

現象論モデルと遺伝的アルゴリズムによる ディーゼルエンジン燃料噴射率の多目的最適化*

廣安 知之¹⁾ 廣安 博之²⁾ 三木 光範¹⁾ 渡邊 真也³⁾ 上浦 二郎³⁾

Multi-Objective Optimization of Diesel Engine Emissions using Genetic Algorithms and Phenomenological Model

Tomoyuki Hiroyasu Hiroyuki Hiroyasu Mitsunori Miki Shinya Watanabe Jiro Kamiura

Because of the merit of the durability and fuel efficiency, many types of vehicles have diesel engines. However, with increasing environmental concerns and legislated emissions standards, current engine research is focused on the simultaneous reduction Soot and NO_x while maintaining reasonable fuel economy. In this study, parameter surveys are performed on computer simulations using the optimization technique. The amounts of NO_x, Soot, and SFC are minimized as objective functions and the optimum values of the shapes of fuel ratio are used as design variables. For the optimization method and the simulation of the diesel engine combustion, Neighborhood Cultivation Genetic Algorithm (NCGA) and HIDECS are applied respectively. In this research, we emphasize the following three topics. Firstly, the multiple injections control the objectives. Secondly, the multi-objective optimization is very useful in an emission problem. Finally, the phenomenological model has a great advantage for optimization. The developed system is illustrated with the simulation examples.

Key Words : Engine Performance, Systems Engineering, Diesel Engine / Combustion, Phenomenological Model, Genetic Algorithm, Multi-Objective Optimization ④

1. はじめに

近年の環境問題への関心の高まりから、ディーゼルエンジンに対する規制はますます高まっている。ディーゼル機関の排気ガス規制に合格する対策技術は、1)ディーゼル燃焼の改善、2)使用燃料の検討、3)後処理装置の開発、の3方向の開発研究が必要である。本研究では、ディーゼル燃焼の改善研究ということに着目し、燃焼改善による排気特性の良好な方策を確立しようとするものである。

ディーゼル機関の排気性能と熱効率をともに高める燃焼の本質的な改良技術確立のためには、燃焼改善を具現化するハード技術の開発とともに、燃焼改善理論の構築をサポートし、またハード技術の机上検討を可能にするソフト技術が重要である。特に小型ディーゼル機関においては、燃料噴射の噴射特性、噴霧特性がディーゼル燃焼に大きく影響する。そこで、本研究の目的は、ハード技術をサポートし、最適な条件を見出すための現象論モデルによるパラメトリックな研究を行い、排気特性と熱効率、すなわちNO_x、すすの排出量、および燃費率がともに最良となる噴射率の条件を見出そうというものである。最適条件を見出す方策として、遺伝的アルゴリズム(Genetic

Algorithm : GA) を利用する。

GAは生物の進化を模倣した確率的な最適化アルゴリズムである。多点探索により選択、交叉、突然変異といった操作を繰り返しながら最適点を探索する。本研究では、多段階噴射を想定し、燃料噴射期間内に噴射率を任意に変化させることが可能であるものとする。噴射率を変更することにより、NO_x、すすの排出量、および燃費率が最良となる設定を探索する。しかしながら、NO_x、すす、燃費率はそれぞれトレードオフの関係にあるため、すべてを最適とする解を求めることはできない。

このような場合、これまでの最適化においては、それぞれの関数にある重みをかけ加算することにより一目的関数に変換して解を探索していた。それに対して、本研究で行う手法は、複数の目的に対して、同時に最適化を行い、他の解と比較して総合的に劣らない解の集合を求める多目的最適化である。これらの解候補群は各目的の関係を示すものであり、特にエンジン設計を行うユーザにとって非常に有意義な情報となる。

2. ディーゼル燃焼の現象論モデルの概要

ディーゼル燃焼は複雑な過程、機構において燃焼を行っている。これらを数学的に記述し計算を行わなければならない。本研究では、計算時間短縮のため、噴霧に注目し、その噴霧を分割して計算する。各要素内の液滴直径、液滴数などは実験的に決定する。なお、各要素はそれぞれ異なる液滴直径、数、温度、当量比を有するが、圧力はすべて同一であるとする。

*2002年11月1日受理。2002年11月28日自動車技術会秋期学術講演会において発表。

1) 同志社大学工学部(610-0394 京田辺市多々羅都谷1-3)

2) 近畿大学工学部(739-2116 広島県東広島市高屋うめの辺1番)

3) 同志社大学大学院(610-0394 京田辺市多々羅都谷1-3)




Fig. 1 Schematic of the package distribution




Fig. 2 Schematic of the mass system during combustion

図 1は時間的かつ空間的に燃料噴霧を分割したモデルである。図 1に示すように、同時刻に噴出した噴霧は、その質量が均等に分割されるように要素の大きさを選択する。そして、この微小要素の現象を時間的に追っていく。このように形成された各要素は、到達距離の実験式に基づいて移動する。

噴霧の任意の一要素に注目し、その中で生じている現象を示すと図 2のようになる。噴射直後、要素の中には多数の微粒と少量の空気が存在する。その要素がノズルから遠ざかるにつれて外部から空気が流入するとともに液滴の蒸発が起こる。噴射後しばらくすると、燃料蒸気と空気からなる混合気内で自発火が起こり、要素は急激に膨張する。着火後の各要素内の噴霧の燃焼過程を図 3に示す。燃焼要素内の噴霧が初期の燃焼期間を過ぎた後、燃焼は図 3(A)のように燃料の蒸発速度や、図 3(B)のように空気流入量に律速されたりする。そして、各要素はその時の要素内の条件により、いずれかの燃焼過程を繰り返しながら燃焼を終了する。

HIDECSは、このモデルを基に開発されたディーゼルエンジンコードである^(1, 2)。HIDECSは、これまでいくつかのシ

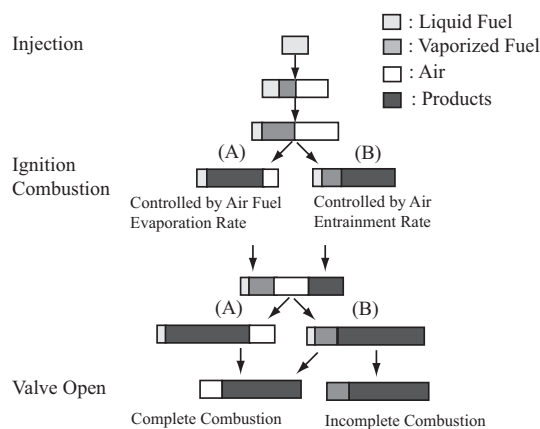


Fig. 3 Schematic of the package combustion process

ミュレーションに適用され成果をあげている^(1, 2)。本研究においても、HIDECSを最適化における目的関数値を決定する解析器として使用する。

HIDECSの最大の特徴は、必要とする計算負荷が非常に軽いことである。詳細論モデルとしてKIVA codeが有名であるが、これは1試行の解析に非常に大きな計算負荷を必要とする。本研究で使用している遺伝的アルゴリズムは、各問題への適用が容易で、非常に強力な最適解の探索能力を有する反面、計算回数を多く必要とする欠点がある。しかしながら、HIDECSを使用することで、十分実用的な時間内で遺伝的アルゴリズムを使用することが可能となる。

3. 遺伝的アルゴリズム

遺伝的アルゴリズム (Genetic Algorithm : GA) は、生物の進化と自然淘汰を工学的に模倣した最適化アルゴリズムである⁽³⁾。GAでは、探索空間上の探索点を生物の個体とみなし、この個体集合を母集団と呼ぶ。母集団に対して、選択、交叉、突然変異、という遺伝的操作を繰り返し適用する。GAは、従来の最適化手法と比較して、様々なタイプの最適化問題に容易に適用可能である。特に、対象問題が連続性を有しない場合にも適用可能であるため、ディーゼルエンジンのシミュレーションにより適していると考えられる。これは、ディーゼルエンジンのシミュレーションではパラメータの値によって、シミュレーション不可能な場合が存在するためである。

複数の目的関数を有する多目的最適化問題に対しても、近年、GAによるアプローチがさかんに行われている^(4, 5, 6)。

多目的最適化においては、解のトレードオフが存在するので、一意に最適な解は存在しない。そのため、互いに優越関係の決定できない解候補群を求めることとなる。一般に、これらの解候補はパレート最適解と呼ばれ⁽⁴⁾、多目的最適化では、このパレート最適解を求めることが目標の1つとなる。

本研究では、パレート最適解の探索能力に優れる”近傍培養型遺伝的アルゴリズム(Neighborhood Cultivation Genetic Algorithm: NCGA)”⁽⁵⁾を採用し、パレート最適解の探索を行う。

4. 近傍培養型遺伝的アルゴリズム

多目的最適化問題に対するGAの適用は近年さかんに行われており、大きな進歩を見せている^(4, 5, 6)。

特に、最近ではNSGA-II⁽⁴⁾、SPEA2⁽⁶⁾といった強力なアルゴリズムが提案され、従来までの手法に比べ良好な結果を示している。これらのアルゴリズムは、多くの共通するメカニズムを有しており、根本的な違いはほとんど無い。これらのアルゴリズムに共通するメカニズムのうち、探索に特に重要な効果を持つメカニズムについて以下に示す。

- 探索した優良解の保存
- 保存している優良解の探索への反映
- 保存している優良解の削減
- 各目的スケールの正規化

一方、大域的な探索を行う多目的GAでは、探索個体どうしの目的関数空間の距離が大きく離れ効果的な交叉を行うことができないといった問題点が存在する。このため、多目的GAではパレート最適解全体に対する局所的な探索を効率よく行うことができない。

我々は、この問題点に対して近傍交叉というメカニズムを取り入れた新たな手法、近傍培養型遺伝的アルゴリズム (Neighborhood Cultivation GA: NCGA)の提案を行った⁽⁵⁾。近傍交叉とは、交叉のための親個体を選択する際、個体どうしの近接度合いを考慮する交叉方法である。

NCGAは、上述の多目的GAにおいて探索に効果的なメカニズムと近傍探索という新たなメカニズムを有したアルゴリズムである。以下に、本モデルの流れを示す。

Step1: 初期個体を生成する。世代 $t = 1$ とする。各個体の評価を行い、これらの初期個体群をアーカイブ個体群(A_t)とする。

Step2: アーカイブ個体群(A_t)を探索個体群(P_t)にコピーし、 P_t を1つの目的関数値を基準にソートする。この際、基準となる目的関数 $f_i(x)$ は、世代 t を目的関数の数 M で割った余りから求める($t \equiv i \pmod{M}$)。また、Step 3, 4において用いる変数 i を0に初期化する。

Step3: Step2によりソートされた探索個体群(P_t)に対して、 i 番目と $i + 1$ 番目の隣り合った2個体をペア個体群として選択する。

Step4: 選択された2個体のペア個体群を用いて交叉、突然変異、評価を行い、ペア個体群を更新する。変数 i に2を加え、 i が個体数と等価になるまでStep3, Step4を繰り返す。この結果、探索個体群がすべて更新される(P_{t+1})。

Step5: 探索個体群(P_{t+1})とアーカイブ個体群(A_t)との比較を行い、アーカイブ個体群を更新する(A_{t+1})。この際、アーカイブ個体群の更新方法としてSPEA2における環境選択(environmental selection) ^{*1}の手法を用いる。また、SPEA2, NSGA-IIと同様、アーカイブ個体群はあらかじめ設定した N 個の個体を優良個体として保存している。

Step6: 終了条件を満たすかどうか判定を行う。終了条件を満たせば終了、満たさない場合には、世代 $t = t + 1$ を行い、Step2へ戻る。

このように提案するNCGAは、探索個体群に対して任意の目的関数軸を基準にしたソートを行い、隣り合う2つの個体を用いた遺伝的操作を行っている。ソートされた個体群の隣り合う個体どうしは、目的関数空間において個体間の距離が比較的近いため、近傍交叉を実現することができる。

ただし、ここでのソートを常にある一定の目的関数軸を基準

に行うと、同じペアどうしでの交叉が繰り返し行われる恐れがあるため、以下のような方法を用いている。

- 世代毎に基準となる目的関数軸を変化
- ソート後のすべての探索個体群に対して、近傍シャッフルを行う。

ソートの基準となる目的関数 $f_i(x)$ は、世代 t を目的関数の数 M で割った余りにより決定する($t \equiv i \pmod{M}$)。そのため、世代ごとに基準が変化し、交叉を行うペアがより変化しやすくなっている。また、近傍シャッフルとは、ある一定の範囲内で個体をランダムに並び替えるものである。本研究では、この範囲として母集団サイズの1割程度の値を用いた。例えば、100個体の個体群が対象である場合、各個体は幅最大10の範囲で乱数を用いたシャッフルが行われる。このことにより、母集団に変化がなくなってくる探索終盤においてもペアが変化するようになっている。

また、アーカイブ個体群(A_t)の更新にはSPEA2の適合度割当て、および端切手法^{*2}を用いた環境選択の方法を用いている⁽⁶⁾。SPEA2における環境選択の大まかな手順を以下に示す。

Step1 探索個体群(P_{t+1})とアーカイブ個体群(A_t)の和集合 R_t を作成する。

Step2 R_t に対してSPEA2における適合度割当てを行う⁽⁶⁾。

Step3 割り当てられた適合度と端切手法を用いて R_t からアーカイブ個体群の個体数分の個体を選択し、新たなアーカイブ個体群 A_{t+1} を生成する。

一方で、SPEA2, NSGA-IIなどの手法が用いているアーカイブ個体群(A_t)から探索個体群(P_t)を選択するメイトング選択(mating selection) ^{*3}を行っていない。メイトング選択操作では、アーカイブ個体群の中から特に優れた個体を重複して選択する。しかし、NCGAでは同じ個体が複数存在すると近傍交叉に悪影響を及ぼす可能性があるためこの操作を行っていない。そのため、NCGAではアーカイブ個体群(A_t)のコピーを探索個体群(P_t)として用いている。

5. 噴射率の最適化システム

本研究において構築した噴射率の最適化システムを図4に示す。

本システムにおいてディーゼルエンジンシミュレーションコードHIDECSIは解候補の噴射率に対して、NOx, すず(Soot), および燃費率(Specific Fuel Consumption: SFC)の値を求める。最適化コードであるNCGAは解候補のNOx, Soot, およびSFCの値を基に、次探索点である噴射率を決定する。これらを繰り返し行い、シミュレーションで得られた結果の中からパレート最適解候補を保存することで、最終的な解が得られる。

^{*1} 一般に、新たに得られた探索個体群を用いて保存しているアーカイブ個体群を更新する場合、探索個体群と優良個体群の和集合から選択操作を用いて新たな優良個体群を生成する。この選択操作のことを環境選択と呼ぶ⁽⁶⁾。

^{*2} SPEA2において用いられている過剰な非劣個体の削減方法⁽⁶⁾。

^{*3} アーカイブ個体群から探索個体群を選び出す選択操作をメイトング選択と言う。メイトング選択は、アーカイブ個体群の中でも特に優れた個体を重複して選択し探索個体群を生成することにより、より効率の良い探索を実現している。




Fig. 4 Optimization System

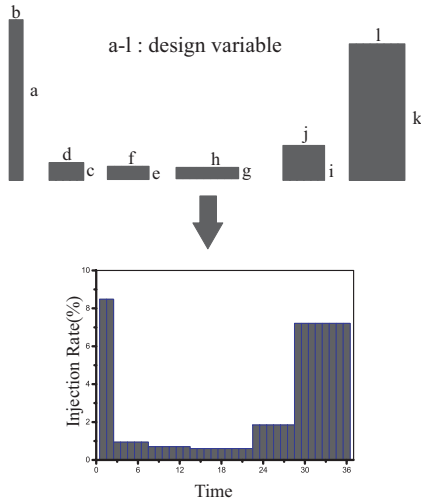


Fig. 5 Coding method

今回のシミュレーションでは、設計変数として噴射率を、目的関数としてNO_x, Soot, SFCを用いている。しかしながら、同一のシステムで、同様に噴射開始時期や噴射期間を設計変数に、その他の値を目的関数として最適化を行うことは可能である。これについては今後の課題とする。

GAにおいては、設計変数をどのように設定するかは非常に大きな問題である。設計変数の決定が、解の精度に大きく影響するからである。設計変数の設定の方法を図5に示す。

まず、噴射期間を6分割する。この6分割された各区分の高さ（噴射率）および幅（噴射期間）が設計変数となる。すなわち、設計変数の数は12である（図5中のaからl）。次節で行うシミュレーションにおいて、総燃料および噴射期間は一定としている。そのため、各区分の総面積および幅の合計が一定となるように、得られた設計変数値を正規化する必要がある。そこで、本研究では、まず幅（噴射期間）の合計が一定となるように幅（噴射期間）を表す設計変数値をスケールリングを行う。そのうえで、各矩形の面積を足し合わせた総面積を求め、その総面積が100となるように各矩形の高さ（噴射率）を表す設計変数値をスケールリングしている。なお、本研究ではそれぞれの設計変数値を10bitのgrayコーディングによって表現する。

6. シミュレーション

6.1. 対象ディーゼルエンジンおよび使用したGAパラメータ

本研究で対象としたディーゼルエンジンは表1に示す通りである。また本シミュレーションにおいては、ATDC-5.0° 4

Table 1 Specification of the target diesel engine

Bore	102 mm
Stroke	105 mm
Compression Ratio	17
Engine Speed	1800 rpm
Swirl Ratio	1.0
Nozzle Hole Diameter	0.2 mm
Nozzle Hole Number	4
Injected Fuel Volume	40.0 mg/st
Injection Timing	ATDC-5.0°
Injection Duration	18.0°

Table 2 GA parameters

Population Size	100
Crossover Rate	1.0
Crossover Method	1X
Totale Length of The Chromosome	12 × 10 bit
Mutation Rate	1/120
Total Evaluation Number	20200

ら噴射が開始され、18°まで噴射が続くものとする。各設計変数値は0.0から1.0の間であるとし、HIDECS内では、噴射区間を36分割して解析が行われる。

GAにおいて用いたパラメータを表2に示す。

6.2. シミュレーション結果

シミュレーションは表3に示す32ノードから構成されるPCクラスタ上で行った。また、本実験では、計算時間短縮のためNCGAをマスタースレーブ型に並列化した並列NCGAを使用した。並列NCGAは、解析部分のHIDECSのみを並列で処理しており、遺伝的処理を行うアルゴリズム自体はNCGAと同一である。GAからは20200回のHIDECSの呼び出しを必要とし、実行時間は11425[s]であった。

図6, 7, 8に得られた非劣解集合*4およびいくつかの非劣解の噴射率形状を示す。今回のシミュレーションは3目的で行っているが、これらの図は、各2平面に結果を投影した図である。

2次元平面に投影した非劣解集合を表す図6, 7, 8から、SFC, NO_x, Sootの各目的にはトレードオフの関係があることが分かる。

得られた結果のうち、図6に示されるSFC-NO_xの関係について検討する。図6における、解1はSFCにおける最小値を表しており、解4はNO_xにおける最小値を表している。SFC最小である解1の噴射率形状では、多段噴射において前半部分に集中して燃料を噴射する形状となっている。対して、NO_x最小である解4の形状では、前半部分と後半部分の2段階に分けて噴射

*4 GAの探索過程における、その時点での最も良好な解、すなわち母集団全体の中で他のどの個体と比較しても優越されていない個体を、非劣個体または非劣解と呼ぶ。多目的GAでは、この非劣解集合をパレート最適解集合へ近づけることが目的となる。

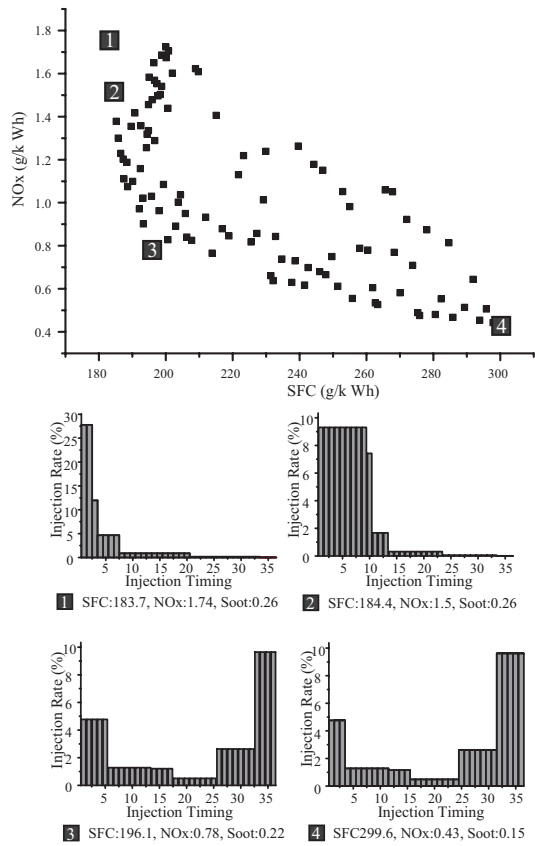


Fig. 6 Derived Pareto solutions (SFC, NOx)

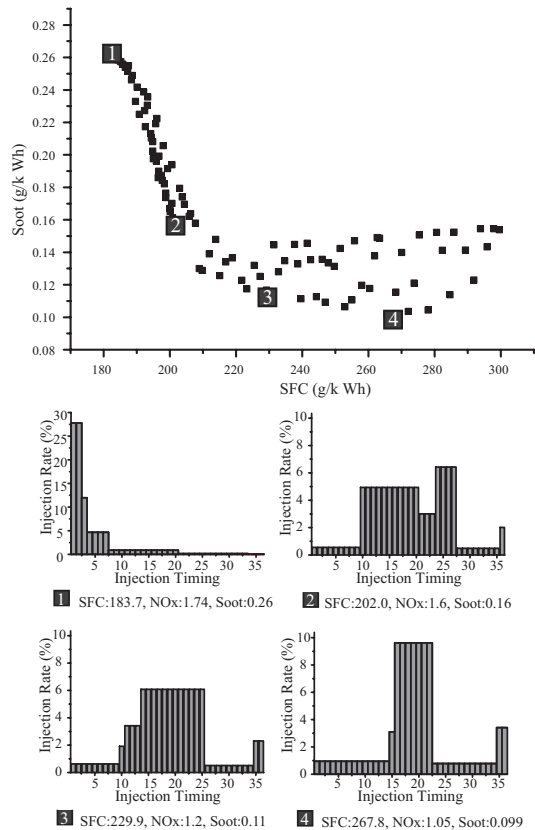


Fig. 7 Derived Pareto solutions (SFC, Soot)

Table 3 PC Cluster

CPU	Pentium III (1GHz)*32
Memory	512 MB
OS	Linux kernel 2.4.4
Network	FastEthernet 100Mbps
Communication Library	LAM/MPI

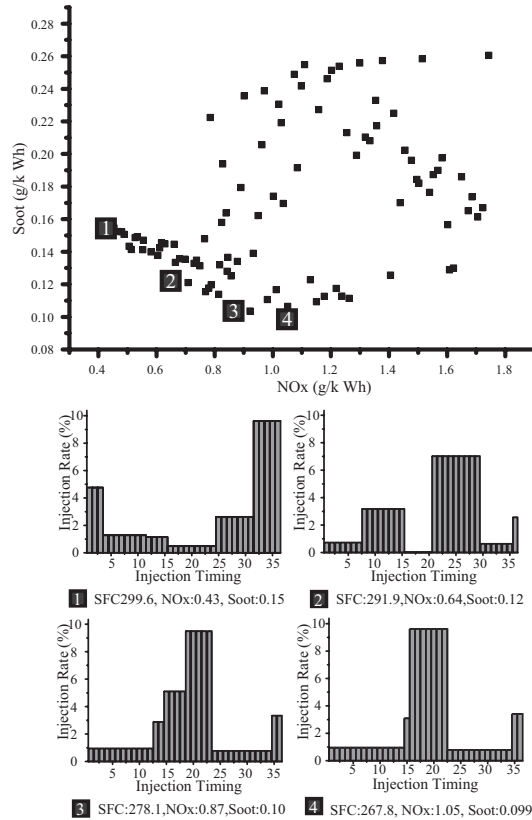


Fig. 8 Derived Pareto solutions (NOx, Soot)

する形状となっている．この2段階噴射はいわゆるPilot噴射として知られているものである．解1から解4までの各候補の噴射率形状より，徐々にSFC最小の噴射率形状からNOx最小の噴射率形状に推移している様子が分かる．解2の噴射率形状では，解1のSFC最小の場合と比較して，前半部分のごく最初の部分に集中していた燃料噴射が，全体へと分散しているのが分かる．また，解3の噴射率形状では，ほぼ解4のNOx最小の場合と同じ前半部分と後半部分の2段階に分かれた形状となっている．

つぎに，図 7に示されるSFC-Sootの関係について検討する．図 6と同様，図 7中の解1の噴射率形状は，SFCにおける最小値を表しており，解4の解候補はSootにおける最小値を表している．解4のSoot最小を表す噴射率形状は，NOx最小の噴射率形状(図 6の解4の噴射率形状)の場合とは反対に，中盤の辺りに集中して噴射する形状となっている．また，解1から解4の噴射率形状の推移について見た場合，徐々にSoot最小の噴射率形状である中盤辺りに集中する噴射率形状となっている様子が分かる．特に，解2から解4にかけては，より中盤辺りに噴射が集中するように噴射率形状が変化しているのが分かる．

Table 4 Calculation time

Total calculation time(sec)	11425
The average execution time of one trial of HIDECS(sec)	11.86
The execution time of only master node running(sec)	525

最後に，NO_x-Sootの関係について図 8から検討する．前述の通り，図 8における解1のNO_x最小の噴射率形状と解4のSoot最小の噴射率形状は全く正反対の性質を持っている．図 8に見られるように，NO_xとSootはトレードオフの関係であることが本実験においても明らかとなった．

最も重要な点は，これらの解候補が1度の最適化試行で同時に得られている点である．また，多目的最適化にGAを適用した場合，同時に複数の解候補が得られるため，解候補1つあたりの計算回数は，単一目的にGAを適用した場合にくらべ格段に少ない．そのため，多目的GAは，単一目的にGAを適用した場合と比べ非常に効率的な手法であると言える．

さらに，各目的関数の最小値の解候補だけでなく，ユーザーの好みに応じた解候補も同時に提示することが可能である．例えば，ユーザーがSFCは200g/kWh程度とし，NO_xは1.0g/kWh以下としたいという要求を持っていた場合，図 6における解候補3がその解となる．

この解も1度の最適化試行で得られた結果であり，ユーザーにパレート最適解の情報を提示する意義は非常に大きい．

6.3. 計算時間

最後に，計算時間について述べる．本実験では，最適化手法として並列NCGAを用いている．本実験にかかった計算時間を表 4に示す．

表 4におけるのマスターのみで動いていた時間とは，NCGAにおける並列化されていない部分を表している．NCGAでは，マスターのみの操作として非劣解の生成などの操作が行われている．しかし，全体の計算時間に対するマスターのみの処理に要した計算時間は，5%程度であることから，問題とならないことが分かった．つまり，NCGAを用いた全計算のうち，95%以上が並列化されていた．また，総計算時間が約3時間程度であることから，十分に現実的な計算時間内に結果が得られていることが分かる．これは，比較的計算負荷の軽いHIDECSを用いたためである．このことより，繰り返し計算がある程度必要となるGAと計算負荷の軽いHIDECSを用いることにより，現実的な時間内に良好な解を得られることが分かった．

7. 結論

本研究においては現象論モデルと遺伝的アルゴリズムによるディーゼルエンジン燃料噴射率の多目的最適化を行った．本研究で構築したシステムでは，多段階噴射可能なディーゼルエンジンを想定し，NO_x，すすの排出量，燃費率がともに最良となる噴射率設定の探索を目標とした．

しかしながらNO_x，すす，燃費率の間にはトレードオフの関

係があるために，一意な最適解を求めることはできない．そのため，パレート最適解と呼ばれる互いに優越関係の決定できない解候補群の探索を試みた．

シミュレーションにより，パレート最適解候補を求めることが可能であることを示すことができた．さらに，このシミュレーションを通じて以下の点が明らかとなった．

- 多段階噴射によるNO_x，すす，燃費率の制御可能性
- NO_x，すす，燃費率のトレードオフの関係
- NO_x，すす，燃費率の各噴射率特性
- パレート最適解をユーザーに示すことの有用性
- 多目的遺伝的アルゴリズムにおける計算負荷の少ないHIDECSを使用することの必要性

今後の課題は，実用的な多段階噴射形状を設定すること，噴射時期や噴射期間なども設計変数として検討を行うことなどが挙げられる．

謝辞

本研究は，文部省学術フロンティア推進事業に基づく同志社大学学術フロンティア研究プロジェクト「知能情報科学とその応用」の一環として行われた．ここに関係各位の謝意を表する．

参考文献

- [1] Hiroyasu, H., et al., "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, April, 1983.
- [2] Hiroyasu, H., et al., "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, April, 1983.
- [3] Goldberg, D. E., "Genetic Algorithms in search, optimization and machine learning." Addison-Wesley, 1989.
- [4] Deb, K., "Multi-Objective Optimization using Evolutionary Algorithms." Chichester, UK : Wiley , 2001.
- [5] Watanabe, S., et al., "NCGA : Neighborhood Cultivation Genetic Algorithm for Multi-Objective Optimization Problems" Proceedings of the Genetic and Evolutionary Computation Conference(GECCO 2002) LATE-BREAKING PAPERS, pages 458-465, 2002.
- [6] Zitzler, E., et al., "SPEA2: Improving the Performance of the Strength Pareto Evolutionary Algorithm" Technical Report 103, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH) Zurich, 2001.