

マイクロリング加工におけるモータ電流を用いた機械学習ベースの形状誤差推定

慶應義塾大学理工学部 ○水原健太, ◎柿沼康弘
メガロ化工株式会社 中道大亮, 静岡工業技術研究所 柳原亘

要旨

近年、複雑光学部品のための微細金型への需要が増加しており、その加工中の状態把握が困難なことからプロセス監視技術の開発が求められている。本研究ではマイクロレンズアレイの微細金型を対象としたエンドミル加工において、サーボ情報と加工領域の形状誤差を結びつける手法を提案した。機械学習による教師あり学習により、加工中のサーボ情報からマイクロスケールの形状誤差を推定できることを示した。

1. 結論

マイクロレンズアレイ(Micro Lens Array:以下, MLA)とはミリメートル〜マイクロメートル単位の微細なレンズをアレイ状に配置したもので、光を効率よく拡散することができるという特徴がある。従来の光学部品よりも微細かつ複雑な構造であるため、MLA 金型は極小径エンドミルを用いた 5 軸超精密加工により製造される。一方で、微小部品の加工では目視やビジョンセンサによる加工中の状態把握や製品の良し悪しの判断が困難なことから、有効なプロセス監視技術の開発が求められている。

超精密加工機はリアモータを採用し、駆動時の摺動抵抗が低い。このため、従来の工作機械に比べて、加工情報がサーボ情報に直接的に反映される。この点に着目し、本研究では、超精密加工機におけるプロセス監視の一機能として、サーボモータ電流を用いた機械学習ベースの形状誤差推定技術を開発し、その有用性を検討した。なお、登壇者は形状誤差推定システムの提案及び解析を担当した。

2. MLA 金型加工の概要と加工結果

本研究では、被削材であるマルテンサイト系ステンレス鋼に直径 200 μm の 2 枚刃超硬ボールエンドミルを用いて直径 600 μm のレンズ型を 5000 個加工した。構築したサーボ情報収集システムにより、超精密 5 軸加工機から加工中のサーボモータ電流と工具軌跡の情報を取得した。また加工後にレンズ型の形状を測定し、CAD モデルと比較することで、形状誤差を算出した。得られた形状誤差データの一例を図 2 に示す。




図 1 サーボ情報収集システムの構成




図 2 レンズ型の形状誤差データ

3. 提案する形状誤差推定システム

提案するマイクロレンズ型の形状誤差推定システムの全体像を図 3 に示す。MLA 金型の加工中に得られたサーボモータ電流データは一定タイムステップごとに FFT で周波数解析した後、機械学習のために主成分分析(Principal Component Analysis:以下, PCA)を施し次元を削減した。サーボ電流データの FFT を行う際にそれぞれの窓の始点と終点における形状誤差データの対応領域を参照することで、サーボ電流の周波数スペクトルと形状誤差データを関連づけた。これらの手順で得られたデータセットを用いて機械学習モデルを訓練し、形状誤差を推定した。機械学習モデルは線形手法(線形回帰, Ridge 回帰, 線形 SVR(Support Vector Regression))及び非線形手法(ガウスカーネルを用いた非線形 SVR, ニューラルネットワーク)を使用し、機械学習手法による推定精度の比較を行った。また XYZ 軸の 3 種類のデータを用いて形状誤差を推定し推定精度の比較を行った。

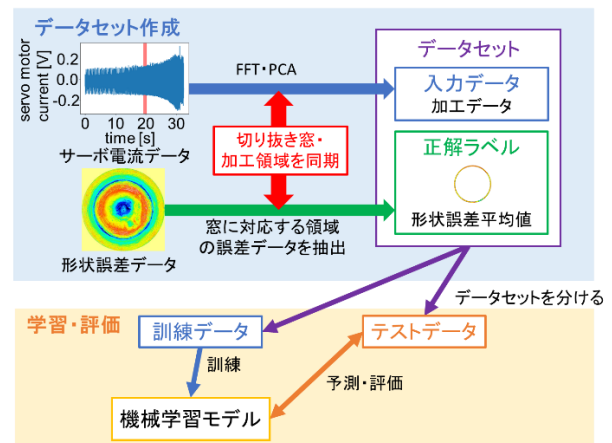


図 3 マイクロレンズ型の形状誤差推定システム

4. 形状誤差の推定手法

4.1 ニューラルネットワーク

ニューラルネットワークは図 4(a)に示すパーセプトロンを組み合わせて構成されたネットワークである。パーセプトロンでは入力 $\mathbf{x} = (x_1, x_2, \dots, x_l)$ を重み $\mathbf{w} = (w_1, w_2, \dots, w_l)$ と掛け合わせ、足し合わせてバイアス w_0 を加えたものを活性化関数 h に代入して y を出力する。

$$y = h \left(\sum_{i=1}^l w_i x_i + w_0 \right) \quad (1)$$




図 4 パーセプトロンとニューラルネットワーク

このような構造を組み合わせた図 4(b)のようなモデルをニューラルネットワークと呼ぶ。ニューラルネットワークを学習するには誤差逆伝播法を用いる。誤差逆伝播法では重みが最適化されていないニューラルネットワークで推定を行い、推定値と正解ラベルの値の誤差を図の矢印の逆方向に伝播しながら各重みを調節する。

4.2 訓練・評価手法

本研究では MLA 金型加工のうち 1, 100, 200, ..., 5000 個目の加工データを取得した。レンズを 1 個加工したデータから 492 個のデータセットを作成した。表 1 に示すように加工個数が少ないものと加工個数が多いものが同程度になるように 5 グループに振り分けてテストデータとし、テストデータに含まれないデータを訓練データとした。各機械学習モデルのパラメータは表 2 のように設定した。

表 1 データセットの分配

| グループ | テストデータ(個目のデータ) | 訓練データ |
|------|-----------------------------|------------------------|
| 1 | 1, 500, 1400, 1900, 2500 | |
| 2 | 100, 700, 1500, 2100, 2700 | テストデータに含まれない 37 個分のデータ |
| 3 | 200, 900, 1600, 2200, 2800 | |
| 4 | 300, 1100, 1700, 2300, 2900 | |
| 5 | 400, 1300, 1800, 2400, 3100 | |

表 2 機械学習パラメータ

| 機械学習手法 | パラメータ |
|-------------|---|
| 線形回帰 | (設定パラメータなし) |
| Ridge 回帰 | $\alpha = 3000$ |
| 線形 SVR | $C = 0.017, \varepsilon = 0.076$ |
| 非線形 SVR | $C = 2200, \gamma = 0.0040, \varepsilon = 0.012$ |
| ニューラルネットワーク | 中間層のノード数:1024, 128, 256, 128, 128 活性化関数:ReLU, 損失関数:MSE, 最適化アルゴリズム:RMSProp |

5. 形状誤差推定の評価

5.1 形状誤差推定

X 軸のサーボモータ電流を用いてニューラルネットワークで推定した結果の一例を図 5 に示す。全てのテストデータにおいて、形状誤差を精度良く推定できることがわかった。




図 5 形状誤差推定

5.2 機械学習手法の比較

X 軸のサーボモータ電流を用いて各機械学習手法で形状誤差を推定した際の精度比較を表 3 に示す。なお、RMSE 及び MAE は次のように与えられる。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2}, \text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - t_i| \quad (2)$$

ここで N はデータ数、 y_i は i 番目の入力データに対する形状誤差の推定値、 t_i は i 番目の入力データに対する正解ラベル(実際の形状誤差の値)である。線形回帰, Ridge 回帰, 線形 SVR は線形手法であり、非線形 SVR 及びニューラルネットワークは非線形手法である。線形手法と非線形手法で結果に開きがあることから、形状誤差の推定には非線形関数を用いるのが適切であるといえる。

表 3 X 軸のサーボモータ電流を用いた各手法の精度比較

| | 評価指標 | |
|-------------|---------------|---------------|
| | RMSE | MAE |
| 線形回帰 | 0.4246 | 0.3373 |
| Ridge 回帰 | 0.4254 | 0.3308 |
| 線形 SVR | 0.4150 | 0.3301 |
| 非線形 SVR | 0.2653 | 0.1942 |
| ニューラルネットワーク | 0.2660 | 0.1931 |

非線形手法において、サーボモータ電流を用いた各並進軸と推定精度の比較結果を表 4 に示す。XYZ の 3 軸で比較した際、X 軸を用いることで精度が著しく向上した。これは、X 軸が工作物側に配置されていること、加工点からサーボモータまでに介在する機械要素が少なく、多くの加工情報がサーボモータまで伝達されたためと考えられる。

表 4 非線形手法における各軸の精度比較

| | 非線形 SVR | | ニューラルネットワーク | |
|-----|---------------|---------------|---------------|---------------|
| | RMSE | MAE | RMSE | MAE |
| X 軸 | 0.2653 | 0.1942 | 0.2660 | 0.1931 |
| Y 軸 | 0.5977 | 0.4617 | 0.6300 | 0.4769 |
| Z 軸 | 0.4058 | 0.3202 | 0.3864 | 0.2877 |

6. 結論

本研究では、機械学習を用いてサーボモータ電流からマイクロレンズ型の形状誤差を推定した。得られた成果を以下に示す。

- I) 作成したデータセットを用いて機械学習モデルで回帰することで、加工中のサーボモータ電流から形状誤差を推定できることがわかった。
- II) 機械学習モデルの選択では、非線形のモデルを用いることで推定精度を高めることができた。
- III) X 軸のサーボモータ電流情報を用いることで推定精度が格段に向上した。工作物側に配置された軸には多くの加工情報が含まれていると推察された。

参考文献

- [1]. 近藤 英二, “切削加工における状態監視と制御に関する最近の研究動向,” 2010 年度精密工学会春季大会学術講演会講演論文集,(2010) 345-346.