

# 事例ベースデータマイニング法を用いた燃費特性モデルの自動構築と任意過渡走行モードにおける燃費予測への応用

野田 明\*    米川 誠\*\*    小川 恭弘\*\*

## Simulation Method based on Case-base Data Mining Modeling to estimate Fuel Consumption for various Driving Modes

by

Akira NODA\*    Makoto YONEKAWA\*\*    Yasuhiro OGAWA\*\*

### Abstract

In order to estimate fuel consumption quantity under various transient driving conditions, the simulation method based on TCBM (Topological Case Base Modeling) data mining modeling procedure was developed. In the first step of this procedure, the simulation program analyzes the input sequential data of fuel flow rate and vehicle operation data such as vehicle speed, acceleration, traction force and so on, which are measured during a typical mode drive operation. In the next step, the simulation program automatically make a suitable database model which represents fuel consumption characteristics of the test vehicle. Using the database model, the simulation program can estimate fuel consumption quantity under any types of transient driving conditions.

The effectiveness of the developed simulation method was examined with comparing the simulated data and the experimental data measured on the chassis dynamometer for various driving modes and test vehicles. As a result, it was found that most estimated data by the simulation not only for total fuel consumption quantity but also sequential fuel flow rate have a good agreement with corresponding experimental data. In conclusion, the simulation method to estimate fuel consumption quantity under various driving conditions has effectiveness and availability. This method can be used for various purposes, for instance, the evaluation of cost benefit for traffic flow control including road construction planning.

---

原稿受付：平成 18 年 1 月 31 日（企画室へ提出した年月日を記載のこと）

\* 理事    \*\* 環境研究領域

## 1. 背景

地球温暖化の防止対策は我が国における重要課題であり、産業、民生、運輸等の各部門においてさらなる省エネルギー化を進めて、CO<sub>2</sub>の排出を抑制する必要がある。自動車部門は、我が国のCO<sub>2</sub>総排出量の20%近くを占め、しかも乗用車を中心に排出量の増加傾向が止まらないことから、CO<sub>2</sub>抑制のための諸施策、例えば低燃費車の普及、モデルシフト、貨物輸送の合理化、道路整備や交通管制による渋滞の解消、省エネ運転の励行等の省エネルギー対策を総合的に進める必要がある。しかし、具体的な対策を検討する時には、それらを実施することによって達成される燃料消費量、CO<sub>2</sub>排出量の削減量を具体的に試算した上で、費用対効果を明らかにすることが望ましい。例えば道路計画等によってある区間の渋滞が改善された場合の通過車両全体の省エネルギー効果を試算するといったことである。

こうした調査を行うため、例えば車両区分別に選定した数台の試験車を用いて、平均速度等の異なるいくつかの走行パターンをシャシダイナモメータ上で運転し、燃料消費量、CO<sub>2</sub>排出量の違いを定量化するといった方法を採用することがある。しかし自動車は、車種が極めて多く、それぞれの使われ方、走り方も千差万別であること、燃費への影響要因が数多くそれらが複合的に作用するので、実験データが少なければ、予測結果もある程度限定的なものとなる。

予測精度を向上させる方策として、調査対象範囲を拡大し、より多くの車種、走行条件のもとでシャシダイナモメータ試験を行い、各々について燃料消費やCO<sub>2</sub>排出量を測定する方法も考えられるが、膨大な実験工数と試験費用の問題に直面する。このように、燃料消費の実態をできるだけ正確に把握しようとすると実施面での制約が多くなり、自動車の省エネルギー対策、温暖化対策の効果予測を行う際の問題となっていた。そこでこれらを解決できる有効かつ実用的な手法が、この分野で期待されていた。

実験に拠らずにシミュレーションで燃費を予測する方法はその解決策のひとつであるが、従来の手法では対象車両の燃費特性を記述する数値モデルを作成しなければならなかった。そのためには車両やエンジンの特性並びに走行条件等の燃費関連パラメータを特定し、それらの影響度を関数化したモデルを設定しなければならず<sup>(1)</sup>、またそのために多くの実験と複雑な解析が必要となるので、処理の煩雑さに比べて汎用性に欠け、扱いも簡便でなかった。

## 2. 事例ベースデータマイニング推計法の概念

こうした技術的課題を解決する目的で、今回筆者らが開発した方法は、最近多くの分野で注目を集めているデータマイニング技術を実用燃費の予測に応用した推計手法である。

「マイニング」の語源は、広大な大地の中から金や銀、石炭の鉱脈や水脈を経験や勘などを頼りに発見し、「採掘」することである。この概念を現代のコンピュータ社会に当てはめると、まず様々な分野で蓄積されている膨大なデータの「鉱脈」から、高速演算処理によって属性やデータ間に成り立つパターンやルールなどの規則性、意味のある相関関係などを読み取り、その結果を用いてさらに新しい知識を発見・学習したり、さらには未知の事象を予測するといった「採掘(mining)」の手法と言える。

すなわちデータマイニングというのは、蓄積されたデータの集合から、規則性や関連性を取り出してその後の目的処理に有効なモデルを作成し、これを使って非線形で複雑な事象を予測する手法である。このように過去の事例データをもとに未知の部分予測する手法は、いろいろな事業分野での計画策定や各種施策の提案、あるいはその効果予測などの用途に応用が可能であり、新しいビジネスパターンの創出にも利用できる汎用技術である。

本論文で示した手法は、まず仕組みが明らかになっていない対象システムをブラックボックスと見なし、このシステムへの入出力の観測データを使ってシステムの特性を記述したモデルを作る。次にシステムへ新たな入力条件が作用した場合の推計出力値を、このモデルを使って計算する。こうした手法は、ブラックボックスモデリング法と呼ばれる。

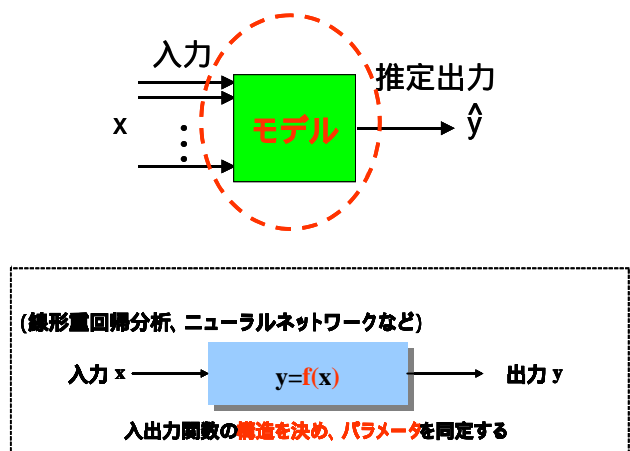


図1 一般的なブラックボックスモデリング

ただし一般のブラックボックスモデリングでは、物理的知見の有無にかかわらず、とにかく図1のような入出力間の関係を記述する関数モデルを作る必要があった。またその仕様を決定するためには、実験や解析などによって最適なモデル構造を探り、モデルのパラメータを同定するための収束計算等を時間をかけて行って、次数やネットワーク構造などの最適なモデルパラメータを決定する必要があった。さらに、追加データなどより新しい情報が取り入れられた場合には、パラメータの修正作業が必要となるため、適応学習が困難という問題もあった。

このように扱いが難しい従来のモデリング手法の問題を解決するため、本研究では、事例データベース推論の枠組みを燃費予測のモデル作りに応用することにした。すなわち、入出力関係の連続性が成り立つ非線形で複雑な事象(今回の対象としては、様々な車の燃料消費特性)に対して、過去の学習結果をもとに作られた事例データベースの中から、新たに与えた入力条件(燃費を予測しようとする車の走行条件)と類似度合いの高いものを探索して、出力予測値(燃料消費量)を得る方法である。このモデリング・推計手法では、事例を多く学ぶにつれて事例データベースが充実し、新たな事象への推計精度が向上していくという適応学習の効果が期待できる。

この事例ベース推論方法においては、過去の経験が蓄積された事例データベースの中に入出力の関係が既に内包されているため、解析等によってモデル構造をわざわざ規定する必要がなくなる。つまり推論に際しては、入出力変数の選択とその与え方だけを問題にすればよい。実際の処理では、まず図2のような代表走行モード(学習モード)での入出力データ群(車の走り方を示す変数パラメータの時系列値とその時の瞬時燃料流量の計測値)をマイニングツールが分析して、その車の燃費特性モデルに相当する事例データベースを作成する。この結果を車両の燃費モデルとして利用して、新たな走行条件に対する燃費の予測計算を行う。

今回開発した燃費推計手法の有効性を確認するため、合計12台の試験車を使ってシャシダイナモメータ実験を行い、様々な走行条件において実測した燃費値と上記の手法で求めた予測値とを比較した。その結果、大半の車種、走行条件において両者が良く一致することが確認でき、本推計手法の有効性と実用性が実証できた。その詳細を以下に報告する。

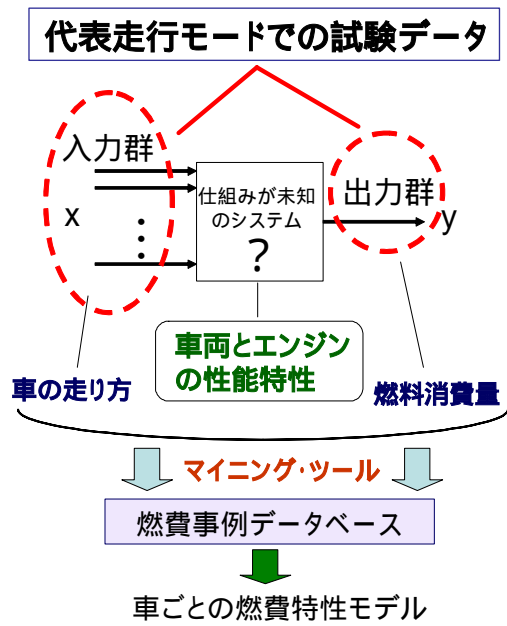


図2 マイニング法を利用した燃費特性モデリング

### 3. 本燃費推計法の概要と実行手順

#### 3.1 概要

本燃費推計法を使う場合には、まず対象車両の燃費特性を推論ツールに学習させる必要がある。そのためには、代表走行条件、例えばJC08モード(2008年から排出ガス試験用に順次導入される実走行型過渡モード)等の運転を行い、車両やエンジンの挙動(入力変数)と瞬時燃料消費量(出力変数)の変化を連続計測し、それらの時系列データを専用プログラム(マイニングツール)に読み込ませる。車両やエンジンの挙動を示す燃費関連の変数パラメータとしては、車速、加速度、エンジン回転数、慣性設定値、走行抵抗、車両駆動力(シャシダイナモメータでの実測値または計算値)などが考えられるが、燃料消費との間で相関性の高いパラメータとなるのであれば、演算で求めた間接情報を利用してもよい。パラメータ選定では、燃費との相関性が高くかつ相互に独立している項目を与える方が、高精度で安定した推計結果が得られる。

今回利用したマイニングツールでは、適切なパラメータの絞り込み、選定のために、燃費への影響度すなわち入出力間の相互関係(相関度)の検証を行う機能があり、また履歴の影響も考慮できるように遅れステップ解析を行い、各瞬間から一定時間遡った過去のパラメータデータも入力変数として利用することが可能である。

データベースの作成過程では、図3に示すような

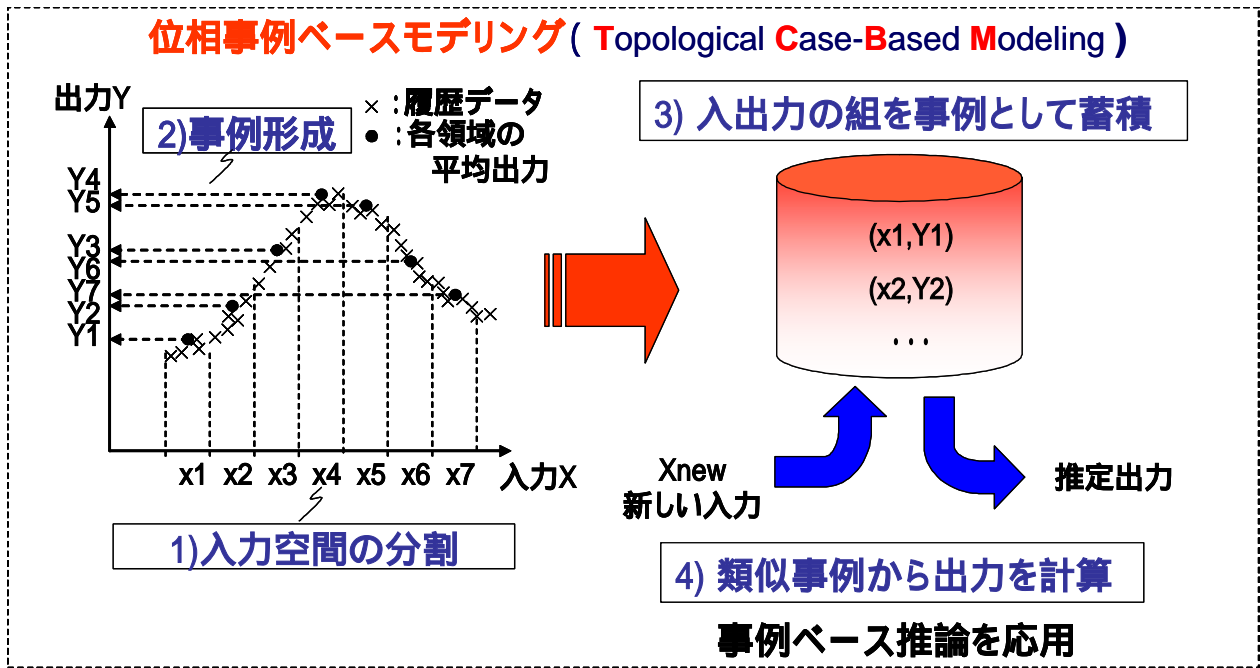


図3 データマイニング法を利用した燃費特性モデリングの概念

位相事例ベースモデリング TCBM ( Topological Case-Based Modeling ) 法を用いている。この処理では、予め設定した  $N$  個の燃費関連パラメータに対応した  $N$  次元の位相空間の中に、代表試験条件において取り込んだ一連の履歴データを、指定した解像度 (メッシュ区分) で量子化して配置し、それら入出力の組が事例ベースの形式に変換される。この処理を学習データ全体に対して行うことにより、対象車両の燃料消費特性モデルが自動的に生成される。なお出力許容誤差を指定したモデリングも可能であり、評価基準に従って、使用した学習データによる作成モデルの完成度を検証する機能もある。

燃費推計では、このモデルを用いて新たな走行条件での燃費を予測する。まず予測しようとする走行パターンの車速変化や車両情報 (車両重量、走行抵抗等) から、事例データベースへ入力したパラメータと同じ項目の時系列値を計算してマイニングツールに入力する。推計処理では、入力されたパラメータの各瞬時値に関して、上記の事例ベースの中からその入力値と最も近い位相等距離の事例を検索し、対応する燃料流量と推計誤差を計算する。このような逐次処理を燃費予測するモード全体に対して行い、最後にそれらの瞬時予測値を積和することにより、対象モードの総燃料消費量を算出する。

燃費推計処理の全体の流れを図4に示す。

### 3.2 燃費事例ベースの作成と予測精度の検証

任意走行におけるモード燃費推計処理では、当研究所と共同研究を実施している (株) 山武が開発した汎用のデータマイニングツール data FOREST を使用した。

本手法の燃費予測への適用性を調べるため、車重、排気量、燃焼方式等が異なる 12 台の車両に関して、道路条件別に選定したいくつかの走行モードの燃費を計算し、同じモードをシャシダイナモメータ上で運転して実測した燃費値と比較した。

車両ごとに運転条件と燃費特性の関係を学習するため、代表走行モード (JC08 モード等) を台上で運転して、燃費に関連した車両挙動データ (0.1 秒毎の計測値及び間接演算値) と燃料流量計測値をマイニングツールに入力した。車両挙動のパラメータとしては、各瞬間の車速と車両駆動力 (計測値)、車速変化から求めた加速度、速度と駆動力から計算した出力値 (仕事率) を用いた。各瞬間の燃料流量は、CVS 希釈排出ガス中の  $CO_2$ 、 $CO$ 、 $HC$  の各濃度変化を連続測定して、カーボンバランス法 (CB法) により 0.1 秒ごとに値を計算した。なお排ガス分析計で測定された各成分の希釈ガス濃度信号は、分析計の応答無駄時間の分が遅れて出力される。そこでこの遅れ時間を別途測定し、その遅れ分だけ時間軸をシフトした上で、CB法の計算式により瞬時燃料

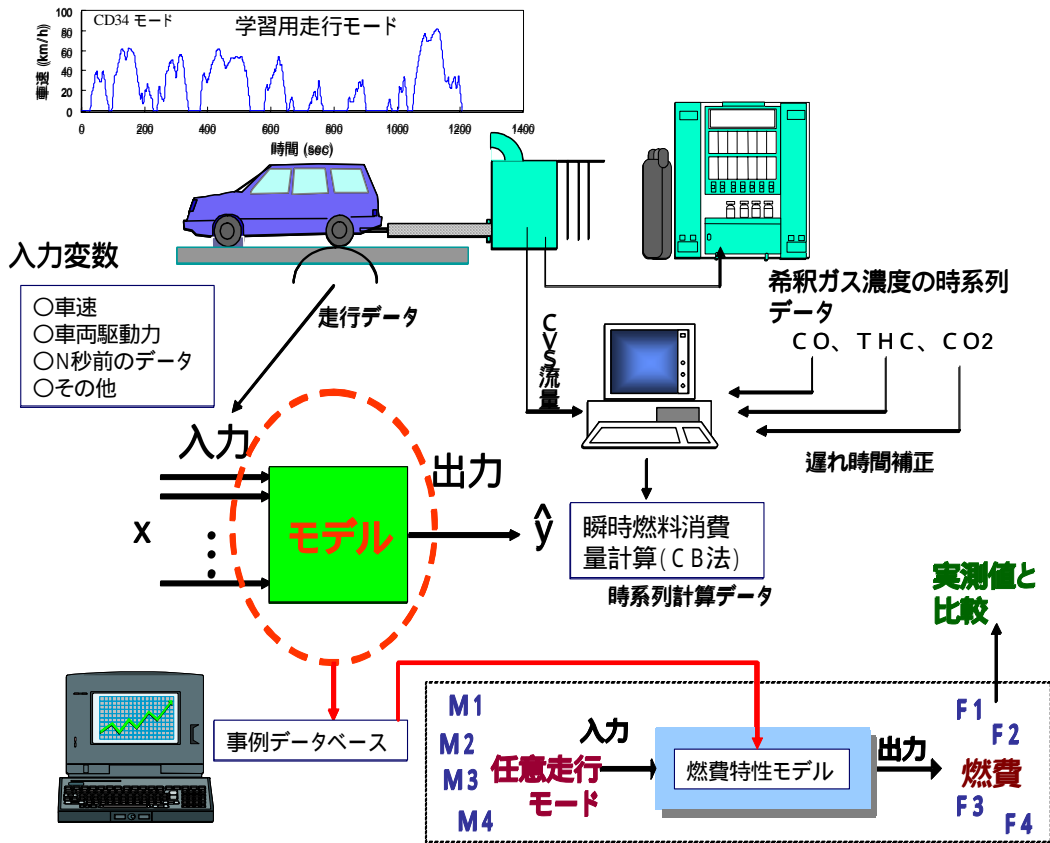


図4 燃費推計の処理の流れ

消費量を求め、車両挙動と時間軸を一致させた上でマイニングツールに入力した。

### 3.3 対象車両、対象モード

検証試験に用いた車は、表1に示すA車～L車で

ある。そのうちガソリン車は11台で、内訳は軽トラック1台、軽乗用1台、乗用車8台、貨物車1台である。試験車の中には、ハイブリッド車、筒内燃料直噴車のように、運転条件に応じて電子制御装置が不連続的にエンジンを制御する車も含まれ、こうし

表1 実験と解析に使用した試験車(合計12台)の一覧

試験車コード	燃料	車種	エンジン総排気量(cc)	初度登録(Y/M)	車両重量(kg)	出力(kw/rpm)	低排出ガス認定	備考
A	G	軽トラック	658	2003.2	780	35/6,400		
B	G	軽乗用	658	2002.7	850	44/6,400		スーパーチャージャー
C	G	小型乗用車	1,339	2002.7	990	63/5,700		コンパクトカー
D	G	小型乗用車	1,497	2002.7	1,080	80/6,000		セダン
E	G	小型乗用車	1,496	2002.1	1,220	53/4,500		ハイブリッド車
F	G	小型乗用車	1,988	1996.2	1,300	99/5,600		セダン
G	G	小型乗用車	1,994	1995.7	1,390	206/6,500		ターボ/4WD
H	G	普通乗用車	2,998	-	1,470	166/6,400		セダン
I	G	普通乗用車	2,997	2002.3	1,580	162/5,600		セダン 筒内直接噴射
J	G	普通乗用車	2,260	2002.7	1,720	120/6,000		ミニバン / 4WD
K	G	貨物車バン	1,789	2000.2	1,300	66/5,000	GVW 2,215kg	
L	D	重量貨物車	4,777	-	3,485	96/3,000	GVW 4,540kg	最大積載量 2t




図5 燃費推計の検証実験に使用した走行モードパターン

た独特な制御機能を持つ車両に関しても、燃費推計がどの程度有効になるか調べた。一方、L車は最大積載量2トンの貨物車で、コモンレール式のディーゼルエンジンを備えた重量車である。

A～Kのガソリン車の場合は、図5に示す走行パターンに対して、それぞれシャシダイナモメータ試験による燃費の実測および事例ベース方式の燃費推計を行った。10・15モードとJC08モード以外は、当研究所の実験車で各種の道路条件を走行して採取した車速データを、それぞれの道路条件の代表性を考慮して編集し合成したトランジェント型モードである。

燃費特性を学習する代表走行モードの適性を調べる観点から、JC08モードと10・15モードの各実験データで作られた2つの事例データベースを基に図5にある他のモードの走行燃費をそれぞれ推計し、実測燃費と比較した。2つの学習モードの特徴の大きな違いは、JC08モードの方は実走行型トランジェントモードで比較的幅広い運転域が使われているのに対して、10・15モードは単純な折れ線型モードのため運転領域が限られている点にある。したがって後者の場合は、形状が異なる他のモードの燃費を推

計する際の参照データが不足する可能性があり、推計計算において不利と予想された。

ディーゼル重量車（貨物車）のL車の場合は、重量車の排出ガス試験モードパターンであるJE05モードによって、車の燃費特性を学習させた。

#### 4. データマイニング法による推計精度の検証

##### 4.1 距離燃費の推計結果

図6は、JC08モード運転において学習し作成した事例データベースから、各々のガソリン車について、(a)10・15モード、(b)都市内実走行モード（都内での加減速の激しい走行条件）(c)渋滞路走行モード、(d)地方道走行モード（交通流の少ない地方道路での中速域中心の走行条件）(e)高速道路走行モード、の各距離燃費（km/l）を、実測値と推計値と比較したものである。なお(a)図の10・15モードには、ディーゼル重量車であるL車の燃費推計値も示されているが、この車は重量車用のJE05モード走行時の計測データに基づく事例ベースから計算した。

図6の結果を見ると、TCBMデータマイニング法による推計燃費値は、それぞれの走行モードにおいて実測値と概ね良い対応関係を示しており、この点

から本推計手法の有効性が確認できた。しかし同図(e)の高速道路走行モードでは、推計値と実測値の差が他のモードよりも大きかった。燃費特性を学習した JC08 モードには、この高速道路走行モードのように準定常で高速走行する運転領域がほとんど存在しない。そのためデータベース中の該当する位相空間に参照できる燃費事例データが含まれていないので、周辺あるいは少し離れた空間領域のデータを使って間接演算で瞬時燃費値を計算しているため、誤差が拡大したと思われる。

図6の結果で車種ごとの違いを見ると、ハイブリッド車であるE車と筒内燃料直接噴射式のI車の推計精度は、他の車よりもやや劣っていた。E車では「モータ単独走行」と「エンジン+モータ走行」の動作モードを車両のECUが制御し、かつタイヤ駆動力に対するエンジンの分担割合が車の走行条件やバッテリー充電状態に応じてきめ細かく制御されている。一方、I車では、負荷条件に応じてリーンバーンとストイキ燃焼を切り換える制御が使われている。こうした構造的な特徴から、両車とも走行中にエンジン制御方式が不連続に変わる状況が時々発生し、入出力関係の連続性が成り立つ事象に適用するという本推計法的前提が当てはまらない部分があり、特にE車に影響が顕著なことが原因であろう。しかしこうした特殊な車でも、より広範な走行条件に基づいて、エンジン制御の切り換え特性も包含した燃費特性を学習できれば、予測精度を改善できる可能性がある。その場合には、制御特性と関連の深い入力パラメータをモデルに追加することも必要であろう。

#### 4.2 ショートトリップの燃料消費量の推計

モード走行燃費のように比較的長い区間の総消費量を推計する場合には、各ポイントの瞬時燃費の計算値に真値からのずれ(誤差)が発生していても、それらが正負にほぼ等しく分散していれば、モード全体での積分処理によって誤差が相殺され、総消費量の推計値は真値に近づくことになる。そこで積分の範囲を比較的短い走行区間に絞り、その間の燃料消費量の推計値を実測値と比較した。具体的には、図7に示すように各走行モード中に複数個存在するショートトリップ(ST:発進から停止までの区間)を対象にして、各STでの燃料消費量をTCBM法で計算し、その推計結果 $Q_{f1}'$ をカーボンバランス法で求めた同じ区間の実測値 $Q_{f1}$ と比較した。STの全集合における $Q_{f1}$ と $Q_{f1}'$ の対応関係を図8に示

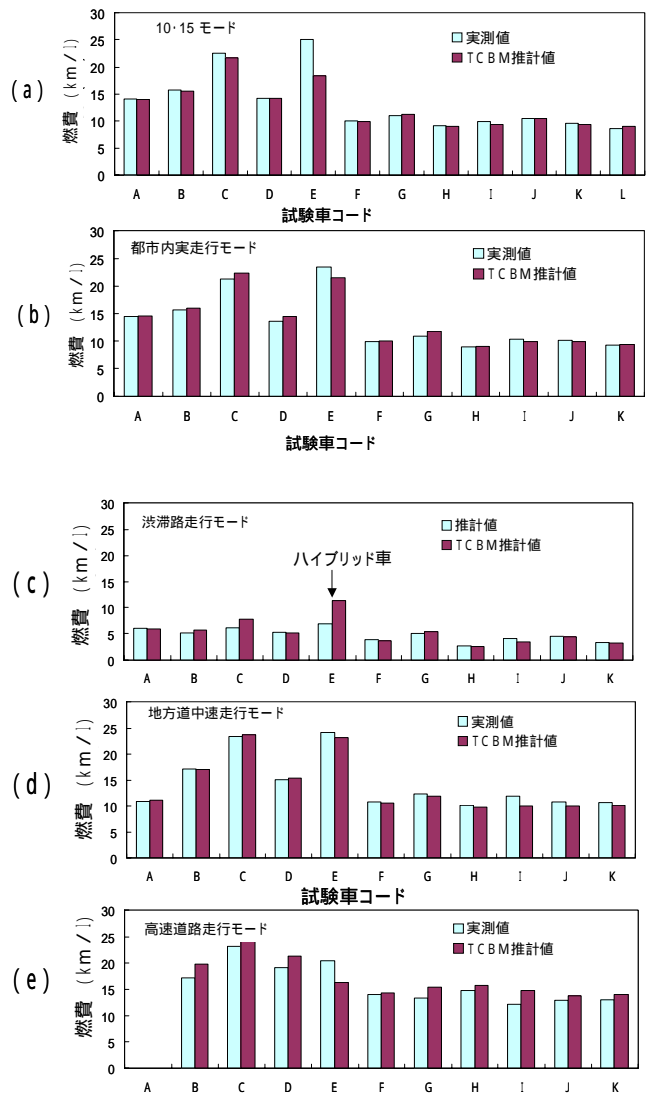


図6 各走行モードの距離燃費の実測値と推計値の比較

#### ショートトリップ(ST)




図7 ショートトリップ(ST)区間の定義およびST燃料消費量の実測値と推計値の比較方法

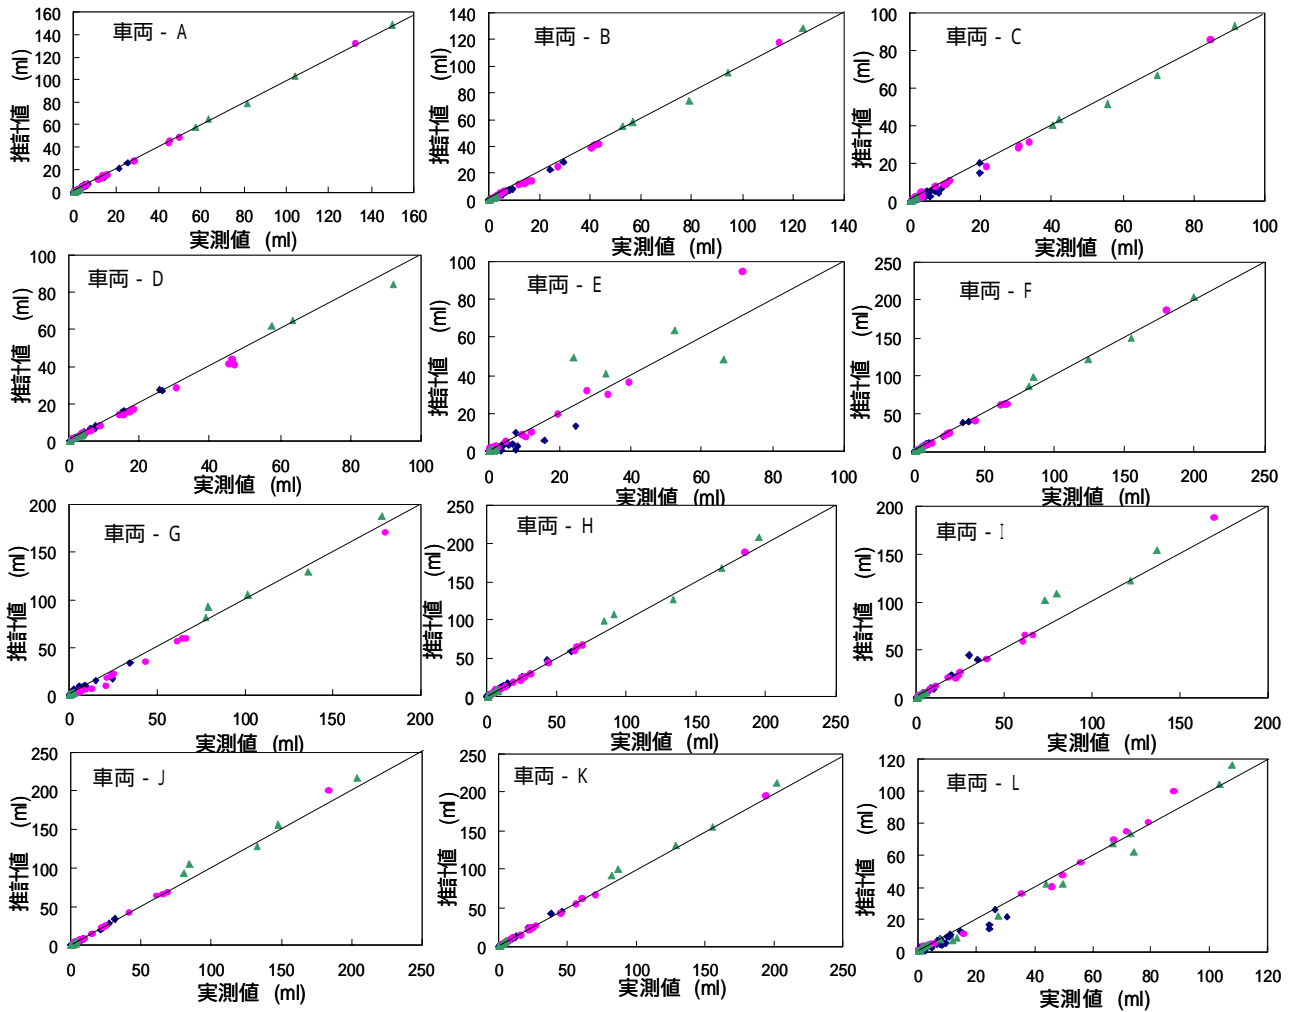


図8 各走行モードのショートトリップ燃料消費量の実測値と推計値の比較

す。図6で示したモード全体の距離燃費の結果と同様に、ハイブリッド車であるE車と筒内直接燃料噴射式のI車を除けば、各S Tの燃料消費量の推計値は、同じ区間の実測消費量とほぼ一致している。また、ディーゼル重量車であるL車でも、走行モードの形はガソリン車とは異なっているものの、推計値と実測値には同様な対応が得られている。

これらの結果から、短距離区間での燃料消費量に関しても、特殊な制御機能を持つ車以外はほぼ良い精度で推計できることが判明した。

#### 4.3 任意地点までの累積消費量の推計結果

次に出発点から任意地点までの累積燃費に関して、実測値と推計値を比較した。累積燃料消費量は、実測値、推計値いずれも瞬時消費量をモード開始時から対象点まで積算した値である。解析の例として、F車（ガソリン車）で4種類の走行モードを運転した

時の累積消費量の推移を図9に示す。各走行モードのどの経過点においても、累積消費量の推計値は実測値とほぼ一致した。この理由は、F車（三元触媒方式）のエンジンが急加速時や減速時以外は常に理論空燃比を維持するよう制御されているため、JC08モードの走行条件で学習し作成した燃費事例データベースが、他の走行モード条件に対してもうまく適合したためである。すなわちこのF車の例のように燃費の事例データベースが適切に作成できていれば、図6や図8のような特定区間の燃料消費量のみならず、図9のような走行中の任意地点までの累積燃料消費量であっても正確に予測できることになる。

一方、F車とは制御方式が異なるハイブリッド車のE車、およびリーバンと理論空燃比制御を切り換えるI車の累積消費量を図10に示す。推計値と実測値の一致度は前図のF車よりもかなり劣ることが明らかである。この2車種は、前述のように運転



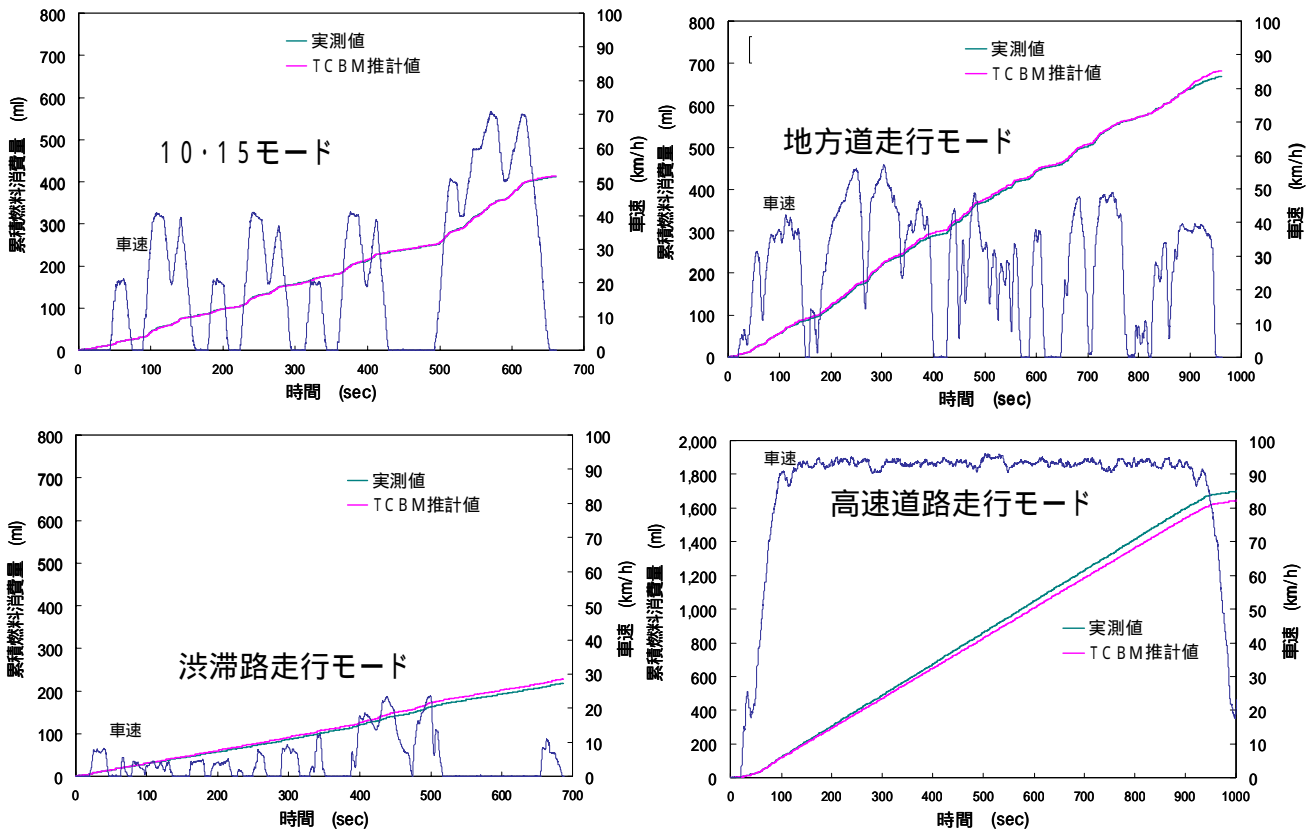
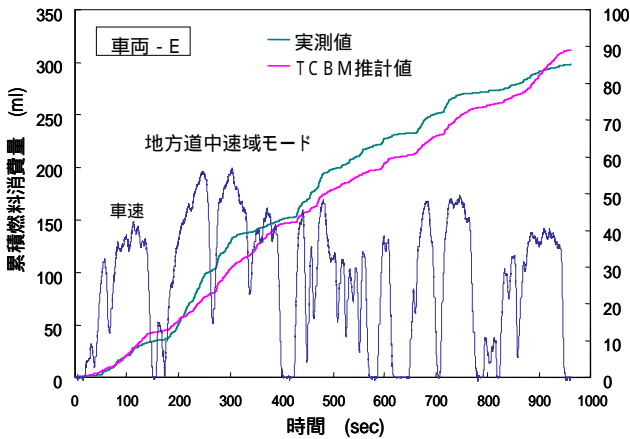


図9 各モードの開始点からの累積燃料消費量に関する実測値と推計値の比較（車両 - F）

## ハイブリッド車



## 筒内直接噴射エンジン車

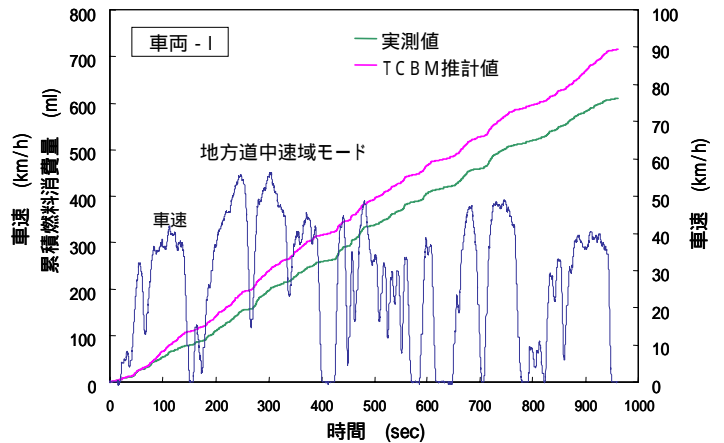


図10 不連続にエンジン制御する車の燃費実測値と推計値の比較

条件に応じて不連続にエンジン制御方式を変える方式のため、燃費特性の学習結果すなわち事例データベースの内容が不十分であったことを意味する。

### 4.4 瞬時燃料消費量の推計結果

燃費の予測法としては、これまでのように燃費値（累積消費量）が精度良く推計できるのであれば、

その使用目的には十分合致するとも言える。しかし本手法は、各瞬間の燃料流量を算出した後それらを積算して燃費値を求める方法であり、各瞬時流量は過去の事例の中から運転パラメータが近い条件を検索し、その時の流量値を参照する原理に拠る。そこでこの基本的な仕組みが有効、適切に機能しているか調べるため、過渡モード運転中の瞬時流量の変化

に関しても、推計値と実測値との対応を調べてみた。

K車の15モード運転時における瞬時流量の推計値と実測値を図11(a)に重ね合わせて示す。推計値の方を見ると、瞬時流量の大きな変化すなわち低周波数成分に関しては、ほぼ実測値に近い変化を示している。したがって、いくらかの変動成分が含まれている推計値でも、積分されたモード全体の距離燃費や任意点までの累積消費量に関しては、実測値にほぼ合致するというこれまでの結果を裏付けている。

しかし、図11(a)の推計値にはノイズ状の変動成分が含まれているので、その原因を考察した。計算時に参照した事例ベースの中身は、JC08モード運転時の連続入力値を変数パラメータのメッシュで区分して量子化し、位相空間に配置したデータである。燃費を予測する走行モードの瞬時燃料流量は、各点の運転パラメータの値に対応した事例ベース内の位相空間に保存されている値(学習結果)を使って計算するが、その場所に参照すべきデータが存在しない(過去に学習されていない)場合には、やむを得ず近傍のメッシュ内のデータを使って演算で求めている。これが図11(a)のような変動成分(推計誤差)を生み出す原因のひとつと考えられる。この点を改善するには、事例データベースの中に必要十分な参照データが収められるように、燃費特性の学習用走行モードのパターンを工夫する必要がある。

さらに燃費特性の学習用データの処理方法にも問題があった。学習モードを運転した時の瞬時燃料流量は、これまで希釈ガス中のCO<sub>2</sub>、CO、HCの濃度を測定して、各成分の検出無駄時間を補正した後、カーボンバランス(CB)法を使って計算していた。しかし分析計のガス濃度検出信号には応答1次遅れ成分も含まれるので、特に加減速時には、上記のCB法で求めた瞬時燃料流量の値にもその遅れ成分が含まれ、変化の速い車速、加速度、車両駆動力などの運転パラメータと分解能が合わず、対応関係が不鮮明なデータで学習した可能性がある。

その解決方法として、CB法瞬時燃料値に対して以下の1次応答遅れ補正を試みた。まず排出ガス分析計にゼロガスと3成分のスパングスを瞬時に切り換えるステップ入力条件を与え、濃度計測信号の変化から各成分素子の時定数を求める。次に分析計の希釈ガス濃度測定が「無駄時間+1次遅れ」から成る系であると仮定し、各成分の無駄時間と上記の時定数の値を用いて遅れ前の値を計算する。この補正値を用いてCB法による瞬時燃料流量を再計算し、




図11(a) 瞬時燃料消費量に関する実測値と推計値の比較1




図11(b) 瞬時燃料消費量に関する実測値と推計値の比較2(一次遅れ補正)

事例データベースに運転関連パラメータとともに入力する。この方法で計算した瞬時流量変化の推計値を図11(b)に示す。運転挙動と燃料消費の対応学習が改善されて図11(a)のノイズ状の変動成分がほぼ消滅し、実測値との対応がかなり良い結果となった。

今後は、燃費関連パラメータを適切に選択し、入出力データを量子化する際のメッシュ区分方法を工夫し、事例データベースの内容、構造をさらに改善できれば、燃料流量の瞬時値の推計においても今以上に実測値に近付けられると考える。

#### 4.5 事例ベース作成用の走行モードの影響

各車両の燃費特性を学習する走行条件として、これまではJC08モードで事例ベースを作成した。しかし実際の試験現場では、今のところ10・15モードを運転する方が一般的で、その際には状態監視のために希釈ガス濃度を連続測定してそのデータを記録する所が多い。つまりこれを燃費特性の学習データ

に利用することも可能となる。そこで 10・15 モード運転で学習した事例ベースを使って他のモードの燃費を推計した値と、JC08 モードで学習した事例ベースから求めた推計値とを比較してみた。

C 車、F 車、J 車に対する推計結果の比較を図 12 に示す。10・15 モードの連続データから推計した値は、特に高速走行や渋滞走行において JC08 モードの学習結果よりも推計精度が低下している。図 13 に示す両モードの台上実験のデータ分布が示すように、折れ線型の 10・15 モードは、燃費特性を学習するための運転領域が JC08 モードよりも狭く偏在している。その結果、事例データベースの情報量が限定的となるので、走行条件が大きく違う他のモードの燃費推計には不利となる。つまり燃費特性を学習する走行モードとしては、JC08 モードのように走行条件、エンジン運転域のより広い条件を用いる方が良い。また多種類の走行モードで追加学習していけば、任意走行条件に対する推計精度もさらに向上すると予想される。

### 5. まとめ

本研究では、データマイニング法を用いて任意走行モードの燃費を予測する手法を提案した。今回開発した手法は、代表走行モードを運転した時に測定した車両・エンジン挙動と燃料消費量の時系列データから、位相事例ベースモデリング TCBM (Topological Case-Based Modeling) 法によりその車の燃料消費特性を自動的に学習・モデリングし、その結果を使って任意の走行モードにおける燃費を




図 12 学習用走行モードの違いが燃費推計結果に与える影響 (C, F, J 車)

計算する方法である。本手法の有効性、実用性を検証するため、台上実験による実測値と推計値とを比較した。解析結果をまとめると、以下のようになる。

(1)車重、排気量、燃焼方式等の異なる合計 12 台の車両を使って種々のモードの走行燃費を推計し、

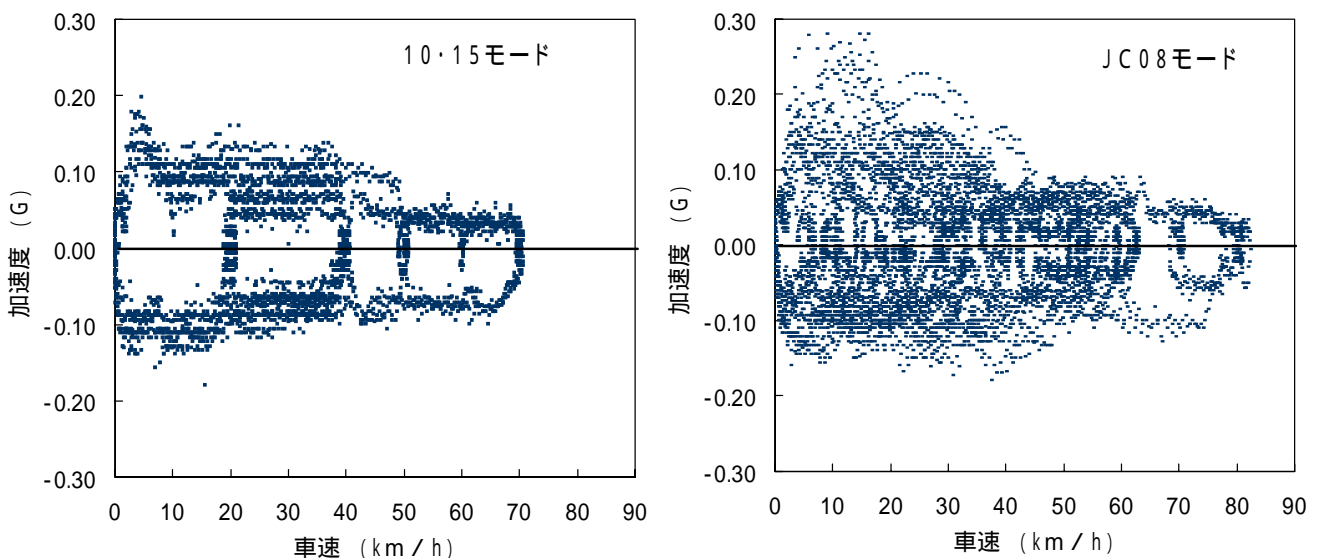


図 13 10・15 モードと JC08 モードの速度・加速度使用範囲の違い

同じモードを台上運転して実測した燃費値と比較した。その結果、燃費の推計値は、全体の距離燃費(km/l)、発進から停止までの個別ショートトリップの消費量(ml)、およびモード開始点から任意点までの累積消費量(ml)に関して、大半の車で実測値と良い対応を示した。すなわち燃費推計への適用が十分可能であり、その有効性が実証できた。

- (2)しかしハイブリッド車や筒内直接燃料噴射式の車のように不連続にエンジン制御を切り換える方式の車では、燃費推計の精度が他の車よりも低下した。主な理由は、ひとつの代表走行モードによる事例学習のみでは、運転条件と燃費特性との関連が十分把握できないことによる。こうした車の推計精度を上げるには、不連続型制御の特性も包含した燃費特性モデルにする必要があり、学習モード、入力パラメータの検討が必要である。
- (3)本予測法は、事例データベースから各瞬間の燃料流量を算出してそれを積和する方法なので、この基本的仕組みの妥当性を瞬時燃料流量の計算値から分析した。その結果、流量変化の大きな動きすなわち低周波数成分に関しては、ほぼ実測値に近い推計出力を示すことがわかり、(1)の積分量に関して良い推計結果が得られた理由が説明できた。
- (4)瞬時流量の推計値に変動成分(推計誤差)が生じた原因を調べた。本手法では、事例データベース空間の該当メッシュ域に参照値が存在しない時は、近傍のメッシュ域のデータを使って間接演算で推計しているため、それが誤差の要因となる。またガス分析の一次遅れ要素の入ったカーボンバランス瞬時燃料流量と変化の早い運転パラメータとの間で分解能に差が生じ、対応関係が不鮮明な状態のまま特性学習したことも誤差の要因である。後者への対策として、ガスの一次応答遅れを補正した事例データベースに修正したところ、瞬時流量の推計値に見られた変動成分が大幅に低減できた。
- (5)燃費特性の学習モードの適否を検討する目的で、折れ線型パターンの10・15モードの学習事例ベースを使って他のモードの燃費を推計した値と、実走行型のJC08モードから推計した値とを比較した。その結果、10・15モードによる学習は、JC08モードよりも燃費推計の精度が劣ることがわかった。この原因は、学習運転領域の違いによる事例データベースの基本情報量の違いである。すなわち特性学習のための走行条件としては、運転領域の範囲の広いモードを用いる方が有利である。

## 6. あとがき

最近各分野で注目を集めているデータマイニングは、多分野の様々なシステムを対象として、過去に蓄積されたデータに基づき現在進行中の複雑な事象の結果(出力)を予測できる汎用的手法といわれる。

本研究では、データマイニングを利用した自動車の燃費推計法とその適用性を検討した。同手法によるモード燃費推計等を台上実験による実測値と比較したところ、多くの種類の車および各種の走行条件に関して、走行燃費をほぼ正確に予測できることが確認され、実用的手法であることを実証した。

自動車は極めて多様な条件のもとで使われる機械システムである。その意味で、実用燃費が車の使用条件によって大きく変わることも広く知られている。自動車の省エネルギー対策を策定する際には、こうした自動車特有の問題を踏まえつつ、投資効果の高い実効ある施策を検討していく必要がある。

しかし自動車の燃料消費の実態を克明に調べる実験調査は、時間や費用の点で課題が多かった。データマイニング手法は、こうした問題を解決するのに有効な分析ツールであり、今後は自動車分野でも導入・活用が進むことが期待される。

さらに新車時の燃費性能、排出ガス性能、動力性能などが使用過程で低下した場合に、運転条件に影響されずにその変化を確実に検知し車内表示する自己診断(OBD)システムが重要となってくる。データマイニング手法は、このOBD装置に組み込む判断アルゴリズムとして利用することも可能であり、今後の有望な応用分野として期待できる。

最後に本研究は、この分野に関して当所と共同研究を実施している(株)山武の研究開発本部との連携による成果であり、同社の筒井宏明氏と西口純也氏には、特にマイニングツールdata FORESTの利用方法に関して多大のご支援、ご助言を頂いたので、ここに謝意を表します。

## 7. 参考文献

- (1) Noda 他 : Evaluation Method for HDV Fuel Economy Performance with PC Simulation and Mapping Procedure SAE 2003-01-2010
- (2) 筒井、西村 : 時系列履歴データからのデータマイニング、計測と制御 第41巻第5号
- (3) 筒井、ほか : 履歴データを事例として使用する非線形モデリング技術TCBM、計測自動制御学会論文集、33-9,947/954 '1997)