

高次元目的関数空間における多目的最適化を利用したパラメータチューニング

石田 裕幸

1 はじめに

近年、様々な分野において、複雑な事象やシステムがモデル化され、コンピュータを用いてシミュレーションが行われている。これらのモデルは一般的に、初期設定するパラメータにより挙動が大きく変化する。そのため、モデルを実用するためには、適切なパラメータを探すことが重要な課題の 1 つとなる。パラメータの適切さを評価するために、実世界における事象の観測値とモデルのシミュレーション結果を比較することが多い。シミュレーション結果と実世界における観測値との誤差が小さければ小さい程、適切なパラメータを用いていると言える。しかし一般的に、比較すべき観測値の数は 1 つではなく、複数存在するため、複数の基準を考慮しなければならない。例えば、地球の振る舞いを模倣したモデルのパラメータチューニングを例にとると、気温、湿度、海の温度、海の塩度などの基準が挙げられ、シミュレーション結果がそれらの観測値に近づくようにパラメータを決定する必要がある¹⁾。そして、これらの値を一定時間ごとに観測することを想定すれば、パラメータチューニングにおいて考慮すべき基準は無限に存在する。また、これらの基準はお互いに競合する関係にある場合が多いため、パラメータチューニングは非常に困難な課題となる。この課題に対し、パラメータチューニングに対する研究は数多く行われてきた。複数の競合する基準を有するモデルのパラメータチューニングには、以下の 2 つのアプローチが挙げられる。

1. 1 つの指標への置き換え

複数の基準から、重み和などを用いることにより 1 つの指標に変換し、その指標を最小化または最大化する。

2. パレートのアプローチ

複数の基準をそれぞれ目的と捉えることで、パラメータチューニングを進化的多目的最適化 (Evolutionary Multi-objective Optimization : EMO) などの多目的最適化手法に適用し、複数のパレート最適解集合を導出する。

これまで、1 つの指標に置き換えるアプローチが主に利用されてきた^{2, 3)}。しかし、このアプローチでは 1 つの指標に変換する際に、最終的に得られた解 (パラメータ) を利用する意思決定者 (Decision Maker : DM) が複数ある基準のそれぞれに重み付けを行う必要がある。最適な重みの選択はそのモデルの分野に精通している人としても困難な場合が多いが、重みの付け方は最終的に得られる解に大きく影響を及ぼしてしまう。また、それぞれの基準が競合すれば、全ての基準について実世界の観測

値と一致するような解を得ることは不可能であるので、幾つかの基準については妥協する必要がある。しかし、1 つの指標に変換するアプローチでは、最終的に 1 つの解しか得られないため、得られた解がそれぞれの基準についてどの程度妥協しているのかを把握することができない。

それに対し、パレートのアプローチによるパラメータチューニングでは、複数の様々なパレート解集合の導出が探索の目標の 1 つになるため、上記の重み付けの問題を回避することができる。更に、同程度の精度を有する様々な解集合の導出が可能のため、それらの解同士を比較することにより、ある解がそれぞれの基準についてどの程度妥協しているのかを相対的に把握することが可能になる。そして、これは DM が最終的に利用するパラメータを決定する際や、そのパラメータを実際に利用する際に非常に有益な情報になると考えられる。従って、近年ではパレート敵アプローチによるパラメータチューニングの研究が行われてきている^{1, 4)}。

しかし、パラメータチューニングでは、上記のように、考慮すべき基準は 2~3 程度の少ない数ではなく、多数挙げられるのに対し、パレートのアプローチによるパラメータチューニングの研究では、多くの基準を取り扱っていない。そこで本稿では、全ての基準を目的として扱うパラメータチューニングのような、多くの目的を有する多目的最適化問題における問題点について述べる。次に、その問題点を基に、新たなパラメータチューニング手法を提案する。そして、作成したテストモデルに提案手法を適用し、導出される解集合の特徴を確認する。最後に、ディーゼルエンジンの燃焼をシミュレートする現象論的モデルの 1 つである HIDECS^{5, 6)} のパラメータチューニングに提案手法を適用し、その有効性を検証する。

2 数多くの目的を有する多目的最適化の問題点

パレートのアプローチによるパラメータチューニングの研究において全ての基準を目的として扱っていないのは、NSGA-II⁷⁾ や SPEA2⁸⁾ などの代表的な EMO は、多数の目的を有する問題に適用された場合、著しく探索性能が低下してしまうからである。高次元目的関数空間における探索では、探索を進めているにも関わらず、解集合がパレート最適フロントから遠ざかる現象が頻繁に起こる。これは、目的関数空間の広さに比べて探索解数が少ないことから、精度の高い解が偶発的に導出されたとしても、高い適合度が割り当てられずに探索中で淘汰されてしまうためだと考えられる⁹⁾。更に、精度の向上と非劣解の数には密接な関わりがあるが、高次元目的関

数空間における探索では、探索の初期段階からアーカイブ母集団は非劣解で占められてしまう。EMO は、適合度が高い解周辺に次世代の解を生成することで解の精度を向上させているが、高次元目的関数空間では解同士で優劣の区別が付かなくなるため、精度が向上しなくなると報告されている^{9, 10)}。

この問題に対して、選択圧を強くすることによりパレート最適フロントへの収束を促進し、精度を向上させる手法が提案されている。Average Ranking (AR)¹¹⁾、Summed Ratio¹¹⁾、The Favour Relation¹²⁾、and K-Optimality¹³⁾ は、非劣解同士にも異なる適合度を付与し、選択圧の強化を実現している。その中でも、AR が最も良好な探索性能を有すると David W. Corne らは報告している¹⁴⁾。AR は、各目的ごとにランキングを計算し、全ての目的のランクを加算した値を適合度とするメカニズムである。例えば、3 目的の問題において、ある解が、 f_1 に関して 3 番目に良好、 f_2 に関して 2 番目に良好、 f_3 に関して 5 番目に良好な値であるとする。この場合、 $3+2+5=10$ がこの解の適合度となる。

しかしながら、AR のように非劣解同士にも異なる適合度を付与して選択圧を強くしたとしても、探索解集合は一点に収束してしまい、多様性が失われてしまうことが確認されている⁹⁾。同様に、優越の定義を拡張することにより選択圧を強めるアプローチも提案されているが、このアプローチにおいても探索解集合の多様性は失われてしまう¹⁵⁾。パラメータチューニングにおいて、この様な多様性のない解集合が導出された場合、DM はそれぞれの解が各観測値に対してどの程度の大きさの誤差を有しているのかを把握することができない。従って、多くの基準を考慮するパラメータチューニングにおいても、多様性のある解集合が導出されることが望ましい。

3 意思決定者の選好情報を利用したパラメータチューニング

本来ならば、パラメータチューニングにおいても、パレート最適フロント全域に分布する解集合を導出することが望ましい。しかし、高次元目的関数空間を対象とした場合は、パレート最適フロントに敷き詰めるのに必要な解の数が莫大であるため、それは困難であると考えられる。仮に、パレート最適フロントの形が線形で、パレート最適解が各目的において $[0, 1]$ の範囲全域に値をとる問題があったとする。この問題のパレート最適フロント上に各目的に関して 0.1 間隔で均一に解をマッピングした時に必要な解の数を考える。2 目的の場合、この問題におけるパレート最適フロントの空間は 1 次元になるため、この空間に解を敷き詰めるには、およそ $1/0.1 = 10$ 個の解が必要であると考えられる。同様に、3 目的の場合は 2 次元のパレート最適フロントになるため、およそ $(1/0.1) * (1/0.1) = 10^2$ 個の解、10 目的の場合は、およそ 10^9 の解が必要になると考えられる。この様に、パレート最適フロントを敷き詰めるために必要な解の数は指数的に増加するため、高次元目的関数空間においてパレ-

ト最適フロント全域に解を敷き詰めることは、計算コストを考慮すると極めて困難である。

そこで、多目的最適化の本来の目標であるパレート最適フロント全域に分布する解集合の導出の代わりに、限定された領域内で多様性を有する解集合の導出が目標とする。そして、精度が高く、限定された領域内で多様性を有する解集合を基にして、DM は局所的に各目的間のトレードオフの度合いを把握できるようになると考えられる。この目標を達成するための戦略として、以下の 2 段階のメカニズムを導入する。

- STEP1: パレート最適フロントへの収束

解集合を限定した領域内へ収束させる。高次元目的関数空間では、2 節で述べたように、従来の優越のメカニズムだけでは解集合はパレート最適フロントに収束しない。そのため、それ以外のパレート最適フロントへの収束のメカニズムとして、各解がどの程度限定した領域に即しているかを判断し、それにより選択圧を加える。

- STEP2: 多様性の維持

限定した領域内で解集合の多様性が維持されるようにする。メカニズム 1 のみの戦略では、2 節で述べたように 1 点に収束してしまい、多様性のある解集合を導出できない。そのため、限定した領域内で、多様性を維持するためにはどの解が重要であるのかを判断し、親選択や解保存の際にその情報を利用する。

領域を限定するアプローチの一例として、DM の選好情報を用いる手法が提案されている^{16, 17, 18)}。これらの手法では、DM の選好情報の基準として、希求点 (目的関数空間上に DM が自由に設定する理想の点) を利用する。本戦略に希求点を適用した場合、希求点から最も近くにある 1 つの解に解集合が収束せず、その近傍にも解集合が分布していれば、目標を満たすことができると考える。高次元目的関数空間のための DM の選好情報を用いた多目的最適化の探索戦略を表す概念図を Fig. 4.2 に示す。ただし、本戦略は高次元目的関数空間を対象としているが、視覚的に理解し易くするため、2 目的最小化問題を想定した概念図により表している。




Fig.1 Strategy for Evolutionary Many-Objective Optimization Using Decision Maker's Preferences

ここで、STEP1 に相当する代表的なメカニズムとして、希求点からの距離や希求点との類似度を表現する

achievement scalarizing function¹⁹⁾ などの指標が挙げられる。また、STEP2 に相当する代表的なメカニズムとして、 ϵ -clearing¹⁶⁾ がある。これは、解同士のユークリッド距離がパラメータ ϵ 以上に保たれるようにするメカニズムである。具体的には、ある解集合から無作為に解を選択し、選ばれた解から ϵ 以下の距離にある解を多様性維持のために不必要な解とみなして重要度を下げることによって、淘汰され易くしたり親として選択されにくくする。そして、無作為に選択した解や重要度を下げた解を除いた後の解集合から、再び無作為に解を選択し、同じ処理を繰り返していく。

DM の選好情報を用いた代表的な多目的 GA である Reference point based NSGA-II (R-NSGA-II)¹⁶⁾ では、非優越ソートで各解にランクを付与した後、同一ランクの解集合に対して探索戦略の STEP1 に相当する希求点からのユークリッド距離（各目的を正規化した後のユークリッド距離）、メカニズム 2 に相当する ϵ -clearing を用いており、希求点が複数ある場合にも適用できる。R-NSGA-II を用いれば、高次元目的関数空間においても、精度が高く、また、希求点付近に多様性のある解集合を得ることが出来ると報告されている¹⁶⁾。そのため、DM の選好情報を利用した EMO をパラメータチューニングに適用すれば、数多くの観測値との誤差を目的と捉えながらも、得られた解集合を基に DM は各目的間のトレードオフの度合い等を把握することが可能だと考えられる。次節では、意思決定者の選考情報を用いたパラメータチューニングの有効性を検証する。

4 提案手法の有効性の検討

本節では、テストモデルを用いた数値実験により、提案手法の性能を、他のパラメータチューニング手法の性能と比較する。

4.1 パラメータチューニング手法

本実験では、以下の 4 つアプローチによるパラメータチューニング手法を比較した。

- ・ 1 つの指標への置き換え

1 つの指標として、以下の数式で示される Root Mean Square(RMS) エラーを用いた。

$$RMS\ error = \sqrt{\frac{1}{m} \sum_{i=0}^m \omega_i (f(x_i) - F_i)} \quad (1)$$

上記の数式において、 m は観測値の数、 x_i は観測点の値、 F_i は x_i における観測値、 ω_i は各誤差に対する重みである。本実験では、代表的な単目的最適化手法である Distributed Genetic Algorithm (DGA)²⁰⁾ を用いて、RMS エラーが最小になるような解を導出した。ここで、 ω_i は全て 1 とした。

- ・ 一般的な EMO の適用

代表的な EMO である NSGA-II をパラメータチ

ューニングに適用した。その際に、調整すべきパラメータをそれぞれ設計変数とみなし、各観測値との誤差を目的関数値として扱った。そのため、観測値の数が m ならば、パラメータチューニングは m 目的最適化問題として扱うことになる。

- ・ 選択圧を高める EMO の適用

選択圧を高めるメカニズムの中でも AR が最も性能が高いと報告されているため、AR を用いた NSGA-II をパラメータチューニングに適用した。設計変数と目的関数値は、一般的な EMO の適用の場合と同様に扱った。

- ・ DM の選好情報を利用した EMO の適用

DM の選好情報を利用した EMO の代表例である R-NSGA-II をパラメータチューニングに適用した。希求点は実行可能領域外の理想の領域にも設定することができるので、各観測値に対する重要度に偏りが無いと仮定して、全ての誤差が 0 となる点を希求点として設定した。また、 ϵ を 0.1 とし、設計変数と目的関数値は、一般的な EMO の適用の場合と同様に扱った。

ここで、NSGA-II および DGA のパラメータは Table 1 の通りに設定した。また、AR を用いた NSGA-II、R-NSGA-II では、NSGA-II の場合と同じパラメータを用いた。

Table1 Parameters of NSGA-II and DGA

アルゴリズム	NSGA-II	DGA
探索母集団サイズ	100	100
アーカイブサイズ	100	—
エリートサイズ	—	1 * 鳥数
終了世代	500	500
交叉率	1.0	1.0
交叉方法	2-point crossover	2-point crossover
遺伝子長	20 * 設計変数長	20 * 設計変数長
突然変異率	1.0/遺伝子長	1.0/遺伝子長
混雑度トーナメントサイズ	2	—
トーナメントサイズ	—	4
鳥数	—	10
移住率	—	0.5
移住間隔	—	5

4.2 テスト問題

以下の数式で表した 2 つのテストモデルを作成し、数値実験に利用した。

$$f(x) = \sum_{i=0}^7 (a_i x^i) \quad (2)$$

where $0 \leq x_i < 1$, $-20 \leq a_i < 20$

$$f(x) = a_0(1 + x^{a_1}) \log |a_2 \sin x + a_3 \cos x| - a_4(1 + x^{a_5}) \log |a_6 \sin x + a_7 \cos x| \quad (3)$$

where $0 \leq x_i < 1$, $0 \leq a_i < 20$

上記の数式において、 $f(x)$ の振る舞いが実世界における何らかの現象やシステムを模倣していると仮定する。

a_i は初期設定を行うパラメータであり、 $f(x)$ の振る舞いに大きな影響を及ぼすため、適切に調整される必要がある。(2) はパラメータ同士に依存関係がないモデルを表し、(3) はパラメータ同士に依存関係があるモデルを表す。ここで、実世界における観測点と観測値は Table 2 の通りであると仮定する。

Table2 Observation value in each observation point

x	0.0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Observation value	-3.0	1.0	2.0	0.0	1.0	-1.0	0.0	3.0	1.0	2.0

各観測点においてモデルの出力値 $f(x)$ が観測値に近づくように、パラメータ a_i を調整しなければならない。例えば、 $x = 0.3$ の時の観測値は 0.0 であるため、モデルの出力値 $f(0.3)$ は 0.0 に近づくようにパラメータは設定されるべきである。しかし、各観測値との誤差同士にはトレードオフの関係が存在するため、全ての観測点において観測値との誤差がない出力値を示すパラメータを得ることは不可能である。

4.3 検討事項

・精度

観測値との誤差が低くなればなるほど、得られたパラメータの精度は高いと言える。従って、導出された解集合を用いた際に生じた観測値との誤差についての比較を行った。NSGA-II, AR を用いた NSGA-II, R-NSGA-II の場合、探索終了時のアーカイブに存在する非劣解集合による誤差の最大値、最小値、平均値を各観測点ごとに示した。また、DGA の場合、探索中で最も RMS エラーが低かった解の誤差を示した。

・多様性

得られた解集合は、精度が同程度の場合、DM がトレードオフの度合いや誤差の大きさを理解できるように、多様性を有していることが望ましい。従って、導出された解集合を用いた際のモデルの出力値の分布を確認した。NSGA-II, AR を用いた NSGA-II, R-NSGA-II の場合、探索終了時のアーカイブに存在する非劣解集合によるモデルの出力値を示した。また、DGA の場合、探索中で最も RMS エラーが低かった解の出力値を示した。

4.4 実験結果

・精度

Fig. 2, Fig. 3 はそれぞれ、(2), (3) により定式化されたモデルにおける誤差を示している。比較を簡単にするため、DGA による結果を NSGA-II, AR を用いた NSGA-II, R-NSGA-II の結果のグラフにも示した。

それぞれのグラフにおいて、横軸は観測値 (x)、縦軸は観測値との誤差を表している。両モデル共に、AR を用いた NSGA-II および R-NSGA-II によ

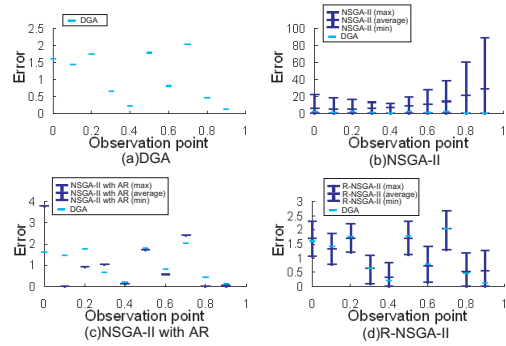


Fig.2 The errors to the observation values of the model formulated by (2)

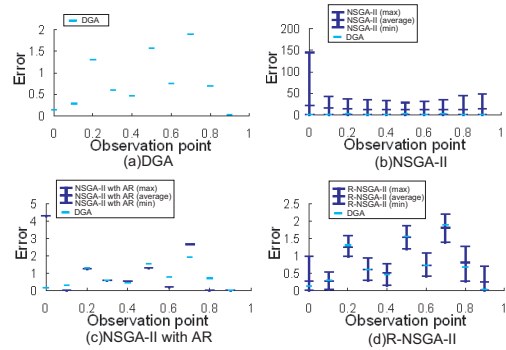


Fig.3 The errors to the observation values of the model formulated by (3)

り得られた解集合の精度は、DGA により得られた解の精度と同程度であったことを確認できる。また、NSGA-II により得られた解集合による誤差は、他の手法によるものよりも著しく高く、精度が悪いことを確認できる。

・多様性

Fig. 4, Fig. 5 はそれぞれ、(2), (3) により定式化されたモデルにおける出力値の分布を示している。

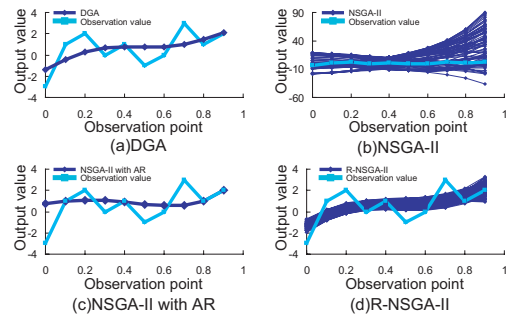


Fig.4 The distribution of output values of the model formulated by (2)

それぞれのグラフにおいて、横軸は観測値、縦軸はモデルの出力値を表している。また、同じ解による出力値であることを表すため、各観測点における出

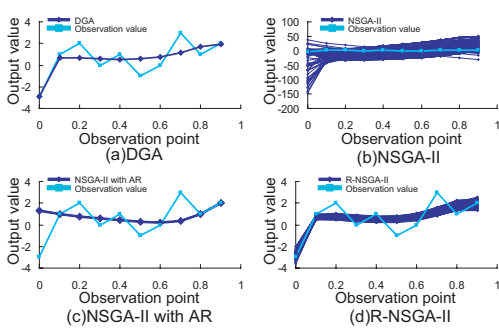


Fig.5 The distribution of output values of the model formulated by (3)

力値を線分で繋いでいる。更に、出力値の分布と一緒に各観測点における観測値も示している。実験結果より、NSGA-II による出力値は幅広く分布したが、観測値から大きく離れてたことを確認できる。また、AR を用いた NSGA-II による出力値は、1 点に集中してしまったことが分かる。それに対し、R-NSGA-II による出力値は、希求点付近に多様性を有しながら分布した。

上記の数値実験から、一般的な EMO を適用したパラメータチューニングでは、誤差が低くなるパラメータを得ることができず、1 つの指標への置き換えるパラメータチューニングや選択圧を高める EMO を適用したパラメータチューニングでは、多様性のある解集合を得られないことが分かった。それに対し、DM の選好情報を利用した EMO を適用したパラメータチューニングでは、精度が高く、希求点付近に多様性のある解集合を導出できることを確認できた。

5 実問題への適用

本節では、テストモデルにおいて有効性を示した DM の選考情報を用いたパラメータチューニングを、実問題の例としてディーゼルエンジンの燃焼モデルの 1 つである HIDECS に適用した。提案手法の性能を確認するため、前節で用いた DGA (1 つの指標へ置き換える例)、NSGA-II (一般的な EMO を適用する例)、AR を用いた NSGA-II (選択圧を高める EMO を適用する例) によるチューニング結果と、精度および多様性の観点から比較した。

5.1 HIDECS

近年、世界規模で CO₂ の削減が大きな注目を集めており、その中でディーゼルエンジンが見直されている。ディーゼルエンジンは燃費に優れており、単位出力に対して、CO₂ の排出が少ないからである。また、これまでディーゼルエンジンはすすなどの排出の問題がとりざたされていたが、それらの技術的な対処もなされ、これまで利用されていたものよりもさらに効率的な小型のディーゼルエンジンが広く利用されるようになってきた。このような背景に対して、小型のディーゼルエンジンのシミュ

レーションに関する研究例はほとんどみられない。一方で、これまで行われてきた中・大型ディーゼルエンジンのシミュレーションを内在するパラメータを調整することで利用することができれば非常に大きな効果が期待できる。そのため、まず、実験において対象となるエンジンのクランク角とシリンダ圧力のデータを測定する。ボア径やクランク長などといった物理的な値は測定から求まるので、シミュレーションにおいて、もっとも影響するパラメータは空気導入率となる。そこで本実験では、ディーゼルエンジンの燃焼をシミュレートする現象論的モデルの 1 つである HIDECS において、5 つの空気導入率を変化させることにより、実験によって得られた各クランク角におけるシリンダ圧力のデータにフィッティングさせる。調整すべき空気導入率の数は 5 であり、それぞれ 0.0 ~ 3.0 の範囲内で、0.1 間隔で制御可能である。クランク角度は 7.0 から 50 まで 1.0 ずつ増加させるので、観測点の数は 58 となり、各クランク角度に対応するシリンダ圧力を観測値として扱った。また、各パラメータチューニング手法を適用する際、遺伝子長を 5* 設計変数長とし、その他のパラメータを前節の実験と同様に設定した。

5.2 実験結果

・精度

Fig. 6 は HIDECS における観測値 (シリンダ圧力) との誤差を示している。比較を簡単にするため、DGA による結果を NSGA-II、AR を用いた NSGA-II、R-NSGA-II の結果のグラフにも示した。

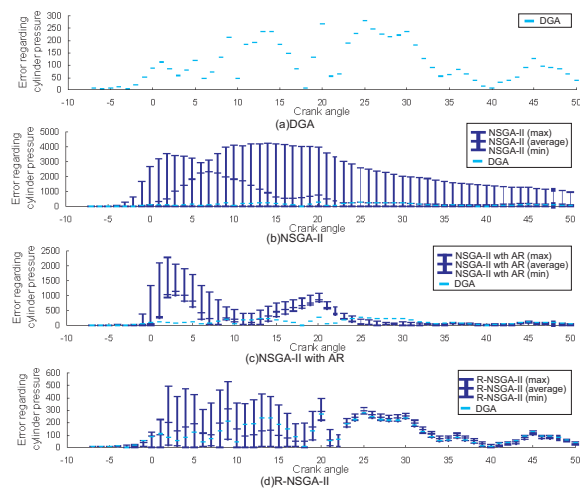


Fig.6 The errors to the observation values of HIDECS

それぞれのグラフにおいて、横軸はクランク角度 (観測点)、縦軸は観測したシリンダ圧力との誤差を表している。テスト問題を用いた実験結果同様、R-NSGA-II による解集合の精度は DGA と同程度であり、NSGA-II による解集合の精度は他の手法のものより著しく悪かったことを確認できる。一方、テストモデルを用いた実験結果とは異なり、AR を用いた NSGA-II による解集合の精度は DGA や R-NSGA-II

Iのものよりも悪くした。

これは、58 目的という問題に対し、AR の選択圧が低下したためだと考えられる。例えば、2 目的最小化問題に AR を適用した場合、 f_1 、 f_2 のそれぞれについてのランクが 1, 9 の解にも 9, 1 の解にも同じ適合度 10 が付与される。つまり、AR を用いた探索において、 f_1 が低い領域にある解も f_2 が低い領域にある解も重要視される。ここで、もしも目的数が増えれば、同じ適合度になる各目的のパターンが増加するため、AR によって重要視される領域も増加する。従って、HIDECS のパラメータチューニングのような 58 目的の問題では、AR によって重要視される領域が広くなり過ぎたため、選択圧が低下したのだと考えられる。

多様性

Fig. 7 は HIDECS における解集合の出力値（シリンダ圧力）の分布を示している。シリンダ圧力はクランク角度によって大きく変化するため、1 つのグラフに全てのクランク角度における出力値を表すと、各クランク角度における多様性の確認が難しくなる。そのため、クランク角度の範囲が -7.0 ~ 5.0, 5.0 ~ 20.0, 20.0 ~ 35.0, 35.0 ~ 50.0 のそれぞれの場合に対応した 4 つのグラフに分割して、実験結果を示した。

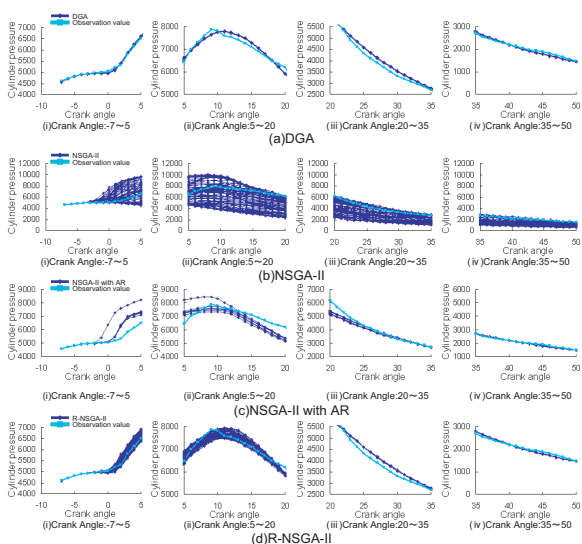


Fig.7 The distribution of output values of HIDECS

それぞれのグラフにおいて、横軸はクランク角度（観測点）、縦軸は HIDECS において出力されたシリンダ圧力を表している。また、同じ解による出力値であることを表すため、各観測点における出力値を線分で繋いでいる。更に、出力値の分布と一緒に各クランク角度における実際に観測されたシリンダ圧力も示している。

実験結果より、NSGA-II および AR を用いた NSGA-II による出力値は幅広く分布したが、観測

値から大きく離れたことを確認できる。AR を用いた NSGA-II による出力値が、テストモデルの実験のように 1 点に集中しなかったのは、上記に説明した精度が低下した理由と同じであると考えられる。それに対し、R-NSGA-II による出力値は、希求点付近に多様性を有しながら分布したことを確認できる。

以上の HIDECS を用いた実験から、意思決定者の選好情報を用いたパラメータチューニングは、実問題においても精度が高く、多様性のある解集合を導出できることが確認できた。この HIDECS のパラメータを決定する課題において、1 つの指標を導入する方法、選択圧を高める EMO を利用する方法のように、多様性のないパラメータや 1 つのパラメータしか提示されなければ、DM は最終的に使用するパラメータに関する情報を得にくくなる。例えば、DGA により得られたパラメータを用いた HIDECS では、Fig. 6(a) に示すように、クランク角度が 9.0 の時の誤差が 213.80 であり、-1.0 の時の誤差が 51.95 である。しかし、単純に 213.80 と 51.95 を比較して 213.80 の方が高いからと言って、クランク角度が 9.0 の時の誤差について大きく妥協し、-1.0 の時の誤差については余り妥協していないと、DM は断定することはできない。それは、誤差が起りうる範囲が各クランク角度によって大きく異なるからである。それに対し、R-NSGA-II により得られた解集合を参照すれば、各解がそれぞれの誤差に対してどの程度妥協しているのかを把握することができると思われる。例えば、R-NSGA-II により得られた解集合の 1 つを用いた HIDECS では、クランク角度が 9.0 の時の誤差が 167.36 であり、-1.0 の時の誤差が 52.02 である。そして、Fig. 6(d) に示す解集合の誤差の範囲を参照すれば、DM が最終的に選んだパラメータが、クランク角度が -1.0 の時に大きく妥協し、9.0 の時に余り妥協していないことが分かる。

また、R-NSGA-II を用いたパラメータチューニングでは、対象モデルの特徴も把握できると考えられる。DGA により得られたパラメータを用いた HIDECS では、Fig. 6(a) に示すように、クランク角度が 25.0 の時の誤差が 278.89 であり、14.0 の時の誤差が 233.71 である。しかし、これだけでは、パラメータが原因で誤差が大きくなったのか、HIDECS の特徴として誤差が大きくなるおえなかったのか分からない。それに対し、R-NSGA-II により得られたパラメータの出力値の分布 Fig. 7(d) を参照すれば、クランク角度が 25.0 の時は観測値から離れて分布し、クランク角度が 14.0 の時は観測値の近くに分布していることが確認できる。この情報を基に DM は、クランク角度が 25.0 の時は、HIDECS の特徴として、小さな誤差の出力値を得ることが難しく、クランク角度が 14.0 の時は、他の観測点での誤差を妥協すれば、小さな誤差の出力値が得られることを理解できる。

このように、意思決定者の選好を用いたパラメータチューニングにより、精度が高く、多様性のあるパラメータを導出すれば、DM は各パラメータの特徴や対象モデルの特徴を把握できることが分かる。

6 まとめ

本稿では、数多く存在する観測値との誤差の最小化をそれぞれ目的と捉えるパラメータチューニング手法を提案した。数多くの目的を有する多目的最適化問題に NSGA-II や SPEA2 といった一般的な EMO に適用させた場合、探索の初期段階からアーカイブ内の全ての解が非劣解になってしまうため、探索性能は著しく悪くなる。更に、非劣解に異なる適合度を割り当てたり、優越の定義を拡張することにより選択圧を高める多目的最適化手法が提案されているが、これらの手法を用いると買い集合の多様性が失われてしまう。一方で、本来は高次元目的関数空間においてもパレートフロント全域に分布する解集合を得ることが望ましいが、これは計算コストを考慮すると非常に困難である。そのため、パレート最適フロント全域に分布する解集合の導出の代わりに、限定された領域内で多様性を有する解集合の導出を目標とし、探索領域を DM の選好情報を基にして限定するパラメータチューニング手法を提案した。テストモデルや HIDECS を用いた数値実験を通して、提案手法により、精度が高く、希求点付近に多様性のある解集合を導出できることが分かった。そして、それらの解集合を基に、DM は各解の特徴や対象モデルの特徴を把握できることを確認できた。

参考文献

- 1) Andrew R. Price, I. I. Voutchkov, Graeme E. Pound, N. R. Edwards, Timothy M. Lenton and Simon J. Cox. Multiobjective Tuning of Grid-Enabled Earth System Models Using a Non-dominated Sorting Genetic Algorithm (NSGA-II). Proceedings of the Second IEEE International Conference on e-Science and Grid Computing. Amsterdam, Netherlands, IEEE, 117-117, 2006.
- 2) Yasue Mitsukura, Toru Yamamoto, and Masahiro Kaneda. Genetic Tuning Scheme of PID Parameters for First-Order Systems with Large Dead Times. IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences Vol.E83-A No.4 pp.740-746, 2000.
- 3) J.C. Hargreaves, J.D. Annan, N.R. Edwards and R. Marsh. An efficient climate forecasting method using an intermediate complexity earth system model and the ensemble Kalman filter. *Climate Dynamics* 23(7-8) pp. 745-760, 2004
- 4) J.M. Herrero, X. Blasco, M. Marti'nez, J. Sanchis. Multiobjective Tuning of Robust PID Controllers Using Evolutionary Algorithms. *Lecture Notes in Computer Science*, 4974, pp. 515 - 524, 2008.
- 5) Hiroyuki Hiroyasu, Toshikazu Kadota, and Masataka Arai. Development and Use of a Spray Combustion Modeling to Predict Diesel Engine Efficiency and Pollutant Emissions (Part 1 Combustion Modeling). *Bulletin of the JSME*, Vol. 26, No. 214, pp. 569.575, April 1983.
- 6) Hiroyuki Hiroyasu, Toshikazu Kadota, and Masataka Arai. Development and Use of a Spray Combustion Modeling to Predict Diesel Engine Efficiency and Pollutant Emissions (Part 2 Computational Procedure and Parametric Study). *Bulletin of the JSME*, Vol. 26, No. 214, pp. 576.583, April 1983.
- 7) K. Deb, S. Agrawal, A. Pratab and T. Meyarivan. A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II, In KanGAL report 200001, Indian Institute of Technology, Kanpur, India, 2000.
- 8) E. Zitzler, M. Laumanns and L. Thiele. SPEA2: Improving

the Performance of the Strength Pareto Evolutionary Algorithm. In *Technical Report 103*, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH) Zurich, 2001.

- 9) Tomoyuki Hiroyasu, Hiroyuki Ishida, Mitsunori Miki, and Hisatake Yokouchi. Difficulties of Evolutionary Many-Objective Optimization. <http://mikilab.doshisha.ac.jp/dia/research/report/2008/1006/004/report20081006004.html>, 2008.
- 10) V. Khara, X. Yao, and K. Deb. Performance scaling of multi-objective evolutionary algorithms. *Lecture Notes in Computer Science 2632: Evolutionary Multi-Criterion Optimization - EMO 2003*, pp. 376-390, Springer, Berlin, 2003.
- 11) Bentley, P.J. and Wakefield, J.P. Finding acceptable solutions in the Pareto-optimal range using multiobjective genetic algorithms. Chawdhry, P.K., Roy, R., & Pant, R.K. (eds) *Soft Computing in Engineering Design and Manufacturing*. Springer Verlag London Limited, Part 5, 231-240, 1997.
- 12) Drechsler, N., Drechsler, R., Becker, B. Multi-objective optimisation based on relation favour. In *Proc. 1st EMO*, pp. 154.166, Springer Verlag, 2001.
- 13) di Pierro, F. Many-objective evolutionary algorithms and applications to water resources engineering. PhD thesis, University of Exeter, UK, August 2006.
- 14) David W, Corne and Joshua D, Knowles. Techniques for Highly Multiobjective Optimisation: Some Nondominated Points are Better than Others. *Proceedings of the 9th annual conference on Genetic and evolutionary computation*, 773-780, 2007.
- 15) H. Sato, H. E. Aguirre, and K. Tanaka. Controlling dominance area of solutions and its impact on the performance of MOEAs. *Lecture Notes in Computer Science 4403: Evolutionary Multi-Criterion Optimization - EMO 2007*, pp. 5-20, Springer, Berlin, March 2007.
- 16) K. Deb and J. Sundar. Reference point based multi-objective optimization using evolutionary algorithms. In *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO-2006)*, 635-642, 2007.
- 17) K. Deb and A. Kumar. Interactive evolutionary multi-objective optimization and decision-making using reference direction method. In *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO-2007)*, pages 781-788. New York: The Association of Computing Machinery (ACM), 2007.
- 18) L. Thiele, K. Miettinen, P. Korhonen, J. Molina, A preference-based interactive evolutionary algorithm for multiobjective optimization, *Technical Report Working Paper Number W-412*, Helsingin School of Economics, Helsingin Kauppakorkeakoulu, Finland, 2007.
- 19) P. Korhonen and J. Laakso. A visual interactive method for solving the multiple criteria problem. *European Journal of Operational Research*, 24:277-287, 1986.
- 20) Reiko Tanese. *Distributed Genetic Algorithms*, Proceedings of the Third International Conference on Genetic Algorithms, pp434-439, 1989.