

# 適応型確率探索による制約充足問題の解法

水野一徳<sup>†</sup> 犬野均<sup>†</sup> 西原清一<sup>†</sup>

近年、大規模な制約充足問題に対して、確率的探索アルゴリズムにおける局所最適解からの脱出のためのメタ戦略に関する研究が注目されている。代表的なメタ戦略としてシミュレーテッド・アニーリング (SA) 法があげられるが、状態遷移確率を決めるパラメータ（温度）のスケジューリングが難しい。そこで本論文では、このスケジュールを与えられた問題に応じて自動的に決定する手法を提案する。本手法は、まず、異なる温度を持つ集団を複数個生成し、各集団に均等に解候補を割り振る。次に、解に収束するまで探索を行う処理と集団を再編成する処理を繰り返す。探索を行う処理では、確率的山登り法による探索を一定回数行う。集団を再編成する処理では、各集団の評価値を求めて、評価値の低い集団から評価値の高い集団へ解候補を移動する処理を行う。本手法は、SA における温度の時間的な推移を、空間的な分布に置き換えたものである。本手法を大規模、かつ制約密度の低いグラフ色塗り問題に適用して、ランダムな初期値から SA を繰り返す方法より有効であることを詳細な実験で確認した。

## Solving Constraint Satisfaction Problems by an Adaptive Stochastic Search Method

KAZUNORI MIZUNO,<sup>†</sup> HITOSHI KANOH<sup>†</sup> and SEIICHI NISHIHARA<sup>†</sup>

A meta-heuristics for escaping from local optima to solve large constraint satisfaction problems is proposed, which gives a method of automatic temperature control in simulated annealing (SA) approach. First, in our method, several groups with different temperatures are created, in each of which the same number of candidate solutions are stored. Then, the main process is repeated until the system comes to a certain convergence. The main process is composed of two phases: searching, or an ordinal stochastic hill-climbing, and population tuning, or temperature adjustment. As to the latter phase, after evaluating the average adaptation value per each group, migration operations of some number of candidate solutions from groups with lower values to groups with higher values are induced. This method represents a temporal change of the temperature in SA, as spatial distribution of the temperature. The method is applied to large scale graph-coloring problems of sparsely-connected, whose experimental simulations prove our meta-heuristics to be more efficient than randomly restarting SA.

### 1. はじめに

制約充足問題 (Constraint Satisfaction Problem: CSP) とは、離散値をとるいくつかの変数に割り当て可能な値の組合せのうち、与えられたすべての制約を満たすような組合せを探索によって発見する問題である<sup>1)</sup>。CSP は人工知能やパターン処理など様々な分野に広く応用されている。しかし、CSP が解を持つかどうかという判定問題は NP 完全であり、その意味で効率的な汎用解法は存在しない。このため、大規模な CSP に対して、反復改良型の確率的探索アルゴリズム（近似解法）によって、つねに解が得られなくても

確率的に保証された形で任意の 1 つの解を高速に求めようとする研究が盛んに行われている<sup>2)</sup>。

近年、制約違反最少化戦略による山登り法 (Min-Conflicts Hill-Climbing: MCHC<sup>3)</sup>) や相互結合型のニューラルネットワークにガードニューロンという補助ネットを附加した方法 (Guarded Discrete Stochastic Network: GDS<sup>4)</sup>) が比較的良好な結果が得ることができたと報告されている。しかし、これらの探索手法では、探索の途中で局所最適解に陥ってしまう危険性が高いということが指摘されている。そこで、局所最適解から脱出するためのメタ戦略に関する研究が注目されている。

シミュレーテッド・アニーリング (Simulated Annealing: SA) は、状態遷移確率を決めるパラメータ（温度）の値を変化させることにより、大域的探索か

<sup>†</sup> 筑波大学電子・情報工学系

Institute of Information Sciences and Electronics, University of Tsukuba

ら徐々に局所的探索に移行させ、大域的最適解を求める探索手法として広く用いられている<sup>5)~7)</sup>。しかし、温度を変化させるスケジューリングが、個々の問題に依存しているため難しいという問題点がある。

本論文では、このスケジューリングを問題に応じて自動的に決定する手法を提案する<sup>15)</sup>。本手法は、まず、解候補の集団を複数個生成し各集団に異なる温度を割り当てる。次に、探索を行う処理と集団を再編成する処理を繰り返すものである。探索を行う処理では、すべての解候補に対して確率的山登り法 (Stochastic Hill-Climbing: SHC) による探索を一定回数行う。集団を再編成する処理では、各集団中の評価値を集団に属する解候補の制約充足度から計算し、評価値が低い集団から評価値が高い集団へ解候補を移動する処理を行う。

以下、2章では、まず、CSPの解法のベンチマークとして広く用いられているグラフ色塗り問題について定義する。次に、従来手法とその問題点について述べる。3章では、提案する手法の基本方針、およびアルゴリズムについて説明する。4章では、ランダムに発生させたグラフ色塗り問題を用いたシミュレーションにより、SHC、ランダムな初期値からSAを繰り返す方法、ならびに本手法の性能を比較検討する。

## 2. 研究分野の概要

### 2.1 対象問題

本論文では、文献3)のグラフ色塗り問題 (Graph-Coloring Problem: GCP) を対象とする。GCPとは、グラフの辺でつながれた隣接する頂点が同じ色にならないように、すべての頂点にある定められた色のうちの1色を塗る問題である。ここでは、GCPを3つ組 ( $V$ ,  $D$ ,  $C$ ) で定義する(図1参照)。 $V = \{v_1, \dots, v_n\}$  は  $n$  個の変数の集合で、各要素はグラフの頂点を表す。 $D = \{R, G, B\}$  は変数に割り当てられる値の集合で、各要素は頂点に塗られる色の候補を表す。 $C = \{c_1, \dots, c_m\}$  は  $m$  個の制約  $c_u$  ( $u = 1, \dots, m$ ) の集合で、 $c_u = (v_p, v_q)$  は  $p$  番目の変数と  $q$  番目の変数の間に制約が存在する、すなわち辺でつながれていることを示す。ここでは、 $c_u = (v_p, v_q)$  は  $v_p$  と  $v_q$  が同じ値を割り当ててはいけないという制約条件を表す。

また、GCPにおける制約密度  $d$  を、変数の数  $n$  と制約の数  $m$  を用いて次式で定義する。

$$d = m/n \quad (1)$$

GCPに関する研究では、グラフの平均次数が4~5の問題が解くのが難しい問題であると報告されてい

$$\begin{aligned} GCP &= (V, D, C) \\ V &= \{v_1, \dots, v_n\} \\ D &= \{R, G, B\} \\ C &= \{c_1, \dots, c_m\} \\ \text{ただし、 } c_u &= (v_p, v_q) \Leftrightarrow v_p \neq v_q \\ n &: \text{変数(頂点)の数} \\ m &: \text{制約(辺)の数} \end{aligned}$$

図1 グラフ色塗り問題  
Fig. 1 Graph-coloring problem.

る<sup>11)</sup>。本論文における制約密度では、それらの問題は  $d = 2 \sim 2.5$  の問題に当たる。本論文では、探索空間が大きく、かつ、制約密度の低い問題を対象とする。具体的には、前者を  $10^{100}$  程度、後者を 5 以下とする。この問題は、探索の手掛かりとなる制約が少ないため、局所最適解が多く存在するといわれており、CSPの近似解法としてしばしば引用される MCHC では、解くのが難しい問題とされている<sup>3)</sup>。

また、本論文では対象問題としてランダムに発生させた GCP を用いるが、GCP は制約密度を変えることにより様々なタイプの問題が生成できる。したがって、提案する手法を GCP に適用することにより、本手法が効率的に解くことができる問題の範囲を明確にできるものと考える。さらに、本論文で得られた結論は、制約密度が同じ他の CSP にも当てはめることができると考えられる。

### 2.2 従来手法とその問題点

2.1節で述べた MCHC の問題点は、解に収束するときは急速に収束するが、そうでないときは局所最適解に捕捉されてしまうという点である。このため、局所最適解からいかに脱出するかというメタ戦略が多数提案されている。解を見つけることができなかった場合に、別の初期値から探索をやり直す戦略<sup>8)</sup>、制約違反している制約の重みを増加させて局所最適解から脱出する戦略<sup>9)</sup>、および、SA が代表的なメタ戦略である。

SA は、統計物理分野における焼なまし過程を模した探索手法として多くの組合せ最適化問題に用いられている。その特徴は、状態遷移確率を決める温度  $T$  の値を大きい値から徐々に小さい値に変化させ、大域的探索から徐々に局所的探索に移行させるという点である。SA のアルゴリズムを図2に示す。

$T$  のスケジューリングに関しては、対数型のアニメーションによって、真の最適解へ収束することが知られている。しかし、これでは非常に長い探索時間を要し、現実的ではない。そこで、通常は図2のようなアニメーション (“for ( $T = T_{\max}; T > T_{\min}; T^* = \gamma$ )”) が用いられている<sup>5)</sup>。しかし、最適なスケジューリン

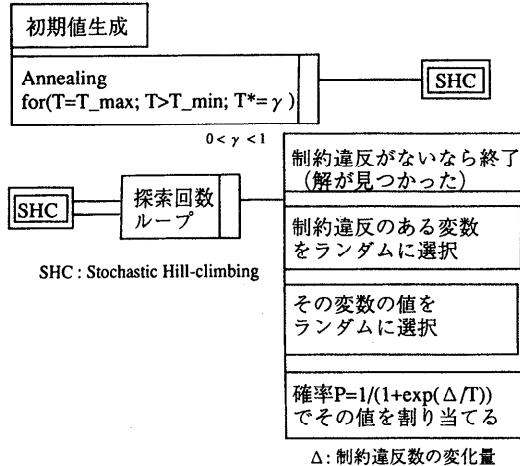


図 2 SA のアルゴリズム

Fig. 2 SA algorithms.

グ ( $T_{\max}$ ,  $T_{\min}$ ,  $\gamma$  の値) が問題に依存しているため、問題ごとのチューニングが必要である。SA 適応化に関する研究も盛んに行われている<sup>7)</sup>が、本論文では、解を発見することができなかった場合、また別の初期値から SA をやり直す (Iterated SA) 方法を、提案する手法と比較する。

### 3. 提案する手法

#### 3.1 基本方針

本論文では、SA における問題点である温度のスケジューリングを、与えられた問題に応じて自動的に決定できる手法を提案する。その基本方針は次の 3 項目である。

- (i) 解候補の集団を複数個生成し、集団ごとに異なる温度を割り当てる。
- (ii) すべての解候補に対して、SHC による探索を行う。
- (iii) 探索の途中で、各集団の評価値を求め、この評価値が低い集団から高い集団へ解候補を移動する処理を行う。

これらにより、対象とする問題に対して適切と思われる温度を持つ集団に、多くの解候補を集めながら探索を進めることができると考えられる。なお、以下では、(iii) の処理を集団の再編成、また解候補を移動する処理を移住処理と呼ぶ。

図 3 は、集団数 = 3、解候補数 = 30 のときの本手法における集団の再編成の例を示したものである。この図では、まず、探索前に 3 集団に各 10 個ずつ解候補が割り振られている。その後、SHC によって一定回数探索を行った結果、 $T = 10$ ,  $T = 5$  の集団から

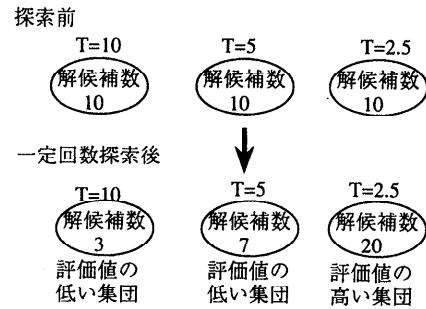


図 3 集団の再編成の例  
Fig. 3 An example of population tuning.

表 1 本論文で用いる記号  
Table 1 The symbols used in this paper.

記号	意味
$M$	解候補の総数
$X_i$	$i$ 番目の解候補
$X_i(p)$	$X_i$ の $p$ 番目に割り当てられている値
$S_j$	$j$ 番目の集団に属する解候補の集合
$N_j =  S_j $	集団 $S_j$ の要素数
$T_j$	集団 $S_j$ の持つ確率パラメータの値
$S_A = \{S_1, \dots, S_{N_A}\}$	すべての集団の集合
$N_A =  S_A $	集団の数

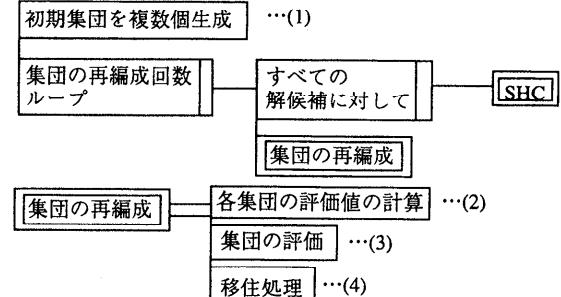


図 4 本手法のアルゴリズム  
Fig. 4 Proposed method algorithms.

それぞれランダムに 7 個、3 個の解候補を取り出して、 $T = 2.5$  の集団に移動したものである。

#### 3.2 アルゴリズム

本論文で用いる記号を表 1、本手法のアルゴリズムを図 4 に示す。本手法は、まず解候補の集団を複数個生成し、次に SHC による探索を行う処理と集団を再編成する処理を繰り返すものである。以下、図 4 の(1)~(4)について説明する。

##### (1) 初期集団を複数個生成

まず、 $M$  個の解候補をランダムに生成する。次に、異なる温度が割り当てられた  $N_A$  個の集団に、生成した解候補を  $M/N_A$  個ずつ均等に割り振る。

## (2) 各集団の評価値の計算

まず、解候補  $X_i$  の制約充足度  $f_i$  と各集団の平均制約充足度  $F_j$  を次式で計算する。

$$f_i = 1 - \left( \sum_{u=1}^m \text{conf}_i(u) \right) / m. \quad (2)$$

ただし、制約  $c_u = (v_p, v_q)$  に対して、

$$\text{conf}_i(u) = \begin{cases} 1 & \text{if } X_i(p) = X_i(q) \\ & \quad (\text{制約違反}). \\ 0 & \text{if } X_i(p) \neq X_i(q) \\ & \quad (\text{制約充足}). \end{cases}$$

$m$ : 制約の数。

$$F_j = \left( \sum_{X_i \in S_j} f_i \right) / N_j. \quad (3)$$

次に、各集団の評価値  $h_j$  を次式によって計算する。ただし、 $F'_{j'}$  は前回集団を再編成したときの  $F_j$  を表し、1回目の集団の再編成時は  $F'_{j'} = 0$  とする。

$$h_j = a \times F_j + b \times |F_j - F'_{j'}|. \quad (4)$$

ただし、 $a, b$ : 定数。

また、評価値  $h_j$  の計算後、 $F'_{j'} = F_j$  とする。

## (3) 集団の評価

各集団の評価値から全集団の平均評価値  $\bar{h}$  を式(5)から計算し、式(6)を用いて、 $\bar{h}$  より評価値が高い集団  $SH$  と評価値が低い集団  $SL$  に分類する。

$$\bar{h} = \left( \sum_{j=1}^{N_A} h_j \right) / N_A. \quad (5)$$

$$SH = \{S_j | h_j \geq \bar{h}\}.$$

$$SL = \{S_j | h_j < \bar{h}\}. \quad (6)$$

ただし、 $j = 1, \dots, N_A$ .

## (4) 移住処理

まず、集団  $S_k \in SL$  から次式により  $B_k$  個の解候補をランダムに取り出す。これにより、評価値の低い集団ほどより多くの解候補が取り出される。

$$B_k = \frac{\bar{h} - h_k}{\sum_{S_j \in SL} (\bar{h} - h_j)} \times N_k. \quad (7)$$

次に、取り出した解候補を集団  $S_r \in SH$  に、次式の確率  $R_r$  で割り振る。これにより、評価値の高い集団ほど確率的により多くの解候補が移動される。

$$R_r = \frac{h_r - \bar{h}}{\sum_{S_j \in SH} (h_j - \bar{h})}. \quad (8)$$

3.1節で示した図3は、 $B_1 = 7$ ,  $B_2 = 3$ ,  $R_3 = 1.0$  の場合の例である。

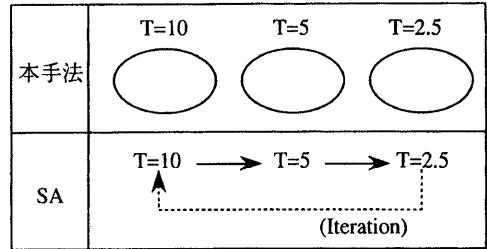


図5 本手法とSAの比較

Fig. 5 Comparison of the proposed method with SA.

## 3.3 本手法の位置付け

図5は本手法とSAを比較したものである。SAでは、温度  $T$  の値を大きい値から徐々に小さい値に変化させている。これに対して、本手法では、SAにおける  $T$  の値に対応する集団をそれぞれ生成している。すなわち、SAにおける  $T$  の時間的な推移を、空間的な分布に置き換えたものである。したがって、本手法はSAでは実現できない、多様なスケジューリングを行うことができるものと考えられる(4.2節参照)。

## 4. 評価実験

### 4.1 実験方法

SHC, SA, 本手法の性能を評価するため、頂点数  $n = 120 \sim 240$ , 色数 = 3 のGCPをランダムに発生させ解探索を試みた。ここでは、制約密度  $2 \leq d \leq 5$  の問題を対象とした。これらの問題における探索空間のサイズはおよそ  $10^{57} \sim 10^{115}$  である。本手法では、解候補数 = 100, 集団数 = 5 とし、各集団における温度はそれぞれ  $T = 10, 5, 2.5, 1.25, 0.625$  とした。これは、SAにおいて、 $10 \geq T \geq 0.625$ ,  $\gamma = 0.5$  とした場合と同じ温度分布である。SAでは、上記の温度スケジューリングで、解を発見することができない場合、別の初期値から探索をやり直す(Iterated SA)ものとした。SHCでは、100個の解候補に対して解探索を行うものとした。これは本手法における集団数 = 1の場合と等価である。また、すべての評価実験において、各手法の総探索回数が同じになるように設定した。ここでは、1ステップの山登りを1回の探索と定義する。1回の探索に要するコストは、1個の解候補の制約違反数を計算するコストに相当する。

性能評価は次の2項目について行った。

#### 【評価項目】

- (1) 探索したGCPのうち、解を発見することができたものの割合(探索成功率: %)
- (2) 解を発見することができたGCPについての平均探索時間(min)とその標準偏差

表 2 パラメータ  $a, b$  の最適化  
Table 2 Experimental results on the optimization  
of parameter  $a, b$ .

$a, b$	1, 0	1, 1	1, 5	1, 10	1, 20	1, 50
suc.	89	88	93	70	48	44
mean	2.65	2.98	2.77	2.95	3.03	3.05
$\sigma$	1.09	1.28	1.14	1.14	1.1	1.27

suc. : 探索成功率 (%)

mean : 平均探索時間 (min)

$\sigma$  : 標準偏差

なお、計算機は IBM Aptiva B75 を使用し、プログラムはすべて C 言語で記述した。

#### 4.2 本手法の特徴

##### 4.2.1 パラメータの最適化

3.2 節で述べた式 (4) のパラメータ  $a, b$  の値を最適化するため、頂点数  $n = 150$ 、制約密度  $d = 2.5$  の GCP を 100 問ランダムに発生させ解探索を行った。表 2 に実験結果を示す。表 2 より、 $a = 1, b = 5$  のときが最適な値であることが分かる。また、このときの解を発見することができた問題 (93 問) について、解候補がどのような集団を移住しながら解に到達したかという追跡調査を行った。この結果より考察される本手法における温度のスケジューリングの典型的なパターンを図 6 (A) に示す。図 6 (A)(a) は解候補が一度も移住せずに解に到達したパターンである。(b) は  $T$  の大きい集団に属する解候補が、探索の初期に  $T$  の小さい集団に移住し解に到達したパターンである。(c) は  $T$  の大きい集団に属する解候補が、探索の初期に  $T$  の小さい集団に移住し、一定時間後さらに  $T$  の小さい集団に移住し解に到達したパターンである。(d) は  $T$  の小さい集団に属する解候補が、一度  $T$  の大きい集団に移住し、再度元の集団に移住して解に到達したパターンである。(e) はランダムに移住しながら解に到達したパターンである。また、図 6 (B) は SA において減少率  $\gamma$  を変えたときの温度スケジューリングの例を示している。これらの図より、SA のスケジューリングが一定であるのに対して、本手法は、問題に応じて、SA と同じようなスケジューリング ((b), (c)) のみならず、SA には実現できないスケジューリング ((d), (e)) も実現できていることが分かる。

##### 4.2.2 考 察

式 (4) の  $a, b$  は、本手法における移住処理、すなわち温度のスケジューリングに大きな影響を与える。特に、式 (4) の第 2 項は、集団の再編成を行うまで探索した結果、どのくらい集団の平均制約充足度が上がったかを評価しているものである。この値が小さいと集団として局所最適解に捕捉されている可能性が高

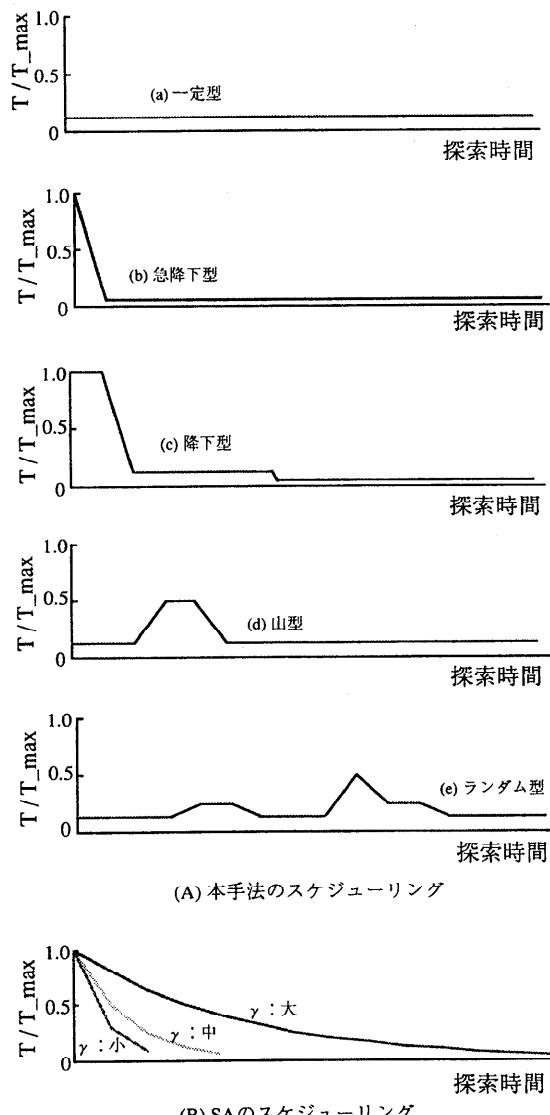


図 6 溫度のスケジューリングパターン  
Fig. 6 Examples of temperature scheduling.

い解候補が多いと考えられる。したがって、重みのパラメータ  $b$  の値を大きくして集団を評価することで、局所最適解に捕捉されている可能性が高い解候補を移住させることができると考える。

本節の評価実験では、パラメータ  $b$  の値が小さいとき、図 6 (A) の (a), (b), (c) のパターンが多くなる。すなわち、SHC や SA と似たスケジューリングパターンになる。しかし、表 2 より、パラメータ  $b$  の値が小さくても比較的探索成功率が高いのは、SHC における  $T$  の値や SA における  $T$  のスケジューリングのようにつねに一定ではなく、 $T$  が小さい値になる、すな

表 3 SHC, 並列 SHC, 本手法に関する実験結果  
Table 3 Experimental results for SHC, parallel SHC and proposed method.

手法	SHC						並列 SHC	本手法
	T	0.313	0.625	1.25	2.5	5	10	
suc.	12	77	99	16	0	0	80	93
mean	2.89	2.77	2.08	3.67	—	—	2.78	2.77
$\sigma$	1.38	1.1	0.78	1.23	—	—	1.24	1.13

suc. : 探索成功率 (%)

mean : 平均探索時間 (min)

$\sigma$  : 標準偏差

わち局所的探索に移行するタイミングが問題や探索状況によって異なっているためであると考えられる。また、パラメータ  $b$  の値が大きいときは、図 6 の (d), (e) のパターンが多くなる。これは、問題に応じて探索の途中でも大域的探索に移行することができる。しかし、表 2 より、パラメータ  $b$  の値を大きくしすぎると移住が頻繁に行われ、解への収束性が失われるため多少探索成功率が低くなっているものと考えられる。

また、本手法では、移住させる解候補はランダムに決めているが、どの解候補を移住させるかを各解候補の制約充足度や制約充足度の変化量などに基づいて決めることが性能の向上を図ることができると思われる。

#### 4.3 SHC との比較

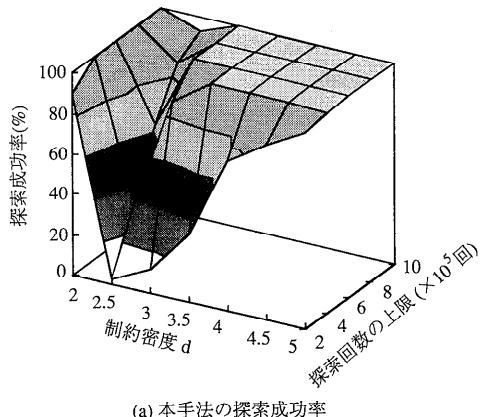
SHC と本手法との性能を比較するために、頂点数  $n = 150$ 、制約密度  $d = 2.5$  の GCP を 100 問ランダムに発生させ解探索を行った。表 3 に実験結果を示す。表 3 の並列 SHC とは、本手法における移住処理を行わずに探索を行うものとする。表 3 より、SHC では探索成功率、平均探索時間ともに  $T$  の値に大きく依存しており、 $T$  を最適化する必要がある。4.2 節において、本手法もパラメータ  $a$ ,  $b$  を最適化しているが、表 2 と表 3 を比較すると、SHC における  $T$  の最適化の方が困難であることが分かる。また、表 3 より並列 SHC と本手法とを比較すると、本手法のほうが優れており、本手法における移住処理が有効であることが分かる。

#### 4.4 SA との比較

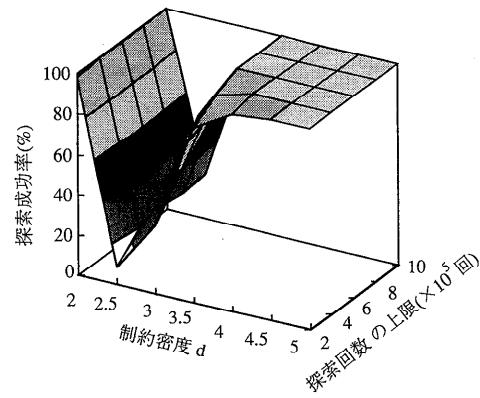
本節では、制約密度、探索空間のサイズの 2 つの指標を変えたときの SA、本手法の性能を比較する。また、一般に近似解法では、探索に要するコストと解の質はトレードオフの関係にあるといわれている。そこで、探索回数の上限を  $2, 4, 6, 8, 10$  ( $\times 10^5$  回) の 5 段階に変えて実験を行った。

##### (1) 制約密度に関する比較

ここでは、頂点数  $n = 150$ 、制約密度  $d = 2, 2.5, 3, 3.5, 4, 4.5, 5$  の GCP を各 100 問ずつ計 700 問ランダムに発生させ解探索を行った。図 7 に実験結果



(a) 本手法の探索成功率



(b) SA の探索成功率

図 7 制約密度に関する実験結果  
Fig. 7 Experimental results on constraint densities.

果を示す。図 7 より、本手法と SA を比較すると、探索回数の上限が  $2 \times 10^5$  回のときは全範囲で SA の探索成功率が上回っている。また、探索回数の上限が  $4 \times 10^5$  回以上のときは  $d = 2$ 、および  $3.5 \sim 5$  では探索成功率がほぼ一致していることが分かる。しかし、 $d = 2.5 \sim 3$  では、SA の探索成功率は大きく悪化しており、探索回数を大きくしても探索成功率はほとんど向上していないことが分かる。これに対して本手法では、探索回数が大きくなるに従って、探索成功率が高くなっていることが分かる。

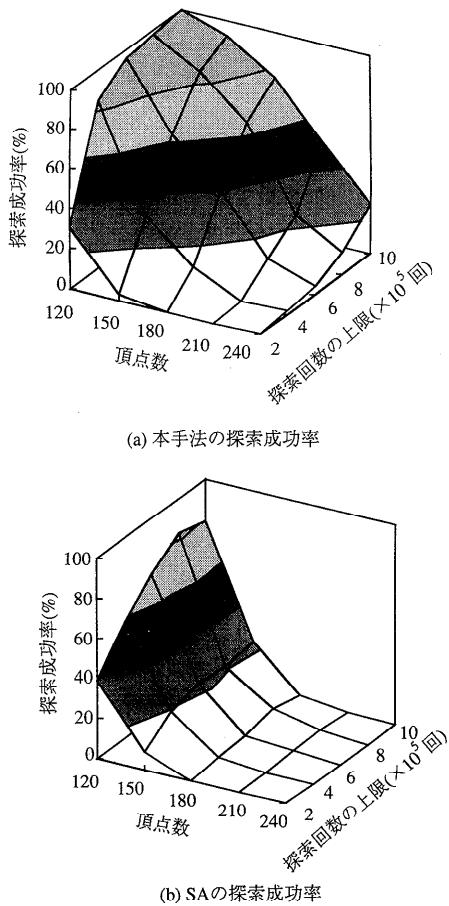


図 8 探索空間のサイズに関する比較  
Fig. 8 Experimental results on the size of search space.

## (2) 探索空間のサイズに関する比較

ここでは、頂点数  $n = 120, 150, 180, 210, 240$ 、制約密度  $d = 2.5$  の GCP を各 100 問ずつ計 500 問ランダムに発生させ解探索を行った。図 8 に実験結果を示す。GCP では、変数の数が大きくなると、探索空間のサイズは指数関数的に大きくなる。図 8 より、SA では、探索空間のサイズが大きくなるに従って、探索成功率が急激に悪化していることが分かる。これに対して本手法では、探索成功率が SA よりも緩やかに悪化しており、全範囲で SA より高い探索成功率であることが分かる。

## 5. おわりに

本論文では、状態遷移確率を決めるパラメータのスケジューリングを、与えられた問題に応じて自動的に決定できる CSP の解法を提案した。本手法は SA における温度の時間的な推移を、空間的な分布に置き換えたものである。また、本手法を大規模かつ制約密度

が低い問題に適用し、SHC, SA よりも有効であることを実験で確認した。CSP は NP 完全問題であるのですべての問題に対して有効な探索手法は存在しない。したがって、問題に依存しないロバスト性の高い探索手法の開発が重要であると考える。本論文における評価実験により、本手法は SA よりもロバスト性の高い手法である可能性が示された。今後は、他の CSP を用いてより詳細な評価実験を行うことにより本手法の適用範囲を明確にすることが重要であると考える。

一般に、CSP の近似解法では、種々のパラメータの調整が難しいということが指摘されている。本手法は、局所最適解からの脱出のためのメタ戦略を山登り法に適用したものであるが、本戦略はニューラルネットワークなどの他の近似解法に対しても有効であると考える。

**謝辞** 本研究を進めるにあたって有益なご意見をいただいた、前本学電子・情報工学系李江洪先生、東京家政学院筑波女子大学鈴木恵美子先生、筑波技術短期大学加藤伸子先生、本学工学研究科内野寛治氏（現（株）富士通研究所）、本学理工学研究科山田弘展氏（現（株）本田技研）に深く感謝いたします。

## 参考文献

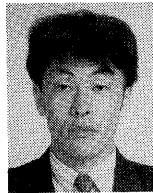
- 1) 西原清一：制約充足問題の基礎と展望、人工知能学会誌, Vol.12, No.3, pp.351-358 (1997).
- 2) 狩野 均：制約充足問題の近似解法、人工知能学会誌, Vol.12, No.3, pp.359-365 (1997).
- 3) Minton, S., Johnston, M.D., Phillips, A.B. and Laird, P.: Minimizing conflicts: A heuristic repair method for constraint satisfaction and scheduling problem, *Artif. Intell.*, 58, pp.161-205 (1992).
- 4) Adorf, H.M. and Johnston, M.D.: A Discrete Stochastic Neural Network Algorithm for Constraint Satisfaction Problems, *IJCNN'90*, pp.917-924 (1990).
- 5) Ackley, D.H.: *A Connectionist machine for Genetic Hillclimbing*, Kluwer Academic Publishers (1987).
- 6) 喜多 一：Hopfield 型ニューラルネットワークとシミュレーテッドアニーリング、人工知能学会誌, Vol.7, No.6, pp.970-979 (1992).
- 7) Rosen, B.E., 中野良平：シミュレーテッドアニーリング—基礎と最新技術、人工知能学会誌, Vol.9, No.3, pp.365-372 (1994).
- 8) Frank, J.: Weighting for Godot: Learning Heuristics for GSAT, *AAAI'96*, pp.338-343 (1996).
- 9) Morris, P.: The Breakout Method for Escaping From Local Minima, *AAAI'93*, pp.40-45

(1993).

- 10) Davenport, A., Tsang, E., Wang, C.J. and Zhu, K.: GENET, A Connectionist Architecture for Solving Constraint Satisfaction Problems by Iterative Improvement, *AAAI'94*, pp.325–330 (1994).
- 11) Hogg, T. and Williams, C.P.: The hardest constraint problems: a double phase transition, *Artif. Intell.*, 69, pp.359–377 (1994).
- 12) Mitchell, D., Selman, B. and Levesque, H.: Hard and Easy Distributions of SAT Problem, *AAAI'92*, pp.459–465 (1992).
- 13) 萩木俊秀：組合せ最適化の手法—巡回セールスマン問題の例から、電気学会論文誌C, Vol.114, No.4, pp.411–419 (1994).
- 14) 松本美幸, 狩野 均, 西原清一：制約違反最少化戦略に基づくハイブリッド GA による制約充足問題の解法, 情報処理学会論文誌, Vol.38, No.5, pp.962–970 (1997).
- 15) 水野一徳, 狩野 均, 西原清一：適応型確率探索による制約充足問題の解法, 情報処理学会研究報告, Vol.97, No.51, 97-ICS-108, pp.1–6 (1997).

(平成 9 年 12 月 11 日受付)

(平成 10 年 6 月 5 日採録)



**水野 一徳** (学生会員)

1972 年生。1996 年筑波大学第三学群情報学類卒業。1998 年同大学院理工学研究科修士課程修了。現在、同大学院工学研究科博士課程在学中。計算機を用いた知識処理、特に制約充足パラダイムにおける探索アルゴリズムの研究に従事。



**狩野 均** (正会員)

1978 年筑波大学第一学群自然学類卒業。1980 年同大学院理工学研究科修士課程修了。同年、日立電線(株)入社。同社オプトロシステム研究所において人工知能・神経回路の応用に関する研究に従事。1993 年より筑波大学電子情報工学系。現在、同助教授。制約に基づく問題解決、遺伝的アルゴリズムの研究に従事。工学博士。1992 年電気学会論文賞受賞。電気学会、計測自動制御学会等各会員。



**西原 清一** (正会員)

1968 年京都大学工学部数理工学科卒業。同年、同大学大型計算機センター助手。1975 年より筑波大学電子・情報工学系。現在、同教授。工学博士。1982~1983 年ヴァージニア工科大学(文部省在外研究員)。グラフィックスと CAD、組合せ探索アルゴリズム、知識処理、制約充足問題、GA の研究に従事。著書に「データ構造」(オーム社)等。1975 年情報処理学会論文賞。電子情報通信学会、人工知能学会、ACM, IEEE 各会員。