

(技術資料)

## 溶接材料開発における MI 技術の適用

谷口元一\*1・高和真名\*1・横田大和\*1・藤平雅信\*2・大谷拓也\*2・四方田真美\*2

### Application of MI Technology to Process of Welding Material Development

Genichi TANIGUCHI・Mana TAKAWA・Hiroyoshi YOKOTA・Masanobu FUJIHIRA・Takuya OTANI・Mami YOMODA

#### 要旨

溶接材料開発における新しい課題解決手法として、マテリアルズ・インフォマティクス (Materials Informatics : MI) が注目されている。本稿では、MIを軸とした材料設計へのデータ活用にフォーカスし、データベース基盤と分析基盤から構成される“溶材開発DataLab”と呼ぶデータ活用基盤の有効性を検証した。

本取り組みを通じて、無機ジンクプライマ塗布鋼板用フラックス入りワイヤや2.25Cr-1Mo-V鋼用サブマージアーク溶接材料など、実際の開発案件においてMIの有効性を実証した。

また、MIを支える良質かつ豊富な学習データの共有と利活用を重視したデータベース基盤を構築し、ユーザビリティの高いデータ蓄積・分析環境を整備した。

#### Abstract

Materials Informatics (MI) is attracting attention as a new problem-solving method in developing welding materials. This paper focuses on the use of data for material design based on MI and examines the effectiveness of a data utilization platform called “DataLab for welding material development,” which consists of a database sub-platform and an analysis sub-platform. Through this effort, the effectiveness of MI has been demonstrated in actual development projects, such as flux-cored wire for steel plates coated with inorganic zinc primer, and submerged arc welding material for 2.25Cr-1Mo-V steel. In addition, a database infrastructure has been constructed emphasizing the sharing and utilization of high-quality and abundant training data to support the MI. A highly usable data storage and analysis environment has been developed.

#### 検索用キーワード

アーク溶接, 溶接材料, AI, 人工知能, 機械学習, MI, 物質情報科学, マテリアルズ・インフォマティクス, マテリアルズインテグレーション

まえがき = 近年、計算機の高性能化、ビッグデータの拡充、深層学習などの技術的ブレイクスルーを背景にして、AI技術の産業応用事例が急増している。AIは学習データから作成されたモデルで人間の思考を再現する技術であり、鉄鋼業界においても高炉操業や製鉄所現場の重機操業へのAI活用事例<sup>1), 2)</sup>が公表されている。

このAI技術を材料開発プロセスに取り入れる考えがマテリアルズ・インフォマティクス (Materials Informatics, 以下MIという) 技術である。MIは、材料科学と情報科学を融合させて材料開発の効率化や新材料開発を目指す新たな材料開発手法であり、全世界で国家プロジェクトが進められている技術領域である。例えば、米国のMaterials Genome Initiativeを筆頭に、EURO圏のNovel Materials Discovery、中国のChina MGI、韓国のCreative Materials Discovery Project、日本(内閣府)のSIP-MIが2010年代初頭から始動している<sup>3), 4)</sup>。MI技術の応用事例は、機能材料や製薬などが中心である。近年は、現代製鉄が次世代自動車用鋼板の開発に米国Google社のAIを活用した事例<sup>5)</sup>、米国QuesTek社が統合計算材料工学技術を活用して軍用のM54鋼をNorthwestern大学と共同開発した事例<sup>6)</sup>など、構造物

料への応用事例も公表され始めている。

当社の溶接材料開発においては、新材料開発だけでなく、①既存メニューのコモディティ化、②材料単体での高付加価値化への頭打ち感、③ベテラン層を筆頭とした材料開発者の減少などの問題を背景に、新たな顧客価値創造を実現する溶接ソリューション技術開発へのリソースシフト、それらを支える技術継承が課題となっている。

当社では、これら溶接材料開発プロセスの効率化と設計力強化における課題解決手段としてMI技術に着目し、「過去から現在に蓄積した実験データ」と「暗黙知を含む独自の溶接知見」とを最大限に利活用可能なデータ活用基盤を構築する取り組みに着手した。本稿では、1章で溶接材料向けのMI技術開発、2章でMI活用の具体的な事例、3章で溶材開発DataLabと称するデータ活用基盤の構築について、それぞれ述べる。

#### 1. MI技術の概要

一般的なMI技術は、材料設計から材料特性の順問題を計算する予測技術と、材料特性から材料設計の逆問題を解く探索技術から構成される。溶接材料開発は、①設

\*1 溶接事業部門 技術センター 溶接開発部 \*2 技術開発本部 デジタルイノベーション技術センター

計すべき原材料配合、②複数原材料から構成される溶接材料の化学成分（以下、溶材成分という）、③溶接後の溶接金属の化学成分（以下、溶金成分という）、④溶接金属の機械的特性（以下、溶金特性という）の各関係性を考慮しながら行う。これら溶接材料の特徴を考慮したMI技術として、①～④の各関係をつなぐ予測探索技術を開発した（図1）。まず、原材料配合から溶材成分の予測は線形式で表せる特徴を有していることから、溶材成分から原材料配合の探索は凸最適化問題と捉えて手法を開発した。いっぽう、溶材成分から溶金成分、溶金成分から溶金特性の各予測は、複雑な溶接現象や材料組織形成が関わるため、明確な関係式を物理理論に従って構築することが難しい。そこで、豊富な実験データから機械学習手法により予測モデルを学習した。そして、探索は学習モデルをベースに最適化を行うことで実現した。各予測探索技術のベースになっている手法を以下に述べる。

### 1.1 溶材成分・溶金成分・溶金特性の予測探索

材料設計  $x \in \mathbb{R}^d$  と材料特性  $y \in \mathbb{R}$  の組み合わせからなるデータセット  $D = \{(x^{(i)}, y^{(i)}), i = 1, \dots, n\}$  が得られているときに、予測モデル  $y = f(x)$  を機械学習手法により学習することができる。

最も単純な機械学習手法として、以下の線形回帰モデルがある。

$$f(x) = w_0 + w_1 x_1 + w_2 x_2 + \dots + w_d x_d \dots \dots \dots (1)$$

ここに、 $w_0, \dots, w_d$  は回帰係数である。

線形回帰モデルは、各変数  $x_i$  に関して線形な傾向を表現するモデルであり、解釈性が高く、データ数が少ない場合にも適用可能であるが、複雑な現象をモデル化することはできない。この線形回帰モデルの表現力を改善しつつ解釈性を持つモデルとして、加法モデルがある。

$$f(x) = f_1(x_1) + f_2(x_2) + \dots + f_d(x_d) \dots \dots \dots (2)$$

ここに、 $f_1, \dots, f_d$  はスプライン基底関数である。

加法モデルは、各変数  $x_i$  に関して個別の非線形な関数  $f_i(x_i)$  で表現されたものを足し合わせた構造になっている。そのため、線形回帰モデルと同等の解釈性を保ちながら、少し複雑な現象をモデル化することができる。ただし、変数間の非線形な相互作用までを捉えることは難しい。

いっぽう、加法モデルでは考慮が難しいより複雑な非線形現象までを捉えることができるモデルに、ガウス過程回帰<sup>7)</sup>がある。詳細は割愛するが、ガウス過程回帰

はカーネル関数と呼ばれる関数を設計することにより、モデル  $f(x)$  の持つ滑らかさ、線形性、加法性、周期性などの様々な性質を表現できる。また、ガウス過程回帰は確定的な予測ではなく、学習データ不足や実験結果がばらつくことに起因した予測の不確かさも表現することができる。この特徴は、つぎに述べるベイズ最適化との相性もよい。非線形モデルには、これ以外にもニューラルネット、ランダムフォレストなどもあるが、上記の特徴からガウス過程回帰がよく使われる。

ここまで、予測モデル  $y = f(x)$  を構築する順問題を解く手段について述べてきた。しかし、実際の材料開発で重要なのは、実現すべき材料特性  $y$  の目標が示されたときに、それを実現する材料設計  $x$  を求める逆問題を考えることである。この目標を達成できる可能性が高い  $x$  を探索する手法にベイズ最適化<sup>8)</sup>がある。まず、ガウス過程回帰のように予測の不確かさも表現可能なモデルを用いて、過去の実験データから予測モデル  $f(x)$  を学習する。この手法では、任意の  $x$  に対する  $y$  の値を不確かさ含めて予測することができ、 $y$  の目標を達成する確率を計算することができる。すなわち、 $y$  の目標を達成する確率を評価指標として、評価指標が最大となる  $x$  を最適化計算により求め、逆問題の解を得ることができる。

評価指標には目的別に様々なものが提案されており、最善の実験データから改善する可能性を期待値、あるいは確率で表現した期待改善度や改善確率などがある。

これまで、MI技術として代表的な予測探索技術について述べてきた。本技術を溶接材料開発に適用する際には、溶材成分、溶金成分、溶金特性の各現象に関する知見、実験データ数、モデル解釈性の可否を踏まえて、適切な機械学習手法の選択や内部パラメータを設定した。また、材料設計  $x$  をどうするかも重要な点であり、材料知見により選択、変換を行っている。実際に本技術を適用した事例は2.1節および2.2節に記載する。

### 1.2 溶材成分からの原材料配合探索（逆成分展開）

本節では、溶材成分から原材料配合を探索する技術について述べる。

溶材成分（例えばC、Siなど）の濃度を表すベクトル  $w$  は、式（3）に示すように原材料成分濃度をまとめた行列  $A$  と配合比率  $x$  の線形式で計算できる。これを成分展開と呼ぶ。

$$w = Ax, \quad A = [a^{(1)}, \dots, a^{(n)}] = \begin{bmatrix} a_C^{(1)} & \dots & a_C^{(n)} \\ a_{Si}^{(1)} & \dots & a_{Si}^{(n)} \\ \vdots & \dots & \vdots \end{bmatrix} \dots (3)$$

ここに、 $w = [w_C, w_{Si}, \dots]^T \in \mathbb{R}^m$  は  $m$  種類の溶材成分濃度、




図1 溶接材料設計におけるMI活用コンセプト  
Fig.1 Concept of MI application for welding material designing

$x \in \mathbb{R}^n$  は  $n$  種類の原材料の配合比率,  $a^{(i)} = [a_C^{(i)}, a_{Si}^{(i)}, \dots]^T \in \mathbb{R}^m$  は  $i$  番目原材料の成分濃度,  $A \in \mathbb{R}^{m \times n}$  は原材料成分濃度をまとめた成分行列である。

溶接材料開発では, 目標とする溶材成分が定まった後に, それを実現する原材料の配合比率を考える。従来は原材料の配合比率を変えながら成分展開計算を行い, 目標の溶材成分に近づけるように試行錯誤を行っていた。そこで, この逆問題を式 (4) の制約付き最適化問題として定式化して解くことを考える。

$$\begin{aligned} \min_x \quad & \|w_{target} - Ax\|_1 \quad \dots \dots \dots (4) \\ \text{subject to} \quad & \sum_j x_j = 1, \quad 0 \leq x_j \leq 1, j = 1, \dots, n \end{aligned}$$

ここに,  $w_{target} = [w_C^{target}, w_{Si}^{target}, \dots]^T \in \mathbb{R}^m$  は目標の溶材成分濃度,  $\|\cdot\|_1$  は L1 ノルムである。

上記の最適化問題は, 目標の溶材成分  $w_{target}$  と成分展開  $Ax$  の誤差を最小化する問題である。また原材料の配合比率を表すために,  $x$  には 0 以上 1 以下, かつその合計が 1 となる制約条件を加えている。

この問題は, 最小化する関数が凸関数であり, かつ制約条件が 1 次の等式と不等式で表現されていることから, 凸最適化問題<sup>9)</sup> に分類することができる。凸最適化問題は, 単体法や内点法などのアルゴリズムを用いることにより, 高速で最適解を求めることができる。また, 特定原材料の使用要否, 配合比率, 溶材成分の制約など, 実務上発生しうる多くの要求も制約条件に加えることにより, その条件を満たした原材料配合比率を求めることができる。

このような定式化と最適化により溶材成分から原材料配合設計を探索する技術を, 成分展開に対して逆成分展開と呼ぶ。実際に本技術を適用した事例は 2.3 節に記載する。

## 2. MI 技術の適用事例

実際の溶接材料開発に MI 技術を適用した事例を以下に述べる。

### 2.1 プライマ塗布鋼板すみ肉溶接フラックス入りワイヤへの MI 適用事例

本節では, 溶接材料に用いるべき原材料とその配合比率を多種多様な候補から MI で選別・決定することにより, 当社製品の特性向上に活用した事例を紹介する。

造船・橋梁・鉄骨分野などでは, 防錆のために無機ジ

ンクを鋼材表面に塗布したプライマ鋼板が使用されている。この鋼板のすみ肉溶接では, 溶接作業のしやすさから, 数十種の原材料を鋼製の外皮で包んでワイヤ状に成形・伸線したフラックス入りワイヤ (以下, FCW という) が好まれている。FCW による溶接では, アーク熱によって気化したプライマガスにより溶接ビード表面にピットと呼ばれる気孔欠陥が発生し, 該当部の除去と再溶接が必要になるリスクがある。そのため, 溶接ビード表面にピットが発生しにくいワイヤが求められている。

そこで, 当社製品の中でもとくに耐気孔欠陥性に優れたワイヤのさらなる改良を目的に, プライマ鋼板のすみ肉溶接部の溶接線方向断面写真を二値化処理して求めた気孔欠陥率を MI で予測することにより, ワイヤに使用する原材料配合の最適化を検討した。

はじめに, 数百点に及ぶ過去の実験データをもとに, 原材料配合から気孔欠陥率を予測するモデルを学習した。つぎに, 予測モデルを用いて気孔欠陥率低減に有効な原材料の配合を抽出し, 実際にワイヤを試作して気孔欠陥率を評価することにより効果を検証した。原材料配合の抽出には, 学習データの分布や気孔欠陥の生じにくいワイヤの特徴, 対象製品からの改善代の観点を総合的に考慮した。また, 試作ワイヤの評価結果を実験データに追加して再度学習させ, 材料設計探索と試作評価を繰り返した。

その結果, 約 80 の原材料候補から気孔欠陥率低減に有効な 13 の原材料を抽出し, 2 サイクル目の試作検証において目標の気孔欠陥率を達成する原材料の配合を見いだした。MI 提案材は従来製品と比較して, 気孔欠陥が発生しやすい加速的な評価条件下においても, ルート部から発生した気孔欠陥の伸張が抑制されている。また, 溶接ビード表層まで達する空隙が認められない (図 2)。その後の量産試験においても, MI 提案材の耐気孔欠陥性, ならびに溶金特性, その他諸特性が良好であることを確認しており, 間もなく製品化される見込みである。

### 2.2 2.25Cr-1Mo-V 鋼用溶接材料への MI 適用事例

本節では, 各種制約下において相反する特性が両立する材料設計を MI で探索し, 未知領域において新規材料知見を獲得した事例を紹介する。

化学プラントや発電プラントで使用される圧力容器は高温・高圧下で長期間稼働するため, その構造部材には高いクリープ強度が求められる。いっぽう, 溶接構造物としての健全性を担保するために, 脆性破壊に対する耐




図 2 試験材によるすみ肉溶接部の溶接線方向の断面写真  
Fig.2 Fracture face in longitudinal direction of fillet weld metal

性確保や溶接施工時の低温割れ抑制の観点から、溶接金属には高いじん性及常温引張強度の上限制約も求められる。これらの特性はフェライト系の溶接材料では相反することがよく知られており、その高位両立が課題である。

ここでは、石油精製リアクタ向け2.25Cr-Mo-V鋼用サブマージアーク溶接材料に焦点を当て、これらの相反する特性を両立する材料設計の探索にMI技術を活用した事例を紹介する。

はじめに、本溶接材料に関わる過去の実験データを収集、学習データ化し、溶金成分や溶接入熱などを材料設計変数として、耐力、じん性、クリープ破断時間を予測するモデルをそれぞれ学習した。各特性予測値と実測値の相関を図3に示す。いずれの特性も予測値と実測値間に強い正の相関が認められる。いっぽう、じん性モデルは比較的ばらつきが大きい。これは、シャルピー衝撃試験温度が本溶接材料の遷移温度近傍であり、測定値のばらつきが大きいことが要因と考えられる。また、多層溶接した溶接試験体から採取した試験片ノッチ直下のマイクロ組織分布の影響など観測していない事実が予測精度に表れていると推察される。

つぎに、公的規格で要求される溶金成分の各種制約下でこれら3特性の目標値をすべて満足し、かつクリープ破断時間とじん性の正規化値の積が最大となる溶金成分をベイズ最適化手法で探索することにより、これら特性を高位に両立する材料設計の抽出を図った。また、探索材を試作評価して得られた結果を学習データに追加して再度学習させ、材料設計探索と試作評価を繰り返した。その結果、3サイクル目の試作検証において、目標特性を両立する、従来知見とは異なる新しい材料設計を見いだした(表1)。過去の改良材はクリープ特性を重視した結果、耐力やじん性への影響を十分に考慮できていなかったが、今回のMI適用によりこれら特性の両立とい

う困難な課題に対してブレイクスルーを果たした。現在、当該材料に要求される他特性、溶接条件による特性影響、生産性を総合的に判断して、製品化を計画している。

### 2.3 硬化肉盛溶接FCWへのMI適用事例

本節では、原材料配合設計の最適化の観点から、1.2節で述べた逆成分展開手法を用いて生産上の課題解決を図った事例を紹介する。

当社JIS Z 3326 YF3B-C-600適合の硬化肉盛溶接FCWは、フラックス充填量が多い製品設計にしているが、この設計に起因する生産上の課題があった。この課題を解決すべく、フラックス充填量を現行設計よりも低減することを前提に、現行材の溶材成分に近い原材料の配合比率を探索した。その結果、フラックス充填量を15%低減しても現行材と同等の溶材成分を実現する原材料配合を抽出し(図4)、その溶金成分も現行材と同等なることを確認した(表2)。また、溶金硬度も現行材と同等であることを確認しており、生産課題の解決に向けた材料設計調整にめどを得た。

従来このような材料設計変更では、溶材成分や溶金特性に大きな影響を及ぼす主要な原材料や成分が注目されやすく、影響が比較的小さい要素の調整は軽視される傾向にあった。いっぽう、本技術を活用して適切な制約条

表1 試作材料の評価結果  
Table 1 Investigation results of testing materials

Testing materials	Proof stress (MPa)	Absorbed energy at -30°C (J)	Creep rupture time (h)
[PWHT condition]	[705°C×8h]	[705°C×8h]	[705°C×32h]
Conventional material	589	101	747
Former improved material	623	62	958
MI improved material	610	150	1,382
Specification	Max. 620	Min. 54	Min. 900

PWHT: Post weld heat treatment  
Tensile test: JIS Z3111 A1 (test temperature= room temperature)  
Charpy impact test: JIS Z3111 V-notch  
Creep rupture test: Test temperature=540°C, Initial stress=210 MPa




図3 各特性MIモデルの精度評価グラフ

(a) 耐力モデル、(b) じん性モデル、(c) クリープ破断時間モデル  
Fig.3 Relationship between actual and predicted values for each model  
(a) Proof stress model (b) Absorbed energy model (c) Creep rupture time model




図4 設計変更前後の原材料配合比率  
Fig.4 Raw material composition ratio in flux cored wire

表2 設計変更前後の溶金成分  
Table 2 Chemical composition of deposited metals

Testing materials	Chemical composition of deposited metals (mass%)									
	C	Si	Mn	P	S	Cr	Mo	V	W	Fe
Conventional material	0.48	0.6	1.0	0.010	0.01	4.8	0.6	0.02	<0.1	Bal.
MI improved material	0.46	0.5	0.9	0.010	0.01	4.6	0.6	0.02	<0.1	Bal.
Specification (JIS Z3326 YF3B-C-600)	0.10-1.50	Max. 3.0	Max. 3.0	Max. 0.03	Max. 0.03	3.0-10.0	Max. 4.0	Max. 2.0	Max. 4.0	Bal.

Testing method: JIS Z3326

件下で配合調整を最適化することにより、従来着目されなかった原材料の使用や微量成分を考慮して、機微な配合調整の検討が迅速にできるようになった。

今後、原材料の化学成分、粒度、水分特性などの溶材設計上重要な物性を総合的に考慮できるよう計算ロジックを改良し、より高度な材料設計が提案できることを計画している。

### 3. 溶材開発 DataLab の概要説明

これまでMI技術やその適用事例を紹介してきたが、本章ではこれらMI技術を材料開発者自身が広く活用していくために開発したデータ活用基盤「溶材開発 DataLab」について述べる。

溶材開発 DataLab (図5) は、実験データを蓄積するデータベース基盤と、MI技術やその他の分析をプログラミングレスで実現する分析基盤から構成されるクラウド上のアプリケーションである。各基盤の概要と特徴を以下に述べる。

#### 3.1 データベース基盤

溶接材料等の材料開発では、様々な実験データが存在する。従来、データは担当者が個人管理するケースが多く、整理の仕方も担当者、実験時期、内容によって統一されないことが多くあった。そのため、これら実験データを分析可能な形式に再整理する負荷が大きく、これがMI活用の障壁になっていた。また、実験データを保存する仕組みとして、データベースを構築するケースもあるが、実験のデータ項目や工程は目的に応じて変化することが多い。そのため、データ構造の事前定義が難しく、データベース設計を困難にしていた。そこで、これらの問題を解消するために、事前定義が不要なデータベース基盤（以下DB基盤という）を構築した。

本DB基盤のデータ処理概要を図6に示す。本DB基盤へのデータ登録には、所定のルールで記述されたヘッダを持つcsvファイルを使用する。記述ルールは、「①各列は先頭行に分類テーブル名とデータ項目名（および必要ならば単位系を含む）を所定の書式に基づいて記述する」と「②データテーブルに各レコードを区別するためのキー項目列を持つ」の2点とした。例えば、炭素Cの含有率を記載するデータ列は、ヘッダに分類テーブル名「化学成分」、データ項目名「C」、単位系「mass%」を含む記述を用いる。キー項目はレコード毎にユニークなID番号などである。

また一連の実験で得られる実験結果をまとめたcsvファイル群は、「化学成分」や「機械特性」などの複数分類テーブルを含む。分類テーブル間には関係性があるレコードが存在する。本基盤では、これら複数分類テーブル間のレコードの対応関係をキー項目値の組合せで表現する。本基盤は「逆スタースキーマ方式」を採用しており、csvファイル群からテーブルデータを抽出し、分類テーブルごとに集約する。さらに各分類テーブルのキー項目を集めたりレレーションテーブルを形成し、分類テーブル間の関係性を表現した。

本DB基盤は、アップロードファイルから自動的に分

類テーブル群とレレーションテーブルに整形・変換しレレーションデータベース内の目的別データベースに保存する。ユーザは必要なデータテーブルを自在に組み合わせ分析データを入手することが可能になった。なお、本基盤は登録ユーザのみが利用でき、ユーザ単位でアクセス権限を設定することにより閲覧・取得可能なデータを制御し、セキュリティ担保とユーザ同士のデータ共有の両立を実現している。

#### 3.2 分析基盤

分析基盤は「市販の表計算ソフトウェアやBI(Business Intelligence) ツールなどの可視化ツール」と「当社が独自に開発した分析ツール」で構成した。

表計算ソフトウェアや可視化ツールは、前述のレレーションデータベースに直接アクセスすることにより必要なデータを迅速に取得・成形・可視化することができる。そのデータや分析結果を俯瞰（ふかん）できる機能は、ユーザの意思決定を補助する役割を担っている。また、分析ツールは、データベース基盤に蓄積された実験データを機械学習した予測モデルを搭載し、直観的な操作で高度な分析を可能とした。その概要を以下に述べる。

これまでも実際の材料開発での検証を通じて、課題解決手段としてのMI技術の有効性は実証されつつあった。しかし、データサイエンティストがPythonやRなどの統計解析向けプログラムを駆使して分析するなど、専門性が高いことがMI技術の広い活用を困難にしていた。そこで、本分析基盤の開発により、一般の材料開発者でも容易に高度な分析を実施できる環境を整備した。

分析ツールには、当社のデータサイエンティストがデータベース基盤上に蓄積された実験データを機械学習・チューニングすることにより作成した様々なモデルが登録されている。分析ツールの使用例を図7に示す。分

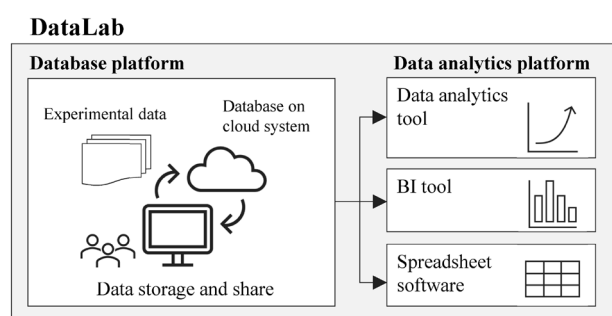


図5 溶材開発 DataLab の構成図  
Fig.5 System architecture image of DataLab




図6 データベース基盤におけるデータ処理の概略図  
Fig.6 Data processing image on the database

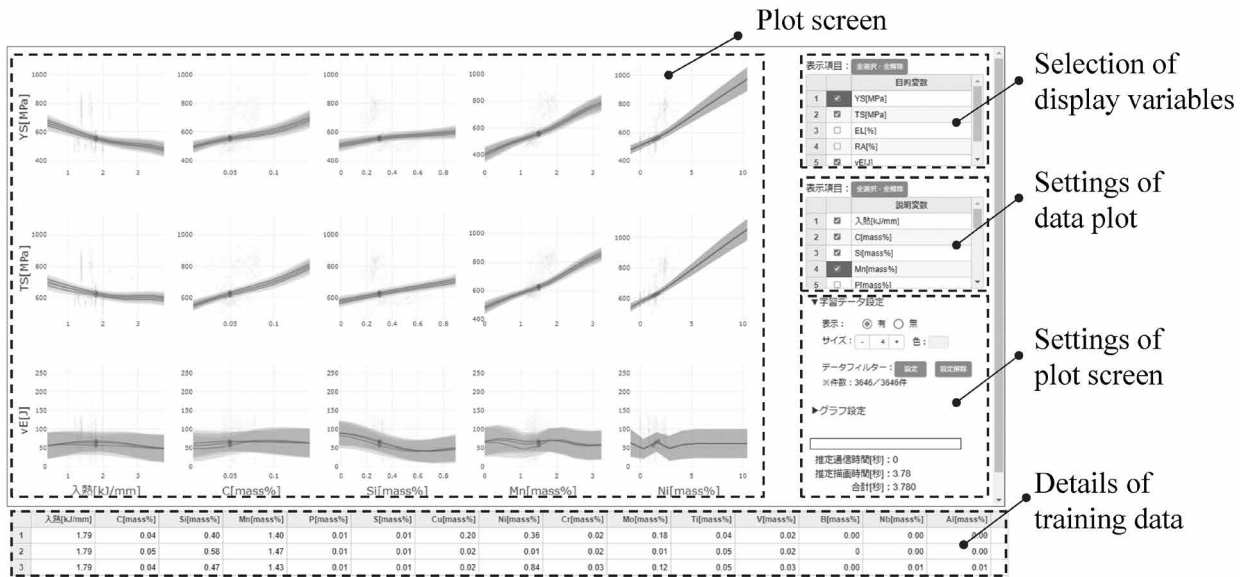


図7 分析ツールの一画面  
Fig.7 Screen example of the data analytic tool

析ツールの画面上には、溶接入熱や溶金成分をパラメータとして、予測の不確かさや各パラメータ変動による特性予測値の変化傾向とともに、強度特性やじん性を予測した結果が表示されている。この事例のように、ユーザは目的に応じてモデルを選択し、変数や条件を入力して計算を実行することにより、容易に材料特性の予測や目的材料の設計探索を行うことができる。また、このような高度な計算をクラウド上で実行することにより、ローカル端末のマシンスペック不足という高度なデータ分析における一般的な問題の解決も図っている。

今後も、予測と探索に関するモデルを拡充し、溶接材料開発をより強化させていくことを計画している。

#### 4. 今後の展望

溶接材料は適用業種、適用箇所、鋼種、施工法ごとに要求特性が異なるため、必要となる実験データやMI技術も異なる。今後、材料開発者ニーズの重要性や一般性が高い要素から継続して実験データの蓄積とMI技術を開発し、技術的に対応できることを順次拡大させる。また、すべての材料開発者がそのメリットを享受できるように溶材開発DataLabのアップデートを継続していく。さらに、材料開発だけでなく、溶接ソリューション開発や生産課題解決にMI技術の適用を拡大し、開発工期短縮、未踏の高位特性確保、製造品質の向上の実現を図っていく。

むすび＝溶接材料の開発プロセスにおける課題解決手段としてMI技術の適用を検討し、実際の材料開発案件に対してその有効性を実証するとともに、学習データ共有とその利活用を可能にするデータ活用基盤を構築した。今後、MI技術と本基盤の最大活用を図り、材料開発の高度化を通じて顧客ニーズに対応していく所存である。

#### 参考文献

- 1) 加茂和史ほか. R&D神戸製鋼技報. 2018, Vol.68, No.2, p.7-11.
- 2) 日本製鉄. ニュースリリース. 2022-03-09.  
[https://www.nipponsteel.com/news/20220309\\_100.html](https://www.nipponsteel.com/news/20220309_100.html). (参照2022-12-19).
- 3) 知京豊裕. 情報知識学会誌. 2017, Vol.27, No.4, p.297-304.
- 4) 出村雅彦ほか. まてりあ. 2019, Vol.58, No.9, p.489-493.
- 5) 東洋経済日報. 2017-06-23.  
[http://www.toyo-keizai.co.jp/news/economy/2017/post\\_6997.php](http://www.toyo-keizai.co.jp/news/economy/2017/post_6997.php). (参照2022-12-19).
- 6) NIST. Materials Innovation Case Study: QuesTek's Ferrium® M54® Steel for Hook Shank Application.  
[https://www.nist.gov/system/files/documents/2018/06/26/materials\\_innovation\\_case\\_study\\_questek\\_090616.pdf](https://www.nist.gov/system/files/documents/2018/06/26/materials_innovation_case_study_questek_090616.pdf). (参照2022-12-19).
- 7) 持橋大地ほか. ガウス過程と機械学習. 講談社, 2019. 256p.
- 8) 松井孝太ほか. まてりあ. 2019, Vol.58, No.1, p.12-16.
- 9) S. Boyd et al. Convex Optimization. Cambridge University Press, 2004. 727p.