



Inverted

PBIを用いたMOEA/D-DRAにおけるパラメータ自動調節に関する検討

メタデータ	言語: Japanese 出版者: 計測自動制御学会 公開日: 2016-02-17 キーワード (Ja): 進化型多目的最適化, 自動パラメータ調節 キーワード (En): MOEA/D, Inverted PBI 作成者: 佐藤, 孝奨, 渡邊, 真也 メールアドレス: 所属:
URL	http://hdl.handle.net/10258/3866

Inverted PBIを用いたMOEA/D-DRAにおけるパラメータ自動調節に関する検討

著者	佐藤 孝奨, 渡邊 真也
雑誌名	計測自動制御学会システム・情報部門学術講演会講演論文集
巻	2015
ページ	1223-1228
発行年	2015-11-18
URL	http://hdl.handle.net/10258/3866

Inverted PBIを用いたMOEA/D-DRAにおける パラメータ自動調節に関する検討

○佐藤 孝奨 渡邊 真也 (室蘭工業大学)

概要 代表的な進化型多目的最適化手法の1つであるMOEA/D-DRA (MOEA/D with Dynamical Resource Allocation) における集約関数としてIPBI (Inverted Penalty-based Boundary Intersection) を用いた際の自動パラメータ調節方法について検討を行った。具体的には、ある一定世代ごとにHyperVolumeによる評価を行い、その結果に基づいてIPBIにおけるパラメータ θ を動的に変更させるというものである。幾つかの代表的なテスト関数を用いた数値実験より、提案するパラメータ調整方法の有効性について検証を行った。

キーワード: 進化型多目的最適化, MOEA/D, Inverted PBI, 自動パラメータ調節

1 はじめに

代表的な進化型多目的最適化手法の1つにMOEA/D (Multiobjective Evolutionary Algorithm Based on Decomposition)¹⁾を改良したMOEA/D-DRA (MOEA/D with Dynamical Resource Allocation) がある²⁾。MOEA/D-DRAは、多目的最適化問題を集約関数を利用して複数の単目的問題に分解してパレートフロントの近似を試みる手法であり、集約関数としてTchebycheff, Weighted Sum, PBI (Penalty-based Boundary Intersection) が利用されている。

近年、佐藤らにより提案されたIPBI (Inverted Penalty-based Boundary Intersection) がその高い探索性能から大きな注目を集めている³⁾。IPBIはWeighted SumとPBIを組み合わせた関数であり既存の集約関数よりも高い性能を示しているが、一方で良好な性能を発揮するためには適切な内部パラメータ(θ)を設定しなければならないという問題がある。また、このパラメータについては、文献⁴⁾に示される様に一般に最適なパラメータ設定は探索フェーズに依存するため、IPBIにおけるパラメータ θ も同様の傾向であることが予想される。

本稿では、集約関数の1つであるIPBIのペナルティパラメータ θ を動的に調整する方法について検討を行い、探索性能の向上を試みた。提案手法の有効性を検証するため、代表的な4つのテスト問題について実験を行い、その効果について考察を行った。

2 MOEA/D-DRA

MOEA/D-DRAは、Liらによって提案されたアルゴリズムであり多目的最適化問題を複数の単目的最適化問題に分割して探索を行う手法である²⁾。

2.1 特徴

MOEA/D-DRAはMOEA/Dを改良した手法であり、MOEA/Dと比べ多様性の維持の困難性が解消され計算コストが削減された。

MOEA/Dでは近傍内からのみ比較・更新を行っており、設計変数が範囲から外れた場合に上限値または下限値を代入して修正しているため設計変数が類似しやすくなり、多様性の維持が困難だった。一方、MOEA/D-DRAでは確率で全個体を比較・更新対象とし、設計変数が範囲から外れた場合に範囲内となるようにランダムで修正することで多様性の増加を図っている。また、




Fig. 1: The flow of the MOEA/D-DRA

確率で全個体を比較・更新対象とするため、解を更新する際に更新する個数を任意で固定している。

MOEA/Dでは全個体に対して遺伝的操作を行っており停滞している個体も評価の対象となっていた。一方、MOEA/D-DRAでは停滞している個体よりも探索が進んでいる個体を重点的に遺伝的操作を行うことで停滞している個体を評価する部分の無駄を省くことができ計算コストが削減された。

2.2 アルゴリズム

各単目的問題は、一様な重みベクトルに基づく集約関数によって定義される。解探索は集約関数毎に対応する重みベクトルの方向にそれぞれおこなわれる。各集約関数の近傍 T に対応する集約関数の個体からランダムに親個体を2つ選択し、交叉と突然変異によって子個体を生成する。近傍 T の集約関数に属する個体と、生成された子個体の集約関数値を比較し、子個体の方が優れているとき、子個体で置き換える。

MOEA/D-DRAのアルゴリズムの流れをFig. 1と以下に示す。

step1 初期化

step1.1 一様な重みベクトル $\lambda^1, \dots, \lambda^N$ に対して、すべての組み合わせでユークリッド距離を求め、各重みベクトルに対して T 個の近傍 $B(i) = \{i_1, \dots, i_T\}$ を定義。

step1.2 初期個体 $x^1, \dots, x^N$ をランダムに生成。

step1.3 参照点 $z = (z_1, \dots, z_m)^T (z_i = \min\{f_i\})$ を設定。

step1.4 重みベクトルが選ばれる確率 π^i を設定。

step2 選択

1. 各目的の最良点をもつ個体を m 個(m :目的数)選択

2. π^i に基づいて個体を 10-トーナメント選択し、選択された個体番号 i を I に追加する. この操作を $\lfloor \frac{N}{5} \rfloor - m$ 回行う.

step3 更新

$i \in I$ までおこなう.

step3.1 $\text{rand} \in [0,1]$ で rand をランダム生成し、その値に応じて更新範囲 P_i を決定.

$$P_i = \begin{cases} B(i) & \text{if } \text{rand} < \delta \\ 1, \dots, N & \text{otherwise} \end{cases} \quad (1)$$

step3.2 $r_1 = i$ をセットし、更新範囲 P_i から 2 つの個体番号 r_2 と r_3 を重複しないようにランダムに選び、3 つの個体から交叉によって $\bar{y}$ を生成. 確率 p_m を用いて $\bar{y}$ を突然変異させ y を生成.

step3.3 y の設計変数が Ω の範囲より外れていれば再びランダムに選ばれる ($\Omega = \{x \in \mathbf{R}^n | h_j(x) \leq 0, j = 1, \dots, k\}$).

step3.4 $z_j < f_j(y)$ の場合、 $z_j = f_j(y)$ とする.

step3.5 更新範囲の中から n_r 個ランダムに抜き出して比較し、優れていれば更新. 以下にプロセスを示す. $c=0$

1. $c = n_r$ または P_i が空ならば Step4 へ. それ以外なら P_i からランダムに j をピックアップ
2. $g(y|\lambda^j, z) \leq g(x^j|\lambda^j, z)$ ならば x^j を y で置き換える. $c=c+1$
3. P_i から j を削除して 1 へ

step4 終了判定

終了条件を満たせば終了. そうでなければ、step5 へ進む.

step5 世代の更新

下記の式に従った π^i の更新を行い、step2 へ戻る.

$$\Delta^i = \frac{F_{old}^i - F_{new}^i}{F_{old}^i}$$

$$\pi^i = \begin{cases} 1 & \text{if } \Delta^i > 0.001 \\ (0.95 + 0.05 \frac{\Delta^i}{0.001}) \pi^i & \text{otherwise} \end{cases} \quad (2)$$

3 Inverted PBI

IPBI は、集約関数の 1 つで従来の PBI(Penalty-Based Boundary Intersection) を拡張し、Weighted Sum の特徴を内包した手法である³⁾. Weighted Sum は多数目的最適化において高い性能を示すものの、非凸型のパレートフロントの近似は不可能であるという特徴を持つ. 一方、PBI はペナルティパラメータ θ によって探索方向に対する解探索の指向性を強化できるが、いくつかの問題において広範なパレートフロントの近似が困難であるという特徴がある.

IPBI はこれらの特徴を組み合わせ、多数目的最適化における解探索性能を高め、広範なパレートフロントを近似可能にした集約関数である. 概念図を Fig. 2 に示す.

関数は式 (3) で定義される.

$$\text{Maximize } g^{ipbi}(x | \lambda) = d_1 - \theta d_2 \quad (3)$$

where,

$$d_1 = \frac{\|(n - f(x))^T \lambda\|}{\|\lambda\|}$$

$$d_2 = \|(n - f(x)) - d_1 \frac{\lambda}{\|\lambda\|}\|$$




Fig. 2: Conception diagram of IPBI

ここで、 λ は集約関数 $g(x)$ に対応する重みベクトルであり、目的関数空間における探索方向を決定する. また、 n は最悪点で、最小化問題の場合探索点 $x \in \Omega$ に対して $n = \max\{f_i(x) | x \in \Omega\} (i = 1, 2, \dots, m)$ である. θ はペナルティパラメータであり、重みベクトルの垂直方向に重み付けする. $\theta=0$ のとき Weighted Sum と同じ効果が得られ、 θ が増加するにつれ単目的問題での収束性が減少するため全体の多様性が増加する.

4 提案手法

パラメータの動的制御のメカニズムについて説明する. 以下、概要を述べた上でアルゴリズムの詳細を説明する.

4.1 コンセプト

Inverted PBI のペナルティパラメータ (θ) を動的に制御することで、最適なパラメータによる探索の実現を試みるものである.

MOEA/D の、探索段階を 2 段階に分けると前半に Weighted Sum などの収束性に優れた集約関数により探索を行い、後半に Techbycheff などの多様性に優れた集約関数を用いて探索を行うことで探索性能が上昇することが知られている⁴⁾. そのため、ペナルティパラメータ (θ) によって多様性および収束性を適応的に変化、制御することで探索性能が大きく向上する可能性がある.

本提案手法では、MOEA/D-DRA において 50 世代毎に重みベクトルの選ばれる確率を更新しているのに合わせて 50 世代毎にペナルティパラメータ (θ) を変更する. 変更時には現在の個体を評価し、50 世代前との評価値の差に着目して θ を変更する. HyperVolume の参照点を変えることで収束性と多様性を計測できるため 50 世代毎の評価の基準となる評価手法として HV を用いた⁶⁾.

4.2 提案手法のプロセス

上記の改良を加えたアルゴリズムの流れを以下に示す. またその流れ図を Fig. 3 に示す.

step1 2.2 節と同様に初期化を行う. その後、初期個体時の HV および θ を保存し、50 世代探索を進める.




Fig. 3: The flow of the proposed approach

step2~4 2.2 節と同様に探索を行う。

step5 世代の更新

step5.1 2.2 節と同様に π^i を更新する.HV により収束性および多様性を評価し, 収束性と多様性の増加量 (HV^{conv} , HV^{div}) を過去の増加量とそれぞれ比較する。

step5.2 , θ の更新については以下の 4 つの Case に分けて異なる更新を行う。

Case 1: HV^{div} および HV^{conv} がともに θ^{old} の場合よりも優れていた場合

Case 2: HV^{div} は優れているものの HV^{conv} では劣っている場合

Case 3: HV^{conv} は優れているものの HV^{div} では劣っている場合

Case 4: HV^{div} および HV^{conv} がともに θ^{old} の場合よりも劣っている場合

上記の各 Case に対応した具体的な更新式を以下に示す。

θ^{now} : 現在の θ 値

θ^{old} : 50 世代前の θ 値

θ^{inc} : θ の増加量

$\theta_{inc} = \theta^{now} - \theta^{old}$

case 1

$$\theta = \theta^{now} + 2 \times \theta^{inc} \quad (4)$$

case 2

$$\theta = \begin{cases} \theta^{now} + \theta^{inc} - \Delta & \text{if } \theta^{now} > \theta^{old} \\ \theta^{now} - \Delta & \text{otherwise} \end{cases} \quad (5)$$

case 3

$$\theta = \begin{cases} \theta^{now} + \theta^{inc} + \Delta & \text{if } \theta^{inc} > 0 \\ \theta^{now} + \Delta & \text{otherwise} \end{cases} \quad (6)$$

Table 2: Parameters

objective num m	2
division parameter H	200
population size N	201
decision variable num	20
neighborhood num T	20
stopping criteria (generation)	3000
update range δ	0.9
update limit n_r	6
distribution index η_m	20

case 4

$$\theta = \begin{cases} \theta^{old} + \frac{\theta^{inc}}{2} & \text{if } \theta^{inc} > \delta \\ \theta^{old} - \theta^{inc} & \text{otherwise} \end{cases} \quad (7)$$

θ の更新後, HV をの値を保存し 50 世代探索を進める ($0 \leq \theta \leq 5$). step2へ。

5 数値実験

本稿では, 提案手法の有効性を検証するため, 凸型と非凸型のパレートフロントを持つテスト問題として ZDT1, ZDT4, WFG4, WFG5 を対象問題として数値実験を行った. ZDT1 と ZDT4 は Table 1 で定義される. 評価手法として IGD, MS, HV を用いた。

5.1 パラメータ設定

WFG 問題のパラメータを位置パラメータ $k=10$, 距離パラメータ $l=10$ とした. MOEA/D-DRA のパラメータを Table 2 に示す。

結果は 30 試行の平均値を用いて比較を行った. 交差には DE operation を, 突然変異には Polynomial mutation⁵⁾を用いた。

5.2 評価手法

提案手法の評価には HyperVolume⁶⁾, Inverted Generational Distance(IGD)⁷⁾, Maximum Spread(MS)⁸⁾を用いた. それぞれの評価手法について述べる。

5.2.1 HyperVolume

HyperVolume は得られた解集合が支配する目的関数空間の体積を評価値とするものである⁶⁾. そのため, 解集合の「パレート最適フロントへの近似度合い」, 「幅広さ」, 「分散」を総合的に評価できる評価手法である. 本実験において基準となる参照点は, 各テスト問題のパレート最適フロントにおける各目的関数値の最大値とした. この参照点は提案手法内で用いる参照点とは異なるものである. HV は式 (8) で定義される. 概念図を Fig. 4 に示す。

$$\text{HyperVolume} = \text{volume}(\cup_{i=1}^{n_{PF}} v_i) \quad (8)$$

5.2.2 Inverted Generational Distance

IGD は得られた解集合のパレート最適フロントへの距離を示す評価尺度である⁷⁾. 解集団のユークリッド距離を利用した IGD を用いた. この IGD は式 (9) で定義され, IGD の値が低いほど得られた解集合はパレ-

Table 1: Test Problems

ZDT4	$f_1 = x_1$ $f_2 = g \times h$ $g = 1.0 + \frac{9}{n-1} + \sum_{i=2}^n (x_i)$ $h = 1.0 - \sqrt{f_1/g}$	$[0, 1]$
ZDT4	$f_1 = x_1$ $f_2 = g \times h$ $g = 1 + 10(n-1) + \sum_{i=2}^n (x_i^2 - 10 \cos(4\pi x_i))$ $h = 1 - \sqrt{f_1/g}$	$[0, 1] \times [-5, 5]^{n-1}$




Fig. 4: Conceptual diagram of HyperVolume




Fig. 5: Conceptual diagram of Inverted Generational Distance

ト最適フロントへの類似度が近いと判断できる。概念図を Fig. 5 に示す。

$$IGD = \frac{1}{N} \sum_{i=1}^N d_i \quad (9)$$

5.2.3 Maximum Spread

MS は得られた解集合の端点の距離を評価値とするものである⁸⁾。MS が高いほど、広範囲にパレート最適フロントが近似できたと考えられるため多様性を示す評価尺度といえる。MS は式 (10) で定義される。概念




Fig. 6: Conceptual diagram of Maximum Spread
図を Fig. 6 に示す。

$$MS = \sqrt{\sum_{j=1}^m \left(\max_{i=1}^{|Q|} f_j^i - \min_{i=1}^{|Q|} f_j^i \right)^2} \quad (10)$$

5.3 実験結果

従来の IPBI(以下、従来手法) と提案手法を組み込んだ IPBI(以下、提案手法) の IGD, MS, HV による探索性能の比較を行う。提案手法の結果を Table 3 に、従来手法の結果を Table 4 に示す。

非凸型のパレートフロントをもつ WFG4 および WFG5 では従来手法と比較して平均では同等またはやや優れており提案手法の有効性を確認できた。一方で、凸型のパレートフロントをもつ ZDT1 および ZDT4 では提案手法において従来手法と比べて最良値と最悪値とで大きく差があり、探索性能が落ちていることがわかった。IGD において、提案手法では従来手法に比べて ZDT1 および ZDT4 では最良値と最悪値の差が大きく、WFG4 では同程度であった。WFG5 では提案手法は従来手法に比べて最良値と最悪値は劣っていたが、平均すると優れていた。MS において、従来手法では ZDT1 と ZDT4 が、提案手法では WFG4, WFG5 が優れていた。HV については WFG4 のみ提案手法の方が従来手法より優れていた。

5.4 考察

MS が真のパレートフロントを近似した場合の値よりも大きくなっていることから端点の探索が上手くいっていないことがわかる。

IGD において最良値と最悪値の差が最も大きい ZDT1 と最良値と最悪値の差が最も小さい WFG5 の世代毎の

Table 3: The results of conventional approach

		ZDT1	ZDT4	WFG4	WFG5
best	IGD	0.002334	0.009623	0.009739	0.05984
	MS	1.34154	396.71	4.47504	4.39389
	HV	0.663441	0.650887	1.67611	1.43097
average	IGD	0.002431	0.015549	0.012192	0.065711
	MS	1.34106	287.975	4.47172	4.36745
	HV	0.663214	0.638665	1.66593	1.40745
worst	IGD	0.0026	0.022683	0.016811	0.068065
	MS	1.33975	169.14	4.4681	4.25565
	HV	0.662896	0.616803	1.65262	1.40246

Table 4: The results of proposed approach

		ZDT1	ZDT4	WFG4	WFG5
best	IGD	0.005505	0.016966	0.009311	0.06504
	MS	1.41428	68.5672	4.47721	4.405569
	HV	0.6660382	0.640595	1.68298	1.40712
average	IGD	0.01635	0.029043	0.011452	0.065997
	MS	1.27891	4.09249	4.4481	4.39018
	HV	0.649381	0.624402	1.67593	1.40405
worst	IGD	0.084014	0.048118	0.020177	0.069243
	MS	0.836995	1.21326	4.26293	4.37543
	HV	0.591061	0.599339	1.66642	1.39212

θ と IGD を用いて、探索の推移を分析する。まず、ZDT1 における提案手法での 30 試行中 IGD が最も低かった試行と最も高かった試行における IGD と θ の推移をそれぞれ Fig. 7, 8 に示す。次に、WFG5 における提案手法での 30 試行中 IGD が最も低かった試行と最も高かった試行における IGD と θ の推移をそれぞれ Fig. 9, 10 に示す。

Fig. 7, 8 より最良値と最悪値とで共に θ の値が $[0, 0.6]$ の範囲に収束していることがわかる。IGD も同様に $[0, 0.1]$ で収束している。このことから最良値と最悪値で本質的な違いはないことがわかる。

Fig. 9, 10 より最良値では早い段階で IGD が収束しているのに対して最悪値は終盤ようやく収束した。 θ を見ると最良値では早い段階で θ が大きく上昇しているが、最悪値では終盤まで変化量が小さかった。このことから WFG5 問題においては IGD が収束するためには θ が一定以上の値をとる必要があることが考えられる。

Fig. 7~10 より θ の振幅が小さいほど最良値と最悪値の差が小さくなる傾向が見られた。

また、 θ の推移を見ると ZDT1 においては振幅が大きく、WFG5 においては最良値と最悪値とでとる θ の値が大きく異なるため、適切な θ の調整が不十分であると考えられる。

6 おわりに

本稿では、MOEA/D-DRA におけるパラメータ設定の問題点の解決策として、集約関数におけるパラメータの自動調節方法を提案した。実験結果より、提案手法を組み込んだ IPBI と従来の IPBI では、非凸型のパレートフロントをもつ問題に対して優れた探索性能を示すことがわかった。一方で凸型のパレートフロントをもつ問題では劣っていることが判明したため、より詳細な分析が必要である。




Fig. 7: The transition of IGD in ZDT1




Fig. 8: The transition of θ in ZDT1

Fig. 9: The transition of IGD in WFG5

Fig. 10: The transition of θ in WFG5

今後の方針として、集約関数のパラメータだけではなく様々なパラメータについても動的制御を適用していきたい。

参考文献

- 1) Qingfu Zhang and H. Li: MOEA/D: A Multi-objective Evolutionary Algorithm Based on Decomposition, IEEE Trans. on Evolutionary Computation, Vol.11, No.6, pp.712-731(2007)
- 2) Q.Zhang, W.Liu and Hui Li: The Performance of a New Version of MOEA/D on CEC09 Unconstrained MOP Test Instances, Working Report CES-491, School of CS and EE, University of Essex, pp.203-208(2009)
- 3) Hiroyuki Sato: Inverted PBI in MOEA/D and its Impact on the Search Performance on Multi and

- 4) 谷垣 勇輝, 能島 裕介, 岩渕 久生:”探索時期に合わせた進化型多目的最適化アルゴリズムの選択, 第9回進化計算学会研究会, pp.131-137(2015)
- 5) K. Deb and M. Goyal:A combined genetic adaptive search(GeneAS) for engineering design, computer Science and Informatics, Vol.26, pp. 30-45(1996)
- 6) E.Zitzler and L.Thiele:Multiobjective Optimization Using Evolutionary Algorithms - A Comparative Case Study. Parallel Problem Solving from Nature - PPSN-V, pp.292-301(1998)
- 7) 増田広之, 谷垣勇輝, 能島裕介, 岩渕久生:進化型多目的最適化アルゴリズムの性能評価指標における参照解の影響調査, 進化計算シンポジウム 2014 講演論文集, pp.48-52(2014)
- 8) K.Deb:Multi-Objective Optimization using Evolutionary Algorithms, Chicheste, UK:Wiley(2001)