

MATERIALS and PROCESSING



Materials and Processing
Division Newsletter November 2023

NO.66



日本機械学会
機械材料・材料加工部門ニュースレター

巻頭言

機械学習を用いた材料・プロセス開発



名古屋大学
竹内 一郎

AI・機械学習の科学技術分野での活用

様々な分野で AI の活用が増え、人間を凌ぐ性能を発揮している。現代の AI は、データに基づいて予測や発見を行うための数理情報技術である機械学習をベースとしている。機械材料・材料加工部門の研究開発においても、生産プロセスの IoT 化によって得られたデータを活用するデータ駆動型アプローチの重要性が増している。ここでは、科学技術分野において、AI・機械学習がどのように活用されているかを解説し、一例として機械学習を活用したデータ駆動設計と呼ばれるアプローチを紹介することで巻頭言としたい。

図 1 は科学技術分野における AI 活用の概念を示したものである。AI・機械学習の活用により、これまでは専門家の




図 1 科学技術における AI 活用の概念図

の知識や経験に依存してきた科学技術の仮説生成、性能予測、仮説検証、知識発見の一部が自動化されつつある。AI には様々なタイプがあり、仮説生成には生成 AI、性能予測には予測 AI、仮説検証には対話 AI、知識発見には説明 AI が利用される。4 つのタイプの AI は異なるタイプの機械学習法に基づいているが、いずれもデータを活用してメカニズムの学習を行うものである。

生成 AI と予測 AI を用いたデータ駆動設計

科学技術のための AI 活用の例として、生成 AI と予測 AI を用いたデータ駆動設計を紹介しよう。多くの科学技術開発は、(広い意味での) 設計問題と捉えることができる。例えば、建築設計、機械設計、車両設計、回路設計、ソフトウェア設計、分子設計などと呼ばれるタスクがあるが、これらの問題では、まず始めに、設計 (パラメータ) 空間を同定し、続いて設計空間における最適化が行われる。データ駆動設計の基本アイデアは、AI・機械学習を利用し、データ駆動で設計空間を構築することである。

図 2 は、データ駆動設計の基本概念を示したものである。データ駆動設計では、Encoder、Decoder と呼ばれる 2 つの機械学習 (深層学習) モデルが重要な役割を果たす。Encoder は設計対象を設計パラメータ空間に変換する役割を担い、Decoder は設計パラメータ空間から設計対象へ戻す変換をする役割を担う。Decoder と Encoder の間の空間は潜在空間と呼ばれ、データ駆動設計では、潜在空間において最適化が行われる。例えば、図 2 は分子 (化学化合物) 設計問題の例を示している。データ駆動設計では、専門家の知識や経験に基づく通常的设计とは異なり、データの背後にある潜在的な設計対象の自由度を過不足なく表現できるようなベクトル空間を構築できるため、複雑な対象に対してもきめ細かな設計が可能になると期待されている。




図 2 データ駆動設計の概念図

近年の AI の進展は著しく様々な分野で変革が起こっている。本稿で議論した科学技術分野においても、専門家の知識

や経験だけに頼るのではなく、データを積極的に活用したデータ駆動型のアプローチが益々重要になってくると考えられる。

■特集：機械学習を用いた材料・プロセス開発

□ 特集1 金属材料の変形・加工におけるデータ同化の活用 □

東京農工大学
山中 晃徳

1. はじめに

データ同化 (Data assimilation) は、実験・計測と数値シミュレーションをつなぐ方法である^{1),2)}。ここで、「つなぐ」に対応する英単語は、assimilate (同化させる)、fuse (融合する)、combine (結びつける) もしくは integrate (統合する) と言えるだろう。このデータ同化を用いることで、実験では計測・測定できない系の状態を推定できるほか、限られた実験・計測データから物性値や材料パラメータを逆推定することも可能である。これは数値シミュレーションの高精度化、予測性能の向上のみならず、実験・計測の設計や最適化にも資する。

筆者らは、データ同化の魅力を認識してから材料工学領域においてはフェーズフィールド法³⁾へ応用してきた。機械工学領域 (特に機械材料の変形・加工) においては、有限要素法を用いた数値シミュレーションへの応用を進めてきた。本稿では、本部門に関連する後者のデータ同化の応用事例を紹介する。

2. データ同化

データ同化は、かなり広い意味を持つ。そのなかでも筆者らは、ベイズの定理に基づくデータ同化に関する研究に取り組んでいる。ここでは、そのデータ同化の基礎となるベイズの定理について簡単に解説する。

データ同化では、実験・計測で対象とする現象の時系列データを取得し、それに対応する系の時間変化を数値シミュレーションモデル (以下、モデルと略記) で解析することを想定する。このとき、ある時刻 t における実験データを含む観測ベクトル y_t と、それに対応するモデル予測値を含む状態ベクトル x_t を定義する。データ同化では、これら x_t と y_t のそれぞれの確率密度関数 (PDF) とその時間発展を考える。 x_t の PDF は $p(x_t)$ と表され、事前分布と呼ばれる。また、 y_t の PDF は $p(y_t|x_t)$ と表され、尤度と呼ばれる。 $p(y_t|x_t)$ は x_t が所与のもとでの y_t の条件付き PDF である。ベイズの定理は、この2つの PDF が与えられたときに、 $p(x_t|y_t) \propto p(y_t|x_t) p(x_t)$ で表される。 $p(x_t|y_t)$ は y_t が所与のもとでの x_t の条件付き PDF であり事後分布と呼ぶ。ベイズの定理における、3つの PDF の関係を図1に示す。これは、実験データを反映する前のモデル予測値が $p(x_t)$ であり、実験データに基づき修正されたモデル予測値が $p(x_t|y_t)$ にあたる。もし、PDF として平均値と標準偏差 (または分散) をパラメータとして規定される単変量ガウス分布を仮定したとすれば、 $p(x_t|y_t)$ の標準偏差 (または分散) を評価することで、修正されたモデル予測値の「不確かさ」を定量化することができる。

時系列データに対するデータ同化のアルゴリズムは、逐次データ同化と非逐次データ同化の2種類に大別できる^{1)~3)}。逐次データ同化は、各時刻でのモデル予測値 x_t に対して、同時刻で取得された観測データ y_t で修正するアルゴリズムである。代表的かつ実用的なアルゴリズムには、アンサンブルカルマンフィルタ (EnKF)⁴⁾、粒子フィルタ⁵⁾ などがある。筆者らは、フェーズフィールド法による材料組織形成シミュ




図1 ベイズの定理における各種の確率密度関数 (事前分布, 尤度, 事後分布) の関係

レーションに対しては EnKF を適用してきた⁶⁾。

非逐次データ同化は、時系列データ全体をトレースするように初期状態 x_0 を推定する方法である。代表的なアルゴリズムには、4次元変分法 (4 DVar) やアンサンブル 4 DVar (En 4 DVar)^{7),8)} などがある。4 DVar では、各時刻での観測データとモデル予測値との誤差 (ミスフィット) の時間積分値を含むコスト関数の最小化問題を解く。この最小化問題を解く際に、コスト関数の勾配を求める必要があるが、後述の事例のような非線形有限要素解析を対象とした場合には難しい。これに対して、筆者らはコスト関数の勾配を求めることなく、様々なモデルに非逐次データ同化を実装できるアルゴリズム DMC-BO⁸⁾ と DMC-TPE⁹⁾ を開発した。以下では、これらの非逐次データ同化の応用事例を紹介する。

3. 材料試験データからの加工硬化則パラメータの逆推定

En 4 DVar を用いた、デジタル画像相関 (DIC) 法による非接触ひずみ計測と非線形弾塑性有限要素解析のデータ同化の事例を紹介する。この事例では、DIC 法によるひずみ計測結果から、A 5052-O アルミニウム合金の加工硬化を表す Swift 式のパラメータを逆推定することを目的とした^{10),11)}。

図2に実験系と試験片を示す。スプレーを用いて、試験片表面にランダムパターンを塗布し、その試験片を用いて単軸引張試験を実施した。2台の CCD カメラで試験片表面の連続画像を撮影し、DIC 法ソフトウェア GOM Correlate




図2 デジタル画像相関法を用いた非接触ひずみ計測による観測データの取得




図3 (a) DIC法によるひずみ測定結果と (b) En4DVarによるデータ同化で推定した加工硬化パラメータを用いたシミュレーション結果

Professionalを用いて、ひずみ場を取得した(図3(a))。このひずみ場を y_i の成分とした。有限要素解析は、ABAQUS/Standardを用いて、ユーザーサブルーチンの導入にはUMMDpを用いた¹²⁾。

データ同化で逆推定したSwift式のパラメータを用いて、単軸引張試験を模擬する有限要素解析を行い、DIC法で計測したひずみ場と比較した(図3(b))。試験片に発生するくびれを含めて、変形挙動を精度良く再現できることがわかる。 x_i に推定したいパラメータを含めることで、計算方法をほとんど変えることなく、複数のパラメータの逆推定も可能である¹³⁾。

4. プレス成形加工試験データからの材料モデルパラメータの逆推定

金属板材のプレス成形加工のシミュレーションに用いる降伏関数(材料モデル)のパラメータは、二軸引張試験などの多軸応力試験のデータを蓄積して、それに基づき同定されてきた¹⁴⁾。これに加えて、筆者らはDMC-TPEに基づく非逐次データ同化手法により、金属板材のプレス成形加工試験で取得できる実験データから降伏関数のパラメータを逆推定する方法を提案している。その事例として、A5052-Oアルミニウム合金板(公称厚さ1.0 mm)に穴広げ試験を行い、同時にDIC法によるひずみ計測を実施し、その計測結果からYld2000-2d降伏関数¹⁵⁾の9つのパラメータを逆推定した。この事例では、観測データを得るために、穴広げ成形試験を実施した(図4)。有限要素解析に用いたソフトウェアやユーザーサブルーチンは、3章で紹介したものと同一である。

DMC-TPEに基づく非逐次データ同化手法で逆推定したパラメータを用いて、穴広げ成形シミュレーションを実施して得られたひずみ場とDIC法で測定したひずみ場との絶対誤差を図5に示す。従来の二軸引張試験データに基づく方法で同定されたパラメータを用いた場合よりも、アルミニウ



図4 穴広げ成形試験におけるDIC法による非接触ひずみ計測による観測データの取得




図5 試験片表面のx方向変位分布のDIC法による測定結果との絶対誤差(パンチ高さ10.8 mm)

ム合金板の変形挙動を高精度に再現できていることがわかる。この事例では、 x_i の成分に金型や金属板材との間の摩擦係数を含めることで、実加工に近い条件で摩擦係数を逆推定することもできる。

5. おわりに

本稿では、データ同化を金属材料の変形および加工の数値シミュレーションに応用した事例を紹介した。冒頭に述べたように、データ同化を用いれば、測定可能な限られた実験データからでも物性値や材料パラメータ等を逆推定し、数値シミュレーションの予測精度を向上させることができる。これはいわば、実現象のデジタルツインを構築する強力な方法であると言えるだろう。データ同化を応用して、各種現象のデジタルツインを構築できるようになれば、様々な材料(サンプル)の物性値の取得方法としても有用ではないだろうか。

本稿では、紙面の都合上、データ同化の概要のみを述べるに留まったが、興味を持って頂いた読者には、解説論文^{16), 17)}も参照して頂けると幸いである。最後に、本稿で紹介した研究成果は、JST CREST(JPMJCR18J4)、科学研究費補助金(20H02476, 23H01297)および公益財団法人天田財団2021年度重点研究開発助成(AF-20210002-A2)のもとで得たものであり、ここに記して深甚なる謝意を表す。

文献

- 1) 淡路敏之, 蒲地政史, 池田元美, 石川洋一, データ同化観測・実験とモデルを融合するイノベーション, (2009), 京都大学学術出版会
- 2) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田亮, データ同化入門次世代のシミュレーション技術, (2011), 朝倉書店
- 3) 山中晃徳, 三好英輔, Pythonによるフェーズフィールド法入門基礎理論からデータ同化の実装まで, (2023), 丸善出版
- 4) G. Evensen, Ocean Dyn, Vol. 53(2003), pp. 343–367.
- 5) G. Kitagawa, J. Comput. Graph. Stat, Vol. 5 (1996), pp. 1–25.
- 6) 例えば, A. Yamanaka, Y. Maeda, K. Sasaki, Mater. Des, Vol. 165 (2019), 107577.
- 7) C. Liu, Q. Xiao, B. Wang, Mon. Weather Rev, Vol. 136 (2008), pp. 3363–3373.

- 8) A. Ishii, A. Yamanaka, E. Miyoshi, A. Yamamoto, Mater. Today Commun., Vol. 30(2022), 103089.
- 9) A. Ishii, A. Yamamoto, A. Yamanaka, Sci. Technol. Adv. Mater.: Methods, Vol. 3(2023), 2239133.
- 10) S. Sueki, A. Ishii, A. Yamanaka, Proceedings of JSME International Conference on Materials and Processing 2022, (2022), Paper No. Tu-3 B-3.
- 11) S. Sueki, A. Ishii, A. Yamanaka, Int. J. Solids Struct., Vol. 279(2023), 112350.
- 12) H. Takizawa, T. Kuwabara, K. Oide, J. Yoshida, J. Phys.: Conf. Ser., Vol. 734(2016), 032028.
- 13) 末木咲衣, 石井秋光, 山中晃徳, 塑性と加工, 第 64 巻(2023), pp.195-201.
- 14) 桑原利彦, 鉄と鋼, 第 108 巻(2022), pp.233-248.
- 15) F. Barlat, J. C. Brem, J. W. Yoon, K. Chung, R. E. Dick, D. J. Lege, F. Pourboghrat, S. H. Choi, E. Chu, Int. J. Plasticity, Vol. 19(2003), pp.1297-1319.
- 16) 山中晃徳, ぷらすとす, 第 6 巻(2023), pp.248-252.
- 17) 山中晃徳, 計算工学, Vol. 28(2023), pp.7-10.

□ 特集 2 材料・プロセス開発における機械学習の活用 □

東京エレクトロン株式会社
守屋 剛・吉井 直樹

1. はじめに

近年、計算能力の向上と AI アルゴリズムの進歩により、機械学習の応用が広がっている。これらの技術を材料科学に応用することで、新たな半導体材料の発見やスクリーニングが期待されている。半導体デバイスは電子機器の中核であり、微細加工を施したシリコン基板から製造される。半導体デバイスの製造には高精度な加工が要求され、エッチング、成膜、洗浄、リソグラフィなどのプロセスがガスや薬液を用いて行われる。半導体製造装置では機械学習が新規材料や製造プロセスの探索に活用されている。¹⁻⁵⁾

本稿では、半導体製造プロセスにおける機械学習の適用例として、成膜原料探索について紹介する。データから有用な知識を効率的に抽出するために、機械学習アルゴリズムを使用してモデルを自動生成した。このモデルを使用して数値の予測を行った。

半導体製造プロセス開発において、機械学習の利点として、大量のデータを高速に処理し、高精度な判定を行うことができる点が挙げられる。また、生成された機械学習モデルを繰り返し利用することも可能であり、十分な学習データがあれば、機械学習は経験豊富な技術者と同等以上の精度で予測を行うことができる。

2. 機械学習による成膜原料の探索

半導体製造プロセスでは、化学気相堆積 (CVD) 法において使用する原料によって成膜結果が異なることが知られている。これまで、エンジニアの知識と経験に基づいてさまざまな原料が開発され、半導体製造工場で使用されてきた。たとえば、プラズマ CVD 法による炭素膜の成膜には、メタン (CH_4)、アセチレン (C_2H_2)、プロピレン (C_3H_6)、シクロブタン (C_4H_8)、シクロヘキサン (C_6H_{12})、トルエン (C_7H_8)、一酸化炭素 (CO) などの原料が使用され、成膜後の膜質や成膜速度は原料とプロセス条件によって変化する。⁶⁻⁷⁾

機械学習では、目的変数と説明変数を使用してモデルを算出する。目的変数は成膜速度や硬度などの目標値を表し、説明変数は成膜原料の特性や構造などの特徴量を示す。材料特性データとしては、Mordred などの分子記述子計算データベースが利用可能であり⁸⁾、本研究では炭素系の成膜原料を対象とし Mordred で公開されている 1,825 の材料記述子を使用した。教師データとして、炭素の成膜に関する 193 報の公開論文から、成膜速度や硬度などの多目的変数を抽出し、表 1 のデータセットを構築した。

説明変数には、圧力、温度、成膜原料ガス流量、プラズマパワー、バイアス電圧などのプロセス条件 12 個が含まれて

表 1 公開論文から収集したデータの情報

原料ガス	データ数	目的変数のデータ数	
		成膜速度	硬度
CH_4	78	56	56
C_2H_2	20	19	13
C_3H_6	9	9	6
C_4H_8	6	6	6
C_6H_{12}	3	3	0
C_7H_8	3	0	3
CO	1	1	1
合計	120	94	85

おり、制約条件は表 2 のように設定した。目的変数として、成膜速度 300[nm/min]以上、硬度 50±5[GPa]以上と設定した。Mordred に含まれる 1,825 の記述子は次元削減を行い、精度向上と過学習リスクのバランスをとった。

最適なアルゴリズムを検討するために、ランダムフォレスト、ガウス過程回帰、サポートベクター回帰を比較した結果を表 3 に示す。図 1 に、成膜速度と硬度のデータセットに対して予測と実測を比較した結果を示す。ランダムフォレスト、ガウス過程回帰、サポートベクター回帰の各アルゴリズムの予測結果を検証した結果、ランダムフォレストの相関係数が最も高いことがわかった。この結果から、本研究ではランダムフォレストによる分析を実施した。

ブロイデン・フレッチャー・ゴールドファープ・シャノン法を使用して、成膜速度と硬度を目的変数として、ターゲット

表 2 プロセス制約条件

項目		制約条件	
		最小値	最大値
圧力 [Pa]		13.3	2,660
温度 [°C]		-60	700
成膜原料ガス流量 [sccm]		10	5,000
H ₂ ガス流量 [sccm]		0	10,000
Arガス流量 [sccm]		0	10,000
Heガス流量 [sccm]		0	10,000
ドーピングガス	(CH ₃) ₃ SiHガス流量 [sccm]	0	1,000
	SiH ₄ ガス流量 [sccm]	0	1,000
	N ₂ ガス流量 [sccm]	0	1,000
主プラズマパワー [W]		10	10,000
リモートプラズマパワー [W]		0	10,000
基板バイアス電圧 [V]		0	10,000

表 3 Mordred 記述子に対する各アルゴリズムの相関係数と平均誤差

項目	成膜速度		硬度	
	相関係数	平均誤差(MAE)	相関係数	平均誤差(MAE)
RF	0.9408	16.6393	0.9666	2.6289
GP	0.9186	21.9626	0.9209	3.6583
SVR	0.8181	33.1561	0.9605	2.6334

Test data




図 1 予実のアルゴリズム依存性 (x 軸: 実測値, y 軸: 予測値)

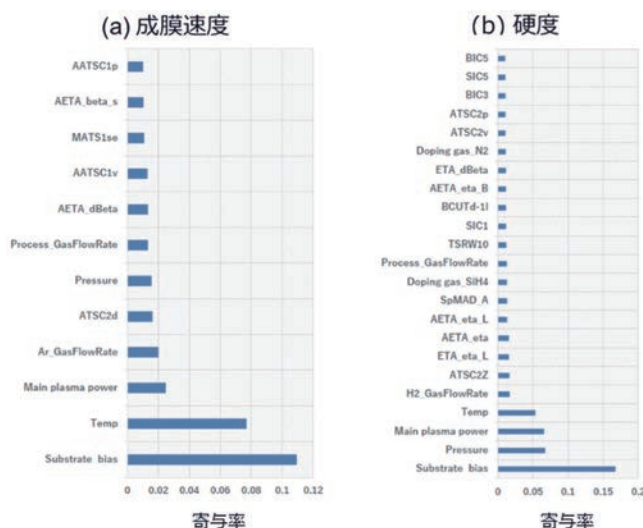


図 2 (a) 成膜速度, (b) 硬度に対する各記述子の寄与率

ト値に近づけるためにどの材料ガスを使用すればよいかを探索した。その結果, $C_3H_6 > CH_4 > C_4H_8 > C_2H_2$, C_6H_{12} , C_7H_8 , CO の優先順位で原料ガスを使用すべきであることがわ

かった。

上記は目的変数を成膜速度と硬度に絞って、どの材料ガスを用いるとターゲット値に近くなるかを探索した結果であり、実際にはプロセス条件についても最適化が必要である。それぞれの記述子の寄与率を算出した結果を図 2 に示す。成膜速度は上位 4 件、硬度は上位 5 件までがプロセス条件記述子であることが分かった。材料記述子の寄与率は、上位のプロセス条件記述子と比較すると小さく、プロセスの最適化が原料ガスの選択よりも重要であるといえる。選択された記述子については、プロセス技術者が重要と考える記述子が削除されていないかを確認し、妥当性についても検証されている。

3. まとめ

本研究では、炭素膜のプラズマ CVD において、成膜原料ガスの探索を行った。公開論文から得られたデータを使用して機械学習モデルを生成し、成膜原料ガスの優先順位を算出した。その結果、プロセスパラメータにより成膜結果が大きく影響されることが明らかになり、特に、基板バイアス電圧の影響度が高いことが示唆された。また、この解析結果を経験のあるプロセス技術者が確認することで、反応メカニズムを理解することができるという利点がある。

このように、機械学習のフレームワークが新規半導体材料探索やプロセス開発に役立つ可能性が示された。ビッグデータの時代においては、自律化された実験装置と機械学習による予測モデルを組み合わせることで、新規材料開発を加速することができると考えられる。

参考文献

- 1) 守屋剛, 応用物理, 90 巻, 5 号, 290 (2021).
- 2) M. Hankinson, T. Vincent, K. Irani and P. Khargonekar, *IEEE Trans. Semicond. Manufact.*, 10, 121 (1997).
- 3) S. Kang, *IEEE Trans. Semicond. Manufact.*, 31, 149 (2018).
- 4) T. Moriya, Y. Suzuki, H. Yonemichi and H. Moki, *J. Phys. D: Appl. Phys.*, 56, 354002 (2023).
- 5) F. Tanaka, H. Sato, N. Yoshii and H. Matsui, *IEEE Trans. Semicond. Manufact.*, 32, 444 (2019).
- 6) M. A. Tamor and W. C. Vassell, *J. Appl. Phys.*, 76, 3823 (1994).
- 7) S. J. Park, D. Kim, S. Lee, Y. Ha, M. Lim and K. Kim, *Thin Solid Films*, 663, 21 (2018).
- 8) 森脇寛智, 川下理日人, 田雨時, 高木達也, 第 39 回ケモインフォマティクス討論会, Y 4 (2016/09/29-30, 浜松).

□ 特集 3 インフォマティクス研究に繋がる セラミックス粉体および薄膜のハイスループット合成・評価・解析技術 □

東京理科大学創域理工学部先端化学科
藤本憲次郎

1. はじめに

セラミックス (無機材料) におけるマテリアルズインフォマティクス (MI) やプロセスインフォマティクス (PI) では、蓄積した化学組成と物性のデータセットから機械学習によって新材料を提案したり、材料合成プロセスのカギとなる要因 (プロセス条件) を特徴量として見出して材料合成へフィードバックさせたりしている。また自律化自動実験への取り組みでは、ベイズ最適化を併用して効率的かつ最短距離 (時間) で最適な機能性材料 (ゴール) を人為的関与なしに見つけ出す挑戦が進められている。効率的に測定および解析

する計測インフォマティクスもあらゆるところで開発が進み、これらの分野のさらなる発展が期待される状況である。

セラミックスの合成方法には「固相合成法」、「液相合成法」、「気相合成法」の 3 つに大きく分類され、そこからさらに研究者の工夫により手法が細分化されている。そしてそこから得られる試料形態も「粉末」、「単結晶」、「焼結体」、「膜」、「非晶質」と多様である。前述の自律化自動実験では、東京大学大学院理学研究科化学専攻の一杉太郎教授らが「気相合成法」により薄膜を作製し、その物性データから次に実験すべき化学組成や熱処理条件をベイズ最適化により提案している¹⁾。

一方で固相合成や液相合成を基盤とした粉体や膜の自律化自動実験は薄膜のように進んでいない。

1999 年以降、筆者を含めたメンバーは、MI、PI そして自律化自動実験に密接な関係となるであろう「固相合成」および「液相合成」に軸足を置いたセラミックス粉体および膜のハイスループットプロセス（コンビナトリアル技術）研究を構築してきた。これは MI や PI で必要となるデータセットを自前の研究データを短期間で作り上げるうえでは非常に重要なツールであり、計算化学や文献データからデータセットを構築する研究者にとっても空白領域を補間するうえでは効果的な研究手法になり得るはずである。そこで本稿では、これまでに構築した各種ハイスループットプロセスのいくつかを紹介したい。

2. ハイスループット合成プロセス

この概念となるコンビナトリアルケミストリーは 1986 年にノーベル化学賞を受賞した Merrifield 氏が提案した微小ポリマービーズを活用した固体ペプチド反応の提案²⁾によるもので、効率的な材料探索の方法の概念として現在ではコンビナトリアル技術（あるいはプロセス）という言葉も多く使われる。セラミックス粉体の場合、合成から X 線回折による結晶構造の定性分析までの一連の作業時間は 1 日～数日を必要とする。この作業効率を飛躍的に高め、従来に比べ 100 倍近い粉体試料群の作製能力を有するコンビナトリアル技術の開発は、東京工業大学と科学技術庁無機材料研究所（のちに物質・材料研究機構（NIMS）として改組）の共同で 1999 年に開始された先導研究プロジェクト（コンビナトリアル材料科学の創製と先端産業への展開（コンビナトリアルプロジェクト；2005 年までの 7 年間実施））の一部として進められた。このプロジェクトは 6 グループから構成され、そのうちのひとつがリチウムイオン二次電池正極材の探索に焦点を当てられ、ここで多元系セラミックス粉体試料群（ライブラリ）のハイスループット合成に向けた装置開発が行われた。

図 1 左は初号機（COMBIG）³⁾、図 1 右は市販を想定した 2 号機（COMBIT）⁴⁾である。両装置の基本概念は、①原料は溶液もしくはスラリー（泥漿）、②原料液体の分注と混合はマイクロピペットを使用、③混合された原料液体は 16 もしくは 36 の窪みを持つ 35×35×5 mm の反応容器に分注しホットプレート上で蒸発乾固、の 3 つで構成される。初号機の COMBIG は天吊り型のロボットアームを有し、複数のハンドが装着可能であった。具体的には液体を分注および攪拌（吸引と吐出の繰り返しにより実施）のためのロボットハンド、もうひとつはルッポの代替となる反応容器の搬送用ハンドである。後者のハンドは蒸発乾固した粉体ライブラリを含む汎用容器を電気炉や分析装置へ搬送するためのものである。合成プロセス全体における律速過程は熱処理であり、時間短縮のために 30 分程度で室温から 1200℃ 付近まで昇

温し、1200℃ から 200℃ までを 30 分で強制冷却するシステムの開発も進められた。ちなみに 200℃ を強制冷却下限としたのはハンドの耐熱温度を考慮したためである。

初号機における知見を踏まえ、COMBIT では反応容器に混合原料を分注し蒸発乾固させるまでに機能を限定するとともに装置を小型化させた。改良した機能に原料液体の混合がある。液体原料が混合されたときに沈殿物を生じることがある。沈殿物内の偏析を避けるため、また液体の混合度合いを均質にするため、攪拌棒が高速回転するホモジナイザを 6 台搭載し、混合原料のためのバイアル群に対し 1 列（6 試料）毎にまとめて攪拌混合する機能を付与した。なお次の 6 試料の攪拌におけるホモジナイザによるコンタミ防止のため、ホモジナイザの洗浄槽を設け、列ごとに攪拌と洗浄を繰り返す仕様とした。装置を小型化し機能を集約したため、粉体ライブラリを調整するまでの間の作業を雰囲気制御させたり、搬送システムを後付けさせたりするのも容易である。

そしてセラミックス粉体ライブラリの作製手法の多様化を図るため、静電噴霧堆積法に基づいた装置開発も開発してきた。静電噴霧堆積法は、シリンジの先端に装着する注射針に相当する部分に高電圧（正電荷）を印加することで、吐出される液体が接地された対極との間での表面張力、静電気力、重力との相関で微細な液滴を発生させ、接地された（負に帯電された）基材上に引き寄せられ堆積させる方法である。図 2 は開発装置（M-ist Combi）の概念図を示す^{5,6)}。当該装置は最大 4 種類の原料液体をそれぞれ独立したシリンジに充填し、シリンジポンプの送液速度を制御することで原料液体の送液速度を制御する。それぞれのシリンジから送り出された液体はマニホールドで 1 本の送液チューブに集約され高電圧を印加したステンレスカットチューブから噴霧される。そして噴霧位置は 3 軸ロボットハンドによって制御される。

Lenggoro らの報告にもあるように、当該装置の基盤となる静電噴霧堆積法は低電圧ではパルスジェット状、高電圧ではコーンジェット状と、印加電圧の制御によって液滴サイズと噴霧形態を変化できる⁷⁾。ただし原料種や溶液濃度によって液滴サイズと噴霧形態は異なるため印加電圧値は固定されない。この現象を活用することで当該装置では印加電圧によって液体・粉体・薄膜の 3 種類の試料形態からなるライブラリを構築することができる。ただし、粉体と薄膜ライブラリを作製する場合、前述の反応容器（35×35×5 mm）のように狭小領域にライブラリを作製する場合、噴霧された液滴が隣接する試料に混入してしまう可能性があるためコンタミ防止用マスクを施す必要がある。この問題点の改善策として、原料を噴霧するステンレスカットチューブの周囲に溶媒のみを噴霧するステンレスカットチューブを複数本均等配置させたノズルを発明した。これにより図 3 のように正電荷を有する液滴同士の反発によって狭小領域に粉体や膜のライブラリをマスクレスで構築できることを可能にした⁸⁾。そし




図 1 溶液やスラリーを原料としたハイスループット粉体合成ロボット COMBIG および COMBIT の全体像




図 2 静電噴霧堆積法を基盤としたハイスループット材料探索装置（M-ist Combi）の概念図




図3 噴霧堆積領域を意図的に絞り込むための方法

て、当該装置は前述の液体分注型よりも小型化が可能であり、こちらもライブラリ作製時においても雰囲気制御が可能である。

3. ハイスループット評価プロセス


合成だけがハイスループット化されても計測と解析が従前のままではデータセットの効率的な生成にほど遠い。これまでに積み上げられてきた評価手法と同等の精度でデータが得られるハイスループット評価・解析ツールの開発が必要である。本項ではこれまで開発に挑戦した計測技術のうち3つを紹介したい。

3.1. 温度一抵抗値測定

前節の M-ist Combi 装置は薄膜ライブラリの作製も可能であることを述べた。膜作成から評価までをハイスループット化する実証例としてサーモクロミック材に着目し、二酸化バナジウム (VO_2) 膜の作製とともに「温度一抵抗値」測定のためにプローブ開発を行った。具体的には M-ist Combi 装置の液体噴霧パーツを四深針プローブに付け替えられる機構を付与し、同一装置で膜作成から物性計測までに行えるようにした。ライブラリの温度変化はホットプレートでパルチヒーターへ置き換えて可能にした。図4左は石英ガラス基板上に堆積させた16個からなる VO_2 膜を示す。そして図4右はそれぞれの VO_2 膜に対する温度一抵抗値曲線を示す。ライブラリは全て VO_2 であるが膜厚にバラツキがあることから抵抗値には相違がみられるが、半導体状態から金属状態への臨界温度は $67\sim 68^\circ\text{C}$ 程度で同一であり、各点は1秒程度で測定が可能であった⁹⁾。

3.2. 実験室系粉末 X 線回折測定

セラミックスを扱う場合、粉体試料を作製したあとは X 線回折測定により結晶相の確認(相同定)を行うのが一般的な流れとなる。近年、高速検出器の発展のおかげで実験室系の粉末 X 線回折装置による測定時間が大幅に短縮され

図4 M-ist Combi 装置による VO_2 膜ライブラリとそのサーモクロミック特性

てきた。前述のコンビナトリアルプロジェクトが実施されていた当時はシンチレーション検出器が主であったことから、測定範囲にも依存するが、おおむね一試料あたりの測定時間は30分程度と見込まれる。前述のハイスループット合成システムでは1日あたり100試料の粉体試料の合成が可能だが、従前の検出器による X 線回折測定では全試料の測定に少なくとも丸二日は必要になる。そこで柳瀬・渡辺らは前述の反応容器から試料を取り出すことなく、X 線の照射位置が制御可能な X-Y ステージに搭載し、検出器に位置敏感型比例検出器 (PSPC) と組み合わせたハイスループット X 線回折装置 (RIGAKU RINT 2550 PC-K) を開発した。これにより $10\sim 140^\circ$ までの X 線回折パターンを結晶性に依存するが最短で30秒程度で、かつ X-Y ステージにより測定位置を変化させて連続して回収することに成功した^{10,11)}。

3.3. 放射光 X 線測定治具

MI 研究では組成と物性から機械学習させることが多い。これに加えて格子定数や分率座標といった結晶学データから得られる結合距離や結合角などもデータセットに加えることができれば材料探索におけるインフォマティクス研究はさらに向上すると考えている。海外と比べれば国内の放射光施設の数は恵まれて、身近なものになってきた。そこで高輝度かつ指向性の高い放射光 X 線回折測定と構造精密化はハイスループットに対応できるか検討した。従前の方法では粉末ライブラリを放射光 X 線回折測定する際に試料準備に要する作業時間が膨大になる。粉体試料をキャピラリーチューブに充填する作業は1試料あたり少なくとも5分程度見込まれるだろう。先ほども述べたが1日当たり100試料程度のライブラリが得られる場合、それらをキャピラリーチューブへ充填する作業は最低でも8時間必要である。さらに放射光施設におけるキャピラリーチューブホルダーへの固定、そして測定ごとに行われるキャピラリーチューブのセンタリング作業も時間を要し、与えられた測定時間(シフト)の半分を測定外の時間として費やしてしまうかもしれない。これらの手間を可能な限り省いた上で同等の質を有する X 線回折強度を得るための手段を考えている。図5は3Dプリンタにより試作した放射光測定治具である。良く粉碎された粉体をポリイミドテープに付着させ、コンタミを防ぐためにもう一枚のポリイミドテープで挟み込み、そのテープをコンパクトカセットに用いられているテープ状に加工するだけである。図6は実際にあいちシンクロトロン光センターの BL 5 S 2 を利用して得られた粉末 X 線回折パターンを従前のキャピラリーに粉体を充填した場合と併せて示す。試料は熱電材探索で作製したペロブスカイト型 $\text{Ca}_{0.97}\text{Bi}_{0.03}\text{MnO}_3$ ¹²⁾ である。キャピラリーに封入された粉末は二次元回折像に見られるように明瞭なデバイシェラー環が観察される。一方、治具を測定系に固定して X 線を照射すると、X 線照射領域(コリメータ径: $0.5\text{ mm}\phi$) 内の粉末が少なく、試料の向きが偏ったため、環ではなく回折点が現れた。図6右の X 線回折パターン(黒と青)の強度比の違いもこれを示している。そこで、固定していた測定系の X 線照射位置を中心に $\pm 5^\circ$ の範囲で回転(揺動)させたところ、概ね従来法で測定したものと同



図5 3D プリンタにより試作した放射光回折測定治具




図6 放射光回折測定治具による $\text{Ca}_{0.97}\text{Bi}_{0.03}\text{MnO}_3$ の測定結果

強度比の X 線回折パターンを得ることができた。回収された回折強度データからリートベルト解析¹³⁾を行い、比較の一例として信頼度因子 R_{wp} を比較したところ、従来法、治具固定時、治具揺動時で、それぞれ 2.77%, 18.9%, 7.2% を示した¹⁴⁾。現在、信頼度因子を含めて従来法に近い精度を得るための改良を現在も進めている。なお、当該治具を作製したことによる副産物として、BN 粉体との混合によりペレット化させてから測定する必要があった透過法による X 線吸収微細構造 (XAFS) 測定が、ポリイミドテープに付着させること以外に新たな加工を必要とせず測定できた。

4. ハイスループット解析プロセス (構造精密化の自動化を例として)

前節で X 線回折測定に関する説明が大半を占めたが、セラミックス材料においては合成したら X 線回折測定をするのが一連の流れとなっているのでご容赦いただきたい。本節ではその続きとなる。化学、物理、機械など、あらゆる分野で物性評価を実施した後は、そのデータを何かしらの方法で解析する。その解析自体もハイスループット化することが今後の MI や PI には必要になる。セラミックス粉体を取り扱う分野では X 線回折測定を実施したのち結晶相の確認 (定性分析) だけでなく単位格子中の原子座標 (分率座標ともいう) を求める「構造精密化」を行う場合があるが、これも一連の実験 (合成・評価・解析) のなかで律速になる可能性が高い。そこで相見晃久氏 (2023 年 10 月より防衛大学校) が構造精密化の代表的な方法である Rietveld 解析を自動化するための開発を進めてきた。Rietveld 解析を行うソフトウェアは国内外で様々なものが提供されているが、我々は泉富士夫博士が開発した RIETAN-FP¹⁵⁾ を使用することを前提とした。

手動解析手順をそのまま自動化するのではなく、「真値に近い初期値を用いることで精密化手順の最適化をしなくても簡単に真値が得られる」というコンセプトの元、自動解析アルゴリズムを考案した。詳細は文献に記載した論文を読んでほしい。本解析法は初期値と精密化手順の最適化を不要にしたことにより、解析者によるパラメータ調整を必要とせず広範な試料に対して適用可能でありかつ解析結果の個人差を排除できる。実験室系 X 線、放射光 X 線問わず様々な試料に対して解析速度約 4 倍でかつ妥当な解析結果が得られた¹⁵⁾。なお本稿で紹介した自動 Rietveld 解析ソフトは東京理科大学藤本研究室のホームページ (以下の URL) から無料でダウンロードが可能である。

<https://tus-fujimotolab.jp/download/autorietveld>
(使用する前に必ず利用規定を確認)

5. おわりに

本稿では MI や PI さらには自律化自動実験に繋がるコンビナトリアル技術の開発状況とハイスループット材料合成および評価・解析の例について触れた。セラミックス粉体における PI 研究では、国立研究開発法人産業総合技術研究所極限機能材料研究部門固体イオニクス材料グループの研究チームがロボット実験と AI によりセラミックスの化学焼結プロセスの条件探索を進めた成果がプレスリリース (2023 年 10 月 18 日) された¹⁶⁾。実験プロセスは限定されているが、今後の発展が期待される。また、セラミックス粉体ではないが、東京大学大学院工学系研究科機械工学専攻の長藤圭介准教授の研究チームが、固体高分子型燃料電池を構成する触媒層である粉体膜の乾燥プロセスにロボットと機械学習を導入して少ない実験回数でクラックのない緻密化膜の条件を最適化した¹⁷⁾。それぞれの専門分野において粉体や液体をハンドリングする技術と知見が集約されれば、「固相合成」や「液相合成」から得られるセラミックス材料の自律化された自動実験や MI、PI の研究もさらに加速するのではと期待している。

謝辞

本稿で触れた放射光測定治具の図面作成、制御回路とソフトウェアの開発には東北大学大学院工学研究科の丸山伸伍准教授のご協力があった成しえたものであり、これまでのご協力に感謝申し上げます。また、このツールを用いた XRD および XAFS 実験は、あいちシンクロトロン光センターの BL 5 S 1 および BL 5 S 2 にて実施されたものです (課題番号: 2017 P 0202, 2018 P 0104, 2019 P 0106)。本研究の遂行に関わられたすべての皆様に深く感謝致します。

文献

- 1) S. Kobayashi et al, *ACS Materials Letters* 5(10) (2023) 2711–2717.
- 2) R. B. Merrifield, *J. Am. Chem. Soc.* 85(1963) 2149–2154.
- 3) K. Fujimoto and M. Watanabe, *Meas. Sci. Tech.* 16 (2005) 41–45.
- 4) S. Suehara et al, *Appl. Surf. Sci.* 252(2006) 2456–2560.
- 5) K. Fujimoto et al, *Solid State Ion.* 177(2006) 2639–2642.
- 6) K. Fujimoto et al, *ACS Comb. Sci.* 15(12) (2013) 626–630.
- 7) I. W. Lenggoro and K. Okuyama, *J. Soc. Powder Technol., Japan* 37(2000) 753–760.
- 8) 藤本憲次郎, 伊藤滋, 特許第 5016960 号
- 9) K. Fujimoto et al, *Mater. Sci. Eng. A* 475(1–2), (2008) 52–56.
- 10) I. Yanase et al, *Solid State Ion.* 154–155(2002) 419–424.
- 11) I. Yanase et al, *Solid State Ion.* 151(1–4) (2002) 189–196.
- 12) K. Fujimoto et al, *J. Ceram. Soc. Jpn* 125(4) (2017) 308–312.
- 13) F. Izumi and K. Momma, *Solid State Phenom.* 130(2007) 15–20.
- 14) K. Fujimoto et al, *ACS Comb. Sci.* 22(12) (2020) 734–737.
- 15) A. Aimi et al, *ACS Comb. Sci.* 22(1) (2020) 35–41.
- 16) https://www.aist.go.jp/aist_j/press_release/pr_2023/pr_20231018/pr_20231018.html
- 17) K. Nagai et al, *Sci. Rep.* 12(2022) 1615.

□ 特集 4 ニューラルネットワークモデルを用いたスピニング加工の高精度板厚制御 □

産業技術総合研究所
榎藤 詩織

1. はじめに

金属加工のものづくりの現場では、加工条件や作業環境、作業者の経験など様々な因子が、成形品の形状や寸法精度などの加工結果に影響を及ぼす。ゆえに、最適加工条件の決定には多くの試行錯誤を要する。このような課題に対し、データ駆動型加工の開発が様々な加工を対象に進められている。これは、金属加工に AI (人工知能) を組み合わせて、最適加工条件を効率的に導く技術である。本研究ではスピニング加工と呼ばれる逐次成形を対象に、目標板厚を得る最適ローラーパスを導出するデータ駆動型加工を開発してきた。本稿ではこれまでの開発^{2)~4)}の概要を紹介する。

2. スピニング加工

スピニング加工は図 1 a) に示すように、ローラーを金属板の一部に押し当てながら動かし、少しずつ変形させて立体形状に成形する技術である。へら絞り加工とも呼ばれる。成形品の用途は自動車部品、航空・宇宙部品、半導体医療部品、建築・工芸品など多岐に渡る。変形は局所的かつ逐次的であるため、成形に必要な金型は一つで済む、小型の装置で成形できるなど、製造コストの観点で多くの利点を有する。また、ローラーを自由自在に動かせるため、ローラーの駆動と金型の回転を同期させて、図 1 b) のような複雑形状の一体成形も可能である。一方、加工中の材料流動はローラーの動作経路 (パス) に敏感である。ゆえに、板厚の制御が容易でなく、前述のように加工条件出しの試行錯誤が避けられない。著者はこの問題に対する解決策として、機械学習モデルの構築と逆問題の解法から成る、データ駆動型加工に着目した。具体的には、複数の加工条件が相互に作用し、人間では結果の予測が難しい加工において、既知の特徴に基づいて予測する機械学習が役立つと考えた。また、加工条件を入力、加工結果を出力とし、両者の関係を機械学習モデルで記述するだけでなく、構築したモデルに対し逆問題を解法することで、目標の板厚を得るための各加工条件の具体値が得られると考えた。




図 1 スピニング加工の a) 様子と b) 複雑形状成形例

3. データ駆動型加工の構成

データ駆動型加工を以下の 3 つの項目で構成した。

1) パラメータ化

加工条件を入力、加工結果を出力とし、それぞれを多変数ベクトル $p = (p_1, p_2, \dots, p_n)$ 、 $q = (q_1, q_2, \dots, q_m)$ で表現する。

2) モデル化

入出力関係を多変数ベクトル関数 $f(p) = q$ で表現する。

本研究では、入力、隠れ層、出力層の 3 層からなるニューラルネットワークモデルで両者の関係をモデル化した。

3) 最適化

目標寸法を q_d とし、 $q_d = f(p)$ を満たす p を、最急降下法に基づく反復計算により求める。具体的には、関数 f に p を与えたさいの出力 q と目標値 q_d の差 e を求め、 e を小さくするように、与える入力値を p から $p + \Delta p$ に更新する。このとき、微小修正量 Δp は差 e とヤコビ行列 J を用いて式 (1) で計算される。

$$\Delta p = -bJ^T e \quad (1)$$

b は係数である。ヤコビ行列は式 (2) で計算される。

$$J(p) = \frac{\partial q}{\partial p} = \frac{\partial f(p)}{\partial p} \quad (2)$$

e が十分に小さいときの p を、 q_d を得る最適な入力値とみなす。

4. 教師データの取得

被加工材には直径 150 mm、板厚 1.5 mm の純アルミニウム A 1050 P-O、ローラーには直径 70 mm、円半径 8 mm の合金工具鋼 SKD 11、金型には直径 85 mm の機械構造用炭素鋼 S 45 C 焼き入れ材を用いた。ローラーは金型の軸方向に対し 45° の方向に設けた。

図 2 a) に示すように、ローラーの軌道を以下のパラメータを用いて表現した。マンドレルの軸方向を x 、半径方向を y とし、ブランク材表面の x 方向位置 x_0 、マンドレル側面の y 方向位置 y_0 を原点 $(0, 0)$ とする。ローラーは x 方向に x_{start} までマンドレルに沿うように直線的に動いたのち、曲線パス上を動く。その後、材料から離れて曲線パスの始点 x_{start} まで戻る。次のパスはここから Δx だけ直線的に動き、同様に曲線パスに移行する。各曲線パスは円弧の一部を x 、 y 方向に伸縮した凹型形状とした。曲線パスの終点は、 (x_{start}, y_0) を中心とし、 (x_{start}, y_{end}) と (x_{end}, y_0) を通る 1/4 楕円上に存在する。曲線パスの始点と終点を結ぶ傾斜角は、1 パス目では α とし、2 パス目以降は一定角ずつ増加し、最終の n パス目で $\pi/2$ となるようにした。マンドレルの回転速度を




図 2 スピニング加工のパラメータ化。a) ローラーパスと b) カップ高さ方向の板厚分布




図3 教師データと最適加工条件下で得た成形品の板厚分布の比較

180 rpm, ローラーの送り速度を 1.31 pfeed mm/rev とした。

本研究では入力パラメータを $p = (n, x_{start}, x_{end}, \Delta x, y_{end}, a, p_{feed})$ とした。36 通りの入力パラメータの組み合わせで成形した。加工後、図 2 b) に該当するように、成形品の高さ h をハイトゲージで測定し、高さの 25%, 50%, 75% の位置での板厚 $t_{25\%}$, $t_{50\%}$, $t_{75\%}$ をマイクロメータを用いて測定した。また、 x_{end} と h の差をパス余り長さ r_p として式 (3) より算出した。

$$r_p = x_{end} - (h + R_{round}) \quad (3)$$

R_{round} はローラー円み半径である。出力パラメータを $q = (h, t_{25\%}, t_{50\%}, t_{75\%}, r_p)$ とした。

教師データの 36 条件のうち、1 条件下でのみ割れが発生したが、その他はカップ状に成形できた。図 3 に教師データとして得た成形品の板厚分布を示す。図中の直線は板厚一定を示す。プロットの多くは直線から離れ、成形品の多くは板厚が高さ方向に一定ではなかった。

5. モデル化

教師データ取得後、入力パラメータ p と出力パラメータ q の関係を 3 層のニューラルネットワークモデルで表現した。隠れ層は 10 ノードとし、活性化関数にはシグモイド関数を採用した。




図4 高さ 50% の位置における板厚の実測値とニューラルネットワークモデルによる予測値の比較

図 4 に $t_{50\%}$ の実測値と構築したニューラルネットワークモデルで計算した予測値の比較を示す。RMSE (二乗平均平方根誤差) は 0.011 となり、高精度に板厚を予測できた。

6. 最適化

構築したモデルを用い、高さ方向の板厚が一定となるような入力パラメータの値を、最急降下法を用いて導出した。実際に最適値として得られた入力パラメータの値でスピニング加工をおこなった。

目標の高さが極端に高く、板厚が薄くなる条件では割れが発生したが、カップ状に加工できた成形品では、高さ方向に板厚が一定となるように成形できた。図 3 に示す通り、その板厚分布は図中の直線に非常に近い位置にプロットされている。線から離れたプロットは、フランジが成形された成形品に該当する。図 5 に教師データと最適条件下で成形したカップの断面を示す。条件の最適化により、明らかな寸法精度の向上が確認でき、精度は 0.1 mm 以内であった。加工の操作に慣れた作業者がローラーパスを設計しても、直径 260 mm, 板厚 2.0 mm の軟鋼のスピニング加工において、高さ方向の板厚分布が 0.5 mm ほど変動するとの報告例がある⁵⁾。一方、本方法では経験の度合いに寄らず、容易に高い精度を達成できる。




図5 教師データと最適加工条件下で得た成形品の断面

7. まとめ

スピニング加工のローラーパスと板厚の関係を、30 程度の少数の教師データからなる AI モデルで構築し、目標の板厚を得る最適ローラーパスを導出するデータ駆動型スピニング加工を開発した。0.1 mm 以内の精度での板厚制御を容易に実現できた。本方法はスピニング加工以外の他加工法にも適用可能で、様々な加工の条件出しの工程の時間短縮と高寸法精度化に大きく貢献できる。

参考文献

- 1) L. M. Russo et al, J. Mater. Process. Technol, 294(2021), 117131.
- 2) S. Gondo, H. Arai, J. Intell. Manuf, 33(2022), 617-635.
- 3) S. Gondo, H. Arai, CIRP Annals, 71-1(2022), 229-232.
- 4) 権藤ら, ぶらすとす, 6-67(2023), 402-406.
- 5) 葉山, 精密機械, 44-4(1978), 472-475.

2023 年度年次大会報告

第 101 期第一技術委員会 (年次大会担当)
委員長 坂口 雅人 (岐阜大学)

去る 2023 年 9 月 3 日 (日) ~6 日 (水) に 4 日間の日程で 2023 年度年次大会が東京立大学南大沢キャンパスを

会場に開催されました。今回の発表件数は 813 件があり、このうち 357 件がポスター発表となりました。また、1599

表 1 過去 5 年間の年次大会の発表件数と有料参加登録者
※オンライン開催

開催年度 (開催地)	発表件数 [件]	有料参加登録者 [人]
2019 (秋田大)	1080	1804
2020 (名古屋大)※	988	1835
2021 (千葉大)※	878	1654
2022 (富山大)	860	1654
2023 (都立大)	813	1599

名の方 (有料参加登録者) にご参加いただきました。表 1 より、過去 5 年分の発表件数を比較すると縮小傾向が継続している状況です。

2023 年度大会では機械材料・材料加工部門の関係する単独オーガナイズドセッションと部門横断的・部門融合的なオーガナイズドセッションに加え、学会のキャッチフレーズ「機械工学の英知を結集しゼロエミッション社会を拓く」に関連した、基調講演、先端技術フォーラムを開催させていただきました。本会が盛況に終えることができましたこと、ご参加・ご協力いただきました皆様に感謝を申し上げます。

末筆となりますが、6 月に委員長を急遽交代することとなったにもかかわらず、活動を支えていただきました委員の皆様にも重ねてお礼申し上げます。

オーガナイズドセッション

[S 041] 伝統産業工学

[S 042] 異種材料の界面強度評価と接合技術

[J 041] 超音波計測・解析法の新展開



会場となった東京都立大学南大沢キャンパス

[J 042] セラミックスおよびセラミックス系複合材料

[J 025] バイオマテリアルおよび細胞/組織のプロセス・力学・強度

[J 113] トライボロジーの基礎・応用と表面設計

[J 121] 1 DCAE・MBD と物理モデリング

[J 132] 加工技術の最前線

[J 133] マイクロナノ理工学：nm から mm までの表面制御とその応用

[J 181] 交通・物流機械の自動運転

[J 224] マイクロ・ナノ機械デバイスとその信頼性

先端技術フォーラム

「複合材料研究の最新動向と今後の展望」(講演 5 件)

「M&P 最前線」(講演 5 件)

基調講演

「高分子基複合材料の成形加工」

2024 年度年次大会のご案内

第 1 技術委員会 (年次大会担当)

高橋 学 (愛媛大学)

坂口 雅人 (岐阜大学)



愛媛大学 城北キャンパス

2024 年 9 月 8 日 (日) ~ 11 日 (水) までの 4 日間 [ただし、8 日 (日) は市民開放行事を予定] にわたり、愛媛大学城北キャンパス (愛媛県松山市文京町 3 番) を会場として、日本機械学会 2024 年度年次大会が開催される予定です。2024 年度年次大会では「機械工学で実現する日本産業変革」

をキャッチフレーズとし、「AI を活用したデジタル変革」、「環境にやさしいエネルギー変革」、「未来を担う技術人材の育成」をテーマに掲げ、講演および各種企画を実施する予定です。2023 年度大会では、新型コロナウイルス感染症の感染症法上の位置付けが 5 類に移行し、従来通りの対面開催が実施され、盛会に終えることができました。2024 年度は愛媛・松山の地にて講演会と懇親会および部門同好会の開催に向け、準備を進めているところです。

本部門では単独、あるいは、他部門と協力しながら幅広い多くのテーマのオーガナイズドセッション企画をすでにご提案いただいておりますので以下にご紹介させていただきます。

【OS (本部門単独企画)】

- ・ 伝統産業工学
- ・ 溶融加工・半凝固加工
- ・ 異種材料の界面強度評価と接合技術
- ・ セラミックスおよびセラミックス系複合材料

【JS (合同企画)】

- ・ 超音波計測・解析法の新展開 (幹事：本部門)
- ・ バイオマテリアルおよび細胞/組織のプロセス・力学・強度
- ・ マイクロ・ナノ機械デバイスとその信頼性

- ・ トライボロジーの基礎・応用と表面設計
 - ・ マイクロナノ理工学：nm から mm までの表面制御とその応用
 - ・ 交通・物流機械の自動運転
 - ・ 1 DCAE・MBD と物理モデリング
- (順不同)

また、上記オーガナイズドセッションの他にも、基調講演、先端技術フォーラム、ワークショップ、市民フォーラム他、市民向け・子供向け行事（9月8日（日）開催）等の各種企画を募集しております。（お申込み、お問い合わせについては文末をご参照いただきますよう、お願いいたします。）

末筆になりますが、2024 年度年次大会の会場となる愛媛大学城北キャンパスは、コンパクトシティとして成熟した町の一つである松山市にあり、さらに『現存十二天守』の一つで

ある松山城の北側に位置します。一方、東側には有名な道後温泉、南側には城下町の商業地域が広がり、路面電車がこれらを繋いでいます。俳人正岡子規や高浜虚子、夏目漱石の小説『坊っちゃん』や司馬遼太郎の小説『坂の上の雲』など、ことばを大切にしまちづくりで“文学のまち”としても知られています。ここが癒やされる松山にぜひ足をお運び頂ければ幸いです。実行委員はじめ愛媛大学スタッフ一同、多数の方のご参加をお待ちしております。

各種企画のお申込み・お問い合わせ先：

第1 技術委員会

2024 年度担当

愛媛大学 高橋学：mtaka@ehime-uac.jp

第 30 回機械材料・材料加工技術講演会（M&P 2023）開催報告

実行委員長 松崎 亮介（東京理科大学）

2023 年 9 月 27 日（水）から 29 日（金）までの 3 日間にわたり、機械材料・材料加工部門主催の第 30 回機械材料・材料加工部門技術講演会（M&P 2023）が筑波大学・筑波キャンパスで開催されました。2019 年以來の久しぶりの対面での開催となり、コロナ禍以前の活発な活動に近づけるべく、技術講演会に加えて、新技術開発フォーラムや若手ポスターシンポジウムも開催しました。

今回は初の取り組みとして、部門間の交流を目的に材料力学部門（M&M）とコロケーション（同会期・同会場）で開催されました。6 件の合同 OS、2 件の合同フォーラム、2 件の合同特別講演、そして合同懇親会など、コロケーション開催を活かした企画が行われました。M&P 側では、117 件の講演と 11 件のポスター発表があり、178 名の方々が参加されました。M&M と合わせると、合計で 510 件の講演が行われ、700 名以上の方々にご参加いただきました。普段の M&P 講演会では聴けないような内容の講演や、普段会うことができない方々との交流ができたことを、実行委員として非常に嬉しく思います。ご尽力いただきました M&M、M&P の関係者の皆様に感謝を申し上げますとともに、参加された皆様に深く感謝申し上げます。

次回の M&P 2024 は富山で開催されます。引き続きのご参加をお待ちしております。



特別講演の様子



M&M と M&P 合同での懇親会の様子

編集後記

機械材料・材料加工部門ニュースレター No.66 をお届けいたします。発行が遅れたこと改めてお詫び申し上げます。本号を発行するにあたり、巻頭言の竹内先生をはじめ、ご執筆いただいた方々、発行にご尽力をいただいた皆様に深く御礼を申し上げます。皆様に様々な情報を発信して、より魅力のある部門にしていきたいと考えておりますので、ご意見・ご要望等がございましたら、遠慮なく広報委員会・櫻井(jun-peisakurai@maenagoya-uac.jp) までご連絡ください。

発行

発行日 2023 年 11 月 18 日

〒 162-0814 東京都新宿区新小川町 4 番 1 号

KDX 飯田橋スクエア 2 階

一般社団法人 日本機械学会 機械材料・材料加工部門

第 101 期部門長 佐々木 元

広報委員会委員長 櫻井 淳平

Tel.03-4335-7616 Fax.03-4335-7619