

## 機械学習による加工状態モニタリングに関する研究（第2報）

生産技術部  
中野太郎  
九州工業大学大学院  
情報工学研究院  
知的システム工学研究系  
是澤宏之 檜原弘之

機械加工において、突発的な加工不良による損失を未然に防ぐために、刃先の損傷や深刻な摩耗といった、工具折損を引き起こす可能性のある異常状態を早期に検知する技術が必要とされている。本研究では、小径穴加工中に放出される Acoustic Emission (AE) 信号に着目し、加工状態をインプロセス診断する技術の開発に取り組む。穴加工中に計測した AE 信号を、連続ウェーブレット変換で前処理し、事前学習済みの深層モデルを用いて特徴量を抽出した。得られた深層特徴に多変量正規分布を当てはめることで正規性を確立し、異常スコアとして定量的に指標化した。さらに、提案手法では、複数の深層モデル層から得られた異常マップを生成することにより、異常状態の違いをレイヤー毎に細分化して可視化することができる。具体的には、小径穴加工中の AE 信号計測を自動化する計測システムの開発と測定・評価実験による検討を行い、本測定手法の有効性を実証した。

### 1. はじめに

製造・加工分野においては、大量生産あるいは多品種少量生産といった従来の製造モデルから、変種変量生産を高い生産性で実現するマス・カスタマイゼーションへの転換を迫られており、工作機械のIoT化によるスマートファクトリーへの取り組みが加速している。また、少子高齢化による就業人口の減少や、熟練技術者の技能伝承問題に伴う生産技術力の低下を解決するためにも、自律的に最適加工を行う知能化された生産システムの開発が急務となっている。

刻々と変化する加工状態を適宜判断し、自律的に最適加工を行う知能化された生産システムを開発するためには、工作機械や加工プロセスに係る情報を高精度に観測するセンシング技術と、加工状態を正確に把握・識別する解析技術の高度化が求められる。本研究では、小径穴加工における工具刃先の損傷や深刻な工具摩耗といった、工具折損を引き起こす可能性のある異常状態を識別することを目的に、Acoustic Emission (AE) センサを用いた加工状態モニタリング技術の開発に取り組む。ここでは、AE 信号から特徴量を抽出するために連続ウェーブレット変換 (Continuous wavelet transform ; CWT) を適用し、得られた2次元特徴量から加工状態を推定する手法

として、画像レベルの異常検出と定量的指標化を実現する深層特徴量分布モデリング (Deep feature Distribution Modeling ; DDM)<sup>1)</sup>を提案する。さらに、切削加工中に計測した AE 信号データを用いて提案手法の識別性能を評価し、加工状態診断における有効性を検証した。

### 2. 切削加工状態をモニタリングする実験対象

本研究では、切削加工状態を示す時系列信号の取得に AE センサを使用する。ペックドリリングによる穴加工実験を、高精度高速小径微細加工機




図1 実験装置の概略図

表 1 小径穴加工条件

Parameter		Value
Cutting tool	Diameter	1 mm
	Tool material	High speed steel(HSS)
Drilling parameters	Strategy	Peck drilling
	One-step feed-length	1 mm
	Depth of hole	8 mm
	Spindle speed	4000 rpm
	Feed rate	0.0075 mm/rev
	Cutting fluid	Water-insoluble
Workpiece	Material	SKD61

(MEGA-360, 礫々産業) を用いて実施した。実験装置の概略を図 1 に、加工条件を表 1 に示す。ワークの側面に取り付けた AE センサ (AE-900M-WB, エヌエフ社製) から加工中の AE 信号データを取得する。センサから出力された AE 信号は、プリアンプ (9913, NF) で 40 dB, メインアンプ (AE9922, NF) で 30 dB 増幅され、高速デジタイザ (PicoScope 5443D MSO, Pico Technology) を介して計測制御のコンピュータに保存する。

### 3. 時系列信号解析

#### 3.1 信号解析方法

切削加工中に発生する AE 弾性波は超音波領域の高周波であるため、AE センサからの信号を数 MHz の高いサンプリング周波数で取得する必要がある。本研究では、センサから得られる膨大な信号データから周波数特性を効率的に抽出するために、連続ウェーブレット変換(CWT)を用い、時間一周波に関する情報をスペクトログラムとして抽出した。

#### 3.2 連続ウェーブレット変換

ウェーブレット変換は、もとのデータを簡潔に記述し、原信号の特徴を調べるのに適した形式に変換する解析手法の一種である<sup>2)</sup>。フーリエ変換が三角関数の波の重ね合わせで波形を表現するのに対し、ウェーブレット変換は、任意の時系列データを短い波 (wavelet) の重ね合わせとして表現する。ウェーブレット変換を行うためには、時間的に局在した波形であるウェーブレット関数が必要であり、数学的には、ウェーブレット関数と原信号の畳み込みである。この畳み込みにおいて、ウェーブレット関数に、図 2 に示すような平行移動と伸縮の 2 種類の操作を施す。

今、時間  $t$  に依存する信号 (関数)  $x(t)$  を考え、この信号は時間と共に振幅や周波数が変化すると仮定する。このとき、連続ウェーブレット変換 (CWT) は次のように定義される<sup>3)</sup>。

$$CWT\{x(t); a, b\} = \int x(t)\overline{\Psi_{a,b}(t)}dt$$

ここで、 $\Psi_{a,b}(t)$  はウェーブレット関数であり、 $\overline{\Psi_{a,b}(t)}$  は  $\Psi_{a,b}(t)$  の共役複素数を示す。このウェーブレット関数  $\Psi_{a,b}(t)$  は、以下に示すマザー・ウェーブレット関数  $\Psi(t)$  を、スケールパラメータ  $a$  と位置パラメータ  $b$  を用いて伸縮・平行移動することによって得られる。

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}}\Psi\left(\frac{t-b}{a}\right)$$

マザー・ウェーブレットには幾つかの種類があるが、本研究では、AE 信号の信号解析に Morlet ウェーブレットを用いた。Morlet マザー・ウェーブレットは以下のように定義される。

$$\Psi(t) = \exp(-t^2/2) \exp(j\omega_0 t)$$

ここで、 $\omega_0$  は無次元化周波数であり、アドミッシブル条件を満たすために  $|\omega_0| = 6$  とした<sup>4)</sup>。このとき、Morlet ウェーブレットによる変換におけるスケールパラメータ軸  $a$  と周波数軸  $f$  に以下の関係が成立する。

$$f = \frac{\omega_0 + \sqrt{2 + \omega_0^2}}{4\pi a} \cong \frac{0.968}{a}$$

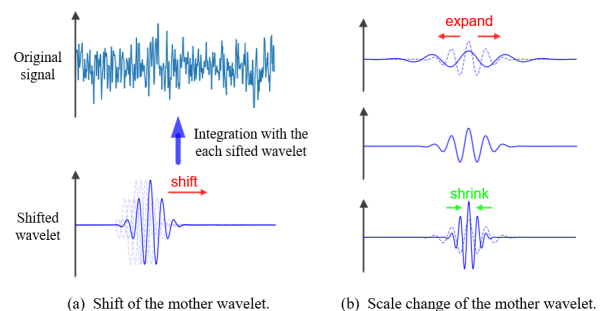


図 2 ウェーブレット変換における 2 種類の処理 (a) 位置変化 (b) スケール変化 (伸縮)

### 3.3 AE 信号の解析

まず、機械振動などの環境騒音の影響を低減するために、取得した AE 信号に 100kHz のハイパスフィルタを適用し、おおよそ工具 1 回転の時間に相当する約 0.016 秒間(32768 サンプル)のデータ毎に固定長で切り出した後、CWT によって 2 次元マトリクスに変換する。周波数軸については、100kHz~1MHz の範囲を 128 分割した周波数解析結果が得られるように CWT スケールを設定した。時間軸については、解析結果を 128 の等間隔に分割し、その平均値を算出する。この処理によって得られるマトリクスは、時間軸(0~0.0163 秒)と周波数軸(100kHz~1MHz)それぞれ 128 次元の 2 次元 1 チャンネル画像となる。

## 4. 異常検知手法の比較

### 4.1 異常状態の定量化

加工中に計測した AE 信号の異常度合いを定量化し、工具状態監視に利用することに焦点を当て、以下の 3 つの異常検知手法について検討した。

- 手法 1 : AE 信号から計算された実効値 (二乗平均平方根 ; RMS) を状態指標として用いる。  
 手法 2 : 画像解析の異常検出において一般的に使用される畳み込みオートエンコーダ (CAE) を用いた指標化。  
 手法 3 : 本研究の提案手法である深層特徴量分布モデリング (DDM) を用いた指標化。


#### 4.1.1 手法 1 : 実効値 (Root Mean Square)

AE 信号の実効値 (RMS) は、工具摩耗を反映する代表的なパラメータであり、切削工具状態のオンライン評価等に使用されている<sup>5)</sup>。ここでは、AE 信号から単純に計算した RMS 値を異常状態の指標として用いる。まず、機械振動などの環境騒音の影響やエイリアシングを低減するために、取得した AE 信号に 100kHz のハイパスフィルタと 1MHz のローパスフィルタを適用する。次に、約 0.016 秒間 (32768 サンプル) のデータ毎に計測信号をクリップし AE 信号の RSM 値を算出する。

#### 4.1.2 手法 2 : 畳み込みオートエンコーダ (CAE)

AE 信号の異常を検出するための状態指標として CAE の再構成誤差を用いる。本検証では、昨年度の研究報告書<sup>6)</sup>で紹介したものと同様のネットワーク構造のモデルを利用した。

CAE に入力データとして渡される 2 次元の時間周



(a) TF image with size 128x128 (b) pseudo-colored TF image

図 3 CWT 処理して得られた TF 画像

(a) グレースケール (b) 疑似カラー化したもの

波数画像 (TF 画像) は、AE 信号に CWT を適用することで生成する。前述の RMS のステップと同様に、AE 信号は 100kHz のハイパスフィルタと 1MHz のローパスフィルタで前処理され、約 0.016 秒間のデータ毎に固定長で切り出した後、CWT によって変換される。

CWT による処理後、得られた値が 0~1 の範囲に収まるよう、以下の式によって正規化 ( $x_{norm}$ ) する。

$$x_{norm} = (x - x_{min}) / (x_{max} - x_{min})$$

ここで、 $x_{min}$  と  $x_{max}$  はデータセット全体の最小値と最大値である。このデータ処理によって得られた通常の切削状態における典型的な TF 画像を図 3 (a) に示す。これらの入力画像のデータセットに対して、最適化アルゴリズムの Adam<sup>7)</sup> を用いて、CAE を 500 エポック学習させる。

#### 4.1.3 手法 3 : 深層特徴量分布モデリング

距離ベースの異常検知手法を、画像特徴量抽出器を用いて拡張した本研究の提案手法を用いる。この手法における正規性は、既存の深層学習モデルから得られた特徴量に、多変量正規分布 (Multivariate Gaussian ; MVG) をフィッティングすることで確立されるため、この提案手法を深層特徴量分布モデリング (Deep feature Distribution Modeling ; DDM)<sup>1)</sup> と呼ぶことにする。

DDM では、TF 画像から深層特徴量ベクトルを得るために、ImageNet データセットで事前に訓練された EfficientNet<sup>8)</sup> を特徴抽出器として用いた。入力に用いる TF 画像は、CAE で用いた入力画像と同じものである。ここでは、図 3 (b) に示すように、まず時間周波数画像に対して疑似カラー処理をおこない、EfficientNet-B4 アーキテクチャの推奨入力サイズに従って 380 × 380 にリサイズする。その後、

EfficientNet-B4 に渡された入力画像は Convolutional Neural Network (CNN) によって処理され、図 4 に”Level” (レベル) として示した各ブロックの中間層から深層特徴量ベクトルが抽出される。この階層化された中間層毎に抽出した深層特徴量は、レイヤー毎に異なる解像度やフィルタ経路に関連する情報を含むため、これらの特徴量を解析することによって、レイヤー間の文脈的解釈を大局的に行うと同時に、画素毎の細かい局所的な分析も行うことができる。本研究の提案手法である DDM は、画像解析の異常検知手法である SPADE<sup>9)</sup>や PaDiM<sup>10)</sup> を応用したものであるが、PaDiM が異なる層からの深層特徴の連結を用いて単一の異常マップを生成するのに対し、DDM は各層からの深層特徴ベクトルを用いて複数の異常マップを生成することができる。

## 4.2 DDM による指標化

### 4.2.1 正規性の学習

DDM による異常状態の定量化および可視化に関する概要を図 5 に示す。学習フェーズにおいて、各レベルから得られる特徴ベクトルの位置  $(i, j)$  における正常データの分布を学習するために、まず、 $N$  個の正常学習データから、レベル  $k$  の位置  $(i, j)$  における深層特徴ベクトルの集合  $Z_{ij}^k = (z_{ij1}^k, z_{ij2}^k, \dots, z_{ijN}^k)$  を取得する。先行研究の結果に基づき<sup>11)</sup>、この集合  $Z_{ij}^k$  は多変量ガウス分布 (MVG)  $\mathcal{N}(\mu_{ij}^k, \Sigma_{ij}^k)$  によって生成されると仮定する。ここで、 $\mu_{ij}^k$  と  $\Sigma_{ij}^k$  はガウスパラメータの推定値であり、平均値ベクトル  $\mu_{ij}^k$  はサンプル  $Z_{ij}^k$  の平均値とし、共分散行列  $\Sigma_{ij}^k$  は次式により推定する。

$$\Sigma_{ij}^k = \frac{1}{N-1} \sum_{n=1}^N (z_{ijn}^k - \mu_{ij}^k)(z_{ijn}^k - \mu_{ij}^k)^T$$

### 4.2.2 異常スコアの計算

評価対象となるテストデータの、各レベル  $k$  の位置  $(i, j)$  における異常状態を定量化するためにマハラノビス距離  $M(z_{ij}^k)$  を適用する。マハラノビス距離はテストデータの深層特徴量  $z_{ij}^k$  と、学習したデータ分布  $\mathcal{N}(\mu_{ij}^k, \Sigma_{ij}^k)$  の中心との距離と解釈でき、 $M(z_{ij}^k)$  は以下の式により計算される。

$$M(z_{ij}^k) = \sqrt{(z_{ij}^k - \mu_{ij}^k)^T \Sigma_{ij}^k{}^{-1} (z_{ij}^k - \mu_{ij}^k)}$$

異常状態を可視化した異常マップを形成するマハ

Pre-trained CNN (EfficientNet-B4)




図 4 CNN モデル(EfficientNet-B4) の構造

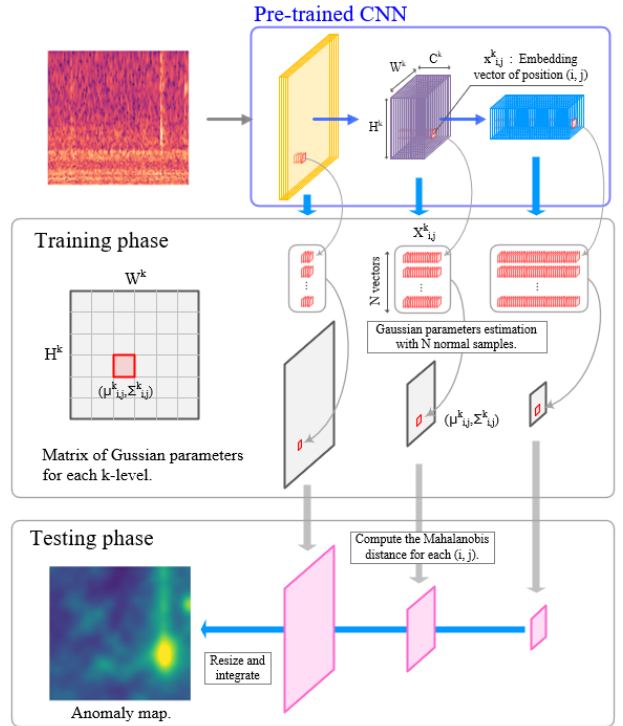


図 5 学習済み CNN モデルの中間層から抽出した深層特徴量とそのデータ分布 (多変量正規分布) に基づき異常状態を定量化可視化する提案手法 (Deep feature Distribution Modeling ; DDM)

ラノビス距離の行列は、レベル  $k$  毎に異なるサイズ  $H^k \times W^k$  で生成される。この異常マップにおいて高い数値を示す位置は異常領域と捉えることができる。また、異常マップはレイヤー毎に生成されるため、細分化された局所的な状態と、広範囲な文脈情報を個別に分析することも可能である。異常スコアの取得のみを目的とするのであれば、学習段階において深層特徴ベクトルに対してアベレージ・プーリングを適用することで、ガウスパラメータの推定に必要な計算回数をレベル  $k$  毎に  $1/(H^k \times W^k)$  と



大幅に削減できる。しかし、この場合は異常マップを生成することができない。

### 4.3 異常検知手法の性能評価

人工的に用意したダミーの異常データを用いて二値分類問題の評価試験を行い、先に述べた3つの異なる手法による分類性能の比較検証を行う。この検証試験においては、未使用の新品のドリルで得られたAE信号データを正常データとし、人工的に損傷を与えたドリルで得られたデータを疑似的な異常データとした。新品のドリル、損傷を与えたドリルを用いて、それぞれ60穴の加工試験を複数回行い検証用のデータを収集した。

表2に得られたデータセットの概要を示す。新しいドリルを用いた実験で得られた最初の60穴までの計測信号のうち、5回分の実験の計測信号を正常データのデータセットとして使用した。正常データの総数は、学習データ  $570 \times 5 = 2850$  テストデータ  $190 \times 5 = 950$  で、疑似損傷ドリルを用いた異常データの総数は、テスト用のみで  $190 \times 9 = 1710$  である。疑似損傷は人為的に与えたものであるため、損傷の程度にばらつきがあり、数穴で折損するドリル(A1~A3)や、60穴開けても折損しないドリル(A4~A9)があった。

異常検知手法の性能を評価するために、5つの正常データセット(N1~N5)のうち4つのグループのみでモデルを学習し、残りの正常データと異常データで分類性能を評価する、グループk分割交差検証(group k-fold cross-validation,  $k = 5$ )を行い、AUC値に基づく分類性の比較検証を行った。

### 4.3 分類性能の評価結果

提案手法であるDDMを用いた異常スコアの算出については、本章の評価においては異常マップを生成する必要がないため、計算負荷を軽減するために、

表2 検証用データセットの概要

Scheme no.	Data type	Tool condition	Tool life	Train data	Test data
N1	normal	sharp	Interrupted at the 60th hole.	570	190
N2	normal	sharp	Interrupted at the 60th hole.	570	190
N3	normal	sharp	Interrupted at the 60th hole.	570	190
N4	normal	sharp	Interrupted at the 60th hole.	570	190
N5	normal	sharp	Interrupted at the 60th hole.	570	190
A1	anomaly	damaged	Failed at the 3rd hole.	-	190
A2	anomaly	damaged	Failed at the 17th hole.	-	190
A3	anomaly	damaged	Failed at the 7th hole.	-	190
A4	anomaly	damaged	Interrupted at the 60th hole.	-	190
A5	anomaly	damaged	Interrupted at the 60th hole.	-	190
A6	anomaly	damaged	Interrupted at the 60th hole.	-	190
A7	anomaly	damaged	Interrupted at the 60th hole.	-	190
A8	anomaly	damaged	Interrupted at the 60th hole.	-	190
A9	anomaly	damaged	Interrupted at the 60th hole.	-	190

平均プーリングを適用して得られるマハラノビス距離を用いた。

表3は、各異常データに対する各手法による性能評価結果を、group k-foldにおけるAUCの平均値で示したものである。AUC値は0~1までの範囲をとり、1に近い程分類性能が優れていることを示している。この結果から、異常状態の傾向には大きく2つのグループがあることがわかる。第一のグループ：AG1はA1からA3までの異常データであり、3穴から17穴の掘削中に工具が折損したものである。RMSによる検出精度は、全体のAUC平均で0.803と比較的高く、これらは単純なAE信号強度で検出できる異常状態であることが示された。第2グループA4からA9までのAG2は、60個の穴を開け、折損しなかった実験のデータである、ここでは、RMSの検出能力はランダム分類器とほぼ同等で、平均AUCは0.4994であり、これらの異常は単純な信号強度では分類できないことを示している。CAEの精度は、AG1では全体の平均AUCが0.8485と高かったが、AG2では0.5151となり、RMSと同様の傾向を示した。DDMの結果については、AG1の検出精度は0.7844で、他の方法よりわずかに低かった。一方、CAEやRMSで分類できなかったAG2に対しては、0.6087と許容できる判別精度<sup>12)</sup>を維持しており、既存の手法に対する提案手法の有効性が示された。

## 5. 提案手法による状態推移の定量化・可視化

### 5.1 小径穴加工の状態推移監視

前章において、工具損傷に対する提案手法(DDM)の識別能力を示したが、実際の穴加工に伴う工具摩耗に関する評価指標としての有効性を検証できていない。本章では、実際の工具摩耗状態とDDMから得られる異常スコアとの相関を調査するために、小径ドリルによる穴あけ加工を行い、工具折損に至る

表3 AUC値による分性能評価結果

Groups	Scheme no.	Anomaly detection method		
		RMS value	The CAE	The DDM
AG1	A1	0.8658	0.8866	0.8573
	A2	0.8047	0.8117	0.7483
	A3	0.8205	0.8472	0.7477
	average (A1-A3)	0.8303	0.8485	0.7844
AG2	A4	0.3795	0.3453	0.6007
	A5	0.5718	0.5628	0.6253
	A6	0.3623	0.3604	0.5310
	A7	0.4331	0.5101	0.5876
	A8	0.6378	0.6486	0.6455
	A9	0.6120	0.6632	0.6621
	average (A4-A9)	0.4994	0.5151	0.6087

までの寿命試験を実施する。

本実験のドリル加工は、1列60穴の加工の繰り返しにより実施した。被削材 (SKD61) の中央列付近から加工を開始し、1800穴 (60穴×30列) を加工した時点で未加工領域が無くなったため被削材を交換した。次に、2つ目の被削材の1列目から加工を継続し、3869穴目 (中央列付近の35列目) で工具が折損した。

DDM による異常スコアの算出に必要な正規性の学習には、第4章の評価試験と同様に、未使用の新品ドリルを用いた5回の実験の、最初の60穴までのデータを用いた。また、工具摩耗の推移に関しては、マシニングセンタのテーブル上に取り付けたデジタルマイクروسコープを用いて、10穴加工ごとに工具先端の状態を撮影し、工具折損に至るまでの、逃げ面摩耗の推移を撮影画像から計測した。

## 5.2 異常スコアと摩耗量の推移

図6は、工具折損までの全期間 (3869穴) にわたる穴加工数の増加に伴う、工具逃げ面摩耗と異常スコアの推移を示している。異常スコアは、提案手法である DDM によって得られたマハラノビス距離であり、各穴の平均値をプロットしたものである。工具摩耗の推移は、Imran, M.ら<sup>13)</sup>や Tan, Q.ら<sup>14)</sup>の報告と同様に3段階のプロセスをたどることがわかる。

図6の摩耗勾配が示すように、Stage-1において、最初の数百穴は、工具の摩耗量が急速に増加し、異常スコアは若干高い値を示した。その後、摩耗曲線の傾きが緩やかになるにつれて、異常スコアは低い値に減少している。これは、工具の初期摩耗による急激な変化と、摩耗の進行の後ではあるが、比較的鋭利な刃先が維持された工具状態を示している可能性がある。

Stage-2の間、摩耗曲線の傾きは Stage-1 よりも小さいが、一定の比率で着実に工具摩耗が進行している。一方、異常スコアは徐々に増加し一時的に高い値を維持したが、Stage-2の後半では減少する傾向にあった。工具摩耗の継続的な増加と異常スコアの増減は、摩耗による切れ味の低下と、それに続く構成刃先の形成が安定した加工状態に繋がった結果と考えられる。

Stage-3は、工具摩耗の段階的な急増と、最終的に致命的な工具破損に至る様子が示されている。異常スコアは概して低かったが、工具摩耗が急速に増加した工具破損直前に大きな反応が観測された。

## 2.2 切りくずの形態観察

Haddag ら<sup>15)</sup>が報告しているように、切りくずの形

成プロセスは、すくい角などの工具形状に大きく依存する。切りくずの形成と形態の変化を説明するために、連続する2つの領域間の距離であるせん断層間隔を利用できると考えられる。そこで、実験中に収集した切りくずのせん断層間隔を、レーザー顕微鏡 (OLYMPUS LEXT OLS4100) を用いて測定した。

図7は、工具摩耗の異なる段階における切りくずのレーザー顕微鏡写真である。また、図8に、加工穴数の増加に伴う切りくずせん断層間隔の変化を示す。工具折損直前までは、平均せん断層間隔に大きな変動は見られず、10μmから15μmの範囲で推移している。しかし、最終段階 (約3800穴) では、その値が約50%も急激に増加した。工具摩耗の進行による切れ刃の鈍化は、見かけのすくい角を増大させ切りくずの形成過程に影響を及ぼす。その結果、図7に示すように切りくず形態が大きく変化し、異常スコアの急上昇として観測されたと考えられる。

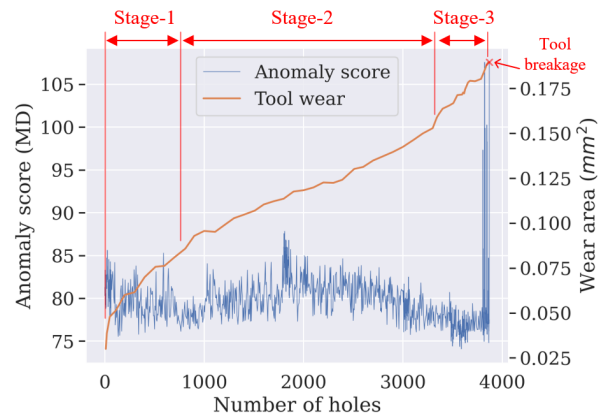


図6 穴加工数の増加に伴う工具摩耗と異常値の推移

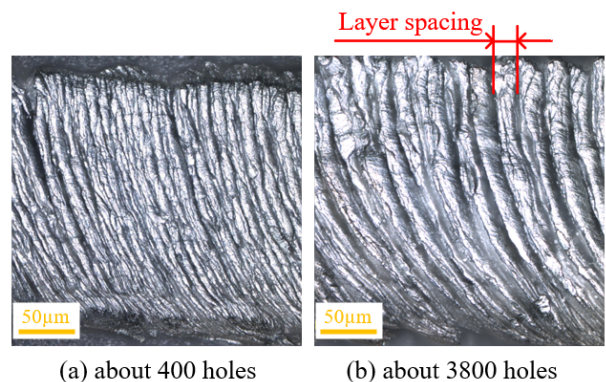


図7 切りくずのレーザー顕微鏡写真  
(a) 400穴加工時 (b) 3800穴加工時 (折損直前)




図 8 穴加工に伴う切りくずせん断層間隔の  
平均値と標準偏差範囲の推移

### 5.2 異常状態の可視化

摩耗 Stage-3 の工具状態を特定することで、小径穴加工のプロセス監視が容易になるため、DDM 異常スコアの推移から得られる情報は有用である。ここでは、摩耗状況の変遷を視覚的に示す工具状態の可視化手法についてさらに調査した。

先に説明したように、提案手法 (DDM) を用いて、深層特徴のデータ分布に基づく指標を時間周波数領域にマッピングすることで、状態を可視化した異常マップを生成することができる。そこで、本試験に

おける異常マップの変化を時系列で確認するために、5つの異なる穴加工数範囲から、それぞれサンプルを無造作に選択し状態の可視化を行う。各範囲の異常マップの特徴を強調するために、ランダムにピックアップした1000枚の異常マップから平均画像を作成した。

深層特徴の各レベルの平均異常マップを図9に示す。Range-2 (780~960穴) と Range-4 (3300~3420穴) は異常スコアが低く、平均異常マップ上で有意な反応は確認されなかった。Range-1 (420~600穴) は摩耗進行の Stage-1 に相当しており、100~300kHz の低周波数帯域に強い反応を示した。Range-3 (2040~2200穴) は Stage-2 に相当し、Level1~3 では主に300kHz、Level3~7 では主に600~700kHz に強い反応が観察された。Range-5 (3800~3869穴) は Stage-3 の破断直前に相当し、特に低周波数帯域 (100kHz) に強い反応が集中している。これらの異常検出の帯域幅の違いは、異常マップを階層毎に細分化して可視化することでより明確化されることが確認された。

### 6. おわりに

工具摩耗とせん断層幅を計測し、異常スコアとの関係を調査した結果、異常スコアに工具の切れ刃の状態に関連すると思われる増減が認められた。さら




図 9 深層特徴量の中層毎に生成した異常マップ (1000 サンプルの平均値画像)。各層毎に異常強度の表示範囲は統一されており、時間軸(0~0.163 秒)、周波数軸(100kHz~1MHz)を持つ。

に、工具折損直前には急激に大きな反応を示し、工具破損の予知に有効である可能性が示唆された。また、異常マップを階層毎に細分化して可視化することで、摩耗状態の遷移がより明確に区別できることを確認した。

提案手法 (DDM) に基づく定量的指標は、学習効率が高く、未知の異常状態に対する対応にも優れるため、工具状態を認識する手法として有用な技術と言える。ただし、工具摩耗や工具刃先の状態遷移に伴う AE 信号特性の変化を捉えるものであるため、切りくずの穴詰まりや異物との接触などの突発的な負荷事象には対応できない可能性がある。実務における適用範囲を検証するためには、異なる被削材や工具径、回転数、送り速度といった、様々な加工条件に焦点を当てた追加調査が必要であろう。また、本検討では、既存の学習済み深層モデルとして EfficientNet を用いた。しかし、特徴量抽出に使用できるモデルは他にも数多く存在する。工具摩耗のモニタリングモデルとして最適な AI 手法を得るためには、将来的に出現する新たなモデルを含めた比較研究が望まれる。

本研究では AE 信号をモニタリングセンサとして採用し、その時系列データから工具状態を推定する手法を提案した。これらの技術は、高価なモニタリングシステムの代わりに、音声情報などの収集が比較的容易なデータをより効果的に活用する手法の基礎となる可能性がある。今後は、様々なセンサ、異なるデータ形式への適用方法について検討し、データ解析における本手法の応用展開を進めていきたい。

本研究を実施するにあたって使用したレーザー顕微鏡は、電源立地地域対策交付金で導入した。

#### 参考文献

- 1) Taro, N., et al., Tool condition monitoring method by anomaly segmentation of time-frequency images using acoustic emission in small hole drilling. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, 2023, 17.3.
- 2) 新誠一, 朝倉書店, 図説ウェーブレット変換ハンドブック, 2005.
- 3) Torrence, C. and G. Compo, A practical guide to wavelet analysis. *Bulletin of the American Meteorological society*, 1998. 79(1): p. 61-78.
- 4) Farge, M., Wavelet transforms and their applications to turbulence. *Annual review of fluid mechanics*, 1992. 24(1): p. 395-458.
- 5) Kosaraju, S., V.G. Anne, and B.B. Popuri, Online tool condition monitoring in turning titanium (grade 5) using acoustic emission: modeling. *The International Journal of Advanced Manufacturing Technology*, 2013. 67: p. 1947-1954.
- 6) 中野太郎, 檜原弘之, 機械学習による加工状態モニタリングに関する研究 (第 1 報), 佐賀県工業技術センター研究報告書, 2023, No.31, p.15-17.
- 7) Kingma, D.P. and J. Ba, Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- 8) Tan, M. and Q. Le. Efficientnet: Rethinking model scaling for convolutional neural networks. in *International conference on machine learning*. 2019. PMLR.
- 9) Cohen, N. and Y. Hoshen, Sub-image anomaly detection with deep pyramid correspondences. *arXiv preprint arXiv:2005.02357*, 2020.
- 10) Defard, T., et al. Padim: a patch distribution modeling framework for anomaly detection and localization. in *International Conference on Pattern Recognition*. 2021. Springer.
- 11) Rippel, O., P. Mertens, and D. Merhof. Modeling the distribution of normal data in pre-trained deep features for anomaly detection. in *2020 25th International Conference on Pattern Recognition (ICPR)*. 2021. IEEE.
- 12) Yang, S. and G. Berdine, The receiver operating characteristic (ROC) curve. *The Southwest Respiratory and Critical Care Chronicles*, 2017. 5(19): p. 34-36.
- 13) Imran, M., P.T. Mativenga, and P.J. Withers, Assessment of machining performance using the wear map approach in micro-drilling. *The International Journal of Advanced Manufacturing Technology*, 2012. 59: p. 119-126.
- 14) Tan, Q., H. Tong, and Y. Li, Drilling force prediction and drill wear monitoring for PCB drilling process based on spindle current signal. *The International Journal of Advanced Manufacturing Technology*, 2023. 126(7-8): p. 3475-3487.
- 15) Haddag, B., et al., Dry machining aeronautical aluminum alloy AA2024-T351: Analysis of cutting forces, chip segmentation and built-up edge formation. *Metals*, 2016. 6(9): p. 197.