

# AI スティックによる機械学習システムの構築と 工作機械の工具損傷診断システムへの応用\*

二瓶 貴之\*\*、菊池 貴\*\*、堀田 昌宏\*\*

製造加工の自働化・省人化における課題として工具の損傷や折損による加工工程の中止や歩留の低下などがあげられる。解決法として状態監視技術による異常診断が求められているが、近年の AI、IoT 技術の発達により、エッジコンピュータを用いて現場での異常診断が可能となってきた。本研究ではエッジコンピュータ上にデータ収集システムを構築し小径ドリルによる加工実験を行い従来の収集システムと比較した。また、深層学習モデルによって、基本的な診断システムを構築したので報告する。

**キーワード :** IoT、AI、エッジコンピューティング、異常検知

Build data acquisition system for machine tool damage diagnosis

NIHEI Takayuki, KIKUCHI Takashi and HOTTA Masahiro

**Key words:** Internet of Thing, Artificial Intelligence, Edge Computing, Anomaly detection

## 1 緒 言

少子高齢化に伴い、労働人口の減少が問題になっている。特に製造加工業を行っている中小企業の現場では、人手不足の問題が常態化しており、AI や IoT 技術を用いて生産の効率化や自働化・省人化を進めることができることになっている。しかしながら、AI、IoT 技術を導入するためには技術に習熟した人材や能力の高い計算機が必要であり導入にコストがかかるなどの要因により中小企業への普及は進んでいない<sup>1)</sup>。

状態監視システムに関する技術は古くから研究がなされており、アコースティックエミッション法や振動診断による工具摩耗の状態監視技術などが研究されている<sup>2) ~4)</sup>。しかしながらそれらのような状態監視システムにかかる費用は比較的高額となるため、問題が起った際に機械に設置し解析するなど限定的に使用されるにとどまっている。

一方で近年、工作機械の状態監視技術へ深層学習(ディープラーニング)を適用する方法が研究されており、工具の異常検知を精度よく予測できるようになってきている<sup>5) ~7)</sup>。また、最近では IoT 技術の著しい発展により高性能なセンサが手に入り易くなっている。ディープラーニング・アクセラレータとしては GPU や FPGA などが主流であるが、近年は省消費電力で高速に並列演算ができる USB 接続デバイスも開発されており、それらは AI スティックと呼ばれている。2021 年時点においては入手性にも優れているため、現場でディープラーニング学習済

モデルの推論を行うためのハード面での AI、IoT 技術導入の敷居が大きく下がったといえる。

本研究では、小径ドリル加工をターゲットとして、工作機械の工具損傷診断を現場で実施するための深層学習モデルを構築すること、および AI スティックを活用し深層学習モデルをエッジコンピュータで実装することを目標とする。

本報告では、エッジコンピュータを用いたデータ収集(Data AcQuisition、以下 DAQ)システムを構築し工作機械の振動データを取得したこと、取得したデータを用いて、異常診断用の深層学習モデルを構築、学習を実施したこと、および、深層学習モデルによる異常診断のシステム構築をエッジコンピュータ上に構築したことについて報告する。

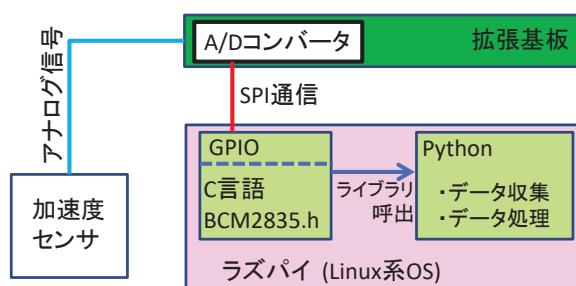


図1 ラズパイ DAQ システムの構成図

\* 令和3・4年度技術シーズ創生・発展研究事業（発展研究）

\*\* 電子情報システム部

表1 加工条件

工作機械	マシニングセンタ (三井精機工業 VS-3A)
ツール	Φ1.0 mm ストレートドリル 材質: Coハイス + TiAlNコート
被削材	アルミダイカスト合金 (ADC12) W75×D55×H20 (mm)
主軸回転数	10,000 rpm (166.7 Hz)
送り速度	18 mm/min (ノンステップ送り)
切削深さ	3 mm
冷却方式	乾式 (Airブローなし)

## 2 実験方法

### 2-1 データ収集システムの構成

エッジコンピュータとしてRaspberry Pi 4B（以下ラズパイ）を用い、ラズパイ上に加工時のデータを取得するシステム（以下、ラズパイ DAQ システム）を構築した。

収集するデータは音響領域の周波数を想定しており、人が触診や聴覚で感じることのできる振動を扱うことから、広帯域な測定周波数(10 Hz ~ 15 kHz)に対応したサンプリング周波数で収集するため、BCM2835 ライブシリなどによりラズパイ DAQ システムを構築した。ラズパイ DAQ システムの主な構成要素を図1に示す。

### 2-2 加工実験および振動データ取得

構築したラズパイ DAQ システムを用いて、マシニングセンタにて金属被削材の小径ドリル加工を行い、加工時の振動データを取得した。加工条件を表1に示す。

1試験片に対し、2 mm の間隔で連続して穴をあけ、それをドリルが折損するまで複数回繰り返した。振動センサは被削材直下のダイにマグネットチャックにて固定し、加工時の鉛直方向の加速度の変化を振動データとして計測した。

また、比較対象としてキスラー製の固定式切削動力計9256A、チャージアンプ 5019 およびテクトロニクス製デジタルオシロスコープ TBS2074 を使用した。切削動力計を VS-3A に被削材の直下に併置し、被削材をボルト固定し加工時の切削抵抗(3軸方向)を収集した。図2にマシニングセンタ、被削材、振動データおよび切削動力計を

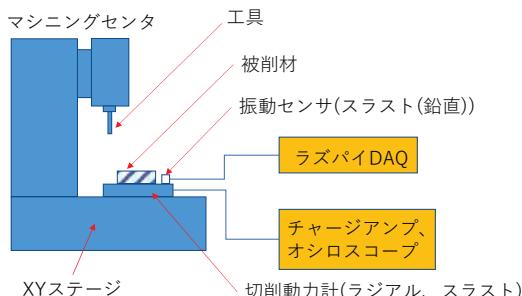


図2 加工時の振動データ取得実験の模式図

設置したときの模式図を示す。図2において奥行方向がX軸(ラジアル)方向、左右方向がY軸(ラジアル)方向、鉛直方向がZ軸(スラスト)方向となる。オシロスコープの収集条件はサンプリング周波数12.5 kS/sで切削抵抗の振動データを記録した。また、計測に使用しているラズパイにてオシロスコープとVirtual Instrument Software Architectureによる通信(VISA通信)を行い、切削抵抗の振動データを、ラズパイ DAQ システムの振動データと同時に取得した。

### 2-3 異常診断のためのオートエンコーダモデル構築および学習条件

産業機械の異常診断では、データ取得時は正常な運転時のデータが多く得られる反面、異常な状態で運転した時のデータは非常に少ないことが多い。したがって本研究では、正常データのみを用いて学習を行う「教師なし学習」ができるオートエンコーダを用いた異常診断を適用した。

オートエンコーダは深層学習のモデルアーキテクチャの一つであり、近年急速に研究が進められている技術である。オートエンコーダは、図3に示すように、それぞれエンコーダ部とデコーダ部の二つの多層ペーセプトロンからなる。エンコーダ部では入力された信号を符号化し、デコーダ部に送り、デコーダ部では符号化されたデータを元の信号に復号化する。

異常診断の分野では、オートエンコーダに入力データとして正常な状態の画像や正常稼働している時の振動データを学習させる。正常な状態のデータをオートエンコーダに入力すれば、元のデータを正しく復元するが、学習に用いていない異常な状態を入力すると正しく復元できない。入力データとオートエンコーダの復元データの差をとることによって、正常か異常を判断できるようになる。従来の異常診断では、ノイズ除去、フーリエ変換などの処理を経て周波数成分解析を行い、パワースペクトル密度に変換し、異常兆候を特定の周波成分のパワースペクトル密度変化を事前に特定する必要がある。しかし、オートエンコーダによる異常診断では周波数成分解析前の振動データをそのまま用いることができるため、

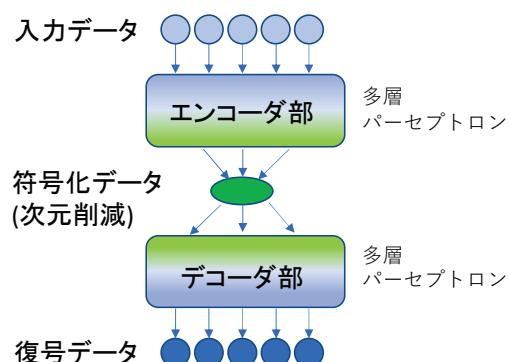


図3 オートエンコーダモデル

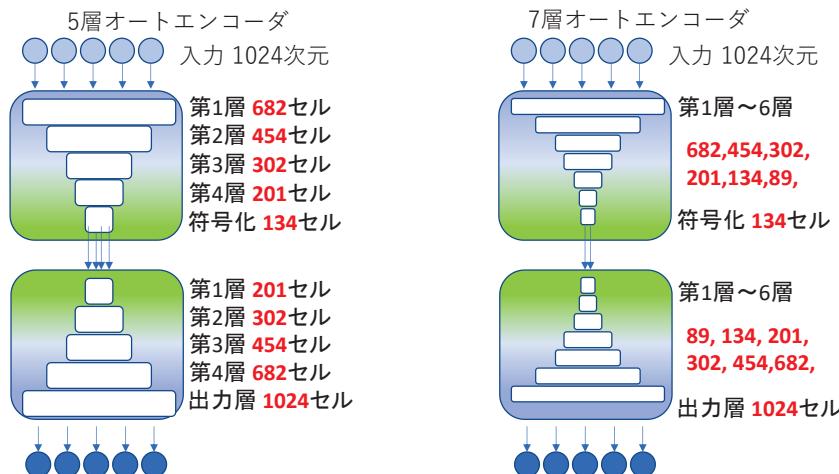


図4 5層および7層のオートエンコーダモデルにおける中間層のパーセプトロンセル数

その場で振動データを取得して診断するエッジ処理に適している。

本研究の小径ドリル加工の実験条件において、振動データを復元できるオートエンコーダの構造を検討した。使用した言語は Python で、深層学習フレームワークに TensorFlow2 (Keras) を用いてオートエンコーダを構築した。検討したオートエンコーダモデルの構造は表 2 に示す通りそれぞれ 3 層、5 層、7 層、9 層のエンコーダ部、デコーダ部を持つオートエンコーダモデルで学習を行い、ドリル加工時の振動データをより復元できるモデルを探査した。本研究においては各層におけるハイパーパラメータの精密な調整は行わない。ただし、各構造はそれぞれエンコーダ部では層が進むに伴い各層のパーセプトロンセル数を一定の割合で減少させ、エンコーダ出力である符号化データの次元が入力点の約 10 分の 1 になるように調整を行っている。

例として、5 層および 7 層のオートエンコーダモデルにおける各層のセル数を図 4 に示す。

深層学習モデルの学習条件を表 3 に示す。深層学習モデルの学習には GPU を備えたワークステーションを用いた。本研究の DAQ システムにより取得した新品時から折損直前までの 2,000 穴分のデータのうち後半 1 割を除いたデータを学習に用いた。

その日の他の設備の稼働状況により振動データに突

発的なスパイクノイズが発生するため、n=3 のメジアンフィルタ処理を実施した。

また、オートエンコーダモデルの入力次元(1,024 点)を窓幅としたスライド窓により 1 穴分の振動データ(時系列データ点数約 55,000 点)につき、1,024 点 × 約 55,000 点のデータセットを作成し、これを 1,942 穴分用意した。

#### 2-4 マハラノビス距離による異常度の指標および異常診断システム

オートエンコーダモデルによって復号化されたデータは、そのままでは異常診断の指標として使用することはできない。1 回あたりに計算される計測点数はオートエンコーダの入力および出力の次元に左右される。

本研究では、出力された符号化データと入力データの差を用いて、以下の式から計算されるマハラノビス距離 (Mahalanobis Distance: M. D.) を異常度の指標として適用した。

$$M. D. = \sqrt{(\vec{x} - \vec{\mu})^T A^{-1} (\vec{x} - \vec{\mu})} \cdots \cdots (1)$$

ここで、 $A^{-1}$  は時系列データ 1,024 点の分散・共分散行列の逆行列であり、 $\vec{x}$  は M. D. を求めたいある瞬間ににおける計測データおよび復号化データの差分ベクトル 1,024 点、 $\vec{\mu}$  は 1,024 点の平均ベクトルである。分散・

表2 オートエンコーダモデル(AE)の検討構造

検討モデル	①3層AE	②5層AE	③7層AE	④9層AE
入力/出力	1024次元	1024次元	1024次元	1024次元
層数	3	5	7	9
中間層セル数	512~128	682~134	682~134	853~196
符号化	128次元	134次元	134次元	196次元
トレーナブルパラメータ数	約69万	約123万	約125万	約275万

**表3 深層学習モデルの学習条件**

フレームワーク	: TensorFlow2.X (Keras)
モデル	: オートエンコーダ
評価関数	: 平均二乗誤差
最適化手法	: Adam
バッチサイズ	: 512バッチ
入力学習サイズ	: size=(512, 1024)
エポック数	: 50~500エポック / 1ファイル
学習データ	: 1942ファイル

共分散行列は異常度を算出する基準データとなる。

また、本研究の異常度は推論計算一回につき1つ算出する。ラズパイ DAQ システムにおいては計測点数1,024点にかかる計測時間は約100ミリ秒であるため、1穴分(約4~5秒)の間に40~50回程度の異常度が計算される。

## 2-5 エッジデバイスによるその場診断

TensorFlowやPyTorchなどの深層学習フレームワークを利用して学習した深層学習モデルは、計算処理の負荷が高くPC上でしか推論計算を実施することはできない。

エッジ処理では、小型のコンピュータであるラズパイ上で深層学習モデルによる推論計算を実施する必要があるが、1回の計算で数秒を要するため、リアルタイムでのその場診断することは難しい。そこで、IntelのAIアクセラレータ(AI スティック)を利用することにより、ラズパイ上で高速に推論計算を実現した。

## 3 結果及び考察

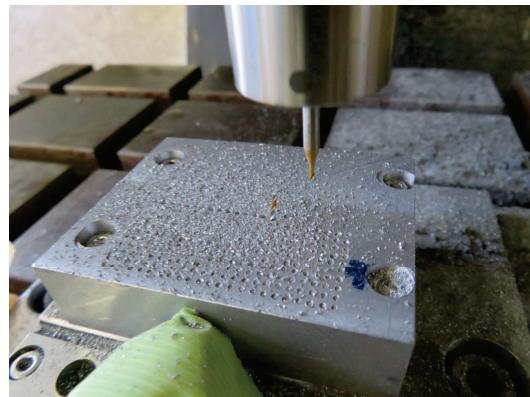
### 3-1 加工実験による振動データ取得

図5は新品のドリルで加工を続け、ドリルが折損したときの写真である。折れた刃先は最後の穴に残っていた。本実験では折損までに約2,000穴の加工を要した。従って、折損は初期故障などの突発的なものではなく、加工面とドリルが凝着し切削時に引抜時に折損したと推測する。

ラズパイ DAQ システムおよび切削動力計で取得した加工時の各計測量の振動データに対して、窓幅1,024点で短時間フーリエ変換(STFT)処理を行い、加工時振動データスペクトrogramをそれぞれ求めて比較した。

図6(a)および(c)は加工初期(約300穴目)および折損直前(約2,000穴目)の、切削動力計で取得した切削抵抗の振動データとスペクトrogramである。それぞれグラフ横軸は時間、縦軸は切削動力計のZ軸(スラスト方向)の切削抵抗である。切削抵抗のスラスト方向振動データでは、ドリルが被削材に接触して削っている時には振幅が大きい。しかし空転している時は振幅が小さいので、切削時及び空転時それぞれの状態が判別できる。これを用いて、振動データの自動計測システムを構築し、700穴目以降より適用した。

ラジアル方向の2つのデータでは、加工開始時点では振幅が小さいが、切削が進むと被削材とドリルの接する面が増大し、振幅が相対的に大きくなる。ラジアル方向のデータからは切削時と空転時の区別を行うことは難し

**図5 ドリル折損時の様子**

いと考える。

図6(b)および(d)は加速度の振動データおよびスペクトrogramである。横軸は時間で縦軸はADコンバータの読み取電圧のビット値である。

加工初期(約300穴目)と折損直前(約2,000穴目)を比較すると、約300穴目では4.1 kHzや3 kHzの周波数が含まれる振動であったが、折損直前では2 kHzや、500 Hz以下の周波数領域の振動が含まれる振動であったことがわかった。

また、切削動力計とラズパイ DAQ システムで取得したデータのスペクトrogramはそれぞれ周波数成分の強さや周波数に違いがみられるが、これは取得する物理量と計測位置が異なることに起因すると思われる。

折損直前に記録された振動データには、折損したと判断できるような振動波形は見られず、折損前の数百穴と類似する振動波形のみが記録されている。これは、ドリル体積が被削材の体積に対して相対的に小さいことから、折損の瞬間の振動も小さかったために計測されなかつたものと推測する。

ところで、加工実験において、図7(a)に示すように、データにスパイクノイズが乗っている現象が見られた。これは他の機械設備の稼働状況に影響した外乱であると思われる。

機械学習する上でスパイクノイズは外乱であり、より正確な予知診断を実施するにはノイズ除去が必須となる。そこで、ノイズ除去の手法の一つであるメジアンフィルタ処理を適用することにより、ノイズ低減を図った。メジアンフィルタのフィルタサイズはn=3とした。

図7(b)はメジアンフィルタ処理後の信号である。処理後の信号にはスパイクノイズが除去できている。また、処理前後それぞれの信号のスペクトrogramを比較しても、信号解析に必要な10 kHz以下の振動情報を保持していることがわかる。

今回新たに構築したラズパイ DAQ システムは、10 kHz程度のサンプリング周波数でデータを取得することができ、使用した振動センサも15 kHzまでの感度領域を持

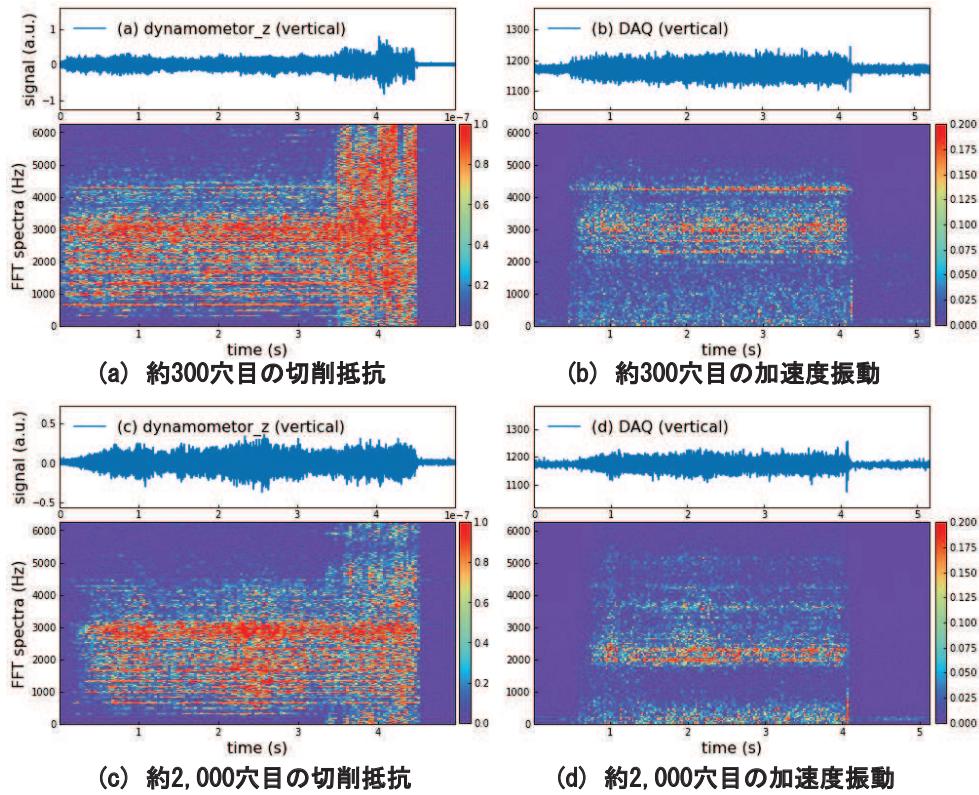


図6 切削動力計の切削抵抗(a, c) ならびにラズパイ DAQ の加速度(b, d)の各振動データおよびスペクトログラム  
(a, b) 加工初期(約300穴目)の例、(c, d) 折損直前(約2,000穴目)の例

つものため、実際に切削時に発生する 10 kHz 程度までの高い周波数分解能を持つシステムを構築できた。

### 3-2 ドリル加工時の振動データに適したオートエンコーダモデルの構造検討

オートエンコーダの学習は GPU を備えたワークステーションで行った。1 ファイル分にかかる時間は CPU 使用で約 20 分、GPU 時で約 2 分と約 10 分の 1 度となり大幅に短縮された。また、各構造のオートエンコーダにつき、1,942 ファイル分の学習にそれぞれ平均約 3 日間程度を要した。

図8 に、各条件のオートエンコーダの復元精度の結果

を示す。図中の各オートエンコーダモデルの結果の青線が振動データであり、赤線は復号データである。また、各グラフの縦軸はラズパイ DAQ から取得した電圧値を無次元化しており、横軸は時系列データである。

一回の推論計算で出力するのは時系列データ 1,024 点だが、見やすくするため横軸の出力点数を半分の 512 点にして表示している。図8 中の 3 層および 5 層のオートエンコーダでは、復号されたデータが計測された振動データに対して再現されていないことが分かる。一方、7 層および 9 層オートエンコーダモデルでは、計測された振動データをよく再現している様子が分かった。

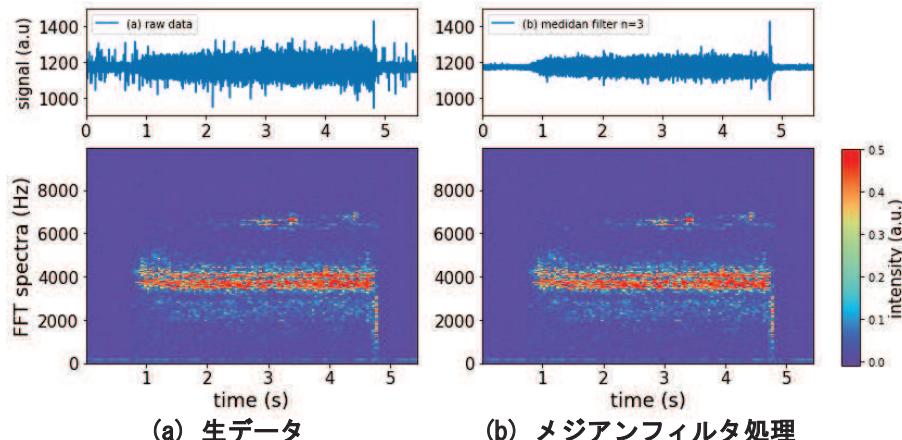


図7 スパイクノイズおよびメジアンフィルタ処理によるノイズ除去

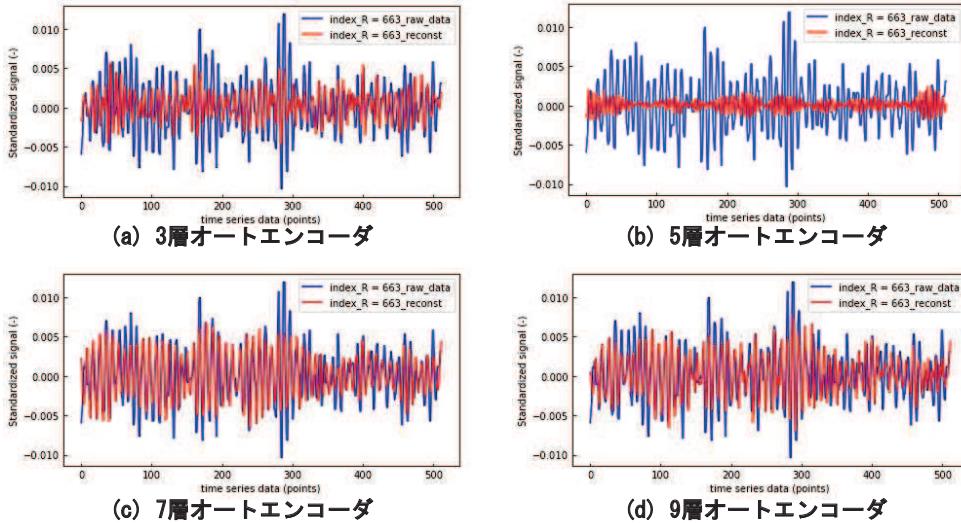


図8 各層のオートエンコーダモデルの復号の精度

一般に、深層学習モデルでは層数が多くなるほど、中間層のニューロン数が増えるほど複雑なデータを表現できると言われており、7層および9層の二つのオートエンコーダモデルは、3層および5層モデルと比較して加工実験の振動データ再現精度が高い結果となった。

次に、約1,000穴目の加工時の振動データ約5.5万点について、各層オートエンコーダモデルの計測データと復号データの絶対誤差をとり、それらをヒストグラムにしたもの図9に示す。各図中横軸は絶対誤差、縦軸は度数である。

各モデルの絶対誤差の平均値を比較すると、最も誤差が小さいのが7層オートエンコーダモデルであることが分かった。9層オートエンコーダモデルと比較すると、7層オートエンコーダモデルの復号データの絶対誤差の平均値は約20%小さく、絶対誤差の分散も小さい。故に、9層より7層オートエンコーダモデルの再現精度が高いと

言える。

9層より7層オートエンコーダモデルの再現精度が高い理由は、層数が深くなりすぎると、深層学習の際のバックプロパゲーション(誤差逆伝搬)の勾配が小さくなり、それ以上学習が進まなくなつたためと考えられる。従つて、9層以上に深いオートエンコーダモデルを構築しても本実験のドリル加工時の振動データの復号データの再現精度は高くなないと予想されるため、本研究に使用するオートエンコーダは7層オートエンコーダモデルが最適であると結論した。

### 3-3 マハラノビス距離による各加工時の異常度の可視化

7層オートエンコーダモデルの復号データと計測データの差から計算されるマハラノビス距離について、図10に示す。図10中(a)横軸は加工回数、縦軸はマハラノビ

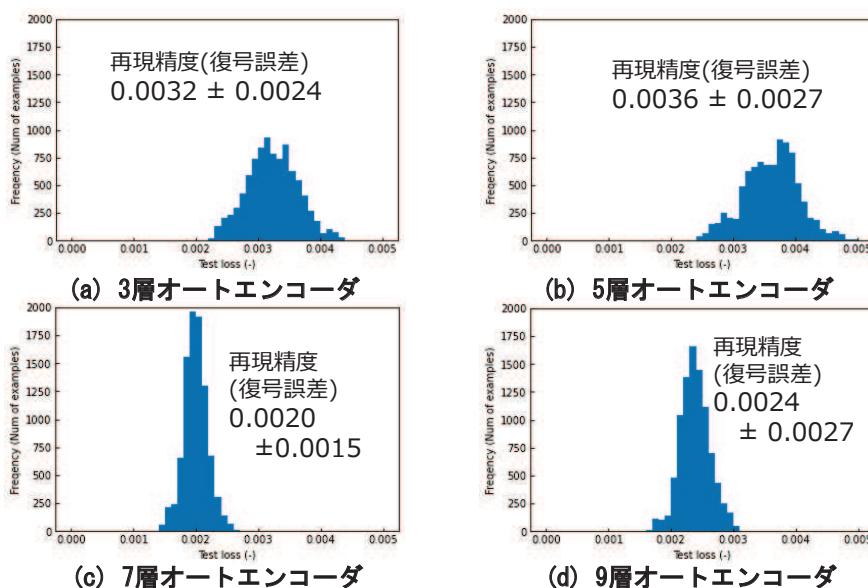


図9 各層オートエンコーダモデルにおける計測と復号データの絶対誤差ヒストグラム

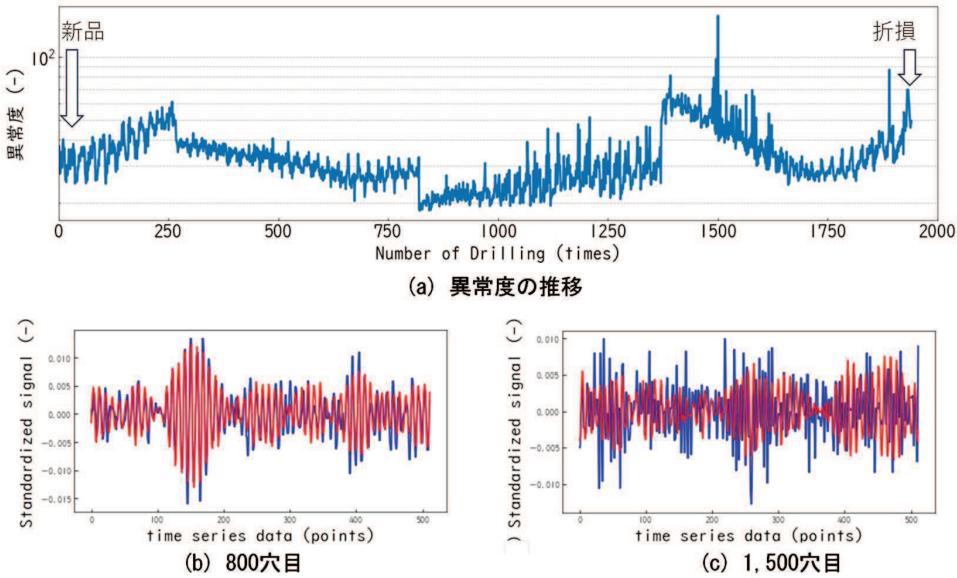


図 10 (a) ドリル折損までの異常度の推移および (b, c) 各加工回数の 7 層オートエンコーダの復号データ

ス距離を異常度として表示している。本結果は、1 本のドリルが折損するまでの約 2,000 穴に対してマハラノビス距離を計算し、それを異常度の指標としてプロットしたものである。本結果は加工回数に対してマハラノビス距離が単調増加していないが、加工回数が 800 穴後以降全体的に増加傾向にある。

また、図 10 中(a)は複数箇所で異常度が不連続で推移している。これは測定時の治具の固定が一定でなかったこと、被削材の形状(特に高さ)が統一できていなかつたこと、そして加工時に計測された振動に含まれる周波数成分が変化したこと、によってオートエンコーダが復号できなかつたため起こったと推察している。

図 10 中(b)、(c)において、異常度が低く計算されている約 800 穴目加工時の振動は再現精度が高い。一方で、最も異常度が高くなつたのは約 1,500 穴目加工時であり、その時の復号データは計測データをほとんど再現していない。

また、1,300 穴から 1,750 穴までは加工回数に対して緩やかに異常度が低下しているが、その後は増加し、約 2,000 穴程度で折損に至る。これは、1,300 穴から 1,750 穴目の間と 1,750 穴から 1,300 穴目の間で、ドリルの振動モードが変化したために異常度は増加したと推測している。

7 層オートエンコーダモデルでは、この時の振動の再

現性が得られておらず、この振動モードの変化の特徴を学習できていない。従つて、今回得られた 7 層オートエンコーダモデルから更に表現能力の高い深層学習モデルを構築する必要がある。

しかしながら、単純に 9 層に増やすなどでは学習が進まないため、スタッキングオートエンコーダ<sup>⑥</sup>などの工夫が必要と思われる。

### 3-4 ラズパイを用いたエッジ処理による異常度判定

3-2 にて構築した学習済の 3 層および 7 層オートエンコーダをラズパイに適用するために、ラズパイにインテルの Neural Compute Stick2 (NCS2) を接続した。そこに、Intel OpenVINO runtime の環境を構築し、TensorFlow の model convertor を用いて、NSC2 で利用可能な OpenVINO 中間表現モデルに変換し、ラズパイにロードした。

比較のため、AI スティックを用いない場合として、TensorFlow lite に変換したモデルを利用した。

NS2 を用いた計算時間の結果を表 4 に示す。AI スティックがない場合、1,024 点の時系列データに対する復号データの計算時間は 1,000 ミリ秒以上を要した。

開発したラズパイ DAQ システムにおいて 1,024 点の振動データを取得するのに要する時間は約 100 ミリ秒である。それ以上を深層学習計算のために使用すると、振動データが計測されない不感時間(デッドタイム)の割合が 50%以上となる。この場合、診断時に必要な情報を含む計

表 4 Neural Compute Stick2 を用いた深層学習推論計算時間の比較

	AI スティックなし 3 層	AI + 3 層 AE	AI + 7 层 AE
パラメータ数	69万個	69万個	125万個
平均誤差(a.u.)	0.0032	0.0032	0.0020
計算時間	1秒(1000ms)以上	3.2±1.85ms	3.75±1.92ms

測データを見逃す可能性が高くなり、リアルタイム診断をすることが困難である。

一方で、AI スティックを用いた3層オートエンコーダの場合は計算時間が約3.2ミリ秒となり、100ミリ秒に対して非常に短時間で推論計算が行える。そのため、計測時間に対するデッドタイムが5%程度となり、診断時に必要な情報を逃さない。

また、3層オートエンコーダのパラメータ約69万個に対し、7層オートエンコーダは約125万個と約2倍程度多い。しかし、7層オートエンコーダの推論計算にかかる時間は約3.7ミリ秒と、極僅かに伸びるもの、デッドタイムの割合にほぼ影響がなかった。従って、3層同様に7層オートエンコーダにおいても、リアルタイム診断を実施することが可能であることが分かった。

#### 4 結 言

本研究では、工作機械の異常診断のためのDAQシステムをラズパイで構築し、従来法として切削動力計の切削抵抗との比較を行った。その結果、以下のことが明らかになった。

- (1) データ収集システムをラズパイ上に構築した。ラズパイDAQシステムは約10kHz程度の高いサンプリング周波数を有している。
- (2) ラズパイDAQシステムで取得したデータを用い振動の変動係数を算出することで切削状態と空転状態を区別でき、それによって自動で振動データを記録できるようにした。
- (3) 小径ドリル加工の加工実験を行い、収集データの比較を行った。加工初期では4.1kHz及び3kHzの周波数が、折損直前では2kHzや、500Hz以下の周波数領域の振動が含まれる振動であったことから、切削加工の状態をラズパイDAQシステムのデータで判断できることが示唆された。
- (4) オートエンコーダの復号データと計測データの差から、ばらつきを考慮したマハラノビス距離を計算し、異常度の指標とした。
- (5) エッジデバイスとして使用しているラズベリーパイにAI スティックを接続し、AI スティック上で7層オートエンコーダを搭載、推論計算したところ、3.7ミリ

秒と非常に短い時間で推論を行うことができ、リアルタイム診断が実施可能であることを確認した。

今後の課題について示す。

7層オートエンコーダモデルは今回検討した条件のなかでは最も再現精度がよかったが、再現精度から計算される異常度は加工回数に対して単調増加していない。

異常診断を行うための理想的なモデルは、加工回数が増えるにつれて徐々に再現しなくなるようなモデルが望まれるが、本研究ではそのようなモデルを構築するまでには至らなかった。

今後、学習データを増やし適切な学習を実施することや更なる深層学習モデルの構造を検討し、再現精度を高めていく。

#### 文 献

- 1) 総務省：令和2年版情報通信白書，p217 (2020)
- 2) 尾上守夫：アコースティックエミッションの基礎と応用, pp1-4 (1976)
- 3) 長谷亜蘭, 和田正毅, 古賀俊彦, 三科博司:アコースティックエミッション法を用いた加工状態監視に関する基礎研究, 精密工学会学術講演会講演論文集 2010S(0), 355-356 (2010)
- 4) Bjorn Weichbrodt: “Mechanical Signature Analysis, A New Tool for product Assurance and Early Fault Detection”, Proc. STH. R/M Cof, 1966.
- 5) Oliver Janssens, Viktor Slavkovikj, Bram Vervish, Kurt Stockman, Mia Loccufier, Steven Verstockt, Rik Van de Walle, Sofie Van Hoecke:Convolutional Neural Network Based Fault Detection for Rotating Machinery, Journal of Sound and Vibration 377, 331-345 (2016)
- 6) Zhou Xiang, Xining Zhang, Wenwen Zhang, Xinrui Xia:Fault diagnosis of rolling bearing under fluctuating speed and variable load based on TCO Spectrum and Stacking Auto-encoder, Measurement 138, 162-174 (2019)
- 7) 朝日翔太, 松井彩華, 田村哲嗣, 速水悟, 井指諒亮, 古川輝, 内藤孝昌:再帰的オートエンコーダを用いた振動データによる工場設備の故障予測手法の提案, Transactions of the JSME (日本機械学会論文集), Vol. 86, No. 891 (2020)