

AI技術を実装したSA減衰力計算の高精度化と AI運用管理基盤の構築

Enhancing the Accuracy of SA Damping Force Simulation Implemented with AI Technology and Building an AI Operational Management Platform

萬谷 浩章 ・ 提箸 良太
MANTANI Hiroaki ・ SAGEHASHI Ryota

要 旨

AI (Artificial Intelligence: 人工知能) の将来動向として、AIとCAE (Computer Aided Engineering) を組み合わせた技術の産業利用が着目されている。AIとCAEを組み合わせることで、AIの学習のために現実世界では起こりえないデータをCAEにより獲得できること、FEM (Finite Element Method: 有限要素法) をAIに縮退化することでCAEの計算時間を短縮できること等のメリットがある。

また、近年、自動車業界ではMBD (Model-Based Development: モデルベース開発) の普及により、試作品の代わりにCAEのモデルを企業・部門の間で交換する“すり合わせ開発”が活発化している。

MBDを円滑に進めるために、当社の主力製品であるショックアブソーバの性能予測のCAEに機械学習を組み合わせることで、性能指標の減衰力を高速かつ高精度に予測できる技術を構築した。あわせて、機械学習モデルの運用管理を自動化するシステムも開発した。

本報では、機械学習を実装したショックアブソーバの減衰力計算と機械学習モデルの運用管理基盤について技術解説する。

Abstract

The future trend of Artificial Intelligence (AI) includes the industrial application of combining AI with Computer Aided Engineering (CAE). By integrating AI and CAE, several benefits emerge, such as the acquisition of data through CAE that would be impossible to obtain in the real world for training AI models, reducing CAE computation time by degenerating Finite Element Method (FEM) tasks for AI.

Additionally, in recent years, the automotive industry has witnessed an increased adoption of Model-Based Development (MBD), leading to collaborative development where CAE models replace physical prototypes between departments or companies.

To facilitate MBD and enhance the performance prediction of our flagship shock absorber products, we developed a technology that combines machine learning with CAE. This allows us to predict damping force performance metrics rapidly and accurately. Furthermore, a system was developed to automate the operation and management of machine learning models.

In this report, we provide a technical explanation of the implementation of machine learning for shock absorber damping force calculations and the construction of an operational management platform for machine learning models.

1 緒言

1.1 対象製品

本報で対象とする図1の自動車用緩衝器のショックアブソーバ（以下SA）について紹介する。SAには車両の振動を減衰させる役割がある。路面の凹凸や車両姿勢の変化によってSAは伸び縮みし、作動速度に応じて容器内で押しつけられた作動油の流れを小さな面積のオリフィスや積層リーフバルブで絞ることで生じる圧力差として減衰力を発生させる。SAの性能は、減衰力-速度特性で評価する。中でも重要な構成部品である積層リーフバルブは、作動中の圧力によって油路面積を変化させるために取り付けられる薄い鋼板で、その積層方法（外径、板厚、枚数）を変えることで車両に合った減衰力にチューニングされる。

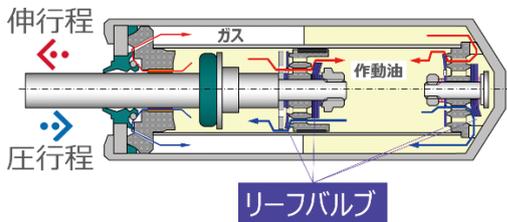


図1 ショックアブソーバの構造

1.2 カヤバのCAEの取り組み

カヤバ（以下、当社）では、1968年にCAEを導入して以来、図2に示す様々な予測技術を導入し、製品・技術の開発を支援してきた。CAEには、企画段階で製品の機能を検討する1DCAE^{注1)}（システムシミュレーション）と製品形状を詳細に検討する3DCAE^{注2)}（FEM^{注3)}）があり、双方の予測技術を培ってきた。1985年に運用を開始した技術計算を容易に行う当社独自の仕組みであるCAE標準実行システム¹⁾では、1DCAE・3DCAEを問わず様々なアプリケーションで入力方法・実行方法・出力方法を統一することで、高度な予測技術をどこからでも簡単に利用できる。現在、このシステムには約2,000個のプログラムが登録されている。

本報で対象とするSAの減衰力計算は、当社の基礎理論が1981年に確立されて以来、CAE標準実行システム上で計算する数式ベースの1DCAEとして取り組んできた。



図2 自動車用緩衝器の解析一例

1.3 概要

昨今では、モデルベース開発（以下MBD^{注4)}）の普及に伴って、製品開発の上流で機能と形状の検討サイクルを回すために、1DCAEと3DCAEを行き来する製品開発を実現する必要がある。また、社内の関係部署や会社間で試作品の代わりにモデルを流通させるニーズが高まっている。MBDに取り組む中で解決すべきと考える技術課題を以下に示す。

- ① シンプルで見通しの良いモデルを扱う1DCAEと実機をより忠実に再現する3DCAEではモデリングに対する考え方や必要なスキルが異なることからCAE専任者の中でも分業化がされており、システム検討と形状検討で連携がうまくとれていない場面がある。
- ② 3DCAEによる形状検討では、解析コストが高くなりがちで、形状検討に多大な時間を要している。
- ③ 関係会社や他部署とのモデル流通では、製品の代わりにモデルが担うため、詳細度が高くても高速に計算できるモデルが要求される。

これらの技術課題を解決してMBDを円滑に進めるために、詳細な形状を扱える3DCAEを機械学習モデルに縮退化して1DCAEに実装する技術構築に取り組む（図3）。

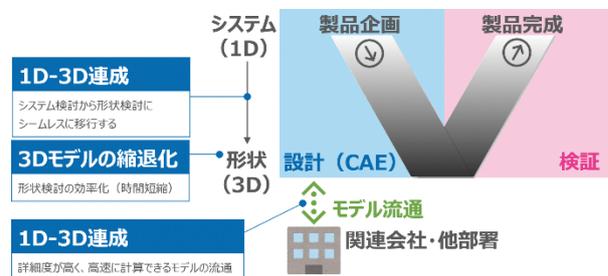


図3 MBDの技術課題

高精度・高速にSAの減衰力を予測できる技術を構築するために、SAの積層リーフバルブのFEMモデルを縮退化した機械学習^{注5)}モデルを1DCAEのシミュレーションツール（以下1D-CAE^{注6)}）に実装す

る技術を構築したので、概要を図4に示す。



図4 積層リーフバルブでの技術構築

- 注1) 数式ベースのシステムシミュレーションを用いて製品性能を見通すCAE分野。
- 注2) FEMを用いて製品形状を詳細に検討するCAE分野。
- 注3) 製品形状を要素(メッシュ)で分割することで、複雑な形状を扱うことができる数値解析手法の一つ。
- 注4) モデルを用いたシミュレーションを活用して設計および開発を行う手法。
- 注5) データから規則性やパターンを学習し、コンピュータが現状判定や将来予測をする技術。
- 注6) 1DCAEのためのシミュレーションツール。ハイフンを使ってCAE分野とツールを差別化して表現される。

2 FEMモデル

技術構築で対象とする積層リーフバルブのFEM解析(図5)の特徴を以下に示す。

- ①組立時(ねじ締結による軸力負荷)と作動時(オリフィス等の油圧抵抗による圧力負荷)の積層リーフバルブの変形量・応力を評価できる
- ②SAの減衰力計算に用いている円板剛性の理論計算では考慮できない締結軸力による初期変形や積層リーフバルブ間の部分接触を考慮できる
- ③微小変形理論のみならず、大変形理論での構造解析ができる
- ④計算時間が長いいため、SAの減衰力計算には敬遠され、主に積層リーフバルブの周辺部品の形状検討に利用されてきた

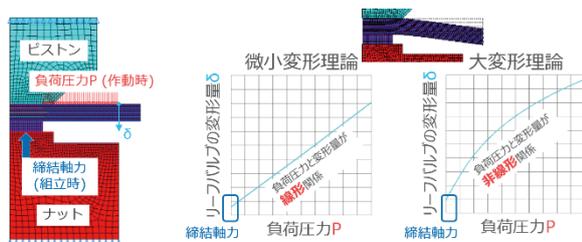


図5 積層リーフバルブのFEM解析

3 データセットの作成

SAの設計ラインナップの一部を対象に、積層リーフバルブの積層方法(外径, 板厚, 枚数), 負荷圧力を変えてFEM解析を連続実行することで、機械学習モデルの学習に必要なデータセットを作成した(表1)。このデータセットでは、積層リーフバルブに高低差を設けて初期変形によるプリロードを付加することで高い減衰力を発生させる図6のプリロードバルブと呼ばれる複雑な積層リーフバルブも計算対象とした。

連続計算にあたり、FEMのプログラムコードをPython[®]で文字列処理をすることで、積層リーフバルブの積層方法(外径, 板厚, 枚数)をランダムに変更したプログラムを事前に作成し、当社のCAE標準システムを用いて、夜間・休日を問わず連続して自動で計算を実行した。

表1 学習データセット

| | |
|-------------|------------|
| 積層リーフバルブの外径 | 5水準以上 |
| 積層リーフバルブの板厚 | 4水準以上 |
| 積層リーフバルブの枚数 | 3水準以上 |
| プリロードバルブ | 2水準(あり/無し) |
| 負荷圧力 | 21条件 |
| 変形理論 | 大変形理論 |
| データ数 | 1,045,380 |

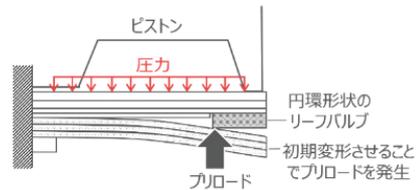


図6 プリロードバルブ

4 機械学習モデルの構築

様々な機械学習のアルゴリズムの実装を試した結果、Microsoft Corporationが近年リリースしたPython^{®注7)}のライブラリであるFLAMLを用いることで、FEMの解析結果を高精度に推論できる機械学習のモデルを構築できた。構築した機械学習モデルの未知データに対する推論精度を図7に示す。機械学習の推論結果(縦軸)とFEMの計算結果(横軸)が傾き1(45度)の直線上にプロットされており、機械学習で高精度な推論ができていることが確認できる。

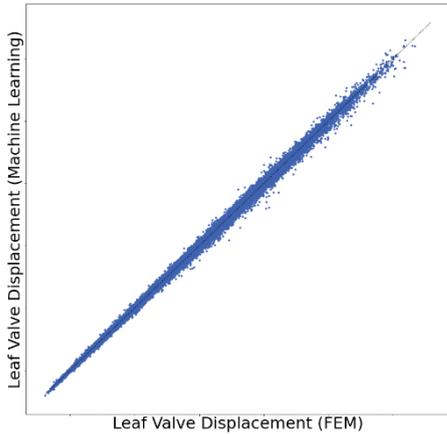


図7 機械学習モデルの推論精度

FLAMLは、決定木^{注8)}の機械学習のアルゴリズムとハイパーパラメータ（モデル作成者がアルゴリズム制御のために学習前に設定するパラメータ）を自動で選択できるAutoMLである。FLAMLを用いた結果、最終的にLightGBMのアルゴリズムを使用することとした。LightGBMは軽くて高速であることが特徴的な決定木のアルゴリズムで、近年、機械学習のコンペなどで広く活用されている。

5 機械学習モデルの1D-CAEへの実装

1D-CAEのSimulationX[®]を対象に、ニュートンワークス株式会社と共同で、Python[®]の機械学習モデルをSimulationX[®]に実装する方法について調査した結果、実装が容易な通信による連成解析を採用することとした。SimulationX[®]とPython[®]の間で通信を行う連成解析のデータ授受の流れを図8に示す。図8では6章で述べる機械学習モデルを実装したSA減衰力計算の有効性を検証するために同一PC内でアプリケーション間の通信を検討しているが、関係会社や他部署とのモデル流通での利用が難しいため、最終的には7.4節に示すクラウドとの通信を採用している。



図8 SimulationX[®]とPython[®]のデータ授受

積層リーフバルブの外径・板厚・枚数などの時間によって変化しない変数は計算開始直後に一度だけSimulationX[®]からPython[®]に変数情報を渡し、負荷圧力のような時間によって変化する変数は通信を用いて通信時間ステップごとに変数情報をPython[®]に渡すこととした。Python[®]ではSimulationX[®]から受け取った変数情報から積層リーフバルブの変形量を推論し、通信でSimulationX[®]に返すこととした。

通信を用いて、SimulationX[®]とPython[®]の連成解析を計算実行するにはSimulationX[®]とPython[®]の2つのツールを起動してそれぞれのツールで計算実行をする必要がある。そこで、SimulationX[®]のみで計算を完結させるために、SimulationX[®]の計算実行と同期して機械学習モデルのPython[®]コードを実行するSimulationX[®]のカスタマイズブロックを自作した(図9)。カスタマイズブロックの作成にはModelica言語^{注9)}を用いた。カスタマイズブロックの特徴を以下に示す。

- ①機械学習モデルのパラメータの設定ができる
- ②SimulationX[®]とPython[®]の間で通信計算(図8)ができる
- ③通信計算で動作させるPython[®]の仮想環境、Python[®]コードを設定できる

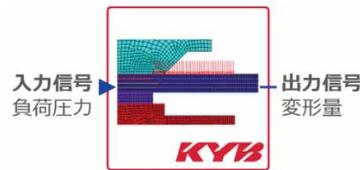


図9 SimulationX[®]のカスタマイズブロック

注7) Pythonは、Python Software Foundationの商標です。

注8) データをツリー構造で条件分岐する機械学習のアルゴリズム。非線形の関係をとらえることができる。

注9) マルチドメインの物理モデリング言語。

6 SAの減衰力計算

4章で構築した機械学習モデルを図9のSimulationX[®]のカスタマイズブロックに実装することで、構築した機械学習モデルがSAの性能指標である減衰力-速度特性の予測精度におよぼす影響について検証する。検証のために、Modelica言語で作成した当社独自の油圧ライブラリと機械学習モデルを接続して減衰力-速度特性を計算するSimulationX[®]のモデルを構築した(図10)。このモデルでは、油圧ライブラリで計算したリーフバルブの負荷圧力から積層リーフバルブの機械学習モデル

で積層リーフバルブの変形量を計算し、油路の開口面積に換算して油圧ライブラリに戻す計算とした。

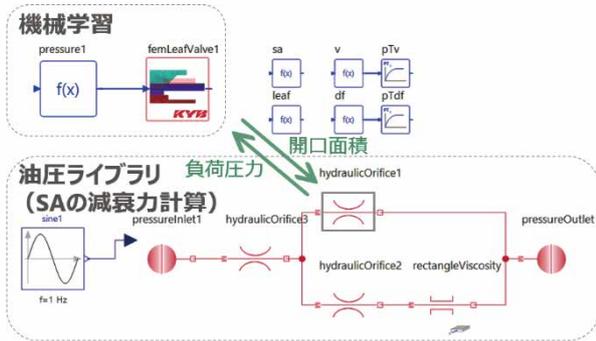


図10 SAの減衰力-速度特性の計算モデル

実験に対する減衰力-速度特性の予測精度検証の一例として、図6のプリロードバルブを対象に予測精度を検証した結果を図11に示す。この結果より、従来手法である理論計算に対して、機械学習モデルを組み込むことで、減衰力-速度特性を高精度に予測できることが確認できた。

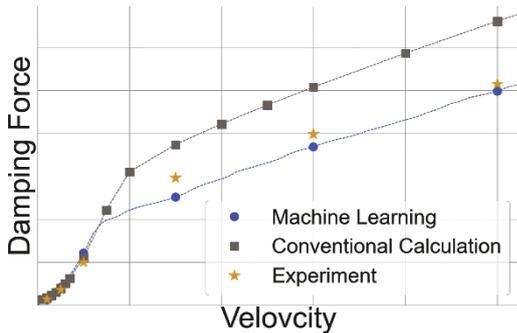


図11 減衰力-速度特性の予測精度

積層リーフバルブのFEMの計算時間93s(圧力条件23点)に対して、FEMモデルを機械学習モデルに縮退化することで計算時間3s(圧力条件1000点・SAの減衰力計算処理を含む)にでき、計算時間を大幅に短くできた。

7 機械学習モデルの運用管理基盤の構築

7.1 機械学習モデルの運用管理システム

前章までで技術構築した機械学習モデルを運用管理する上で、大きく以下の3つの課題が顕在化した。

- ①環境構築の複雑さ・技術漏洩の懸念
- ②機械学習モデルの運用管理工数の肥大化
- ③機械学習モデルの品質管理の難しさ

①の“環境”とは、機械学習モデルの利用環境を指している。通常、機械学習モデルを個人のPC上で

利用するためにはPython[®]のプログラミング環境を構築する必要があり、機械学習のモデルデータに加えてPython[®]のプログラムコードの提供が必要となる。このため、関係会社や他部署とのモデル流通において、技術漏洩の懸念が生じる。また、プログラムコードにはサードパーティ製のライブラリも含まれており、動作するPC環境によっては、対象となるバージョンのライブラリが利用できない可能性も考えられる。このようなトラブルが生じる可能性も含め、環境構築は複雑になりやすく、モデル利用者の工数負担が大きくなる懸念が生じる。②について、機械学習モデルの運用は、一度モデル生成すれば終わりではない。機械学習モデルの精度は、環境の変化などにより、時間経過に伴って次第に劣化していく可能性がある。具体的には、積層リーフバルブの使われ方（設計のトレンド）が変化することで予測精度が低下する可能性がある。こうした問題に対処するため、安定した機械学習モデルの運用にはモデル再学習の工程が必要不可欠となる。機械学習モデルを継続的に再学習する作業は、機械学習モデルの管理者の工数負担が大きく、こうした運用工程がワークフロー化されていない場合は工数の肥大化が懸念される。③については、再学習によって機械学習モデルを更新しても、前述した①の利用方式では、機械学習モデルの管理そのものが利用者個人に依存してしまい、機械学習モデルの品質管理が困難であることが懸念される。

これらの課題を解決するために、管理された高品質な機械学習モデルを関係者で共有して利用できるシステムとして、MLOps^{注10)}を実現する機械学習モデルの運用管理基盤を自社開発した。図12にその概略図を示す。

開発したシステムでは、機械学習モデルの元となる学習データの収集から加工、可視化、分析だけでなく、機械学習モデルの学習、精度の確認、作成したモデルのAPI^{注11)}化による、SAの減衰力計算に活用可能なAIサービスの展開等、機械学習モデルに関連する工程を一元的に管理でき、機械学習モデルの管理者が従来行う必要のあった作業を大幅に削減することができるようになる。また、システムの構築には、オンプレミス^{注12)}と比較して機能拡張性や、耐障害性に強みのあるAmazon Web Services[®]のクラウドを活用した。また本システムの開発は、部門横断で機械学習やシステム開発に見識の深い社員が集まる社内のAIコミュニティ²⁾で担当し、1年間でPoC^{注13)}を完了させた。

注10) 機械学習 (Machine Learning) と運用 (Operations) を組み合わせた造語。機械学習モデルの開発、分析、

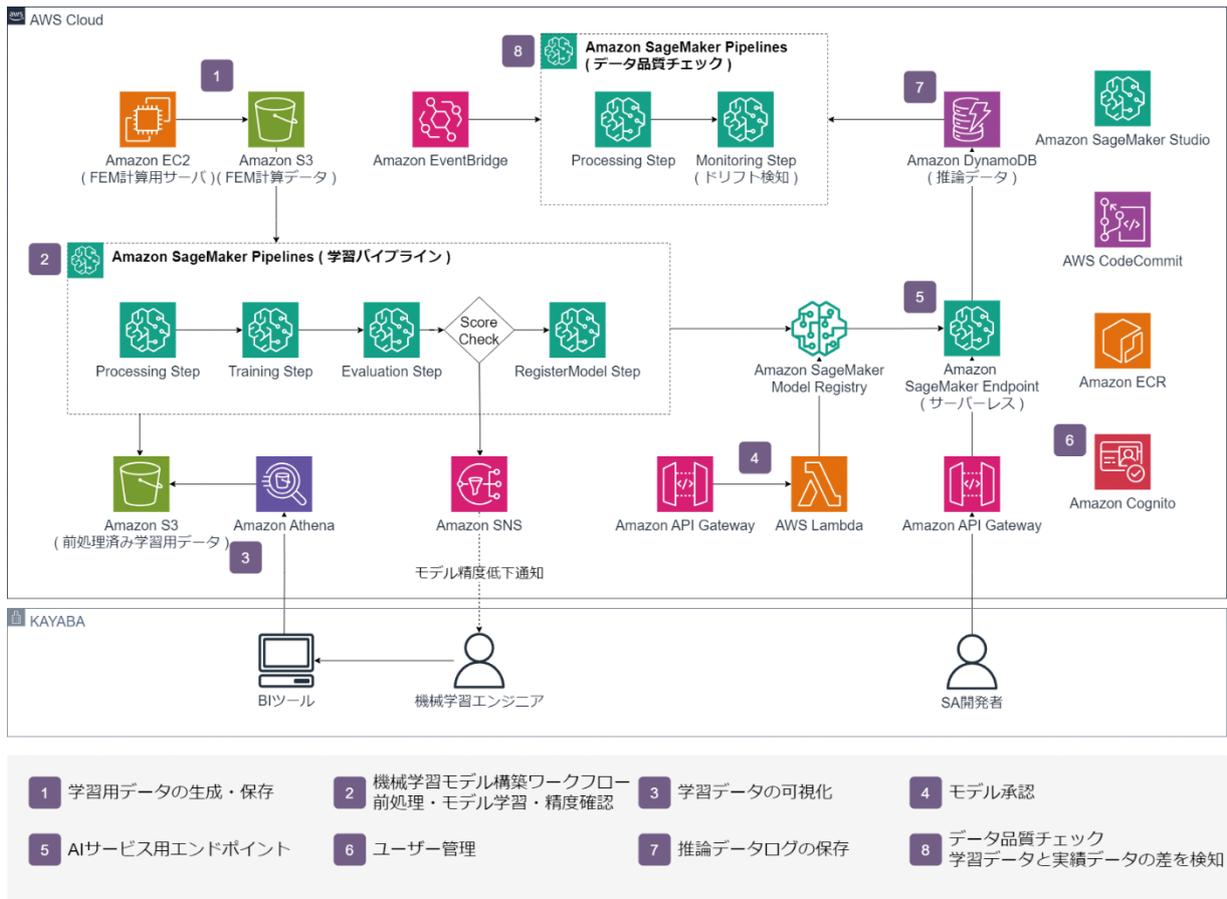


図12 機械学習モデルの運用管理基盤概略図

運用を効率化するための手法や考え方。

注11) ソフトウェアやプログラム等システム同士を繋ぎその機能を共有できる仕組み（インターフェース）。

注12) インフラの構築に必要なサーバやネットワーク機器などを自社で保有し運用するシステムの利用形態。

注13) Proof of Concept（概念実証）の略でありサービスや製品に用いられるアイデアや技術が実現可能かを確認する一連の検証作業。

7.2 データ収集・管理・可視化

本システムを活用することで、学習データの生成からアップロードまでの一連の工程をスクリプトで自動化することによって、作業者は最小限の操作で作業を実施することができる。学習データの元となるFEM解析データは、当社のCAE専任者によってモデルの再学習が必要と判断された時に、学習データ生成スクリプトによって、CAE部門が管理するクラウド上の計算サーバに生成されるようになっている。このスクリプトによって、FEM解析データは機械学習モデルの学習データとして利用できるようデータ加工され、本システムのAmazon S3^{注14)}へ自動的に転送される仕組みとなっている。

また、転送されたデータはBI^{注15)}ツールの

Tableau^{注16)}を用いて可視化することができる仕組みとなっている（図13）。当社では、全社横断的にTableau[®]を使ったデータ分析環境を提供しており、社内でも活用しているBIツールとの親和性を高めている。これによって社内の機械学習モデルの管理者やデータサイエンティストが素早くデータ分析を行える仕組みを実現した。

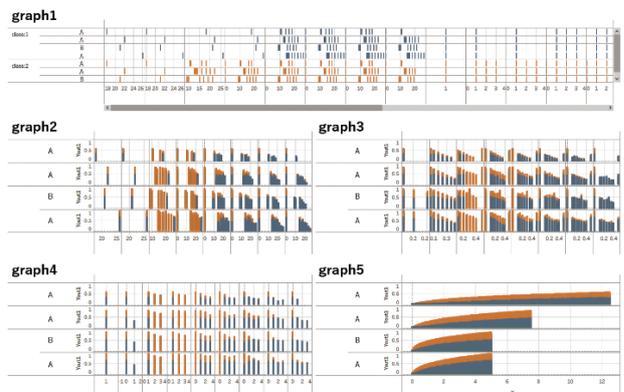


図13 学習データ分析画面

注14) 高い耐障害性を持ち、タイプや容量に制限を受けることなくデータを保存、保護するクラウドストレージ。

注15) Business Intelligence：大量に蓄積しているデータ

から必要な情報を集約・分析し、企業の経営や業務に活用できるようにする技術や手法。

注16) Salesforce社が提供するBIツール、Tableau[®]はSalesforce社の登録商標です。

7.3 学習パイプライン

本システムでは、機械学習モデルの開発者が、少ない工数で機械学習モデルを開発できる学習パイプラインを構成している。この学習パイプラインは、Amazon SageMaker^{注17)}の機能を用いて、データ前処理^{注18)}、モデル学習、モデル精度検証、推論エンドポイント^{注19)}化の一連の工程を統合し、ワークフローとして自動化する仕組みとなっている。

Amazon SageMakerを活用することで、処理に必要なスペックを兼ね備えた仮想コンピューティング環境でワークフローを実施することができる。このため、過剰なスペックの物理的な計算サーバを導入することなく、処理に最適なリソースを素早く展開でき、コスト最適な処理を実現できる。

機械学習モデルは、特定の計算条件によって複数のモデルに分割する構成としている。これによって、モデルの設計変更が容易となり、需要の変化に強い柔軟な開発を実現できる。加えて、モデル再学習によって起こり得る予測精度の劣化についても、その原因となるデータを特定しやすくする効果も期待できる。

機械学習モデルの開発者は、機械学習モデルの条件を指定するコマンドを1行実行するだけで、対象のモデルを学習するパイプラインを起動することができる。さらにこの学習パイプラインは、機械学習モデルの新規作成と、再学習による更新の両方に対応しており、長期的な運用を見越したモデル開発に関わる全ての工程を単一のパイプラインに集約した。一方で、パイプラインに入力されるデータから機械学習モデル新規作成のワークフローか、再学習のワークフローかを自動的に判定することができる設計になっている。また、モデル開発に関わる基本的なパラメータは、事前に調査した最適な値を定義しておくことで、パイプラインの実行毎に本来必要な煩雑な項目設定を排除した。こうした工夫により、モデル学習の再現性を高めつつ、機械学習モデルの開発者の工数削減を達成するパイプラインを構築することができた。

機械学習モデルの学習が完了すると、生成された学習モデルが自動的にAmazon S3に保存され、モデル性能を評価したレポートが社内内で活用しているコミュニケーションツールを介して機械学習モデルの管理者に通知される仕組みとなっている(図14)。

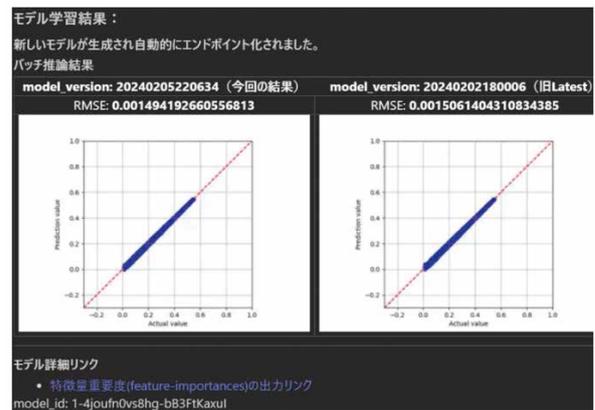


図14 機械学習モデル結果の通知画面

学習結果の通知画面では、生成されたモデルのテスト結果に対するRMSE^{注20)}や特徴量重要度^{注21)}を参照することができる。加えて、再学習によって更新された機械学習モデルの場合は、前回のモデルとの比較結果を自動的に表示するようになっており、一目で学習結果を確認できる工夫を取り入れている。

また機械学習モデルの詳細についてはAmazon SageMaker上でも確認することができる。機械学習モデルの開発者はAmazon SageMaker Experiments^{注22)}の機能を活用して、学習中のモデル精度の推移や、学習アルゴリズムに必要な各種パラメータの最適値の推移、最終的なモデル精度の可視化に加えて、任意の過去のモデルとモデル性能を比較することができる(図15)。

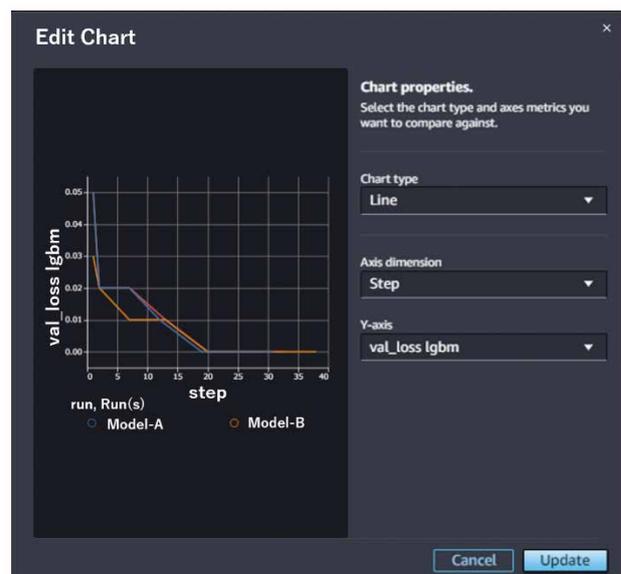


図15 機械学習モデルの学習精度推移の可視化

注17) 機械学習モデルを高速に開発、展開するための実装環境を提供するクラウドサービス。

注18) 学習データ生成スクリプトによるデータ加工後に

生成される学習データと過去の学習データを統合する処理。

注19) 機械学習モデルを外部から利用できるようにするためのインターフェース。

注20) 予測誤差の二乗値の平均に対する平方根を算出する関数。回帰問題を扱う機械学習モデルの一般的な評価関数。

注21) 学習データの各特徴量がモデル精度の改善にどれだけ貢献したかを示す指標。

注22) モデルの学習記録を追跡できるAmazon SageMakerの機能の一つ。

7.4 AIサービス化

学習パイプラインを経て生成された機械学習モデルは、自動的に推論エンドポイントとしてデプロイされ、エンドユーザがリアルタイムに機械学習モデルを利用することができるようになっている。

本システムでは、主に社内のSA開発者が社内で普段利用しているSimulationX[®]から直接的に機械学習を用いたSAの減衰力計算を行える仕組みとして、SimulationX[®]に組み込むカスタムライブラリを独自開発した。このカスタムライブラリをCAEツールにインポートすることで、カスタムライブラリはクラウド上の推論エンドポイントに対してWebAPI^{注23)}で通信を行うことができる。

WebAPIはWebサイトなどのバックエンド処理^{注24)}に用いられる一般的な仕組みであり、これを活用することにより、モデルデータやプログラムコードの要素を含む具体的な処理内容を秘匿化することができる。この仕組みを活用することで、ID-CAEから直接的に推論エンドポイントと通信することができ、そこから取得した機械学習モデルの推論結果をID-CAEに反映させた、高精度なSAの減衰力計算を行うことができる。

本仕組みを用いたSAの減衰力計算では、クラウド上の機械学習モデルで推論処理を行うため、インターネット通信が発生する。このため、シミュレーション時間を短縮する方法として、機械学習モデルとの通信回数を最適化する独自の通信アルゴリズムを考案した。機械学習を活用したSAの減衰力計算にこのアルゴリズムを適用した結果、図11の減衰力-速度特性の計算時間について、このアルゴリズムを適用する前と比較しておよそ1/10の通信時間に抑えることができた。以上のことから、本仕組みを活用することにより、エンドユーザは個人で機械学習の環境構築を必要とせず、簡素な手順で機械学習モデルを利用でき、高速・高精度なSAの減衰力計算を行うことができる。

また、開発した機械学習モデルは本システムで全

てバージョン管理されており、システムによって再学習しモデルが更新された後でも、引き続き旧モデルを利用できる仕組みとなっている(図16)。

これによって、機械学習を用いたSA減衰力計算の計算結果について、再現性を担保することができる。

カスタムライブラリはFMI規格^{注25)}のデータ形式へ変換出力できるようになっており、FMI規格をサポートする他種のCAEツールにおいても互換性をもって活用することができる。具体的には、独自開発したカスタムライブラリを含むSimulationX[®]で作成したモデルをライセンスフリーのFMU^{注26)}に変換することができる。これによって、他種のCAEツールを利用する社外のSA開発者でも本仕組みを利用することができる。本システムでは、主に社外のエンドユーザを想定したユーザーアカウント管理の機能も実装しており、サービス利用範囲の拡大を狙いつつ、セキュリティ性の高いAPIの提供を検討している。予め登録された社外のエンドユーザは、本システムで提供するユーザーログイン画面から、各ユーザーアカウントへのログインを実施することができ、ログインに成功すると認証トークンを取得することができる(図17)。

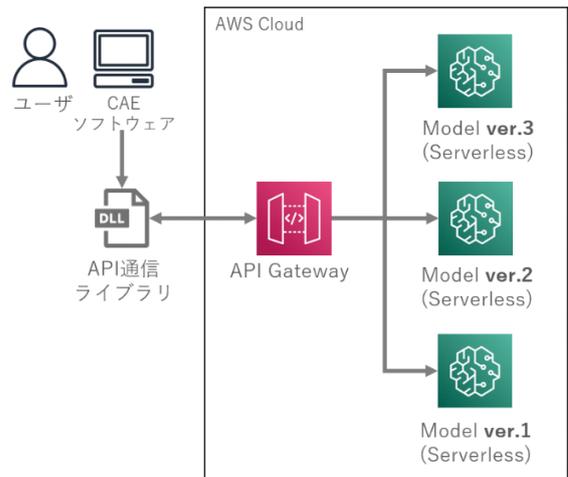


図16 機械学習モデルのバージョン管理模式図

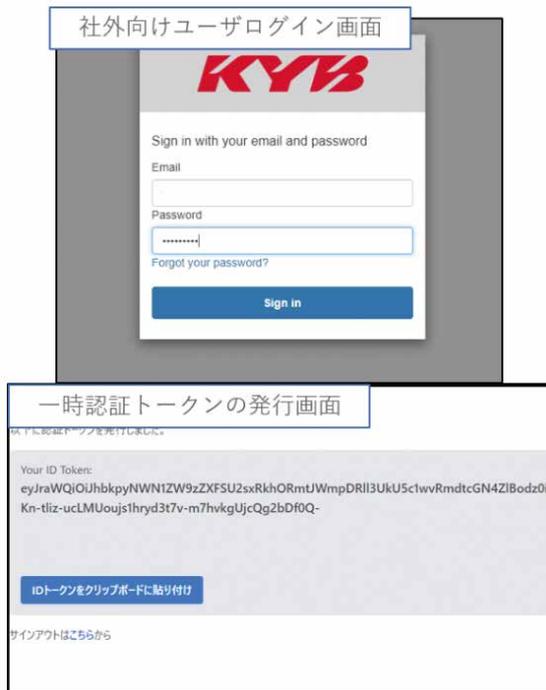


図17 社外向けユーザーログイン画面と認証トークン発行画面

社外のエンドユーザは、事前に提供されるFMUをCAEツールにインポートすることで、CAEツールを介して認証トークンを入力することができるようになる。このFMUを利用すると、認証トークンを利用した通信のみが許可され、システム側でアクセスが認可された場合にのみ、機械学習モデルとの通信ができるようになる。この機能により、社内外問わず全てのエンドユーザが同じように、機械学習モデルを活用したSAの減衰力計算を行うことができるようになる（図18）。

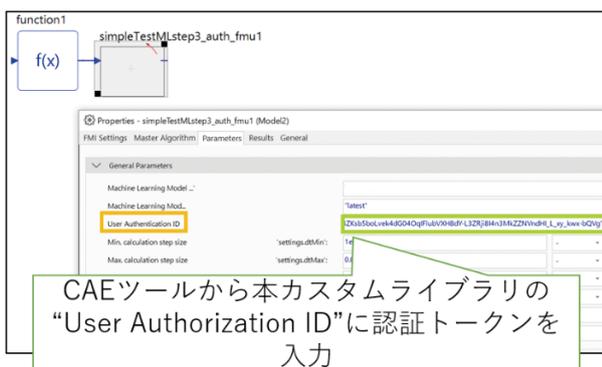


図18 一時認証トークンを使ったAPIリクエスト画面

また、認証トークンの不正利用のリスクを低減させるため、ユーザーログインから一定時間経過すると認証トークン自体を無効化するように設定されている。仮に認証トークンが外部流出したとしても、

一定時間で無効化された認証トークンを使ったAPIへのリクエストがシステム側で拒否されるようになる。さらに、こうしたアクセス履歴は常時システム側で記録され、不正が疑われる場合にはシステムの管理者に警告する機能も有している。

注23) インターネット上で提供されるAPI。

注24) ユーザから見えないサーバーサイド領域の処理。

注25) Functional Mock-Up Interface: 標準化された形式が異なるツール間で動的なシミュレーションモデルを交換・接続するためのオープンな規格。

注26) Functional Mockup Unit: FMIに基づいた実行モジュールで、モデルを秘匿化した上でCAEツールの種類に依存せずにモデルを利用できる。

7.5 学習データ品質のモニタリング

本システムにおける機械学習モデルの精度を確認するには、機械学習モデルの推論結果と実際のFEM計算結果を照らし合わせる必要がある。エンドユーザから諸元情報が入力されれば推論エンドポイントから機械学習モデルの予測結果が出力される。これに対する正確なFEM計算値の算出には時間とコストを要し、運用中の機械学習モデルの精度を確認することは難しい。そこで本システムでは、モデルの精度に影響を与える学習データの品質に注目した。

AIサービスの利用時に入力されるSAの諸元情報は、機械学習モデルの利用履歴として本システム上に記録される。本システムでは、機械学習モデルが学習してきたデータ分布と実際に利用されているデータ分布を比較することができる。各統計量は自動計算され、定期的に比較検証される仕組みとなっている。比較結果は社内のコミュニケーションツールを介して機械学習モデルの管理者に自動的に通知され、モデル再学習の検討材料として活用することができる（図19）。

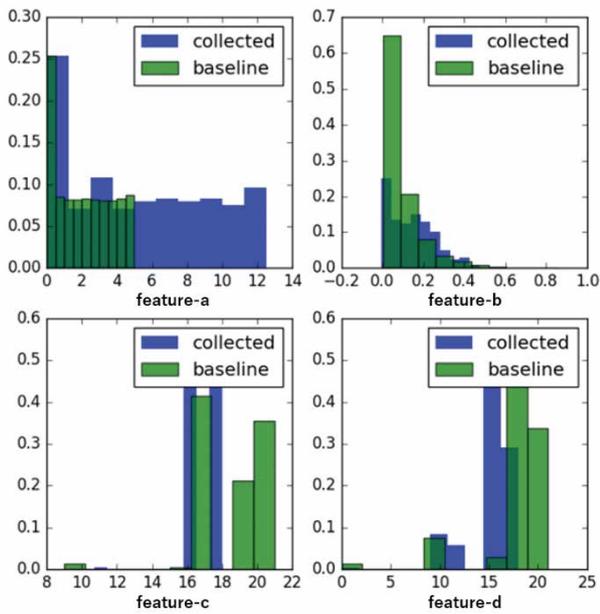


図19 学習データと推論データにおける特徴量別データ分布比較例

8 結言

モデルの詳細度が高く計算時間の長いFEMモデ

ルを機械学習モデルに縮退化することで、高精度でありながら計算時間を短くして1D-CAEに実装する計算基盤を構築した。更に、管理された高品質な機械学習モデルを皆で利用するために、機械学習モデルの運用管理基盤も構築した。

これらの構築した技術により、図3で述べた全てのMBDの技術課題（1Dのシステム検討から3Dへのシームレスな移行、3Dの形状検討の効率化、関係会社・他部署とのモデル流通）に貢献できると考える。社内外のモデルベース開発に積極的に本技術を適用し、モデルベース開発の効果を最大化できるよう努めたい。

最後に本取組に際しご協力をいただきましたCAEソフトウェアやクラウドのベンダー様、ならびに社内関係部門の皆様にはこの場をお借りして厚く御礼を申し上げます。

参 考 文 献

- 1) 島田実, 満嶋弘二, 渡辺博仁: カヤバ工業におけるCAEの導入と定着, カヤバ技報, 第24号 (2002年4月).
- 2) 宮内悠樹, 井指諒亮, 瀧野慎介: デジタル人財育成の取組み, カヤバ技報, 第66号 (2023年4月).

著 者



萬谷 浩章

2009年入社。技術本部 CAE推進部 (岐阜分室)。主に自動車用緩衝器の性能予測のためのCAEに従事。



提箸 良太

2019年入社。デジタル変革推進本部 デジタル戦略室 (相模駐在)。データ分析関連のシステム開発に従事。