

機械学習を用いた切削加工面粗さの判別

横田 知宏 (情報・生産技術部 加工評価グループ)

奥田 誠 (情報・生産技術部 システム技術グループ)

1. はじめに

近年の製造現場では、人手不足、後継者不足などの問題への対応のため、デジタル技術を活用した工程の自動化が進められている。しかしながら、切削加工においてはまだまだ人の経験知が必要な作業が多く、自動化を阻害している。例えば、エンドミル加工において良好な表面性状（加工面粗さ）を得るために、作業者が経験を頼りに加工条件の設定、調整をおこなっている。自動化を進めるためには、工作機械が加工中に自動で加工条件を適切な値に調整することが必要となる。このような自律型工作機械を実現するためには、切削加工で得られる加工面粗さを正確に予測する技術が必要である。そこで我々は加工中のセンサデータから加工面粗さを推定する機械学習モデルの開発を進めている。これまでに、加工面粗さの悪化に大きな影響を及ぼすびり振動の発生を判定可能な機械学習モデルを開発したり。

本研究では、びり振動判定の機械学習モデルを応用し、加工面粗さを特定の閾値で判別する機械学習モデルを作成した。

2. 実験及び結果

スクエアエンドミルによる切削実験をおこない、機械学習に必要なデータを収集した。使用した工作機械は、立形マシニングセンタ V33 (牧野フライス製作所製、以下 MC1 と記す) 及び 5 軸制御マシニングセンタ VC-X350 (ニデックオーケー製、以下 MC2 と記す) である。MC2 での実験環境を図 1 に示す。MC1 でもほぼ同様の環境を構築した。加工中の加速度を測定するために、主軸に加速度センサを設置した。また切削抵抗を測定するために、治具を介して被削材を切削動力計に固定した。直径 10 mm、刃数 2 枚のスクエアエンドミルを用い、ドライで長さ 100 mm の板材 (材質 S50C) の側面切削をおこなった。表 1 に示す範囲の中で切削条件の各項目をランダムに選定し、100 通りの組み合わせを設定して 2 台のマシニングセンタで同一条件の実験をおこなった。実験後、表面粗さ測定機 SURFCOM NEX 241 SD2-13 (東京精密製) により各条件の被削材の加工面粗さを測定した。算術平均粗さ Ra 及び最大高さ Rz を機械学習の判別データとした。

同一条件で加工した場合の面粗さ Ra について、横軸を MC1、縦軸を MC2 としてプロットした散布図を図 2 に示す。同種のエンドミル、被削材を用いて、同一の切削条件で加工したにも関わらず、加工面粗さが大きく異なっている。これは、工作機械の剛性などの違いが加工面粗さに影




図 1 実験環境 (5 軸制御マシニングセンタ)

表 1 切削条件の各項目の設定範囲

項目		設定範囲
切削速度	(m/min)	50~100
一刃当り送り量	(mm/tooth)	0.05~0.15
径方向切込み量	(mm)	0.2~1.0
軸方向切込み量	(mm)	3.0~15.0

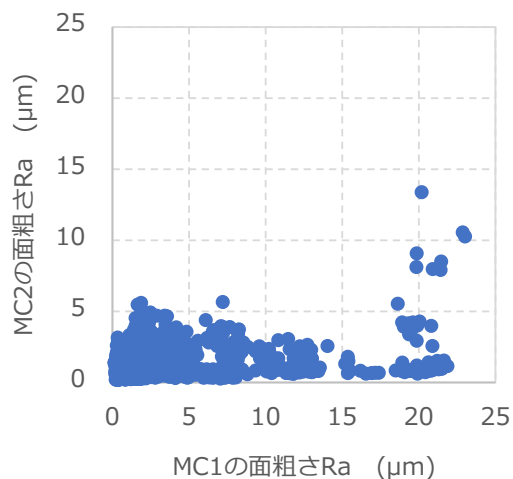


図 2 加工面粗さ Ra の散布図

響することを示している。このことから、異なる工作機械に対して、切削条件のみで加工面粗さを予測することは難しいと考えられる。

本研究では、加工面粗さを特定の閾値で判別する機械学習の分類モデルを作成した。機械学習モデルにはランダムフォレストを用い、加工面粗さ判別の正解率により学習モデルの性能を評価した。正解率とは、予測に用いた全デー

タ件数に対して、加工面粗さを正しく判別した件数の割合である。学習モデルの汎化性能の評価に、全データを条件ごとにランダムに学習データ 8 割、評価データ 2 割で分割してグループ交差検証をおこなった。

機械学習モデルの作成に用いたデータセットは次のとおりである。目的変数は、実験で得られた加工面粗さ Ra 及び Rz を元に 0 または 1 でラベル付けした二値データとした。被削材の切削開始 6 mm の位置から 94 mm までを 4 mm ごとに分割し、その 4 mm 区間ごとに $Ra < 1.6 \mu\text{m}$ かつ $Rz < 6.3 \mu\text{m}$ の場合を 0、その他の場合を 1 にラベル付けた。作成した機械学習モデルでは、目的変数である加工面粗さを 0 または 1 で分類した。説明変数は切削 4 条件（切削速度、一刃当り送り量、径方向切込み量、軸方向切込み量）と、加速度及び切削抵抗のセンサデータから算出した特徴量とした。

センサデータの特徴量の算出方法について述べる。加速度の周波数分析によるパワースペクトル分布を求めると、加工面粗さが大きい区間では 3,000~4,000 Hz のパワースペクトルが大きくなる傾向にあった。3,000~4,000 Hz 以外の周波数領域では加工面粗さによる違いはほとんどなかった。このことから、加工面粗さの判定に 3,000~4,000 Hz のパワースペクトルを用いることが有効であると考えられた。そこで、X、Y、Z 軸方向の加速度データそれぞれについて、3,000~4,000 Hz のパワースペクトルの積分値を特徴量とした。また切削抵抗については、X、Y、Z 軸方向それぞれの 4 mm 区間ごとの最大値を特徴量とした。

ここから、作成した機械学習モデルの評価結果を示す。はじめに切削 4 条件のみを説明変数とした機械学習モデルの正解率を評価した。その結果、正解率は MC1 の場合 79.4%、MC2 の場合 83.3% であり、いずれも十分な値ではなかった。これは、前述した通り加工面粗さに工作機械の剛性や工具ホルダ等の影響が加わっているためである。したがって、機械学習モデルの正解率を向上させるには、工作機械の特性を考慮した説明変数を追加する必要がある。

ランダムフォレストでは各説明変数の重要度を導出することができる。MC1 の場合の各説明変数の重要度を図 3 に示す。径方向切込み量の重要度が他に比べ著しく高かった。この傾向は MC2 の場合でも同様であった。したがって切削 4 条件の中では、加工面粗さには径方向切込み量の影響が大きいことがわかった。

機械学習の正解率を向上させるために、説明変数に加速度特徴量と切削抵抗特徴量を追加した機械学習モデルを作成した。機械学習モデルの正解率を図 4 に示す。切削 4 条件と加速度特徴量を組み合わせた場合に MC1、MC2 いずれも正解率は 90% を超えた。一方、切削 4 条件と切削抵抗特徴量を組み合わせた場合では MC1、MC2 とも 90% を下回った。また、切削 4 条件と加速度特徴量、切削抵抗特徴量をすべて組み合わせた場合の正解率は、切削 4 条件+加速度特徴量の場合と大差なかった。このことから、機械学習モデルに対して切削抵抗特徴量の影響度は小さく、センサデータとしては加速度特徴量の追加のみで高い精度の機械学習モデルを構築できることがわかった。また加速




図 3 切削 4 条件を説明変数として作成した機械学習モデルの説明変数の重要度 (MC1 の場合)




図 4 各種説明変数の組み合わせによる機械学習モデルの正解率

度特徴量の追加により、MC1、MC2 の正解率にほとんど差がなくなった。このことから、異なる工作機械でも主軸の加速度データを説明変数に用いることで、加工面粗さを精度良く推定できることが示唆された。

3. おわりに

本研究では、スクエアエンドミルによる側面切削の実験データから、加工面粗さを特定の閾値で判別する機械学習モデルを作成した。その結果、2 台のマシニングセンタいづれにも高い正解率が得られる機械学習モデルを構築することができた。今後は、工作機械の自律制御への応用を考慮して、機械学習モデルの分類結果から適正な加工条件を出力する手法を開発する。

謝辞

本研究は公益財団法人大澤科学技術振興財団の研究助成金を受けて実施しました。ここに感謝申し上げます。

【参考文献】

- 横田知宏, 奥田誠, 2022 年度砥粒加工学会学術講演会 (ABTEC2022), 345-346(2022)

【外部発表】 口頭発表 1 件