

AI を用いたフェイスミル加工における異常検知に関する研究

森本 和邦*, 服部 俊**

A Study of AI-Based Anomaly Detection for Face Milling

Kazukuni MORIMOTO, Suguru HATTORI

An analytical method of with neural networks was proposed for anomaly detection in face milling. In the analytical method, a normal condition model was created from the normal conditions without anomaly data in face milling wave form per rotation: the data were cutting forces, accelerations, and tool wears. Next, based on the normal condition model, the occurrence of abnormal condition was detected. As a result, the analysis method identified over tool wear from created normal condition model.

Keywords: Anomaly Detection, Autoencoder, Tool Wear, Cutting Force, Face Milling

1. はじめに

切削加工における異常検知では、切削抵抗、振動、切削音、アコースティックエミッションを対象に周波数解析、統計解析、ニューラルネットワークを用いた研究が行われている^{1,4)}。ニューラルネットワークは中間層を多層化することで高精度化するディープラーニングの技術が開発され、近年再び注目されている。しかしながら切削加工の異常検知にニューラルネットワークを活用する場合の課題として、十分な量の学習データが必要となるが、工場においては切削異常のデータを十分に集めるのに時間がかかるという課題がある。そこで本研究では、教師データを不要とするニューラルネットワークのアルゴリズムの1つであるオートエンコーダ^{1,2)}に着目した。オートエンコーダは、情報量圧縮を特徴としたニューラルネットワークのアルゴリズムであり、入力したデータ群（信号）を非線形に圧縮した特徴量を抽出し、抽出した特徴量から再度に入力データを復元した信号を出力する「予測モデル（予測は再編成という）」を作るものである。入力と同じ出力を返す学習モデルである。この予測モデルでは次のようにし

て状態識別に用いる事ができる。すなわち、予測モデルには異常時の入力データの情報は何ら取り入れられていないものの、異常時の入力データに対しては正常時との差が入力と出力の差である再編成誤差として表れる。したがって、再編成誤差に閾値を設定することで、正常状態と異常状態が識別できる。このように、予測モデルは正常時のデータから作成されるため、異常データが不要であるという大きな特徴を有している。本研究では、フェイスミル加工における状態識別（正常、異常の2カテゴリ）へのオートエンコーダの適用の可能性を検討することを目的に、工具摩耗、切削抵抗、振動における工具の1回転あたりの加工波形を対象としたオートエンコーダにて状態識別を試みた。その結果、状態識別の可能性が見いだされたので以下に報告する。

2. 実験方法

2. 1 実験装置概要

実験装置を図1に示す。金属平面を削り出すフェイスミル加工における振動及び切削抵抗を測定するため、切削動力計に供試材及び加速度ピックアップを取り付けた構成とした。フェイスミル加工においては、定期的に工具の摩耗を観察し、工具の逃げ面またはすくい面の摩耗量が0.2 mmに達する

* プロジェクト研究課

** ものづくり研究課




図1 実験装置の概要




図2 試験片形状

まで加工を行った。

2.2 供試材

切削試験に用いた供試材は SUS306 材を用いた。供試材の形状は、図 2 に示すようなフランジを設けた形で、その大きさは W48×L170×H50 mm とし、このうち W48×L120×H23 mm の部分を切削した。切削抵抗を測定するため、供試材のフランジ部分の 2 か所に取付用座繰り穴を設け、六角穴付きボルトにより切削動力計に固定した。

2.3 加工方法及びセンサ取付

加工方法は、フェイスミル加工とし、直径 50 mm のフェイスミル工具を用いて、表 1 に示す試験条件で加工を行った。また切削動力計では加工時の切削抵抗を 1.2 kHz でサンプリングした。評価には測定した X,Y,Z 軸方向の切削抵抗を 100 Hz 間隔平均し、(1)式で示す合成切削抵抗を算出し、オートエンコーダの入力とした。

合成切削抵抗

$$F_{xyz} = \sqrt{F_x^2 + F_y^2 + F_z^2} \quad (1)$$

表 1 切削条件

Cutting condition	
Cutting speed [m/min]	94.2
Feed rate [mm/min]	30
Spindle rotation [rpm]	600
Cutting width [mm]	48
Cutting length [mm /回]	120
Courant	刷毛により水溶性 切削油を塗布
Facemill tool	tangaloy TNMU120708PE R-MJ / AH3135

振動は、1 軸の加速度ピックアップを Y 軸方向の加速度が測定できるように切削動力計の前面に取り付け、サンプリング周期 3 kHz で計測した。加速度ピックアップは、アンプと AD 変換器を用いて加速度をパソコンに取り込むシステム構成とした。測定した加速度は、窓幅 1 秒ごとに、離散フーリエ解析を行い、0 から 1.5 kHz まで計算した後、1 Hz から 200 Hz までの 1 Hz 間隔で 200 個の振幅値をオートエンコーダの入力とした。

2.4 オートエンコーダ

この研究では、フェイスミル加工の工具 1 回転あたりの正常時の合成切削抵抗及び加速度の加工波形をオートエンコーダの入力として、正常時の入力を出力するように学習させている。

オートエンコーダの構造を図 3 に示す。ノード数は、入力層は m, 中間層 1 は 1/2 m, 中間層 2 は 1/4 m, 中間層 3 は 1/2 m, 出力層は m とした。m は加速度では 200 個、切削抵抗では 1 回転あたりの変動が大きかったため、m は 1 秒分 (10 回転分) で 1,000 個とした。

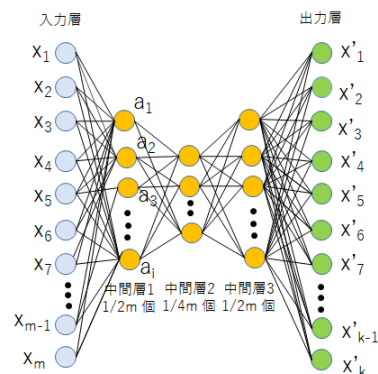


図3 オートエンコーダ

オートエンコーダの中間層及び出力層は(2),(3)の式により計算を行った。

$$\text{中間層 } a_i = f\left(\sum_{j=1}^n (W_{ij} x_j + b_i)\right) \quad (2)$$

$$\text{出力層 } \hat{x}_k = \hat{f}\left(\sum_{l=1}^m (W'_{kl} x_k + b'_k)\right) \quad (3)$$

W, W' : 重み係数 b, b' : バイアス n, m : 合成切削抵抗, 加速度の周波数解析結果の入力数

ここで合成切削抵抗の入力及び出力数は $n = 1000, m = 250$, 加速度の周波数解析の入力、出力数は $n = 200, m = 50$ とした。 $f(x)$ は活性化関数で中間層では(4)式で示す ReLU (Rectified Linear Unit) 関数, 出力層では(5)式で示すシグモイド関数を使用した。

$$\text{中間層の活性化関数 } f(x) = \max(0, x) \quad (4)$$

$$\text{出力層の活性化関数 } f(x) = \frac{1}{1+e^{-x}} \quad (5)$$

学習における重み係数は(6)式で示す平均二乗誤差を使用し, adam[®]で提案されている方法にて(6)式が最小となるように 100 回繰り返して, 重み係数 w, w' , バイアス b, b' の最適化を行った。

$$(w, w', b, b') = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i) \quad (6)$$

作成した予測モデルからの出力と入力の差である再編成誤差を(7)式に示す工具1回転あたりの異常度として定義した。異常度に閾値を設定して、加工状態の状態識別を行った。

$$\text{異常度 } anomaly\ score = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i) \quad (7)$$

ここで, n は工具 1 回転あたりの合成切削抵抗及び加速度の周波数解析結果のデータ数である。




図4 工具摩耗観察結果

2. 5 工具摩耗観察

オートエンコーダの出力波形と測定波形の差分の閾値を設定するために、定期的に工具摩耗をビデオマイクscopeにより観察した。工具の逃げ面及びすくい面摩耗幅を測定し、いずれか大きい摩耗幅を工具摩耗量とし、工具摩耗量が 0.2 mm に達した時点を加速度, 切削抵抗の閾値の基準とした。また瞬間的な測定値の上昇の影響を抑えるために、異常度に 200 区間で移動平均を適用し、その結果に対して閾値の設定を行った。学習には設定した閾値以下の加速度周波数解析結果と合成切削抵抗を学習データとし、テストデータにて学習モデルの正確性を検証した。

3. 結果および考察

3. 1 工具摩耗観察結果

工具摩耗の観察結果を図 4~5 に示す。工具摩耗はすくい面の摩耗が進行し、45 回目の加工においてすくい面摩耗量が 0.2 mm に達した。すくい面の摩耗が進行した理由は、SUS306 材は熱伝導率が低い材料で、切削熱の多くが切粉と接触するすくい面に集中したためと考えられる。

3. 2 加速度解析結果

加速度, 加速度のフーリエ解析結果を図 6~7 に示す。加速度は、工具の摩耗に従い上昇する傾向であった。また加速度のフーリエ解析結果からは工具回転周期 10 Hz 及びその整数倍, また加工物-切削動力計の固有振動数である約 600 Hz~800 Hz の周波数が確認された。そこで、異常時の特徴として、固有振動数の影響を取り除き、工具回転に起因する振動を抽出するために、フーリエ解析結果から 0 ~ 200 Hz の振動をオートエンコーダの入力とした。




図5 すくい面工具摩耗量

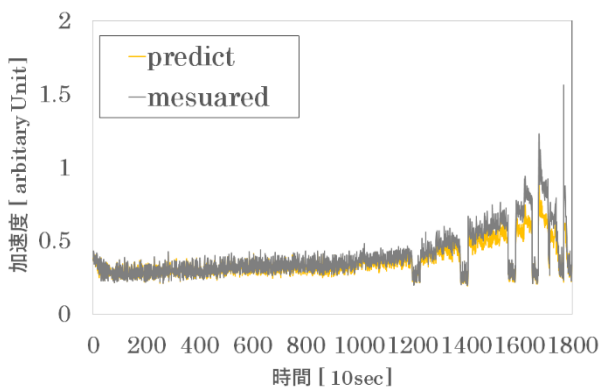


図 6 フェイスミル加工における加速度及びオートエンコーダ出力




図 7 フェイスミル加工における加速度の周波数解析結果




図 8 加速度測定値とオートエンコーダ出力の差分




図 9 フェイスミル加工における合成切削抵抗




図 10 合成切削抵抗とオートエンコーダ出力の差分

加速度の異常度を図 8 に示す。異常度は、限界工具摩耗量に近づくに従い上昇した。これは限界工具摩耗量付近では学習したデータの範囲を超える大きさの振動が発生しているために、オートエンコーダの再編成誤差が大きくなり、異常度が大きくなったためである。ゆえに限界工具摩耗量付近で正常と異常を識別できる可能性が示唆された。

3. 3 切削抵抗解析結果

合成切削抵抗の測定結果を図 9 に示す。合成切削抵抗は加速度と同様に工具摩耗に従い上昇し、最終的には約 5~6 倍に増加していた。合成切削抵抗の異常度を図 10 に示す。異常度は、限界工具摩耗量に達した付近で大きく上昇していた。これは学習したデータの範囲を超える大きさの加工負荷が発生した事に対して、異常度が大きくなったためであると考えられる。ゆえに工具摩耗量が一定値を超える付近で正常値と異常値を識別できることが示唆された。

3. 4 課題

本手法により、切削抵抗、加速度の周波数解析結果に閾値を設定することで、状態識別できる可能性が示唆されたが、本手法は様々な条件下での適用を想定しており、実際の加工においては、工具、切削条件、使用する装置などの条件の組み合わせで行われる。そのため使用環境に応じて適用可否を調べる必要がある。

4. まとめ

SUS306 材のフェイスミル加工において切削抵抗、加速度を測定し、オートエンコーダを用いて状態識別を行った結果、以下の事が得られた。

1. 加速度は、加工物の固有振動数の影響を除くために、周波数解析結果から工具回転周期の影響が表れる 0~200 Hz の範囲を抽出して、その結果に閾値を設定することで、正常と異常を識別できる可能性が示唆された。
2. 合成切削抵抗は、工具摩耗に伴いその値が増加した。限界工具摩耗量を閾値として設定することで、正常と異常を識別できる可能性が示唆された。
3. 本手法は、加工条件の異なる場合にも適用することを想定しているため、様々な使用環境においてその適用可否を調べる事が今後の課題である。

参考文献

- 1) 櫻田真由: “オートエンコーダを用いた次元削減による宇宙機の異常検知”, The 28th Annual Conference(2014)
- 2) 中塚 俊介ほか: “少数不良品サンプル下における Adversarial AutoEncoder による正常モデルの生成と異常検出”, 精密工学会誌, vol.84,

No.12 (2018)

- 3) IoT センサデータの分析: (一社) 広島県中小企業診断協会, ニューロビジネス研究会 (2018)
- 4) 新村諭ほか: “オートエンコーダを用いた工具摩耗の検知”, 長野県工業技術センター研究報告, No.12, p41-p44 (2017)
- 5) 古賀俊彦ほか: アコースティックエミッション法を用いた切削状態の監視に関する実験的検討、トライボロジスト, 第 63 巻 第 7 号(2018) 487~498
- 6) DK Maxime et al.: “Anomaly Detection in Orthogonal Metal cutting based on Autoencoder Method”, international Conference on Intelligent Systems, p485-493 (2018)
- 7) D.Kingma et al.: “Adam: A Method for Stochastic Optimization”, Proceedings of the international Conference on Learning Representations (2015), arXiv: 1412. 6980v9. Preprint, posted December 22, 2014

(本研究は、法人県民税の超過課税を財源としています。)