

研究課題名

ディープラーニングを用いた加工状態監視

北九州市立大学 / 村上 洋

## 1. はじめに

近年、産業界でもスマートファクトリー化が進展し、加工中の異常の検知・予測技術に関する関心が高まっている。スマートファクトリー構築において機械加工工程の自動化は生産工程全体を自動化する際の重要な問題の一つである。特に主軸や工具状態の監視技術は適切な時期に工具交換することによる工具コストの低減、加工品位の向上や工作機械ダウンタイムの低減による生産性向上などに寄与する。実際に製造現場において工具交換を行う際は、一定個数加工後あるいは一定時間加工後に工具を交換することが多く、まだ使用可能な工具も破棄していることが多い。同一の加工条件、工具、工作物においても工具摩耗の進行は大きく異なるため、かなり安全を見て工具交換が多く、工具の有効利用率は現状高くはない。したがって、生産性、加工表面性状の向上のためには加工中の切削工具の状態を監視する工具状態監視システムを構築し、切削工具を適切な時期に交換することが重要となる。生産性向上やコスト低減の他にも機械の破損や故障、消耗品劣化などを防ぐ予知保全効果も期待できる。工具摩耗の進行には様々な要素が影響しているため、同じ加工条件でも摩耗量は加工毎に大きく異なる。さらに、AE信号や切削力は工具摩耗だけでなく切込み量や切削速度が変動しても変化するため単体のセンサで工具摩耗状態を信頼性高く推定することは困難である。また、加工中や工具交換中に工具先端とワーク表面との距離が変化すると加工誤差につながるため、加工中の主軸の伸びを監視・補正する必要がある。この主軸の伸びは主軸回転数や環境温度の変化、工具摩耗などにより変化するため、主軸の伸びおよび工具摩耗量を正確にインプロセスで測定あるいは推測する必要がある。

## 2. 目的

我々はこれまでに加工状態のモニタリングを目的として、各種センサを内蔵した空気静圧軸受エアタービンスピンドルを開発してきた<sup>1)</sup>。収集データにはノイズが多く含まれているので、工具摩耗に関連した特徴量を抽出し、機械学習により工具状態の分類や工具摩耗量の推移を予測する

必要がある。また、このような各種センサで取得したデータを用いて加工状態監視モデルの予測精度を向上させるためには、センサ信号の生データから不要な部分を除去し、信号を適切なものに加工するデータの前処理手法が重要になると考えられる。そこで、本報告では、複数のセンサ信号を用いた加工モニタリングにおけるデータ前処理手法の検討結果についても報告する。

## 3. 実用的な価値、実用化の見込など

工具折損、工具摩耗、ベアリングの異常やその他のスピンドルの異常をリアルタイムに検出することが可能なシステムが実用可能になることで以下の成果が期待できる。工具摩耗や熱による主軸の伸び、びびり振動などが測定可能になることで加工の高精度化が可能になる。現状は安全をみてある一定時間加工すると工具を交換しているが、工具が摩耗した適切な時期に交換できるようになることで、工具コストの低減や、NC工作機械の自動工具交換装置を用いた連続加工が可能となる。現在の状況としては単一の加工条件であればある程度工具摩耗量を予測可能であることを確認している。実際の加工現場において実用化するためには任意の加工条件でも可能となるシステムを開発する必要がある。

## 4. 研究内容の詳細

センサビルトインスピンドルの設計・製作に時間を要するため、信号処理技術の開発のためにスピンドルの設計・製作と並行して、既存の工作機械に複数のセンサを取り付けて加工実験を実施し、そのデータを用いて信号処理技術および機械学習モデルの開発を行った。リニアモータステージ上に多成分動力計を設置し、その上に工作物をボルトで固定した。多成分動力計は加工中のX、YおよびZ方向の切削抵抗( $F_x$ ,  $F_y$ ,  $F_z$ )を計測するために用いる。動力計のトッププレート側面には高感度AEセンサを取り付けており、切削加工の際に工作物とエンドミルの摩擦や塑性変形により発生するAE波(A)を取得する。スピンドルのハウジング部には3軸加速度センサを取り付けており、スピンドルのX、YおよびZ方向の振動( $V_x$ ,  $V_y$ ,  $V_z$ )を測定する。マイクロフォンはマグネットベースを用いて工具先端に向けて設

置されており、切削加工で生じる音( $M$ )を記録する。各センサ信号はサンプリング周波数 500kHz で取得した。また、NC の制御装置から XYZ 軸駆動用モータのトルク( $T_x, T_y, T_z$ )、モータ電流( $I_x, I_y, I_z$ )、主軸トルク( $T_s$ )、主軸消費電力( $P_s$ )の信号をサンプリング周波数 1kHz で取得した。

工作物の材料には S45C を用いて、2枚刃のスクエアエンドミルにて加工を行った。半径方向切込み 0.1 mm、軸方向切込み 3 mm、ダウンカットで-X 方向にエンドミル側面切削を行う。工具摩耗を測定する際は工作機械を一時停止し、主軸から取り外した工具先端のマイクロスコープ画像から逃げ面摩耗幅を計測した。

機械学習を用いて高精度な予測を行うためには生データから工具摩耗や表面粗さと相関の高い情報を抽出・選択することが重要となる。今回は時間領域、周波数領域のそれぞれから特徴量を求めた。今回は得られた生データから 8 種類の時間領域特徴、FFT により求めた周波数スペクトルから 8 種類の周波数領域特徴、計 16 種類の特徴量を求める。表 1 に特徴量の一覧を示す。

表 1 特徴量一覧

時間領域	Mean	平均値
	Var(Variance)	分散
	Ske(Skewness)	歪度
	Kur(Kurtosis)	尖度
	Min(Minimum)	最小値
	Max(Maximum)	最大値
	Med(Median)	中央値
	Rms(Root mean square)	二乗平均平方根
周波数領域	PB1(Power Band 1)	0~50kHz のパワースペクトルの総和
	PB2(Power Band 2)	50~100kHz のパワースペクトルの総和
	PB3(Power Band 3)	100~150kHz のパワースペクトルの総和
	PB4(Power Band 4)	150~200kHz のパワースペクトルの総和
	PB5(Power Band 5)	200~250kHz のパワースペクトルの総和
	PB6(Power Band 6)	90~100Hz のパワースペクトルの総和
	PB7(Power Band 7)	180~190Hz のパワースペクトルの総和
	E(Energy)	直流成分を除いたパワースペクトルの平均値

上記 16 のセンサ信号それぞれに対して、表 1 に示す 16 個の特徴量を計算し、合計 256 個の特徴量を得た。それぞれの特徴量に対してピアソンの相関係数を算出した。一例として、X 方向の切削抵抗  $F_x$  と工具逃げ面摩耗幅との相関を示すヒートマップを図 1 に示す。

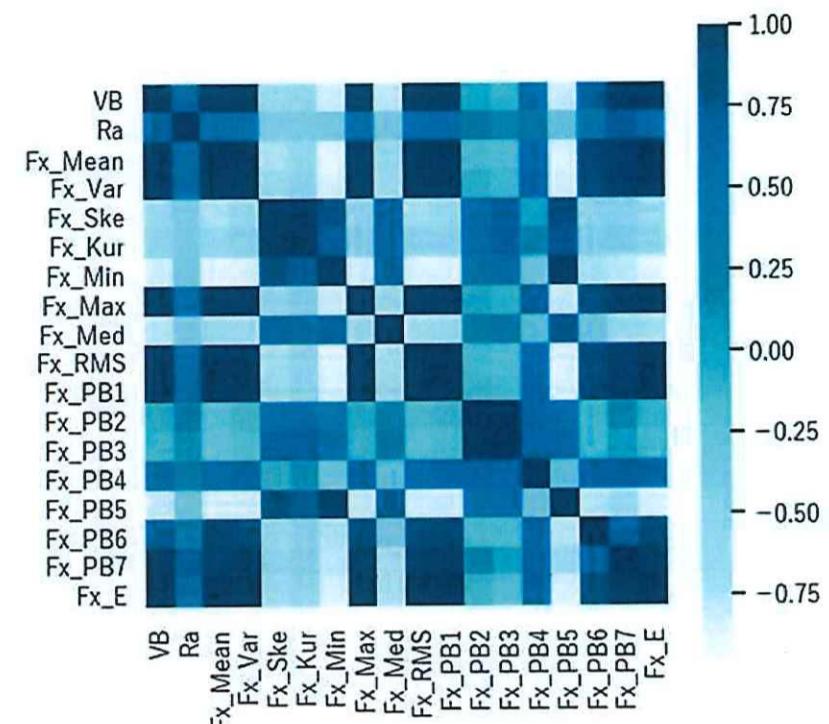


図 1 X 方向切削抵抗特徴量と逃げ面摩耗幅の相関関係

得られた 256 個の特徴量の中から逃げ面摩耗幅と相関の高い、4 個の特徴量( $F_x_{RMS}, V_x_{RMS}, A_{RMS}, M_{RMS}$ )を選定し、以降の学習に使用する。今回は各学習モデルの比較のため、ランダムフォレスト(RF)、勾配ブースティング決定木(GBDT)、サポートベクター回帰(SVR)、ディープラーニング(DL)の 4 つの手法で工具逃げ面摩耗幅の予測を行った。ランダムフォレストは複数の決定木を組み合わせることで、汎化能力を向上させるアンサンブル学習のひとつであり、分類や回帰に用いられる。決定木を並列に作成して、各決定木の出力結果の平均を算出して予測を行う。勾配ブースティング決定木は勾配降下法とアンサンブル学習、決定木の 3 つの手法が組み合わされた機械学習の手法である。サポートベクターマシンは 2 つのクラスのデータ群を分割するような境界線や超平面を決定することで分類や回帰を行うことができる。ディープラーニングは脳の神経細胞の仕組みを模したシステムであるニューラルネットワークがベースになっており、ネットワークを多層にすることでデータに含まれる特徴を学習することができる。損失関数は MSE を用いて評価した。各モデルの予測結果を図 2 に示す。ディープラーニングが最も予測精度が高く、工具の逃げ面摩耗幅を RMSE 18.3 μm の誤差で予測可能であることを確認した。(RF: 25.3 μm, GBDT: 28.0 μm, SVR: 24.8 μm, DL: 18.3 μm)

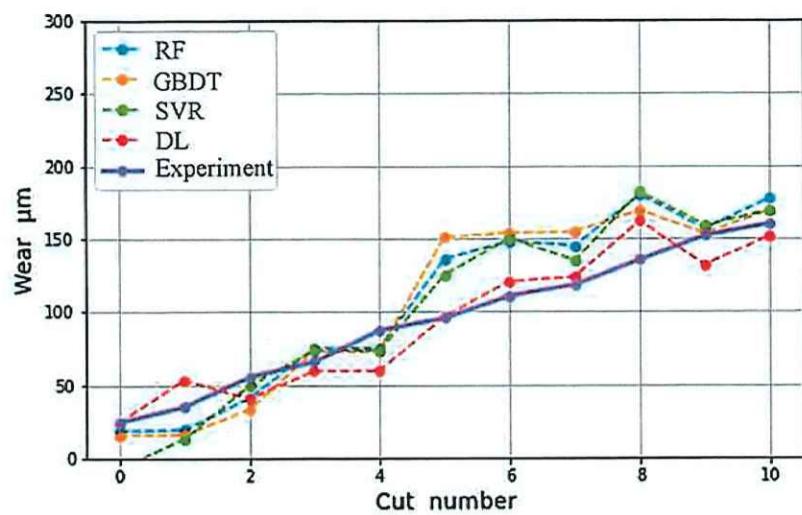
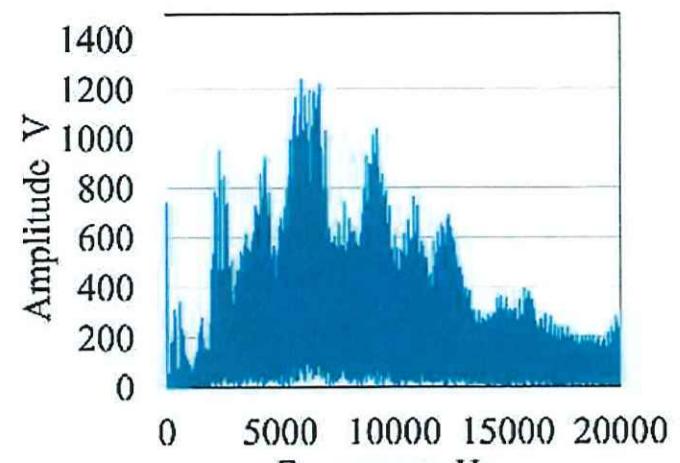
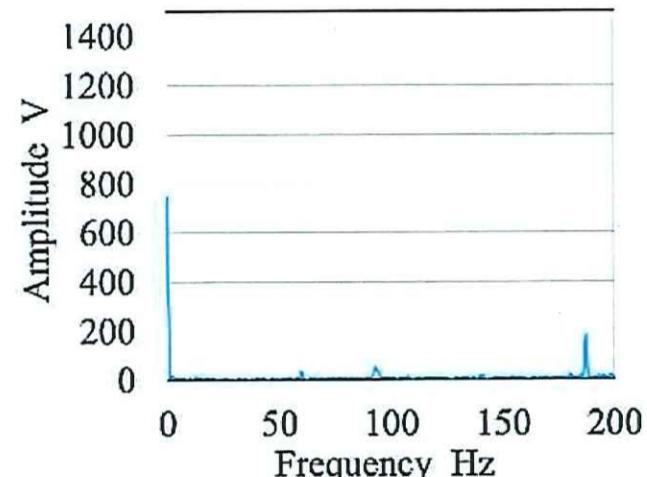


図 2 各モデルの逃げ面摩耗幅予測結果

今後、各種センサで取得したデータを用いて加工状態監視モデルの予測精度を向上させるためには、センサ信号の生データから不要な部分を除去し、信号を適切なものに加工する前処理手法が重要になると考えられる。そこで、センサ信号を用いた加工モニタリングにおけるデータ前処理手法について検討した。エンドミル加工の場合、工具は複数の切れ刃を有するが、主軸の回転振れの影響などにより各切れ刃での除去量が刃毎に異なる。そのため、得られたセンサ信号をそのまま加工するのではなく、刃毎にセンサ信号を分割した上で信号処理する必要があると考えられる。図 3 (a)は直径 3 mm の 2 枚刃エンドミルで被削材 (S45C) を加工した際の Acoustic Emission (AE) 信号の FFT 解析結果である。主軸回転数 2800 rpm, 送り速度 200 mm/min, 半径方向切込み 0.1 mm, 軸方向切込み 3 mm で加工した。図 3 (b)は低周波領域のみを拡大した図である。図 4 は、生データから各切れ刃(刃 1 および刃 2)の AE 信号を分離して FFT 処理した結果である。使用したエンドミルは 2 枚刃であり、図 4 (a) が 1 枚目の切れ刃の結果であり、図 4 (b) が 2 枚目の切れ刃の結果を示す。図 4 (a) および図 4 (b) を比較すると、同じ工具でも刃毎に FFT スペクトルの分布や強度が異なることが確認できる。工具が被削材を切削する切れ刃通過周波数は約 93 Hz であるが、図 3 (a) に示すように高周波成分のスペクトル強度が大きいため図 3 (b) から切れ刃通過周波数での明瞭なピークを確認することは難しい。切れ刃通過周波数の信号には工具状態や回転振れ、切削条件、被削材等に関する重要な特徴量が多く含まれていると推測される。そこで、図 5 に示すように生データの包絡線を求め、この包絡線を FFT 解析する。その結果を図 6 に示す。図 6 からわかるように信号の包絡線を FFT 解析することで回転周波数成分を強調したスペクトルを得ることができる。

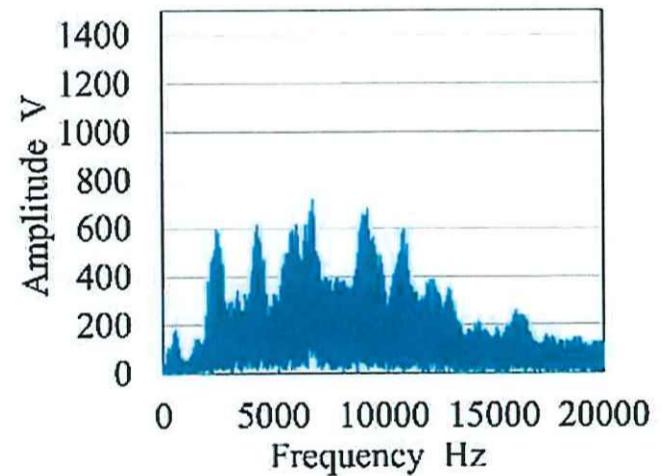


(a) 0-20000 Hz

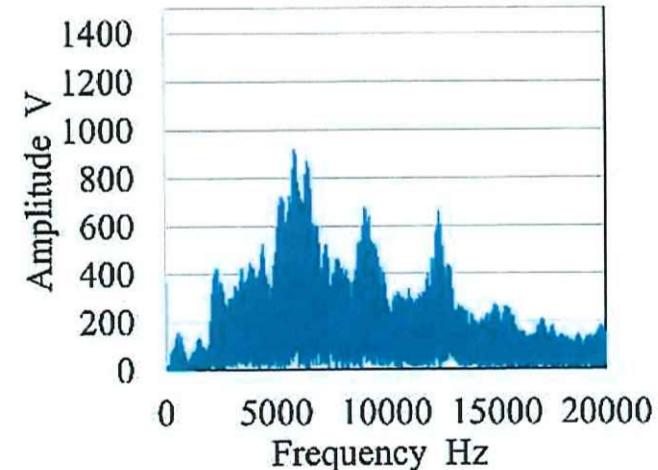


(b) 0-200 Hz

図 3 生データの FFT 結果



(a) 1 枚目の切れ刃



(b) 2 枚目の切れ刃

図 4 生データの FFT 結果

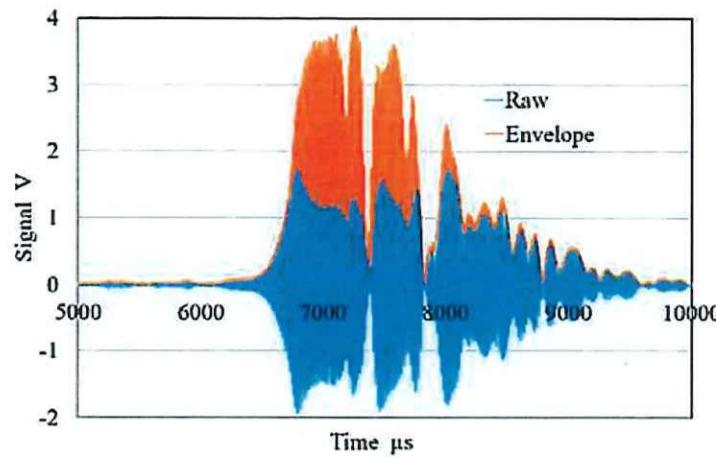
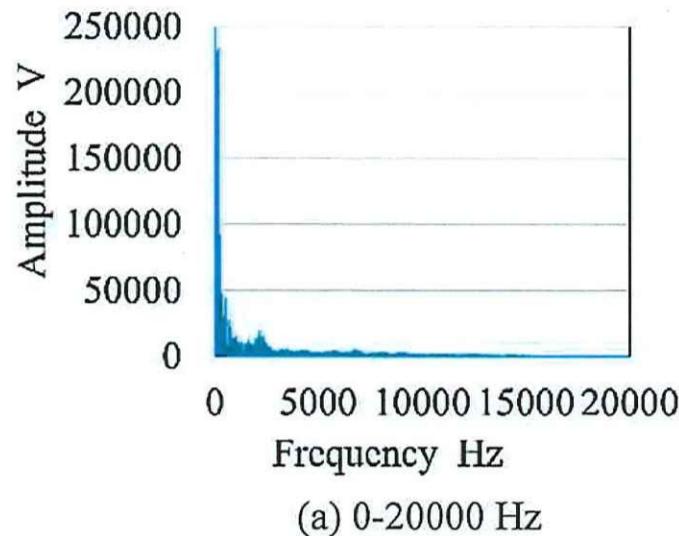
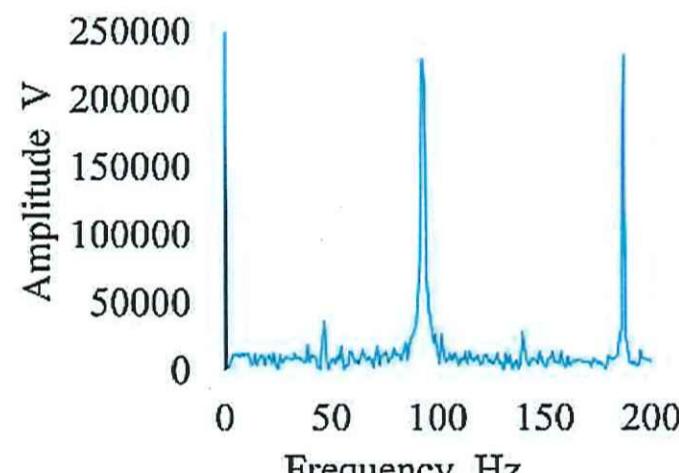


図 5 AE 信号の包絡線処理



(a) 0-20000 Hz



(b) 0-200 Hz

図 6 包絡線信号の FFT 結果

## 5. まとめ(結言)

本研究では、複数のセンサ信号を用いた加工モニタリング手法およびデータ前処理手法について検討した。ディープラーニングによる予測精度はまだ十分ではないため今後学習モデルの予測精度を向上させるための信号処理技術の開発が必要となる。学習モデルの予測精度向上を目的としたデータ前処理手法について検討し、切れ刃毎の信号処理により異なるスペクトルが得られること、信号の包絡線を FFT 処理することにより切れ刃通過周波数成分を強調したスペクトルが得られることを確認した。今後は、他の信号前処

理手法についても検討し、前処理した信号から特徴量を抽出、選択し、状態予測モデルを構築していく予定である。

## 6. 謝辞

本研究は公益財団法人金型技術振興財団令和3年度金型等に関する研究開発助成の援助の下で実施されました。厚く御礼申し上げます。

## 7. 参考文献等

- 1) Hiroshi Murakami, Akio Katsuki, Takao Sajima, Kosuke Uchiyama, Keisuke Houda, Yuta Sugihara. Spindle with built-in acoustic emission sensor to realize contact detection. Precision Engineering. 2021;70:26-33.