

10 事例ベースデータマイニング法による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

環境研究領域 *野田 明 米川 誠 小川 恭弘
 (株)山武 筒井 宏明 西口 純也

1. まえがき

地球温暖化防止対策は我が国の重要課題であり、CO₂ 総排出量の20%近くを占める自動車部門においても、排出抑制のための施策として、物流対策、道路整備、交通規制、低燃費車の普及、省エネ運転の励行等、種々の省エネルギー対策を総合的に推進する必要がある。しかし、このような関連施策を検討、計画する際には、燃料消費量やCO₂ 排出量の具体的な削減効果も検討する必要がある。

例えば、道路計画等によって交通状況を改善する施策を実施した場合の省エネ効果を予測するため、車両区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条件をシャシダイナモメータ上で運転して、燃料消費量、CO₂ 排出量を測定する方法が考えられる。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から、試料数の少ない実験データによって求めた効果予測は限定的なものとならざるを得ない。

一方、より正確な調査を実施するため範囲を広げて、多数の車種、多種類の走行条件による実験を行

い、それぞれの燃費やCO₂ を測定しようとするれば、膨大な実験工数と試験費用が必要になることから、現実的には困難である。こうした実証データ取得の困難さは、自動車の省エネ施策、温暖化対策の効果予測における問題のひとつであった。

今回開発した燃費予測法は、図1に示すブラックボックスモデリングの手法のひとつである位相事例ベースモデリングTCBM (Topological Case-Based Modeling) 法の応用であり、代表走行での試験データから対象車両の燃料消費特性モデルを自動構築し、これを基に任意の走行条件における燃料消費量を推計する方法である。モデリングは、基準の走行モードを運転した時に測定した燃料消費量と車両挙動の時系列データを用いて車両特性を学習する。

合計12台の試験車を使って、様々な走行条件における台上燃費試験の実測値と本手法で求めた推計値を比較した結果、両者が比較的良く一致することがわかり、本推計手法の有効性、実用性が確認できたので、以下に報告する。

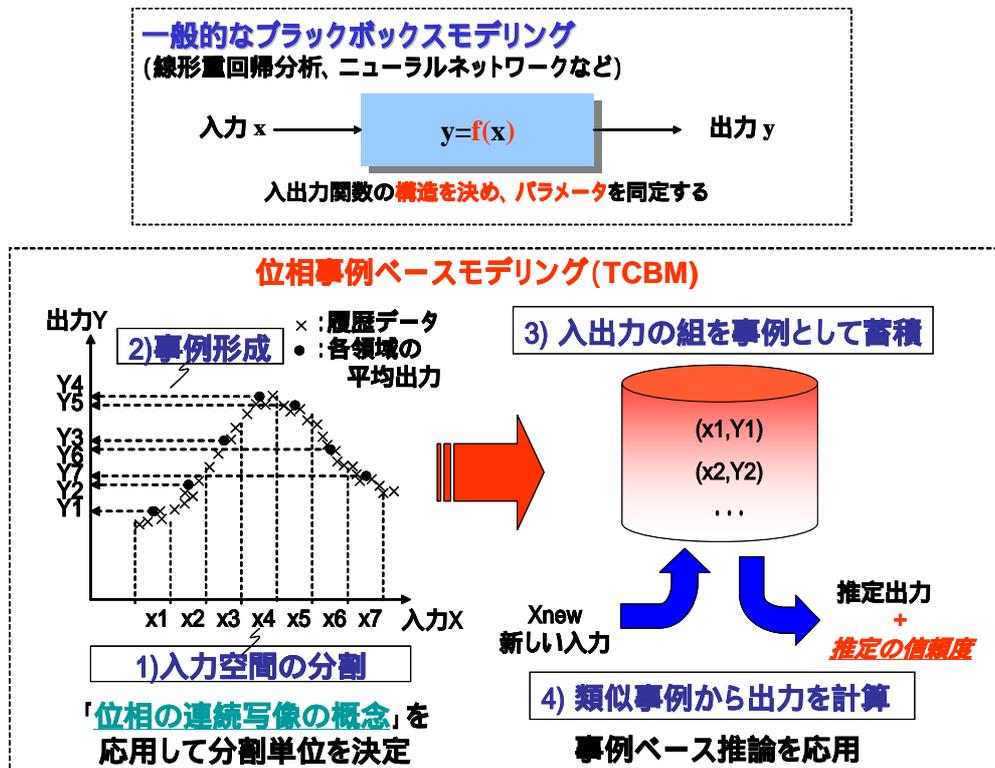


図1 非線形事象推計のための位相事例ベースモデリングの概念図

2. 燃費推計方法の概要

2.1 基本概念

本推計法は、例えば公式の燃費評価試験などで使われる代表走行モードにおいて、車両挙動と瞬時燃料消費量の変化を連続計測し、両者の関係を示すこの時系列データを量子化して、対象車両の燃費特性に関する事例データベースを自動作成する。次に燃費を予測する走行モードの速度変化と車両情報（車両重量、走行抵抗等）を入力変数として、データマイニング法により上記の事例ベースを参照し、対象モード走行時の燃料消費量を逐次計算する。なおデータマイニングとは、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モデルを作成し、非線形で複雑な事象を予測する手法である。こうした手法は、システムをブラックボックスとみなして、物理的な知見を用いず、入出力の観測データからモデルを同定する手法である。

従来一般的なブラックボックスモデリングでは、図1上段に示すように入出力間の関係を規定する関数モデルを作成する必要がある。そのためには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収束計算などを時間をかけて行って、次数やネットワーク構造などのモデルパラメータを決定する必要がある。さらに、追加データなどにより新しい情報を取り入れた場合には、パラメータの修正作業が必要で、適応学習が困難という問題があった。

今回提案する燃費推計法は、取得された学習データから非線形な入出力関係を定めるために、図1下段の位相事例ベースモデリングTCBM (Topological Case-Based Modeling) 法を応用している。TCBM法は、位相(トポロジー)の概念に基づき、事例データベース推論の枠組みをモデリングに

適用したもので、入出力関係の連続性が成り立つ一般的な対象に、入力事例と事例ベースとの類似度合いをもとにモデリングする方法であり、事例を多く学ぶほどモデルの推計精度が向上する特長を有する。

こうした事例ベース推論法では、過去に経験した事例データベースの中に入出力関係が内包されているため、入出力関係を規定するモデル構造を特別に作る必要が無く、与えられた問題に類似した過去の事例を参照して、必要な解を導く。以下では燃費推計への適用性を検証した。

2.2 燃費事例ベースの作成と推計精度の検証

本手法を使って任意走行でのモード燃費を推計するため、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。

本手法による燃費の推計精度や適用性を調べるため、車重、排気量、燃焼方式等が異なる表1の合計12台の車両に関して、速度パターンの異なる各種走行モードにおける燃費を推計計算し、それぞれの結果をシャシダイナモメータ試験で同じモードを運転して求めた実測値と比較した。

各車両ごとに運転条件に対する燃費特性を学習し事例データベースとして用意するため、ひとつの代表モードを1回台上運転し、燃費に関連した車両挙動パラメータと燃料流量の0.1秒毎の計測データをマイニングツールに入力した。今回の計算に使用した車両挙動パラメータは、各瞬間の実車速、加速度、車両駆動力、エンジン出力とした。これに対応する各瞬間の燃料流量は、CVS希釈排出ガス中のCO₂、CO、HCの濃度変化を連続測定して、カーボンバランス法(CB法)により算出した。なお車両挙動と同時

表1 試験車の諸元

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

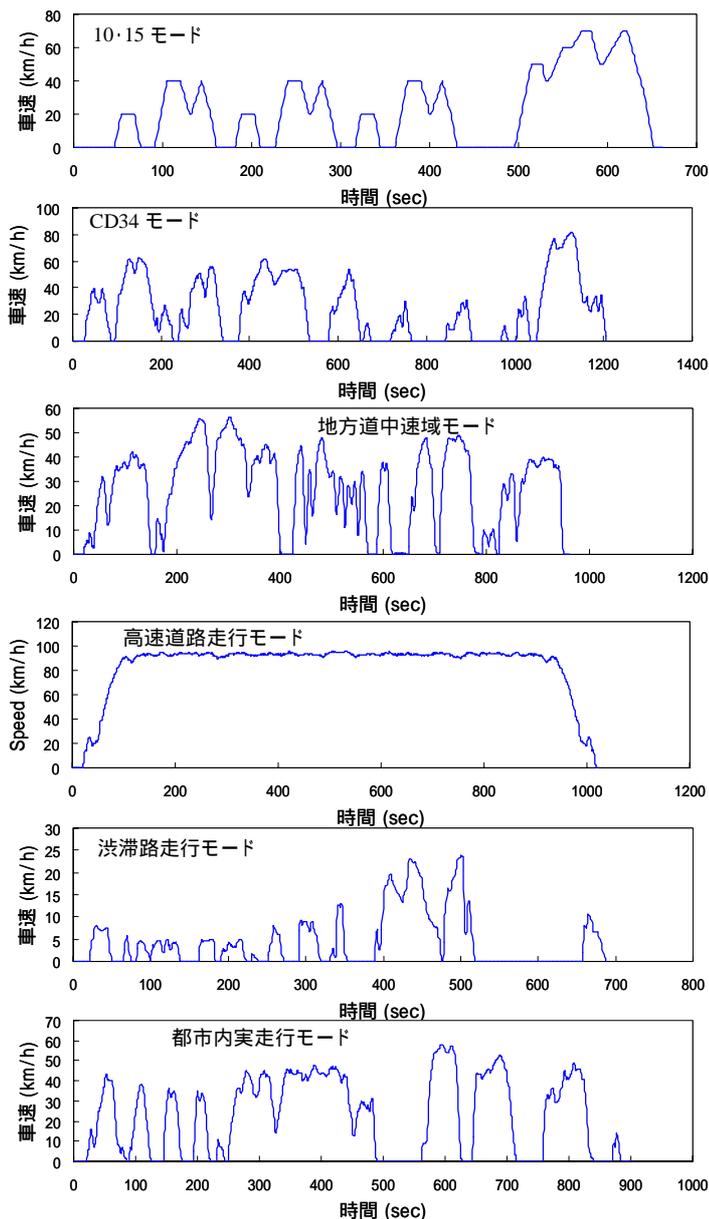


図2 ガソリン車の燃費推計精度検証用の走行モード

間に測定した各成分の希釈ガス濃度変化には、ガス検出に伴う無駄時間と分析計の応答遅れ分が含まれているため、希釈ガス濃度測定での遅れ時間を各成分ごとに補正した上で、CB法による瞬時燃料消費量を計算し、車両挙動と時間軸を合わせた形でマイニングツールに入力した。

2.3 対象車両、対象モード

本手法の有効性を調べる対象車両は、表1に示すA車～L車である。ガソリン車は11台で、その内訳は軽トラック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、ハイブリッド車やリーンバーン筒内直噴車のように、運転条件に応じて車載のECUが不連続的にエンジンを制御する車両もあり、こうした特殊なエンジン方式の車両に関して、

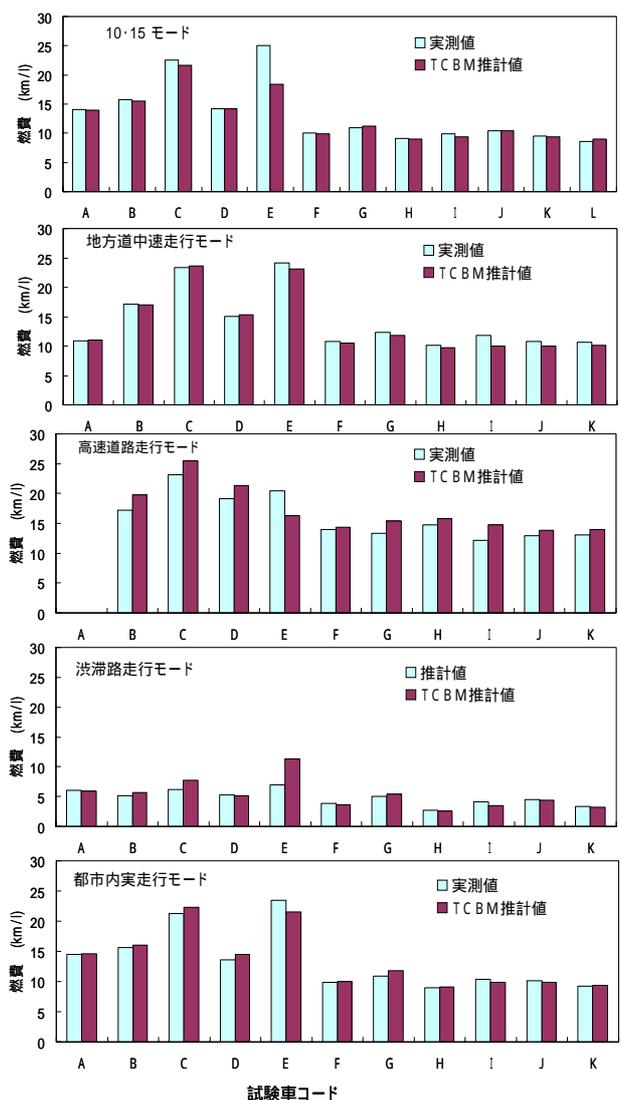


図3 各走行モードの距離燃費における実測値と推計値の比較

本手法による燃費の推計精度を調べた。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。

ガソリン車に関して、シャシダイナモメータ上の燃費測定及びデータマイニング方式の燃費推計を行った走行モードパターンを図2に示す。10・15モードとCD34モード以外は、専用計測車で各種の道路条件を実走行させて求めた車速データから条件別に構成した過渡走行パターンである。

燃費事例データベース作成用の学習モードとしては、ガソリン車では、CD34モードを用いた場合と10・15モードの2通りについて、推計結果の違いを比較した。前者は実走行型過渡モードであり、幅広い運転域での特性学習が可能であるのに対して、後者は折れ線型モードのため学習の上では運転領域が狭いという問題がある。ディーゼル貨物車の場合は、JE05モード走行時の実測データで学習させた。

3. データマイニング法による推計精度の検討

3.1 距離燃費の推計結果

図3は、CD34モード運転による事例ベースから、各車の10・15モード、地方道中速域モード（交通流の少ない地方道路での中速域中心の走行条件）、高速道路走行モード、渋滞路走行モード、都市内実走行モード（都内における急加減速の多い走行条件）の各モードにおける距離燃費の推計値と台上試験での実測値との比較である。なお10・15モードの図に示したディーゼル重量車のL車の推計値は、JE05モード走行時の事例ベースを基に計算した値である。

データマイニング法を使って推計した燃費値は、それぞれの走行モードにおいて、シャシダイナモメータ上で実測した値と概ね良い対応関係を示していることがわかった。しかしながら高速道路走行モードでは、推計値と実測値の一致度が他のモードよりも低下している。これは、燃費特性を学習したCD34モードには、この高速道路走行モードのように、比較的定常運転に近い形で高速走行する条件が少なく、学習データが不足したことが原因と考えられる。

一方、ハイブリッド車であるE車と希薄燃焼筒内直接噴射式のI車の推計精度は、他の車の結果よりも劣っている。その原因は、両車とも不連続にエンジン制御方式を切り替える機構を備えているため、1種類のモード運転のみでは燃費特性の学習が不十分であったことによると考える。

3.2 ショートトリップでの燃料消費量の推計

比較的短距離の走行区間における燃費の推計精度を確認するため、それぞれのモードにおける発進から停止までの各ショートトリップ(ST)区間における燃料消費量を推計し、実測値と比較した。結果を図4に示す。前図の距離燃費の場合と同様に、ハイブリッド車であるE車と筒内直接噴射式のI車を除けば、各ST区間での燃料消費量の推計値は、同じ区間に実測した消費量と良く対応している。また、ディーゼル重量車であるL車においても、走行モードの形はガソリン車とは異なっているが、推計値と実測値にはほぼ同様な対応関係が得られている。

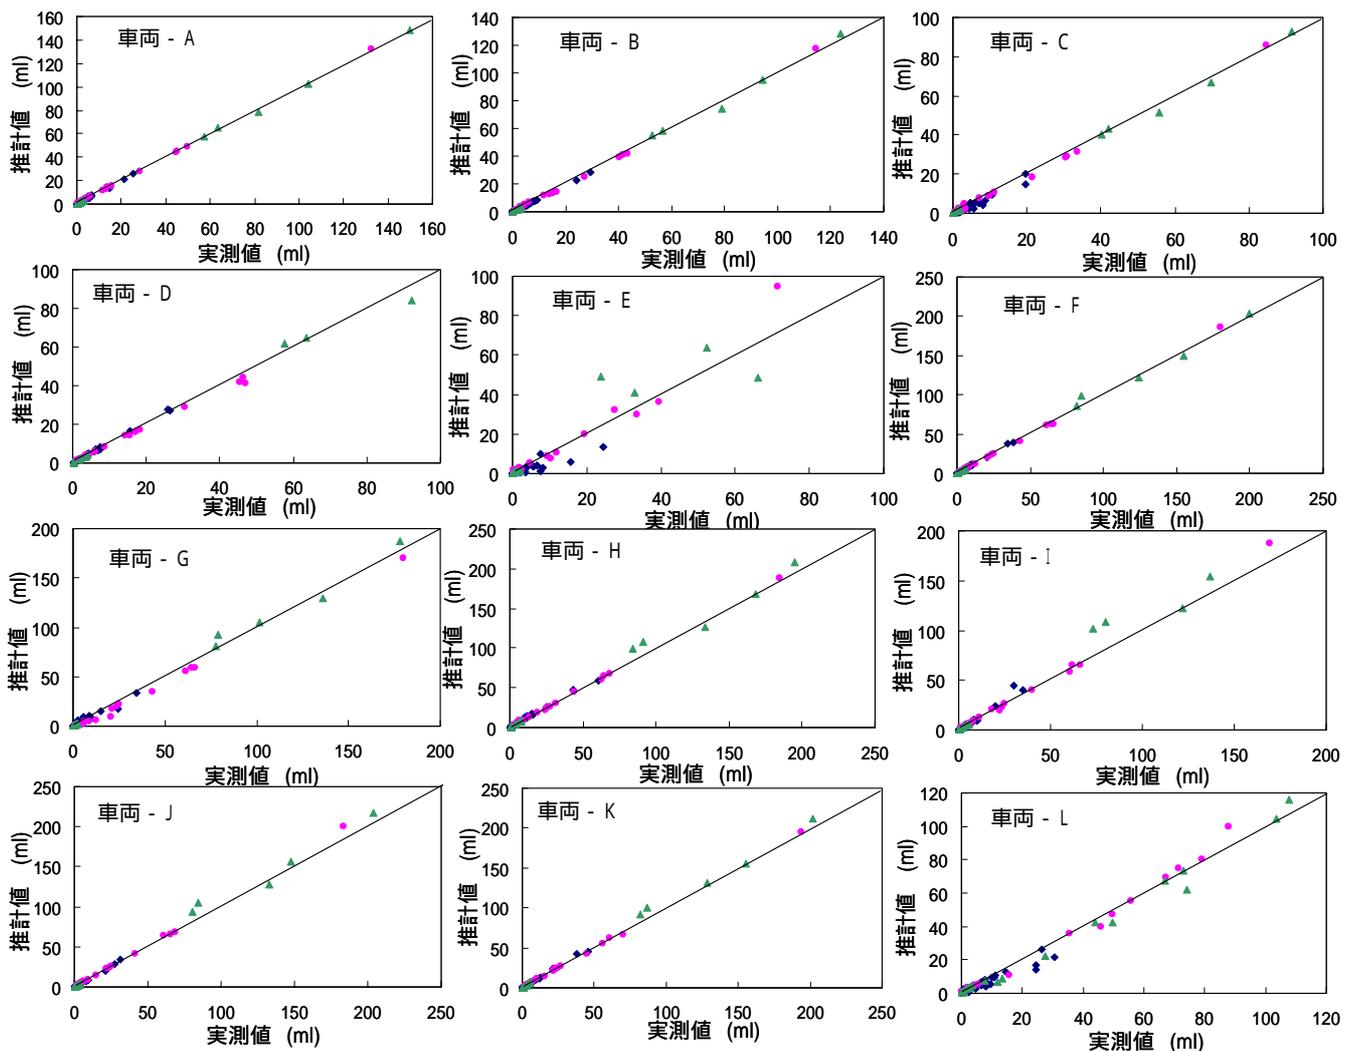


図4 各走行モードのショートトリップ燃料消費量に関する実測値と推計値との比較

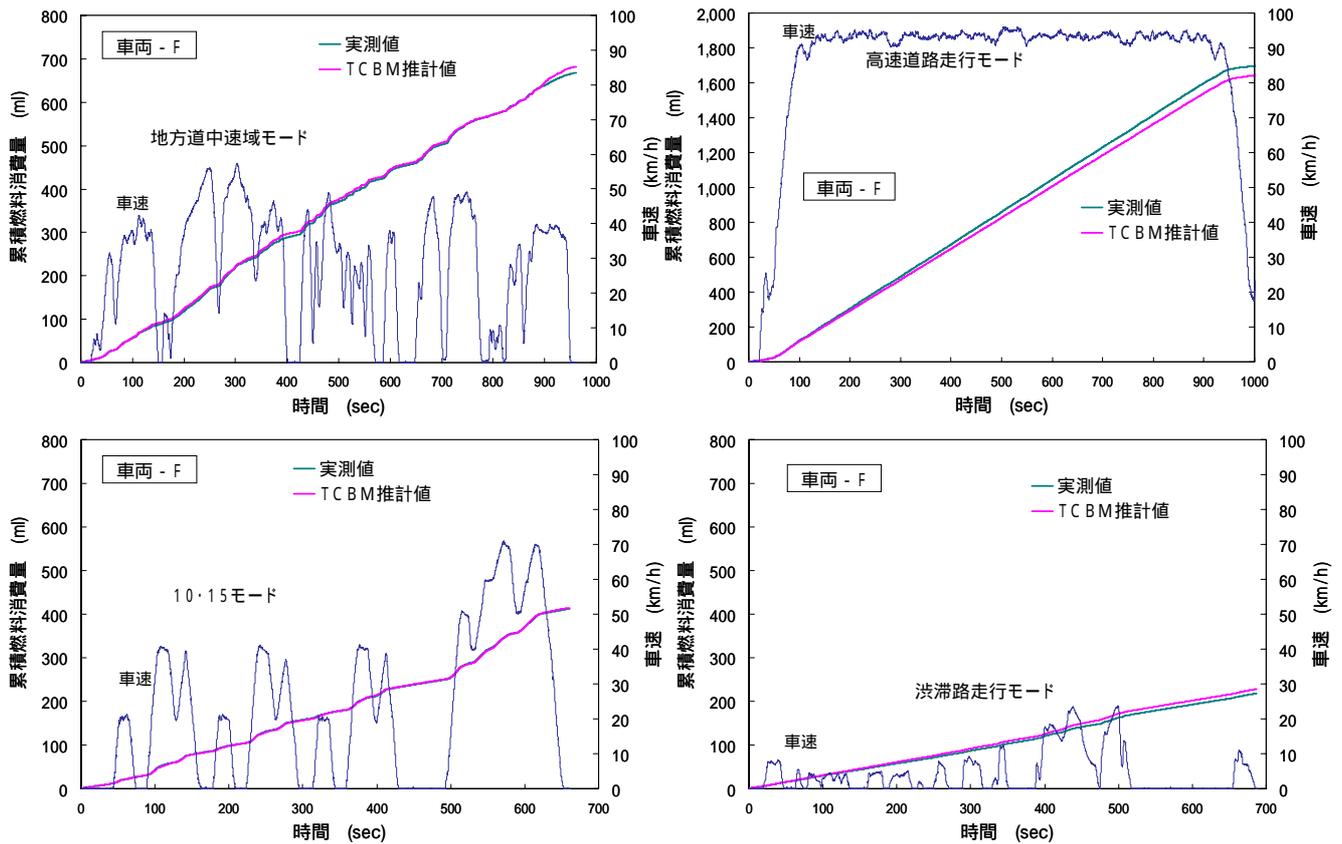


図5 各試験モードの運転開始点からの累積燃料消費量に関する実測値と推計値との比較

3.3 走行中の任意点における累積消費量の推計
 走行中の任意点での累積燃料消費量に関して、実測値と推計値を比較し本手法の有効性を検証した。累積消費量は、実測値、推計値いずれも算出した瞬時消費量を運転開始時から積算した値である。解析結果の例として、ガソリン車であるF車で走り方の全く異なる4種類の走行モードを運転した時の各々の累積量の推移を図5に示す。各走行モード運転中のどの経過点においても、推計した累積消費量は実測値にほぼ一致している。この理由は、F車が理論空燃比制御方式の車であるため、CD34モードのデータで構築した運転域と燃費特性との関連を記述する事例ベースが、他のモード走行条件でもうまく適用できたことによる。すなわち対象車の事例ベース構築が適切なものとなれば、図3や図4のようなある走行区間全体の燃費だけでなく、図5のように走行中のどの点においても、燃料の消費量をほぼ正確に予測できることがわかった。

次にハイブリッド車のE車と、リーンバーンと理論空燃比制御を切り替えるタイプのI車の累積消費量の結果を図6に示す。推計値と実測値の一致度はF車より劣っている。これは両車とも、車載ECUが運転条件に応じて不連続にエンジン制御方式を切り替えているため、この部分の燃費特性の学習が不十分であったことによる。

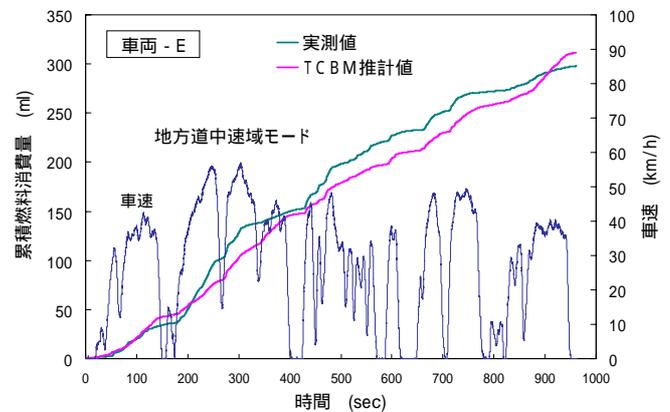


図6(a) ハイブリッド車に対する累積消費量の予測

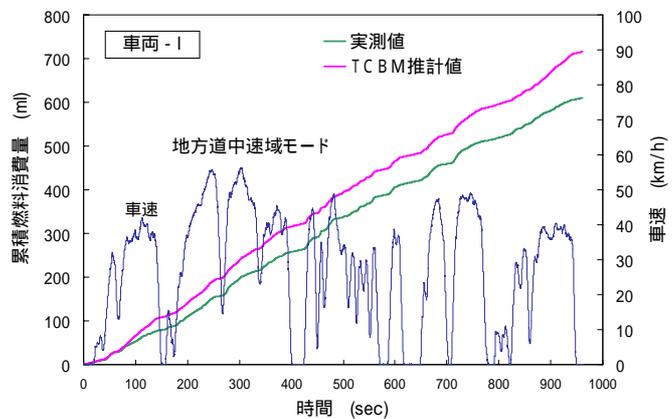


図6(b) 筒内直接噴射車両に対する累積消費量の予測

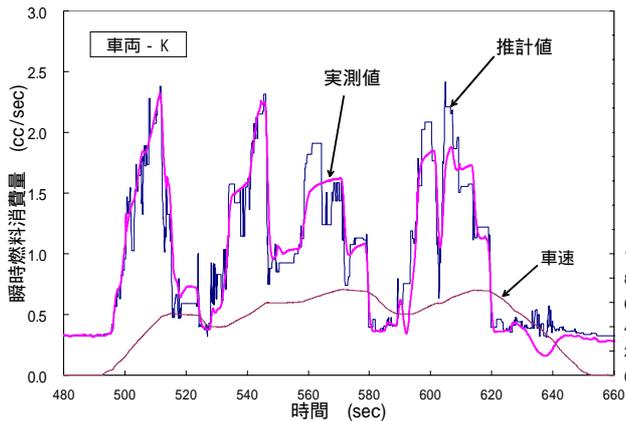


図7 瞬時燃料消費量に関する実測値と推計値との比較

3.4 瞬時燃料消費量の推計結果

燃料消費量の予測では、累積値が精度良く推計できれば目的を達するといえるが、本手法は各瞬間の状態を予測するため過去の近い事例を参照するという原理なので、この仕組みの妥当性を調べる観点から、過渡モード運転中の瞬時流量変化についても推計値と実測値との対応を調べた。

K車の15モード運転時における瞬時値の比較を図7に示す。推計値は、低い周波数成分で見ればほぼ実測値に近い計算結果を示しており、これが距離燃費や累積消費量で推計値と実測値がほぼ対応する理由である。しかし、図7の推計値にはノイズ状の変動成分が含まれている。参照した事例ベースはCD34モード運転時の連続データを関連パラメータのメッシュで区分して量子化したものであり、また推計を行う走行モードの各ポイントの運転領域に対応する事例ベースの規定メッシュ内に該当する燃費データが存在しない場合は、近隣のメッシュの事例データを使って演算で求めていること等が原因と考えられる。

今後、パラメータ選択とメッシュ区分などに関してさらに検討し、事例ベース作成方法の適正化が実現できれば、瞬時値の推計でもさらに実測値に近付けられると考える。

3.5 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CD34モードから事例ベースを作成したが、実際には現行の燃費評価試験用である10・15モードを運転して車両の燃費特性を調べる方が多いと考えられる。そこで10・15モード結果から他のモードの燃費推計を行う場合の精度を調べた。

C車、F車、J車に対する推計結果の比較を図8に示す。折れ線で構成されて単純なパターンの10・15モードは、車両挙動と燃費との関連性を学習する条件としての情報量がCD34よりも不足し、他のモードの燃費推計を行うには不利と見られる。図8にもそれが現れており、実験値との比較では、CD34ベースで推計する方が良い結果が得られている。

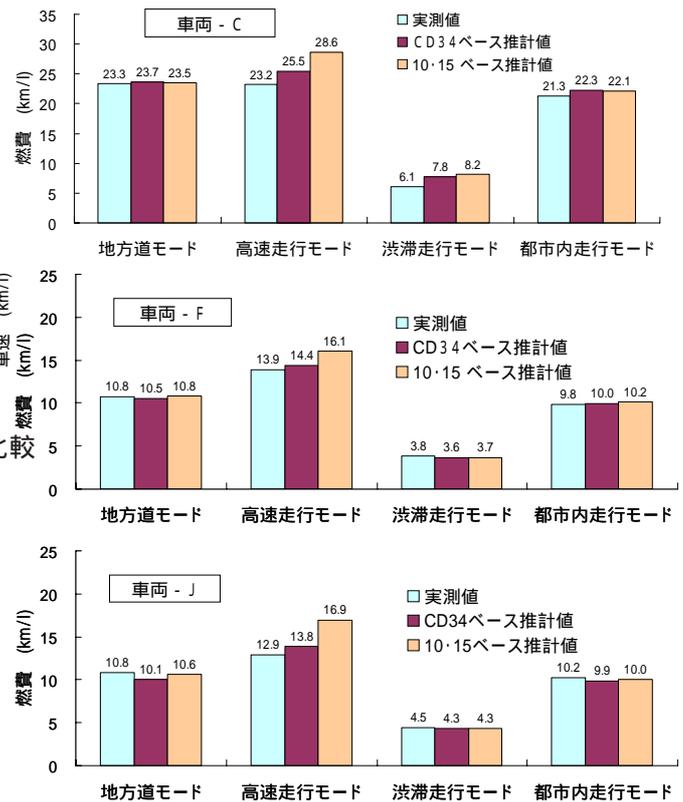


図8 燃費特性学習モードの違いによる実測値との対応 (CD34ベースと10・15ベースとの比較)

4. まとめ

事例ベースデータマイニング法による燃費推計の可能性を検討した。この方法は、代表走行モードを運転して測定した燃料消費量の時系列データから、その車の燃料消費特性を学習、自動モデリングして、これを基に任意の走行モードにおける燃料消費量を予測する実用的手法である。

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走行条件における燃費を計算し、台上運転での実測値と比較した。その結果、各モードの燃費推計値は、全体の距離燃費(km/l)、発進から停止までの各ショートトリップの燃料費量、モード開始点から任意点までの累積消費量に関して、大半の車で推計値と実測値が良く一致しており、本推計手法の有効性、実用性が確認できた。

ただし、ハイブリッド車や筒内直接噴射式の車のように不連続にエンジン制御方法を切り替える方式の車では、ひとつの代表走行条件の事例のみでは運転条件と燃費特性との関連を学習しきれないため、燃費の推計精度が低下した。

燃料消費の瞬時値でも、推計値の低周波数成分は実測値と概ね一致したが、推計値にノイズ的な変動分が含まれていて、対策は今後の課題となる。事例ベースの構築では、情報量の多いCD34を使う方が10・15モードよりも効果があった。