

サポートベクターマシンと多項式回帰を併用した加工条件導出手法の開発

慶應義塾大学 ○林典行, ◎青山藤詞郎, 柿沼康弘

要旨

加工条件は、切削温度、切削抵抗、これらに起因する工具摩耗やびびり振動の発生に対して大きく影響を与えるが、その決定は作業者の知識と経験に依存している。そこで本研究では、センサレス材料特性計測と機械学習を応用することで、超精密加工機が自律的に加工条件を決定する手法を提案した。サーボ情報に基づく机上計測法で推定した材料のヤング率と硬度に基づき、適切な切削速度を与える条件の導出システムを開発した。

1. 結論

光学機器や電子機器の大容量化・高機能化・小型化・高速化に伴い、それらの素子や部品の微細化・微小化の需要が急速に高まっている。その需要を満たすため、超精密加工における周辺技術の発展は必要不可欠である。多くの技術が自動化している中で、加工条件の選定は作業者の経験や勘に頼るところが多く、切削実験を繰り返して決定される。加工条件は、適切に選定すれば、生産能率を高め、工具寿命を延長できる一方、誤れば過大な負荷による工具折損やびびり振動を誘発する。特に超精密加工や小径工具によるマイクロ加工では寸法効果の影響で、加工条件の選定は一層難しくなる。そのため、経験の浅い技術者でも容易に加工条件を決定することができるユーザフレンドリな技術の開発が強く求められている。

そこで本研究では、先行研究^[1]で開発したセンサレス材料特性計測技術によって求めた材料の硬度とヤング率を基に、機械学習を応用した小径エンドミル加工の工具条件・加工条件の導出手法を提案した。具体的には、工具のコーティング種類とねじれ角、回転数と送り速度を導出するアルゴリズムを開発した。

2. 加工条件導出技術の提案

本研究では、工作物情報に応じてエンドミル工具およびその加工条件を導出するシステムを提案する。エンドミル加工における工具条件として工具径、工具刃長、コーティング種類、ねじれ角があり、加工条件として回転数と送り速度がある。工具径と工具刃長は加工形状に応じて自ずと決定される。工具のコーティング種類は被削材の材料特性に主に依存する。工具のねじれ角・回転数・送り速度は被削材の材料特性、工具形状、コーティング種類を統合的に検討して決定する必要がある。この考えに基づき、これらの条件を導出する手法を提案した。図1に提案した加工条件導出手法の概念を示す。




図1 加工条件導出手法

本研究では、工具のコーティング種類は4種類、ねじれ角は5種類に分類する。この分類を行うにあたり、分類問題に適したサポートベクターマシンを用いる。サポートベクターマシンとは、

2値分類問題を解くために考えられた学習アルゴリズムで、図2に示すように、 $f(x) = 0$ となる、データを分類する適切な識別境界を導出する手法である。データベクトルを x 、係数行列 ω とバイアス項 b とすると、識別境界は式(1)のように表される。

$$f(x) = \omega^T x + b \quad (1)$$

例えば、データベクトルの各成分 x_i を被削材の硬度とヤング率として、コーティングの種類を分類する場合に利用できる。識別境界 $f(x)$ と各データの最短距離を求め、その最小値をマージン M と定義し、それを最大化するよう識別境界 $f(x)$ を求める。ここで、2クラス分類を前提とし、分類される y_i は、分類に応じて $1(f(x) > 0)$ か $-1(f(x) < 0)$ の値をとるとすると、上記は式(2)のように表される。ただし、 i はデータ番号とする。

$$\max_{\omega, b, M} \frac{M}{\|\omega\|} \quad \text{s.t.} \quad y_i(\omega^T x_i + b) \geq M, \quad i \in [n] \quad (2)$$




図2 線形サポートベクターマシン

しかしながら、本研究では説明変数を被削材の硬度とヤング率とし、目的変数を工具のコーティング種類としているが、図2のような線形な識別境界で分類できるような単純な分布となっていない。そこで、図3に示すように座標変換行列 $\phi(x)$ を用いて、線形分離可能な分布への変換を考える。この手法を非線形サポートベクターマシンと呼び、座標変換行列 $\phi(x)$ には、一般的にガウシアン分布を応用して、以下のような $\phi(x)$ が用いられる。

$$\phi(x_i)^T \phi(x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3)$$




図3 非線形サポートベクターマシン

ただし、 x_i, x_j はデータベクトル、 γ はスケールパラメータである。つまり、データ要素間の距離に応じた評価空間へ $\phi(x)$ を用いて分布を展開することで線形な識別境界による分類を可能にする。

本研究では、工具のコーティング種類とねじれ角を被削材の特性と工具の情報から決定するために、この非線形サポートベクターマシンを利用した。

回転数と送り速度は連続な数値の予測が求められるため、多項式回帰を用いる。多項式回帰は、式(4)のように図1で示される説明変数 $x_1 \sim x_5$ と回帰係数 ω_n のべき乗を式(5)、式(6)のように z で置き換え、線形回帰と同様の計算をする。図1に示す通り、本研究における説明変数は $x_1 \sim x_5$ の被削材の硬度とヤング率、工具径と工具刃長、工具のコーティングとし、目的変数は回転数 y_3 と送り速度 y_4 である。線形回帰と同様、目的変数の教師データ行列 \mathbf{y} と予測値行列 $\hat{\mathbf{y}}$ の誤差を最小にできる ω を求めることで近似式を得る(式(7))。

$$y_{i(i=3,4)} = \omega_0 + \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_6 x_1^2 + \omega_7 x_1 x_2 + \dots + \omega_{21} x_1^3 + \dots \quad (4)$$

$$\hat{y}_{i(i=3,4)} = \omega_0 + \omega_1 z_1 + \omega_2 z_2 + \dots + \omega_p z_p \quad (5)$$

$$\hat{\mathbf{y}} = \begin{pmatrix} \hat{y}_{1i} \\ \vdots \\ \hat{y}_{ni} \end{pmatrix} = \begin{pmatrix} 1 & z_{11} & \dots & z_{1p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & z_{n1} & \dots & z_{np} \end{pmatrix} \begin{pmatrix} \omega_0 \\ \vdots \\ \omega_p \end{pmatrix} = \mathbf{z}\omega \quad (6)$$

$$\min_{\omega} \|\mathbf{z}\omega - \mathbf{y}\|^2 \quad (7)$$

多項式回帰は、次数を高めると推定精度が高まるが、一方で図4に示される過学習が発生するという問題点がある。そこで、過学習を抑制するために式(8)に示す通り、推定誤差項 $\alpha\|\omega\|$ を意図的に導入するLasso回帰を本研究では応用した。推定誤差項の導入により、評価範囲内の推定精度は低下するが、評価範囲外のデータに対する推定誤差の低減が可能となる。

$$\min_{\omega} \|\mathbf{z}\omega - \mathbf{y}\|^2 + \alpha\|\omega\| \quad (8)$$




図4 過学習

3. シミュレーション条件

工具条件、加工条件を導出するにあたり、事前に学習データとして工具メーカーの推奨する加工条件を学習アルゴリズムに与えている。工具のコーティング種類は、説明変数と目的変数の組である学習データ246組を与えており、学習データに含まれていない説明変数に対し、3000HV、3400HV、3600HV、9000HVの4種類に分類する。ねじれ角は学習データを239組与えており、25°、30°、35°、40°、45°の5種類に分類する。回転数と送り速度は、1412組の学習データを与えており、学習データに含まれていない説明変数に対し、多項式-Lasso回帰を用いて実数値を予測する。使用したパラメータを表1に示す。

表1 シミュレーションパラメータ

非線形サポートベクターマシン	正則化項係数 C	1000
	スケールパラメータ γ	0.000001
多項式-Lasso回帰	多項式回帰次数	8
	正則化項係数 α	1000

4. 加工条件導出手法の評価

提案手法の有効性を評価するために、シミュレーションを行った。表2と表3に非線形サポートベクターマシンによる工具決定結果を、図5と図6に加工条件導出結果を示す。本手法によって得られた工具と加工条件の推定値を、工具メーカーが推奨するカタログデータと比較している。

工具条件導出手法は、コーティング、ねじれ角ともに平均分類正答率96%、平均分類誤差はコーティングでは9HV、ねじれ角では0.37°を達成した。また、加工条件導出手法は予測精度を表す決定係数がそれぞれ、回転数では0.892、送り速度では0.831を達成した。

表2 コーティング種類の正答率

種類 HV	3000	3400	3600	9000	平均
正答率 %	100	100	82	100	96
誤差 HV	0	0	36	0	9

表3 ねじれ角の正答率

角度 °	25	30	35	40	45	平均
正答率 %	100	100	80	100	100	96
誤差 °	0	0	1.86	0	0	0.37




図5 回転数の推定結果




図6 送り速度の推定結果

5. 結論

機械学習を応用した工具決定手法と加工条件導出手法を提案した。工具決定は正答率96%を達成し、加工条件導出は決定係数0.80以上を達成した。工具メーカーが推奨する標準条件とよく一致した加工条件を推定でき、提案手法の有効性が示された。

参考文献

- [1] S.Nagakari, M. Sangkee, Y.Kakinuma: "Mechanical Characteristic Identification of Workpiece by Applying Sensor-less Micro-tool Contact Detection with Ultra-precision Machine", The 16th International Conference on Precision Engineering, (2016)