

## 探索特性に可塑性を有する進化計算法とそのパラメータ獲得

晶 崇人<sup>†</sup> 長尾 智晴<sup>‡</sup>

横浜国立大学大学院環境情報学府<sup>†</sup>

横浜国立大学大学院環境情報研究院<sup>‡</sup>

### 1 はじめに

進化計算法とは、生物の進化の過程や行動などから着想を得た最適化アルゴリズムの総称である。目的関数の連続性や微分可能性が保証されない問題においても適応可能であることから、様々な領域において応用されている。しかし、あらゆる問題においても有効な手法は存在せず (No Free Lunch Theorem)、手法によって得意とする問題や不得意とする問題が必ず存在する。

そこで本研究では、様々な特性を内包し、パラメータを変えることでその特性を調節することができる自由度の高い進化計算法を提案する。さらに、パラメータのメタ最適化によって、ある関数を学習させることで、その関数に類似した問題に特化したパラメータを獲得することができると考えられる。

### 2 実数値最適化における進化計算法

実数値最適化における代表的な進化計算法は、Evolution Strategy (ES), Real-coded Genetic Algorithm (RCGA), Particle Swarm Optimization (PSO), Differential Evolution (DE) などが挙げられる。中でも PSO[1]と DE[2]は広く用いられる手法である。PSOは探索の過程で発見した暫定解方向へのベクトルと、個体の持つ慣性をもとに新たな探索点を取る。一般に局所探索性能に優れ、単峰性関数に対して優れた収束性能がある一方で、局所解の多い目的関数だと性能が悪化することが指摘されている。DEはランダムに選んだ個体間の差分をもとに新たな探索点を取る手法で、収束速度はPSOに劣るものの、優れた大域探索能力を持つ。

また、手法の欠点を補うべく、異なる特徴を持つ進化計算法を組み合わせたハイブリッド手法も提案されている。中でも、PSOの持つ収束性能と、DEの持つ大域探索能力を組み合わせた手法が様々な提案され、高い性能を示すことが報告されている[3]。本稿でも異なる探索オペレータの組み合わせによるアプローチを採るが、探索特性の自由度という観点から改良を加える。

### 3 提案手法

本手法では、より幅広い探索特性を表現するために、移動探索と子個体生成探索という性質の異なる

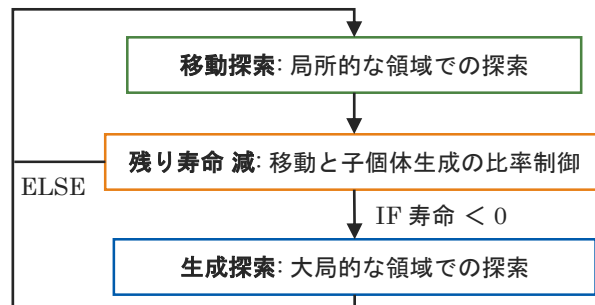


図1 提案手法の一世代の流れ

2つの探索オペレータを組み合わせる。さらに、移動と子個体生成の比率を調節するため、各個体に寿命を設ける。図1に提案手法の大まかな流れを示す。各個体は世代ごとに移動探索を行い、その後寿命を減少させる。寿命が0を下回った個体は、子個体生成へ移行する。

移動探索は、PSOのような局所的な探索を表現する。ここでは各個体がこれまでに発見した暫定解と、近隣個体間で共有している暫定解の情報を利用する。近隣個体の接続関係は ring topology を用いる。これによって、個体群の一部に着目した局所的な領域での探索を実現する。ここでは各個体が発見した暫定解と近隣個体が発見した暫定解、個体の慣性のそれぞれの重み  $w_{pbest}$ ,  $w_{lbest}$ ,  $w_{inrt}$  を移動探索のもつパラメータとする。

子個体生成探索では、DEのような大域的な探索を表現する。ここで大域的な探索とは、個体群全体の情報を活用することができる探索である。これによって、過去に探索していた領域とは全く異なる領域への個体生成を期待する。ここでは各個体の持つ暫定解を、DEをもとにしたプロセスで更新する。ここで、従来のDEのように多様性に富んだ個体を生成するだけでなく、個体群内の良質解周辺への子個体生成を可能にするため、基底ベクトルの選択方法に、式(1)で表現される重み付きルーレットを導入する。なお、 $p_i$ は個体 $\mathbf{x}_i$ が選択される確率、 $f$ は目的関数で、 $w_{rlt}$ によって適応度の重みを調節する。 $w_{rlt}$ を1に近づけると、良質な個体を中心とする子個体生成が行われやすくなり、 $w_{rlt}$ を0に近づけると、ランダムな領域に子個体が生成されやすくなる。

$$p_i = \frac{F(\mathbf{x}_i)}{\sum_{j=1}^N F(\mathbf{x}_j)} \quad \dots (1)$$

$$F(\mathbf{x}_j) = w_{rlt} \cdot 1/f(\mathbf{x}_j) + (1 - w_{rlt})$$

子個体生成探索では、ルーレット選択の重み  $w_{rlt}$  と

An Evolutionary Computation Having Plasticity on Search Characteristics, and Parameter Acquisition

<sup>†</sup> HATA Takahito, Graduate School of Environment and Information Sciences, Yokohama National University

<sup>‡</sup> NAGAO Tomoharu, Research Institute of Environment and Information Sciences, Yokohama National University

表1 獲得されたパラメータ

	$w_{lbest}$	$w_{pbest}$	$w_{inrt}$	$w_{mu}$	$w_{rlt}$	$w_{cr}$	$k$	$t_0$
Sph	1.474	0.974	0.344	0.017	0.913	0.182	0.468	4045
Schw	0.463	0.802	0.189	0.304	0.834	0.880	0.412	3079




図2 パラメータの学習に用いた目的関数

突然変異の大きさ $w_{mu}$ ，交叉率 $w_{cr}$ をパラメータとする。

続いて個体寿命の制御について述べる。各個体群は初めに初期寿命1で初期化され，移動探索が行われるたびにロジスティック曲線に基づく式(2)に従って寿命を減らす。

$$\Delta L_i = \frac{1}{1 + \exp[k t - t_0]} \cdot \frac{R_i - 1}{N - 1} \dots (2)$$

ここで， $k$ はロジスティック曲線の傾き， $t_0$ は変曲点の位置を表す。 $R_i$ は個体 $i$ の適応度順位を表す。この式によって，世代に応じて移動と子個体生成の比率が変わる。また個体群中の適応度順位が高いほど移動探索に重きが置かれ，順位が低いほど大域的な探索が増える。 $\Delta L$ の推移のしかたは $k$ と $t_0$ によって制御することができる。

#### 4 提案手法のパラメータ獲得実験

##### 4.1 実験設定

本稿では 30 次元の実数値最適化問題において提案手法の検証を行う。まず，機械学習のパラメータチューニングで用いられる Tree-structured Parzen Estimator (TPE)[4]を用いて，パラメータの学習を行う。学習させるパラメータは，移動探索での $w_{lbest}$ ， $w_{pbest}$ ， $w_{inrt}$ ，子個体生成探索での $w_{mu}$ ， $w_{rlt}$ ， $w_{cr}$ ，寿命の制御での $t_0$ と $k$ の計8パラメータである。パラメータ学習の目的関数は，学習用関数を最適化した際に得られる収束曲線の下側面積とする。学習用関数は Sphere 関数と Schwefel 関数(図2)とする。また，進化計算の個体数は 30，最大評価回数は 150,000 とする。

##### 4.2 獲得されたパラメータ

表1に獲得された各パラメータを示す。Sphere 関数で学習させたパラメータは，best 方向への重みやルーレット選択における適応度の重み $w_{rlt}$ が大きいため，個体を収束させるようなパラメータが獲得された。一方で，Schwefel 関数を学習させた場合，best 方向への重みが小さい，交叉率が高いなど，性質の異なるパラメータが得られた。

表2 Sphere で学習したパラメータの適用結果

	Prop.	DE	PSO
Sph	<b>6.094E-128</b>	4.216E-01	3.564E-71
SDP	<b>7.429E-167</b>	4.578E+22	4.293E-133

表3 Schwefel で学習したパラメータの適用結果

	Prop.	DE	PSO
Schw	4.833E+01	<b>4.821E+01</b>	4.835E+03
Rast	3.294E+01	<b>2.487E-01</b>	5.213E+02

#### 4.3 パラメータの適用結果

続いて獲得されたパラメータを連続最適化問題に適用した結果を表2，表3に示す。ベンチマーク関数は，パラメータ学習に用いた Sphere，Schwefel 関数に加え，Sum of different power (SDP) 関数と Rastrigin 関数を用いる。比較手法は，4.1 節と同様にパラメータの学習を行った ring topology PSO と DE/rand/1/bin とする。

表2に関して，Sphere 関数で学習させたパラメータが単峰性関数において優れたものであることが確認できる。一方表3に関しては，学習対象であった Schwefel 関数では DE と同等の精度が得られたが，Rastrigin 関数では DE に劣る結果が得られた。多峰性関数は谷の形状や数などによって最適なパラメータが異なると考えられる。

#### 5 まとめ

本稿では，移動探索と子個体生成探索という性質の異なる探索オペレータを個体寿命によって制御することで，探索特性に可塑性を持たせた進化計算法を提案した。また，実験において特定の関数に対してパラメータのメタ最適化を行うことで，その関数に適したパラメータを獲得した。今後の展望として，探索している関数景観を推定する手法と統合し，適応的な寿命制御を検討してゆく。

#### 参考文献

- [1] James Kennedy and Russell Eberhart. Particle swarm optimization. *The 1995 IEEE International Conference on Neural Networks*, Vol. 4, pp. 1942-1948, 1995.
- [2] Rainer Storm and Kenneth Price. *Differential evolution-a simple and efficient adaptive scheme for global optimization over continuous spaces*, Vol. 3. ICSI Berkeley, 1995.
- [3] Bin Xin, Jie Chen, Juan Zhang, Hao Fang, and Zhi-Hong Peng. Hybridizing differential evolution and particle swarm optimization to design powerful optimizers: a review and taxonomy. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol. 42, No. 5, pp. 744-767, 2012.
- [4] James S. Bergstra, Rémi Bardenet, Yoshua Bengio, and Bálázs Kégl. Algorithms for hyper-parameter optimization. *In Advances in Neural Information Processing Systems*, pp. 2516-2554, 2011.