

探索点生成メカニズムの競争進化に基づく数値最適化

大西 圭[†] 高木 英行^{††}

本論文では、最適化問題の探索点生成メカニズムの競争進化に基づく最適化の考え方を示し、その考え方に基づいた数値最適化問題のためのアルゴリズムを実現し、ベンチマーク関数を用いて評価する。提案する最適化法における探索点生成メカニズムは、探索点生成領域とその領域内でのサンプリング法を持つ。従来の進化計算の探索点生成メカニズムは選択、交叉、突然変異などの演算であり生成メカニズムの特性自体は一定であった。このメカニズムを確率モデルに置き換える研究アプローチも確率モデルの構成法は固定であった。本論文での議論は、探索点生成メカニズムの構造や特性パラメータを動的に変化させることによって最適化能力を向上させようとする点に本質がある。

Numerical Optimization Based on Competition and Evolution among Generating Mechanisms for Search Points

KEI OHNISHI[†] and HIDEYUKI TAKAGI^{††}

We show a concept of optimization based on competition and evolution among mechanisms that generate search points, and realize an algorithm for numerical optimization problems based on the concept, and evaluate it with several benchmark functions. The mechanisms that generate search points in the proposal concept have (1) areas where search points are generated and (2) sampling methods within their areas. Conventional evolutionary computation (EC) generates new search points by using EC operators, and the characteristics of its mechanism that generates search points does not change. Conventional probabilistic approaches that replace the EC search mechanism with probabilistic models do not change the characteristics of its mechanism that generates search points, too. The essential point of our discussion in this paper is to dynamically change the characteristics of a mechanism that generates search points and aim to increase its optimization capability.

1. はじめに

最適化手法としての従来の進化計算²⁾ (以下 EC) は、(1) 探索点をそれらの持つ適応度に基づき競争させ、(2) その競争に勝ち残った探索点に確率的演算を適用して探索点を進化させる。探索点に対する確率的演算とは、現探索点から新探索点を生成する領域を決め、その領域内に確率的に新探索点をつくるものである。この方法の利点は、適応度ランドスケープに局所的な特徴があることを期待できる最適化問題に対して、その特徴を考慮して設計できることである。局所的な演算が有効に働くためには一般に演算が施される探索点どうしが空間的に近くにある必要がある。しかし、局所探索を重視して探索点が空間的に近い場所に早い段階で集まるような探索点間の競争を行うと、局所解への収束を引き起こす可能性が高くなる。

機能分担仮説⁵⁾ は、EC の 1 つである遺伝的アルゴリズム (以下 GA) についての設計指針であり、探索点を生成する演算と探索点を競争させる方法の役割が示されている。この設計指針に沿う実数値 GA の交叉演算として、単峰性正規分布交叉⁶⁾ (UNDX)、シンプレックス交叉⁴⁾ (SPX) などがあり、優れた探索点の多様性維持の方法として、世代交代モデルである Minimal Generation Gap⁹⁾ (MGG) などがある。

従来の EC がかかえる一般的な問題点は、局所探索効率の良い演算が設計されているとすれば、探索点の分布の制御が探索性能を決める大きな要素であるにもかかわらず、空間的な位置を考慮せず適応度に応じて保持する探索点を決定することや演算の持つ確率的な要素のために保持しておくべき探索点が消失してしまう可能性を持つこと、である。

以上の一般的な EC の問題点に対して、過去の探索点の分布を明示的な構造として学習し、学習で得た構造を探索点生成に利用するアプローチが考えられる。学習に用いられる構造として現在活発に研究が行われているものは確率モデルである⁸⁾。このアプローチ

[†] 九州芸術工科大学大学院

Graduate School, Kyushu Institute of Design

^{††} 九州大学大学院芸術工学研究院

Faculty of Design, Kyushu University

は、現探索点の分布をある確率モデルに従った標本化の結果と考え、実際に現探索点の分布を説明可能な確率モデルを構築し、次の探索点を構築された確率モデルに従い生成する。また、蟻の群生に着想を得た Ant Colony System³⁾ もこのような考え方に基づく方法である。明示的な構造として探索すべき領域情報を持つことにより、偶発的な探索点の消失による探索性能の低下を防ぐことができる。ただし、この方法の探索性能は構造学習能力に依存する。

本論文では、(a) EC と構造学習を用いる方法の持つ考え方を含み最適化手法の考え方を提案し、(b) その考え方に基づく数値最適化問題のためのアルゴリズムを実現し評価する。まず、構造学習を用いる方法からは、探索領域を明示的な構造として保持するという考え方を得る。また、EC からは、競争進化主体の持つ情報を利用して新たな競争進化主体を形成するという考え方を得る。これらの考え方を合わせて、探索領域情報を明示的な構造として持つ探索点生成メカニズムを競争進化主体とする最適化手法とする。探索点生成メカニズムとは、それ自身が持つ領域内にそれ自身で探索点を生成可能なものである。

1 章では研究の背景と目的を示した。以下 2 章では提案する「探索点生成メカニズムの競争進化に基づく最適化」の考え方を説明する。3 章ではその考え方に基づいて数値最適化問題のためのアルゴリズムを提案する。4 章では提案するアルゴリズムを様々なベンチマーク関数に適用し評価する。5 章と 6 章は考察とまとめである。

2. 探索点生成メカニズムの競争進化に基づく最適化

2.1 基本的な考え方

この最適化方法は、探索点生成領域とその領域内に探索点を生成する方法とを持つ様々な探索点生成メカニズムの間に競争進化を生み、その結果として探索すべき領域とその領域内でのサンプリング法を獲得する、というものである。この考え方と同じように探索点生成メカニズム自体を問題に適応させる従来の方法として EC の 1 つである進化戦略¹⁾ (以下 ES) がある。

この最適化方法における競争進化主体は、従来の EC や確率モデルを用いる方法が一般に探索点を競争進化主体とするのに比べるとメタレベルのものである。しかし、基本的には競争進化の原理として EC が用いるような演算が利用できる。また、メタレベルな競争進化主体であるがゆえに確率モデルを用いる方法のように探索領域を構造として明示的に保持できる。




図 1 提案する最適化方法の概要

Fig. 1 Outline of the proposed optimization method.

探索点生成メカニズムの持つ探索点生成領域とその領域内に探索点を生成する方法とを決めるパラメータを以下では**構成要素**と呼ぶ。探索点生成メカニズムと構成要素の関係は、EC における個体と遺伝子の関係、あるいは確率モデルを用いる方法における確率モデルとモデルパラメータの関係、に類似するものである。たとえば、 N 実変数最適化問題のとき、各変数の値を乱数生成ルーチンにより生成するとすれば、乱数発生区間を決めるパラメータと乱数生成ルーチンの種類が構成要素と呼べるものになる。探索点生成メカニズムは、各変数の値を決める乱数生成ルーチン（構成要素）を組み合わせることで N 変数すべての値（探索点）を決めることができるものである。

提案する最適化方法の基本的な流れは以下のようである（図 1）。

- (1) 構成要素の集合を決定する。
- (2) 構成要素を組み合わせる様々な探索点生成メカニズムを構成する。
- (3) 構成した探索点生成メカニズムで複数の探索点を生成してそれらの適応度を計算する。
- (4) 各適応度を当該探索点を生成した探索点生成メカニズムの構成要素に分配する。
- (5) 分配された適応度に基づいて探索点生成メカニズムの構成要素を淘汰生成する。
- (6) (1)～(5)を繰り返す。

さらに、以上の (1)～(6) の手続きを 1 つの単位として階層的に縮小していく探索空間に対して適用する（図 2）。最初はデフォルトの探索空間に対して以上の (1)～(6) の手続きを適用する。ある段階で探索点生成メカニズムの持つ探索点生成領域（デフォルトの探索空間よりも縮小した空間）を次の探索空間として同様の手続きを適用する。またさらにある段階で探索点生成メカニズムの持つ探索点生成領域（さらに縮小した空間）を次の探索空間として同様の手続きを適用する。このように同手続きを縮小していく探索空間に対して適用していくことで精度の高い解が順次得られていくことを期待する。




図 2 階層的な解探索
Fig. 2 Hierarchical search.

2.2 (μ, λ) -ES との違い

ES の一実現形態である (μ, λ) -ES¹⁾ は、探索点生成メカニズムの特性パラメータを解探索と並行して適応させる。つまり、探索点を決定するガウス乱数が必要とする標準偏差や共分散行列の値を探索点とともに個体にコーディングすることで、探索点が選ばれると同時にその生成メカニズムも強化保持する。このとき、個体の一部である探索点はガウス乱数が必要とする期待値にもなる。

以上の (μ, λ) -ES の方法は、進化主体が探索点生成領域を明示的に持つ点が提案する最適化の方法と同じである。違いは (1) 競争の主体、(2) 探索点生成メカニズムの特性を適応させる方法、にある。

まず、 (μ, λ) -ES における競争主体は探索点であり、探索点が競争に勝ち残る結果としてそれに付随する探索点生成メカニズムも生き残ることになる。このとき、探索点と探索点生成メカニズムは 1 対 1 の関係にある。一方、提案する最適化の方法においては、競争主体は探索点生成メカニズムである。探索点生成メカニズムの適応度を見積もるとき、そのメカニズムにより生成した複数の探索点の適応度を利用するが、このとき探索点と探索点生成メカニズムは多対 1 の関係にある。 (μ, λ) -ES において 1 個の個体から複数の探索点を生成すれば、提案する最適化方法と (μ, λ) -ES は、競争主体の観点から類似点を持つと考えられる。

次に、 (μ, λ) -ES においては本来の目的である解探索と付随して探索点生成メカニズムの特性の適応が起こるため、その適応は連続的な過程となる。一方、提案する最適化方法は、 (μ, λ) -ES と同様に連続的な適応過程を持つが、図 2 に示す階層の導入に見られるように断続的な適応過程も持つ。

3. 数値最適化のためのアルゴリズムの提案

2.1 節に示した最適化方法の考え方に基づいた数値最適化問題のためのアルゴリズムを提案する。これは、2.1 節に示した考え方に基づいた一実現例である。

提案する数値最適化アルゴリズムの流れを以下に

説明する。以下では N 変数最適化問題を想定している。以下の説明に出てくる N_c , N_m , N_s , N_p , L , K , R_{max} , R_{min} , R_{rc} , R_{rs} , p_m はアルゴリズムの持つパラメータである。

(1) 構成要素の初期化

各変数の値を区間パラメータ（区間の中心となる座標と区間の大きさ）を持つ一様乱数生成ルーチンで生成する。構成要素は、この区間パラメータである。構成要素の数は各変数につき N_c 個とする。区間の大きさは、 $[R_{min}S_i, R_{max}S_i]$ 内にランダムに生成される。ここで、 S_i は、各変数 $(x_i, i = 1, 2, \dots, n)$ の定義域の大きさであり、 R_{min} と R_{max} ($R_{min} < R_{max}$) は、 $[0, 1]$ 内の値である。区間の中心は各変数の定義域内にランダムに生成される。

(2) 探索点生成メカニズム構成

探索点生成メカニズムは、探索点である N 変数の値を同時に決定できる仕組みである。ここでは構成要素を変数ごとに 1 つずつ無作為に選びだし組み合わせる 1 個の探索点生成メカニズムとする。構成される探索点生成メカニズムの数を N_m 個とする。

(3) 探索点生成・適応度計算

N_m 個の探索点生成メカニズムそれぞれが N_s 個の探索点を生成し、それらの適応度を計算する。

(4) 探索点生成メカニズムに適応度を付与

各探索点生成メカニズムで生成した探索点の適応度からそのメカニズムの適応度を算出する。ここでは各メカニズムが生成した探索点の適応度のうち最良のものをそのメカニズムの適応度とする。さらにそのメカニズムの構成要素である区間の中心を最良適応度を持つ探索点座標に合わせる。

(5) 定めた数の探索点を生成したかを判定

生成探索点数があらかじめ定めた数 N_p に達しているかをまず判定する。生成探索点数が N_p に達していなければ次の手続き (6) に進む。最初の探索空間において、生成探索点数が N_p に達していれば、それまでに得られている適応度上位 L 個の探索点生成メカニズムが持つ探索点生成領域をそれぞれ次の探索空間とし、それらに対して手続き (1) から (9) までを新たに実行する。最初の探索空間以外の縮小した探索空間において、生成探索点数が N_p に達していれば、それまでに得られている最良探索点生成メカニズムが持つ探索点生成領域を次の探索空間とし、それに対して手続き (1) から (9) までを新たに実行する。最初の探索空間を第 1 階層とすると、それに続く L 個の縮小した探索空間は第 2 階層となる。同様に L 個のさらに縮小した探索空間は第 3 階層となる。このアルゴリズム

表 1 提案するアルゴリズムの評価に用いるベンチマーク関数

Table 1 Benchmark functions used for the evaluation of the proposed algorithm.

Label	Function	Range of variable
F1	$\sum_{i=1}^N x_i^2$	$x_i \in [-5.12, 5.12]$
F2	$\sum_{i=2}^N \{100(x_1 - x_i^2)^2 + (x_i - 1)^2\}$	$x_i \in [-2.048, 2.048]$
F3	$\sum_{i=1}^N \lfloor x_i \rfloor$	$x_i \in [-5.12, 5.12]$
F4	$0.5 + \frac{\sin^2 \sqrt{\sum_{i=1}^N x_i^2 - 0.5}}{1.0 + 0.001 \sum_{i=1}^N x_i^2}$	$x_i \in [-100, 100]$
F5	$(\sum_{i=1}^N x_i^2)^{0.25} [\sin^2 \{50(\sum_{i=1}^N x_i^2)^{0.1}\} + 1.0]$	$x_i \in [-100, 100]$
F6	$10N + \sum_{i=1}^N \{x_i^2 - 10 \cos(2\pi x_i)\}$	$x_i \in [-5.12, 5.12]$
F7	$418.9829N + \sum_{i=1}^N \{-x_i \sin \sqrt{ x_i }\}$	$x_i \in [-500, 500]$
F8	$(x_1 - 5)^2 + \sum_{i=2}^N \{1000(x_i - 5)^2\}$	$x_i \in [-5.12, 5.12]$
F9	$20 + e - 20 \exp(-0.2 \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}) - \exp\{\frac{1}{N} \sum_{i=1}^N \cos(2\pi x_i)\}$	$x_i \in [-30, 30]$
F10	$\frac{\sum_{i=1}^N x_i^2}{4000} - \prod_{i=1}^N \cos(\frac{x_i}{\sqrt{i}}) + 1$	$x_i \in [-600, 600]$
F11	$-\sum_{i=1}^N \sin(x_i) \sin^{2m}(\frac{ix^2}{\pi}), \text{ where } m = 10$	$x_i \in [0, \pi]$

は、第 K 階層の L 個の探索空間における探索が終了したときに停止する。

(6) 構成要素に適応度分配

探索点生成メカニズムに与えられた適応度をその構成要素にも直接与える。

(7) 構成要素の選択

各変数について適応度上位 N_c 個の構成要素を選択する。

(8) 構成要素の変形

現在の区間の中心と大きさをそれぞれ c, s , 変形後の中心と大きさをそれぞれ c', s' とすると、式 $c' = c + u(-R_{rc}S_i, R_{rc}S_i)$, $s' = s + u(-R_{rs}S_i, R_{rs}S_i)$ により確率 p_m で変形が行われる。ただし、 $u(a, b)$ は区間 $[a, b]$ 内の一様乱数、 S_i は各変数 $(x_i, i = 1, 2, \dots, N)$ の定義域の大きさ、 R_{rc} と R_{rs} は $[0, 1]$ 内の値、である。

(9) (2) に戻る

4. アルゴリズムの実験による評価

4.1 実験目的

実数値 GA などの従来の EC と提案する最適化方法の間の本質的な違いは、探索点生成の方法にある。具体的には、新たな探索点が生成される領域の決定方法が異なる。この違いは、それぞれの最適化方法が持つ解の精度を上げる戦略の違いに関係する。

従来の EC は、競争進化主体である探索点を引数として探索点生成領域を決定する。この場合、個体集団

として保持する探索点が増加すると、それらを引数として決定する探索点生成領域も直接変化することになる。従来の EC の解の精度を上げる戦略は、個体集団として保持する探索点を特定領域に集め、それらを引数として決定する探索点生成領域内の大部分に高い確率でより良い探索領域を包含することである。

一方、提案する最適化方法においては、競争進化主体である探索点生成メカニズム自身が探索点生成領域を保持しており、それらが競争進化することで探索点生成領域は変更される。このとき、各探索点生成メカニズムが生成した探索点は、新たな探索点生成領域の決定に直接利用されず、それらを生成したメカニズムが持つ探索点生成領域の評価に用いられる。高い評価を得た探索点生成メカニズムの持つ構成要素は、新たな探索点生成メカニズムの構成に利用されるので、結果として、高い評価を得た探索点生成メカニズムの持つ探索点生成領域と類似した領域を持つ探索点生成メカニズムがその後増えることになる。しかし、このことは提案する手法の解の精度を上げる中心戦略とはならない。なぜなら、それが必ずしも探索点生成領域の縮小をともしないからである。提案手法の解の精度を上げる中心戦略は、高い評価を得た探索点生成メカニズムの持つ探索点生成領域を、定められた数の探索点が生成されたときに強制的に縮小した探索空間とすることである（階層的な解探索）。

以上の違いによる探索特性の違いを見ることを本実験の目的とする。

表 2 実験に用いるアルゴリズムのパラメータ値

Table 2 Values of the algorithm's parameters for the experiments.

parameter	used value
N_c	50, 100, 200
N_m	500, 1000, 2000
N_s	5
N_p	5×10^5
L	2
K	3
R_{max}, R_{min}	(0.1, 0.02)
R_{rc}, R_{rs}	(0.2, 0.02)
p_m	0.01

4.2 実験条件

3 章において提案したアルゴリズム（以下 PA）を表 1 に示す 11 種類のベンチマーク関数に対して適用し評価する．各ベンチマーク関数の変数の数 N は 20 とする．

実験には表 2 に示すアルゴリズムのパラメータ値を用いる．いくつかのパラメータについては複数の値を用意しており，それらの組合せを考慮するとアルゴリズムのパラメータ値セットは全部で 9 通りある．

比較には実数値 GA（以下 RGA）を用いる．RGA は，世代交代モデルに MGG⁹⁾，交叉演算に BLX- α ⁷⁾ と SPX⁴⁾，突然変異に一様乱数付加，を用いる．MGG のパラメータである交叉演算による子個体生成数は，2 とする．MGG と BLX- α の組合せにおける生存選択は，個体集団からランダムに非復元抽出した親個体 2 個と子個体 2 個の中から最良個体および，ルーレット選択で選んだ 1 個体を選び，それらを個体集団に戻すものとする．MGG と SPX の組合せにおける生存選択は，親個体 21 個と子個体 2 個の中から最良個体および，ルーレット選択で選んだ 1 個体を選び，それらを 21 個の親個体からランダムに非復元抽出した 2 個体の代わりに個体集団に戻すものとする．BLX- α 交叉演算の持つパラメータ α は 0.36 とし，SPX のパラメータである拡張率 ε は $\sqrt{22}$ とする．突然変異率は交叉法を問わず 0.01 とする．個体数は 500 とする．

すべてのアルゴリズムは 2.5×10^6 回適応度を計算したところで 1 回の実行を終了するものとし，各ベンチマーク関数に対して初期乱数値を変えて 50 回適用される．

4.3 実験結果

表 3 に実験の結果を示す．PA は，1 つのベンチマーク関数に対して 9 通りのパラメータ値セットを用いており，表 3 には 9 通りのうち最終的に得られた最良適応度の 50 回平均値が最も良かった結果を，その結果を得たパラメータ値 (N_c, N_m) とともに示す．RGA

は，2 種類の交叉演算を用いており，表 3 にはそのうち良い結果の方を交叉演算名 (BLX- α , SPX) とともに示す．

良い探索性能を得るために，PA は最適解を包含して探索空間を縮小させる必要があり，RGA は交叉演算が決定する探索点生成領域内に高い確率で最適解近傍を包含する必要がある．各ベンチマーク関数に対してそれらのことが実際のどの程度起こったかを示す値を“Opt-PA”と“Opt-GA”とし，それらも表 3 に示す．

Opt-PA は，PA が探索空間を縮小させるとき，その探索空間に最適解を包含した回数を表す．たとえば，50 試行中 10 回包含したとき，10/50，と表記する．

Opt-GA は，RGA の交叉演算が決定する探索点生成領域内に最適解近傍を包含した回数を表す．その値は，50 試行の平均値である．交叉演算が決定する探索点生成領域内に最適解近傍を包含したかどうかの判断の仕方は，交叉演算によって異なる．BLX- α 交叉の場合，2 個の親個体から決定される超立方体内部に，最適解を与える 20 個の変数値のうち 11 個以上の変数値が含まれたとき，探索点生成領域内に最適解近傍を包含したと判断した．SPX の場合，親個体集団から決定される重心点とそれから最も遠くにある親個体までの距離に SPX の拡張率 $\varepsilon = \sqrt{22}$ を乗じた値を半径とする超球の内部に最適解が含まれたとき，探索点生成領域内に最適解近傍を包含したと判断した．

4.4 実験結果に対する考察

4.4.1 結果の解釈の仕方

表 3 からは，最も良い精度の解を得たアルゴリズムはベンチマーク関数によって異なることが分かる．ここでは，RGA の交叉演算が大局的あるいは局所的な適応度ランドスケープに適合するかどうかを基準に実験結果を分類し，それらについて考える．交叉演算が大局的な適応度ランドスケープに適合する，とは，探索空間内に広く分布した探索点を引数として決定する探索点生成領域内に高い確率で最適解近傍を包含できること，を意味するものとし，交叉演算が局所的な適応度ランドスケープに適合する，とは，個体集団が最適解近傍に導かれたときに，それらの探索点を引数として決定する探索点生成領域内に高い確率で最適解近傍を包含できること，を意味するものとする．

交叉演算が実際に適応度ランドスケープに適合しているかどうかの判断は，表 3 に示した“Opt-GA”の値に基づいて行う．交叉演算が大局的にも局所的にも適応度ランドスケープに適合しているとき，解探索全般において Opt-GA の値は大まかに単調増加すると考えられる．また，交叉演算が大局的なそれらのみ適

表 3 実験の結果. 適応度計算回数が 5×10^5 , 10^6 , 1.5×10^6 , 2×10^6 , 2.5×10^6 に達したときの, 最良適応度の平均 (Mean), 最良適応度の標準偏差 (SD), PA の各階層の探索空間に最適解を包含した回数 (Opt-PA), RGA の交叉演算が決定する探索点生成領域に最適解近傍を包含した回数 (Opt-GA), 1 回の実行に要した平均時間 (T), を示す

Table 3 Results of the experiments. This shows the average of the best fitness values (Mean), the standard deviations of those (SD), the number of times which a search space for PA contains the global optimum (Opt-PA), the average of the number of times which an area that RGA crossover operator determines contains the neighborhood of the global optimum (Opt-GA), and the average of calculation times for one implementation (T) at 5×10^5 , 10^6 , 1.5×10^6 , 2×10^6 , and 2.5×10^6 iterations.

			1st (5×10^5)	2nd (10^6)	3rd (1.5×10^6)	2nd (2×10^6)	3rd (2.5×10^6)	T[s]
			L=1			L=2		
F1	PA ($N_c=50$) ($N_m=500$)	Mean	2.0530×10^{-2}	8.9941×10^{-6}	3.7629×10^{-9}	3.7629×10^{-9}	3.4457×10^{-9}	33
		SD	9.1270×10^{-6}	1.9353×10^{-12}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-PA	50/50	46/50	44/50	43/50	43/50	
	RGA (BLX- α)	Mean	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	53
		SD	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-GA	344541	683706	1021521	1359552	1401993	
F2	PA ($N_c=200$) ($N_m=1000$)	Mean	1.7670	4.1377×10^{-1}	4.0896×10^{-1}	3.9239×10^{-1}	3.9055×10^{-1}	36
		SD	5.3804×10^{-2}	4.8452×10^{-2}	4.7980×10^{-2}	4.8066×10^{-2}	4.8047×10^{-2}	
		Opt-PA	50/50	0/50	0/50	0/50	0/50	
	RGA (SPX)	Mean	2.7754	1.6606	1.1491	8.6096×10^{-1}	6.6892×10^{-1}	286
		SD	1.2391×10^{-1}	4.1596×10^{-2}	1.8881×10^{-2}	1.0857×10^{-2}	7.5419×10^{-3}	
		Opt-GA	35011	69542	106735	145640	185876	
F3	PA ($N_c=200$) ($N_m=1000$)	Mean	-120	-120	-120	-120	-120	40
		SD	0	0	0	0	0	
		Opt-PA	50/50	50/50	50/50	50/50	50/50	
	RGA (BLX- α)	Mean	-120	-120	-120	-120	-120	46
		SD	0	0	0	0	0	
		Opt-GA	488044	988044	1488044	1988044	2488044	
F4	PA ($N_c=50$) ($N_m=2000$)	Mean	2.9714×10^{-1}	5.2452×10^{-1}	4.3670×10^{-2}	4.3670×10^{-2}	4.3670×10^{-2}	33
		SD	3.0857×10^{-4}	1.0692×10^{-3}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-PA	50/50	10/50	0/50	5/50	0/50	
	RGA (BLX- α)	Mean	1.1055×10^{-1}	1.1055×10^{-1}	1.1055×10^{-1}	1.1055×10^{-1}	1.1055×10^{-1}	41
		SD	1.2732×10^{-2}	1.2731×10^{-2}	1.2731×10^{-2}	1.2731×10^{-2}	1.2731×10^{-2}	
		Opt-GA	25344	25344	25344	25344	25344	
F5	PA ($N_c=50$) ($N_m=1000$)	Mean	2.0316	3.8963×10^{-1}	2.3343×10^{-1}	1.8791×10^{-1}	1.4385×10^{-1}	35
		SD	9.7479×10^{-3}	2.1322×10^{-2}	5.0576×10^{-2}	2.0387×10^{-2}	1.4508×10^{-2}	
		Opt-PA	50/50	20/50	3/50	22/50	3/50	
	RGA (BLX- α)	Mean	6.4889×10^{-1}	6.4615×10^{-1}	6.4253×10^{-1}	6.3921×10^{-1}	6.3921×10^{-1}	45
		SD	7.7086×10^{-2}	7.6289×10^{-2}	7.1763×10^{-2}	6.8747×10^{-2}	6.8747×10^{-2}	
		Opt-GA	36373	36373	36373	36373	36373	
F6	PA ($N_c=200$) ($N_m=500$)	Mean	5.4971	1.2604×10^{-1}	1.2268×10^{-1}	6.2049×10^{-2}	6.1777×10^{-2}	42
		SD	6.0063×10^{-1}	1.0389×10^{-1}	1.0399×10^{-1}	5.5767×10^{-2}	5.5796×10^{-2}	
		Opt-PA	50/50	23/50	20/50	19/50	18/50	
	RGA (BLX- α)	Mean	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	53
		SD	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-GA	52881	52881	52881	52881	52881	
F7	PA ($N_c=100$) ($N_m=500$)	Mean	27.1536	1.2115×10^{-2}	1.0169×10^{-5}	1.0169×10^{-5}	4.9315×10^{-6}	50
		SD	13.0297	4.0692×10^{-6}	1.0048×10^{-9}	1.0048×10^{-9}	4.9254×10^{-13}	
		Opt-PA	50/50	49/50	46/50	49/50	45/50	
	RGA (BLX- α)	Mean	5.5132×10^{-7}	5.5132×10^{-7}	5.5132×10^{-7}	5.5132×10^{-7}	5.5132×10^{-7}	57
		SD	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-GA	22403	22403	22403	22403	22403	
F8	PA ($N_c=50$) ($N_m=500$)	Mean	15.1815	1.1241×10^{-1}	1.0270×10^{-1}	1.6628×10^{-2}	1.3842×10^{-2}	32
		SD	3.5177	7.7046×10^{-2}	7.5297×10^{-2}	3.0628×10^{-3}	2.9422×10^{-3}	
		Opt-PA	50/50	21/50	7/50	20/50	12/50	
	RGA (BLX- α)	Mean	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	43
		SD	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-GA	408475	908475	1408475	1908475	2408475	
F9	PA ($N_c=50$) ($N_m=1000$)	Mean	1.9227	9.2158×10^{-2}	7.3605×10^{-2}	1.7295×10^{-2}	1.1696×10^{-2}	42
		SD	2.7182×10^{-2}	1.9963×10^{-2}	1.9698×10^{-2}	1.8672×10^{-3}	1.8870×10^{-3}	
		Opt-PA	50/50	31/50	31/50	27/50	23/50	
	RGA (BLX- α)	Mean	6.22×10^{-16}	6.22×10^{-16}	6.22×10^{-16}	6.22×10^{-16}	6.22×10^{-16}	55
		SD	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	under 10^{-18}	
		Opt-GA	153758	153758	153758	153758	153758	
F10	PA ($N_c=100$) ($N_m=1000$)	Mean	1.0760	1.1926×10^{-2}	1.9469×10^{-3}	1.4999×10^{-3}	5.5676×10^{-6}	52
		SD	1.1469×10^{-4}	7.4330×10^{-5}	2.3087×10^{-5}	1.0075×10^{-5}	2.5473×10^{-11}	
		Opt-PA	50/50	50/50	33/50	48/50	33/50	
	RGA (BLX- α)	Mean	1.1336×10^{-3}	1.1336×10^{-3}	1.1336×10^{-3}	1.1336×10^{-3}	1.1336×10^{-3}	62
		SD	1.0010×10^{-5}	1.0010×10^{-5}	1.0010×10^{-5}	1.0010×10^{-5}	1.0010×10^{-5}	
		Opt-GA	106634	106634	106634	106634	106634	
F11	PA ($N_c=100$) ($N_m=1000$)	Mean	-17.5017	-18.9745	-18.9711	-19.0394	-19.0404	66
		SD	4.5242×10^{-2}	3.3437×10^{-2}	3.3395×10^{-2}	2.6880×10^{-2}	2.6848×10^{-2}	
		Opt-PA	50/50	0/50	0/50	0/50	0/50	
	RGA (SPX)	Mean	-19.6364	-19.6369	-19.6370	-19.6370	-19.6370	296
		SD	3.5918×10^{-6}	4.2152×10^{-8}	5.4550×10^{-13}	5.6346×10^{-13}	4.2393×10^{-13}	
		Opt-GA	108080	178905	252261	325727	398589	

合しているとき、解探索前半において Opt-GA の値は大まかに単調増加し、解探索後半にその増加が鈍くなると考えられる。また、交叉演算が局所的なそれらにのみ適合しているとき、解探索前半において Opt-GA の値の増加が鈍く、解探索後半に Opt-GA の値は大まかに単調増加すると考えられる。

4.4.2 F1, F3, F8 について

以上の考え方に従うと、BLX- α 交叉が大局的および局所的な適応度ランドスケープに適合したと判断できるベンチマーク関数は、F1 と F3 と F8 である。また、SPX が大局的および局所的な適応度ランドスケープに適合したと判断できるベンチマーク関数は、F11 である。ただし、F1 と F3 と F8 に対する BLX- α 交叉ほど SPX が F11 に適合しているわけではないことが Opt-GA の値から分かる。

F1 と F8 は、変数間に依存関係のない単峰性関数である。F3 は、階段状の関数であるが、大局的に見ると超平面状の関数である。これらの適応度関数に対しては、適応度のより高い探索点を個体集団として保持することが、それらを最適解近傍に導くこととほぼ等価であり、かつ交叉演算が大局的にも局所的にも適合しているので、解探索の中に冗長な部分が少ないと考えられる。F11 の適応度ランドスケープは、適応度の低い平坦領域が大半を占め、その平坦領域に複数の各変数軸と平行な溝が走っており、それらの溝が交差するところに局所解あるいは最適解となる深い谷がある、というものである。適応度ランドスケープを構成する複数の異なる溝に位置する探索点を SPX の引数として探索点生成領域を決定すれば、探索空間内の中央付近に位置する最適解近傍を包含する可能性が高いと考えられる。

一方、PA は、F1 と F3 に対して、高い確率で最適解を包含して探索空間を縮小させたことが、Opt-PA の値から分かる。ただし、RGA よりも得られた解の精度と収束の速度が劣る。これは、それぞれの解の精度を上げる戦略の違いによるものと考えられる。つまり、PA は、探索点生成領域の変更、生成した探索点を直接用いないからだと考えられる。F8 は、F1 と同様に単峰性関数であるが、1 つの変数軸方向についてだけ適応度の変化が緩やかである。PA は、この関数に対して、F1 に対する場合と同じような探索性能が得られていない。これは、PA が、高い適応度を得るために重要な、適応度の変化が鋭い変数軸方向についての変数値生成領域を中心に適応させた結果、適応度の変化が緩やか変数軸方向についての変数値生成領域の適応を進められないまま探索空間を縮小させたからと考え




図3 ベンチマーク関数 F4, F5, F6, F7, F8, F9, F10 について、適応度計算回数が 5×10^5 に達するまでの “Opt-GA” の値を描いたグラフ

Fig. 3 Graph drawing values of “Opt-GA” up to 5×10^5 iterations for the benchmark functions F4, F5, F6, F7, F8, and F10.

られる。F11 に対して PA は、RGA よりも得られた解の精度および収束速度の点で劣る。PA は、探索点から新探索点生成領域を直接的に決定しないため、適応度ランドスケープの大半を占める平坦領域に位置した探索点生成メカニズムから新たな有望領域を発見することが困難であったことがその理由と考えられる。

4.4.3 F4, F5, F6, F7, F9, F10 について

ベンチマーク関数 F4, F5, F6, F7, F9, F10 に対する RGA の解探索は、適応度計算回数が 5×10^5 に達するまでに収束していたことが表 3 から分かる。また、それらに対する Opt-GA の値は、交叉演算が大局的および局所的な適応度ランドスケープに適合していたときに比べて小さいことが分かる。定義に従うと、これらすべてに対して交叉演算は、大局的にも局所的にも適合しなかったといえる。しかし、F6 や F9 に対して得られた最良適応度が最適解の適応度 0 と非常に近いことから、本論文で定義した交叉演算の適応度ランドスケープに対する適合の度合いが、良い探索性性能を得るために必ずしも重要であるとはいえない。そこで、以下では、それらのベンチマーク関数に対する結果を適応度計算回数が 5×10^5 に達するまでの Opt-GA の値 (図 3) に基づいて新たに分類し議論する。

図 3 から、各ベンチマーク関数に対する Opt-GA の値の変化を相対的に比較すると、ベンチマーク関数 F9 と F10 に対して、RGA の BLX- α 交叉が大局的な適応度ランドスケープに最も適合していたと考えられる。これらのベンチマーク関数は、大局的には単峰性下に凸状かつ適応度の山谷の高さが大局的な凸状超曲面の深さに比べて十分小さい適応度ランドスケープを持つことがその理由であると考えられる。最終的に得られる解の精度は、F9 と F10 の最適解近傍の適応度ラン

ドスケープの複雑さの違いに依存すると考えられる。

一方、PA は、F9 と F10 に対して、比較的高い確率で最適解を包含して探索空間を縮小させたことが、Opt-PA の値から分かる。最終的に得られた解の精度は、F10 の場合の方が F9 の場合よりも高い。これは、RGA の結果と逆である。PA における探索点生成メカニズムの持つサンプリング法は、ランダムサンプリング法であるので、PA は、適応度に滑らかで緩やかな連続性がない複雑な適応度ランドスケープに対して良い探索性能を得る可能性がある。一方、RGA は、適応度に滑らかで緩やかな連続性のある単純な適応度ランドスケープに対して良い探索性能を得る可能性がある。F9 と F10 の最適解近傍の適応度ランドスケープを以上の意味での複雑さの点で比較すると、F10 の方が F9 よりも複雑であるので、F9 に対して RGA の探索性能が良く、F10 に対して PA の探索性能が良い、という結果を得たと考えられる。

ベンチマーク関数 F4 と F5 に対しては、RGA の BLX- α 交叉が大局的な適応度ランドスケープに若干適合する短い期間があったことが分かる。この期間に個体集団は、特定領域に導かれたと考えられる。原点を中心に同心円状に分布する F4 と F5 の適応度の谷間の包絡超曲面は、単峰性下に凸状である。しかし、激しい適応度の山谷の繰返しがある。これらの適応度の谷間の包絡超曲面は単峰性状であるため、交叉演算が大局的な適応度ランドスケープに適合する余地があったと考えられる。しかし、局所的な適応度ランドスケープでは、適応度に滑らかで緩やかな連続性が失われるので、交叉演算が局所的な適応度ランドスケープに適合せず、局所探索が効率良く行われなかったと考えられる。

一方、PA は、F4 と F5 に対して、高い確率で最適解を包含して探索空間を縮小させることができなかったものの、RGA よりも若干高い精度の解を得ている。これは、PA が、ランダムサンプリング法を用いていることと、より高い探索点を包含する領域を強制的に縮小した探索空間とすることができることが理由と考えられる。

ベンチマーク関数 F6 と F7 に対しては、RGA の BLX- α 交叉が局所的な適応度ランドスケープに適合する期間があったことが分かる。F7 の局所解間の包絡超曲面は、単峰性上に凸状となるので、今回実験に用いたベンチマーク関数の中で F7 は、最も交叉演算が大局的な適応度ランドスケープに適合しなかったと考えられる。F6 の局所解間の包絡超曲面は、F4 や F5 と同様に単峰性下に凸状である。しかし、その局所解は

格子点状に分布し、すべての局所解近傍が探索空間内の中で占める割合は、F4 や F5 の場合よりも低い。これが、F4 や F5 よりも交叉演算が適応度ランドスケープに適合する期間が遅れて現れた理由だと考えられる。一方、F6 と F7 の最適解極近傍の適応度ランドスケープは単峰性状となるので、個体集団を最適解近傍に導くことができれば、良い探索性能が得られる可能性が高い。実験結果からは、実際そのことがどちらのベンチマーク関数に対しても起こっていたと推測できる。

一方、PA は、F6 と F7 に対して、RGA よりも得られた解の精度および収束速度の点で劣る。F6 に対する PA の探索特性は、F5 に対するそれと類似する点が多い。これは、局所解分布の仕方がそれらの間で異なるものの、大局的および局所的な適応度ランドスケープの特徴が類似するからと考えられる。F6 に対して、PA の探索性能が RGA のそれより大きく劣る理由は、RGA の交叉演算が局所的な適応度ランドスケープに適合しているから、と考えられる。F7 に対して PA は、高い確率で最適解を包含して探索空間を縮小させており、PA が最終的に得た解は、RGA のそれに迫るものである。F7 に対して RGA の交叉演算は、大局的な適応度ランドスケープに適合していないので、F7 の最適解近傍に複雑な適応度ランドスケープが存在し局所的にも交叉演算が適合しないような場合であれば、PA の探索性能が RGA のそれを上回る可能性があると考えられる。

4.4.4 F2 について

最後に、ベンチマーク関数 F2 に対しては、Opt-GA の値の変化から、さらに適応度の計算回数を増やしていけば、RGA の SPX が局所的な適応度ランドスケープにさらに適合すると予想される。ベンチマーク関数 F2 は、変数間に強い依存関係がある単峰性関数であり、SPX は、そのような変数間の依存関係を考慮して設計された交叉演算であることも理由としてあげられる。ただし、本実験では、MGG と SPX の組合せにおける交叉回数（子個体生成数）を少なく設定したことで、F2 に限らず実験に用いたすべてのベンチマーク関数に対して、SPX が決定する探索点生成領域を正しく評価し、良い探索領域に素早く探索点を集めることが困難であったと考えられる。

一方、PA の F2 に対する探索性能は、本実験で設定した適応度計算回数全般において RGA のそれを上回っている。しかし、Opt-PA の値から分かるように、全試行において、最適解を包含せずに探索空間を縮小させており、さらに適応度の計算回数を増やせば、RGA の探索性能が PA のそれを上回るになると

考えられる。

4.4.5 その他の知見

実験結果からいえるその他のことは、最適な PA のアルゴリズムパラメータ (N_c , N_m) 値は問題に依存すること、である。これらのパラメータ値は主に競争進化主体の多様性維持に関係するものである。パラメータ値の設定に PA の探索性能がどのように依存するかの調査は、今後の課題とする。本実験を通じていえる定性的なこととしては、探索空間を探索点生成メカニズムの持つ探索点生成領域でカバーする割合に強く関係するパラメータ N_m について、大局的に単峰性状である適応度関数の場合は N_m が小さくても信頼性の高い探索性能が得られ、多峰性あるいは変数間に強い依存関係がある適応度関数の場合は N_m は大きいほうが信頼性の高い探索性能を得られる、などである。基本的に、このことは、従来の進化計算手法における個体集団サイズにもあてはまる。また、PA の計算コストは BLX- α 交叉を用いる RGA のそれよりやや低いことが分かる。ランダムサンプリングを用いていることがその理由と考えられる。

5. 提案手法の特徴についての考察

前章の実験の結果から示唆されたことの 1 つは、個体集団として保持する探索点を引数として新探索点生成領域を決定する従来の進化的演算が局所的な適応度ランドスケープに適合しないとき、提案手法が従来の EC 手法よりも有効に最適手法として機能する可能性があることである。一方、従来の進化的演算が大局的および局所的な適応度ランドスケープに適合する場合、従来の進化計算手法は提案手法よりも収束速度および得られる解の精度の点で優れていることが示唆された。

前章の実験を通じていうには不十分なこととしては、従来の進化的演算が局所的な適応度ランドスケープに適合するが大局的なそれに適合しない場合、および大局的および局所的な適応度ランドスケープに適合しない場合、提案手法と従来法の探索特性の違いである。

まず、前節の実験において、従来の進化的演算が大局的な適応度ランドスケープに適合しないことが顕著に現れた唯一のベンチマーク関数は、F7 である。このベンチマーク関数は、多峰性の適応度ランドスケープを持ち、その最適解は探索空間の境界近くに位置する。このような適応度ランドスケープに対して、従来の進化計算により満足な探索性能が得られない場合がある理由として、一部の進化的演算にサンプリング・バイアスがあることが指摘されている^{10)~12)}。サンプリング・バイアスとは、選択圧のない状況下で、探索点が

探索空間の中央付近に偏って生成されることである。しかし、実際の進化計算手法の実行のときには、選択圧が個体に対してかけられるので、F7 のような場合でも、選択圧のかけ方などの多様性の維持に関係する設定の仕方によっては、最適化手法として機能すると考えられる。本実験で用いた BLX- α 交叉と SPX は、サンプリング・バイアスの問題を持つが、実験では選択圧などの多様性維持に関係する設定が適切であったため、良い結果を得たと考えられる。

一方、提案手法には、以上に述べたサンプリング・バイアスの問題は存在しない。その理由は、新たな探索点生成メカニズムの構成の際、交叉演算のように複数の親探索点生成メカニズムから子探索点生成メカニズムを構成せず、勝ち残った探索点生成メカニズムの構成要素をランダムに組み合わせて新たな探索点生成メカニズムを構成し、さらに探索点の生成にランダムサンプリング法を用いているからである。

次に、従来の進化的演算が大局的および局所的な適応度ランドスケープに適合しないようなベンチマーク関数は、前章の実験では 1 つも用いられなかった。そのようなベンチマーク関数の適応度ランドスケープは、全体的に適応度に滑らかで緩やかな連続性がなく、かつ最適解が探索空間の中央付近に位置しないものだと考えられる。これは、従来の進化的演算が大局的および局所的に適合する適応度ランドスケープの対極にあるものである。このような適応度ランドスケープに対して、サンプリング・バイアスの問題を持たず、かつ適応度に滑らかで緩やかな連続性がない適応度ランドスケープに対して柔軟に働くと考えられる提案手法は、従来の進化計算手法よりも効果的に働く可能性があると考えられる。今後、この点について詳しく調査する。

また、前章の実験で用いたベンチマーク関数 F2 のように、変数間の依存関係が探索空間の広範にわたって存在するような適応度ランドスケープに対して、超立方体領域を探索点生成メカニズムの持つ探索点生成領域とすることは、効果的でないと考えられる。この解決法としては、探索点生成メカニズムの持つ探索点生成領域として、極座標表現も選択できるようにすることが考えられる。本来の探索空間における変数間の依存関係は、極座標空間内において消失あるいは緩和されるからである。

6. おわりに

本論文では探索点生成メカニズムの競争進化に基づく最適化の考え方を示し、その考え方に基づく数値最適化問題のためのアルゴリズムを実現し、ベンチマー

ク関数を用いて実験的に評価した。

本実験の結果およびそれに基づく考察からは、提案手法は、従来の進化計算手法が効率良く解探索を行うことが困難な最適化問題に対して、有効な解法となることが示唆された。具体的には、従来の進化的演算が局所的な適応度ランドスケープに適合しないとき、または、大局的かつ局所的な適応度ランドスケープに適合しないとき、に有効な解法となると考えられる。特に後者の場合の検証は、本論文においてなされていないが、このとき従来の進化計算手法との探索性能の差が最も大きくなると論理的に考えられる。

今後は、従来の進化計算手法が効率良く解探索を行うことが困難な最適化問題に対して、提案手法が有効であることをさらに示し、進化計算手法の応用問題の拡大を目指す予定である。

謝辞 本論文は、科学研究費基盤研究(C)(2)(課題番号 13680451)の補助を受けている。

参考文献

- 1) Bäck, T. and Schwefel, H.-P.: Evolution Strategies 1: Variants and their computational implementation, Winter, G., Priaux, J., Gal, M. and Cuesta, P. (Eds.), *Genetic Algorithms in Engineering and Computer Science*, pp.127–140, Wiley, Chichester (1995).
- 2) Bäck, T. and Schwefel, H.-P.: Evolutionary Computation: An Overview, *3rd IEEE Conf. on Evolutionary Computation (ICEC'96)*, Nagoya, Japan, pp.20–29 (May 1996).
- 3) Dorigo, M., Maniezzo, V. and Colormi, A.: The ant system: optimization by a colony of cooperating agents, *IEEE Trans. on Systems, Man, and Cybernetics-Part B*, Vol.26, No.2, pp.29–41, (1996).
- 4) 樋口隆英, 筒井茂義, 山村雅幸: 実数値 GA におけるシンプレックス交叉の提案, 人工知能学会論文誌, Vol.16, No.1, pp.146–155 (2001).
- 5) Kita, H. and Yamamura, M.: A Functional Specialization Hypothesis for Designing Genetic Algorithms, *IEEE Int. Conf. on Systems, Man, and Cybernetics (SMC'99)*, Tokyo, Japan, Vol.3, pp.579–584 (Oct. 1999).
- 6) 小野 功, 小林重信: 単峰性正規分布交叉 UNDX を用いた実数値による関数最適化, 人工知能学会論文誌, Vol.14, No.6, pp.1146–1155 (1999).
- 7) 小野 功, 山村雅幸, 喜多 一: 実数値 GA とその応用, 人工知能学会論文誌, Vol.15, No.2, pp.259–266 (2000).
- 8) Pelikan, M., Goldberg, D.E. and Lobo, F.: A Survey of Optimization by Building and

Using Probabilistic Models, *IlliGAL Report No.99018*, Illinois Genetic Algorithms Lab., Univ. of Illinois at Urbana-Champaign (1999).

- 9) 佐藤 浩, 小野 功, 小林重信: 遺伝的アルゴリズムにおける世代交代モデルの提案と評価, 人工知能学会論文誌, Vol.12, No.5, pp.734–744 (1997).
- 10) 佐久間淳, 小林重信: 実数値 GA におけるサンプリングバイアスを考慮した外挿的交叉 EDX, 人工知能学会論文誌, Vol.17, No.6, pp.699–707 (2002).
- 11) 染谷博司, 山村雅幸: 最適解の位置にロバストな実数値 GA を実現する Toroidal Search Space Conversion の提案, 人工知能学会論文誌, Vol.16, No.3, pp.333–343 (2001).
- 12) Tsutsui, S.: Sampling Bias and Search Space Boundary Extension in Real Coded Genetic Algorithms, *Proc. Genetic and Evolutionary Computation Conference 2000*, pp.211–218 (2000).

(平成 14 年 8 月 23 日受付)

(平成 14 年 12 月 13 日再受付)

(平成 15 年 4 月 3 日採録)

大西 圭



平成 10 年九州芸術工科大学音響設計学科卒業。平成 15 年同大学大学院芸術工学研究科博士後期課程修了。平成 15 年～16 年 Univ. of Illinois at Urbana-Champaign 研究員。平成 16 年九州工業大学情報工学部研究員。博士(芸術工学)。進化計算の研究に従事。日本知能情報ファジィ学会会員。

高木 英行



昭和 56 年九州芸術工科大学修士課程修了。同年松下電器産業(株)入社, 昭和 56 年～平成 7 年同社中央研究所勤務。平成 3 年～5 年 UC Berkeley 客員研究員。平成 7 年九州芸術工科大学助教授。平成 15 年大学統合により九州大学大学院芸術工学研究院。博士(工学)。ファジィ, ニューラルネット, 進化計算, ヒューマンインタフェース等の研究に従事。電子情報通信学会篠原記念学術奨励賞(1989), 最優秀論文賞(KES'97 および IIZUKA'98), プログラム委員会最優秀論文賞(ICOIN-15), 功労賞(スロバキア人工知能学会, 2002 および IEEE SMC Society, 2003) 各受賞。IEEE, 電子情報通信学会, 人工知能学会, 日本知能情報ファジィ学会, 日本音響学会, 日本 VR 学会各会員。