $\mathcal{O} = \{o_0, o_1, \dots, o_n, o_{n+1}\}$ となる。そして、各工程 o_i に対して決定変数 X_i を定義する。ただし、 $i \in \{0, \dots, n\}$ である。決定変数 X_0 のドメインは $D_0 = \{1, \dots, n\}$ であり、他の決定変数 X_i のドメインは $D_i = \{1, \dots, n+1\} \setminus i$ である。決定変数 X_i に値 $j \in D_i$ を割り当てることは、全工程の順列において o_i のすぐ後に o_j が位置することを意味する。また、決定変数 X_i とその値 $j \in D_i$ の組合せをコンポーネント c_i^j とする。よってフェロモン \mathcal{T} は各コンポーネント c_i^j に対応するフェロモンパラメータ τ_i^j で構成される。

スケジュールの構築にはリストスケジューラアルゴリズムを用いる。このアルゴリズムでは、割当て候補となる工程の集合 \mathcal{O}_t から1つの工程を取り出し、その工程を割り当てる処理を n 回繰り返すことによって、全工程の順列を左から右に向かって構築する。 \mathcal{O} は次のように定義される。

*1 ただし、一般的には実行可能な順列から解への写像は多対1の関係にある。

$$\mathcal{O}_i \leftarrow \{o \in \mathcal{O}^+ | \text{pred}(o) \cap \mathcal{O}^+ = \emptyset\} \quad (9)$$

ここで、 \mathcal{O}^+ は割り当てられていない工程の集合である。

ACO の解の構築は以下のように行う。 i_c を直前に割り当てた工程のインデックス番号とする。まず、部分解 $s^P = \langle \rangle$ とし、 $i_c = 0$ とする。その後、コンポーネント $c_{i_c}^j \in \mathfrak{N}(s^P)$ を s^P へ追加していく。ただし、

$$\mathfrak{N}(s^P) = \{c_{i_c}^k | o_k \in \mathcal{O}_i\} \quad (10)$$

とする。 s^P にコンポーネント $c_{i_c}^j$ を追加したときは、 $i_c \leftarrow j$ として引き続き処理を行う。追加するコンポーネントは次式の確率分布に従って決定する。

$$p(c_{i_c}^j | \mathcal{T}) = \frac{[\tau_{i_c}^j]^\alpha}{\sum_{c_{i_c}^k \in \mathfrak{N}(s^P)} [\tau_{i_c}^k]^\alpha}, \quad \forall c_{i_c}^j \in \mathfrak{N}(s^P) \quad (11)$$

これは式 (1) の分布と同じであるが、ヒューリスティック情報は用いていない。

$\mathcal{P}_{\text{JSS}}^{\text{succ}}$ モデルでは IB-更新ルールを用いたとしても、2 次騙しの効果による評価値の減少を防ぐことができない^{9),10)}。このため、別のモデル $\mathcal{P}_{\text{JSS}}^{\text{pos}}$ ¹⁸⁾、 $\mathcal{P}_{\text{JSS}}^{\text{rel}}$ ⁹⁾ が提案されており、このモデルを用いることで 2 次騙し効果を抑制することができる。しかしながら、本研究の目的はフェロモン更新ルールを改良することによって、モデルの変更をせずに 2 次騙し効果を防ぐことであるため、これらのモデルは用いず、探索バイアスの影響が明確に見てとれる $\mathcal{P}_{\text{JSS}}^{\text{succ}}$ モデルを用いて性能の評価を行う。

なお、JSS においては別のモデルを用いたとしても探索バイアスによる悪影響が生じる。 $\mathcal{P}_{\text{JSS}}^{\text{pos}}$ モデルでは 2 次騙し効果を完全には抑制できておらず、IB-更新ルールを用いた場合は問題ないが、AS-更新ルールを用いた場合には平均評価値が低下していく。 $\mathcal{P}_{\text{JSS}}^{\text{rel}}$ モデルでは評価値が高い解へのバイアスがかかるため、2 次騙し効果による平均評価値の低下は発生しない。しかしながら評価値が高い解であっても、その中に最適解 s^* が含まれている保証がなく、大域的な最適化を目指す場合には悪影響となる可能性がある。

4.3 2 次騙しの例

文献 9) では以下の小規模な問題例 (jss_simple_inst) における 2 次騙しの発生例を示している。

$$\mathcal{O} = \{o_1, o_2, o_3, o_4\}$$

$$\mathcal{J} = \{\mathcal{J}_1 = \{o_1, o_2\}, \mathcal{J}_2 = \{o_3, o_4\}\}$$




図 2 jss_simple_inst の探索木
Fig. 2 Search tree of instance jss_simple_inst.

$$\mathcal{M} = \{\mathcal{M}_1 = \{o_1, o_4\}, \mathcal{M}_2 = \{o_2, o_3\}\}$$

$$p(o_1) = p(o_4) = 10$$

$$p(o_2) = p(o_3) = 20$$

この問題において、前述のリストスケジューラアルゴリズムを用いて解を構築する際の探索木を図 2 に示す。生成される解は s_1, \dots, s_6 の 6 つである。目的関数値は、 $i = 1, 6$ のとき $f(s_i) = 60$ であり、 $i = 2, 3, 4, 5$ のとき $f(s_i) = 40$ である。評価値は $F(s_i) = 1/f(s_i)$ として与える。

この問題で 2 次騙し効果が発生する仕組みは以下のように説明できる。部分解が $s^P = \langle c_0^1 \rangle$ のとき (図 2 において $0 \rightarrow 1$ とたどったとき) を考えると、次に加えられるコンポーネントの候補は c_1^2 と c_1^3 である。ここで、 c_1^2 は 3 つの解 s_1, s_4, s_6 に含まれるのに対し、 c_1^3 は s_2, s_3 の 2 つの解にしか含まれない。よって、フェロモン量 τ_1^2 には 1 つの最適解 (評価値 $1/40$) と 2 つの準最適解 (評価値 $1/60$) から新たなフェロモンが加えられるのに対し、 τ_1^3 には 2 つの最適解からしか新たなフェロモンが加えられない。つまり、 τ_1^2 には τ_1^3 よりも多くのフェロモンが加えられやすいといえる。また、対称的な構造により、 τ_3^4 と τ_3^1 にも同様のことがいえる。したがって、反復を繰り返すごとに、準最適解 s_1, s_6 の生成確率が上昇し、最適解 s_2, s_3, s_4, s_5 の生成確率が減少していく。

この問題に対して、AS-更新ルールを用いる ACO を適用した結果を図 3 に示す。図 3(a) には、3 章で示した簡略化モデルにおける理論的な期待更新ルールを用いたときの期待評価値の推移を、図 3(b) には通常の AS-更新ルールを適用したときの平均評価値の推移を示す。

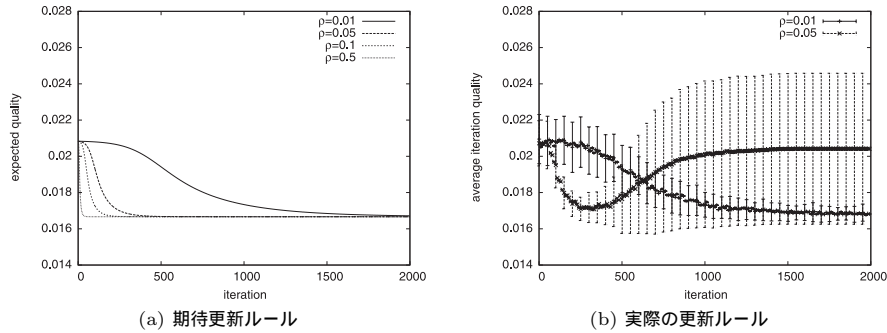


図 3 AS-更新ルールを用いたときの評価値の推移．同様の結果が文献 9) に示されている
Fig. 3 Performance of AS-update rule. Comparable results have been shown in Ref. 9).

これは $n_a = 10$ とし、100 回の試行を行ったときの平均であり、エラーバーは標準偏差を表す．反復を繰り返すごとに、評価値が減少していることが分かる．なお、通常の更新ルールを用い、 $\rho = 0.05$ としたときに標準偏差が増加しているのは、高い学習率によって良い解にも悪い解にも収束しうるためである．

5. 提案手法

5.1 概要

探索バイアスは適切なフェロモンのモデル化を行うことで抑制することができる^{9),14),18)}．しかしながら適切なモデルの設計には経験的な知識が必要であり、容易にそのようなモデルが得られない場合もあると考えられる．そこで、適切でないモデルを用いることで 2 次騙し効果が多少発生したとしても実用上問題のない性能が得られるように、フェロモン量更新ルールの改良によりバイアスを抑制する方法を検討する．なお、更新ルールの改良と適切なフェロモンのモデル化の両方を行うことでさらなる性能向上を実現できると考えられるが、本論文ではルールの改良のみでも実用上問題ない性能が得られることを目指す．

4.3 節で示したように、ACO ではより多くの実行可能解に含まれるコンポーネントほどフェロモン量が増加しやすい．よって、多くの解に含まれるコンポーネントのフェロモン増加量を減らし、少ない解にしか含まれないコンポーネントのフェロモン増加量を増やすことで、このバイアスを抑制できると考えられる．そこで、以下のフェロモン量更新ルールを提案する．

$$\tau_i^j \leftarrow \begin{cases} (1 - \rho) \tau_i^j + \frac{\rho}{|\mathcal{G}_i^j|} \sum_{s \in \mathcal{G}_i^j} F(s) & |\mathcal{G}_i^j| > 0 \\ \tau_i^j & \text{otherwise} \end{cases} \quad (12)$$

ただし、 $\mathcal{G}_i^j = \{s \in \mathcal{G}_{upd} | c_i^j \in s\}$ とする．

この更新ルールでは、1 回の反復でコンポーネント c_i^j を含む解が複数生成された場合は、その評価値の平均をフェロモンの増加量とする．多くの解に含まれるコンポーネントには、1 回の反復で多くの解からフェロモン量の増加が行われるため、その偏りを抑制するために平均をとる．また、コンポーネント c_i^j が含まれる解が生成された場合にフェロモン量の更新を行い、1 つも生成されない場合は更新を行わない．少ない解にしか含まれないコンポーネントにはフェロモン量の増加が起こりにくいのが、通常のルールでは蒸発は毎回の反復で行われるため、急速にフェロモン量が減少してしまう．これを防ぐために、フェロモンの蒸発は分泌が発生するときのみ行う．

なお、フェロモン量の更新処理に用いる解の集合 \mathcal{G}_{upd} の設定法によって、次の 2 つの更新ルールを定義する．式 (3) の設定法を用いるルールを AS-proposal ルールと呼び、式 (4) の設定法を用いるルールを IB-proposal ルールと呼ぶ．

5.2 提案ルールの性質

3 章と同様に、 $n_a = \infty$ と仮定したときに期待されるフェロモン量更新について考える． $n_a = \infty$ とすると、大数の法則により AS-proposal ルールは以下ようになる．

$$\tau_i^j(t+1) \leftarrow (1 - \rho) \tau_i^j(t) + \rho \sum_{s \in \mathcal{G}_i^j} F(s) \cdot \mathbf{p}(s|T, X_i = v_i^j) \quad (13)$$

ただし、 $\mathcal{G}_i^j = \{s \in \mathcal{G} | c_i^j \in s\}$ となる． $\mathbf{p}(s|T, X_i = v_i^j)$ は $X_i = v_i^j$ と固定したときに解 s が生成される確率である．ここで、

$$W_F(T|X_i = v_i^j) := \sum_{s \in \mathcal{G}_i^j} F(s) \cdot \mathbf{p}(s|T, X_i = v_i^j) \quad (14)$$

は $X_i = v_i^j$ としたときに生成される解の期待評価値である．よって提案する更新ルールでは、期待評価値の高いコンポーネントほどフェロモンの増加量が多くなる．

フェロモン量の上限值、下限値は以下のように得られる．提案する更新ルールにおいてフェロモン量 τ_i^j の増加量が最大となるのは、 c_i^j を含む解の中で、評価値が最大となる解のみが \mathcal{G}_i^j に含まれる場合である．この場合の評価値を $F_i^{j, \max} := \max_{s \in \mathcal{G} | c_i^j \in s} \{F(s)\}$ とす

ると、提案する更新ルールは

$$\tau_i^j(t+1) \leftarrow (1-\rho)\tau_i^j(t) + \rho F_i^{j\max} \quad (15)$$

となる．この一般項は、

$$\tau_i^j(t) = (1-\rho)^t \cdot c + \rho \sum_{k=0}^{t-1} (1-\rho)^k F_i^{j\max} \quad (16)$$

となり、フェロモン量の極限值は、

$$\lim_{t \rightarrow \infty} \tau_i^j(t) = F_i^{j\max} \quad (17)$$

となる．よってフェロモン量の上限値は $\max\{F_i^{j\max}, c\}$ となる．下限値は上限値の場合と同様に、 c_i^j を含む解の中で、評価値が最小となる解のみが \mathcal{G}_i^j に含まれる場合を考えればよい．この場合の評価値を $F_i^{j\min} := \min_{s \in \mathcal{G}_i^j | c_i^j \in s} \{F(s)\}$ とすると、このときのフェロモン量の極限值は

$$\lim_{t \rightarrow \infty} \tau_i^j(t) = F_i^{j\min} \quad (18)$$

であり、下限値は $\min\{F_i^{j\min}, c\}$ として得られる．以上より、提案するフェロモン量更新ルールでは、暗黙的にフェロモン量の上下限値が設定されることになる．このような上下限値は ACS³⁾ においては暗黙的に、MMAS⁵⁾ においては明示的に設定されている．しかしながら、MMAS においてはすべてのコンポーネントにおいて同じ上下限値が設定され、ACS では上限値はコンポーネントごとに異なる値が設定されるが、下限値は同じ値が設定される．これに対して、提案手法では上限値、下限値ともにコンポーネントごとに異なる値が設定されることになる．

5.3 従来手法との比較

4.3 節と同様に、jss_simple_inst に対して AS-proposal ルールを用いる ACO を適用した結果を図 4 に示す．図 4(a) には、簡略化モデルにおける理論的な期待更新ルールを用いたときの期待評価値の推移を、図 4(b) には通常の更新ルールを適用したときの平均評価値の推移を示す．提案ルールを用いる場合、反復を繰り返すごとに評価値が上昇していることが分かる．

なお、ACO のパラメータは $\alpha = 10.0$ 、 $c = 0.5$ とした． α パラメータについては AS など従来の ACO アルゴリズムでは 1.0 とすることが多いが、提案手法ではそれに比べ大きい値を設定しなければ良好な性能が得られない．これは提案する更新ルールでは、コンポーネ

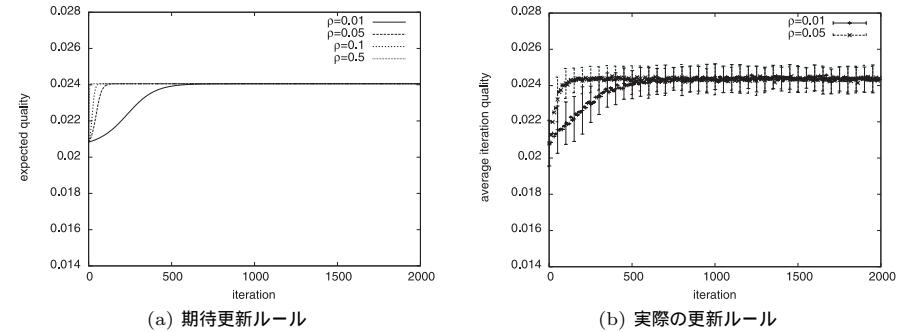


図 4 AS-proposal ルールを用いたときの評価値の推移
Fig. 4 Performance of AS-proposal rule.

ントが含まれる解が生成された場合のみフェロモン量の更新が行われるため、各コンポーネントのフェロモン量の差が小さくなるのが原因である．この状態では式 (11) によって与えられるコンポーネント選択確率の差が非常に小さくなり、ランダムにコンポーネントを選択することと変わらなくなる．よって、選択確率の差を大きくして適切な選択が行われるように α パラメータを大きく設定しなければならない．

6. 性能評価実験

文献 9) と同様に、JSS のベンチマーク問題である、ft10¹⁹⁾ と orb08²⁰⁾ を用いて性能評価を行う．ここでは平均評価値の推移とともに、以下の式で定義される sequencing factor の推移も調べる．

$$f_{seq}(\pi) \leftarrow \frac{\sum_{i=1}^{n-1} \delta(\pi, i, i+1)}{\sum_{J_j \in \mathcal{J}} (|J_j| - 1)} \quad (19)$$

ここで、 $\delta(\pi, i, i+1)$ は順列 π の i 番目にある工程と、 $i+1$ 番目にある工程が同じジョブに属する場合に 1 となり、そうでなければ 0 となる関数である． P_{JSS}^{seq} モデルを用いる場合、探索バイアスによって f_{seq} の高い解が生成されやすいことが分かっている⁹⁾．

各更新ルールを適用した結果を図 5 に示す．なお、ACO のパラメータは AS-更新ルールでは蒸発率 $\rho = 0.1$ 、初期フェロモン量 $c = 0.5$ とし、IB-更新ルールでは $\rho = 0.03$ 、 $c = 0.5$ とした．これらは文献 9) と同様の結果が得られるように設定した．提案するルールを適用

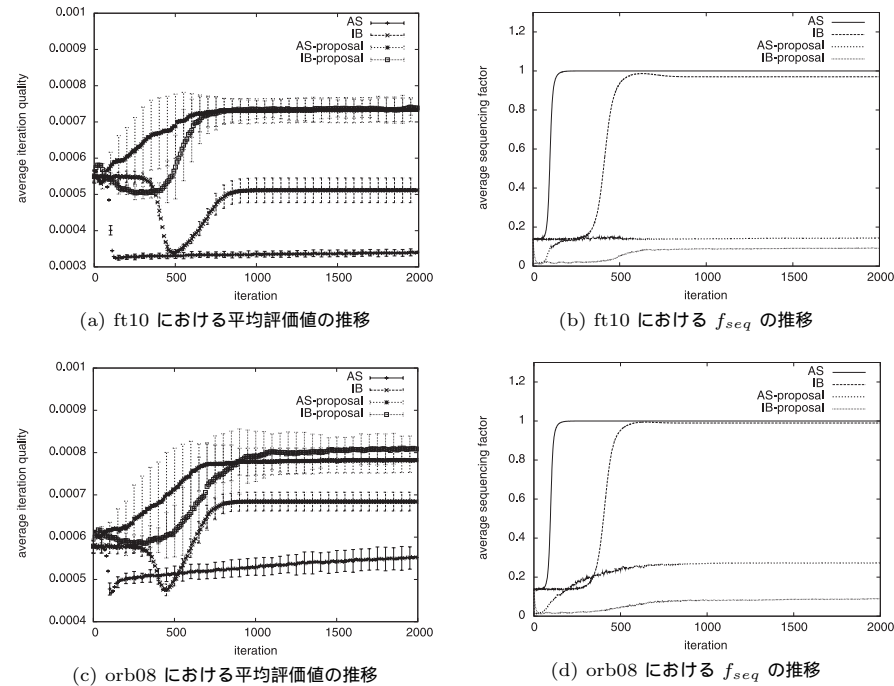


図 5 ベンチマーク問題における各手法の性能

Fig. 5 Comparison of performance on benchmark instances.

する場合, AS-proposal ルールでは $\alpha = 80$, $\rho = 0.3$, $c = 0.001$ とした. IB-proposal ルールでは $\rho = 0.4$ とし, 他のパラメータは AS-proposal ルールと同様の値を用いた. これらは事前実験により良好な結果を示した値である. なお, α パラメータは小さすぎるとコンポーネントの選択が正しく行われなくなるので性能が低下する. また大きすぎても初期収束が発生するため性能低下が見込まれる. 本実験では $\alpha = 80$ と設定したが, 70~120 程度では良好な性能を示すことを確認している. 蒸発率 ρ については既存の ACO アルゴリズムと同様に, 大きい場合は収束が早まるが性能が低くなり, 小さい場合は収束が遅くなるが性能は高くなる. 初期フェロモン量 c については, 探索の初期段階において想定されるフェロモン分泌量よりも, 多少大きい値に設定することが良いとされている¹⁾. 提案手法においてもそのような傾向があり, 本実験で採用した $c = 0.001$ は, ft10 および orb08 において

はこの分泌量の 1.7 倍程度である. また分泌量は問題によって異なるため, 初期化処理の際にいくつかの解を生成し, その結果より初期の分泌量を推定することで自動的に設定する方法が有効であると考えられる.

提案する更新ルールを用いることで, 平均評価値が通常の更新ルールに比べ向上している. しかしながら, 探索の初期段階では性能の低下が見られる. 提案ルールでは, あるコンポーネントを含む解が生成されない場合, そのコンポーネントのフェロモン量は変化しない. また, 前述のパラメータ設定では初期フェロモン量に比べてフェロモン増加量は小さい値となる. よって, 探索の初期では更新処理によりフェロモン量が減少し, 対応するコンポーネントが選ばれにくくなる. \mathcal{P}_{JSS}^{suc} モデルを用いると f_{seq} の高い解が生成されやすいため, この段階では f_{seq} が急激に減少することになる. その後, 他のコンポーネントにも更新処理が行われ, 全体のフェロモン量が均一化するため, f_{seq} も上昇する. 有効な探索はこの初期段階の後から始まり, 平均評価値が上昇していく.

なお, $\mathcal{P}_{JSS}^{rel(9),12)}$ など適切なフェロモンモデルを用いた手法に比べると, 提案手法の性能は低いといえる. この原因として, 探索バイアスを抑制しつつフェロモンパラメータの学習を行わなければならないため, 有効な探索が行いにくいことがあげられる. 適切なモデルを用いる方法では, バイアスについては考慮せずに学習を行えばよいので, 有効な探索をより簡単に行えると考えられる.

次に, 文献 9) で提案されている問題である patho_1 における性能評価を行う. この問題は 10 ジョブ, 10 機械からなり, 1 つのジョブには 10 工程が含まれる. ジョブ内の工程は第 1 工程は機械 \mathcal{M}_1 , 第 2 工程は機械 \mathcal{M}_2 というように, 各機械で順に処理する. 機械 \mathcal{M}_j で処理する工程 o の処理時間は $p(o) = 110 - (10 \times j)$ とする. この問題では f_{seq} が大きいほど評価値も高くなるため, 通常の AS-更新ルール, IB-更新ルールを用いれば最適解を簡単に求めることができる. なお, 最適解は f_{seq} が 1 (最大値) となる解である. しかしながら, このような問題の特性は JSS の一般的な問題とは異なる⁹⁾. ft10 や orb08 を含めた既存のベンチマーク問題やランダムに生成した問題例においては, f_{seq} が大きくなるほど評価値が減少する傾向がある. これに対し, patho_1 では f_{seq} が大きいほど評価値が上昇する.

各更新ルールを適用した結果を図 6 に示す. ACO のパラメータは AS-更新ルール, IB-更新ルールでは $\rho = 0.1$, $c = 0.5$ とした. 提案するルールを適用する場合は, AS-proposal ルールでは $\alpha = 80$, $\rho = 0.05$, $c = 0.001$ とした. IB-proposal ルールでは $\rho = 0.3$ とし, 他のパラメータは AS-proposal ルールと同様に設定した. 提案するルールを適用した場合,




図 6 patho_1 における各手法の性能
Fig. 6 Comparison of performance on instance patho_1.

従来手法に比べ平均評価値は減少しているが、最終的には比較的良好な解に収束している。図 5 の結果と合わせると、提案するルールを適用することで f_{seq} に関する特性によらず最適化できるといえる。

patho_1 においては、 \mathcal{P}_{JSS}^{sus} モデルを用い AS-更新ルールなどの従来の更新ルールを適用する場合が最も性能が高く、 \mathcal{P}_{JSS}^{rel} などの適切なフェロモンモデルを用いる方法もそれに比べて低い性能となる⁹⁾。また、この問題における提案手法の性能は、適切なモデルを用いる手法と同等程度である。ft10 および orb08 での結果と合わせて比較すると、適切なモデルを用いる手法に比べて提案手法の性能は多少劣るといえる。しかしながら、適切なモデルを用いたとしても探索バイアスによる悪影響を完全には抑制できないため、さらなる性能向上のためには適切なモデル化と更新ルールの改良の両方が必要であると考えられる。

7. おわりに

本研究では 2 次騙し効果を軽減するための新しいフェロモン量更新ルールを提案した。提案するルールでは、簡略化したモデルを jss_simple_inst 問題に適用した場合に期待評価値が上昇していくことを示し、また代表的なベンチマーク問題である ft10, orb08 を用いた性能評価実験の結果、提案する更新ルールを用いることで通常の更新ルールに比べ良好な性能が得られることが分かった。

今後の課題としては、まず ACO のパラメータの設定があげられる。特に α パラメータについては、一般的には 1.0 とすることが良いとされているが、提案手法ではそれに比べて非

常に大きい値を設定しなければならないなど、従来手法とは設定法が異なる場合もある。より広範な実験によって適切な設定法を確立することとともに、パラメータに依存せず良好な性能が得られるような改良法を検討する必要がある。また、ヒューリスティック情報を表す η 関数や、局所探索を適用した場合の性能を調べる必要がある。これらの処理は ACO の探索に人為的な偏りを与えるため、フェロモン情報のみを用いる場合とは異なると考えられる。

さらに、探索バイアスの抑制による性能低下についても改良の余地がある。4.3 節の例では適切でないコンポーネントが多く解に含まれていたため、提案する更新ルールによりバイアスを抑制することで性能が向上した。反対に、多くの解に含まれるコンポーネントが適切なものであるような問題では、探索バイアスを抑制すると適切なコンポーネントのフェロモン量が増加しにくくなるため、性能が低下すると考えられる。また、6 章で示した patho_1 問題の例では f_{seq} の大きい解ほど評価値が高くなるため、探索バイアスが好ましい影響を与える。よって、バイアスを抑制する提案ルールは従来のルールに比べ性能が低下している。

参考文献

- 1) Dorigo, M. and Stützle, T.: *Ant Colony Optimization*, MIT Press (2004).
- 2) Dorigo, M., Maniezzo, V. and Colnari, A.: The Ant System: Optimization by a Colony of Cooperating Agents, *IEEE Trans. Systems, Man and Cybernetics - Part B*, Vol.26, No.1, pp.29-41 (1996).
- 3) Dorigo, M. and Gambardella, L.M.: Ant Colonies for the Traveling Salesman Problem, *Biosystems*, Vol.43, pp.73-81 (1997).
- 4) Bullnheimer, B., 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*, Vol.7, pp.25-38 (1997).
- 5) Stützle, T. and Hoos, H.H.: *MAX-MIN* Ant System, *Future Generation Computer Systems*, Vol.16, No.9, pp.889-914 (2000).
- 6) Bullnheimer, B., Hartl, R.F. and Strauss, C.: An Improved Ant System Algorithm for the Vehicle Routing Problem, *Annals of Operations Research*, Vol.89, pp.319-328 (1999).
- 7) Bonabeau, E., Dorigo, M. and Theraulaz, G.: Inspiration for Optimization from Social Insect Behaviour, *Nature*, Vol.406, pp.39-42 (2000).
- 8) Dorigo, M., Di Caro, G. and Gambardella, L.M.: Ant Algorithms for Discrete Optimization, *Artif. Life*, Vol.5, No.2, pp.137-172 (1999).
- 9) Blum, C. and Dorigo, M.: Search Bias in Ant Colony Optimization: On the Role of Competition-Balanced Systems, *IEEE Trans. Evolutionary Computation*, Vol.9,

No.2, pp.159–174 (2005).

- 10) Blum, C. and Dorigo, M.: Deception in Ant Colony Optimization, *Proc. ANTS 2004 – 4th International Workshop on Ant Colony Optimization and Swarm Intelligence*, Lecture Notes in Computer Science, Vol.3172, pp.118–129 (2004).
- 11) Blum, C., Sampels, M. and Zlochin, M.: On a Particularity in Model-Based Search, *Proc. Genetic and Evolutionary Computation Conference (GECCO2002)*, pp.35–42 (2002).
- 12) Blum, C. and Sampels, M.: Ant Colony Optimization for FOP Shop Scheduling: A Case Study on Different Pheromone Representations, *Proc. 2002 Congress on Evolutionary Computing (CEC'02)*, pp.1558–1563 (2002).
- 13) Blum, C. and Sampels, M.: When Model Bias Is Stronger than Selection Pressure, *Proc. 7th Int. Conf. on Parallel Problem Solving from Nature*, Lecture Notes in Computer Science, Vol.2439, pp.893–902 (2002).
- 14) Montgomery, J., Randall, M. and Hendtlass, T.: Solution Bias in Ant Colony Optimisation: Lessons for Selecting Pheromone Models, *Computers & Operations Research*, Vol.35, No.9, pp.2728–2749 (2008).
- 15) Blum, C. and Dorigo, M.: The Hyper-Cube Framework for Ant Colony Optimization, *IEEE Trans. Systems, Man and Cybernetics – Part B*, Vol.34, No.2, pp.1161–1172 (2004).
- 16) Merkle, D. and Middendorf, M.: Modelling the Dynamics of Ant Colony Optimization Algorithms, *Evolutionary Computation*, Vol.10, No.3, pp.235–262 (2002).
- 17) Colnari, A., Dorigo, M., Maniezzo, V. and Trubian, M.: Ant System for Job-Shop Scheduling, *Belgian J. Oper. Res. Statis. Comput. Sci. (JORBEL)*, Vol.34, No.1, pp.39–53 (1994).
- 18) Merkle, D. and Middendorf, M.: An Ant Algorithm with a New Pheromone Evaluation Rule for Total Tardiness Problems, *EvoWorkshops*, Lecture Notes in Computer Science, Vol.1803, pp.287–296 (2000).
- 19) Muth, J.F. and Thompson, G.L.: *Industrial Scheduling*, Englewood-Cliffs, N.J., Prentice-Hall (1963).
- 20) Applegate, D. and Cook, W.: A Computational Study of the Job-Shop Scheduling Problem, *INFORMS Journal on Computing*, Vol.3, No.2, pp.149–156 (1991).

(平成 21 年 10 月 19 日受付)

(平成 22 年 2 月 5 日採録)

推薦文

最適化法における 2 次騙し問題を解決するアルゴリズムを提案し、実験によりその有効性を明らかにしたことが評価に値する。

(FIT2009 第 8 回情報科学技術フォーラム プログラム委員長 本位田真一)




大谷 隆浩 (学生会員)

2008 年石川工業高等専門学校専攻科電子機械工学専攻卒業。同年金沢大学大学院自然科学研究科博士前期課程入学。この間、アントコロニー最適化等メタヒューリスティクスの研究に従事。電子情報通信学会、人工知能学会各会員。



越野 亮 (正会員)

2000 年金沢大学工学部電気情報工学科卒業。2002 年同大学院博士前期課程修了。同年富士通(株)入社。2003 年石川工業高等専門学校電子情報工学科助手。2004 年金沢大学大学院博士後期課程数理情報科学専攻修了。博士(工学)。現在、石川工業高等専門学校電子情報工学科講師。この間、推論と探索、メタヒューリスティクスの研究に従事。IEEE, ACM, 電子情報通信学会、日本ロボット学会等の会員



木村 春彦 (正会員)

1979 年東北大学大学院工学研究科情報工学専攻博士後期課程修了。工学博士。同年富士通(株)入社。1984 年金沢大学経済学部助教授。1994 年同大学工学部電気・情報工学科教授。現在、同大学理工研究域電子情報学系教授。ソフトコンピューティングおよび独居老人の介護支援システム等の研究に従事。