

## 新技術

# 深層学習による3次元分析画像の超解像化

材料の微細構造の情報を得たい場合、3次元SEM像は有力な手法です。3次元SEM像は、FIBによる削り出しと断面SEM撮影を繰り返して取得します(図1)。ここで、SEMとFIB加工の解像度の違いが問題となります。例えば一辺10 $\mu\text{m}$ の領域を観察する場合、SEM像は一般に10nm以下の解像度を持ちますが、FIB加工を同様のピッチで加工と撮像を繰り返すとたいへん多くのマシンタイムを要してしまうため、現実には100スライス(100nmピッチ)程度とすることが多く、解像度の差が生じてしまいます。

SEM撮影枚数を増やさずに深さ方向の解像度を向上する新たな方法として、深層学習を活用した超解像技術<sup>\*注)</sup>を開発しました(図2)。深層学習モデルの構築に当たっては、学習教材として、断面SEM像とそれを画像圧縮して解像度を下げた断面SEM像のペアを用意します。これらを深層学習モデルに入力し、解像度を下げたSEM像から元のSEM像を修復する深層学習モデルを作成します。このモデルを3次元における深さ方向に適応し高解像情報を生成することで、高解像3次元像を取得することができます。

深層学習モデルにはResidual Attention Module<sup>1)</sup>と呼ばれるモジュールを採用しました。このモジュールは画像の中の領域同士の関係性を学習することに長けており、これにより画像全体の特徴を効率的に抽出することができます。このモジュールを組み込んだ画像生成AIを作成いたしました。

リチウムイオン二次電池の正極材を対象として、従来手法と深層学習手法で得られた3次元SEM像を図3に示します。図3の従来手法は100nmピッチで撮影した結果です。赤色の部分は活物質と呼ばれ、電気を起こす反応に関与する物質です。活物質の表面積について表1でその結果を比較しました。これによると約3割の違いが生じており、その機能推定において現実に近いことができるものと考えます。


この手法の精度評価として、実際に10nmピッチでFIB加工して撮影した像との誤差を算出しました。表2に一般的な画像処理手法と比較した誤差計算結果を示します。本稿技術では実際の高解像度画像との誤差が小さく、より高精度であることがわかります。

一方でこの深層学習モデルの学習では2次元の断面SEM像を用いているため、学習のために高解像3次元像を用意する必要がありません。実用面ではこの点も重要なメリットと考えます。

\*注) 一般的に超解像技術は複数画像情報や光学的な機能付与等により低解像度画像の高周波成分を復元する技術として知られています。ここでは深層学習技術で高周波成分を予測・生成することに対して、同じ表現をもちいています。


1) J-H. Kim et al., "RAM: Residual Attention Module for Single Image Super-Resolution", arXiv:1811.12043

■図1 FIB加工とSEM解析の繰り返しによる連続断面SEM画像の取得




(SEM解像度は約10nmと高いが、深さ方向は100nm程度の削り出しのため、赤枠部の解像度は低いという課題がある)

■図2 超解像のための深層学習モデルの構築



(断面SEM画像の圧縮ありとなしのペアを教材として深層学習モデルを作り、低解像度の入力画像を高精度化する)

■図3 従来手法と深層学習手法の3次元SEM像の比較



■表1 活物質表面積比較

$\mu\text{m}^2$	従来手法	深層学習手法
活物質表面積	307.3	391.3

■表2 復元精度比較:  
画素値(グレースケールで0~255の値を持つ)のMSE

	深層学習手法	Lanczos法
MSE	0.66	1.41



## 新技術 宇宙用電気推進機へのCeIr<sub>2</sub>の応用

### ① 概要

2020年9月より、当社および国立研究開発法人 宇宙航空研究開発機構（以下、JAXA）は共同研究を開始しました。宇宙用途の電気推進機の性能向上を実現するために、当社が開発した電子放出源用CeIr<sub>2</sub>材料を電気推進の一種のホールスラストへ適用することを検討しました。

ホールスラストの作動試験の結果、従来電子放出源と比較してコスト低減や寿命という面で優位性が期待できることが分かりました。当社での評価やJAXAとの共同研究により得られたCeIr<sub>2</sub>の特長を以下に示します。

### ② CeIr<sub>2</sub>材料の特長と期待効果

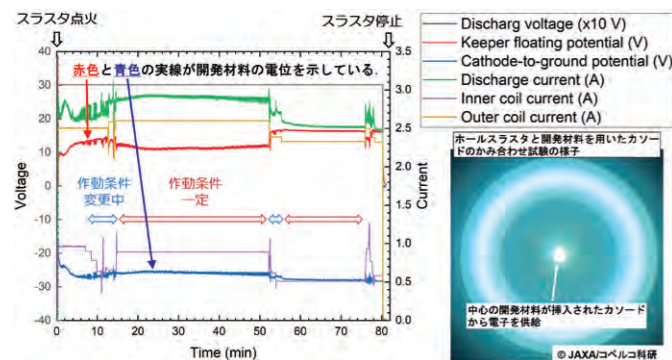
#### 【特長】

- ・主立った電子放出源LaB<sub>6</sub>と比較して低仕事関数を示すため（図1）、同等以上の電子放出効率が期待できます。
  - ・同一条件のもとでの電子放出電流と温度について比較測定した結果、LaB<sub>6</sub>に比べて、低温域での動作を確認しています（図2）。\*
  - ・数時間の連続作動下で安定的な熱電子放出を維持することができます（図3）。\*
  - ・試験前と試験後の電子放出面を確認した結果、強い蒸発なども確認されませんでした（図4）。\*
- ※ JAXAとの共同研究成果

#### 【期待効果】

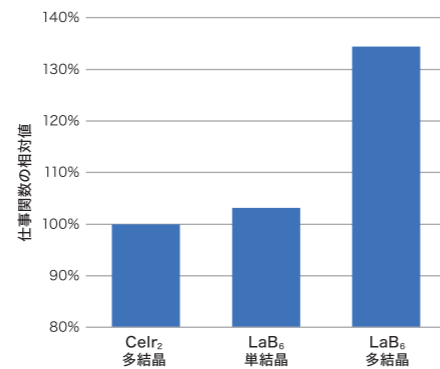
- ・ホールスラスト以外でも熱電子放出源として以下への適用が期待できます。
- ・X線CT装置：高解像度化や検査時間の短縮
- ・金属3Dプリンター：高出力化による能力向上
- ・電子ビーム描画マスク装置：作動温度低下による長寿命化

■図3 ホールスラストにCeIr<sub>2</sub>を組み込んだ際の連続作動下での安定性

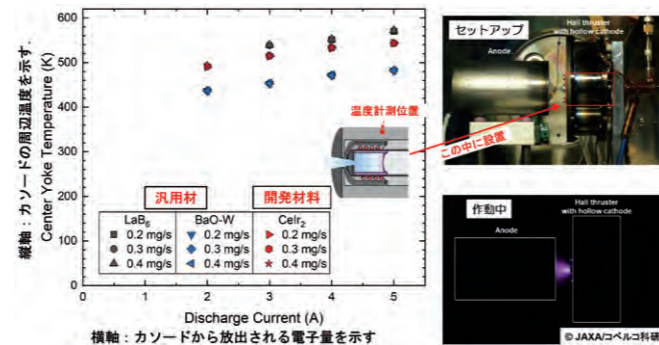


黒線：スラストの稼働状態（スラストがプラズマをつけている状態）を示す。  
赤、青線：カソードからの電子供給の状態を示す。  
紫、黄線：スラストの放電を安定させるために制御する電流  
緑線：スラストに入力されている電力を示す電流

■図1 紫外光電子分光法による仕事関数測定結果の相対値




■図2 ホールスラストにおけるイオン中和模擬した実験構成における各種熱電子放出源材料の放出電流（横軸）と周辺温度（縦軸）の相関図



注) BaO-Wの方が、本データで最も低温で動作しているが、推進剤内の不純物による劣化など取り扱い性に課題有り

■図4 図3の試験前後の電子放出面状態（内周部）



## 新技術 最高200℃の“高温”パワーサイクル試験サービス

### ① 概要

当社のパワーサイクル (P/C) 試験設備 (写真1) は、多様な環境条件、接続方法、電流シーケンスなどを自在にカスタマイズ対応できますが、冷媒温度は水系冷媒の制約から80℃以下に限られました。このたび水系に加えて、オイル系の高温冷媒の採用により、最高200℃までの試験が可能になりました。

■写真1 パワーサイクル (P/C) 試験機 (本体)



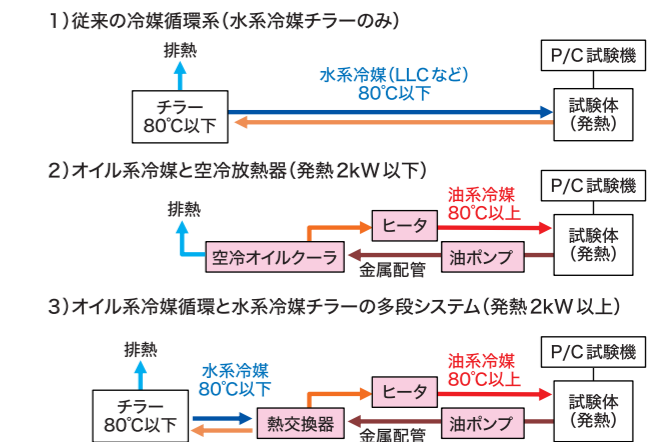
### ② 詳細

インバータへの実用化が進むSiCやGaNなどの新しいパワー半導体は、一般のSiとは異なり素子温度 (Tj) が200℃以上での常用が想定されるため、それに対応した高温試験が必要になってきました。そこで、高温冷媒としてエンジンやモータ冷却に使われるオイルを採用し、耐熱性も高めた循環系を構築しました（図1）。これにより、半導体素子の温度特性だけでなく、接合材や伝熱基材などの実装部材を含めた熱応力や熱疲労の高温試験が可能になりました。

### ③ 主な仕様

- ・ DC電源：20V・800A（最大2000A）
- ・ 制御パラメータ：主電流、ゲートOn/Off、Tj<sub>max</sub>・min、ΔTj
- ・ 対応冷媒：各種冷却用オイル、フッ素系冷媒
- ・ 冷媒制御温度：-10℃～200℃
- ・ 冷却（抜熱）能力：6.3kW ヒータ（加熱）能力：6kW
- ・ ポンプ能力：最大55L/min

■図1 高温冷媒循環系



## 新技術 機械学習を活用した破壊靱性値予測ツールの開発

### ① 概要


大きな温度変化の環境下にあるフェライト鋼構造物の健全性評価では、延性ぜい性遷移温度 (Ductile to Brittle Transition Temperature, DBTT) 領域における材料の破壊靱性値K<sub>Jc</sub>が必要となります。K<sub>Jc</sub>は、i) 温度依存性、ii) 寸法依存性、iii) 同一試験条件における大きなバラツキ、といった課題があることから、少ない試験結果からK<sub>Jc</sub>を予測することに関心が集められてきました。

今回、引張特性（室温での降伏応力σ<sub>YS</sub>と引張強さσ<sub>BRT</sub>およびK<sub>Jc</sub>予測温度でのσ<sub>YS</sub>）に基づいて、データ駆動型の機械学習を活用することにより、K<sub>Jc</sub>を簡便に予測するツールを開発したので紹介します。

### ② 学習データと機械学習モデル

機械学習には、DBTT領域のフェライト鋼であるRPV鋼5種とRPV鋼以外の7種の計531K<sub>Jc</sub>データを使用しました<sup>1)</sup>。図1に学習データのK<sub>Jc</sub>とσ<sub>YSRT</sub>/σ<sub>YS</sub>の関係を示します。機械学習モデルは、複雑な非線形関係を表現できる人工ニューラルネットワーク (Artificial Neural Network, ANN) により構築しました。入力値の説明変数 (特徴量) を引張特性 (σ<sub>YS</sub>、σ<sub>YSRT</sub>、σ<sub>BRT</sub>) と試験片寸法W、出力値の目的変数をK<sub>Jc</sub>としました。

■図1 学習データ：K<sub>Jc</sub>とσ<sub>YSRT</sub>/σ<sub>YS</sub>の関係




参考文献  
1) K. Ishihara et al.: Metals (2021), 11, 1740. <https://doi.org/10.3390/met11111740>

### ③ 機械学習を活用した破壊靱性値予測ツールの適用事例

図2にRPV鋼、図3にSCM440を対象に横軸を温度T、縦軸をK<sub>Jc</sub>として、ASTM E1921のマスターカーブ (MC) のK<sub>Jc</sub>と開発ツールにより予測したK<sub>Jc</sub>を比較した結果を示します。図中の試験結果のプロットは平均値、上下線は最大最小値です。第2図では、両者のK<sub>Jc</sub>は各温度で試験結果の平均値に近い値を示しています。一方、第3図では、温度が高くなるにつれてMCのK<sub>Jc</sub>は試験結果との差異が大きくなっていますが、開発ツールにより予測したK<sub>Jc</sub>は試験結果の平均値に近い値を予測できました。本ツールは、降伏応力328～775MPa、引張強さ519～832MPa、試験片タイプCT、SEB、試験片幅0.4T～4Tのフェライト鋼材が現在の適用範囲です。

■図2 ASTM E1921 MCのK<sub>Jc</sub>と開発ツールで予測したK<sub>Jc</sub>の比較：RPV鋼  
■図3 ASTM E1921 MCのK<sub>Jc</sub>と開発ツールで予測したK<sub>Jc</sub>の比較：SCM440



### ④ おわりに

今回開発したK<sub>Jc</sub>予測ツールを活用することによって、時間とコストを要する破壊靱性試験を行わなくとも、引張特性と試験片寸法から簡便なK<sub>Jc</sub>予測が可能となります。また、試験片を採取困難な実機においても、実機材確保のハードルが下がり、材料のぜい化特性診断の利便性の向上に寄与することが期待されます。