

## [研究助成 (A)]

## 熟練技能者の技術の継承を支援する人協調型 AI システムの開発

2231029



研究代表者 北九州市立大学 国際環境工学部 教授 村上 洋

## [研究の目的]

近年、少子高齢化に伴う製造業の人手不足により熟練技能者の技術伝承が困難となりつつある。そこで産業界では人手不足を補うためスマートファクトリー化が進展し、生産工程の自動化や加工中の異常の検知・予測技術に関する関心が高まってきている。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、加工面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、熟練技能者が五感を駆使して工具寿命を判断する場合や、一度加工を止めて測定して判断する場合などがある。同じ形状を大量に加工する場合は、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することが多く、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熟練技能者に頼らなくても加工中の切削工具の状態を監視することが可能な加工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。そこで、本研究では、ソフト（人工知能技術）とハード（複数のセンサ）を融合させることで熟練技能者の技術の伝承を支援する人協調型 AI システムを開発することを目的とする。

## [研究の内容、成果]

スピンドルや工作機械ステージなど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工具摩耗を予測する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を記録す

る。各センサ信号はサンプリング周波数 1 MHz 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、モータ電流、主軸トルク、主軸消費電力の信号をサンプリング周波数 1 kHz で取得した。

工作物の材料には S50C, SKD11 および NAK55 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。送り速度、切削速度、軸方向切込み量、ドライ・MQL 加工など切削条件を変えて加工実験を実施し、合計 21 回分のデータを取得した。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 9 種類の時間領域特徴（平均値、分散、尖度、歪度、波形率、など）、FFT により求めた周波数スペクトルから 21 種類の周波数領域特徴（平均、分散、歪度、尖度、50 kHz 毎のパワースペクトルの平均、工具切れ刃通過周波数のパワースペクトルなど）、計 30 種類の特徴量を求めた。上記 16 のセンサ信号それぞれに対して、30 個の特徴量を計算し、合計 480 個の特徴量を得た。これまでに機械学習を用いた様々な工具摩耗量の予測手法が提案されてきたが、教師データが必要であるために、膨大な加工実験を実施する必要があった。そこで、本報では従来の教師あり学習法（Random forest, GBTD（Gradient boosting decision tree）, SVR（Support vector regression）, Deep learning, LightGBM（Light Gradient Boosting Machine）, XGBoost（eXtreme Gradient Boosting））と大量の教師データを必要としない教師なし学習（One-class SVM）による新しい摩耗予測法の性能を比較検討した結果について報告する。

複数のセンサ信号から得られた上記特徴量と

機械学習モデルの一つである One-class SVM を用いて工具摩耗の予測を行う。One-class SVM とは Support Vector Machine を用いる外れ値検知手法である。One-class SVM は正常データを囲むような境界を作成し、この境界からの距離を異常度として計算する。今回は各実験の最初のデータの特徴量のみを用いてモデルの境界を作成した。その後、取得した加工中のデータをそのモデルを使用して異常度  $a$  を算出した。この異常度に加工条件のパラメータ（切削速度、送り量、切込み深さの累乗）と工具と工作物の組み合わせによる係数、切削液に関する係数を乗じることで摩耗を算出する。パラメータ指数の同定には複数の実験結果を必要とする。また、One-class SVM などの機械学習の評価関数には一般的に RMSE（Root Mean Squared Error）が用いられることが多い。しかし、今回のような加工において工具摩耗を予測する場合、加工条件によっては構成刃先などが発生し、その影響で各種センサ信号が変動することで予測した摩耗量に大きな変動が生じることがある。そこで、今回は摩耗予測の大幅な変動を抑制させるために新たな評価関数 NEF を式（1）のように定義して用いることにした。

$$NEF = \sqrt{\underbrace{\frac{1}{N} \sum_{i=1}^N (y_i - y_i)^2}_{\text{RMSE}} + \underbrace{\alpha}_{\text{調整係数}} \underbrace{\sqrt{\frac{1}{N-1} \sum_{i=2}^N (y_i - y_{i-1})^2}}_{\text{摩耗の不連続性}}} \quad (1)$$

$y_i$  は切削回数  $i$  番目における摩耗量の予測値を示しており、前回の予測値との不連続性を少なくすることによる変動の抑制が期待できる。

図 1 に工作物（S50C）を加工した際に One-class SVM を用いて予測した結果を示す。実線が実験で測定した工具逃げ面摩耗幅、破線が評価関数に RMSE を用いて予測した工具逃げ面摩耗幅、一点鎖線が評価関数に NEF を用いて予測した工具逃げ面摩耗幅を示す。新しい評価関数を用いることで予測値の変動が抑制可能であることが確認できる。




図1 One-class SVM を用いた工具摩耗量予測結果




図2 各機械学習モデルによる工具摩耗予測結果

表1 予測結果の比較 (RMSE:  $\mu\text{m}$ )

|                     | S50C, Dry Axial<br>depth of cut : 1.5 mm |
|---------------------|------------------------------------------|
| Random forest       | 8.5                                      |
| GBDT                | 7.6                                      |
| SVR                 | 4.2                                      |
| Deep learning       | 13.9                                     |
| LightGBM            | 11.9                                     |
| XGBoost             | 12.0                                     |
| One-class SVM       | 27.4                                     |
| One-class SVM (NEF) | 12.3                                     |

図2に教師ありおよび教師なしの各機械学習モデルによる予測結果を示す。また、表1に予測結果のRMSEを示す。教師なし学習であるOne-class SVMでも教師あり学習法と同等の予測が可能であることを確認した。

表2に工作物S50Cを加工した場合のドライ加工とMQL (Minimum Quantity Lubrication) 加工の比較 (工具摩耗予測結果のRMSE)を示す。ドライ加工においては他の教師あり学習と同等の精度で予測ができているが、MQL加工の場合は誤差が4倍近く大きくなっている。

表2 ドライ加工とMQL加工の予測結果 (RMSE:  $\mu\text{m}$ )

|                     | S50C, Dry<br>Axial depth<br>of cut : 3 mm | S50C, Dry<br>Axial depth<br>of cut : 1.5 mm | S50C, MQL<br>Axial depth<br>of cut : 3 mm |
|---------------------|-------------------------------------------|---------------------------------------------|-------------------------------------------|
| Random forest       | 12.7                                      | 8.5                                         | 13.3                                      |
| GBDT                | 10.1                                      | 7.6                                         | 14.3                                      |
| SVR                 | 9                                         | 4.2                                         | 11.1                                      |
| Deep learning       | 10.9                                      | 13.9                                        | 11.4                                      |
| LightGBM            | 16.0                                      | 11.9                                        | 12.3                                      |
| XGBoost             | 12.8                                      | 12.0                                        | 13.6                                      |
| One-class SVM       | 27.5                                      | 27.4                                        | 33.3                                      |
| One-class SVM (NEF) | 19.7                                      | 12.3                                        | 43.8                                      |

表3 SKD11とNAK55の予測結果 (RMSE:  $\mu\text{m}$ )

|                     | SKD11, Dry Axial<br>depth of cut : 3 mm | NAK55, Dry Axial<br>depth of cut : 3 mm |
|---------------------|-----------------------------------------|-----------------------------------------|
| Random forest       | 27.5                                    | 24.4                                    |
| GBDT                | 27.9                                    | 20.9                                    |
| SVR                 | 36.7                                    | 21.8                                    |
| Deep learning       | 32.7                                    | 35.6                                    |
| LightGBM            | 27.4                                    | 18.2                                    |
| XGBoost             | 30.7                                    | 19.7                                    |
| One-class SVM       | 32.1                                    | 37                                      |
| One-class SVM (NEF) | 42.4                                    | 28.7                                    |

今後は工具摩耗の予測式を改良する等の対策を行いMQL加工の場合の予測精度を向上させる必要がある。参考までに特徴量重要度 (どのセンサが予測に寄与したかの指標) を算出したところ、軸駆動用モータ、加速度センサの順に重要度が高くなっていた。

One-class SVMを用いた教師なし学習手法においてはワークピース材料と工具の組み合わせが変わった場合は、最低1回加工実験を実施して、データを取得し係数を決定する必要がある。表2および表3より一度ワークピースと工具との間の係数を決めることができれば切削条件が変わっても適切に予測可能であることが確認できた。

次に図3に示すセンサビルトインスピンドルの製作を実施した。軸受には空気静圧軸受を使用し、エアータービンにより駆動する。主軸内部、タービン部、工具先端部に主軸内蔵型光ファイバ式AE (Acoustic Emission, アコースティックエミッション) センサ、光ファイバ式




図3 センサビルトインスピンドルの概略図

圧力センサおよび光ファイバ式マイクロフォンの各センサを設置する。本研究では新たに小型で低ノイズの各種センサを作成するために、レーザによりファイバ端面の高精度加工に取り組んだ。図4に示すように加工に最適なレーザパワー、波長、使用するレンズNA、を決定するために加工実験を実施した。

加工実験の一例として、図5にパルスエネルギーと加工穴直径の関係および図6にパルスエネルギーと加工穴深さの関係を示す。




図4 レーザ加工痕の写真




図5 パルスエネルギーと加工穴直径の関係




図6 パルスエネルギーと加工穴深さの関係

本研究では、複数のセンサ信号を用いて教師あり学習法 (Random forest, GBTD (Gradient boosting decision tree), SVR (Support vector regression), Deep learning, LightGBM (Light Gradient Boosting Machine), XGBoost (eXtreme Gradient Boosting)) と大量の教師データを必要としない教師なし学習 (One-class SVM) による新規摩耗予測法の性能について比較検討し、ワークピースの材料や切削条件が変わった場合でも工具逃げ面摩耗量を予測可能であることを確認した。また、教師なし学習手法 (One-class SVM) においても教師あり学習手法と同程度の精度で予測が可能であることを確認した。今後は工具摩耗の予測式を改良し、MQL加工の場合等、各種条件における予測精度向上に取り組む予定である。本研究は公益財団法人立石科学技術振興財団の研究助成を受けて行ったことを記し、謝意を表す。

#### [成果の発表、論文など]

- (1) 村上洋, 甲木昭雄, 佐島隆生, 松田智大, 岩下悠人, 吉積孝紘, “One-class support vector machineを用いた教師なし工具摩耗予測法の開発”, 2024年度精密工学会春季大会講演論文集, p.106, 2024.
- (2) 吉積孝紘, 村上洋, 甲木昭雄, 松田智大, “エンドミル加工における教師ありおよび教師なし工具摩耗予測法の開発”, 日本機械学会第15回生産加工・工作機械部門講演会講演論文集, p.75, 2024.