

# 6

久留米工業大学  
インテリジェント・モビリティ研究所 研究報告

2022



## 目次

### 研究・技術報告

山口卓也

ニューラルネットワークによる大型ディーゼルエンジンにおける摩擦平均有効圧力 (FMEP) の予測および FMEP に関するパラメータ検討

インテリジェント・モビリティ研究所 活動報告

編集後記



# 研究 · 技術 報告



# ニューラルネットワークによる大型ディーゼルエンジンにおける摩擦平均有効圧力(FMEP)の予測および FMEP に関するパラメータ検討

## 1. はじめに

ディーゼルエンジンは正味熱効率が高く CO<sub>2</sub> の排出が少ない内燃機関である。その一方で、地球温暖化の抑制の観点から正味熱効率をさらに向上させ、ディーゼルエンジンからの CO<sub>2</sub> の排出量を低減することが強く求められている。エンジンの正味熱効率の向上には冷却損失や機械損失などの低減が必要であり、特にエンジン内部の摩擦損失や補器類の駆動損失などからなる機械損失の低減は、正味熱効率の改善に直接寄与することから、この低減は重要な課題である。

近年、エンジンの開発プロセスにおいて MBD (Model Based Development) の手法が取り入れられている。1 次元および 3 次元シミュレーションツールを利用したエンジン性能予測計算における摩擦平均有効圧力(FMEP)は、Chen-Flynn により提案された筒内最高圧力( $P_{max}$ )と平均ピストン速度( $C_m$ )を関数としたモデル<sup>(1)</sup>を用いて予測されることが多い。Chen-Flynn により提案されたモデルは、実験結果をベースに  $P_{max}$  と  $C_m$  に関するモデル定数を適正化することで、FMEP を簡便に予測できる利点を有しており、工学的に重要な点は抑えられている。しかし、Chen-Flynn モデルが提案された時代のディーゼルエンジンと異なり近年のディーゼルエンジンはコモンレール燃料噴射システムを採用し、機関速度に依存することなく燃料噴射圧力を変化させることが可能になったことに加えて、燃料の多段噴射などによりシリンダ内の圧力プロファイルを変化させることも可能となり、燃焼位相および熱発生率プロファイルを大きく変化させることが可能となっている。このような現在のディーゼルエンジンにおいて、 $P_{max}$  と  $C_m$  のみを考慮した Chen-Flynn モデルによる FMEP の予測では、燃料噴射圧力やシリンダ内の圧力プロファイルなどの変化が FMEP に及ぼす影響を十分に考慮することができていないのではないかと考えられる。このため、エンジンの開発段階における 1 次元および 3 次元シミュレーションにおいて精度の高い正味のエンジン性能予測を行うためには、 $P_{max}$  と  $C_m$  に加えて燃料噴射圧力の変化、燃焼位相および熱発生率に関連する因子も考慮した新たな FMEP の予測手法が必要であると考えられる。そこで、本研究は新たな FMEP の予測手法として、機械学習のひとつであるニューラルネットワークの適用を試みた。近年、エンジン性能や排気性能の予測にニューラルネットワークの利用が試みられており<sup>(2)(3)</sup>、今後もエンジンの研究・開発における様々な領域に適用されていくと考えられる。本研究では、大型単気筒ディーゼルエンジンの様々な運転条件における実験から得られた FMEP や燃焼状態に関する実験結果を教師データとして、ニューラルネットワークで FMEP に関する機械学習を行った。その後、機械学習を行ったニューラルネットワークにより FMEP の予測を試みたので、その予測結果について報告する。また本研究では、FMEP を予測するための学習済みのニューラルネットワークモデルと 1 次元エンジン性能計算ツール (GT-POWER) を用いて、圧縮比や等容度などの因子が FMEP および図示平均有効圧力 (IMEP) に及ぼす傾向について品質工学により検討を行ったので、この検討結果についても報告する。

## 2. 実験装置

### 2.1. 研究用大型単気筒エンジン

ニューラルネットワークにおける機械学習用のデータは、研究用の大型単気筒ディーゼルエンジンの実験結果を使用した。表 1 は大型単気筒ディーゼルエンジンの主要諸元を示す。本実験エンジンはデジタル可変バルブ<sup>(4)</sup>を装着し、吸排気バルブの開閉時期を任意に変化することができる。燃料噴射システムはコモンレール方式である。また、大型単気筒エンジンにおける過給は、エンジンから独立したモータ駆動の外部過給機を使用し、吸気圧力と排気圧力をそれぞれ独立に設定することができる。エンジン性能実験は、モータ駆動の外部過給機によるプラスのポンプ仕事を失くすため、吸気圧力と排気圧力を同じ圧力まで高めた条件で実施している。これらの実験における冷却水温度は  $80 \pm 2^\circ\text{C}$  に制御されている。

### 2.2. 動力計測装置

大型単気筒エンジンにおける機関速度およびエンジントルクは、明電舎製の動力計で計測した。また、燃焼解析には小野測器製の DS-2000 シリーズを、そして筒内圧ピックアップはキスラー社製水冷 Type6043A を使用した。

### 2.3. 供試燃料と潤滑油

供試燃料は低硫黄分の軽油（JIS2号，S分5ppm）を使用した。また，潤滑油は低サルファエンジンオイル（SAE10W30）を使用した。

### 2.4. FMEPの算出方法

FMEPは動力計により計測されたエンジントルクから正味平均有効圧力(BMEP)を求め，指圧線図の計測結果から求めた図示平均有効圧力(IMEP)およびポンピング平均有効圧力(PMEP)より式(1)から求めた。

$$\text{FMEP} = \text{IMEP} + \text{PMEP} - \text{BMEP} \quad (1)$$

Table 1 Engine specifications

Item	Specifications
Engine type	DI single cyl. 4 valve
Displacement	cm <sup>3</sup> 2004
Bore x Stroke	mm 135x140
Max. engine speed	rpm 2000
Injection system	Engine driven common rail system
Piston material	Steel (Monotherm)
Aspiration	Externally supercharged
EGR system	High pressure loop

### 3. 機械学習に用いる実験データの取得条件について

本研究は FMEP の予測を目的として，ニューラルネットワークにて機械学習を行う。機械学習に使用する教師データは前述したように，大型単気筒ディーゼルエンジンの実験結果を用いる。機械学習における教師データおよび検証用データとして使用する実験データの総数は 5227 点である。これらの実験データは図 1 に示す運転条件において取得されたものである。図 1 における円のサイズは実験データ数を示しており，本研究の機械学習に使用する実験データの多くは大型商用車において運転頻度の高い機関速度  $N_e=1000\sim 1200\text{rpm}$  の中負荷および高負荷条件において取得されたものである。

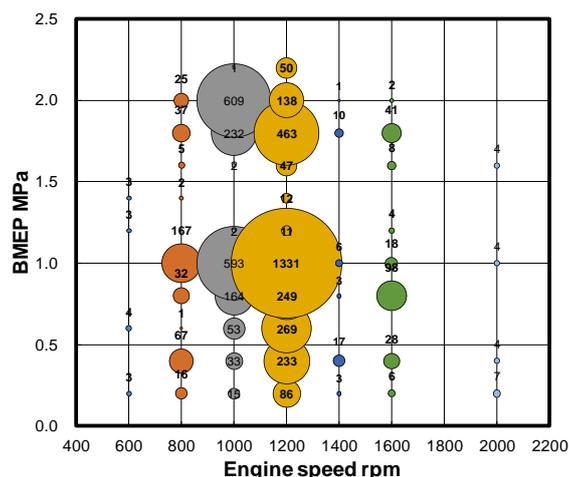


Fig. 1 Operating conditions of experimental data

### 4. 重回帰分析による FMEP に影響する因子の特定

前述したように，従来から広く利用されている Chen-Flynn による FMEP の予測モデルは筒内最高圧力 ( $P_{\max}$ ) および平均ピストン速度 ( $C_m$ ) のみが FMEP に対し強く影響する因子として考慮されており，燃焼位相や熱発生率に関する因子などが FMEP に及ぼす影響については深く検討されてこ

かった。このため、本章ではニューラルネットワークによる FMEP の予測モデル構築に先立ち、 $P_{max}$  や  $C_m$  以外に FMEP に強く影響している因子について大型単気筒エンジンの 5227 点の実験結果を用いて重回帰分析により検討した。

#### 4.1. 重回帰分析の対象とする因子について

ここでの重回帰分析では、FMEP を目的変数とし下記の 11 因子を説明変数とした。これらの説明変数は、重回帰分析において変数間の多重共線性が生じないように考慮し選定を行った。表 2 は 5227 点の実験結果における FMEP および説明変数に設定した 11 因子の最大値、最小値、平均値および標準偏差を示す。

- ・ 平均ピストン速度  $C_m$  [m/s]
- ・ 圧縮比  $\varepsilon$
- ・ 有効圧縮比  $\varepsilon_{effec}$
- ・ 膨張行程中の圧力上昇率の最大値 [kPa/deg.]
- ・ 膨張行程中の圧力上昇率の最大となるクランク角 [deg. ATDC]
- ・ 質量燃焼割合 30% MFB30 [deg. ATDC]
- ・ 燃料噴射圧力  $P_{inj}$  [MPa]
- ・ 筒内最高圧力  $P_{max}$  [MPa]
- ・ 筒内圧力が最大時となるときのクランク角 [deg. ATDC]
- ・ 潤滑油温度  $T_{oil}$  [°C]
- ・ 等容度  $\eta_{gl}$

本章における重回帰分析では、FMEP への影響度を検討する説明変数の全てに標準化処理を実施した。これは、重回帰分析後に求められる各因子の標準偏回帰係数を用い、各因子の FMEP への影響度を直接比較するためである。各因子の標準化は式(2)にて行った。ここで、 $\mu$  は各因子の平均値、 $\sigma$  は各因子の標準偏差である。

$$Z = \frac{x - \mu}{\sigma} \quad (2)$$

Table 2 Range of objective variable and explanatory variable in multiple regression analysis

< Objective variable >

	Maximum	Minimum	Average	Standard deviation
Friction mean effective pressure FMEP kPa	448.1	91.0	254.2	60.326

< Explanatory variable >

	Maximum	Minimum	Average	Standard deviation
Mean piston speed $C_m$ m/s	9.3	2.8	5.3	0.784
Compression ratio	30.0	14.0	20.5	3.418
Effective compression ratio	30.0	7.6	17.6	3.605
Max dP/dθ in expansion stroke kPa/deg.	2006.3	6.4	745.6	361.891
Crank angle at Max.dP/dθ in expansion stroke deg. ATDC	355.00	0.00	4.31	8.492
Mass fraction burned 30% MFB30 deg. ATDC	16.75	-7.75	5.49	3.246
Fuel injection pressure $P_{inj}$ MPa	306.2	81.0	190.8	32.101
Maximum in-cylinder pressure $P_{max}$ MPa	31.0	5.7	17.9	6.382
Crank angle at maximum in-cylinder pressure deg. ATDC	20.25	-0.25	8.60	3.085
Lubricant oil temperature $T_{oil}$ °C	91.4	59.3	79.7	1.625
Degree of constant volume $\eta_{gl}$	100.0	80.0	95.2	2.755

#### 4.2. 重回帰分析の結果について

本章における重回帰分析の結果，自由度調整済み決定係数は  $R^2=0.771$  であり，おおむね適合度の高い重回帰式を得ることができた．また，表 3 は重回帰分析の結果一覧（標準偏回帰係数，T 値の絶対値，p 値および分散拡大要因）を示す．各説明変数の分散拡大要因（VIF）は， $VIF<5.0$  であり，本章での重回帰分析においては変数間の多重共線性を回避できていると考えられる．

図 2 および図 3 は重回帰分析における各説明変数の標準偏回帰係数と T 値の絶対値を示す．重回帰分析における標準偏回帰係数と T 値の絶対値の結果から，筒内最高圧力と平均ピストン速度の標準偏回帰係数および T 値の絶対値は他の因子と比較し大きく，FMEP に対して強く影響を及ぼす因子であり，Chen-Flynn の FMEP 予測モデルにおいて代表的な因子として考慮されている妥当性を確認することができる．その一方で，圧縮比，燃料噴射圧力，筒内最高圧力が最大となる時のクランク角および等容度の標準偏回帰係数と T 値の絶対値は無視できるほど小さくはなく，これらの因子も FMEP に対して影響していることが示唆されている．この重回帰分析による結果は，筒内最高圧力や平均ピストン速度に加えてこれらの因子が FMEP 予測モデルに考慮される必要があることを示している．また，ここでの重回帰分析の結果，有効圧縮比，膨張行程中の圧力上昇率の最大値，膨張行程中の圧力上昇率の最大となるクランク角および MFB30 の標準偏回帰係数と T 値は小さく，これらの因子が FMEP に対する影響は小さいと考えられる．ここでの解析において，潤滑油温度の標準偏回帰係数と T 値の絶対値が小さく，潤滑油温度が FMEP に及ぼす影響度は小さくなっている．これは，重回帰分析に使用した 5227 点の実験データのほとんどが潤滑油温度  $T_{oil}=80\pm 2^{\circ}\text{C}$  に温度コントロールされた条件で取得されていることから，FMEP への影響度が小さいと分析されている．

Table 3 Result of multiple regression analysis

	Standard partial regression coefficient	Absolute value of T-value	p-value	Variance inflation factor VIF
Mean piston speed $C_m$	0.228	27.2	0.00	1.600
Compression ratio	-0.079	8.8	0.00	1.840
Effective compression ratio	-0.009	1.0	0.31	1.668
Max dP/d $\theta$ in expansion stroke kPa/deg.	-0.009	0.8	0.43	2.624
Crank angle at Max.dP/d $\theta$ in expansion stroke	0.007	1.0	0.30	1.133
Mass fraction burned 30% MFB30	0.018	1.3	0.21	4.615
Fuel injection pressure $P_{inj}$	0.075	9.4	0.00	1.435
Maximum in-cylinder pressure $P_{max}$	0.763	90.3	0.00	1.628
Crank angle at maximum in-cylinder pressure	0.141	17.2	0.00	1.552
Lubricant oil temperature $T_{oil}$	-0.007	1.0	0.34	1.150
Degree of constant volume $\eta_{gl}$	-0.170	13.7	0.00	3.508

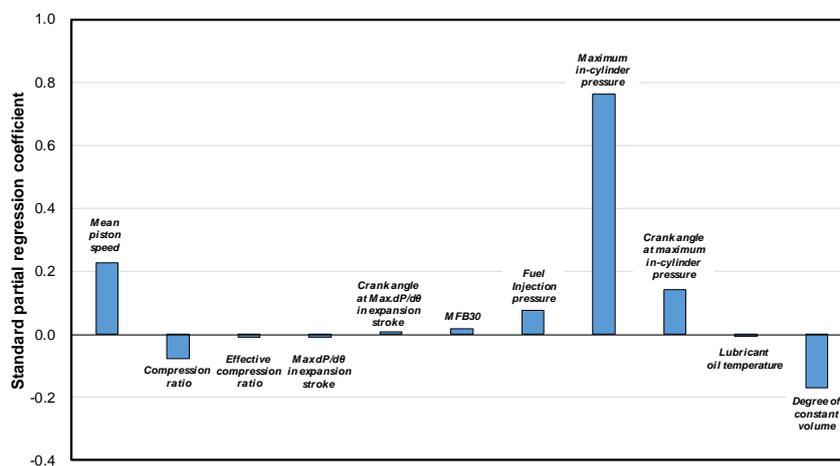


Fig. 2 Result of standard partial regression coefficient

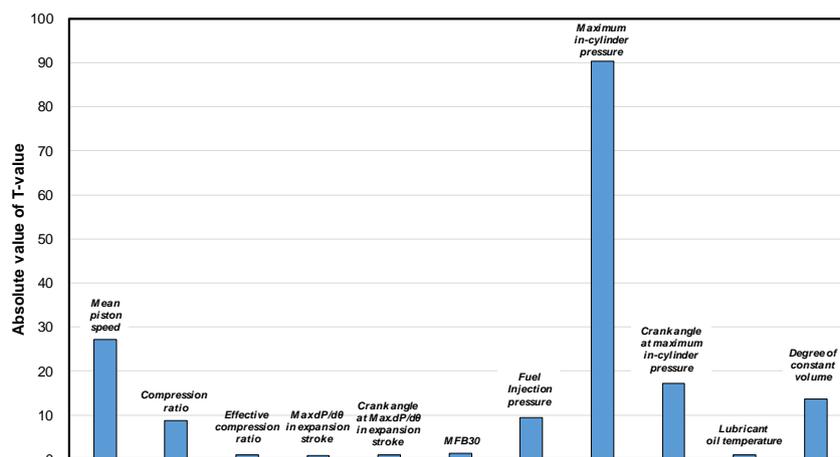


Fig. 3 Result of absolute value of T-value

## 5. ニューラルネットワークについて

ニューラルネットワークとは、人間の脳内における神経細胞の回路網を人工ニューロンという数式モデルで表現したものであり、機械学習の手法のひとつである。図4はニューラルネットワークの構造を示す。ニューラルネットワークは人間の脳の階層構造を模しており、入力層、隠れ層、出力層という3つの層から成り立っている。隠れ層は統計的な処理を行うだけでなく、未だ認識されていないパラメータ間の相互作用なども予測機能として取り込むことができるという特徴がある。ニューラルネットワークによる機械学習は、教師データ(正解)の入力によって問題を最適化していく教師あり学習と教師データを必要としない教師なし学習に分類される。本研究におけるニューラルネットワークを用いた FMEP の予測は、教師あり学習を試みており、大型単気筒ディーゼルエンジンの実験により得られたデータを教師データとして利用する。

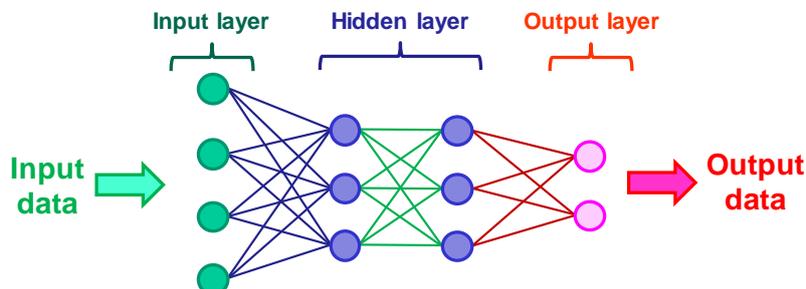


Fig. 4 Structure of neural network

## 6. FMEP 予測のためのニューラルネットワークモデル

### 6.1. ニューラルネットワークモデルと機械学習条件

本研究におけるニューラルネットワークモデルの構築は Neural network console(5)で行った。図5は構築したニューラルネットワークモデルの概要を示す。構築したニューラルネットワークモデルは4層の隠れ層を有し、入力層への入力項目は、後述する17項目の実験結果である。モデル中における Affine は、入力層からすべての出力ニューロンへの結合を持つ全結合層である。本研究において構築したニューラルネットワークモデルは過学習の抑制を目的として PReLU (Parametric Rectified Linear Unit)<sup>(6)</sup>を活性化関数として用いた。PReLU とは、入力値が 0 以上の場合、出力値は入力値と同じ値となり、入力値が 0 以下の場合には出力値が入力値を  $\alpha$  倍した値を出力する関数である。このとき、 $\alpha$  は機械学習時に誤差逆伝播法により学習を行って決められる。また、本モデルでは機械学習の安定性と学習の進行を早めるために、BatchNormalization<sup>(7)</sup>を全結合層の Affine と活性化関数 PReLU の間に挿入している。BatchNormalization とは入力値を平均 0、分散 1 に正規化することであり、学習の収束を早める効果がある。さらに、本モデルは、機械学習後のニューラルネットワークモデルの汎用性能を向上させるために Dropout<sup>(8)</sup>を適用している。Dropout とは隠れ層のニューロンを任意の割合で不

活性化することで過学習を抑制する手法である。本研究では 50%の割合で隠れ層のニューロンを不活性化させた。本研究におけるニューラルネットワークモデルは FMEP を予測するための回帰モデルであることから、出力層は二乗誤差(Squareerror)を用いた。

本研究のニューラルネットワークにおける機械学習では Batch size と Epoch を設定する必要がある。機械学習では教師データをサブセットとして分け、教師データ内の異常値による学習への影響を小さくする手法が採られている。Batch size とはサブセットのデータ数である。本研究の機械学習における Batch size は 128 とした。Epoch とは、教師データを Batch size に従って分けられた各サブセットを学習する手法である。全てのサブセットの学習が 1 回実行されることを 1 Epoch と呼び、本研究の機械学習における Epoch は 1400 とした。

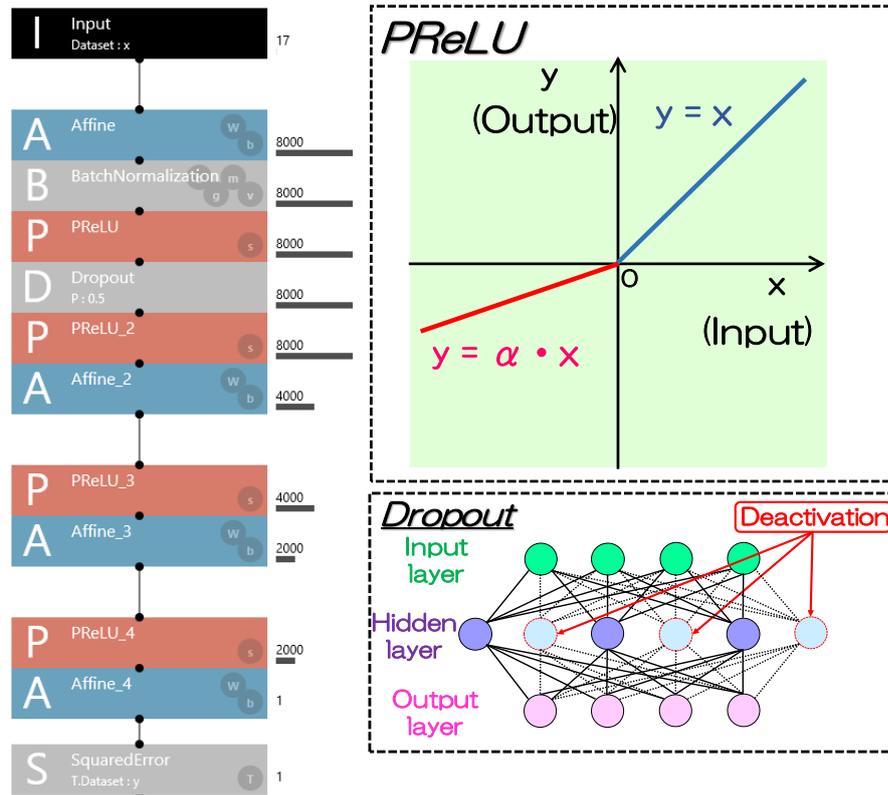


Fig. 5 Overview of neural network model for the FMEP prediction

## 6.2. 機械学習における教師データの項目について

ニューラルネットワークでの機械学習における教師データの項目は、Chen-Flynn のモデルでも考慮されている筒内最高圧力( $P_{max}$ )と平均ピストン速度( $C_m$ )に加えて、図 6 および表 4 に示すように燃料噴射圧力( $P_{inj}$ )、 $P_{max}$  が最大となる時のクランク角、潤滑油温度( $T_{oil}$ )、等容度( $\eta_{gl}$ )、圧縮比 ( $\epsilon$ )、有効圧縮比 ( $\epsilon_{effec}$ )、MFB10~MFB90 などの 17 項目である。

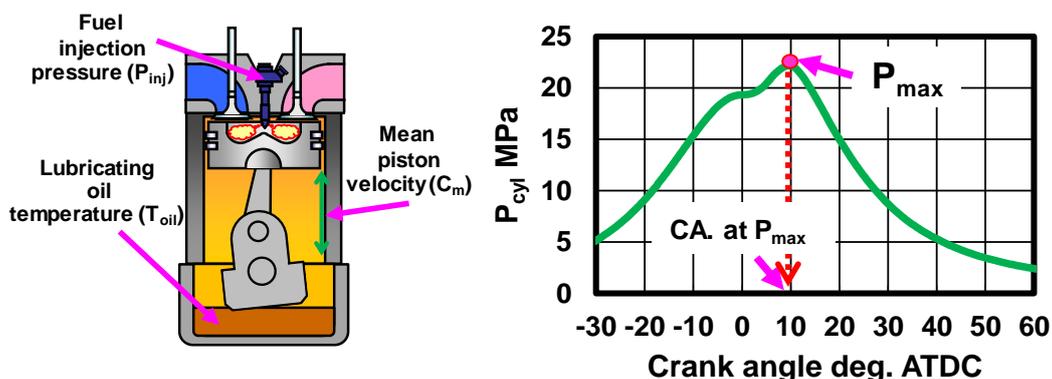


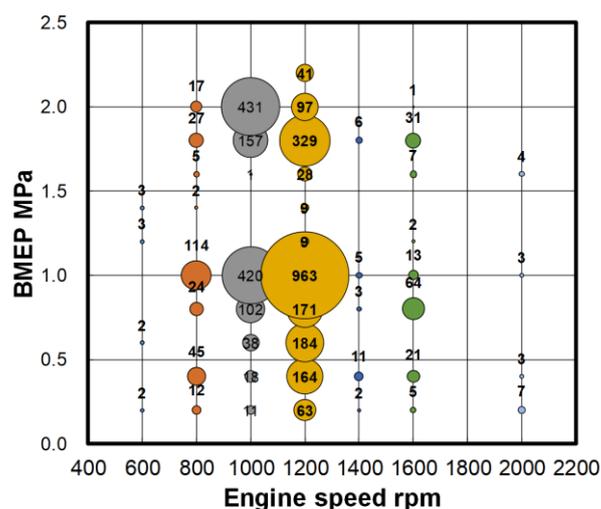
Fig. 6 Input items in machine learning

Table 4 The range of training data and validation data in machine learning

	Training data		Validation data	
	Minimum value	Maximum value	Minimum value	Maximum value
Mean piston speed ( $C_m$ ) m/s	2.8	9.3	2.8	9.3
Fuel injection pressure ( $P_{inj}$ ) MPa	81.0	306.2	87.3	306.0
Lubricating oil temperature ( $T_{oil}$ ) °C	59.3	91.4	59.6	90.6
Maximum in-cylinder pressure ( $P_{max}$ ) MPa	5.9	30.8	5.7	31.0
Crank angle at $P_{max}$ deg. ATDC	-0.3	20.3	0.0	18.0
Compression ratio $\epsilon$	14.0	30.0	14.0	30.0
Effective compression ratio $\epsilon_{effec}$	7.6	30.0	7.6	30.0
Degree of constant volume $\eta_{gl}$	80.2	99.9	80.0	100.0
MFB10 deg. ATDC	-10.25	13.75	-9.50	13.00
MFB20 deg. ATDC	-8.25	15.50	-8.75	14.25
MFB30 deg. ATDC	-7.50	16.75	-7.75	16.25
MFB40 deg. ATDC	-6.50	18.00	-6.25	18.00
MFB50 deg. ATDC	-5.25	20.50	-5.00	20.00
MFB60 deg. ATDC	-5.25	23.00	-2.75	22.25
MFB70 deg. ATDC	-5.25	25.50	-1.25	26.50
MFB80 deg. ATDC	-5.25	33.00	1.25	34.75
MFB90 deg. ATDC	-5.25	49.50	1.75	50.50

### 6.3. 教師データおよび検証用データについて

ニューラルネットワークでの機械学習に使用するデータは、前述したように、大型単気筒ディーゼルエンジンの実験結果（データ総数：5227点）である。本研究の機械学習において、これらの実験結果は約7：3の比率で教師データ（3684点）と検証用データ（1543点）に分けて使用した。図7a)および図7b)は教師データと検証用データを取得した際のエンジンの運転条件を示す。図7a)および図7b)が示すように、教師データと検証用データは機関速度と負荷を広範囲に変化させた条件において取得されたものである。また、表4は教師データおよび検証用データの各入力項目におけるレンジ（最大値と最小値）を示す。





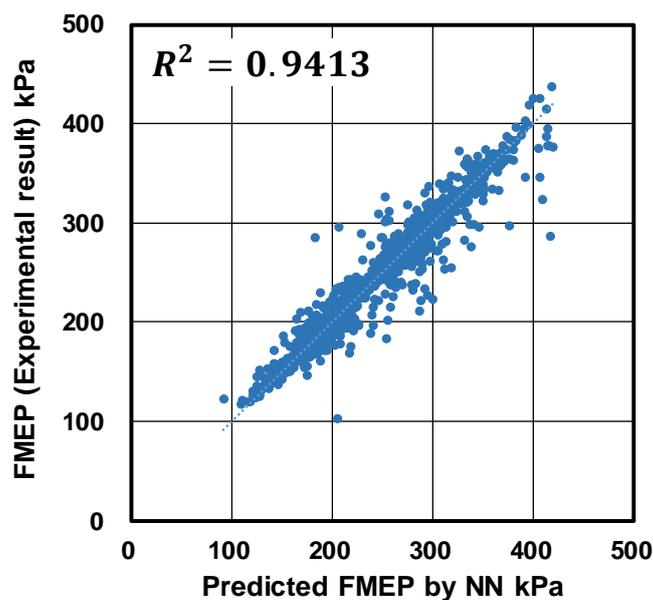


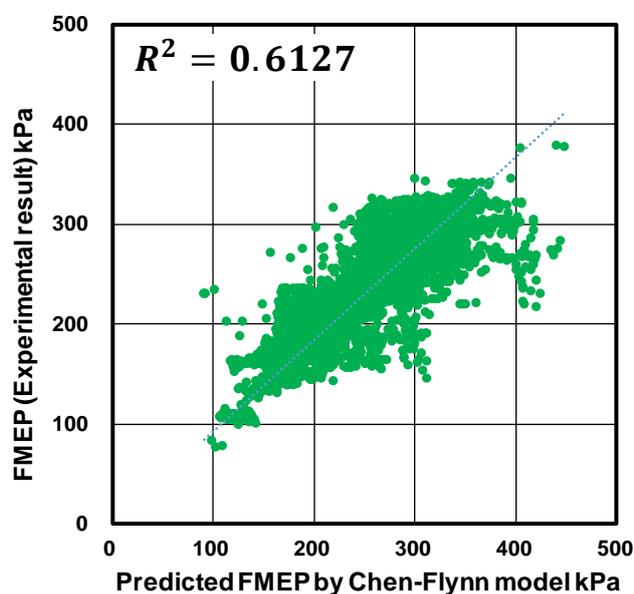
Fig. 9 Correlation of FMEP (exp.) and predicted FMEP by neural network (NN) in validation data

## 7. 学習済みニューラルネットワークによる FMEP の予測

本章は、機械学習を行ったニューラルネットワークによる FMEP の予測結果について述べる。ここでは、機関速度( $N_e$ )と正味平均有効圧力(BMEP), 燃焼開始時期(SOC), 燃料噴射圧力( $P_{inj}$ )を変化させた際の FMEP の実験結果と機械学習済みのニューラルネットワークによる FMEP の予測結果との比較を行った。また、これらの比較には Chen-Flynn モデルによる FMEP<sub>CF</sub> の予測値も比較のため併記した。本研究における Chen-Flynn モデルは式(3)で示され、FMEP<sub>c</sub>, PF, MPSF および MPSSF はモデル定数である。

$$\text{FMEP}_{CF} [\text{kPa}] = \text{FMEP}_c + (\text{PF} \times P_{\max}) + (\text{MPSF} \times C_m) + (\text{MPSSF} \times C_m^2) \quad (3)$$

図 10 は本研究で設定した Chen-Flynn モデルのモデル定数, FMEP の実験結果(5227 点)と Chen-Flynn モデルによる FMEP の予測値との相関と決定係数  $R^2$  を示す。本研究でのモデル定数における Chen-Flynn モデルによる FMEP の予測値と FMEP の実験結果との決定係数は  $R^2=0.6127$  である。



### < Model constant >

- FMEP<sub>c</sub> = -74.0 [kPa]
- PF = 7.73
- MPSF = 39.93 [kPa/(m/s)]
- MPSSF = -1.359 [kPa/(m<sup>2</sup>/s<sup>2</sup>)]

Fig. 10 Correlation of FMEP (exp.) and predicted FMEP by Chen-Flynn model

## 7.1. Ne と BMEP が変化したときの FMEP の予測結果検証

Ne と BMEP が変化したときの FMEP の予測結果の検証は, Ne=600rpm~Ne=2000rpm の条件で行った. 表 5 は実験条件の詳細を示す. BMEP は各機関速度において低負荷から全負荷まで変化させた. また, 燃焼開始時期は全て上死点である. 図 11 は Ne と BMEP を変化させた際の FMEP の実験結果に関するコンターマップである. 図 11 が示すように, FMEP は低速・低負荷領域において小さく, Ne が高速化し且つ BMEP が高くなるにしたがい増大する.

Table 5 Experimental conditions when Ne and BMEP are changed

Ne rpm	BMEP MPa	P <sub>b</sub> kPa (abs.)	ε	P <sub>inj</sub> MPa	IVO deg	IVC deg	EVO deg	EVC deg	SR	Start of combustion deg. ATDC
600	1.312	281.1	16	120	371	540	160	356	0.87	TDC
	1.015	265.3		120						
	0.513	234.7		100						
	0.155	125.2		80						
800	1.602	356.6		200	366	540	160	361		
	1.281	342.1		200						
	0.963	301.5		200						
	0.668	231.0		200						
	0.323	162.1		180						
	0.178	127.5		150						
1200	2.000	398.4		200	362	550	160	366		
	1.606	376.8		200						
	1.213	351.8		200						
	0.798	277.3		200						
	0.400	178.6		180						
	0.198	129.0		150						
1600	1.801	401.9	200	357	574	140	372			
	1.454	361.8								
	1.083	325.9								
	0.726	256.8								
	0.373	171.1								
	0.190	127.0								
2000	1.493	353.5	200	352	580	130	379			
	0.906	312.3								
	0.306	182.8								
	0.150	126.6								

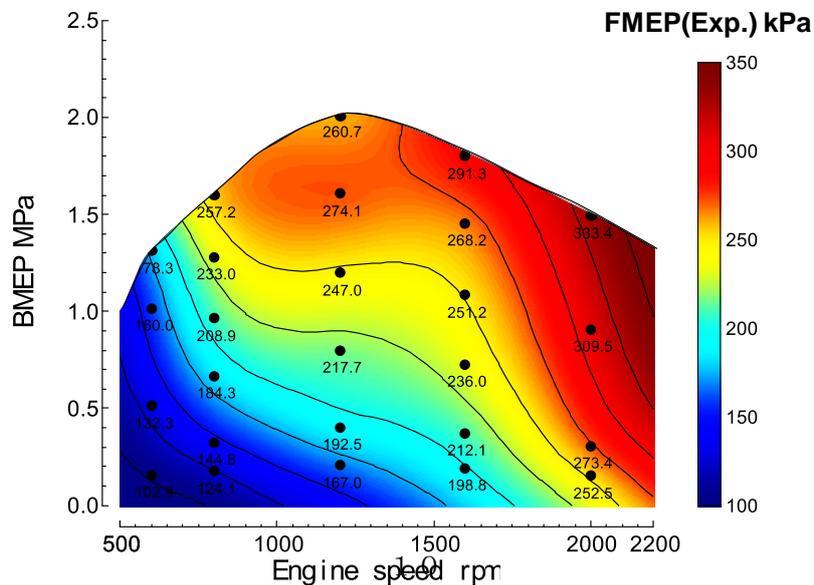


Fig. 11 Contour map of FMEP (exp. result) when Ne and BMEP are varied

図 12 a) は Ne と BMEP が変化したときの学習済みニューラルネットワークによる FMEP の予測結果を示すコンターマップである。学習済みニューラルネットワークモデルは Ne と BMEP が変化した場合の FMEP の実験結果の傾向をおおむね良好に予測している。図 12 b) は FMEP の実験結果と学習済みニューラルネットワークモデルにより予測された FMEP との誤差を示したコンターマップである。学習済みニューラルネットワークモデルの FMEP の予測結果は、Ne=800rpm の高負荷および Ne=1200rpm の軽負荷において FMEP の実験結果に対し誤差の大きい領域が見られるが、Ne と BMEP を広範囲に変化させた FMEP の実験結果に対しおおむね±3%以内の誤差である。

図 13 a) は Ne と BMEP が変化したときの Chen-Flynn モデルによる FMEP の予測結果を示す。また、図 11 b) は FMEP の実験結果に対する、Chen-Flynn モデルによる FMEP の予測値の誤差を示したコンターマップである。Chen-Flynn モデルは Ne と BMEP が高まるにしたがい FMEP が増大するという実験結果の傾向を予測することができている。しかし、図 13 b) に示すように、Chen-Flynn モデルの FMEP 予測結果は、FMEP の実験結果に対し誤差がやや大きい。特に FMEP の実験結果に対する Chen-Flynn モデルによる FMEP の予測値の誤差は Ne が低速および高速条件において 10%以上になっている領域が見られる。以上の結果が示すように、学習済みニューラルネットワークモデルおよび Chen-Flynn モデルともに Ne と BMEP の変化に対する FMEP の傾向を予測することができている。また、学習済みニューラルネットワークモデルは Chen-Flynn モデルよりも FMEP の実験結果をより精度良く予測できることをここでは確認できた。

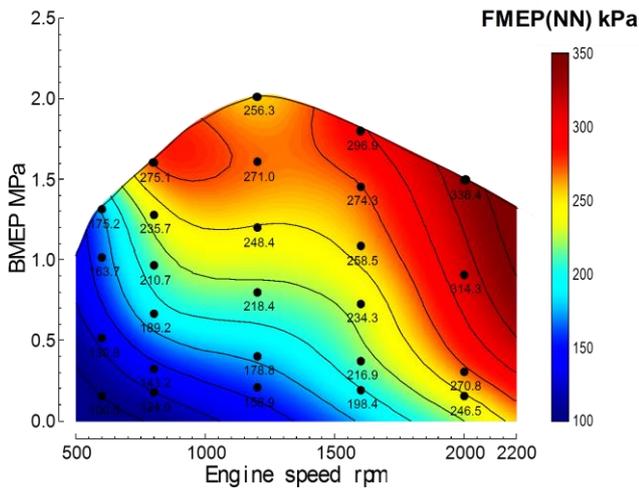


Fig. 12 a) Contour map of predicted FMEP (NN) when Ne and BMEP are varied

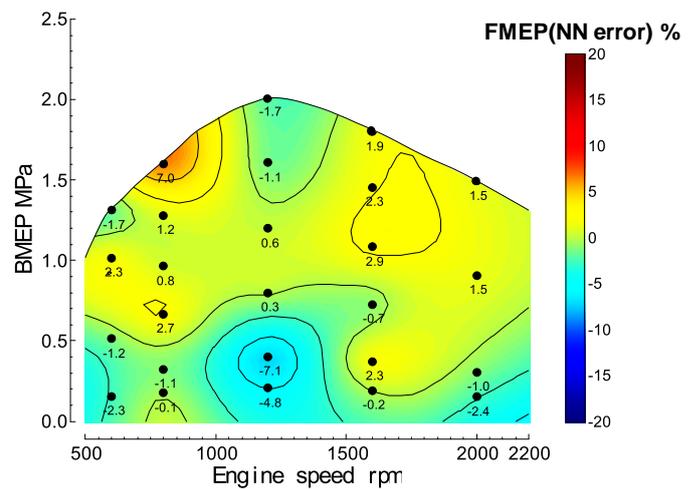


Fig. 12 b) Contour map of error of predicted FMEP (NN) with respect to experimental result of FMEP when Ne and BMEP are varied

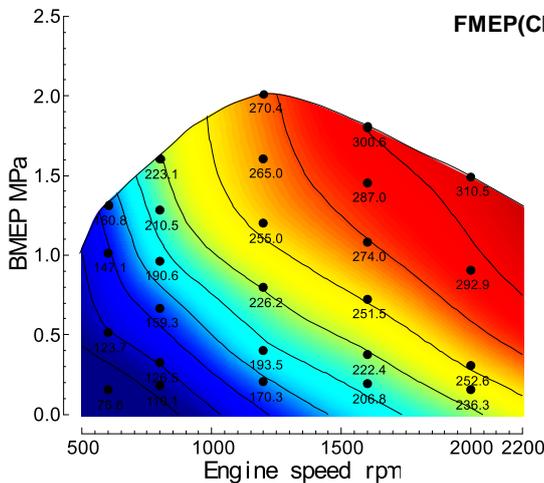


Fig. 13 a) Contour map of predicted FMEP (Chen-Flynn) when Ne and BMEP are varied

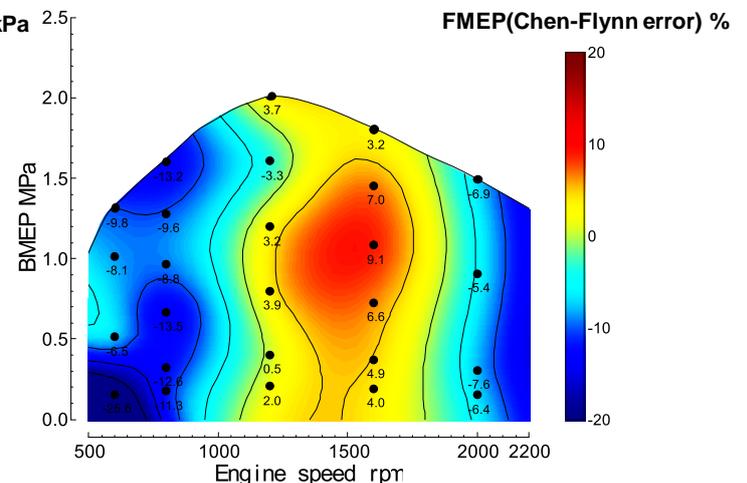


Fig. 13 b) Contour map of error of predicted FMEP (Chen-Flynn) with respect to experimental result of FMEP when Ne and BMEP are varied

## 7.2. 燃焼開始時期(SOC)が変化したときの FMEP の予測結果の検証

SOC が変化したときの FMEP の予測値の検証は  $N_e=1200\text{rpm}$ ,  $BMEP=1.2\text{MPa}$  の条件で行った. 表 6 は実験条件の詳細を示す. SOC は上死点(TDC)から  $-7\text{ deg. ATDC}$  まで  $1\text{ deg.}$  刻みに進角させた. 図 14 は SOC を上死点から  $-7\text{ deg. ATDC}$  に進角させた際の筒内圧力および熱発生率である.  $P_{\max}$  は TDC を起点とした SOC の進角に従い高まっていく.

Table 6 Experimental conditions when SOC is changed

Ne rpm	BMEP MPa	$P_b$ kPa (abs.)	$\epsilon$	$P_{inj}$ MPa	IVO deg	IVC deg	EVO deg	EVC deg	SR	Start of combustion deg. ATDC
1200	1.2	351.3	16	200	362	550	160	366	0.87	$-7 \sim \text{TDC}$

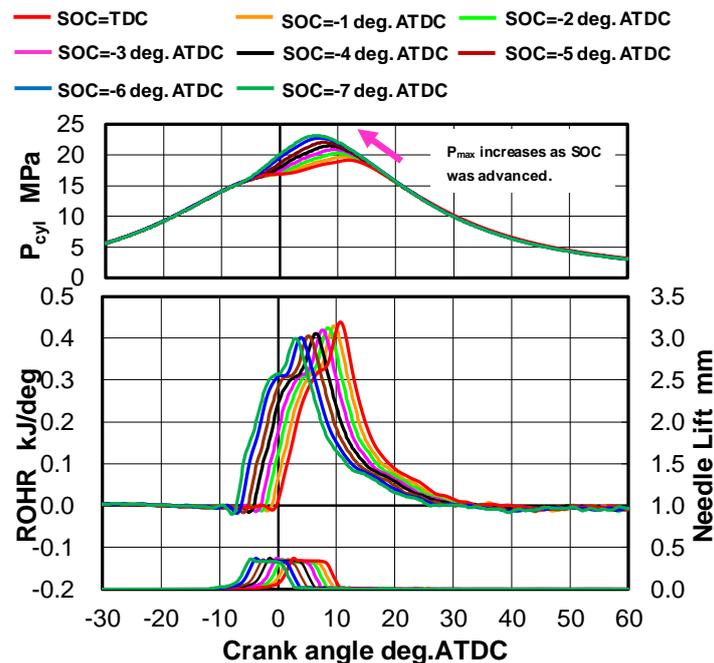


Fig. 14 The effect of SOC on in-cylinder pressure and ROHR

図 15 は横軸に SOC をとり, 縦軸に FMEP の実験結果, 学習済みニューラルネットワークと Chen-Flynn モデルによる FMEP の予測値を示す. FMEP の実験結果は, SOC が TDC を起点として進角し,  $P_{\max}$  が高まっても大きく増加しない傾向である. 学習済みニューラルネットワークによる FMEP の予測値は, SOC を進角させた際の FMEP の実験結果の傾向を概ね捉えることができている. 一方, Chen-Flynn モデルは,  $P_{\max}$  が SOC の進角に伴い増加するため, FMEP が SOC の進角に対し線形に増加すると予測し, 実験結果に対し乖離が生じている.

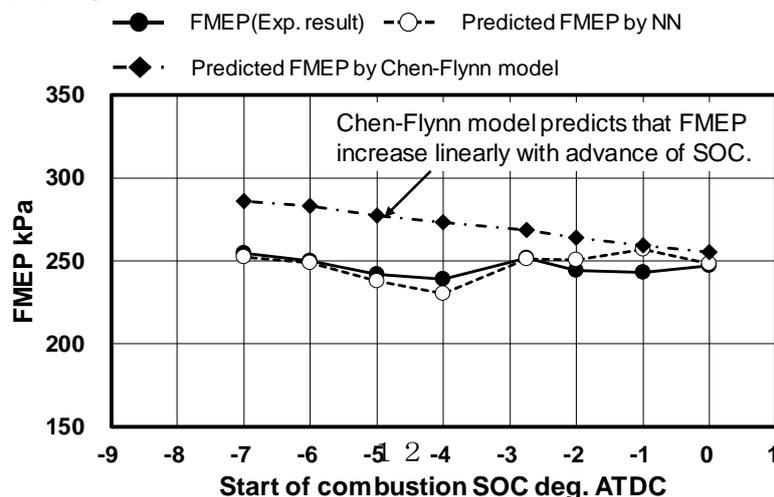


Fig. 15 Comparison of measured FMEP and predicted FMEP by neural network (NN) (SOC=TDC -7 deg. ATDC)

7.3. 燃料噴射圧力( $P_{inj}$ )が変化するときの FMEP の予測結果の検証

$P_{inj}$  が変化するときの FMEP の予測値の検証は  $N_e=1200\text{rpm}$ ,  $BMEP=0.4\text{MPa}$  の条件で行った. 表 7 は実験条件の詳細を示す.  $P_{inj}$  は  $120\text{MPa}$  から  $200\text{MPa}$  の範囲で  $20\text{MPa}$  刻みに変化させた. 図 16 は  $P_{inj}$  を変化させた際の筒内圧力および熱発生率である.  $P_{max}$  および熱発生率のピークは  $P_{inj}$  が増大するに従い微増してはいるが, これらの  $P_{inj}$  の変化に対する顕著な違いは見られない.

Table 7 Experimental conditions when  $P_{inj}$  is changed

Ne rpm	BMEP MPa	$P_b$ kPa (abs.)	$\epsilon$	$P_{inj}$ MPa	IVO deg	IVC deg	EVO deg	EVC deg	SR	Start of combustion deg ATDC
1200	0.4	151.3	16	120~200	359	625	160	369	5.6	TDC

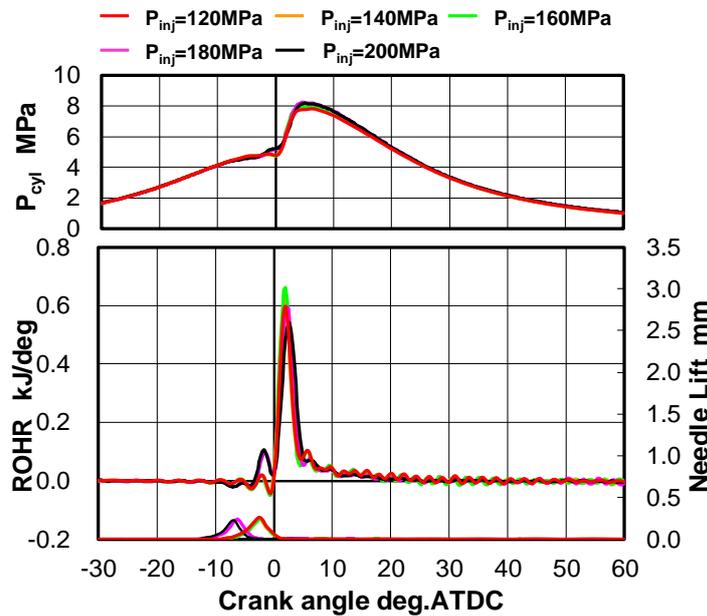


Fig. 16 The effect of  $P_{inj}$  on in-cylinder pressure and ROHR

図 17 は横軸に  $P_{inj}$  をとり, 縦軸に FMEP の実験結果, 学習済みニューラルネットワークと Chen-Flynn モデルによる FMEP の予測値を示す. FMEP の実験結果は  $P_{inj}$  が高まるに従い増加する傾向である. これは  $P_{inj}$  を高めた際にコモンレールシステムにおけるサプライポンプ駆動仕事が増大することに起因している. Chen-Flynn モデルは  $P_{inj}$  の FMEP に対する影響を考慮していないことから,  $P_{inj}$  が変化しても FMEP の予測値は  $167\sim 171\text{kPa}$  の範囲にあり, 実験結果の傾向を捉えることができない. その一方で, 学習済みニューラルネットワークによる FMEP の予測値は,  $P_{inj}$  を高めていった際の FMEP の傾向をよく捉えることができおり,  $P_{inj}$  を変化させた際の FMEP の予測にも十分に適用することができると考えられる.

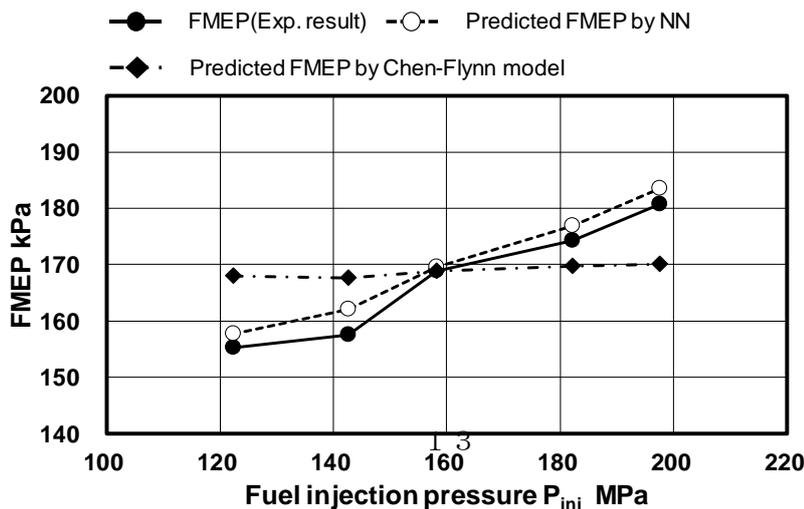


Fig. 17 The comparison of measured FMEP and predicted FMEP by neural network (NN) ( $P_{inj}=120-200$  MPa)  
 8. 品質工学による FMEP と IMEP に関するパラメータ検討

前章において、大型単気筒ディーゼルエンジンの実験結果を教師データとして FMEP を予測するために機械学習を行ったニューラルネットワークモデルは、正味平均有効圧力、機関速度、燃焼開始時期および燃料噴射圧力が変化した際の FMEP を概ね予測可能であることを示した。そこで、本章では機械学習の入力項目としても考慮した圧縮比 ( $\epsilon$ )、有効圧縮比 ( $\epsilon_{effec}$ )、筒内最高圧力が最大となる時のクランク角 ( $CA.@P_{max}$ ) および等容度 ( $\eta_{gl}$ ) が FMEP に及ぼす傾向について学習済みニューラルネットワークモデルと GT-POWER により構築した大型単気筒ディーゼルエンジンの性能予測モデルを用いて品質工学により検討したので、その結果について述べる。この品質工学によるパラメータ検討では、筒内最高圧力 ( $P_{max}$ ) を誤差因子として取り上げ、 $P_{max}$  の変動に対し、FMEP のバラツキを抑制しロバスト性を高めていくためには、上記 4 つのパラメータをどのように適正化していくべきかという指針を得ることを目的としている。また、ここでは  $P_{max}$  の変動に対し、図示平均有効圧力 (IMEP) のロバスト性を高めるための上記 4 つのパラメータの適正化に関しても検討を行ったので、この結果についても併せて述べる。

### 8.1. 計算条件および各パラメータの水準と直交表への割り付け

本章におけるエンジンの性能計算は、機関速度  $Ne=1000$ rpm、燃料噴射量  $q=240$ mm<sup>3</sup>/st の条件で実施した。表 8 は計算条件の詳細を示す。品質工学を利用したパラメータ検討は L9 直交表を用いた。L9 著公表において、 $\epsilon$ 、 $\epsilon_{effec}$ 、 $CA.@P_{max}$  および  $\eta_{gl}$  を制御因子に設定している。表 9 は各制御因子の水準を示す。また、表 10 は各制御因子の水準を L9 直交表に割り振ったものを示す。上述したように、本章のパラメータ検討では筒内最高圧力 ( $P_{max}$ ) を誤差因子として取り上げている。誤差因子である筒内最高圧力は、 $P_{max}=25, 27, 29$ MPa の 3 水準とし、L9 直交表の外側に割り付けている。この品質工学を用いたパラメータ検討における S/N 比は、FMEP に対しては望小特性で評価し、IMEP に対しては望大特性で評価を行った。

Table 8 Calculation condition

Ne	q	$P_{inj}$	Intake temperature	EGR rate
rpm	mm <sup>3</sup> /st	MPa	°C	%
1000	240	200	50	0

Table 9 Control factor and its level

Control factor	Level		
	1	2	3
A $\epsilon$	18	22	26
B $\epsilon_{effec}$	14	16	18
C $CA@P_{max}$ [deg. ATDC]	7	12	17
D $\eta_{gl}$	91	93	95

Table 10 L9 orthogonal array

Test No.	A	B	C	D	$P_{max}$ =25MPa	$P_{max}$ =27MPa	$P_{max}$ =29MPa
	$\epsilon$	$\epsilon_{effec}$	$CA@P_{max}$	$\eta_{gl}$			
1	18	14	7	91			
2	18	16	12	93			
3	18	18	17	95			
4	22	14	12	95			
5	22	16	17	91			
6	22	18	7	93			
7	26	14	17	93			
8	26	16	7	95			
9	26	18	12	91			

## 8.2. シミュレーション手法について

図 18 は表 10 に示した L9 直交表における各テストの各制御因子の水準に対応するよう調整を行った熱発生率プロファイルである。この正規化された熱発生率プロファイルは Wiebe 関数を用いて調整を行った。(Wiebe 関数を用いた熱発生率プロファイルの調整に関する概要は付録 B に記載。) 大型単気筒ディーゼルエンジンの性能計算は、前述したように 1 次元エンジン性能予測ルールである GT-POWER を用いて行った。図 19 は GT-POWER により作成した大型単気筒ディーゼルエンジンモデルを示す。この大型単気筒ディーゼルエンジンモデルにおける燃焼モデルは GT-POWER 内の燃焼モデルである [Comb-prof] を使用しており、図 18 に示す正規化された熱発生率プロファイルを入力条件として与えている。熱損失のモデルは Woschni の熱伝達モデルを用いている。また、ここでのエンジン性能計算における FMEP は学習済みニューラルネットワークモデルから求めている。本章における品質工学を用いたパラメータ検討では、前述したように  $P_{max}$  を誤差因子として変化させているが、これは GT-POWER によるエンジン性能モデルにおいて過給圧を変化させることで調整を行った。

(本報告で使用した大型単気筒ディーゼルエンジンモデル大型単気筒ディーゼルエンジンの実験結果をベースにモデル定数のキャリブレーションを実施している。キャリブレーション結果の概要は付録 A に記載。)

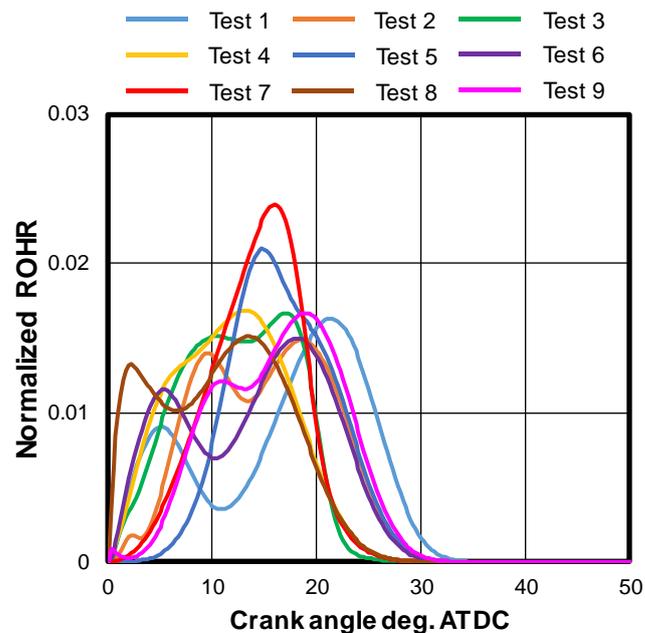


Fig.18 Normalized ROHR profile in quality engineering

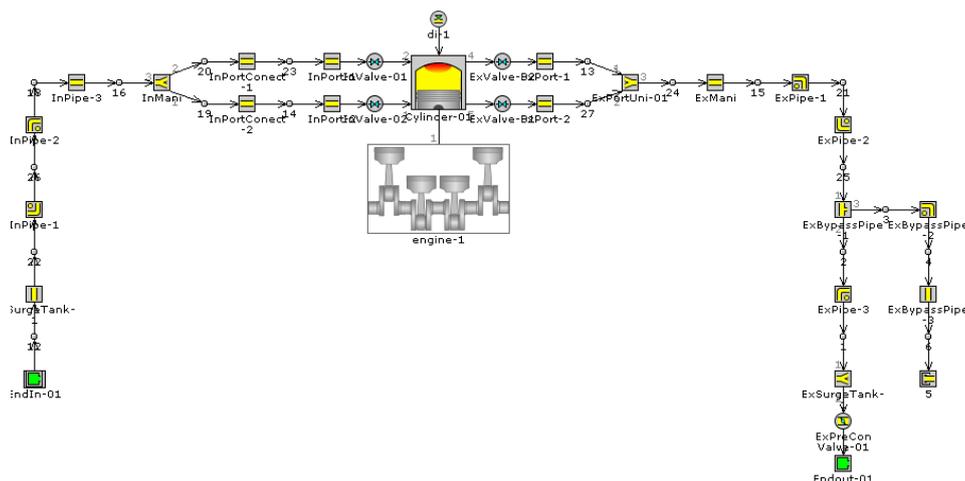


Fig. 19 Single cylinder diesel engine 1D-simulation model by GT-POWER

8.3. FMEP に関するパラメータ検討結果

表 11 および表 12 は L9 直交表の条件における学習済みのニューラルネットワークによる FMEP の予測結果と S/N 比の結果である。また、図 20 は L9 直交表における各制御因子の FMEP に関する要因効果図である。図 20 の要因効果図から、 $P_{max}$  の変動に対する FMEP のロバスト性は  $\epsilon$  と  $\eta_{gl}$  を増加させていくに従い高まる傾向である。有効圧縮比は  $\epsilon_{effec}=16$ 、 $P_{max}$  が最大となるクランク角は CA. @ $P_{max}=12deg. ATDC$  で S/N 比が最も高くなる条件となっている。以上の結果から、 $P_{max}$  の変動に対して、FMEP が高いロバスト性を有することができる制御因子の組み合わせは表 13 に示す条件となる。

Table 11 Calculation result of FMEP and S/N ratio

Test No.	A	B	C	D	$P_{max}$ =25MPa	$P_{max}$ =27MPa	$P_{max}$ =29MPa	S/N ratio
	$\epsilon$	$\epsilon_{effec}$	CA@Pmax	$\eta_{gl}$				
1	18	14	7	91	320.9	346.3	360.5	-50.71
2	18	16	12	93	295.6	309.8	326.4	-49.85
3	18	18	17	95	335.0	336.6	331.9	-50.49
4	22	14	12	95	291.4	298.6	306.5	-49.51
5	22	16	17	91	322.2	321.0	323.6	-50.16
6	22	18	7	93	298.8	304.7	313.5	-49.71
7	26	14	17	93	321.2	320.9	321.2	-50.13
8	26	16	7	95	289.0	297.3	304.8	-49.46
9	26	18	12	91	288.1	295.1	295.8	-49.34

Table 12 S/N ratio for each level of each parameter

Control factor	Level			S/N ratio		
	1	2	3	1	2	3
A $\epsilon$	18	22	26	-50.35	-49.79	-49.64
B $\epsilon_{effec}$	14	16	18	-50.12	-49.82	-49.84
C CA@Pmax [deg. ATDC]	7	12	17	-49.96	-49.57	-50.26
D $\eta_{gl}$	91	93	95	-50.07	-49.90	-49.82

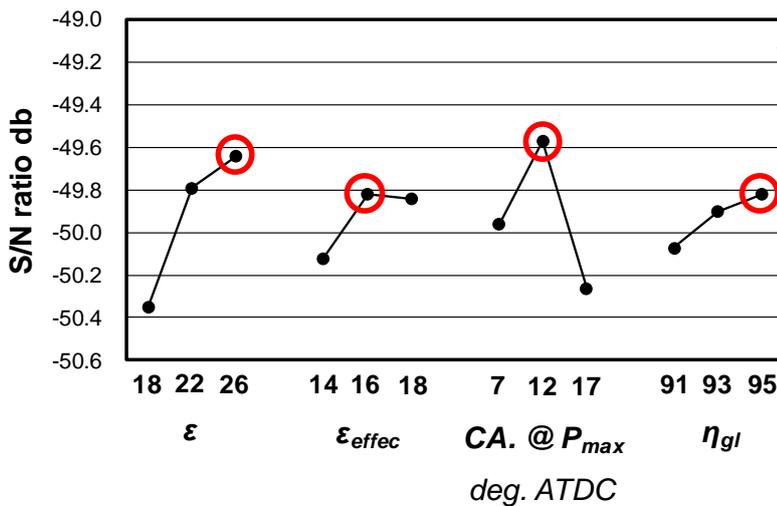


Fig.20 Graph of factorial effects for FMEP

Table 13 Optimum condition for FMEP

Control factor		
A	$\epsilon$	26
B	$\epsilon_{effec}$	16
C	CA@Pmax [deg. ATDC]	12
D	$\eta_{gl}$	95

8.4. IMEP に関するパラメータ検討結果

前節では  $P_{max}$  の変動に対して FMEP のロバスト性が高くなるような制御因子の適正化について示したが、FMEP のロバスト性を高めるための制御因子の適正化が、IMEP を低下させる方向に作用してしまった場合、結果としてエンジンの正味熱効率を低下させることに繋がることも考えられる。このため、ここでは、 $P_{max}$  の変動に対し IMEP のロバスト性を高めるための  $\epsilon$ 、 $\epsilon_{effec}$ 、CA. @  $P_{max}$  および  $\eta_{gl}$  の適正化の傾向に関する結果について述べる。

表 14 および表 15 は L9 直交表における各制御因子の水準に対応するよう調整を行った熱発生率プロファイルを用いて、GT-POWER で計算して求めた IMEP の予測結果と S/N 比の結果である。また、図 21 は L9 直交表における各制御因子の IMEP に関する要因効果図である。図 21 の要因効果図から、 $P_{max}$  の変動に対する IMEP のロバスト性は  $\eta_{gl}$  を増加するほど高まる傾向であり、 $P_{max}$  の変動に対し IMEP と FMEP のロバスト性を高めるための  $\eta_{gl}$  の適正化の方向性は同じである。また、 $P_{max}$  が最大となるクランク角の適正值は CA. @ $P_{max}=12deg. ATDC$  であり、これも FMEP の場合と同様の考え方で適正化ができることを示している。これらの結果は、 $P_{max}$  の変動に対し IMEP と FMEP のロバスト

性を高めるための  $\eta_{gl}$  と  $P_{max}$  が最大となるクランク角の適正化に対して、等容度と  $P_{max}$  が最大となるクランク角との間にトレードオフなく、共通した考え方でできることを示している。圧縮比の適正值は  $\varepsilon=22$ 、有効圧縮比の適正值は  $\varepsilon_{effec}=18$  であった。この結果は、 $P_{max}$  の変動に対して IMEP に高いロバスト性を有するためには、 $\varepsilon$  に対して  $\varepsilon_{effec}$  を過度に低くしない方が良いことを示唆している。以上の結果から、 $P_{max}$  の変動に対して、IMEP の高いロバスト性を得ることができる各制御因子の組み合わせは表 16 に示す条件となる。

Table 14 Calculation result of IMEP and S/N ratio

Test No.	A	B	C	D	$P_{max}$ =25MPa	$P_{max}$ =27MPa	$P_{max}$ =29MPa	S/N ratio
	$\varepsilon$	$\varepsilon_{effec}$	CA@Pmax	$\eta_{gl}$				
1	18	14	7	91	2210.8	2220.7	2228.9	66.93
2	18	16	12	93	2262.2	2273.0	2281.9	67.13
3	18	18	17	95	2290.3	2305.8	2318.1	67.25
4	22	14	12	95	2301.4	2326.2	2344.7	67.32
5	22	16	17	91	2257.5	2269.5	2279.4	67.12
6	22	18	7	93	2281.4	2299.0	2313.4	67.23
7	26	14	17	93	2275.2	2284.7	2292.3	67.17
8	26	16	7	95	2300.6	2321.8	2339.2	67.31
9	26	18	12	91	2262.6	2277.4	2290.2	67.15

Table 15 S/N ratio for each level of each parameter

Control factor	Level			S/N ratio		
	1	2	3	1	2	3
A $\varepsilon$	18	22	26	67.10	67.22	67.21
B $\varepsilon_{effec}$	14	16	18	67.14	67.19	67.21
C CA@Pmax [deg. ATDC]	7	12	17	67.15	67.20	67.18
D $\eta_{gl}$	91	93	95	67.06	67.18	67.30

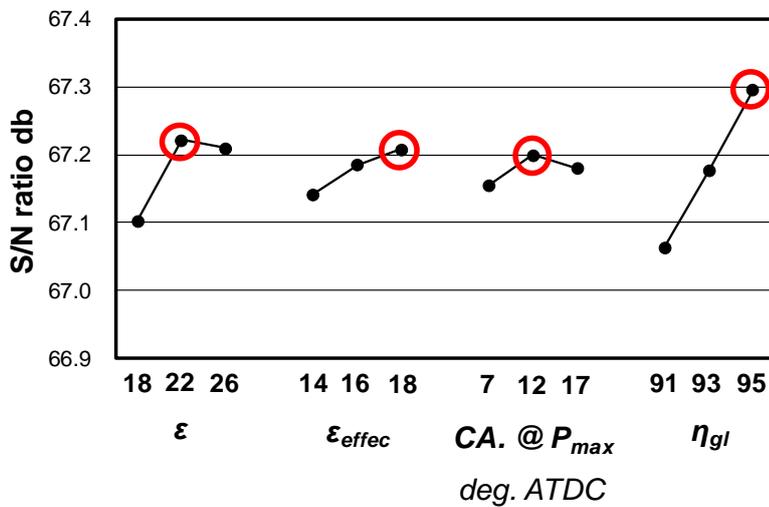


Table 16 Optimum condition for IMEP

Control factor		
A	$\varepsilon$	22
B	$\varepsilon_{effec}$	18
C	CA@Pmax [deg. ATDC]	12
D	$\eta_{gl}$	95

Fig.21 Graph of factorial effects for IMEP

### 8.5. 制御因子の適正条件における熱発生率プロフィールと正味熱効率の予測結果について

$P_{max}$  の変動に対して FMEP と IMEP が高いロバスト性を有するのに適正な  $\varepsilon$ ,  $\varepsilon_{effec}$ , CA. @  $P_{max}$  および  $\eta_{gl}$  の条件を前節までに示した。ここでは、これら 4 つの制御因子の適正条件におけるエンジン性能と正味熱効率の予測結果について述べる。図 22 は、表 13 に示した FMEP に対して適正な制御因子および表 16 に示した IMEP に対して適正な制御因子に対応するよう調整を行った熱発生率プロフィールである。FMEP および IMEP の適正条件に対応した熱発生率プロフィールを比較すると、FMEP の適正条件に対応した熱発生率プロフィールが IMEP の適正条件に対応した熱発生率プロフィールよりも僅かに熱発生率ピークが高くなっている。

ここでは、これらの FMEP および IMEP の適正条件に対応した熱発生率プロフィールを用いて、大型単気筒ディーゼルエンジンモデルによりエンジンの性能予測計算を実施した。この予測計算では、図 23 に示すように、 $P_{max}=27\text{MPa}$  となるよう計算モデルにおける過給圧を調整している。

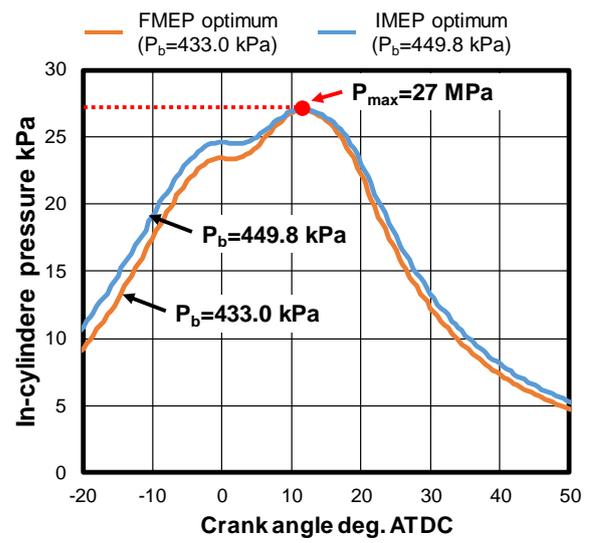
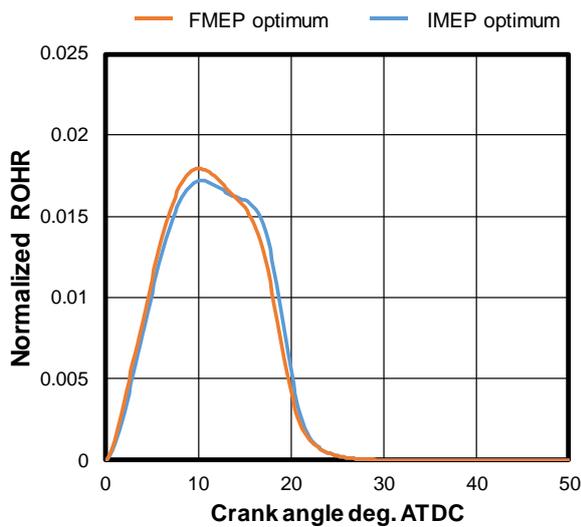


図 24 は GT-POWER を用いた大型単気筒ディーゼルエンジンモデルにおいて、FMEP および IMEP に適応した熱発生率プロファイルを基にエンジン性能計算を行った結果である。制御条件に対して適正化された条件における FMEP の予測結果 (FMEP=305.0 kPa) よりも FMEP に対して適正化された条件における FMEP の予測結果 (FMEP=315.7 kPa) の方が大きい予測結果となっているが、顕著な差ではない。また、IMEP の予測結果に関しては、IMEP に対して適正化された条件の IMEP の予測結果が IMEP=2342.3 kPa、FMEP に対して適正化された条件の IMEP の予測結果が IMEP=2331.9 kPa であり、顕著な差ではないが IMEP に対して適正化された条件の方が僅かに良い結果となっている。空気過剰率  $\lambda$  は FMEP に対して適正化された条件における圧縮比が  $\epsilon=26$ 、IMEP に対して適正化された条件における圧縮比が  $\epsilon=22$  であることから、 $P_{\max}=27\text{MPa}$  という計算条件の下では FMEP に対して適正化された条件の過給圧を図 23 に示すように低く設定しなければならないことから、FMEP に対して適正化された条件での空気過剰率 ( $\lambda=1.96$ ) は IMEP に対して適正化した条件における空気過剰率 ( $\lambda=2.46$ ) よりも低くなっている。正味熱効率 (BTE) の予測結果は、IMEP に対して適正化された条件の予測結果が BTE=47.5%、FMEP に対して適正化された条件の予測結果 BTE=48.0%であった。以上のことから、本章におけるパラメータ検討における  $\epsilon$ 、 $\epsilon_{\text{effec}}$ 、 $\text{CA.}@P_{\max}$  および  $\eta_{gl}$  の適正値により得られる可能性のある BTE は、BTE=47.5~48.0%の範囲内であると予測される。

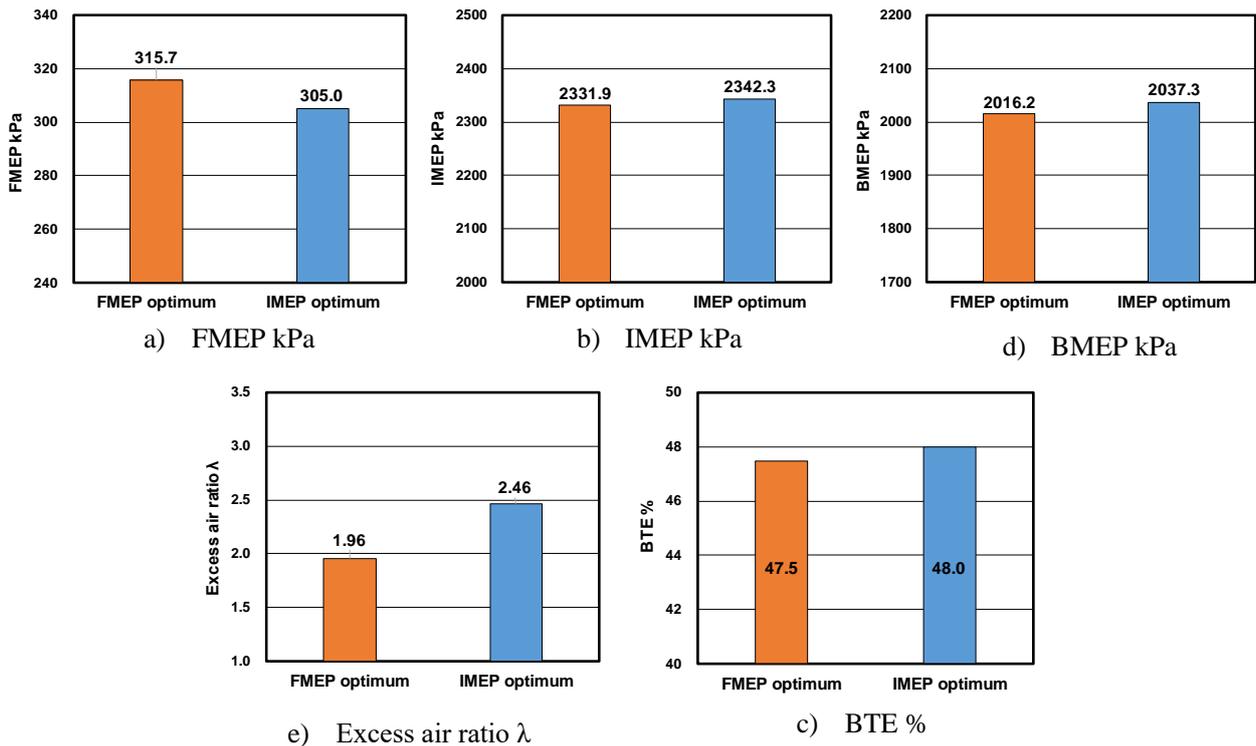


Fig.24 Predicted result of engine performance

## 9. まとめ

大型単気筒ディーゼルエンジンにおける摩擦平均有効圧力(FMEP)の予測を目的としてニューラルネットワークモデルを構築し、大型単気筒ディーゼルエンジンの実験結果を教師データとする機械学習を行った。また、機械学習済みのニューラルネットワークモデルを用いて FMEP の予測と圧縮比 ( $\epsilon$ )、有効圧縮比 ( $\epsilon_{\text{effec}}$ )、筒内最高圧力が最大となるクランク角 ( $\text{CA.}@P_{\max}$ ) および等容度 ( $\eta_{gl}$ ) のパラメータの適正化に関する検討を試み、以下の結果を得た。

- (1) 大型単気筒エンジンの 5227 点の実験結果を用いて筒内最高圧力 ( $P_{max}$ ) や平均ピストン速度 ( $C_m$ ) 以外に FMEP に強く影響している因子を重回帰分析により検討した. その結果,  $P_{max}$  および  $C_m$  に次いで圧縮比, 燃料噴射圧力, 筒内最高圧力が最大となる時のクランク角および等容度が FMEP に対して影響していることが示唆された.
- (2) 大型単気筒ディーゼルエンジンにおいて, 機関速度とエンジンの負荷を広範囲に変化させた 5227 点の実験結果を教師データと検証用データに約 7:3 の比率で分け, ニューラルネットワークで FMEP を予測するための機械学習を行った. 機械学習の過程において, Training error 曲線は約 800 Epoch, Validation error 曲線は約 700 Epoch で収束し, 過学習の傾向は見られなかった. 機械学習の検証用データにおける FMEP の実験結果とニューラルネットワークによる検証用データの FMEP の予測値との決定係数は  $R^2=0.9413$  と良好であり, 本研究で使用した大型単気筒ディーゼルエンジンにおいて汎用性のある FMEP 予測のためのニューラルネットワークモデルを構築できた.
- (3) FMEP を予測するための機械学習済みのニューラルネットワークモデルを用い, 機関速度 ( $N_e$ ), 正味平均有効圧力(BMEP), 燃焼開始時期(SOC)および燃料噴射圧力( $P_{inj}$ )を変化させた際の FMEP の傾向を予測できるかを検証した. その結果, 機械学習済みのニューラルネットワークモデルは, BMEP, SOC および  $P_{inj}$  を変化させた際の FMEP の傾向を十分に捉えることが可能であることを確認できた.
- (4) FMEP を予測するためのニューラルネットワークにおける機械学習では, SOC や質量燃焼割合 (MFB : Mass fraction burned)などの燃焼位相や熱発生率に関する因子に加え  $P_{inj}$  も学習項目として考慮されている. このため, 機械学習済みのニューラルネットワークモデルは, SOC を変化させた際の FMEP の傾向および  $P_{inj}$  を変化させた際の FMEP の傾向を Chen-Flynn モデルよりも良好に予測することができている. これらのことから機械学習を行ったニューラルネットワークモデルによる FMEP の予測手法は, 燃焼位相や  $P_{inj}$  が変化するような条件でのエンジン性能予測計算において FMEP の予測に有効な手法であることを確認することができた.
- (5) 機関速度  $N_e=1000\text{rpm}$ , 燃料噴射量  $q=240\text{mm}^3/\text{st}$  の条件において, 学習済みニューラルネットワークモデルおよび GT-POWER による大型単気筒ディーゼルエンジンモデルを用いて, 品質工学により FMEP および図示平均有効圧力 (IMEP) に対する,  $\epsilon_{effec}$ , CA. @  $P_{max}$  および  $\eta_{gl}$  のパラメータの適正化を試みた. その結果, FMEP と IMEP に対する  $\eta_{gl}$  と  $P_{max}$  が最大となるクランク角の適正化において, CA. @  $P_{max}$  と  $\eta_{gl}$  との間にトレードオフなく, 共通した考え方で適正化が行えることを示している.

### 参考文献

- (1) Chen, S. and Flynn, P., Y. : R Development of a Single Cylinder Compression Ignition Research Engine : SAE Technical Paper 650733
- (2) Mauro AD, Chen H and Sick V. : Neural network prediction of cycle-to-cycle power variability in a spark-ignited internal combustion engine : Proc. Combust Inst., 2019, 37(4), 4937-4944
- (3) Hang X., Papaioannou N., Leach F., and Davy M. : On the application of artificial neural networks for the prediction of NOx emissions from a high-speed direct injection diesel engine : International of Engine Research, 2021, Vol.22(6), 1808-1824
- (4) Yamaguchi, T., Aoyagi, Y., Osada, H. Sturman, E., and Drummond, E. : Improvement for Volumetric Efficiency and Emissions using Digital Hydraulic VVA in a High Boosting Diesel Engine : Proceedings Thermo-and fluid Dynamic Process in Diesel Engines, 2008, 463-475.
- (5) Neural Network Console, <https://dl.sony.com/ja/>
- (6) K. He, Zhang, S. Ren and J. Sun : Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification : In IEEE International Conference on Computer Vision (ICCV), 2015
- (7) Ioffe Sergey and Christian Szegedy : Batch normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift : arXiv preprint arXiv:1502.03167, 2015
- (8) N. Srivastava, G. E. Hilton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov : Dropout : A simple way to

## 付録 A GT-POWER モデルのキャリブレーション結果

GT-POWER による大型単気筒ディーゼルエンジンモデルのキャリブレーションは表 A1 に示すエンジン諸元において行った実験結果をベースとしている。表 A2 は実験条件を示す。

Table A1 Engine specifications

Item	Specifications
Engine type	DI single cyl. 4 valve
Displacement	cm <sup>3</sup> 2004
Bore x Stroke	mm 135x140
Max. engine speed	rpm 2000
Injection system	Common rail system (Max. Pinj=220MPa)
Piston material	Steel (Monotherm)
Compression ratio	22.0
Aspiration	Externally supercharging

Table A2 Engine operation conditions

Ne	q	BMEP	P <sub>inj</sub>	P <sub>b</sub>	λ	Intake temp. T <sub>in</sub>	EGR rate	ε <sub>c</sub>	ε <sub>e</sub>
rpm	mm <sup>3</sup> /st	MPa	MPa	kPa.abs		°C	%		
1000	240	1.96	200	431.3	2.4	20	0	20	22

図 A1 および図 A2 筒内圧力と筒内平均ガス温度の実験結果と計算結果である。図 A1 および図 A2 が示すように、実験結果と計算結果の筒内圧力および筒内平均ガス温度は概ね一致している。また、図 A3～図 A6 は GT-POWER のエンジン性能の実験結果と計算結果との比較である。体積効率、吸気質量流量、正味熱効率、PMEP などの計算結果はほぼ実験結果と一致しており、GT-POWER のモデルにより大型単気筒エンジンにおける実験結果を模擬できる状態であることを確認できた。

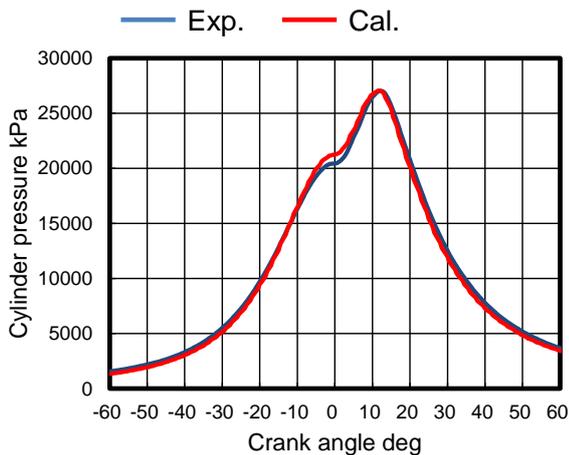


Fig. A1 In-cylinder pressure of experiment and calculation result

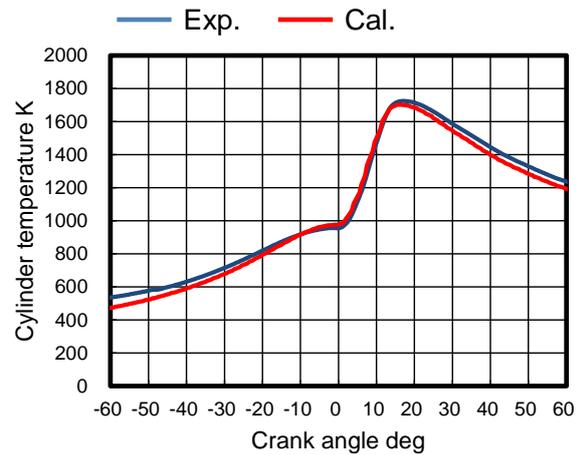


Fig. A2 In-cylinder temperature of experiment and calculation result

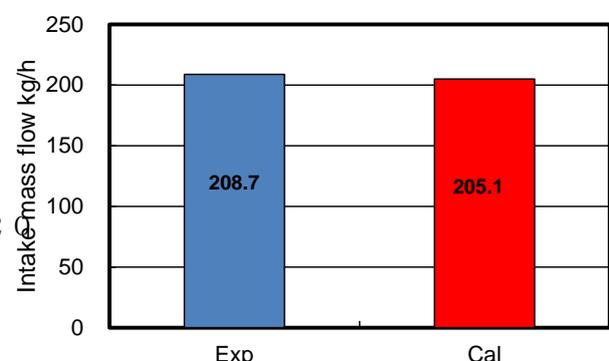
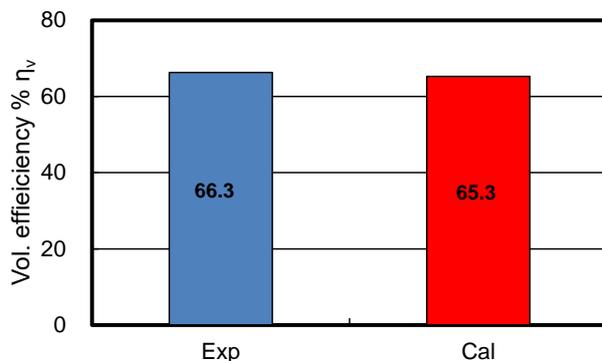


Fig. A3 Volumetric efficiency %

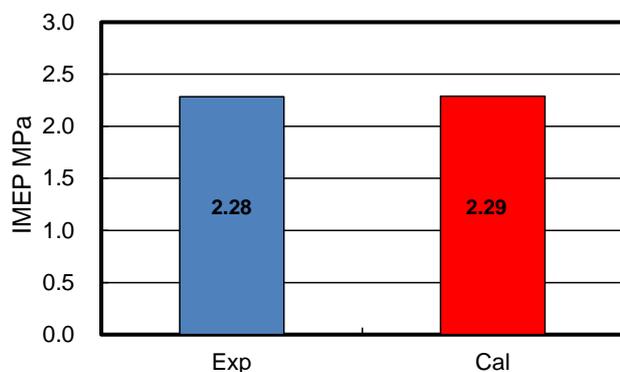


Fig. A5 IMEP MPa

Fig. A4 Intake mass flow kg/h

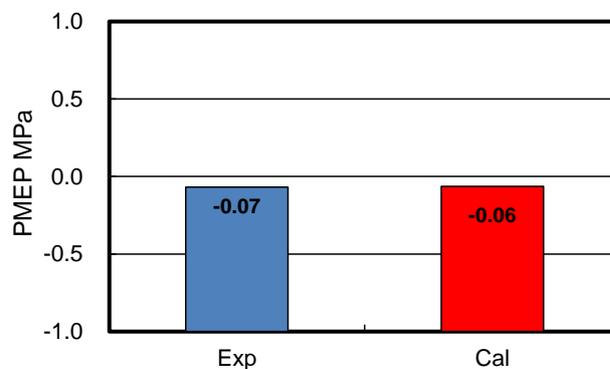


Fig. A6 PMEP MPa

## 付録 B Wiebe 関数による熱発生率プロファイルの調整について

GT-POWER を用いた 1 次元エンジン性能計算モデルにおける熱発生率の波形は Wiebe 関数を利用して求めた。Wiebe 関数は、図 B1 に示すように、13 項目の変数を調整することで任意の熱発生率プロファイルを作り出すことが可能である。

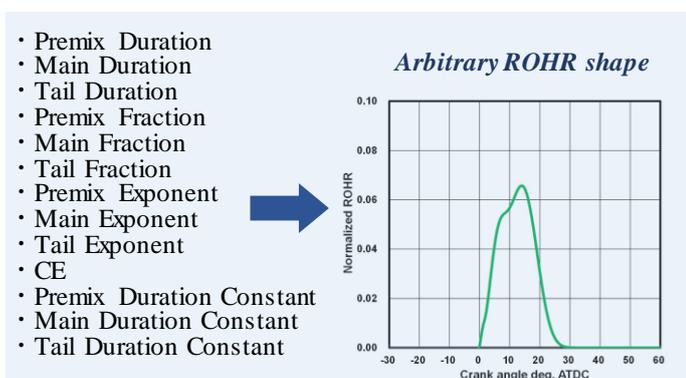


Fig. B1 Wiebe function and arbitrary ROHR shape

本研究では、Wiebe 関数における 13 項目の変数のうち、Premix duration=1.65, Main duration=6.5, Tail duration=12, Tail exponent=3.39, CE=6.908, Premix duration constant=0.029, Main duration constant=0.1628, Tail duration constant= $8.835 \times 10^{-5}$  と設定し、Premix fraction, Main fraction, Tail fraction, Premix exponent, Main exponent, Tail exponent を調整定数として L9 直交表に割り振った制御因子に対応する熱発生率プロファイルとなるよう調整を行った。



# [1] 多段面旋回流・後方逆旋回流型ハイブリッドロケット

## エンジンの性能向上に向けた酸化剤配分率の研究

21m301：坂本 龍太郎

主論文指導教員：麻生 茂

副論文指導教員：片山 雅之

### 1. 序論

近年、超小型衛星の打ち上げ手段、宇宙観光事業サービスなどの目的において、ハイブリッドロケットが注目されている。<sup>1)</sup>

ハイブリッドロケットとは、図1のような固体燃料グレインと気体または液体の酸化剤を用いることで推力を得るロケットシステムである。このロケットの特徴は 1)コストが低い、2)安全性が高い、3)再着火が可能、4)推力制御が容易、5)無毒で無害な推進剤の選択が可能といった利点を持つ一方で、1)遅い燃料後退速度、2)低燃焼効率、3)燃焼中の O/F(酸化剤/燃料)シフト、4)燃焼の不安定さが欠点として挙げられる。そのため、これらの課題改善に向けた研究が各所で行われている。

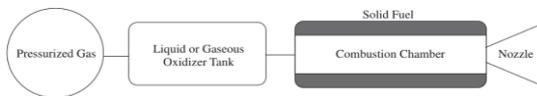


Fig.1 ハイブリッドロケットの概略図

### 2. 多段面旋回流・後方逆旋回流型ハイブリッドロケットエンジン

本研究では、多段面旋回流・後方逆旋回流方式<sup>2)</sup>に着目した。この方式による燃焼器の概略図を図2に示す。本方式による利点は

1)高い燃料後退速度が得られる、2)燃焼効率を向上が期待できる、3)O/Fを維持できるなどが挙げられる。本研究では、この方式による燃焼効率、O/F値、比推力等を評価し、性能向上に向けた最適な酸化剤の配分率について、考察することを目的とした。

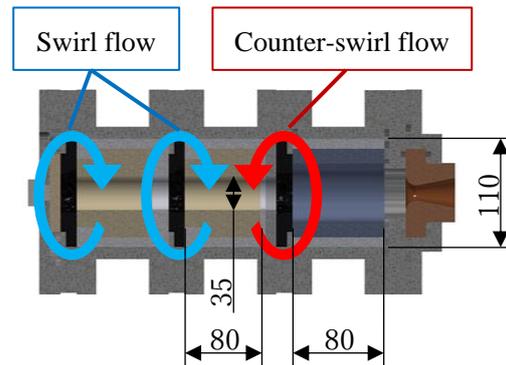


Fig.2 多段面旋回流・後方逆旋回流型燃焼器の概略図

### 3. 実験方法

本研究では、酸化剤として気体酸素を用いた。気体酸素は、酸素ボンベから配管、酸化剤供給制御装置、オリフィスの順に通過し、流量と供給圧力が制御された状態でエンジンへ供給される。また、燃料は融点の低さ、靱性の高さを考慮し、7.5%wtのステアリン酸を含めたマイクロクリスタリンワックス(Hi-Mic-1080)を選定した。

#### 4. 実験結果及び考察

燃焼実験を行い、燃料後退速度、O/F、平均推力、比推力等の結果を得た。その中から代表的な例として EXP5 の燃焼室内圧力及び推力変化のグラフを図 3 に、燃焼火炎の様子を図 4 に示す。また、EXP1 から EXP6 までの各条件における比推力値をまとめたグラフを図 5 に示す。このグラフを見ると、EXP5 の条件の際に、最も高い比推力が得られていることが分かる。

ハイブリッドロケットにおいて重要なパラメータの一つが比推力である。これまでの燃焼実験結果の中で、最も比推力が低かったのは EXP1 の 221s であり、最も比推力が高かったのは EXP5 の 329s であった。図 5 を見ると分かるように、3 段目の後方逆旋回流がない EXP1 と、後方逆旋回流を施した EXP2 から EXP6 までの各条件を比較すると、どの条件も EXP1 より高い比推力が得られている。この結果から、多段面旋回流方式と、そこに後方逆旋回流を加えた方式を比較すると、後者の方が高い比推力を得られることが示唆される。また、各セクションの酸化剤の配分率により、比推力の値が異なることから、最適な酸化剤配分率の組み合わせが存在することが明らかとなった。

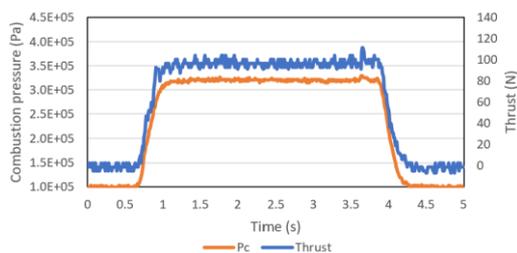


Fig.3 燃焼室内圧力及び推力変化(EXP5)



Fig.4 燃焼火炎の様子(EXP5)

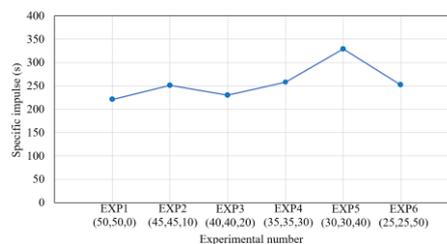


Fig.5 各条件における比推力値

#### 5. 結論

本研究の結論は以下のように要約される。

- 1) 最も高い比推力を得たのは EXP5 の 329s であり、最も低い比推力であったのは EXP1 の 221s であった。
- 2) 多段面旋回流方式に後方逆旋回流を加えることは比推力向上において、有効であることが明らかとなった。
- 3) 各セクションによる最適な酸化剤配分率の組み合わせが存在することが明らかとなった。

#### 参考文献

- 1) H. Saito., and Y. Masumoto., “Piggy-Back Satellite for Aurora Observation and technology demonstration”, Acta Astronautica Vol.48, No.5-12, pp.723-735, 2001.
- 2) Shigeru Aso et. al.: A Study on New Hybrid Rocket Engine with Multi-Section Swirl Injection and Aft Counter-Swirl Injection Method, IAC-19-C4.2.8, (2019).

## [2] 小型ディーゼルエンジンにおいてデュアルフューエル（水素+軽油）がエンジン性能に及ぼす影響

20M302 納富 義樹

指導教員 山口 卓也 副指導教員 東 大輔

### 1. はじめに

ディーゼルエンジンは高効率で燃焼消費の少ない特徴を有するが、使用する燃料が主に軽油や重油などの炭化水素燃料であることから、CO<sub>2</sub>の排出を避けることができない。地球温暖化による環境や生態系への影響が深刻化しており、ディーゼルエンジンにおいても従来の炭化水素燃料の使用から、廃食用油など植物由来の油脂類から作られたバイオディーゼル燃料（BDF）などのカーボンニュートラル燃料や水素やアンモニアなどの非炭化水素燃料などの使用への早急な転換が求められている。修士論文では非炭化水素燃料である水素に着目し、小型ディーゼルエンジン（トヨタ製：IND-TV）において、従来から使用している軽油と水素とのデュアルフューエルシステムを構築する。水素と軽油を燃料とすることで、軽油の使用量を抑制しディーゼルエンジンからのCO<sub>2</sub>の排出量を低減するコンセプトである。修士論文では水素を小型ディーゼルエンジンへ供給するシステム検討とその製作を実施した。また、軽油と水素とのデュアルフューエルシステムにおいて軽油と水素との供給割合を変化させた実験を行い、その際の基本エンジン性能について調べたのでその内容について報告する。

### 2. 実験装置

#### 2.1 研究用小型ディーゼルエンジン

本研究で使用するディーゼルエンジンの主要諸元を図1および表1に示す。エンジンは最高噴射圧160MPa仕様のコモンレール式燃料噴射装置を搭載した排気量1.36Lの直列4気筒ディーゼルエンジン（トヨタ自動車製：IND-TV）である。

Table 1 Engine specifications

Item	Specifications	
Engine type	DI inline 4	
Displacement	cm <sup>3</sup>	1362
Bore × Stroke	mm	73.0 × 81.4
Compression ratio	18.5	
Maximum torque	Nm	170(@ 2000-2800rpm)
Maximum power	kW	53

### 3. 水素噴射システムの計画と製作

図2は本研究で計画したデュアルフューエルシステムのシステムである。デュアルフューエルシステムにおいて、軽油は従来の仕様と同様に、コモンレールシステムのインジェクタより筒内に直接噴射を行う。水素はガスインジェクターを介して、吸気管内に噴射する。吸気管内にて水素と空気の子混合気を形成し、シリンダー内に吸入させた後に、軽油を筒内直接噴射するシステムを想定している。

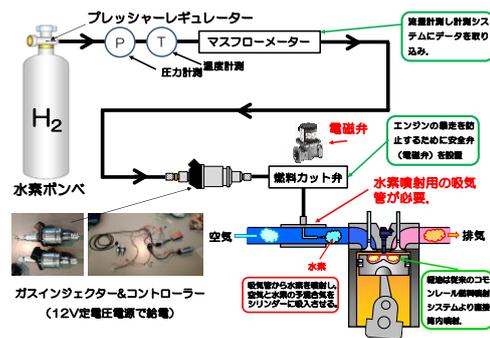
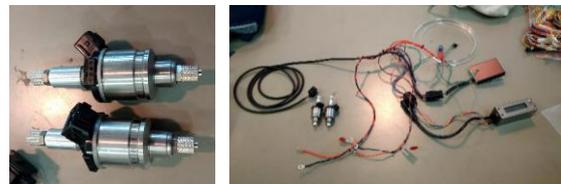


Fig. 2 Planned dual fuel (H<sub>2</sub>+diesel fuel) system

#### 3.1 水素用インジェクタとコントローラー

エンジンへの水素供給は図3に示す水素用インジェクタとコントローラーを使用する。これらの噴射システムは12VDC電源より給電を行う。



a) H<sub>2</sub> gas injector b) H<sub>2</sub> gas injector controller

Fig. 3 Gas injector for hydrogen and controller

#### 3.2 水素噴射用の吸気管の設計と製作

エンジンに水素を供給するための水素供給用吸気管の設計と製作を行った。図4は製作した水素供給用吸気管である。また、図5は水素供給用吸気管をエンジンシステムの吸気系に取り付け、水素用ガスインジェクターをセッティングした状況を示す。水素供給用吸気管は問題なくエンジンシステムに組み込むことがで

き、水素用ガスインジェクターと耐圧チューブが吸気管に問題なく取り付けできることを確認した。



Fig. 4 Intake pipe for H<sub>2</sub> supply

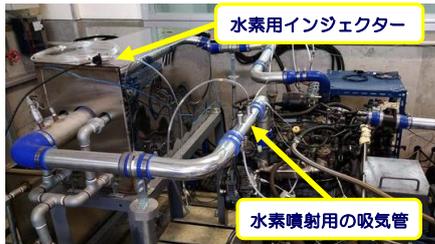


Fig. 5 Diesel engine bench with gas injector and intake pipe for H<sub>2</sub> supply

### 3.3 水素供給装置と水素用流量計

エンジンに水素を供給するために水素供給装置（ガスボンベとプレッシャーレギュレーター）と水素用流量計が必要である。図6は水素供給装置および水素流量計を示す。水素供給装置はガスボンベスタンドとプレッシャーレギュレーターで構成されている。水素流量計は測定レンジが0~500 [L/min]のものを使用する。



Fig. 6 H<sub>2</sub> supply device and flowmeter for H<sub>2</sub>

## 4. デュアルフューエルシステムのエンジン実験

軽油と水素とのデュアルフューエルシステムにおける基本エンジン性能を調べる実験を行った。実験は機関速度 Ne=1640 rpm, 正味平均有効圧力 BMEP=0.3MPa の条件で実施した。

### 4.1 水素インジェクターの噴射条件

水素の噴射量は、水素インジェクターの開弁期間もしくは噴射周波数を変化させることで調整できる。本実験では水素の噴射圧力  $P_{inj}=0.25\text{MPa}$ , 開弁期間  $3\mu\text{sec}$  の条件で噴射周波数を 5~20Hz の範囲において 5Hz 刻みで変化させた。図7は水素インジェクターの噴射周波数に対する水素の体積流量の変化である。噴射周波数が大きくなるに従って、インジェクターからの水素の噴射量が増加している。

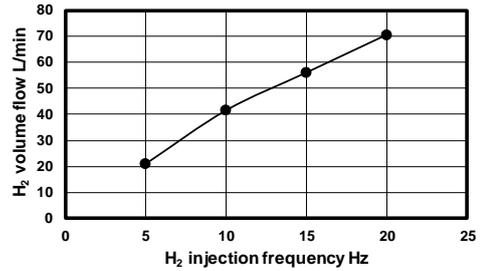


Fig. 7 H<sub>2</sub> volume flow with H<sub>2</sub> injection frequency

### 4.2 エンジンへの供給熱量に占める水素の割合

水素インジェクターの噴射周波数が大きくなるに従い、水素の噴射量は増加していく。このため、水素の噴射量が増加していくに従って、軽油の噴射量は減少していく。図8は水素インジェクターの噴射周波数ごとのエンジンへの供給熱量における水素の割合を示したものである。水素インジェクターの噴射周波数が大きくなるにしたが、エンジンへの供給熱量に占める水素の割合は増加し、水素の噴射周波数が 20Hz の条件ではエンジンへの供給熱量の 60.3%が水素によるものとなる。このため、水素の噴射周波数が 20Hz の条件では、従来の軽油のみの運転条件に対して約 60%の CO<sub>2</sub> 排出削減を見込むことができる。

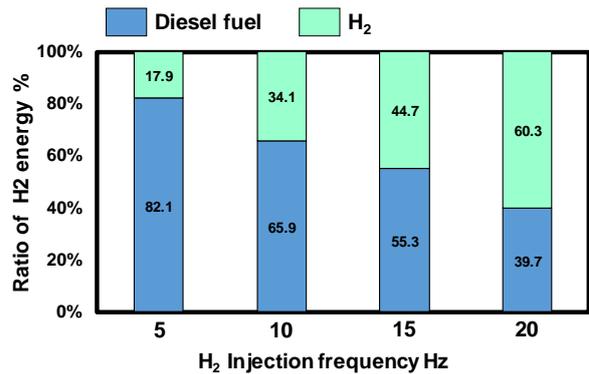


Fig. 8 Ratio of H<sub>2</sub> energy

### 4.2 デュアルフューエルシステムの正味熱効率

図9は水素と軽油とのデュアルフューエルシステム運転における正味熱効率である。水素を噴射した条件では、水素の噴射周波数によらず正味熱効率は軽油のみで運転した条件における正味熱効率よりも低下している。これは、水素噴射時の軽油噴射時期の遅角や冷却損失の増加など影響と推察される。

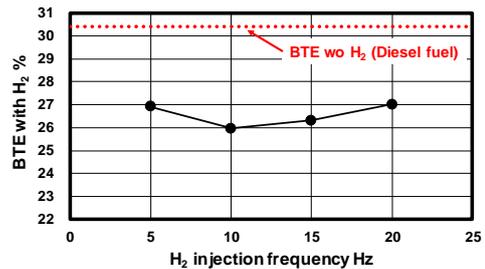


Fig. 9 Brake thermal efficiency (BTE) with H<sub>2</sub>

## [3] 小型先進モビリティの走行安全性を高める

### センサフュージョン手法の検討

21M303 松山 幸広

主論文指導教員 東 大輔

副論文指導教員 田中 基大

#### 1. 背景

我が国は世界でも稀な速度で高齢化が進んでおり、その社会保障費の増大と少子化による経済活力の低下が喫緊の課題となっている。厚生労働省平成 28 年 介護保険事業状況報告によると、2007 年時点での要介護（要支援）認定者数は 437.8 万人だったのに対し、団塊世代が 65 歳以上となる 2016 年には認定者数が 618.7 万人と 1.4 倍に増加しており、介護保険事業費も増大している。

そこで政府は「地域包括ケアシステム構想」を提唱し、高齢や障がいで介護が必要な人も可能な限り自立した生活が送れる地域（福祉サービス）づくりを推進している。その中でも高齢者の移動支援を行う事によるその健康維持・増進への効果は大きいとされており「地域包括ケアシステム構想」を具現化する上で重要な役割を果たすと期待されている。

次世代モビリティの開発技術を強みとする本研究室では、移動支援サービスの社会実装に向けて数々の実証実験の中で完全自動運転型電動車椅子の運転システム開発を行ってきた。そして 2022 年 10 月 25 日、本学 IML とパーソル R&D（株）と共同開発を行った観光向け新型自動運転モビリティ「PARTNER MOBILITY ONE」の発表を行った。移動支援サービスの本格始動にあたり最重要事項となるのは、いかなる状況においても走行安全性の確保と搭乗者に恐怖

感を与えない事である。具体的には、障害物だけでなく走行路の段差への乗り上げ等を考慮し、これらに対して事故回避を行う際に急減速等の車体挙動を示さない事が恐怖感の無い乗り心地に繋がる。そこで本研究では、小型赤外線ステレオカメラから得られる画像を領域分割し、段差や車体周辺の障害物との距離を検出し、脱輪や衝突を回避するシステムを構築した。

#### 2. 目的

本研究では、移動支援サービスを実現する上で最も重要な「自動運転の安全性を高める車体周辺の障害物情報を取得するセンサフュージョン手法の先行研究」について報告する。

#### 3. IML 事故回避システムのコンセプト

本システムの開発コンセプトを以下に示す。

- ① 広範囲の周辺環境を迅速かつ正確に測距可能なセンサ構成
- ② 環境変化に物物検出精度が左右されない堅牢性
- ③ コンパクトなハードウェア構成
- ④ 人間が停止操作可能な安全機能装備

#### 4. IML 事故回避システム各種センサ機能

本システムに採用した各種センサの役割について以下に示す。

#### 4.1 赤外線ステレオカメラシステム

主に車体の進路上に特化した障害物・路面段差の詳細な距離・位置情報検知を検出する事を目的とする。また、自ら照射した赤外線反射率を基にした測距により、環境変化に左右されない測距精度を確保している。

#### 4.2 超音波センサシステム

赤外線ステレオカメラでは光透過によって測距不可能なガラス面を対象にした測距を行う事を目的とする。これにより、自動ドア等のガラス面に対する衝突回避を行う。

#### 4.3 緊急停止ボタンシステム

搭乗者が何らかの理由で停止する必要があると判断した場合に自ら停止が出来る事を目的とする。

### 5. 速度制御則

測距データを基に本モビリティとの衝突の恐れがある物体・段差との位置関係、車間距離を把握し、最適な前進駆動力の算出を行う。理由は、静的障害物と通行人などの動的障害物が対面進行する場合での、本モビリティと障害物との接近相対速度は約3倍となるためだ。一定加速度による減速では両場面に対応した安全な減速は不可能と言える。また、走行路面に段差が存在する場合、走破可能な範囲での段差であっても、その高低差に比例した減速走行を行わなければ、落車・車体破損等のリスクも増加してしまう。

以上の事を踏まえ本システムの速度制御では、障害物との車間距離(D)6[m]以上を100[%]とする車間距離に比例した項にて正の駆動力を決定し、その値から相対速度( $\Delta D / \Delta t$ )に比例させ減速させる項と走破可能範囲内での段差に対してその大きさ(G)に比例した減速をさ

せる項の総和を負の項とすることで、相対速度・段差の大きさに応じた減速が可能となる。この駆動力算出は次式で表される。

$$P = \underbrace{\left(\frac{D}{6} * 100\right)}_{\text{基本駆動力項 (比例項)}} - \left[ \underbrace{\left(0.1 * \frac{\Delta D}{\Delta t}\right)}_{\text{相対速度項 (微分項)}} + \underbrace{\left\{0.1 * \left(\frac{G}{0.05} * 100\right)\right\}}_{\text{段差項 (比例項)}} \right]$$

### 6. システム検証

本検証では、暗所・明所・逆光走行環境下において事故回避を行った際の回避精度の変化、走行中の本モビリティが通行人に対して衝突回避を行った際の搭乗者心理的評価を行った。

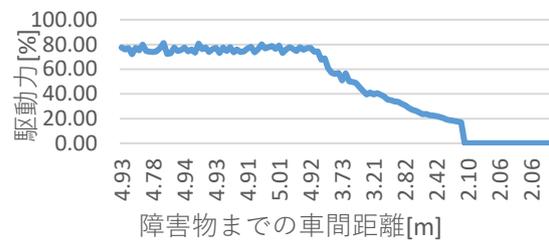


Fig1. 暗闇下での障害物回避の様子

- 十分な余裕があった
- 余裕があった
- 普通だった
- もう少し余裕を持つべきだった
- 衝突するかと思った



Fig2. 搭乗者の衝突回避行動に対する評価

### 6. 結言

2つの検証により、本システムの外界光量変化に左右されない事故回避精度の堅牢性と搭乗者に安心感を与えた状態での回避行動を取れていることに対して一定の成果を得ることが出来た。今後は、実用環境下において常に安定した挙動を示し、安心感のある回避行動を取れているか、更に実践的な走行検証を行いたい。

# [4] 固定翼付き eVTOL の開発に向けた概念設計法の開発と 2 重反転プロペラ間隔が推力に及ぼす影響に関する研究

21M304 呂 精

主論文指導教員 麻生 茂

副論文指導教員 井川 秀信

## 1. 緒言

技術の発展により、地域間のコミュニケーションはますます盛んになっている。物流、人的交流のための交通手段の利用は特に大切である。大都市における交通渋滞が益々深刻になってきており、排気ガスを源とする大気汚染が広がりを見せている。現在、世界人口の 55% が都市に住んでいるが、国連の推計によると、2050 年には 78% に増加し、特にメガシティでは都市の地上交通渋滞や大気汚染が現在以上に深刻化すると言われている。大気汚染対策の一つとして、自動車については電気自動車への転換が進みつつある。

一方、現在使われている飛行機のほとんどは化石燃料を用いており、飛行中に  $\text{CO}_2$  に限らず、 $\text{NO}_x$  や  $\text{SO}_x$  などの大気汚染物質を排出するため、環境負荷が大きい。その打開策として考えられているのが空飛ぶクルマ構想をはじめとする電動航空機である。また、台湾と日本などのように比較的大きな都市間に高い山間部が存在する地域は世界各地に見出すことができる。また、離島が多く、本島と離島間の高速なアクセスが必要とされる地域が多く存在する。さらに、土地の有効活用と電動航空機の普及性から考えると滑走路がなくても運用できるシステムが望ましい。

このような条件を満たす機体として、現在、特に注目されているのが電動垂直離着陸機 (eVTOL) の開発である。電動垂直離着陸機 (eVTOL) は地形の障害を乗り越え、人や物を素早く運ぶことができる。また、滑走路を必要としないので利便性が増す。このような機体は欧米や日本及び台湾においてもエアタクシーまたは空飛ぶクルマとして構想が練られ、また開発が行われている。

このような機体の開発にあたっては従来の化石燃料を用いる機体であればその概念設計の方法はほぼ確立しており、必要とされる仕様に応じて機体の概念設計が可能であり、その結果として機体規模や性能を推算することができる。しかしながら、電動飛行機は重量が変わらないためこの方法を利用した概念設計を行うことができない。したがって、電動飛行機用のミッション要求から機体規模を策定する概念設計法が必要である。

## 2. 研究目的

今回の研究は翼付き eVTOL 機が後続距離も長く取れることからこの機体に絞って概念設計手法の開発を行うとともに推力の発生源の一つである二重反転プロペラの推力特性について考察を行った。

## 3. 電動飛行機用概念設計手法

離陸時における全備質量  $M_0$  は次式のように表せる。上に上がるためのモーター質量 ( $M_{motor}$ ) とモーターを支えるストラクチャー質量 ( $M_{support}$ ) も考える。

$$M_0 = M_{crew} + M_{payload} + M_{battery} + M_e + M_{motor} + M_{support}$$

$M_{crew}$ ,  $M_{payload}$  は 1 人あたりの体重を 80kg, 1 人あたりの手荷物を 15kg とすれば

$$M_{crew} = 95n_{crew}, \quad M_{payload} = 95n_{passenger}$$

と表せるので、前式は次のように表せる。

$$M_0 = 95n_{crew} + 95n_{passenger} + M_{battery} + M_e + M_{motor} + M_{support}$$

その中に、 $M_{support}$  と  $M_{battery}$  は  $M_0$  の関数となるので、 $M_{battery}$ ,  $M_{support}$  を次のように表す。

$$M_{battery} = M_{battery}(M_0), \quad M_{support} = M_{support}(M_0)$$

世界中の小型電動航空機を参考し、ローターの質量の全備質量に対する比率は 0.214 とする。つまり  $M_{motor}$  は  $0.214M_0$  とする。

また、参考文献の Table 7.2, Gen. Av. - twin

engine」を選択すると

$$\frac{M_e}{M_0} = -0.90 + 1.36M_0^{-0.10} AR^{0.08} \left(\frac{H_p}{W_0}\right)^{0.05} \left\{\left(\frac{W}{S}\right)_{\min}\right\}^{-0.05} (V_{\max[\text{kt}]})^{0.20}$$

これより、

$$M_e = \left[ -0.90 + 1.36M_0^{-0.10} AR^{0.08} \left(\frac{H_p}{W_0}\right)^{0.05} \left\{\left(\frac{W}{S}\right)_{\min}\right\}^{-0.05} (V_{\max[\text{kt}]})^{0.20} \right] M_0$$

したがって、前式は次式のように書き直す。

$$M_0^{(n+1)} = 95n_{\text{crew}} + 95n_{\text{passenger}} + M_{\text{battery}}(M_0^{(n)}) + M_e(M_0^{(n)}) + M_{\text{motor}}(M_0^{(n)}) + M_{\text{support}}(M_0^{(n)})$$

Microsoft Excel で  $M_0^{(n+1)}$  と  $M_0^{(n)}$  の値が一致するまで反復計算を行う。一つ例として、航続距離が 150 km, 4 人乗りの場合の計算結果は以下である。

機体全備質量 $M_0$ [kg]	1942.04
空虚質量 $M_e$ [kg]	888.84
バッテリー質量 $M_{\text{battery}}$ [kg]	237.66
モーター固定用支柱質量 $M_{\text{support}}$ [kg]	20.29
必要パワー $H_{p, \text{required}}$ [kW]	209.16
機体全長 $l_{\text{fuselage}}$ [m]	8.80
主翼スパン $b_{\text{wing}}$ [m]	10.44
主翼コード $c_{\text{wing}}$ [m]	1.74

計算した結果から、得られた機体の図面を Fig.1 に表示す。

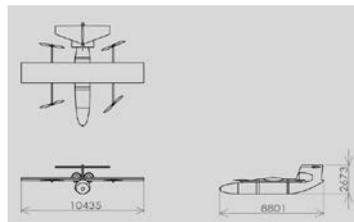


Fig. 1 概念設計によって得られた eVTOL 図面 (単位:mm)

ここで得られた機体の諸元や性能はこれまでに開発された 4 人乗りの化石燃料の機体と比べ、バッテリー質量が大きいため機体質量が大きくなっているが、それを除けば妥当なものであると考えられる。よって、電動で垂直離着陸する主翼付き航空機について新たに概念設計法を開発することができたと考えられる。

#### 4. 二重反転プロペラ推力測定実験

上と下のプロペラがどのくらい力を出すか、電

流の信号が直流型歪増幅器に入り、scope corder で電圧の変更量が見える。Fig. 2 は二重反転プロペラの推力を測る実験の流れである。



Fig. 2 二重反転プロペラ推力測る実験の模型

二重反転プロペラ推力測定実験の結果は Fig. 3 に示す。

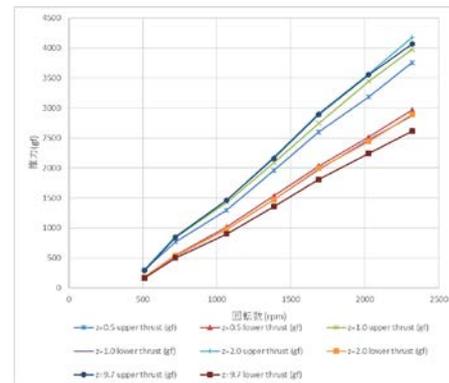


Fig. 3 個別推力と回転数の関係(z はモーターの間の距離/弦長)

#### 5. 結論

- 1) 電動で垂直離着陸する主翼付き航空機について新たに概念設計法を開発した。
- 2) 新たに開発した電動で垂直離着陸する主翼付き航空機の概念設計法を用いて、まず、航続距離 150 km の 4 人乗り eVTOL について具体的に計算を行い、機体の諸元を明らかにした。
- 3) さらに、航続距離 150 km に維持しつつ乗員を数を 6 名、8 名、10 名と増やして機体の全備質量、バッテリー質量、主翼面積の影響を調べ、妥当な値を得た。
- 4) ここで開発した概念設計法は今後、電動で垂直離着陸する主翼付き航空機の形態の概念設計を行う上で有用であると考えられる。
- 5) 二重反転プロペラの特性を明らかにした。

#### 参考文献

- 1) [https://jidounten-lab.com/y\\_sky-car-matome-toha](https://jidounten-lab.com/y_sky-car-matome-toha)
- 2) Daniel P. Raymer, 「Aircraft Design : A Conceptual Approach Sixth Edition」, AIAA EDUCATION SERIES. (2018).





インテリジェント・モビリティ研究所 活動報告

1. 研究

年月	内容
2022.07	通信・放送イベントに展示
2022.10	佐賀駅前にて自動運転の実証試験
2022.10	新型車両の発表
2022.11	嬉野温泉駅前で自動運転体験会
2023.01	自動運転モビリティ導入
2023.02	公道での自動運転の実証試験



---

久留米工業大学  
インテリジェント・モビリティ研究所 研究報告 第6号

BULLETIN OF KURUME INSTITUTE OF TECHNOLOGY  
INTELLIGENT MOBILITY LAB No.6

2023年3月20日発行

Published 20 March 2023

---

発行 久留米工業大学 インテリジェント・モビリティ研究所  
〒830-0052 久留米市上津町 2228-66  
TEL (0942)-22-2345  
URL <https://www.kurume-it.ac.jp>

Editor Editorial Committee for Kurume Institute of Technology Bulletin  
2228-66 Kamitsu-machi, Kurume-shi,  
Fukuoka-ken, Japan. 830-0052  
TEL (0942)22-2345  
URL <https://www.kurume-it.ac.jp>

---



久留米工業大学

KURUME INSTITUTE OF TECHNOLOGY