

AI を活用したガスエンジンの異常燃焼予測技術の開発

New Method for Predicting Abnormal Combustion in Gas Engines Using Artificial Intelligence

宮内 健太 技術開発本部技術基盤センターレシプロエンジングループ
増田 裕 技術開発本部技術基盤センターレシプロエンジングループ
廣瀬 孝行 技術開発本部技術基盤センターレシプロエンジングループ 課長

シェールガスを代表とする非在来型ガスは、従来の天然ガスよりも多様な成分構成をもつ。そのため、特に予混合燃焼方式のガスエンジンの燃料として用いた場合、その組成によってはノッキングをはじめとした異常燃焼を起こしやすくなる。そこでシェールガスを対象に、ノッキングの予測が可能な技術を開発した。要素試験と数値解析の両面からシェールガスの自着火特性を調査し、得られたデータと AI を組み合わせて自着火遅れ時間の予測モデルを構築することで、高い精度でのノッキングの予測が可能になった。

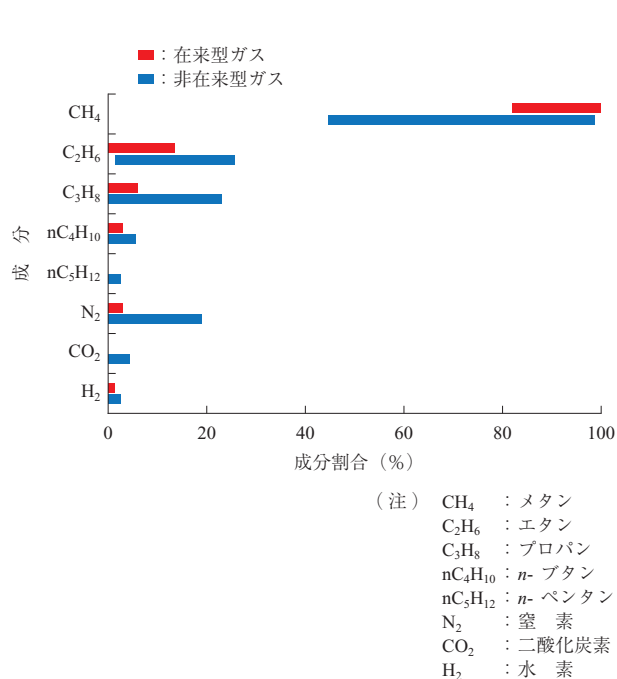
Unconventional gases, as typified by shale gas, contain a greater variety of compositions than conventional natural gas. This means that the use of unconventional gases is more likely to induce knock in premixed combustion gas engines. In this study, in order to predict the knock timing of shale gas, a prediction model of auto-ignition delay of shale gas was developed by using artificial intelligence (AI) technology. Both experimental results and chemical kinetic analysis data were used as learning data. To compensate for the differences between these data sets, a correction method was developed and applied to the chemical kinetic analysis results. This new prediction method realizes accurate knock timing prediction.

1. 緒 言

近年、温室効果ガス規制や有毒な排ガスの規制が厳しくなっている。2015年12月に採択されたパリ協定において、日本は2030年度までにCO₂を2013年度比で26%削減することを目標としている⁽¹⁾。また、国際海事機関(IMO)では2016年から船舶が排出する窒素酸化物(NO_x)のⅢ次規制が始まっている⁽²⁾など、各業界での排ガス規制も強化されている。そのなかで、船用の動力源やプラントなどの電力源としてガスエンジンが注目されている。特に予混合燃焼方式のガスエンジンは、化石燃料を焚くディーゼルエンジンと比べ、硫黄酸化物(SO_x)や粒子状物質(PM)などの有害物質の排出がほとんどなく、燃料中の炭素原子の割合が小さいことからCO₂の排出量も少ない。さらに、希薄予混合燃焼方式の場合、エンジン単体でNO_xの低減も可能である。

一方、燃料として用いられる天然ガスに着目すると、一般的なガス田から採掘される自噴の在来型天然ガス以外に、非在来型ガス資源の産出量が増加している⁽³⁾。非在来型ガスとは、シェールガスやタイトサンドガス、コールベッドメタンなど、従来のガス田とは異なる地層や場所から採掘されるガスである。特に、シェールガスはシェール

層(頁岩層)に含まれるガスであり、近年の採掘技術の革新により生産量が飛躍的に増加している。第1図に在来型ガスおよび非在来型ガスの成分構成範囲を示す^{(4)~(8)}。非在来型ガスの特徴として、在来型ガスよりもその構成成



第1図 在来型ガスおよび非在来型ガスの成分構成範囲
Fig. 1 Composition ranges of typical conventional and unconventional gases

分割合の範囲が広い点が挙げられる。

在来型ガスと組成が異なる非在来型ガスは、その燃焼特性も大きく異なることから、ガスエンジンの燃料として用いた場合、異常燃焼を生じることでエンジンの損傷や十分な出力が得られないなどのトラブルが発生する可能性がある。そのため、異常燃焼を避けるには、多様なガス組成に対して異常燃焼の発生を予測できる技術が有効である。

本稿では、非在来型ガスの代表としてシェールガスを取り上げ、シェールガスの燃焼特性を在来型ガスと比較評価し、シェールガスをガスエンジンの燃料として使用する際に懸念される異常燃焼が予測できる技術を開発した結果について報告する。


2. 異常燃焼とその予測手法

2.1 異常燃焼の発生メカニズム

異常燃焼にはノッキングや過早着火などがあり、ここでは特にノッキングと呼ばれる現象について着目する。

予混合燃焼方式のガスエンジンの燃焼は通常、以下のよう進行する。第2図にガスエンジンの燃焼の模式図を示す。ガスエンジンには燃料と空気の予混合気を取り込まれ、その予混合気がピストンにより圧縮されて高温高压となる。高温高压となった予混合気は、電気火花もしくはパイロット火炎によって点火され、火炎伝ばにより点火がなされた位置から順次燃焼する。

しかしこのとき、火炎が到達していない領域（エンドガス）は、ピストンによる圧縮に加え、火炎によっても圧縮されてより高温高压となる。高温高压に一定時間さらされた予混合気は、火花などの火種がなくとも自らが化学反応を起こして着火する性質をもっており、この現象を自着火と呼ぶ。このようにして高温高压となったエンドガス



第2図 ガスエンジンの燃焼の模式図
Fig. 2 Schematic of combustion of gas engine

が火炎の到達より先に自着火を起こす現象をノッキングと呼び、エンジンの燃焼室内に異常な圧力振動が生じたり、ピストンなどの溶損が生じたりすることがあり、エンジンの損傷につながるものであるため避ける必要がある。

第1図でも示したように、シェールガスを含む非在来型ガスは、特にプロパンより炭素数の多い炭化水素を多く含むことがある。これらの成分を多く含むガス燃料は、これらの成分の含有量が少ない在来型ガスと比べて自着火を起こしやすいために⁽⁹⁾、ノッキング発生リスクが高くなると考えられる。

2.2 ノッキングの予測方法

エンドガスの自着火時期までに正常な火炎伝ばによって燃焼が完了しなければ、ノッキングが生じるとみなすことができる。よって、ノッキングの発生有無の判定には、エンドガスの自着火時期を予測できることが必要である。

ある一定の温度、圧力条件下では、燃料の組成および当量比が定めれば自着火するまでの時間（自着火遅れ時間）は一定値になる。自着火遅れ時間が短い燃料組成であるほどノッキングが起きやすいが、実際のエンジンの燃焼室内は圧力および温度が時々刻々と変化するため、特定の圧力・温度における自着火遅れ時間から直接エンドガスの自着火時期（すなわちノッキング時期）を予測できるわけではない。そこで、ノッキング時期予測には一般に、(1)式に示す Livengood-Wu 積分（熱炎自着火発生時期推定法）が用いられる⁽¹⁰⁾。

$$\int_0^{t_{ig}} \frac{1}{\tau} dt = 1 \dots\dots\dots (1)$$

t_{ig} : ノッキング時期
 τ : 時々刻々の圧力および温度における自着火遅れ時間

すなわち、(1)式は時々刻々の自着火遅れ時間の逆数を時間で積分していき、しきい値（ここでは右辺に示す1）を超えた時期がノッキング時期 t_{ig} であることを示している。各圧力、温度条件における自着火遅れ時間の予測精度が高ければ、Livengood-Wu 積分で予測されたノッキング時期は実際のノッキング時期とよく一致することが知られている。

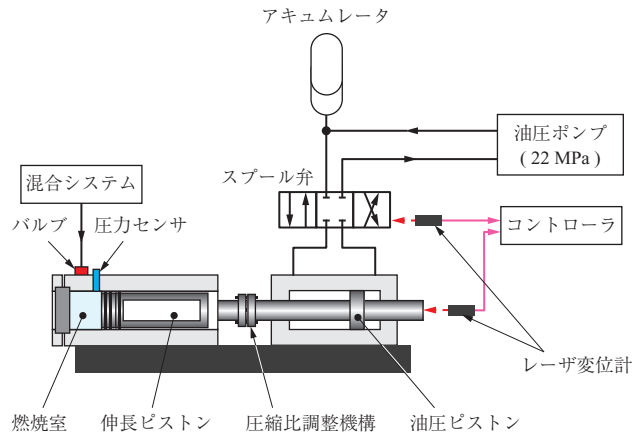
ガス燃料の自着火遅れ時間 τ と温度 T との関係は、燃料の組成や当量比、圧力が一定である場合、係数 α 、 β を用いて、一般に(2)式のようなアレニウスの式（反応速度と温度の影響を定式化）で表すことができる。

$$\tau = \alpha \exp\left(\frac{\beta}{T}\right) \dots\dots\dots (2)$$

なお、アレニウスの式の各係数 (α , β) は燃料によって異なり、また複数成分が混合されることによっても変わるため、シェールガスのような多成分燃料に対してその組成を考慮した (2) 式から自着火遅れ時間の予測は困難である。また、ガソリン燃料であればオクタン価、ガス燃料であればメタン価といった、ノッキングの起きにくさを示すことができる指標が存在するが⁽¹¹⁾、後述するように成分範囲の広いシェールガスでは、メタン価によってノッキングの原因となる自着火の起きにくさを表すことができない。そこで本稿では、このように簡単な形では表すことができないと考えられるシェールガスの自着火遅れ時間の予測モデルを、人工知能 (AI) を用いて構築することで、ノッキング時期を予測することとした。

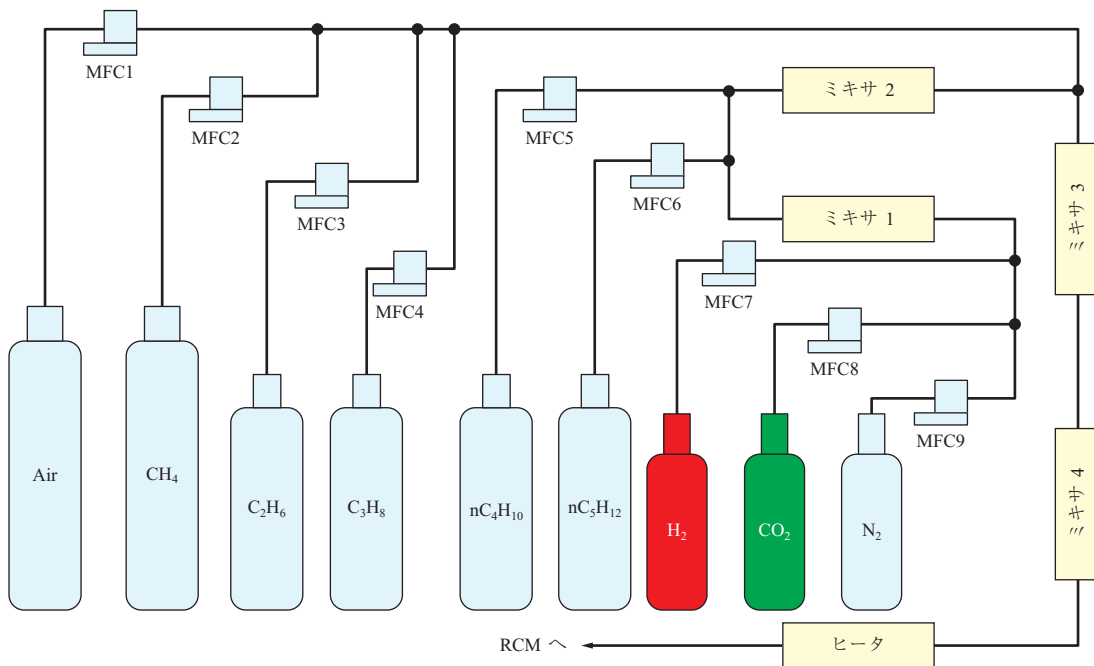
3. 試験方法

第 3 図に急速圧縮装置 (Rapid Compression Machine, 以下、RCM) の模式図を示す。在来型ガスと非在来型ガスの自着火遅れ時間を把握するために、図に示す RCM を使用して基礎燃焼試験を行った。圧縮端でエンジンの燃焼室内と同等の温度および圧力となるように、給気温度、給気圧力および圧縮比を調整した。圧縮端で最大 350 ms の時間、ピストンを停止させることで自着火遅れ時間を計測した。第 4 図にガス混合システムの模式図を示す。な




第 3 図 急速圧縮装置 (RCM) の模式図
Fig. 3 Schematic of Rapid Compression Machine

お、図に示すように、各ガス成分のボンベからマスフローコントローラ (Mass Flow Controller, MFC) によって流量を制御し、混合させたものを予混合気として RCM へ供給している。各ガス成分の流量はガス組成と当量比から決定した。また、燃焼室内の圧力はピエゾ式の圧力センサを用いて計測し、温度については圧力と予混合気の比熱比から断熱過程を仮定して算出した。第 5 図に予混合気を圧縮した際のピストン位置と圧力履歴を示す。ピストン位置が圧縮端で一定となったときに予混合気の圧力も一定となり、一定時間の後に自着火による燃焼で圧力が大きく立ち上がっていることが分かる。本稿では、ピストンが圧縮端に到達した時点から圧力が立ち上がる時点までを自着火遅れ時間と定義した。



第 4 図 ガス混合システムの模式図
Fig. 4 Schematic of gas mixing system



第5図 RCMのピストン位置と筒内圧および自着火遅れ時間
Fig. 5 In-cylinder pressure and piston position of RCM and definition of auto-ignition delay



4. 素反応解析

例えば、メタンの燃焼は(3)式のような総括反応で表される。



しかし、実際の化学反応は、素反応と呼ばれる詳細な化学反応が複雑に組み合わせられることにより生じている。

(4)～(6)式に素反応の例を示す。



素反応の数は、最も炭素数が少ない炭化水素であるメタンの燃焼であっても数百に及ぶとされ、対象となる燃料の組成が複雑になるほど増加する。この個々の素反応の反応速度から全体の化学反応を計算することを素反応解析と呼ぶ。

本稿では、試験実施が困難な条件での自着火遅れ時間の評価などに素反応解析を用いた。使用した化学反応モデルは CRECK Complete mechanism Ver. 1 412⁽¹²⁾であり、素反応解析には市販ソフトウェアの Chemkin-Pro Ver. 17.1⁽¹³⁾

を用いた。

5. シェールガスの燃焼特性

5.1 シェールガスの自着火遅れ時間とメタン価

まず、シェールガスの自着火遅れ時間を一般的なメタン価で表せるかを確認した。第1表、第2表に在来型ガスおよびシェールガスの成分範囲を示し、第6図に温度および圧力を一定にして試験した際のメタン価と自着火遅れ時間の関係を示す。なお、各混合ガスのメタン価は AVL Methane Ver. 3.2⁽¹⁴⁾を用いて算出した。第6図-(a)に示す在来型ガスではメタン価に対して自着火遅れ時間が一意に定まるのに対し、-(b)に示すシェールガスでは同じメタン価においても自着火遅れ時間に幅があり、メタン価から一義的に自着火遅れ時間の予測は困難である。

5.2 各燃料成分の影響

シェールガスの自着火遅れ時間がメタン価で整理できない原因を調査するため、どの成分が自着火遅れ時間に影響を及ぼしているかを感度解析により評価した。タグチメソッドの L18 直交表⁽¹⁵⁾に従って試験を実施するガスの組成を決定し、その試験結果から感度解析を行った。

第3表に感度解析に用いたガスの組成を示し、第7図にエタンの炭素数以上の炭化水素についての感度解析の結果を示す。数値がグラフの正方向であればそれぞれの燃料成分の増加が自着火遅れ時間を短くする方向に、負方向であれば長くする方向に影響を与えることを示している。一般的に、エタン以上の炭素数をもつ炭化水素はメタンに比べて自着火遅れ時間が短いため⁽¹⁶⁾、第7図に示したすべての燃料成分が正の値を示すと考えられる。しかし、本稿の感度解析の結果では、プロパンの炭素数以上の燃料成分については従来の知見と同様に成分割合が増加することで自着火遅れ時間が短縮される効果を示しているものの、エタンについては、逆に成分割合の増加が自着火遅れ時間

第1表 在来型ガスの組成
Table 1 Typical composition of conventional gas

試験 No.	メタン価 (-)	単位	CH ₄	C ₂ H ₆	C ₃ H ₈	nC ₄ H ₁₀	nC ₅ H ₁₂	CO ₂	N ₂
1	56.0	vol%	81.0	6.5	5.9	3.3	1.4	1.7	0.2
2	59.0	vol%	78.1	8.1	4.7	2.7	1.8	4.4	0.2
3	65.0	vol%	75.1	23.1	1.7	0.1	0.0	0.0	0.0
4	66.0	vol%	87.7	6.9	3.1	1.8	0.1	0.0	0.4
5	67.0	vol%	88.8	5.6	3.7	1.8	0.0	0.0	0.1
6	69.0	vol%	87.5	8.1	3.4	1.0	0.0	0.0	0.0
7	71.0	vol%	91.6	4.1	2.7	1.4	0.1	0.0	0.1
8	90.0	vol%	97.0	1.4	0.5	0.2	0.0	0.2	0.9
9	91.0	vol%	94.9	2.5	0.2	0.1	0.0	0.7	1.6


第 2 表 シェールガスの組成範囲
Table 2 Typical composition of shale gas

パラメータ	単 位	範 囲
CH ₄	vol%	63.8 ~ 96.8
C ₂ H ₆	vol%	0.0 ~ 30.0
C ₃ H ₈	vol%	0.0 ~ 25.0
nC ₄ H ₁₀	vol%	0.0 ~ 3.2
nC ₅ H ₁₂	vol%	0.0 ~ 3.2
H ₂	vol%	0.0 ~ 10.0
CO ₂	vol%	0.0 ~ 15.1
N ₂	vol%	0.0 ~ 8.0
温 度	K	720 ~ 950
圧 力	MPa	4.0 ~ 7.0
当 量 比	-	0.5 ~ 0.7
メ タ ン 価	-	40 ~ 100

の増大につながることを示唆されている。

5.3 エタンの影響

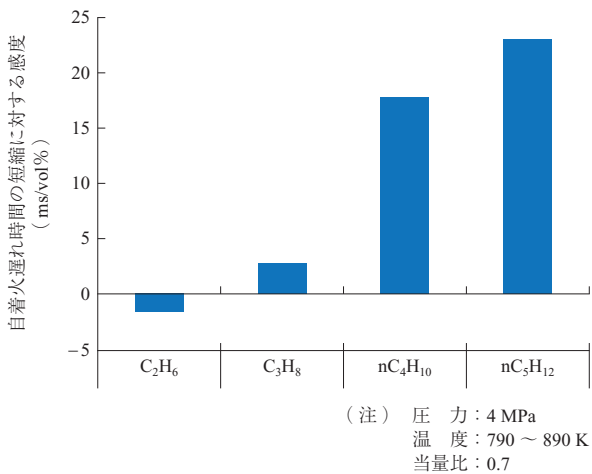
エタンの自着火遅れ時間への影響について、より詳細に調査するため、素反応解析を用いてエタンが増加した際の自着火遅れ時間の変化を計算した。在来型ガスを模擬した組成として、メタン単体にエタンを少しずつ加えた場合、およびシェールガスを模擬した組成として、メタンに *n*-ペンタンを 5% 加えた組成にエタンを少しずつ加えた場合の 2 条件について計算を行った。それぞれの組成に対し、エンジンの燃焼室内で取り得る温度である 1 050 K と 800 K の 2 条件について計算した。なお、800 K は RCM で実施



第 6 図 各ガス燃料のメタン価と自着火遅れ時間の関係
Fig. 6 Relationship between MN and auto-ignition delay of gaseous fuels

第 3 表 感度解析に用いたガス組成 (L18 直交表)
Table 3 Gas component of sensitivity analysis (L18 orthogonal array)

試験 No.	単 位	CH ₄	C ₂ H ₆	C ₃ H ₈	nC ₄ H ₁₀	nC ₅ H ₁₂	H ₂	CO ₂	N ₂
1	vol%	46.0	7.1	7.4	0.4	0.6	18.9	5.4	14.0
2	vol%	45.2	5.7	18.5	1.8	1.0	13.5	7.0	7.2
3	vol%	44.6	0.1	26.4	2.8	1.5	11.9	8.1	4.6
4	vol%	44.2	15.2	4.2	0.9	0.8	14.4	11.0	9.3
5	vol%	44.5	16.6	19.9	2.0	1.7	13.9	0.1	1.4
6	vol%	45.7	10.1	31.2	1.6	0.5	0.9	4.8	5.2
7	vol%	44.4	25.4	4.3	1.9	0.2	16.8	2.7	4.4
8	vol%	45.2	22.1	12.0	2.2	1.1	2.6	14.1	0.8
9	vol%	44.3	23.5	24.6	0.6	1.6	2.7	1.8	0.9
10	vol%	74.4	0.5	3.4	2.9	2.0	10.3	5.1	1.5
11	vol%	75.2	0.2	9.1	0.7	0.3	10.1	2.8	1.6
12	vol%	74.6	0.3	15.2	1.5	0.8	0.5	2.2	5.0
13	vol%	74.2	9.0	0.4	2.0	1.8	1.8	7.8	2.9
14	vol%	74.7	8.5	7.1	2.1	0.3	2.9	0.3	4.1
15	vol%	75.1	8.3	11.6	0.2	1.2	2.4	1.2	0.1
16	vol%	74.2	8.4	0.7	2.6	0.9	10.2	0.4	2.7
17	vol%	75.4	8.4	6.4	0.8	1.9	0.2	3.0	4.0
18	vol%	75.6	7.7	10.2	1.7	0.7	1.5	2.6	0.1



第 7 図 自着火遅れ時間に対する各成分の感度
Fig. 7 Sensitivity of each gas component to auto-ignition delay

した試験の範囲内であり、1 050 K はそれよりも高温である。

自着火遅れ時間に対するエタンの影響を第 8 図に示す。1 050 K の場合の結果を第 8 図 - (a) に、800 K の結果を - (b) にそれぞれ示す。第 8 図 - (a) の場合は組成によらずエタンの増加により自着火遅れ時間が短くなっており、一般的な知見と同様の結果である。一方で第 8 図 - (b) の場合、シェールガス模擬である *n*-ペンタンを加えた組成については、エタンの増加に伴い自着火遅れ時間が長くなっている。すなわち、シェールガスの広い組成範囲かつ RCM で試験可能な温度領域で感度解析を行ったために、エタンによって自着火遅れ時間が長くなる、従来の知見と異なる結果が第 7 図に現れたものと考えられる。

以上より、エタンの自着火遅れへの影響は、温度領域やその他の成分濃度によって、その度合いのみならず方向性

自体も変化することが分かる。その原因については今後さらに考察が必要であるものの、このエタンの特性がシェールガスの自着火特性の複雑さにもつながっていると考えられる。

6. 予測モデルの構築

6.1 予測モデルの概要


前述のとおり、シェールガスの自着火遅れ時間はシンプルな形では表しにくい。そこで、AI (深層学習を使用) を用いて自着火遅れ時間の予測モデルを構築することとした。

作成する自着火遅れ時間の予測モデルは、燃料組成、温度、圧力、当量比を入力値とし、自着火遅れ時間を出力値とするモデルであり、深層学習に用いる学習用データも同様である。

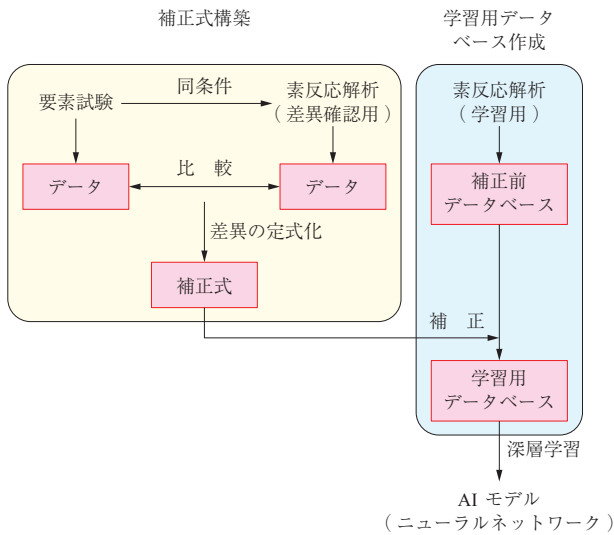
深層学習を行うためには学習用データとして膨大なデータベースが必要である。それらすべてのデータを試験によって得るのは困難であり、また実際のエンジンの筒内は要素試験よりもさらに高温・高圧になる場合もある。そのため、要素試験のみではデータを取得できないことから、素反応解析と組み合わせて学習用のデータベースを作成することとした。ただし、試験値と解析値の間には差異があるため、試験値を基準として補正式を作成して素反応解析の結果を補正することで、解析値を疑似的な要素試験結果として扱えるようにした。具体的な手順を第 9 図に示す。

6.2 素反応解析結果の補正方法

2 章でも述べたように、ある組成のガス燃料の自着火遅れ時間と温度の関係は、(2) 式で示したアレニウスの式で表せる。試験値と解析値ではその結果に差があるものの、



第 8 図 自着火遅れ時間に対するエタンの影響
Fig. 8 Effect of ethane on auto-ignition delay



第9図 自着火遅れ時間予測モデルの構築手順

Fig. 9 Procedure for constructing prediction model of auto-ignition Delay

それぞれの結果はアレニウスの式に従うと考えられる。

素反応解析を用いて、(2)式の係数である α 、 β について調査を行った。特定の成分割合を変化させ、その成分の割合とメタンの成分割合の和が一定となるようにメタンの割合を変化させて、各組成でのアレニウスの式への近似から α 、 β を求めると、 α はその成分濃度の指数関数で、 β は一次関数で、おおよそ表せることを確認した。その例を第10図に示す。このことから、 α 、 β はそれぞれ係数 γ 、 ϵ を用いて(7)式、(8)式の形で表すことができ、これらを(2)式に代入することで、素反応解析によって算出される自着火遅れ時間 τ_{cal} は(9)式で表すことが可能である。



$$\alpha_{cal} = \gamma_{cal,1} \prod_{i=2}^5 \exp(\gamma_{cal,i} [C_i H_{2i+2}]) \quad \dots\dots\dots (7)$$

$$\beta_{cal} = \epsilon_{cal,1} + \sum_{i=2}^5 \epsilon_{cal,i} [C_i H_{2i+2}] \quad \dots\dots\dots (8)$$

$$\tau_{cal} = \gamma_{cal,1} \left(\prod_{i=2}^5 \exp(\gamma_{cal,i} [C_i H_{2i+2}]) \right) \times \exp \left(\frac{\epsilon_{cal,1} + \sum_{i=2}^5 \epsilon_{cal,i} [C_i H_{2i+2}]}{T} \right) \quad \dots\dots\dots (9)$$

試験値も同様の関係式で表せると仮定すると、試験値 τ_{exp} は以下の(10)式で表され、さらに解析値 τ_{cal} と試験値 τ_{exp} の比の対数をとると、以下の(11)式が得られる。

$$\tau_{exp} = \gamma_{exp,1} \left(\prod_{i=2}^5 \exp(\gamma_{exp,i} [C_i H_{2i+2}]) \right) \times \exp \left(\frac{\epsilon_{exp,1} + \sum_{i=2}^5 \epsilon_{exp,i} [C_i H_{2i+2}]}{T} \right) \quad \dots\dots (10)$$



第10図 ガスの成分割合とアレニウス式の係数の関係の例
Fig. 10 Example of relationship between fraction of components and parameters of Arrhenius' equation (Calculation results)

$$\ln \left(\frac{\tau_{exp}}{\tau_{cal}} \right) = \ln(\gamma_1) + \sum_{i=2}^5 \gamma_i [C_i H_{2i+2}] + \epsilon_1 \cdot \frac{1}{T} + \sum_{i=2}^5 \epsilon_i \frac{[C_i H_{2i+2}]}{T} \quad \dots\dots\dots (11)$$

(11)式の右辺の各項は成分濃度もしくは温度と係数の積で表されることから、同じ条件での試験結果と解析結果の両方を用いて重回帰分析を行うことで、(11)式の係数 γ 、 ϵ を求めることができる。

また、(11)式を変形すると以下の(12)式になる。

$$\tau_{exp} = \gamma_1 \left(\prod_{i=2}^5 \exp(\gamma_i [C_i H_{2i+2}]) \right) \times \exp \left(\frac{\epsilon_1 + \sum_{i=2}^5 \epsilon_i [C_i H_{2i+2}]}{T} \right) \times \tau_{cal} \quad \dots\dots (12)$$

(12)式に上記で求めた係数(γ, ϵ)を入力することで、試験を行っていない条件についても、その条件についての解析値を補正して疑似的な要素試験結果として扱えるようになった。

6.3 モデルの構築

本稿では深層学習を自着火遅れ時間の予測に適用し、予測モデルを構築した。学習方法には教師あり学習を用いた。

学習用データには、6.2節で述べた補正式により素反応解析の結果を補正したものを使用した。第4表に自着火遅れ時間の予測モデルの構築範囲を示す。具体的には、表に示す範囲でガス組成、温度、圧力、当量比を振って計20 000点の計算条件を設定し、Chemkinを用いて各条件における自着火遅れ時間を計算した。このChemkinで算出された自着火遅れ時間を6.2節の方法で補正し、学習用データとして用いた。学習に用いる入力パラメータは、ガス組成(エタン、プロパン、*n*-ブタン、*n*-ペンタン)、温度、圧力、当量比の7変数とした。なお、ガスの成分割合の合計は必ず100%であるため、ここでは最も多く含まれるメタンの成分割合を従属変数として扱い、学習させる変数には含めていない。

深層学習には簡易プログラミング言語Python Ver. 2.7の機械学習ライブラリChainer 1.24.0(Preferred Networks社)⁽¹⁷⁾を用いた。適切なネットワーク構成を決定するため、中間層と中間層ノード数を変更して精度を確認した。中間層を6層、1層当たりのノード数を200とした場合が最も学習による誤差が小さくなったため、これらの値を採用した。活性化関数はLeaky ReLU⁽¹⁸⁾、最適化アルゴリズムにはAdam⁽¹⁹⁾を用い、過学習を防ぐためにDropout⁽²⁰⁾を10%使用した。バッチ数500、学習回数5 000回とし、学習では乱数を用いて20 000個のデータ中500個を検証用データ、残りの19 500個のデータを学習用データに分けて使用した。

第4表 自着火遅れ時間の予測モデルの構築範囲
Table 4 Ranges for developing prediction model

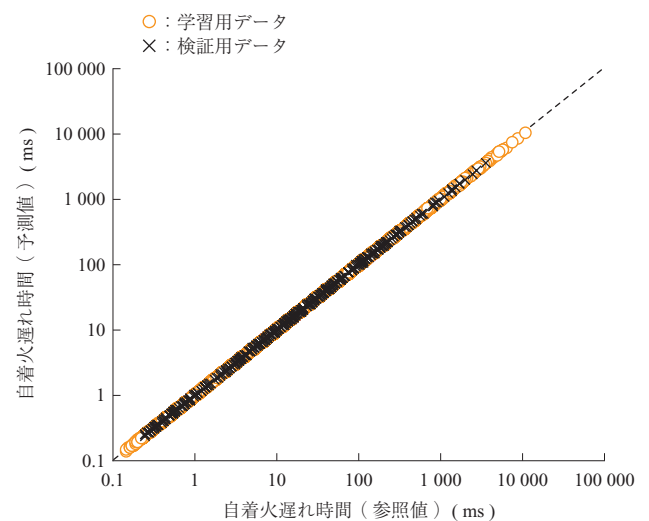
パラメータ	単位	範囲
CH ₄	vol%	64.5 ~ 100.0
C ₂ H ₆	vol%	0.0 ~ 25.0
C ₃ H ₈	vol%	0.0 ~ 5.0
nC ₄ H ₁₀	vol%	0.0 ~ 3.0
nC ₅ H ₁₂	vol%	0.0 ~ 2.5
温度	K	750 ~ 1 100
圧力	MPa	1 ~ 20
当量比	-	0.3 ~ 0.9

なお一般的に、教師あり学習における回帰の重み付けの更新に使用される誤差関数には平均二乗誤差が用いられ、本稿でも二乗誤差を用いているが、この方法では学習用データの全域において絶対誤差が同程度になるように学習がなされる。本稿の場合、自着火遅れ時間には条件によって大きな幅があり、数百msとなる条件もあれば1ms以下となる条件も存在する。そのため、すべての条件に対して同程度の絶対誤差を許容した場合、自着火遅れ時間が短い条件では算出される予測値が負の値となることがあり、自着火遅れ時間の予測モデルとしては不適切である。また、ノッキング時期の予測で用いる(1)式のLivengood-Wu積分では、予測した自着火遅れ時間の逆数を積分することから、自着火遅れ時間が長い条件では誤差が大きくてもノッキング時期の予測に及ぼす影響は比較的少ない。そこで、学習用データには自着火遅れ時間そのものではなく自着火遅れ時間の対数をとったものを用い、実際に自着火遅れ時間を予測するときは、深層学習によって学習されたニューラルネットワークから予測された数値を指数関数で変換して用いることとした。

学習の結果を第11図に示す。学習用データ、検証用データともに参照値と予測値がよく一致しており、自着火遅れ時間の学習精度が高いモデルを構築できていることが分かる。

6.4 精度検証

構築した自着火遅れ時間予測モデルの精度を検証するため、RCMにおいて実際のエンジンと同様の火花点火による火炎伝ばを再現し、エンドガスの自着火を生じさせるこ

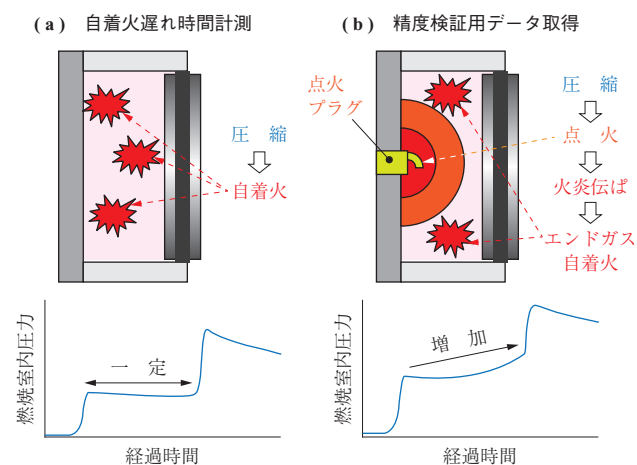


第11図 ニューラルネットワーク作成に用いた自着火遅れ時間の参照値と予測値の比較
Fig. 11 Comparison of reference and predicted value of auto-ignition delay


とでエンジンのノッキングを模擬した試験を実施した。3章で示した基礎燃焼試験と本精度検証試験の違いを第12図に示す。試験で計測した時々刻々変化する燃焼室内の圧力および温度履歴を基に、本自着火遅れ時間予測モデルによって各時刻の圧力・温度における自着火遅れ時間を算出し、算出された時々刻々の自着火遅れ時間をさらにLivengood-Wu 積分することでノッキング時期を予測した。ノッキング時期の予測値の算出の模式図を第13図に示す。

精度検証用試験は計 117 点実施した。第5表に自着火遅れ時間の予測モデルの検証範囲を示す。試験条件範囲はガス組成を第4表に示した予測モデルを構築した組成範囲と同様とし、当量比、圧縮端温度および圧縮端圧力を第5表に示す範囲とした。火花点火後は火炎伝ばにより圧力および温度が圧縮端での状態から上昇するが、その上昇過程についても、すべての試験条件で第4表に示した予測モデルの構築範囲に収まった。目標予測精度については、エンジンの燃焼モデルでは燃焼の時期の予測精度の目標値として、クランク軸の回転角1度を用いることが多い^{(21), (22)}。船用大型低速エンジンではクランク軸の回転角1度に当たる時間が約2msであることから、本稿では2msを本ノッキング予測モデルの精度の目標とした。

第14図に精度検証の結果を示す。横軸、縦軸ともに火花点火を起点としたときのノッキング時期を示している。横軸が精度検証に用いた試験データの値、縦軸が本モデルによる予測値となっている。第14図の点線は予測値と計測値が一致する条件を表し、データ点がこの線に近いほどその試験条件におけるノッキング時期の予測精度が高いことを示している。精度検証用試験の結果、多くのデータ点



第12図 要素試験と精度検証試験の差異の模式図
Fig. 12 Schematic of difference between fundamental test and validation test




第13図 自着火遅れ時間予測モデルを使ったノッキング時期予測の模式図

Fig. 13 Schematic of predicting knock timing by auto-ignition delay model

第5表 自着火遅れ時間の予測モデルの検証範囲
Table 5 Ranges for validating prediction model

パラメータ	単位	範囲
圧縮端温度	K	780 ~ 870
圧縮端圧力	MPa	4.0 ~ 5.5
当量比	-	0.6 ~ 0.7

が点線に対して非常に近い位置にあることが分かる。ノッキング時期を目標誤差2ms以内で予測できているデータ数は総データ数の78%に達しており、高い精度でノッキング時期を予測できている。なお、誤差2ms以上となった試験条件については、試験を行ったなかでも自着火遅れ



第 14 図 構築したモデルの予測精度の検証

Fig. 14 Comparison of knock timing between fundamental test and prediction

が比較的長く、実際のエンジン運転に当てはめるとノッキングが生じにくい条件である。今後はこのような条件での予測精度も高めていく必要があるものの、比較的ノッキングが生じやすく予測精度が必要とされる条件については、本ノッキング予測モデルによってノッキング時期を高い精度で予測できているといえる。

7. 結 言

非在来型ガスのガスエンジンにおける利用を考え、シェールガスの自着火特性について調査し、シェールガスを使用した際のノッキングが予測可能な技術を開発した。以下に得られた知見を述べる。

- ・メタン以外の成分を多く含む非在来型ガスでは、メタン価と自着火遅れ時間の相関は低く、メタン価から自着火遅れ時間やノッキング時期の予測は難しい。
- ・エタンの自着火遅れ時間への影響は、比較的溫度が低く、ほかの化学成分が多く含まれる場合、従来の知見と異なり、エタンの増加により自着火遅れ時間は長くなる。
- ・深層学習を用いることで、複雑な自着火特性をもつ非在来型ガスのノッキング時期を、高い精度で予測することが可能になった。

今後の課題と展望を以下に記す。

エタンの自着火遅れ時間に及ぼす影響が組成や溫度によって異なるメカニズムについては、現状ではまだ判明しておらず、さらなる分析が必要である。また、予測モデルの評価については、本稿では要素試験装置のみを用いて行ったが、今後は実際のエンジンでも評価する必要がある。

本稿では非在来型ガスの代表としてシェールガスを取り上げたが、同様の手法を用いることで、例えばバイオマス由来のガスや水素混合ガスなどの、より多様なガス燃料に対してもノッキング予測モデルの構築が可能であると考えられる。

— 謝 辞 —

本稿で述べた RCM を用いた要素試験は、国立研究開発法人産業技術総合研究所の高橋栄一氏にご協力いただき、実施いたしました。ここに深く感謝いたします。

参 考 文 献

- (1) COP21 の成果と今後：環境省地球環境局, https://www.env.go.jp/earth/ondanka/cop21_paris/paris_conv-c.pdf, (参照 2019. 10. 28)
- (2) International Maritime Organization : Amendments to the Annex of the Protocol of 1997 to amend the International Convention for the Prevention of Pollution from Ships, 1973, as modified by the Protocol of 1978 relating thereto (Revised MARPOL Annex VI), <http://www.imo.org/en/OurWork/Environment/PollutionPrevention/AirPollution/Documents/176%2858%29.pdf>, (参照 2019. 10. 28)
- (3) U. S. Energy Information Administration : Annual Energy Outlook 2018, (2018. 2), p. 65
- (4) R. J. Hill, D. M. Jarvie, J. Zumberge, M. Henry and R. M. Pollastro : Oil and gas geochemistry and petroleum systems of the Fort Worth Basin, AAPG Bulletin, Vol. 91, No. 4, (2007. 2), pp. 445 - 473
- (5) A. M. Martini, L. M. Walter and J. C. McIntosh : Identification of microbial and thermogenic gas components from Upper Devonian black shale cores, Illinois and Michigan basins, AAPG Bulletin, Vol. 92, No. 3, (2008. 3), pp. 327 - 339
- (6) International Group of Liquefied Natural Gas Importers : The LNG Industry in 2012, (2012)
- (7) K. Bullin and P. Krouskop : Composition Variety Complicates Processing Plans for US Shale Gas, (2008. 10)
- (8) National Energy Technology Laboratory : Liquefied Natural Gas: Understanding the Basic Facts, (2005)

- (9) G. Bourque, D. Healy, H. Curran, C. Zinner, D. Kalitan, J. de Vries, C. Aul and E. Petersen : Ignition and Flame Speed Kinetics of Two Natural Gas Blends With High Levels of Heavier Hydrocarbons, *Journal of Engineering for Gas Turbines and Power*, Vol. 132, No. 2, (2010. 2), 021504
- (10) J. C. Livengood and P. C. Wu : Correlation of autoignition phenomena in internal combustion engines and rapid compression machines, *Symposium (International) on Combustion*, Vol. 5, Iss. 1, No. 1, (1955), pp. 347 – 356
- (11) M. Leiker, K. Christoph, M. Rankl, W. Cartellieri and U. Pfeifer : Evaluation of antiknocking property of gaseous fuels by means of methane number and its practical application to gas engines, *ASME Paper*, (1972), No. 72-DGP-4
- (12) The CRECK Modeling Group : Complete mechanism (Version 1 412, December 2014), <http://creckmodeling.chem.polimi.it/>, (参照 2019. 10. 28)
- (13) ANSYS : Chemkin-Pro 15152, (2016)
- (14) AVL LIST GmbH : AVL Methane Ver. 3. 2, (2002)
- (15) P. J. Ross : Taguchi Techniques for Quality Engineering, McGraw-Hill, (1988)
- (16) J. Huang and W. K. Bushe : Experimental and kinetic study of autoignition in methane/ethane/air and methane/propane/air mixtures under engine-relevant conditions, *Combustion and Flame*, Vol. 144, Iss. 1 – 2, (2006. 1), pp. 74 – 88
- (17) Chainer : A flexible framework of neural networks, <https://chainer.org>, (参照 2019. 10. 28)
- (18) A. L. Maas, A. Y. Hannun and A. Y. Ng : Rectifier Nonlinearities Improve Neural Network Acoustic Models, *Proceedings of the 30th International Conference on Machine Learning*, (2013)
- (19) D. P. Kingma and J. L. Ba : Adam: A Method for Stochastic Optimization, *Proceedings of the 3rd International Conference for Learning Representations*, (2015), arXiv:1412.6980v9
- (20) N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov : Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research*, Vol. 15, (2014. 6), pp. 1 929 – 1 958
- (21) 林 卓哉, 山崎由大, 金子成彦, 疋田孝幸, 水野沙織, 藤井拓磨 : 離散化モデルを用いた HCCI エンジンの制御シミュレーション, *日本機械学会論文集*, Vol. 84, No. 860, 2018 年, p. 17-00325
- (22) Y. Yamasaki, R. Ikemura, M. Takahashi, F. Shimizu and S. Kaneko : Simple combustion model for a diesel engine with multiple fuel injections, *International Journal of Engine Research*, Vol. 20, No. 2, (2019), pp. 167 – 180