

機械学習による切削加工面粗さの判別

情報・生産技術部 加工評価グループ
横田 知宏


KISTEC Innovation Hub
2023 11.13 Mon. to 11.17 Fri.

背景

人手不足・後継者不足への対応



生産工程の自動化の取組み



切削加工 加工条件の設定・調整

経験と勘を頼りに
人が設定・調整



加工条件設定の自動化




加工前 適切な加工条件を自動設定

加工中 加工面粗さを判別 ➡ 適切な条件に調整

目的

加工面の例

良好な加工面（加工面粗さが小さい）



荒れた加工面（加工面粗さが大きい）



特性値 = 面粗さ $R_a \cdot R_z$

加工中に測ることはできない

代用特性 $\Rightarrow$ 面粗さを推定

加工中に測定できる
センサデータ


代用特性の特徴量

機械学習

加工中のセンサデータ（代用特性）から、加工面粗さを推定し
良好か不良かを判別する機械学習モデルを作成する

機械学習の考え方と作成手順

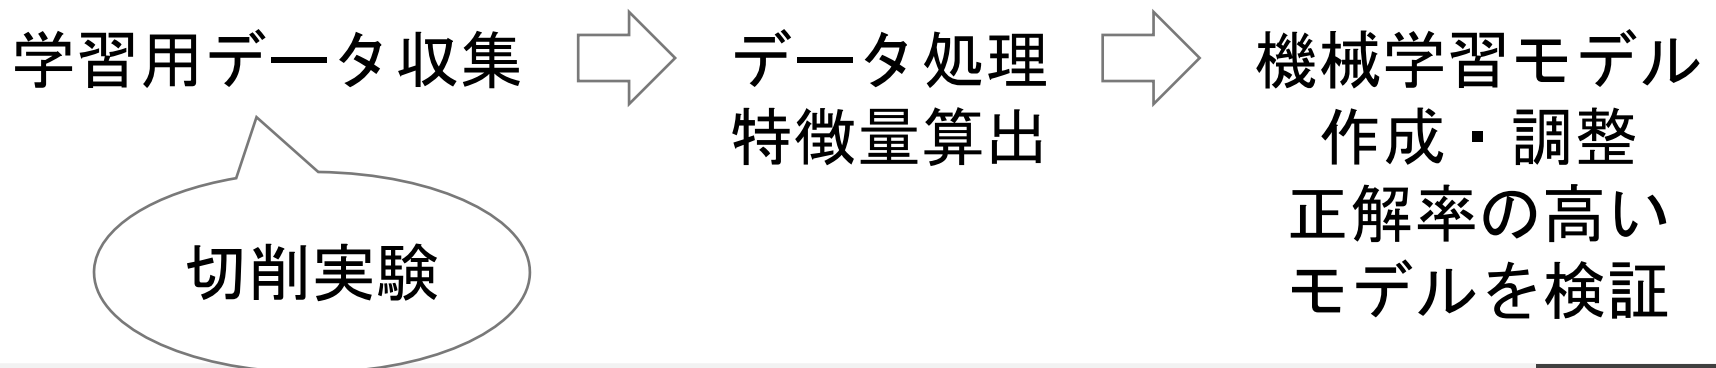
機械学習モデル（教師あり学習）



Point


説明変数にどのような特徴量を選定するか

どのような機械学習アルゴリズムを用いるか



実験方法

スクエアエンドミルによる側面切削



切削条件

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

被削材 : S50C 100×32×5mm

100通りのランダムな組合せを実施

工具 : 直径10mm2枚刃スクエアエンドミル


工作機械 : V33 (牧野フライス製作所製)

VC-X350 (ニデックオーケーケー)

MC1 } ※同一条件の測定を実施
MC2 }

データ処理 加工面粗さによるラベル付け

加工面プロフィール




	0	4	8	12	16	20	24	28	32	36	40	44	48	52	56	60	64	68	72	76	80	84	88	92	96	100
0											✓				✓		✓	✓	✓	✓	✓	✓	✓	✓	✓	
1	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓		✓	✓	✓		✓										

4mm区間ごとにRaとRzを算出 ⇒0か1でラベル付け

$Ra < 1.6 \mu m$ かつ $Rz < 6.3 \mu m$: 0

その他 : 1


データ処理 センサデータの特徴量の選定 – 加速度 –



面粗さRaとの相関係数


	MC1			MC2		
	X	Y	Z	X	Y	Z
平均値	0.03	-0.09	-0.09	0.28	0.20	0.17
標準偏差	0.80	0.75	0.72	0.85	0.74	0.78
最大値	0.77	0.70	0.72	0.57	0.42	0.10

データ処理 センサデータの特徴量の選定 – 加速度 –



1kHzごとに周波数帯を分けてパワースペクトルの合計を算出


データ処理 センサデータの特徴量の選定 – 加速度 –



面粗さRaとの相関係数

	MC1			MC2		
	X	Y	Z	X	Y	Z
0-1kHz合計	0.28	0.35	0.42	0.38	0.48	0.19
1-2kHz合計	0.43	0.32	0.40	0.26	0.16	0.07
2-3kHz合計	0.76	0.76	0.71	0.53	0.37	0.13
3-4kHz合計	0.82	0.83	0.63	0.77	0.75	0.73
4-5kHz合計	0.32	0.26	0.39	0.32	0.30	0.31

データ処理 センサデータの特徴量の選定 –切削抵抗–



面粗さRaとの相関係数

	MC1				MC2			
	X	Y	Z	合力	X	Y	Z	合力
平均値	0.42	0.48	0.43	0.48	0.23	0.34	0.23	0.33
標準偏差	0.51	0.56	0.64	0.52	0.32	0.39	0.53	0.32
最大値	0.60	0.62	0.73	0.59	0.50	0.47	0.74	0.49

目的変数と説明変数

目的変数：加工面粗さ（ラベル0 or ラベル1）


説明変数

項目	特徴量
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
加速度特徴量 (X,Y,Z)	● 標準偏差 ● 3-4kHz帯のパワースペクトル合計値
切削抵抗特徴量 (X,Y,Z)	● 最大値


機械学習の判別精度の高い説明変数の組合せを検討

機械学習アルゴリズム (分類)

ランダムフォレスト(RF)



サポートベクタマシン(SVM)



マージンを最大化するような
決定境界を探索する。

機械学習の予測結果例

- ✓ 全2200データを学習データ8割、テストデータ2割に分割
- ✓ グループ付き公差検証 (GroupKFold)

		予測	
		ラベル0 (Ra<1.6かつRz<6.3)	ラベル1 その他
実測	ラベル0 (Ra<1.6 かつ Rz<6.3)	750 正解	159 不正解
	ラベル1 その他	53 不正解	1238 正解

← 全データ →

グループA	グループB	グループC	グループD	グループE
テストデータ	学習データ			
学習データ	テストデータ	学習データ		
学習データ		テストデータ	学習データ	
学習データ			テストデータ	学習データ
学習データ				テストデータ



正解率

$$= (750 + 1238) / 2200 \times 100$$

$$= 90.4\%$$


加工面粗さ判別結果①

説明変数：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)



RF、SVMとも正解率は80%程度
⇒切削4条件のみで加工面粗さの判別精度は低い

加工面粗さ（測定データ）





2台のマシニングセンタで加工面粗さが大きく異なる
⇒機械の剛性などが加工面粗さに大きく影響している

加工面粗さ判別結果②

説明変数：加速度特徴量



(標準偏差、3-4kHzパワースペクトル)



標準偏差よりパワースペクトルのほうが正解率が高い
⇒パワースペクトルを説明変数として用いる

加工面粗さ判別結果③



説明変数：切削抵抗特徴量（最大値）



RF、SVMとも正解率が90%を下回る
⇒説明変数として、加速度のほうが適当

加工面粗さ判別結果④

説明変数：切削4条件 + 加速度特徴量
 + 切削抵抗特徴量



RFにて【切削4条件 + 加速度】により約94%の正解率
切削抵抗を加えることで正解率低下

まとめ

スクエアエンドミルの側面切削を対象に、加工中のセンサーデータから加工面粗さを判別する機械学習モデルを作成した。

- ✓ 異なるマシニングセンタでは同一切削条件でも加工面粗さが大きく異なるため、切削条件のみの説明変数では加工面粗さの判別精度が低かった。
- ✓ 主軸加速度の特徴量（3-4kHz帯のパワースペクトルの合計値）が、切削抵抗の特徴量よりも、説明変数として用いた場合の判別精度が高かった。
- ✓ 切削条件と加速度特徴量を組み合わせた説明変数とすることで、2台のマシニングセンタともランダムフォレストにより正解率約94%で加工面粗さを判別することができた。