

論文・解説

31 直噴ディーゼル・エンジンにおけるモデルベース キャリブレーションの適用

Model Based Calibration for Common Rail Diesel Engine

吉田 元 則^{*1} 山田 薫^{*2} 奥田 恒久^{*3}

Motonori Yoshida Kaoru Yamada Tsunehisa Okuda

原田 真悟^{*4}

Shingo Harada

要 約

今後、エンジン制御はますます複雑高度化することが予想される。そのため制御パラメータのキャリブレーションの効率化が要求されており、解決策の一端として実験データを元に作成した統計モデルを用いる適合手法(MBC)が主流となりつつある。本論で、当社の直噴ディーゼル・エンジンにおけるMBC適用事例の紹介と、本手法の今後の課題について報告する。

Summary

The calibration method with a statistical model based on experimental data has been recently become mainstream in calibrating parameters in ECU of a complicated and high-level engine system. This paper reports introduction of MBC for a direct-injection diesel engine and future MBC issues.

1. はじめに

排気ガスやOBDなどの規制強化、安全性や燃費の向上に対応するために、近年自動車用エンジン制御は複雑高度化の一途をたどっており、エンジン制御用ECU(Electronic Control Unit)内部の制御パラメータ数は、増加傾向にある。全ての制御パラメータの組み合わせを実機確認し、最適な組み合わせを選択するという従来の適合手法では、商品開発の定められた期間内に対応することは、近い将来困難となることは明らかである。

この解決のために、テストベンチで採取した必要最小限のデータから統計モデルを作成し、このモデルを元にキャリブレーションを行う手法(Model Based Calibration; 以下MBC)が、自動車製造各社で広く用いられはじめた。またこの手法をサポートするツールが、様々なツールメーカーから提供されている。⁽¹⁾⁽²⁾

今回、当社では、本手法を直噴コモンレール・ディーゼルエンジン(以下DI-DE)開発に適用し、多次元パラメータのキャリブレーションにおいて、効率および品質向上両面でその有効性を確認できた。この事例から得られた知見の紹介と、本手法の今後の課題について以下に述べる。

2. MBCの概要とDI-DEへの適用状況

2.1 MBCのプロセス

MBCのプロセスは、一般的にFig.1のような4つの工程からなる。データ採取ポイントを決定するDOE(実験計画法)の工程、データ採取の工程、実験データから統計モデルを作成するモデル化の工程、およびモデルから最適値を抽出する最適化の工程である。

これらの工程に移行する前の準備作業として、制御対象の入力パラメータと出力パラメータを決定し、出力パラメータを目的性能と制約条件に分けることも重要である。

Table 1 Engine Specification

| | |
|-------------------|---|
| Displacement | 2.5L, 3.0L |
| Turbocharger Type | VGT (Variable Geometry Turbo) |
| Injection Pattern | 1 or 2 Pilot Injection(s) 1 Main Injection |
| EGR | With EGR |
| Other Features | Swirl Control Valve, Shutter Valve |

*1, 3, 4 第3エンジン開発部
Engine Development Dept. No.3

*2 第2エンジン開発部
Engine Development Dept. No.2

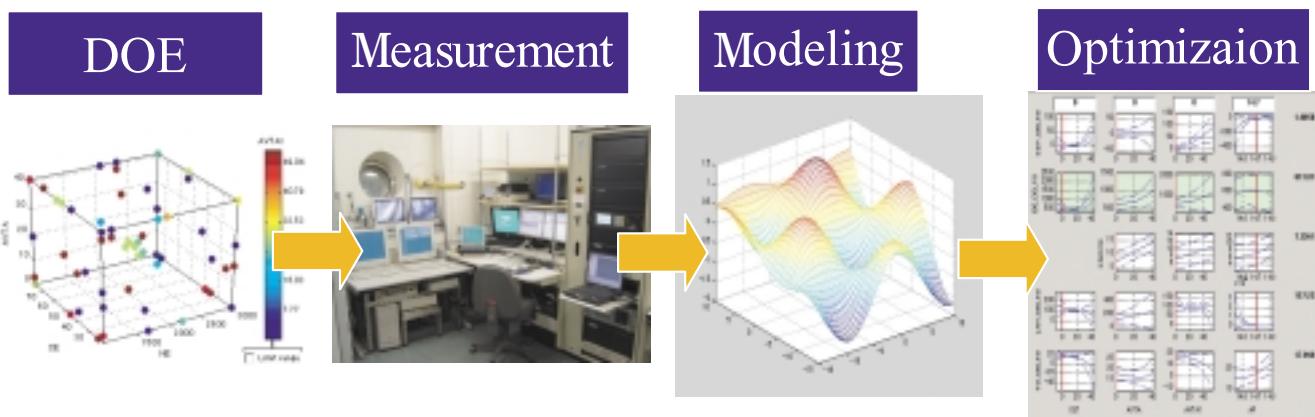


Fig.1 Calibration Flow with MBC

今回適用対象としたDI-DEの概略仕様を, Table 1に示す。入力パラメータは2回の燃料噴射量と2回の噴射開始時期・燃料圧力・EGR率・VGT開度・エンジン回転数等合計8個とした。出力パラメータは、目的性能とするパラメータを燃費(BSFC)・NO_x、制約条件となるパラメータを、エミッション規制からスモーク、エンジンの信頼性確保から最大筒内圧(P_{max})・排気ガス温度、燃焼音の代用特性としてCPL(Cylinder Pressure Level)とした。

2.2 DOE(実験計画法)

要求精度を満足するモデルを作成するため、必要最小限のデータ採取ポイントを効率的に決定する工程である。

実際にDOEを実施するに当たっては、いくつかの項目を仮決定する必要がある。対象エンジンの運転可能領域の特定と、その領域をカバーする入力パラメータの配置範囲。事前の対象エンジンの特性把握に基づいた、およそのモデルタイプ。更に、DOEで採取すべきデータ数である。これらの仮決定項目は、相互関係があり、モデル精度に大きく影響するため大変苦慮する項目である。DOEからモデル化までを何度も試行錯誤を重ね、場合によってはモデル精度確保のために、エンジン回転・負荷の領域をいくつかの領域に分割するなどの工夫も必要である。

データ採取ポイントの配置は、各種のDOE手法を用いる。

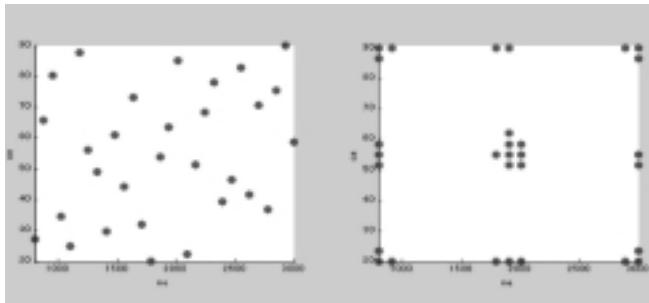


Fig.2 SPACE FILLING and D-OPTIMAL

一般的に想定モデルが線形の多項式関数モデルの場合は、D-OPTIMAL(D-最適)などがよく使われ⁽³⁾、モデルタイプが非線形な場合には、SPACE FILLING(空間充填法)が用いられる⁽⁴⁾。Fig.2にSPACE FILLINGとD-OPTIMALにて、データ採取ポイントを数十点発生させた例を示す。図中右側のD-OPTIMALでは、例えば2次モデルを想定すれば特性に合致した発生ポイントが得られる反面、事前にモデルタイプが既知であるべきことが欠点である。一方、SPACE FILLINGは、モデルが未知であっても、ある程度のデータ数を確保すればモデル精度の向上が可能である。

当社では、特性把握時や通常のモデル化時にはSPACE FILLINGを採用し、データ採取数を極限まで減少させる要求がある時のみ、D-OPTIMALでのDOEを利用している。また、モデルタイプは、不安定領域を含めると非線形特性となり複雑なものが必要であるが、安定領域だけに絞り2次モデルと仮決定した。採取するデータ数は、Fig.3に示すようなデータばらつきを考慮したシミュレーション結果のグラフから、要求精度を例えればRMSE(モデル誤差の標準偏差値)5%とし、1領域当たり500個以上となるよう仮決定した。

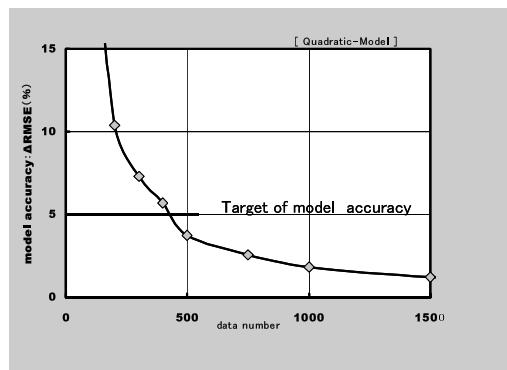


Fig.3 Model Accuracy with Data Number

2.3 Measurement (データ採取)

多次元の入力パラメータを与えて、実験データを採取する工程である。キャリブレーションに費やすかなりの時間はこの工程が占めるといつても過言ではない。このため、手動のベンチではデータ計測に多くの時間を要し、ベンチ担当者の負担が大きい。そこでデータ採取時間の短縮と、ベンチ担当者の負担低減のために、当社で内製しているキャリブレーションツールにDOEで求めたデータ採取ポイントのファイルを読み込み、自動でパラメータを変更する機能を追加した。これにより、計測時間を従来の方法に対し約3分の1に短縮でき、データ採取時間を大幅に低減することができた。

2.4 Modeling (モデル化)

採取した実験データから統計的モデルを作成する工程である。モデル化に当たっては、実験データの精査、入出力パラメータの関数変換、モデルの再構築などが必要である。

実験データの精査とは、計測上の問題や環境条件の変化により影響を受けたデータを除外するなど、データの品質確保を行う作業である。また、今回のモデルは線形領域のみのモデルを想定しているため、非線形特性を示す不安定領域のデータも併せて除外している。

入出力パラメータの関数変換とは、例えばエンジントルクのモデル作成時に、スロットルバルブ開度を角度のまま入力するのではなく、開口面積に変換するなど、入出力パラメータを物理特性に合わせて変換する作業である。

モデルの再構築とは、作成した統計モデルと理論式を利用し、より有効なモデルを構築することである。例えば、BSFCのモデルは、本来非線形特性であり統計モデルでの

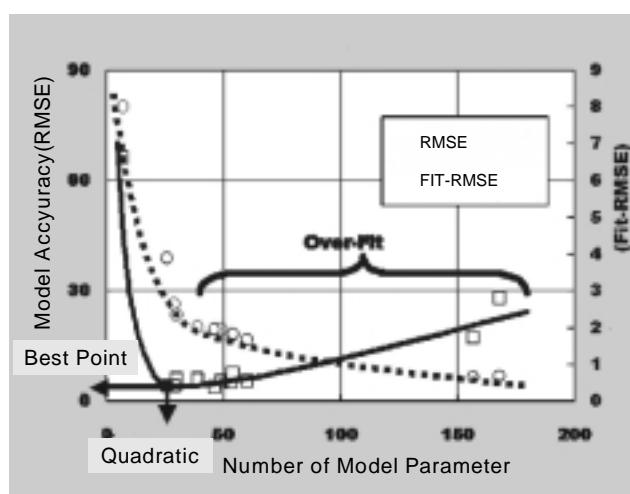


Fig.4 Model Accuracy with Number of Model Parameter

精度向上が難しいため、燃料消費量とエンジン出力のモデルから演算する手法を用いた。

このようにモデル化の工程の中でも、精度確保のために試行錯誤せざるを得ない。

また、作成したモデルの精度検証を有効に行うために、検証用データを別途採取しておくことが重要である。その検証用データを用いて、いくつかのモデルタイプでモデルを作成し、どのモデルタイプが最適であるかを検証する。

DI-DEへの適用では、モデルタイプは2次モデルが最良であることの検証をFig.4のように行った。点線に示すように、モデルの自由度を表す係数を増やすことによりモ

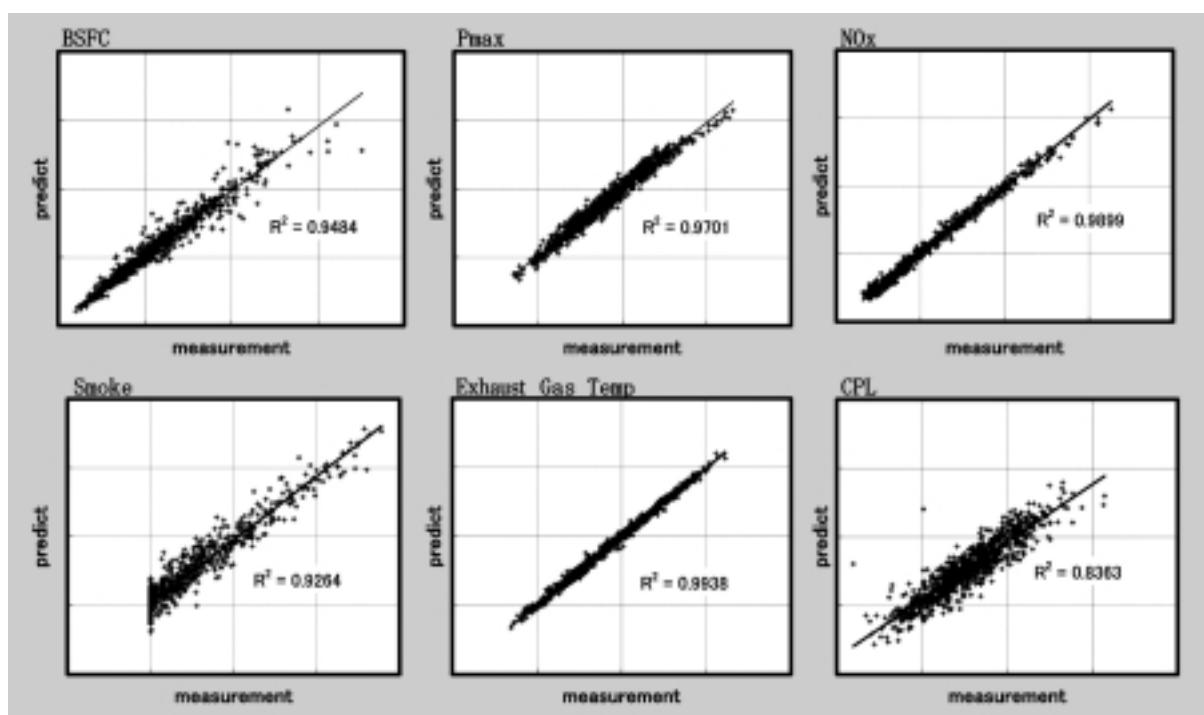


Fig.5 Model Accuracy

ル精度 (RMSE) は向上するが、検証用データを用いた精度は実線のように、2次モデルのところで最高精度を示した後は悪化する。

Fig.5に作成したモデルの精度検証結果の一例を示す。スモークやCPLは計測精度が悪いため、モデル精度は他のモデルに比べて良くないが、全体的にはRMSE5%の要求精度を満足したモデルを作成することができた。

2.5 Optimization (最適化)

作成した統計モデルを元に、ある制約条件下において複数の入力パラメータをうまくバランス取りし、目的とする出力パラメータを最適値にする工程である。

最適化を行うにはいくつかの手法があり、対象となるモデルの山が1つのみ（単峰性）か、複数存在する（多峰性）かによって異なる。単峰性の場合には最急降下法やSQP（逐次二次計画法）⁽⁵⁾、多峰性の場合にはGA（遺伝的手法）が用いられる⁽⁶⁾。更に目的が複数の場合にはMOGA（多目的遺伝的手法）が適している⁽⁷⁾。

DI-DEへの適用では、2つの目的性能を複数の制約条件下で最適化する必要があるためMOGAを採用した。MOGAは、遺伝的手法を用いて最適値の候補を複数求めるもので、その候補点を結んだラインがいわゆるトレードオフラインとなる。MOGAでの遺伝的手法による世代の進み方をFig.6に示す。入力パラメータをランダムに発生させた時の出力パラメータ群（燃費・NOx）を1世代目として、求めたいトレードオフラインに近いものから順位をつけ（評価 - Evaluation），優先順位の高いものの同士を親と見立てその近くに子を追加し（交配 - Crossing），優先順位の低いものを削除していく（淘汰 - Selection）。この評価・交配・淘汰の一巡は世代と呼ばれ、繰り返し行われる。

MOGAによって、エンジン回転数・負荷の1運転領域での最適化を行うことができる。更に当社ではキャリブレーション作業を簡素化するために、複数の運転領域を市場での走行頻度で重み付けし、対象とする全ての運転領域での燃費・NOxを最適にするトレードオフラインを求められ

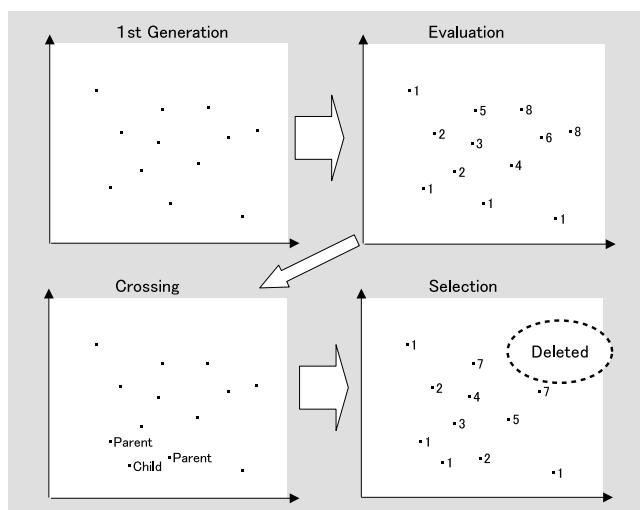


Fig.6 Flow of MOGA

るよう改善した。Fig.7に1世代目、10世代目、および50世代目の最適化結果を示す。50世代目で燃費・NOxのトレードオフラインが明確になることがわかる。このトレードオフライン上の1点を選択することで、対象とする全ての運転領域の回転と負荷の格子（以下MAP）が一意的に求まる。

実際に最適化を実施するに当たって、制約条件が厳しそうると最適解が得られない場合があり、制約条件を緩和し再度最適化するなど試行錯誤せざるを得ない。この問題に対して当社では、緩和可能な制約条件を明確にし、その制約条件を目的関数に変更し、再度MOGAを行う手順を追加した。これにより、制約条件を含むトレードオフラインを得ることができ、試行錯誤を減らすことができた。

また、最適化で求めたMAPは格子点毎の値が凸凹になり、走行フィーリングが悪化するなどの問題が生じるケースがある。この対応としてMAPのスムージングが必要である。現在は部分的に手動でスムージング調整を行っているが、本領域の自動化は重要な残技術課題といえる。

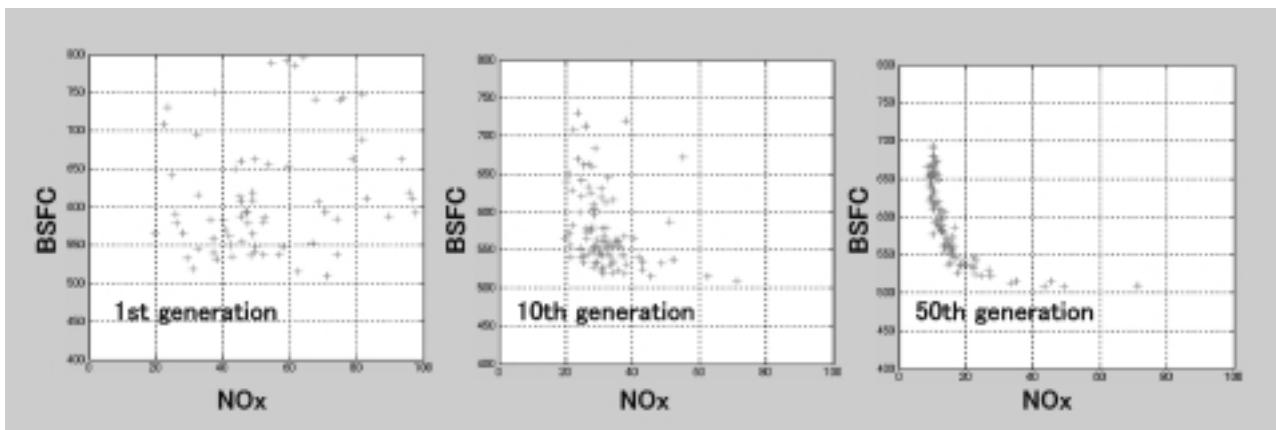


Fig.7 Display of Tradeoff Line with MOGA

3. 今後の課題

以上述べてきたように、MBCを実際に適用する際には、未だ試行錯誤に頼らざるを得ない領域が多く残っている。MBCは極めて優秀な手法であるが、現実問題として本格展開上のリスクとなっている。現手法の改善ポイントは、これらの試行錯誤の削減にあるといえる。本領域の主な残課題としては、2項目が挙がる。まず、対象エンジンの運転可能領域の探索とプレテスト手法の開発が必要である。その際、エンジン運転の安定領域と不安定領域の限界点を含む、非線形なモデル記述方法の確立もあわせて必要となる。更には、前項で述べたMAPの自動スムージング最適化手法の確立が不可欠で、実用性向上のキー技術と考えている。

その他、対象領域の拡大という観点で2つの中期課題があるととらえている。そのひとつが過渡モデルへの応用である。統計モデルだけでなく理論モデルとの融合などを図り、システム全体の同定を行うなどエンジニアリング的なアプローチが必要である。例えば、入力パラメータを時系列的にランダムに変化させ過渡モデルを同定する手法も紹介されている⁽⁸⁾。

もうひとつが、エンジン制御ECUパラメータのみならず、ハードウェアのパラメータを含めた最適化手法である。CAE技術との連携がキーとなる。ピストンTOPの形状決定にDOEを用いて形状変化させ、CFDモデルによりシミュレーション計算し、作成したトルクモデルから最適なピストン形状を決定する手法などが紹介されている。⁽⁹⁾

4. おわりに

複雑高度化するエンジン制御の多次元パラメータのキャリブレーションは、もはや人智の及ばない領域に達しようとしている。これに対応するには、MBC手法以外のアプローチはないといつても過言ではない。まだまだ熟成長段階の手法だが、夢の実現にむけて邁進したいと考えている。最大のポイントは、当社のみならず、おそらく同業他社においてもそうであるように、技術者育成にある。非常に多岐にわたる領域の固有技術とスキルが必要であるだけに、組織を挙げた取り組みが、今まさに要求されている。

参考文献

- (1) Mathworks UKによるMBCホームページ
<http://www.mathworks.co.uk/products/mbc/>
- (2) R.Leithgoeb et al. : Optimization of New Advanced Combustion Systems Using Real-Time Combustion Control, SAE Paper, 2003-01-1053 (2003)
- (3) 柳井晴夫：多変量解析実例ハンドブック，東京，朝倉書店，p.40-49 (2002)

- (4) M.Guerrier et al. : The Development of Model Based Methodologies for Gasoline IC Engine Calibration, SAE Paper, 2004-01-1466 (2004)
- (5) 立命館大学集積機械知能研究室：数理工学，
<http://www.ritsumei.ac.jp/~hirai/>
- (6) 静岡理工科大学情報システム学科：システムエンジニアの基礎知識，http://www.sist.jp/~suganuma/kougi/other_lecture/SE/SE.html
- (7) 同志社大学知的システムデザイン研究室：多目的遺伝的アルゴリズム，http://mikilab.doshisha.ac.jp/dia/research/mop_ga/
- (8) K.Ropke : Design of Experiments (DoE) in Engine Development II , Germany, expert verlag, p.66-76 (2005)
- (9) K.Ropke : Design of Experiments (DoE) in Engine Development II , Germany, expert verlag, p.77-93 (2005)

著 者



吉田 元則



山田 薫



奥田恒久



原田 真悟