

群知能の相互作用構造を導入した適応的差分進化による 連続最適化問題の解法

岩崎丈徳^{†1} 穴田一^{†1}

概要：ニューラルネットワークの学習やエネルギーシステムの制御、新幹線の形状設計など多くの工学分野や産業分野の問題が連続最適化問題を解くことに帰着できる。しかし、これらのほとんどの問題は現実的な時間内で厳密解を求めることが困難であるため、高速かつ高精度に解探索できる、生物の進化や群れ行動を模倣した進化計算（EC）と呼ばれる近似解法が研究されてきた。その EC の 1 つに差分進化（DE）という手法があり、DE のパラメータ調整を動的に行う適応的差分進化が提案されているが、集団内の情報を有効活用しないまま収束してしまう。そこで本研究では、群れ行動の相互作用を導入した適応的差分進化を提案し、その有効性を確認した。

キーワード：連続最適化問題、進化計算、差分進化

An Algorithm for Continuous Optimization Problem using Adaptive Differential Evolution introducing Interaction Structure of Swarm Intelligence

TAKENORI IWASAKI^{†1} HAJIME ANADA^{†1}

1. はじめに

ニューラルネットワークの学習やエネルギーシステムの構築、新幹線の形状設計など、多くの工学分野や産業分野の問題が連続最適化問題を解くことに帰着できる。しかし、高次元や複雑な曲面、微分不可能な問題など、ほとんどの問題が現実的な時間内で厳密解を求めることが困難になってしまう。そのような問題に対する最適化アルゴリズムに生物の進化や群れ行動を模倣した進化計算（Evolutionary Computation, EC）と呼ばれる近似解法の枠組みが存在する。その EC の 1 つに差分進化（Differential Evolution, DE）[1]と呼ばれる手法があるが、DE の探索性能はハイパラメータの設定に依存してしまう。そのため、パラメータ調整を動的に行う適応的差分進化が提案されているが、集団内の良い情報を有効活用しないまま収束してしまう。

そこで本研究では、適応的差分進化の中でも J. Zhang らによって提案された JADE [2]と呼ばれる代表的な手法をベースとして、群れ行動の相互作用を導入した適応的差分進化を提案し、その有効性を確認した。

2. 提案手法

本研究では、PSO で用いられる各個体 i のこれまでの最良解 $pbest_i$ と全個体のこれまでの最良解 $gbest$ を変異ベクトル生成時に新たに導入し、それらを差分ベクトルにより変異させた JADE を提案した。以下に提案手法のアルゴリズムの手順を示す。

STEP1 初期個体群の生成と初期設定

n 次元の実数値ベクトルで表される初期個体 $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ をランダムに m 個生成する。ここで、各個体 i のこれまでの最良解 $pbest_i$ に現在の解 x_i を設定し、それらの最良解 $gbest$ を $pbest_i$ の中から決定する。

STEP2 変異ベクトルの生成（突然変異）

ターゲットベクトル x_i において、差分ベクトル生成のためにランダムに個体 $x_{r1} \sim x_{r6}$ を互いに異なるように選択する。選択した個体 $x_{r1} \sim x_{r6}$ に基づき 3 つの差分ベクトルを生成し、 x_i , $pbest_i$, $gbest$ を以下のような式で変異させ、 x'_i , $pbest'_i$, $gbest'$ を生成する。

$$F_i \sim \text{Cauchy}(\mu_F, \sigma_F) \quad (1)$$

$$x'_i = x_i + F_i(x_{r1} - x_{r2}) \quad (2)$$

$$pbest'_i = pbest_i + F_i(x_{r3} - x_{r4}) \quad (3)$$

$$gbest' = gbest + F_i(x_{r5} - x_{r6}) \quad (4)$$

ここで、 F_i は個体 i のスケーリングファクタで、コーシー分布に基づき生成される。そして、 x'_i , $pbest'_i$, $gbest'$ に基づき以下のような式で変異ベクトル v_i を生成する。

$$v_i = F_i \times x'_i + F_i \times pbest'_i + F_i \times gbest' \quad (5)$$

^{†1} 東京都市大学大学院
Graduated School of Tokyo City University

STEP3 トライアルベクトルの生成 (交叉)

STEP2 で生成した変異ベクトル v_i と現世代の個体 x_i を一樣交叉し, トライアルベクトルと呼ばれる子個体 $u_i = (u_{i1}, u_{i2}, \dots, u_{in})$ を生成する. 交叉方法として, 以下に示した binomial 交叉を用いた.

$$CR_i \sim \text{Norm}(\mu_{CR}, \sigma_{CR}) \quad (6)$$

$$u_{ij} = \begin{cases} v_{ij}, & \text{if } \text{rand}(0, 1) \leq CR_i \text{ or } j = j_{rand} \\ x_{ij}, & \text{otherwise} \end{cases} \quad (7)$$

ここで, CR_i は個体 i の交叉率で, 正規分布に基づき生成される. また, j_{rand} は $1 \sim n$ の範囲内で生成した整数乱数で, 変異ベクトルの j_{rand} 次元目の値は必ず交叉させる.

STEP4 トライアルベクトルとの比較 (生存選択)

STEP3 で生成したトライアルベクトル u_i と現世代の個体 x_i の評価値を比較し, トライアルベクトルが現世代の個体より良ければトライアルベクトルを次世代の個体として置き換える.

STEP5 μ_F , μ_{CR} の更新

μ_F, μ_{CR} を以下の更新式によって更新する.

$$\mu_F(t+1) = (1-c)\mu_F(t) + c S_{F^2}/S_F \quad (8)$$

$$\mu_{CR}(t+1) = (1-c)\mu_{CR}(t) + c S_{CR}/S_N \quad (9)$$

ここで, S_F, S_{F^2}, S_{CR} はそれぞれ式(7)における更新成功時の F_i, F_i^2, CR_i の和, S_N は更新に成功した回数, c は $[0, 1]$ の学習率である.

STEP6 $pbest_i$, $gbest$ の更新

全個体の $pbest_i$, $gbest$ を更新する.

STEP1 の後, 以上の STEP2~STEP6 を規定世代数繰り返す.

3. 評価実験

本研究では, 提案手法の有効性を評価するために小林[3]が使用したベンチマーク関数 (F_1 : 単峰性, F_2, F_3 : 多峰性, F_4 : 変数間依存性, F_5 : 悪スケール性)を用いて既存手法との性能比較を実施した. 提案手法のパラメータは予備実験により最も良かった $\mu_F(0) = 0.5$, $\mu_{CR}(0) = 0.5$, $c = 0.1$ と設定した. 終了世代数は1000世代とし, 各手法を50回試行平均した際の既存手法との性能比較を表1に示す. また, 各手法を50回試行平均した際の100次元の F_3 における評価値の推移を図1に示す.

表1 既存手法との性能比較

Function	Dim	JADE		Proposed	
		ave	std	ave	std
F_1	100	2.28e-02	9.12e-05	8.00e-121	1.46e-119
	500	2.30e+02	3.75e-01	1.85e-104	4.95e-103
	1000	9.02e+02	8.25e-01	1.44e-96	1.47e-95
F_2	100	7.00e+00	4.11e-02	0.00e+00	2.54e-17
	500	1.56e+01	3.88e-02	0.00e+00	1.55e-17
	1000	1.69e+01	2.12e-02	0.00e+00	8.87e-17
F_3	100	1.62e+02	1.46e+01	0.00e+00	0.00e+00
	500	3.23e+03	8.12e+01	0.00e+00	0.00e+00
	1000	7.26e+03	9.85e+01	0.00e+00	0.00e+00
F_4	100	4.08e+02	6.75e-01	9.80e+01	3.06e-02
	500	5.58e+04	1.11e+02	4.98e+02	1.24e-02
	1000	2.72e+05	3.58e+02	9.98e+02	8.85e-03
F_5	100	1.99e+02	1.55e+00	6.64e-109	1.90e-107
	500	1.16e+06	2.41e+03	1.81e-97	6.04e-96
	1000	5.75e+06	5.92e+03	2.11e-98	4.19e-96




図1 F_3 における評価値の推移

表1より, 提案手法は既存手法より単峰性, 多峰性, 変数間依存性, 悪スケール性の全ての関数に対して大幅に解精度が向上したことが確認できた. 特に, F_2, F_3 の多峰性を持つ関数に対しては厳密解を求めることができた. また, 図1の結果から収束を大幅に早めることができた. これは $pbest_i$, $gbest$ の導入により各個体が良い情報を獲得しやすくなったことが考えられる.

4. 今後の課題

今後の課題としては, 大幅に探索能力が向上した要因の分析や連続最適化以外の問題への適用を検討したいと考えている.

参考文献

- [1] R. Storn, K. Price, "Differential Evolution – A simple and efficient adaptive scheme for global optimization over continuous spaces", J. Global Optimiz., Vol.11, No.4, pp.341-359 (1997).
- [2] J. Zhang, A. C. Sanderson, "JADE: Adaptive Differential Evolution With Optional External Archive", IEEE Tran. Evol. Comput., Vol.13, No.5, pp.945-958 (2009).
- [3] 小林重信, "実数値 GA のフロンティア", 人工知能学会誌, Vol.24, No.1, pp.147-162 (2009).