

時系列信号の HHT 解析及び異常検知への応用

茨城大学 ○濱津 武琉, ◎周 立波, 清水 淳, 小貫 哲平, 尾畷 裕隆, 金子 和暉

要 旨

製造業では突然の故障やメンテナンス後の立ち上げ不良の抑止などの対策として異常検知の需要が高まっている。その異常検知の手段として本研究では HHT (Hilbert-Huang Transform) と呼ばれる信号解析手法を活用することにより、時系列信号から得られた瞬間振幅と瞬間周波数を特徴量として画像化し、それを VGG16 と呼ばれる画像認識 CNN による学習を行う Deep Learning model を開発した。本報は、開発モデルを切削時の AE 信号に応用したときの異常検知処理結果を報告する。

1. 緒 言

現在の生産分野では、IoT(Internet of Things)による時系列データの収集、蓄積が進んでいる。これより異常検知について、これまでルールベース判定から、機械学習の手法によるアプローチが可能となった。本研究は、工作機械から取得した振動、抵抗などの時系列データから切削工具の摩耗などによって生じる異常を検出できる AI モデルの開発を目的としている。手法として時系列信号から特徴量を抽出するための信号解析手法として HHT 解析を適応し、解析結果を画像として VGG16 によって異常検知を行う。

2. HHT 解析と VGG16

HHT¹⁾は 1998 年に提案された比較的新しい解析手法であり、従来の解析手法に比べて高い時間分解能と周波数分解能を同時に有している。手法の説明のために、式(1)に示す 2 つの周波数成分を持つ正弦波を疑似データとして扱う。

$$x(t) = \sin(2\pi \times 6t) + \sin(2\pi \times 15t) \quad (1)$$

HHT は大きく分けて 2 つの処理があり、初めに EMD(Empirical Mode Decomposition)²⁾ と呼ばれる手法を用いて図 1 のように入力波形データを単純な固有振動モード(Intrinsic Mode Function : IMF) に分解する。EMD の操作によって $x(t)$ を式(2)のように表せる。

$$x(t) = \sum_{i=1} IMF_i + r(t) \quad (2)$$

ここで、 $r(t)$ は残差を表す。

次に、Hilbert Spectrum 解析(HS) と呼ばれる手法の説明をする。実関数 $X(t)$ の Hilbert 変換 $Y(t)$ は $X(t)$ と $1/\pi t$ の畳み込み(Convolution)で定義され、式(3)のように表せる。

$$Y(t) = X(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{X(\tau)}{t - \tau} d\tau \quad (3)$$

ここで、* は畳み込みで、積分はコーシーの主値積分である。複素信号となった解析信号 $Z(t)$ は式(4)で表される。

$$Z(t) = X(t) + jY(t) = a(t)e^{j\theta(t)} \quad (4)$$

ここで振幅 $a(t)$ と位相 $\theta(t)$ は式(5)と式(6)で求まる。

$$a(t) = \sqrt{X(t)^2 + Y(t)^2} \quad (5)$$

$$\theta(t) = \tan^{-1} \frac{Y(t)}{X(t)} \quad (6)$$

また、位相 $\theta(t)$ を微分して、式(7)のように瞬間周波数が求まる。

$$f(t) = \frac{1}{2\pi} \frac{d}{dt} \theta(t) \quad (7)$$




Fig.1 Decomposition by EMD




Fig.2 HS analysis




Fig.3 VGG16 architecture

上記 EMD で求めた各 IMF を HS 変換すれば、時系列信号 $x(t)$ から瞬間振幅と瞬間周波数を算出できる。さらに求めた瞬間振幅を週間周波数—時間平面に対してプロットすると、図 2 のようなカラーマップ化することができる。この解析結果を 224×224 ピクセルの画像として、図 3 に示す代表的な画像認識 CNN の一つである VGG16³⁾への入力にして機械学習を行う。

3. 切削実験と AE 時系列信号

表 1 に Inconel 718 の切削実験に使用した実験設備と切削条件を示す。図 4 には切削時に収集した AE 時系列信号の一例と対応する工具摩耗と切り屑の観察結果である。今回の切削条件では、新品の切削工具は、順に正常時、過渡期、異常時の 3 段階を経て、約 400sec 程度で寿命を迎えることとなった。

図 5 には、2 節で述べた HHT 手法で解析した瞬間周波数と瞬間振幅のカラーマップを示す。これを 0.2sec (2000 pixel) ごとに分割して、切削時間に比例した教師データ (Label ∈ [0, 1]) を与えて VGG16 による学習を行なった。学習条件を表 2 に示す。

4. AE 時系列信号に対する異常検知

学習が終了して完成したモデルに対して、もう一つの切削加工から得た AE 信号を同じように 0.2 秒ずつ区切り、それを入力としてテストを行う。テスト結果を図 6 に示す。

図 6 の上のパネルは VGG16 からの出力であり、下のパネルはその移動平均をとったものである。出力そのものでは異常度がばらついてしまっているが、移動平均のほうではある程度の異常度の傾向を検知できているといえる。

5. 結 言

本研究では HHT と VGG16 を組み合わせて、時系列信号から得られた瞬間振幅と瞬間周波数を特徴量として画像化し、CNN による学習を行う Deep Learning model を開発した。しかし実用化には精度が乏しく、専用の画像認識 CNN モデルを作り上げる等といった改善が必要であると考える。

参考文献

- 1) Huang, N. E., Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N. C. Yen, C. C. Tung, and H. H. Liu: The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis, 1998.
- 2) Hongjun Wang, Yongjian Ji: A Revised Hilbert–Huang Transform and Its Application to Fault Diagnosis in a Rotor System, 2018
- 3) Tinsy John Perumanoor, VGG16 とは何ですか？—VGG16 の概要, 2021
<https://ichi.pro/vgg-16-to-wa-nani-desu-ka-vgg-16-no-gaiyo-267001881294357>

謝 辞

本研究は、JST, A-STEP トライアウトタイプ(JPMJTM20KQ) と経済産業省、戦略的基盤技術高度化支援事業 JPJ005698 の助成を受けて行われたことを記して、謝意を表す。

Table.1 Cutting experimental setup and conditions

Experimental setup	
Machine tool	OKUMA, MULTUS B400 II
Cutting insert	Tungaloy, CNMG120412-HRM: AH8005
Workpiece	Inconel 718
Sensor	AE, Accelerometer, Strain gauge, Thermocouple, Sound
Sampling rate	10kHz
Cutting conditions	
Cutting speed	V = 60 m/min
Feed rate	f = 0.3 mm/rev
Depth of cut	d = 0.5 mm

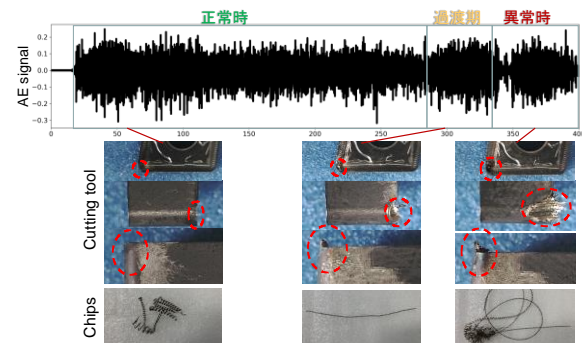


Fig.4 AE signal and corresponding tool wear




Fig.5 HHT analysis results of AE signal

Table.2 Conditions for training

Training : validation	1440 : 160
Epoch	10000
Batch size	64
Optimizer	SGD(lr=0.0001,momentum=0.9)
Activation function	ReLU




Fig.6 Anomaly score