室蘭工業大学
学術資源アーカイブ
Muroran Institute of Technology Academic Resources Archive

進化型多目的最適化アルゴリズムにおける初期個体生成の違いによる探索への影響について

メタデータ	言語: jpn 出版者: 計測自動制御学会 公開日: 2016-02-17 キーワード (Ja): 多目的最適化, 初期個体 キーワード (En): MOEA/D 作成者: 高橋, 恒太, 渡邉, 真也 メールアドレス: 所属:
URL	http://hdl.handle.net/10258/3867

室蘭工業大学
学術資源アーカイブ
Muroran Institute of Technology Academic Resources Archive

進化型多目的最適化アルゴリズムにおける初期個体生成の違いによる探索への影響について

著者	高橋　恒太，渡邉　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	1229-1234
発行年	2015-11-18
URL	http://hdl.handle.net/10258/3867

進化型多目的最適化アルゴリズムにおける初期個体生成の違いによる探索への影響について

○高橋恒太　渡邉真也　（室蘭工業大学）

概要　従来の多くの進化型多目的最適化アルゴリズムでは個体数分の初期個体をランダムに生成するものがほとんどである．しかしながら，初期個体はその後の探索の出発点となる重要な要素であり，初期個体の質はその後の探索に多大な影響を及ぼすことが予想される．本発表では最も代表的なアルゴリズムの 1 つである MOEA/D(A Multi-objective Evolutionary Algorithm Based on Decomposition) において様々な初期個体生成メカニズムを実装し，それらの探索への影響について調査した．

キーワード: 多目的最適化，初期個体，MOEA/D

1　はじめに

近年，多目的最適化問題 (Multi-objective Optimization Problem，MOP) の解法に進化型アルゴリズムを用いる，多目的進化型アルゴリズム (Multi-objective Evolutionary Algorithm，MOEA) の研究が活発に行われている [1)]．

MOEA における探索結果を大きく左右させる重要な要素に，初期個体がある．従来の多くの MOEA では，ランダムな初期個体生成を行っているため，試行ごとの結果のばらつきが目立ち，乱数による探索への影響が少なく無いという特徴を持つ．また探索アルゴリズムに注力する既存研究は多数存在するものの，初期個体に関する研究事例は決して多くなく，問題の特徴と初期個体生成の関係について十分に議論されていないのが現状である．初期個体そのものの質により初期収束や多様性が失われることもあるため，初期個体が及ぼす探索への影響を十分に考慮する必要がある．

そこで本研究では，初期個体生成にいくつかのメカニズムを適用することにより，初期個体による探索結果および探索過程への影響を調査した．提案手法では，初期個体生成に計算コストを費やし，必要量の個体より多くの個体を生成，それらを厳選 [2)] することで良質な個体を初期個体として探索を始めるメカニズムや，乱数要素を排除し，決定論的に個体生成するメカニズムなど特徴の異なる生成方法について実験を行った．

提案手法の有効性の検証のため，代表的な MOEA の一つである MOEA/D-DRA[3)](MOEA based on Decomposition with DRA) をベースとし，いくつかの代表的なテスト問題に対して生成方法の比較を行った．

2　MOEA/D-DRA

本稿ではベースとなるアルゴリズムとして，Li らによる MOEA/D-DRA[3)] を用いる．本章では，MOEA/D-DRA の特徴について述べた上で，具体的なアルゴリズムの手順を概説する．

2.1　特徴

MOEA/D-DRA は，交叉法に SBX[4)](Simulated Binary Crossover) を用いる MOEA/D[5)] に対して差分進化 (Differential Evolution, DE) の交叉を用いるなど，いくつかの改良を加えたアルゴリズムである [3)]．MOEA/D の概念図を Fig. 1 に示す．探索は一様な重みベクトルに基づくスカラー化関数によって複数の部分問題に分割して行われ，本稿では，文献 [5)] に示されるスカラー化関数のうち，式 (1) で定義される Tchebycheff

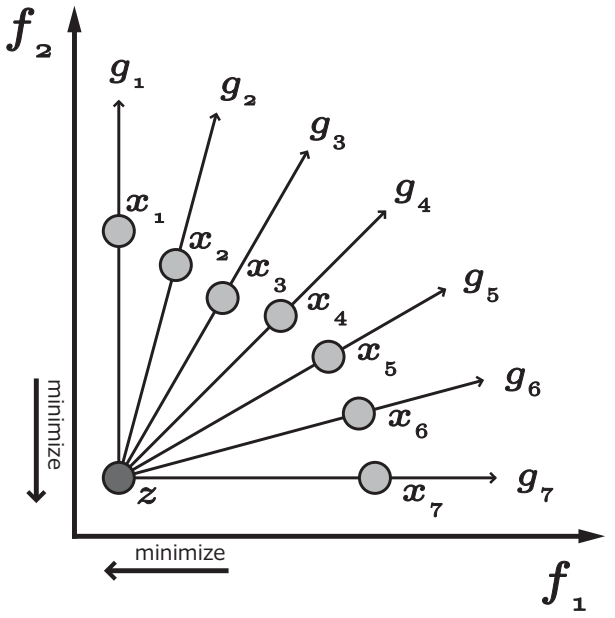


Fig. 1: Concept of MOEA/D

関数を採用した．

$$g^{te}(\boldsymbol{x}|\lambda, z^*) = \max_{1\leq i\leq m} \{\lambda_i |f_i(\boldsymbol{x}) - z_i^*|\} \qquad (1)$$

ここで, λ はスカラー化関数 $g(\boldsymbol{x})$ 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, z^* は参照点を意味しており，最小化問題の場合には探索点 $\boldsymbol{x} \in \Omega$ のうち各目的における最小値 $z_i^* = \min\{f_i(\boldsymbol{x})|\boldsymbol{x} \in \Omega\}(i = 1, 2, \ldots, m)$ を基準に決定されるのが一般的である．

2.2　アルゴリズム

MOEA/D-DRA のアルゴリズムを以下に示す．なお，ここでは最小化問題を想定しているものとする．

step1. 初期化

step1-1. 近傍の決定
一様な重みベクトル $\boldsymbol{\lambda}^1, \ldots, \boldsymbol{\lambda}^N$ 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 $\boldsymbol{B}(i) = \{i_1, \ldots, i_T\}$ を定義.

step1-2. 初期個体の生成
初期個体 $\boldsymbol{x}^1, \ldots, \boldsymbol{x}^N$ を生成し, 評価.

SY0010/15/0000-1229 © 2015 SICE

step1-3. 初期参照点の決定

参照点 $\boldsymbol{z} = (z_1, \ldots, z_m)^T (z_i = \min\{f_i\})$ 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. 10-トーナメントを π^i に基づいて選択し, 選択された個体番号 i を I に追加する. この操作を $[\frac{N}{5}] - m$ 回行う.

step3. 更新

$i = 1, \ldots, N$ の範囲で行う.

step3-1. 更新・選択範囲の決定

$[0, 1]$ の一様乱数を用いて, 以下の式で更新範囲 P を決定.

$$\boldsymbol{P} = \begin{cases} \boldsymbol{B}(i) & \text{if } rand < \delta \\ \{1, \ldots, N\} & \text{otherwise} \end{cases}$$

step3-2. 交叉

$r_1 = i$ とし, $\boldsymbol{P}$ からランダムで重複しない r_2, r_3 を選択. $\boldsymbol{x}^{r_1}, \boldsymbol{x}^{r_2}, \boldsymbol{x}^{r_3}$ から DE 交叉により子個体 $\bar{\boldsymbol{y}}$ を生成. $\bar{\boldsymbol{y}}$ が設計変数の領域外にあった場合, 該当の設計変数をランダムな値で置き換える.

step3-3. 突然変異

$\bar{\boldsymbol{y}}$ に Polynomial Mutation[6] を適用し, $\boldsymbol{y}$ を生成.

step3-4. 参照点の更新

$\boldsymbol{z}_j < f_j(\boldsymbol{y})$ の場合, $\boldsymbol{z}_j = f_j(\boldsymbol{y}) (j = 1, \ldots, m)$ とする.

step3-5. 解の更新

更新カウンタ $c = 0$ とする.

1) $c = n_r$ もしくは P が空の場合, step3 へ進む. そうでなければ, $\boldsymbol{P}$ からランダムで j を選択.

2) $g(\boldsymbol{y}|\lambda^j, \boldsymbol{z}) \leq g(\boldsymbol{x}^j|\lambda^j, \boldsymbol{z})$ なら, $\boldsymbol{x}^j = \boldsymbol{y}$ とおき, $c = c + 1$ とする.

3) $\boldsymbol{P}$ から j を削除し, 1) に戻る.

step4. 終了判定

終了条件を満たしていれば終了. そうでなければ, step5 へ進む.

step5. 世代の更新

50 世代毎に相対的減少量 Δ^i を計算し, その値に応じて π^i を下記の式に基づき更新し, Step2 へ戻る.

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

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

3 初期個体生成

探索の初期段階である初期個体生成についての様々な方法を検討し, それらの探索への影響を調べた. ここでは本論文で用いた初期個体生成方法について概説する.

3.1 概要

多目的最適化問題では, 初期個体を母集団サイズ分ランダムに生成することにより, 解空間全体を網羅的に探索することを目指している. しかし, ランダム性に依存するため必ずしも網羅的に探索されているとは限らない.

ここで使用した初期個体生成法を列挙する. 具体的には, 下記に示す 5 つの case について実装, 実験をおこなった.

case1 m 倍の初期個体候補を生成し厳選

case2 擬似的に等間隔に個体を生成

case3 設計変数空間における端点を確保した初期個体候補を生成し厳選

case4 ランダムに参考個体を生成し, その中の優秀な個体集合の範囲に更に多くの個体をランダムに生成し厳選

case5 case1 の手法を d 回に分けて行い, 段階的に個体を生成

3.2 初期個体生成メカニズム

本研究では, いくつかの初期個体生成メカニズムを実装した. 個体を必要数より多く作るだけでなく, 設計変数空間の情報を利用し, 初期個体を意図的に生成する.

以下, 母集団サイズを N, 初期個体候補数を mN 個 ($m > 1$) とし, 各メカニズムを説明する.

case1

m 倍の初期個体候補を生成し厳選

この手法では, 既存の手法の m 倍の個体 (mN 個体) を生成することで, より解空間全体を網羅することが出来るため, 探索効率の向上が期待できる. また, この手法における個体生成の概念図を Fig. 2 に示す.

厳選手法として, 生成された初期個体候補の非劣解集合を割り出し, それを除く初期個体候補の中の非劣解集合を第 2 非劣解集合, と初期個体をランク付けする. 優秀な非劣解集合から順に選択し, 選択された非劣解集合に含まれる個体数が N よりも多い場合, FS-MOGA[2] を用いて個体を選択する.

case2

擬似的に等間隔に個体を生成

この手法では, 設計変数を擬似的に等間隔に設定することで設計変数空間全体を網羅することが出来るため, 初期個体の多様性の確保が期待できる. また, この手法における個体生成の概念図を Fig. 3, 4 に示す.

生成方法は, 設計変数の上限値から下限値まで等間隔に分割した数値を, 各個体の設計変数の奇数番目に割り当てた個体, 偶数番目に割り当てた個体, 全てに

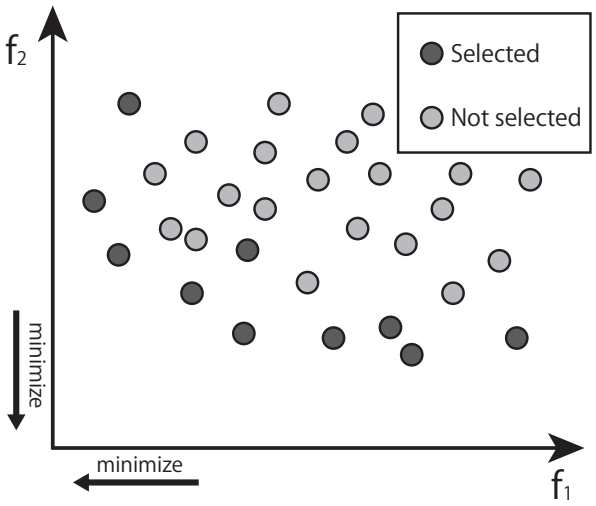


Fig. 2: Concept figure of case1

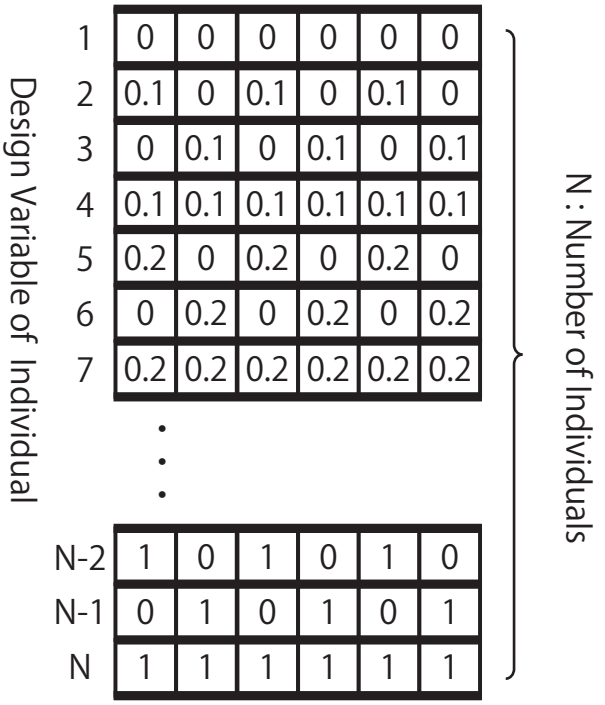


Fig. 3: Setting examples of case2

割り当てた個体を順に生成していく．これにより，完全に均等に個体を生成し，空間全体の網羅はできないが，線形的に空間を網羅することで，設計変数数に左右されることなくこの手法を用いることが出来る．

case3

設計変数空間における端点を確保した初期個体候補を生成し厳選

この手法では，各設計変数の上限値と下限値を確保して個体を生成するため，探索における端点の見逃しを防ぐ効果が期待できる．また，この手法における個体生成の概念図を Fig. 5 に示す．

設計変数数を n とする．最初の個体に全ての設計変数に上限値を，次の個体に全ての設計変数に下限値を割り当てる．次に $\frac{n}{2}$ 個の上限値と $\frac{n}{2}$ 個の下限値を持つ個体をランダムに生成する．同様に，上限値と下限値

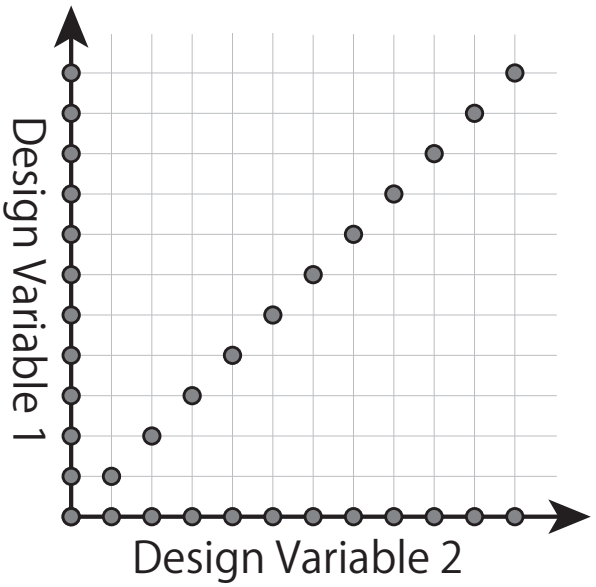


Fig. 4: Concept figure of case2

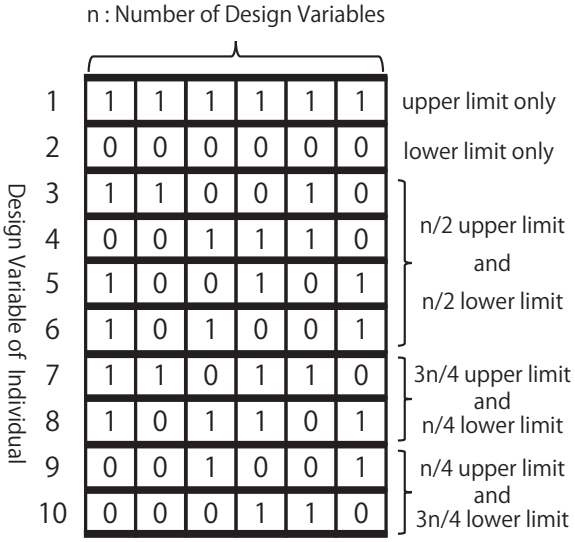


Fig. 5: Setting examples of case3

の割合を変更した個体を mN 個ランダム生成していく．ただし，設定した設計変数の上限値と下限値の数に対する設計変数の組み合わせ数が生成数より少ない場合，既存の MOEA/D の生成通り，ランダム生成で不足分を補う．

こうして生成された初期個体候補から，case1 と同様の方法で N 個まで厳選する．

case4

ランダムに参考個体を生成し，その中の優秀な個体集合の範囲に更に多くの個体をランダムに生成し厳選

この手法では，ランダムに生成した個体の内，優秀な非劣解集合の設計変数を参考に個体を生成・厳選するため，探索速度の向上や一部の解空間の網羅が期待できる．また，この手法における個体生成の概念図を Fig. 6 に示す．

生成手法は，まず既存手法通りランダムに参考個体を $mN/5$ 個生成する．その後，case1 と同様の手法で個

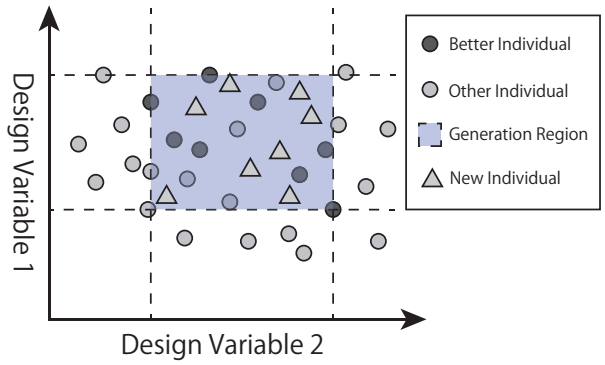


Fig. 6: Concept figure of case4

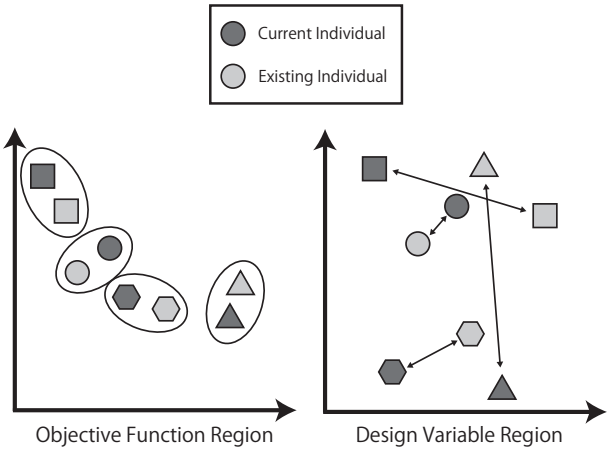


Fig. 7: Concept figure of case5

体のランク付けを行い，上位の一定数を優良個体とする．次に優良個体集合における各設計変数の最大値・最小値を保存し，その値の範囲に初期個体候補を $4mN/5$ 生成，case1 と同様の手法で N 個まで厳選する．

case5

case1 の手法を d 回に分けて行い，段階的に個体を生成

この手法では，case1 同様に解空間全体を網羅し，分割して個体生成・厳選を繰り返すため，多様性の確保が期待できる．また，この手法における厳選方法の図解を Fig. 7 に示す．

基本的には case1 と同様の手法を d 回 ($d < N/2$ を満たす自然数) に分けて繰り返すが，2 回目以降の個体生成における個体厳選方法が異なる．2 回目以降の個体生成では，初期個体候補 1 つ 1 つに対しすでに生成された個体の中で目的関数空間における距離が最も近い個体とペアリングし，ペアとなった個体同士の設計変数空間における距離が遠い順に個体を選択していく．

4 数値実験

本章では，初期個体生成が及ぼす探索への影響の検証のため，代表的なテスト問題である WFG テストスイーツより, WFG2，WFG4，WFG8 に対する数値実験をおこなった．

4.1 実験概要

本実験を行うにあたり，MOEA/D のパラメータと前章で紹介した初期個体生成メカニズムの具体的パラメータを説明する．MOEA/D のパラメータは目的数 $m = 2$, 分割パラメータ $H = 59$ とし, これに合わせて個体数 $N = 60$ となる．近傍サイズは $T = 6$ とし, 評価結果は全て評価回数 50000，30 試行の平均値および最良値と最悪値を用いて比較した．

初期個体候補数 $N' = 100N$ とし，case5 における分割数を $d = 5$ とした．また，case4 における優良個体の範囲として，生成した参考個体から上位 $\frac{1}{4}$ の個体とした．ただし，上位 $\frac{1}{4}$ の個体の内，最もランクが低い個体と同ランクの個体は，これに含むこととする．

4.2 対象問題

本実験では, WFG2，WFG4，WFG8 に対する数値実験を行った．問題のパラメータは，設計変数数による探索への影響調査のため，一部の問題では設計変数数を変化させた．各問題共通で位置パラメータ $k = 18$, 距離パラメータ $l = 12$ とし, 設計変数数は $k + l = 30$ に設定した．またそれに加え，WFG4，WFG8 においては，位置パラメータ $k = 6$, 距離パラメータ $l = 4$ とし, 設計変数数が $k + l = 10$ の場合と，位置パラメータ $k = 60$, 距離パラメータ $l = 40$ とし, 設計変数数が $k + l = 100$ の場合の実験を行った．

4.3 評価手法

WFG2，WFG4，WFG8 の初期個体評価・解評価には Hypervolume[7](HV)，Overall pareto Spread[8](OS) を用いた．それぞれの評価手法について以下に述べる．

4.3.1 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．解集合の支配する空間を評価値としているため，解集合の「パレート最適フロントへの近接度合い」,「幅広さ」,「分散具合」を総合的に評価する評価手法と言える．本実験において基準となる参照点は，今回行った同条件の実験の中で導出した解の最大値とした．

4.3.2 Overall pareto Spread

Overall pareto Spread は最良点 (P_G) と最悪点 (P_B) で囲まれる空間に対して，得られた非劣解集合の各目的関数の最大値，最小値から囲まれる空間がどの程度の割合を占めているかを求め，広がりを評価する．OS は 0 から 1 までの値を取り 1 に近ければその解集合は広がりが大きいことを意味する．OS は次式で定式化される．

$$OS(S, P_G, P_B) = \prod_{k=1}^{m} \frac{\mid max_{\vec{s} \in S} f_k(\vec{s}) - min_{\vec{s} \in S} f_k(\vec{s}) \mid}{\mid f_k(P_B) - f_k(P_G) \mid}$$

m は目的関数の数である．OS を用いて複数の非劣解集合の広がりを比較する場合は最良点と最悪点を同じものにする必要があるため，本実験では，今回行った同条件の実験の中の初期個体時点での最大値，最小値，導出した解の最大値，最小値を各最悪点，最良点とした．

4.4 比較結果

今回行った実験の結果を Fig 8〜Fig 9 に示す．また，Table 1〜Table 2 に各実験の HV と OS の数値を示す．ただし，本稿では 4.2 節であげた問題の内，WFG2(30 変数) と WFG8(100 変数) のみを掲載する．

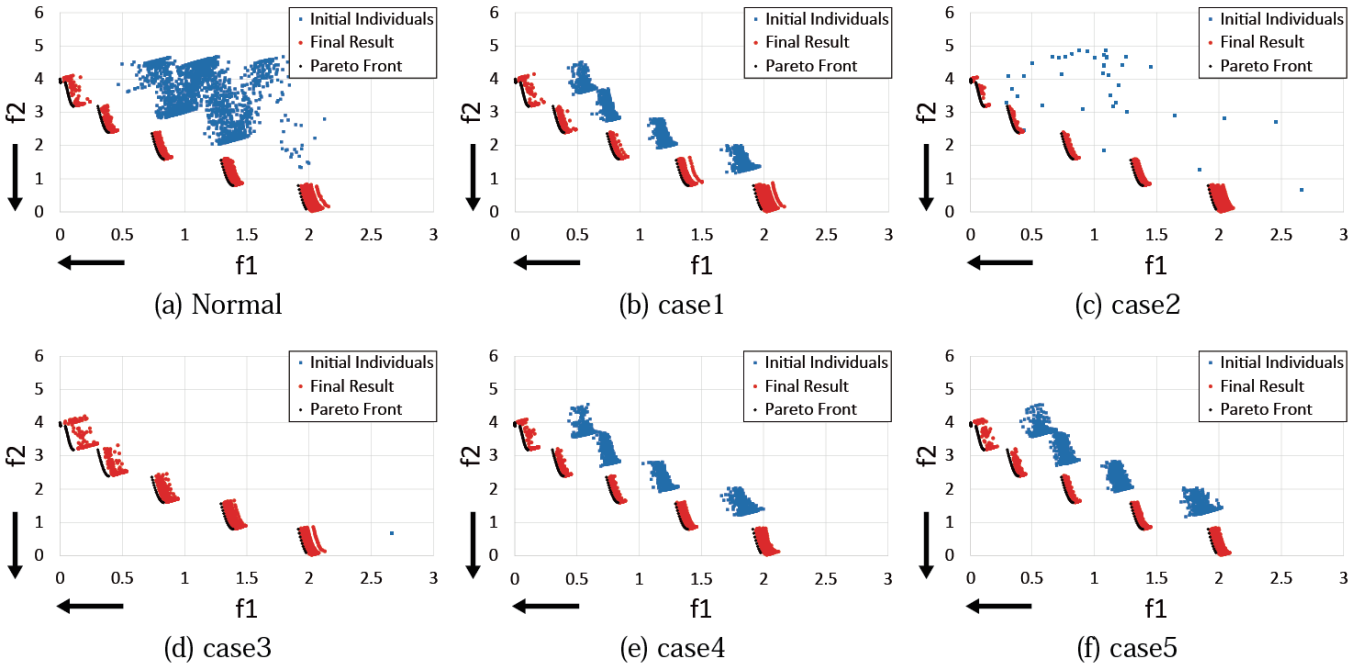


Fig. 8: WFG2 Evaluation Values

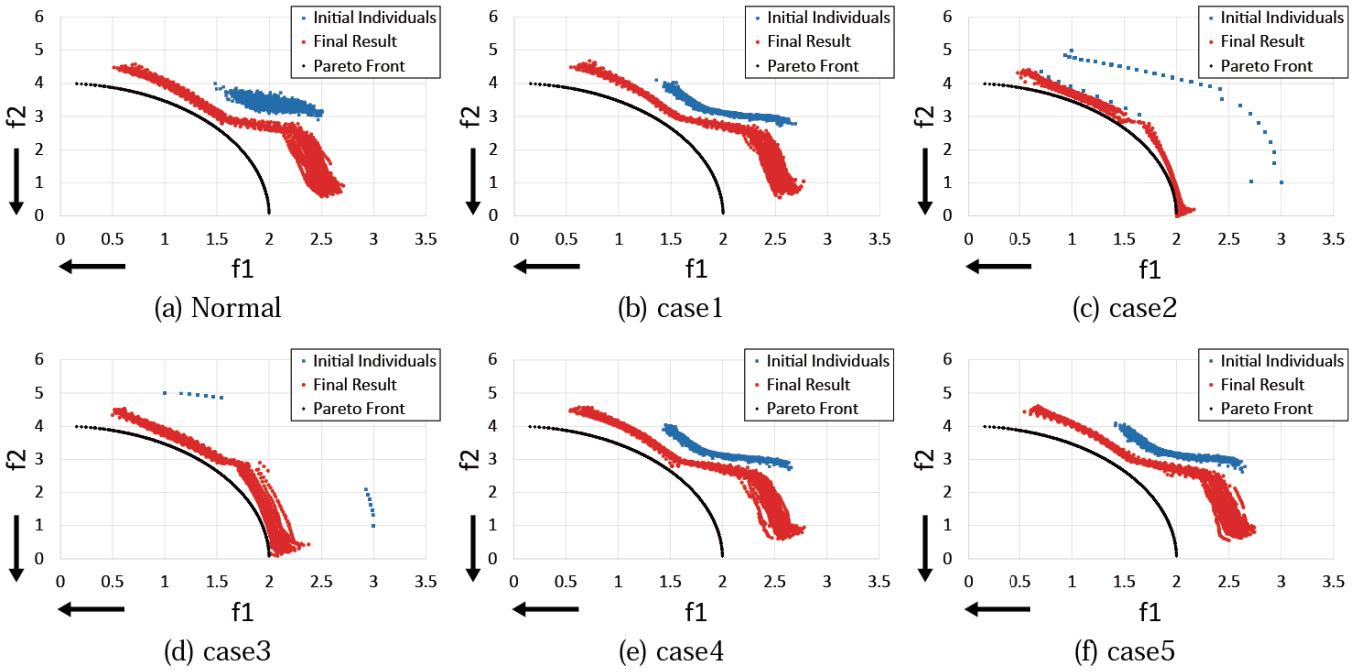


Fig. 9: WFG8(Number of Design Variables:100) Evaluation Values

4.5 考察

本実験から，テスト問題 WFG2，WFG8 においては，case2 の生成手法が優れた解を導出しやすいことがわかった．これは，各設計変数の端点を含む個体を必ず生成し，かつ均等に数値を持った個体を生成することで，探索の見逃しを減少させているからだと思われる．また，生成手順にランダム要素が含まれていないため，解のばらつきも減っていることがわかる．

WFG8 において，case2 と case3 の HV の値が明らかに優れていることがわかった．特に case2 に関しては WFG2 において，HV と OS の両方で最も優れた解を導出したことがわかる．これらの手法は設計変数空間における端点が重要な問題に対しては有効な初期個体生成方法といえる．しかし，本実験ではテスト問題しか扱っていないため，実問題における有効性の検証を行っていく必要があると思われる．

Normal，case1 と case5 の比較をしてみると，WFG2 においての最悪値が case5 の方が良い値が出ていることがわかる．これは，case5 の段階的初期個体生成が，安定性を向上させていると考えられる．しかし WFG8 においては，Normal 手法が case1，case5 よりも優れた結果を導出できている事がわかる．よって，問題特性

Table 1: Performance comparison（WFG2）

生成手法 \ 評価手法	Hypervolume			Overall pareto Spread		
	Best	Average	Worst	Best	Average	Worst
Normal	6.34938	6.17043	5.87220	0.80330	0.64876	0.42896
case1	6.35205	6.212204	5.77207	0.80196	0.73187	0.42990
case2	**6.43976**	**6.34361**	**6.21290**	**0.81566**	**0.80078**	**0.78101**
case3	6.26966	6.05015	5.59885	0.79723	0.77395	0.74941
case4	6.35205	6.23283	6.01641	0.80571	0.75702	0.42655
case5	6.39089	6.21061	6.04196	0.80778	0.74306	0.43172

Table 2: Performance comparison（WFG8）n:100

生成手法 \ 評価手法	Hypervolume			Overall pareto Spread		
	Best	Average	Worst	Best	Average	Worst
Normal	4.20554	3.83622	3.48469	0.73247	0.68165	0.58642
case1	3.93229	3.65923	3.45017	0.73187	0.69478	0.60786
case2	**5.73327**	**5.44448**	**5.29527**	0.62277	0.59862	0.56930
case3	5.50641	5.25374	4.81040	0.67254	0.63762	0.60398
case4	4.13344	3.69707	3.40363	**0.74784**	**0.69820**	0.63259
case5	4.09428	3.70183	3.48504	0.73336	0.69134	**0.63343**

に応じて初期個体生成方法を選択することにより，探索性能の向上が見込めると考えられる．

case4 に関しては，WFG8 において OS の値が他より優れているが，HV の値では明らかに劣っていることがわかる．これはパレートフロントに収束できなかった個体が広がりを大きくしていることで，広がりの指標である OS の値が良く出ているものと思われる．

5 おわりに

本稿では，初期個体生成に幾つかのメカニズムを適用することにより，探索結果のばらつきの抑制及び，より良い解を導出することを目的として，3.1 節であげた初期個体生成方法の提案および数値実験を行い，初期個体が及ぼす探索への影響を調査した．以下に本論文において確認できた事項を示す．

- 実験結果より，問題によるが初期個体の質はやはり探索に大きな影響を及ぼしていることがわかった．
- case2 の手法は，今回扱ったテスト問題に対して大きな有効性が確認できた．
- case5 の手法は，特定の問題に対し，Normal，case1 よりも安定した解の導出が出来ることを確認した．
- 問題に応じた初期個体生成の必要性も重要だと確認することが出来た．
- 4 章で扱った実験はテスト問題であるため，実問題における実験が必要であると考える．

今後の展望として，問題特性に応じた探索中における初期個体生成の変更や，初期個体生成時の劣解の探索への再利用などを考えている．

参考文献

1) K.Deb. *Multi-Objective Optimization using Evolutionary Algorithms*. Chichester, UK:Wiley, 2001.
2) 濱田直希, 田中雅晴, 佐久間淳, 小林重信, 小野功（東京工業大学）. 機能分担多目的実数値 GA:FS-MOGA の提案 . 2009.
3) Wudong Liu Qingfu Zhang and Hui Li. The Performance of a New Version of MOEA/D on CEC09 Unconstrained MOP Test Instances. 2009.
4) K. Deb and R.B. Agrawal. Simulated binary crossover for continuous search space. *Complex systems*, Vol. 9, No. 2, pp. 115–148, 1995.
5) Qingfu Zhang and Hui Li. MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition. *IEEE Trans. Evolutionary Computation*, Vol. 11, No. 6, pp. 712–731, 2007.
6) K. Deb and M. Goyal. A combined genetic adaptive search (GeneAS) for engineering design. *Computer Science and Informatics*, Vol. 26, pp. 30–45, 1996.
7) 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.
8) Jie Zhang Liang Feng Siwei Jiang, Yew-Soon Ong. Consistencies and Contradictions of Performance Metrics in Multiobjective Optimization. 2014.