FTIR 赤外吸収スペクトルを用いた排出ガス THC 濃度推定モデル開発

藪下 広高^{*1}, 永岡 真^{*2}, 吉岡 雅也^{*1}, 森 雄一^{*1}

Development of THC estimation model using FTIR spectrum

Hirotaka YABUSHITA^{*1}, Makoto NAGAOKA^{*2}, Masaya YOSHIOKA^{*1} and Yuichi MORI^{*1}^{*1,*2} HORIBA, Ltd.

2 Miyanohigashi-cho, Kisshoin, Minami-ku, Kyoto 601-8510, Japan

Received: 11 October 2020; Revised: 15 December 2020; Accepted: 24 January 2021

Abstract

A novel total hydrocarbon (THC) emission concentration estimation model is proposed for reduction of engine development cost as well as simplification of measurement system. The model is based on machine learning algorithm including the least absolute shrinkage and selection operator (LASSO) regression and bagging techniques. Major features of the proposal model are taking the absorbance spectrum of Fourier transform infrared (FTIR) spectrometer as input and incorporating not only spectra of the engine exhaust gas but also those of individual hydrocarbon and inorganic gas components as training data set. This method was validated on the exhaust gas before the catalyst of a gasoline engine. The results show an error of less than 5% in both steady and transient operating conditions, outperforming the 20 % error of conventional regression model using only the reference hydrocarbon concentrations. We also evaluate the contribution to performance improvements in THC estimation of employing FTIR spectrum and incorporating spectrum information of gas components, respectively.

Keywords : THC, FTIR, Estimation model, Machine learning, LASSO, Bagging

1. 緒言

内燃機関は地球環境の観点から排出される CO₂ や有害物質のさらなる低減を目指して研究開発が続けられている。また、排出量規制の強化とともに、規制対象成分の追加も予定されている。これらに対応するために、計測、評価、解析にかかる工数も増加することになり、より一層の開発効率の向上が求められている。

一般に排気系の計測システムでは、各種計測対象成分に応じて計測原理が異なり、複数の分析装置が用いられている。装置本体や設置時に必要な設備コスト以外に、校正用ガスやユーティリティガスの費用、校正、メンテナンスに必要な工数も計測における負荷となる。そのため、他の分析計で計測されている値を、別の分析計の値から推定することで装置の一部を補間、代替することができれば、計測系の負荷を低減することが可能となる。

そこで、本研究では、全炭化水素 (THC) 計を用いずに、フーリエ変換赤外分光計 (FTIR) の赤外吸収スペクトルから THC 濃度を推定することを目的とした。エンジン排出ガス中の炭化水素の計測には、1960 年代までは非分散型赤外吸収法 (NDIR) によるプロパン換算が一般的であったが、その後、検知下限や干渉影響の点で有利な水素炎イオン化検出法 (FID) を用いた THC 測定が標準となっている (堀場製作所, 2016)。水素炎中で炭化水素を燃焼させるとイオンが発生し、そのイオン発生量がほとんどの炭化水素に対してその炭素数に比例するため、FID ではすべての炭化水素に含まれる全炭素量、すなわち THC を知る事ができ (堀場製作所 自動車セグメント, 2013)、近年では RDE 規制など実路走行時での THC を計測するために車載化システムに組み込まれ、高地低温条件でも応用可能となってきた (茂原他, 2019)。一方、FTIR では、干渉計と高速フーリエ変換を組み合わせる

No.20-00358 [DOI:10.1299/transjsme.20-00358], J-STAGE Advance Publication date : 2 February, 2021

本論文は、第31回内燃機関シンポジウム 講演論文集(2020)、No.36の掲載内容に基づいた論文である。

^{*1} (株) 堀場製作所 (〒601-8510 京都府京都市南区吉祥院宮の東町 2)^{*2} 正員, (株) 堀場製作所

E-mail of corresponding author: hirotaka.yabushita@horiba.com

ことで高分解能の赤外吸収スペクトル（以下、スペクトルと呼ぶ）を得ることができ、ガス分子ごとに固有の吸収波数に着目することで、複数のガス成分の濃度を同時に計測することができる。エンジンの排出ガス分析においても、水、二酸化炭素、一酸化炭素、一酸化窒素などの無機ガスや、メタン、エタン、トルエンなどいくつかの炭化水素の濃度が、FTIR を用いて同時計測されている（Adachi et al., 1992）。

FID を用いずに THC を推定する方法としては、FTIR で計測された各炭化水素濃度について、構成炭素数による重みづけ和をとる方法（安藤，足立，2018）が報告されている。しかし、エンジンの排出ガスには数百種類の炭化水素が含まれ（山本他，1997），FTIR では全ての炭化水素の濃度を計測しているわけではないため、FTIR で計測している炭化水素濃度のみでは THC を算出することはできない。また、前記重みづけ和を用いて線形近似する方法（Li et al., 2006）や炭化水素濃度をすべて計測せずに化学構造の似た炭化水素をセットで扱う方法（井上他，1992, Gierczak et al., 2017）も提案されている。これら従来の THC 推定方法は、いずれも FTIR で濃度値を計測していない炭化水素成分の濃度と、計測している炭化水素の濃度の比が一定であることを前提としている。しかし、エンジンの燃料および燃焼-後処理コンセプトとその制御方法によって、排出ガスの組成割合は大きく変化するため、従来の方法では THC の推定精度は十分とはいえない。

そこで、本研究では個別の炭化水素濃度を用いず、FTIR のスペクトルと THC の関係を直接機械学習でモデル化することで、THC を推定する方法を提案する。モデルの複雑化を避けるため線形モデルを用い、学習アルゴリズムには、LASSO 回帰とアンサンブル学習の 1 つであるバギングを組み合わせた。学習データには、エンジンの排出ガスのスペクトルに加えて、各ガス成分の THC への寄与を効率的に学習するために排出ガスに含まれる炭化水素や無機ガスの単成分スペクトルを用いた。テストデータには、学習データとは別で取得した世界統一試験サイクル（WLTC）模擬条件、実路運転模擬条件、定常条件を用い、THC 計の計測値とモデルによる推定値を比較し、本手法を検証した。

2. 方法

2・1 計測システム

計測システムの構成を図 1 に示す。実験には、直列 4 気筒、排気量 1.6L の過給直噴ガソリンエンジンを用いた。エンジン排出ガスについては、触媒前の配管から排出ガスをサンプリングし、FTIR と THC 計（FID）を内蔵した分析計に接続し同時計測した（図 1(a)）。また、単成分ガススペクトル計測時は、既知濃度のガスボンベとマスフローコントローラ（MFC）を用いて、複数の既知濃度ガスを生成し、FTIR で計測した（図 1(b)）。

Fig. 1 Measurement system configurations. (a) Measurement of exhaust gas. (b) Measurement of individual gas component.

実験の運転条件を表 1 に示す。定常条件（steady condition）は図 2(a)に示す 31 点でデータを取得した。過渡運転条件（transient condition）の WLTC 模擬（WLTC simulation）と実路走行模擬（Real drive simulation）は、それぞれ

れシヤシダイナモ上での WLTC 走行試験, 実路試験時のエンジン回転数とスロットル開度を与えてエンジンベンチで実験した. 実験時の 1 秒ごとのエンジン回転数とトルクを図 2(b), (c)に, またその時間変化を図 3 に示す. また, WLTC 模擬は 3 回, 実路走行模擬は 2 回実施した.

Table 1 Data acquisition conditions.

	Operating Conditions	Data size	Remarks
Steady	Steady conditions in Fig. 2	5 min/condition $\times$ 31 conditions	
Transient	WLTC simulation 1	30.1 min (9078 data)	Hot start, Training data
	WLTC simulation 2	31.3 min (9424 data)	Cold start
	WLTC simulation 3	30.1 min (9072 data)	Cold start
	Real drive simulation 1	20.5 min (6163 data)	Hot start
	Real drive simulation 2	19.0 min (5697 data)	Cold start

Fig. 2 Engine speed and torque in different conditions.

Fig. 3 Engine speed and torque in transient conditions.

2・2 THC 推定

2・2・1 FTIR スペクトルの利用

FTIR スペクトルから THC 濃度を推定するモデルには、式(1)の線形関数を用いた。

$$\hat{y} = \sum_{k=1}^M w_k A_k \quad (1)$$

ここで、 $\hat{y}$ は THC 濃度の推定値、 M はモデルへ入力するスペクトルに含まれる波数（入力変数）の数、 A_k, w_k はそれぞれ k 番目の波数に対応する吸光度と回帰係数である。

2・2・2 LASSO 回帰

ガス濃度が変わると、複数の波数の吸光度が同時に変化する。隣り合う波数の吸光度のように入力変数間の相関が極端に高い場合、最小二乗法によって式(1)の回帰係数を決めると、学習データの少しの差で回帰係数が大きく変化し、適切な推定精度が得られないことがある（川野他,2018）。そのため、本研究では LASSO 回帰（Tibshirani, 1996）を用いた。

LASSO 回帰では式(2)の通り誤差の二乗和に回帰係数の絶対値の和（L1 ノルム）を加えた値を最小化するように回帰係数を求める。L1 ノルムの効果により回帰係数 w_k が 0 になりやすく、LASSO 回帰ではモデル生成と同時に変数選択が行われるという特長がある。すなわち、本ケースでは THC に寄与するスペクトルの波数域を自動的に抽出することができる。

$$\mathbf{w} = \arg \min_{\mathbf{w}} \left(\sum_{i=1}^N (\hat{y}_i - y_i)^2 + \lambda \sum_{k=1}^M |w_k| \right) \quad (2)$$

ここで、 $y_i, \hat{y}_i$ は、 i 番目のデータの THC 濃度の実測値と推定値、 N は学習データのサンプル数である。また、 λ はハイパーパラメータであり、候補パラメータを(0.01, 0.1, 1, 10, 100)として、5 分割交差検証（5-fold CV）にて決定した。5 分割交差検証の手順を以下に示す。ここで、性能評価には二乗平均誤差（RMSE）を用いた。

1. 学習データをランダムに 5 つのサブセットに分割する。
2. 1 つのサブセットで学習しモデルを作成、残り 4 つで性能評価を行う。
3. 2 を 5 つのサブセットすべてで繰り返し、その平均性能をそのモデルの性能とする。
4. 2, 3 を λ の候補パラメータすべてで実施し、最も性能の良いパラメータを採用する。

2・2・3 バギング

本手法では、LASSO 回帰にバギング（Breiman, 1996）を組み合わせて使用する。バギングとは、複数のモデルを用いて推定するアンサンブル学習の 1 つであり、学習データの一部と、入力変数の一部のみを用いてモデルを作成することを L 回繰り返し、最終的に各モデルの推定結果 $\hat{y}^{(j)}$ の平均値を推定値として採用する手法である。

$$\hat{y} = \frac{1}{L} \sum_{j=1}^L \hat{y}^{(j)} \quad (3)$$

FITR のスペクトルには、相関の強い波数が含まれているため、LASSO 回帰ではそれらの波数のうち 1 つが選択されると、他方の波数は選択されにくくなる。そのため、両方の波数を使用する場合と比べ、ランダムノイズの影響を受けやすくなる。バギングと LASSO を組み合わせることによって、ノイズの影響を低減することができる。また、バギング時に作成したすべてのモデルが、式(1)の線形関数のため、それらの平均である式(3)の関数も、式(1)と同じ形で表すことができる。そのため、バギングで使用するモデルの数が増えても推定時の演算量は増加しない。

2・2・4 単成分ガスのスペクトル学習

学習データには、表 1 に示した WLTC 模擬条件のデータに加えて、表 2 に示す炭化水素、含酸素炭化水素、無機ガスの単成分のみを含むスペクトルを用いた。

Table 2 Spectra of individual gas components.

Objective	Components
Learning each component's contribution to the THC	Methane, ethane, ethylene, propane, propylene, n-butane, isobutylene, 1,3-butadiene, benzene, toluene, ethanol, acetaldehyde, formaldehyde, formic acid
Avoiding spurious correlation	Carbon dioxide, water
Avoiding interference	Carbon monoxide, nitric oxide, nitric dioxide, nitrous oxide

これらのスペクトルを学習させる目的は 3 つある。第一の目的は、各炭化水素の THC 濃度への寄与を効率的に学習するためである。エンジンの排出ガスは複雑な混合物であり、多くの条件で各炭化水素の濃度は互いに高い相関を持つ。そのため、排出ガスのみを学習した場合、各炭化水素の THC 濃度への寄与を個別に効率良く学習することは難しい。また、ホルムアルデヒドやギ酸など、FTIR では計測されるが、THC 計の感度がない成分の影響を正しく学習することも困難である。したがって、運転条件によって炭化水素の組成が変わった場合に、推定精度が低下する。そこで、1 種類の炭化水素のみを含むガスのスペクトルとそのときの THC 濃度を学習することによって、その炭化水素の THC 濃度への寄与を学習させ、排出ガス中の炭化水素組成変化に対する推定精度のロバスト性を確保した。第二の目的は、疑似相関の学習を回避することである。エンジンの排出ガスでは、多くの条件で THC 濃度と水、二酸化炭素の濃度に高い相関関係がみられる。そのため、排出ガスのみを学習した場合、THC 濃度で吸光度が変動する波数の情報だけでなく、水や二酸化炭素濃度によって吸光度が変動する波数の情報をモデルに含めてしまう可能性がある。したがって、燃料カット時など、THC 濃度と水、二酸化炭素の濃度との相関関係が崩れる条件では、推定精度が低下する。そこで、水や二酸化炭素の単成分のスペクトルが、THC 濃度 0 ppmC に対応することを学習することによって、疑似相関の学習を避けた。第三の目的は干渉影響を除くことである。炭化水素と窒素酸化物の吸収波数は一部重なっているため、その波数の吸光度変化は炭化水素だけでなく窒素酸化物によっても起こる。そのため、その波数を用いて THC 濃度を推定しようとする、THC 濃度の変化ではなく窒素酸化物の濃度変化の影響を受ける、いわゆる干渉が起こる。そのため学習データに窒素酸化物のスペクトルを加え、対象波数は窒素酸化物によっても変化することを学習させ、干渉影響を避けた。

2・3 精度評価指標

推定精度の評価には、各条件での総排出質量を用いた。

THC 総排出質量 M_{THC} は以下の式(4)を用いて算出する。

$$M_{THC} = \sum_{i=1}^N r \times y_i \times m_{exh,i} \times \Delta t \quad (4)$$

ここで、 M_{THC} は THC 総排出質量[g]、 N は評価期間のサンプルデータ数、 r は排出ガスに対する THC の質量比、 Δt はデータサンプリング間隔[min]、 $y_i, m_{exh,i}$ は、それぞれ i 番目のデータの THC 濃度[ppmC]、排出ガスの質量流量[kg/min]である。実測値から得られる THC 総排出量 M_{THC} に対して推定値 $\hat{M}_{THC}$ は、式(4)の THC 濃度 y_i に THC 濃度推定値 $\hat{y}_i$ を用いる。

総排出質量の推定誤差[%]は式(5)により算出する。

$$\text{Error} = \frac{\hat{M}_{THC} - M_{THC}}{M_{THC}} \times 100 \quad (5)$$

3. 結果と考察

3・1 定常条件

入力にスペクトルを使用することと、排出ガスだけでなく単成分ガスのスペクトルを学習することの効果調べるために、表3に示す3つのモデルを作成し推定誤差を比較した。Model1ではFTIRで計測した9種の炭化水素の濃度のみを入力に用い、排出ガスのデータを学習させた。Model2ではスペクトルを入力に用い、排出ガスのスペクトルを学習させた。Model3では、スペクトルを入力に用い、排出ガスのスペクトルだけでなく、水や炭化水素などの単成分ガスのスペクトルも学習させた(本手法)。それぞれのモデルの定常条件における推定誤差を図4に示す。図中の円の大きさは、各定常条件点における推定誤差を示しており、赤は実測値より大きく、青は小さく推定されたことを示す。また、灰色の点は学習データ(WLTC simulation 1)に含まれる運転条件を示す。

また、図5に図4のArea 1, Area 2の条件におけるTHC濃度に対するメタン及びFTIRで計測したその他の炭化水素のメタン換算濃度の比を積み上げ棒グラフで示す。メタン換算濃度とは各ガス濃度に各ガス分子に含まれる炭素数をかけたものを表す。FTIRで計測した炭化水素は、表3 Model1のInputと同じものである。

Table 3 Models.

Model	Input	Training data	Remarks
Model 1	Concentrations of hydrocarbons (methane, ethylene, ethane, propylene, butadiene, isobutylene, benzene, toluene, acetaldehyde)	Exhaust gas	
Model 2	Spectrum	Exhaust gas	
Model 3	Spectrum	Exhaust gas and single gas components	Proposal method

Fig. 4 Model performances in steady state condition. (a) Model 1: trained with concentrations of the exhaust gas hydrocarbons. (b) Model 2: trained with spectra of the exhaust gas. (c) Model 3 (proposal method): trained with spectra of both the exhaust gas and the individual gas components. Using spectrum as input, Model 2 is more accurate than Model 1. With prior knowledge of spectra of individual gas components, Model 3 is more accurate than Model 2 under higher load conditions (Area 2).

3・1・1 スペクトルを学習することによる効果

FTIR で計測した 9 種の炭化水素濃度を入力とする Model 1 では、多くの条件で約 20% 過大評価している (図 4(a))。一方、スペクトルを入力とした Model 2 の推定精度は、Model 1 に比べ大きく改善した (図 4(b))。

図 5 に示す通り FTIR で計測した 9 種の炭化水素のメタン換算濃度の総和と、THC 濃度の比が 0.4-0.7 であった。したがって、FTIR で計測した 9 種の炭化水素濃度では THC 濃度の 40-70% 程度しか説明できていないことがわかる。一般にガソリンエンジンの排出ガスには、炭素数 10 以下の炭化水素が多く含まれており (山本他, 1997)、本実験で用いた FTIR では表 3 に示す炭化水素のみを計測しているため、残りの 60-30% は炭素数 5 のペンタン異性体や炭素数 8 以上のキシレンやトリメチルベンゼンなどの寄与と考えられる。THC 濃度を知るには、これら未計測の炭化水素の影響を入力情報から推定する必要がある。Model 1 では、FTIR で計測した炭化水素濃度情報のみを入力としているため、計測成分と未計測成分の濃度比が一定である場合のみしか正確に推定できないが、Model 2 では、スペクトルの情報を用いて未計測成分の影響を直接考慮することができ、推定精度が向上したと考えられる。

3・1・2 単成分ガスのスペクトルを学習することによる効果

図 4 の Area 1 は学習データに含まれている条件であり、それらの条件では炭化水素の組成に大きな差はない (図 5)。また、図 4(b), (c) に示すように、Area 1 の条件では Model 2 と Model 3 とともに、5% 以下の推定誤差で THC を推定できている。一方、Area 2 で示される高負荷領域では、メタンの割合が大きく、Area 1 の炭化水素組成とは異なる条件になっている (図 5)。これらの条件では、図 4(b), (c) に示すように、Model 2 に比べ Model 3 では推定精度が大きく改善している。排出ガスのみを学習した Model 2 では、メタンの濃度が学習データに含まれている範囲より大きくなると推定精度が悪化するが、Model 3 では、単成分ガスのスペクトルを学習データに加えることによって、増えたメタンの寄与を正しく見積もることができ、推定精度が改善したと考えられる。

Fig. 5 Comparison of hydrocarbon to THC ratios under different conditions. There is a higher proportion of methane in THC in high torque conditions (Area 2) than in low torque (Area 1).

3・2 過渡条件

図 6 に WLTC simulation 2 条件での Model 3 (本手法) の推定結果を示す。全時間において、THC 排出質量の推定値は実測値とよく一致している (図 6(a))。詳細にみると、一部の区間では 6% 程度過小評価している (図 6(b))ものの、THC 排出質量が大きく変動する区間においても推定値は実測値に追従している (図 6(c))。

図 6(b) に示す時刻 500 s のデータについて、学習に用いた WLTC simulation 1 と、Cold start 条件である WLTC simulation 2 の FTIR で計測した炭化水素の組成を比べると、エタンは 1.5 倍、トルエンは 2 倍以上後者の方が大きく、FTIR で計測していない他の炭化水素の組成比も同様に異なっていることが推測される。すなわち、時刻 500 s 付近の誤差の原因は、単成分のスペクトルの学習に含まれていない炭化水素の寄与が、WLTC simulation 1 のデータでは十分に学習されなかったためと推察される。より広範囲の炭化水素の組成を学習データに含めることで精度を確保できると考えられる。

図 7 に Model 1 と Model 3 (本手法) における過渡条件の総排出質量の推定誤差を示す。本手法では、すべての条件に置いて、推定精度が大幅に改善することを確認した。

Fig. 6 Estimation results of WLTC simulation 2. The THC predictions are consistent with measured THC in all regions.

Fig. 7 Performances in transient state condition. Model 3 shows higher accuracy in all scenarios.

4. 結言

機械学習アルゴリズムである LASSO 回帰とバギング手法を用いて, THC 計を用いずに, FTIR 赤外吸収スペクトルから THC 排出量を推定する手法を提案した. スペクトルを入力変数とすることで, FTIR では濃度計測していない炭化水素の寄与を直接学習することができ, 濃度を入力変数とするよりも推定精度が改善することを確認した. また, 単成分ガスデータを学習データに加えることで, 炭化水素の成分組成変化に対して推定精度がロバストとなり, 定常, 過渡いずれの条件においてもガソリンエンジンのエンジンアウト THC を誤差 5%未満で推定できた.

本稿では, ガソリンエンジンのエンジンアウトガスに関する THC 推定モデルを作成したが, ディーゼルエンジンやエタノールなどの含酸素燃料においては排ガス組成が異なり, 同一のモデルで本結果と同等の推定精度が得られるかは今後の課題である. 精度不十分の場合には, 追加学習あるいは燃料ごとに学習したモデルを複数用意するなどの利用法が考えられる. また, 学習データの取得条件を改善することでも, 炭化水素組成変化に対するロバスト性はさらに向上すると考えられる.

謝辞

実験に協力いただいた, 株式会社堀場製作所宮地幸治氏, 吉村達也氏, 株式会社堀場テクノサービス北将憲氏に感謝する.

文献

- Adachi, M., Yamagishi, Y., Inoue, K. and Ishida, K., Automotive emission analyses using FTIR spectrophotometer, SAE Technical Paper 920723 (1992).
- 安藤嘉健, 足立正之, 分析装置, 分析方法, 分析装置用プログラム及び分析用学習装置, WO2019-031331(2018).
- Breiman, L., Bagging predictors, Machine Learning, Vol. 24 (1996), pp. 123-140.
- Gierczak, A. C., Kralik, L. L., Mauti, A., Harwell, L. A. and Maricq, M. M., Measuring NMHC and NMOG emissions from motor vehicles via FTIR spectroscopy, Atmospheric Environment, Vol. 150 (2017), pp. 425-433.
- 株式会社堀場製作所, MEXA50 年のあゆみ (2016), p.37.
- 株式会社堀場製作所自動車計測セグメント編, エンジンエミッション計測ハンドブック (2013), p.85.
- 井上香, 山岸豊, 足立正之, FTIR を用いた多成分定量分析方法, 特開平 4-265842 (1992).
- 川野秀一, 松井秀俊, 廣瀬慧, スパース推定法による統計モデリング (2018), p.3, 共立出版.
- Li, H., Ropkins, K., Andrews, G. E., Daham, B., Bell, M., Tate, J. and Hawley, G., Evaluation of FTIR emission Measurement

system for legislated emission using a SI car, Proceedings of SAE 2006 Powertrain and Fluid Systems Conference 2006-01-3368 (2006).

茂原治久, 深見瞬, 西川雅浩, 高地走行を前提とした車載型排出ガス計測システムの計測精度向上, 自動車技術会 2019 年春季大会学術講演会講演予稿集 (2019).

Tibshirani, R., Regression shrinkage and selection via the lasso, Journal of the Royal Statistical Society Series B, Vol. 58 (1996), pp. 267-288.

山本正美, 伊藤宏, 大嶋文子, 自動車排出ガス中の個別炭化水素解析システムの開発 (その 1) 個別炭化水素の分析法, 豊田中央研究所 R&D レビュー, Vol. 32, No. 4 (1997), pp. 71-79.

Reference

Adachi, M., Yamagishi, Y., Inoue, K. and Ishida, K., Automotive emission analyses using FTIR spectrophotometer, SAE Technical Paper 920723 (1992).

Ando, Y. and Adachi, M., Analyzer, analysis method, analyzer program and analysis learning device, WO2019-031331(2018).

Breiman, L., Bagging predictors, Machine Learning, Vol. 24 (1996), pp. 123-140.

Gierczak, A. C., Kralik, L. L., Mauti, A., Harwell, L. A. and Maricq, M. M., Measuring NMHC and NMOG emissions from motor vehicles via FTIR spectroscopy, Atmospheric Environment, Vol. 150 (2017), pp. 425-433.

HORIBA, Ltd., Fifty years progress of MEXA, (2016), p.37 (in Japanese).

HORIBA, Ltd. automotive measurement segment ed., Engine Emissions Measurement Handbook (2013), p.85 (in Japanese).

Inoue, K., Yamagishi, Y. and Adachi, M., Method for multi-component quantitative analysis using FTIR, Japanese patent disclosure H04-265842(1992).

Kawano, S., Matsui, H. and Hirose, K., Statistical modeling by sparse estimation method (2018), p.3, Kyoritsu Shuppan (in Japanese).

Li, H., Ropkins, K., Andrews, G. E., Daham, B., Bell, M., Tate, J. and Hawley, G., Evaluation of FTIR emission Measurement system for legislated emission using a SI car, Proceedings of SAE 2006 Powertrain and Fluid Systems Conference 2006-01-3368 (2006).

Mohara, H., Fukami, S. and Nishikawa, M., Improvement for measuring accuracy for PEMS (Portable Emissions Measurement System based on a high altitude driving, Proceedings of the 2019 JSAE spring conference (2019) (in Japanese).

Tibshirani, R., Regression shrinkage and selection via the lasso, Journal of the Royal Statistical Society Series B, Vol. 58 (1996), pp. 267-288.

Yamamoto, M., Ito, H. and Ohshima, A., Development of quick sampling GC system for analyzing specific hydrocarbons in exhaust gas. (Part1) method for analyzing specific hydrocarbons, R&D Review of Toyota CRDL, Vol. 32, No. 4 (1997), pp. 71-79 (in Japanese).