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）

生産技術部
中野太郎
九州工業大学
知的システム工学研究系
楢原弘之

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，AE センサを用いて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．時系列データである AE 信号波形に STFT (Short-Time Fourier Transform) を適用し，抽出した時間－周波数特徴を加工状態の推定・診断に利用することを検討した．加工状態を定量化する深層学習モデルとして neural network ベースの自己符号化器 (autoencoder) を採用する．その際，入力データが 2 次元マトリクスとなるため，特徴量の形態に対応する畳み込みオートエンコーダ (convolutional autoencoder: CAE) を設計した．設計した CAE モデルを正常状態の AE 信号データを用いて学習させ，評価時において再構成誤差を算出することで，加工状態の定量的な評価が可能であることを確認した．

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 STFT (Short-Time Fourier Transform) 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深層モデルとして，畳み込みオートエンコーダ(convolutional autoencoder: CAE) の利用を検討した．切削加工中に計測した AE 信号データを用いて CAE 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する．

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 driling
	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

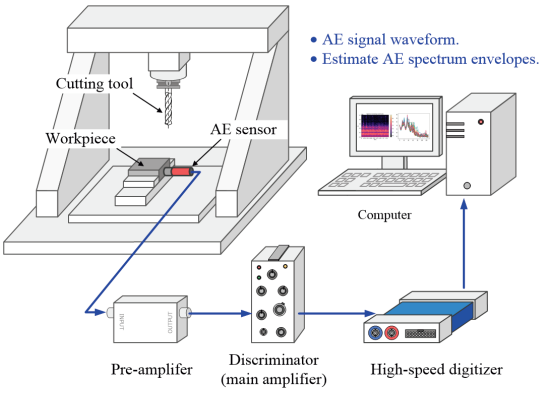

図 1　実験装置の概略図

2. 切削加工実験

2.1 実験方法

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（MEGA-360，碌々産業）を用いて実施した．加工条件を表 1 に，実験装置の概略を図 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．

2.2 AE 信号の解析

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，短時間フーリエ変換(STFT)を用い，時間－周波に関する情報をスペクトログラムとして抽出した．

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 0.020 秒間（40704 点）のデータ毎に計測信号を切り出した．その後，分析窓のフレーム長を 8192 点，フレームシフト量 256 点とし，ハニング窓で前処理した STFT を適用することで，2 元のパワースペクトル（サイズ 128×4097）を抽出した．

CAE の入力データとして利用するためには，適当なサイズの時間－周波数画像にする必要がある．そこで抽出したパワースペクトルを 100kHz～1000kHz の周波数範囲でクリップし，その後リサイズして 128×128 のグレースケースの画像データとして利用する．

2.3 畳み込みオートエンコーダ（CAE）

CAE は，一般にエンコーダとデコーダの 2 つのコンポーネントから構成される [1,2]．エンコーダは，パラメータ$\theta = \{W, b\}$を持つ関数$F_\theta = \sigma(x * W + b) \equiv h$によって，入力$x$を，潜在表現$h$に圧縮する．ここで，$\sigma$は活性化関数，“$*$”は畳み込み演算子を表す．次に，デコーダは，パラメータ$\theta' = \{W', b'\}$を持つ関数$G_{\theta'} = \sigma(h * W' + b')$を用いて元の入力を潜在表現$h$から再構成する．このとき，元の入力$x$に対するオートエンコーダの再構成$\hat{x}$は$\hat{x} = G_{\theta'}\big(F_\theta(x)\big)$となる．再構成誤差は平均二乗誤差（MSE）を用いて算出され，勾配法に基づき学習データ全体の再構成誤差を最小化するようにパラメータ更新が行われる．

本研究で使用した CAE の構造を図 2 に示す．エンコーダコンポーネントは 4 つの隠れ層からなり，畳み込みフィルタのカーネルサイズはそれぞれ 4，4，4，4 である．ボトルネック層は 8192 個の隠れユニットを持つ 1 つの全結合層であり，ここで 1024 次元の潜在空間を得る．デコーダはエンコーダの鏡像となっており，全結合層が潜在空間を拡張し，エンコーダの最終層の形に整形する．その後，4 つの転置畳み込み層が続く構造となっている．

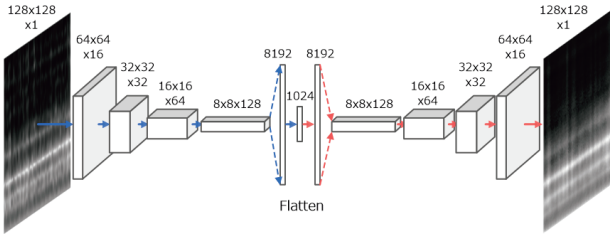

図 2　畳み込みオートエンコーダの構造

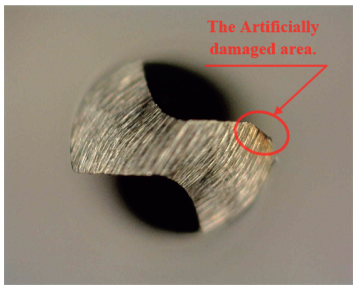

図 3　擬似的に損傷を与えたドリルの例

表 2　検証用データセットの概要

	Data type	Tool condition	Tool life	Data train	Data test
N1	normal	sharp	Interrupted at the 60th hole.	680	300
N2	normal	sharp	Interrupted at the 60th hole.	680	300
N3	normal	sharp	Interrupted at the 60th hole.	680	300
N4	normal	sharp	Interrupted at the 60th hole.	680	300
N5	normal	sharp	Interrupted at the 60th hole.	680	300
A1	anomaly	damaged	Failed after several to dozen holes.	-	300

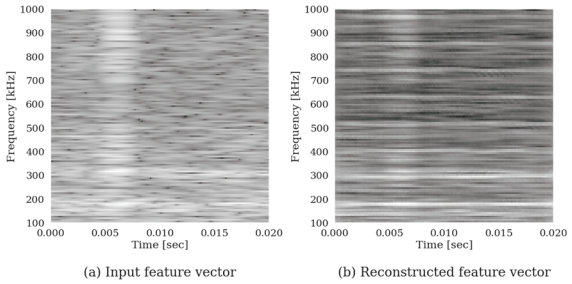

図 4　STFT 特徴量　(a)入力データ　(b)再構成画像

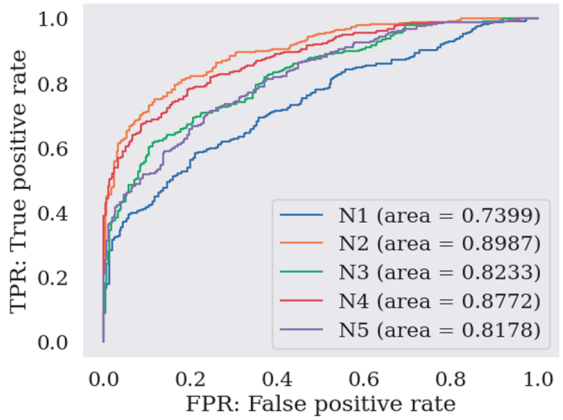

図 5　ROC 曲線と AUC

3. 性能評価

3.1 検証データ

ここでの目的は，工具の激しい摩耗や工具刃先の局所的な損傷など，工具折損につながる可能性のある穴あけ状態の異常を診断することである．本実験では，未使用のドリルを使用して取得したデータを正常，擬似的に損傷を与えたドリルで取得したデータを異常と定義した評価用の検証データセットを用意した．電着工具を用いた超音波研削により，擬似的に損傷を与えたドリルの一例を図 3 に示す．表 2 に実験から得られたデータセットの概要を示す．未使用ドリルを用いた実験で得られた最初の 60 穴までのデータを通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，トレーニングデータ $680 \times 5 = 3400$個，テストデータ$300 \times 5 = 1500$個である．擬似損傷ドリルを用いた異常データの総数は，数～十数穴の加工で折損した複数の実験から得られたテスト用データ300個とする．

3.2 検証方法および結果

異常な加工状態で発生する AE 信号が未知であると仮定すると，標準的な正常状態の AE 信号のみを用いて異常を検出する必要がある．この場合，モデルの学習には正常データ（1 クラス）しか使用できないため，半教師あり学習の異常検出アプローチでこの課題に取り組む．異常検出能力を検証するために，学習用の正常データ（N1～N5）のうち 4 つだけを各 fold における学習データとして利用する Group k-Fold cross-validation (k=5)を実施し，AUC (area under the receiver operating characteristic curve)[3] による性能評価を行った．

提案する CAE モデルは, 入力ベクトルとその再構成の間の MSE を最小化するために，正常なデータのみを用いて学習させた．Adam オプティマイザを使用し，学習手順はバッチサイズ 64 で 500 エポックまで繰り返した．解析のために開発したプログラムはすべて Python で実装した．図 4 に入力特徴ベクトルと学習済み CAE モデルが生成する再構成画像の一例を示す．また，各 fold から得られた ROC 曲線 (receiver operating characteristic curve)とその AUC 値を図 5 に示す. 各 fold の AUC 値は 0.7399～0.8987 とばらつきがあるものの，全体の平均値が 0.831 と比較的高い識別性能を示している．

4. まとめ

時系列データである AE 信号波形から，時間－周波数解析で特徴量を抽出し，CAE を利用して加工状態を定量的に評価する手法について検討した．正常状態の AE 信号データで学習させた CAE モデルを用いて再構成誤差を算出することで，加工状態の定量的な評価が可能であることを確認した．今後は，実加工における工具損傷の評価や検出精度を向上させる方法などについて検討していきたい．

参考文献

1) Guo, Xifeng, et al., 2017, Deep clustering with convolutional autoencoders, International conference on neural information processing, pp. 373-382.
2) Masci, Jonathan, et al., 2011, Stacked convolutional auto-encoders for hierarchical feature extraction, International conference on artificial neural networks, pp.52-59.
3) Bradley, A. P., 1997, The use of the area under the ROC curve in the evaluation of machine learning algorithms, Pattern recognition, 30(7), pp. 1145-1159.