

複数手法の個体の増減に基づく進化計算法の適応的選択

Adaptive Selection of Evolutionary Algorithms by Increasing and Decreasing Population Size

土屋 大樹 長尾 智晴
Daiki Tsuchiya Tomoharu Nagao

横浜国立大学大学院環境情報学府
Graduate School of Environment and Information Sciences, Yokohama National University

Many evolutionary algorithms for real parameter optimization have been developed in recent years. These methods often have certain search characteristics, and therefore, the effectiveness of each method depends on characteristics of an objective function. In this report, we propose a framework to adaptively select evolutionary algorithms during evolutionary search process. By increasing or decreasing population sizes of each method according to the contribution to optimization, effective methods are used spontaneously for searching intensively in this framework. We show the proposed framework is able to select effective methods on a set of benchmark problems.

1. はじめに

数値最適化手法の一つとして、進化計算法が様々な分野に応用されている。その中で、Differential Evolution (DE) [Storn 97] や Particle Swarm Optimization (PSO) [Kennedy 95] など数多くの優れた進化計算法が提案されており、有効性が示されてきた。しかし、それらの手法はそれぞれある種の探索特性をもつことが多く、対象とする問題の特性によっては良好な解を得ることができない場合がある。そのため、進化計算を応用する際には、その対象に応じて有効な手法を経験的に選択しなくてはならないという課題がある。そこで、複数の進化計算法を組み合わせて、より多様な問題に対応できるようにしたり、探索効率の向上を図る研究が行われている。

たとえば、島モデルを用いて性質の異なる探索手法を選択するモデル [Biazzini 09] では、各手法ごとに個体群を島に割り当て、独立かつ並列に探索させるモデルが良好な性能を示していた。しかしこのモデルは、解の評価回数が多くなってしまうことを仮定しており、探索効率については考慮されていない。また、複数の手法それぞれの子個体生成数を適応的に変化させる A MultiAlgorithm Genetically Adaptive Method for Single Objective Optimization (AMALGAM-SO) が提案されている [Vrugt 09]。この手法では、定められた条件を満たすまで1度探索を行い、その結果をもとに各手法の生成子個体数を調節した後、探索をリスタートさせる。これを繰り返して探索を行う。これにより、異なる特性を持つ複数の問題に対し、頑健かつ効率よく探索することができていた。しかし [Vrugt 09] では、有効な手法の選択は探索のリスタート時のみ行われており、1度の探索中に個体数を変化させることはない。

これに対して本稿では、1度の探索中に個体数を増減させることによって、有効な探索手法を選択しつつ探索を行う手法を提案する。1度の探索中に、有効な手法の個体数は増加させ有効でない手法の個体数は減少させることによって、対象とする問題に有効な手法で重点的に探索を行うことを目的とする。さらに、最良個体の共有を行うことによって、探索状況に応じた手法の選択を行い、収束性を向上させる。1度の探索中に有効な手法を選択することができれば、従来研究と組み合わせにより効率的に進化計算法を適用することができると考えられる。

連絡先: 土屋大樹, 横浜国立大学大学院環境情報学府, 神奈川県横浜市保土ヶ谷区 79-1, tsuchiya-daiki-xv@ynu.jp

2. 提案手法

2.1 全体の流れ

提案手法では、複数の探索手法それぞれに割り当てられた個体群間で競争を行わせ、各手法の個体数が増減することによって探索中に有効な探索手法が選択される。ここで、提案手法内部で用いる探索手法の種類を q 種類とすると、全個体 G を $G = \{G_1, \dots, G_q\}$ と表す。 $\{G_1, \dots, G_q\}$ は各手法に割り当てられた個体群であり、それぞれの初期個体数を N_0 とする。したがって、提案手法における初期個体群の個体数は $q \times N_0$ となる。また、手法 x に割り当てられた個体のうち、探索に用いる個体を **有効個体**、そうでない個体を **無効個体** と定義し、それぞれ G_x^{eff} , G_x^{non} と表す。提案手法の流れを次に示す。

Step 1 初期個体群の生成と評価

全個体 G を探索空間内で初期化し、評価する。

Step 2 各手法による探索

探索手法それぞれについて、有効個体 $\{G_1^{\text{eff}}, \dots, G_q^{\text{eff}}\}$ を用いて探索を行う。例えば、手法 1 は G_1^{eff} だけで探索を行う。

Step 3 有効個体の増減

各手法の個体群 $\{G_1, \dots, G_q\}$ が持つ評価値に基づき、各手法の有効個体 G_x^{eff} を増減させる。

Step 4 個体情報の共有

各手法の個体群間で、最良評価値をもつ個体情報 (e.g. 目的変数 \mathbf{x} , 各手法の独自パラメータ) の共有を行う。

Step 5 終了判定

終了条件を満たしていれば探索を終了する。満たしていなければ Step 2 に戻る。

2.2 有効個体の増減

2.1 節における Step 3 の詳細な流れを次に示す。

Step 3.1 各手法の個体群のソート

各手法の個体群 $\{G_1, \dots, G_q\}$ それぞれについて独立に、評価値によってソートを行う。

Step 3.2 勝利手法, 敗北手法の決定

全手法の中で評価値の最も良い個体が割り当てられてい



図 1: 有効個体の増減方法について. (a) 1 つの探索手法の個体群の内訳. Step 3.1 によって評価値順にソートされる. (b) 有効個体を増加させる場合. (c) 有効個体を減少させる場合.

る手法を勝利手法とする. それ以外の手法については敗北手法とする. なお, 勝利手法は複数存在してもよい.

Step 3.3 有効個体の増減

敗北手法の有効個体数を $R\%$ 減少させ, 勝利手法の有効個体を $\frac{R}{1-R}\%$ 増加させる. このとき, 有効個体数の下限 N_{min} を超えて減少させることや, 上限 N_0 を超えて増加させることはないものとする. ここで, R は有効個体減少率を表す百分率である.

Step 3.3 における増減方法を図 1 に示す.

2.3 個体情報の共有

2.1 節における Step 4 は, 最良個体の周辺を複数の手法で探索することを目的としており, この操作により収束性の向上が期待できる. 具体的には, 敗北手法の有効個体のうち最も評価値の低い個体 $I_{lose}^{effworst}$ の情報を, 勝利手法の最良個体 I_{win}^{best} の情報で書き換える操作を行う. Step 4 の詳細な流れを次に示す. なお, この処理は敗北手法のそれぞれについて実行する.

Step 4.1 重複個体の確認

敗北手法の最良個体の目的変数 \mathbf{x} が I_{win}^{best} と等しい場合は Step 4.2, Step 4.3 は実行しない. 等しくなければ Step 4.2 へ進む. これは, 個体群の多様性を損なわないようにすることを目的としている.

Step 4.2 最近傍個体の探索

敗北手法の個体のうち, 目的変数 \mathbf{x} に関して I_{win}^{best} とユークリッド距離がもっとも近い個体 $I_{lose}^{nearest_best}$ を求める.

Step 4.3 最良個体情報のコピー

$I_{lose}^{effworst}$ の目的変数 \mathbf{x} は I_{win}^{best} の目的変数 \mathbf{x} で書き換える. 目的変数以外のパラメータ (e.g. Evolution Strategy の戦略パラメータ σ , PSO の速度 \mathbf{v}) に関しては, Step 4.2 で求めた個体 $I_{lose}^{nearest_best}$ の情報で書き換える.

2.4 提案手法内部で用いる進化計算法について

本稿では, 提案手法内部で用いる進化計算法として次の代表的な手法 3 種を用いることとした.

Differential Evolution (DE)

戦略として rand/1/bin を用い, パラメータについては, [Storn 97] の推奨値である $F = 0.5, CR = 0.1$ とした.

表 1: 実験で使用したベンチマーク関数. D は次元数, \mathbf{s} は最適解の位置であり, 今回は $\mathbf{s} = (10, \dots, 10)$ とした. \mathbf{A} は回転行列である.

Benchmark Functions

$$\begin{aligned}
 f_1(\mathbf{x}) &= \sum_{i=1}^D z_i^2, \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_2(\mathbf{x}) &= \sum_{i=1}^D |z_i|^{i+1}, \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_3(\mathbf{x}) &= \sum_{i=1}^D |z_i|^{i+1}, \mathbf{z} = \mathbf{A}(\mathbf{x} - \mathbf{s}) \\
 f_4(\mathbf{x}) &= \sum_{i=1}^{D-1} [100(z_{i+1} - z_i^2)^2 + (1 - z_i)^2], \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_5(\mathbf{x}) &= \sum_{i=1}^D \left(\sum_{j=1}^i z_j \right)^2, \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_6(\mathbf{x}) &= 10D + \sum_{i=1}^D (z_i^2 - 10 \cos(2\pi z_i)), \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_7(\mathbf{x}) &= -20 \exp \left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D z_i^2} \right) \\
 &\quad - \exp \left(\frac{1}{D} \sum_{i=1}^D \cos 2\pi z_i \right) + 20 + e, \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_8(\mathbf{x}) &\text{ は [Liang 13] を参照のこと.} \\
 f_9(\mathbf{x}) &= 1 + \frac{1}{4000} \sum_{i=1}^D z_i^2 - \prod_{i=1}^D \cos \left(\frac{z_i}{\sqrt{i}} \right), \mathbf{z} = \mathbf{x} - \mathbf{s} \\
 f_{10}(\mathbf{x}) &= 10D + \sum_{i=1}^D (z_i^2 - 10 \cos(2\pi z_i)), \mathbf{z} = \mathbf{A}(\mathbf{x} - \mathbf{s}) \\
 f_{11}(\mathbf{x}) &= \frac{0.5 + (\sin^2(\sqrt{z_D^2 + z_1^2}) - 0.5)}{1 + 0.001(z_D^2 + z_1^2)} \\
 &\quad + \sum_{i=1}^{D-1} \frac{0.5 + (\sin^2(\sqrt{z_i^2 + z_{i+1}^2}) - 0.5)}{1 + 0.001(z_i^2 + z_{i+1}^2)}, \mathbf{z} = \mathbf{x} - \mathbf{s}
 \end{aligned}$$

Evolution Strategy (ES) [Rechenberg 65, Schwefel 65]

(μ, λ) -ES を用い, $\lambda = 5 \times \mu$ とした. 変異方法として correlated mutation を用い, パラメータについては, $\tau_0 = 0.397635, \tau = 0.223607, \beta = 0.0873$ とした. ES では, 探索に用いる個体数は λ で決定されるため, 提案手法における 1 手法あたりの個体数は $N_0 = \lambda$ とする. すなわち, 初期親個体数は $\mu = N_0/5$ となる.

Particle Swarm Optimization (PSO)

[Shi 98] で提案されている inertia weight を導入した PSO を用いる. パラメータについては, [Eberhart 00] の推奨値である $w = 0.729, c_1 = c_2 = 1.49445$ とした.

3. 実験

3.1 実験設定

提案手法の有効性を検証するため, ベンチマーク関数に適用する実験を行った. 検証する事項とそれに対応する比較手法は次のとおりである.

検証事項 1. 有効な手法を選択することができているか

提案手法内部で用いている DE, ES, PSO をそれぞれ単独で実行するものと比較する.

検証事項 2. 効率的に手法を選択することができているか

提案手法内部で用いている DE, ES, PSO を独立かつ並列に実行するものと比較する. なお, この比較手法を以下 DE+ES+PSO と表す.

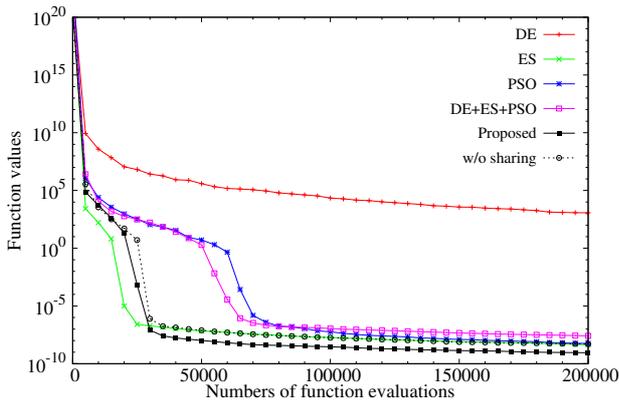
検証事項 3. 個体情報の共有が探索に好影響を与えているか

個体情報の共有を行わない, すなわち 2.1 節における Step 4 を行わない提案手法を用いる. なお, この比較手法を以下 w/o sharing と表す.

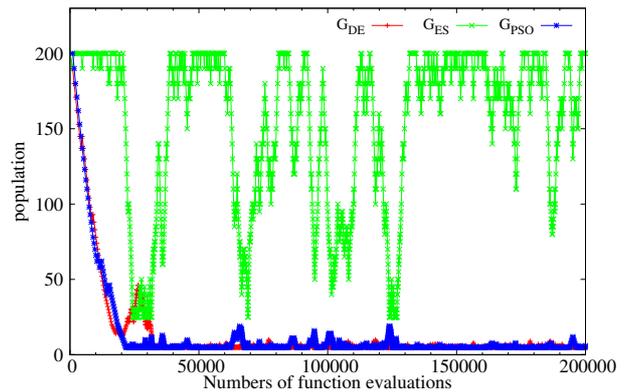
実験で用いたベンチマーク関数を表 1 に示す. ベンチマーク関数はすべて $D = 10$ とし, 関数評価回数を 200000 回, 提案手法, 比較手法ともに各関数において 20 試行ずつ実験を行った. また, 提案手法の 1 手法あたりの初期個体数は $N_0 = 200$ とし, 個体増減率は $R = 5\%$, 有効個体数の下限 $N_{min} = 5$

表 2: 10 次元のベンチマーク関数における提案手法と比較手法の実験結果. 表中の数値は関数評価回数 200000 回で得られた最良値の 20 試行平均値であり, 太字の値と下線が引かれた値はそれぞれ各関数における最良値と 2 番目に良い値を示している.

	DE	ES	PSO	DE+ES+PSO	Proposed	w/o sharing
f_1	0.000E+00	0.000E+00	0.000E+00	0.000E+00	0.000E+00	0.000E+00
f_2	1.003E-124	2.947E-10	0.000E+00	3.049E-27	0.000E+00	1.070E-10
f_3	1.183E+03	<u>4.349E-09</u>	5.732E-09	2.612E-08	8.927E-10	5.044E-09
f_4	7.687E-01	1.319E+00	<u>4.155E-01</u>	2.851E+00	1.334E-02	4.945E-01
f_5	6.367E+00	5.680E-30	0.000E+00	5.342E-11	<u>1.735E-30</u>	3.471E-30
f_6	0.000E+00	2.094E+01	1.841E+00	1.271E-02	0.000E+00	1.990E-01
f_7	1.250E-02	0.000E+00	7.995E+00	0.000E+00	0.000E+00	0.000E+00
f_8	0.000E+00	1.403E+03	9.031E+01	2.566E+01	2.176E-01	<u>6.665E-07</u>
f_9	<u>1.287E+01</u>	2.070E+01	1.826E+01	1.436E+01	7.216E+00	1.324E+01
f_{10}	<u>5.551E-18</u>	0.000E+00	4.305E-02	0.000E+00	0.000E+00	3.698E-04
f_{11}	1.276E-01	2.454E+00	<u>1.112E-01</u>	2.348E-01	9.233E-02	1.655E-01



(a) 最良解の関数値推移の 20 試行平均



(b) 1 試行中の各手法の有効個体数の推移

図 2: 提案手法における f_3 の最良解の関数値推移と有効個体数推移

とした. 比較手法の個体数は, DE,ES,PSO はそれぞれ 200 個体, DE+ES+PSO は各手法 200 個体の計 600 個体とし, 個体数以外の内部パラメータは全て提案手法内部で用いている各手法と同じ設定とした.

3.2 実験結果と考察

実験結果を表 2 に示す. 結果から, 全体的に提案手法は比較手法よりも良好な探索性能を示していることがわかる. f_8 を除き, 実験で用いたベンチマーク関数に対して比較手法の DE,ES,PSO がそれぞれ良好な性能を示している関数において, 提案手法はそれに勝る, あるいは比肩する結果となった. また, 提案手法は DE+ES+PSO よりも高い性能を示しており, 単純に全手法を並列に適用するよりも効率よく探索できていることがわかる. さらに, 個体情報を共有しない提案手法よりも高い性能を示していることから, 提案手法における個体情報の共有は探索の過程で有効に働いていると考えられる. しかし, f_8 に関しては個体情報を共有しないほうが良い結果となっており, 個体情報の共有が必ずしも良い影響を与えるわけではないことがわかる. これは, 収束性の高い手法において評価値の高かった個体が共有されてしまったために, 局所最適解の周辺を重点的に探索してしまった可能性が考えられる.

3.2.1 関数値推移について

提案手法の f_3, f_6, f_{11} における最良解の関数値推移の 20 試行平均のグラフを図 2(a), 図 3(a), 図 4(a) に示す. f_3, f_6, f_{11} はそれぞれ ES, DE, PSO が他手法と比べて良好な探索性能を示している関数である. 提案手法は, それぞれの関数について良好な探索性能を示している手法と類似した関数値推移となっており, 問題に対して有効な探索手法を選択できていることが示唆される.

3.2.2 提案手法における各手法の有効個体数推移

提案手法の f_3, f_6, f_{11} における探索中の各手法の有効個体数の推移の一例を図 2(b), 図 3(b), 図 4(b) に示す. それぞれの関数について, 有効な探索手法の個体数が他手法に比べて多くなっており, 有効でない探索手法の個体数は少なくなっていることがわかる. 例えば, f_3 は変数間に依存性があり, DE では最適化が困難な関数である. そのため, 提案手法内の DE の個体数は探索初期で急激に減少し, それ以降ほとんど増えていない. f_6 は, 大域的には単峰性の関数であるが, 多くの局所解を有する多峰性関数である. そのため, 探索初期には単峰性の関数で強い収束性を示す ES の個体数が多くなっていると考えられる. 図 3(a) からは, 提案手法が探索初期は ES と類似した関数値推移であることを確認することができる. しかし, f_6 は最適解に近づくにつれて多峰性の度合いが高くなるために, 多峰性関数においても頑健な探索を行うことのできる DE の個体数が徐々に増加していき, DE によって重点的に探索が行われていると解釈できる. これは, 探索状況に合わせて手法を使い分けられていると考えることもできる. f_{11} に関しては, PSO と DE が ES に比べ良好な探索性能を示していることから, 提案手法では ES の個体は探索にほとんど使われな一方, PSO と DE が拮抗し合って個体数が増減していると考えられる.

4. まとめと今後の課題

本稿では, 個体の増減に基づき, 探索中に有効な探索手法を選択する手法を提案した. 本手法では, 評価値の高い個体を生成している手法の個体数を増加させ, そうでない手法の個体数

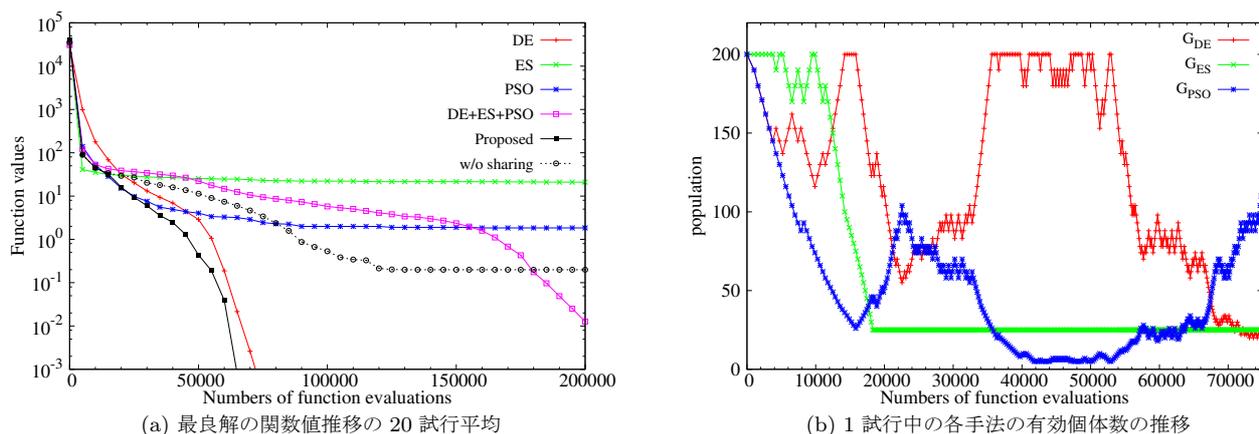


図 3: 提案手法における f_6 の最良解の関数値推移と有効個体数推移

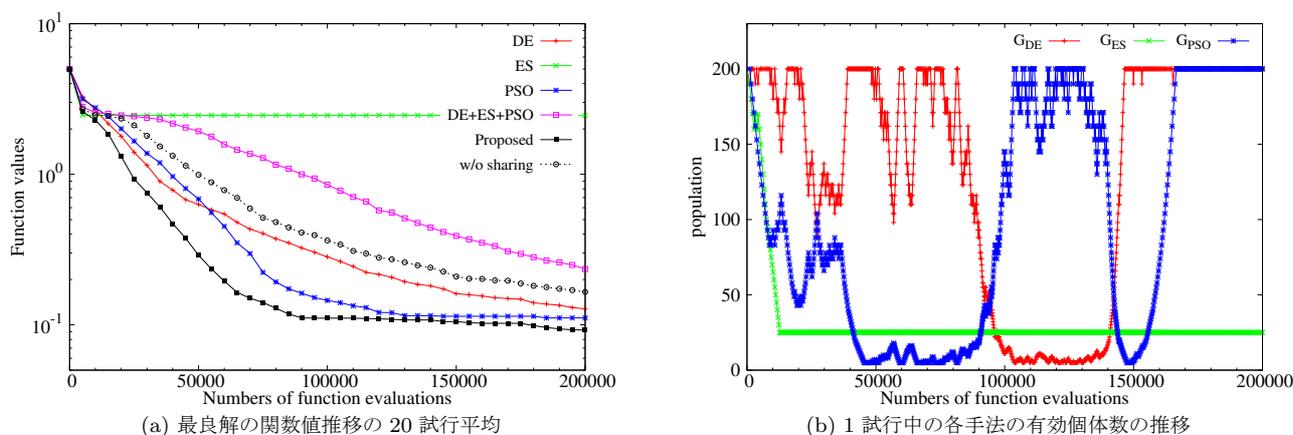


図 4: 提案手法における f_{11} の最良解の関数値推移と有効個体数推移

は減少させることで、対象とする問題に有効な探索手法で重点的に探索を行うことができる。実験として、ベンチマーク関数に提案手法を適用し性能の検証を行った。結果、提案手法が探索中に有効な手法を自動的に、自発的に選択できていることが示唆された。今後の課題としては、提案手法内部で用いる手法としてより高性能な手法を採用することや、個体増減の方法、個体情報の共有方法の更なる検討を行うことなどが挙げられる。

参考文献

[Biazzini 09] Biazzini, M., Bánhelyi, B., Montresor, A., and Jelasity, M.: Distributed hyper-heuristics for real parameter optimization, in *Proceedings of the 11th annual conference on Genetic and evolutionary computation (GECCO '09)*, pp. 1339–1346 (2009)

[Eberhart 00] Eberhart, R. and Shi, Y.: Comparing inertia weight and constriction factors in particle swarm optimization, in *Proceedings of the 2000 Congress on Evolutionary Computation* (2000)

[Kennedy 95] Kennedy, J. and Eberhart, R.: Particle Swarm Optimization, in *Proceedings of IEEE International Conference on Neural Networks* (1995)

[Liang 13] Liang, J. J., Qu, B. Y., Suganthan, P. N., and Hernández-Díaz, A. G.: Problem definitions and evaluation criteria for the CEC 2013 special session on real-parameter optimization, Technical Report 201212 (2013)

[Rechenberg 65] Rechenberg, I.: *Cybernetic Solution Path of an Experimental Problem*, No. 1122, Royal Aircraft Establishment, Library Translation (1965)

[Schwefel 65] Schwefel, H. P.: *Kybernetische Evolution als Strategie der experimentellen Forschung in der Strömungs Technik*, Diploma thesis, Technische Universität Berlin (1965)

[Shi 98] Shi, Y. and Eberhart, R.: A modified particle swarm optimizer, in *Proceedings of the IEEE International Conference on Evolutionary Computation* (1998)

[Storn 97] Storn, R. and Price, K.: Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces, *Journal of Global Optimization*, Vol. 11, No. 4, pp. 341–359 (1997)

[Vrugt 09] Vrugt, J. A., Robinson, B. A., and Hyman, J. A.: Self-Adaptive Multimethod Search for Global Optimization in Real-Parameter Spaces, *IEEE Transactions on Evolutionary Computation*, Vol. 13, No. 2, pp. 243–259 (2009)