

顧客のデータ分析内製化を支援する

データ分析基盤ソリューションの概要と金型 IoT への応用

Overview of Data Analysis Platform Solution that Supports Customers

in Their Own Data Analysis and Application to the IoT System for Die Production

松 林 毅, 吉 本 昌 平, 大 塚 洋, 藤 本 泰 士

要 約 UEL 株式会社はユニアデックス株式会社と共同で、金型分野において機械学習や AI を活用する研究を長年に渡り実施してきた。また、IoT によるセンサーデータを分析することで、金型内部で生じている問題点の可視化や、予測につながる分析技術を磨いてきた。そこから、ドメイン知識とデータ分析技術の融合が重要であることが判明した。そこで2社は、顧客自身によるデータ収集と分析の内製化を支援するサービスである「データ分析基盤ソリューション」と、それを金型分野に応用した「金型 IoT プラットフォーム」の提供を進めている。この取り組みにより、製造現場で活用できる分析技術を届け、直面する労働人口減少の問題や勘と経験による匠の技術伝承の問題解決に貢献していく。

Abstract Uniadex and UEL Corporation have been working on production technology improvement in the die industry based on IoT digital information. By analyzing IoT sensor data of phenomena inside the die, we have been improving analysis technology which leads to projection and visualization of problems that cause quality defects. From these activities, it becomes clear that the integration of domain knowledge and data analysis technology is important. Therefore, we are promoting the provision of “data analysis platform solution”, which is a service that supports the in-house production of data collection and analysis performed by customers themselves, and “die IoT platform” that applies it to the die field. Through this initiative, we will deliver analysis technology that can be used at manufacturing sites, and contribute to solving the problem of a declining working population and the achievement of handing down craftsmanship based on intuition and experience.

1. はじめに

ものづくりや設備メンテナンスの現場では、勘と経験をよりどころとした匠の技が重用されてきたが、近年の労働人口減少やグローバル化などで技術の伝承に問題が生じていることが少なくない。IoT、機械学習や AI といったデジタル技術の進歩により、これらの匠の技を IT で伝承する試みが盛んに行なわれている。

金型向け CAD を開発する UEL 株式会社（以下、UEL と略す）の顧客である金型業界も同様で、機械の稼働状況等の情報を取得して稼働監視や定期点検に活用する事例が存在するが、金型の内部で生じている現象をデジタル化して、不具合の発生分析や予兆検知等に活用する事例はまだ少ない。

UEL は、機械学習や AI による設備機械分析のノウハウを持つユニアデックス株式会社（以下、ユニアデックス）と共同で、「かしこい金型研究会^{*1}」や「岐阜大学スマート金型拠点開発プロジェクト^{*2}」に参画し、金型分野において機械学習や AI を活用する研究を長年に渡り

実施してきた。

ユニアデックスは、機械学習や AI などのデータ分析技術による設備機械分析に長年取り組んでいる。それらの実績から得られた知見を基に、製造現場におけるデータ分析の共通課題を解決する「データ分析基盤ソリューション」を顧客に試験提供している。

本稿では、このデータ分析基盤ソリューションと、それをベースに IoT センサーによる金型からのデータ収集・分析を行うソリューションとして企画を進めている「金型 IoT プラットフォーム」について説明する。2 章にてデータ活用の現状を述べ、3 章でデータ分析手法、4 章でデータ分析基盤ソリューションとその金型 IoT プラットフォームへの応用について説明する。

2. 製造現場におけるデータ活用の現状

本章では、製造現場におけるデータ活用の現状として、機械学習や AI、IoT の活用の際の課題について述べる。

2.1 製造現場における機械学習/AI 活用の課題と解決策

産学連携の共同研究や数多くの製造系企業との実証実験を行った我々の経験上、製造現場において機械学習や AI の活用を阻んでいる障壁は、機械学習モデル^{*3}の汎用性の問題と、機械学習モデル開発プロジェクトの不確実性の問題であることが多い。本節にて説明する。

2.1.1 汎用性の問題

汎用性の問題とは、機械学習モデルを特定の対象や条件に合わせて開発する場合、他の対象や条件にも適合する能力、つまり汎用性を低くせざるを得ないという問題である。例えば、ある金型をある成形機に取り付けて、ある材料で得られたデータを基に作成した機械学習モデルを他の成形機や成形条件で動作させるには、パラメータの見直しは勿論、場合によってはデータの前処理も含めた機械学習モデル自体にも手を入れることもある。この汎用性は機械学習モデルの精度（表現力）とのトレードオフであることが多く、従来は精度を落とすことで汎用性を確保することが多かったが、この手法では製造現場が求める精度に到達することは難しい。

機械学習モデルの精度を落とさずに現場で活用するには、機械学習モデル自体の性能で汎用性を高めるというアプローチと並行して、機械学習モデルを人間が対象に合わせて調整するサイクルを回し続けることで汎用性を確保するという運用面と連携したアプローチを行うべきである。これは、現場に機械学習モデルを開発できる要員が配置されている場合には問題にはならないが、機械学習モデルの開発を IT ベンダーに外注している場合にはコストや費用対効果の問題が発生する。これが製造現場に機械学習や AI を導入する際の大きな障壁となっている。

2.1.2 不確実性の問題

不確実性の問題とは、機械学習モデルの開発において、計画段階や開発初期の段階では精度保証や開発期間の見積を行うことが難しいという問題である。これらは機械学習モデルだけではなくソフトウェア開発において一般的に発生する問題であるが、特に機械学習モデルの開発においては、精度の不明な機械学習モデルの仮説を基にデータや現場経験で精度を高めるという統計的手法を採用するため、これらの問題が発生しやすい。

例えば、射出成形の匠が経験と勘で日々設定しているバリが発生しない限界の成形条件を我々が機械学習モデル化しようと試みる場合、最初に行うのは匠へのヒアリングである。匠へのヒアリングを基に気温や湿度をモデル化したものの期待する精度が出せず、実は匠が識閲下で材料の乾燥時間や個々の成形機のクセも判断材料としていて、現場で機械学習モデルのトライ&エラーを繰り返す中で、匠自身がそのことに気づき、ようやく満足できる精度に到達するケースは頻繁に存在する。また、試験環境でPoCを終えた後、実際に故障などの現象を現場で検証するのに年単位の時間を要する対象も多い。

つまり、機械学習プロジェクトの初期段階では、精度や開発期間、費用対効果を明確にできないのである。これは積極的に研究投資を行う一部の企業を除いて、プロジェクト開始前に費用対効果の明確化を求める外注を前提とした日本の企業IT文化とは相反しており、製造現場に機械学習やAIを導入する際の大きな障壁となっている。

2.1.3 解決策

本節で挙げた、汎用性を確保するために現場で機械学習モデルを運用し続けなければいけない問題、また、不確実性のために初期段階で費用対効果が算出できず外注が難しい問題を、シンプル且つ最も費用対効果を高く解決する方法は、データ分析と活用を顧客企業内で実施する「データ分析の内製化」である。3.4節にて詳述する。

2.2 金型分野ユーザにおけるIoTによるデータ活用

製造業においてIoTはモノの挙動を見える化し、これまで勘と経験に頼っていた判断をデジタル化できるようにした。金型分野では、IoTを活用してSmartManufacturingを実現しようと様々な取り組みが行われている。たとえばプレス加工では、パネルの割れ、シワ、かじりなどの不具合を検知して不良品を出さないようにしたり、金型の摩耗等を検出してメンテナンスの時期を予測したりすることが期待されている。樹脂型ではさらに、製品の傾向を把握して、成形機の射出速度や圧力、材料の温度等を自律調整する究極のノンストップ自動化が期待される。「かしこい金型研究会」では、このような期待に応えるIoT関連技術を開発している。

金型関連のIoTシステムの課題として以下1)と2)がある。

- 1) 金型の稼働時、数百トンの圧力がかかる、数百度にもなる高温の樹脂材料を扱うなどの過酷な環境でデータを採取しなければならない。
- 2) 割れやしわなどの現象は瞬間的なものであり、それを捉えるためには1ショット（金型1回分の動作）あたり数千～数十万の大量のセンサーデータを採取しなければならない。

3. データ分析における「特微量エンジニアリング」の重要性と内製化に向けた方策

2.2節にて、1ショットの成形動作を捉えるために数千～数十万のセンサーデータを採取すると述べた。例えば金型の摩耗による劣化状況を観測、分析したいのであれば、数千～数万ショットのデータを採取する。つまり分析対象のデータ件数は数千～数十万×数千～数万ショットということになる。本章では、こうした大量データをいかに分析すべきかについて述べる。

3.1 ドメイン知識を踏まえた特徴抽出

一般にデータ分析の手順でまず最初に行うべきは、データ空間の構造を知ること、データの分布を把握することである。表形式で1000行のデータがあったとして、具体的には項目ごとのヒストグラムを描くことだろう。図1のようなセンサー波形データが1000ショット分あるとすると、人間にとっては波形グラフ画像が1000枚あるということである。グラフ画像というのは人間が眺めて初めて意味があるものであり、それを1000枚並べたとし、その中の分布、何らかの傾向を把握することは困難である。重要なのは、データを分析できる状態にするために各ショットから何らかの代表値を取り出すことである。分析できる状態とは、ショットごとに複数の代表値を項目として持つ二次元の表形式データにすることであり、この代表値を特徴量と呼ぶ。




図1 プレス時の荷重波形の例

一般に代表値と言うと、まず平均や分散が挙げられ、これらも特徴量になり得るのだが、図1のような時系列データに対しては、意味を持たないことが多い。見るべきポイントが局所的に偏在しており、全体の平均や分散はショットごとの特徴を表さないからである。有効な特徴量を抽出するには、波形のどの部分で何が起きているかを適切に理解できるドメイン知識が求められる。図1は、直感的にわかりやすい題材を選んでいるが、③が破断点であり、鋼板が完全に切断される瞬間であるということが理解できなければ、そこに注目することができない。

3.1.1 特徴抽出の手順化・自動化

人間の特征抽出能力は優秀だが、数千件のグラフ画像からの特徴抽出を手作業で行うのは無理がある。特徴抽出作業を何らかの方法で手順化・自動化しなければならない。そのための考え方を、図1のデータを例に説明する。

まず②の最大荷重点は、文字どおり荷重の最大点であり、データの最大点を特定すれば良い。場合によって、移動平均などによるノイズ除去を要するが、特に複雑な処理は不要である。次に③破断点について考える。破断点は、切れかかっていた鋼板がついに完全に切断される瞬間であると述べた。それまで繋がっていた鋼板によりかかっていた荷重が突然抜ける、最大荷重に近いところから反動で元々のベースラインである0より大きい値まで一気に落ち込む、つまりこの時速度はこのデータ中最大になっていると考えられる。大きな速度を生むのは、それに先立つ大きな加速度である。つまり、破断点は加速度極大点と定義できることがわかる(図2)。




図2 破断点は加速度の極大点

人間が時系列グラフを眺めて、「特徴点」と認識するものの特徴を洗い出すと、

- 水平から上昇/下降に転じる点
- 上昇/下降からより急な上昇/下降に転じる点
- 上昇/下降からよりなだらかな上昇/下降に転じる点
- 上昇/下降から水平に転じる点
- 上昇から下降に転じる点/下降から上昇に転じる点

となり、共通点をまとめるとすなわち、

- その前後で速度が変わる点

と定義でき、それは加速度の極大・極小として検出できる。最後の「上昇から下降に転じる点/下降から上昇に転じる点」はすなわち元波形の極大・極小点と重なり、元波形の極大・極小として検出した方が、検出感度としても処理効率としても好ましい。よって、

- 元波形、加速度いずれかの極大・極小点

と定義できる。元波形から速度を求める処理は階差 (diff(), 時系列上一つ前のポイントからの差分をとったもの)、さらに速度の階差を求めたものが加速度であり、自動化のための実装は容易である。

しかしながら、実際のデータで自動化するにはまだ困難な点がある。極大・極小の検索と、ノイズの除去である。本節の残りの2項で解説する。

3.1.2 「極大・極小」は「最大・最小」ではない

特徴点の定義において、「最大・最小」ではなく敢えて「極大・極小」としているのには、重要な意味がある。図2で破断点を示す縦線位置の加速度ピークは、実は極大点ではあるが最大点ではなく、右にあるもう一つの加速度ピークの方が値としては大きいのである。人間は、「荷重開始点を抽出する」というコンテキストを与えられた時点で、無意識に「荷重開始点とは何か」を理解し、「その前後どの程度の範囲を検討の対象にすれば良いか」を判断し、その「範囲の中の極大・極小」を検索することができる。しかもその人間が定義した「検索範囲」は「無意識ではあるがデータに合わせて適切に設定」され、ポイント単位で具体的に定義されることはない。一方コンピュータは、検索範囲が具体的に指定されない限り「極大・極小」点を見つけることはできない。自動化が難しい理由の一つである。

3.1.3 ノイズ

もう一つの難しい理由はノイズである。変位→速度→加速度算出の過程で使われる階差処理は、変動周期の長い長期トレンドを失わせる嫌がある。これは逆に短周期のノイズを相対的に拡大することになる。このことが端的に現れるのが、図1の①荷重開始点であり、特に加速度の極大・極小点の検出を難しくしている。




図3 階差処理によるノイズの増幅

図3は、荷重開始点前後を拡大し速度、加速度を併せて描画したものである。荷重開始点は、水平から下降に転じる点であり、加速度極小点として検出できるはずだが、ノイズが多く全く検出できない。グラフのY軸のスケールは、荷重の値域が700ほどあるのに対し、加速度の値域は3程度しかないことを示している。元々の荷重のデータにも加速度のグラフに見えるようなノイズが含まれているのだが、荷重の値域に対してノイズが充分小さいので、きれいに見えるだけなのである。本章で使っているデータは、荷重センサーのデータとしては極めてノイズの少ないきれいなデータなのだが、それでも荷重開始点のなだらかな速度変化に比較すると、影響は相対的に大きくなってしまう。

対策としては、移動平均などの手法によりノイズを除去することであるが、ここで注意しなければならないのは、ノイズだけを選別して除去する都合のよい手法は存在しないということである。移動平均範囲を広げて強力にノイズ除去しようとするればするほど、失われる情報は増え、元波形の本来の形を変えてしまう。このため、ノイズ除去処理は必要最低限に留めるべきである。図4は、荷重開始点検出処理を、3種類の移動平均と組み合わせて行っているものである。




図4 移動平均範囲とノイズ除去効果

5点移動平均（図4左）ではノイズの影響で荷重開始点を誤検出しており、正しく検出させ

には検索範囲をかなり狭く、例えば網掛け部分に限定しなければならないだろう。9点移動平均(図4中央)では期待どおり検出できているが、5点で誤検出した右隣りの加速度ピークもほとんど変わらない大きさを示しており、検出処理の堅牢性を確保するにはやはり検索範囲を網掛け部分に限定すべきである。19点移動平均(図4右)では、検出した加速度ピークはかなり突出しており、グラフの横幅全体を検索範囲にできる。このようにノイズ除去の度合いを高めていけば、検出処理の堅牢性は増していくが、元波形の形を変えてしまう危険性というトレードオフがある。一方、加速度ピーク検索の範囲を狭くすればするほど、ノイズ除去の度合いを限定でき、より精度の高い特徴抽出ができるのである。

3.2 検索範囲の限定

特徴量抽出の手順化・自動化を阻んでいる二つの困難を、人間はいとも簡単に、無意識に解決している。解決の鍵は、「何となくこのあたり」と行われる範囲限定であり、その範囲内で行われる「極大・極小値」の検索である。この「何となくこのあたり」の範囲限定を再現できれば、人間に近い適切かつ柔軟な特徴量抽出が実現できる。人間は、以下のような方法の場合により柔軟に組み合わせて総合的に判断していると思われる。

- 特徴点の現れるタイミングを固定的に範囲限定(ショットごとに大きくはブレない、もしくはタイミングは固定で値だけを採れば良い)
- ある特徴点特定により別の特徴点検索範囲を限定(荷重開始は必ず最大荷重以前にある)
- 元波形の値域により範囲限定(破断点は高荷重域でしか発生し得ない)
- 複数系列の関係性により範囲限定(複数センサー間の相関、分散など)

3.3 特徴抽出フレームワーク

ここまで見てきたように、検索範囲の限定が特徴抽出の精度を大幅に上げることは間違いなが、その手法はまさにケースバイケースであり、データの性質により複数の手法を使い分ける。個々には全く難しいことではないが、データに応じて適切な手法を選択するためには、それなりの慣れを要すると考えられる。そのため、使い分けの考え方をフレームワーク(図5)としてまとめた。

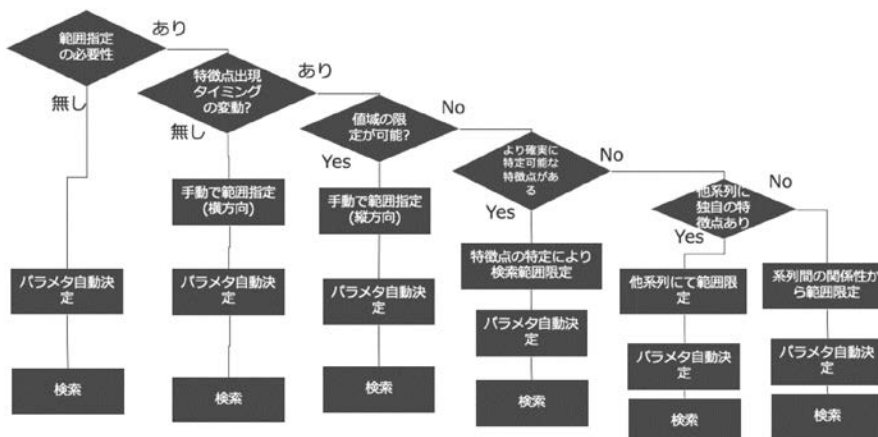


図5 特徴抽出フレームワーク

このフレームワークに沿って、データと特徴点の性質に応じた個々のケースに対応することで、適切な範囲限定手法を選択することができる。個々の範囲限定手法は、それぞれ簡単なものであり、その処理を「コード化」、「手続き化」することは容易である。

3.4 内製化に向けた方策

検索範囲を限定する手法の使い分けの判断には、「破断は高荷重域で発生」のような、測定対象に対するドメイン知識を要するケースが少なくない。また、特徴抽出の後工程である分析作業において、明快な結果が1回で得られることはない。データ採取・特徴抽出・分析を含めた試行錯誤を繰り返すのがむしろ一般的であると考えられる。故に、発注・請負のような作業形態は実は現実的ではなく、既にドメイン知識を持っている顧客による内製化が望ましい。これを実現するため、時間範囲の限定と、その範囲内での検索処理をGUI操作で実行できるツールを開発した。図6はこのツールを使ってプレス荷重波形から破断点を検出するための手続きを定義している画面である。図中の①から⑦について以下に説明する。



図6 特徴抽出定義ツール

- ① 入力となるデータソースを選択し、項目ごとにグラフの表示位置を指示する。この時、入力データに対して速度、加速度変換、移動平均、ゼロ補正、タイミング補正などの加工ができる。定義した内容は②の表示設定テーブルに反映され、同時に③④⑤の波形グラフが描画される。
- ② グラフ表示設定テーブル
- ③ プレス荷重元波形のグラフ表示
- ④ 同速度のグラフ表示
- ⑤ 同加速度のグラフ表示
- ⑥ 特徴抽出手続き編集テーブル。1行目で速度最大点を検出しており、これに vct_

max と名前を付けている。2 行目ではその vct_max を参照して検索範囲を設定し、その範囲での加速度最大点を検出 (acc_max) している。さらに 3 行目でその acc_max を元波形グラフ上に表示している。

- ⑦ 一連の入力データ選択、加工、特徴抽出指示は手続きとして保存されており、全ショットに適用することができる。

画面上部は表示する波形グラフの配置指示を行っており、画面中央のグラフ表示部に荷重波形、及びその速度波形、加速度波形を表示することを指示している。また画面下部では、荷重波形における破断点特定までの手続きを定義している。ここでは図5に示したフレームワークのいずれかの手法による時間範囲設定、及びその時間範囲でのピーク検索処理を波形を確認しながら定義することができる。さらに、定義した特徴抽出手続きを保存し、全ショットに適用して、その抽出結果を保存することができる。

波形の速度、加速度といった概念的な理解や、図5で示したフレームワークへの慣れはある程度求められるものの、煩雑なコーディングは不要であり、プログラミング初学者にも馴染みやすく、内製化を支援するものである。

4. データ分析基盤ソリューションと応用

2章で述べた通り、製造現場において機械学習やAIの活用を阻んでいる障壁は、機械学習モデルの汎用性問題と不確実性問題である。これらの障壁を乗り越えて製造現場で機械学習を活用するには、3章で述べたように、機械学習モデルの設計・開発・検証・導入・運用を自社で行う内製化が必須である。

このようなAI機械学習モデルの設計・開発・検証・運用サイクルを回し続けるためのベストプラクティスを集めたのが、Google等が提唱するMLOps^{*4}である。このMLOpsを顧客が簡易に低コストで内製化できるよう企画開発したのが、データ分析基盤ソリューション(図7)である。本章では、データ分析基盤ソリューションと、金型IoTへの応用について説明する。

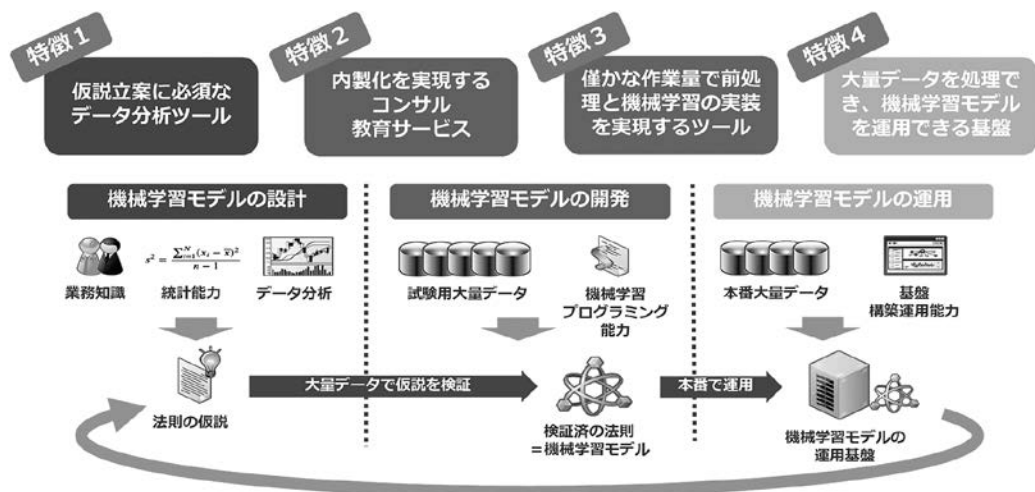


図7 データ分析基盤ソリューションの概要

4.1 データ分析基盤ソリューションの基本的な機能

データ分析基盤ソリューションでは、機械学習モデルの開発プロジェクトのMLOpsサイクルを顧客が自ら内製化できるよう、データを収集・分析し機械学習モデルを運用するための機械学習/AI基盤、内製化のためのプログラミング教育や、ユニアデックスのノウハウを活用できる機械学習モデル開発ソフトウェアの開発を進めており、一部の顧客には既に提供している。

データ分析基盤ソリューションは主に四つの特徴を備えている。第1の特徴は、「大量データを分析し、仮説立案を効率的に行うためのツール」を備えていることである。機械学習モデルの設計開発を効率よく行うには、機械学習モデル開発の前提となる仮説の精度が高いことが求められる。データ分析基盤ソリューションでは、我々の経験に基づき機械学習モデルの開発時に使う主要なデータ分析機能（データの前処理や、折れ線グラフ・散布図・相関行列・圧力分布などの可視化）を準備しており、図8のように顧客要望に応じてカスタマイズして納入する。顧客自身で独自のグラフをマウス操作のみで追加することもできる。これらを用いることで、顧客自身で手軽に高い精度の仮説を紡ぎ出すことができる。



図8 データ分析基盤ソリューション画面

第2の特徴は「内製化を実現する各種支援サービス」を提供していることである。対象物について十分な知識を持った顧客の社内人材が、自ら機械学習プロジェクトのサイクルを回せる人材となるための各種支援サービスである。例えば、ユニアデックスのデータサイエンティストの知見を基に計画段階からプロジェクト完了まで助言を行うコンサルティングサービスや、教育支援サービスを提供している。

第3の特徴は、顧客の作業負荷を最小にする様々なツールを予め実装していることである。面倒な前処理や機械学習のプログラミングにて使用する機能をツールやライブラリとして予め準備している。特にプログラミング難易度が高い特徴量抽出については、独自の簡易なドメイン固有言語（DSL）を開発し、プログラミングに習熟していなくとも簡単に記載できる仕様とした。機械学習モデルの開発もできるだけマウス操作としつつ、Python言語を用いて本格的に記述することもできる。顧客はブラウザからのマウス操作と数十行の僅かなプログラムを書くだけで機械学習モデルを開発することができる。

第4の特徴は、開発した機械学習モデルの現実的な運用手段を、ユニアデックスの豊富なシステム基盤開発の経験に基づいて準備していることである。主要クラウドも採用するOSSの

機械学習モデル運用ソフトウェアをベースに機械学習モデルの運用機能を提供している。機械学習モデルの精度が上がった際には、顧客のシステム形態や他社へのサービス販売を支援する形で、オンプレミス型・クラウド型の機械学習モデルの運用機能を提供している。

4.2 データ分析基盤の金型IoTへの応用

プレス金型を設計、製作すると、トライ用のプレス機で実際にプレス部品を製作してテストを行う。事前にCAEでプレス板の成形性を見込んではあるが、何回もトライ補正を繰り返す。トライ結果からの補正はベテランの経験値に依存している。最近では軽量化と安全性（強度）向上のため超高張力鋼（超ハイテン材）の新素材を使用するケースが増え、これまでの経験値が通用しなくなってきている。プレス金型業務フローは図9の通りである。




図9 プレス金型業務フロー図

トライプレス機で合格すると、工場に金型を運搬し実プレス機に設置して、再びトライを行う。工場では、環境や、材料などの条件が異なり、それに加えてプレス機械も異なり所謂機差が発生して、1回では合格しない。工場でもトライ用のプレス機と同じようなトライ補正作業が発生する。このような状況において、プレス機の荷重状態を可視化できれば、ベテランの経験値に依存せず対策が立てやすくなり収束も早くなる。

「かしこい金型研究会」では、様々なセンサー部品を開発して金型内部の挙動をデジタル化する取り組みをしている。この取り組みの中で、金型の荷重状況を可視化するボルトセンサーと圧力プレートシステムを開発（図10）し、本節で述べた課題に対応している。

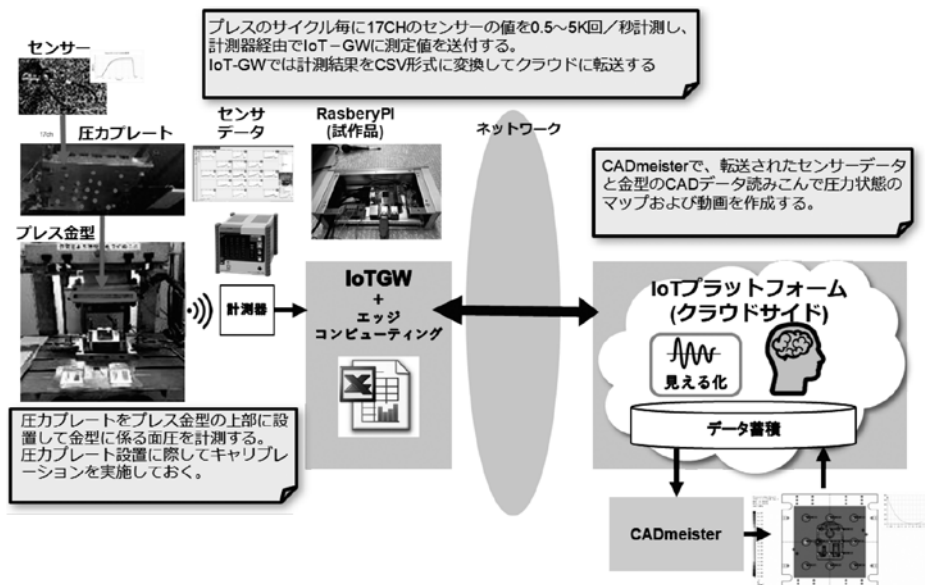


図10 圧力プレートシステム

ボルトにひずみセンサーを内蔵して加圧量を測定するボルトセンサー（図10左上）を圧力プレートに格子状に穴をあけて設置して（図10左中）、そのプレートを金型と一緒にプレス機に設置する。1ショットプレスする度、500～5000回/秒の短いタイミングでセンサー値を採取し、CSVに変換してPCに転送する。PC側ではCADmeister[®]でそのデータを読み込み、加圧状況を金型CADデータと重ね合わせて可視化する（図11）。




図11 加圧カラーマップ

このようにプレス加工のショット単位の挙動を可視化すれば、金型の偏荷重状況や機差の分析などに使用できる。最近では、工場のプレス機にセンサーを設置して定期的にデータを採取し、不具合の検出やメンテナンスの時期を最適化したいという要望が増えてきた。これを実現するために、データ分析基盤ソリューションをベースとした金型IoTプラットフォームを活用して定期的にデータを採取、蓄積し、ショット単位に特徴量を算出して課題のモデル化、分析を行う。

例として、パネルに穴をあけるピアスポンチ（穴あけ工具、図12）のケースを考える。穴あけは物理的に強い力を加える工程で摩擦が発生したり、折れたりする課題があり、これらの課題を解決するために、研削や工具交換のタイミングを最適化する。




図12 ピアスポンチ

ピアスポンチにかかる圧力を計測するセンサーを取り付けて圧力状況を継続的に見ながら、以下の仮説を立てた。

- 荷重開始から破断に至るまでの間隔が長くなる = 工具の切れが悪くなる ⇒ 磨きのタイミングを計る

ピアスポンチにかかる圧力は図13の通りで、金型IoTプラットフォームの特徴量算出機能を利用して荷重開始点の特定とその時刻、および破断点の特定とその時刻を求める。




図13 プレス時の荷重波形上の特徴量

求められた時刻を基に金型 IoT プラットフォームの分析ツールを利用して、破断-荷重開始時間差をプロットすると図14のようになり、800ショットを超えると間隔が長くなっていることがわかる。あけた穴の状態と間隔の長さの関係を把握して磨きの閾値を決めたり、ポンチ折れが発生した時点の間隔との関係を検証して交換時期を定義したりすることができるように、メンテナンスの時期の最適化が実現できる。

このケースのように、現物の状態と特徴量の関係を導き出して、金型 IoT プラットフォームで課題を解決するためのモデルを定義し、採取されたセンサー値から、何らかの判断を行う仕組みを構築することができる。




図14 破断-荷重開始時間差の1000件推移

5. おわりに

製造業・金型成形におけるデータ活用は、材料・成形設備、成形する製品個々の要件により発生する物理現象を捉えることであり、製造・生産技術の極致にいたる経験の活用なくして成し得ないことを学んだ。そこで、顧客が持つドメイン知識の活用を前提とした、顧客自身がデータサイエンス技術を習得し、継続したデータ活用による成長サイクルを形成する内製化を支援する教育システムなどを包含したデータ分析基盤ソリューションを提供した。データ分析機能には、我々が研究活動などで得た経験から、必要不可欠な汎用機能をテンプレートとして包含することで付加価値の提供を目標としている。今後も製造業・金型成形分野におけるデータ分析技術の継続的な向上を目指すとともに、データ分析・活用技術を製造現場に提供してゆきたい。

- * 1 かしこい金型研究会とは、金型とIoTの融合を目指す金型業者などの研究組織である。
- * 2 岐阜大学スマート金型開発拠点プロジェクトとは、岐阜大学が複数のものづくり企業と立ち上げた、IoTやAIを使って新しい金型の研究開発に取り組む共同研究講座である。

- * 3 通常のコンピュータプログラムでは、入力と出力の関係性をプログラマが記述する。この入力と出力の関係性をデータから導く考え方及びそのための技術が機械学習である。このデータから導かれた入力と出力の間の関係性、処理方式を機械学習モデルと呼ぶ。
- * 4 MLOps とは、機械学習 (Machine Learning) チームと運用 (Operations) チームが協調し、機械学習モデルの実装や運用を円滑に進める管理体制のこと。
- * 5 CADmeister とは、UEL 株式会社が開発・提供する CAD/CAM システムのこと。

- 参考文献**
- [1] 沖本竜義, “経済・ファイナンスデータの計量時系列分析”, 朝倉書店, 2010年2月
 - [2] “時系列データに対する異常検知”, データ分析基盤知識, 株式会社 ALBERT,
https://www.albert2005.co.jp/knowledge/machine_learning/anomaly_detection_basics/anomaly_detection_time
 - [3] 久野拓郎, “プレスマシンにおける機差計測法の提案”, 型技術, 日刊工業新聞社, VOL35 NO7, 2020年7月, P86-87
 - [4] 近藤大輔, 久野拓律, “かしこい金型自動欠損検知を装備するピアスポンチユニットの開発”, 2016年 型技術者会議 講演論文集, 一般社団法人型技術協会, P193-194
 - [5] 松林毅, 藤本泰士, “IoTを活用した「かしこい金型」”, 型技術, 日刊工業新聞社, VOL31 NO13, 2016年12月, P24-25
 - [6] 松林毅, 吉本昌平, 藤本泰士, “金型IoTプラットフォーム紹介”, 型技術, 日刊工業新聞社, VOL36 NO7, 2021年7月号, P102-103

※ 上記参考文献に含まれる URL のリンク先は、2022年10月5日時点での存在を確認。

執筆者紹介 松林毅 (Takeshi Matsubayashi)

1980年日本ユニバック(株)入社。お客様向け専用CAD/CAMシステムの開発を担当。1995年より日本ユニシスグループのCAD/CAM/CAEプロダクトの開発、サービスに従事。2014年より日本ユニシス・エクセリョーションズ(株)に出向してViewerの企画及びCAD/CAM/CAEシステムとIoT、AIの連携に注力。



吉本昌平 (Shohei Yoshimoto)

国内ソフトウェアベンチャーにてシステム設計・開発を担当後、2006年に(株)ネットマークス(現ユニアデックス(株))入社。2013年からIoT/AI分野のソリューション企画・大学との共同研究等に従事。現在はDXビジネス創生本部BI統括部で機械学習/AI分野の新規事業開発を担当。



大塚洋 (Hiroshi Ohtsuka)

1988年日本ユニシス(株)入社。ソフトウェア・プロダクトの開発・保守・利用技術を担当。2014年よりデータサイエンティストとして異常検知サービスの開発、大学との共同研究等に従事。特に回転機械の振動分析、成形金型の圧力・荷重分析への機械学習の応用に注力するため2019年ユニアデックス(株)へ出向し現在に至る。



藤本 泰士 (Yasushi Fujimoto)

1998年日本ユニシス・エグゼキューションズ(株)入社。2009年より、自社アプリケーションのクラウド化など企画業務に従事。

