

特集：エネルギー産業への機械学習の応用

エネルギー産業における機械学習への期待

Expectations for Machine Learning in Energy Industries



深潟 康二*¹
FUKAGATA Koji

今は第3次人工知能（AI）ブームと言われており、インターネットやスマートフォンをはじめとして、至る所で機械学習技術が用いられるようになってきている。特に、FacebookやGoogleフォトに代表される機械学習を用いた画像の分類・タグ付け技術や、Google翻訳に代表される自動翻訳技術のここ数年での飛躍的な精度向上には驚かされている読者諸氏も多いのではなかろうか。この精度向上は、機械学習に用いられるネットワーク構造や要素の進化のみならず、インターネット上を行き来し、我々が意識しないうちに学習に用いられているデータ量の爆発的な増大の結果である。

実は筆者が初めて機械学習と出会ったのは今から27年前、まだ学部3年生の頃に受けていた「脳の情報処理論」という講義であった。既に第2次AIブームは終わってしまっていたが、何となくその面白さに惹かれ、その後、大学院修士課程の時分に、流体シミュレーション手法として当時新しい手法であった粒子法を二相流に拡張するにあたり、界面の計算の一部をニューラルネットワーク（NN）に肩代わりさせるという研究に挑戦していたが、何も結果が出ないまま留学を機にテーマを変えることとなった。その当時はNNを学習させるための「バックプロパゲーション」というアルゴリズムを実装するために、FORTRAN 77で何十行にもわたるプログラムを、教科書の数式を見ながら自分で書いていたものであった。

その後、留学先で始めた乱流に関するテーマで博士号を取得し、運よく大学教員となり、その後つい数年前まで機械学習をあまり意識することなく仕事をしてきたが、某研究会で材料科学への機械学習の応用に関する講演を聴き、その可能性に大きな衝撃を受けた。それ以来、私の専門である流体力学、特に、大量の学習データに事欠かない乱流に応用すればきっと面白いことができるに違いないと、主に乱流制御分野の研究者仲間と共に議論を重ね、現在「機械学習による乱流ビッグデータの特徴抽出手法の構築」という研究プロジェクトを始めている⁽¹⁾。

この研究プロジェクトで実際に手を動かしているのは筆者や研究分担者の研究室の学生達であるが、筆者が初めて機械学習に出会った頃に比べ、現在の機械学習の始めやすさには感動せざるを得ない。TensorFlowに代表されるバックエンド、それを使いやすくするKeras等のライブラリ群、そして勿論Python言語とその数値計算／描画ライブラリ群の充実により、20年前には何十行もコードを書かなければならなかったことが、今ではたった数行書けばできる。しかもGPUを使って高速に！また、数々の書籍やQiitaに代表される情報サイトのおかげで、非常に短時間で機械学習プログラミングが習得できる環境が整っている。さらには、技術計算言語であるMATLABの機械学習モジュールや、USBポートに差すだけの機械学習ハードウェア等の登場により、今後ますます機械学習は身近で殊更特別ではない技術になっていくであろう。

機械学習が得意とするのは分類と回帰であるが、どちらも今のところ我々が定義した評価関数を最小化する「単なるフィッティング」に過ぎないと筆者は感じている。しかし、人の手でフィッティングできるのはせいぜい2変数間の関係までであるのに対し、機械学習であれば10万変数のデータでも、GPUは多少熱くならうが嫌な顔一つせずフィッティングしてくれる。ここが機械学習の非常に強力な点であると言えよう。

本特集ではエネルギー産業における諸問題に対する機械学習の応用や、関連する低次元特徴抽出手法の応用に関する興味深い取り組みがいくつも紹介されている。機械学習の成否は、「単なるフィッティング」がそれ以上に価値を生み出すかどうかにあるが、エネルギー産業での機械学習の活用が本格化すれば、発電機器の高効率化やエネルギーのより安全で有効な利用等を通じて、持続的対して大きく貢献できることは想像に難くない。この分野における研究の進展に大いに期待したい。

参考文献

- (1) 慶應義塾大学理工学部機械工学科 深潟研究室, 「基盤Aのページ」 < <http://kflab.jp/ja/index.php?18H03758> > (参照日 2019年7月25日)。


原稿受付 2019年7月25日

* 1 慶應義塾大学理工学部機械工学科
〒223-8522 横浜市港北区日吉3-14-1
E-mail: fukagata@mech.keio.ac.jp

特集：エネルギー産業への機械学習の応用

典型例で眺める機械学習の様々なタスク

Various Tasks of Machine Learning with Typical Examples



矢入 健久*¹
YAIRI Takehisa

キーワード：機械学習, 人工知能, データ駆動科学

Key Words: Machine Learning, Artificial Intelligence, Data-driven Science

1. 緒言

機械学習の研究は、目的（ゴール）や利用可能なデータの性質などにより様々な学習タスクに細分化され、各タスクを解決するための手法・アルゴリズムが開発されてきた。したがって、機械学習を何かに応用する際には、まず、解決したい問題がどの学習タスクに分類されるのかを分析し、その後に具体的な手法を検討・選択するのが基本手順である。しかし、昨今のAIブーム・深層学習の流行の影響で、深層学習という手段・テクニックを使うこと自体が目的化してしまい、「（機械学習を使って）どんな問題を解決したいのか」、「どのようなデータが利用可能なのか」という本来の目的が軽視されているように感じられる。それどころか、「流行りの機械学習手法を使うために目的を変えてしまう」本末転倒な適用事例も見かけるようになった。本稿の目的は、機械学習が扱う様々な学習タスクを典型的な例題および代表的な手法とともに紹介することによって、研究者・開発者に「正しく」機械学習を使ってもらうことである。

2. そもそも機械学習とは？

機械学習とは、その名の通り、「機械（計算機）がデータから何かを自ら学習する」ための理論やアルゴリズムのことを指す。近年の第3次人工知能ブームの影響で、人工知能、機械学習、深層学習の3つが混同されることも多いが、本来、機械学習は人工知能の一分野として生まれ、統計解析（特に多変量分析）や最適化理論などの影響を受けて発展してきた。一方、深層学習は現在の機械学習において非常に有力な一分野あるいは一方法論という位置付けである（Fig. 1）。

機械学習には様々な理論・手法・アルゴリズムが含まれるが、その分類・整理の仕方についても様々な観点がある。




Fig. 1 Relationships among Artificial Intelligence (AI), Machine Learning (ML), and Deep Learning (DL)

ある。例えば、「教師ありか教師なしか」、「ベイズ的か非ベイズ的か」、「識別モデルか生成モデルか」、「スパース（疎）なモデルか否か」などである。これらの分類軸は、機械学習の専門家にとっては非常に重要な議論対象であるが、機械学習を手段・道具として使いたい他分野の専門家たちにとっては分かりにくさ、とっつきにくさの要因になっていると思われる。そこで、本稿では、(1)何を、(2)どのようなデータから、学習しようとするのかという「学習問題の類型」に基づいて様々な機械学習タスクを紹介し説明する。

例えば、入力パターン x に対して出力 y を返すような関数 $y=f(x)$ をデータから学習する場合を考える。このとき、(i) 出力 y が離散的な値（クラス・カテゴリーを表す値）か、連続的な数値（ベクトルの場合を含む）か、(ii) 学習に用いるデータ（訓練データ）が入力-出力の組 $\{(x_i, y_i)\}_{i=1, \dots, N}$ として与えられるか、入力のみ $\{x_i\}_{i=1, \dots, N}$ であるか、という2つの分類軸により、機械学習における4大タスク、すなわち、分類学習、回帰学習、クラスタリング、次元削減（特徴抽出）が導かれる（Table 1）。特に後者(ii)の分類軸はいわゆる「教師あり」と「教師なし」の違いを表すものであり、一般に、出力 y_i のことを（離散値、連続値に関わらず）「ラベル」と呼ぶ。次章では、これら4大タスクに加えて、強化学習などいくつかの主要な機械学習タスクについて、まず、典型的

原稿受付 2019年7月31日

* 1 東京大学・先端科学技術研究センター
〒153-0041 目黒区駒場4-6-1
E-mail: yairi@gecc.u-tokyo.ac.jp

Table 1 Major 4 Topics of Machine Learning: Classification, Regression, Clustering and Dimensionality Reduction

	Type of y: Categorical	Type of y: Numerical
Supervised	Classification	Regression
Unsupervised	Clustering	Dimensionality Reduction

な例題を挙げて直感的な理解を図ったうえで、代表的な手法や適用例を挙げる。

4. 例題で考える機械学習の主要タスク

4.1 分類学習

例題1 (分類学習): 迷惑メール判定器

過去に受け取った通常のメールと迷惑メールがともに多数あるとき、これを訓練データとして両者を自動的に判別する分類器を学習したい。

おそらく、読者のほとんどがお世話になっているであろう、迷惑メールフィルタは、機械学習の最も基本的なタスクである教師あり分類 (supervised classification) の典型的な例の1つである。このタスクでは、2つ以上のクラス (この例題の場合は、「通常メール」と「迷惑メール」という2つのクラス) について、それぞれ十分な数の事例 (データサンプル) が訓練データとして与えられることを前提とする。言い換えれば、訓練データに含まれる全サンプルに対して、「通常」か「迷惑」かのラベルが付与されているとする。このとき、分類学習の目標は、各メールに含まれている単語の頻度などのパターン (特徴ベクトル) x に基づいて、そのメールのクラス $y \in \{\text{通常}, \text{迷惑}\}$ をできるだけ正しく判定する分類器 (classifier) を与えられた訓練データから学習することである。このことは、Fig. 2 に示すように、パターンの空間 (特徴空間などと呼ばれる) に通常メール、迷惑メールのデータが分布していて、両者の識別境界面 (decision boundary) を求めることも考えることができる。

分類学習は機械学習において最も主要なタスクであり、多種多様な手法・アルゴリズムが開発されてきた。その中でも最も基本的なのが、多変量解析の線形判別分析に由来する線形識別器 (linear classifier) である。その他、順不同で有名なものを挙げれば、決定木 (decision

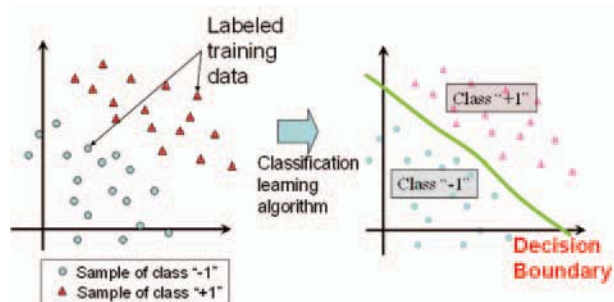


Fig. 2 Two-Class (Binary) Classification

tree), ランダムフォレスト (random forest), 多層パーセプトロン (multi-layer perceptron), ロジスティック回帰 (logistic regression), サポートベクトルマシン (support vector machine), k-最近傍法 (k-nearest neighborhood) などがある。なお、例題の迷惑メール判定器では、単純ベイズ分類器 (naïve Bayesian classifier) による実装が有名である。

分類学習の応用は多岐にわたるが、画像による物体認識、文字認識、文章分類、などが分かりやすい例であろう。ガスタービン分野の研究においても、例えば、観測データから燃焼状態を既知のクラスに分類したい、というようなケースはあるのではないかと想像する。ただし、繰り返し述べているように、教師あり分類学習では、ラベル付けされた訓練データが必要である。

4.2 回帰学習

例題2 (回帰学習): 賃貸物件の家賃推定

賃貸物件の様々な条件 (部屋の広さ、建物の築年数、最寄駅までの距離、等) を入力したら適正な家賃を出力するシステムを、過去の賃貸物件データを利用して作りたい。

これは、民泊仲介サイトとして有名なAirbnbが2015年に発表した、貸主にとって最適な宿泊料を決定してくれるAerosolveというサービスをヒントにした例題である。この例のように、データサンプル (賃貸物件) の特徴 (属性) ベクトル x が与えられたときに、数値 y を出力するモデル (関数) $f(x)$ をリグレッサー (regressor) と呼び、関数 $f(x)$ を訓練データ $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ から推定することを回帰学習あるいは単に回帰 (regression) と呼ぶ。

訓練データ D の各サンプルに正しい出力値 (ラベル) y_i が含まれていることから、回帰学習もまた分類学習と同様に教師あり学習であることが分かる。言い換えれば、分類学習と回帰学習の違いは、出力値がクラスを表すカテゴリー値であるか、数値であるか、という点にある。分類学習と回帰学習の2つを合わせて教師あり学習と呼ぶことが多いが、カテゴリー値や数値以外の型 (例えば、グラフや木などの構造や関係、順位、など) を出力する教師あり学習も存在する。

分類学習の場合と同様、様々な回帰学習手法が開発されてきた。最も基本的なのは、最小二乗法による線形回帰 (linear regression) モデルであり、これを色々な方法で非線形化することで、サポートベクトル回帰 (support vector regression), ガウス過程回帰 (Gaussian process regression), 局所重み付き線形回帰 (locally weighted linear regression) などが生まれてきた。また、分類学習手法である決定木や多層パーセプトロンの出力を実数値に変更することによっても非線形回帰モデルが得られる。

回帰学習における重大な関心事として、入力 (特徴、説明変数) ベクトル x が非常に高次元であり、かつ、そ




Fig. 3 Regression




Fig. 4 Clustering

の中には多数の無関係な特徴も含まれているような場合に、重要な（意味のある）少数の特徴だけを選択したいという要求、すなわち、特徴選択（feature selection）がある。特徴選択機能を有する回帰学習として、近年、LASSO（least absolute shrinkage and selection operator）に代表されるスパース回帰（sparse regression）の研究が発展した。賃貸物件の家賃予測の例で言えば、例えば、「2軒隣の住人の血液型」とか「最寄りの歯科医の苗字」など、家賃決定に何ら影響を及ぼさないであろう説明変数・特徴量は自動的に除外される（その特徴に対する重み係数が0になる）ということである。

多数の計測値やパラメータ値からシステムの出力結果を予測したいという問題は様々な分野にあるが、専門知識に基づくモデルが無い代わりに過去の実績データが十分にあるような場合は、回帰学習の適用を検討する価値があるであろう。ただし、訓練データとは大きく異なる入力 x に対して出力 y を予測すること、すなわち、外挿はどのようなモデル・アルゴリズムを用いたとしても難しい。

4.3 クラスタリング

例題3（クラスタリング）論文ファイル自動分類

研究や勉強で使う参考論文の電子ファイルを全て同じフォルダにダウンロードしていたら、いつの間にかファイル数が数百個になって取捨が付かなくなりました。内容が関連しているもの同士をグループ化して、自動分類したい。

著者は整理整頓が苦手なため、このような例題を考えてみた。ここでは、データ（ファイル群）の各サンプル（各論文ファイル）に、あらかじめ「空力関連」とか「材料関連」などの所属すべきカテゴリー、すなわち、ラベルが付けられていないため、前述の（教師あり）分類学習では扱うことができない。それに対して、教師なし学習の代表格であるクラスタリング（clustering）は、ラベルの代わりにサンプル同士の関連性、類似度、距離に基づいてデータを「自然な」グループに仕分けする問題・手法である。

例題に類似する問題は他にも多数ある。例えば、通信販売サイトなどで顧客の購買データをクラスタリングしていくつかのグループに分類することは、マーケティング戦略などを検討するのに役立つし、バイオインフォマティクスでは生物種の遺伝子配列をクラスタリングすることで、系統図を作成することができる。読者も大量に取得した実験計測データや画像データなどを自動分類し

たいと思ったことはあるのではないだろうか。このような利用例を見ると、クラスタリングは分類学習と比べて、より人間のかつ曖昧なタスクに感じられると思う。実際、分類学習における識別精度のような絶対的な評価基準がクラスタリングには無い。つまり、クラスタリング結果の良し悪しの判断は、最終的にはそれを利用する人間が行うしかない。また、データから得られたクラスタが実世界の何のカテゴリーに対応しているのか、という疑問に対してもクラスタリングアルゴリズム自体が答えてくれるわけではなく、人間が結果を評価して考えなければいけない。逆に言えば、全体像を把握することが困難な膨大な高次元データについて、人間にヒントを与えてくれることがクラスタリングの意義のひとつである。

教師あり学習（分類・回帰学習）に比べれば少ないが、クラスタリングにおいても様々な手法・アルゴリズムが考案されてきた。代表的なのが、 k -平均法（ k -means method）、混合ガウス分布モデル（Gaussian mixture model）をEM algorithmによって学習する方法、階層的クラスタリング、スペクトラルクラスタリング（spectral clustering）、などである。最後に挙げたスペクトラルクラスタリングでは、グラフラプラシアン（Graph Laplacian）と呼ばれる行列が出てくるが、これは、物理学でお馴染みのラプラス作用素 Δ と深く関連している。ラプラス方程式を解く代わりに、グラフラプラシアンの「小さい固有値」に対応する固有ベクトルを計算することで、各データサンプルの「自然な」帰属を求めており、物理的な解釈が可能な点で興味深いと思う。

ところで、クラスタリングを実際のデータに適用する際には、クラスタの数をどうやって決めるのかという問題が生じる。この問題は、より一般的にモデル選択（model selection）と呼ばれる機械学習の大問題の一種であり、情報量基準による方法、ベイズ的な立場から周辺尤度を最大化する方法などの理論的な研究も多数行われている。しかし、筆者が知る限り、実際の応用の現場では、固有の問題ごとに経験則を用いたり、結果を見ながら試行錯誤的に決めることがほとんどである。これは研究者にとっても利用者にとっても歯がゆい状況であるが、そもそも訓練データに正解ラベルが含まれていないという教師なし学習の本質から見て、根本的かつ汎用な解決策は存在しないであろうと著者は考える。

4.4 次元削減

例題 4 (次元削減) 高次元データの可視化・特徴抽出
フィールドワークや実験で収集した多数のサンプルについて、様々な計測を行って得られた高次元データがあるとする。このデータの分布、サンプル間のバリエーションを特徴づける比較的少数の特徴量を発見し、それらを座標軸とした空間に表示することでデータの分布を可視化したい。

データの次元削減 (dimensionality reduction) とは、「高次元データをできるだけ本質的な情報を失わずに低次元データに変換して表現すること」である。

次元削減の利用法として一番わかりやすいのは、上の例題で取り上げたような高次元データの可視化であろう。一般に、4次元(変数)以上のデータを1度のプロットで見ることができないが、2次元あるいは3次元に次元削減して散布図をプロットすれば、データの分布やサンプル間の近接関係を把握することができる。また、次元削減によって得られた少数の変数は、データ(サンプル)の特徴量、あるいはデータが生成される背後にある因子、として解釈することもでき、それを目的としたデータ解析は特徴抽出、因子分析などと呼ばれる。また、複雑な現象から生じた多変量時系列データをいくつかの固有モードの重み和に近似的に分解することも次元削減の一種として捉えることができる。さらに、次元削減によって得られた低次元データから元の高次元データを近似的に復元できる場合には、データ圧縮の目的でも用いられる。

様々な次元削減手法の中で、最も基本となるのが主成分分析 (Principal Components Analysis; PCA) である。PCAは、分野によってKarhunen-Loeve展開 (KL展開) や固有直行分解 (Proper Orthogonal Decomposition; POD) などの名前でも呼ばれている。一般的な多変量解析の教科書では、PCAはデータ共分散行列の固有値・固有ベクトルを求める問題として紹介されることが多いが、別の解釈として、中心化された(平均ベクトルを全サンプルから一様に差し引くことによって、平均が0に一致するように補正された)データ行列の特異値分解 (Singular Value Decomposition; SVD) と等価であることが知られている。そのため、機械学習では、文脈によって、PCAとSVDを区別せずに扱うこともある。

PCA以外にも多くの次元削減手法が存在するが、そのほとんどは、PCAを何らかの形で拡張したものとみなすことができる。例えば、上で述べたSVDとの等価性に基づいて、データ行列の分解・低ランク近似として派生したのが、非負値行列分解 (Non-negative Matrix Factorization; NMF) や、疎表現 (sparse coding) における辞書学習 (dictionary learning) であり、非線形化したのがカーネルPCA (kernel PCA)、Isomapなどの一連の多様体学習アルゴリズム、ニューラルネットワークを用いたオートエンコーダ (Autoencoder) な

どであり、確率的な潜在変数モデルに拡張したのが因子分析 (Factor Analysis; FA) モデル、確率主成分分析 (Probabilistic Principal Components Analysis; PPCA) モデル、変分オートエンコーダ (Variational Autoencoder; VAE) などである。

ところで、次元削減と言えば通常は教師なし次元削減を意味するが、実は、教師あり次元削減と呼ばれる手法も存在する。これは、教師あり分類・回帰学習において、膨大な数の説明変数からより少数の特徴量を得る目的で使われるもので、フィッシャー判別分析 (Fisher's Discriminant Analysis; FDA) や、部分線形二乗回帰 (Partial Least Squares regression; PLS) などが代表である。

4.5 潜在変数モデル・生成モデルの学習

例題 5 猫画像生成モデルの学習

大量の猫の画像コレクションを訓練データとして、猫画像が確率的に生成される過程のモデルを学習し、新規の猫画像のサンプルを生成(創作)させたい。

前々節と前節では、教師なし学習のツートップであるクラスタリングと次元削減を、教師あり学習(分類学習、回帰学習)との違い、すなわち、学習時にラベル(目的変数の値)が与えられるか否かという点を強調して説明してきた。教師あり学習と対比させるのは一見分かりやすいが、裏を返せば、「教師ありではない学習が教師なし学習である」と言っているのと大して変わらず、教師なし学習の本質を的確にとらえているとは言い難い。

ここでは一旦、教師あり学習のことは忘れて、教師なし学習とは何かを考えてみよう。前々節で述べたクラスタリングは「与えられたデータを自然なグループ(クラス)に分割すること」、前節で述べた次元削減は「高次元データをなるべく情報を失わずに低次元データに変換すること」であった。これらに共通するのは、与えられたデータの背後にあるクラスや低次元空間という構造を求めようとしている点である。すなわち、教師なし学習とは、「高次元の複雑なデータを、少数の潜在変数あるいは単純な構造とパラメータで表現すること」、もっと乱暴に言えば、「データを勝手にモデル化すること」である。そして、そのようなデータモデル化の方法として機械学習で広く用いられているのが、潜在変数モデル (Latent Variable Models; LVM) である。LVMでは、データとは我々が直接観測できる顕在変数(ベクトル)の値であり、その背後に直接観測できない潜在変数が存在していると考えられる。潜在変数として離散的な有限個の値を取るスカラー変数を考える場合がクラスタリング、連続値を取る低次元ベクトルを考える場合が次元削減、と解釈することができる。

高次元データが与えられたときに潜在変数(ベクトル)の値を推定するだけでなく、同時に、潜在変数からデータが生成されるメカニズム、すなわち、生成モデル (generative model) も得られる場合、本節の例題のよ

うな画像生成のような応用も考えることができる。

実際、深層ニューラルネットワークを用いた教師なし学習である前述のVAEや生成的敵対ネットワーク (Generative Adversarial Networks; GAN) が、現在、そのような用途に盛んに利用され注目を受けている。画像生成 (創作) というと極めて高度な「知性」のように感じられるが、冷静に考えれば、「ある学校で行った身体測定で得られた児童の身長・体重のデータを2次元の正規分布でモデル化し、この正規分布からサンプリングし直すことで、仮想的な (つまりプライバシー問題の無い) 児童の身長・体重データを生成する」という別の簡単な問題とやっていることは本質的には同じである (違うのは複雑さだけである) ことを付け加えておきたい。

このカテゴリーに属する基礎的な手法としては、クラスタリング、次元削減の節でそれぞれ言及したGMM, PPCAが挙げられる。また、自然言語処理などで用いられている潜在的ディリクレ配分 (Latent Dirichlet Allocation; LDA) などの確率的トピックモデルも潜在変数モデルの代表である。

4.6 強化学習

例題6 (強化学習) 最適経路の学習

引越してきたばかりの街で、毎日いろいろな経路や交通手段を試しながら職場への最適な通勤経路を学習したい。

GPSと連動した地図ナビゲーションソフトや乗り換え案内サービスが普及している今日では、ややリアルティに欠ける問題設定ではあるが、強化学習の「未知環境下における最適意思決定問題」という重要な性質を端的に表している例題であると考えられる。

今まで述べてきた教師あり・教師なし学習では、まず (訓練) データが与えられているという前提があった。それに対して強化学習ではそのようなデータが最初から与えられておらず、各時刻で行為 (action) を選択して状態遷移し、知覚と報酬を得ることで逐次的に新しいデータ (というよりも経験) を得る。そして、その経験から、評価関数 (報酬の和) を最大化するような行動則を獲得することが学習の目的となる。より具体的には、ある状態 s が与えられたときにどの行為 a を選択すべきか、という方策 (policy), あるいは、状態 s において行為 a を選択することの行動価値関数 (state-action value function) を学習する。もしも、初めから環境に関する完全な知識を持っていれば、評価関数を最大化する行為を選択することは比較的容易だが、実際はそのような知識がないために、リスクを取って未経験の行動を試してみる必要がある。これは、探索と利用 (exploration and exploitation) のトレードオフと呼ばれている。また、強化学習はしばしば制御工学における適応制御 (adaptive control) 問題との類似性を指摘される。すなわち、状態空間や制御入力を離散化した場合の適応制御問題が強化学習であるという解釈である。

冒頭に挙げた経路学習の例に限らず、未知環境下での意思決定問題は世の中のあらゆるところに存在する。それどころか、各個人の人生自体が未知環境下での意思決定問題 (の連続) によって成り立っていると見ることができる。その意味で強化学習は極めて汎用な枠組みである。ただし現実的には、学習に必要な多数の試行錯誤が許容される問題、例えば、ゲームプレイであったりシミュレーション世界でのロボットの行動学習、などへの応用が先行している。

強化学習の代表的な手法としては、行動価値関数 $Q(s, a)$ を更新していくQ学習 (Q-learning) や、方策 (のパラメータ) を学習する方策勾配 (policy gradient) 法などが挙げられる。また、近年では深層ニューラルネットワークを用いて行動価値関数を近似的に学習する方法が大きな成果を挙げている。

4.7 半教師あり学習

例題7 (半教師あり学習) : 迷惑メール判定器2

目的は例題1と同じく迷惑メール分類器を学習することだが、訓練データの中で「迷惑」「通常」のラベルが付けられたメールの数は少なく、大多数は未分類 (ラベル無し) メールである状況を考える。

再び、教師あり・教師なし学習の話に戻るのだが、両者の中間となる問題が、その名の通り、半教師あり学習 (semi-supervised learning) である。そのモチベーションは分かりやすく、「本当は教師あり (分類・回帰) 学習をしたいのだけど、ラベルの付いている訓練データがあまりない」あるいは、「教師なし学習 (クラスタリング・次元削減) をやろうと思ったが、いくつかのサンプルにはラベルが付いているのでそれを最大限有効利用したい」というものである。冒頭の例題の場合、膨大な過去のメールの1つ1つに対して「迷惑メール」「通常のメール」というラベルを手動で付けて行くのは面倒である。数十個程度のメールを手動で分類したら、後は自動でやって欲しいと思うのが自然であろう。つまり、「ラベルは (コストが) 高い」ので、ラベルあり・なしデータを混ぜて使おうというのが半教師あり学習、および、トランスダクティブ学習 (transductive learning) と呼ばれる学習法である。

Fig. 5は、多数のラベル無しデータと少数のラベルありデータが混在する状況下での、教師あり・教師なし・半教師あり分類学習を対比して図示したものである。半教師あり学習手法としては、生成モデルを用いて教師あり学習と教師なし学習を組み合わせる方法や、データから近傍グラフを作成して正則化 (regularization) を行う方法などがある。




Fig. 5 Comparison among Supervised, Unsupervised, and Semi-supervised Classification

4.8 異常検知

例題 8：稼働異常検出

A社では自社工場の稼働データを蓄積している。このデータを利用して異常な稼働状態を早期検出したい。ただし、異常発生は極めて稀であり、過去のデータにはほとんど含まれていないとする。

IoTに代表される計測通信技術が発達し、現在、例題のような生産現場を始めとして、様々な分野で常時大量のデータが取得されている。そのような蓄積データの有望な利用法の1つが異常検知 (anomaly detection) である。その名の通り、正常なサンプルと異常なサンプルとを識別することが目的であり、その点では教師あり分類学習と変わらない。しかし、分類学習では、訓練データの中に各クラス (すなわち、正常と異常それぞれ) に属するサンプルが十分に含まれることを前提しているのに対して、異常検知では異常サンプルがほとんどあるいは全く与えられない、すなわち、正常データだけで学習することが求められるという点で大きく異なっている。正常クラスのみから学習するという意味で、1クラス分類学習 (one-class classification) とも呼ばれる。1クラスサポートベクトルマシン (One-Class Support Vector Machines; OCSVM) のように1クラス分類問題に特化した手法、最近傍サンプルとの距離に基づく手法、確率密度推定に基づく手法、再構成誤差に基づく手法などがある。また、異常検知手法の多くは、教師なし学習の応用と見ることができる。つまり、正常データについて教師なし学習を適用することによって、その生成モデルやクラスタ構造、低次元構造などを学習し、それらのモデル・構造から乖離するサンプルを異常として検出するという考え方に基いている。

4.9 動的システム学習

例題 9：時系列データのモデル化

B研究室では、ある非定常現象に関する実験を複数回実施し、大量の多次元時系列データを取得した。このデータから当該現象を再現・予測できるようなモデルを得たい。

4.6節で述べた強化学習を除けば、一般に機械学習ではデータサンプル間の時間的な依存関係を考慮しない場合がほとんどである。本稿の2章で、「典型的な機械学習は関数 $y=f(x)$ をデータから推定することである」と述べたが、この関数に時刻変数 t が含まれていないことか

らも典型的な機械学習は静的なシステムを前提として行うことが分かる。それに対して、時系列データを入力として、常微分方程式 (や差分方程式) で表されるような動的なシステムのモデルを学習しようとするのが、動的システム学習 (learning dynamical systems) と呼ばれる問題である。歴史的な経緯は異なるが、制御工学のシステム同定問題と関連性が強い。機械学習での動的システム学習の研究は、隠れマルコフモデル (Hidden Markov Models; HMM) や線形状態空間モデル (Linear Dynamical Systems; LDS) などの基本的なモデルを前述の潜在変数モデルへ一般化することで発展してきた。さらに近年では、深層ニューラルネットワークと融合することにより高次元で非線形性の強い動的システムを扱おうとする研究も多く見られる。

5. 結言

本稿では、機械学習で扱う様々なタスクのタイプを典型的な例題とともに紹介した。一概に機械学習と言っても、何を目的とするのか、どのようなデータが与えられるのか、などの違いによって、用いるアプローチや手法は大きく異なることを分かって頂けたと思う。自身の専門領域やデータに機械学習を応用することを検討している読者の役に立てれば幸いである。

なお、紙面の制約上、本稿で挙げた様々な手法名について原典を参考文献として挙げることは控えたが、手法名で検索すれば、原典の論文や詳しい解説、実装方法を容易に調べることができる。一応、各分野の代表的な教科書を挙げておくと、分類・回帰学習、クラスタリング・次元削減の4大分野および動的システム学習を基礎から学ぶ場合は、現代の機械学習のバイブルとも呼ばれているBishopによる(1)を推奨する。また、強化学習についてはSuttonとBartoによる(2)を、半教師あり学習については詳細に学びたい場合は(3)をお薦めする。

参考文献

- (1) Bishop, C. M., Pattern Recognition and Machine Learning, (2006), Springer.
- (2) Sutton, R. S. and Barto, A. G., Reinforcement Learning: An Introduction, Second Edition (2018), MIT Press.
- (3) Chapelle, O., et. al. (eds.), Semi-Supervised Learning, (2006), MIT Press.

特集：エネルギー産業への機械学習の応用

発電設備におけるデジタルテクノロジーの適用について Digital Technology Applications for Power Generation Assets



シン イ エキ
秦 宇暉*1
SHIN Ieki

キーワード：ガスタービン，コンバインドサイクル，汽力発電，IoT

Key Words：Gas Turbine, Combined Cycle, Steam Power, IoT

1. 緒言

近年、発電事業者を取り巻く環境は目まぐるしく変化している。とりわけ、風力発電や太陽光発電に代表される再生可能エネルギーの増加と電力自由化による競争の激化は発電所運営に不確実性をもたらし、また事業者には更なる原価低減の努力が求められる。

一方、通信環境の発達や計算機の処理能力の目覚ましい発展は、大量に生み出される発電所運転データをいわゆるビッグデータ解析と呼ばれる、AI、機械学習等を活用したリアルタイム分析を通じた新たな知見を設備運用者へ提供することを可能にした。現在、日本のみならず海外でも多くの事業者がこれらIoT技術を活用した発電所運営の更なる最適化、効率化に向けての取り組みを実施しており、General Electric社（以下、GE）もソリューション提供社の一つとして活動を行っている。本稿では、GEの提供するソリューションの解説を通じて、発電設備へのデジタルテクノロジーの適用についての一つの形を紹介する。

2. 産業向けIoTプラットフォーム PREDIX

GEでは、産業向けIoTの基盤としてPREDIXというIoTプラットフォームを整備してきた。オープンイノベーションプラットフォームであるPREDIXでは、すでに950社以上、33,000人以上の開発者が参加してPREDIX上でのアプリケーションの開発を行っている。次章以降で説明する予兆管理、保全最適化ソフトウェアはGEがPREDIX上で開発したアプリケーションであり、その開発に当たってはGEがこれまで蓄積してきた発電設備の設計ノウハウ等を投入しているが、プラットフォームをあえてオープンにすることで、多様な知見、経験を持ったパートナーが独自の分析アルゴリズムなど

をPREDIX上に展開しやすい環境を整備している。次章以降では、PREDIX上で展開するGEが開発したアプリケーションについて個別に紹介していく。



Fig. 1 PREDIX Overview

3. 予兆検知による信頼性の向上

本章ではGEが開発しPREDIX上で展開している予兆検知システムについて説明する。

予兆検知とは、機器の異常状態を従来の監視制御システムで警報と認知される前にその運転状態値の微小な変化を捉えることである。機器の異常が軽微な段階で運転員に通知することで、異常の進展による損傷箇所の拡大を防止し、それによって補修費用の増大と停止期間の長期化を軽減する。また、異常の進展による突発的なユニットトリップを防ぐことで計画外の発電停止を計画的な停止にすることができれば、代替電源を事前に確保することによる収益面での貢献も考えられる。

一般的に、予兆検知には2通りのアプローチが考えられる。一つ目は、正常な運転データを基に本来あるべき運転データを予測し、実測値がこれから外れた場合に異常とみなす方法。もう一つのアプローチは、異常時の運転データを基に異常分析のモデルを作り、実測値がこのモデルに合致すれば異常とみなす方法である。

Fig. 3は前者アプローチの予兆検知の概念図で、正常な運転データから作られたモデルから出てくる“あるべき姿”と実データ（実測値）との乖離が従来の監視制御

原稿受付 2019年7月8日

*1 GE Power

〒107-0052 港区赤坂5-2-20

E-mail: Ieki.Shin@ge.com




Fig. 2 Conceptual benefit of Predictive Alert System

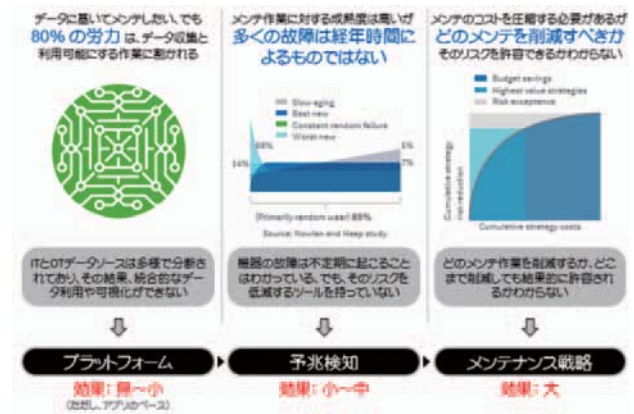


Fig. 4 Problems for Optimized Maintenance Planning

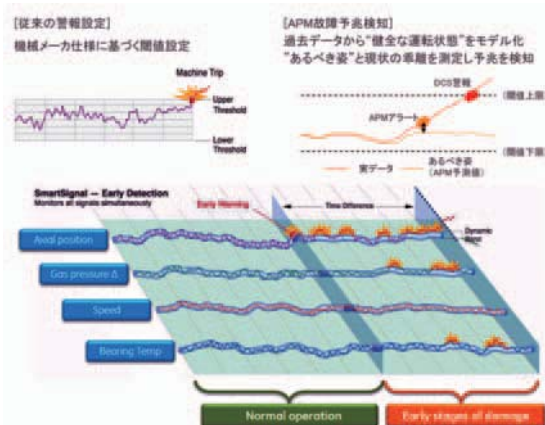


Fig. 3 Concept of Predictive Alert System. Comparison between Actual Data and Model Predicted Data

システムによる警報設定値（図ではDCS警報値）より下で始まれば予兆警報として有用と言える。そのためには“あるべき姿”の精度が重要で、モデルの設計には細心の注意が必要になる。

後者のアプローチは、コンセプトは従来の監視制御システムで行われている異常検知と同じであるが、複数の入力を基にしたより複雑な異常検知分析を行い、しかもDCSの外に分析モデルを持つことで比較的容易にこれらの変更、チューニングを行うことが出来るという利点がある。

3. デジタルテクノロジーを活用した保全計画の最適化

GEの提唱する保全計画の最適化に向けたアプローチは時間基準保全（TBM：タイムベースドメンテナンス）の保全から状態基準保全（CBM：コンディションベースドメンテナンス）と信頼性中心保全（RCM：リライアビリティベースドメンテナンス）への移行を目指すことである。既に多くの事業者では状態基準あるいは信頼性中心の保守の取り組みが実施されているが、現実的にはいくつかの課題がある。

Fig. 4では3つの課題を取り上げた。まず、保全員が

設備の保全計画を保守最適化の考え方に基づいて策定しようとした場合、実際の検討に要する時間よりも検討に必要な関連情報を収集する事に多大な労力を使っているという実態がある。

過去の保全履歴や故障履歴等のデータは社内のIT環境（業務用PCや社内共通のデータサーバー等）に保存されている事が多いが、一方、当該設備の警報発生履歴はOT環境（プラント制御用計算機等）に蓄積され、さらには運転員による巡視点検記録は紙ベースでの管理、あるいは保全履歴とは別のIT環境、データベースで管理されている事がある。この場合、保全員は複数の情報源からの情報を収集、整理する事になり負担が大きい。これに対する解決策として、EAM（設備情報管理システム）からの情報をデータ連携によってタイムリーに受信し、設備毎に自動的に表示させることでメンテナンス最適化の第一段階である情報収集にかかる労力を大幅に削減させることが考えられる。これにより、保全員に本来の業務である「考えること」に集中する時間を確保し、より生産性の高い保全計画の策定を促すことができる。

次の課題として、不定期に発生する機器の異常を効果的に予見することができないと言う事がある。GEの調査によると、発電所で発生する機器の異常の原因の多くは運転時間に依存しないことが分かっている。これは、現在広く行われている時間基準保全の効果の現れとも言えるが、保全周期を延長する事によって上昇するかもしれないリスクを低減するためのツールが必要になる。こ



Fig. 5 Dashboard with real time quantified maintenance factors in equipment level

ここで、GEでは先に述べた予兆検知の仕組みを活用することでより状態基準保全に近い運用を提案している。

最後の課題として、保全メニューの変更による費用削減効果とリスク上昇幅が定量化されておらず、変更の際の意思決定が難しいということである。定性的なリスク評価は個人レベルでの裁量に依存することになり、結果的に意思決定にブレが生じることになり、膨大な量の設備を長期間にわたって運用する発電事業者にとっては保全計画最適化の大掛かりな仕組みを導入しづらい。これに対して、GEの提案するソフトウェアではポンプやボイラーといった設備単位よりさらに細かく部位単位での故障リスクと影響度を数値化して表示する事で、リスクの定量化を支援することができる。これらの数値化の基本となるのはFMEAとRCAで、ユーザー自身が実施したFMEAあるいはRCAの結果をソフトウェアに入力することから始まる。これらの初期設定が終わればソフトウェアがEAMから自動的に関連設備データを抽出してリスクと効果を数値化、表示する仕組みである。

4. デジタルツインによるプラント性能可視化




Fig. 6 Image of Digital Twin

前章まではデジタルテクノロジーを活用した予兆検知による信頼性向上と保全計画最適化といった火力プラントの運用面の改善のための取り組みを紹介してきた。

以降の章では、デジタルテクノロジーによるプラント性能向上についての取り組みをいくつか紹介する。

これらの取り組みのポイントとなるのはデジタルツインと呼ばれる仮想空間上に構築したプラントモデルと実運転状態との比較であるが、まずはデジタルツインを用いた性能可視化の概要とその目的について述べる。

火力プラントにとって経年的な性能の劣化はプラントのタイプによって程度の差はあるものの必ず発生するもので、事業者にとっては定量的な性能の管理はきわめて重要である。既に多くの事業者が独自に性能管理ツールを導入し日々の運用に活用されているが、近年のデジタル技術の発展と共に、これらをより詳細かつ広範囲に適用できる仕組みが整ってきた。

性能劣化可視化の第一歩は理想の運転状態をデジタルツイン上に再現することである。多くの場合、新設時の設計条件または新設時点での運転状態を理想の運転状態

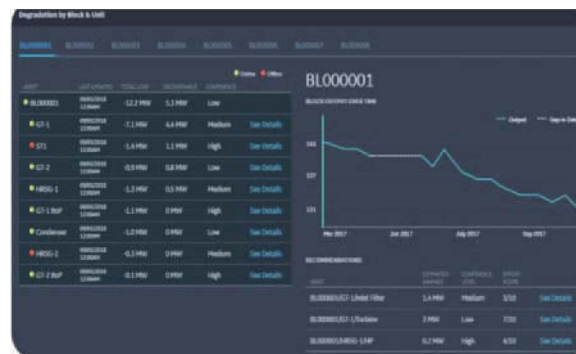


Fig. 7 Detailed Performance Degradation Overview screen

とみなし、これと現在の運転状態を比較することで劣化の程度を評価するが、この方法論自体は従前と大きく変わってはいない。

近年では、IoT環境の性能向上によって火力プラントからの大量の運転データを同時高速処理できるようになったが、これにより性能劣化の可視化の単位をこれまでのプラント／発電所単位から機器単位、更には機器を構成する部位単位まで細分化する事が可能になってきた。構成単位の細分化によって、劣化の著しい部位を特定することができるため、事業者が性能回復のための対応策をより効果的に立案することが可能となった。

複数の火力プラントを運用する事業者にとっては異なる地点の性能を一元管理することによる利点も存在する。Fig. 8はその一例であるが、複数地点に点在するプラントの性能を同一画面で管理することにより効果的な運用／保全計画の策定、更には地点毎の好事例を共有して全体の性能向上を図るための情報を提供することができる。

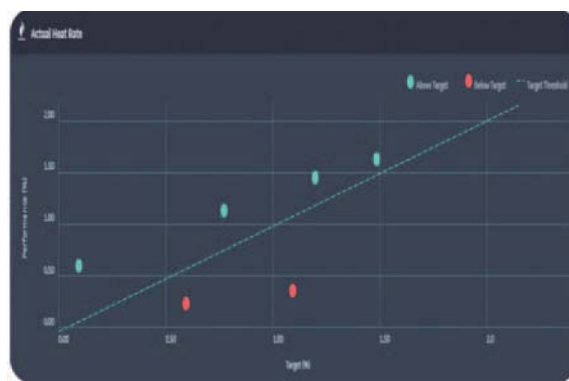


Fig. 8 Fleet Level Performance Overview. Each dot indicates individual performance of user's fleet

事業者内での性能劣化量をリアルタイムに把握する事は電力市場自由化への対応という意味からも重要である。市場取引に際しては、販売電力量を最大にするために火力プラントからの最大可能発電量を正確に把握する事が必要で、性能劣化、気象条件等の発電量に影響を及ぼす要素を全て取り込んで最大量を予測する機能がこれからますます重要になってくると思われる。




Fig. 9 Capacity Forecasting in granular detail for better dispatch and energy trading

5. ガスタービン最適制御による性能向上

本章ではデジタルツインを用いたガスタービンコンバインドサイクル向け最適制御アプリケーションについて説明する。



Fig. 10 Reduce fuel consumption during operations and with performance recovery

まず、ガスタービンコンバインドサイクルを構成する各コンポーネントの理想的な運転状態についてデジタルツインを搭載したサーバー上に仮想的に再現する。再現されるのは、プラントの性能に影響を与える外的要因（大気温度、大気圧力、湿度等）をインプットデータとして、機器の経年劣化や性能に影響を与えるプラントの異常状態を除外した設計上の理想的な運転状態である。次に、現場センサーから収集されたリアルタイムの運転データをデジタルツイン上の理想状態と比較することで現在の性能劣化の要因箇所を特定する。

これらの情報を元に、サーバー内のAIモデル上では現状の運転を理想的な運転状態に最も近づけるためのプラント内各制御操作対象への最適な指令値が導き出され、その値が制御ループへ直接送信される。最適な操作量を通知し、それを元に運転員が操作を実行する所謂オープンループコントロール方式も考えられるが、時々刻々変化する気象状態、発電出力等の外的要因に対して常に最適な運転状態を維持し続けるため、GEでは上述のような運転員の手を介さないクローズループコントロール方式を採用している。

Fig. 11ではクローズループコントロール方式による最適制御の対象可能制御ループの一例を掲載した。空気圧縮機空気流量制御、燃料流量制御といったガスタービン廻りの制御に加えて、排熱回収ボイラー等のBOP機器の制御ループも対象とすることが可能になっている。




Fig. 11 Plant-wide system orchestration to lower heat rate and reduce fuel consumption

6. ボイラー最適制御による性能向上

前章では火力発電プラントの中でもガスタービンコンバインドサイクル方式へのデジタルテクノロジーの適用について紹介したが、本章では火力発電向けのアプリケーションについて説明する。

クローズループコントロール方式によってボイラー制御の最適化を図り、その結果として熱効率回復、出力回復、排気ガス中の窒素酸化物等の有害物質の発生を抑制するという目的自体はコンバインドサイクル方式の火力発電プラントと同じであるが、ボイラー制御、特に石炭火力ボイラーの運転制御は操作可能制御ループ数が多く各運転パラメーターとの相関関係も複雑であるため、最適制御の方式もより複雑になる。

ここで主に用いられるのはニューラルネットワークを中心に、モデルプレディティブコントロール、ファーストプリンシパルモデリング等複数のモデル化技術で、対象制御ループの複雑性、応答性等によってこれらを使い分けしている。

Fig. 12でニューラルネットワークの一例を示す。まず、相関関係の複雑なボイラーの運転パラメーターと各所に配置されたダンパー、ベーン等の操作端との関係性を図のように紐付ける。次に、実機運転での試運転を通じて相関関係の重み付けを行ってニューラルネットワークのチューニングを行うことで精度を高めていく。

ガスタービンコンバインドサイクル発電方式での最適制御と同様に、ボイラー最適制御の目的はあくまでも機器の劣化と変化し続ける外的要因にきめ細かく対応して

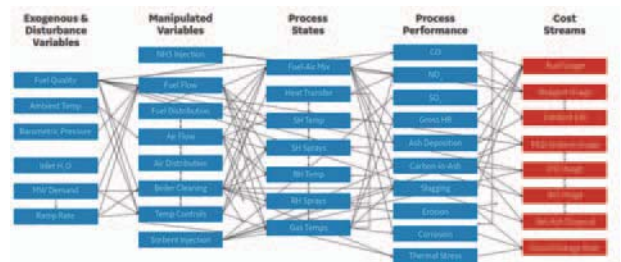


Fig. 12 Image of Neural Networks for Boiler Operation

その時点での最適パラメーターを計算しクローズループ制御を行うことであり、機器の設計上の限界を逸脱することは無い。

Fig. 13はボイラー最適制御を導入した場合の運転改善の一例である。改善幅は導入前の運転状態とボイラーメーカー、サイズによって大きく異なるがいずれの場合でも一定幅の改善が見込まれる。

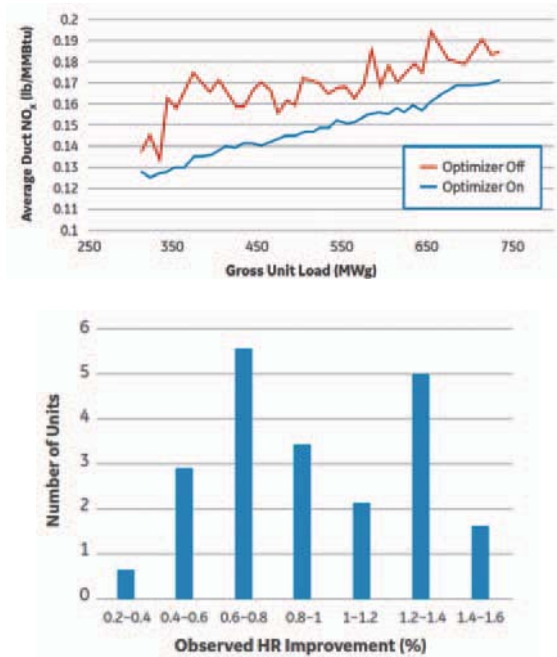


Fig. 13 Nox Emission (above) and Heat Rate (bottom) Improvement driven by Boiler Optimizer Software

7. 結言

本稿では、主に火力発電プラントへのデジタルソリューションの現状の取り組みについて紹介してきた。今回は予兆検知による信頼性向上、保守情報の効率的な管理による保守費用の最適化、性能情報の可視化とクローズループコントロールによる性能改善を取り上げたが、昨今この領域での技術の発展は目覚しく、今後さまざまな領域での更なる技術革新が進むものと思われる。

デジタル技術の革新による発電設備の最適運用の広がりにますます期待したい。

参考文献

- (1) GE'S DIGITAL ENERGY SOFTWARE SOLUTIONS
<https://www.ge.com/power/software?UTM_Source=GEDigital> (accessed on 8 July, 2019).

特集：エネルギー産業への機械学習の応用

電力設備保全など電力データ活用へのAI技術の適用

Application of AI to Data Utilization as Power Facility Maintenance



堤 富士雄*1
TSUTSUMI Fujio

キーワード：機械学習, 様相判定, 錆画像判定, データ復元, 需要推定

Key Words : Machine learning, Modal judgment, Rust image judgement, Data recovery, Demand estimation

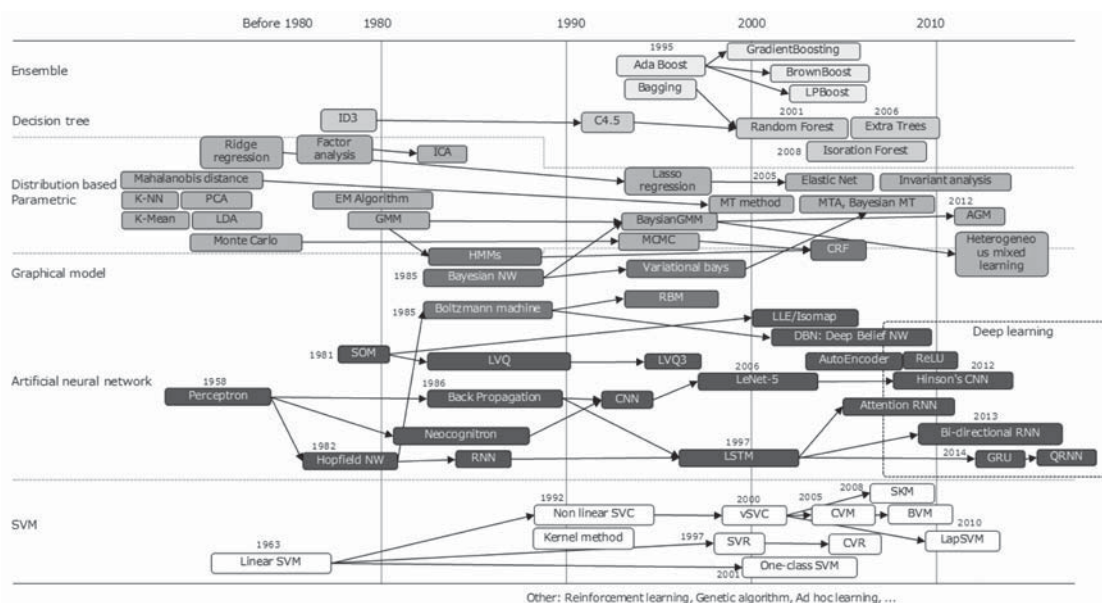


Fig. 1 Progress of major machine learning algorithms

1. はじめに

人口減少など縮小する社会、設備の老朽化、再エネの普及拡大、スマートグリッド化など、日本の電力・エネルギー産業は大きな変化の時代を迎えている。これを乗り越えるには、蓄積してきた高い現場力を基盤に、デジタルトランスフォーメーション (Digital Transformation: DX) の流れを味方につける必要がある⁽¹⁾。DXは「科学技術 (中略) の活用がもたらす機会を捉えて事業を推進すること」と定義され、その創造的破壊力の強さから「変化を拒む者たちは消し去られる」とまで言われる⁽²⁾。電気事業においては、電力の安定供給に関わる既存業務の高度化・省力化と、新たな

価値を創出する新事業への展開の両面でDXが推進されている。なお、DXはデータ活用、またはデータ中心主義 (Dataism)⁽³⁾という大きな流れの中にあり、AIを中心とするデジタル技術が人間の知的作業の一部を代替し始めている。本稿では、AIの中でも進展の著しい「機械学習」(Machine Learning, 以下MLと記載) に関して、活用を進める上でのポイントを、当所の研究事例を踏まえて考察する。

Fig. 1に、主要なML手法の変遷を当所で整理した図を示す。本稿で詳説する紙数はないが、異なる観点から多数の手法が開発され続けていることがわかるだろう。昨今、登場機会の多いディープラーニングはこの一種である。他にも複数の学習器を組み合わせる性能向上をはかるアンサンブル、データ群の塊ではなく境界に着目するSVM (Support Vector Machine) など、それぞれに守備範囲の異なる手法が、相互に影響を与えながら発展している。また、ICA (Independent Component

原稿受付 2019年7月8日

* 1 (一財) 電力中央研究所
エネルギーイノベーション創発センター
〒240-0196 横須賀市長坂2-6-1
E-mail: tutumi@criepi.denken.or.jp

Analysis) など古典的な手法の多くも、最新の計算機性能を背景に、使い勝手や性能を向上させており、十分に現役である。

さて、これら多数の手法群の多くは、今や便利なツールとなっており、手元のPCに無償でダウンロードして利用したり、クラウドサービスとして時間貸で安価に利用可能になったりしている。そのため、MLを使うだけであれば敷居は大幅に下がっている。一方で「使いこなす」という水準に至るには、まだ多数の障壁があるのも事実である。本稿では、その障壁を(1)ディープデータ、(2)前処理、(3)道具の選定、という3つの観点から述べる。

2. ディープデータ取得の難しさと重要性

昨今、ガンの画像診断など、ML応用の成功事例がメディアを賑わせている。ただし、そのほとんどは、与えられた正解 = 答え付きデータを計算機が学ぶことで認識・分類・予測などの判断を行う「教師あり学習」であることは、本特集の読者には常識であろう。答えとは例えば、設備保全であれば実際の設備劣化状態を表す情報、高齢者の見守りであれば実際の健康状態など、付加価値と直結した情報である。

当所ではこれら高品質な答えが付与されたデータのことを「ディープデータ」と呼んでいる (Fig. 2)。ディープデータには、答えの安定性、高い解像度、欠測・ノイズの少なさ、物理現象との紐づけの強さなどの観点で高品質であることが求められる。そして、その品質に応じて仕上がりMLの性能が決まる。一方、スマートフォンやエッジデバイスなど、IoTの進展によりデータの取得自体は急速に低コストかつ容易になりつつあるが、これらのデータの多くには答えがない。答えを得るには、手間やコストを要する詳細な計測・検査や、加速劣化試験、専門家の分析などが必要となる。よって、答えの存在する現場と連携して、効率的にディープデータ取得を進めることが結局は最も肝心となる。以下では、当所の研究事例を通じてディープデータの収集戦略を述べる。

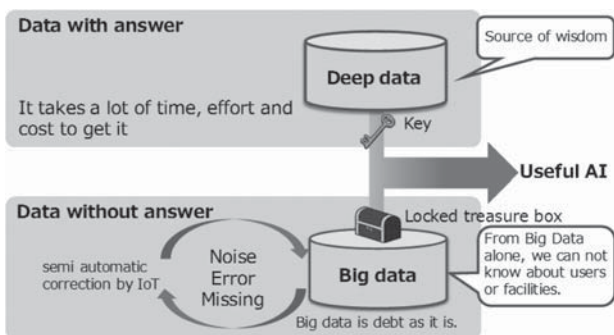


Fig. 2 How to get the knowledge to teach to AI

2.1 変圧器・OFケーブルの様相診断

電力会社では電力用変圧器の絶縁油を一部抜き取り、油中ガス分析により内部不具合の診断を行っている。こ

れは変圧器の劣化進展にともない、発生するガスの種類・量に変化する現象を利用した診断である。電気協同研究会は2010年に不具合判定基準の見直しを行い、正常な変圧器約1000台と内部不具合のある変圧器約120台の内部様相データを収集した。企業の枠を超えて共通の問題に対処すべく、一気にディープデータを収集した事例である。当所では、簡潔かつ高精度な判定基準を作成できる新たなAI手法を開発し、本収集データに適用することで、精度の高い内部不具合の判定基準を作成した⁽⁴⁾ (Fig. 3)。

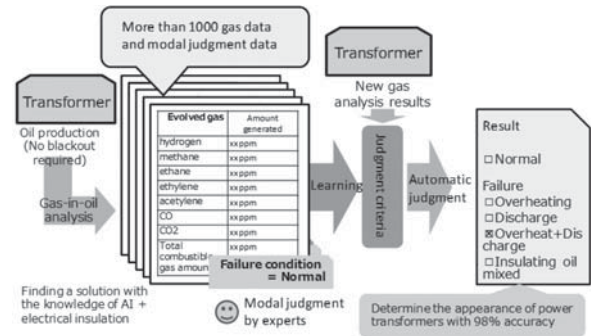


Fig. 3 Application of machine learning to power transformer modal diagnosis

基準作成に用いたML手法である線形サポートカーネルマシン (以下、線形SKMと記載) は、広く使用されているSVMを当所で拡張したものである。SVMは他のAI手法に比べ、少ないデータでも高精度の判定が行える特徴があり、不具合データが入手しづらい電力設備への適用にアドバンテージがある。さらに線形SKMでは、自動変数選択の機能を加え、判定基準の分かりやすさの向上と、さらなる精度向上を達成した。例えば、入力データである主要ガス量など全9成分のうち、正常か否かは C_2H_4 、 C_2H_2 の2ガスのみ、内部不具合が過熱+微小放電によるものか否かは CH_4 、 $TCnHm$ (炭化水素ガス総量) の2指標のみから判定可能であることを明らかにした。

作成した判定基準による、未知データに対する推定正解率は98%である。さらに本手法を、地中送電線などで使用される油入 (OF) ケーブルの油中ガス分析にも適用した結果⁽⁵⁾、これまで50%程度の判定精度であったものを約80%まで向上させることに成功した。いずれの判定基準も、電力の現場で活用されている。

2.2 鋳画像の劣化判定

電力設備にはメッキ塗装が多用されており、高経年化に従い、劣化が進んだ設備の取り換えや、防錆塗装が開始されている。しかし、従来の目視による劣化判断にはバラツキがあるため、判断基準を統一し、劣化の進んだものから計画的に対処を施す必要がある。そこで、当所では前述の線形SKMを適用した鋳画像判定ツールを開発した (Fig. 4)。最初の適用は、配電用腕金の接写

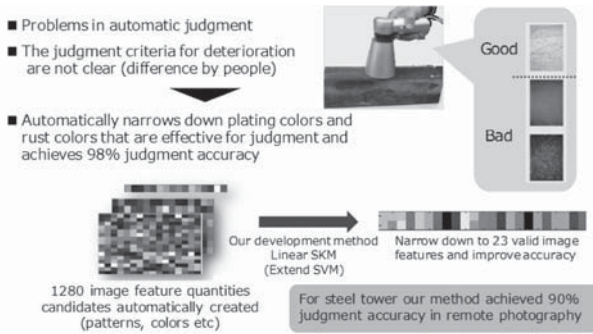


Fig. 4 Application of machine learning to deterioration judgment of steel rust image

カメラによる判定であり、判定精度98%を達成した。ただし、送電鉄塔など、多くの設備は接写が困難であるため、遠隔撮影した画像に対しても判定できるよう改善する必要が生じた。従来であれば、専門家が試行錯誤して前処理を工夫するのが通例である。これに対し当所では、画像認識で利用可能な大量の特徴量を自動生成した上で、自動的に有効な特徴量だけに絞り込む技術を改良した。その結果、模様、色合い、色の偏りなど多数の特徴量から23種の特徴量が自動的に選択され、送電鉄塔鋼材を90%の精度で劣化判定できるようになった⁽⁶⁾。

この例では、電力の現場担当者および設備劣化の専門家と連携し、鉄塔の場合であれば昇塔して撮影した多量の画像に対して、劣化状態を示すラベル（答えの情報）を付与した。さらに同じデータに対して、ラベルを隠してシャッフルした後、人間が再判定するブラインドテストを行なって、ラベルの確度を高める工夫を施した。現場担当者および専門家とのチームプレイでディープデータ取得をした事例である。

2.3 架空地線の異常検出

当所では、自走式点検装置で撮影した架空地線の映像から、異常検出する手法を開発してきた⁽⁷⁾(Fig. 5)。検出対象は、雷撃などによる素線表面の凹凸や変形であり、現場ではヘリ空撮などによるビデオ撮影の後、目視で確

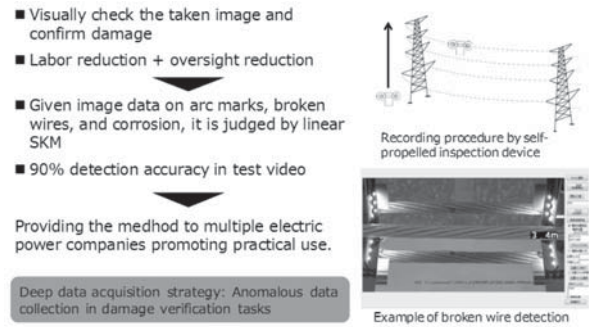


Fig. 5 Automatic determination of transmission line damage

認されている異常である。また、塩害などにより内部で腐食が起こる問題も顕在化しているため、腐食検出も開発した⁽⁸⁾。ディープデータとしては、異常確認業務で収集された溶痕や腐食の画像を用いた。テスト映像での検証で異常箇所の見逃しが無いことを確認し、実用化への見通しを得た。

本事例は、既存業務の中で異常画像としてディープデータを取得し、AIの支援により徐々に業務効率化を進めることで現場を支援した。人による確認業務の支援という形で、徐々にディープデータの収集を行い、データ更新により検出性能を向上させ、業務支援と機械学習の性能向上の両立を図るという戦略である。

3. 前処理を甘く見ない

実問題への適用時に立ちちはだかる第2のハードルが前処理である。Fig. 6に、ML適用の前段階として必要な代表的な前処理を例示した。まず、データには通常、欠損やドリフトなど多数のノイズが含まれており、それを除去するクレンジングが必要となる。ただし計測エラーなのか、本当に異常値なのかの区別は難しいため、計測系の特性を考慮した判断が必要となる。次に、データの種別毎にMLが扱いやすい形（特徴量）に変換する「特徴抽出」がある。色空間の選択、周波数特徴の抽出などが該当する。その後、特徴量を揃えたり、組み合わせた

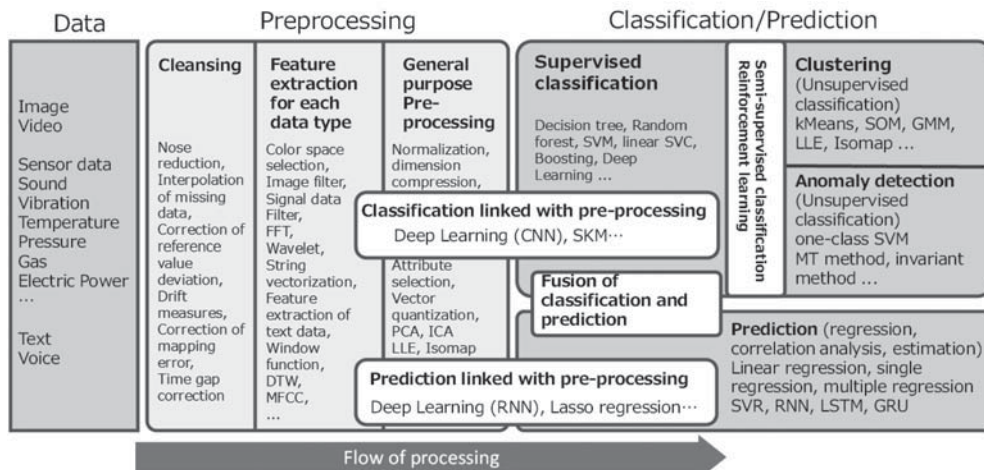


Fig. 6 Typical preprocessing required for machine learning applications

りする汎用的な前処理を行ってからはじめて、MLに入力できるデータとなる。汎用的な前処理の例としてデータの標準化 (Standardization) がある。これは、データの多次元空間における距離を用いる多くのMLにおいて、属性ごとに値域が大きく異なると適切に学習できないため、用いられる前処理である。

従来、前処理のほとんどは専門的なノウハウをもとに人手で行われていたため、活用の障壁となっていた。これに対し昨今、自動的に前処理を行える手法・ツールが徐々に登場しつつある。例えば特徴量を自動構成する深層学習や、変数の自動選択を行うスパースコーディングなどである。ただ、現状ではまだ一切の前処理無しに適用できる幸運な事例は少ないため、相当の工数を覚悟する必要がある。以下に、前処理の重要性を示す当所の研究事例を紹介する。

3.1 スマートメータデータによる在不在判定

現在、スマートメータの設置が全国で進められており、一般家庭における電力消費データの簡易な収集・活用が可能となる環境が整備されつつある。スマートメータで自動検針された電力消費データを電力会社へ送るルートはAルートと呼ばれ、Aルートを介して取得できる家庭の電力消費データ (Aルートデータ) は、メータの設置さえ完了していれば追加の機器購入を必要とせず利用できる。そのため、Aルートデータを活用することで安価かつ多くの需要家を対象としたサービスが実現可能となる。2016年4月の電力自由化以降、電力各社の販売部門では顧客満足度向上を目的とした価値創出のため、消費の見える化や節電などを目的としたサービスを始めている。

その一方で、Aルートデータの活用にあたってはデータの計測粒度の粗さ (30分間隔・100Wh単位) が課題となっている。Aルートデータは30分単位で100Whに満たない消費量は切り捨てられ、30分後に繰り越される仕様となっている。そのためFig. 7最上部に見られるように、実際には存在しない見かけの変動が生じてしまう。そこで当所では、Aルートデータから実際の電力消費量 (実需要) を推定する手法を開発した⁹⁾。開発した手法による実需要推定結果をFig. 7の下から2段目に示す。需要のピークがやや抑制されているものの、それ以外の時間帯において実需要 (Fig. 7最下部) がより正確に反映されていることがわかる。

欧州や米国ではスマートメータの設置が日本に先んじて進められていることから、スマートメータから得られる電力消費データを用いて居住者が在宅しているか否かを推定する「在・不在判定」と呼ばれる手法が、省エネ目的に広く研究されている。日本でもAルートデータから家庭の在・不在を判定することができれば、高齢者の見守りやピークシフトなど幅広い応用が期待される。しかし、計測粒度の問題からAルートデータは家庭の電力消費傾向を正確に反映できているとは言えず、そのまま

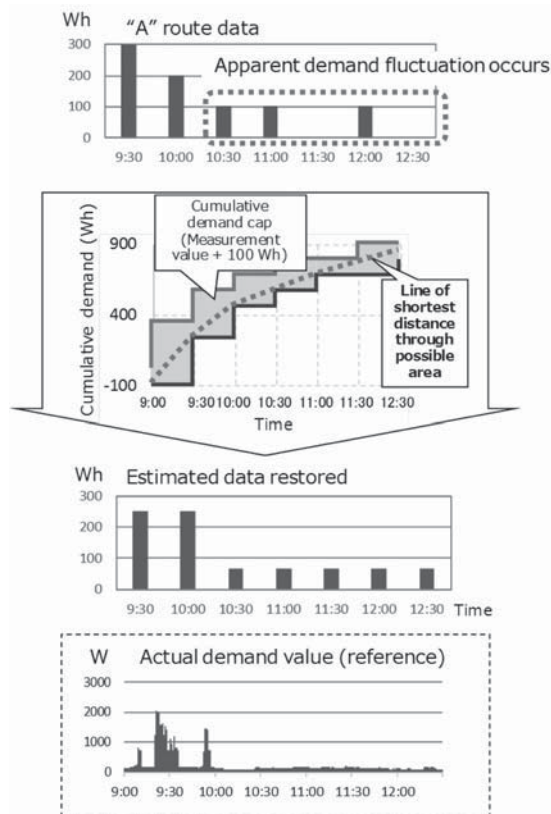


Fig. 7 Estimate actual demand by preprocessing

利用しても在・不在を高精度で判定することは難しい。

そこで、前述の実需要推定手法を前処理として在・不在判定を行うことで、より正確な判定が行える手法を開発した⁹⁾。MLとしてはランダムフォレストやSVMを用いた。評価実験を行った結果、Aルートデータをそのまま入力した場合と比較して、在宅時の判定精度が89.0%から93.3%、不在時の精度が68.5%から83.7%へと向上することがわかった。前処理の重要性がわかる事例である。

4. 道具は使いよう

Fig. 1に示したようにMLには複数の手法があり、それぞれに特徴を持つ。古くても未だ実用的な手法も多数ある。また最近では、クラウドで簡易に学習できるMLサービスや、さらに学習すら不要なサービスも多数登場している。そこでFig. 3に、既存のMLサービスやツールを、使用の難易度から大きく3つのレベルに分けてみた。まず「レトルト食品レベル」とは、既にデータを学習済みで、すぐに利用できるMLサービスやツールである。音声認識や顔画像認識などに関して多数のサービスがリリースされている。これらはすぐに利用できる点で容易だが、特殊なニーズには対応できない。次が「家庭料理レベル」である。学習させるデータは自前で用意する必要があるが、細かなチューニングや学習モデルの設計などは不要であり、デフォルトのパラメータ設定でそれなりに機能するMLを実現できる。Scikit-learnはその



Fig. 8 Level of difficulty in using machine learning tools and services

代表であり¹⁰⁾、代表的なMLに関しては高々数行のプログラムで利用できる。最後が「料理人レベル」であり、汎用的なMLライブラリを使って、オリジナルの学習モデルを設計したり、学習のさせ方を工夫したり、またはパラメータチューニングを繰り返すことで、所望のAIを開発するというレベルである。これも高性能なライブラリが続々と登場したことで、敷居は大きく下がっているが、難度が高いことを覚悟して利用すべき、となる。

さて、これだけ揃っていれば、MLで何でもできそうに感じる方もいるだろうが、実際にできることには限りがある。ある意味、ノコギリやドリルなど便利な工具が揃ったホームセンターのようなものだと考えた方がよい。そのため、どのMLを、どう使うかという、使い方の工夫が重要である。以下では、道具の一つである「教師無し学習」を効果的に使った事例を紹介する。

4.1 スマートメータデータから空調需要を簡易に推定

当所では、中小事業所向けに省エネアドバイスレポートを自動生成するツールを開発している¹¹⁾(Fig. 9)。入力として用いるデータは事業所の過去の電力需要データ(スマートメータデータ)と気温データのみである。よって、既にスマートメータが導入されている事業所であれば、追加コストなしに、省エネアドバイスを作成できる。このツールでは、多面的な分析を行うために多数のMLを活用している。

本稿では、それらの分析の内、省エネ改善に重要である「空調需要」を推定する手法について述べる。用いるデータは事業所の消費電力全体であるため、当然ながら空調がどの程度を占めているのかはわからない。従来、空調専用の計測装置を用いる方式や、分電盤に特殊な計測装置を設置して推定する方式はあったが、本ツールは追加装置無しで推定できる。まずツールでは、需要パターンから、事業所の稼働日と非稼働日の分類基準を作成する。稼働日とは、例えば学校であれば平日の授業がある時間帯、工場であれば通常操業状態を意味する。し

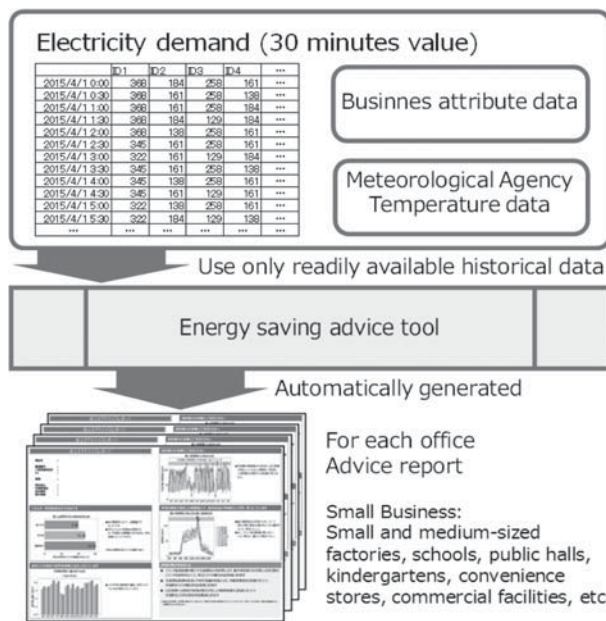


Fig. 9 Energy saving advice tool for medium-sized businesses

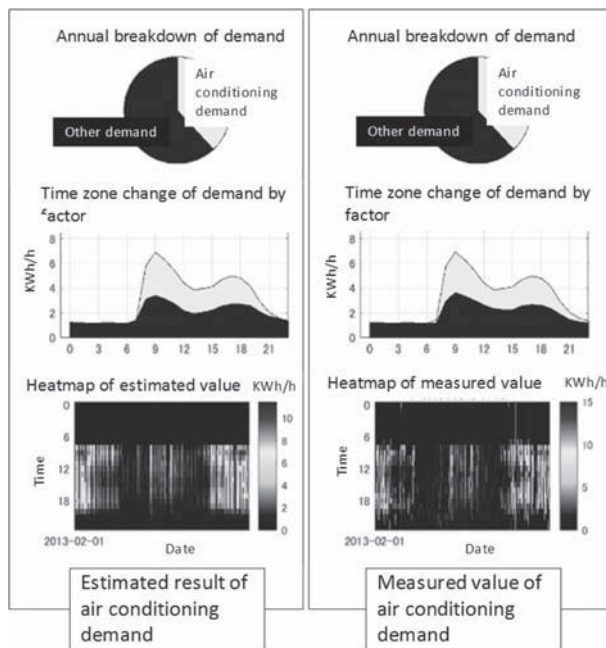


Fig. 10 Accurately estimate air conditioning demand by utilizing clustering

かし稼働日を表す正解データはないため、「教師無し学習」の一種であるクラスタリング手法(自己組織化マップ等)を適用して、稼働日、非稼働日、さらに半稼働日をグループ分けする。その上で、グループ毎に、気温と相関する需要と相関しない需要とを回帰分析で推定する。古典的なMLの効果的な組み合わせである。中小事業所77件に適用し、1時間値のスマートメータデータと気温の実績データのみから、誤差率の絶対値が約12%の精度で年間の空調需要を推定できることを示した。Fig. 10に推定結果例を示す。現在、当該ツールは複数の電力会社に提供している。

4.2 例外データ抽出を水車軸受け振動解析に適用

発電プラント異常の早期発見へのニーズは高いが、プラントの信頼性は高く、蓄積データのほとんどは正常状態のデータであるため、異常予兆を大量の正常状態データから見つけ出す必要がある。そこで当所では、水力発電所の発電機軸受け振動を対象に、温度や圧力、振動などのセンサデータを用いて「異常予兆の発見を支援する手法」を開発した¹²⁾。本手法では、上述したSVMの拡張の一つである1クラスSVMを用いる。1クラスSVMはデータ全体の中で特異なデータを弾き出す例外抽出(Anomaly Detection)手法の一種であり、データの分布を前提とせずに適用できる利便性がある。

手法は2ステップで構成される。Fig. 11の右下の円内部にあるデータはすべて正常状態のデータであるが、円の中心から遠いデータほど特異なデータと捉えられる。まずステップ1として、1クラスSVMを用いて特異な方から順にn個(例えば100個)のデータを抽出する。現場技術員は抽出したデータを確認し、運転記録や点検記録等を参考に、トラブルや怪しい事例をピックアップする。次にステップ2として、ピックアップ事例と類似のデータを線型SKMで追跡し、類似データの発生が高頻度になったら現場技術員にアラートを出す。何も手がかりが無い状態から、機械が手助けして、現場のプロの意見を反映しながら、徐々にディープデータを構成するというアプローチである。

ステップ1の例外抽出を実際の運転データ1年分に適用した結果、油漏れが発生した時点のデータを正しく抽出できることを確認した。また、ステップ2を同データに適用したところ、8種のセンサ項目を追跡することで異常予兆を検出できることがわかった。

5. おわりに

本稿では当所の研究事例を示しつつ、機械学習(ML)を効果的に利用するためのポイントを示した。3つのポイントは、ある意味基本中の基本であり、MLに限らず、AI技術全般、さらにはデータサイエンスを業務に活用する上で避けては通れない基礎的な要件である。

一方で、例えばディープデータ取得に関して、近年「半教師あり学習」という、ディープデータが少数であっても高性能なMLを構築できる技術が注目を集めている。例えば、転移学習は既に構築した汎用的なAIをベースに、少数の特殊事例を追加するだけで学習を完了できる。また、敵対的学習では、尤もらしいデータを自動的にこしらえて学習を進めることができる。また、本文中で述べたように自動的に前処理を行えるMLも続々と登場しており、AIツール用のIDE(統合開発環境)も登場するなど、利用環境は急速に変化しつつある。よって、基本は抑えつつ、アンテナを高くして最新の技術・ツールを活用することが、変化の激しいデジタルの未来を先取りする方策と言えるだろう。




Fig. 11 Abnormal estimation from normal sensor data

参考文献

- (1) 堤富士雄, 篠原靖志, 村田博士, 渡邊勇, 芦澤正美, 電気事業のビジネス変革への貢献に向けた電中研のIoT研究(その1) — 電気事業におけるデジタルトランスフォーメーションの可能性と電中研の取組 —, Business i. ENECO, 2017年12月号, (2017).
- (2) ユルゲン・メフェルト, 野中賢治, アンドレ・アンドニアン, デジタルの未来 事業の存続をかけた変革戦略, (2018), 日本経済新聞社.
- (3) ユヴァル・ノア・ハラリ, ホモ・デウス 下 テクノロジーとサピエンスの未来, (2018), 河出書房新社.
- (4) 篠原靖志, 油中ガス分析データによる電力用変圧器の様相判定手法, 電中研報告R10030, (2011).
- (5) 篠原靖志, 鶴見剛也, 嘉屋健, 松谷悠司, 油中ガス分析によるOFケーブル接続部の異常判定手法-サポートベクターマシンを活用した判定基準の提案, 電中研報告R13002, (2013).
- (6) 篠原靖志, 中島慶人, 状態監視保全のための設備画像に基づく良否判定基準の自動生成手法-主要な画像特徴の自動抽出手法-, 電中研報告R10004, (2010).
- (7) 石野隆一, 堤富士雄, 自走式点検装置で撮影した架空地線映像からの異常検出手法, 電中研報告R09016, (2010).
- (8) 石野隆一, 篠原靖志, 架空地線を自走するカメラで撮影した画像への機械学習適用による地線異常検出の可能性, 精密工学会, 動的画像の実利用ワークショップDIA2014, (2014).
- (9) 服部俊一, 篠原靖志, スマートメータの電力需要データを用いた在・不在判定—Aルートからのデータを用いた在・不在判定の精度改善手法—, 電中研報告R15004, (2016).
- (10) scikit-learn: machine learning in Python - scikit-learn 0.21.2 documentation <<https://scikit-learn.org/stable/>> (accessed on 8 July, 2019).
- (11) 小松秀徳, 木村宰, 中小事業所向け省エネアドバイスレポートにおける稼働日推定・簡易用途分解の改善検討, 第34回エネルギーシステム・経済・環境コンファレンスプログラム, (2018).
- (12) 村田博士, 篠原靖志, 水力発電所の異常予兆発見に影響を与えるセンサの絞り込み方法の開発, 電中研報告R11019, (2012).

特集：エネルギー産業への機械学習の応用

機械学習を用いた航空機エンジン排気温度予測の取り組み

Aircraft Engine Exhaust Temperature Prediction by Machine Learning



茂木 悠佑*¹
MOTEGI Yusuke



鹿庭 政人*²
KANIWA Masato



中村 恵子
NAKAMURA Keiko



河野 幸弘
KAWANO Yukihiro



細矢 征史
HOSOYA Masashi



櫛川 卓也
MITSUKAWA Takuya

キーワード：ガスタービン，ジェットエンジン，原動機，性能予測

Key Words：Gas Turbine, Jet Engine, Prime Mover, Performance prediction

1. 緒言

定時発着率が世界一位となっている日本のエアラインにおいては、運航遅延や欠航に結び付く航空機や関連機材のトラブルなどを発生させないよう、万全を期して整備を実施している。

こういったエアライン各社の整備業務に、エンジン専門家としてのサポートを行なうため、IHIでは独自のIoTプラットフォームであるILIPS (IHI group Lifecycle Partner System) を活用して航空機エンジン稼働情報の収集を行なっている。

本論文では、収集した航空機エンジン稼働情報を活用した、機械学習を用いた航空機エンジンの排気温度予測の取り組み事例を紹介する。

2. 航空機エンジンの整備

本章では、航空機エンジンの整備の概要について示す。

2.1 エアラインのニーズ

エアライン各社は、次のようなニーズを持っている。

- ① 運航遅延やキャンセルの回避
- ② エンジン不定期取卸の回避
- ③ イベント（不具合や事故）が起こった際の迅速対応
- ④ エンジンの整備費用削減

これらは、計画外の機材トラブルを防止し、運行に専念するために必要である。

2.2 航空機エンジン整備の種類

航空機のトラブルを回避する整備方式について、Table 1に示す。

Table 1 List of maintenance type

整備方式	定義	特徴
オーバーホール方式	・決められた時間で取卸，全て分解・検査	エンジンの状態に関係なく，定期的実施
オンコン (On-condition) 整備方式	・整備の主目的を定め，最低限の分解・検査	エンジンの状態に応じた整備
プロアクティブ整備方式	・避けられない取り卸しで行う整備（性能回復，LLP*交換）以外にエンジンを取り卸さない *LLP:Life Limited Part:使用回数期限のある部品	先を見越した積極的な整備

Table 1に示した各種整備方式の中で、「オンコン (On-condition) 整備方式」および「プロアクティブ整備方式」は、運用している航空機エンジンの性能・状態に対応した整備を実施する。そのため、収集した航空機エンジン稼働情報を活用し、より性能・状態を正確に把握することで、

- ① 航空機エンジン1の重要計測項目の異常事前検知と対策
- ② 不具合発生時のトラブルシュートを迅速に実施
- ③ 最適な航空機エンジン取卸時期や、最適な整備仕様の提案

など、整備メニューや整備時期の最適化といった、技術的なサポートが可能となる。「性能・状態」には目的別に様々な種類があるが、以降では、航空機の飛行の可否判断においても重要な、エンジン排気温度（タービン出口温度）の予測について述べる。

原稿受付 2019年8月19日

*1 (株)IHI 高度情報マネジメント統括本部 IoTプロジェクト部 情報科学技術グループ
E-mail: motegi4737@ihi-g.com

*2 (株)IHI 航空・宇宙・防衛事業領域 民間エンジン事業部 技術部 ライフサイクル技術・RSA担当
E-mail: kaniwa6830@ihi-g.com

3. エンジン排気温度予測概要

3.1 性能劣化と排気温度の関係

航空機エンジンは、コンプレッサで空気を取り込み、燃焼室に送り込んで燃料を燃焼させ、燃焼ガスの一部のエネルギーをタービンによって回収した後、後方噴出によって推力を生み出している。エンジン内に汚れが蓄積すると、エンジンの性能（効率）が劣化する。

同一機種エンジンを搭載した航空機であっても、使用環境の違いで劣化速度には差が生じてくる。

性能（効率）が低下すると、推力を確保するために必要な燃料噴射量が増加し、この結果排気温度（タービン出口温度）が上昇する。性能（効率）が低下した状態は燃費の観点からも好ましくないが、タービン出口温度が上昇しすぎるとエンジンの破損の原因となる。

このためタービン出口温度には運航制限値が設けられており、超過すると飛行することができない。エアライン各社は、定期的な整備によってエンジンの性能を回復し、運航制限値の超過を回避する必要がある。

3.2 水洗による性能回復の必要性

今回対象としている航空機エンジンの場合、エンジンの性能を回復させ、タービン出口温度を下げる整備の一つに、エンジンの水洗作業（Water Wash）がある。

この水洗作業は、現在はタービン出口温度をエアライン担当者がモニタリングして、おおよその水洗実施時期を設定している。

整備に必要な設備がある空港は限られているため、予

想外に制限値超過のリスクが高くなった場合は、飛行停止を避けるため設備のある空港まで計画外で移動する必要がある、整備コストの上昇に繋がる。

もし、1週間先までのタービン出口温度を予測することができれば、その期間内の運用で対象航空機が水洗の設備・作業者がいる空港に戻るタイミングを選べるため、正確な整備の作業計画を立てることが可能となり、コスト上昇を抑えることができる。

3.3 航空機エンジン排気温度予測手法

このような背景から、航空機エンジンの稼働情報を学習させ、将来のタービン出口温度が運用制限値を超過する確率を予測するシステムを構築した。

Fig. 1に、航空機エンジン排気温度予測の概念図を示す。

このシステムでは、過去一定期間のエンジン稼働情報を学習して、将来の排気温度（タービン出口温度）を推定する。この学習の際に、学習用データの適正化をするために、航空エンジンの物理モデル（詳細は5章で解説）を併用する。

次に、学習したデータを元に、将来のフライト時の排気温度（タービン出口温度）を予測する。この予測はタービン出口温度の確率分布として計算し、運用制限値を超過する確率を計算する。

計算結果は、水洗の必要性を判断するための情報としてエアライン各社の担当者に提供される。

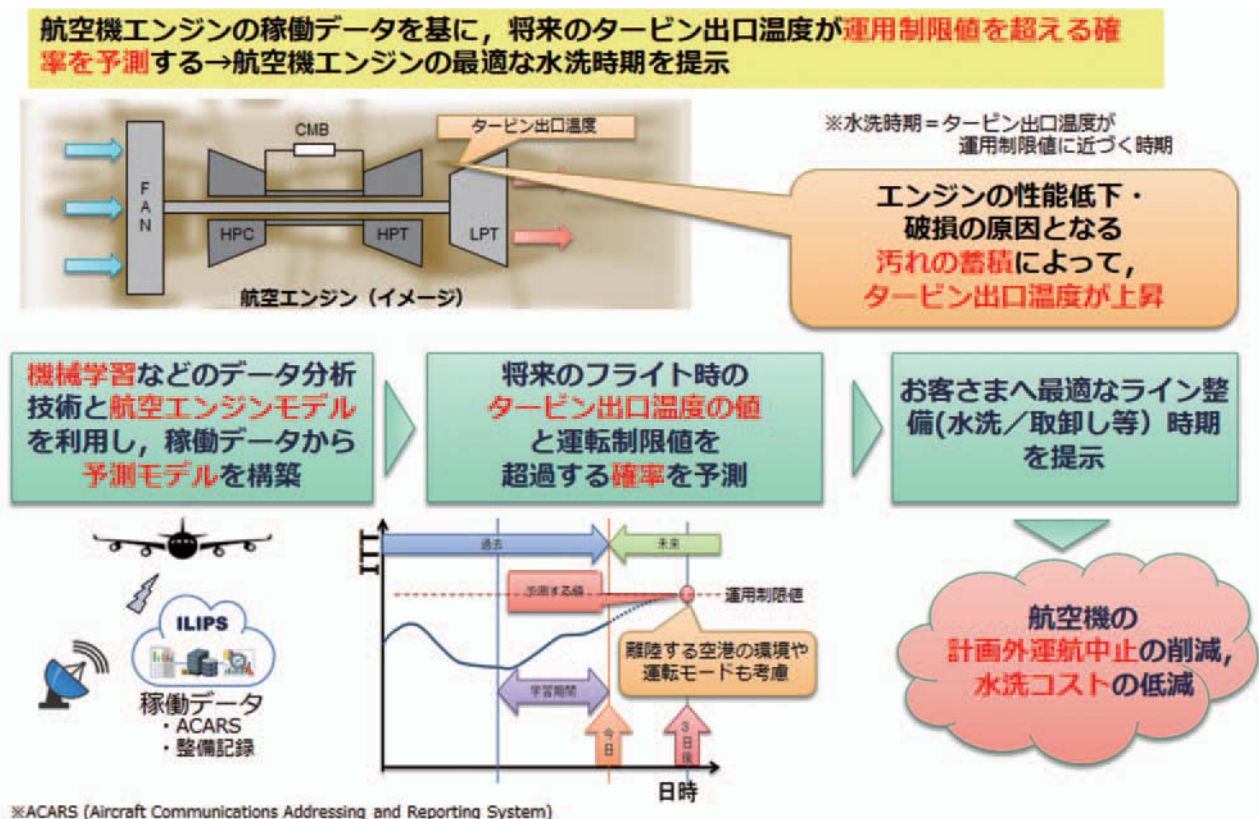


Fig. 1 Turbine exhaust temperature prediction process overview

4. データ

4.1 ACARSデータ

4章では、機械学習に使用するデータについて説明する。

航空機エンジンの稼働情報として、ACARSデータを正在している。ACARSとはAircraft Communications Addressing and Reporting Systemの略で、必要な運航情報を航空機側から地上へ、または地上から航空機側へ自動的に提供するシステムである。出発・到着時刻や出発地・目的地、便名などのデータはデータリンクの無線通信系を介して地上のACARS無線局に送信される。このデータは無線局から中央の処理装置に伝送され、各エアラインのコンピュータへ伝送される。Fig. 2にデータ収集の概要を示す。

送信されてくるACARSデータのうち、ILIPSに取り込んでいる情報には離陸時に取得されるTake-Off、巡航時に取得されるCruiseデータなどがある。

Take-Off時のデータ、Cruise時のデータは、それぞれ「タービン出口温度」、「燃料流量」、「オイル温度/圧力」、「振動値」、「回転数」、「抽気状況」など、約40パラメータを持つスナップショット（瞬時値）データである。

今回の取り組みでは、Take-Offデータを学習し、「将来のTake-Off時のタービン出口温度」の予測を行なっている。

第3章で述べた通り、タービン出口温度が運航制限値を超えると飛行停止となるため、事前にタービン出口温度を予測する必要がある。

なお、タービン出口温度はTake-Off時に最もタービン出口温度が高くなる傾向があるため、Take-Off時の値を予測する。

Fig. 3に概要を示す。

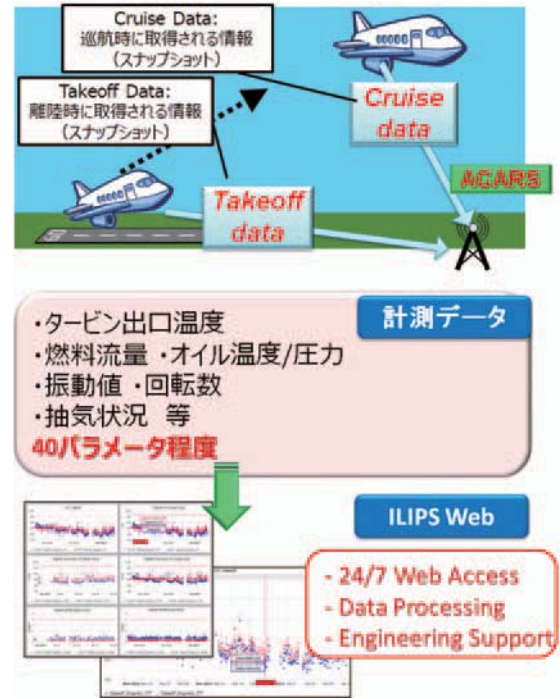


Fig. 3 Overview of snapshot data

4.2 天気予報（環境）データ

航空機エンジンの排気温度は外気温など環境の影響を受けるため、動作環境の予測精度を上げることが重要となる。第4.1節で述べた通り、Take-Offデータを学習して「将来のTake-Off時の排気温度」を予測するため、天気予報の情報を利用して、離陸時の動作環境予測を行なう。

天気予報は、オンラインサービスを用いてAPI経由で自動取得することが可能である。主要な都市の気温、気圧などの項目を取得することができる。

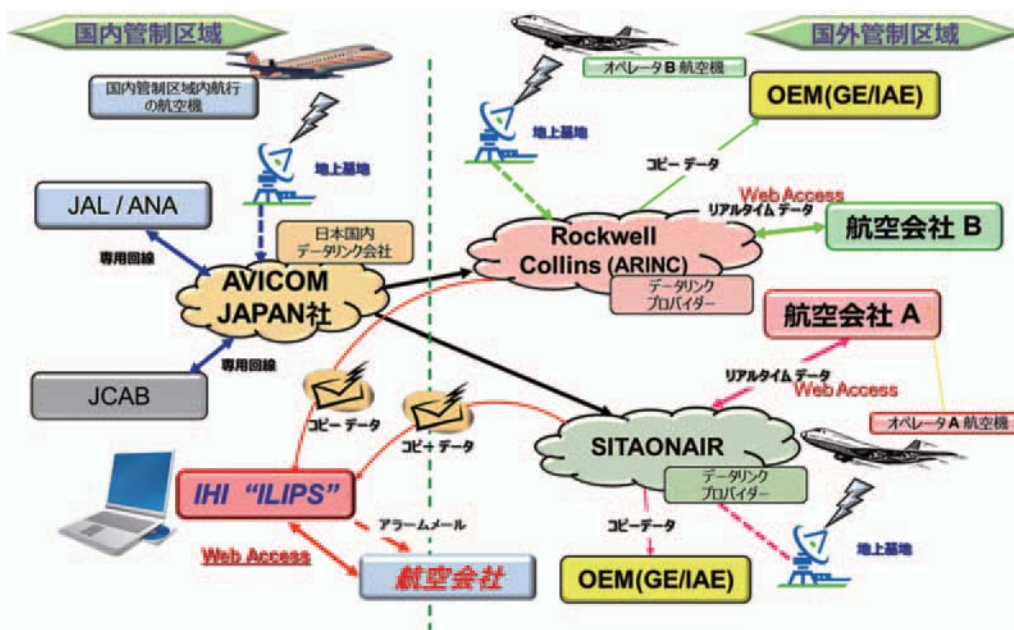


Fig. 2 Overview of the data I/F

ただし、取得した天気予報の情報と、離陸する空港の環境は一致するとは限らないため、天気予報の情報から離陸時の環境を予測する「環境予測モデル」を構築する。

これはACARSで得られた情報を元に離陸時の気温（機外温度、吸気温度）、気圧（高度）情報を計算し、この離陸時環境と天気予報のデータを元にモデル式を構築し、離陸時の環境を推定するものである。

Fig. 4に環境予測モデルの概要を示す。

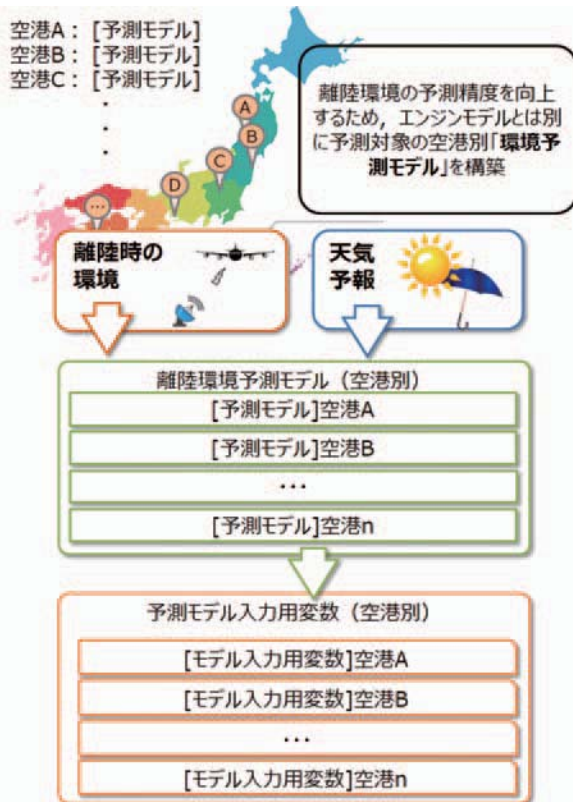


Fig. 4 Overview of environmental prediction model

5. 機械学習モデル

5.1 モデル構築上の問題点

航空機のエンジンは、航路や使用状況によって、徐々に性能劣化など、状態が変化する。よって、事前に作成した固定的な予測モデルでは、この変化に追従できず、高い予測精度を出すことができない。

このため、常に最新のエンジンの状態を反映させた、オンライン機械学習を採用した。

また、タービン出口温度は、さまざまな動作モード・制御状態・メンテナンスなどの影響を受けるため、計測データが非正規分布・非線形の変化を取る。よって、機械学習モデルは、データの非線形性に対応する必要がある。

Fig. 5に、サンプルとしてプロットしたTake-offデータの非正規分布の事例を示す。

Fig. 5に示したTake-offデータの分布の違いは、主に離陸時の運転モードの違いにより発生する。「高度」が

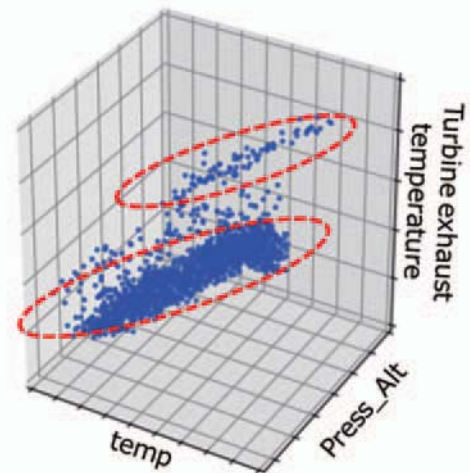


Fig. 5 Example of non-normal distribution

高い領域でタービン出口温度が高いデータの分布が見られるのは、より推力を出せる動作モードを使用するケースが多いためである。

また、Fig. 6にタービン出口温度が非線形の変化を示す例を示す。

この非線形な変化は、温度が一定以上に高くなった場合に内部制御を切り替えるために発生する。

正確な予測を行なうため、これらの非正規分布や非線形性のデータ分布上の問題は、第5.2節に示す機械学習モデルを用いて対応している。

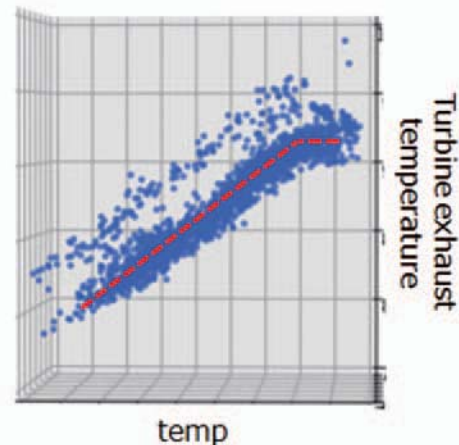


Fig. 6 Example of Nonlinear distribution

5.2 機械学習モデルの概要

機械学習モデル全体の概要図を、Fig. 7に示す。

この機械学習モデルでは、「環境予測モデル」により、オンラインで更新されるエンジン稼働情報と天気予報情報を用いて、離陸時の環境を推定する。

また、エンジン稼働情報から、物理式で動作モードなどを得る「物理モデル」を利用する。この「物理モデル」では、コンプレッサの回転数、圧力などの値から動作モードなどの作動状態を推定する。Fig. 5のように、クラス（データ群）を適切に分類するためには、実際

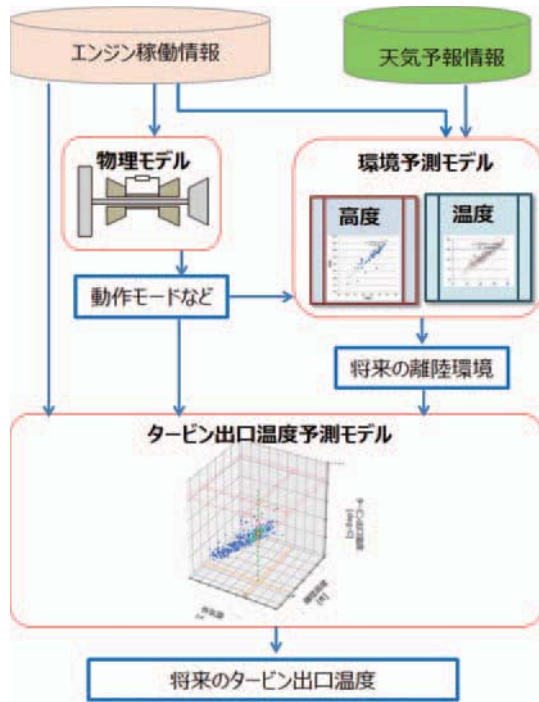


Fig. 7 Overview of the learning phase

には「高度」の大小だけでは不十分である。これは、離陸時の機体重量など、高度以外の要素でも運転モードが変更されるためである。この運転モードを正確に推定するため、エンジンの動作状態を数式化した物理モデルを用いることで、精度向上を図った。

エンジン稼働情報、作動状態、将来離陸環境を入力値として、将来のタービン出口温度をタービン出口温度予測モデルが計算する。この詳細を次節で説明する。

5.3 タービン出口温度予測モデル

タービン出口温度予測モデルは、将来離陸環境を元に、類似した環境下での過去のエンジンの動作情報に基づき、将来のタービン出口温度の予測値、および運行制限温度の超過確率の算出を行なう。Fig. 8に、タービン出口温度予測モデルの概要を示す。Fig. 8では2項目のみに入力情報を簡略化して描写している。

この類似環境下の動作情報に基づくことで、例えば抽出したデータが正規分布に近づくなどが考えられるため、Fig. 6で示したような、非線形の変化をする場合でも、適切な予測が可能となる。

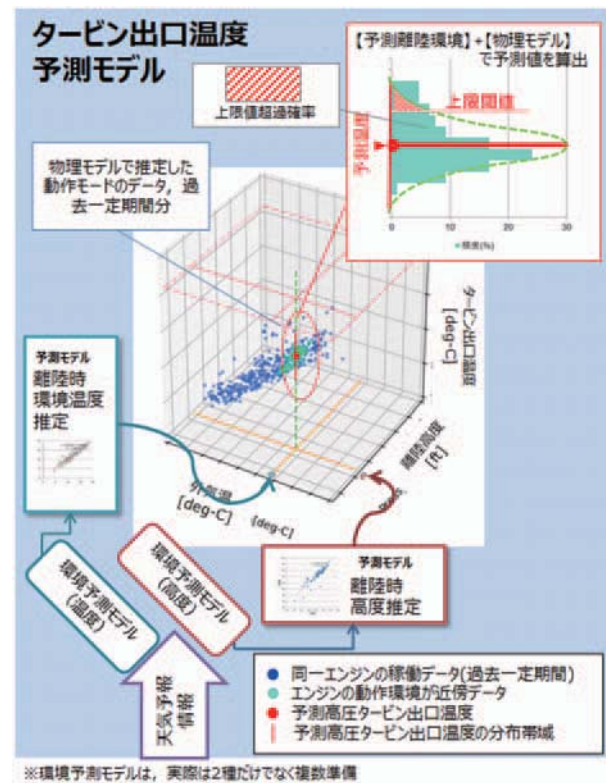


Fig. 8 Overview of the Turbine exhaust temperature prediction model

6. 画面イメージ

将来タービン出口温度予測結果として、各機体（左右エンジン）別に離陸空港ごとの予測タービン出口温度、制限温度超過確率を表示する。

タービン出口温度は、出力を高くした時や、吸気温度が高い場合に上昇するため、標高が高く出力が必要な空港や、気温の高い空港で離陸する場合に、特に運航制限値の超過確率が高くなる傾向がある。

そのため、各空港での予測値を確認し、標高が高い空港や、気温が高くなる可能性のある空港で運航制限温度の超過確率が高い場合は、その空港で離陸する前に水洗を実施可能なように運航スケジュールの調整を行なう。こうすることで、緊急対応のために空荷で水洗装置のある空港へ計画外移動させるといった不要なコスト上昇を回避させ、運航停止リスクの低下をすることができる。

Fig. 9に、タービン出口温度予測機能の実装画面の例を示す。

凡例に示したように、各枠が「空港名」、「左右エンジンの予測タービン出口温度」、「飛行制限温度の超過確率」を示している。

特定の機体Aと、予測日（1日後～7日後）を指定すると、マップで示された空港で離陸した場合の、予測タービン出口温度、および飛行制限温度の超過確率が表示される。

Fig. 9下側の、太枠で強調した空港のようなケースでは、離陸時に飛行制限温度を超過する確率が50%と高い

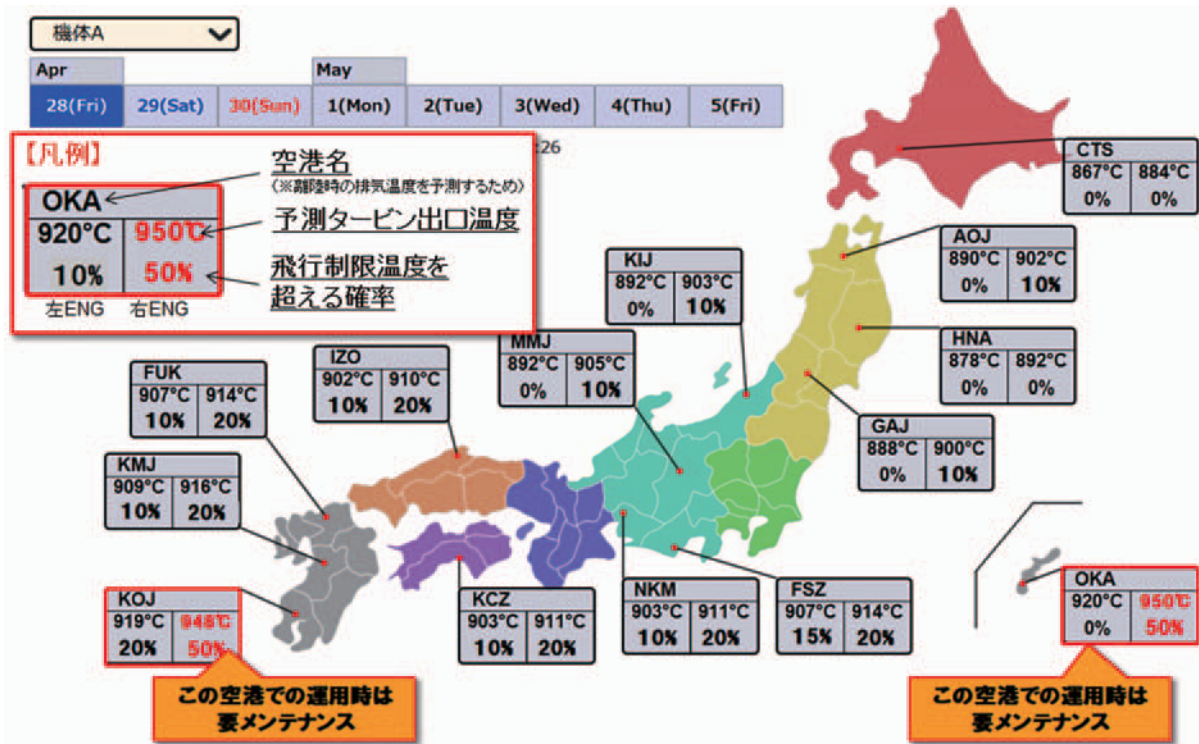


Fig. 9 Overview of turbine outlet temperature prediction application

ため、前述のとおり運航スケジュールの調整により対応を行なう。

7. 検証結果

予測精度の確認のため、Fig. 10に、抜粋した1機体での7日前タービン出口温度予測値および予測分布と、実測のタービン出口温度をプロットしたトレンドグラフを示す。




Fig. 10 Trend graph of predicted and measured values

7日前に予測した離陸時のタービン出口温度と、実際に計測されたタービン出口温度について、約3か月間のデータを用いて比較した。図中の後半に見られるようなタービン出口温度トレンドの変化にも追従しつつ、精度の高い予測結果を算出可能なことが分かる。

8. まとめと今後の展開

8.1 まとめ

高精度でタービン出口温度を予測するロジックを構築することにより、水洗スケジュールの最適化に繋がる情報提供が可能になった。

また、天気予報情報、空港の離陸環境を考慮することで、飛行制限温度の超過確率リスクが可視化され、運航停止や、空荷での水洗設備のある空港への移動など、不要なメンテナンスコストの上昇をさけることが容易になる。

今後、最適な航空機エンジン取卸時期や、最適な整備仕様の提案をエアライン各社に積極的に実施していく。

8.2 今後の展開

今回の手法は汎用性が高いため、他のエンジン、エンジン以外の機械設備の性能予測手法として、整備提案につなげていく。

参考文献

- (1) ガスタービン工学, (2013), p. 254, 日本ガスタービン学会.
- (2) Nicholas Cumpsty, Andrew Heyes, Jet Propulsion, third Edition (2015), 4.3 THE GAS TURBINE THERMAL AND CYCLE EFFICIENCY, p. 47, CAMBRIDGE UNIVERSITY PRESS.
- (3) 田口玄一, 田口玄一論説集 第4巻 (2012), p. 94, 日本規格協会.
- (4) 田村 希志臣, よくわかるMTシステム (2009), p. 17, 日本規格協会.

特集：エネルギー産業への機械学習の応用

機械学習を利用した再使用ロケットエンジンの故障検知・診断

Machine Learning for Anomaly Prognostics and Diagnostics in Reusable Rocket Engines

堤 誠司*¹
TSUTSUMI Seiji

平林 美樹*¹
HIRABAYASHI Miki

佐藤 大和*¹
SATO Daiwa

河津 要*²
KAWATSU Kaname

安部 賢治*³
ABE Masaharu

佐藤 正喜*⁴
SATO Masaki

橋本 知之*⁴
HASHIMOTO Tomoyuki

木村 俊哉*⁴
KIMURA Toshiya

キーワード：再使用ロケットエンジン，故障検知，故障診断，機械学習

Key Words：Reusable Rocket Engine, Anomaly Prognostics, Anomaly Diagnostics, Machine Learning

1. 緒言

近年，故障検知・診断技術は幅広い産業機器において積極的に利用されている。ロケットエンジンに関しても，世界初の再使用ロケットエンジンであったSpace Shuttle Main Engine (SSME) に対して，1990年には既にヘルスマニタリングに関する研究が行われた⁽¹⁾。しかし，SSMEはフライト毎に分解点検が必要で，再整備コストや期間の増加を招く結果となった。航空機エンジンと同様に，フライト毎に分解点検することなく，ある一定期間使用すればオーバーホールするような運用形態が必須である。このような運用形態を実現するためには，予寿命評価技術，非破壊検査技術，ヘルスマネジメント技術の3つを確立しなければならない。本稿で紹介するのは，3つ目のヘルスマネジメント技術である。

ロケットエンジンの故障検知・診断に関する研究は，1990年代を中心に数多く行われてきた⁽²⁾。近年では，Schwabacherら⁽³⁾，Iannettiら⁽⁴⁾，佐藤ら⁽⁵⁾が機械学習を利用した取り組みを行っている。具体的な手法の検討を行う前に，著者らは液体ロケットエンジンの故障検知・診断を行う上で避けて通れない技術課題を調べた。抽出された課題は2章にて紹介するが，著者らの知る限り，これらの課題をすべて解決可能な手法は存在しない。そこで，これらの技術課題を克服することを目指した故障検知・診断手法の研究開発を行ってきた^{(6),(7),(8),(9)}。ここで開発する手法は，破壊的な事象を防ぐためにリアルタ

イム性が要求されるレッドライン判定は対象とせず，あくまでフライト間の整備コスト・期間の短縮を目指しており，データ駆動型故障検知とモデルベース型故障診断の2つから成る。再使用ロケット着陸後，エンジンに関するセンサデータを取得し，まずはデータ駆動型故障検知手法にて故障の有無を調べる。故障が検知されなければ次のフライトに臨むわけだが，もし何らかの故障が検知された場合は，モデルベース型の故障診断手法を用いて故障原因を特定する。そして，故障を修理した後，次のフライトに臨むわけである。例えば液体ロケットエンジンの地上燃焼試験では，試験が終わるごとに数十～数百個あるセンサの時系列データを観察し，故障の有無を調べているのが実情である。万が一故障があれば，エキスパートの判断を仰ぎながら故障モードを特定する。本手法ではこの作業を機械学習により代替することから，期間とコストの抜本的な削減が期待できるわけである。

本稿では，著者らが研究開発してきたデータ駆動型故障検知手法，及びモデルベース型故障診断手法を紹介する。そして，開発手法の実証は，宇宙航空研究開発機構 (JAXA) で進められた再使用観測ロケット技術実証計画 (Reusable Sounding Rocket, RSR)^{(1),(12)}において開発されたエンジン (RSRエンジン)⁽¹³⁾の地上燃焼試験データ，もしくはモデルデータを活用して行っており，実証結果についても併せて紹介する。

2. ロケットエンジンの故障検知・診断に関する課題

ロケットエンジンの故障検知・診断技術に関する課題を整理した結果，以下の8つが抽出された。ロケットエンジンに特有な課題もあれば，ガスタービンエンジンなどの一般の産業機器に関連する課題も挙げられる。

- 1) 学習データが少ない。特に，故障データは極めて限られる。
- 2) センサ故障が起り得るため，システム故障との識別が必要。
- 3) 個体差がある。また，同一エンジンでも運転中に作

原稿受付 2019年7月8日

* 1 JAXA 研究開発部門 第三研究ユニット (JEDIセンター)
〒252-0222 相模原市中央区由野台3-1-1

E-mail: tsutsumi.seiji@jaxa.jp

* 2 JAXA 研究開発部門 第三研究ユニット (JEDIセンター)
〒305-0047 つくば市千現2-1-1

* 3 (株)菱友システムズ 事業統括本部 航空宇宙エンジニアリング・ソリューション事業部
〒455-0024 名古屋市港区大江町6番地19号 菱興ビル南館

* 4 JAXA 研究開発部門 第四研究ユニット
〒981-1525 角田市君萱字小金沢1

動点がドリフトすることがある。

- 4) 定常作動時だけでなく、起動/停止過渡状態や、制御入力に起因する作動タイミングの変化も考慮する必要がある。
- 5) 故障検知やその診断を行うために、センサの配置や点数の最適化が必要である。
- 6) センサの設置位置には制約があり、計測値と実現象の間には乖離があることがある。
- 7) 故障診断手法に関する研究や実用例は少ない。
- 8) 数値シミュレーションを活用する場合、正常状態だけでなく、故障状態も模擬する必要がある。故障の物理的メカニズムの理解とそのモデル化、またその検証データは必ずしも十分ではない。

3. データ駆動型故障検知

3.1 手法

2章に挙げた課題の中で、データ駆動型故障検知に関連する項目は1)～4)である。まずは2)項目のセンサ故障とシステム故障の識別に着目すると、従来からよく利用されている単変量の変化点検知手法のみではセンサ故障なのかシステム故障なのかを識別することはできない。そのため、著者らは2つのセンサから得られる時系列データ間の関係性に着目した二変量の時系列解析手法に着目した。

第*i*番センサ($i \in [1, S]$)の時刻 $t \in [1, T]$ における計測値を x_t^{si} とする。そして、第*i*番目センサで計測した時系列データを $D^{si} = [x_1^{si}, \dots, x_T^{si}]^T$ とする。なお、 T は転置を表す。得られたセンサ計測値 D^{si} から平均と分散を求め、標準化して \tilde{D}^{si} とする。 \tilde{D}^{si} からそのデータの特徴づけるモードを抽出するため、主成分分析 (PCA) を使う。1次モードは時系列データの主要な変動を表し、2次モードは1次モードの上ののっている高周波の変動である。更に高次のモードにはより高周波成分の変動が現れる。センサの計測値にはノイズが含まれるわけだが、PCAを利用して主要なモードを抽出することは、不要な変動を無視する、つまりノイズフィルタと等価であり、センサから得られた時系列データからプリ処理をせず処理が可能というメリットがある。単変量の時系列データ \tilde{D}^{si} にPCAをかけるため、 W 点の幅をもつスライド窓を用いて \tilde{D}^{si} を切り出す⁽⁴⁾。時刻 $t=j$ にて切り出した時系列データの集合を $\tilde{D}_j^{si} = [x_j^{si}, \dots, x_{j+W-1}^{si}]^T$ とし、これらを並べて $\tilde{D}_{win}^{si} = [\tilde{D}_1^{si}, \dots, \tilde{D}_{T-W+1}^{si}]^T \in \mathbb{R}^{(T-W+1) \times W}$ を作る。 \tilde{D}_{win}^{si} に対してPCAを適用し、第*m*番モードの固有ベクトルに写像した主成分スコア $Y^{si(m)} = [y_1^{si(m)}, \dots, y_{T-W+1}^{si(m)}]^T$ を得る。なお、 \tilde{D}_{win}^{si} の分布が超平面である保証はないことから、非線形性を加味するためにカーネル主成分分析を利用する必要がある。しかし、多数のセンサデータに対して最適なカーネル関数の選択は容易ではないことから、ここではカーネル関数は利用しない。

s_i, s_j の2つのセンサに関する第*m*次の主成分スコア

$Y^{si(m)}, Y^{sj(m)}$ をそれぞれ横軸、縦軸にとり、時間 t を媒介変数とした2次元の位相面軌道

$$O^{(m)}(s_i, s_j) = [Y^{si(m)}, Y^{sj(m)}] =$$

$$\left[\begin{array}{c} [y_1^{s_i(m)}, y_1^{s_j(m)}], \dots, [y_{T-W+1}^{s_i(m)}, y_{T-W+1}^{s_j(m)}] \end{array} \right]^T$$

を描く。位相面軌道 $O^{(m)}(s_i, s_j)$ は s_i, s_j の関係性を示しており、事前に学習した正常時の $O^{(m)}(s_i, s_j)$ とは異なる位相面軌道がフライトデータ (もしくは地上燃焼試験データ) から得られた場合、そのフライト (もしくは地上燃焼試験) には故障があると判断できる。

位相面軌道の形状を試験ケース間で比較するにあたり、動的時間伸縮法 (DTW)⁽⁵⁾を用いて位相面軌道形状同士の類似度を定量評価した。動的時間伸縮法は音声や手書き文字認識などで用いられている手法で、人によって微妙に波形が異なっているにもかかわらず、大きな特徴を捉えることによってパターンマッチングを行う。従って、2章の3), 4)項目に挙げた課題にあるように、エンジンの個体差や作動点のドリフト、また、制御入力に起因してフライト間や地上燃焼試験間で作動タイミングが変化しても堅牢に非類似度を比較できると考えられる。正常な基準となる基準フライトケース (もしくは基準地上燃焼試験ケース) を R_0 、比較対象とするケースを R_k ($k \in [1, K]$) とすると、 s_i, s_j の2つのセンサから成る第*m*次モードの位相面軌道をそれぞれ $O_{R_0}^{(m)}(s_i, s_j)$ 、 $O_{R_k}^{(m)}(s_i, s_j)$ と表す。 $O_{R_0}^{(m)}(s_i, s_j)$ の時刻 t と $O_{R_k}^{(m)}(s_i, s_j)$ の時刻 t' の局所距離関数 $g_{s_i, s_j}^{(m)}(t, t')$ はユークリッド距離を使い以下のように定義し、DTW距離 $G_{s_i, s_j}^{(m)}(R_0, R_k)$ を算出する。

$$g_{s_i, s_j}^{(m)}(t, t') = \left\| \begin{array}{c} [y_t^{s_i(m)}, y_t^{s_j(m)}]^{(R_0)} \\ - [y_{t'}^{s_i(m)}, y_{t'}^{s_j(m)}]^{(R_k)} \end{array} \right\|_2 \quad (1)$$

学習データに関するDTW距離を $G = \{G_{s_i, s_j}^{(m)}(R_0, R_1), \dots, G_{s_i, s_j}^{(m)}(R_0, R_K)\}$ とすると、単変量の変化点検知手法を利用可能となる。ここで、 G は正規分布に従うと仮定し、故障検知対象となる試験ケース R' の異常度 α は、負の対数尤度で次のように定義する。

$$\begin{aligned} \alpha & \left(G_{s_i, s_j}^{(m)}(R_0, R') \right) \\ & \equiv -\frac{K-1}{K+1} \ln \left\{ \mathcal{N} \left(G_{s_i, s_j}^{(m)}(R_0, R') \mid G \right) \right\} \end{aligned} \quad (2)$$

ホテリング理論より、上式は自由度 $(1, K-1)$ のF分布に従う。

$$\alpha \left(G_{s_i, s_j}^{(m)}(R_0, R') \right) \sim \mathcal{F}(1, K-1) \quad (3)$$

$K \gg 1$ であれば、上式は自由度1、スケール因子1のカイ二乗分布 $(\chi^2(1, 1))$ に従うため、一般的にはカイ二乗分布で定義されることが多い。しかし、2章の1)項目に挙げたように、学習データが少ないのがロケットエンジンの課題であるため、本稿では式(3)を用いた。

対象とする1つのシステムに S 個のセンサが搭載されている場合、すべてのセンサ組合せ(sC_2)に対してこの手法を適用する。そして、故障の有無を状態推定マトリクス (SEM) にて可視化する。RSRエンジンの地上燃焼試験データに対して作成したSEMの例をFig. 4に示す。行、列はともに対象とするセンサすべてを表し (Fig. 4では $S=59$)、行列の要素はそれぞれが対応するセンサの組み合わせにおける検知結果である。なお、SEMは対称行列となることから、下三角部分のみの結果を示す。行列の要素には、故障と検知された試験ケースを試験ケース毎に色分けして表示する。ある1つのセンサでセンサ故障が起きた場合、その故障したセンサに関する58個の組み合わせ (行列要素) に対して、故障した試験ケースが帯状に表示される。一方、システム故障の場合は複数のセンサ対の関係性が崩れると考えられ、システム故障を起こした試験ケースを示す行列要素がSEM内に点在する。つまり、SEM上に現れる故障検知結果のパターンを見れば、センサ故障なのかシステム故障なのかを識別可能である。




Fig. 1 Schematic of RSR engine.

3.2 RSRエンジンデータを利用した実証

RSRエンジンは液体酸素 (LH2) /液体水素 (LOX) を燃料とし、100%スロットリング時に40kNの推力 (sea level) を発生する液体ロケットエンジンである。Fig. 1に示すように、エンジンサイクルはエキスパンダーブリードサイクルを採用する。燃焼室、ノズルを冷却することでエネルギーを得た水素を使い、LH2とLOXを昇圧するための水素ターボポンプ (FTP) と酸素ターボポンプ (OTP) を駆動する。再利用を可能とするため、100%スロットリング時の燃焼圧は3.4 MPaと低く設計されており、比推力は320秒である。また、地上への帰還に向けた軌道の変更や減速を行うため、再着火や40~100%のスロットリングが可能である。詳細は参考文献³⁾を参照されたい。

RSRエンジンでは全54回の地上燃焼試験が行われたが、そのうち同一のオペレーショナルシーケンスで試験が行われた19試験ケース (Run001 ~ 019) ではセンサ故障とシステム故障がそれぞれ1回ずつ発生した。そこで、本手法を用いてこれらの故障を識別できるかを試行

する。Fig. 2に典型的な燃焼室圧の時間履歴を示す。0秒でエンジンを点火し、推力をいったん40%まで立ち上げ、8秒後に100%とする。100%推力になった10秒後にエンジンをシャットダウンし、その後、約40秒間隔でアイドリングと100%推力立ち上げを4回繰り返した。地上燃焼試験では設備を含めて350に及ぶ様々なセンサが用いられたが、本研究ではそのうちエンジン回りの59センサ ($S=59$) を故障検知に利用した。センサのサンプリング周波数は100 Hzである。

対象とするセンサ故障は、FTPタービン入口温度 (TT1F) を計測するために配管内に設置したシース熱電対が、エンジン運転中に配管内を流れるタービン駆動ガスの流体力によって振動し断線しかかったため計測値にノイズが現れた事象であり、Run008で発生した。Fig. 3では、故障が発生したRun008と典型的な正常試験の典型例であるRun009に関するTT1Fの時系列信号を比較する。本稿では二変量時系列解析を行うことから、対となるセンサの例としてFTPタービン出口温度 (TT2F) も併せて示す。TT1Fを比較すると、エンジン起動中のみで計測値にノイズが乗っていることが観察される。一方、TT2FはRun008, Run009ともに正常である。ただし、再着火時に推力が100%に立ち上がるタイミングは試験間で必ずしも一致しておらず、試験ケースによってずれている。次に、対象とするシステム故障はRun005で発生したもので、Fig. 1に示したエキスパンダーブリードサイクルを採用するRSRエンジンでは、FTP, OTPを駆動した水素ガスを外部に排気するわけだが、5回目のエンジン停止時に排気ライン下流の設備バルブが意図せず遮断し、排気ラインの排圧上昇を招いた。その結果、FTPやOTPのタービン周りの圧力センサに異常値が現れた。

Fig. 2の点線で示したエンジンが起動している区間のデータを切り出し、ノイズフィルタ等のプリ処理は何もせず、3.1章で紹介した二変量の故障検知手法を適用した。センサ組み合わせは $s_9C_2=1711$ 、全19試験の処理を行った。事前検討結果をもとに、窓幅 $W=5$ とした。そして、主要な変動を表すPCAの1次モードとその次に高周波な変動である2次モードの2つを用いて位相面軌道を作成した。故障検知に要した計算時間は、PCクラスタ (Intel Xeon E5-2643v4) の108コアを利用して33分であった。Fig. 4にモード1とモード2のSEMを示す。なお、基準試験ケース R_0 は正常データの中で典型的なRun018とし、式(3)で表される異常度の閾値は99.5%とした。Fig. 4 (a)に示すモード1の結果を見ると、PEXV2, PT10, PT201に関する複数のセンサ組み合わせでRun005試験が故障であること示している。また、PSDO1, QHEOに関連するセンサ組み合わせでRun019試験が故障であると示している。次にFig. 4 (b)に示したモード2の結果を見ると、モード1と同様にPEXV2, PT201に関する組み合わせのいくつかでRun005が故障

であることを示している。更に、TPBF2*とTT1Fに関してそれぞれRun015, Run008の故障が帯状に検知されている。上述の通り、今回比較した19試験ケースの中で、タービン排気ラインに関連するシステム故障がRun005で、TT1Fのセンサ故障がRun008で発生した。Fig. 3から分かるように、Run008のセンサ故障は大きなモードの変化ではなくより高周波数のノイズである。従って、Fig. 4 (b)に示すモード2のみに帯状にRun008が検知されたわけである。また、TT1Fに関するセンサ組み合わせでのみRun008の故障が帯状に現れていることから、センサ故障と考えられる。一方、システム故障が起きたRun005に関しては、モード1, 2のいずれにおいても関連する複数の圧力センサ (PEXV2, PT10, PT201など) の周りで故障が検知された。同時にこれだけ複数のセンサが故障することもないことから、Run005ではこれらのセンサ周りで何らかのシステム故障が起きたと判断できる。位相面軌道の例として、ここではFig. 3に示したTT1FとTT2Fに関する第2モードの位相面軌道を、全19試験に関して比較したのがFig. 5である。これら19試験の位相面軌道を比較すると、Run008以外の正常時は縦棒のような軌道形状であり、Run008のみが他の明らかに異なることが一目瞭然である。よって、この軌道形状の際がDTW法により非類似度の差異に現れ、Fig. 4 (b)のSEM上で検知されたわけである。

最後に、Fig. 4に示すSEM上で見つかった誤検知について議論する。モード1においてRun019を故障と判定したPSDO1とQHEOの2つのセンサに関して、それらの時系列信号を調べた。その結果、いずれも正常値の範




Fig. 2 Time history of combustion pressure.


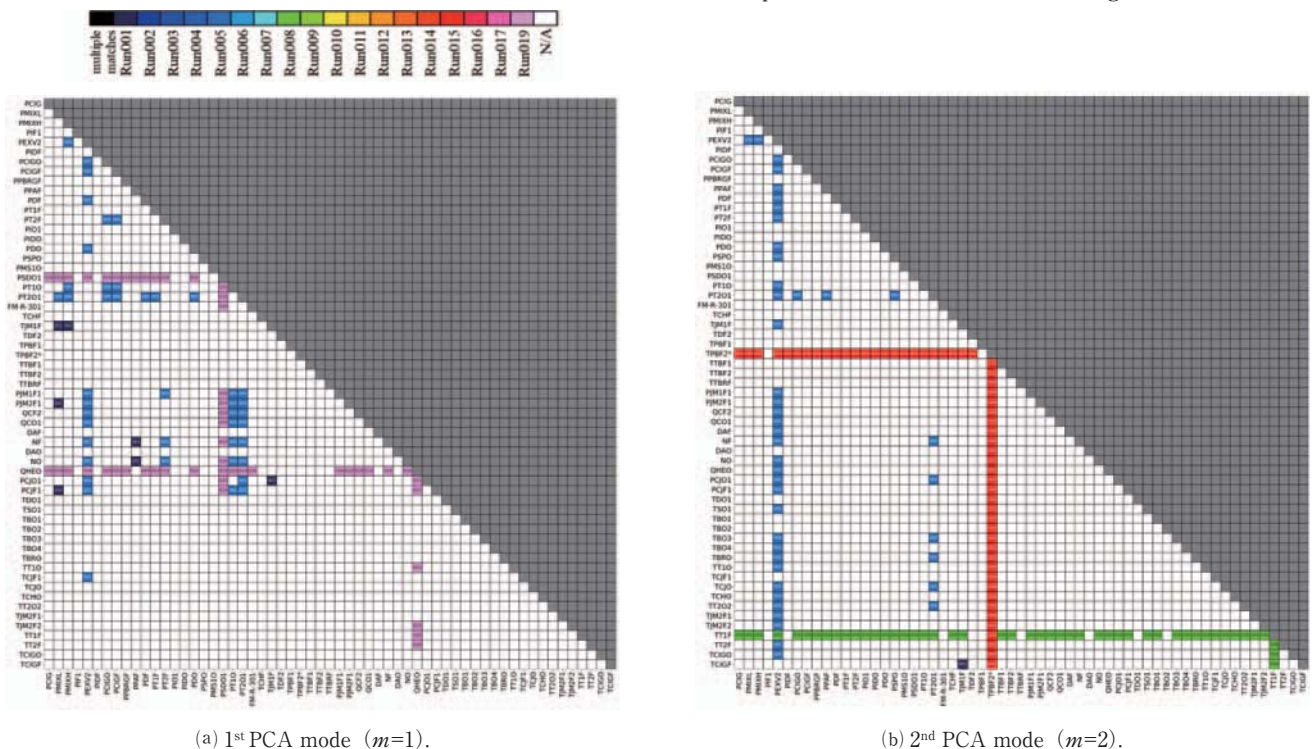


Fig. 3 Comparison of FTP turbine inlet and outlet temperature profiles of normal and abnormal firing tests.



(a) 1st PCA mode ($m=1$).

(b) 2nd PCA mode ($m=2$).

Fig. 4 SEM with α of 99.5 %.

圈内だが、他の18試験から明らかに外れていることが判明した。現状では、式(3)に示す通り、非類似度が単峰性の正規分布に従うと仮定して異常度を算出しているわけだが、正常値の範囲内であって単変量正規分布から外れるものがあることから、多峰性を仮定して正常データの分布を学習する必要があること示唆している。次に、モード2においてRun015を故障と判定したTPBF2*に関して調べると、Run015でのみPCAの固有ベクトルの第2、3モードが他と異なっていることが分かった。TPBF2*はセンサノイズの影響が顕著であることが原因であると考えられ、PCAによるモード抽出やノイズフィルタについて検討する必要がある。

以上のように、RSRエンジンの地上燃焼試験データを利用し、著者らが研究開発した二変量時系列解析による故障検知手法を試行した。センサ故障とシステム故障をどちらも含む全19試験データに対して故障となるセンサ組み合わせと試験ケースを抽出し、SEM上で検知箇所を可視化することで、センサ故障が発生した試験ケースとシステム故障が発生した試験ケースを識別可能であることが実証できた。

4. モデルベース型故障診断

4.1 手法

2章で紹介した課題の7)項に挙げられるように、故障診断手法に関する研究や実用例は少ないのが実情である。そこで、著者らが研究開発しているモデルベース型の故障診断手法を紹介する。

第*i*番センサ($i \in [1, S]$)の時刻 $t \in [1, T]$ における計測値を x_i^{st} とし、 $x_t = [x_t^{s1}, \dots, x_t^{sS}]^T$ とする。

そして、モデルパラメータ θ 、制御入力 u とする下記の非線形システムを考える。

$$x_t = f(\theta, u, t) \quad (4)$$

時系列データを $Z = [x_1, \dots, x_T]$ とする。本稿ではロケットエンジンや電動バルブといったシステム全体を対象とするため、流体、構造、電気、熱、制御、電力などの複合物理モデルとその連成が求められる。ここでは、システムレベルシミュレーション(SLS)を利用して非線形システムの方程式 f をモデル化する。故障モードはモデルパラメータ θ に異常がある場合や、制御入力 u に異常がある場合、更に非線形システムの方程式 f そのものに異常がある場合が想定される。故障モード r ($r \in [1, R]$)に対応するセンサの時系列信号を \hat{Z}_r とし、予め想定する故障モードのデータベース $\hat{Z} = [\hat{Z}_1, \dots, \hat{Z}_R]$ をSLSにて作成する。そして、未知の故障 ρ に関する時系列データ \hat{Z}_ρ と故障データベース \hat{Z} のパターンマッチングを行い、最も近い故障モードを検索するというのが基本的なアイデアである。

パターンマッチングを行う際、正常データ Z と故障データ \hat{Z}_r の差 $\hat{Z}'_r = \hat{Z}_r - Z$ を用いる。 \hat{Z}'_r と $\hat{Z}_\rho = \hat{Z}_\rho - Z$ を比較するため、データ駆動型異常検知手法と同様に、

DTW法を用いて類似度 $G(\hat{Z}'_r, \hat{Z}_\rho)$ を評価した。そして、 $G(\hat{Z}'_r, \hat{Z}_\rho)$ を最小化する r が故障原因であると特定できる。

$$\rho = \operatorname{argmin}_{r \in [1, R]} G(\hat{Z}'_r, \hat{Z}_\rho) \quad (5)$$

一方、正常データからの差をデータベース $\hat{Z}' = [\hat{Z}'_1, \dots, \hat{Z}'_R]$ とし、 \hat{Z}' に関するDTW距離に対してクラスタリングすると、故障モード毎に分類可能である。そこで、故障モードのデータベース \hat{Z}' に \hat{Z}'_ρ を加えてクラスタリ




Fig. 5 Phase plane trajectories ($O_{Rk}^{(2)}$ (TT1F, TT2F)) for 19 firing tests ($k \in [1, 19]$).

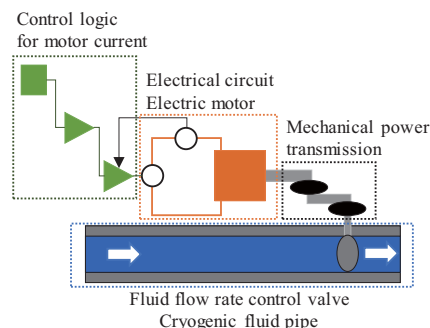


Fig. 6 Schematic of typical electromechanical actuated valve control system for liquid-propellant rocket engines.




Fig. 7 Value control input.




Fig. 8 Comparison of motor current for anomaly cases with test data (\hat{Z}).

ングすると、 ρ が分類されたクラスが故障モードと特定できる。本手法は、データ駆動型故障検知手法と同様に、DTW法を用いて類似度を評価するため、2章の3)、4)項に挙げたエンジンの個体差、作動点ドリフト、また入力の変化といった課題に対しても堅牢な診断が可能である。

4.2 電動バルブモデルを利用した検証

Fig. 6は液体ロケットエンジンで用いられる典型的な電動バルブの概要であり、モータ電流の信号制御ロジック、電気回路、モータ、動力伝達部、流量調整弁、極低温流体配管から構成される。本稿ではこの電動バルブを対象に故障診断手法を検証した結果を紹介する。SimulationX (ESI ITI社)を使い、Fig. 6に示す電動バルブのSLSモデルを作成した。Fig. 7はこのバルブに対する制御入力信号で、モータ電流値である。実フライトにおいては環境条件の不確定性に起因し、制御タイミングが変動することから、ここではFig. 7に示す8パターンの制御信号 (Case 1～Case 8)を入力信号とした。故障モードとして、以下の4つをSLSでモデル化した。

- 1) 動力伝達部の機構トルク異常 (TF)
- 2) 流量調整弁の圧力損失異常 (RF)
- 3) モータコイルの断線 (MF)
- 4) 流体配管内流れの異常に起因した流量調整弁にかかる流体トルク異常 (FF)

そして、Fig. 7に示す8つの制御入力に対してそれぞれ故障データを作成し、故障データベース \hat{Z} として合計32セットのデータを作成した。(R=32)故障を診断するためのセンサは、電動バルブの故障に対して最も感度のあるモータ駆動電流の1点のみとした。(S=1)SLSを利用して作成した、モータ駆動電流値の正常状態からの差 \hat{Z} をFig. 8に示す。上述した4つの故障モード毎に色分けし、故障モード毎にFig. 8に示した8つの制御入力に関する結果をプロットしている。故障モードTF (赤)は6秒から9秒にかけて正 (正常値より大きい)の異常値を示し、故障モードRF (緑)は4秒から9秒の幅広

い区間にかけて負 (正常値より小さい)の異常値を示す。故障モードMF (青)は4秒から6秒の狭い領域に正の異常値を示しており、最後に故障モードFF (マゼンタ)は、故障モードRFと同様に、4秒から9秒の幅広い区間にかけて負の異常値を示す。ただし、絶対値としては小さい。32セットの時系列データからなる故障データベース \hat{Z} 同士のDTW距離を計算し、階層型クラスタリングをした結果をFig. 9に示す。ただし、Fig. 9は後ほど述べる故障模擬データも含んだクラスタリング結果である。Fig. 9より、TF, RF, MF, FFの4つの故障モードで分類されていることがわかる。従って、Fig. 8に示した故障データベースの時系列波形は、DTW距離を類似度を使うことによって故障モード毎に分類可能であることが分かる。

次に、本手法にて故障診断が可能であるかを検証するため、故障模擬データ \hat{Z}_ρ を作成した。今回作成した故障模擬データは故障モードTFに対応し、更に、フライトデータを想定して計測ノイズを負荷した。Fig. 8では \hat{Z}_ρ (黒)も併せて示しており、 \hat{Z} にはないノイズ成分が \hat{Z}_ρ に負荷されていることが見て取れる。更に、故障モードTFと同様に、6秒から9秒に正の異常値が現れていることが観察される。故障データベース \hat{Z} と故障模擬データ \hat{Z}_ρ を含めた階層型クラスタリングの結果をFig. 8に示す。今回の故障模擬データは左端に現れており、故障データベースに含まれる4つの故障モードの中では故障モードTFのクラスに最も近い。そのため、模擬された故障 ρ はTFであると識別される。

以上のように、液体ロケットエンジンに典型的な電動バルブを対象に、本研究にて開発した故障診断手法を適用した。その結果、故障原因を診断可能であることが分かった。現在、故障を模擬したロケットエンジン用電動アクチュエータに対し、本手法の実証を既に実施しているところである。また、より複雑な再使用ロケットエンジンシステム全体に対しても故障診断技術の獲得を目指し、まずはSLSモデルの研究開発を進めている。




Fig. 9 Hierarchical clustering of DTW distance between anomaly database with test data.

5. まとめ

再使用ロケットの開発において、整備コストとその期間の短縮は、成立性や国際競争力に直結する重要な課題の1つである。本稿では、著者らが実施している再利用ロケットエンジンの整備コスト・期間の削減に向けた故障検知・診断手法の研究開発状況を紹介した。本手法は、再使用ロケット着陸後のフライトデータに対して1)データ駆動型の故障検知を行い、もし何らかのシステム故障が検知された場合は2)モデルベース型の故障診断を行って故障箇所を特定する、という二段構えから成る。データ駆動型故障検知手法は、センサ/システム故障の切り分け、エンジン個体差、作動点や制御入力の変化にも対応することを目指し、二変量時系列解析に基づく故障検知手法を開発した。そして、再使用液体ロケットエンジンの地上燃焼試験データに適用し、センサ故障とシステム故障を識別して検知することができた。モデルベース型故障診断手法では、システムレベルシミュレーションを用いて重要故障モードに対する故障のデータベースを予め作成し、故障が検知されたフライトデータとのパターンマッチングを行うことで、たとえ制御入力による状態の変化があっても堅牢に故障モードの診断が可能な手法を開発した。液体ロケットエンジンで用いられる典型的な電動バルブに対して本手法を適用し、故障モードを診断可能であることを検証した。

ここで開発した手法は、再使用ロケットエンジンのみならず、ガスタービンエンジン等の産業機器にも適用可能である。本稿に端を発し、幅広い産業分野でも利用され、我国の産業技術力向上に貢献できれば幸いである。

参考文献

- (1) Hawman, M.W., Galinaitis, W.S., Tulpule, S., and Mattedi, A.K., Framework for a Space Shuttle Main Engine Health Monitoring System, NASA CR-185224 (1990).
- (2) Wu, J., Liquid-propellant rocket engines health-monitoring-a survey, *Acta Astronautica*, Vol. 56 (2005), pp. 347-356.
- (3) Schwabacher, M., Oza, N., and Mathews, B., Unsupervised Anomaly Detection for Liquid-Fueled Rocket Propulsion Health Monitoring, *Journal of Aerospace Computing, Information, and Communication*, Vol. 6 (2009), pp. 464-482.
- (4) Iannetti, A., Marzat, J., Piet-Lahanier, Ordonneau, G., and Vingert L., Fault diagnosis benchmark for a rocket engine demonstrator, Proceedings of 9th International Federation of Automatic Control Symposium on Fault Detection, *Supervision and Safety for Technical Processes SAFEPROCESS 2015*, Paris, France (2015), pp. 895-900.
- (5) Sato, M., Hashimoto, T., Soma, T., and Mizoguchi, T., Failure Detection of Liquid Propellant Rocket Engine Using System Invariant Analysis Technology, *68th International Astronautical Congress (IAC)*, IAC-17-C4.1.12 (2017).
- (6) 堤 誠司, 平林 美樹, 佐藤 大和, 河津 要, 佐藤 正喜, 橋本 知之, 木村 俊哉, 機械学習を利用した再使用ロケットエンジンの故障予知に関する研究, 第59回航空原動機・宇宙推進講演会, 1B15 (2019).
- (7) 佐藤大和, 堤誠司, 河津要, 平林美樹, 木村俊哉, アンサンブルカルマンフィルタを用いたロケットエンジンのシステムモデリング技術, 第59回航空原動機・宇宙推進講演会, 1B16 (2019).
- (8) Kawatsu, K., PHM by Using Multi-Physics system-Level Modeling and Simulation for EMAs of Liquid Rocket Engine, *2019 IEEE Aerospace Conference*, 2019.
- (9) Hirabayashi, M., Sato, D., Tsutsumi, S., Kawatsu, K., Sato, M., Hashimoto, T., and Kimura, T., Complementary-Integrated Approach to Model-Based and Data-Driven Prognostics and Fault Diagnosis for Reusable Rocket Engine Systems, *32nd International Symposium on Space Technology and Science*, 2019-t-06 (2019).
- (10) Jolliffe, I.T., *Principal Component Analysis*, Second Edition. New York: Springer (2012).
- (11) Inatani, Y., Ogawa, H., Naruo, Y., Nonaka, S. and Tokudome, S., Recent Progress Toward Reusable Sounding Rocket, *61st International Astronautical Congress*, IAC-10-D2.4.9 (2010).
- (12) Nonaka, S., Ito, T. and Ogawa, H., System Design and Technical Demonstrations for Reusable Sounding Rocket, *64th International Astronautical Congress*, IAC-13-D2.5.5 (2013).
- (13) Kimura, T., Hashimoto, T., Sato, M., Takada, S., Moriya, S., Yagishita, T., Naruo, Y., Ogawa, H., Ito, T., Obase, K., and Ohmura, H., Reusable Rocket Engine: Firing Tests and Lifetime Analysis of Combustion Chamber, *Journal of Propulsion and Power*, Vol. 32, No. 5 (2016), pp. 1087-1094.
- (14) Fujimaki, R., Yairi, T., and Machida, K., An approach to spacecraft anomaly detection problem using kernel feature space, *Proceedings of the 11th ACM SIGKDD international conference on knowledge discovery in data mining*, (2005), pp. 401-410.
- (15) Bahlmann, C., and Burkhardt, H., The Writer Independent Online Handwriting Recognition System frog on hand and Cluster Generative Statistical Dynamic Time Warping, *IEEE Transaction on pattern analysis and machine learning intelligence*, Vol. 26, No. 3 (2004), pp. 299-310.

特集：エネルギー産業への機械学習の応用

MIを用いた極小熱伝導率を有する無機複合材料の開発

Development of Ultra-Low Thermal Conductive Inorganic Composite by MI



徐一斌^{*1}
XU Yibin



Wu Yen-Ju^{*1}
WU Yen-Ju



佐々木道子^{*1}
SASAKI Michiko



後藤真宏^{*1}
GOTO Masahiro

キーワード：界面熱抵抗，ナノ複合材料，機械学習，コンビナトリアルスパッタ

Key Words：Interfacial Thermal Resistance, Nano-composite, Machine Learning, Combinatorial Sputter

1. 緒言

断熱コーティングは、ガスタービンや自動車内燃機関などのエネルギー効率，または，電子デバイスの安全性と寿命を向上させるための重要な材料技術である。従来の断熱材料の多くは，空孔などによって空気を含有させることで，低熱伝導率を実現しているが，このような材料は，強度と耐摩耗性が低いので，実用的なコーティングとしての利用は難しい。熱遮蔽コーティングとして多く報告されているイットリア安定化ジルコニア（YSZ）も，粒界や亀裂により熱輸送を阻害できるものの，同様に強度と断熱性能のトレードオフが存在する。

異相・異種材料の界面では，熱キャリアであるフォノンが散乱或いは反射されるので，空隙がなくても熱抵抗が生じる。完全に結合している界面の熱抵抗は，材料の組合せによって，最大 $10^{-7} \text{ m}^2 \text{ KW}^{-1}$ の桁数の大きさに達することが可能であり⁽¹⁾，これはアモルファス SiO_2 の数百nm厚さの熱抵抗に相当し，熱伝導率を効率的に下げることが可能と考えられる。本研究では，異種材料の界面熱抵抗を利用して，空孔のない，緻密な低熱伝導率コーティングの設計技術の確立と実験検証を目標とする。当該目標の達成には，主に二つの技術課題がある：(1)界面熱抵抗の高い材料組合せの設計，(2)複合材料の組織最適化による熱伝導率の最小化。

2. 高界面熱抵抗の材料組合せの設計

2.1 界面熱抵抗の予測

界面熱抵抗は，界面構成材料の特性，界面での化学結

合，新相の生成や界面構造など，多くの要因に影響されるため，その予測は，熱輸送理論の難問の一つと認識されている。これまでに，界面熱抵抗の予測に多く用いられている物理モデルは以下の二つがある⁽²⁾：Acoustic Mismatch Model (AMM) と Diffusion Mismatch Model (DMM) である。これら二つのモデルは，界面両側材料特性のミスマッチにより，界面熱抵抗を計算しており，界面の化学的な変化や，材料作製プロセスの影響などは一切考慮されていない。AMMとDMMの予測値と実験値の比較⁽³⁾をFig. 1に示す。全体の変化傾向は一致するものの，精度が高いとは言えない。

界面熱抵抗を高精度に予測するためには，界面での化学結合や作製プロセスの要因も考えなければならないが，それらの要因を物理モデルに全て取り込むことは困難である。そこで，我々は，データ科学のアプローチから本課題の解決を試みた。

2.1.1 界面熱抵抗データの収集 機械学習は，大量のデータに基づいて，事前を選択したアルゴリズムによってデータモデルを作成し，未知のデータを予測したり，分類したりする手法である。材料特性などの現象の原因となる物理や化学的なプロセスが分からなくても，データ間の相関性を見つけ出し，特性を予測することを可能とする。機械学習を適用するために，まず，これまでに発表された論文から界面熱抵抗の実験データを収集した。Fig. 2は，収集した456界面サンプルの熱抵抗のデータである⁽⁴⁾。

2.1.2 記述子の選定 記述子は，界面熱抵抗計算時の入力パラメータである。界面熱抵抗に影響を及ぼす要因が多く存在するので，その中から，重要且つ代表的なものを選択する必要がある。また，合わせてデータ入手のしやすさ，データの信頼性も考慮すべきである。これまでの経験に基づいて，我々は，界面熱抵抗の記述子を物

原稿受付 2019年7月4日

*1 物質・材料研究機構 統合型材料開発・情報基盤部門 情報統合型物質・材料研究拠点
〒305-0047 つくば市千現1-2-1
E-mail: XU.Yibin@nims.go.jp

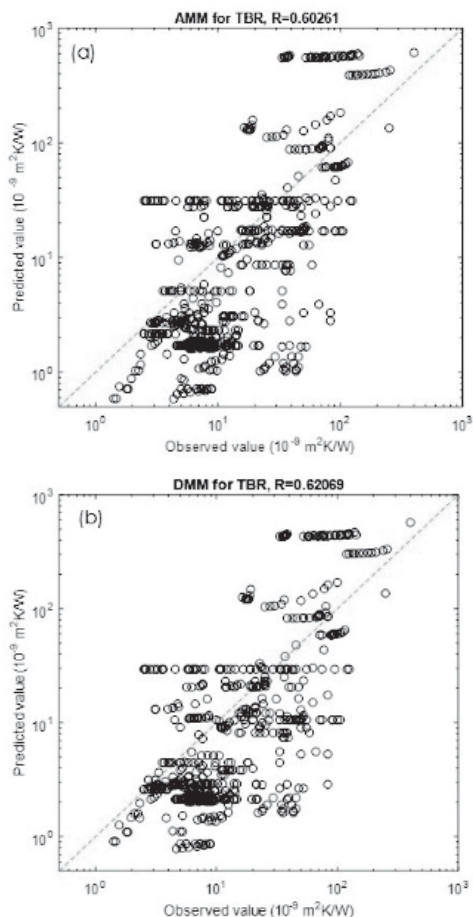


Fig. 1 Comparison of interfacial thermal resistances measured and calculated by AMM (a) and DMM (b) models.




Fig. 2 Experimental data of interfacial thermal resistance used in machine learning.

理的, 化学的, 材料的な三カテゴリに分類した。

1) 物理的記述子 物理的な記述子は, 熱伝導に関連する界面両側材料の特性や, 結晶構造等を指す。熱伝導に関連する特性は多く存在するが, ハンドブック⁽⁵⁾やデータベース⁽⁶⁾⁻⁽⁸⁾等に多く収録されているのは, 比熱, 融点, 熱伝導率, Debye温度, 音速(縦, 横), 弾性係数, 体積弾性係数, 熱膨張係数, 単位胞体積, 密度の11種類である。その11種類のデータを収集し, 相関性解析を行い, クラスタリングを行った。同じクラスターに所属する関

連性の強い物性は, 同じ物理・化学要因に支配されるものと考えられ, そのうちの代表的な一つを記述子として選択すればよい。Fig. 3は, その11種類の物性の相関性解析結果である。この結果に基づいて, 更にデータの入手しやすさや, ばらつき等を考慮し, 密度, 比熱, 融点, 単位胞体積の4つを記述子として選定した。




Fig. 3 Linear correlation of 11 physica properties related to heat transfer.

2) 化学的記述子 化学的な記述子は, 界面での化学結合や, 新相の生成しやすさを表わすパラメータである。化学の基本原則に基づいて, 界面構成原子の周期と族, 電気陰性度, イオン化ポテンシャル, また, 両側材料の安定性を表わす結合エネルギーを記述子として選定した。

3) 材料的記述子 材料の作製プロセスや界面構造等は, 界面熱抵抗に大きな影響を及ぼす可能性があるため, 記述子として取り込む必要がある。しかし, 作製方法によって, 制御パラメータが様々であり, 論文著者によって, 記述方法も異なるため, 抽出できる共通のパラメータは非常に少ない。最終的に, 膜厚と中間層の有無の二つを記述子として選定した。また, 界面熱抵抗は温度の関数なので, 測定温度も一つの記述子となる。

2.1.3 機械学習 上記の界面熱抵抗と記述子データを用いて, 機械学習を行った。機械学習のアルゴリズムは, Regression tree ensembles of LSBoost (LSBoost), support vector machines (SVM), Gaussian regression processes (GRP) の三つを利用した。その三つの方法の予測精度を表わす相関係数 (R), 決定係数 (R²), 二乗平均平方根誤差 (root mean squared error : RMSE)⁽⁴⁾を

Table 1 に示す。RとR²は1, RMSEは0に近づくほど精度が高い。三つのアルゴリズムとも, 高い予測精度が

Table 1 Accuracies of the machine learning algorithms used in this work.

アルゴリズム	R	R ²	RMSE
LSBoost	0.958	0.919	8.944
SVM	0.938	0.879	10.897
GRP	0.957	0.916	9.073

得られた。なかでも、LSBoostの予測精度は最も高い。LSBoostの予測値と実験値との比較⁴⁾をFig. 4に示す。




Fig. 4 Comparison of interfacial thermal resistances predicted by LSBoost machine learning model and experimental values.

2.2 高界面熱抵抗材料組合せの探索

上記の三つの機械学習モデルを利用して、様々な材料組合せに対して界面熱抵抗を計算し、高熱抵抗の材料組合せを探索した。探索空間は、一元と二元の約300物質の組合せにより構成した80,282の界面である。それぞれの方法で予測したトップ100の高熱抵抗界面をリストアップし、その重なり状況を検討した。三つの方法全てでランクインしたのは3界面、二つの方法でランクインしたのは22界面であった。その合計25界面の類似性を表わすMulti-Dimension Scaling (MDS) 図⁴⁾をFig. 5に示す。MDS図では、点と点の距離が近いほど類似性が高い。図の左下の楕円で囲まれた3界面は、三つの方法とも高




Fig. 5 MDS plot of 25 interfaces with high interfacial thermal resistance predicted by more than two machine learning methods. Those enclosed in the ellipse are predicted by all of the three methods to have high thermal resistance. Bi/Si enclosed in the square is selected to be verified by experiments.

熱抵抗を予測した界面であるが、材料の作製し易さや界面安定性などを考慮し、この3界面ではなく、それらと類似するBi/Si界面を材料実験の検証対象として選択した。

3. Bi/Si系材料の実験検証

実験検証は、Bi/Si単界面の作製・熱抵抗測定と、Bi/Si複合材料の作製・熱伝導率測定の二つのステップで行った。

3.1 Bi/Si単界面熱抵抗の検証

マグネトロンスパッタ法を用いて、Si単結晶基板上に結晶性のBiを成膜し、我々が独自に開発した周波数領域法 (ω 法)を用いて、その界面熱抵抗を測定した。Bi/Siの界面熱抵抗の測定値は、 $51.8 \pm 4.5 \times 10^{-9} \text{ m}^2 \text{ KW}^{-1}$ であった。LSBoost, SVM, GPRのそれぞれの予測値は、50.7, 61.1, $60.3 \times 10^{-9} \text{ m}^2 \text{ KW}^{-1}$ であり、LSBoostの予測値が、実験値に最も近いことがわかる。

3.2 Bi/Si複合材料熱伝導率の検証

複合材料の熱伝導率は、フィラーの体積率、サイズ、配向などの組織構造にも強く依存するので、構造最適化は、低熱伝導率を得るための重要なプロセスである。そのために、独自開発のコンビナトリアルスパッタ成膜装置 (COSCOS) を利用した⁹⁾。この装置の特徴は、事前に設定した作製条件に従って、14枚の試料を一枚ずつ、条件を変更しなから自動成膜できることである。Si単結晶基板の上に、厚さ0.5 ~ 3 nmに制御したBiとSi層を交互に蒸着し、総厚さ約100 nmの薄膜を作製した。BiとSiの成分比や、基板温度、RF印加電力などを変更し、




Fig. 6 Examples of the TEM images of the synthesized Bi/Si composites.

28枚の試料を作製した。X線回折の解析結果によって、作製した複合材料は、アモルファスSiのマトリクス中に、Biのナノ結晶が分散していることが分かった。作製条件によって、Bi結晶粒のサイズは、数nm～百nmに変化し、形状や配向も異なる¹⁰⁾。その例として、Fig. 6にNo.16とNo.22の試料の組織構造を示す。

複合材料の熱伝導率は、周波数領域法 (ω 法)を用いて測定した。全ての試料の熱伝導率は、 $0.4 \text{ Wm}^{-1}\text{K}^{-1}$ 以下であり、最も低いものは、 $0.16 \text{ Wm}^{-1}\text{K}^{-1}$ であった¹⁰⁾。Fig.7は、本研究の結果とこれまでに報告された無機複合材料及び高分子の熱伝導率との比較である。本研究で得られた熱伝導率は、無機複合材料で最も低く、高分子の熱伝導率に相当する。結晶性BiとアモルファスSiのバルク熱伝導率は、それぞれ、約7と $1 \text{ Wm}^{-1}\text{K}^{-1}$ であることから、複合材料の極小熱伝導率の要因は、高界面熱抵抗の影響と考えられる。




Fig. 7 Thermal conductivity of the Bi/Si composites with comparison to those of the inorganic composites reported so far and polymers .

4. まとめ

界面熱抵抗の実験データと物理的、化学的、材料的な記述子を用いて、三つの機械学習アルゴリズムにより、界面熱抵抗の予測モデルを作成し、AMMとDMM物理モデルより高い予測精度が得られた。それらを利用して、80,000種類の界面熱抵抗を予測し、高界面熱抵抗の材料組合せ候補を特定し、その中からBi/Siの組合せに対して、実験検証を行った。まず、Bi/Si単界面の熱抵抗を測定し、機械学習の予測値と一致することを確認した。次にスパッタ法により、組織構造の異なるBi/Siナノ複合膜を作製し、熱伝導率を測定した。最も小さい熱伝導率として、 $0.16 \text{ Wm}^{-1}\text{K}^{-1}$ を達成した。

機械学習は、材料現象の原因となる物理、化学プロセスが分からなくても、データ間の相関性を利用して、モ

デリングや特性予測などが可能であるため、界面のような複雑な材料現象の研究に役に立つことを本研究により実証した。ただし、機械学習用のデータセットの作成の際には、データ量だけではなく、記述子の選定やデータの品質も考慮する必要がある。この時、これまでの物理・化学理論と材料経験が、記述子選択の重要指針になる。また、特性データ間の相関性を利用して、入手困難、または、品質の低いデータを、データ量が豊富、もしくは、品質の高いデータで代用することは、データ不足の問題を解決するための有効な手法である。

謝辞

本研究は、科学技術振興機構 (JST) のイノベーションハブ構築支援事業の「情報統合型物質・材料開発イニシアティブ (MI²I)」から支援を受けた。ここに記して謝意を表す。

参考文献

- (1) Wang H., Yibin Xu, Shimono M., Tanaka Y. and Yamazaki M., Computation of interfacial thermal resistance by phonon diffuse mismatch model, MATERIALS TRANSACTIONS, 48 (9) (2007), pp. 2349-2352.
- (2) Swartz, E. T. & Pohl, R. O. Thermal boundary resistance. Rev. Mod. Phys. 65 (1989), pp. 605-668.
- (3) Zhan T., Fang L., Xu Y., Prediction of thermal boundary resistance by the machine learning method, Scientific REPORTs | 7: 7109 | DOI:10.1038/s41598-017-07150-7 (2017).
- (4) Wu Y., Fang L., Xu Y., Predicting Interfacial thermal resistance by machine learning, npj Comput. Mater. (2019) 56.
- (5) Touloukian, Y. S. in The TPRC Data Series (Plenum Publishing Corporation, West Lafayette, IN, USA, 1970).
- (6) 無機材料データベース AtomWork-Adv < <https://atomwork-adv.nims.go.jp/> > (参照日 2017年).
- (7) 電子構造計算データベース CompES-X < <https://compes-x.nims.go.jp/> > (参照日 2017年).
- (8) The Materials Project < <https://materialsproject.org/> > (参照日 2017年).
- (9) Goto M., Kasahara A., Tosa M., Low frictional property of copper oxide thin films optimised using a combinatorial sputter coating system, Appl. Surf. Sci. 252 (7) (2006), pp. 2482-2487.
- (10) Wu Y. J., Sasaki M., Goto M., Fang L. Xu Y., Electrically conductive thermally insulating Bi-Si nanocomposites by interface design for thermal management, ACS Appl. Nano Mater. 1 (7) (2018), pp. 3355-3363.

特集：エネルギー産業への機械学習の応用

データドリブン手法に基づく低次元特徴抽出手法を用いた 燃焼不安定性解析

Combustion Instability Analysis of Low-lank Structure Extraction Method Based on Data-driven Approach



中谷 辰爾*¹
NAKAYA Shinji

キーワード：燃焼振動，水素燃焼，ラム燃焼器，主成分分析，機械学習

Key Words：Combustion Instability, Hydrogen Combustion, Ram Combustor, Principal Component Analysis, Machine Learning

1. 緒言

ガスタービン，ジェットエンジンおよびロケットエンジン燃焼器において，燃焼振動は騒音の原因となるのに加え，燃焼室の損傷やエンジンの故障の原因となりうる。燃焼振動は強い圧力振幅を伴う燃焼である。変動は自発的に起きる場合や，自然な擾乱や外部から加えられた擾乱により開始される。燃焼不安定性は内在的な不安定性に起因する低周波数帯，局所的な燃空比のばらつきや音響がカップリングした中周波数帯，音響擾乱と燃焼が相互作用した高周波帯の現象がある⁽¹⁾⁻⁽³⁾。音響による燃焼振動の発生条件に関しては，レイリーの条件⁽⁴⁾により判定されているものの，これらの発生や遷移は高次元かつ非線形であり，それらの原因の特定やメカニズムの理解は困難である。また，実験室における燃焼器で生じる燃焼振動と，複数の噴射器を伴う実燃焼器の高圧力，高温度でおきる燃焼振動は大きく異なることが指摘されており⁽⁵⁾，実スケールでの現象解明が必要である。しかしながら，実際の燃焼器の環境においては計測手段や数値計算手段が限定的であるのが現状である。

上記のような燃焼振動現象を把握するには，流体力学や燃焼化学に基づいた解析だけでは限界があり，データドリブンな手法により，数学，ベイズ統計および機械学習を用いた手法を用いることで多くの知見が得られる。流体力学や燃焼の分野においては，決定論的手法として，主成分分析 (Principal Component Analysis: PCA)⁽⁶⁾ や動的モード分解 (Dynamic Mode Decomposition: DMD)⁽⁷⁾ などの線形手法による解析が実施されている。流体力学分野等ではPCAは固有直交分解 (Proper Orthogonal Decomposition: POD)^{(8),(9)} として知られる。

これらの線形解析手法により，内在する特徴量を抽出することができるが，基本的には時不変な系に対して用いられる手法である。これらの解析手法をカーネル関数を使用することで非線形系に拡張したものとして，カーネルPCA (Kernel PCA)⁽¹⁰⁾，カーネルDMD (Kernel DMD) などがある。これらの非線形手法ではハイパーパラメータを自身で設定するのに加え，計算負荷が大きくなる。上記のPCA手法において，データに基づき最尤推定などを行うことでパラメータを特定し，確率論的に主成分分析を行う確率論的PCA (Probabilistic PCA)⁽¹¹⁾，さらにこれを拡張し，潜在空間と観測空間をガウス過程 (Gaussian Process: GP) により結びつけ，潜在変数およびハイパーパラメータを学習させたガウス過程潜在変数モデル (Gaussian Process Latent Variable Models: GP-LVM)⁽¹²⁾ による低次元化による解析がある。GP-LVMの学習は教師なし学習手法の一つである。GP-LVMはベイズ的機械学習により作成した自己組織化マップ (Self-Organizing Map: SOM)^{(13),(14)} としてみることができる。本稿ではこれらの手法および，筆者らの研究室で実施されている解析結果を概説する。

2. 解析手法

ここでは実験や数値解析によって得られた M 次元のデータが N 個あるとする。例えば，高速度カメラの画像だと M ピクセルの画像が N 枚得られているとする。各画像 (観測変数) を1次元ベクトル $\mathbf{y}_i \in \mathbb{R}^M$ に変換し一つの行列にマージすると， $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{N-1}, \mathbf{y}_N] \in \mathbb{R}^{M \times N}$ となる。これらから平均成分 $\boldsymbol{\mu}$ を差し引いた後，データ行列 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N-1}, \mathbf{x}_N] \in \mathbb{R}^{M \times N}$ が得られる。このデータ行列に対して解析を実施し，特徴量抽出を行う。また，以下 M 次元を D 次元 ($D < M$) に低次元化することとする。本稿では特に再定義がなければ上記定義を用いる。

原稿受付 2019年7月25日

* 1 東京大学大学院工学系研究科航空宇宙工学専攻
〒113-8656 文京区本郷7-3-1
E-mail: tsnakaya@mail.ecc.u-tokyo.ac.jp

2.1 主成分分析 (PCA)

主成分分析では、 M 次元データ \mathbf{x}_i を単位ベクトル \mathbf{u} に直交射影を行う。この時、 $\{\mathbf{u}^T \mathbf{x}_i\}_{i=1}^N$ の分散が最大となるように第一主成分をとり、 \mathbf{u}_1 は以下の式で表される。

$$\begin{aligned} \mathbf{u}_1 &= \operatorname{argmax}_{\|\mathbf{u}\|=1} \frac{1}{N} \sum_{i=1}^N (\mathbf{u}^T \mathbf{x}_i)^2 \\ &= \operatorname{argmax}_{\|\mathbf{u}\|=1} \mathbf{u}^T \mathbf{S} \mathbf{u} \end{aligned} \quad (1)$$

ただし、 \mathbf{S} は標本分散共分散行列であり、以下の式で表される。

$$\mathbf{S} = \frac{1}{N} \mathbf{X} \mathbf{X}^T \quad (2)$$

$\mathbf{u}_1^T \mathbf{x}_i$ はデータ \mathbf{x}_i の第一主成分である。主成分は、標本分散共分散行列 \mathbf{S} を固有直交分解し、固有値の大きい順に D 個対応する固有ベクトル $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_D$ が得られる。データ \mathbf{x}_i をこれらの主軸に直交射影することで、主成分が得られる。Fig. 1に2次元データに対して主成分分析を実施する場合の概念図を示す。

これらの解析は固有値問題を解くため、データの次元に依存して計算負荷が大きくなる。上記の場合、 $M \leq N$ の場合においては、Rモードと呼ばれる式(2)の共分散行列の固有値問題を解けばよいが、 $M > N$ の場合には、双対問題を解くと計算コストを削減できる。式(2)の行列の固有値 λ_i とそれに対応する固有ベクトル \mathbf{u}_i を用いると以下の式が得られる。

$$\frac{1}{N} \mathbf{X} \mathbf{X}^T \mathbf{u}_i = \lambda_i \mathbf{u}_i \quad (3)$$

式(3)の左から \mathbf{X}^T をかけると、

$$\frac{1}{N} \mathbf{X}^T \mathbf{X} (\mathbf{X}^T \mathbf{u}_i) = \lambda_i (\mathbf{X}^T \mathbf{u}_i) \quad (4)$$

この場合、行列 $1/N \mathbf{X}^T \mathbf{X}$ ($N \times N$ 行列)の固有値問題(Qモード)を解くことにより、必要な主成分を求めることが可能である。この時の固有ベクトル成分を \mathbf{v}_i とすると、 \mathbf{u}_i と \mathbf{v}_i は以下の関係を満たす。

$$\mathbf{v}_i = \frac{1}{\sqrt{N \lambda_i}} \mathbf{X}^T \mathbf{u}_i \leftrightarrow \mathbf{u}_i = \sqrt{N \lambda_i} \mathbf{X} \mathbf{v}_i \quad (5)$$

これを双対PCA (Dual PCA) と呼ぶ。

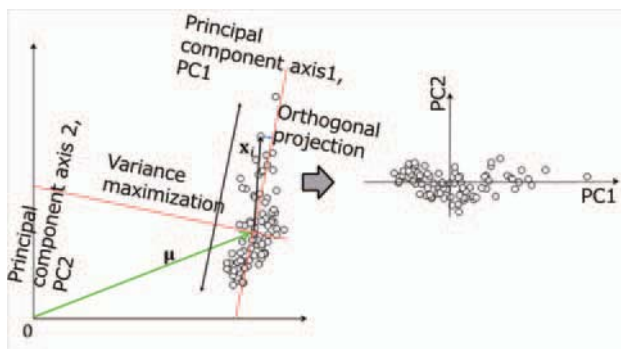


Fig. 1 Conceptual image of PCA.

2.2 確率論的PCA (PPCA)

ここでは、変数が制約のあるガウス分布に従うとする。観測変数 $\mathbf{y}_i \in \mathbb{R}^M$ が対応する D 次元の潜在変数 $\mathbf{z}_i \in \mathbb{R}^D$ で表される。 \mathbf{z}_i の事前分布が平均0、分散1の正規分布に従うとすると、 $p(\mathbf{z}_i) = \mathcal{N}(\mathbf{z}_i | \mathbf{0}, \mathbf{I})$ で記述される。この時、条件付確率分布 $p(\mathbf{y}_i | \mathbf{z}_i)$ は以下のように表される。

$$p(\mathbf{y}_i | \mathbf{z}_i) = \mathcal{N}(\mathbf{y}_i | \mathbf{W} \mathbf{z}_i + \boldsymbol{\mu}, \sigma^2 \mathbf{I}) \quad (6)$$

すなわち、データは $\sigma^2 \mathbf{I}$ に従うノイズ $\boldsymbol{\varepsilon}$ を持ち、下記の式で表される。

$$\mathbf{y}_i = \mathbf{W} \mathbf{z}_i + \boldsymbol{\mu} + \boldsymbol{\varepsilon} \quad (7)$$

潜在変数の事前分布 $p(\mathbf{z}_i)$ により周辺化すると、

$$\begin{aligned} p(\mathbf{y}_i | \mathbf{W}, \boldsymbol{\mu}, \sigma^2) &= \int p(\mathbf{y}_i | \mathbf{z}_i, \mathbf{W}, \boldsymbol{\mu}, \sigma^2) p(\mathbf{z}_i) d\mathbf{z}_i \\ &= \mathcal{N}(\mathbf{y}_i | \boldsymbol{\mu}, \mathbf{W} \mathbf{W}^T + \sigma^2 \mathbf{I}) \end{aligned} \quad (8)$$

観測変数 \mathbf{y}_i の尤度 $p(\mathbf{y}_i | \mathbf{W}, \boldsymbol{\mu}, \sigma^2)$ もガウス分布となる。これを全データに対して行うと、

$$p(\mathbf{Y} | \mathbf{W}, \boldsymbol{\mu}, \sigma^2) = \prod_{i=1}^N \mathcal{N}(\mathbf{y}_i | \boldsymbol{\mu}, \mathbf{W} \mathbf{W}^T + \sigma^2 \mathbf{I}) \quad (9)$$

この尤度の対数をとった対数尤度関数を最大化することで \mathbf{W} , $\boldsymbol{\mu}$, σ^2 のパラメータを求める。これには最尤推定、EMアルゴリズムなどの手法により行う。

上記は潜在変数 \mathbf{z}_i に関して周辺化を行った。同様に双対問題として、以下の事前分布で周辺化する。

$$p(\mathbf{W}) = \prod_{j=1}^D \mathcal{N}(\mathbf{w}_j | \mathbf{0}, \mathbf{I}) \quad (10)$$

それにより確率論的双対PCAとして取り扱うことができる。

$$p(\mathbf{Y} | \mathbf{Z}, \boldsymbol{\mu}, \sigma^2) = \prod_{j=1}^D \mathcal{N}(\mathbf{y}_{i,j} | \boldsymbol{\mu}, \mathbf{Z}^T \mathbf{Z} + \sigma^2 \mathbf{I}) \quad (11)$$

対数尤度関数に関して最急勾配法などにより最適化する。 $\sigma^2 = 0$ の極限においてはPCAとPPCAの結果は一致する。

上記確率論的PCAにおいても、潜在空間成分を \mathbf{w}_i に射影するため、線型的に直線上にしか動くことができない。そのため、より複雑な系を解析するためには非線形への拡張が望ましい。

2.3 カーネルPCA (KPCA)

決定論的手法において、非線形関数である特徴射影 Φ を用いて、データ空間 Ω から、より高次の特徴空間 \mathbb{H} に射影し、特徴空間でPCAを実施する。この時、特徴射影 Φ を陽に定義せず、カーネル関数を特徴空間における内積として捉えるカーネルトリックを用いることで計算を行う。データ行列 \mathbf{X} を特徴空間に射影すると $\Phi = \{\boldsymbol{\phi}(\mathbf{x}_1), \boldsymbol{\phi}(\mathbf{x}_2), \dots, \boldsymbol{\phi}(\mathbf{x}_{N-1}), \boldsymbol{\phi}(\mathbf{x}_N)\}$ 。これから平均をひき $\tilde{\boldsymbol{\phi}}(\mathbf{x}_i)$ を次のように定義する。

$$\tilde{\boldsymbol{\phi}}(\mathbf{x}_i) = \boldsymbol{\phi}(\mathbf{x}_i) - \frac{1}{N} \sum_{j=1}^N \boldsymbol{\phi}(\mathbf{x}_j) \quad (12)$$

ここで、PCAの場合と同様に、標本分散共分散行列 \mathbf{C} が以下のように定義される。

$$\mathbf{C} = \frac{1}{N} \sum_{i=1}^N \tilde{\Phi}(\mathbf{x}_i) \tilde{\Phi}(\mathbf{x}_i)^T \quad (13)$$

この共分散行列の直交固有分解を行うと、固有ベクトル（主軸単位ベクトル） \mathbf{v}_i は固有値 λ_i と以下の関係式を満たす。

$$\mathbf{C} \mathbf{v}_i = \frac{1}{N} \sum_{j=1}^N \tilde{\Phi}(\mathbf{x}_j) \tilde{\Phi}(\mathbf{x}_j)^T \mathbf{v}_i = \lambda_i \mathbf{v}_i \quad (14)$$

$\tilde{\Phi}(\mathbf{x}_i)$ が陽でないため \mathbf{C} が求まらない。主軸 \mathbf{v}_i を以下の形として定義して探索する。

$$\mathbf{v}_i = \sum_{j=1}^N a_{ij} \tilde{\Phi}(\mathbf{x}_j) \quad (15)$$

式(15)を式(14)に代入し、

$$\frac{1}{N} \sum_{j=1}^N \tilde{\Phi}(\mathbf{x}_j) \tilde{\Phi}(\mathbf{x}_j)^T \sum_{j=1}^N a_{ij} \tilde{\Phi}(\mathbf{x}_j) = \lambda_i \sum_{j=1}^N a_{ij} \tilde{\Phi}(\mathbf{x}_j) \quad (16)$$

要素 $\tilde{K}_{ij} = \tilde{\Phi}(\mathbf{x}_i)^T \tilde{\Phi}(\mathbf{x}_j)$ で定義されるグラム行列 $\tilde{\mathbf{K}}$ に式(12)を代入し、カーネルトリックにより、 $k(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)$ の内積の形で表されるカーネル関数によって表されるとすると、

$$\begin{aligned} \tilde{K}_{ij} &= k(\mathbf{x}_i, \mathbf{x}_j) - \frac{1}{N} \sum_{l=1}^N k(\mathbf{x}_l, \mathbf{x}_j) - \frac{1}{N} \sum_{l=1}^N k(\mathbf{x}_i, \mathbf{x}_l) \\ &\quad + \frac{1}{N^2} \sum_{l=1}^N \sum_{m=1}^N k(\mathbf{x}_l, \mathbf{x}_m) \end{aligned} \quad (17)$$

このグラム行列を用いると式(16)は以下ようになる。

$$\frac{1}{N} \tilde{\mathbf{K}} \mathbf{a}_i = \lambda_i \mathbf{a}_i \quad (18)$$

ここでは上記のグラム行列の固有値分解に帰着する。特徴射影 Φ を明確に定義せず、対称性および正定値性を満たしたカーネルを使用する。カーネルは例えば、以下のようなガウスカーネルが用いられる。

$$\begin{aligned} k(\mathbf{x}_n, \mathbf{x}_m) &= \theta_0 \exp \left\{ -\frac{\theta_1}{2} \|\mathbf{x}_n - \mathbf{x}_m\|^2 \right\} + \theta_2 \\ &\quad + \theta_3 \mathbf{x}_n^T \mathbf{x}_m \end{aligned} \quad (19)$$

以上のように高次元空間でPCAを実施し非線形な主成分を求める。

2.4 ガウス過程潜在変数モデル (GP-LVM)

ガウス過程潜在変数モデルは、上記のPPCAを拡張しガウス過程を組み込む。PPCAの双対問題により以下に示される \mathbf{W} の事前分布 $p(\mathbf{W})$ で周辺化する。

$$p(\mathbf{W}) = \prod_{j=1}^D \mathcal{N}(\mathbf{w}_j | \mathbf{0}, \alpha^{-1} \mathbf{I}) \quad (20)$$

ここでは、観測データ $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{N-1}, \mathbf{y}_N\}^T \in \mathbb{R}^{N \times M}$ 、潜在変数 $\mathbf{Z} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_{N-1}, \mathbf{z}_N\}^T \in \mathbb{R}^{N \times D}$ の転置行列で考える。 $p(\mathbf{W})$ をかけて積分して周辺化することで、尤度関数が得られる。

$$p(\mathbf{Y} | \mathbf{Z}, \beta) = \frac{1}{(2\pi)^{\frac{MN}{2}} |\mathbf{K}|^{\frac{M}{2}}} \exp \left(-\frac{1}{2} \text{tr}(\mathbf{K}^{-1} \mathbf{Y} \mathbf{Y}^T) \right) \quad (21)$$

ここでは、精度 $\beta^{-1} = \sigma^2$ で、 $\mathbf{K} = \alpha \mathbf{Z} \mathbf{Z}^T + \beta^{-1} \mathbf{I}$ である。これに相当する対数尤度関数は、

$$L = -\frac{MN}{2} \ln(2\pi) - \frac{M}{2} \ln(\mathbf{K}) - \frac{1}{2} \text{tr}(\mathbf{K}^{-1} \mathbf{Y} \mathbf{Y}^T) \quad (22)$$

\mathbf{K} のグラム行列に関して、式(19)のようなカーネル関数を用いて記述する。すなわち、潜在変数 \mathbf{Z} からガウス過程を用いて観測変数 \mathbf{Y} へ非線形射影を行う。この潜在変数 \mathbf{Z} およびカーネルに関するハイパーパラメータ θ を対数尤度関数が最大となるように学習させる。この学習に際して、一般的にPCAで得られた主成分を初期値として与える。PCAの場合においては、低次元化した際に、考慮していない主軸の固有値の和である歪み尺度 $J = \sum_{i=D+1}^M \lambda_i$ を最小化しているだけであり、低次元の主成分から高次元の観測変数へ再構築した時の誤差が大きい。一方で、GP-LVMにおいては、 D 次元の潜在変数 \mathbf{z}_i からガウス過程を用いて観測変数 \mathbf{y}_i に射影するため誤差が小さい。高次元データが低次元潜在変数に圧縮されている。この潜在空間における潜在変数の挙動を観察することで複雑な現象の挙動を把握することが可能である。

2.5 動的モード分解 (DMD)

データ行列 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N-1}, \mathbf{x}_N\} \in \mathbb{R}^{M \times N}$ に対して、1ステップ時間を進めたデータ $\mathbf{X}' = \{\mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_N, \mathbf{x}_{N+1}\} \in \mathbb{R}^{M \times N}$ を用意する。行列 \mathbf{A} を時間方向に線形射影すると、 $\mathbf{X}' = \mathbf{A} \mathbf{X}$ で表される。 \mathbf{A} は変換の二乗誤差が最小となるように定義される。 \mathbf{X} を特異値分解すると、 $\mathbf{X} \approx \mathbf{U} \mathbf{\Sigma} \mathbf{V}^*$ となる。 \mathbf{U} は主成分 (PODモード)、 $\mathbf{\Sigma}$ は対応する固有値を対角成分、 \mathbf{V}^* は時間変動成分とする行列である。以上より行列 \mathbf{A} は以下のように定義される。

$$\mathbf{A} = \mathbf{X}' \mathbf{V} \mathbf{\Sigma}^{-1} \mathbf{U}^* \quad (23)$$

計算を効率的に実施するため、 \mathbf{A} をPODモードに射影した $\tilde{\mathbf{A}}$ に対して固有値分解を実施する。

$$\tilde{\mathbf{A}} = \mathbf{U}^* \mathbf{A} \mathbf{U} = \mathbf{U}^* \mathbf{X}' \mathbf{V} \mathbf{\Sigma}^{-1} \quad (24)$$

$$\tilde{\mathbf{A}} \mathbf{W} = \mathbf{W} \mathbf{\Lambda} \quad (25)$$

ここでは \mathbf{W} は固有ベクトル行列であり、 $\mathbf{\Lambda}$ は固有値行列である。これらを用いると以下の行列が求まる。

$$\Phi = \mathbf{X}' \mathbf{V} \mathbf{\Sigma}^{-1} \mathbf{W} \quad (26)$$

Φ の列ベクトルがDMDモードである。 $\mathbf{b} = \Phi^\dagger \mathbf{x}_1$ とすると、

$$\mathbf{X} \approx (\Phi_1 \Phi_2 \dots) \begin{pmatrix} b_1 & 0 & \dots \\ 0 & b_2 & \dots \\ \vdots & \vdots & \ddots \end{pmatrix} \begin{pmatrix} 1 & \lambda_1 & \dots & \lambda_1^{N-1} \\ 1 & \lambda_2 & \dots & \lambda_2^{N-1} \\ \vdots & \vdots & \dots & \vdots \end{pmatrix} \quad (27)$$

DMDはデータドリブン解析手法であり、固有値 λ_i が複素数となり、各モードに固有な周波数をもつ。本稿では高速度カメラの画像に関して、ガボール変換を用いたDMD解析を実施することで、変動成分のスペクトログラムを求める。

2.6 自己組織化マップ (SOM)

SOMはKohonen^[3]らによって提案された大脳皮質の視野をモデル化したものであり、教師なし学習の一つで、ニューラルネットワークの一種である。高次元データを2次元などに射影し、容易に可視化および観察することが可能となる。本稿ではパラメータ毎の相関を D 次元で可視化した。 D 個のノードを2次元上に分布させ、可視化を行う。

ここでは観測変数 $\mathbf{Y}=\{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{N-1}, \mathbf{y}_N\} \in \mathbb{R}^{M \times N}$ はパラメータ数を M 次元とし、実験回数を N 次元とする。潜在変数を $\mathbf{Z}=\{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_{N-1}, \mathbf{z}_N\} \in \mathbb{R}^{D \times N}$ と定義する。潜在変数から観測変数への射影 \mathbf{f} を考える。潜在空間は可視化しやすいよう、2次元にまとめられることが多い。この時、潜在空間のノード点を $\zeta_k (= \mathbf{z}_k)$ とする。初期ノードの射影 $\mathbf{f}(\zeta_k)$ は本研究ではデータ行列に対してPCAを実施し、上位 D 個の固有ベクトルとした。

競合過程において、各観測データに対して、最も近い参照射影を持つ勝者ノード番号 k_i^* をすべての \mathbf{y}_i に対して求め、潜在変数 $\mathbf{z}_i = \zeta_{k_i^*}$ として推定する。

$$k_i^* = \underset{k}{\operatorname{argmin}} \|\mathbf{y}_i - \mathbf{f}(\zeta_k)\| \quad i = 1, \dots, N \quad (28)$$

次に協調過程において、各勝者ノードが近傍ノードに分配する学習量を $r_{i,k}$ とすると、

$$r_{ik} = \exp\left(-\frac{1}{2\sigma(n)^2}(\mathbf{z}_i - \zeta_k)^2\right) \quad (29)$$

$\sigma(n)$ は、例えば以下のように定義される^[4](τ は定数)。

$$\sigma(n) = \exp\left(-\frac{n}{\tau}\right) \quad (30)$$

n ステップにおける減衰パラメータで、ステップを重ねる毎に近傍に及ぼす影響を減衰させる。

$$\mathbf{f}(\zeta_k) = \frac{\sum_{i=1}^N r_{ik} \mathbf{y}_i}{\sum_{j=1}^N r_{jk}} \quad (31)$$

として射影を更新する。このプロセスを $n+1$ ステップに進み収束するまで繰り返す。

3. 解析対象

本稿では、JAXAで開発中の予冷ターボジェットエンジン (PCTJ)^[5]の過濃水素モデルアフターバーナーを用いて、東京大学の柏キャンパスにある高エンタルピー風洞において燃焼試験を実施した結果に対して低次元化解析を適用する。ラム燃焼器の燃焼不安定性は液体燃料において報告されているが^[6]、水素燃焼器に関しては限定的である。当量比が1.0から3.3程度まで燃焼試験を実施し、振動燃焼の発生を調べた。特に、当量比2.4の時、強い熱音響振動燃焼への遷移が確認された。本稿では当量比2.4の可視化画像に対して上記の低次元化を実施する。PCTJのクルージング時の当量比は2.2である。高速度カメラにより6000fpsで撮影した火炎の発光 (主にNaの発光) に対して解析を実施する。高速度カメラの画像は M ピクセルからなる M 次元データであり、これを D 次

元 (ここでは2次元あるいは3次元) の低次元空間において現象の変化を解析する。Fig. 2にPCTJエンジンの概略図^[5]およびFig. 3にモデルアフターバーナーでの燃焼の様子を示す。上流側の可視化窓の画像に対して計測を行った。Fig. 4に燃焼室内の圧力履歴およびウェーブレット変換により得られた圧力変動のスペクトログラムを示す。この系においては、最初インジェクターの渦放出に起因する2200Hz程度の周波数 (ここでは渦モードとする) が観察され、3.5から4秒あたりから基本周波数を560Hz程度とする熱音響振動モードと高次成分が強く励起されたり弱められた後、最終的には熱音響振動燃焼モードのリミットサイクルに入ることが圧力のスペクトログラムからわかる。この4.400秒から4.567秒の遷移挙動を、1000枚の画像に対して低次元化して解析し画像データからどのような燃焼状態にあるかを解析した。




Fig. 2 Schematic of PCTJ sub-scale engine^[5].




Fig. 3 Combustion behavior of model after burner.




Fig. 4 Pressure history and spectrogram obtained by wavelet transform.

4. 解析結果

4.1 燃焼不安定性発生時の自己組織化マップ

最初にどのような条件で燃焼不安定性が発現するのかを観察するため、実験条件のパラメータ毎の相関を2次元マップ上で自己組織化マップにより可視化した。当量比、水素噴射圧、流入空気圧力、燃焼圧力、断熱火炎温度、インジェクターにおけるチョークの有無 (1 or 0)、振動の有無 (1 or 0) に対して解析を行った。当量比が

1.0から3.3まで変化させて実験を行った際のパラメータを用いた。Fig. 5に結果を示す。上記のパラメータ以外にU-matrixを示す。自己組織化マップの位置は二次元の潜在変数に相当し、潜在変数から観察空間に写像される。あらゆる観察データの射影が学習され、その参照点近傍にその影響を及ぼすよう色付けされる。近い状態のデータは参照点近傍に射影される。結果、各々のパラメータに対して、二次元平面上の座標が対応する。そのため、同じ座標領域の値を比較することで、パラメータの相関を見ることができる。自己組織化マップにおいては、二次元平面上における距離は線形ではない。SOMにおいて、観察空間から潜在空間への縮尺は異なる。データ数密度の高い領域は拡大され、低い領域は縮小される。これを表す指標としてU-matrixがある。U-Matrixにおいて数密度が高い領域は青色で示され、低い領域は赤色で示される。地形図のように解釈され、数密度が高い領域は平野に相当し、低い領域は山脈に相当する。平野部の距離が近い方がより近く、山脈を挟むと隔てられていると解釈される。




Fig. 5 Self organization map for experimental conditions and combustion oscillation index.

この結果から見ると、燃焼不安定性は当量比が1.0付近を除いて観察される。当量比、断熱火炎温度および水素噴射圧に相関があると考えられる。噴射器においてチョークしているかどうかについてはあまり相関がなく、変動に起因した燃料噴射量のカップリングがここではあまり影響していないと考えられる。

4.2 当量比2.4における動的モード分解結果

本稿ではガボルフイルタを用いたDMDを実施し、初期値bを用いて画像に内在する周波数成分のスペクトログラムを求めた。その結果をFig. 6に示す。圧力のスペクトログラムと同様に、2200Hzの渦モードが支配的であることがわかる。一方で、圧力変動で観察されていた560Hz程度の熱音響振動の第1モードは観察されない。概ね3.7秒において熱音響振動モードが励起され始めることがわかる。その後4.5秒程度で渦モードから熱音響振動モードに遷移しリミットサイクルに入ると考えられる。これらの遷移から、最初、渦モードの発熱振動が、熱音響振動燃焼の第4高調成分を励起し、熱音響振動燃焼に遷移したと考えられる。





Fig. 6 Spectrogram of flame emission obtained by Gabor-filtered DMD.


Fig. 4の圧力履歴のウェーブレット解析結果と比較すると、火炎発光画像からも概ね同じ情報が得られていると考えられる。一方で、火炎発光の場合においては、より整数倍のモードが明確に捉えられていることがわかる。高速度カメラデータを用いたデータドリブン手法である動的モード分解結果においても、概ね2200Hz程度の渦モードが熱音響振動モードの4倍波成分を励起し、基本波から整数倍波成分の熱音響振動が引き起こされたことがわかる。

4.3 燃焼画像の主成分分析を用いた低次元化

圧力履歴および火炎発光画像のスペクトログラムにおいて、4.400秒から4.567秒の間に渦モードから強い熱音響モードへの遷移が確認された。この期間の画像データに対してPCAおよびKPCAにより解析を実施した。PPCAに関しては σ^2 の大きさにより絶対値は異なるもののPCAと挙動と同じであるため省略する。これらは高次元空間でのダイナミクスが低次元へ圧縮され、そのダイナミクスが軌道アトラクタによって示される。低次元空間に主成分の挙動（軌道）から、現象がどのように変化しているかわかる。2次元で挙動を可視化するのは視覚的に観察しやすいが、現象が複雑な場合それらの主軸に垂直な方向に変化している場合も多々あり、2次元への射影では捉えられない。そのため、3次元の解析も同時に行った。基本的に、周期的に同じ変化をしている場合には、同じ軌道上を変化することになる。Fig. 7にPCAにより2次元の主成分、3次元の主成分の時間変化を示した結果を示す。図中のプロットの色は時間を表す。2次元の結果に着目すると、時間が経過するにつれて渦モードから熱音響モードへ遷移していくのがわかる。渦モードの場合は周波数が2200Hzと高速のため、細かく捉えられないもののジグザグ状に動きながら、右下の方に収束していくのがわかる。これを第3主成分まで考慮してプロットしてみると、より挙動が鮮明にわかる。最終的にはアトラクタはジグザグ状の軌道から円軌道に入り重なっていくのがわかる。徐々に熱音響振動モードのリミットサイクルに入る様子がわかる。




(a) First two principal components




(b) First three principal components

Fig. 7 Visualization of flame-emission data obtained by projecting principal components of PCA.



(a) First two principal components



(b) First three principal components

Fig. 8 Visualization of flame-emission data obtained by projecting principal components of KPCA.


同様の解析をKPCAにより行った。本稿では $\sigma=10$ の場合の結果をFig. 8に示す。本稿ではカーネル関数として以下の式を用いた。

$$k(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{(\mathbf{x} - \mathbf{y})^2}{\sigma^2}\right) \quad (32)$$


σ が小さくすぎると、主成分が線状に分布し、データの重なりが多くなる。逆に大きくしすぎるとPCAの結果に近づく。KPCAとPCAに着目すると、データのばらつきが抑制されより明確に遷移の様子を観察することができる。2次元で潰れているものの、リミットサイクル挙動が2次元においても明確に観察される。3成分まで観察するとアトラクタは円軌道を描いてリミットサイクルに入る様子が明確に観察される。これらの主成分の挙動により燃焼状態がどのような状態で振動燃焼モードが変化していくかを観察することができる。

4.4 燃焼画像のガウス過程潜在変数モデル (GP-LVM) を用いた低次元化

次にGP-LVMを用いて2次元および3次元への潜在空間への低次元化を行った。Fig. 9にその結果を示す。2次元の場合に着目すると遷移の挙動に着目すると、PCAと比較するとより渦モードから熱音響モードへの遷移において、軌道が大きく変化する様子を観察することができる。プロットの分布が広がっている。しかしながら、この場合もプロットが固まっておらず、リミットサ



(a) Two dimensional latent variables



(b) Three dimensional latent variables

Fig. 9 Visualization of latent variables obtained by GP-LVM.

イクルに入る前と後の状態は把握できるものの、それほど明確に分類されているわけではない。

潜在空間の次元を3次元にした場合の結果に着目すると、挙動が大きく変化されており、状態がよく分類されていることがわかる。渦モードから熱音響モードおよびその遷移を示すデータ点が潜在空間内で明確に分かれており、そのアトラクタの挙動も異なる。最終的には潜在空間において円状に回転しており平衡軌道となり、熱音響モードのリミットサイクルに入ることがわかる。ここでは示さないが、より高周波測定を実施した際に、より明確に渦モードと熱音響モードの軌道の差異が得られている。PCAやKPCAと比較して、データがより明確に分離されている。PCAの場合においては、考慮していない主成分の固有値成分の和が歪み度となり、これらが大きいと元データを再現しているとは言えない。GP-LVMは潜在空間と観測空間をガウス過程で射影するため、精度良く状態およびその遷移の挙動を把握することが可能である。このような低次元空間で挙動を判別することで振動燃焼の検知や状態の把握が可能となる。

5. まとめ

データドリブン手法により高次元データを低次元化して帰納的に解析する手法について説明した。圧力センサーで測定された燃焼振動は、高次元の火炎画像データに対して動的モード分解を実施することで捉えることができる。また、自己組織化マップにより、振動が発生時のパラメータを可視化することができる。高速度カメラによって撮影された火炎発光挙動から渦モードから熱音響モードへの遷移状態をデータドリブン手法により調べた、PCAによる低次元化においてはその挙動を力学系のアトラクタとして可視化することができる。KPCAによりそれらの状態が明確にすることが可能である。一方でKPCAではハイパーパラメータを自身で調整する必要がある。また、PCAおよびKPCAは主成分を抽出しているため、考慮していない高次元成分の影響を無視することができない。そのため、PCAと同様の低次元空間を潜在空間とし、潜在空間と観察空間の射影をガウス過程とし、潜在変数とカーネル関数のハイパーパラメータを学習させることで、より明確に状態を分離することができる。また、潜在変数のアトラクタから状態の把握に加え、観測変数へ射影し、高次元データを再現することが可能である。

謝辞

本稿の作成にあたり実験および解析にご助力頂いた、岡本敏樹氏、池田有空氏、尾身興一氏、吉原光太郎氏に謝意を表す。

参考文献

- (1) Lieuwen, T. C. and Yang, V., *Combustion Instabilities In Gas Turbine Engines: Operational Experience, Fundamental Mechanisms, and Modeling* (2015), AIAA.
- (2) Huang, Y., and Yang, V., *Dynamics and Stability of Lean-Premixed Swirl-Stabilized Combustion*, *Progress in Energy and Combustion Science*, Vol. 35 (2009), pp. 293-364.
- (3) Dowling, A. P., and Mahmoudi, Y., *Combustion Noise*, *Proceedings of the Combustion Institute*, Vol. 35 (2015), pp. 65-100.
- (4) Rayleigh, J. W. S., *The Theory of Sound*, Vol. 2 (1986), Macmillan and Co.
- (5) Poinso, T., *Prediction and Control of Combustion Instabilities in Real Engines*, *Proceedings of the Combustion Institute*, Vol. 36 (2017), pp. 1-28.
- (6) Jolliffe, I. T., *Principal Component Analysis*, (2002), Springer.
- (7) Kutz, J. N., Brunton, S. L., Brunton, B. W. and Proctor, J. L., *Dynamic Mode Decomposition (Second ed.)*, (2016), SIAM.
- (8) 平邦彦, 固有直交分解による流体解析: 1. 基礎, *ながれ*, Vol. 30 (2011), pp. 115-123.
- (9) 平邦彦, 固有直交分解による流体解析: 2. 応用, *ながれ*, Vol. 30 (2011), pp. 263-271.
- (10) Schölkopf, B., Smola, A., and Müller, K.-R., *Nonlinear Component Analysis as a Kernel Eigenvalue Problem*, *Nural Computation*, Vol. 10 (5), (1998), pp. 1299-1319.
- (11) Tipping, M. E., and Bishop, C. M., *Probabilistic Principal Component Analysis*, *Journal of the Royal Statistical Society, Series B*, Vol. 21 (3), (1999), pp. 611-622.
- (12) Lawrence, N. D., *Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data*, *Proceedings of NIPS 16*, (2004).
- (13) T. Kohonen, *Self-organized formation of topologically correct feature maps*, *Biological Cybernetics* 43 (1) (1982) 59-69.
- (14) Haykin, S., *Neural Networks and Learning Machines (Third ed.)*, (2009), Pearson Education, Inc.
- (15) Taguchi, H., Harada, K., Kobayashi, H., Kojima, T., Hongoh, M., Masaki, D., Sawai, S. and Maru, Y., *Firing Test of a Hypersonic Turbojet Engine Installed on a Flight Test Vehicle*, *16th International Space Planes and Hypersonic Systems and Technologies Conference*, (2009), AIAA-2009-7311.
- (16) Culick, F. E. C., *Combustion Instabilities in Liquid-Fueled Propulsion Systems-an Overview*, *AGARD Conference Proceedings No.450*, (1989), NATO ASI Series Publication Coordination Office.

特集：エネルギー産業への機械学習の応用

推進工学への機械学習の適用

Application of Machine Learning to Propulsion Engineering

佐藤 哲也*¹

SATO Tetsuya

山本 姫子*¹

YAMAMOTO Himeko

樺山 昂生*¹

KABAYAMA Koki

辻村 光樹*¹

TSUJIMURA Hiroki

坂野 友香理*¹

SAKANO Yukari

キーワード：深層学習，ニューラルネットワーク，気液二相流，乱流燃焼，微粒化

Key Words：Deep Learning, Neural Network, Two Phase Flow, Turbulent Combustion, Atomization

1. 緒言

昨今注目を集める深層学習は，ニューラルネットワーク（NN: Neural Network）の発展形である。NNは機械学習の一手法で，生物の神経回路網を模倣した層状の人工モデルである。NNは，ある入力と出力の間の潜在的な関係を，大量の入力・出力のペアデータから学習し，モデル化する。入力・出力として用いられるものは適切に数値化さえできればどのようなものでも良いという特性から，様々な回帰・分類タスクに用いられている。

NNの層数を増やし，モデルの表現力を高めた深層学習は，NNと比べモデル性能が飛躍的に向上したことから注目を浴びたが，その本質的な強みは，データが大量にあり，それを適切に数値化さえできればあらゆる分野に適用可能であるという点にある。本稿では，当研究室で取り組む研究課題にNNや深層学習を適用した3つの事例を紹介する。

2. 気液二相流への機械学習の適用事例

2.1 二相流の流動様式判別

ロケットや将来型極超音速機の燃料として用いられる液体水素や液体酸素等の極低温流体は，沸点が低く，燃料配管予冷時やエンジン始動時のように配管温度が十分低温になっていない場合，配管内で容易に気化し，気体と液体の混ざった気液二相流となる。

気液二相流における気体と液体の分布を，その外見から気泡流，層状流等パターン分けしたものを流動様式という。気液二相流においては流動様式が時々刻々と変化し，それに伴って圧力損失特性や熱伝達係数などの熱流動特性も変動する。熱流動特性は燃料流動制御に不可欠なパラメータであるため，流動様式が常に変化し続ける気液二相流の特性はエンジンの動作安定性を妨げる一因となっている。したがって，気液二相流の流動様式をリアルタイムでとらえ，配管内の流動状態を詳しく把握できるような技術が必要とされている。

そこで著者らは，深層学習が画像判別において優れた

性能を発揮することに着目し，深層学習を用いた流動様式の自動判別を目指している⁽¹⁾。現在は，その前段階として，Fig. 1に示すように気液二相流の流動画像を入力するとその画像がどのような気液流量条件における流動であるかを自動判別する深層学習モデルを研究している。




Fig. 1 Deep learning model

2.2 研究手法

2.2.1 流動画像取得実験 深層学習を利用する際，学習のために大量のデータ（画像やセンサーデータなど）が必要である。そこで本研究では，Fig. 2に示すように，シリコンオイルと空気を作動流体とした水平管内流動実験を実施した⁽¹⁾。各流量が既知である2流体を合流させ，助走区間を経て流れが安定した段階で流動画像を撮影，実験後フレーム分割することで流動画像を取得した。撮影においては高速度カメラを使用し，420 fps，224×168 pxの撮影条件で各流量条件につき約25秒間（およそ10,000枚分）撮影した。これは，深層学習利用という観点から言えば1クラスにつき10,000枚の画像を取得したことに相当する。

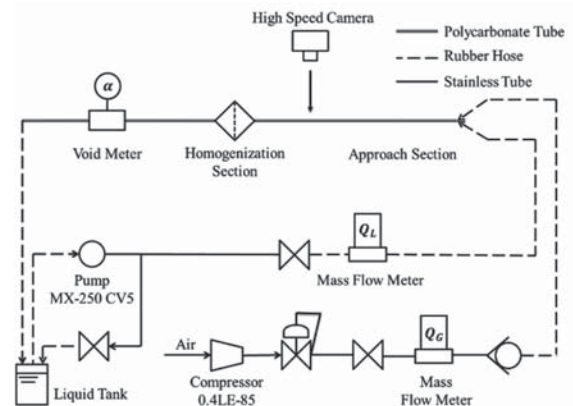


Fig. 2 Schematic diagram of the experiment set-up

原稿受付 2019年7月8日

* 1 早稲田大学 基幹理工学部

〒169-8555 新宿区大久保3-4-1

E-mail: sato.tetsuya@waseda.jp

気液流量条件については、液相流量 Q_l の2条件と気相流量 Q_g の10条件を組み合わせて、計20条件を設定した (Table 1)。また、流量条件の全く同じ実験の日を改めて5回行った。本稿では便宜上、最初の実験日に取得した流動画像データから順に、データ①, ②, ③, ④, ⑤とする。結果的に、本実験で取得した流動画像枚数はおよそ1,000,000枚となった。

Table 1 Flow rate conditions

Q_l L/min	Q_g L/min									
1	1	5	10	20	30	40	50	60	70	80
10	1	5	10	20	30	40	50	60	70	80

2.2.2 深層学習モデルの学習 前項のようにして得られた大量の流動画像データを用いて、深層学習モデルの学習を行った。本事例は画像の分類タスクであるため、まずは流動画像一枚一枚にラベル、すなわち分類先の名前を設定した。今回は気液流量条件がラベルであるため、例えば液相流量8 L/min, 気相流量20 L/min の条件時に撮影した流動画像には「L8G20」といったラベルを付けた。この操作によって得られる画像とラベルのペア一つが、今回の深層学習で用いるデータ一つとみなされ、このデータが沢山集まったものをデータセットと呼ぶ。

深層学習モデルの学習に際し、データに対してもう一つ行わなければならない操作が、データセットの分割である。多くの場合、元のデータセットを訓練データセット、検証データセット、テストデータセットの三つに分割する。訓練データセットによって深層学習モデル内のパラメータ最適化、すなわち学習を行い、学習後にテストデータセットを用いて最終的な性能を評価する。検証データセットは、学習の途中で学習がうまくいっているかどうかの確認や、人間側で設定する必要のあるハイパーパラメータの調整に用いるが、使用しない場合もある。つまり、深層学習モデルの学習に用いられるのは訓練データセットのみであり、検証データセットとテストデータセットは学習自体には影響しない。本事例では、検証データセットは用いず、訓練データセットとテストデータセットのみを用意した。

今回は、流動画像データ①から④までを組み合わせて訓練データセットを、⑤のみを用いてテストデータセットを作成した。訓練データセットの詳細をTable 2に示す。各データセットに含まれる流動画像は、実験で取得した全画像からランダムに選択した。例えばデータセットBでは、1クラスにつき①と②を合わせた約20,000枚の画像から、ランダムに2,000枚の画像を抽出している。なお、invertedと表記のあるものは画像の色を反転している。深層学習では元の画像と色を反転した画像は別物として扱われるため、色反転はデータ拡張 (Data Augmentation) の有効な手段の一つとなる。また、データセットF, Gではそれぞれ、気相流量が40 L/min

以上のデータセットと気相流量が30 L/min 以下のデータセットのみを用いているため、クラス数は10となっている。また、テストデータセットについては、⑤から1クラスにつき100枚の画像をランダムに抽出した。

ところで、上記のように訓練データセットとテストデータセットで用いるデータの実験日を分けたのは、得られたモデルの性能評価を正しく行うためである⁽¹⁾。例えば、①のデータで訓練したモデルは、①のデータでテストすればかなり高性能を示すが、②のデータでテストするとほとんど判別できない。そこで今回は、初めから実験日の異なるデータで訓練とテストを行うことで、より正確にモデルの性能を評価できるようにした。

Table 2 Details of training dataset

Name	Combination	Data / Class	Classes
A	①	2,000	20
B	①+②	2,000	20
C	①+②+③	2,000	20
D	①+②+③+④	2,000	20
E	①+②+③+④+(①+②+③+④) (inverted)	2,000	20
D9000	①+②+③+④	9,000	20
E9000	①+②+③+④+(①+②+③+④) (inverted)	9,000	20
E19000	①+②+③+④+(①+②+③+④) (inverted)	19,000	20
F	①+②+③+④+(①+②+③+④) (inverted) $Q_g \geq 40$ L/min	2,000	10
G	①+②+③+④+(①+②+③+④) (inverted) $Q_g \leq 30$ L/min	2,000	10

次に、用いる深層学習モデルを決定した。今回は画像の分類タスクであるため、画像判別に高い性能を示す畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を選択し、中でもSzegedyら⁽²⁾によって開発されたGoogLeNetを採用した。また、最適化手法はAdam⁽³⁾を採用し、初期学習係数は0.001とした。Adam内部のパラメータも含め、その他のハイパーパラメータは全てGoogLeNetのデフォルト値に設定した。

上記のデータセット、深層学習モデルに対する操作は、NVIDIA社が提供する深層学習用GUIであるNVIDIA DIGITSを用いて行った。

2.3 流動画像判別結果と考察

判別結果の概要をFig. 3に示す。ここで、accは深層学習モデルが出した答えの第1候補が正解であった率を、acc top5は深層学習モデルが出した答えの第5候補までに正解が含まれていた率を示す。

まず、AからDまでの結果を見ると、おおむね組み合わせるデータセットの種類が増えるに従って判別精度が向上していることが分かる。AとDの詳細な判別結果をヒートマップにしたものがFig. 4であるが、特に液相流量が小さい (L1) 側で判別結果が大幅に改善していることが分かる。なお、本ヒートマップでは列が正しい流量条件、行が深層学習モデルによる判別先を示している。

次に、EからE19000までの結果について分析する。こ




Fig. 3 Overview of classification results

A	L1G1	L1G5	L1G10	L1G20	L1G30	L1G40	L1G50	L1G60	L1G70	L1G80	L1G85	L1G90	L1G95	L1G100	L1G105	L1G110	L1G115	L1G120	L1G125	L1G130	L1G135	L1G140	L1G145	L1G150	L1G155	L1G160	L1G165	L1G170	L1G175	L1G180	L1G185	L1G190	L1G195	L1G200	Accuracy
L1G1	15	0	0	0	0	28	1	0	0	0	3	53	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	15.00%	
L1G5	0	0	0	0	0	0	0	0	0	0	0	95	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G10	0	0	0	0	0	0	0	0	0	0	0	41	0	59	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G20	0	0	0	0	3	0	0	0	0	0	0	2	95	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G30	0	0	0	0	0	0	1	0	0	0	0	0	0	0	88	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	52	48	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G50	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20	80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G60	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	94	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G70	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	92	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	35	0	0	0	65	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G85	41	0	0	0	12	4	0	0	0	0	0	3	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3.00%	
L1G95	3	0	0	1	1	0	0	0	0	0	0	88	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	88.00%	
L1G10	0	0	0	0	0	0	0	0	0	0	0	35	3	61	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3.00%	
L1G20	0	0	0	0	0	0	0	1	0	0	0	1	19	69	14	1	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	60.00%	
L1G30	0	0	0	0	0	0	0	0	0	0	0	0	41	35	0	1	0	23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	35.00%	
L1G40	0	0	0	0	0	0	0	0	0	0	0	0	15	1	1	51	17	11	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	51.00%	
L1G50	0	0	0	0	0	0	0	0	0	0	0	0	3	0	1	59	20	13	4	20	0	0	0	0	0	0	0	0	0	0	0	0	0	20.00%	
L1G60	0	0	0	0	0	0	0	0	0	0	0	0	0	0	27	30	27	0	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	27.00%	
L1G70	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	15	0	0	81	0	0	0	0	0	0	0	0	0	0	0	0	0	0	81.00%	
L1G80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	76	2	14	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	8.00%	

D	L1G1	L1G5	L1G10	L1G20	L1G30	L1G40	L1G50	L1G60	L1G70	L1G80	L1G85	L1G90	L1G95	L1G100	L1G105	L1G110	L1G115	L1G120	L1G125	L1G130	L1G135	L1G140	L1G145	L1G150	L1G155	L1G160	L1G165	L1G170	L1G175	L1G180	L1G185	L1G190	L1G195	L1G200	Accuracy
L1G1	98	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98.00%	
L1G5	0	79	21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	79.00%	
L1G10	0	31	66	1	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	66.00%	
L1G20	0	0	55	47	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	47.00%	
L1G30	0	0	0	57	41	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	41.00%	
L1G40	0	0	0	15	55	9	15	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9.00%	
L1G50	0	0	0	3	18	3	21	55	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21.00%	
L1G60	0	0	0	1	14	41	8	6	27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8.00%	
L1G70	0	0	0	0	7	30	13	19	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10.00%	
L1G80	0	0	0	0	0	5	94	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G85	0	0	0	0	0	0	0	0	0	0	73	27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	73.00%	
L1G95	0	0	0	0	0	0	0	0	0	0	0	69	11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	89.00%	
L1G10	0	0	0	0	0	0	0	0	0	0	0	9	77	4	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	77.00%	
L1G20	0	0	0	0	0	0	0	0	0	0	0	0	7	74	8	11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	74.00%	
L1G30	0	0	0	0	0	0	0	0	0	0	0	2	9	83	0	1	0	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	83.00%	
L1G40	0	0	0	0	0	0	0	0	0	0	0	0	20	8	67	1	0	4	67	0	0	0	0	0	0	0	0	0	0	0	0	0	0	67.00%	
L1G50	0	0	0	0	0	0	0	0	0	0	0	0	6	31	56	1	0	5	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.00%	
L1G60	0	0	0	0	0	0	0	0	0	0	0	1	0	48	30	4	0	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.00%	
L1G70	0	0	0	0	0	0	0	0	0	0	0	0	1	4	41	24	0	22	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22.00%	
L1G80	0	0	0	0	0	0	0	0	0	0	0	0	1	33	35	0	0	25	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6.00%	

Fig. 4 Classification results of dataset A and dataset D. Top: dataset A, Bottom: dataset D

これらの訓練データセットとDとの違いはデータ数や画像を色反転しているかどうかである。深層学習では、多くの場合データ数の増量や色反転によるデータ拡張によって性能改善が期待できるが、今回の結果ではあまり違いは見られなかった。

ところで、Fig. 4より気相流量が低い場合は比較的精度よく判別できているのに対し、高い場合は判別精度が低い傾向がみられる。そこで、若干恣意的ではあるが、

高流量側のデータのみから作成したデータセットFと、低流量側のデータのみから作成したデータセットGを用いて学習を行ったところ、低流量側での判別は77.2%と高い結果が得られた。実際の画像を見ても、低流量側では気泡流から環状流まで多彩な流動様式が観察されるのに対し、高流量側ではほとんどが環状噴霧流となっており、外見様式からの判別は困難と考えられる。

以上、気液二相流への機械学習の適用可能性を示せたものの、データ拡張等で効果が見られなかったことなど、結果は著者らの意図しないものも多く、性能改善手法の更なる模索が課題である。今後の展望としては、流動パターンの時間遷移情報を取り扱うことのできる再帰型ニューラルネットワーク (RNN: Recurrent Neural Network) の利用などを検討している。

3. 燃焼数値解析におけるNN適用事例

3.1 Tabulated ChemistryとNN

膨大な資金や時間をかけた燃焼試験による燃焼器開発を効率化するため、実用的な燃焼数値解析技術の利用が必要不可欠である。しかし、古典的な燃焼数値解析手法では膨大な数の化学種の移流や反応を追うため、輸送方程式数の増加や化学反応方程式の硬直性により計算時間が膨大となる。このような背景から、化学反応の再現に必要な熱化学量のテーブルを事前に作成し、数値計算に活用することで計算負荷を大幅に削減する、Tabulated Chemistryと呼ばれる数々の計算手法が提案されてきた。一方、Tabulated Chemistryでは熱化学量テーブルのメモリ使用量の増加が大きな課題である。複雑な燃焼現象に対するテーブルの次元の増加や、並列計算で分割した各計算領域がテーブルの情報を有することで、メモリ使用量は著しく増加し計算が困難となる。近年ではこの課題を解決する有望な技術としてNNの活用が期待されている⁽⁴⁾。本章ではTabulated Chemistryの一つであるlaminar flamelet modelに着目し、その拡張モデルである圧縮性flameletモデル⁽⁵⁾へのNN適用に関する取り組みを紹介する。

3.2 laminar flamelet model

laminar flamelet modelでは一次元層流対向流拡散火炎の詳細解析から事前作成した熱化学量テーブル (flameletテーブル) を用い乱流火炎を効率良く再現する。一般的に、燃焼数値解析では計算時間削減のため低マッハ数近似を用いることが多く、これに基づく典型的なlaminar flamelet modelでは、数値解析から得た流れ場の特徴量 (混合分率 ξ , スカラー消散率 χ) を入力変数として、対応する反応の特徴量 (密度, 温度) をテーブルの出力変数として取得し、状態方程式から圧力を算出する。

一方、近年ではテーブルの入力変数に反応進行度を選び消炎や再着火を再現するflamelet progress-variable approachや、低マッハ数近似を用いずエネルギー輸送

方程式を解き、かつ出力変数に化学種質量分率を選ぶことで反応性流体の圧力伝播を高精度に再現する圧縮性flameletモデルなど、複雑な燃焼形態に対応する様々な拡張モデルが提案されている。しかし、これらの拡張モデルではテーブルの入出力変数の次元が増加するため、前述したメモリ使用量の問題が顕在化する。著者らは特にテーブルの大規模化が顕著である圧縮性flameletモデルへのNNの活用に取り組み成果を得ている⁽⁶⁾⁻⁽⁸⁾。

3.3 圧縮性flameletモデル

圧縮性flameletモデルでは、flameletテーブルから得る各化学種質量分率から算出する内部エネルギーが、エネルギー輸送方程式を満たすように、温度や圧力を反復法により陰的に算出する。従来のlaminar flamelet modelでは圧力として熱力学的圧力のみを扱うが、圧縮性flameletモデルでは動力学的圧力の影響まで考慮した圧力値を算出するため、燃焼器内に衝撃波の生じるスクラムジェットエンジンや時間的・空間的に正確な圧力伝播の再現を必要とする燃焼振動の解析などへの活用が期待されている。

LES解析における一般的な圧縮性flameletモデルのflameletテーブル作成手順を説明する。まず、一次元層流対向流拡散火炎の詳細計算を様々な流れ条件に対して行い、混合分率 ξ とスカラー消散率 χ に対応する各化学種質量分率 Y_i を得る。続いて、混合分率のSGS変動成分 $\tilde{\xi}''$ について確率密度関数による数値積分を行い、空間フィルタ後の化学種質量分率 \tilde{Y}_i を算出する。以上の手順⁽⁶⁾により、最終的に $\tilde{\xi}$ 、 $\tilde{\chi}$ 、 $\tilde{\xi}''$ を入力変数として、 \tilde{Y}_i を出力変数とするflameletテーブルを作成する。ここで、反応を構成する各化学種に応じて増加する圧縮性flameletモデルのflameletテーブルを、NNの非線形関数で近似することで数値解析に用いるテーブルのメモリ使用量を大幅に低減することができる。燃焼反応の再現に要する化学種数は水素-空気反応モデルにおいては5~10程度、炭化水素燃料-空気反応モデルでは数十~数百程度になるため、NNによるメモリ使用量低減には大きな意義がある。

3.4 圧縮性flameletモデルへのNN適用

圧縮性flameletモデルに対するNN適用の具体的手順を説明する。まず、NNの非線形関数でflameletテーブルを近似することにより、流れ場の特徴量からなる入力ベクトル($\vec{u}=[\tilde{\xi}, \tilde{\chi}, \tilde{\xi}'']^T$)と反応の特徴量からなる出力($f(\vec{u})=\tilde{Y}_i$)を結びつけることができる。隠れ層を3層、重みを w 、バイアスを b 、活性化関数を g とすると、NNの非線形関数は式(1)と表すことができる。

$$f(\vec{u}) = g_4[\overline{w}_4 g_3\{\overline{w}_3 g_2(\overline{w}_2 g_1(\overline{w}_1 g_0 \vec{u} + \overline{b}_1) + \overline{b}_2) + \overline{b}_3\} + \overline{b}_4] \quad (1)$$

FlameMaster⁽⁹⁾による水素-空気反応モデル(9化学種、19段階反応)の一次元層流対向流拡散火炎の詳細解析と確率密度関数による数値積分から作成したflameletテーブルの各化学種質量分率に対し、作成したNNの例

(OH質量分率)をFig. 5に示す。NNには式(1)と同じ構成のものを用いた。隠れ層のニューロン数はいずれも10とする。入力層と隠れ層の活性化関数にはソフトサイン関数($g_i(n)=n/(1+|n|)$, $i=0,1,2,3$)、出力層の活性化関数には線形伝達関数($g_4(n)=n$)を設定した。Fig. 5にNNにより作成したflameletテーブルの曲面を示す。Fig. 5のプロットはNNの訓練に使用した一次元層流対向流拡散火炎の解を表す。Fig. 5より、量論比近傍で急激な変化を示す中間生成物(OH)であっても曲面が精度よく近似できていることがわかる。




Fig. 5 Flamelet table of \tilde{Y}_{OH} created by NN ($\tilde{\xi}''=0$)

これらの化学種質量分率を出力するNNの訓練にはMATLABを用い、130650種類のデータ($\tilde{\xi} \times \tilde{\chi} \times \tilde{\xi}''$: $201 \times 50 \times 13$)にLevenberg-Marquardt法を適用し、重み w とバイアス b の調整を行った。ここで、NNによる近似の利点について述べる。まず、従来のflameletモデルではテーブルから線形補間により値を呼び出すが、NNでは滑らかな連続関数でデータを表現することで近似精度の向上が期待できる。また、NNでは重みとバイアスの係数行列の情報のみで応答曲面を表現するため、メモリ使用量が大幅に低減される。従来のflameletテーブルとしてNNの訓練に用いた130650種類のデータセットを仮定し、この線形補間に要するメモリ使用量を算出すると約75.3 MBとなる。これに対し、全化学種のNNの重みとバイアスのメモリ使用量を合計すると約0.0195 MBとなる。さらに、従来のflameletモデルではテーブルの次元の増加に比例してメモリ使用量が増加するが、NNではメモリ使用量の増加率は小さく、類似のデータの増加に対しては隠れ層数やニューロン数を変えることなく対応できる場合も多い。

また、従来のTabulated ChemistryのNN活用事例では、シグモイド関数($g(n)=1/(1+\exp(-n))$)や双曲線正接関数($g(n)=\tanh(n)$)など計算負荷の高い活性化関数を用いることによる計算速度の低下もみられたが、近年ではソフトサイン関数やReLU (Rectified Linear Unit; $g(n)=\max(0, n)$)などの新しい活性化関数の提案により、これらの問題も解決されつつある。線形補間を用いる従来のテーブルでは、数値解析から得た入力変数に対応するデータを二分探索などで呼び出す時間があることを踏まえると、NNの活用により全体的な計算速度の向上も期待できる。参考として、線形補間およびNN

によるflameletテーブルを用い、スクラムジェットエンジン試験燃焼器 (Fig. 6) のLES解析により得た温度分布をFig. 7に示す。計算条件や定式化の詳細は文献⁽⁶⁾に基づく。同文献で著者らが提案した圧縮性flameletモデルの新しいflameletテーブルに対し、各熱化学量をNN (隠れ層の活性化関数には双曲線正接関数を設定) で算出している。Fig. 7(i)(ii)の温度分布はほぼ一致しており、flameletテーブルにNNを用いる場合には従来手法と同程度の計算結果がより高い計算性能で得られるといえる。




Fig. 6 Overview of DLR scramjet test-engine combustor




Fig. 7 Time-averaged temperature distribution

4. 粒子法を用いた燃料の微粒化解析への適用事例

4.1 格子・粒子ハイブリッド解析へのニーズ

微粒化は液体燃料の噴射だけでなく、塗装、農業散布、3Dプリンタ等、様々な産業分野に使用されており、数値解析による現象解明が期待されている。VOF法やレベルセット法を用いた格子法による計算が主流だが、微粒化で生じる格子幅よりも小さな液滴の変形や分裂は解像できない。さらに微粒化では、液滴は方々に飛散する。その全てを追跡するには、全解析領域に高解像度の格子を張り巡らすこととなり、計算コストは膨大となる。

そこで本研究では、格子法では対応しきれない微小液滴の変形を粒子法で解析する「格子・粒子ハイブリッド解析」の開発に取り組んでいる。粒子法とは、流体をオイラー格子ではなくラグランジュ粒子で離散化し、ナビエ・ストークス方程式を解く手法である。ハイブリッド解析のメリットは、格子幅以下の液滴であっても、流体の運動方程式に従った変形を解析できること、そして粒子法がラグランジュ型解法であることから、液滴内が常に微小粒子で離散化された状況を作り出せることにある。いわば、詳細に解析したい液滴内にも「格子を寄

せる」ことを、自動的かつ簡便に行える手法である。

4.2 液滴に対する空気力のモデル化

ハイブリッド解析では、気流を格子法、液滴を粒子法で解析するため、その相互作用を考慮する必要がある。著者らは、気流が液滴に与える力学的作用のモデル化 (空気力モデル/Aerodynamic Force Model) に取り組んできた^{(10),(11)}。そのコンセプトをFig. 8に示す。各表面粒子において、格子法で得られる気流の密度 ρ_g および液滴との相対速度 \vec{u}_{gl} と、表面の法線ベクトル \hat{n} とから、液滴表面が受ける圧力 P を算出し、表面粒子に与える。この圧力を、一様気流中に置かれた円柱まわりの圧力分布を模擬して、上流側は円柱まわりのポテンシャル流れの圧力 $C_p = 1 - 4\sin^2 \theta$ 、下流側は一定値 $C_p = -4/3$ とした (Fig. 9)。角度は $\theta = \cos^{-1}(\vec{u}_{gl} \cdot \hat{n} / |\vec{u}_{gl}|)$ より求める。モデルの妥当性評価として、液滴変形 (droplet breakup) の解析を行い (Fig. 10)、いくつかのウェーバー数において、格子法 (VOF法) を用いた数値解析や実験的研究の結果と近い変形を得ることができた。

空気力モデルの特長は、空気力 P を表面粒子近傍の局所的な情報 $\rho_g, \vec{u}_{gl}, \hat{n}$ のみから算出できる簡便なモデルである点にある。そのため、本手法を既存の計算コードに導入することは比較的容易であり、多方面への展開が期待される。一方で、液滴が如何なる形状であっても、本モデルでは円形を仮定した圧力分布を与えるため、液滴が変形すると、実際の液滴表面にかかるべき圧力との




Fig. 8 Concept of the grid-particle hybrid analysis technique and the Aerodynamic Force Model (AFM).




Fig. 9 Pressure distribution along the surface of a circular droplet (cylinder) exposed to uniform airflow.




Fig. 10 Result of a numerical analysis of droplet breakup using the AFM. Air flows from the left.

間に大きな乖離が生じてしまうことが課題であった。

4.3 任意形状液滴に対応するための機械学習の適用

変形した任意形状の液滴にも正確な空気力を与えるためには、形状も入力変数となる。また、ポテンシャル流れよりも、粘性や時間変化を考慮した流れ場からの圧力を与える方が望ましい。しかし、多様な形状の液滴一つ一つに対し、表面上の圧力分布を時間ステップの度に演繹的に算出することは、計算コストの上で現実的ではない。そこで本研究では機械学習の活用を試みている。機械学習モデルには、様々な液滴形状とそれに対応する圧力分布を学習させておく。そして微粒化解析において、発生する液滴の形状を読み取り、液滴表面に与えるべき圧力値を出力する回帰タスクを行わせる。

まずは実現可能性を検討するため、ランダムに生成した形状について、パネル法を用いて低コストに算出できるポテンシャル流れの圧力分布を学習データとする機械学習モデルを作成した。形状データは、粒子法の表面粒子を想定した100の離散点列で表したのち、 x, y 座標値それぞれに対して離散フーリエ変換を実施し、実部・虚部それぞれのフーリエ係数に対して主成分分析を施して第10主成分までを採用することで、計40値にまで縮約した。圧力分布データは全ての離散点に対する100値とした。モデル作成には深層学習用フレームワークKerasを使用し、5層のネットワークを用いて学習させた。最適化手法はAdamとし、初期学習係数は0.0001とした。誤差関数には二乗誤差平均を、活性化関数には等価関数を用いた。Fig. 11にテストに用いた形状と出力された圧力分布を示す。従来の空気力モデルでは捉えることのできない液滴側部での負圧も再現できる機械学習モデルを作成することができた（下流側では空気力モデルは一定




Fig. 11 Pressure distribution on the surface of the droplet shown on the lower left of this figure.

値を与えるため、ポテンシャル流れとの比較はできないことに注意)。今後は、学習に用いる形状を液滴として生じる形状に絞ってモデルの高精度化を図るとともに、各形状に対して粘性を考慮した非定常数値解析を行い、得られる圧力分布を学習させることで、より妥当な圧力分布を評価できる機械学習モデルの開発を目指す。

5. 結言

本稿では、機械学習を実験および数値解析に適用した事例を紹介した。最近では、機械学習はパッケージ化されたツールとして、情報工学に精通していなくても比較的簡単に利用でき、新しい計測、解析手法の創出に繋がっている。一方、中身がブラックボックスであることから、結果の妥当性検証や思わぬ結果が得られた時の対処方法が課題となり、そこに使用する研究者の創意工夫が活かされると考える。

参考文献

- (1) 樺山昂生他, 深層学習による気液二相流の流動様式判別に関する研究, 平成29年度宇宙輸送シンポジウム講演集録, STCP-2017-029 (2018).
- (2) Szegedy, C. et al., Going Deeper With Convolutions, IEEE Conf. Comp. Vision Pattern Recognition (CVPR), (2014).
- (3) Kingma, D. and Ba, J., Adam: A Method for Stochastic Optimization. arXiv:1412.6980 [cs], (2014).
- (4) Ihme, M., Schmitt, C., and Pitsch, H., Optimal Artificial Neural Networks and Tabulation Methods for Chemistry Representation in LES of a Bluff-body Swirl-stabilized Flame, Proc. Comb. Inst., Vol.32 (2009), pp. 1527-1535.
- (5) Oevermann, M., Numerical Investigation of Turbulent Hydrogen Combustion in a SCRAMJET Using Flamelet Modeling, Aerospace Sci. Tech., Vol.4 (2000), pp. 463-480.
- (6) 山本姫子他, Artificial Neural Network (ANN) を用いた圧縮性Flameletモデルの改良, 航空宇宙技術, Vol.18 (2019), pp. 91-100.
- (7) Yamamoto, H. et al., Improvement of Compressible Flamelet Model Using Artificial Neural Network, Asian Joint Conf. Propulsion Power, Xiamen, China, 2018.
- (8) Toyonaga, R. et al., Evaluation of Compressible Flamelet Tabulation Method Using Artificial Neural Network, Asian Cong. Gas Turbines, Iwate, Japan, (2018).
- (9) Pitsch, H., FlameMaster, A C++ Computer Program for 0D Combustion and 1D Laminar Flame Calculations, RWTH Aachen, Germany, (1998).
- (10) 辻村光樹他, 粒子法を用いた液滴解析における空気力のモデル化, ながれ, Vol. 38, No. 2 (2019), pp. 105-113.
- (11) Tsujimura, H., Kubota, K., and Sato, T., Development of Aerodynamic Force Model Based on Potential Flow for Liquid Droplets Analyzed by Particle Method, 32nd Int. Symp. Space Tech. Sci., 2019-e-39 (2019).

Ni-Co基超合金の高温引張および クリープ特性に及ぼすBとZrの影響

The Effects of B and Zr on High-temperature Tensile and Creep Properties of Ni-Co base Superalloy

小林 信一*¹
KOBAYASHI Shinichi

伊達 正芳*¹
DATE Masayoshi

上野 友典*¹
UENO Tomonori

大野 丈博*¹
OHNO Takehiro

川岸 京子*²
KAWAGISHI Kyoko

ABSTRACT

The effects of boron and zirconium on tensile and creep properties in Ni-Co base superalloy (TMW*-4M3) were investigated. Tensile tests at 650 °C and creep tests at 725 °C /630MPa of TMW-4M3 containing various boron and zirconium concentrations were performed. The results showed that boron was found to have a larger effect than zirconium on the high-temperature properties of TMW-4M3. Tensile strength, ductility, creep resistance, and creep rupture ductility were improved effectively by increase of boron content. On the other hand, increase of zirconium content reduced creep rupture ductility although it improved tensile strength and creep resistance slightly. (*TMW is a trademark of National Institute for Materials Science registered in Japan.)

キーワード：タービンディスク，Ni-Co基，引張，クリープ，ボロン，ジルコニウム

Key words：Turbine disc, Ni-Co base, Tensile, Creep, Boron, Zirconium

1. はじめに

航空機エンジンや発電用ガスタービンの高効率化のためには、使用される部材の耐用温度を高めることが有効である。このため、タービン翼用Ni基超合金のみならず、それを支えるタービンディスクにおいても耐用温度の向上が望まれている。物質・材料研究機構（NIMS）では、鋳鍛造（C&W: Cast & Wrought）プロセスにて製造可能な高強度ディスク用鍛造合金として、Ni基超合金とCo基合金を融合させたNi-Co基超合金：TMW*合金⁽¹⁾⁻⁽⁸⁾を開発した（*TMWはNIMSの商標登録）。TMW合金の中では、TMW-2、-24、-4M3の3つの合金が実用合金として有望である^{(2),(5)-(8)}。これらはNi基超合金Alloy720Liよりも高い耐用温度を有するとともに、ton級インゴットから実規模ディスクが製造された実績⁽⁵⁾⁻⁽⁸⁾があり、今後の実用化が期待される。中でもTMW-4M3は、粉末冶金（P/M: Powder Metallurgy）材に匹敵す

る優れたクリープ強度を有する^{(7),(8)}。またTMW-4M3は溶体化処理温度の上昇に伴い、引張特性⁽⁹⁾やクリープ特性⁽⁸⁾が更に向上すると報告されている。

しかし、溶体化温度を向上させていくと結晶粒の過度な粗大化が生じて延性の低下を招く。従って、TMW-4M3の更なるクリープ特性向上のためには、既に微量添加されているC、BおよびZr量の最適化が有望である。特にBおよびZrは、古くからNi基超合金のクリープ特性を向上させる元素として認識されており^{(10),(11)}、多くのNi基超合金⁽¹²⁾⁻⁽¹⁵⁾でその効果が確認されている。TMW-4M3においても、BもしくはZr量を増加させるとクリープ特性が向上することが示唆されている⁽¹⁶⁾。ただしこの報告⁽¹⁶⁾の化学組成は、すでに提案されている公称組成^{(5),(7)}に対して、BおよびZr量が共に高く、またTi量も僅かながら高いため、クリープ特性に及ぼすBとZrのそれぞれの影響が不明瞭である。従って、本研究ではTMW-4M3の公称組成^{(5),(7)}を基準とし、この組成に対してBおよびZr量をそれぞれ変化させた際の650°C高温引張特性および725°Cクリープ特性について調査した。

原稿受付 2018年8月31日

査読完了 2019年7月30日

*1 日立金属(株) 冶金研究所
〒692-0011 安来市安来町2107-2

*2 国立研究開発法人 物質・材料研究機構
〒305-0047 つくば市千現1-2-1

2. 実験方法

2.1 素材作製

TMW-4M3の公称組成^{(5),(7)}は, Bal.Ni, 25Co, 13.5Cr, 2.8Mo, 1.2W, 2.3Al, 6.2Ti, 0.015C, 0.015B, 0.03Zr (wt%)である。この公称組成に対し, 本研究ではBおよびZr量をそれぞれ0.008~0.030%および0.017~0.047%の範囲で調整した合金を作製した。また比較のため, 公称組成と同様の基本組成の合金も作製した。各合金の化学組成をTable 1に示す。基本組成合金はSTD材と称し, その他の合金はこのSTD材に対するBおよびZr量の違いから, Low B材, High B材, Low Zr材, High Zr材, High B+Zr材とそれぞれ称した。

これらの合金は小型の真空誘導炉を用いて約Φ80mmのインゴットとして得た。得られた各インゴットに対して均質化処理を施した後, 旋削加工を施してΦ65mm×130mmLの押出用素材を得た。押出用素材には管封止を施した後, 素材温度を1100℃に加熱してから熱間押出加工を実施した。この加熱温度1100℃はTMW-4M3の γ' 相固溶温度未満(γ' sub-solvus)の温度域である。熱間押出加工にて得た素材よりΦ14mm×60-70mmLの熱処理用素材を切り出し, 溶体化処理となる1135℃/4hの熱処理と, 時効処理となる650℃/24hおよび760℃/16hの熱処理を施した。溶体化温度は, TMW-4M3において硬さが最大化する γ' sub-solvus溶体化温度である⁽⁹⁾。時効条件は, Alloy720Liの標準的な2段時効条件を採用した。冷却方法はすべて空冷とし, 各素材の冷却速度が同一となるよう配慮した。溶体化処理後の冷却速度は, Φ14mmの測温用素材にて測定し, 溶体化温度1135℃から温度600℃までの間の平均冷却速度は244℃/minであった。

2.2 強度評価

時効処理を施した各素材を用いて, 引張試験とクリープ試験を実施した。引張試験は, ASTM E21を準拠し試験温度650℃にて実施した。引張試験片はΦ4mm×16mmGLの平滑試験片を用いた。引張試験速度は, 0.2%耐力値の取得までを0.5%/minとし, その後に伸び計を取り外して破断までをクロスヘッド速度で5%/minとした。クリープ試験は, ASTM E139を準拠し, 試験温度725℃, 試験応力630MPaにて実施した。クリープ試験片はΦ4mm×16mmGLのツバ付き試験片を用いた。

2.3 金属組織観察

時効処理を施した各素材を用いてマイクロ組織観察を実施した。各素材は全て鏡面研磨を施した後に, Kalling液(塩酸:100ml, メタノール:100ml, 塩化第二銅:5g)による腐食を行い, 光学顕微鏡によるマイクロ組織観察とASTM E112に基づく結晶粒度No.測定を行った。また引張破断後の試験片については, 実体顕微鏡および走査型電子顕微鏡(SEM: Scanning Electron Microscope)を用いて破面観察を行った。

3. 実験結果および考察

3.1 金属組織観察結果

Fig. 1に代表としてSTD材のマイクロ組織写真を示す。Fig. 1よりSTD材のマイクロ組織は, 1次 γ' 相によって結晶粒界がピン止めされた微細な再結晶組織であることを確認した。また他のBおよびZr量が異なる各合金も, STD材と同様, 1次 γ' 相によって結晶粒界がピン止めされたマイクロ組織であった。Table 1に示す通り, 各合金の結晶粒度No.は10.5~11.0であった。




Fig. 1 Typical microstructure of TMW-4M3 STD (B:0.015%, Zr:0.029%) after heat-treatment

3.2 650℃引張特性

Fig. 2 (a)にB量の異なるLow B材, STD材およびHigh B材の応力-変位曲線を, Fig. 2 (b)にZr量の異なるLow Zr材, STD材およびHigh Zr材の応力-変位曲線を, それぞれ示す。Fig. 2 (a)より, B量が高い合金ほど, 均一伸びは向上しており, これにより引張強さも向上していることが分かった。これに対してFig. 2 (b)より, Zr量が

Table 1 Chemical composition (wt%) and average grain size number (GSNo.) of TMW-4M3

Alloy	C	Ni	Cr	Co	Mo	W	Al	Ti	B	Zr	GSNo.
High B+Zr	0.017	Bal.	13.5	24.7	2.8	1.2	2.35	6.17	0.029	0.047	10.5
High Zr	0.015	Bal.	13.4	24.8	2.8	1.2	2.32	6.06	0.014	0.047	10.5
High B	0.016	Bal.	13.4	24.7	2.9	1.2	2.32	6.20	0.030	0.029	11.0
STD	0.015	Bal.	13.5	24.8	2.8	1.2	2.37	6.18	0.015	0.029	11.0
Low B	0.015	Bal.	13.5	24.8	2.8	1.2	2.36	6.12	0.008	0.028	11.0
Low Zr	0.017	Bal.	13.5	24.4	2.9	1.2	2.35	6.17	0.017	0.017	10.5

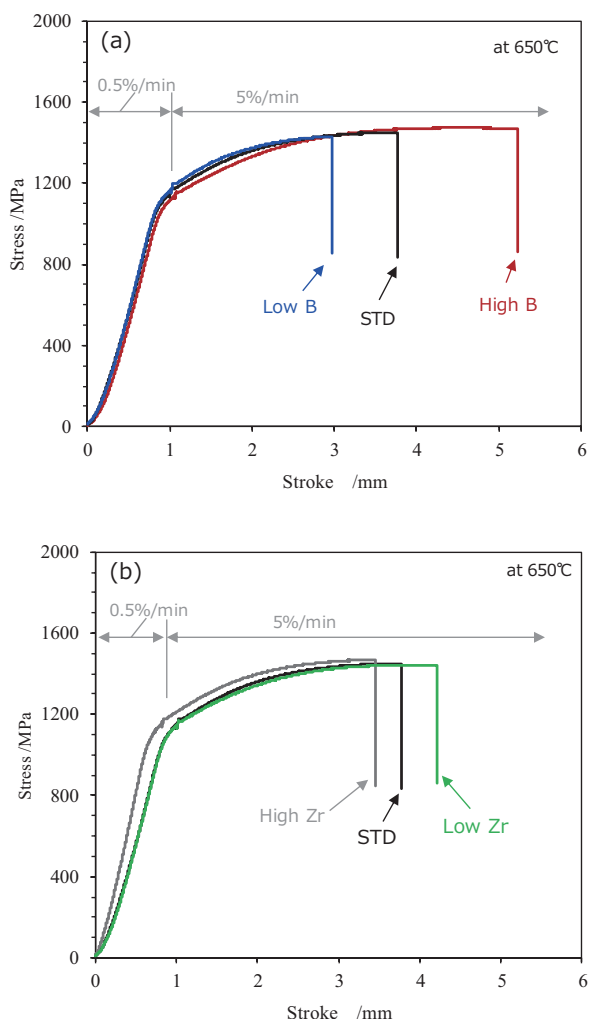


Fig. 2 Stress - stroke curves of TMW-4M3 with
(a) B:0.008-0.030% (Low B, STD, High B) and
(b) Zr:0.017-0.047% (Low Zr, STD, High Zr)

変化した合金間の均一伸びの差は、B量が変化した場合に比べると小さく、Zr量を増加させても延性が向上する傾向は得られなかった。

Fig. 3 (a)にB量と引張強さおよび0.2%耐力の関係を、Fig. 3 (b)にB量と破断伸びの関係をそれぞれ示す。Fig. 3 (a)より、引張強さはBおよびZr量が増加するほど向上し、High B材の引張強さはLow B材に対して44MPa高く、High Zr材の引張強さはLow Zr材に対して24MPa高かった。またFig. 3 (b)より、B量が増加するほど破断伸びは明確に向上しており、High B材の破断伸びはLow B材の2.6倍となっていた。一方、Zr量の破断伸びへの影響は殆ど見られなかった。従って、BおよびZr量が異なる各合金の破断伸びは、Fig. 2 (a)および(b)で確認された均一伸びとよく対応していた。なおFig. 3 (a)における0.2%耐力は、Zr量が増加しても0.2%耐力は殆ど変わらなかったが、B量が増加すると僅かに低下する傾向を示した。ただし、High B材とLow B材の0.2%耐力差は30MPaであり、引張強さの変化と比較するとB量増加の影響は小さかった。




Fig. 3 Tensile properties of TMW-4M3 with various B and Zr contents at 650°C : (a)0.2%YS, UTS and (b)elongation

引張試験後の各合金の破断面について観察したところ、B量の異なる合金の破断面で差異が見られた。Fig. 4 (a), (b)および(c)に、Low B材、STD材およびHigh B材における引張試験後の破断面観察結果をそれぞれ示す。破断面の全体像は実体顕微鏡写真であり、Fig. 4 (a)-(c)中の矢印で示している拡大像は破壊の起点部のSEM像である。いずれの合金も表面から破壊が生じており、酸化による青黒い変色部分が観察された。この酸化部分は、それぞれのSEM像からFig. 1とよく対応する結晶粒の形状が観察されるため、粒界破壊であることが確認できた。Fig. 4 (a), (b)および(c)を比較すると、B量が高くなるほど青黒く変色した粒界破壊部の面積は減少する傾向にあった。従って、B量を増すほど粒界破壊が抑制されており、これが均一伸びを増大させて破断伸びと引張強さを向上させた理由と考えられる。一方、Low Zr材とHigh Zr材における粒界破壊面積には大きな差異が無く、Fig. 3 (b)においてZr量が増加しても破断伸びが変わらなかったことと良い一致を示していた。




Fig. 4 Fracture surfaces of TMW-4M3 of (a) B:0.008% (Low B), (b) B:0.015% (STD) and (c) B:0.030% (High B)

3.3 725°C /630MPaクリープ特性

Fig. 5 (a)および(b)に、各素材の試験温度725°C、試験応力630MPaにおけるクリープ曲線を示す。Fig. 5 (a)は破断に至るまでのクリープ曲線であり、Fig. 5 (b)がクリープ初期段階を示したものである。Fig. 5 (a)より、クリープ破断寿命はB量ごとで大きく異なっていた。クリープ破断寿命はB量が高いHigh B+Zr材とHigh B材が最も優れており、次いでB量が中程度のHigh Zr材、STD材およびLow Zr材となり、B量が低いLow B材が最も劣っていた。また同程度のB量においては、Zr量が多いほどクリープ破断寿命が僅かに優れる傾向にあった。Fig. 5 (b)より、クリープ変形の初期段階においてもB量の多い合金がクリープ抵抗に優れていた。なお同B量における各合金のクリープ抵抗の比較では、High B+Zr材やHigh Zr材がHigh B材やSTD材よりも優れていたが、Low Zr材とHigh Zr材が同等であるため、Zr量の影響は明確ではなかった。

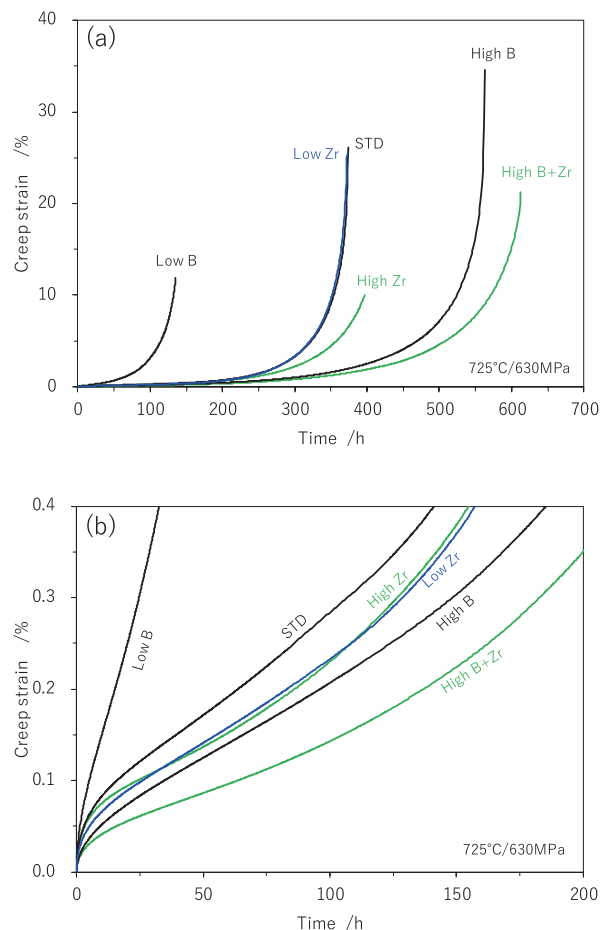


Fig. 5 Creep curves of TMW-4M3 with various B and Zr contents at 725°C /630MPa: (a)full curves, (b)until 0.4% creep strain

Fig. 6 (a), (b)および(c)に、B量とクリープ破断寿命、0.2%クリープ歪み到達時間および破断伸びの関係をそれぞれ示す。Fig. 6 (a), (b)および(c)より、B量の増加に伴って、クリープ破断寿命、0.2%クリープ歪み到達時間および破断伸びが右肩上がりに向上した。B量が与えるクリープ特性への影響は大きく、High B材のクリープ破断寿命はLow B材の約4倍であり、0.2%クリープ歪み到達時間は約6倍であり、破断伸びは約3倍であった。またSTD材に対するHigh B材のクリープ破断寿命、0.2%クリープ歪み到達時間および破断伸びは、いずれも1.5倍程度向上しており、B量の増加がTMW-4M3のクリープ特性を明確に向上させる手段として極めて有効であることが分かった。なおクリープ特性が著しく向上した理由については不明であるが、Fig. 4 (a)-(c)で示した粒界破壊面積の減少との関連性はあると考えられ、クリープ変形中で生じる粒界破壊およびその要因となる粒界すべりが抑制されたことが一因であると考えられる。一方、Zr量が増加した場合、Fig. 6 (a)よりクリープ破断寿命は向上するが僅かであり、Fig. 6 (c)より破断伸びは低下した。

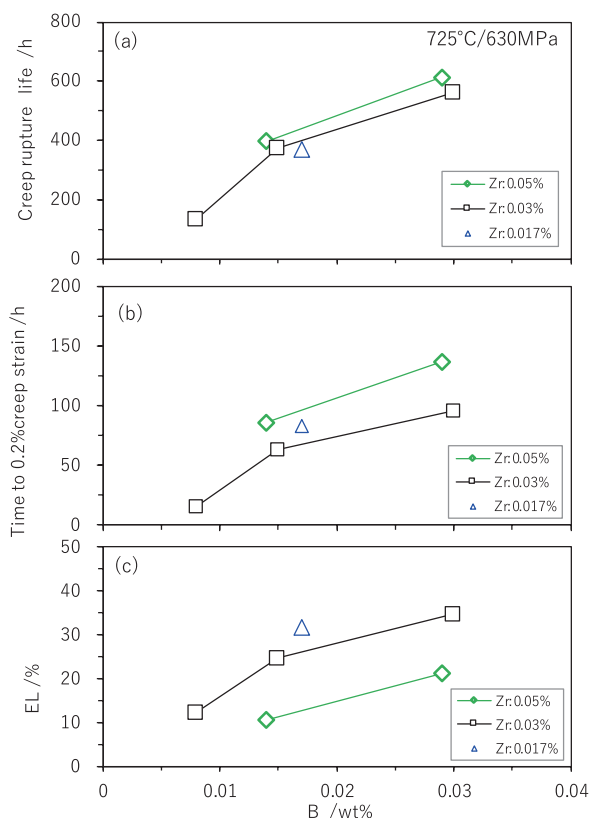


Fig. 6 Creep properties of TMW-4M3 with various B and Zr contents at 725°C /630MPa: (a)creep rupture life, (b)time to 0.2% creep strain, (c)rupture elongation

3.4 高温引張・クリープ特性に対するBとZrの影響

Fig. 7に本研究における650°C引張強さと725°C /630MPaのクリープ破断寿命との関係を示す。また比較として、1120°Cの溶体化処理が施されたTMW-4M3ディスク⁽⁷⁾のデータも示す。このディスクの公称組成はSTD材と同様であり、溶体化温度も比較的近いものである。Fig. 7より、このディスクとSTD材には製造工程の違いがあるため、引張強さおよびクリープ破断寿命の差異があるが、この差異以上にSTD材に対してB量を変化させた場合の特性変化の方が大きいことが分かる。従って、TMW-4M3の実規模ディスクに対して本研究から得られたB量増加を適用することで、TMW-4M3ディスクの引張およびクリープ特性の更なる向上が期待できる。




Fig. 7 Relationship between tensile strength and creep rupture life of TMW-4M3 (B:0.008-0.03%, Zr:0.017-0.05%) and a TMW-4M3 disc⁽⁷⁾

4. まとめ

本研究は、既に提案されているTMW-4M3の公称組成を基準として、BおよびZr量を変化させた各合金を作製し、TMW-4M3の650°C高温引張特性および725°C /630MPaクリープ特性に及ぼすBおよびZrの影響を調査した。得られた結論を以下に示す。

- 1) 各合金の結晶粒度はNo.10.5 ~ 11.0であった。
- 2) B量を増加させると、均一伸びが増大して引張強さと破断伸びが向上した。Zr量を増加させると破断伸びは殆ど変化せず、引張強さが僅かに向上した。
- 3) 各合金の650°C引張変形における破壊は、いずれも表面で生じており、酸化を伴った粒界破壊であった。粒界破壊の面積は、B量が増加するほど減少した。
- 4) B量が増加すると、クリープ破断寿命、0.2%Creep歪み到達時間および破断伸びが明確に向上した。Zr量が増加すると、クリープ破断寿命が僅かに向上し、破断伸びが低下した。
- 5) B量の増加が、高温引張特性やクリープ特性を向上させるのに有効であった。

5. 謝辞

本研究は、国立研究開発法人 物質・材料研究機構と日立金属株式会社の間で2016年度より設立された「NIMS-日立金属次世代材料開発センター」における研究活動の一環として行われたものである。本論文の執筆にあたっては、NIMSの長田俊郎博士、小野嘉則博士、井誠一郎博士、横川忠晴博士、原田広史博士に多くのご助言を頂いた。この場を借りて感謝の意を申し上げる。

参考文献

- (1) Y. F. Gu, H. Harada, C. Y. Cui, D. H. Ping, A. Sato and J. Fujioka, *Scr. Mater.* 55, (2006), pp. 815-818.
- (2) 福田正, 谷月峰, 崔傳勇, 原田広史, *日本金属学会誌*, 第71巻, 第9号, (2007), pp. 667-671.
- (3) Y. Gu, C. Cui, H. Harada, T. Fukuda, D. Ping, A. Mitsuhashi, K. Kato, T. Kobayashi, and J. Fujioka, *Superalloys 2008*, (TMS, 2008), pp. 53-61.
- (4) Y.F. Gu, C. Cui, D. Ping, H. Harada, T. Fukuda, J. Fujioka, *Mater. Sci. Eng. A*, 510-511 (2009) 250-255.
- (5) 横川忠晴, 谷月峰, 崔傳勇, 小泉裕, 藤岡順三, 原田広史, 福田正, 三橋章, *日本金属学会誌*, 第74巻, 第3号, (2010), pp. 221-225.
- (6) 藤岡順三, 谷月峰, 崔傳勇, 横川忠晴, 小林敏治, 原田広史, 福田正, 三橋章, *日本ガスタービン学会誌*, Vol. 40, No. 2, (2012), pp. 107-112.
- (7) Y. Gu, Z. Zhong, Y. Yuan, T. Osada, C. Cui, T. Yokokawa, and H. Harada, *Superalloys 2012*, (TMS, 2012), pp. 903-910.
- (8) J. Fujioka, Y. Gu, T. Osada, C. Cui, T. Yokokawa, T. Kobayashi, H. Harada, T. Fukuda, A. Mitsuhashi, *Proceedings of International Gas Turbine Congress 2015 Tokyo*, (2015), pp. 333-338.
- (9) T. Osada, Y. Gu, N. Nagashima, Y. Yuan, T. Yokokawa, H. Harada, *Acta Mater.* 61, (2013), pp. 1820-1829.
- (10) C.T. SIMS, N. S. STOLOFF, W. C. HAGEL, *SUPERALLOYS II*, Wiley, (1987), pp. 98-99, 120-121.
- (11) 藤田利夫, 柴田浩司, *日本金属学会会報*, 第16巻, 第4号, (1977), pp. 231-239.
- (12) W. D. Cao, R. L. Kennedy, *Superalloys 1996*, (TMS, 1996), pp. 589-597.
- (13) T. Garosshen, T. Tillman, G. McCarthy, *Metall. Trans. A*, Vol.18A, (1987), 69-77.
- (14) S. K. Jain, B. A. Ewing, C. A. Yin, *Superalloys 2000*, (TMS, 2000), pp. 785-794.
- (15) P. Kontis, H.A. Mohd Yusof, S. Pedrazzini, M. Danaie, K.L. Moore, P.A.J. Bagot, M.P. Moody, C.R.M. Grovenor, R.C. Reed, *Acta Mater.* 103, (2016), 688-699.
- (16) S. Kobayashi, T. Ueno, T. Ohno, H. Harada, *Superalloys 2016*, (TMS, 2016), pp. 849-857.

2019年ASME国際ガスタービン会議

1. 全 般

渡辺 紀徳*¹

WATANABE Toshinori

2019年のASME Turbo Expoは北米開催の順番で、アリゾナ州フェニックスのフェニックスコンベンションセンターを会場に、6月17日から21日まで開催された。フェニックスは砂漠の中に作られた都市で、会期中の最高気温が40℃を超え、湿度は10%未満で、日本からの参加者には厳しい気候であった。しかし会議場の中は例によって冷房が効き過ぎ、体調を壊された方もおられると聞いた。会議の趣旨から見ても問題がある。

講演会はいつもと同程度の規模だったが、数年前の最大規模のときと比べると論文数は減少して約960件であった。21の技術分野に分かれてセッションがオーガナイズされる。論文数の多い分野はTurbomachinery (224件)、Heat Transfer (152件)、Structures & Dynamics (136件)、燃焼 (122件)などで、例年通りであった。一方、会議活性化の方策として、チュートリアルとパネルセッションを大幅に増加させており、今回の特徴と言える。チュートリアルは58件も実施され、またパネル討論は28ものセッションが設けられた。

業界の最近の状況を反映してか、スポンサー企業の参画度合いは後退しており、プラチナスポンサーが1社もない状態であった。展示会も縮小傾向にある。他方、活発に感じられたのは学生によるポスター発表で、70件以上あり、審査員の評価により表彰が行われた。

最近の米中政府の関係が影響したためか、中国からの参加予定者でビザを取得できなかった人がかなりおり、近年ほとんど見かけなかったNo-showが目立った。一部にはASME自体の内向き傾向を指摘する声もあった。

会議1日目の午前中にオープニングセッションが行われ、キーノートパネルと各種表彰が行われた (Fig.1)。パネルのテーマはTurbomachines for Clean Power and Propulsion Systemsで、P&WのKohli氏とNASAのDel Rosario氏がモデレータを務め、3人の登壇者が講演して討論が行われた。NASA Glenn研究所のKavandi氏は持続可能性を有するクリーンで静粛な航空エンジンの実現に向けて、電動化、機体との統合、高出力コア開発などの重要性を指摘された。GEのDeLeonardo氏は将来のエネルギーというテーマで、いわゆる3D (Decarbonization, Decentralization, Digitization or

Digitalization)の基調について話され、再生可能エネルギーの成長に、天然ガス火力による調整が柔軟性と急速起動性の観点から重要となることを強調された。日本でも研究開発が実施されているが、ガスタービン火力のこの役割については国際的な常識となっている。GTCCの効率に近いうちに67%まで上昇するだろうとの見通しだった。EPRIのAlley氏は今後の技術を展望された。国際的な地域特性を視野に入れた経済性の観点や、柔軟性と安定的なエネルギー供給のバランスの重要性を指摘され、2050年のガスタービンのビジョンとして、ゼロエミッション、自動オペレーション、再生可能エネルギーとの関係から柔軟性と急速起動性、水素利用などの技術課題を指摘された。

今回の会議ではオープニングの他に発電と航空それぞれについてプレナリーセッションがあり、CO₂削減を基調とするオープニングと同様の共通的な論点が話し合われた。登壇された三菱重工の福泉氏が、15年前にこの会議で登壇した当時はメーカー各社が厳しい競争関係にあったが、現在は各社が協調してこの分野の技術を普及させなければならない雰囲気であり、大きな変化を感じるとコメントされていたのが印象的だった。

当学会はTurbo ExpoにParticipating Organizationとして参加し、展示ブースを出展しており、IGTCやACGT等の国際活動の情報を発信する場として効果を挙げている。また、今年のIGTC2019 Tokyoには前回に引き続き、ASMEが展示ブースを出展する予定である。

ASMEの過度な商業主義化を問題視して改善(回復?)の議論が数年行われた末、改革派が別の国際学会



Fig. 1 Opening Keynote Session (courtesy of ASME)

原稿受付 2019年7月30日

* 1 東京大学大学院 工学系研究科 航空宇宙工学専攻
〒113-8656 文京区本郷7-3-1
E-mail: watanabe@aero.t.u-tokyo.ac.jp

GPPS (Global Power and Propulsion Society) を3年前に立ち上げた。GPPSは模索を続けながら発展して来ているが、ASME内部に残って改革の努力を続けている人たちもいる。彼らによれば、ASMEも人事刷新等を行い、少しずつ良くなっているとのことである。今回の参加登録費はここ数年のレベルに比べると大幅に安

くなったが、改善によるものかも知れない。2020年のTurbo Expoはロンドンで6月22日から26日まで開催される。アブストラクトの締切りがこれまでより1か月以上も遅くなり、10月4日となっている。これも改善の一つであろう。今後の動向が注目される。

2. 航空用ガスタービン

浅子 知昭*¹
ASAKO Tomoaki

1. 概要

航空エンジン関連 (Aircraft Engine Committee主催) のセッション数は、全部で15セッション (2018年: 15 / 2017年: 11 / 2016年: 11) であった。セッションの内訳は、パネルセッションが1セッション (同4 / 1 / 1)、チュートリアルセッションは1つがキャンセルされたため実際に行われたものが4セッション (同2 / 2 / 2)、残りの10セッション (同9 / 8 / 8) がテクニカルセッション (論文発表) であった。また、テクニカルセッションでの発表件数は32件 (同40 / 31 / 38) で、昨年よりも減少している。この内、中国からの発表 (4件) は、2件が代理発表で2件がNo-showであった。また、これらとは別にTurbomachinery Committeeとのジョイントセッションとして騒音関係のテクニカルセッションが1つ行われた。(なお、セッション数、発表件数とも筆者による集計値である。)

今回のパネルセッションは、ハイブリッド電気推進とそれを可能にする技術の開発に関するものであり、パネリストは、NASA Glenn Research Center, United Technology Research Center, DLR(独), Aurora Flight Sciences社, オクラホマ州立大学からの5名であった。

チュートリアルセッションは、①ガスタービンエンジンのサイクルモデル作成の基礎、②ガスタービンエンジンコアの基礎、③電動飛行に関してのプロペラや電動機について、④機体から見た推進システムのインテグレーションに関するものであった。このうち①は、過去に行われたエンジン性能計算方法と非定常性能予測方法、エンジンの概念設計のチュートリアルセッションの内容を合わせたものであり、③、④は新しい内容であった。なお、ターボシャフトエンジンの最適化についてのセッションはキャンセルされた。

テクニカルセッション10セッションの内訳は、①オペ

ラビリティ、②モデル化、シミュレーションと検証、③インレット、排気部、ダクト、④熱管理とオイルシステムが2つ、⑤エンジン全体の性能と新エンジンコンセプトが2つ、⑥プロペラとオープンロータ、⑦インレット、ナセル、排気ノズル、ミキサ、⑧機上でのエンジン状態監視、モデル化と最適化である。この中にインレットに関するセッションが2つあるが、昨年、一昨年と聴講者の多かったインレットとファンの干渉に関する発表は、どちらにも含まれなかった。(Turbomachinery主催のインレットディストーションのセッションへ移ったものと推察する。)

2. テクニカルセッション内容

2.1 オペラビリティ

この中では、小型ファン模型を用いたストールの兆候に関する研究の発表 (GT-90243, 90242) があった。

2.2 モデル化・シミュレーションと検証

ここでは、タービンの段間で燃焼させる形態のエンジンの非定常挙動の予測について (GT-90583)、機械学習を用いた高圧圧縮機の最終段翼高さの予測について (GT-91432)、可変ピッチファンのリバース推力時の流れの解析 (GT-91039) などの発表があった。

2.3 インレット、排気部、ダクト

このセッションでは、ナセルのアンチアイス装置の形態差の比較を行ったもの (GT-90992)、タービン出口のフレームの表面粗さを考慮したCFDと試験結果の比較 (GT-90472) などの発表があった。

2.4 熱管理とオイルシステム

ここでの発表は、ベアリングチャンバー内の流れの挙動を形状毎に試験により確認し評価した結果の発表 (GT-90320)、遊星歯車内の二相流の挙動をCFDで計算・評価したもの (GT-90347)、ファン駆動用歯車のロスをロスの種類毎の方法により予測した結果についての発表 (GT-91309)、Cooled Coolingの熱交換器を含むシステムの挙動の試験結果とモデルによる予測を比較したもの (GT-90701)、流れ場へ液体を噴出した時の粒滴の挙

原稿受付 2019年7月22日

* 1 (株)IHI 航空・宇宙・防衛事業領域 技術開発センター
エンジン技術部 性能・システム技術グループ
〒196-8686 昭島市拝島町3975番地18

動の数値解析 (GT-91076) などがあつた。

2.5 エンジン全体の性能と新エンジンコンセプト

ここでの発表は、Ducted Prop用ファン特性の新しい整理方法 (GT-90788)、エンジンが劣化した場合に、それに合わせて飛行経路を最適化したときの燃費、飛行時間等の改善量の検討 (GT-90175)、タービンの翼型をエンジンの燃費が最も良くなるように最適化する検討 (GT-92011)、熱交換器をつけた、中間冷却再生サイクルとSemi-Closed式の新しいコンセプト (2形態) の特徴を比較したもの (GT-92066) などであつた。

2.6 プロペラとオープンロータ

このセッションの中では、2050年のEISを想定したオープンロータの経済面での出現可能性の検討 (GT-90290)、ドローン用のプロペラの低騒音化の検討 (GT-90534) などが発表された。

2.7 インレット、ナセル、排気ノズル、ミキサ

ここでは、アクロバット競技機用のターボプロップエンジンのインレットの圧力と温度のディストーションを試験結果とCFD結果を比較した結果 (GT-91689)、インレットディストーションが生じている流れを離散点で計測した場合に計測結果から実際の流れがどの程度再現できるかを示したもの (GT-91780)、実エンジンのバイパスダクト内の流れのPIVでの計測に関するもの (GT-92064) の発表があつた。

2.8 機上でのエンジン状態監視、モデル化と最適化

このセッションでは、非定常の性能シミュレーション予測のためのモデル化方法 (GT-90420) や高圧タービンの劣化時の詳細な形状 (エロージョン等による表面形状の変化等) をモデル化しCFDでその時の性能を評価したもの (GT-90882)、機体の上昇経路を変えた場合の高圧タービンディスクの寿命に与える影響を評価した検討 (GT-91190) の発表があつた。

3. 産業用ガスタービン

石原 信哉*¹
ISHIHARA Shinya

産業用ガスタービンは以下に示す8セッション開催され、“Oil and Gas Applications”と、ガスタービン関連の発展的研究の“Cycle Innovations”, “Supercritical CO Power Cycles”のセッションで全体の半分以上を占めた。昨年と比較して“Coal, Biomass and Alternative Fuels”と“Cycle Innovations”の発表数の増加が目立った。また、産業用ガスタービンの論文発表数は155件と3割近く多かつた。

1. Electric Power : 発電用途

論文数は9件で、昨年より2件減少した。バーデン地方における80年に亘るオープンサイクルガスタービンの開発 (GT-90177)、高効率5MWクラスガスタービンM5Aの開発 (GT-90773)、コンバインドサイクルガスタービンにおける熱経済的健全性の消失に関する批評 (GT-90883)、ガスタービンの異常検出におけるベクトル自己回帰モデルの適用 (GT-90995)、低エミッションと運用柔軟性のための高度なガスタービン調整自動化 (GT-91587)、7/9 HA初号機に関する報告 (GT-91594)、低圧力損失フレームシート燃焼器の検証 (GT-

91647)、産業用GTへの人工知能応用と影響の考察 (GT-91963)、先進燃焼システムの健全性監視に関する調査 (GT-91973) の発表があつた。

2. Industrial and Cogeneration : 産業用途と熱電併給

論文数は16件で、昨年より5件増加した。ガスタービン電力増大技術 (GT-90136, 90172)、数値モデルによる低発熱量合成ガスの経済性への影響と排ガス分析 (GT-90274)、貫流ボイラのガス経路診断 (GT-90324)、二相水性圧縮機洗浄の優位性 (GT-90340)、ハイブリッド太陽光ガスタービンプラントの性能解析 (GT-90604)、2軸GTの航空転用 (GT-90617)、産業用GTへのガス流路解析の適用 (GT-90686)、CHPのための蒸気噴射ガスタービン (GT-90748)、CHP構成に関するハイブリッド発電の最適化評価 (GT-90946)、石油蒸留プロセスに適用される排熱回収有機ランキンサイクルのための作動流体選択 (GT-91122)、ガス圧縮機におけるガスタービン軸の油圧損失の推定 (GT-91316)、排熱回収についての評価と設計 (GT-92141)、排出ガス基準 (GT-92174, 92195)、蓄熱を含む太陽光およびバイオマスエネルギーのコージェネレーション (GT-92141) の発表があつた。

原稿受付 2019年7月18日

* 1 川崎重工業(株) エネルギー・環境プラントカンパニー
エネルギーシステム総括部
〒673-8666 明石市川崎町1番1号
E-mail: ishihara_shinya@khi.co.jp

3. Oil and Gas Applications : 石油・ガス産業用途

論文数は29件で、昨年より1件減少した。排熱回収ORCサイクル (GT-90009), 非常停止時の圧縮機速度低下 (GT-90020), ガスタービンの健全状態予測 (GT-90054, 90055, 90056, 90057), 液化天然ガスパラントの資産リスク評価 (GT-90068), MS5002 GT用のホイールボックス試験 (GT-90075), 多段中間冷却圧縮機の不安定性解析モデル (GT-90098), 理想気体モデルを用いた実在気体との偏差推定 (GT-90112) の発表があった。航空転用GTの機外横断火炎検出 (GT-90158), シェブロン型スラスト軸受のモデル最適化 (GT-90228), LNG液化プラントにおける遠心圧縮機設計 (GT-90329), ガス輸送におけるH₂の影響 (GT-90348), 湿式ガス圧縮機モデリング (GT-90353, 90354) の発表があった。また, LNGプラントの設計外性能評価 (GT-90495), SGT-A35 (GT61) の改良 (GT-90610), ガス井における坑内用途のための圧縮技術 (GT-90854), パッケージ設計におけるCFDモデル (GT-90871), 爆燃による圧力波に対するターボ機械への過渡荷重 (GT-90942), 部分負荷エミッション低減のための制御アルゴリズム (GT-91053), 遠心圧縮機軸出力に及ぼす湿潤気体の挙動の影響 (GT-91143), ガス漏れ/ドライガスシール (GT-91199, 91748, 91865, 92147), 遠心圧縮機軸端温度測定 (GT-91798), ロータダイナミクス (GT-92146) の発表があった。

4. Marine : 船舶用途

論文数は9件で、昨年より4件減少した。海洋環境におけるガスタービンの腐食 (GT-90111, 90784), 船用GTエンジン性能と航海解析 (GT-90135), 可逆タービン概念検証 (GT-90246), US海軍501-K34取外し分析 (GT-91535), ホバークラフト用遠心ファンの空力・構造的設計 (GT-91738), CODELAG海軍海洋システムにおけるSSSクラッチの利点と経験 (GT-91873), 修理容易な船用GT設計 (GT-91992), 2段空気を過システム (GT-92053) が発表された。

5. Coal, Biomass and Alternative Fuels : 石炭, バイオマス, 代替燃料

論文数は23件で、昨年より14件増加した。代替ジェット燃料の噴霧特性 (GT-90115), リッチ燃焼状態での固体バイオマス (GT-90196), フィッシュヤートロブシュ法におけるジェット燃料の自己着火 (GT-90270), SPH法による一定流量下における燃料微粒化の大気圧影響調査 (GT-90372), テーラード燃料処理によるGT運転最適化 (GT-90380), 液体水素推進技術導入に対するニーズ分析 (GT-90453), 層流火炎速度 (GT-90475, 90570), ミクロミックス燃焼システム (GT-90532, 90538, 90833), 高圧熱腐食バーナの開発 (GT-90576), 燃焼器バーナの

噴霧火炎特性 (GT-90663), ブタノール混合ガソリン代替燃料の燃焼特性 (GT-90911), 圧縮機ロータのためのLCA設計法 (GT-91185), 産業GT開発ライフサイクルに対する環境影響評価 (GT-91191), 乱流予混合バイオガス火炎の動的応答 (GT-91379), アンモニアとコークス炉ガスまたはメタンとの同時燃焼のGTサイクル分析 (GT-91404), IMPGCサイクルの開発と解析 (GT-91707, 91711), 熱分解油の噴霧特性 (GT-91742), メタンとバイオアルコール混合燃料の自己着火 (GT-91978), CO₂環境におけるオキシメタン燃焼中のCO変化 (GT-92086) が発表された。

6. Cycle Innovations : 革新サイクル

論文数は33件で、昨年より21件増加した。部分負荷性能過渡シミュレーションのための圧縮機特性 (GT-90457), 逆ブレイトンサイクルとランキンサイクルの複合 (GT-90767), 音響解析を用いたサージと失速の検出 (GT-91021), ヒートポンプと熱エネルギー貯蔵を統合した複合サイクル発電 (GT-91036, 91354, 91541), ブレードレスタービンの設計・評価 (GT-91047, 91708), 風力発電バランスのための水中CAESシステム (GT-91048), 蒸気タービン空気保温によるCCPPの始動改善モデルベース解析 (GT-91138), ソーラーハイブリッドMGTシステムの監視と最適運転予測 (GT-91180), 燃料電池ハイブリッドシステム (GT-90379, 91351, 91534, 91585, 91920, 91929, 91946, 92070, 92145), デトネーション燃焼器下流の超音速タービンの非定常熱伝達評価 (GT-91460), 実物大インターフェースにおける物理モデル化とシミュレーション (GT-91597), 超音速ラジアルタービンの設計および解析 (GT-91756), 超臨界CO₂石炭火力発電所の多目的最適化 (GT-91789), スマート診断 (GT-91950) の発表があった。なお, 航空用と小型ガスタービンは除外した。

7. Supercritical CO₂ Power Cycles : 超臨界CO₂ 発電サイクル

論文数は33件で、昨年より6件増加した。熱交換器関連 (GT-90063, 90374, 91772), サイクル性能 (GT-90178, 90315, 90393, 90496, 90647, 90704, 90777, 91088, 91371, 91509, 91917), 部品開発/コスト影響 (GT-90337, 90493, 91391), 軸流タービンの設計・開発 (GT-90392, 90409, 90606, 90681) の発表があった。また, 圧縮機/ターボ機械設計 (GT-90876, 91189, 91615), 燃焼/CO測定 (GT-90899, 91691, 91779, 92109), フィルムシール剛性 (GT-90975), 熱力学的モデリング/数値解析 (GT-90497, 91409, 91443, 91613) の発表があった。

8. Organic Rankine Cycle Power Systems : 有機ランキンサイクル発電システム

論文数は3件で、昨年より3件減少した。ロバスト最適化のための革新的技術 (GT-90170), 韓国における複

合海洋熱エネルギー変換 (GT-90758), 高密度ガス蒸気用のブローダウン施設の開発 (GT-91609) の発表があった。

4. 小型ガスタービンおよびセラミックス

金子 雅直*1

KANEKO Masanao

Microturbines, Turbochargers & Small Turbomachines Committeeが主催するテクニカルセッションでの発表件数は、小型ガスタービンに関する「燃焼と燃料」の3件、「要素設計と性能解析」の2件、「分散型発電とハイブリッドエネルギーグリッド」の2件、ターボ過給機に関する「性能評価と予測」の3件、「タービン」の4件、「圧縮機」の6件、および小型ガスタービンとターボ過給機に関する「新興システムと適用」の4件である。総論文件数は24件（日本からの発表は1件）で、昨年より1件増えている。これら以外には「ベアリング」に関するチュートリアルが2件あった。

Ceramics Committeeが主催するテクニカルセッションでの発表件数は、セラミックス基複合材 (CMC) に関する「要素」の3件、「挙動」の6件、「材料挙動」の7件である。総論文件数は16件（日本からの発表は2件）で、昨年より1件増えている。これら以外にチュートリアルが1件あった。

以下に各テクニカルセッションにおける発表の概要を示す。

1. Microturbines, Turbochargers & Small Turbomachines

小型ガスタービンに関する「燃焼と燃料」のセッションでは、マイクロガスタービンでの利用を想定して設計された希薄予混合燃焼器と部分過濃形態燃焼器におけるメタン・水素混合気燃焼時の火炎挙動や燃焼特性を数値解析的に調査・比較した研究 (GT-90229), 100 kW水素焼きマイクロガスタービン向けの圧縮機と燃焼器の設計に関する研究 (GT-91342), およびバイオガス焼きマイクロガスタービンのエネルギー性能と環境性能を分析した研究 (GT-91483) について発表があった。「要素設計と性能解析」のセッションでは、航空転用マイクロガスタービンを対象に、熱漏れ損失の違いが全体性能に及ぼす影響や発電機冷却法の違いによる影響などを実験

的・解析的に評価した研究 (GT-90010) などについて発表があった。「分散型発電とハイブリッドエネルギーグリッド」のセッションでは、30 kWマイクロガスタービンが用いられた試験装置により、様々な運転条件下で各構成要素の特性を調査した研究 (GT-90709) と複合領域設計最適化手法をマイクロ Kaplan 水車の設計に適用した研究 (GT-90509) が報告された。

ターボ過給機に関する「性能評価と予測」のセッションでは、触媒装置が装着された過給機を対象に、熱・流動連成解析を行い、その結果を実験値と比較した研究 (GT-90451) や固定パッド油潤滑スラスト軸受の熱流体解析手法を提案した研究 (GT-91596) などの発表があった。「タービン」のセッションでは、3次ベジェ曲線を用いたラジアルタービンロータの形状生成法を提案し、その有効性をCFDにより評価した研究 (GT-90163), ラジアルタービンの性能に定常および非定常の入口旋回流れが及ぼす影響を数値解析的に調査した研究 (GT-91155) や曲がり流路を有するウェーブロータタービンに対する準1次元モデルを提案し、その妥当性を評価した研究 (GT-90868) などについて発表があった。「圧縮機」のセッションでは、PIVを用いて遠心圧縮機のインデューサ付近における流れ場を調査した研究 (GT-90384), 遠心圧縮機のポリユート形状をCFD解析により得られたエントロピー生成率に基づいて最適化する手法を提案した研究 (GT-90867), 遠心圧縮機の性能に循環型ケーシングトリートメントが及ぼす影響を抽気溝の位置などに関してパラメトリックスタディした研究 (GT-91245), 高比速度小型斜流圧縮機の設計に関する研究 (GT-90980), この研究で設計された圧縮機を対象に、ケーシングトリートメントがサージマージンなどに及ぼす効果をNon-Matching Mesh Interfaceと同境界面に対する非保存型補間法を用いて調査した研究 (GT-90977) などについて報告があった。

小型ガスタービンとターボ過給機に関する「新興システムと適用」のセッションでは、半径吐出型の1段ターボエクスパンダを最適化アルゴリズムが組み込まれた翼型中心線設計コードを用いて設計し、その内部流れの挙動を数値解析的に調査した研究 (GT-90346), 固体

原稿受付 2019年7月23日

*1 東京電機大学 理工学部 機械工学系
〒350-0394 比企郡鳩山町石坂
E-mail: kaneko@mail.dendai.ac.jp

酸化物形燃料電池システム向けの再循環送風機を設計し、その諸性能を実験的・数値解析的に調査した研究 (GT-91361)、小型軸流式ターボエキスパンダを金属積層造形により製造するための設計と製造プロセスに関する研究 (GT-91822) などについて発表があった。

2. Ceramics

CMCに関する「要素」のセッションでは、CMCタービンペーンを設計するための破断予測モデルの検証結果 (GT-91233) やCMC高圧タービン翼を設計する際の留意点 (GT-91787) などについて発表があった。「挙動」のセッションでは、ENFとELSによりSiC/SiC CMCのモードII層間破壊じん性を調査した研究 (GT-90031)、CMCのモードIIき裂進展抵抗の予測手法を提案した研究 (GT-90985)、SiC_f/SiC CMCを対象としたき裂検出法としてin-situ引張試験を提案した研究 (GT-90356)、室温

におけるSiC_f/SiC CMCの機械的損傷蓄積をin-situ X線CTを用いて調査した研究 (GT-90357)、CMCにおける損傷の発生にマイクロポロシティが及ぼす影響を調査した研究 (GT-91908)、2.5次元織物複合材の張力特性を実験と計算により評価した研究 (GT-90838) などについて報告があった。「材料挙動」のセッションでは、ヒステリシスベース損傷パラメータを用いてCMCの熱機械疲労を調査した研究 (GT-90067)、SiC_f/SiC CMCの高温疲労をDICやAEを用いて評価した研究 (GT-90355)、異物衝突によるCMCの損傷を予測する手法を提案した研究 (GT-90368)、MI SiC/SiC CMCにおけるエロージョン挙動を粒子の速度や大きさをパラメータに調査した研究 (GT-90837)、CMCタービンペーンの疲労性能に前縁への異物衝突が及ぼす影響を実験的に調査した研究 (GT-90841) などについての発表があった。

5. ターボ機械の性能と流れ

5.1 軸流関係 5.1.1 ファン・圧縮機

加藤 大*¹
KATO Dai

ファン・圧縮機では11セッションが生まれ、講演数は40件で、昨年度の45件、一昨年度の46件に比べやや少なかった。中国12編、ドイツ11編が突出して多く、続いて英国、米国が各4編、日本、フランスが各3編、インドが2編、カナダが1編だった (収録ベース)。ただし、中国の講演ではキャンセルも目立った。非定常流れ、設計手法とCFDモデリング、ダクトと要素干渉に関する分野でも、計20編近くのファン・圧縮機に関する発表があり、ここでも幾つか紹介するが、併せて参照されたい。

圧縮機設計では2セッションが組まれた。ブレンド補修した圧縮機の作動範囲を機械学習により予測する特筆すべき発表がなされた (GT-91339)。個々の翼形状ではなく、多くの圧縮機専門家から聞き取った英知に基づく補修翼の配置・程度等を規定するパラメータを変数とすることで、必要な学習データを1オーダー減らした上で、単段圧縮機の換装から試験データ取得までを15分で行うRapid Testと称する手法により、100ケースの学習データを取得し機械学習させる。25ケースの検証試験により作動範囲を2%の誤差で予測できることを示している。そのほか、ブリードシステムでの圧力損失発生機構とそ

の低減方法 (GT-90150)、シュラウド付き両持ち静翼のハブ径を上げて空気通路内に突出させ、静翼ハブでの前後差圧を減少させることにより、漏れ流れを低減させた低速試験結果 (GT-91611)、可変静翼の支持部 (Penny) における間隙を通過する漏れ流れのRANS、DES解析による分析 (GT-90289)、等の興味深い報告もなされた。

高速多段圧縮機の大規模CFDによる流れ予測・評価が幾つかのセッションで報告された。2段機の流れ場をDESにより再現し、動翼、静翼で発生する圧力損失を詳細に細分化した報告 (GT-90439)、高負荷6.5段機におけるラジアルミキシング現象をIDDESにより捉え、翼先端漏れ流れの非等方性乱流との相関を示した報告 (GT-91141) がなされた。ガスタービンの起動時に8段圧縮機に生じる旋回失速を全周・全段のURANSにより再現したうえで、失速を回避するVSV変更案をCFDで見出した報告 (GT-91340)、8段機の半周全段解析結果を用い、全圧・全温の周方向分布に伴う段間性能計測の不確かさを減らす計測器配置を計画する方法を示した報告 (GT-90839)、が注目を集めた。そのほか、乱流モデルの改修による失速付近でのURANSの予測精度の改善 (GT-91227)、RANSでのラジアルミキシング予測精度の改善 (GT-90363) 等も報告された。

航空機の大幅な燃費改善の期待される境界層吸い込み (Boundary Layer Ingestion; BLI) に伴うファンのインレットディストーションに関する報告も多かった。主翼

原稿受付 2019年7月19日

* 1 (株)IHI 航空・宇宙・防衛事業領域 技術開発センター
要素技術部 空力技術グループ
〒196-8686 昭島市拝島町3975番地18
E-mail: kato8842@ihi-g.com

上にエンジンを置いた場合と通常の周方向ディストーションを受けた場合とのファン性能のCFD比較 (GT-90425), ファン動翼部を体積力で置き換えたBody Force法 (BFM) による効率的な設計手法のURANSとの比較 (GT-90471), コンセプト設計段階でのスルーフローを用いた設計手法 (GT-90257) が報告された。BLIで発生するSwirl distortionを模擬するディストーション発生装置Stream Vanes™ (Virginia工科大の特許) の出口流れ場を詳細に計測したNASAによる報告も注目を浴びた (GT-92073)。

ケーシングトリートメントならびに翼先端漏れ流れに関しては1セッションずつ組まれた。中でも軸方向循環型トリートメントについて、動翼前縁上流での主流への吐き出し方向を回転逆方向、順方向に変更した場合の作動範囲、効率、流れ場を比較した実験報告 (GT-91050),

翼先端漏れ流れを簡単なモデルに置き換えた上でLESにより解析し、漏れ流れの乱流特性のBudgetを分析した報告 (GT-90844) が注目された。

翼端壁流れでは、直線翼列の3次元LDA/PDAによる詳細な流れ計測に基づくコーナ渦構造の同定 (GT-90123), VLES Lattice Boltzmann法により、試験でのコーナはく離の規模、圧力損失を高精度に、かつLESの数十分の1の計算時間で予測できること (GT-90919) が報告された。

流体制御は中国からの論文が多かったが、GE (ドイツ) からは、動翼ハブにスロットを設けて圧力面側から負圧面へのジェットを生成しハブストールを遅延する技術のCFD検討 (GT-90754) が構造面の課題と共に報告された。

5.1 軸流関係 5.1.2 タービン

木村 泰徳*1

KIMURA Yasunori

軸流タービンでは、6つの論文セッションがあり、発表件数は31件と昨年 (33件) と同等規模であった。地域別に見た件数は、北米7件、欧州16件、アジア8件であった。船崎氏の論説記事 (本誌Vo.45 No.4) によれば、「翼部以外での流れ場の影響を考慮した複雑かつ複合的な現象や非定常現象の実験的・数値的解明と、それらから得られた知見の設計への落とし込み」が近年の技術動向となっており、今回もその傾向が踏襲されている。

エンドウォールコンタリング

英国Bath大学から3件の発表が見られ、新たなリグ試験装置において、レーザー誘起蛍光法により、パージ空気の影響を捉える試み (GT-90377), 前縁の馬蹄形渦を抑制する新たな形状の規定方法の提唱があった (GT-90443, 90446)。

空力性能と設計

超音速タービンの設計手法 (GT-91255), 機械駆動用途を想定した幅広い作動条件でのディフューザー性能評価 (GT-91262), LES適用例 (GT-91592), 静翼後縁や動翼先端の腐食による熱効率の影響の調査 (GT-90636), 反転タービンの無次元パラメータの整理 (GT-91632), 燃焼器、二次空気を考慮したりグ試験装置において段効率 $\pm 0.1\%$ の不確かさでの計測を可能とし、動翼翼端形状

や燃焼器と静翼のクロッキングによる性能差を捉えた報告があった (GT-90294)。

漏れ流れ

ハニカム構造をした翼端からの空気吹き出しによる漏れ流れ損失低減の試み (GT-90589), 実験と解析による静翼ハブの漏れ流れによる損失評価 (GT-90726), パージ空気と静翼後縁冷却空気を模擬したりグ試験により、キャビティ部のシール効率に対する後縁空気の影響や過渡応答特性の評価 (GT-91576, 91654), PIVによる主流とパージ空気との干渉の可視化例 (GT-90827) が見られた。

非定常流れと遷移

高速の翼列風洞において、流れの乱れ成分をPIVと熱線流速計によって計測し、その差異を比較したもの (GT-90473), タービン出口案内翼を対象に、Re数、流入角、乱れ度の影響を翼列試験で詳細に調査し、遷移モデルを入れたRANS解析と比較したもの (GT-91234), 各種デトネーションエンジンの内部流れの評価 (GT-91263, 91485), 翼端間隙値がばらついた流れ場をリグ試験装置で確認したもの (GT-91629), 燃焼器による非等方の乱れによる下流静翼の損失への影響を燃焼器と翼列を模した試験により調査し、損失増加要因を詳細に分析したものが見られた (GT-90307)。

低圧タービンの空力

様々な負荷 (減速率) の翼型に対して、上流翼のウェークとの干渉を考慮し、主流乱れ度、Re数、St数の影響を低速風洞試験により網羅的に調べたもの (GT-

原稿受付 2019年7月18日

*1 三菱重工(株) 総合研究所
流体研究部 ターボ機械第二研究室
〒676-8686 高砂市荒井町新浜2-1-1
E-mail: yasunori_kimura@mhi.co.jp

90408), フェンスや前縁突起 (GT-91280, 91284, 91820) による空力損失低減の試みが見られた。

空力検討

検査体積法に基づく新たなプロファイル損失の算出手法 (GT-90401), 大転向角遷音速タービンのプロファイ

ル損失評価 (GT-91264), 衝撃波の可視化 (GT-90342), 新たな渦同定方法の高圧タービン流れ場への適用例 (GT-90462), 新たな乱流遷移モデル (GT-90585), 主流と壁との温度比が遷移に及ぼす影響の調査 (GT-91834) が見られた。

5.2 遠心関係

玉木 秀明*¹
TAMAKI Hideaki

遠心関係では、7セッション、22件の発表があった。昨年の31件に比べると約2/3と、大幅に発表件数が減っている。内訳は、欧州から11件、アジアから8件、北米から3件であり、遠心圧縮機に関するものが15件 (昨年は24件)、ラジアルタービンに関するものが7件 (昨年は7件) であった。遠心圧縮機については、失速・サージ現象に関するものが約1/3を占めている。CFD、EFDの進化によって着実に現象自体の理解は進んでいるが、これらに関わる事象には未検討なものも多く、引き続き産官学の研究者の興味を引いている。これに加えて、実験を中心に据えて流れ場および流体損失を分析して、より良い設計へ結びつけようとする試みも目立った。ラジアルタービンについては7件中6件が過給機に関するもので、エンジン側からの要求である低U/Cでの効率改善、エンジン排気脈動流からの効率的なエネルギー回収に関する技術開発に力点が置かれている。遠心圧縮機の失速・サージ現象に関わるものとして、失速点近傍において、インペラ翼端漏れ流れと主流の境界でKelvin-Helmholtzの不安定から竜巻状の翼端漏れ渦が形成され、隣接する長羽根と干渉する過程と、その過程にポリユートによって作られる非軸対象圧力場が及ぼす影響を示したもの (GT-90217)、遠心圧縮機上流に曲り管があると、サージ限界が小流量側へ移動する事例がいくつか報告されているが、この理由をCFDによって明らかにしたもの (GT-90794)、圧縮機出口配管端部にエンジンの吸気バルブが存在する過給機用圧縮機をターゲットに、圧縮機下流の背圧脈動と圧縮機性能、特にサージ近傍での圧縮機特性との関係について実験的に調査したもの (GT-90735)、マイルドサージとディープサージの挙動に対するインペラ回転数、圧縮機下流貯気槽の容積の影響を実験的に調べたもの (GT-90781)、羽付きディフューザのベーンをいくつかのセクタに分割し、セクタ毎に異なる取り付け角のベーンを設置したものをを用い

て、従来型の羽根付きディフューザに発生する3セルの旋回失速の抑制とインペラに誘起される振動応力を低減させる試みがあった (GT-90914)。実験をベースにした現象解明やCFDの精度検証を試みたものとして、多段遠心圧縮機の段間をつなぐリターンシステム (U-Bend, リターンチャンネル, L-Bend) に発生する損失を摩擦損失、2次流れ、インシデンスロス、翼後縁部流れに由来する損失に分離し、高損失要因を明確にしたもの (GT-91195)、レイノルズ数とリターンシステムの全圧損失係数の関係を調査したもの (GT-90559)、U-Bend部の流れ場に対して乱流モデルの精度評価を行ったものがあつた (GT-90455)。また、圧縮機的设计点での羽根付きディフューザの流れをLDVによって詳細に計測したもの (GT-90476)、新設計の遷音速遠心圧縮機について、設計手法の妥当性検証のためにL2Fで計測したものがあつた (GT-903908)。圧縮機の性能改善の取り組みとして、クローズド・インペラを有する遠心圧縮機に対して有効性が確認されている翼面をリーンさせ2次流れを抑制する設計手法をオープン・インペラに適用し、その有効性を調査したもの (GT-91153)、入熱の影響を考慮した超電導磁石向け極低温He冷凍機用圧縮機的设计手法の提案 (GT-90614)、翼負荷の最適分配と流れの転向を小刻みに複数の翼に受け持たせることによる離れ抑制効果等を期待して、同一のインペラ上に複数の翼を設置し多段化 (長羽根をいくつかの羽根に分離) するMulti-Rotor圧縮機の試設計に関する報告があつた (GT-91967)。ラジアルタービンでは、エンジン加速時の低U/C (Uはロータ入口チップ周速, Cは理論ガス速度) 条件で、従来のラジアルタービンよりも高効率が期待できる斜流タービンの設計に関する報告が4件あつた。ロータ設計に関するものとしては、基本的な設計指針の提案 (GT-90070)、ハブ側翼長の選定と性能の関係を調べたものがあつた (GT-90389)。静翼については、ノズルベーンをリーンさせ、スパン方向にスロート幅を変えることで流出角をコントロールし、斜流タービンロータハブ側に生じる離れを抑制する試みが報告された (GT-90398)。また、エンジン排気脈動下における斜流タービ

原稿受付 2019年7月25日

*1 (株)IHI 技術開発本部

〒235-8501 横浜市磯子区新中原町1番地

E-mail: tamaki5546@ihi-g.com

ンの性能を、ロータ部をアクチュエータディスクのようにモデル化し1Dの圧縮性流れを解くことで予測するコードの開発が紹介された (GT-91299)。過給機以外では、オイル&ガス向け排熱回収用ガス・エキスパンダー

に関するものが1件あった。実験結果を用いて極端に設計点から離れた運転点の性能を精度よく外挿予測するための新たなデータ整理法の提案があった (GT-91856)。

5.3 非定常流れと数値流体力学

山田 和豊*1

YAMADA Kazutoyo

1. 概要

非定常流れ関係では10セッションで31件の講演があった。昨年とセッション数は同数であるが、論文数は38件から減少している。昨年と同様、中国からの講演が10件と最も多く、次いでイタリア7件、イギリス4件の講演があった。設計手法とCFDモデリングについては、13セッションあり、43件の講演があった。これは、昨年、一昨年と比較すると10件以上減少している。国別では、昨年同様イギリスからの講演が11件と最も多く、次いでアメリカおよび中国からそれぞれ6件の講演があった。

2. Unsteady Flow in Turbomachinery

タービン関係の非定常流れが最も多く研究されている。主には、燃焼器を含むコンポーネント間の干渉に伴う非定常流れが実験的および数値的に調査されている (GT-90790, 90824, 91206, 91276)。後流干渉については、PIV計測結果に対しPODを適用して詳細に分析した研究 (GT-91222, 91226, 91229) があった。他には、渦放出を伴う非定常流れに関して、RANSの予測精度改善のために、機械学習を用いて乱流モデルを改善する試み (GT-90179) が紹介された。

失速関係では、遠心圧縮機の旋回失速が調査されており、失速の発達過程を実験および数値計算により調査した研究 (GT-90797)、ポリュートによる非軸対称性が失速初生に及ぼす影響を調べた研究 (GT-90713) が発表された。また、ケーシングトリートメントの効果に関連して、斜流羽根車の失速初生現象の変化を実験的に調査した研究 (GT-92034) があった。

圧縮機関係では、wall-resolved LESの応用に関する研究がみられた。自身の翼から発生する後流を上流翼列からの後流として入口境界に用い、リピーティングステージの圧縮機を単翼計算で模擬することで、高解像度LESを実施して動静翼間距離と性能の関係を調査してい

た (GT-91007)。一方で、翼列干渉を効率的に解析するために、ハーモニックバランス法を改良した時間・空間スペクトル法を提案した発表 (GT-91545) などもあった。

より実際の設計に関連した研究として、Millerの方法を拡張して、RANSやLESの計算結果をもとに損失解析を実施する方法を提案した発表 (GT-91253) や、サージ予測に必要とされる圧縮機性能について、軸対称を仮定した性能予測モデルを構築した研究 (GT-90091) があった。

3. Design Methods & CFD Modeling for Turbomachinery

設計関係では、設計で使用される各モデルの改良が研究されている。最適化手法を用いて各マッハ数域でSmith Chartを改良した研究 (GT-91569)、実在気体や三次元流れ、スパン方向mixingの効果を導入したCFDベースの子午面流れ解析手法の開発 (GT-90851)、流線曲率法で用いる衝撃波モデルについて、翼間の衝撃波構造をもとに損失モデルを構築した研究 (GT-91701) などがあった。基礎的な研究として、エントロピー損失の評価に関して、エントロピー輸送方程式中で生成に寄与する各項をRANSとLESの結果で分析した研究 (GT-90126)、様々な気体で試験を実施し、等エントロピー指数によるタービン損失の変化を調査した研究 (GT-90251) があった。他に、Adjoint法を用いた空力最適化 (GT-91608) や、放射基底関数ネットワークを用いた新しい逆問題設計 (GT-91637) などの研究もみられた。

例年と同様に、LESの応用に向けた研究がなされており、LESにおける境界条件や入口乱れが検討されていた (GT-90747, 91622)。他にも、LESの実用化に関連して、タービン負圧面上のはく離遷移流れの予測についての検証 (GT-90214) や、表面粗さによって生じる流れ構造まで解像した計算を効率的に実施するための手法 (GT-90314) に関する発表があった。一方で、RANSによる定常計算でmixing planeによって失われるradial mixingの効果を渦粘性でモデル化することで予測精度の改善を図った研究 (GT-90363) や、効率的な非定常流れ計算手法であるNLH法についてより簡単に柔軟に定式化した手法に関する発表 (GT-91300) があった。

原稿受付 2019年7月29日

* 1 岩手大学理工学部システム創成工学科機械科学コース
〒020-8551 盛岡市上田4丁目3-5
E-mail: kyamada@iwate-u.ac.jp

その他には、ベアリングチャンバー内の気液二相の熱流体問題について、VOF、DPM（分散相モデル）、ETFM（薄膜モデル）を組み合わせた解析が多く研究されていた（GT-90146, 90264, 91314, 91323）。ま

た、遷音速のターボ機械において、渦や衝撃波、二次流れを解析するための新しい可視化手法（GT-91378）や、境界条件にペナルティー法を用いて安定化させたPODベースの縮約モデル（GT-90323）なども紹介された。

6. 伝熱関係

大北 洋治*¹
OKITA Yoji

1. 全般

Heat Transfer Committeeが主催した約50のセッションでは、例年よりやや少ない151件のTechnical Paperが発表された。GT伝熱研究の切り口が多様化し、分野間の境界も曖昧になってきているため、フィルム冷却、内部冷却といった従前の分類で論文数の推移等を議論することに意味がなくなりつつあるが、敢えて独断的に今回の傾向を言えば、アプリケーション別では、翼周りへの関心が依然きわめて高い一方で、燃焼器や2次空気システム関係の発表は例年より低調だった。また冷却アプローチの分類で言えば、相変わらずフィルム冷却への研究意欲が旺盛な一方で、内部冷却はネタが尽きてきた感がありつつも、Additive Manufacturing (AM) やAI適用にその活路を見出そうとしているように感じた。

2. 各論

2.1 フィルム冷却, 新コンセプト等

GT-91788は、一言で言えば、「RANSでフィルム冷却を計算することに意味はあるのか」という研究。結論としては、冷却空気が主流面に噴出した後に起こる拡散、混合はRANSでは再現が難しいものの、少なくとも冷却孔の中で起きている現象については十分に評価可能というもので、聴衆からの質疑も概ねPositiveな反応。主流側はあきらめてしまうのかとやや肩透かしを感じつつも、そう割り切った上で使い方を考えるのは実践的とも納得。

翼後縁は一般的に腹側をカットバックしてフィルム冷却を行うが、GT-91123は後縁形状を波型にすることで背側と腹側の両方をフィルム冷却するという新奇なアイデア。空力性能への影響や構造成立性など議論満載のコンセプトではあるが、似たような研究が多い中で、設計者に新鮮なヒントを提示している点で価値があり面白いと感じた。

GT-91375は、ファンダクトの吸音ライナのレゾネータで発生する“Synthetic Jets”の伝熱特性を調べたこ

れも目新しい研究であり、(明示はされていないものの) Surface Cooler等ファンダクト周りの熱交換デバイスへの適用が暗示されている。

GT-91548は、音響等により境界層に周期的な擾乱を与えることで、圧力損失等の空力特性には影響を及ぼさず、壁面近傍の伝熱促進あるいは熱流束低減が可能になる“Streaming”という現象／手法について、その解析法を論じている。この研究は、冷却噴流やフィルム冷却流のパルス化等の能動的な非定常性の活用や、主流の動静翼干渉による伝熱促進／伝熱抑制といった受動的な非定常性影響を、設計や解析で具体的に扱う際の方向性を示すものと感じた。

2.2 最適化

冷却翼のような入り組んだ系は、パラメタをいわずらに増やすことなく最適化するのが難しいが、GT-91208はスキュータイプの動翼端部というきわめて複雑な部位を、RR社の設計知見に基づいた形状の正規化によってエレガントにパラメタ化することに成功しており、エンジニアリングセンスを欠いた有象無象の最適化研究とは一線を画している。

GT-91004はAIによる最適化の将来像を垣間見た発表。昨年までは乱流モデルのモデル定数のチューニングにAIを使うといったレベルに留まっていたが、今年は、例えばGT-91004のようにタービン翼の伝熱解析等にAIを使った研究が報告された。現時点ではまだPrimitiveなレベルだが、数年内には実戦相当の設計最適化にReadyとなる勢いを感じた。

2.3 Additive Manufacturing (AM)

明示的なAM伝熱の企画セッションも組まれていたが、そこではもう取まりきれないほど、あらゆる伝熱セッションでAMに関連した発表が見られた。駆け足でサマライズすると、まずGT-91583はトランスピレーション構造への適用を前提に、AM品内部の空孔形状のばらつきおよびその伝熱特性への影響を評価、GT-90931はAM品の表面粗さに関する研究で、まず実機サイズで試作して粗さを測り、それをスケールモデルで再現して空力特性を評価。新奇な冷却コンセプトへの適用例としては、GT-91949のラティス構造、GT-91783のAuxetic構造(ポ

原稿受付 2019年7月16日

* 1 (国研) 宇宙航空研究開発機構 航空技術部門
〒182-8522 調布市深大寺東町7-44-1
E-mail: okita.yoji@jaxa.jp

アソン比が負の構造)等が新たに提唱された一方で、数年前から研究者達が注目している可動部を持たない自励掃引流発生デバイスについては今年もフィルム冷却への適用(GT-91678, 91696)や、インピンジ冷却への適用(GT-91897)等、複数の発表があった。

2.4 新しい試験リグ、計測法

GT-90483では、欧州プロジェクト“FACTOR”で新たに導入された燃焼器シミュレータを有する1.5段HPT試験リグが紹介された。RANS計算による比較も示しているが、下流のミキシングが過少評価されて実測値とあまり合致していないことを正直に課題として示していたのは興味深く拝聴した。

GT-90965は、GE社が新たに導入したラビリンスシール開発用の“ASTR”という試験リグの紹介。実機相当条件で試験できることはむろんのこと、シールが偏心している状態を模擬した試験も可能。

ペンシルバニア州立大のグループは、彼らが数年前に整備したタービンリグ“START”に適用する厚み4

μm の薄膜熱流束センサをGT-91817で紹介した。Short-duration型のリグで使われるセンサに比べて、STARTのような連続作動リグに適した耐久性を有している。

2.5 余談とまとめ

最後にやや余談的に補足。Heat Transfer Committeeのセッションではないが、2日目に、将来の航空推進(具体的には電動化)に関するPlenaryがあり、その中でGE社、P&W社、Honeywell社からの発表や意見交換あり。その中で、各登壇者から「電動化においては、モーターやバッテリー周りの熱マネジメント及びシステム排熱の再利用が、実用化のキーテクノロジーになる」という趣旨の言及が繰り返された。

まだまだ、翼周りの伝熱問題やフィルム冷却といった伝統的な切り口の研究が盛んな一方、これ等の推進技術全体の大きな動きや、上述のAIやAMといった新技術の適用フェーズへの加速感も肌で感じる事ができ、GT伝熱屋としての来し方行く末、これからのメシのタネのヒントをもらえる有用な講演会であった。

7. 燃焼および燃料関係

浅井 智広*1
ASAI Tomohiro

1. 概要

燃焼、燃料および排出物(Combustion, Fuels & Emissions)の分野では、論文セッションが31、パネルセッションが2、チュートリアルセッションが3の計36セッションが開催され、発表件数は論文発表122件、パネル発表8件、チュートリアル発表4件の計134件であった。今年は昨年の発表件数145件より10件ほど減少した。本分野の会合で今年の論文投稿の統計が報告された。アブストラクト提出数228件に対して、ドラフト論文提出数139件、却下3件、取り下げ86件であった。そのうち最終論文受理数は122件、却下14件、取り下げ3件であった。論文発表の筆頭者の所属を国別に分類すると、アメリカが34件と昨年と同様に最多で、次いでドイツ22件、イギリスと中国がそれぞれ14件、インド9件、イタリア8件、フランス6件、カナダ4件であった。アジアからは中国が最多の14件、韓国2件であり、日本は0件であった。来年の会議(イギリス・ロンドン開催)では、アブストラクト締切が2019/10/4、ドラフト論文締切が2019/12/4で例年に比べて締切までの期間が長くなったため、日本からの発表を期待したい。

論文発表を主なテーマ別に分類すると、「燃焼力学」が14セッション・50件と例年通り最多で、次に「燃焼器の設計・開発」が3セッション・10件、続いていずれも2セッションの「基礎燃焼」(8件)、「燃焼モデリング」(7件)、「新燃焼方式」(6件)の発表があった。また「環境汚染排出物の形成と制御」(7件)、「火炎の吹き飛び・逆火・着火」(6件)、「燃料効果」(5件)、「微粒化・噴霧」(4件)、「高濃度水素燃焼」(3件)の発表があった。

今年の特徴は、機械学習や人工知能(Artificial Intelligence: AI)に関する発表が新しく見受けられた点、および液体燃料に関する発表が多かった点である。特に、機械学習やAIに関する発表では、聴講者が多く議論も活発であったため、このテーマへの関心の高さがうかがわれた。また、今年もチュートリアルセッションが開催され、燃焼分野で著名なジョージア工科大(米国)のLieuwen教授が燃焼基礎や燃焼力学について講義した。このような講義を聴講できるのは貴重な機会であるため、来年参加する人はぜひ聴講してほしい。

2. 個別テーマ

2.1 燃焼力学

例年、このテーマの発表件数が最も多く、内容は火炎干渉、環状・多缶連成燃焼振動、燃焼振動制御、流体力

原稿受付 2019年7月16日

*1 三菱重工業(株)総合研究所 燃焼研究部
〒676-8686 高砂市荒井町新浜2-1-1
E-mail: tomohiro3_asai@mhi.co.jp

学的不安定性、回転デトネーションなど多岐にわたる。

火炎干渉では、旋回角が異なる複数の旋回バーナの火炎干渉を調べた研究 (GT-90679)、マルチノズルの燃料ステージングを想定し当量比が異なる複数のノズルの火炎干渉を調べた研究 (GT-91152, 91656) が報告された。環状・多缶連成燃焼振動では、缶型燃焼器を対象に、2缶の連成の振動メカニズムと振動抑制方法を実験で調べた研究 (GT-90327)、ノイズ・非線形性がキャニユラ型燃焼器の熱音響系に与える影響を解析で調べた研究 (GT-90546)、アニユラ型燃焼器の自励振動をLarge Eddy Simulation (LES) で調べた研究 (GT-90793) が報告された。燃焼振動制御では、主に減衰器による制御が報告された。アニユラ型燃焼器にて複数の減衰器の周方向配置の影響を調べた研究 (GT-90238, 91246)、減衰器内の温度分布を調べた研究 (GT-90239)、音響ライナの効果を調べた研究 (GT-90600) が報告された。流体力学的不安定性では、歳差運動する渦芯を対象に、乱流の影響を調べた研究 (GT-91095)、液体燃料の噴霧への影響を調べた研究 (GT-91619) が報告された。昨年
の新テーマであった圧力ゲイン燃焼は今年も論文セッションが開催された。天然ガスを燃料とした回転デトネーションエンジンの不安定性を解析で調べた研究 (GT-91643)、天然ガスと水素の混合ガスを燃料とした回転デトネーション燃焼器の不安定性を実験で調べた研究 (GT-90938)、回転デトネーションエンジンの非予混合燃焼を解析で調べた研究 (GT-91931) が報告された。

2.2 燃料多様化、高濃度水素燃焼

ガスタービンの標準的な燃料である天然ガスに加えて、水素や一酸化炭素などを含む多種燃料に対応した燃焼技術の研究開発が進められている。多種燃料の中で、近年は再生可能エネルギーの発電量増加に伴い、その余剰電力により製造した水素の利用が注目されている。水素と天然ガスの混焼を対象に、二段燃焼器の高圧単缶燃焼試験結果 (GT-90798) やマイクロミキサーの大気圧要素バーナ燃焼試験結果 (GT-90095) が報告された。水素以外の多種燃料については、製鉄過程の副生ガスである高炉ガス (Blast Furnace Gas : BFG) ・コークス炉ガス (Coke Oven Gas : COG) 焚き燃焼器の大気圧単缶燃焼試験結果 (GT-91360) や天然ガスの構成成分であ

るエタンの濃度の影響を調べた実圧単缶燃焼試験結果 (GT-90903) が報告された。

2.3 液体燃料

今年には液体燃料に関する発表が多かった。液体燃料の微粒化・燃焼のチュートリアルセッションや液体燃焼で課題となる煤のモデル化のパネルセッションも開催された。論文セッションでは、液体燃焼の燃焼振動に関する研究 (GT-91547, 91835)、積層造形 (Additive Manufacturing : AM) で製作した環状液膜型微粒化器の噴霧・燃焼特性を調べた研究 (GT-91624)、アニユラ型モデル燃焼器の壁面温度の影響と壁面モデルを評価した研究 (GT-91396)、歳差運動する渦芯が液体燃料の噴霧に与える影響を調べた研究 (GT-91619)、液体燃焼のレーザ計測 (GT-91177, 91971)、原油焚きノズルの高圧燃焼試験結果 (GT-90672)、横風中の液体噴流の噴霧・蒸発特性を解析で調べた研究 (GT-91972)、航空エンジン用燃焼器のエマルジョン燃料焚き燃焼特性を調べた研究 (GT-92039) が報告された。

2.4 環境汚染排出物の形成と制御

このテーマでは窒素酸化物 (Nitrogen Oxides : NO_x) と煤に関する研究が報告された。NO_xについては高温の横風空気流中に噴射されたメタン・エタン混合ガス噴流のNO_xを実験で調べた研究 (GT-90952)、希薄予混合火炎により形成されるNOへの圧力の影響を解析で調べた研究 (GT-91037) が報告された。煤については、原油に微量の金属を混ぜることによる原油燃焼の煤塵低減効果を実機ガスタービンで調べた試験結果 (GT-90380, 90382)、エチレンの層流・乱流火炎を対象に煤の成長・酸化の反応メカニズムのモデル化の研究 (GT-90873) が報告された。

2.5 機械学習, AI

今年には機械学習やAIに関する発表が新しく見受けられた。本分野ではバーナ火炎記述関数のデータ内挿・外挿に機械学習を活用した研究 (GT-91319) が報告された。また、電力分野のセッションであるが、発電用ガスタービン産業界でのAI活用 (GT-91963) が報告された。今後、このような燃焼分野への機械学習・AI活用に関する研究が増加すると考える。

8. 制御と診断

坂田 彬*1
SAKATA Akira

1. 全般

制御と診断関連の主管は、Controls, Diagnostics & Instrumentation (CDI) コミッティである。発表内容を制御 (Controls), 診断 (Diagnostics) および計測 (Instrumentation) に分け、これらのセッションを聴講した内容を報告する。

今年、制御と診断関連では、9セッションで27件の発表 (昨年比2件減) とチュートリアル・セッション1件があった (集計は筆者による。以下同様)。分野別の発表数は、制御が5件、診断が10件、計測が12件であった。国別構成は米国11件、中国4件、ドイツ3件、ベルギー3件、スウェーデン2件、イギリス2件、その他2件であった。全体を概観して、制御分野および診断分野では、エンジンモニタリングデータを活用した制御パラメータ同定や診断手法についての報告が盛んだった。また、計測分野では、圧力計測以外にも光学や音響技術などを応用した計測手法と活用例が多く報告された。チュートリアル・セッションでは、ガスタービンの過渡運転時のシミュレーションおよび制御についての発表がなされた。以下、個別に報告する。

2. 制御分野

制御分野は、制御トピックと先進制御の2セッションで5件の発表があった。

制御トピックでは、カルマンフィルタの応用として、テストセルの設備センサのノイズを低減した例 (GT-90116) や産業用ガスタービンに適用してモデル化した例 (GT-91413) が報告された。また、制御設計手法として、ターボプロップエンジン制御行列設計での非対角成分の分離手法の適用 (GT-90429) や、ターボファンエンジン向けセルフチューニング付き制御システムの提案 (GT-90118) があった。発表国は中国および韓国で占められていた。

先進制御では、NASAのGlenn研究所によるEAP (Electric Aircraft Propulsion) の制御に関連する課題をまとめた発表 (GT-91413) がなされた。ターボファンとモーターの統合制御をする必要があり、計測値のLimitが多岐にわたるため制御が複雑になること、またCertificateの枠組みも課題として挙げていた。電動推進

を機体側で制御するのか、エンジン側で制御するののかも議論の途中であるとのことであった。また、ターボファンとモーターの動力配分の設計については、加減速時の設計に左右されるとのことであった。今回の制御と診断関連では最も質疑が盛り上がった発表であった。

3. 診断分野

診断分野は、診断トピック、モニタリング、パラメータ推定の3セッションで10件の発表があった。

診断トピックでは、圧縮機のストール診断方法確立を目的とした圧力の計測および解析手法 (GT-90998)、音響センサでラム波を計測する欠陥診断手法の適用例 (GT-91111) や、ガスタービン診断手法であるデータ駆動型と物理ベース型の2手法の精度の比較 (GT-91644) が報告された。

モニタリングでは、汎用的なモニタリング手法として、エンジン計測項目に対応するモニタリングパラメータの選定方法提案 (GT-91018)、産業用ガスタービン向けのモデルベース故障診断手法の提案と適用例 (GT-90858) や、ヘリコプターのギアボックス振動モニタリング手法の改善提案と適用結果 (GT-91150) の報告がなされた。また、P&W社によるガスパス解析をフル飛行データに適用した結果の報告 (GT-90161) では、質疑が盛り上がり興味の高さを伺わせた。

パラメータ推定では、モニタリングデータを使った発表として、ガスタービン発電所の運転データに対するビッグデータ技術の利用例 (GT-91259) や、産業用ガスタービン燃焼室のエネルギーモデル推定 (GT-90273) の報告がなされた。また、乱流強度について計測データの不確かさを考慮した評価手法の発表 (GT-90461) があった。

4. 計測分野

計測分野は、圧力計測、表面計測、境界流れ計測、自由流れ計測の4セッションで12件の発表があった。

圧力計測では、マルチホールプローブに関して、AMを適用して形状の自由度を向上させたセンサ (GT-90079)、圧力室の膜の変位を光学的に計測することで動特性および耐EMI性を向上させたセンサ (同上)、5穴プローブの詳細特性 (GT-90470) や、9穴プローブの詳細特性 (GT-91428) の報告がなされた。また、シート型の半導体圧力センサによる壁面の流れ計測の発表 (GT-91681) があった。

表面計測では、高周波数の熱流速計測のためのサーモパイルの開発 (GT-91012)、アコースティックサーモグ

原稿受付 2019年7月24日

*1 (株)IHI 航空・宇宙・防衛事業領域
技術開発センター 制御技術部
〒196-8686 昭島市拜島町3975番地18
E-mail: sakata1375@ihi-g.com

ラフィを利用した欠陥の非破壊評価例 (GT-90260) や、エンジン外殻ケーシング温度から内部温度を熱伝導方程式で推定する手法の実験データとの比較 (GT-91105) が報告された。

境界流れ計測では、静圧軸受隙間内の感圧塗料を使った圧力分布計測の成立性検討 (GT-90288)、高高度用無人航空機向けの超小型ガスタービンに対して低レイノルズ数での低圧タービン負圧面のはく離流発生試験と

CFDの比較 (GT-91020) や、航空機エンジンに吸込まれる砂塵などの粒子を計測する光ファイバセンサの高温試験や耐久性試験の結果 (GT-91077) が報告された。

自由流れ計測では、エタノールとガソリン燃料混合物の噴霧特性をレーザー干渉計で計測した結果 (GT-91421) や、産業用ガスタービンの運転範囲拡大を目的に入口空気流量を直接計測する手法 (GT-91955) が報告された。

9. 材料, 構造および製造技術

石川 博司*¹

ISHIKAWA Hiroshi

1. 全般

材料, 構造および製造技術の分野では、製造と冶金 (Manufacturing Materials and Metallurgy) から34件, 構造とダイナミクス (Structures and Dynamics) から89件 (ロータダイナミクスとベアリングおよびシールドダイナミクスは除く) の発表があった。構造とダイナミクスの分野における内訳は、疲労・破壊および寿命予測が20件, 新設計手法が6件, 確率論的手法が12件, 空力振動および減衰が22件, 構造力学・振動および減衰が29件である。筆者が主に出席した積層造形 (Additive Manufacturing, AM), 疲労・破壊および寿命予測に関するセッションの発表内容について概説する。

2. Manufacturing Materials & Metallurgy

製造と冶金の分野では、12のセッションが開催され、内テクニカルセッションが7件, パネルセッションが2件, チュートリアルセッションが2件, ディスカッションセッションが1件であった。

積層造形 (AM) に関しては8件の発表があり、いずれの会場も立ち見が出るほどの盛況であり、AM技術に対する関心の高さを感じた。実機適用に向けた報告が多数あり、Solar TurbinesからはInconel738LCを電子ビームにより積層した2段動翼の実機適用に向けた検証状況の報告 (GT-90966)、並びに燃料ノズルを対象とした断層撮影 (CT) 並びにECI (渦電流検査) による積層造形時の材料欠陥に関する研究報告があった (GT-90971)。また、TiAlによるターボチャージャホイール作製の事例紹介もあり、余熱 (850°C) と酸素濃度の制御が材料健全性のポイントであるとの報告内容であった

原稿受付 2019年7月5日

* 1 三菱重工業(株) 総合研究所 強度・構造研究部
強度第二研究室
〒676-8686 高砂市荒井町新浜 2-1-1
E-mail: hiroshi_ishikawa@mhi.co.jp

(GT-90947)。なお、AMの実用化に向けた事例については、本セッション以外でも多数の発表があり、Siemensから大型ガスタービンのリングセグメントへの適用に向けた検討状況の報告 (GT-90344, 90227)、航空用マイクロタービン向け熱交換器 (GT-90978) 等も参照されたい。

また、コーティングに関しても11件の発表があり、内7件が遮熱コーティング (TBC) に関する研究であり、界面形態にフラクタルを用いた解析的な研究 (GT-91722)、コーティングの残留ひずみに着目した研究 (GT-91013, 90828)、レーザー走査による円板熱サイクル疲労評価 (GT-90210) などの報告があった。

更に、ろう付けに関するチュートリアルセッションに出席したが、製造や補修時の重要な接合技術であるにも関わらず、企業ごとにノウハウがあるため開示された技術情報が乏しく、全米でも4大学でしか研究が行われていない等説明があり、ろう付けに関する基本的な事項から適用事例までを学べる貴重な機会を得た (GT-92148)。

3. Structures & Dynamics: Fatigue, Fracture & Life Prediction

疲労・破壊および寿命予測の分野では、5つのセッションが開催され、すべてがテクニカルセッションであった。寿命予測並びにクリープモデリングに関しては、合計9件の発表があった。内5件がクリープ速度の予測に関する研究であり、データ取得に長時間を要するクリープ速度データについて、応力急変法 (GT-91137)、応力緩和挙動からの推定 (GT-90616)、 θ 法などの既存式の改良 (GT-90625, 90267, 90637) による予測に関する報告があり、質疑応答時には、長時間負荷中の材料組織変化の考慮が必要等の意見もあった。

疲労き裂発生並びに進展に関しては、合計7件の発表があった。低サイクル疲労を対象とした寿命評価パラメータに関する研究成果 (GT-91572)、中空円筒試験片を外面加熱/内面冷却することによる温度勾配下での低

サイクル疲労寿命への影響評価 (GT-91450)、実機翼を対象としたき裂進展評価事例 (GT-91630) 等が報告された。

更にGT運用多様性の要求の高まりに伴い、運転中の材料挙動を忠実に表現することで、寿命予測精度の向上を狙った非弾性構成式に関するセッションも設けられた。クリープ並びに応力緩和に着目した研究 (GT-91521)、一定温度下におけるクリープ疲労時のヒステリシスループの評価 (GT-91695)、Ni基単結晶合金を対象とした結晶塑性による評価 (GT-91903)、多軸及び非比例荷重下での寿命評価パラメータに関する検討結果 (GT-90174)、一方向凝固材や単結晶の異方性を考慮した熱疲労挙動評価 (GT-90142) があり、多くはChaboche型の粘塑性構

成式を用いた評価であった。更に別セッションではあるが、燃焼器ライナを対象に、CFDとFEMを結合した熱疲労評価内でも本構成式の適用事例 (GT-90897) があるので合わせて参照されたい。

なお、蒸気タービンのセッションにおいても、クリープ疲労寿命評価の概論、並びに従来の累積損傷評価に替わる確率的評価や構成式による研究状況 (GT-92133)、運転履歴・材料データ・損傷クライテリアに確率分布を与えた寿命評価の研究状況 (GT-91297)、粘塑性構成式に基づく寿命評価状況 (GT-90909, 91450)、Ni基超合金を対象としたクリープ疲労及び熱疲労下のき裂発生並びに進展の波形 (OPとIP) 効果に関する研究 (GT-92028) が発表されており、合わせて参照されたい。

10. ロータダイナミクスとベアリング

金子 康智*¹

KANEKO Yasutomo

1. 全般

この分野は、シールや軸受を含めたロータの振動に関連する講演と、翼振動に関連する講演とに大別できる。ロータの振動に関しては、ロータダイナミクス (15件)、流体軸受 (9件)、スクイーズフィルムダンパ (3件)、気体軸受 (10件)、磁気軸受 (4件)、シール (19件)、設計法 (3件) のセッションがあった。また、翼振動に関しては、翼振動と減衰 (28件)、および翼に作用する加振力 (22件) のセッションがあった。通常の講演の他に、ロータの曲げ振動 (GT-92071, 92345)、ねじり振動 (GT-92091)、API規格への対応 (GT-92138)、および翼振動の概要 (GT-92069) に関するチュートリアルが行われた。それぞれのチュートリアルでは、各分野の経験豊富なエンジニアが現場の事例を交えて分かり易く解説していた。

2. ロータダイナミクス

様々な力学的特性を有するロータを適切な手法でモデル化し、振動特性を解析している論文が多い。具体的には、スピンドルボルトのコンタクト剛性を考慮したロータの振動解析や最適化 (GT-90256, 90573, 90396)、部分構造合成法による非対称ロータの振動解析 (GT-90598)、ファンブレード飛散時の非線形振動解析 (GT-90367)、ベベルギアで結合された軸系の振動解析 (GT-91445) などが報告された。

3. ベアリング

数値解析を利用して動特性の解析を行い実験と比較した論文、あるいは巧妙な計測手法を利用して軸受の特性を調査した論文が多い。具体的には、コンタクト部分の非線形性 (摩擦や隙間) を考慮したバンパフォイル軸受の解析 (GT-90494)、油膜への気泡の混入を考慮したスクイーズフィルムダンパ軸受の解析 (GT-90330, 91285)、テイルテイングパッド軸受の動特性の周波数依存性の解析 (GT-90195)、パッドやライナーの材料がテイルテイングパッド軸受の特性に及ぼす影響の解析 (GT-90231) などが報告された。

4. シール

バルクフロー理論やCFDを利用して様々なシールの動特性を解析し実験と比較した論文、あるいはシールの動特性に及ぼす二層流などの影響を実験的に調査した論文が多い。具体的には、バルクフロー理論によるポケットダンパシールの動特性の解析と実験 (GT-90059, 90331)、遠心圧縮機のラビリンスシールの動特性に及ぼす偏心の影響の解析と実験 (GT-90237, 90669)、ポンプ用アニュラーシールの動特性に及ぼす予旋回流の影響の実験的検証 (GT-90113)、ハニカムシールの動特性に及ぼす二層流の影響の実験的検証 (GT-91824, 91831) などが報告された。この他にも、プレートシール (GT-90962)、溝付きシール (GT-90254, 90499)、ホールパターンシール (GT-90776, 90846) など、様々なシールの動特性の解析結果や計測結果が報告された。

原稿受付 2019年7月1日

* 1 龍谷大学 理工学部 機械システム工学科
〒520-2194 大津市瀬田大江町横谷1-5
E-mail: y_kaneko@rins.ryukoku.ac.jp

5. 翼振動

翼振動の講演は、ミスチューン現象の解析、ダンパ翼などの非線形振動の解析、非定常流体力による応答解析（フラッタを含む）に大別できる。ミスチューン現象の解析モデルは年々緻密になっており、大規模な幾何学的ミスチューンを考慮した解析（GT-91094）、異方性翼（シラウド翼）に対して結晶方向の変動と摩擦減衰の変動を同時に考慮した解析（GT-90629, 90632）、加振試験結果からミスチューンを同定する方法（GT-91072）、インテンショナルミスチューンによる応答低減（GT-92047）などが報告された。非線形振動の解析では

従来通り摩擦減衰や大変形解析を取り扱った論文が多く、大規模な幾何学的非線形性を取り扱った解析（GT-91213, 90813）、プラットフォーム型ダンパ翼の最適設計（GT-90416, 91040）などが報告された。非定常流体力による応答解析では、CFDとFEM（またはその低次元モデル）を利用して共振応答や空力減衰を解析した結果（GT-90105, 90387, 81832）などが報告された。特にGT-81832では、摩擦減衰を有する翼構造ではフラッタ発生時に複数のモードのリミットサイクルが生じることを大規模なモデルで検証しており興味深かった。

11. 蒸気タービン

渋川 直紀*1
SHIBUKAWA Naoki

概要

発表論文数は34編で、2014年の51編をピークとした漸減傾向が継続し、前年度37編からも微減となったが、テクニカル、パネル、チュートリアル3種類のセッションが期間中を通じて同一室で運営され、リラックスした雰囲気でのディスカッションがなされたので、蒸気タービン仲間の顔がよく見え、居心地のよさを感じることができた。

テクニカルセッション

負荷変動対策や信頼性評価に関するテーマが目立ったのが特筆すべき点である。急速起動に対応したタービン予熱システムについて、非定常温度・熱伸び解析を含む内容でSiemens（GT-90464）、Aachen工科大とGEの共著（GT-90580, 90761）から競うように発表され、活発な議論が交わされた。また、フレットングによる疲労破壊形態の現象説明（Sulzer, GT-90106）や、Darmstadt大を中心としたチームによるクリープ疲労評価新規格策定を目指した研究プロジェクト（GT-91450）などにも注目が集まった。さらに、チュートリアルのテーマも「クリープと疲労負荷環境下での亀裂初生と進展」と題して多くの聴衆を集め、蒸気タービンセッション全体としての一貫性を感じた。

一方で、会議初日には毎年の定番として低圧最終段セッションが3枠連続で設定され、連結構造の空力損失（Stuttgart大, GT-91815）、試験タービン全体をプローブまで含めて詳細に模擬した大規模解析（MHI, GT-90640）、世界最長級のチタン最終段翼の包括的開発

（MHPS, GT-90003）などが注目を集めた。

発表者別にみると、Stuttgart 大、Aachen工科大、Darmstadt 大やドイツの大学からの発表が目立ち、次いで中国の企業、大学が続いた。国内からはMHIとMHPSから計5件が発表され、存在感を示した。

パネルセッション

3日目の午後2枠がパネルセッションに割付けられ、聴講者とのオープンな議論が交わされた。今回のテーマは「Clean Energy with Steam Turbine Technology」で、蒸気タービンメーカーにとっては難題であったが、MHPS, GE, Siemens, 上海電気, 東芝エネルギーシステムズの各社（Doosanはキャンセル）から、限界に迫るUSCの高効率化、コンバインドサイクル高性能ユニット、太陽光発電、再生可能エネルギー主導を想定した調整火力、新概念火力発電プラント、超臨界CO₂タービン等に関する開発状況など様々なトピックが誠実に紹介された。聞き手からは、調整火力としての部分負荷運用に向けた開発目標、水素燃焼や新媒体タービン等の次世代サイクルの可能性、その普及形態や市場規模感などの質問が寄せられた。さらに、これからの開発は何を目指せばよいのか、といった漠然とした質問も投げかけられたが、確固とした答えはなく、蒸気タービン関連の研究開発方向性が模索されている印象であった。

委員会活動

第3日の夕刻に、蒸気タービン委員会（Committee Meeting）が開催され、運営、発表などで定着したメンバーに新規加入の面々が加わり、論文数統計紹介、活動報告、幹事引継ぎ、表彰、来年のパネルセッション候補選定など、なごやかながらも活発に議論された。続いて会場近隣のレストランに場所を移して企画されたディナーにも約20名が参加、研究開発の動向からプライベートな話題まで、賑々しく交流が図られた。

原稿受付 2019年7月19日

*1 東芝エネルギーシステムズ㈱
エネルギーシステム技術開発センター
〒230-0045 横浜市鶴見区末広町2-4
E-mail: naoki.shibukawa@toshiba.co.jp

12. 展 示

松沼 孝幸*1

MATSUNUMA Takayuki

展示会は、TURBO EXPO期間中（5日間）のうち2日目から4日目までの3日間（6月18日から20日）、会場のフェニックスコンベンションセンター地下1階のExhibit Hallで開催された。開催時間は、最初の2日間は12:30-18:30、3日目が11:30-14:30であり、昼食頃に展示が始まった。例年どおり、昼食会場に行くまでには必ずこの展示会場を通るように配置されているため、特に昼食時から午後のセッションが開始する14:00頃まで、多くの参加者が来場した。さらに、18日と19日の夕刻には、展示会場にてレセプションが開催され、参加者がビールなどを手に歓談・商談をして賑わった。

展示ブースは、北米開催のためか、合計119件と例年よりも多かった。国別で見ると、米国が80件と圧倒的に多く、カナダ3件を含めると、北米で83件となり、全体の70%近くを占める。次いで、イギリス12件、ドイツ9件、フランス4件、ベルギー3件、イタリア、オランダ、スイス、ロシア各1件、とヨーロッパ勢が合計32件（全体の27%）を占めた。その他の地域は、日本からは2件、シンガポールと南アフリカが各1件であった。地元フェニックスでの開催とあって、ハネウェルがTURBO EXPOゴールドスポンサーになっていた。ガスタービンメーカーを始め、計測機器や部品メーカー、流体・構造解析のソフトウェアなどの企業が多く出展し、活発な展示を行っていた。NASA、NETL、カナダ国立研究所などの公的研究機関、ペンシルベニア州立大学、テキサスA&M大学、デルフト工科大学、シュツットガルト大学などの、大学からの展示もあった。日本からは、優れた5軸マシニング技術を有するアイコクアルファ株式会社、そして日本ガスタービン学会が出展していた。

分野別に見ると、コンサルティング・エンジニアリングサービス29件、試験計測19件、ソフトウェア・コンピュータハードウェア17件、アディティブ・マニファクチャリング14件となっており、製品別で見ると、ガスタービン29件、蒸気タービン17件、圧縮機12件、ファン・ブロワー11件、風力タービン10件となっていた。

ガスタービンメーカーとしては、ハネウェルやブラットアンドホイットニーが出展していた。ハネウェルはHTF7000ターボファンエンジンのカットモデルを展示していた。入口すぐには解析ソフトウェアベンダー ANSYSの大きなブースが設置され、複数の大型

ディスプレイで解析結果を表示して目立っていた。また、表面処理技術のMMP (Micro Machining Process) Technologyも大きなブースを出展していた。どの展示者も、多くの人に来場してもらえるように様々な工夫をしており、例えば、アディティブ・マニファクチャリングのメーカーは多数の製作見本を展示し、センサーや計測器のメーカーはデモ機器で実演するなど積極的な展示をしていた。

展示会場の一角には、ステージが用意され、30分のプレゼンテーションが13件行われた。ANSYS社が3件、SoftInWay社が2件のプレゼンテーションをするなど、特にソフトウェア企業が自社技術の紹介に力を入れている。また、NETLによる米国DOEの先進タービンプログラムの概要なども発表された。集客は毎回10-20名程度でそれほど多くはないが、詳しい説明を聞ける良い機会になっていた。

展示会場では同時に学生のポスター展示も開催された。展示初日の昼には、発表者によるポスターセッションもあり、活発な議論が交わされていた。展示されたポスターは46件で、昨年の41件よりも多くなっていた。国別では、米国16件、韓国9件、イギリス5件、カナダ、ドイツ、ベルギー、インド各2件、フランス、ハンガリー、オーストリア、スウェーデン、イタリア、イスラエル、中国、オーストラリア各1件と続いた。米国に次いで、韓国が2位になっていたのが意外であった。

展示会場の奥には、今回の目玉として、ジェットエンジン駆動のドラッグスター TURBINATOR IIが展示された。昨年10月にユタ州のボンネビル・ソルトフラッツでDave Spangler運転手によって503.332mph（時速約805km）を達成し、車輪駆動の世界最速記録を保持した車である。TURBINATOR IIは、長さ約11mで、チヌークヘリコプター用のライカミング社（現ハネウェル社）製タービンエンジン（5,000馬力）を用いている。世界記録を達成した時のビデオも上映されていた。

2014年から続いている日本ガスタービン学会からの展示ブースでは、国際委員や学会員が交代で展示対応を行っていた。今回は、今年11月に開催される2019年国際ガスタービン会議東京大会（IGTC2019）に力を入れて紹介していた。学会案内とIGTC開催案内を収めたお寿司柄のクリアファイルが250部配布され、ガスタービン学会の活動を宣伝する良い機会となった。日本のガスタービン関係者の拠点として、懇親を深められる場所にもなっていた。

展示最終日の昼休みには、展示会場内のプレゼン

原稿受付 2019年7月17日

*1 国立研究開発法人 産業技術総合研究所
〒305-8564 つくば市並木1-2-1
E-mail: t-matsunuma@aist.go.jp

テーション会場にて、Closing CeremonyとTurbo Expo 2020のキックオフが行われた。優秀学生ポスター賞や優秀展示賞などが表彰され、来年のロンドンでの再会を期待しての終了となった。



図1 展示会場の様子 (ASME/IGTI提供)

高効率 5 MW級ガスタービンコージェネPUC50D

High Efficiency 5 MW Class Gas Turbine Cogeneration PUC50D

久保 博史*¹
KUBO Hiroshi

寺内 晃司*¹
TERAUCHI Koji

笠 正憲*¹
RYU Masanori

キーワード：ガスタービン，コージェネ，効率，エミッション

Key Words：Gas Turbine, Cogeneration, Efficiency, Emission

1. はじめに

コージェネレーション（以下、コージェネ）は、省エネルギーやCO₂削減を目的として導入が進んできた。近年では系統電源に対するエネルギーセキュリティ確保の観点から、分散型エネルギーシステムとしての価値も評価されている。


川崎重工業では1983年に自社開発のガスタービンを用いた1 MW級のコージェネを市場投入して以来、これまでに1万台以上のガスタービンを生産してきた。当社は、1 MW級～30MW級に至るラインナップを揃え、常に高性能な新製品開発や製品改良を行ってきた。本稿では、当社が長年培ってきた開発力を結集して製品化した、5 MW級のM5A-01Dガスタービンと同機を用いたPUC50Dコージェネシステムについて紹介する。

2. M5A-01Dガスタービン

Fig. 1にM5A-01Dガスタービンの主要諸元と鳥観図を示す。M5Aはカワサキガスタービンのラインナップを拡充する新機種で、発電用途、特にコージェネ用途向けに開発された産業用ガスタービンである。

Fig. 2に市場のガスタービン発電装置の出力と効率の関係を示す。発電端効率は5 MW級のガスタービンの中で卓越して高く、高効率機種のトレンドからも抜きん出た高効率を実現している。また、排熱回収に適した排ガス温度の設定により総合効率にも優れる。

設計開発においては、実績がある機種の信頼性を継承するため、これらの既存モデルをベースとし、従来からの材料やコーティングなどの確立した技術などを引き継いだ。その上で、高効率、環境性能、コンパクト、整備性、運用性などの特長を高いレベルで実現することを技術上の課題とした。以降に、M5Aガスタービンの各構成要素への適用技術について述べる。



形式	単純開放サイクル1軸式
圧縮機	11段軸流式
タービン	3段軸流式
燃焼器	6缶型
発電端出力	4.71MW
発電端効率 (LHV基準)	32.6%
排気温度	511℃
エミッション	NOx:52.5ppm以下 (O ₂ =0%)

ISO条件，吸排気圧損無し，100% CH₄

Fig. 1 M5A-01D GasTurbine main specifications




Fig. 2 Power output vs Electrical efficiency
(Output:1 ~ 40MW)

原稿受付 2019年7月26日

* 1 川崎重工業(株) エネルギー・環境プラントカンパニー
エネルギーシステム総括部
〒673-8666 明石市川崎町1-1

2.1 圧縮機

実績のあるM7A-03Dガスタービンの圧縮機を基に、M5Aの空気流量に合うように設計した。小型化に対し、広い作動範囲で高効率を維持するため、全翼に最新の開発で技術開発した最適化翼型を採用するとともに、全段の流れ解析 (Fig. 3) で最適化を行っている。




Fig. 3 Flow analysis of all compressor stages

2.2 燃焼器

燃焼器は整備が容易な缶型DLE燃焼器を採用した。パイロット、メイン、追焚の3つのタイプの燃料ノズルにより、各ノズルへの燃料流量を制御し、最適な希薄予混合燃焼条件を維持することで、幅広い運転範囲で低エミッションを実現している (Fig. 4)。




Fig. 4 DLE combustor

2.3 タービン

最近の開発で実証された高負荷設計技術により、M5Aのタービンは従来より段数を減らし、冷却部品の数と必要な冷却空気量の低減を実現している。また、全段流れ解析 (Fig. 5) を活用して形状を最適化することにより、高い効率を実現した。




Fig. 5 Flow analysis of all turbine stages

2.4 構造

ガスタービンの吸気側端面が減速機に組付き一体となる。これにより、アライメントの調整が不要で、整備停止時間の短縮に寄与している。ケーシングは軽量、コンパクトなリングケーシング構造を採用している (Fig. 6)。



Fig. 6 Casing structure

3. PUC50Dコージェネレーション

PUC50Dのコージェネ性能をTable 1に示す。発電端効率は31.9%と同クラスのガスタービンに比べ約3ポイント高い。また総合効率も84.6%と同クラスに比べ約4ポイント高く、優れた経済性を有している。NO_x値は50～100%負荷の範囲で52.5ppm (O₂=0%) を達成し、同クラス最高の環境性能となっている。

PUC50Dコージェネを導入した場合のCO₂排出量の削減効果をFig. 7に示す。PUC50Dは従来型システム (商用電力とガス焚ボイラ) と比較して、CO₂排出量は約25%削減が見込まれる。

Table 1 Cogeneration specifications

機種	PUC50D	
ガスタービンモデル	M5A-01D	
発電端出力	kW	4,440
燃料消費量	Nm ³ /h	1,235
送気蒸気量	kg/h	10,480
発電端効率	%	31.9
熱回収効率	%	52.7
総合効率	%	84.6
NO _x 値 O ₂ =0%換算 (DLE運転範囲)	ppm	52.5 (50～100%負荷)

吸気温度：15℃、大気圧力：101.3kPa (高度0m)
 吸気圧損：0.98kPa、排気圧損：2.94kPa
 燃料：都市ガス13A
 排熱ボイラ：蒸気圧力 0.78MPaG、給水温度60℃




Fig. 7 CO₂ emissions reduction effect^(*)
 (*1) CO₂排出係数 商用電源0.496kg-CO₂/kWh、
 都市ガス2.29kg-CO₂/m³N

発電装置の外観図をFig. 8に示す。更新需要にも対応可能な、同クラスの発電装置の中で最もコンパクトな設置面積としている。




Fig. 8 PUC 50D generator appearance

PUC50Dの標準コージェネ設備の配置図をFig. 9に示す。寸法は長さ23,500mm×幅13,500mmである。排熱ボイラはPUC50D用に高効率・コンパクトな水管式ボイラをシリーズ化した（川重冷熱工業製）。




Fig. 9 PUC50D standard layout
(幅13500mm × 長さ23500mm)

4. メンテナンス

ガスタービンのメンテナンスは、年に一度のボアスコープ点検（以下、BSI）と、4年ごとにオーバーホール（以下、O/H）によるエンジン交換を設定し、1年間連続運転を可能とした（Table 2）。BSIは、複数箇所に設けられた点検孔から直視もしくはボアスコープ（内視

鏡）による点検により、主要ケーシングを分解することなく作業可能である。燃焼器は、BSIの際に現地に交換も可能である。O/Hは、エンジンのトレードイン交換方式を採用することで、整備停止時間を短縮している。

エンジン監視/保守システムとして、「テクノネット」と呼ばれる遠隔監視システムによって1日24時間、1年365日サポート体制を整備している。さらに、ユーザーのトレンドデータから将来の需要を予測するエネルギー管理システム（EMS）を採用し、ユーザーの運用上の利点を最大化することが可能である。

Table 2 Standard maintenance schedule

Year	1	2	3	4	5
BSI	I	I	I		I
O/H				I	

5. 運用実績について

PUC50Dコージェネ量産初号機（Fig. 10）は国内のユーザに納入し、2018年7月から運用を開始し運用期間は1年を超えた。順調に運用実績を重ねており、点検により健全性を確認している。今後も引き続き経過観察を行い、運用実績とともに耐久性および信頼性を実証する。



Fig. 10 The fleet leader of M5A

6. おわりに

本稿では、M5A-01Dガスタービンと同機を用いたPUC50Dコージェネシステムについて紹介した。

近年のエネルギー環境やCO₂排出量削減の要望などから、ガスタービンにはより一層の高効率化が求められており、当社ではこれらに応えるためにガスタービンの効率向上、低エミッション化の取り組みを継続的に実行する。

デジタルツイン・コンセプトによるガスタービンの性能 シミュレーションと性能トレンドの監視

Gas Turbine Performance Simulation and Status Tracking Based on Digital Twin Concepts

カーステン・クステラー*¹
Karsten KUSTERER

杉本 隆雄*¹
SUGIMOTO Takao

イエング・ディックホッフ*¹
Jens DICKHOFF

キーワード：ガスタービン，デジタルツイン，デジタルハブ，熱サイクルモデリング，運転監視，性能劣化予測，メンテナンス計画

Key Words：Gas Turbine, Digital twin, Digital hub, Thermodynamic Cycle modeling, Fleet monitoring, Performance tracking, Deterioration prediction, Maintenance scheduling

1. 緒言

近年はガスタービンのような複雑な機械で測定された多量の運転データをデジタルデータとして活用することが国際的なコミュニティの議論の場で注目されている。そのようなデータは、現場での運転操作やOEMでのデータベースなどに活用することが可能で、さらに特殊な条件下での機械の挙動、機械寿命の消耗と残存寿命のシミュレーションなどの課題にも応えることができる。

そのようなデジタルデータは‘デジタルツイン’(digital twins)と呼ばれて目的が明確に定義されているが、そのアプローチにおける制限がどこにあるのか、そして既存のソフトウェアやデータシステムを利用してどのように構築するかについては必ずしも明確でない。

B&B-AGEMA社はハイテク分野におけるサービスプロバイダーとして、ガスタービンの設計と運転に関する将来展望を提供するための努力を継続している。またそれによって、タービン技術者が先進的なタスクを遂行できるようにサポートすることができる。

2. 概要および特徴

当社では先端技術分野の課題解決のためにユーザーの要求に基づいた設計計算を実行し、シミュレーションソフトウェアを開発している。そして課題解決の課程で得られたツールのうちの幾つかは、次に示す商用コードとして製品化している。

***CHTflow** (Conjugate Heat Transfer & Flow)^{(1),(2),(3)}
流体内部、流体と固体の間の熱伝達、固体内部の熱伝導を結合して一体解析するCFDベースの解析ツール。このCHT技術はBohnらが1990年代に初めて開発した。

***TDT** (Thermodynamic Design Tool)⁽³⁾
高精度のガス特性データを内部に持ち、熱力学サイクル

を効率的にモデリングできる設計ツールで、豊富な応用事例によって精度が十分に検証されている。

***ACF** (Axial Compressor Flow)⁽³⁾
2次元の流線曲率法による軸流圧縮機の設計コードで、豊富な実績を持ち十分に検証されている。

***ATF** (Axial Turbine Flow)
1次元のタービン性能計算ツール(ATF-1D)および2次元の流線曲率法によるタービン性能計算ツール(ATF-2D)より構成されている。

***CSC** (Combustion Stability Control)
ガスタービン燃焼器における燃焼振動挙動の計算、解析およびチューニングのためのツール。

***GTPtracker** (Gas Turbine Performance Tracker)⁽³⁾
オンライン状態のガスタービンの測定データの編集、分析およびトレンドの監視、ならびに部品劣化の予測および整備間隔を最適化するためのツール。

***GTPsim** (Gas Turbine Performance Simulation)⁽⁴⁾
産業ガスタービンや航空エンジンの主流と二次空気流れについて、熱的要素を含む物理的モデリングとデジタル環境下でのシミュレーションを行うためのプラットフォーム。定常状態と非定常状態の両方を扱うことができる。

以上のうち、GTPtrackerやGTPsimなどのGTPソフトウェアは‘デジタルツイン・コンセプト’に基づいてガスタービン本体や周辺部のデジタル表現を作成し、目的とする処理をデジタル的に行う。またそのデジタル表現は、忠実度を高めるために継続して改良を行っている。

一般的に‘デジタルツイン’としては(1)既存のハードウェアの物理的特性をデジタル的に再現する‘デジタル双子’と、(2)現実のハードウェア機器(兄弟)を持たない仮想のデジタル表現とに区別されるべきで、後者は将来製品の表現であり、それによって試験機が稼働するよりも先にその動作を予測し、実用化するよりもずっと以前から製品の最適化を行うことができる。

原稿受付 2019年6月29日

*1 B&B-AGEMA GmbH
E-mail: eao@bub-agema.de

3. GTPtrackerについて⁽³⁾

GTPtrackerは、発電プラント全体、航空エンジン、産業ガスタービン、有機ランキンサイクルなどについて(1)のカテゴリの‘デジタルツイン’を作成する。最新版では周辺機器も含めることができる。

このツールは、オンライン上の機器の稼働状態を追跡し、その運転状態、故障の検出、劣化状況や欠陥部位を予測するなどの機能を持ち、ガスタービンの運転操作をサポートするために開発された。すなわちリアルタイムの性能、振動、オイル系統など、さまざまな機械パラメータを収集し、その後データは構造化、編集、グラフィック処理を行う。それらの処理データへはGTPtrackerの実行バージョンや任意のブラウザを使ってWeb経由でアクセスすることができる。このツールによって世界中のどこからでも、端末やOSに関わりなく柔軟にデータにアクセスすることができる。そして収集および処理されたデータを技術者が分析することで、実機の作動状態をより良く理解し、改良設計の方針を立てるのに役立つ。

GTPtrackerは、運転パラメータについて独自の物理ベースのルールセットによって関連付けられた重要なパラメータを識別する。運転性能データがルールセットと一致すると、タービン要素の劣化や損傷モードとして示される。それは自動的に検出され、メンテナンス計画を支援するための情報に変換される。これによってメンテナンス間隔をより適切に計画し、計画外停止を回避することができる。そして整備計画の改善により、停止時間と整備コストが削減されると共に、致命的な障害のリスクが大幅に削減される。その結果として製品のライフサイクルコストを最小化することができる。

さらにGTPtrackerは、同系機種の中での異なる個体のガスタービンのデータや各種のデータシステムを組み合わせ、その機種の全体像をより良く把握をすることもできる。

4. GTPsimについて⁽⁴⁾

GTPsimは、あらゆる種類のガスタービンをモデル化するためのシミュレーションツールであり、(2)のカテゴリ

の‘デジタルツイン’を実現できる。さらに多くの用途をカバーし、各種の構成要素を組み合わせる構造のために、非常に柔軟なツールになっている。基本的なガスタービン要素に加えて、複雑な二次空気系統(SAS)や熱容量要素を加えた点が従来のサイクル計算ツールよりも優れている。また要素の組み合わせは無制限であり、エンジン本体と周辺のアクセサリとの相互作用を分析することも可能で、主流ガスやSAS、および熱伝達要素を完全な共役モデルとすることで、シミュレーションの精度が向上する。さらに設計点の計算、定常状態や過渡状態のシミュレーションによって、熱力学的サイクルの正確な予測が可能になる。このためSASを省略したサイクルモデルと比べて計算の自由度が大幅に増加して並列計算が可能になり、複雑なモデルの計算時間が大幅に短縮される。

GTPsimの応用例として、ハイブリッド式のコミューター航空機の推進システムの開発に使用された例⁽⁴⁾があり、離陸時のエンジン性能シミュレーションを行っている。さらにFig. 1には、GTPsimでモデル化した二軸産業用ガスタービンに関する完全共役なCycle-SASモデルを示す。

ここでは3つの主要要素、つまり圧縮機、燃焼器、タービンに加えて、単純化されたSASシステムが示されている。さらに中間セクション、タービン車室、第1段静翼部などについての熱容量モデルを含んでいる。このモデルによって、始動時の過渡熱伝達、負荷遮断および部分負荷への急激な変化の際に生じる各部の変化についての正確な情報を得ることが可能になる。

Fig. 2はこのモデルを使った負荷遮断時の性能パラメータを示す。上から順に、圧力比、出力タービン回転数、タービン入口温度、冷却空気量比の過渡的变化を示しており、熱容量モデルによって忠実度が高いシミュレーション結果が得られている。

このGTPsimの結果から、LCF寿命やTMF寿命を計算する際に必要になる時間依存の熱伝達係数を抽出して、FEM構造解析ソフトで使用することができる。すなわち起動中のガスタービンのSAS系の空気温度は、比較的高い熱慣性を持つロータおよびケーシングなどの温度に




Fig. 1 Gas Turbine Cycle and SAS system including heat capacity elements modeled with GTPsim




Fig. 2 Load shedding simulation with GTPsim

強く影響されるが、これらの熱容量効果は、FEM構造解析ソフトにインポートする熱伝達係数や基準温度など、境界条件の予測精度を上げるのに有効である。そしてGTPsimによって得られる正確な境界条件によって、過渡熱応力や部品の寿命評価の精度を向上することができる。

5. 今後の方向

当社は今後、Fig. 3に示すようなGTPsimをハブとしたデジタルツインシステムの拡張を計画している。この場合のハブはインテリジェントなコントロールセンターとして機能し、モデリング精度の欠陥を検出し、実装された専用インターフェースを介して付属のソフトウェアパッケージを稼働させてその欠陥を補うことで、より成熟した‘ツイン（双子）’を構築することができる。

ここでのGTPsimは、ユーザーがモデル化した定常条件でのガスタービンの基本熱力学モデルとSASシステムを表すデジタルハブとして機能し、設計点以外の動作点をモデル化する際の精度を向上させるために、周辺に付帯したソフトウェアパッケージのどれを呼び出すべきかを自動的に決定する。例えば圧縮機マップについては、設計点外となる対象部分のマップを作成するために、前述の圧縮機用ツールACFが呼び出される。設計外のモデリングの誤差はユーザーが予め定義したしきい値を下回るまで繰り返し改善される。収束後は非常に複雑なCHTシミュレーションまたは燃焼器の音響モデル(CSC)を呼び出して、機械の健全性や設計点を外れた場合の寿命減少をチェックすることができる。

このようなDigital Hubシステムは、モデルの精度を向上させる無限の可能性を持っている。例えば、このモデルにAIの技術を応用してモデル化の方法を改善し、要求された忠実度を効率的に導き出す方法を機械学習させることもできる。Fig. 3に示すDigital Hubの理想的な周辺パートナーは次のようになるだろう。

- ・圧縮機設計ツール（例：ACF）
- ・サブシステムのCFDモデル
- ・燃焼器の機能を表示するための反応モデル
- ・SASサブシステムの追加。これはハブが持つ全体の

Fig. 3 Digital Hub Schematic
(Special B&B-AGEMA tools highlighted red)

モデルに含まれていないサブシステムを指す。(例：ブレード冷却、燃焼器冷却、複雑なシール構造)

- ・要素の寿命計算のための過渡FEMモデル
これには単一要素と組み合わせ要素を含む
- ・単一要素の熱流体モデル（CHT）

このハブモデルは一旦設定されると、例えば気象条件の変化、極端な動作点、構成要素（例えば圧縮機）の経年劣化などについての確率関数を与える。また開発中の新しいエンジンの動作の推定も可能になる。モンテカルロ法を用いて特定の動作点のデータをデジタルハブに供給すれば、より忠実度が高い‘ツイン’が生成される。また部品の劣化について、デジタルツインは実際のエンジンと同じように経年劣化させる。これによって機械が実装される以前の時点でも、その機械の全寿命期間についてシミュレートすることができ、タービン翼の温度分布の経時変化などの詳細も現実性を持って表現できる。

B&B-AGEMA社は、このような戦略的な方針の下で、来るべきビッグデータ社会と技術ニーズの高度化に備えるために、既存ソフトウェア製品の整備と統合を強力に推進する。

参考文献

- (1) Bohn, D., Bonhoff, B., Schönenborn, H., Combined Aerodynamic and Thermal Analysis of a High-pressure Turbine Nozzle Guide Vane, IGTC-conference paper No. 108, (1995)
- (2) Bohn, D., Krüger, U., Kusterer, K., Conjugate Heat Transfer: An advanced Computational Method for the Cooling Design of Modern Gas Turbine Blades and Vanes, Gas Turbine Heat Transfer pp. 57 - 108, Editors: B. Sunden and M. Faghri, WIT Press, 2001.
- (3) <http://www.bub-agema.de/> Products
- (4) Schneider, M., Dickhoff, J., Kusterer, K., Visser, W., Bohn, D., Stumpf, E., Hofmann, J-P., Development of a Gas Turbine Concept for Electric Power Generation in a Commercial Hybrid Electric Aircraft, Proceedings of the ASME Turbo Expo 2019, GT2019-92065 (2019).

2018年ガスタービン及び過給機生産統計

ガスタービン統計作成委員会

ガスタービン統計作成委員会は、2018年1月から12月までのガスタービン及び過給機を生産状況を調査・集計して生産統計資料を作成しましたので、ここに報告申し上げます。

陸船用ガスタービンは14社、航空用ガスタービンは3社、過給機は9社に資料提供を依頼し、ご提供頂いた範囲で生産統計資料として集計いたしました。なお、過給機はすべて排気タービン方式のターボチャージャであり、機械駆動によるものは含まれておりません。資料提供にご協力頂いた関係各社に対し、この場をお借りして厚く御礼を申し上げます。

I. 概要

1. 2018年陸船用ガスタービン生産統計概要

(1) 生産台数および出力(図1)をみると、台数は前年の252台に対し277台で、前年に比べて25台(10%)の増加となった。出力区分別の前年との比較では、小型は3台、中型が28台の増加、大型は6台の減少となった。また、出力では前年の6,105MWに対し5,953MWと、前年から152MW(2%)の減少となった。出力区分別の前年との比較では、小型は微増、中型が60MWの増加、大型は213MWの減少となっている。最近6年間でみると台数では4番目、出力では3番目となっている。出力区分別の傾向は次の通りとなった。

ア) 小型(735kW以下)は前年と比べて、台数は4%、出力は1%の増加で、それぞれ70台、31MWとなった。

イ) 中型(736~22,064kW)は前年と比べて、台数は18%、出力は16%の増加で、それぞれ184台、447MWとなった。

ウ) 大型(22,065kW以上)は前年と比べて、台数は21%、出力は4%の減少で、それぞれ23台、5,475MWとなった。

(2) 用途別(表1, 図2, 図3)をみると、ベースロード発電用(BL)、非常用発電用(EM)、その他(MC)用途の他、今年も艦艇用(MM)、実験用(XP)に実績があった。台数で最も多いのは非常用発電用(EM)の222台(80%)、出力で最も多いのはベースロード発

※文中の前年との差異や増加率などの出力に関する数値は、後に示す数表に基づきkW単位で算出している。

電用(BL)の5,548MW(93%)である。また、艦艇用(MM)は中型で6台、実験用は小型で1台計上された。前年同様、ピークロード発電用(PL)、商船用(M)、石油化学プロセス用(OR)、その他のプロセス用(PR)、空調用(ACD)は実績なしとなった。全体的な構成は例年と大きく変わっていない。

ア) 非常用発電用(EM)は前年と比べて、台数は33台(17%)増加の222台、出力は44MW(16%)増加の327MWとなった。出力区分別にみると、小型は台数で変わらず、出力で3%の減少、中型は台数で26%、出力で18%の増加となった。今年、小型は台数変わらず、出力は微減、中型は台数、出力とも増加となっている。

イ) ベースロード発電用(BL)は前年と比べて、台数は15台(29%)減少の36台、出力は98MW(2%)減少の5,548MWとなり、台数は大幅に減少、出力は微減した。出力区分別にみると、小型は台数で40%、出力で42%の減少、中型は台数で44%、出力で6%の減少、大型は台数で18%、出力で2%の減少となっている。1台あたりの出力を前年と比べると、小型:前年318kW/台、今年309kW/台、中型:前年4.3MW/台、今年7.2MW/台、大型:前年199MW/台、今年238MW/台となっており、中型、大型は大出力化という結果となった。

ウ) 艦艇用(MM)は今年、台数で6台、出力で65MWの実績があった。

エ) 実験用(XP)は今年、台数で1台、出力で51kWの実績があった。

オ) その他用途向け(MC)は前年と比べて、台数は5台増加の12台、出力は3MW増加の12MWとなっている。

(3) 燃料の種類別(表2, 図4, 図5)にみると、台数ではガス燃料が前年から13台減少の43台、液体燃料が前年から35台増加の231台となっている。出力ではガス燃料が前年から15%減少の4,942MW、液体燃料が前年から23%増加の390MWとなっている。台数、出力ともガス燃料は減少、液体燃料は増加している。構成比率は、台数ではガス燃料が全体の16%に対し、液体燃料が83%、出力ではガス燃料が83%に対し、液体燃料が7%で、割合として台数は液体燃料、出力はガス

燃料という傾向が継続している。また、前年に実績がなかった石炭が、今年は台数で2台、出力で622MW、その他(MF)が台数で1台、出力で51kWをそれぞれ計上した。

ア) 液体燃料では、台数、出力ともに最も多いのが重油1種(H1)で、台数は136台で燃料全体の49%、出力は193MWで燃料全体の3%をそれぞれ占めており、前年と比べると台数は10%、出力は18%の増加となっている。台数で見ると、灯油(T)が36台、軽油(K)が59台となり、灯油(T)は前年に比べ44%の増加、軽油(K)は前年に比べ26%の増加となっている。出力で見ると、灯油(T)が71MW、軽油(K)が125MWとなっており、前年と比べると、灯油(T)は104%の大幅増加、軽油(K)は8%の増加となっている。灯油(T)は今年、台数・出力ともに大幅に増加し、軽油(K)も、台数・出力ともに増加となった。

イ) ガス燃料では、天然ガス(GNG)が18台、都市ガス(GTW)が17台と台数が多く、合計で燃料全体の13%を占めている。他の燃料としては、液化天然ガス(LNG)が4台、高炉ガス(BFG)が3台、プロセスガス(GRF)が1台ある。出力では天然ガス(GNG)が最も多く、3,571MWで燃料全体の60%を占めている。次に出力が多いのは液化天然ガス(LNG)の958MW、以下は高炉ガス(BFG)の333MW、都市ガス(GTW)の47MW、プロセスガス(GRF)の33MWとなっている。昨年に引き続き、今年も台数・出力とも天然ガス(GNG)がトップを占めた。液化石油ガス(LPG)、石油プラントオフガス(GOG)、石炭(ガス化)ガス(GCG)は今年も実績がなかった。

ウ) 燃料別比率を出力区分別にみると、台数の上位3種は、小型が重油1種(66%)、軽油(16%)、灯油(13%)、中型が重油1種(49%)、軽油(26%)、灯油(15%)で、大型は天然ガス(57%)、液化天然ガス(17%)、高炉ガス(13%)となっている。全体では重油1種(49%)、軽油(21%)、灯油(13%)となっている。出力の上位3種は、小型が重油1種(68%)、灯油(15%)、軽油(14%)、中型が重油1種(39%)、軽油(27%)、灯油(15%)で、大型は天然ガス(64%)、液化天然ガス(18%)、石炭(11%)となっている。全体では天然ガス(60%)、液化天然ガス(16%)、石炭(10%)となっている。

エ) 2種類以上の燃料が使用できるものは、全体で19台、1,276MWであった。

注：燃料の集計にあたっては、2種類以上の燃料を使える場合は、納入時点で最も多く使用する燃料で集計している。

(4) 納入地域別(表3)で見ると、台数では国内向けが前年に比べて10台増加の230台、輸出向けが15台増加の47台となった。出力では国内向けが前年に比べて270MW増加の2,470MW、輸出向けが423MW減少の3,483MWとなっている。

ア) 国内向けは総台数の83%、全出力の41%を占めており、全体に占める割合を前年と比べると、台数では4ポイントの減少、出力では5ポイントの増加となっている。また前年から台数で5%増加し、出力では12%の増加となっている。出力区分別に台数、出力を前年と比べると、小型で3台増加、出力は微増、中型で8台、48MWの増加、大型では台数は1台減少、出力は222MWの増加となっている。前年は小型で台数、出力とも減少、中型は台数増加、出力は微減、大型は台数、出力とも大幅増加となっていたが、今年は小型、中型で台数、出力とも増加、大型で台数は減少、出力は増加となっている。また、その他は今年、台数で13台、出力で1,755MWを計上した。

イ) 輸出は総台数の17%、全出力の59%を占めており、前年と比べた全体に占める割合は、台数では4ポイント増加、出力では5ポイント減少となっている。前年より台数は15台増加し、出力は423MW減少している。出力区分別に台数・出力を前年と比べると、小型は前年同様、今年も実績なし、中型で20台、12MWの増加、大型で5台、435MWの減少となっている。輸出先別にみると、台数ではアジア(77%)、ロシア・NIS諸国(11%)、欧州(6%)の順で、アジアは前年から30ポイントの大幅増加となっている。出力ではアジア(35%)、ロシア・NIS諸国(29%)、中南米(17%)、欧州(10%)の順となっている。今年も中南米が台数、出力とも大幅に減少し、ロシア・NIS諸国は台数、出力とも大幅に増加している。アジアは前年と比べて、台数は21台の大幅増加だが、出力は385MWの減少となっている。

(5) 被駆動機械別(表4、図6、図7)では、これまでと同様に、台数、出力とも発電機(G)がほとんどを占め、全体に占める割合は台数で95%、出力で99%であった。発電機(G)について出力区分別にみると、小型では台数、出力ともに前年に比べて減少しており、中型では台数、出力とも増加、大型では台数、出力とも減少している。それぞれ前年と比べると、台数では小型が6%の減少、中型が19%の増加で、大型は18%の減少であった。出力では小型が10%の減少、中型が17%の増加、大型が2%の減少となっている。水ポンプ(W)は全体で、前年に比べて7台、4MWの増加となっており、出力区分別にみると、小型は台数で7

台、出力で3 MWの増加、中型は台数変わらず、出力は1 MWの増加となっている。また、推進機または回転翼（PRR）は前年同様、今年2台、41MWとなったが、その他圧縮機（GC）は実績なしとなった。

- (6) 出力区分別（表5）を前年と比べると、小型は全体で台数、出力ともに増加している。さらに詳細な区分別にみると、0～146kWでは、台数は変わらず、出力は微増、147～367kWでは1台、1 MWの増加、368～735kWでは2台の増加、出力は微減となった。中型は全体で台数・出力ともに増加したが、さらに詳細な区分別にみると、736～4,412kWでは23台、10MWの増加、4,413～10,296kWでは1台増加、3 MWの減少、10,297～16,180kWでは前年実績なしが、3台、37MWを計上、16,181～22,064kWでは1台、17MWの増加となった。大型は全体で台数・出力ともに減少し、さらに詳細な区分別にみると、22,065～44,129kWで1台、16MWの減少、44,130kW以上では、5台、197MWの減少となった。台数の多い順では、736～4,412kW、368～735kW、44,130kW以上となっており、前年から変わっていない。また出力の多い順では44,130kW以上、736～4,412kW、4,413～10,296kWとなっており、1、2番目は前年から変わっていないが、前年は4番目だった4,413～10,296kWが今年は3番目に多くなっている。
- (7) 発電用ガスタービン用途別（表6）の台数と出力を前年と比較すると、事業用は、国内では6台、1,695MWとなり、前年と比べて台数は3台減少、出力は72MWの増加となった。輸出では10台、3,159MWとなり、前年と比べて台数は6台、出力は290MWの減少となった。自家用は、国内が214台、477MWとなり、前年と比べて台数は14台の増加、出力は43MWの減少となった。輸出は36台、290MWとなり、前年と比べ台数は20台の増加、出力は167MWの減少であった。事業用は、前年に比べて国内では台数は減少、出力は増加し、輸出は台数、出力とも減少した。自家用は、前年に比べて国内、輸出とも台数は増加したが、出力は減少した。

2. 2018年航空用ガスタービン生産統計概要

- (1) ターボジェットエンジン／ターボファンエンジンの新規製造状況については、昨年と同様にP-1固定翼哨戒機用のF7-10のみであり、製造台数は20台、合計推力は1,148kNであった。製造台数は昨年の20台から増減はない。その他に国内で開発されたターボファンエンジンとして、HondaJetに搭載されているHF120があり、2014年に米国連邦航空局（FAA）の型式承認を取得し、2015年に出荷が開始されている。HF120エンジンは米国GEホンダ・エアロ・エンジンズ社製であ

り、米国内で製造されているため、本統計には含まれていない。（表7、図8参照）

- (2) 前年同様にターボプロップエンジンの新規製造は無く、ターボシャフトエンジンの新規製造状況はT700のみとなり、合計台数は16台、合計出力は19,824kWであった。製造台数は昨年の6台から増加した。（表8、図9参照）
- (3) 民間航空機用エンジン向けモジュールの新規製造状況については、過去5年間、航空輸送需要の回復に伴い増加傾向にあり、2018年は3,359台となり過去最高を更新した。従来機種用モジュール（V2500、CF34）が高い生産台数を維持しているだけでなく、新機種用モジュール（Trent1000、GENx、TrentXWB、PW1100G-JM）の量産が順調に増えている。2015年からV2500の後継機種として開発されたPW1100G-JMエンジンのファンモジュールと低圧圧縮機モジュールの製造が開始されているが、2016年1月にPW1100G-JMを搭載したA320neoが商業運航を開始し、本格的な量産に入っている。（図10参照）
- (4) 日本の航空用ガスタービン生産全体の動向としては、近年防衛省向けエンジンの製造台数はあまり変化がないが、戦闘機用エンジン「XF-9」が研究試作され、防衛装備庁にて運転試験が行われている⁽¹⁾。一方民間航空機用エンジン向けモジュールの製造台数については、増加傾向にあり、今後世界的な航空機需要の増加⁽²⁾に伴い、Trent1000、GENx、新機種のTrentXWB、PW1100G-JMのモジュール製造、部品製造が本格化している。更にビジネスジェット機であるGlobal7500に搭載されているPassport 20（2018年12月に就航）が量産されている。次世代大型民間輸送機B777Xシリーズに搭載予定のGE9X（2019年にエンジン型式承認を取得予定）等、新機種エンジンの国際共同開発が行われている状況⁽³⁾であり、今後も民間航空機用エンジン関連の占める割合が増加する傾向は続くと思われる。

出典(1)：防衛省（お知らせ）戦闘機用エンジンシステムの研究試作（プロトタイプエンジン）の納入について 平成30年6月29日

出典(2)：一般財団法人 日本航空機開発協会「民間航空機に関する市場予測 2019-2038」

出典(3)：一般社団法人 日本航空宇宙工業会「平成31年版 日本の航空宇宙工業」、ISSN 0910-1527

3. 2018年過給機生産統計概要

(1) 生産台数(表9)については、主に自動車向けに使用される圧縮機翼車外径100mm以下のClass 1 過給機の生産台数は2010年以降増加を続ける世界自動車生産台数を背景に増加傾向を保っており、約518万台となった。主に建設機械、陸上発電設備、小型船舶用機関等向けに使用される圧縮機翼車外径101mm～200mmのClass 2 過給機のプロダクション数は、前年比5%減の約3.7万台となった。主に船舶用機関向けに使用される圧縮機翼車外径201mm以上のClass 3以上の過給機については、Class 5, Class 7, Class 9は減少しているものの、Class 3, Class 4, Class 6, Class 8においてはそれぞれ約12%増, 5%増, 13%増, 24%増となっており、総じて

前年度比約3%増の1696台となった。歴史的な国内新造船不況となった2016年から底を抜けたものの、2020年に始まる新しい環境規制に向け、多くの船主が市場動向を伺っている状況にあるためと考えられる。

(2) 生産型式数(表10)については、2018年は前年比16型式減の127型式(全Class含む)であった。これはますます厳しくなる環境汚染物質に対する規制に対応するため、従来型エンジンに搭載する旧過給機型式の淘汰が進んだことによるものである。環境対応の新型エンジンに対応した新過給機型式の投入も進んでいるが、今後も各種規制に対応した高度な環境技術を持つ過給機のラインアップが増えてくるものと考えられる。

II. 統計

1. 陸船用ガスタービン




図1 陸船用ガスタービン

表1 2018年用途別生産台数及び出力 (kW)

用途 Application	区分 Code	小型 Small Unit ~735kW		中型 Medium Unit 736~22,064kW		大型 Large Unit 22,065kW~		全出力 Total	
		台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)
ベースロード発電用 Generator Drive for Base Load	BL	3	927	10	72,320	23	5,475,220	36	5,548,467
ピークロード発電用 Generator Drive for Peak Load	PL	0	0	0	0	0	0	0	0
非常用発電用 Generator Drive for Emergency	EM	61	27,653	161	299,450	0	0	222	327,103
商船用 Merchant Marine	M	0	0	0	0	0	0	0	0
艦艇用 Military Marine	MM	0	0	6	65,188	0	0	6	65,188
石油化学プロセス用 Oil Refinery and Chemical Process	OR	0	0	0	0	0	0	0	0
その他のプロセス用 Miscellaneous Chemical Process	PR	0	0	0	0	0	0	0	0
実験用 Experimental	XP	1	51	0	0	0	0	1	51
空調用 Air Conditioning	ACD	0	0	0	0	0	0	0	0
その他 Miscellaneous	MC	5	2,446	7	9,754	0	0	12	12,200
合計 Total		70	31,077	184	446,712	23	5,475,220	277	5,953,009




図2 2018年用途別生産台数割合 (%)




図3 2018年用途別出力割合 (%)

表2 2018年燃料別生産台数及び出力 (kW)

区分		Size	小型 Small Unit ~735kW	中型 Medium Unit 736~22,064kW	大型 Large Unit 22,065kW~	全出力 Total				
燃料種類 Kind of Fuel	コード Code	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)			
ガス燃料 Gaseous Fuel	液化天然ガス Liquefied Natural Gas	LNG	0	0	0	4	958,400			
	天然ガス Natural Gas	GNG	0	0	5	41,060	13	3,529,480		
	液化石油ガス	LPG	0	0	0	0	0	0		
	石油プラントオフガス	GOG	0	0	0	0	0	0		
	石炭 (ガス化) ガス	GCG	0	0	0	0	0	0		
	プロセスガス	GRF	0	0	0	1	33,040	1	33,040	
	都市ガス Town Gas	GTW	3	927	14	46,158	0	0	17	47,085
	高炉ガス Blast Furnace Gas	BFG	0	0	0	3	332,700	3	332,700	
	ガス燃料 小計 Sub Total		3	927	19	87,218	21	4,853,620	43	4,941,765
液体燃料 Liquid Fuel	灯油 Kerosene	T	9	4,522	27	66,370	0	0	36	70,892
	軽油 Gas Oil	K	11	4,391	48	120,828	0	0	59	125,219
	重油1種 Heavy Oil No.1	H1	46	21,186	90	172,296	0	0	136	193,482
	液体燃料 小計 Sub Total		66	30,099	165	359,494	0	0	231	389,593
固体燃料 Solid Fuel	石炭	CB	0	0	0	2	621,600	2	621,600	
	固体燃料 小計 Sub Total		0	0	0	2	621,600	2	621,600	
その他 Miscellaneous Fuel	MF	1	51	0	0	0	0	1	51	
合計 Total			70	31,077	184	446,712	23	5,475,220	277	5,953,009





図4 2018年燃料別生産台数割合 (%)

図5 2018年燃料別出力割合 (%)

表3 2018年地域別納入台数及び出力 (kW)

地域 Location		区分 Size	小型 Small Unit ~735kW	中型 Medium Unit 736~22,064kW	大型 Large Unit 22,065kW~	全出力 Total			
		台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)		
国内向け Domestic Use	北海道 Hokkaido	1	400	4	4,800	0	0	5	5,200
	東北 Tohoku	7	2,896	3	4,240	0	0	10	7,136
	関東 Kanto	24	9,170	60	133,646	0	0	84	142,816
	中部 Chubu	17	8,310	17	34,190	2	320,000	36	362,500
	近畿 Kinki	7	3,741	36	96,280	0	0	43	100,021
	中国 Chugoku	5	1,860	7	8,600	0	0	12	10,460
	四国 Shikoku	5	2,600	1	800	0	0	6	3,400
	九州 Kyushu	4	2,100	9	13,724	0	0	13	15,824
	沖縄 Okinawa	0	0	2	2,200	0	0	2	2,200
	艦艇用 Military Marine	0	0	6	65,188	0	0	6	65,188
その他 Miscellaneous	0	0	5	13,994	8	1,741,100	13	1,755,094	
国内向け 小計 Sub Total		70	31,077	150	377,662	10	2,061,100	230	2,469,839
輸出向け For Export	北米 North America	0	0	0	0	0	0	0	0
	中南米 South Central America	0	0	0	0	2	587,200	2	587,200
	アジア Asia	0	0	30	35,800	6	1,194,000	36	1,229,800
	大洋州 Oceania	0	0	0	0	0	0	0	0
	欧州 Europe	0	0	2	9,500	1	346,500	3	356,000
	ロシア・NIS諸国 Russia・NIS	0	0	2	23,750	3	990,300	5	1,014,050
	中東 Middle East	0	0	0	0	0	0	0	0
	アフリカ Africa	0	0	0	0	1	296,120	1	296,120
輸出向け 小計 Sub Total		0	0	34	69,050	13	3,414,120	47	3,483,170
合計 Total		70	31,077	184	446,712	23	5,475,220	277	5,953,009

表4 2018年被駆動機械別生産台数及び出力 (kW)

被駆動機械 Driven Machinery	区分 Size コード Code	小型 Small Unit ~735kW		中型 Medium Unit 736~22,064kW		大型 Large Unit 22,065kW~		全出力 Total	
		台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)
発電機 Electric Generator	G	62	26,891	179	401,954	23	5,475,220	264	5,904,065
水ポンプ Water Pump	W	8	4,186	3	3,570	0	0	11	7,756
推進機または回転翼	PRR	0	0	2	41,188	0	0	2	41,188
動力計	DM	0	0	0	0	0	0	0	0
その他圧縮機	GC	0	0	0	0	0	0	0	0
合計 Total		70	31,077	184	446,712	23	5,475,220	277	5,953,009





図6 2018年被駆動機械別生産台数割合 (%)

図7 2018年被駆動機械別出力割合 (%)

表5 2018年出力区分別生産台数及び出力 (kW)

出力区分 (kW) Units Output		台数 Units	出力 Output (kW)
小型 Small Unit 0~735kW	0~146	2	171
	147~367	16	4,340
	368~735	52	26,566
	小計 Sub Total	70	31,077
中型 Medium Unit 736~22,064kW	736~4,412	166	278,854
	4,413~10,296	12	73,430
	10,297~16,180	3	36,640
	16,181~22,064	3	57,788
小計 Sub Total		184	446,712
大型 Large Unit 22,065kW~	22,065~44,129	2	67,840
	44,130~	21	5,407,380
	小計 Sub Total	23	5,475,220
合計 Total		277	5,953,009

表6 2018年発電用ガスタービン用途別生産台数及び出力 (kW)

区分		Size	小型 Small Unit ~735kW		中型 Medium Unit 736~22,064kW		大型 Large Unit 22,065kW~		全出力 Total	
			台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)	台数 Units	出力 Output (kW)
用途 Application	コード Code									
国内事業用	ベースロード発電用	BL	0	0	0	0	6	1,695,400	6	1,695,400
	ピークロード発電用	PL	0	0	0	0	0	0	0	0
	非常用発電用	EM	0	0	0	0	0	0	0	0
	試験用	XP	0	0	0	0	0	0	0	0
	その他	MC	0	0	0	0	0	0	0	0
Domestic/Public Use 国内事業用 小計 Sub Total			0	0	0	0	6	1,695,400	6	1,695,400
国内自家用	ベースロード発電用	BL	3	927	6	39,070	1	112,000	10	151,997
	ピークロード発電用	PL	0	0	0	0	0	0	0	0
	非常用発電用	EM	61	27,653	131	263,650	0	0	192	291,303
	試験用	XP	1	51	0	0	0	0	1	51
	艦艇用	MM	0	0	4	24,000	0	0	4	24,000
	その他	MC	0	0	7	9,754	0	0	7	9,754
Domestic/Private Use 国内自家用 小計 Sub Total			65	28,631	148	336,474	1	112,000	214	477,105
国内合計 Domestic Use Total			65	28,631	148	336,474	7	1,807,400	220	2,172,505
輸出事業用	ベースロード発電用	BL	0	0	0	0	10	3,158,620	10	3,158,620
	ピークロード発電用	PL	0	0	0	0	0	0	0	0
	非常用発電用	EM	0	0	0	0	0	0	0	0
	試験用	XP	0	0	0	0	0	0	0	0
	艦艇用	MM	0	0	0	0	0	0	0	0
	その他	MC	0	0	0	0	0	0	0	0
For Export/Public Use 輸出事業用 小計 Sub Total			0	0	0	0	10	3,158,620	10	3,158,620
輸出自家用	ベースロード発電用	BL	0	0	4	33,250	2	220,700	6	253,950
	ピークロード発電用	PL	0	0	0	0	0	0	0	0
	非常用発電用	EM	0	0	30	35,800	0	0	30	35,800
	試験用	XP	0	0	0	0	0	0	0	0
	艦艇用	MM	0	0	0	0	0	0	0	0
	その他	MC	0	0	0	0	0	0	0	0
For Export/Private Use 輸出自家用 小計 Sub Total			0	0	34	69,050	2	220,700	36	289,750
輸出合計 For Export Total			0	0	34	69,050	12	3,379,320	46	3,448,370
事業用	ベースロード発電用	BL	0	0	0	0	16	4,854,020	16	4,854,020
	ピークロード発電用	PL	0	0	0	0	0	0	0	0
	非常用発電用	EM	0	0	0	0	0	0	0	0
	試験用	XP	0	0	0	0	0	0	0	0
	艦艇用	MM	0	0	0	0	0	0	0	0
	その他	MC	0	0	0	0	0	0	0	0
Public Use 事業用 合計 Total			0	0	0	0	16	4,854,020	16	4,854,020
自家用	ベースロード発電用	BL	3	927	10	72,320	3	332,700	16	405,947
	ピークロード発電用	PL	0	0	0	0	0	0	0	0
	非常用発電用	EM	61	27,653	161	299,450	0	0	222	327,103
	試験用	XP	1	51	0	0	0	0	1	51
	艦艇用	MM	0	0	4	24,000	0	0	4	24,000
	その他	MC	0	0	7	9,754	0	0	7	9,754
Private Use 自家用 合計 Total			65	28,631	182	405,524	3	332,700	250	766,855
総計 Grand Total			65	28,631	182	405,524	19	5,186,720	266	5,620,875

Note : Code Explanation BL : for Base Load PL : for Peak Load EM : for Emergency

2. 航空用ガスタービン




図8 ターボジェットエンジン／ターボファンエンジン




図10 民間航空エンジン用モジュール




図9 ターボシャフトエンジン／ターボプロップエンジン

表7 2018年ターボジェットエンジン／ターボファン・エンジン生産台数及びスラスト合計 (kN)

生産台数 Number of Units	20	スラスト合計*1 Thrust	1,148
-------------------------	----	--------------------	-------

※1 海面上静止常用スラスト
Normal Thrust at Sea Level Static Condition

表8 2018年ターボシャフトエンジン／ターボプロップ・エンジン生産台数及び出力 (kW)

区分 Size	0~735kW		736kW~		全出力	
	台数 Units	出力*2 Output (kW)	台数 Units	出力*2 Output (kW)	台数 Units	出力*2 Output (kW)
固定翼機 Fixed Wing Aircraft	0	0	0	0	0	0
ヘリコプタ用 Helicopter	0	0	16	19,824	16	19,824
補助機関駆動用 Aux. Drive Units	0	0	0	0	0	0
合計 Total	0	0	16	19,824	16	19,824

※2 海面上静止常用出力
Normal Output at Sea Level Static Condition

3. 過給機

表9 クラス別の年間生産台数

区分 Class	Size 圧縮機翼車外径(mm) Outside Diameter of Compressor Impeller	年間生産台数					
		2013年	2014年	2015年	2016年	2017年	2018年
Class 1	0～100	約395万	約413万	約441万	約441万	約462万	約518万
Class 2	101～200	29,930	35,294	35,810	34,041	39,008	37,067
Class 3	201～300	574	641	668	951	897	1,005
Class 4	301～400	260	310	183	196	164	172
Class 5	401～500	74	161	214	299	239	181
Class 6	501～600	195	255	241	233	173	196
Class 7	601～700	150	232	184	148	88	85
Class 8	701～800	33	46	35	22	38	47
Class 9	801～900	94	81	11	25	44	10
Class 10	901～1000	0	0	0	0	0	0
Class 11	1001～	0	0	0	0	0	0
合計 Total*		31,310	37,020	37,346	35,915	40,651	38,763

Class 1の台数が多いため、Class 2～11の合計を示す。
As the Production number of Class1 is too many, Total number only includes Class2 to Class11.

表10 クラス別の型式数*

区分 Class	Size 圧縮機翼車外径(mm) Outside Diameter of Compressor Impeller	型式数					
		2013年	2014年	2015年	2016年	2017年	2018年
Class 1	0～100	64	55	55	50	48	48
Class 2	101～200	29	29	29	20	25	21
Class 3	201～300	18	18	18	15	16	15
Class 4	301～400	18	18	18	12	13	10
Class 5	401～500	14	16	16	13	13	12
Class 6	501～600	15	16	16	14	12	9
Class 7	601～700	15	17	17	7	8	6
Class 8	701～800	5	5	5	5	3	4
Class 9	801～900	10	9	9	4	5	2
Class 10	901～1000	0	0	0	0	0	0
Class 11	1001～	0	0	0	0	0	0
合計 Total*		124	128	128	90	95	79

※3 型式はいずれも排気タービンである。
Every model is an exhaust turbine type supercharger.

※4 合計数は、圧縮機翼車外径100mmを越す分を示す。
The figure shows total number of superchargers over 100mm in impeller diameter.




図11 2018年過給機生産台数及び型式数

ASME Turbo Expo 2019 GTSJ展示 実施報告

国際委員会

国際委員会では、当学会が主催または共催するIGTCやAGCTといった国際会議などの活動をはじめとして、日本におけるガスタービンの研究開発に関する情報を発信することを目的として、2014年からASME Turbo Expoの展示に日本ガスタービン学会のブースを構えております。今年はTurbo Expoの期間中6月18日から20日までの3日間展示活動を行いました。ブースの設営、撤去、物品の輸送等は事務局の中村さんを含む国際委員会展示ワーキンググループが中心となって行いましたが、ブースでの説明には会議に参加された会員の皆さんなどにもご協力を頂きました。ご協力いただいた皆さまに心よりお礼を申し上げます。なお、ASME/IGTIと当学会とは国際会議に関する協力協定を締結しており、IGTI事務局に大変お世話になっています。

今年の展示ブースは、展示会場のほぼ中央部に近い位置に設置され、毎年人気のブースの一つであるNASAのブースの通路を挟んで反対側にあったこともあり、露出度という点で恵まれていました。ブースでは昨年と同様ポスターの展示と各種資料の配布を行いました。ポスターはGTSJの紹介2019年度版と、日本のガスタービン開発史を紹介するものの2点です。今回は今年虎ノ門ヒルズで開催するIGTC2019の情報展開に重きを置き活動しました。配布物は、(1)IGTC2019/ACGTパンフレット、(2)GTSJ英文パンフレット2019年度版、(3)日本のガスタービン関連機関情報パンフレット2019年度版、(4)学会ネーム入りクリアファイル(寿司バージョン)の5点

でした。これらを250部用意し、クリアファイルに入れて配布しました。インパクトのある図柄ということもあり、多くの来客者に大好評で、用意した250部はあっという間に配布されました。学会のロゴ等が控えめに印刷されていたので学会のイメージが正しく伝わったのか一抹の不安を覚えないわけではありませんが、日本関係の展示が多くはない状況でもあり、日本の存在感を展示という形でアピールできたのではないかと自負しております。

展示そのものは以前ほどの賑わいを失っている感がありますが、日本人の参加者が集う場としても機能しております。日本人同士の様々な情報伝達にも便利な拠点となっています。また、日本人以外の常連様も少しずつ増えてきているようで、IGTCなどの情報を効果的に伝える機会ができています。勿論、展示方法を適宜見直すことや宣伝効果の調査などの工夫の余地はありますが、今後とも継続して行きたいと思っておりますので、ご理解とご協力をいただきますよう宜しくお願い致します。



GTSJブース

ASME Turbo Expo 2019 参加報告

日本ガスタービン学会事務局
中村 優美

アメリカ・アリゾナ州 フェニックスで開催のASME Turbo Expoに参加してまいりました。展示ブース出展も6回目となり、ブース設営等もスムーズに準備することができました。ブースでは、国際委員会メンバーの方々と共に来訪者の対応にあたり、GTSJの紹介や、11月に開催のIGTC2019Tokyoの講演セッションや展示会の紹介をいたしました。講演会2日目夜にはWomen in Engineering Eventが催され、参加希望者は午後7時45分に会場前からバスに乗り、郊外のレストランに行きました。今年も多数の女性エンジニアが集まりました。私たちはヨーロッパの若い女性(みんな美人)と席しましたが、明るく楽しそうで、日本の若い女性技術者の方ももっと増えるといいなあと思いつつ会話と食事を楽しみました。また、例年Turbo Expo会期中に開催するGTSJ International Advisory Committee Meetingは、

今回はお昼の休憩時間が短いため、夕方に開催いたしました。委員の皆さんからはIGTC2019に向けたご助言を多数いただき、たいへん有意義な会議でした。

Turbo Expoに参加された国際委員会委員やGTSJ会員のみなさまのご協力により、今年も無事に、そして充実した日々を送ることができました。この場をお借りして御礼申し上げます。



GTSJ IAC Meeting

2019年度 見学会報告

萩川 宏樹

HARAIKAWA Hiroki

2019年7月5日(金)午後、(株)JALエンジニアリングのエンジン整備センター並びに成田航空機整備センターにおいて、本会主催の見学会が開催された。両センターは、千葉県成田国際空港内のJAL整備地区に位置しているが、当日は懸念していた雨も降らず、メーカー、大学を中心として58名の参加があり、近年稀にみる大盛況の見学会となった。

まずエンジン整備センターに到着した一同は、見学者ホールへ案内され、整備技術グループの清水みはる氏より、JALにおける航空機整備とエンジン整備の概要について説明を頂き、JALではシップ整備と呼ばれる運航・点検整備から、ショップ整備と呼ばれる部品・エンジン整備まで、幅広く整備を行っている状況がよく伺えた。その後、3つのグループに分かれて見学を行ったが、カウリングやスラストリバーサーという外装品の整備から、分解されたエンジンの部品の洗浄、非破壊検査、又、溶接や溶射などの修理工程、更に、モジュールや大型エンジンの分解組み立て、試運転工程など、航空機エンジンに関わる整備を隅々まで見学した。見学の途中では、実際にエンジン内部で使用されてきたタービンブレードの状況を手にとって確認するなど、大変貴重な経験をさせてもらった。見学後の質疑応答では、部品修理の開発や整備コストに関する質疑が多くなされ、活発な意見交換も含めて時間が足らずに、質問の打ち切りをせざるを得ない状況であった。

次に徒歩で成田航空機整備センターに移動し、ボーイング787の機体整備の様子を見学した。整備中の飛行機は外板のパネルが一部外された状態で、通常は見ることが出来ない航空機の内部に位置する様々な部品や電線、配管などを確認することが出来、又、普段は近くで見ることがないランディングギアや、機体の周囲に取り付いている各種センサーも間近に見ることが出来た。案内役の方の軽妙な説明も相まって、航空機のシステムについて理解が深まり、大変有意義な見学会となった。

最後に、本見学会を開催するに当たり、準備から当日の案内まで、多岐にわたってご尽力・ご協力頂いたJALエンジニアリングの関係者の皆様に厚く御礼を申し上げます。
(集会行事委員会委員)



エンジン整備センター玄関での集合写真



ボーイング787機体整備の見学

第32回ガスタービン教育シンポジウム報告

小沢 寛二
OZAWA Kanji

2019年7月18日(木)と19日(金)の2日間にわたり、本会主催の第32回ガスタービン教育シンポジウムが、東京都昭島市にある株式会社IHI昭島事務所において開催された。今回は前年と比較すると人数は若干少なめであったが、大学、公的機関、電力会社およびメーカーなどから59名(学生：15名、社会人：44名)の参加があった。

ガスタービン教育シンポジウムは、学生や若手技術者などガスタービン初学者を対象に、ガスタービンに関する基礎知識を学んで頂くことを主目的に、第一線で活躍されている各専門家の方々による講義を行う企画で、関東地区では毎年、関西地区では隔年で実施されているが、今年度は関東地区でのみで開催する年にあたる。

今回の教育シンポジウム1日目は、受付終了後すぐに講義が開始され、(1)「ガスタービン概論」(黒木博史氏)、(2)特別講演「ジェットエンジンへの要求と技術開発 - IHIの取り組み -」(浅子知昭氏)、(3)「ガスタービンと伝熱工学」(村田章氏)、(4)「ガスタービンと材料工学」(石川茂浩氏)、(5)「ガスタービンと制御工学」(垣内大紀氏)の5つの講義が昼食休憩および小休憩を挟みながら18時近くまで実施された。また2日目は、前日に引き続き(6)「ガスタービンと流体力学」(山本誠氏)、(7)「ガスタービンと燃焼工学」(藤秀実氏)の2つの講義が午前中に行われた。それぞれの講義ではガスタービンの基礎から最新の技術動向までを専門家の立場から説明がなされ、受講者にとって今後の研究や仕事などを行ううえで役立つ内容の講義となっており、講義の最後には時間が許す限り質疑応答が活発に行われた。

教育シンポジウムでは、講義だけではなく見学会も例年実施されており、今回は2日目の午後にIHI昭島事務所内に併設されている「IHI そらの未来館」の見学が行

われた。館内には日本のガスタービン開発の歴史ならびにIHIでのガスタービンの開発・生産の歴史をたどるように航空機用や発電用のガスタービンの実物や模型が展示されていて、参加者はIHIの説明者(弓手良行名誉館長、他)の話聞きながら間近にガスタービンを見る機会を得られた。

また1日目の夕刻には、昭島事務所内で場所を移して懇親会が行われた。懇親会には教育シンポジウム参加者の約7割の方が参加し、会場の各所で参加者同士、官学または企業間などの枠を超えての懇談が時間いっぱいまで行われ、参加者に交流を図る有意義な時間と場所を提供できたと思う。

本シンポジウムでは本会が出版する「ガスタービン工学」を教材として用いており、これに沿った講義を講師の方々をお願いしている。ただ、本教材は300ページ近いもので、2日間の集中講義では時間の都合もあり、教材の一部については説明が駆け足になったり、割愛させて頂く部分もあった。今回参加された方々には教材を各々の現場で活用して頂き、ガスタービンの知識をさらに深めるのに役立てて頂ければ幸いである。なお、参加者には講義受講後に修了の証として受講証が手渡され、また今後の教育シンポジウムの運営および教材に関するアンケートの記入にご協力頂いた。アンケートの集計結果は次回以降の企画および教材の改訂に反映していく予定である。

最後に、講義や資料の作成・準備にご尽力して頂いた講師の方々に感謝するとともに、会場の提供、見学会および懇親会の実施において色々のご協力頂いた株式会社IHIの関係各位に深く感謝いたします。

(集會行事委員会委員)



講義風景



懇親会風景

International Gas Turbine Congress 2019 Tokyoのご案内

IGTC2019実行委員会
委員長 西澤 敏雄

学会誌、ホームページ等でご案内しておりますInternational Gas Turbine Congress 2019 Tokyo (IGTC2019 Tokyo)の期日が近づいて参りました。下記の通り概要をお知らせします。

おかげさまで多数の論文が集まり、最終的に187件を採択致しました。展示も28社に出展いただき、盛況となっています。また、招待講演と合わせて、毎回好評を得ておりますパネルディスカッションを開催する予定です。

今後も実行委員会にて開催まで努力を続け、学術発表と討論、情報交換、およびネットワーキングの場として価値の高い国際会議を実現したいと思っております。会員の皆様には是非この場を活用いただきますよう、宜しくお願い致します。

記


- 会 期： 2019年11月17日(日)～ 22日(金)
開 催 場 所： 虎ノ門ヒルズ フォーラム (虎ノ門ヒルズ 4階・5階)
ウェブサイト： <http://igtc2019.org/>
講 演 会： 採択論文187件 (国内85件, 海外102件) (優秀な論文はJGPPに推薦)
招待講演 7件
 (1) Dr. James D Heidmann (NASA Glenn Research Center)
 (2) Dr. Frank Haselbach (Rolls-Royce)
 (3) Prof. Timothy C. Lieuwen (Georgia Institute of Technology)
 (4) Prof. Joerg R. Seume, (Leibniz University Hannover)
 (5) Prof. Mehdi Vahdati (Imperial College London)
 (6) Prof. Francesco Montomoli (Imperial College London)
 (7) Dr. Thomas Pang (GE Additive)
パネルディスカッション 2件
 (1) 航空推進技術の将来：メーカーの視点
 (2) 低炭素社会・水素社会のタービン技術開発
展 示： 28社 11月18日(月)～ 21日(木), 入場無料
行 事： ウェルカム・レセプション 11月17日(日) 18:00～20:00
 バンケット 11月20日(水) 18:00～20:30
 見学ツアー 11月22日(金) 2コース
 虎ノ門ヒルズ・バックヤード見学 11月19日(火)～ 21日(木) 昼食時
参 加 登 録： ウェブサイトから参加登録をお願いします。

2019年度若手技術者交流会開催のお知らせ

個々の研究・技術レベルの向上と会員相互の情報交換の促進を図ることを目的とし、2019年度若手技術者交流会を下記の通り開催いたします。今回は「流体」をテーマとしています。

1. 日時：2019年12月13日(金) 13：30～20：00
2. 場所：川崎重工業株式会社 明石工場 新総合事務所 2階（明石市川崎町1-1）
3. 講師：
 - 講義：古川雅人氏（九州大学）
 - 講演：松岡右典氏（川崎重工業株式会社）
4. プログラム（予定）：
 - 13：30-14：20 参加者自己紹介
 - 14：30-17：00 講義, 講演
 - 17：00-17：45 質疑応答およびディスカッション
 - 18：00-20：00 懇親会

詳細および申込方法につきましては、10月中旬に日本ガスタービン学会HP (<http://www.gtsj.org/>) において公開いたします。



第48回ガスタービンセミナー開催のお知らせ

第48回ガスタービンセミナーを下記の通り開催いたします。

最前線で活躍されている方々のご講演を通して、発電用および航空用ガスタービンに関する最新技術動向を学ぶと共に、各種用途のガスタービンの高性能化につながる幅広い技術分野の知見を高める内容を企画しております。

（詳細につきましては、11月号学会誌、ホームページ等で後日お知らせいたします）

1. 日 時 : 2020年1月 23日(木) 10：00～17：00（予定）
24日(金) 10：00～17：00（予定）
2. 場 所 : 東京大学 山上会館 大会議室
〒113-8654 東京都文京区本郷7-3-1（東京大学本郷キャンパス構内）
※東京メトロ丸の内線・都営地下鉄大江戸線「本郷三丁目」駅より徒歩約15分
※東京メトロ南北線「東大前」駅より徒歩約16分
※東京メトロ千代田線「湯島」駅・「根津」駅より徒歩約15分
3. テ ー マ : 「ガスタービンの最新技術動向」（予定）
4. 参加要領 : 11月号学会誌、当学会ホームページに掲載予定です。（<http://www.gtsj.org/>）

2019年度日本ガスタービン学会賞候補募集のお知らせ（再掲）

応募締切日：2019年10月31日(木)

日本ガスタービン学会では、下記の趣旨により2年毎に学会賞（論文賞、技術賞および奨励賞）の贈呈を行っております。つきましては、今年度も下記要領により学会賞の募集を行うこととなりましたので、お知らせ致します。

募集要領

1. 日本ガスタービン学会賞の趣旨

本会はガスタービンおよびエネルギー関連技術に関する工学および技術の発展を奨励することを目的として、優れた論文、技術ならびに新進会員個人の業績に対して、それぞれ日本ガスタービン学会論文賞、技術賞、奨励賞を贈り、表彰を行う。

2. 対象となる業績

- (1)論文賞：日本ガスタービン学会誌および日本ガスタービン学会英文電子ジャーナルJGPP (International Journal of Gas Turbine, Propulsion and Power Systems) に2015年11月以降2019年10月迄に公表された論文で、独創性があり工学および技術に寄与したものの。
- (2)技術賞：ガスタービンおよびエネルギー関連の技術で画期的な新製品の開発、製品の品質または性能の向上、材料開発、制御計測および保守技術の向上等に寄与したものの。
- (3)奨励賞：日本ガスタービン学会誌および日本ガスタービン学会英文電子ジャーナルJGPP (International Journal of Gas Turbine, Propulsion and Power Systems) に2015年11月以降2019年10月迄に公表された独創的な論文（本人が中心的役割を果たしたものの）。なお、萌芽的研究も対象とする。
奨励賞の候補者は、1984年4月2日以降生まれの個人とする。ただし、論文賞、技術賞あるいは奨励賞をすでに受けた者および今年度の論文賞、技術賞内定者は奨励賞を受けることはできない。

3. 受賞件数

論文賞2件、技術賞2件、奨励賞2名程度とする。

4. 表彰の方法

審査の上、表彰状および賞牌を授与する。

5. 表彰の時期

表彰は、2020年4月開催予定の日本ガスタービン学会総会において行う。

6. 応募の方法

公募によるものとし、論文賞、技術賞は推薦または本人より申請、奨励賞は推薦による。なお、一度申請して受賞しなかったものでも、再度応募して差し支えない。

7. 提出書類

推薦または申請には、本会の所定用紙に必要事項を記載して、1件につき正1通、副2通（コピーで可）の計3通を提出する。

- ・日本ガスタービン学会賞（論文・奨励）申請書・推薦書
- ・日本ガスタービン学会賞（技術）申請書・推薦書

所定用紙は本会ホームページ (<http://www.gtsj.org/>) からダウンロード可能。

8. 提出締切日

2019年10月31日(木)17時必着

9. 提出先

〒160-0023
東京都新宿区西新宿7-5-13
第3工新ビル402
公益社団法人日本ガスタービン学会
表彰委員会 宛

○ 本会協賛行事 ○

主催学協会	会合名	協賛	開催日	会場	詳細問合せ先
日本機械学会	2019年度計算力学技術者(CAE技術者)資格認定事業(固体力学分野の有限要素法解析技術者・熱流体力学分野の解析技術者・振動分野の有限要素法解析技術者)	協賛	2019/9/15, 9/22,12/7	慶應義塾大学理工学部(矢上キャンパス)ほか	URL : https://www.jsme.or.jp/cee/
日本機械学会	No.19-23講習会「『伝熱工学資料(改定第5版)』の内容を教材にした熱設計の基礎と応用」	協賛	2019/9/24-25	日本機械学会 会議室	URL : https://www.jsme.or.jp/event/2019-40752/
日本機械学会	No.19-335講習会「脱炭素社会における火力発電の未来」	協賛	2019/10/16	(株)IHI 横浜ゲストハウス	URL : https://www.2jsme.or.jp/fw/index.php?action=kousyu_index&gyojino=19-335
日本機械学会 関西支部	第20回秋季技術交流フォーラム	協賛	2019/10/19	大阪市立大学 杉本キャンパス	URL : http://www.kansaijsme.or.jp/
日本機械学会 関西支部	第363回講習会「応力計測の基礎とその応用(デモンストレーション付き)」	協賛	2019/10/24-25	大阪科学技術センター 8階 中ホール	URL : http://www.kansaijsme.or.jp/
東京大学大学院工学系研究科 ポスト「京」重点課題⑥	第4回ポスト「京」重点課題⑥シンポジウム「世界最高水準のスーパーシミュレーションで革新的なクリーンエネルギーシステムの实用化を加速する」	協賛	2019/11/5	東京大学弥生講堂一条ホール	URL : https://postk6.t.u-tokyo.ac.jp/event/symposium201911.html
日本機械学会	No.19-332「第27回機械材料・材料加工技術講演会(M&P2019)」	協賛	2019/11/20-22	フェニックスプラザ(福井市)	URL : https://jsmempd.com/conference/mpdconf/2019/
日本機械学会 関西支部	第364回講習会「実務者のための流体解析技術の基礎と応用(各種シミュレーション技術の適用事例紹介付き)」	協賛	2019/11/21	大阪科学技術センター 8階 中ホール	URL : http://www.kansaijsme.or.jp/
自動車技術会	第30回内燃機関シンポジウム 内燃機関の持続的発展へー飽くなき挑戦ー	協賛	2019/12/10-12	広島国際会議場	URL : https://www.jsae.or.jp/intconf/ice/sympo2019.php
日本液体微粒化学会	20th Annual Conference of ILASS-Asia&第28回微粒化シンポジウム	協賛	2019/12/21-23	山口大学 常盤キャンパス	URL: http://www.ilass-japan.gr.jp



▷ 入会者名簿 ◁

〔正会員〕

若林 祥(IHI)

岡田 崇宏(川崎重工業)

齋藤 勇人(東芝エネルギーシステムズ)

泊川 晃(東北電力)

素都 益史(マルショー)

池田 崇之(川崎重工業)

范 勇(産業技術総合研究所)

井上 直久(東電設計)

味崎 隆久(東北電力)

黛 健斗(三井E&Sマシナリー)

石原 諒大(川崎重工業)

泉 光宏(ダイヤモンド電機)

下鳥 進(東北電力)

向明戸 結衣(東北電力)

谷川 弘晃(三菱日立パワーシステムズ)

〔学生会員〕

長尾 順(京都大学大学院)

上田 朝陽(東京大学)

松本 悠太郎(東京大学)

2019年度役員名簿

会長 渡辺 紀徳 (東大)

副会長 識名 朝春 (IHI)

法人管理担当執行理事 大石 勉 (IHI), 飭 雅英 (川崎重工), 寺本 進 (東大), 北山 和弘 (東芝ESS) (兼務)

公益目的事業担当執行理事 伊藤 栄作 (三菱重工), 岡田 満利 (電中研), 岸部 忠晴 (MHPS), 佐藤 哲也 (早大), 高原 雄児 (防衛装備庁), 野崎 理 (高知工科大), 村田 章 (東京農工大), 山本 誠 (東京理科大), 壹岐 典彦 (産総研) (兼務)

理事 石井 達哉 (JAXA), 大塚 裕也 (本田), 黒瀬 良一 (京大), 千葉 秀樹 (酒田共同火力発電), 菟川 宏樹 (JALエンジニアリング)

監事 筒井 康賢 (元高知工科大), 松崎 裕之 (東北発電工業)

2019年度委員名簿 (順不同)

2019年7月8日現在

○は委員長

倫理規定委員会 ○飭 雅英 (川崎重工), 壹岐 典彦 (産総研), 大石 勉 (IHI), 寺本 進 (東大), 山本 誠 (東京理科大)

自己点検委員会 ○飭 雅英 (川崎重工), 壹岐 典彦 (産総研), 大石 勉 (IHI), 寺本 進 (東大), 山本 誠 (東京理科大)

運営委員会 ○寺本 進 (東大), 壹岐 典彦 (産総研), 大石 勉 (IHI), 飭 雅英 (川崎重工), 北山 和弘 (東芝ESS), 酒井 義明 (東芝ESS), 佐藤 哲也 (早大), 塚原 章友 (MHPS), 松沼 孝幸 (産総研), 山本 誠 (東京理科大)

企画委員会 ○壹岐 典彦 (産総研), 太田 有 (早大), 飭 雅英 (川崎重工), 北山 和弘 (東芝ESS), 佐藤 哲也 (早大), 塚原 章友 (MHPS), 寺本 進 (東大), 安田 聡 (MHPS), 山本 誠 (東京理科大), 輪嶋 善彦 (本田)

国際委員会 ○船崎 健一 (岩手大), 伊藤 優 (東大), 岡井 敬一 (JAXA), 北山 和弘 (東芝ESS), 小森 豊明 (MHPS), 佐藤 眞一郎 (本田), 谷 直樹 (IHI), 都留 智子 (川崎重工), 福田 雅文 (高効率発電システム研究所), 山根 敬 (JAXA), 山本 誠 (東京理科大)

学術講演会委員会 ○渡邊 裕章 (九大), 今野 晋也 (MHPS), 岡嶋 芳史 (三菱重工), 尾関 高行 (電中研), 糟谷 宏樹 (東芝ESS), 北村 英二郎 (本田), 富永 純一 (JFEエンジニアリング), 中山 健太郎 (川崎重工), 野崎 理 (高知工科大), 姫野 武洋 (東大), 平川 香林 (IHI), 平野 孝典 (拓殖大), 藤原 仁志 (JAXA), 松沼 孝幸 (産総研), 山形 通史 (富士電機)

集行事務委員会 ○山本 誠 (東京理科大), 安藤 友香 (防衛装備庁), 伊藤 栄作 (三菱重工), 小沢 寛二 (IHI), 金澤 直毅 (川崎重工), 河上 誠 (日立), 久保 俊介 (本田), 小島 充大 (富士電機), 澤 徹 (東芝ESS), 泰中 一樹 (電中研), 西村 英彦 (MHPS), 菟川 宏樹 (JALエンジニアリング), 黛 健斗 (三井E&Sマシナリー), 吉田 征二 (JAXA)

ガスタービン技術普及委員会 ○岡田 満利 (電中研), 石田 克彦 (川崎重工), 垣内 大紀 (IHI), 窪谷 悟 (東芝ESS), 鈴木 正也 (JAXA), 高橋 康雄 (MHPS), 谷岡 忠輝 (MHPS), 長谷川 晃 (JALエンジニアリング), 村田 章 (東京農工大), 山本 誠 (東京理科大)

学会誌編集委員会 ○佐藤 哲也 (早大), 荒木 秀文 (MHPS), 壹岐 典彦 (産総研), 石井 達哉 (JAXA), 岩井 裕 (京大), 大塚 裕也 (本田), 加藤 千幸 (東大), 金子 雅直 (東京電機大), 黒瀬 良一 (京大), 渋谷 直紀 (東芝ESS), 高橋 俊彦 (電中研), 田尻 敬次 (荏原エリオット), 多田 暁 (JALエンジニアリング), 千葉 秀樹 (酒田共同火力発電), 辻田 星歩 (法政大), 寺澤 秀彰 (東京ガス), 寺本 進 (東大), 中野 賢治 (IHI回転機械), 新関 良樹 (徳島文理大), 野原 弘康 (ダイハツディーゼル), 八田 直樹 (三井E&Sマシナリー), 原 浩之 (MHPS), 北條 正弘 (JAXA), 松崎 裕之 (東

北発電工業), 松田 博和 (川崎重工), 村上 秀之 (物材研), 室岡 武 (IHI), 森澤 優一 (東芝ESS), 山下一憲 (荏原製作所), 山根 喜三郎 (防衛装備庁)

論文委員会 ○村田 章 (東京農工大), 青塚 瑞穂 (IHI), 壹岐 典彦 (産総研), 小田 剛生 (川崎重工), 田頭 剛 (JAXA), 寺本 進 (東大), 中谷 辰爾 (東大), 姫野 武洋 (東大), 山田 和豊 (岩手大), 山根 敬 (JAXA), 山本 武 (JAXA), 山本 誠 (東京理科大), 吉岡 洋明 (東北大)

ガスタービン統計作成委員会 ○太田 有 (早大), 赤澤 弘毅 (川崎重工), 井田 真澄 (ターボシステムズユニテッド), 恵比寿 幹 (三菱重工エンジン&ターボチャージャ), 後藤 裕一 (IHI), 佐々木 慎吾 (MHPS), 澤 徹 (東芝ESS), 藤澤 信道 (早大), 山上 展由 (MHPS), 米田 幸人 (ヤンマー)

産官学連携委員会 ○岸部 忠晴 (MHPS), 壹岐 典彦 (産総研), 岡崎 正和 (長岡技術科学大), 及部 朋紀 (防衛装備庁), 金津 和徳 (IHI), 幸田 栄一 (電中研), 佐々木 隆 (東芝ESS), 野崎 理 (高知工科大), 原田 広史 (物材研), 二村 尚夫 (JAXA), 松崎 裕之 (東北発電工業), 吉田 英生 (京大), 笠 正憲 (川崎重工), 輪嶋 善彦 (本田), 渡辺 紀徳 (東大)

広報委員会 ○高原 雄児 (防衛装備庁), 壹岐 典彦 (産総研), 尾関 高行 (電中研), 酒井 義明 (東芝ESS), 谷 直樹 (IHI), 長谷川 晃 (JALエンジニアリング), 姫野 武洋 (東大), 吉田 征二 (JAXA)

表彰委員会 ○識名 朝春 (IHI), 壹岐 典彦 (産総研), 佐藤 哲也 (早大), 飭 雅英 (川崎重工), 山本 誠 (東京理科大)

調査研究委員会 ○川岸 京子 (物材研), 岡崎 正和 (長岡技術科学大), 長田 俊郎 (物材研), 笈 幸次 (首都大学東京), 金久保 善郎 (IHI), 貴志 公博 (三菱重工航空エンジン), 岸部 忠晴 (MHPS), 東部 泰昌 (川崎重工), 日野 武久 (東芝ESS), 福山 佳孝 (JAXA), 輪嶋 善彦 (本田)

将来ビジョン検討委員会 ○高橋 徹 (電中研), 小田 豊 (関西大), 賀澤 順一 (JAXA), 酒井 義明 (東芝ESS), 柴田 貴範 (三菱重工), 柴田 良輔 (本田), 多田 和幸 (東北電力), 寺本 進 (東大), 仲俣 千由紀 (IHI), 姫野 武洋 (東大)

男女共同参画推進委員会 ○都留 智子 (川崎重工), 旭 睦 (IHI), 川岸 京子 (物材研), 川澄 郁絵 (本田), 森川 朋子 (MHPS)

IGTC実行委員会 ○西澤 敏雄 (JAXA), 猪亦 麻子 (東芝ESS), 太田 有 (早大), 北山 和弘 (東芝ESS), 渋谷 直紀 (東芝ESS), 鈴木 正也 (JAXA), 塚原 章友 (MHPS), 寺本 進 (東大), 仲俣 千由紀 (IHI), 中村 恵子 (IHI), 牧田 光正 (JAXA), 安田 聡 (MHPS), 山根 敬 (JAXA), 吉田 征二 (JAXA)

IGTC総務委員会 ○山根 敬 (JAXA), 泰中 一樹 (電中研), 吉田 征二 (JAXA)

IGTC論文委員会 ○寺本 進 (東大), 壹岐 典彦 (産総研), 井上 智博 (九大), 大北 洋治 (JAXA), 岡井 敬一 (JAXA), 小田 豊 (関西大), 齋藤 敏彦 (三菱重工), 酒井 英司 (電中研), 柴田 貴範 (三菱重工), 鈴木 正也 (JAXA), 田頭 剛 (JAXA), 高橋 聡 (IHI), 谷 直樹 (IHI), 都留 智子 (川崎重工), 福田 雅文 (高効率発電システム研究所), 北條 正弘 (JAXA), 堀川 敦史 (川崎重工), 山本 誠 (東京理科大)

IGTC展示委員会 ○安田 聡 (MHPS), 赤澤 弘毅 (川崎重工), 高崎 恭子 (本田), 仲真 幸洋 (GEガスパワー), 藤木 貴子 (IHI), 分銅 克 (東芝ESS), 水野 拓哉 (JAXA), 山形 通史 (富士電機), 安形 友希子 (MHPS), 小森 豊明 (MHPS), 谷岡 忠輝 (MHPS), 塚原 章友 (MHPS), 渡部 文 (MHPS)

IGTC行事委員会 ○仲俣 千由紀 (IHI), 石川 智貴 (東芝), 長田 俊郎 (物材研), 川澄 郁絵 (本田), 高田 和正 (MHPS), 玉井 亮嗣 (川崎重工), 中村 恵子 (IHI), 南條 華子 (IHI)

IGTC財務委員会 ○渋谷 直紀 (東芝ESS), 猪亦 麻子 (東芝ESS)

エキスパート委員会 ○船崎 健一 (岩手大), 田沼 唯士 (帝京大), 二村 尚夫 (JAXA), 山脇 栄道 (アイ・エヌ・シーエンジニアリング)

次号予告 日本ガスタービン学会誌2019年11月号 (Vol.47 No. 6)**特集** マルチフィジックスシミュレーションの進展**論説・解説****巻頭言** 加藤 千幸 (東京大学)

ジェットエンジンにおけるマルチフィジックスCFDシミュレーション

鈴木 正也 (JAXA) 山本 誠 (東京理科大)

非平衡凝縮を伴うマルチフィジックス熱流動のシミュレーション技術 山本 悟, 古澤 卓 (東北大学)

相変化を伴う気液二相流の数値解析 (仮題) 渡辺 紀徳, 姫野 武洋 (東京大学)

Numerical Simulations of Combustion Noise (仮題) Abhishek L. Pillai, 黒瀬 良一 (京都大学)

石炭ガス化炉内現象の数値シミュレーション 渡邊 裕章 (九州大学)

分離反復型並列連成解法の開発と燃焼シミュレーションへの適用 吉村 忍, 山田 知典 (東京大学)

ジェットエンジンにおけるエアロメカ解析技術について (仮) 青塚 瑞穂, 立石 敦 (IHI)

新製品紹介

3次元熱流体解析プログラムCONVERGEによるガスタービンのマルチフィジックスシミュレーション

村上 駿, 石川 正俊 (IDAJ)

ガスタービンエンジン全系解析手法の紹介 河口 洋子 (NUMECAジャパン)

NuFD/FrontFlowRedを用いた解析事例のご紹介 藤澤 ゆき (数値フローデザイン)

※タイトル, 執筆者は変更する可能性があります。

編集 後記

暦の上では8月も終わりましたが、まだまだ厳しい残暑が続いており、今も汗を流しながら編集後記を書いております。九州ならびに中国地方では、線状降水帯の影響で大雨が続いているというニュースを聞き、自然の力をまざまざと感じております。被害を受けられた皆様には、心よりお見舞い申し上げます。

さて、9月号の特集は、「エネルギー産業への機械学習の応用」と題しまして、9編の解説記事を掲載致しました。実は、機械学習については以前より個人的に興味があり、2年前にアソシエイトエディタになった時にも、同テーマで特集号を組もうと思った経緯があります。当時は記事が集まらずに断念しましたが、現在では多くの研究者が機械学習を取り入れ、その手法の幅も広がっております。テーマがガスタービンに直結していないのではないかという懸念はございますが、エネルギー関連に関わる新しい技術の一つとしてお読みいただきたく思います。

詳しい内容は各記事に委ねますが、深淵先生の巻頭言と矢入先生の機械学習の概説で、機械学習への理解が深まり、身近に感じられて頂けたのではないのでしょうか。また、企業、研究所、大学における、発電設備、エンジン、ロケット、材料等、様々な適用例が揃い、私自身、多くを勉強させていただきました。また、本号は、6月に米国Phoenixで開催されたASME国際ガスタービン学会の見聞記やガスタービン及び過給機生産統計が掲載されており、内容的にも分量的にもボリュームのあるものとなっております。

私は、この4月より編集委員長長の責務を仰せつかり、編集のやりがいと難しさ、先人たちのご苦勞を感じております。学会誌をより良くしていくためには、世の中の

動向に目を向けるだけでなく、学会員の皆様のご意見をフィードバックすることが大事だと思っております。また、特集記事以外にも、技術論文や寄稿、講義など、学会誌をより充実させたいと思っております。その際、会員の皆様方には、ご意見をいただいたり、記事の執筆をお願いすることになりますので、是非ともご協力いただきたいと思っております。

最後になりましたが、執筆者の方々にはご多忙の中、ご執筆を快くお引き受けいただきましたことを編集委員一同より心から感謝申し上げます。(佐藤 哲也)

- 9月号アソシエイトエディター
佐藤 哲也 (早稲田大学)
- 9月号担当委員
野原 弘康 (ダイハツディーゼル)
八田 直樹 (三井E&Sマシナリー)
村上 秀之 (物質・材料研究機構)
山下 一憲 (荏原製作所)
ASME見聞記：金子 雅直 (東京電機大学)

(表紙写真)

今回の表紙については、【論説・解説】の著者より流用およびお借りしています。

詳細については、下記記事をご参照ください。

- ・【典型例で眺める機械学習の様々なタスク】
..... (P.282 ~ 287)
- ・【発電設備におけるデジタルテクノロジーの適用について】..... (P.288 ~ 292)
- ・【データドリブン手法に基づく低次元特徴抽出手法を用いた燃焼不安定性解析】..... (P.316 ~ 322)

だより

♣事務局

今年は梅雨の季節に長雨、低温が続く、涼しい夏を期待していたのですが、例年通りの厳しい暑さとなってしまいましたね。ようやく秋の気配が感じられるようになった今日この頃、皆様いかがお過ごしでしょうか。

幸いにも今年は夏バテを感じることはなかったものの、春先から長引く肩の不調に悩んでおります。中年以降の多くの人が悩む、肩が痛んで上がらなくなる通称「五十肩」です。聞くと思わずクスッと笑ってしまいそうになるのは、このネーミングのせいかもしれませんが、正式には「肩関節周囲炎」と言うそうです。放っておいても自然に治ると言われているためか、整形外科を受診しても、注射や湿布の対症療法に、“気長にリハビリしてね”，と軽くあしらわれます。ゆえに、五十肩患者は、日々の痛みを耐え、肩への負担がある一

線を越えた時に襲われる激痛に怯えながら、じっと時間が過ぎるのを待つしかないのです(涙)。私もようやく痛みは落ち着いてきたものの、なかなか腕は思うように上がらず、未だリハビリに通っております。服の着替えにもがく日々は、まだまだ続きそうです・・・。

さて、IGTC2019Tokyoの開催まで残り2か月足らずとなりました。本号がお手元に届く頃には、定期講演会@函館も終わり、事務局内はIGTCモードに切り替わっている頃かと思えます。4年前のIGTC2015開催時は、世界27カ国、約150名の海外からの参加者にお越しいただきました。7月よりすでに参加登録がスタートしておりますが、近年のインバウンドブームにより、前回以上に多くの海外の皆様にご参加いただけるのではと内心期待しております(*^^)v (山本 由香)

学会誌編集および発行要領（抜粋）

2018年7月13日改定

1. 本会誌の原稿はつぎの3区分とする。
 - A. 依頼原稿：学会誌編集委員会（以下、編集委員会）がテーマを定めて特定の人に執筆を依頼する原稿。執筆者は本学会会員（以下、会員）外でもよい。
 - B. 投稿原稿：会員から自由に随時投稿される原稿。執筆者は会員に限る。
 - C. 学会原稿：本学会の運営・活動に関する記事（報告、会告等）および会員による調査・研究活動の成果等の報告。
- 1.2. 技術論文の投稿については、「技術論文投稿要領」による。
- 1.3. 英文技術論文の投稿については、Instruction to Authors, JGPP (International Journal of Gas Turbine, Propulsion and Power Systems) による。
2. 依頼原稿および投稿原稿は、論説・解説、講義、技術論文、寄書（研究だより、見聞記、新製品・新設備紹介）、随筆、書評、情報欄記事の掲載欄に掲載することとし、刷り上がりページ数は原則として以下のとおりとする。

論説・解説、講義	6ページ以内
技術論文	「技術論文投稿要領」による
寄書、随筆	3ページ以内
書評	1ページ以内
情報欄記事	1/2ページ以内
3. 原稿の執筆者は、本会誌の「学会誌原稿執筆要領」に従って原稿を執筆し、編集委員会事務局（以下、編集事務局）まで原稿を提出する。編集事務局の所在は付記1に示す。
4. 依頼原稿は、編集委員会の担当委員が、原稿の構成、理解の容易さ等の観点および図表や参考文献の書式の観点から査読を行う。編集事務局は査読結果に基づいて、執筆者への照会、修正依頼を行う。
5. 投稿原稿のうち技術論文以外のものは、編集委員会が審査し、本会誌への掲載可否を決定する。
6. 投稿原稿のうち技術論文の審査、掲載については、「技術論文投稿要領」に従う。
7. 依頼原稿の執筆者には、学会事務局から原則として「学会誌の執筆謝礼に関する内規」第2条に定めた謝礼を贈呈する。
8. 非会員の第一著者には掲載号学会誌1部を贈呈する。
9. 本会誌に掲載された著作物の著作権は原則として本学会に帰属する。本学会での著作権の取扱いについては別途定める「日本ガスタービン学会著作権規程」による。
10. 他者論文から引用を行う場合、本会誌に掲載するために必要な事務処理及び費用分担は著者に負うところとする。

付記1 原稿提出先および原稿執筆要領請求先（編集事務局）
 ニッセイエブロ(株) 企画制作部
 学会誌担当：高橋 邦和
 〒105-0003 東京都港区西新橋1-18-17 明産西新橋ビル
 TEL：03-5157-1277
 FAX：03-5157-1273
 E-mail：eblo_h3@eblo.co.jp

技術論文投稿要領（抜粋）

2018年7月13日改定

1. 本学会誌に技術論文として投稿する原稿は次の条件を満たすものであること。
 - 1) 主たる著者は本学会会員であること。
 - 2) ガスタービン及びエネルギー関連技術に関連するものであること。
 - 3) 「学会誌原稿執筆要領」に従って執筆された、日本語原稿であること。
 - 4) 一般に公表されている刊行物に未投稿であること。ただし、以下に掲載されたものは未投稿と認め技術論文に投稿することができる。
 - 本学会主催の学術講演会・国際会議のプロシーディングス
 - 特許および実用新案の公報、科学研究費補助金等にかかわる成果報告書
 - 他学協会の講演要旨前刷、社内報・技報、官公庁の紀要等の要旨または抄録
2. 原則として刷り上がり8ページ以内とする。ただし、「学会誌の掲載料に関する内規」第2条に定めた金額の著者負担で4ページ以内の増ページをすることができる。
3. カラー図は電子版と本学会ホームページ上の「技術論文掲載欄」に掲載し、冊子体にはモノクロ変換した図を掲載する。著者が「学会誌の掲載料に関する内規」第3条に定めた金額を負担する場合には、冊子体もカラー印刷とすることができる。
4. 投稿者は、「学会誌原稿執筆要領」に従って作成された印刷原稿または原稿電子データを、技術論文原稿表紙とともに学会誌編集事務局に提出する。
5. 投稿された論文は、論文委員会が「論文査読に関する内規」に従って査読を行い、掲載可否を決定する。
6. 論文内容についての責任は、すべて著者が負う。
7. 本技術論文の著作権に関しては、「学会誌編集および発行要領（抜粋）」9.および10.を適用する。

日本ガスタービン学会誌
Vol.47 No.5 2019.9

発行日 2019年9月20日
 発行所 公益社団法人日本ガスタービン学会
 編集者 佐藤 哲也
 発行者 渡辺 紀徳
 〒160-0023 東京都新宿区西新宿7-5-13
 第3工新ビル402
 Tel. 03-3365-0095 Fax. 03-3365-0387
 郵便振替 00170-9-179578
 銀行振込 みずほ銀行 新宿西口支店
 (普) 1703707
 印刷所 ニッセイエブロ(株)
 〒105-0003 東京都港区西新橋1-18-17
 明産西新橋ビル
 Tel. 03-5157-1277 Fax. 03-5157-1273

©2019, 公益社団法人日本ガスタービン学会

複写複製をご希望の方へ

公益社団法人日本ガスタービン学会では、複写複製に係る著作権を一般社団法人学術著作権協会に委託しています。当該利用をご希望の方は、学術著作権協会 (<https://www.jaacc.org/>) が提供している複製利用許諾システムを通じて申請ください。