

博士学位論文

ガウス過程回帰を用いた  
エンジンシリンダー内の空気充填効率を  
推定するための統計モデリングに関する研究

**Study on Statistical Modeling using Gaussian  
Process for Charging Efficiency  
in Engine Cylinder**

小川 史恵

**Fumie Ogawa**

令和1年12月

# 目次

<b>第1章 緒言</b> .....	6
1.1 エンジン開発の歴史と期待される性能.....	6
1.2 目的.....	9
1.3 エンジン開発の課題.....	10
1.3.1 効率改善.....	10
1.3.2 電子制御システム開発の効率化.....	12
1.4 方法.....	15
1.5 論文構成.....	20
<b>第2章 研究で使用する統計モデルの方法について</b> .....	21
2.1 ガウス過程回帰の説明.....	21
2.2 本研究で使用している時系列データの取り込みおよびガウス回帰の構成.....	25
2.3 実験装置および試験車両データ.....	28
<b>第3章 試験車両データを使用した検証</b> .....	30
3.1 はじめに.....	30
3.2 分割法の提案および有効性検証.....	30
3.3 検定数を増やした試験車両データの評価について.....	35
3.4 散布図による検証.....	39
3.5 統計モデルの推定精度と有効性検証.....	50
3.5.1 データの分割周期の変更を行った検討.....	50
3.5.2 Max Time Lag の設定比較.....	52
3.5.3 FFTを用いた周波数領域の解析.....	56
3.5.4 LPFを適用した統計モデルの推定精度と有効性検証.....	60
3.5.5 サンプリング周期の変化についての検討.....	64
3.6 小括.....	73
<b>第4章 WLTCモードを使用した検証と評価</b> .....	74
4.1 はじめに.....	74
4.2 推定を実施する条件の検討.....	75
4.3 データの分割周期の変更を行った検討.....	78
4.4 Max Time Lag の設定比較.....	80
4.5 LPFを適用した統計モデルの推定精度と有効性検証.....	84
4.6 サンプリング周期の変化についての検討.....	92
4.7 小括.....	99
<b>第5章 総括</b> .....	100
<b>付録</b> .....	102
<b>参考文献</b> .....	105
<b>謝辞</b> .....	111

## 图目录

Fig. 1.1 Three major performances of the automobile engine.....	6
Fig. 1.2 History in combustion engine .....	8
Fig. 1.3 Major four losses in combustion engine.....	10
Fig. 1.4 Energy loss control factor for engine <sup>[13]</sup> .....	11
Fig. 1.5 Group of vehicle control system by CAN .....	12
Fig. 1.6 Four steps of control for combustion engine .....	13
Fig. 1.7 Detailed process in the estimation of air volume in-cylinder.....	15
Fig. 1.8 General model development process .....	16
Fig. 1.9 Conventional model for estimation air volume in-cylinder .....	17
Fig. 1.10 Purpose of this research .....	18
Fig. 1.11 Soft sensor diagram .....	19
Fig. 2.1 Compare with statistical way.....	21
Fig. 2.2 Configuration diagram : Import of time-series data to Gaussian Process.....	26
Fig. 2.3 Definition of charging efficiency.....	27
Fig. 2.4 Engine system diagram.....	28
Fig. 3.1 Vehicle data for GP.....	31
Fig. 3.2 The way of data separation.....	32
Fig. 3.3 Comparison of prediction for vehicle running behavior.....	33
Fig. 3.4 Comparison of prediction for vehicle no-load behavior.....	34
Fig. 3.5 Subplot of prediction error and CE in dataset 1530.....	39
Fig. 3.6 Subplot of prediction error and CE in dataset 1605.....	42
Fig. 3.7 Subplot of prediction error and CE in dataset 1435.....	46
Fig. 3.8 Focus of Subplot of prediction error and CE in dataset 1435 .....	49
Fig. 3.9 Comparison of prediction for Max Time Lag.....	52
Fig. 3.10 Result of Inverse Autocorrelation Function .....	55
Fig. 3.11 Amplitude characteristic of explanatory variable .....	57
Fig. 3.12 Amplitude characteristic of explanatory variable .....	58
Fig. 3.13 Detail of Low Pass Filter Data Plotting.....	60
Fig. 3.14 Comparison of prediction for LPF effect.....	62
Fig. 3.15 Comparison of prediction for sampling effect.....	67
Fig. 3.16 Comparison of prediction for sampling effect in dataset 1605.....	68
Fig. 4.1 WLTC mode simulation data for GP of explanatory value.....	76

Fig. 4.2 Result of Inverse Autocorrelation Function for WLTC mode .....	80
Fig. 4.3 Comparison of prediction for Max Time Lag .....	82
Fig. 4.4 Amplitude characteristic of explanatory variable on WLTC;600-1200[sec].....	84
Fig. 4.5 Comparison of prediction for LPF in transient behavior .....	86
Fig. 4.6 Comparison of prediction for LPF in steady behavior .....	87
Fig. 4.7 A Vehicle running data on WLTC .....	88
Fig. 4.8 An AT Vehicle running data on WLTC .....	89
Fig. 4.9 Comparison of prediction for down sampling in transient behavior .....	93
Fig. 4.10 Comparison of prediction for down sampling in steady behavior .....	94
Fig. 4.11 Comparison of prediction for WLTC mode running;0-600[sec].....	96

## 表目次

Table 2.1 Specification of polynomial function.....	22
Table 2.2 Specification of the 4-cylinder gasoline engine (For section 3).....	29
Table 2.3 Specification of the 4-cylinder gasoline engine (For section 4).....	29
Table 3.1 The name of preprocessing parameter .....	31
Table 3.2 The parameter of GP calculation's parameter setting .....	33
Table 3.3 Comparison of CE in prediction and original data .....	37
Table 3.4 Comparison of prediction for separation time in dataset.....	50
Table 3.5 Table of GP Simulation Parameters.....	61
Table 3.6 Comparison prediction error with difference in LPF's cutoff frequency .....	63
Table 3.7 Comparison of prediction for sampling effect .....	65
Table 4.1 The parameter of GP calculation's parameter setting .....	77
Table 4.2 Comparison of prediction for separation time by width.....	78
Table 4.3 Table of GP Simulation Parameters.....	84
Table 4.4 Comparison prediction error with difference in LPF's cutoff frequency .....	85
Table 4.5 Average for Steady and transient behavior .....	91
Table 4.6 Comparison of prediction for sampling effect;600-1200[sec] .....	92



## 略語・記号

本論文で用いる略語，および記号を定義する。ここで定義した略語・記号は本論文中では断りなく使用する。

ECU	Electronic Control Unit
GP	Gaussian Process
LPF	Low Pass Filter
WLTC	Worldwide-harmonized Light vehicles Test Cycle
AFS	Air Flow Sensor
IACF	Inverse Autocorrelation Function

# 第1章 緒言

## 1.1 エンジン開発の歴史と期待される性能

内燃機関とは広義にはシリンダなどの機関内で燃料を燃焼させ、それによって発生した燃焼ガスを用いて直接に機械仕事を得る原動機を指す。1800年代には、ガソリンによって機械仕事を得るガソリンエンジンが發明された。ガソリンエンジンは、小型化に適したエンジンの型に比例して行う仕事量や低振動・低騒音等の利点から乗用車・小型商用車・自動二輪車などに広く採用され、一般向けの自動車普及に大きく貢献した。一方で自動車の急速な普及により、ガソリンエンジンの排ガスによる大気汚染や気候変動の影響は看過できないものとなった。エンジンが与える環境負荷の抑制は、自動車メーカーが果たすべき社会的な責任として認識されるようになった。エンジン開発は、顧客が期待する性能と、社会責任として満たすべき性能の両立であるといっても過言ではない。時代ごとの困難な性能要求に対して、エンジニアは、革新的なアイデアで相反する性能を両立してきた<sup>[1,2,3,4,5,6,7,8,9]</sup>。




Fig. 1.1 Three major performances of the automobile engine

Fig.1.1 に自動車エンジンの3大性能を示す。エンジンの主要な性能は出力性能、排気ガス性能、燃費性能の3つに大別される。

- ・出力性能(馬力, トルク)

出力性能は、最高速度に影響を与える馬力、加速性能に影響を与えるトルク等を指す。出力性能の向上が顧客に意識され始めたのは、自動車普及の初期である。その理由は、高速道路の整備や自動車レースの開催等により、一般消費者にも高出力な自動車が求められるようになったためである。

- ・排気ガス性能

排気ガス性能は、内燃機関の燃焼後に排出される成分の量で排気管から排出されるガスやその成分を指す。このガスは、窒素、二酸化炭素(CO<sub>2</sub>)、水蒸気が大部分を占める。また、燃焼の状態によって、窒素酸化物(NO<sub>x</sub>)、炭化水素(HC)、一酸化炭素(CO)、粒子状物質(PM)等のガスが排出され、これらの排出するガスの量が少ないほど高い性能を有していることを示す。そもそも排気ガス性能への関心が高まったのは、一般消費者の自動車保有率の増加に伴い、大気汚染が深刻な問題となったためである。これにより、各国では、マスキー法に代表される排気ガス量制限の法整備が進んだ。また、今日では、地球温暖化等が要因の一つである気候変動が顕在化している。そこで、CO<sub>2</sub>等の地球温暖化の原因となる温室効果ガスの削減を目的とし、全世界で継続的に排出するガスに対する規制の強化が図られている。

- ・燃費性能

燃費性能は燃料1L当たりの走行距離で示す。少ない燃料で長い距離を走行することが可能であれば燃費性能が高いエンジンであると言える。バブル崩壊やリーマンショックなどによる景気低迷により、消費者はこの燃費性能の高いエンジンが搭載されたハイブリッドカーを求めるようになった。




Fig. 1.2 History in combustion engine

Fig. 1.2 に自動車エンジンの3大性能と技術の変遷を示す。1950年からのエンジン開発～自動車普及へと至る今日まで、自動車エンジンの3大性能は継続的に進化している。現在の開発で重視されているのは、排出ガス性能の改善である。この排気ガス性能の改善は、1970年代のマスキー法をきっかけに三元触媒や排気ガス再循環、電子制御システムによって飛躍的に改善されたが、2010年以降は、CO<sub>2</sub>を代表とする温室効果ガスの削減が中心となってきた。

以上のように自動車におけるエンジン開発の歴史では、排出ガス性能や燃費性能が重要な指標であることを説明してきた。また、これらの性能はエンジンの種類や車両重量にも左右され細かく分類されている。ただし、路上の走行時に取得したデータを評価するのではなく、台上試験と呼ばれる方法で、試験室内で路上の走行パターンを再現して評価を可能にしている。走行パターンは走行モードとも呼ばれ、地域ごとに異なる走行モードで試験されている。代表例としてJC08(日本)、US6(米国)、NEDC(欧州)がある。これらの走行モードで評価した排出ガス性能や燃費性能は、新型の自動車の生産や販売を行う際に国に申請する重要な数値となる。しかし、これらの走行モードは地域ごとの制限速度や道路環境の事情を考慮して策定されたものであり、同一エンジンでも販売地域の走行モードの違いによって排出ガス性能や燃費性能に差が出るのが問題点として指摘されてきた。そこで、近年ではWLTCモードと呼ばれる世界共通の走行モードでの試験に切り替わりつつあり、エンジン開発でも早急な対応が求められている。

## 1.2 目的

近年では自動車エンジンの低排出ガス・低燃費化への関心が高まり、燃料によりクリーンかつ効率的に燃焼する技術が求められている。その中でも重要な技術に位置付けられているのが、気筒内の空気と燃料を適切な量に混合する空燃比制御技術である。この空燃比制御の高精度化において、筒内吸気量と呼ばれるエンジン気筒内へ吸引される空気量の推定精度を改善することが重要な課題として認識されている。今日の空燃比制御システムでは筒内吸気量を直接計測することが困難なため、筒外の空気量センサから推定された筒内吸気量に基づいて燃料噴射量を決定し、目標の空燃比を実現している。

筒内吸気量の推定精度は、先行研究の成果<sup>[1,2,3,4,5,6,7,8,9]</sup>により着実な改善が行われている。しかし、現在までに積み残された課題として過渡状態による推定値と真値間の誤差がある。従来技術では筒内吸気量は筒外の空気量センサの値から吸気系の物理方程式と、定常運転時における筒内吸気量の実験データに基づいたマップを組み合わせて推定されてきた。

環境に配慮したエンジンの制御システム開発では、制御装置に制御対象モデルを実装し統計モデルなどを適切に配置することが鍵と考えられている。これまでは、車両走行およびエンジンデータを基に物理方程式を用いてモデルを作成していた。ただし上述の物理方程式では、表現しきれないシステムの挙動がありセンサデータを効率的に活用するうえで課題となっていた。そこで上記物理方程式を用いたモデルの一部について統計モデルに置き換えることを目標とし、筒内の吸気量を周囲のセンサデータから推定することを目的とする。この際、筒内吸気量の過渡変化も考慮できるモデル推定を実施する。

本研究では、統計モデルとして広く知られるガウス過程回帰の GP<sup>[10,11,12]</sup>を筒内吸気量の推定に適用し、推定精度の更なる改善を目指す。この GP を選択した経緯としては、従来手法の統計モデルに比べ過渡領域の推定に強く時系列データを扱うことができる動特性に優れているからである。CE の推定には、過渡領域の動特性を考慮することが重要であると考えられる。エンジンの開発の課題について次章で詳細を述べていく。

## 1.3 エンジン開発の課題

### 1.3.1 効率改善




Fig. 1.3 Major four losses in combustion engine

Fig.1.3 にエンジンの 4 大損失を示す。エンジンは、燃料の持つ化学エネルギーをピストンの運動エネルギーに変換する装置である。したがって、エンジン内でピストンの運動エネルギー（有効仕事）に変換されなかったエネルギーは損失となる。エンジン内で発生する損失は、「排気損失」、「冷却損失」、「機械抵抗損失」と「ポンプ損失」の 4 つに分けることができる。排気損失は、エンジン内で燃焼後に高温の燃焼ガスを排出する際に発生する損失である。冷却損失は、エンジンのオーバーヒート为了避免するために設けられた冷却装置への熱損失である。機械抵抗損失は、エンジンの回転によって、ピストンやシリンダ、クランクシャフト等の機構が動作するときの摩擦抵抗による損失である。ポンプ損失は、シリンダ内での気体吸入、排出時の抵抗に対して発生する損失である。ガソリンエンジンでは、これら 4 大損失により燃料が持つエネルギーの約 8 割以上が捨てられている。エンジンにはいまだ多くの改善代が残っており、エンジンのエネルギー効率改善は電動化時代にも必要不可欠な開発課題といえる。

下記の Fig.1.4 の制御因子の項目は、自動車メーカーがエンジンの設計過程で制御可能な項目を指す。エンジンの効率に寄与する設計値は「圧縮比」, 「比熱比」, 「燃焼期間」, 「燃焼タイミング」, 「吸排気高低圧力差」, 「機械抵抗」の6つのみであり、これら6つの設計値を理想の状態へ近づけることで Fig.1.3 の4つの損失を低減することができる<sup>[13]</sup>。

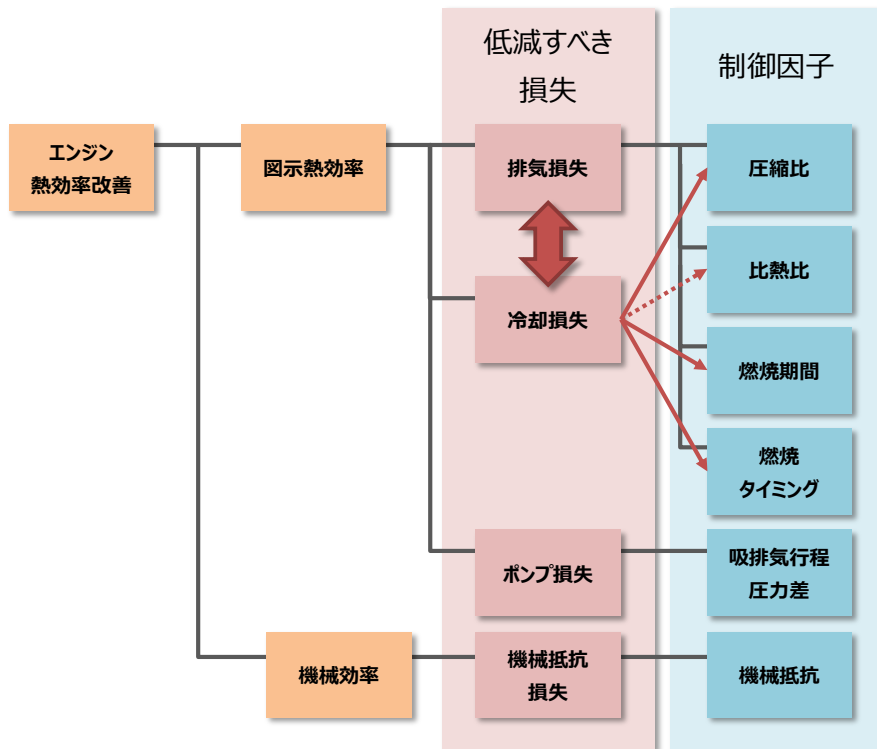


Fig. 1.4 Energy loss control factor for engine<sup>[13]</sup>

### 1.3.2 電子制御システム開発の効率化

近年、複数の相反するエンジン性能を両立するため、エンジンの電子制御の重要性はますます増加している。そのため本研究では、電子制御システム開発に着目した<sup>[13]</sup>。


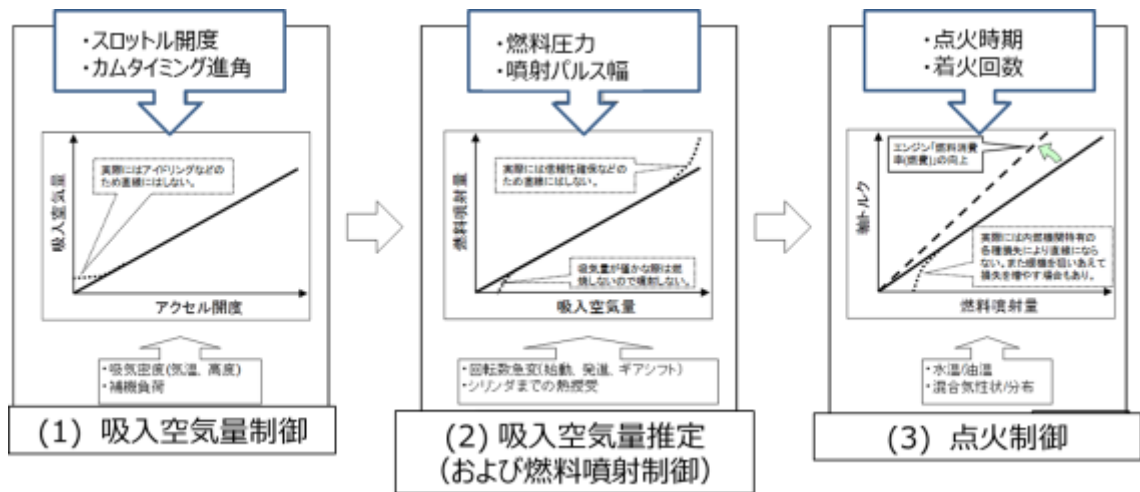


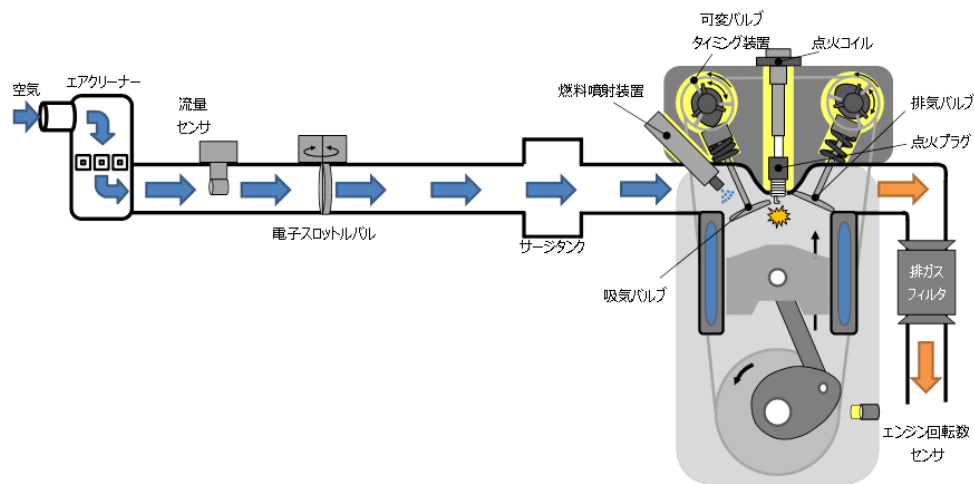
Fig. 1.5 Group of vehicle control system by CAN

Fig.1.5 に自動車の電子制御システムの概念図を示す。今日の自動車制御では、自動車の走る、曲がる、止まる機能すべてにおいて ECU による制御が行われている。自動車に ECU が初めて導入されたのはエンジンであり、本来 ECU は Engine Control Unit の略であった。エンジンに ECU が搭載された背景には 1970 年代の厳しい排ガス規制がある。この規制に対してエンジン ECU は、燃焼に必要な空気と燃料の混合比率や混合気への点火時期等のこれまで制御の難しかった領域にまで踏み込んだ性能改善を可能にした。その結果、エンジン ECU は、大型車から小型車に至るまで急速に普及し、今日のエンジンには欠かせない存在となっている。





(a) ECU(エンジン制御ユニット)



(b) 制御のステップについて

Fig. 1.6 Four steps of control for combustion engine

Fig.1.6 に示すようにエンジンの制御は大きく分けて「吸入空気量制御」, 「吸入空気量推定」, 「燃料噴射制御」, 「点火制御」のステップで計算が行われる。このうちのそれぞれの制御のかかわりを(a)に示した吸入空気量制御は, ドライバからの加速指令をアクセルペダルで受け, 設計段階で決められた吸入空気量が気筒内に入るよう, 電子スロットルバルブや可変バルブタイミング機構の制御量を決定する。吸入空気量推定では, 吸気系に設置された流量センサの値から気筒内に吸入される空気量を推定する。

そして, 燃料噴射制御では吸入空気量の推定値から予め決められた目標空燃比(空気と燃料の比率)となるように燃料噴射量を決定する。点火制御では, 吸入空気と噴射された燃料による混合気に対して, 点火プラグでどのタイミングで何回点火するのかを決定する。これらを(b)に示している。

以上の4つのステップがエンジン制御ユニットで繰り返し計算されることによって適切な量の空気と燃料が適切なタイミングで点火される。つまり, 「吸入空気量制御」, 「吸入空気量推定」, 「燃料噴射制御」, 「点火制御」の4ステップの精度がエンジンの出力, 燃費, 排気ガス性能に影響を与える。

## 1.4 方法

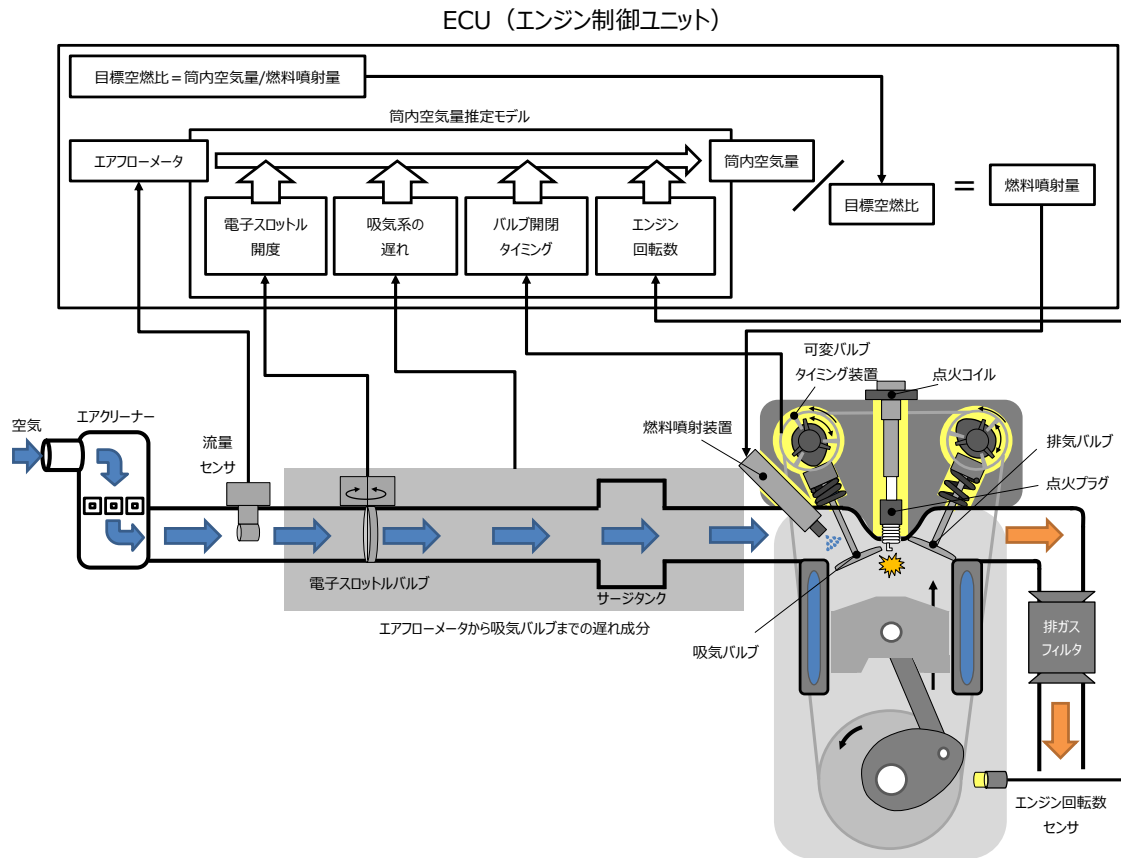


Fig. 1.7 Detailed process in the estimation of air volume in-cylinder

Fig.1.7 に吸入空気量推定の詳細な計算プロセスを示す。吸入空気量推定の基本的な考え方は、エンジン気筒外に設置された流量センサの値から筒内の空気量を推定することである。エンジン負荷の変動を伴う実用の運転状態においては、バルブタイミングの変化などで吸気圧・排気圧が動的に変動する<sup>[13]</sup>。

吸気バルブの開閉タイミングや電子スロットルバルブの開度によって筒内吸気量の変動する箇所は、流量センサの値に対して吸気系の物理特性や定常運転時における実験データ(電子スロットルバルブ開度、バルブ開閉タイミング、エンジン回転数) から作成したマップを組み合わせることで補正している。これを定常的な物理方程式に実験データを組み合わせることで補正している。この推定方法は、先行研究<sup>[1,2,3]</sup> によって改良がなされ、筒内吸気量の推定精度は着実に改善している。




Fig. 1.8 General model development process

Fig.1.8 は従来の推定モデルの全体像である<sup>[14,15,16]</sup>。推定モデルの開発では、エンジンベンチと呼ばれる実験室で評価用エンジンを並列に運転し電子スロットルバルブ開度・バルブ開閉タイミング・エンジン回転数等の条件を変えながら筒内吸気量の計測を行う。そして計測したデータに基づいて、流量センサの値を筒内吸気量の値に補正する推定モデルを構築する複数のエンジンを並列に稼働させる。

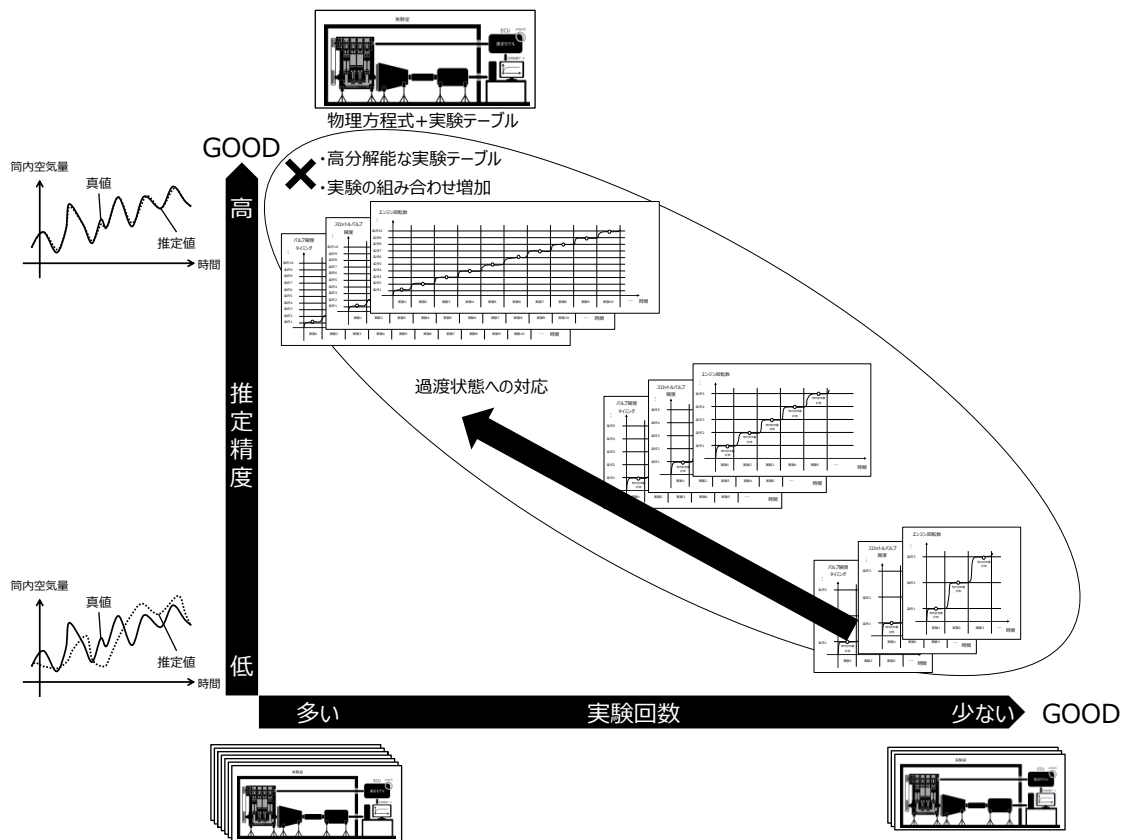


Fig. 1.9 Conventional model for estimation air volume in-cylinder

現状の従来の実験方法について整理する。Fig.1.9 には、従来方法での課題について示す。エンジンベンチによる同定試験において定常領域や過渡領域の推定精度を向上させるには、実験条件を細かく分割して分解能を高める必要がある。但し現状は、実験の組み合わせ数が爆発的に増えるため全領域の合わせこみをしているので推定が困難な領域がある。

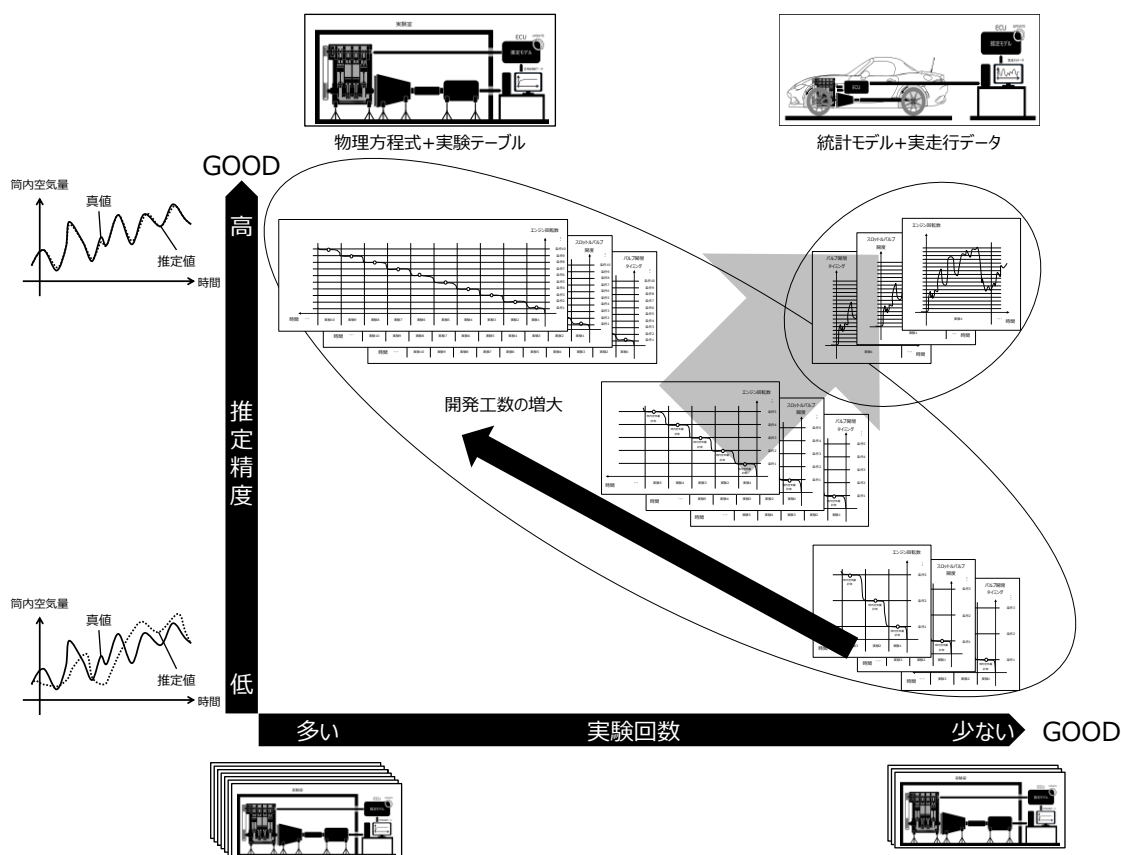


Fig. 1.10 Purpose of this research

そのため本研究では次のような方法をとった。

Fig.1.10 に示すように少ないデータでも精度のよいモデルを構築できる統計学を導入する。試験車両などで取得したデータからセンサの代わり（ソフトセンサともいう）として、推定モデルの開発を進めることを検討していく [17,18,19,20,21,22]

この時、統計モデルを作成して複雑な系を制御対象とするならば説明変数の選択が重要となる。メカニズムを知らずにむやみにモデル精度を追求するだけでは、逆に推定モデルの誤差を対処療法で直すことになる。管理の難しいモデルにするのではなくモデル精度に寄与するのが説明変数であり、これらは内燃機関が動作するのに不可欠な要素である。本研究ならば吸気系モデルのため、カムタイミングやスロットル開度のセンサ値がこれにあたる。

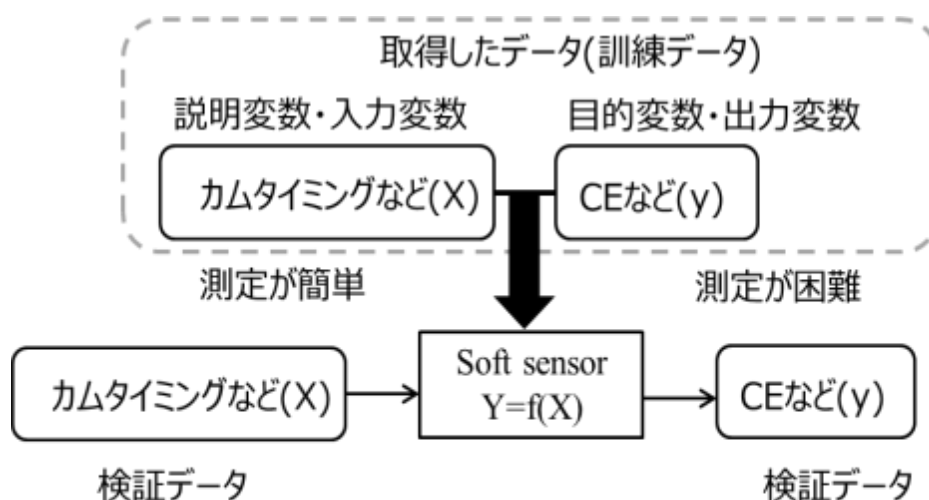
物理方程式モデルや統計モデルの場合でも対象のメカニズムをしっかり解明することが重要である。統計モデルにおいては、精度に寄与する根本的な要素を押さえたうえで統計の要素を加えたエンジンの性能と品質の要求に対して必要な精度を持つように汎用性を高めていく。統計モデルを採用すると、排気ガス性能や燃費性能に応じていく多様な内燃および電動化エンジンの開発に対応していくためにも迅速に開発を進めることができる点も利点となる。

統計モデルを利用する利点は、下記の2点である。

- ・推定モデル作成に必要な実験回数を大幅に削減し、開発効率を向上できる
- ・過渡状態を含む実走行データに対応したモデル化手法の選択が柔軟である

本研究は気筒近くに設置されたセンサにより、計測されたエンジンデータから統計モデルを用いて吸入空気量の推定モデルを作成する(Fig.1.11)。

計測される実走行データから統計モデルを用いて吸入空気量の推定モデルを作成する。変数が自在に選択でき、かつ非線形のモデル式に対応できる手法である<sup>[19,20]</sup>。



例：CE=f(カムタイミング、スロットルポジション、エンジン回転数)

Fig. 1.11 Soft sensor diagram

## 1.5 論文構成

本論文の構成を示す。5章で構成し、以下に章ごとの内容を示す。

第1章の緒言では、本研究の社会的位置づけについて述べる。次に従来<sup>1)</sup>の知見について述べ、最後に本論文の解決すべき課題を整理して目的を明確にする。

第2章では、研究で使用する統計モデルの方法であるガウス過程回帰である Gaussian Process(GP) について説明記述した。

第3章では、試験車両データを元に GP を利用した統計モデルの特性検証を行う。まず、データの前処理方法の提案を行った。続いて本研究で提案する時系列データの取り込みの方法としての分割法について述べる。さらに、推定を高める方策として LPF 効果およびダウンサンプリングの有効性について考察する。<sup>2)</sup>、最後に入力データの取り込み幅を変化させた検証をする。

第4章では、国際的な基準である走行モード、WLTC モードで検証する場合を考えた。検証データから、統計モデルにあてはめた際に推定誤差の原因となる要因を取り除くことができるように推定条件を考慮して実際に使う場合に相対誤差を小さくする検討を行う。3章同様に LPF 効果およびダウンサンプリングの有効性、入力データの取り込み幅を変化させた検証についても考察する。

第5章では、考察およびまとめを述べる。



## 第2章 研究で使用する統計モデルの方法について

### 2.1 ガウス過程回帰の説明

ガウス回帰である GP 法は、ベイズ確率理論に基づいた解析法である。本手法は、Rasmussen(1996) の論じるガウス過程が元になっている<sup>[10,11,12,23,24]</sup>。GP は外れ値の処理に強い学習方法であるため通常は統計モデルを用いて学習を行う場合、外れ値がモデル学習に大きな影響を与える。今回の研究では商品化後のエンジンから学習データを取得しており、外れ値の混合は避けて通れない。したがって、外れ値の処理に強い学習方法を検討した結果 GP の採用に至った。下記 Fig.2.1 に他の回帰との比較結果を示す。

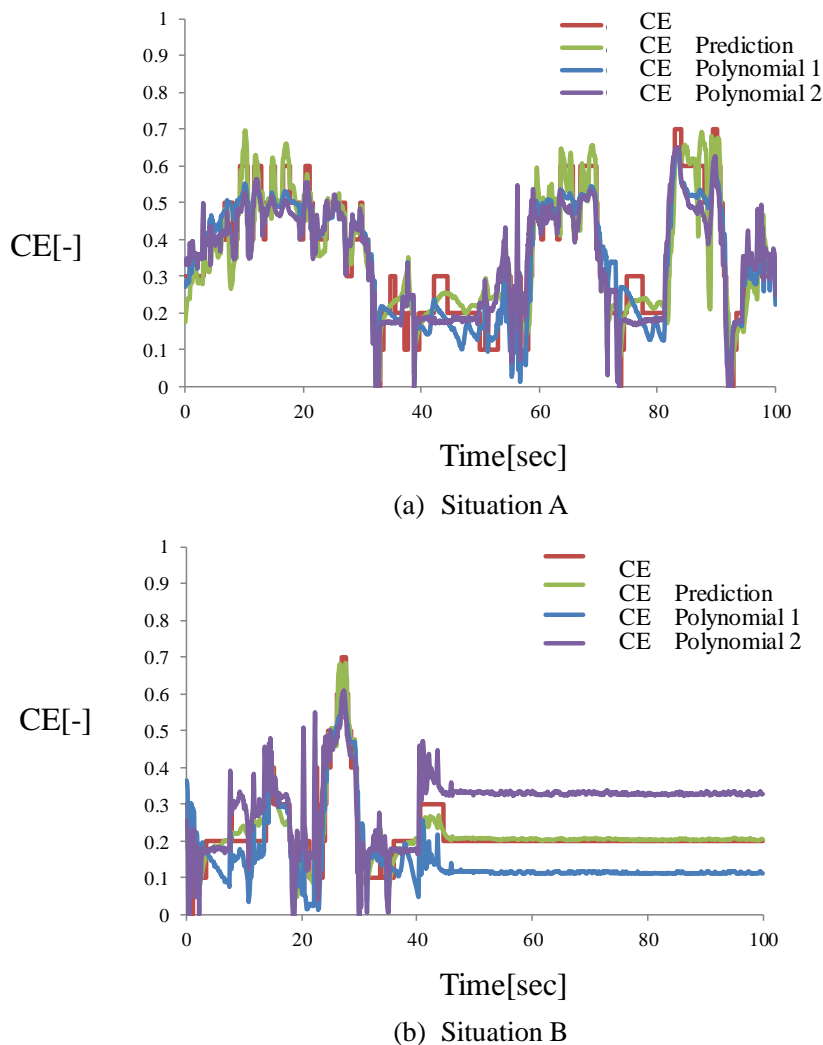


Fig. 2.1 Compare with statistical way

Fig.2.1(a)のSituation Aは上下変動が激しい場面での多項式回帰とGP回帰の比較をした。Situation Bでは激しい車両の動きから静かなエンジン停止に向けての動きの場面で比較をした。使用した多項式Polynomial 1は、いずれもアルゴリズムを Gauss-Newton法の利用とし、最大反復:200回、許容限界：0.00001とし Minitab16を使用している。

また、同図(b)のPolynomial 2では関数をNernstの式とし2つのパラメータで推定したが共線性の影響が強く本手法は採用し辛い。以上2手法との比較を行ったが、エンジン特有の上下振動をよく表してはいるものの推定精度がGPに比べると確実とは言えないことから多項式回帰ではなくGPを採用するに至った。それぞれの条件を下記Table.2.1に示す。

Table 2.1 Specification of polynomial function

---

計算条件：多項式1

パラメータ 値 (下記のパラメータを選択し、推定式を求めた)

$\theta 1$	3
$\theta 2$	650
$\theta 3$	30
$\theta 4$	0.03

推定式

$$CE = 'tps(\%)' \times 'ne(rpm)' / (15353 - 1004.9 \times 'tps(\%)' + 2.14926 \times 'tps(\%)' \times 'ne(rpm)' - 9.52014 \times 'tps(\%)' \times avta)$$


---

計算条件：多項式2

パラメータ 値 (下記のパラメータを選択し、推定式を求めた)

$\theta 1$	3
$\theta 2$	650
$\theta 3$	2

推定式

$$CE = 1.56589 + 0.246443 \times (\ln('tps(\%)' + 1.57921) - \ln('ne(rpm)'))$$

GPの回帰とは、入力値の  $\mathbf{X}^*$  が与えられる時、それに対応する推定値  $\mathbf{y}$  を求めることである。GPの利点は最適なモデルのパラメータにより、各データを表現する曲線(カーネル関数)を使ってモデル化ができる事である。推測する統計モデル  $\mathbf{y}_t$  はカーネル関数で回帰させる。カーネル関数を用いて (2.3 式) 表現する。これは共分散の関数と表現される。

しかし一方で、回帰が入力データによりオーバーフィッティングすることが問題として挙げられる場合もある。オーバーフィッティングとは、過剰に反応しすぎてモデル化が正確にできないことを指す。この問題を回避するため GPの回帰分析では、実システムから計測された実験データを用いて推測したい予測パラメータと関連するパラメータの関係を回帰曲線として求めることが提案されている。入力データ値によって何通りかの多項式を描けるが、入力データは後述する最尤法を用いて1つのカーネル関数を使って表現される<sup>[25,26,27,28,29]</sup>。

ここで  $n$  組の訓練データを考えると、以下のように入力と出力の 2 通りが考えられる。

$$\mathbf{X}^* = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_n] \dots\dots\dots (2.1)$$

$$\mathbf{y} = [y_1, y_2, y_3, \dots, y_n]^T \dots\dots\dots (2.2)$$

$$f|\mathbf{x} \sim N(f|0, k(\mathbf{x}, \mathbf{x})) \dots\dots\dots (2.3)$$

このとき、観測ノイズは  $\sigma^2$  とする。観測ノイズをカーネル表現した式を(2.4)とした。

$$\mathbf{y}|f, \mathbf{x} \sim N(f(\mathbf{x}), \sigma_n^2) \dots\dots\dots (2.4)$$

予測分布は下記の(2.5)式と表せる。但し(2.6)や(2.7)式は予測分布を出す分散・平均の式である。またカーネル関数は(2.8)式と表現できる事から、行列  $\mathbf{X}$  が与えられるとカーネル関数は(2.9)式と表現できる。

$$\mathbf{y}_*|\mathbf{x}_*, \mathbf{X}, \mathbf{y} \sim N(\boldsymbol{\mu}_*, \boldsymbol{\sigma}_*^2) \dots\dots\dots (2.5)$$

$$\boldsymbol{\mu}_* = k(\mathbf{x}_*, \mathbf{X}) \cdot (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y} \dots\dots\dots (2.6)$$

$$\sigma_*^2 = k(\mathbf{x}_*, \mathbf{x}_*) - k(\mathbf{x}_*, \mathbf{X}) \cdot (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} k(\mathbf{X}, \mathbf{x}_*) \dots \dots \dots (2.7)$$

但し

$\sigma_*^2$  : 分散      $\mu_*$  : 平均

とする.

推定値は  $f(\mathbf{x})$  であり今回は(2.8)式を使用した. 下記の(2.9)(2.10)式は一般式で表示した<sup>[29]</sup>.

$$f(\mathbf{x}) = \sum_{r=1}^m \{a_r \cos(2\pi \mathbf{s}_r^T \mathbf{x}) + b_r \sin(2\pi \mathbf{s}_r^T \mathbf{x})\} \dots \dots (2.8)$$

但し

$\mathbf{s}_r$  :  $\mathbf{x}$  の係数ベクトル      $m$  : 基底関数の個数

とする.

$$\mathbf{K} = k(\mathbf{x}, \mathbf{x}) \dots \dots \dots (2.9)$$

$$\begin{aligned} k(\mathbf{x}^*, \mathbf{X}) &= [k(\mathbf{x}^*, \mathbf{x}_1), \dots, k(\mathbf{x}^*, \mathbf{x}_N)] \\ &= k(\mathbf{X}, \mathbf{x}^*)^T \end{aligned} \dots \dots \dots (2.10)$$

本研究では過渡現象の推定精度を上げるためにカーネル関数を(2.8)式の Trigonometric 関数とした. (2.11)式は一般式で表現した場合である.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \frac{\sigma_0^2}{m} \sum_{r=1}^m \cos(2\pi \mathbf{s}_r^T (\mathbf{x}_i - \mathbf{x}_j)) \dots \dots (2.11)$$

下記, 補足をするとデータに見合うカーネル関数は設計者が選択する. 取得するデータの回帰が非線形であり, かつデータ数を削減し計算する目的で(2.9)式を使用することもある. (2.11)式の小文字  $i, j$  については  $i, j = 1, \dots, n$  を意味している. GP 回帰では条件付き分布は平均と共分散を持つので, これらを計算する. またモデルを作成する訓練データの予測分布の分散を計算する場合は,  $k$  の変数, 平均の場合は  $(\mathbf{K} + \sigma_n^2 \mathbf{I})$  を(2.6)式で表現し, その変数を用いてそれぞれ計算を行っている. 一般的には, データフィットとモデルの複雑さにはトレードオフの関係があり両立することはできない. 以上の計算をもとにして, 周辺尤度 (marginal likelihood) を最大化することで「データフィット」対「モデルの複雑さ」のバランスがとれた最適モデルパラメータ(ハイパーパラメータとも呼ぶ)から推定式を求めている. これが GP 内部のアルゴリズムのプロセスである.

## 2.2 本研究で使用している時系列データの取り込みおよびガウス

### 回帰の構成

エンジンの実データは、正弦波や余弦波の複合体かつ周期的でない波形が含まれることが多い。また時系列挙動を扱う過渡状態の再現には高い計算負荷とメモリ要求が必要である。そのため訓練データのサンプル数  $n$  個を基底関数の数  $m$  個よりも多くとっている。  $n > m$  の場合、演算負荷  $nm^2$ 、メモリ要求を  $m^2$  まで低減できるため基底関数は Trigonometric Basis Function を用いた。

GP は入力信号から、それぞれ過去のデータとして読み込み時系列データを取り込んで計算する。モデルパラメータは最尤法で求める。このパラメータは、推定にどれだけカーネル関数が寄与しているかを示す。

システム構造には、Nonlinear Auto-Regressive with eXogenous inputs (NARX) モデルを用いている。過去の推定値も GP の入力信号として扱うモデルである。例えば入力データ 1 個手前の情報が入る場合は 1 ステップ先の推定値となる方法で、エンジンの各状態量が過去の状態影響を受けることを考慮している。実際のエンジンは各アクチュエータの動作遅れや測定値が目標値を超えるオーバーシュートが存在する。これらの挙動を正確に表現するため、NARX 構想とし過去のデータもモデルへの信号として使用した。Fig.2.2 ではこの時系列データの取り込みについて説明している。ここでは対象を非線形モデルと仮定した時に、考慮すべき最大の遅れであるラグ(Max lag)をデータの特性的確認をして決定する目安としている<sup>[29,30]</sup>。

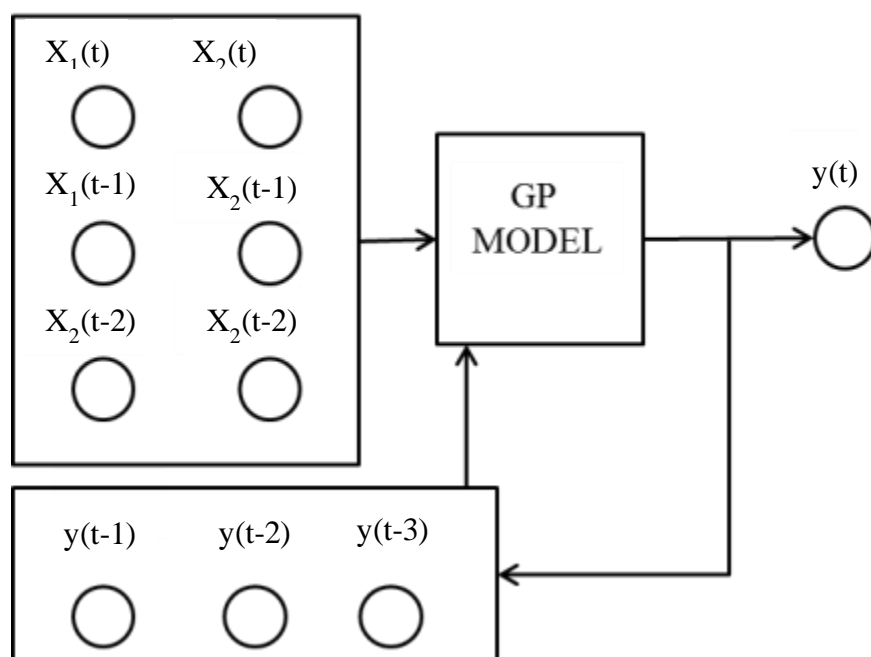


Fig. 2.2 Configuration diagram : Import of time-series data to Gaussian Process

$x$ ,  $y$  のそれぞれに入力信号 : 2チャンネル, Max time lag Inputs = 2, Max time lag Outputs= 3 の場合を示している. 本解析の際は Max time lag Inputs = 10, Max time lag Outputs= 10 と設定した. データの特性の確認としてむだ時間や時定数などの応答性を明らかにするために利用されている場合が多い.

エンジンモデルの統計モデル化にあたって注意したのは, 空気の通り道すべてのセンサ値からモデル化しない点である. 初期検討で全部の因子をモデルに反映させたところ, 残差が大きく出過ぎてモデル化が不可能であった. その次に行ったのは相関係数の大小であった. ところが統計的な視点でエンジンのモデル化をしてもエンジニアの知見が得にくいことが多く, 深堀の必要があった. 最終的な結論としては, 本研究の説明変数の選択は知見と相関係数の合わせこみとで行っている.

統計モデリングの目的変数については直接計測が困難な値をとり, センサーなどで計測が安易である値を説明変数としている. 例えば, 本研究の充填効率は直接の計測が不可能である.

今回検証に使用した充填効率の検証用真値は、筒外の空気量センサの値から吸気系の物理方程式と定常運転時における筒内吸気量の実験データに基づいたテーブルを組み合わせた値を用いた。本研究で使用した計算ソフトウェアは ASCMO である。すべての計算を Ver.4.10 SP1 で行った。

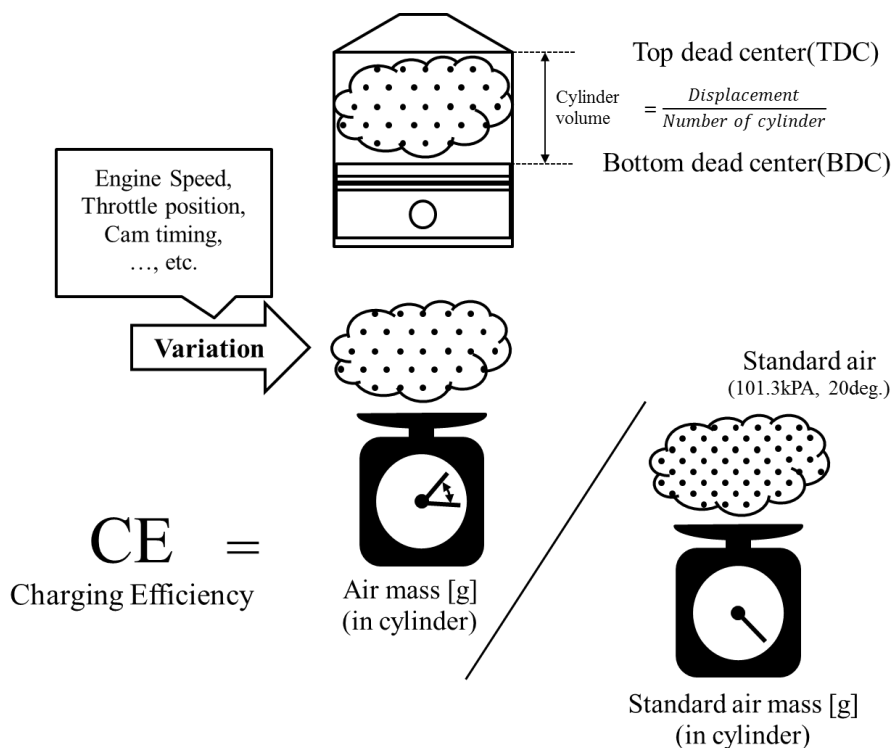


Fig. 2.3 Definition of charging efficiency

Fig.2.3 に示すように充填効率は、筒内に流入した空気の質量を行程容積 (1.298L / 4 気筒 = 0.325L) を占める標準空気(20°C, 1atm)の質量で正規化した値である。

## 2.3 実験装置および試験車両データ

試験車両データは、排気量 1.3L、4 気筒の可変バルブタイミング機構を備える直噴ガソリンエンジンから取得した。エンジンの吸気システムの概要を Fig.2.4 に示す。




Fig. 2.4 Engine system diagram

エアダクトから吸気された空気は、スロットルバルブを通じてサージタンク内に流入する。サージタンク内の空気は、クランクの回転に同期して開閉する吸気バルブを通じてシリンダ内に流入する。それに伴い、シリンダ内に流入した空気はシリンダ内に直接噴射される燃料と混合して火花点火により燃焼する。燃焼後のガスは同じくクランク回転に同期して開閉する排気バルブを通じて排気管に排出され、排気ガスの浄化装置などを通過して大気に出る。

統計モデルは筒内吸入空気量推定(以降、筒内吸気量と記す)モデルとした。従来や現行の方法での出力は、充填効率というパラメータで表される。この充填効率は一般に直接計測する事が難しく、推定量が用いられる。この推定は物理方程式や近似物理方程式により行われる。具体的には、吸気系のダイナミクスを表現した物理モデルに AFS やクランク角センサを用いて計算されるエンジン回転数などの多くのセンサからの信号により構成されるマップを用いて計算され、各自動車メーカーが工夫を凝らしている<sup>[1,2,3]</sup>。



本研究で使用したエンジンの仕様は Table 2.2 および 2.3 に記す. 統計モデルの作成には, 充填効率をモデルの出力(目的変数)として, エンジン回転数やスロットル開度, カムタイミングを入力(説明変数)としたモデルを対象とした.

Table 2.2 Specification of the 4-cylinder gasoline engine (For section 3)

---

Displaced volume	1.3L
Bore	89mm
Stroke	100mm
Compression Ratio	13.0
Ignition under	1-3-4-2

Table 2.3 Specification of the 4-cylinder gasoline engine (For section 4)

---

Displaced volume	1.997L
Bore	83.5mm
Stroke	91.2mm
Compression Ratio	13.0
Ignition under	1-3-4-2

## 第3章 試験車両データを使用した検証

### 3.1 はじめに

現在のエンジンの開発では、気筒内の空気の量を把握することが要だと前章で述べた。この吸入空気モデルとしては、内燃機関を物理方程式に見立てて計算していることが多い。しかし物理方程式を元にした解析モデルの管理・更新は、車型や型式により多大な時間を要する。そのため統計モデルを導入したいと考えている<sup>[19,20,21,22,28]</sup>。

本章では車両の試験車両データを用いて、統計モデルを作成する。無負荷領域や走行領域において空気量推定モデルが成立するか検証する。3.2節では、様々な時間長のデータの活用策として分割法の提案や検証を行う。3.3節では検定数を増やした推定評価を実施する。

### 3.2 分割法の提案および有効性検証

本節では取得したデータがエンジンテストベンチであったり、試験車両から取得したデータを用いて行うことと仮定した。限られた環境や工数で測定時間や記録装置の容量の関係で、両者のデータの長さはそれぞれ一致しない。そのため統計モデルに対する前処理がモデリングに有効だという報告に着想を得て、データの分割をして学習させた<sup>[31,32,33,34,35]</sup>。第2章で説明した説明変数および目的変数のデータを Fig.3.1 に示す。また、その際に使用した変数名を Table3.1 に示した。

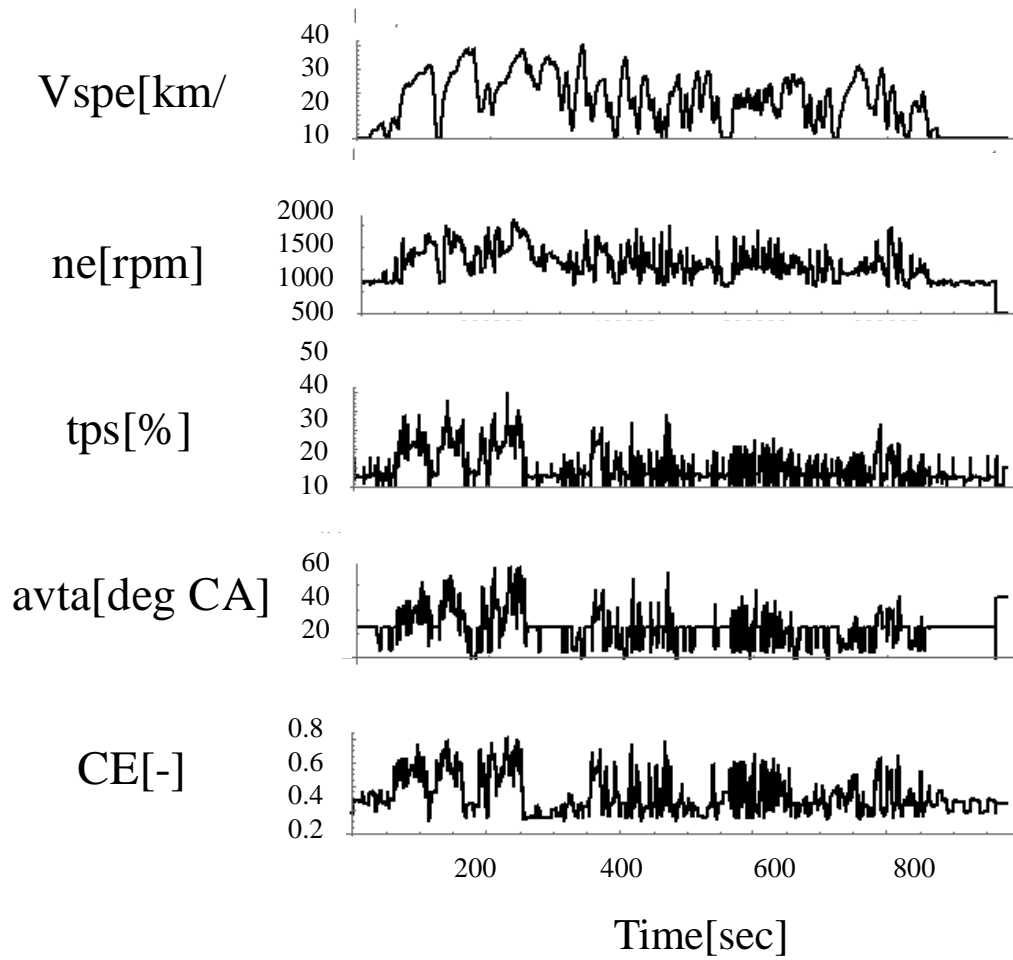


Fig. 3.1 Vehicle data for GP

Table 3.1 The name of preprocessing parameter

Parameter	Name [unit]
Vspe	Vehicle Speed [km/h]
ne	Engine Speed [rpm]
tps	Throttle Position [%]
avta (avta_ex)	Cam Timing of Intake Valve (Cam Timing of Exhaust Valve) [deg. of Crank Angle (deg.CA)]
CE,ce	Charging Efficiency [-]

分割方法は Fig.3.2 の Case1 と Case2 である。Case1 はモデルを一定長で取り込む従来法である。また同図 Case2 に、本研究で提案する訓練データの取り込み方法を示す。この方法では部分的に取り込んでデータを結合させた。詳細を下記に述べる。

従来の訓練データの構成法を Fig.3.2 の Case1 に示す。また提案する訓練データの構成法を同図 Case2 に示す。Case1, 2 に学習させる訓練データの長さが、同じになるように調整した。Case1 はある一定時間の時系列データを切り取り訓練データとする。残りの領域の時系列データを検証用データとした。Case2 は全長が 1000 秒のデータであれば、全体を 10 分割して 100 秒ずつに分断したデータを一つ飛ばしで結合、半分の 500 秒を訓練用データ、残りを検証用データとした。

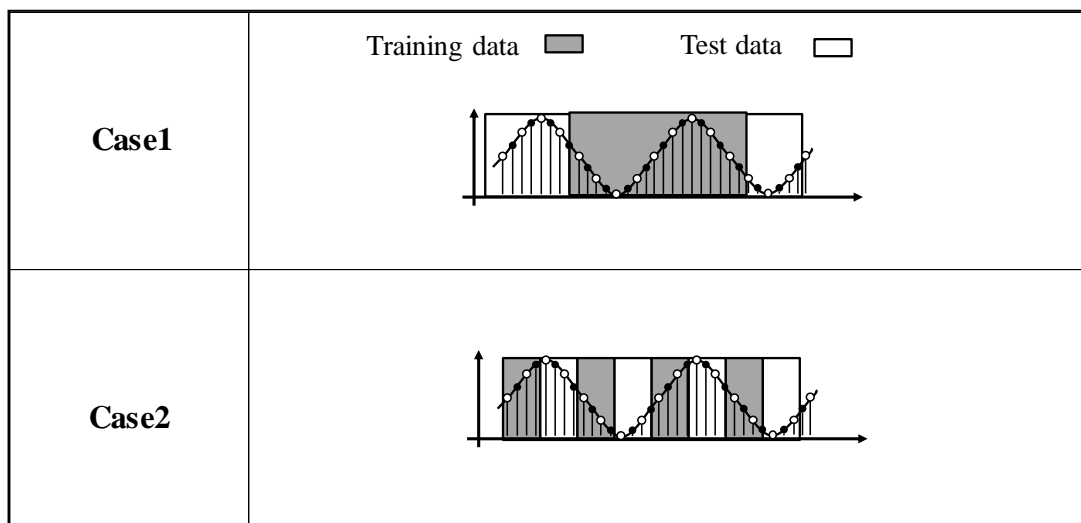


Fig. 3.2 The way of data separation

ここでの Case1 は従来方法の取り込み方法であることから、Case2 と比較する対象とした<sup>[34,36]</sup>。時間的に不連続であるデータの学習法を行った Case2 について、Case1 との推定精度の差がなければ分断したデータを結合した Case2 の方法の有効性が確認できる。Table 3.2 に GP での計算条件を示す。

Table 3.2 The parameter of GP calculation's parameter setting

Name	Parameter Setting
Kernel as subset size	50
Number of Iteration	100
Minimum Time Lag Inputs / Outputs	0,1
Max Time Lag Inputs / Outputs	[10,10]

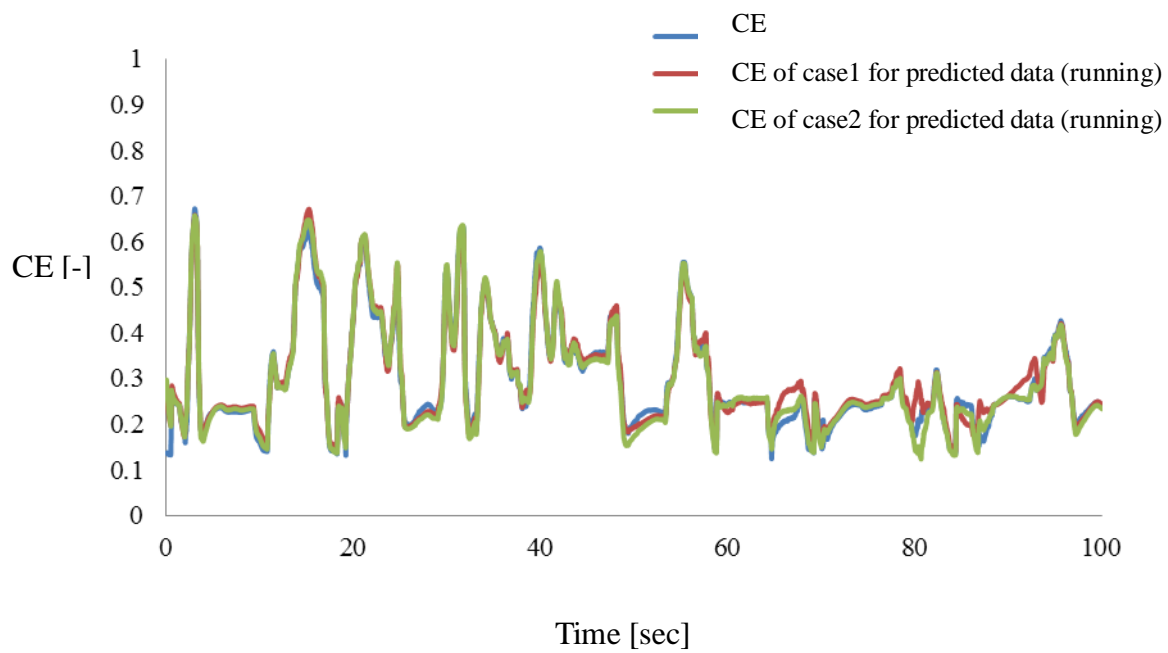


Fig. 3.3 Comparison of prediction for vehicle running behavior

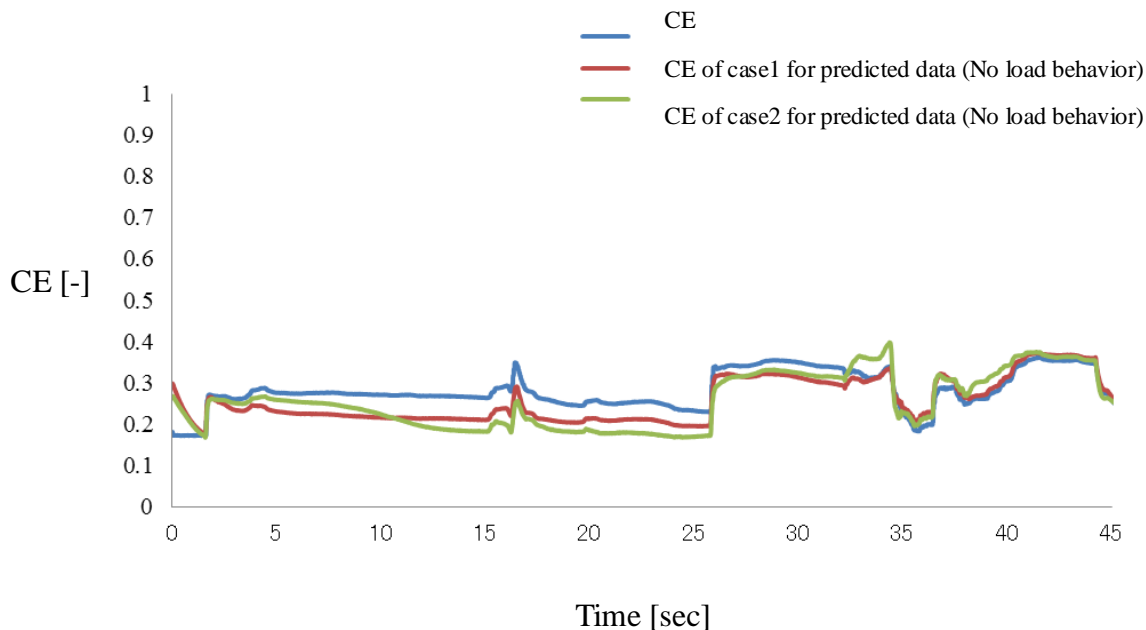


Fig. 3.4 Comparison of prediction for vehicle no-load behavior

データは車速 0 となる「無負荷状態」と、車速が 0 以上になる「走行状態」の 2 つの車両データに分類した。論文中では定義として、「定常領域」とは試験車両データ中の一定区間を特定した幅以上に上下変動しない箇所を指す。また、「過渡領域」は上下変動する箇所と定義する。この時、無負荷領域と走行領域のいずれにも定常・過渡の 2 つの領域が存在する。

Fig.3.3 に走行領域の推定結果 CE を示す。検証用真値(真値もしくは True Value と示す) を精度よく再現している。また、Case1 の従来法と Case2 提案方法の差異は小さい。この結果から新規手法の妥当性を示唆できる。更に、Fig.3.4 には無負荷領域の推定結果を示す。データには 0~25 秒間に定常領域が含まれている。

この領域では、若干の真値と推定値にかい離があることを確認できる。また全体的に確認できるのは、データのばらつきが大きい過渡領域に比べてばらつきがあまりないことである。対象の領域には今回の GP の統計モデルが有効に機能しない特徴を持っているデータが含まれているのではないかと考えられる。次節では、検定数を増やした検証を行っていく。

### 3.3 検定数を増やした試験車両データの評価について

本節では検定数を増やした場合に，統計モデルの精度がどのように変化するかを検証した．検証データは市内走行のデータの中からランダムに抽出したものをを用いており，同仕様かつ同一車両で異なる時期に取得したデータとした．検定数は 10 である．

モデルの誤差を評価するための相対的な指標に  $R^2$  を(3.1) 式として用いており，全部の測定データの平均値に対する分散とモデルに対する分散の比を示す [36,37,38]．

$R^2$

Coefficient of Determination

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{i,predictive} - y_{i,true})^2}{\sum_{i=1}^n (y_{i,measure} - \bar{y}_{i,true})^2} \dots\dots\dots(3.1)$$

$y_{i,predictive}$  : 推定値,  $y_{i,true}$  : 真値

$\bar{y}_{i,true}$  : 真値の平均

$n$  : 測定データの数

これまでの先行研究では統計モデルの精度は  $R^2$  の指標が主であった．本報告ではこれに加え，相対誤差，標準偏差の考えに近い RMSE の考えを追加する．誤差に関しては下記のように考えた．

誤差の定義とは一般的に，絶対誤差＝推定値－真値である．この推定値と真値との差を絶対誤差や相対誤差という．本検討ではエンジン特有の時系列データの解析で(3.2) 式で示す相対誤差を使用することとした．採用理由は，エンジン解析において時系列データを使用することが多く，A/F(空燃比，Air/ fuel ratio)を指標とするためである．推定精度の目安は  $14.7 \pm 1.5 (\pm 10\%)$  の範囲内に収まることが推奨され，燃費や排気ガス成分の改善など燃焼性能を制御するために用いられている [13]．

※A/F 炭化水素などの燃料を空気で燃焼させた熱を利用する熱機関類における燃焼の際に、空気質量を燃料質量で割った無次元量である。A/F（エアバイエフ）や AFR とも示される。

相対誤差の式は

$$\text{相対誤差} = (\text{推定値} - \text{真値}) / (\text{真値}) \times 100 [\%] \cdots \cdots (3.2)$$

を使用する。

RMSE (Root Mean Square Error)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{i,predictive} - y_{i,true})^2}{n}} \cdots \cdots (3.3)$$

Table3.3 では  $R^2$ 、RMSE を、最悪値(Worst value) と積算値(Integration value) について示している。最悪値と積算値を併せて示す理由とは、エンジンの瞬間値による判断基準に則っているためである。その理由は、制御システムのモデリングをする際に主なサブシステムに電子スロットル制御系がモデルとなると考えた。そこで、自動車の走る機能に必要なエンジン出力を制御することに着目した。制御の際には目標値に対して制御器として PID 制御、制御対象として(ここでは電子スロットル) からフィードバックを返して制御量を決めていると仮定した。制御装置の軽量化が可能となるのは最悪値がなるべく低く、積算値もハードの容量を考慮すると少ないことが好ましい。

無負荷領域は no-load behavior, 走行領域は running behavior とした。前節の 3.2 で説明した手法と同様に Case1 と Case2 の手法で検証している。連続的なデータ活用が Case 1 であり、対して断片的に切断したデータ活用が Case 2 である。比較のため、両者の学習する時間はともに同等にした。また両者の手法に同じ効果があることも確認する。



Table 3.3 Comparison of CE in prediction and original data  
 {Result of Coefficient of Determination (N=10)}

DATA_NO	The way of training data	behavior	R2	RMSE	Worst value[%]	Integration value[% s]
1015	Case1	no-load	0.97	0.01	9.82	54.57
		Running	0.99	0.02	42.28	164.30
	Case2	no-load	0.00	0.02	16.44	469.59
		Running	0.97	0.03	80.50	2085.15
1037	Case1	no-load	0.83	0.02	70.30	1480.15
		Running	0.98	0.03	45.56	150.91
	Case2	no-load	0.92	0.01	48.92	439.55
		Running	0.99	0.02	56.12	105.22
1307	Case1	no-load	0.33	0.02	74.47	1101.49
		Running	0.96	0.02	82.40	1206.29
	Case2	no-load	0.83	0.01	13.38	210.98
		Running	0.32	0.12	110.70	836.14
1335	Case1	no-load	0.44	0.04	39.93	3649.23
		Running	0.98	0.01	43.82	812.38
	Case2	no-load	0.88	0.01	42.43	405.46
		Running	0.81	0.06	46.03	158.12
1355	Case1	no-load	0.98	0.01	30.19	239.83
		Running	0.96	0.11	23.65	1121.08
	Case2	no-load	0.77	0.06	59.63	689.26
		Running	1.00	0.05	98.52	84.95
1435	Case1	no-load	0.00	0.21	160.11	8040.52
		Running	0.00	18.70	301477.91	109762.56
	Case2	no-load	0.00	0.14	24.41	4838.92
		Running	0.95	0.03	35.67	751.27
1500	Case1	no-load	0.73	0.04	100.91	128.11
		Running	0.99	0.02	21.66	60.89
	Case2	no-load	0.87	0.02	21.37	39.88
		Running	0.98	0.02	39.92	32.60
1530	Case1	no-load	0.65	0.00	2.75	8.67
		Running	0.97	0.02	118.60	597.64
	Case2	no-load	0.82	0.03	33.93	207.96
		Running	0.96	0.02	95.72	625.80
1605	Case1	no-load	0.95	0.00	6.80	25.31
		Running	0.97	0.03	13.50	801.58
	Case2	no-load	0.05	0.01	34.05	143.21
		Running	0.92	0.00	16.90	18.47
1650	Case1	no-load	0.57	0.03	67.05	756.06
		Running	0.63	0.09	132.26	7704.52
	Case2	no-load	0.70	0.04	63.02	186.01
		Running	0.97	0.06	67.24	497.58

Table 3.3 を検証する。Table 3.3 の DATA\_NO は 1000[sec] 程度から成る前後のデータラベル名を意味する。The way of Training data は Case1, Case2 のデータの取り込み方法を指す。無負荷領域と走行領域の区分けをし、それぞれの  $R^2$ , RMSE, 最悪値および積算値を求めた。各検証で取り出したデータラベル No.は無作為抽出とする。


検定数 10 の検証をした結果から、Case1, 2 の両方の手法で訓練データ取り込み法により統計モデル全体の平均値は、Case1 における無負荷領域は  $R^2$  が 0.64, 走行領域は 0.84。また、Case2 はそれぞれ 0.58, 0.89 であった。以上から Case1 と Case2 の  $R^2$  に差異はないと考えられるので提案手法の妥当値が示された。さらに、無負荷領域の定常領域では統計推定モデルそのものが成り立たないことが判明した(Table 3.3 における 1435 の事例)。訓練データの  $R^2=0$  に近い値を示す大きな理由は領域に定常領域を多く含んでいる事が考えられる。

加えて Case2 の有効性についても確認すると、限られたデータで所望の推定精度を満足するモデルを構築する方法として一定の時間間隔ごとに分割して 1 つ飛ばし毎に結合する本方法は有効であった。ただ、切り出したデータがエンジンの作動場面ごとに異なることも推測できる。目的変数の CE が変動している場合は Case1, Case2 とともに  $R^2$  が高く得られていた。しかし CE の変動がないと、説明変数であるカムタイミングなどの学習が特定の場面だけになる傾向が強いの Case2 の可能性が高い。そのため検定数が 10 の中で Case2 の統計モデル精度が Case1 より悪い場合も生じてしまうことが考えられる。

$R^2$  は 1, RMSE は 0 に近いほどに統計モデルの推定精度が高いと言われる。DATA\_NO が Table 3.3 における 1500 において  $R^2 = 0.98$ , 最悪値 = 39.92 であった。同じく 1530 (Table 3.3) は  $R^2 = 0.96$ , 最悪値 = 95.72 となっている。ほぼ同じ  $R^2$  であっても最悪値にかい離がみられる。さらに 1605 (Table 3.3) では、 $R^2 = 0.92$  の時に最悪値 = 16.90, 1650 (Table 3.3) では  $R^2 = 0.97$ , 最悪値 = 67.24 である。以上 2 例のデータからも  $R^2$  が高ければ最悪値が低くなるという傾向は見えない。また、統計モデルの指標と相対誤差である物理的な精度とが必ずしも一致していないことを示している。以上から、相対誤差や相対誤差により求めた最悪値・積算を指標に使う優先的に議論する。

### 3.4 散布図による検証

Table3.3 では数値的に確認を行ったが，目的変数と相対誤差との関係性についても散布図で確認する．縦軸に相対誤差の絶対値，横軸に CE とした．入力データ(訓練データ) から統計モデルを作成しデータの分散を見ることによって，事前に検証できるかを検討した<sup>[36,37,38]</sup>．



(a)1530 ; case1 with no-load-behavior

Fig. 3.5 Subplot of prediction error and CE in dataset 1530

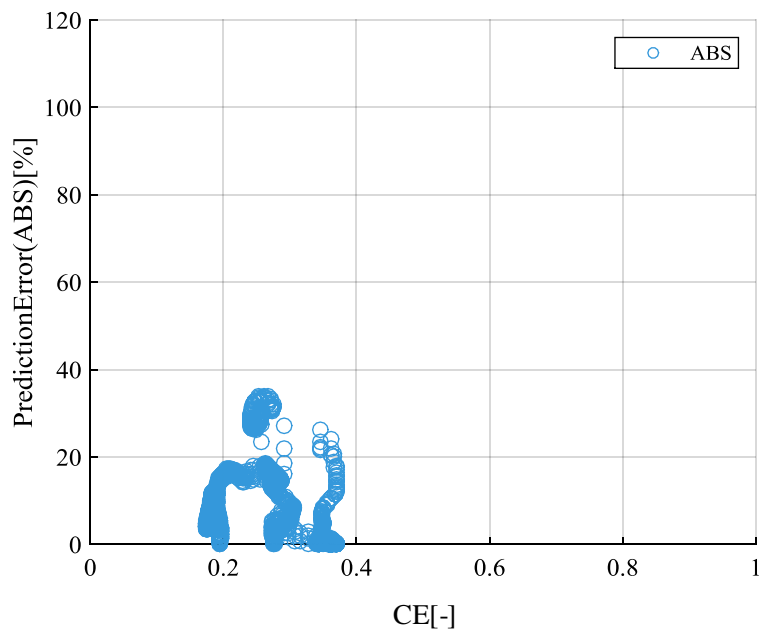

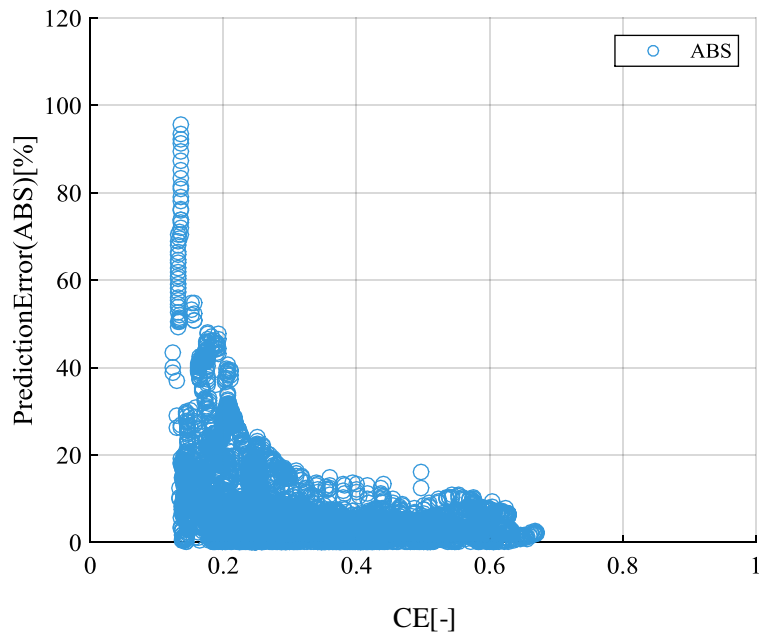


Fig. 3.5 Subplot of prediction error and CE in dataset 1530 (Cont.)




(d)1530; case2 with running behavior


Fig. 3.5 Subplot of prediction error and CE in dataset 1530 (Cont.)

$R^2$ は、1に近ければ統計モデルの精度が高いことを示す。Fig.3.5では1530データラベルの分布を確認している。Table3.3(a)は無負荷領域の $R^2$ は、0.65とやや低いながらも最悪値は2.75に収まっていた。(b)においては $R^2$ は、0.97と高いが最悪値は118.6である。データ点数が違うことも原因と考えられるが、 $R^2$ は物理的な判断基準とは必ずしも言えないことを示す。

このような背景にはCEの値が0.1~0.2付近であるとスロットルポジションの特性を考慮する必要がある。CEが0.2以下では精度が下がる傾向がある一方で、CEは0.2以上になると判定精度が高くなる。0.4~0.6以降の相対誤差を検証すると平均値±10%の領域に収まっていることがわかった。実用上CEの感度が確保される領域はこの範囲になるのではないかと推測する。

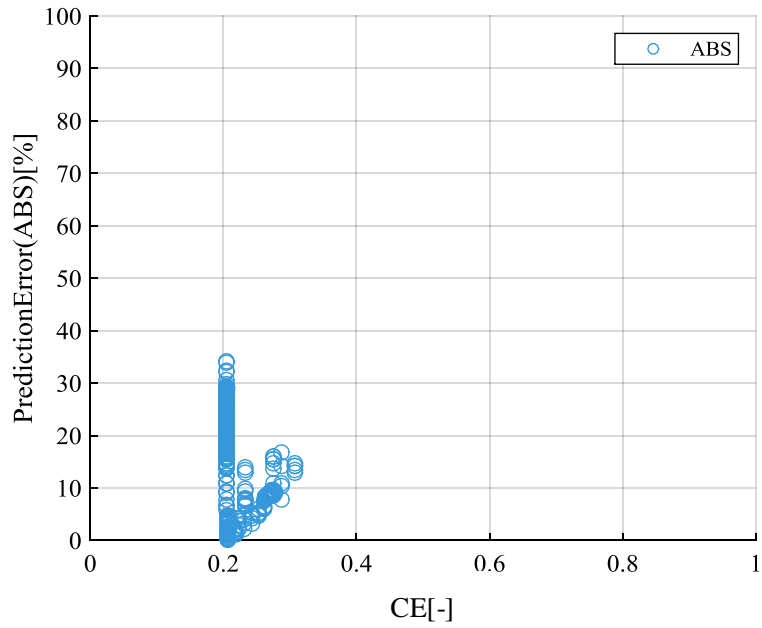


(a) 1605; case1 no-load-behavior




(b) 1605 ; case1 running behavior

Fig. 3.6 Subplot of prediction error and CE in dataset 1605




(c) 1605; case2 no-load behavior ( $R^2$  low)




(d) 1605 ; case2 running behavior ( $R^2$  low)

Fig. 3.6 Subplot of prediction error and CE in dataset 1605 (Cont.)



(e) 1605 with case2 no-load behavior ( $R^2$  high)



(f) 1605 ; case2 running behavior ( $R^2$  high)


Fig. 3.6 Subplot of prediction error and CE in dataset 1605 (Cont.)



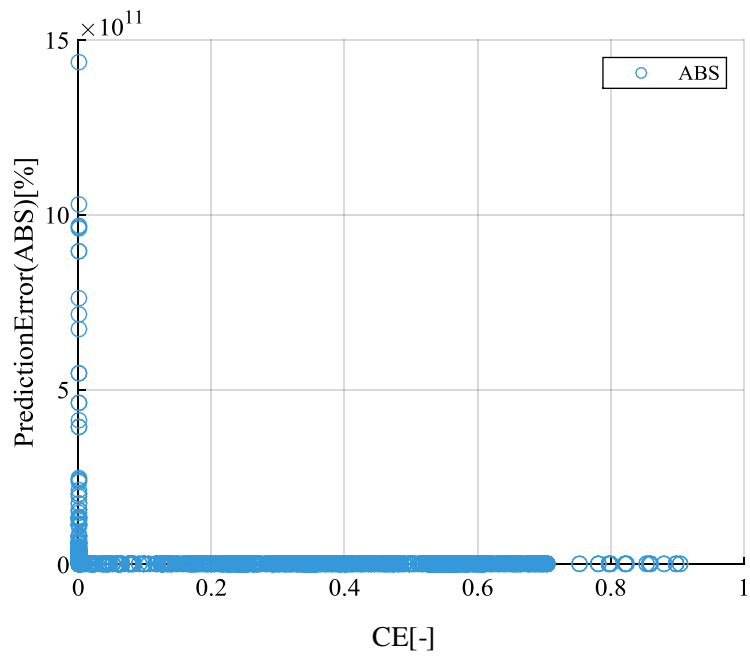
つぎに 1605 のデータラベルについて分散図を確認する。Fig.3.6 (c), (d) および(e), (f)のように  $R^2$  の高低とデータの分散が関わっていることが確認できたケースである。データ数が多いことがモデルの精度を高めることは当たり前だとも考えられるが、統計モデルの指標である  $R^2$  が(c), (d) の場合はデータ数自体が多くなかった。

統計モデルの精度は時として最悪値だけでは判断できず、 $R^2$  の大きさも必要なことを示している具体例である。前述の 1530 のデータラベルでは、 $R^2$  は物理的な判断基準とは必ずしも言えないと述べた。本データは 10 パターン中では(e), (f) のパターンが  $R^2$  と最悪値、積算値それぞれが比例している。入力データ側で閾値やフィルタを設ける事により、最悪値だけでは判断せず  $R^2$  の統計指標なども必要なことを示す可能性がある。

最期に Table.3.3 の中で本検証データ中、統計モデルの  $R^2$  値はゼロが多く最悪値も異常値を示している 1435 のデータラベルについて Fig.3.7 にて確認する。




(a) 1435; case1 with no-load behavior




(b) 1435 ; case1 with running behavior

Fig. 3.7 Subplot of prediction error and CE in dataset 1435



(c) 1435; case2 with no-load behavior




(d) 1435; case2 with running behavior


Fig. 3.7 Subplot of prediction error and CE in dataset 1435 (Cont.)

Fig.3.7の結果を確認すると、エンジンの気筒内のCEの状態を考慮すれば検証データに対して相対誤差が極端に大きいものが含まれている。CEが0の部分に点在している相対誤差の絶対値はメカニズム上外れ値にあたる値だと考える。なぜならば気筒内の上死点と下死点にあたる部位の値がこれに相当し、ここには通常の気筒内の空気の量を図るCEではない値が含まれているのではないかと考えているからである。そのため「通常の気筒内の空気の量を図るCEではない値」と考える外れ値のデータを省いて散布図としたものをFig.3.8とした。これは1435のデータラベルFig.3.7(b)および(c)を拡大したものである。

このFig.3.8(a)ではCEが0.2~0.7を中心に密集しているが上部に散布する特異な点の散布が確認できた。また同図(b)では、特徴ある形状をしており一部は密集しておらず点在していた。これらの密集地帯は、いずれも $R^2$ が高く出ているデータラベルとは異なる分布であった。推測理由としては、精度にのつとる適切なセンサ信号が入手できず、結果としてCEの推定値が異常な値を示してしまう例にあたるのではないかと推測している。つまり十分な統計モデル作成に必要なデータが欠落し、統計的指標である $R^2$ が低下しモデルとして満たない値が出てしまったのではないかと考える。以上の知見を事前に入力するデータから取り除く方法の一つとして、LPFの考え方やダウンサンプリングで事前に除去できるかを次節以降で検討していく<sup>[39,40,41]</sup>。



(a) Focus of 1435; case1 with running behavior



(b) Focus of 1435 ; case2 with no-load behavior

Fig. 3.8 Focus of Subplot of prediction error and CE in dataset 1435

### 3.5 統計モデルの推定精度と有効性検証

本節ではエンジンの吸気モデルにおいて、LPF による推定精度への影響検証する。エンジンの吸気系に送り込まれた空気は、スロットルバルブや吸気をバルブの開放タイミングで複雑に変化し、筒内までの動特性を正確に把握することは難しい<sup>[38]</sup>。しかし、これまでの知見により吸気系の動特性を 1 次遅れ特性に近似することが可能であることがわかっている<sup>[39,40,41]</sup>。推定結果のずれを解決するためには 1 次遅れの考え方を取り入れる必要があると考えた。3.5.1 節ではデータの分割周期を変化させた効果を検討した。続いて 3.5.2 節では FFT を用いた周波数領域の解析を行った。また、3.5.3 節では LPF を用いた検討とその効果の確認を行った。3.5.4 節ではダウンサンプリングを変化させた効果を検討した。

#### 3.5.1 データの分割周期の変更を行った検討

入力データの取り込み時に、分割周期の変更を伴う場合の最悪値および積算値の確認を行った。定常や過渡、車速の有り無しなどを区別せずに混合して GP で推定精度を予備検討した。

Case2 の手法である入力データ 30[sec]であれば、30[sec]ずつに切断して 1 つ抜きで結合させた。Table.3.4 に示した分割周期として 10・20・30・60・80・100[sec]ごとに訓練データを学習させた。検証データに基づき、推定精度を求めた。この時、サンプリング周期はいずれも 0.01[sec]とした。

Table 3.4 Comparison of prediction for separation time in dataset  
(Sampling: 0.01sec, Max Time Lag=2)


Separation time[sec]	10	20	30	60	80	100
Worst Value [%]	62.6	51.5	40.8	54.4	78.8	81.4
Integration Value [% s]	180.7	72.7	296.0	532.2	523.0	687.4

結果は 10・20・30[sec] ごとに分割すると一旦最悪値は低下したが、分割周期が 60・80・100[sec] と増加すると誤差の最悪値も増加する傾向がみられた。


ダウンサンプリングは LPF のような低域通過特性を持つことが知られている。しかし実際の LPF では遮断周波数を定め、周波数ごとの特性を踏まえた構成になっている。積算値は最悪値と比例せず、20[sec]時に 72.73[% s] と低減効果が見られたが 30[sec] 以降増加していった。以上からデータの分割周期は分割する時間ごとに変化が見られ、分割周期そのものが誤差に与える影響を与えると考えられる。分割周期は本データラベルに対して、30[sec] と刻んだ場合が最も最悪値の誤差を低く抑える可能性があった。ただし本検討ではある一定の長さのデータである 100[sec]を採用し、4章で改めて同検討するため今回は予備検証とした。

### 3.5.2 Max Time Lag の設定比較

次に入力データの統計モデル学習時に、Max Time Lag = 0, 2 (3 次)と Max Time Lag=10 (11 次)を設定、場面である SCENE 1 と 2 を設定して比較した。




(a) Max Time Lag = 0 SCENE-1




(b) Max Time Lag = 0 SCENE-2

Fig. 3.9 Comparison of prediction for Max Time Lag






(c) Max Time Lag = 2 SCENE-1




(d) Max Time Lag = 2 SCENE-2

Fig 3.9 Comparison of prediction for Max Time Lag (Cont.)



(e) Max Time Lag = 10 SCENE-1



(f) Max Time Lag = 10 SCENE-2

Fig 3.9 Comparison of prediction for Max Time Lag (Cont.)

Fig.3.9 の各(a)(c)(e) SCENE-1 では加速時の場面の検証ができた. Max Time Lag=2 時は推定しているが振動的であり, ギブス現象が確認できた. 元の信号に対して不連続点近傍で見られる”ひげが生える”現象である. 無理に近似した結果, このような結果が生じていると考えている. また同図の各(b)(d)(f) SCENE-2 においていずれの条件の Max Time Lag でも, 車速がゼロの領域で著しく推定精度が下がっていることが確認できる. さらに次元を変化させて学習させた場合は, 加速時において推定精度は低速や過渡領域のいずれにおいても安定して精度を高く維持できているのが 3 次と 11 次の設定であった. このとき Fig.3.10 で IACF(Inverse Autocorrelation Function)と呼ばれる逆自己相関関数でエンジン開発に使用される計測データを使用してコレログラムをプロットし指数関数的に減衰する係数を確認した<sup>[30]</sup>. コレログラムとは Fig.3.10 に示す逆自己相関のグラフの事で元のデータと時間をずらしたデータとの相関係数を示したものである. 元データからずらした量を横軸にとり, 計算した相関関数を縦軸にとっている. このコレログラムをみると, データが周期性を持つかを調べる事が可能となる.

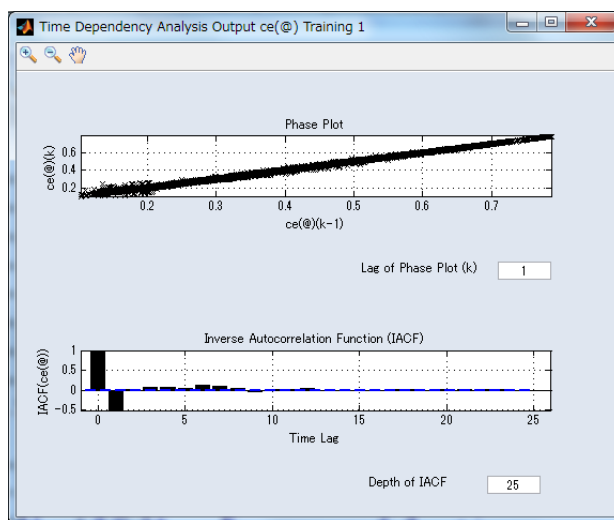


Fig. 3.10 Result of Inverse Autocorrelation Function



予備検証では学習する過去データをどの程度読み込むかの指標であり, 事前にこの値を調べ Input/Output 値を決めてきた. 指数関数的に収束する最終値を推奨値とし, ここでは 10 と読める. ただ, 結果 Fig.3.10 が示すように Lag は 2 と考えた. そのため, 本節の検証ではこの IACF を指標とした. 今後は, データに対して何通りかの Input/Output 値を確認してから推定精度を確認していくことが必要だと言える.

### 3.5.3 FFTを用いた周波数領域の解析



本節では一般的なエンジンのエンジニアが不要と考えている高周波領域を LPF で遮断した場合、推定精度をさらに高めていくのではないかと考える。各説明因子の持つ周波数領域において、遮断周波数はパワースペクトル $-3\text{dB}$ の縦軸から、各データを FFT 解析して読み取りながら決定した(MATLAB の関数 FFT)。徐々に高周波成分を除去して検証した。その結果、遮断周波数を高く設定したほうが統計モデルの精度は  $R^2$  を指標にすると向上していった。基本的には、周波数設計においてシステムを知るためには入力と出力のある周波数に対する振幅比と位相遅れの情報が必要である。目的変数や説明変数を FFT を行い波形を見ている。今回は各説明変数がどのような周波数成分を持つのかを FFT で確認し、段階を経て遮断周波数を設定していく検証を行った<sup>[38]</sup>。

カムタイミングの排気側では周波数スペクトラムは  $4[\text{Hz}] \sim 50[\text{Hz}]$  を示していた。他の説明変数はカムタイミングの入力側では  $0.9[\text{Hz}] \sim 4[\text{Hz}]$ 、スロットルポジションは  $0.7[\text{Hz}] \sim 2.9[\text{Hz}]$ 。そしてエンジン回転数は  $0.6[\text{Hz}] \sim 4[\text{Hz}]$  を示していた。そこで遮断周波数の特定を最初に行い、3 変数にそれぞれに共通の周波数から排気側の周波数スペクトラム値を考慮し LPF を決めていった。

続いて FFT 解析した場合でもエンジンのデータはノイズが多く含まれるため、ウェルチのパワースペクトル密度推定(MATLAB の関数 pwelch) を用いて振幅特性を確認した<sup>[42]</sup>。本関数では、ウェルチのオーバーラップ セグメント平均推定器を使用して検出された入力信号  $X$  のパワースペクトル密度 (PSD) 推定を求めることができる。この関数はスペクトルを平均化して潜在するピークとなる周波数を探す関数の役目を持つので、信号を区分化してその区分ごとにフーリエ変換を行って結果を平均化する。たとえば白色雑音のようなノイズを含む信号についても区分ごとの結果を平均化するため、ノイズ成分を除去し主要な信号を得やすい。フィルタリングにはハミング ウィンドウを適用した。1500 及び 1530 のデータラベルに PSD 処理を実施し、得た結果を Fig.3.11 および Fig.3.12 に示す。FFT 解析だけで読み取ることができなかった特徴あるパルスなどを読み取ることができる。次節以降は PSD 処理値を参考にした遮断周波数をもつ LPF 処理と、推定精度の比較対象としてダウンサンプリングをかけて検証していく<sup>[43,44,45,46,47,48]</sup>。



Software used for operation: MATLAB 2016b  
 With Hamming window, Sampling Time: 0.01sec  
 Fig. 3.11 Amplitude characteristic of explanatory variable



Software used for operation: MATLAB 2016b  
 With Hamming window, Sampling Time: 0.1sec

Fig. 3.12 Amplitude characteristic of explanatory variable

PSD 処理を実施した結果の考察を行う。Fig.3.11 に示す(b)の 1530 における周波数 200[Hz] 以降で、高周波ノイズの帯域が確認されている。スロットル開度の因子では、周波数 16[Hz]以降からパワー／周波数値が緩やかに落ちていく。排気側のカムタイミングの因子は 30～50[Hz]間に特徴のあるパルスやノイズと読み取ることができる帯域があるのを確認した。

サンプリング周期を拡大し、分布を検証した Fig.3.12 にはサンプリング 0.1[sec] 時の PSD の計算結果を合わせて示す。ここでは Fig.3.11 ほど顕著なスペクトルがえられず、ノイズに埋もれてしまう。0.1 以降の数値のサンプリングでは、さらにノイズが多くなり Fig.3.11 のような顕著なスペクトルを得ることが出来ないため、以降の LPF の検証は 0.1 まで範囲としてを検証していくこととした。

### 3.5.4 LPF を適用した統計モデルの推定精度と有効性検証

本節では PSD 処理した遮断周波数以降の周波数を押さえて制御などの設計値に利用することを念頭に置き LPF を用いてノイズを低減化させた場合の検証とした。目的変数及び説明変数を LPF で処理し、それらの値を訓練データとして学習させた事例について報告する。エンジンの実データは FFT をかけると多岐の周波数成分を含んでいたため、LPF 処理を施し計測ノイズを減らす解析を実施する。Fig.3.13 には LPF をかけた際と元のオリジナルデータの比較、Table3.5 には検証に用いたパラメータの詳細を示す。過去のデータを 3 次（現在+過去 2 つ: Max Time Lag Inputs / Outputs=[2,2]）にした。その理由は IACF という時系列データの検定の一種で予測検証を行うと最も推定精度が高いのは 3 次であったためである。




Fig. 3.13 Detail of Low Pass Filter Data Plotting



Table 3.5 Table of GP Simulation Parameters

Name	Parameter Setting
Kernel as subset size	50
Number of Iteration	100
Minimum Time Lag Inputs / Outputs	0, 1
Max Time Lag Inputs / Outputs	[2, 2]

Fig.3.14 は遮断周波数を変化させた LPF 適用の結果を示す。遮断周波数を変化させて 10・16・20・30・40[Hz] の適用とした。使用した式は下記(3.4)～(3.13)式である。高周波領域をあまり含まない定常領域の推定精度を向上させるためには、LPF が有効であるのではと考えた。これはエンジンの吸気系の物理的な構造上で一次遅れが含まれるためである。そこで下記に述べた一次遅れのローパスフィルタの式を使用した。

$$K = 1 - \frac{1}{1 + \tau / \text{sampling\_rate}} \dots\dots\dots (3.4)$$

$$f_i = \frac{1}{2\pi\tau} \dots\dots\dots (3.5)$$

但し

K : フィルタ係数

$\tau$  : 時定数

$f_i$  : 遮断周波数

としている。この式から

$$K = 1 - \frac{1}{1 + \tau / \text{samp}} \dots\dots\dots (3.6)$$

$$K(1 + \tau / \text{samp}) = (1 + \tau / \text{samp}) - 1 \dots\dots\dots (3.7)$$

$$K(1 + \tau / \text{samp}) = \frac{\tau}{\text{samp}} \dots\dots\dots (3.8)$$

$$K + K(\tau / \text{samp}) = \frac{\tau}{\text{samp}} \dots\dots\dots (3.9)$$

$$K \cdot \text{samp} + K\tau = \tau \dots\dots\dots (3.10)$$

$$\tau(1 - K) = K \cdot \text{samp} \dots\dots\dots (3.11)$$

$$\tau = \frac{K \cdot \text{samp}}{(1 - K)} \dots\dots\dots (3.12)$$


これを

$f_i = \frac{1}{2\pi\tau}$  の式へ代入すると下記のように展開できる

$$f_i = \frac{1}{2\pi} \cdot \frac{1 - K}{K \cdot \text{samp}} \dots\dots\dots (3.13)$$

この(3.13)式に 0.01 秒ごとに取得したデータを代入するとフィルタ係数  $K=0.5$  のとき、遮断周波数  $f_i$  は  $15.91=16[\text{Hz}]$  となる。

本計算方法で遮断周波数を設定した。Fig.3.14 の結果では、大きく 2 か所、推定結果と真値が異なる箇所がある。着目する箇所としては 7~10[sec]、もう一つは 70~80[sec] の領域である。遮断周波数を変化させた場合の LPF 効果検証であり、周波数 20[Hz]、30[Hz] の時の検証結果でのずれが出ている。ここでは検証用真値の CE は、LPF 未処理の値を使用し比較している。次に LPF 効果の推定精度と有効性を確認する。



LPF condition: W/O windowing

Cutoff frequency with 10, 16, 20, 30,40Hz

Fig. 3.14 Comparison of prediction for LPF effect

(By Case2, Data: 1530, Sampling time:100sec)

Table 3.6 Comparison prediction error with difference in LPF's cutoff frequency  
(in dataset 1530)

LPF[Hz]	40	30	20	16	10	Original
Worst Value [%]	86.5	120.6	73.7	93.7	102.2	81.4
Integration Value [% s]	634.3	1394.2	669.4	694.3	902.4	653.4

Table.3.6 の結果では、LPF ごとの誤差確認で、一番軽微な最悪値を示したのは目標値 20[Hz] の LPF の時であった。また誤差の積算値は LPF の値に比例せず、平均して 650[% s] 前後となっていた。本節での検討では 30[Hz] 時には、積算値が 1400[% s] 近くまで上がっている。その結果、同じ検定数の遮断周波数違いで比較しても大きな値のばらつきが見られる。ここでは LPF の遮断周波数を選択することで最悪値および積算値が変化することは確認できた。この事象が示唆するのは、入力するデータ側で前処理にも制御条件づけなどを行う必要性を示唆している。そこで、次節でサンプリング率の変更を検証する。

### 3.5.5 サンプリング周期の変化についての検討

本節では、サンプリング周期の変化をエンジンデータに適応させることにより統計モデルの推定向上を狙う。サンプリング周期の変化とはダウンサンプリングともいい、サンプリング時間の幅を大きくとりサンプリングレートを低下させる処理である。本検証でも、0.01[sec] からダウンサンプリング率を下げていくと 0.1[sec] からは、ノイズ成分は抽出されなかった。そのためダウンサンプリング 0.1 まで原因が吸気の特徴であると特定できたのでノイズが重畳しないダウンサンプリング 0.1[sec] までを閾値として設定する。

ダウンサンプリングは LPF のようなローパス特性を持つことが知られている。しかし実際の LPF では遮断周波数を定め、周波数ごとの特性を踏まえた構成になっている。前節での LPF の検証データ結果を確認すると 20[Hz] 時に 73.7% であり小さい相対誤差の値ではない。厳密に言えば本データはデジタル処理で取り込むため離散時間による時系列データとなっている<sup>[44,45]</sup>。ダウンサンプリング時間の変更に伴いどのような挙動をするかについて、詳細な検討を次章で行う。確認のためアナログで取得した連続時間システムについて考えてみる。この連続データをサンプリングする場合の周期は、下記のサンプリング定理により決定される。

#### 【サンプリング定理】

或る信号が  $f_N=1/(2T)$  より大きな周波数成分を含んでいないときは、任意の時刻におけるその信号値はサンプリング周期を  $T$  としたときのサンプル値より完全に再現できる。この  $f_N$  をナイキスト周波数という。

この元となる信号がナイキスト周波数よりも高い周波数成分を持つときは、このサンプリング周期  $T$  でサンプリングするとエイリアシングと呼ばれる情報損失を生じる<sup>[44]</sup>。

実データで本研究のように空気充填量を入力データから推定する場合、入出力信号がその変数の持つ周波数よりも高い周波数成分を含んでいないとは言いきれない。今後の予定として、解析するデータがどのような周波数成分を持っているかを把握しフィルタとして設計の際に考慮していく。

Table 3.7 Comparison of prediction for sampling effect  
(Separation time: 100sec, Max Time Lag=2)

(a) Data 1530

Down sampling rate [s]	Worst Value [%]	Integration Value [% s]
0.01	81.4	653.4
0.02	74.1	589.3
0.04	95.7	1102.9
0.06	123.0	181.1
0.08	79.8	818.5
0.1	75.4	597.3
0.2	93.3	825.4
0.4	73.4	882.3
0.6	119.8	1541.4

(b) Data 1015

Down sampling rate [s]	Worst Value [%]	Integration Value [% s]
0.01	42.7	985.4
0.02	60.4	901.3
0.04	56.0	724.7
0.06	48.7	617.6
0.08	48.9	686.3
0.1	209.1	226.3
0.2	30.6	654.4
0.4	60.8	694.8
0.6	37.8	634.4


Table 3.7 Comparison of prediction for sampling effect(Cont.)

(Separation time: 100sec, Max Time Lag=2)


(c) Data 1605

Down sampling rate [s]	Worst Value [%]	Integration Value [% s]
0.01	110.4	887.6
0.02	99.3	706.8
0.04	79.4	58.6
0.06	243.1	790.7
0.08	76.7	596.3
0.1	82.1	809.7
0.2	95.0	752.3
0.4	105.4	1110.2
0.6	151.0	1796.3

Table 3.7 には任意抽出の 3 つの時系列データのサンプリング周期を変化させた数値を示す。また Fig.3.13 では、0.02 から 0.6 まで、サンプリング周期の幅を変化させ比較を行った。Fig.3.14 は 1605 データラベルを時系列データで示したものである。



(a) The effect comparison worst value of original and down-sampling [%]



(b) The effect comparison-integration on value of original and down-sampling [% s]

Fig. 3.15 Comparison of prediction for sampling effect  
(Data\_No:1530, 1015, 1605 Separation time: 100sec, Max Time Lag=2)





Fig. 3.16 Comparison of prediction for sampling effect in dataset 1605








Fig 3.16 Comparison of prediction for sampling effect in dataset1605 (Cont.)



(e) Sampling : 0.4sec

Fig. 3.16 Comparison of prediction for sampling effect in Dataset1605 (Cont.)

以上の結果を基にダウンサンプリングを考察する。これはエンジンデータの推定を行うに当たり、さらに推定精度を高める方法だと考えて実施した<sup>[47,48,49]</sup>。その理由は下記である。

原データのサンプリング周波数は 0.01[sec]であり、目的変数 CE について推定値と検証データの比較をおこなった。この結果が(a)であり、推定値は 40 秒前後までは非常に良く推定していることがわかる。しかし 40[sec]を超えた後から 100[sec]まで急激に精度が鈍くなる。そこで更なるダウンサンプリングを続けると、同じ作業をすると後半の 40[sec]を超えた後から 100[sec]まで急激に精度が高くなる。

これは文献[44]によるとダウンサンプリングおよびデシメーション（間引き）とも呼ばれ、ダウンサンプリング前の信号を  $x[n]$ 、ダウンサンプリング後の信号を  $y_D[m]$  とすると入出力信号の関係は下記(3.14)式にて示すことができる<sup>[44]</sup>。

$$y_D[m] = x[Mm] \dots \dots \dots (3.14)$$

但し

M: ダウンサンプリング比(デシメーション比)

ここでの  $M$  は信号を間引く比率であり、信号を間引くことで時系列データの持つ周波数スペクトル成分が変化する。つまり一部の信号列がゼロ値に置き換わりイメージングの従来は生じていない空間にデータが生じることがある。

ダウンサンプリングでレートが低下すると、隣に接するスペクトル同志が近づく。また前節での検討(入力信号  $X$  のパワースペクトル密度 (PSD))にもみられるように、 $M$  が大きくなるとエイリアジングが起きる傾向もみられる。(3.15) (3.16) 式のように表現できる。

$x[n]$  の周波数スペクトルを  $X[\Omega]$  とすると  $x_1[n]$  のスペクトルは  $X_1[\Omega]$

$$X_1(\Omega) = \frac{1}{M} \sum_{k=0}^{M-1} X\left(\Omega + \frac{2\pi k}{M}\right) \dots\dots\dots(3.15)$$

と表せる。

$$Y_D(\Omega') = X_1\left(\frac{\Omega'}{M}\right) = \frac{1}{M} \sum_{k=0}^{M-1} X\left(\frac{\Omega' + 2\pi k}{M}\right) \dots\dots\dots(3.16)$$

但し

$\Omega$  : 入力信号の各周波数軸     $\Omega'$  : 出力信号の各周波数軸

これらには

$$\Omega' = \left(\frac{1}{M}\right)\Omega$$

の関係がある。

(3.16)式で表現されるようにダウンサンプリングの過程に関する時間領域の信号  $x[n]$  について間隔  $M$  ごとにサンプル値を選ぶと(3.17)式のように表現することができる。 $M=2$  の場合は

$$x_1[n] = \begin{cases} x[n] & n = 0, \pm M, \pm 2M \\ 0 & \text{Otherwise} \end{cases} \dots\dots\dots(3.17)$$

となる。

信号  $x_1[n]$  を  $\frac{1}{M}$  倍である原データが 0.01[sec]なら 0.4[sec]になるとき、 $M=40$  のサンプリングレートとなる。この時レートを変更したダウンサンプリング信号である、 $y_D[m]$  処理をして GP を用いて統計モデルに置き換えた。

説明変数の振幅特性確認をする。ダウンサンプリングを 0.1[sec]で確保した場合、サンプリングレートが低下したので隣接するスペクトルが近づく。そのため定常と過渡の誤差の差異が少なくなる。これは信号処理のダウンサンプリングの考え方に基づく<sup>[45,46]</sup>。

Table3.6 のデータラベル 1015 では、最悪値が 0.1[sec] 時の解析を除きおおむね効果が出ている。データラベル 1530 では、0.02, 0.08, 0.1, 0.4[sec] で推定精度が上がっているのが確認できる。データラベル 1605 において、どのダウンサンプリングにおいてもノイズ低減効果を確認できた。もっとも低いのは 0.04[sec] であった。

つぎに積算値について確認をする。次に 1015 でも全体的に積算値は低くなっている。もっとも低いのは 0.1[sec] 時であった。1530 の結果では特に 0.06[sec] にノイズ低減効果を確認できた。

1605 のデータラベルである時系列データ (Fig.3.16) の (a) と (d) の比較をするとオリジナル値 (0.01[sec]) と 0.1[sec] とを比べると 40[sec]~50[sec] の領域では  $CE = 0.2$  に比べて絶対誤差では 0.02 程度の低減になっている。さらに同図の (b) や (c) では 40[sec]~50[sec] の領域では  $CE = 0.2$  に比べて絶対誤差では 0.02 よりやや大きい差が生まれ、(e) では (a) ほどではないが  $\pm 0.05$  の誤差が確認できた。

推定値と真値の時系列データおよび絶対誤差 (Fig.3.16 に緑で記載) を示したように最悪値や積算値以外にも、時系列データを目視にて確認する報告が先行研究では多くなされている。オリジナル値の (a) に比較するとダウンサンプリングが小数点 2 ケタの際には推定値と真値の差はほとんどない。しかし Fig.3.16 (e) の 0.4[sec] 時など、ダウンサンプリングは (3.16) 式よりサンプリング幅が広くなるほど推定精度が低くなっていく傾向にある。

しかし、指標として用いるには先にあげた最悪値や積算値の判断の方が明確な場合もある。今後の精度を上げる際の確認作業に目視は参考にしながら、数値で判断することとする。以上の結果から、対象のデータラベルの時系列データだけで判断せず、データ長に適したダウンサンプリングの値を選択する必要がある。またその場合でも、サンプリング周期が細かい値の方が推定精度は高まる傾向にあった。

## 3.6 小括

3 章前半の 3.3.2 節での検討は統計モデルのこれまでの評価方法に加え相対誤差を用いた評価であった。検証の結果、相対誤差は統計指標と比例していないが物理的な判断基準として使う事は可能であった。

1. エンジンのセンサで取得したデータには、少なからずノイズ成分が含まれると考えた<sup>[47,48]</sup>。そこでダウンサンプリングを行い、高周波成分の除去を試みた。但し推定精度の低減効果は見られたが、規則性がなかった。これは、統計モデルを構成する入力データへの依存性が強いことが示唆される。検証結果よりは、ダウンサンプリングや LPF だけで±10%の相対誤差の範囲内に推定精度を収めることが難しかった。また本章である程度の高周波成分の除去は行えたが推定精度の規則性はなかった。
2. ダウンサンプリング値の選択幅は比較的広い。しかし 0.1[sec] より大な値を選択してしまうと、推定精度が劣化する傾向があった。オリジナルデータのサンプリング幅の設定は、出来るだけ小さい値でデータを取得しておくでダウンサンプリング値の推定精度を上げられる種類が多くなる可能性が高まる。精度を上げて統計モデルを当てはめ推定しようとする時はハードの 1/10 よりも小さい値でダウンサンプリングをすると推定精度を高めることができる。
3. Table 3.3 における 1530 のデータ中で比較すると、ダウンサンプリングや LPF, データ分割周期を確認した。結果、分割周期の効果が一番大であった。元となるデータ長に対し今回の検討では 30[sec] が最も効果があった。これはデータの取り込み時に定常や過渡、車速の有り無しなどを区別せずに検討した結果であり汎用性は高くなる傾向が見られる。

## 第4章 WLTCモードを使用した検証と評価

### 4.1 はじめに

日本は欧州に比較すると加減速が多く速度域が低いといった特徴がある。従来の JC08(日本)・US6(米国)・NEDC(欧州)といった走行パターンでは、実際の路上では制限速度や道路環境の差異がある。そこで、同一の走行モードとして世界で統一された規定が Fig.4.1 に示す WLTC モードである。本章で使用する WLTC モードとは、低速・中速・高速の 3 モードがある実際の場面を想定した走行モードである。燃費規制を満たすために国連で規定している国際基準でもあり、国内が対応するモードは前者の 2 つである<sup>[3,13,49]</sup>。

本章では統計モデルに入力データとして使用する値を、オリジナルの 1 次元吸排気シミュレーションツールで求めた。実際の内燃機関を理想状態としてシミュレーションできる。それぞれ WLTC モードでの低速モードを中心に、統計モデルを作成した。但し、本章では行程容積を  $1.997\text{L} / 4 \text{気筒} = 0.499\text{L}$  としている。また、一番車両の走行で使われることの多い中速域をモデル対象とした。実際の車両を想定したシミュレーション値とエンジンの吹き返しを考慮した気筒内の理想状態のシミュレーション値を比較対象とした。なおエンジンの吹き返しとは、オーバーラップという吸排気バルブを同時に開く制御時に排気バルブの空気が吸気バルブへ逆流する現象である。エンジンから吸気系への逆流要素である吹き返し/吹き戻し/吹き通りについて、扱いとしては排気への流れと変わらずバルブが開いているときの吸気/筒内/排気の主に圧力バランスで決まる。例えば吸排気バルブが同時に開くオーバーラップ時には、軽負荷では排気から吸気へ流れる吹き通り現象が、全開領域では吸気の流れで筒内のガスが排気へ押し出される掃気現象が発生する。これらのような物理現象のことを示している。


4.3 節は LPF を適用した統計モデルの推定精度と有効性検証を行い、4.4 節はサンプリング周期の変化についての検討を行った。最後に 4.5 節で分割周期の変更を行った検討を実施した。いずれもエンジンの定常と過渡に分けて考えている。定常と考える領域の定義は少なくとも 2 秒以上にわたって上下振動がない、かつ目的変数が  $\pm 0.05$  以内の領域とした。過渡とは定常以外を指し上下振動が頻繁に起こる領域とする。過渡現象は主に「急に加速する 急に減速する」という作動状態に伴い説明変数や目的変数などが急峻に変化する状態と定義した。

具体的には加速・減速を数秒間の範囲で行う場合は過渡であり，10 秒程度継続の時には定常状態もしくは領域といえる。


## 4.2 推定を実施する条件の検討

本節では WLTC モードの走行データ(Fig.4.1) をもとにしている<sup>[48,49]</sup>。シミュレーションでは国内走行の場面で一番使用される速度域の中速モードを想定した。そのため WLTC モードの 600～1200[sec]までの範囲をシミュレーションにおける計算条件とした。そこで Case2 の手法である訓練データを 300[sec]の長さで結合させる。内訳は 700[sec]～800[sec]，900[sec]～1000[sec]，1100[sec]～1200[sec]である。一方 600[sec]～700[sec]，800[sec]～900[sec]，1000[sec]～1100[sec]である。現場ではデータ長にばらつきが生じることを想定して，それぞれ時系列データ群を各 100[sec]ごとに分割している。統計モデルに使用した説明変数は Fig.4.1 に示した。統計モデル作成の計算条件パラメータを Table 4.1 に示す。本節でのモデルは，目的変数は 1 気筒目の CE を使用した(3 章では 4 気筒分の平均値を使用している)。

今回は説明変数にアイドリングストップが入ると数値ゼロに落ちてしまう領域が多かったため，アイドリングストップが入らない条件で検証した。また，入力データには 1 次元吸排気シミュレーションの結果を使用した。それぞれエアダクトスロットルバルブ間にあるセンサ取得の流量瞬間値とバルブタイミングの IVC 時点(上死点)の筒内空気量から算出したものを使用した。この入力に詳細なシミュレーションの結果を利用することによって，さらに繊細なエンジンの挙動を学習させることができると考えた<sup>[39]</sup>。



(a) ne, tps



(b) avta, avta\_ex

Fig. 4.1 WLTC mode simulation data for GP of explanatory value



WLTC モード上では車両走行状態により、速度がゼロになりまた加速するシーンが何か所か発生する。また検証データの開始時には、統計モデルの精度が著しく低下することが多く見られた。最初の数秒間は相対誤差の結果は、100[%]を超える値が発生することもあった。ここでの 100[%] は必ずしも精度が高いという意味ではない。本研究で使用している相対誤差の数式は 0[%] ならば精度が高いという意味である。Table4.1 の条件で GP の計算を実施した。

Table 4.1 The parameter of GP calculation's parameter setting

Name	Parameter Setting
Kernel as subset size	50
Number of Iteration	100
Minimum Time Lag Inputs / Outputs	0,1
Max Time Lag Inputs / Outputs	[0,0]

### 4.3 データの分割周期の変更を行った検討

今回使用したデータ長は中速域の 600[sec]から 1200[sec]までとしているため合計 600 秒間のデータに対して半分の 300 秒を訓練データ，残りを検証データと割り当てた．訓練データに対して分割周期の変更を行い，検証データを入力し推定精度を最悪値および積算値の指標を用いて検証を行った．定常と過渡の領域に分けて分割周期を変更し，推定精度の向上を試みた．

3 章で提案した Case2 の訓練データの構成手法についてであるが，分割周期を 30[sec]であれば 30[sec] ごとに切断して 1つおきで結合している．その訓練データを用いて統計学モデルを作成し，真値と推定値の比較を行った．結果を Table4.2 に示した．WLTC モードの低速領域 600[sec]までを範囲とし，分割周期は 30・60・80・100 および 180[sec]ごとに分割して学習させている．サンプリング周期はいずれも 0.01[sec]とした．

Table 4.2 Comparison of prediction for separation time by width  
(Data sampling rate: 0.01sec, Separation time: 30/60/80/100/180sec,

Max Time Lag = 0

(a) Transient behavior

	Transient				
Separation time [sec]	30	60	80	100	180
Worst Value [%]	33.3	47.4	70.3	28.0	66.8
Integration Value [% s]	21.9	89.6	340.5	87.4	22.1

(b) Steady behavior

	Steady				
Separation time [sec]	30	60	80	100	180
Worst Value [%]	13.4	37.9	96.3	31.8	39.9
Integration Value [% s]	10.9	73.4	244.8	64.5	9.9

まず Table4.2 について考察する。データの分割数によって推定精度には差異があった。今回の検証条件である Max Time Lag = 0 とすると、過渡領域でデータに対して 100[sec] 刻みで行った場合に最も精度が高く得られた。定常領域では、30[sec] 時に軽減効果が最も高く続いて 100[sec] 時でも効果が得られた。

エンジンの相対誤差は瞬間値で判断することが多く、その瞬間で定常および過渡領域において±10%以内に収まることが望ましい。本検証で分割することで物理的に精度が上下することが判明したので、WLTC モードのようにエンジン回転数が変動する場合においても高い推定精度を確保できるのではないかと考えられる。以上の結果から過渡領域の推定精度を向上させるために分割数を 100[sec] として以降の検証を行った。

## 4.4 Max Time Lag の設定比較

本節では 3 章で使用した実車相当の ECU での結果および 4 章で使用している 1 次元吸排気シミュレーションツールの解析結果による統計モデルの推定精度を比較した。走行条件は WLTC モードとした。一番条件の厳しい走行場面を含んでいる低速状態の 0[sec]~600[sec]で Max Time Lag = 0, 2 (3 次)と Max Time Lag = 10 (11 次)を設定, 比較した。Fig.4.2 に IACF での指標の確認, Fig.4.3 に Max Time Lag 違いの結果を示した。

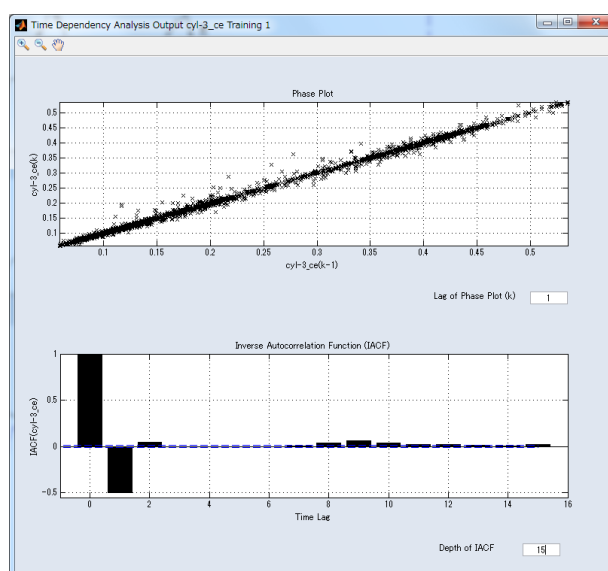





Fig. 4.2 Result of Inverse Autocorrelation Function for WLTC mode  
(Area: 0 to 600[sec])



(a) Max Time Lag = 0



(b) Max Time Lag = 2



(c)Max Time Lag = 10

Fig. 4.3 Comparison of prediction for Max Time Lag  
(Data sampling rate: 0.01[sec])

Fig.4.2 では 3.5.2 節と同様に逆自己相関関数の IACF を確認した。例えば、物理的な意味は Time Lag = 2 は「学習を過去の 3 次まで行う」という意味である。ここでは 3 次まで行うのが最も精度の高い統計モデルが作成できると読み取れる。また Fig.4.3 の検証で AT および MT 車の両方に於いて Max Time Lag = 0, 2, 10 におけるそれぞれの過去の学習値を選択すると、「ECU の CE」と「シミュレーション結果から推定する CE」と若干の時間差を生じながら推定していることがわかった。


この値は AT および MT 車において差異があり、Max Time Lag ごとに検証していくと Max Time Lag = 0 設定時は推定値に上下にひげが発生するギブス現象がみられる。さらに車速の Vspe = 0 以外の領域において AT 車および MT 車ともに推定精度が確保できている。その他の領域である過渡や定常において、MT 車ではギブス現象が確認できたが、CE 推定精度が高かった。

続いて Max Time Lag = 2 の時は, 55[sec]~60[sec] の領域で減速する場面で CE の推定値が 0.1 ほど低くなっている. 全般的な推定精度は Max Time Lag = 0 時と Vspe = 0 以外の領域以外では差異がほとんど見られなかった. 最後に Max Time Lag = 10 時は Vspe = 0 の条件では CE が 0.2~0.3 低い値を推定していた. AT 車での加速の場面は, 真値と推定値の差は生じていない. 減速時は Lag = 0,2 に比較すると 55[sec]~60[sec] の領域で誤差が確認できた. 70[sec] 付近ではシミュレーション結果から推定する CE は, 推定したい真値の CE 値まで上昇していなかった. Time Lag が大きくなるにつれて「ECU による CE 値」と「解析による CE 値」を比較すると推定開始から 18[sec]前後まで, IACF による相違が大きく差となって見られた. また 50[sec]から 60[sec]にかけての推定領域には差異の開きが出ていた. 一方 MT 車では加減速により推定精度が Time Lag が大きくなるにつれ差異が出ていた. 説明変数が条件によりゼロに落ちることがその大きな理由だと考えられる.

以上より 3 種類の Max Time Lag の中で精度劣化の最も少ない Max Time Lag = 0 を本章では採用する. また AT 車についてこの中で精度劣化の一番低い Max Time Lag = 0 について取り上げて検討を進める. ただし今後 IACF を基準とした統計モデルの作成には想定できることから, Max Time Lag が 0 および 2 (3 次) の場合の検討を本章後半で検討した.

## 4.5 LPF を適用した統計モデルの推定精度と有効性検証

本節では LPF による推定精度への影響を確認する。3.5.1 節で検討した各説明因子のもつ周波数領域を参考に遮断周波数を決定した。LPF を用いて説明変数と目的変数の両者に LPF を施した<sup>[50,51,52]</sup>。3.5.1 章と同様に窓関数は Hamming 窓を使用している。Fig.4.4 に示す説明変数の確認結果について確認したところ、20,30[Hz]周辺での挙動を確認できた。そのため LPF を用いる際の遮断周波数も  $10 \cdot 16 \cdot 20 \cdot 30 \cdot 40 \cdot 50$ [Hz]と設定している。解析条件を Table.4.3 に示す。



Software used for operation: MATLAB 2016b  
With Hamming window, Sampling Time: 0.01sec

Fig. 4.4 Amplitude characteristic of explanatory variable on WLTC;600-1200[sec]

Table 4.3 Table of GP Simulation Parameters

Name	Parameter Setting
Kernel as subset size	50
Number of Iteration	100
Minimum Time Lag Inputs / Outputs	0, 1
Max Time Lag Inputs / Outputs	[0,0]



### 最悪値と積算値による検証

各遮断周波数における LPF 適用時について Table4.4 の結果を検証する。推定値とオリジナル値との相対誤差を、オリジナル(LP F をかけていないデータ)と各周波数による結果と同一のデータ帯域で確認している。


Table 4.4 Comparison prediction error with difference in LPF's cutoff frequency  
(Separation time: 100sec, Max Time Lag = 0 )

#### (a) Transient behavior


Transient LPF[Hz]	50	40	30	20	16	10	Original
Worst Value[%]	24.8	24.8	24.9	25.5	24.9	30.9	28.0
Integration Value[% s]	119.3	119.0	119.7	118.5	124.0	146.6	87.4

#### (b) Steady behavior

Steady LPF[Hz]	50	40	30	20	16	10	Original
Worst Value[%]	37.5	42.6	42.4	40.2	23.7	54.9	31.8
Integration Value[% s]	52.9	58.9	58.9	55.8	28.7	120.7	64.5




(a) The effect comparison worst value of original and control [%]




(b) The effect comparison-integration value of original and control [% s]

Fig. 4.5 Comparison of prediction for LPF in transient behavior  
(Separation time: 100sec, Max Time Lag = 0)



(a) The effect comparison worst value of original and control [%]



(b) The effect comparison-integration value of original and control [% s]

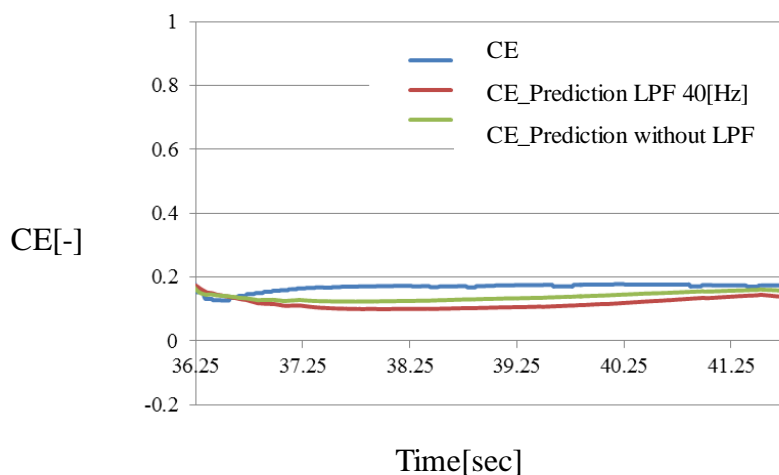
Fig. 4.6 Comparison of prediction for LPF in steady behavior  
(Separation time: 100sec, Max Time Lag = 0)

Fig.4.5 および Fig.4.6 では Max Time Lag = 0 の 1 次で過去のデータを学習させた場合, 全般的な傾向として過渡領域では 4[%] 程度の最悪値の低減効果が確認された. 定常領域ではオリジナル値と比較するといずれの LPF も悪化した, 16[Hz] 時には低減効果が得られた. 全般的に最悪値そのものは過去のデータを学習させた場合よりもいずれの周波数帯で悪化してしまうが, Max Time Lag = 0 とした場合は突発的に発生する極端に高い推定値を取り去ることができた.


予備検証では Max Time Lag = 2 としてそれぞれの数値を求めたが、時系列データの不連続面においてギブス現象が発生していた。以上の結果より、定常や過渡の領域における精度向上を確認する際のデータは IACF 検証で適合するようにした。最初は IACF 設定数値で統計モデルを作成し、推定精度が落ちる際には Max Time Lag = 0 として再確認することを推奨する。

続いて Max Time Lag = 2 とした場合の LPF の効果について Fig.4.7 に考察を試みた<sup>[44,45,46,47,48]</sup>。

考察① Time Lag = 2 とした場合の定常/過渡領域の精度の向上の度合い



(a) Steady behavior



(b) Transient behavior

Fig. 4.7 A Vehicle running data on WLTC

Fig.4.7(a)ではLPFなし推定CEが真値のCEより外れることが確認できた。LPFをかけた場合よりも0.05ほど定常領域は改善できなかったが、過渡領域に置いては効果があった。またFig.4.7(b)では18秒付近でLPFなし推定CEが実際のCEより±0.1ほど精度が下がっている。LPFを利用すると定常領域では真値に近い値に補正できていることがわかる。過渡領域においてLPFの効果を得た。

次に各領域の精度の向上の度合いについて、


(LPF:40Hz)－(CE:True Value)

を求めると時系列的にFig.4.8のデータが得られる。下記では先の定常や過渡の定義に則り、次のように切り分けを試みた。切り分け条件は以下の2つである。

- ・カムタイミングの説明変数が変化しない領域で著しく推定精度が下がる。
- ・説明変数が停止しているとCEの推定も停止する


定常：①36.25-41.72[sec] ②52.82-60[sec]

過渡：③14.48-31.99[sec]




(a) 100[sec] running data

Fig. 4.8 An AT Vehicle running data on WLTC



(b) Above: Steady area from 36.25[sec] to 41.72[sec]  
 Under: 52.82[sec] to 60[sec]



(c) Transient area from 14.48[sec] to 31.99 [sec]

Fig. 4.8 An AT Vehicle running data on WLTC(Cont.)

Fig.4.8(a)が対象としたデータの全長である。Fig.4.8(b)では、説明変数が定常と考える領域の定義は少なくとも 2 秒以上にわたって上下振動がない、目的変数が $\pm 0.05$  以内の領域とした。同図(c)で示すように、過渡とは定常以外を指し上下振動が頻繁に起こる領域とした。

さらにデータ全体を俯瞰すると青い線が  
 (LPF をかけていない CE 推定値) - (LPF:40Hz 処理後の CE 推定値)  
 を示している。この中で切り分けた定常値および過渡値の平均値は Table4.5 の結果から定量的にみると総合評価への影響は少なからず大きく、相対誤差の平均は過渡の区間では $\pm 5\%$ 以内に収まり定常の区間では $\pm 20\sim 30\%$ であるという結果が得られた。また定常および過渡領域の推定精度向上を確認できたが、過渡の場面では改善率が高かった。

Table 4.5 Average for Steady and transient behavior

	① Steady	② Steady	③ Transient
(Proposed CE without LPF) - (Proposed CE with LPF)	39.0	56.41	23.24
Average of relative error	-29.64	-22.15	-4.44

## 4.6 サンプルング周期の変化についての検討

統計モデルに取り込む際に、訓練データのサンプルング周期を変化させた。サンプルングを変化させた際の推定値について最悪値および積算値の結果を Table 4.6, Fig.4.9 および Fig.4.10 に示した。ここでは過渡と定常の領域について検証している。統計モデルに取り込む際にデータの前処理としてサンプルング周期を変化させて前処理を行い GP に学習させた。結果を下記に示す。

Table 4.6 Comparison of prediction for sampling effect;600-1200[sec]  
(Separation time: 100sec, Max Time Lag = 0)


### (a) Transient behavior

Data sampling rate[s]	Worst Value [%]	Integration Value [% s]
0.01	28.0	87.4
0.02	50.1	95.3
0.04	38.1	36.7
0.06	41.5	21.4
0.08	56.5	30.2
0.1	34.1	21.6
0.2	42.0	11.7
0.4	40.6	3.0
0.6	47.8	3.2

### (b) Steady behavior


Data sampling rate[s]	Worst Value [%]	Integration Value [% s]
0.01	31.8	64.5
0.02	33.6	35.9
0.04	37.9	21.0
0.06	13.0	8.1
0.08	25.0	11.1
0.1	63.5	11.4
0.2	20.8	4.0
0.4	13.4	1.9
0.6	18.7	1.3





Sampling time [sec]

(a) The effect comparison worst value of original and control [%]




Sampling time [sec]


(b) The effect comparison-integration value of original and control [% s]

Fig. 4.9 Comparison of prediction for down sampling in transient behavior

(Separation time: 100sec, Max Time Lag = 0)



(a) The effect comparison worst value of original and control [%]



(b) The effect comparison-integration on value of original and control [% s]

Fig. 4.10 Comparison of prediction for down sampling in steady behavior  
(Separation time: 100sec, Max Time Lag = 0)

Table4.6 には、WLTC モードを走った時系列データのサンプリング周期を変化させて求めた結果を示した。同内容をグラフ化したものを Fig.4.9 と Fig.4.10 に示した。Fig.4.9 では過渡領域のサンプリングによる結果、Fig.4.10 は定常領域による結果である。

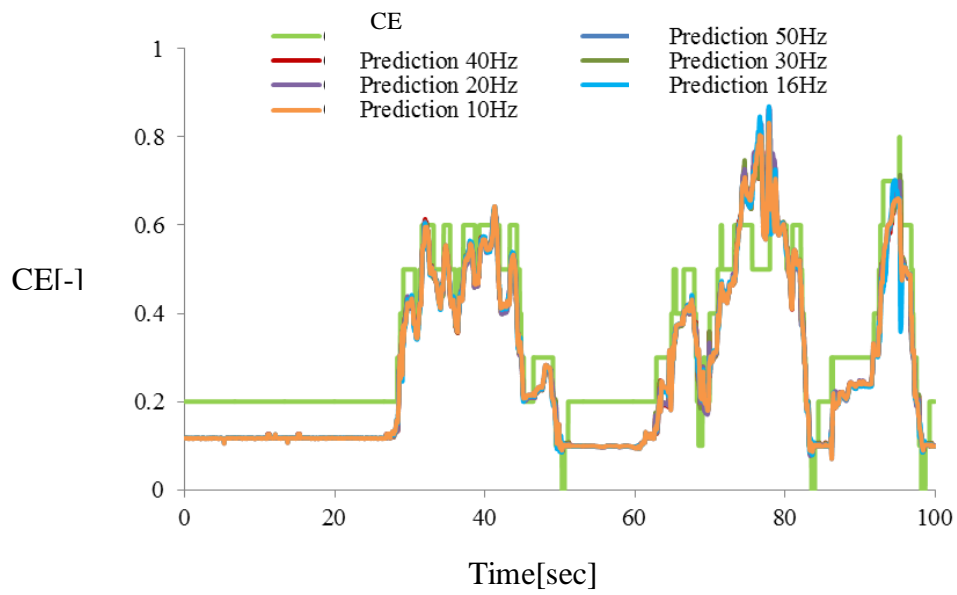
サンプリング周期変化の結果を考察する。Fig.4.9(a)の過渡領域はサンプリング効果が低くいずれもオリジナルの 0.01[sec]よりも高い値となった。一方で Fig.4.10(a)定常領域のデータは 0.06[sec]や 0.4[sec]で刻んだとき、最悪値が 13[%]程度と大幅な精度の向上が見られた。Fig.4.9, Fig.4.10(b)の過渡領域および定常領域の積算値に関しては、0.4[sec]と 0.6[sec]時でもっとも低く抑える効果を得ている。

以上の事例から激しい上下の動きのある過渡領域および一定の状態が続く定常領域の両方に効果があったものの、過渡と定常の最悪値低減を両立した設定値を選択することは難しかった。定常領域がデータに多く含まれる場合は、最悪値低減を優先させたほうが設計時の閾値の考慮に有効ではないかと考えられる。


#### 考察②Max Time Lag = 0, 2 における遮断周波数違いの LPF による推定精度とサンプリング周波数違いの比較

Fig.4.11(a)(b)では遮断周波数違いの LPF による推定精度とサンプリング周波数違いでそれぞれ比較している。LPF の設定について同図(a)(b)では、10,16,20,30,40,50[Hz]とした。また同図(c)(d) は Max Time Lag = 0, 2 のダウンサンプリングの前処理を行い統計モデルを作成した比較である。以下に考察を述べる。

Fig.4.11 には、Max Time Lag 違いの 0(1 次) および 2(3 次) について LPF を変化した場合の(a)(b)、サンプリング周期の変化について(c)(d)を示した。これらはいずれも推定精度比較の各時系列データである。Fig.4.11(a) Max Time Lag = 0 ではそれらの領域は推定できてはいるが、開始から 30[sec]前後まで一律 CE は 0.1 低く推定されている。また図中の過渡領域では真値の CE を再現してはいるものの、定常領域の CE データ成分が 50[sec] や 80[sec]後半は実際よりも高く推定されていた。一方 Fig.4.11(b) の Max Time Lag = 2 では推定精度は安定して高く得られているが、16, 20[Hz] が最も CE 真値に近いことがわかった。




(a) Comparison of prediction difference in LPF's cutoff frequency Max Time Lag = 0

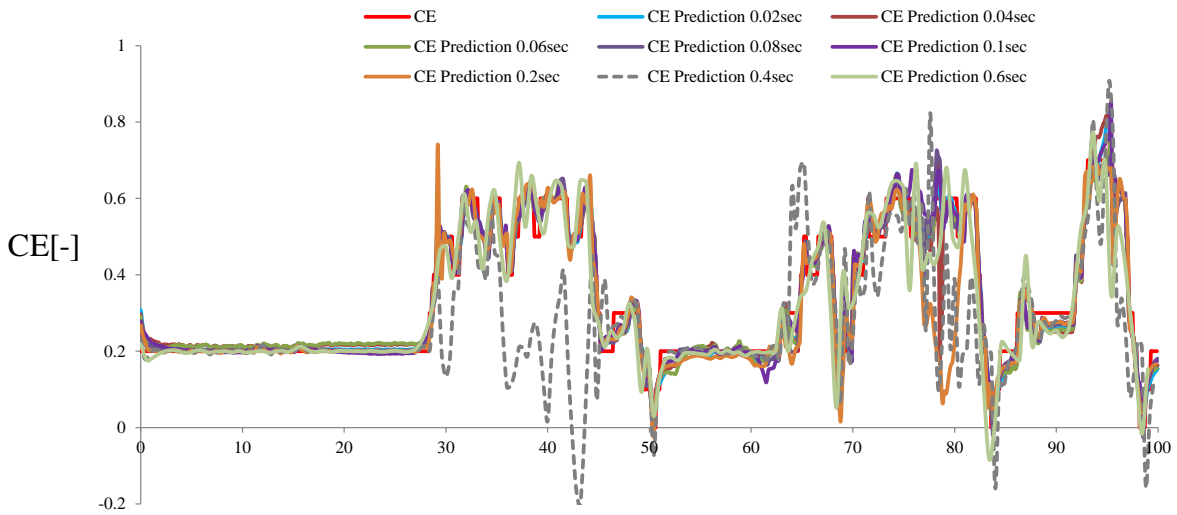


(b) Comparison of prediction difference in LPF's cutoff frequency Max Time Lag = 2

Fig. 4.11 Comparison of prediction for WLTC mode running;0-600[sec]



(c) Comparison of prediction difference for down sampling Max Time Lag = 0



(d) Comparison of prediction difference for down sampling Max Time Lag = 2

Fig. 4.11 Comparison of prediction for WLTC mode running (Cont.); 0-600[sec]

また予備検討として Max Time Lag = 2(3次)とした際にはLPFの周波数を上げていくと推定精度が劣化する傾向が見られた。これは最大周波数と遮断周波数を同じだという前提で下記の式を考えた場合、時間 T[sec] でサンプリングした場合の その遮断周波数  $f_l$  は(4.1)式以下で与えられる。

$$f_l = \frac{1}{2T} \dots\dots\dots(4.1)$$

(4.1)式より 0.01[sec]でサンプリングしたエンジンのデータ信号は次のように表現できる。

$$f_l = 1/0.02 = 50 \dots\dots\dots(4.2)$$

以上(4.2)式より 50[Hz]となり、基本的にそれ以上の周波数の信号は減衰すると考えられる。以上から過去のデータを学習値として使用する際にはいずれの周波数帯でも減衰傾向があると考えたほうが良い。

さらに Fig.4.11(c)の Max Time Lag = 0 では過去の学習値を予測に使用しないため一律に推定は真値に近くなっている。特に 80[sec], 90[sec] を超えた周辺ではいずれの周波数帯域でも検証データを読み込み推定開始後、最低で CE が 0.1 から最高 0.3 まで精度が悪化することが確認できた。Fig.4.11(d) Max Time Lag = 2 ではダウンサンプリング値を 0.4[sec]のように設定すると推定精度が低下した。この場合は前章でも述べた時間軸と周波数軸でサンプリング周期を大きく変更すると隣接する元のデータ同士が被ってしまう。その影響が強く出ていると推測できる。

以上②の考察から LPF とダウンサンプリング両方の手法の優劣の比較について次の知見を得た。まず過去のデータの学習度合いに関わらずダウンサンプリングの前処理を取ると全体的に精度が高めであった。ここでは精度が低下せずに推定できる Max Time Lag = 0 が推奨される。

## 4.7 小括

WLTC モードでの走行状態を想定した統計モデル検証を行った。Max Time Lag を 0,2(1 次・3 次)とした過去のデータ学習に関し推定精度を確認した。Max Time Lag = 0 を選択する方が加速や減速の場面で推定精度が高く得られた。

1. サンプリング周期の変化について処理後に検証データの最悪値が一律低く抑えられ、積算値もオリジナル値に比べて大幅な軽減効果があった。Max Time Lag の設定により推定精度が大きく変化した。過去の学習の度合いや過渡なのか定常か、どの領域に強い統計モデルを作成したいのかを判断基準として設定値を決める必要がある。
2. LPF の適用検討では、両方の領域に効果があったものの最悪値と積算値の両方を同じ設定値で低減させることは難しかった。
3. 分割周期の変化についての検討では、最悪値を基準にすると一つの値の設定で過渡と定常に対応しにくかった。最悪値に主眼をおき、前処理の手法から優先順位として①ダウンサンプリング②LPF を選択する。また過渡や定常両方の学習をさせる場合は分割周期の手法をとることとした。

以上を踏まえたこれらの結果から、分割モデルの精度を上げるためにはデータごとに Max Time Lag を調べ前処理はダウンサンプリングを利用することが加速の多い場面では統計モデルの実用に最も有効であると考えられる。

## 第5章 総括

この研究ではエアダクトから吸気された空気が、スロットルバルブを通じてサージタンク内に流入した内側の空気の燃焼している気筒内に流れ込む空気量を推定するため周辺のセンサ値から統計モデルを作成してきた。

統計モデルは筒内吸気量のモデルとした。従来や現行の方法での出力は、充填効率というパラメータで表される。この充填効率は一般に直接計測する事が難しく、推定量が用いられてきた。この推定は物理方程式や近似物理方程式により行われるのが長年の手法であった。本研究では、充填効率をモデルの出力(目的変数)として、エンジン回転数やスロットル開度、吸気バルブの開放タイミングを入力(説明変数)としたモデルを対象として考察した。

エンジンのセンサデータ値から統計モデルを作る際の推定精度を高めるために有効な一つの手法として、ガウス過程回帰である GP における前処理を提案した。訓練データを可能な限り取り込んで検証すれば推定が過渡状態でも可能であると言うのが、これまでの先行研究では多く報告されていた。本研究では限定的なデータ量でも、統計モデルを確立することが出来た。

3章ではエンジンのセンサで取得したデータには、少なからずノイズが含まれていると考え LPF やダウンサンプリングによる前処理の検証について述べた。前処理を施して作成した訓練データによって統計モデルを学習させると、判断基準とした統計的な指標  $R^2$  や相対誤差とした最悪値・積算値は判断基準としておおむね効果があった。LPF は 20[Hz] 時では推定誤差が低く抑えられたが、前後の遮断周波数では誤差が高い結果であった。また、ダウンサンプリングの値の選択幅は比較的広がった。低減できる値を一つに定めることが難しかったといえる。これは、統計モデルの推定精度がデータへの依存性が強いということを示唆している。

続いて4章において走行場面を意識し、WLTC モードを選択した。Max Time Lag が 0,2(1次・3次)とした過去のデータ学習に関して推定精度を確認した。Max Time Lag = 0 と選択する方が、加速や減速の場面で推定精度が高く得られた。WLTC モードのように加速・減速が著しい場面の統計モデル活用においては、ダウンサンプリングの前処理を利用する(サンプリング周期の変化)ことが最も有効である。



前半では最悪値に主眼をおき、最初に分割周期の手法をとる。次に LPF やダウンサンプリングによる前処理を行うことを確認した。後半では時系列データの活用も行い、Max Time Lag の設定も重要であることがわかった。さらにダウンサンプリングを活用し、GP による統計モデルに対して事前検証で適切な敷居値を定めた。

本研究では GP を統計モデルに用いることで、吸気系の制御器の設計構想を基に相対誤差を用いて検証した。これまでの制御がマップを組み合わせていた点からマップに頼ることなく、データを用いてエンジンの運転をすることが可能だということが実証できた。研究の結果から、入力するデータの処理ではサンプリング周期の変化を利用することが最も有効であったといえる。

全体を通して A/F の $\pm 10\%$ の相対誤差内に収まることを目指したが、範囲内には届かなかった。この点を考慮すると各パラメータの重みの調整や、入力するデータの処理で A/F からみた推定精度の目標値を達成するにはまだ検討の余地がある。

今後の課題はエンジンの吸気系モデルだけでなく、他の対応できる領域を増やしていくことである。Max Time Lag の設定と推定精度が鈍い場面の見極めなどの区別をして、推定精度を合わせこむことにも取り組んでいきたいと考えている。

## 付録

3 節で使用した車両仕様に関して

### 試験車両情報 Technical information

#### 主要な構造, 装置

ボディタイプ	ハッチバック
機種名	デミオ
駆動方式	前輪駆動, 無段変速(CVT)
エンジンタイプ	1.3L
全長	3900×1695×1475(mm)
ホイールベース	2570(mm)
トレッド 前/後	1495/1480(mm)
最低地上高	145
乗車定員	5 名
車両重量	1020(kg)前後
ステアリング	ラック & ピニオン式
エンジン型式	P3-VPS 型
種類	水冷直列 4 気筒 DOHC 16 バルブ
総排気量	1298(L)
圧縮比	12
燃料供給装置	筒内直接噴射(DI)
使用燃料, タンク容量	無鉛レギュラーガソリン, 44L

## 用語補足

### ■ 逆流要素 吹き返し/吹き戻し/吹き通りについて

すべて吸気行程中にシリンダから吸気系（吸気ポート～インマニ）へガスが逆流する現象のことである。

- ・ 吹き返し…IVO（Intake Valve Open）直後にシリンダ内のガスが吸気系へ逆流する現象
- ・ 吹き通り…オーバーラップ中に圧力差によって排気系内のガスがシリンダを通過して吸気系へ逆流する現象
- ・ 吹き戻し…吸気行程後半で下死点からピストンが上昇するのに伴いシリンダ内のガスが吸気系へ逆流する現象

### ■ 相対誤差についての考え方

相対誤差とはその時刻の推定値と真値を使って、  
(真値－推定値) / (真値もしくは推定) ×100%で計算する。

A/F の誤差と CE の誤差の関係は

空気が入った量＝真値の CE

噴射した燃料量＝推定 CE で計算

なので、

現時刻の  $A/F = (\text{Air の質量}) / (\text{燃料の質量})$

$= (\text{真値の CE} \times \text{単筒容積} \times \text{標準空気密度}) / (\text{推定 CE} \times \text{単筒容積} \times \text{標準空気密度} / 14.7)$

$= (\text{真値の CE} / \text{推定 CE}) \times 14.7$

A/F 誤差  $= (\text{現時刻の A/F} - 14.7) / 14.7$

$= (\text{真値の CE} / \text{推定 CE}) - 1$

$= (\text{真値の CE} - \text{推定 CE}) / \text{推定 CE}$

つまり CE の相対誤差と同じということになる。

論文中で用いた  $A/F \pm 8\%$  は每時刻の、真値  $C_e$  と推定  $C_e$  を使った相対誤差が  $\pm 8\%$  ということの意味する。

## 関連文献リスト

### 査読付き論文

「ガウス過程を用いたガソリンエンジンの吸入空気量推定における 統計モデリング手法の開発」, 自動車技術会論文集, 2019 年 50 巻 2 号 p.260-266, 小川 史恵・清水 良・和田 正義

### 国際学会発表

1. IEEE ICMA 2017, 2017IEEE International Conference on Mechatronics and Automation, 9th  
[A Study on Statistical Modeling with Gaussian Process Prediction], Fumie Ogawa /Hiroki Kawano /Ryo Shimizu /Masayoshi Wada, 20170809  
於：高松市シンボルタワー
2. SAMCON 2019, The IEEJ international Workshop on Sensing, Action, Motion Control and Optimization  
[Study on Advanced Statistical Modeling using Gaussian Process for Charging Efficiency (2<sup>nd</sup> Report)], Fumie Ogawa/Kota Matsue Ryo /Shimizu /Masayoshi Wada, 20190305, 2019.  
於：千葉大学

### その他

1. 自動車技術会 学術講演会 春大会 2018  
「ガウス過程を用いたガソリンエンジンの統計モデリング手法の開発」,  
小川史恵・清水良・和田正義, 自動車技術会学術講演会講演予稿集, No.5-18  
20185021, 2018.  
於：パシフィコ横浜
2. 第 61 回自動制御連合講演会  
「Gaussian Process を用いたガソリンエンジンの推定手法の検討」, 20181118  
於：南山大学 名古屋キャンパス
3. 第 62 回自動制御連合講演会  
「ガウス過程回帰を用いたエンジンシリンダー内の空気充填効率を推定するソフトセンサーモデリング検討」, 20191110  
於：札幌コンベンションホール

## 参考文献

- [1] 高橋信補, 瀬古沢照治, 塩谷真: “自動車エンジンにおける気筒流入空気量推定による空燃比制御方式”, 計測自動制御学会産業論文集 Vol.27 No.11 ,1258/1265 (1991).
- [2] 申鉄龍, 大畠明: “自動車エンジンのモデリングと制御”, コロナ社, (2011).
- [3] 金子成彦監修, 山崎由大, 大森浩充, 平田光男, 水本郁朗, 一柳満久, 松永彰生, 神田智博: “基礎からわかる自動車エンジンのモデルベースと制御”, コロナ社, (2019).
- [4] 豊田充, 申鉄龍: “D-最適実験計画に基づくエンジンにおける吸気流量モデルの適合”, vol.82, No.839, (2016).
- [5] Christian Friedrich, Matthias Auer, and Gunnar Stiesch: “Model Based Calibration Techniques for Medium Speed Engine Optimization: Investigations on Common Modeling Approaches for Modeling of Selected Steady State Engine Outputs”, 2016-01-2156, SAE International, (2016).
- [6] 鈴木健士, 申鉄龍, 加古純一, 吉田庄三: “シングルセンサによる気筒毎空燃比のモデリングと制御”, 日本機械学会論文集(C集), Vol.74-738, (2008).
- [7] 西馬功泰, 二木一, 木村英紀: “拡張カルマンフィルタを用いた自動車エンジン制御のための筒内吸気量推定”, 計測自動制御学会産業論文集 Vol.33 No.5, 397/402, (1997).
- [8] Feilong Liu, Gehan A. J. Amaratunga and Nick Collings, Ahmed Soliman, “An Experimental Study on Engine Dynamics Model Based In-Cylinder Pressure Estimation”, 2012-01-0896, SAE International

- [9] Farraen Mohd Azmin and Richard K. Stobart and Edward Winward, “Using a Statistical Machine Learning Tool for Diesel Engine Air Path Calibration”, Vol.2014-01-2391, Loughborough University John Rutledge Caterpillar Inc. Loughborough University, SAE Technical paper 2014-01-2319,doi: 10.4271/2014-01-2391. (2014).
- [10] T. Kruze, S, Kurz and T. Lang: “Modern Statistical Modeling and Evolutionary Optimization Methods for the Broad Use in ECU Calibration”, IFAC-Symposium Advances in Automotive Control, (2010).
- [11] T.Gutjahr : “Advanst statistical system Identification in ECU Development and Optimization”, SE international, 2015-01-2796, (2015).
- [12] T. Gutjahr H. Kleinegraeber, T. Huber, and T. Kruse : “Advanced Statistical System Identification in ECU-Development and Optimization”, ETAS Inc. and ETAS GmbH, SAE Technical Paper 2015-01-2796, doi:10.4271/2015-01-2796, (2015).
- [13] “自動車技術ハンドブック”, 第 5 分冊 設計 (パワートレイン) 編, (2016).
- [14] M. Sato, K. Shimojo, Y. Kitamura, Y. Miki, “Measurement Methods for Automotive Engine Identification”, Honda R&D Co., Ltd. SICE, (2014).
- [15] 花岡洋一, 長門達也: ”エンジンベンチでの実験計画法活用によるデータ計測精度の改善”, 第 59 回自動制御連合講演会, pp188-191, (2016) .
- [16] 長門達也: “エンジンテストベンチに対する制御システムの再設計による適合と検証効率の向上”, 修士論文,慶応義塾大学大学院システムデザインマネジメント研究科, (2017).
- [17] 金城敬太: “影響変数を伴う関係データの分析と応用についての研究”, 博士 (情報学) , 総合研究大学院大学複合科学研究科, 情報学専攻 博士号論文, (2009).
- [18] 筒井 宏明, 黒崎 淳, 佐藤 友彦: “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: Topological Case Based Modeling”, 計測自動制御学会制御部門大会, (2001).

- [19] 船津公人:“ソフトセンサ入門-基礎から実用的研究例まで-”, (2014).
- [20] 加納 学:“ソフトセンサ／バーチャルセンサの設計”, (研究メモ )  
[http://manabukano.brilliant-future.net/research/report/Report2009\\_Softsensor.pdf](http://manabukano.brilliant-future.net/research/report/Report2009_Softsensor.pdf)
- [21] S. Chen: “Local regularization assisted orthogonal least squares regression”,  
Neuro computing, Vol. 69, 559–585,(2006).
- [22] 藤原幸一, 加納学, 長谷部伸治:“相関型 Just-In-Time モデリングによるソフトセンサの設計”, 計測自動制御学会論文集, (2008).
- [23] Christopher Bishop: “Pattern Recognition and Machine Learning”, Chapter 6.,  
Springer, (2006).
- [24] Carl Edward Rasmussen and Christopher K. I. Williams: “Gaussian Processes-for-Machine-Learning”, MIT-Press.Press,  
<http://www.gaussianprocess.org/gpml>, (2006).
- [25] S. Akaho : “Kernel multivariate analysis”, Iwanami-shoten, (2016).
- [26] Gianluigi Pillonetto: “A new kernel-based approach for linear system identification”, <https://doi.org/10.1016/j.automatica.2009.10.031>
- [27] Gianluigi Pillonetto, Francesco Dinuzzo, Tianshi Chen, Giuseppe De Nicolao and Lennart Ljung: “Kernel methods in system identification machine learning and function estimation”: A survey Linköping University Post Print, (2014).
- [28] 小川雅俊, 鈴木泰政, 大貝晴俊, 草鹿 仁:“エンジンの応答曲面モデルと制御パラメータ最適化手法の開発”, 計測自動制御学会論文集, CVOL47,No.10,501/510, (2011).
- [29] Miguel Lázaro-Gredilla, Joaquin Quiñonero-Candela, Carl Edward Rasmussen, Aníbal R. Figueiras-Vidal: “Sparse Spectrum Gaussian Process Regression”, pp.1865-1881, Journal of machine Learning Research 11 , (2010).

- [30] 北川源四朗：“時系列入門解析”，岩波書店，(2005).
- [31] 田村担之・近藤正：“最近の GMDH の方法論と応用”，日本オペレーションズ・リサーチ学会
- [32] 池田三郎・榎木義一：“GMDHと複雑な系の同定・予測”，計測と制御，Vol.14,No.2(解説論文), pp185-195,(2004).
- [33] 小林瑞季・小林一郎：“複数の時系列データの比較に基づく言語化の試み”，The 26th Annual Conference of the Japanese Society for Artificial Intelligence, (2012).
- [34] 荒木裕，有田大作，谷口倫一郎：“時系列動作情報からの頻出動作パターンの抽出について”，電気学会研究会資料. IIS, 産業システム情報化研究会. Vol.6, pp.39-44, 2006-03, (2006).
- [35] 大山博之，山北昌毅：“エンジンベンチマークシミュレータを用いた制御モデル学習手法の検証”，日本シミュレーション学会論文誌，Vol.9,No.3, pp.47-55, (2017).
- [36] 久保拓哉：“データ解析のための統計モデリング入門— 一般化線形モデル・階層ベイズモデル・MCMC (確率と情報の科学)”，岩波書店，(2012).
- [37] 本橋智光：“前処理大全”，技術評論社
- [38] T.Sugiyama,Y.Fujikoshi and T.Ogura: “Multivariate data analysis, Asakura-shoten”, (2014).
- [39] 飯島晃良，基礎から学ぶ 高効率エンジンの理論と実際，グランプリ出版，(2018).
- [40] T. Aono and M. Saruwatari: “Estimation of Engine Torque and Cylinder Pressure Index Based on Crankshaft Rotation Measurement”，計測自動制御学会論文集Vol.51, No.9, 606/613, (2015).



- [41] T. Nagano and T. Iwamoto: “Combustion Torque Estimation Utilizing Smoother Implicit Derivatives from Crank Sensor Samples”: Proc. Of ICROS-SICE International Joint Conference 2009, pp.2894-2896 (2009).
- [42] <https://jp.mathworks.com/help/signal/ref/pwelch.html>, Mathworks HP
- [43] 和田成夫著, フーリエ解析からウェーブレット変換まで, 森北出版株式会社
- [44] 足立修一, ユーザのためのシステム同定理論, コロナ社, (1993).
- [45] ビギナーズ・デジタルフーリエ変換, 東京電機大学出版局, (2001).
- [46] Yuichi Tanaka: “Recent Advances in Signal Processing on Graphs”, IEICE Fundamental Review, pp. pp.28 Vol.8 No.1, (2014).
- [47] Jie Duan, Mingfeng Li and Teik C. Lim, Ming-Ran Lee, Wayne Vanhaaften, Ming-Te Cheng and Takeshi Abe :“ Control of Powertrain Noise Using a Frequency Domain Filtered-x LMS Algorithm”, 2009-01-2145, (2009).
- [48] Zamir Zulkefli, Maurice Adams: “Experimental Investigation of the Low Pass Filtering Effect of a Hydrostatic Bearing”, SAE International, 2014-01-1758 ,(2014).
- [49] “燃料消費率試験”(WLTC)  
<https://www.naltec.go.jp/publication/regulation/fkoifn0000000ljx-att/fkoifn00000060rh.pdf>
- [50] Ji Xu, Guohua Sun, Tao Feng, Mingfeng Li, and Teik Lim: “Comparative Study of Adaptive Algorithms for Vehicle Powertrain Noise Control”, 2016-01-9108,SAE International ,(2016).
- [51] M.Nakamura, M.Sasaki et al: “Active Control of Periodic Noise with High-Order Harmonic Frequencies ( Control Performance Improvement using a Spectrum-Shaping Method)”, pp.3145-3152, 日本機械学会論文集 Vol.63-613, (1997).

- [52] Chapman and Hall: “Time Series Analysis”, pp.125-130, CRC Texts in Statistical science series, (2007).

## 謝辞

本論文をまとめるにあたり東京農工大学 和田正義准教授には細部にわたり懇切丁寧なご指導，ご助言を賜りましたこと心から感謝申し上げます。併せて同大学 毛利宏教授，Pongsathorn Raksincharoensak教授，田川泰敬教授，鎌田崇義教授，涌井伸二教授，石井一夫特任教授（現：久留米大学）の各先生から貴重なご意見を頂きましたこと誠に感謝しております。また原稿初期から文章の添削で，ご協力いただいた手島美帆先生(豊橋技術科学大学)，東京農工大学卒業生の富井圭一様にもお礼を申し上げます。

東京農工大学卒業生でもあり社会人の先輩として，手塚直人様には公私にわたり叱咤激励をいただき，深謝いたします。また研究会および各会社に所属される小川雅俊様，武藤晴文様には本論文および学会での参加を通じて，有意義な議論をさせていただきました。さらに社会人博士課程の仲間の皆様にも多くの励ましをいただきました。そして和田研究室の大学院生ならびに学部生，卒業生の皆様，特に宗方宥博士には毎週末いろいろ相談に乗っていただきました。大変感謝しております。

最期に本研究を行うにあたり暖かな目で見守ってくださり，多くのアドバイスを頂いた清水良様，松江浩太様には大変お世話になりました。目良貢様には統計処理などの相談に乗っていただきました。開発部門の各メンバーおよび技術研究所の皆様にも，データのご提供や研究についての相談・議論を始めとして大変お世話になりました。

末尾に精神的に大きな支えになってくれた家族には感謝してもしきれません。本当にありがとうございました。この論文を故人である父，小川尚徳博士および同期で共に広島で励まし合った石田珠貴デザイナーに捧げます。

広島・東京にて 小川史恵