



エンジン制御パラメータの実験ベース 進化的多目的最適化

Experiment-Based Evolutionary Multi-objective Optimization of
Engine Control Parameters

梶 洋隆 喜多一

Abstract

In order to accommodate the various evaluation norms involved in testing and adjusting performance of a motor vehicle engine, including toxic gases in the exhaust (CO, HC, NO), fuel efficiency and output/torque, there is a need to optimize the control parameters. However, the relationships between these parameters are usually of the “trade off” type where improving one detracts from the effectiveness of the other. Furthermore, the growing number of electronic control systems on today’s engines and the corresponding growth in control parameters makes it increasingly difficult to manually adjust performance. To deal with this problem, we focused our attention on an experiment-based (test-based) approach that uses the actual engine as part of a simulation program, thus allowing the optimizing methods to be applied directly to the engine. Based on this approach, we have been conducting research and experiments in which Multi-objective Evolutionary Algorithms (MOEA) are applied as an effective form of multi-objective optimization directly to an actual test engine. In this report we present the results of experiments on an actual engine to show how MOEA and their accelerated methods were used to greatly reduce the time required for experiment-based optimization.

要旨

自動車用エンジンの適合では、排出ガスの有害成分量(CO、HC、NO_x)・燃費・出力トルクなどの複数の評価規範を満たすように制御パラメータを調整する必要がある。しかしながら、これらは一般にトレードオフの関係にある。さらに、エンジンに付加される電子制御装置とその制御パラメータの数の増加にともない、手動による適合は困難さを増してきている。これに対し我々は、実機をシミュレーションの一部に組み込んで最適化手法を直接適用する実験ベースのアプローチに注目している。そして、最適化アルゴリズムとして多目的最適化の有力な手法である多目的進化アルゴリズム(Multi-objective Evolutionary Algorithms, MOEA)を直接、実機に適用する手法の研究を進めている。本論文では、エンジンの実験ベース最適化にMOEAとその加速手法を適用し、最適化時間を大幅に削減できることを実機実験により示す。

1 はじめに

自動車・モーターサイクル用エンジンの制御パラメータは、排出ガスの有害成分量(CO、HC、NO_x)・燃費・出力トルクなどの複数の評価規範を高い次元でバランスさせるように適合する必要がある。しかしながら、これらは一般にトレードオフの関係にあるものが多く、多目的最適化問題と呼ばれるクラスの問題を解いていることに相当する。さらに、エンジンに付加される電子制御装置とその制御パラメータの数は増加してきており、手動による適合は困難さを増してきている。

このような背景から、エンジンの開発期間に占める適合工程の割合は増加傾向にあり、適合の効率化・自動化が進められている。適合の自動化には大きく分けて3種類のアプローチが考えられる。

(1) 物理シミュレーションベースの適合

熱・流体・機構などのエンジンの詳細な物理モデルを構築し、シミュレーション上で適合を行う方法である。実機エンジンを用いることなく、完全にオフラインで適合を行うことができる。しかしながら、エンジンの挙動は複雑なために詳細な物理モデルの構築は容易ではなく、その計算時間も実機より長くなってしまうこともある。

(2) 応答曲面法ベースの適合

応答曲面法(Response Surface Methodology, RSM)⁸⁾とは、実験計画法(Design of Experiments, DoE)と統計モデルに基づく最適化手法である。実機エンジンで評価すべき制御パラメータの数を大幅に削減して適合期間を短縮することが可能であり、多くの事例が報告されている⁹⁾。しかしながら、開発中のエンジンの仕様変更されるたびに近似モデルを作成しなおす必要があり、調整可能なパラメータが増加するたびにモデル選択と実験計画をやりなおす必要がある。また、非線形性の強いエンジン特性を2次多項式などの単純な関数で近似すると、大きな推定誤差を生む可能性があり、結果への影響が無視できない。

(3) 実験ベースの適合

実機をシミュレーションの一部に組み込んで最適化手法を直接適用する方法である。近年の計測制御技術の発展により、このような実験環境の利用が現実的になってきている。実機を直接最適化するので、詳細な物理モデルや近似的な統計モデルを作成する必要がなくなる。一方で、計測に実時間が必要である、評価値にセンサーの観測ノイズやダイナミクスなどの不確実性が含まれる、などの問題がある。

我々は、(3)の実験ベースのアプローチに注目し、最適化アルゴリズムとして多目的最適化の有力な手法である多目的進化アルゴリズム(Multi-objective Evolutionary Algorithms, MOEA)を直接実機に適用する研究を進めている。本論文では、MOEAを実機に直接適用するアプローチを実験ベース進化的多目的最適化(Experiment-Based Evolutionary Multi-objective Optimization, EBEMO)と呼ぶ。そして、エンジンのEBEMOにMOEAの加速手法を適用し、従来のMOEAよりも最適化時間を大幅に削減できること示す。

2 多目的最適化問題と多目的進化計算手法

実世界における最適化問題の多くは、**図1**に示すような複数の対立する評価規範(目的関数)を満たすような合理解の集合であるPareto最適解を求める、多目的最適化問題(Multi-objective Optimization Problems, MOP)に帰着できる。

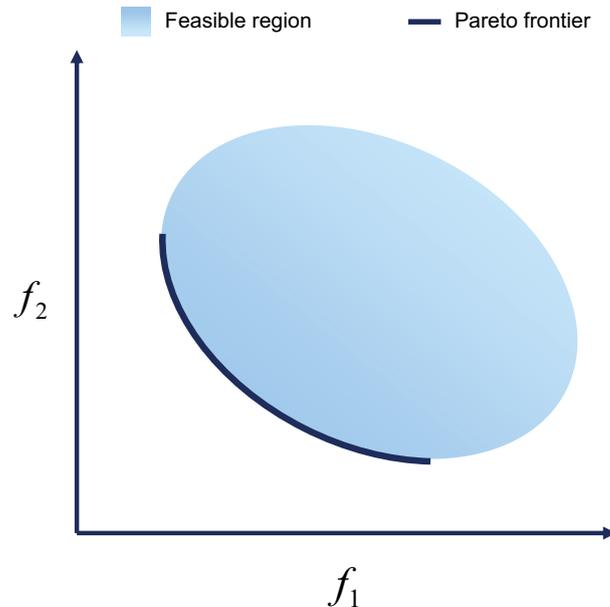


図1 Pareto frontier

n 変数 m 目的最適化問題は

$$\begin{aligned} & \min_{\mathbf{x}} \mathbf{f}(\mathbf{x}) \\ & \text{subject to } \mathbf{x} \in X = \left\{ \mathbf{x} \mid \mathbf{x} \in \mathbb{R}^n, \mathbf{g}(\mathbf{x}) \leq 0 \right\} \end{aligned}$$

のように定義される。ここで $\mathbf{x} = [x_1 \cdots x_n]^T$ は n 次元決定変数ベクトル、 $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \cdots f_m(\mathbf{x})]^T$ は m 次元目的関数ベクトル、 $\mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}) \cdots g_l(\mathbf{x})]^T$ は l 次元制約条件ベクトルである。 $\mathbf{f}(\mathbf{x}) \leq \mathbf{f}(\mathbf{x}^*)$ を満たす $\mathbf{x} \in X$ が存在しないとき、 $\mathbf{x}^* \in X$ をPareto最適解と呼ぶ。ただし、 $\mathbf{f}(\mathbf{x}) \leq \mathbf{f}(\mathbf{x}^*)$ は $f_i(\mathbf{x}) \leq f_i(\mathbf{x}^*), \forall i = 1, \dots, m$ と定義される。

MOPの実用的な解法として、生物の進化に着想を得た多目的最適化手法である多目的進化アルゴリズム(MOEA)が注目されている。MOEAは、遺伝的アルゴリズム(Genetic Algorithms, GA)³⁾に代表される進化計算手法の多点探索という特徴を活かして、Pareto最適解集合を一括して求めることができる。そして、その適用範囲の広さから様々な分野で応用されており、工学分野ではシミュレーションと組み合わせた方法がよく用いられている。

本論文では、代表的なMOEAであるNSGA-II²⁾を採用する。そして、実機エンジンのEBEMOによりトレードオフをなす制御パラメータの集合を一括して求めることを試みる。

なお、進化計算手法では慣例的に決定変数ベクトルを個体、個体の集合を個体群、目的関数を適応度関数、目的関数を適応度などと呼ぶ。本論文でも、特に断りのないかぎりこれらの表記は慣例にしたがう。

3 適応度推定による多目的進化計算の加速

シミュレーションとは異なり、実機エンジンの出力にはセンサーの観測ノイズや、制御パラメータの切換による変動などの不確実性が含まれる。従来のMOEAは、このような不確実性により最適化性能が低下することが知られている。これまでに我々は、この課題を解決するための研究を進め、実機エンジンを用いた実験により最適化性能の向上を確認している^{4,6)}。しかしながら、MOEAは一般に多くの評価回数を要するために、最適化に要する時間が熟練したエンジン適合技術者に及ばないという課題が残されていた。

そこで、この課題を解決するために、進化計算手法の加速手法を導入する。加速手法として、過去に評価した個体と適応度から最適化対象の近似モデルを生成して利用する方法が主流である。加速手法の概念図を図2に示す。近似モデルに必要な評価時間は実問題のそれに比べて無視できるほど小さいので、実質的な評価回数を低減することが可能である。そして、Computational Fluid Dynamics (CFD) など、1回あたりの評価時間が非常に大きなシミュレーションを中心に多くの研究が報告されている。

本論文で用いるPre-selectionは加速手法の一種であり、多数生成された子個体を近似モデル上で事前評価し、有望なものだけを実環境で評価することで効率的に最適化を行う。Pre-selectionの概念図を図3に示す。MOEAのPre-selectionはこれまでもいくつか提案されているが、適応度の不確実性を考慮しておらず、エンジンのEBEMOには適していなかった。そこで我々は、独自のPre-selectionアルゴリズムを開発した。そして、ノイズに強い近似モデリング手法である局所重み付き回帰 (Locally Weighted Regression, LWR)¹⁾ を組み合わせることにより、不確実性のある環境下でもMOEAによる最適化を加速できることを数値実験により確認した⁷⁾。

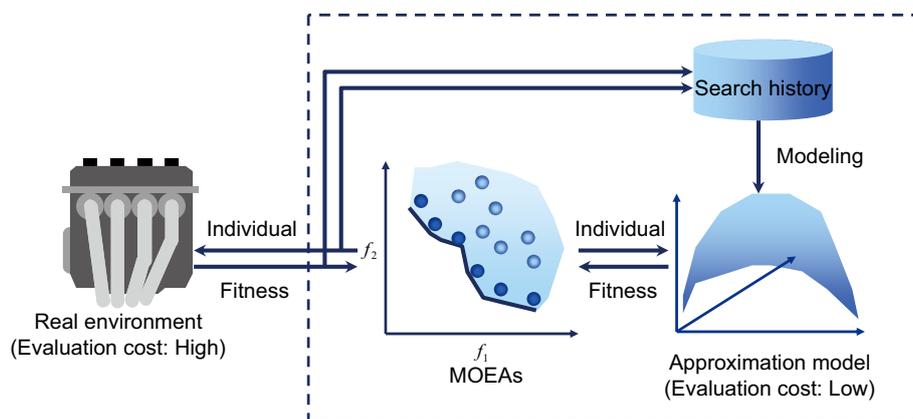


図2 An acceleration method using fitness estimation

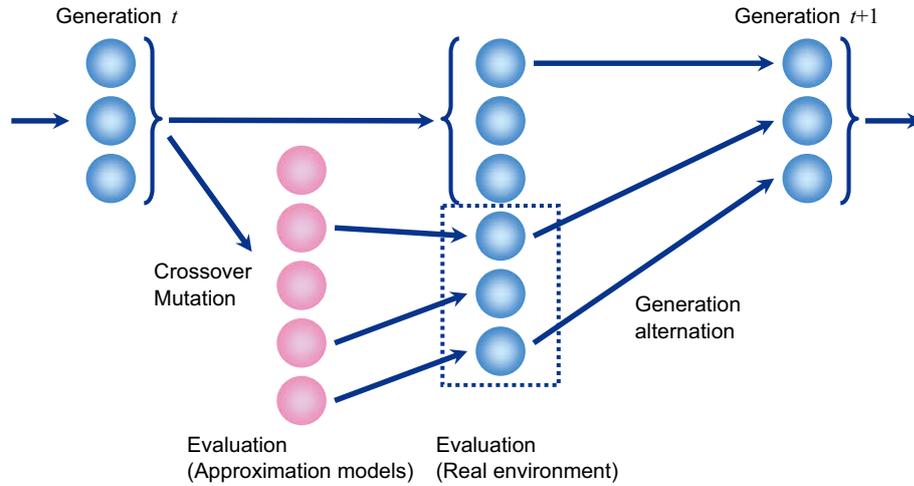


図3 Conceptual diagram of the Pre-selection algorithm

開発したPre-selectionアルゴリズムを以下に示す。

- ① 期個体群 $P(0)$ の適応度 $f(x)$ を実環境で評価し、探索履歴 H に保存する。
- ② 個体群 P に選択、交叉および突然変異を適用し、候補子個体群 Q_C を生成する。
- ③ H を用い、 $R_C = P \cup Q_C$ の推定値 $\hat{f}(x)$ をLWRにより求める。
- ④ $\hat{f}(x)$ に基づいて R_C のランキングを α -domination 戦略を用いて行う。
- ⑤ 非劣個体となった子個体候補を一つ取り出し、 P に加えたときの混雑度を計算する。子個体候補がなくなるまで、この操作を繰り返す。
- ⑥ 非劣個体となった子個体候補を混雑度の良い順に整列し、上位 q 個体を評価子個体群 Q とする。
- ⑦ Q を実環境で評価し、 $f(x)$ を H に保存する。
- ⑧ $\hat{f}(x)$ に基づいて $R = P \cup Q$ のランキングと混雑度計算を行い、世代交代をして②に戻る。

なお、 H に保存された個体数がLWRの必要数に達するまでは実環境のみで評価を行う。④の α -domination戦略は、推定誤差により非劣個体として扱われてしまう個体を排除するために用いる^{4,7)}。⑧の混雑度としてはDebらの混雑度距離²⁾を用いる。

4 実機エンジンによる実験

4.1 実験の設定

代表的なMOEAであるNSGA-II²⁾と、提案するPre-selectionを導入したNSGA-II(以下、単にPre-selectionと呼ぶ)を大型モーターサイクル用の4サイクルガソリンエンジンに適用し、提案手法の効果を確認する。実験環境を図4に示す。実験環境は、エンジン・エンジン試験機・計測器などから構成される。NSGA-IIおよびPre-selectionを実装した適合用PCは、エンジンを制御するECU(Engine Control Unit)の制御パラメータを自由に変更可能であり、実験環境をハードウェアを含む一種のシミュレーション(Hardware In the Loop Simulation, HILS)とみなして多目的最適化を実施する。

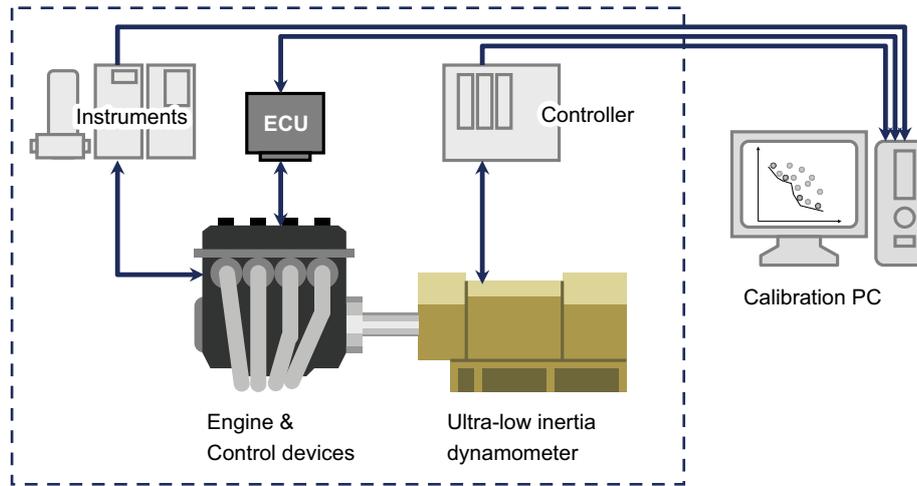


図4 Block diagram of the HILS environment

実施する2目的4変数の最適化問題の設定は以下のとおりである。

目的関数(適応度関数):出力トルクの最大化、燃料消費量の最小化

制御パラメータ(個体):燃料噴射時期(INJ)、点火時期(ING)、目標空燃比(AFR)、バルブ制御パラメータ(VCP)

AFRは空燃比フィードバック制御の目標値、VCPはバルブ制御装置の目標値である。目的関数値はエンジン回転速度一定の条件で計測する。個体で表される制御パラメータ(INJ、IGN、AFR、VCP)を適合用PCから送信すると、ECUの制御パラメータが切り替えられる。その後、ECUにより制御されたエンジンの出力トルク・燃料消費量を一定間隔で受信する。適合用PCは、切換に伴う過渡応答の影響を排除するために一定時間の受信データを無視し、そこから所定の時間のデータの平均値を個体の適応度としてMOEAを実行する。

NSGA-IIとPre-selectionの最適化終了後には、得られた個体群の検証実験を行う。検証実験では、個体を切り替えてから出力が安定するまで待ち、十分な時間をかけて測定したデータを真の適応度として比較に用いる。

NSGA-IIの設定は、個体群サイズ $|P| = 30$ 、子個体群サイズ $|Q| = 30$ 、打ち切り評価回数1530回(個体群 P の再評価あり、25世代)とし、交叉演算としてUNDX-P⁵⁾を用いる。Pre-selectionの設定は、個体群サイズ $|P| = 30$ 、候補子個体群サイズ $|Q_c| = 100$ 、評価子個体群サイズ $|Q| = 4$ 、打ち切り評価回数1530回(個体の再評価なし、375世代)とし、LWRで用いる k -最近傍法の近傍集合サイズ k を探索履歴に保存された個体数の5%とする。また、交叉演算としてUNDX-Pを用いる。

4.2 実験結果と考察

Pre-selection は評価回数130 回で十分収束していたことから、NSGA-IIの1530回の評価後に得られた個体群とPre-selectionの130回の評価後に得られた個体群を比較する。いずれのグラフも、軸は正規化した値で表している。

(1) 目的関数空間における特徴

最適化に用いた適応度と検証テストで得られた真の適応度を図5、6 に示す。また、真の適応度同士の比較を図7に示す。最適化問題は出力トルクの最大化と燃料消費量の最小化であるので、グラフの右下方向に行くほど良い個体となる。グラフより、以下のことが分かる。

- ・ 実験で用いたエンジンの出力トルクと燃料消費量のPareto境界(トレードオフ)は、(出力トルク, 燃料消費量) = (0.8, 0.8)から(0.5, 0.55)の間に直線状に存在している。
- ・ Pre-selectionで用いた適応度は、NSGA-IIのそれに比べて真の適応度に非常に近い。
- ・ Pre-selection の真の適応度はNSGA-IIのそれに比べて、0.8 付近の燃料消費量が特に改善されている。これは、ノイズを含むデータに対してLWR が適応度を精度よく推定するので、最適化が停滞しないためであると考えられる。

(2) 決定変数空間における特徴

決定変数空間上の解分布の様子を図8、9に示す。グラフより、以下のことが分かる。

- ・ 燃料噴射時期INJ とバルブ制御パラメータVCPに強い相関関係が見られる。
- ・ 点火時期IGN とVCP に弱い相関関係が見られる。
- ・ 目標空燃比AFR がほぼ1 付近に収束している。AFR に関する探索領域の制約条件を広げることで更なる性能の改善が期待できる。
- ・ VCP は他のパラメータに比べ、0 から0.5 の範囲を大きく動いており、Pareto境界の形状はVCP に強く依存していると考えられる。
- ・ Pre-selectionの個体群はNSGA-IIのそれよりも収束が進んでいる。

NSGA-II では、実際には1000 回弱程度の評価で個体群がほぼ収束しており、したがって今回の実験条件ではPre-selection により最適化時間を1/7 に低減できたといえる。得られたPareto最適解には妥当性があり、低減された最適化時間も十分に実用レベルであることをエンジン適合技術者との議論により確認している。

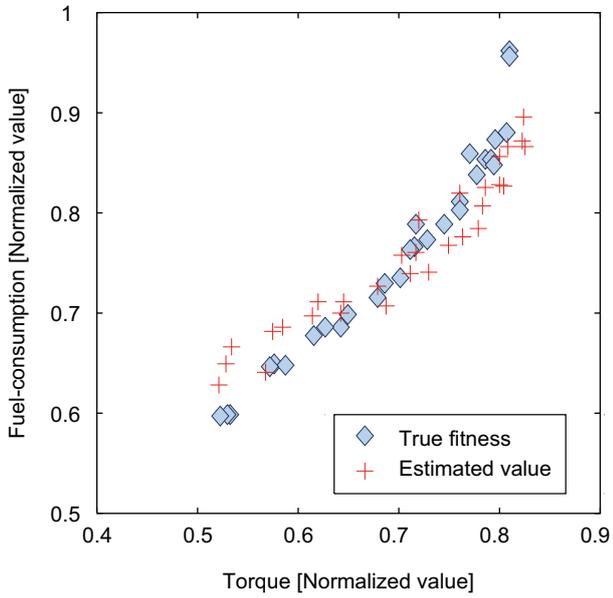


図5 Population distribution in the objective function space (NSGA-II, 1530 evaluations)

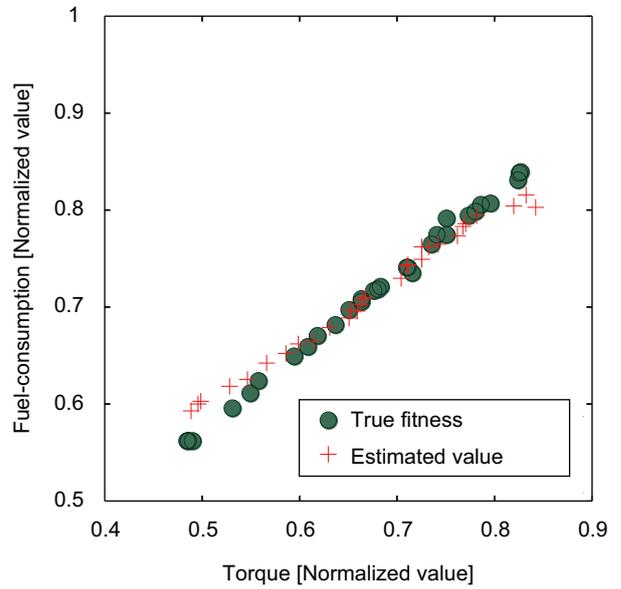


図6 Population distribution in the objective function space (Pre-selection, 130 evaluations)

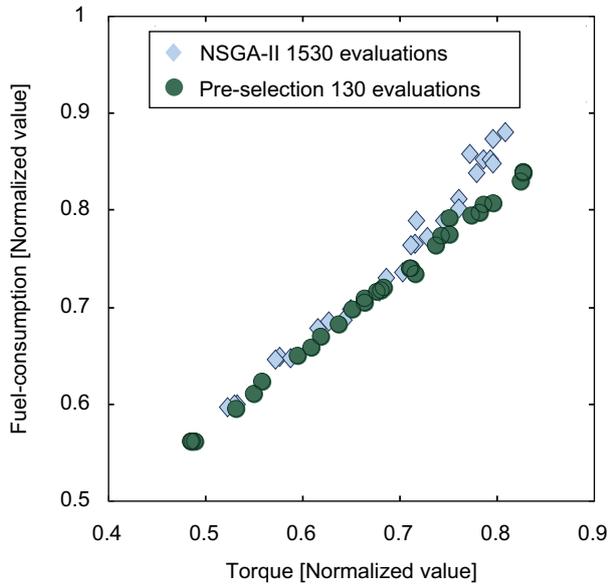


図7 Comparison of approximation Pareto frontiers

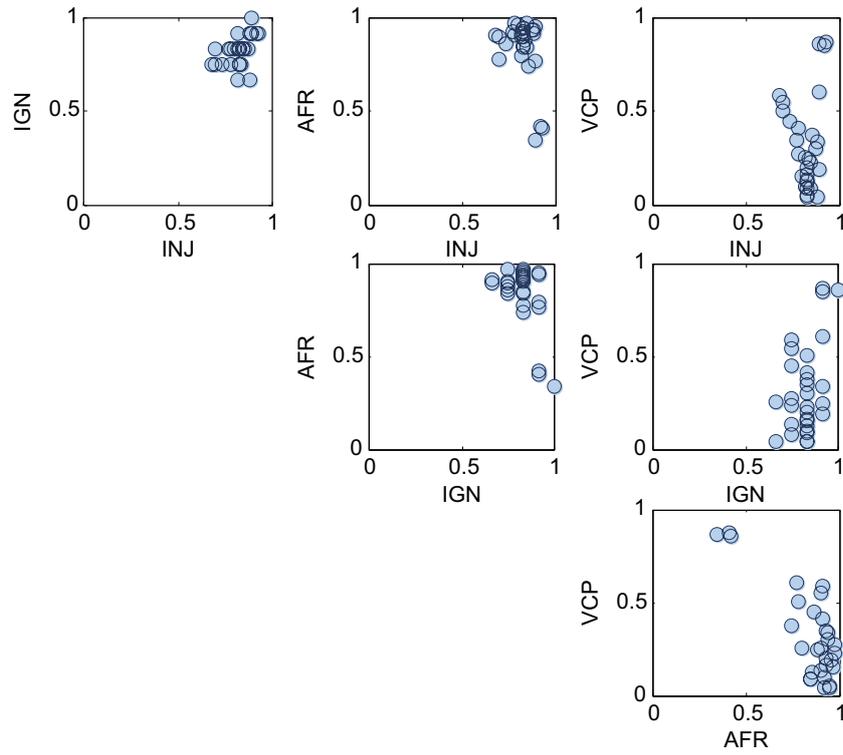


図 8 Population distribution in the decision variable space (NSGA-II, 1530 evaluations)

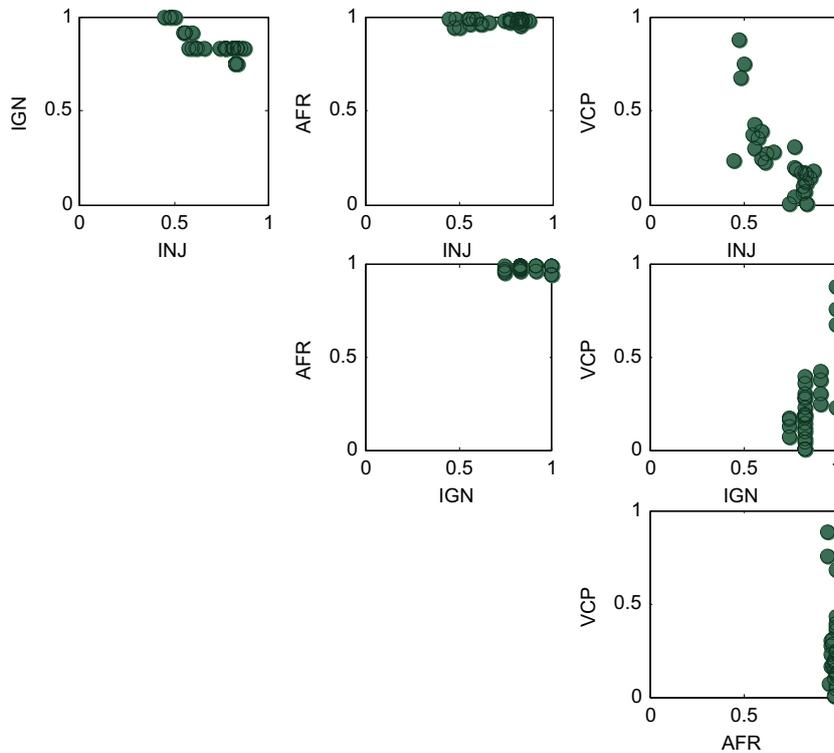


図 9 Population distribution in the decision variable space (Pre-selection, 130 evaluations)

5 おわりに

本論文では、従来の応答曲面法(RSM)ベースとは異なる適合の自動化へのアプローチとして、実験ベースの最適化に注目した。そして、適合を多目的最適化問題として扱い、実機エンジンの2目的4変数最適化問題に対して多目的進化アルゴリズム(MOEA)とその加速手法であるPre-selection を適用した。その結果、通常のNSGA-IIを適用した結果と比べて最適化の精度を改善しつつ時間を1/7程度に低減でき、実用レベルの最適化時間を達成できることが分かった。今後は、Pre-selectionに加えて、適合に特化した改良を行っていくことで適合手法としての実用性を向上させ、今回の実験よりも制御パラメータや目的関数の多い、より複雑な問題に取り組んでいく予定である。

■参考文献

- 1) C. G. Atkeson, A. W. Moore, and S. Schaal: Locally Weighted Learning, Artificial Intelligence Review, Vol. 11, pp. 11-73 (1997)
- 2) K. Deb, S. Agrawal, A. Pratab, and T. Meyarivan: A Fast and Elitist Multi-objective Genetic Algorithm: NSGA-II, IEEE Trans. on Evolutionary. Computation., Vol. 6, No. 2, pp. 182-197 (2002)
- 3) D. E. Goldberg: Genetic Algorithms in Search, Optimization, and Machine Learning, Addison-Wesley (1989)
- 4) 梶: 不確実な関数を最適化する多目的遺伝的アルゴリズムの提案, システム制御情報学会論文誌, Vol. 18, No. 12, pp. 423-432 (2005)
- 5) 梶, 喜多: 周期関数最適化のための遺伝的アルゴリズムの交叉演算, 計測自動制御学会論文集, Vol. 43, No. 4, pp. 323-330 (2007)
- 6) H. Kaji, and H. Kita: Individual Evaluation Scheduling for Experiment-Based Evolutionary Multi-objective Optimization, Proc. of EMO2007, pp. 645-659 (2007)
- 7) H. Kaji, and H. Kita: Acceleration of Experiment-Based Evolutionary Multi-objective Optimization Using Fitness Estimation, Proc. of EMO2007, pp. 818-831 (2007)
- 8) R. Myers, and D. Montgomery: Response Surface Methodology 2nd edition, John Wiley & Sons (2002)
- 9) R. Röpke (Ed.): Design of Experiments (DoE) in Engine Development II, Expert Verlag (2005)

■著者



梶 洋隆
Hiroataka Kaji

コーポレートR&D統括部
システム技術研究部



喜多 一
Hajime Kita

京都大学
学術情報メディアセンター