

畳み込みニューラルネットワークを用いた キャビテーションの状態予測

日大生産工(院) ○劉 嘉辰 日大生産工 沖田 浩平

1. まえがき

油圧機器において、作動油の圧力が飽和水蒸気圧以下に低下することで気泡が発生するキャビテーション現象がある。この気泡が高圧域の材料壁面近傍で崩壊することで、材料が損傷（エロージョン）する事が問題になっている。動作中の油圧機器内部に生じるキャビテーションを把握するのは困難であるため、可視化せずにキャビテーションを検知する手法が必要である。

そこで、本研究では画像認識でよく用いられている畳み込みニューラルネットワーク（CNN: Convolutional Neural Network）で用いられる手法の一つであるVGG16を使用し、キャビテーション気泡の崩壊に伴って生じる機器外部壁面の振動から、機器内部のキャビテーションが発生しているかを予測する手法について検討を行った。

2. 実験方法¹⁾

油圧機器でキャビテーションエロージョン試験に用いた装置の概略図を以下のFig.1に示す。部品②から直径Dのノズルから流量Qで噴出した油のジェットに生じたキャビテーション気泡が、ノズルから噴流距離Lだけ離れた試験片の表面で崩壊する。その際に試験片表面が損傷する場合がある。実験条件として、流量Q、噴流距離L、下流圧Pdの3つを用いて実験を行った。




Fig.1 キャビテーションエロージョン試験装置の概略図

試験片の材料にはΦ15mm×15mmのアルミニウム（材質：A01070）を用いた。試験片の表面をUSBマイクロスコープで観測を行った。観測をすることで、試験片表面に損傷があればキャビテーションが発生しており、損傷がなければキャビテーションが発生していないということがわかる。

また、部品⑦に取り付けた加速度センサ（TEAC製圧電型加速度トランデュース702FB）で振動を取得し、データロガー（小野測器製DS-3000）を用いて振動データを記録した。


3. エロージョン試験結果

Table 1にキャビテーションエロージョン試験の実験条件を示す。流量Q=3.4, 4.4L/minと下流圧Pd=0.10, 0.20MPaの各2条件を組み合わせた計4条件となっている。噴流距離は全てL=10mmである。

各条件における試験片表面の様子をFig.2に示す。流量Q=3.4L/minのCase 1とCase 2の実験条件では、試験片表面にキャビテーションによる損傷が見られない。一方、Q=4.4L/minのCase 3とCase 4の実験条件では、試験片表面でキャビテーション気泡が崩壊し、崩壊した際の高圧力によって生じた試験片表面の小さな凹みが観察される。

Table 1 実験条件

Case No.	流量 Q[L/min]	上流圧 Pu[MPa]	下流圧 Pd[MPa]
1	3.4	2.0	0.10
2	3.4	2.0	0.20
3	4.4	4.0	0.10
4	4.4	4.0	0.20



Case1 Case 2 Case 3 Case 4
Fig.2 各実験条件での試験片表面

4. CNN による予測

4.1 CNNを構成している要素

CNNは主に画像認識の分野で応用されている手法であり, CNNを用いて多数の画像を学習して分類することができる²⁾. CNNによる画像分類では, 画像データを入力として複数の畳み込み層とプーリング層を経て結合層より画像のラベルが出力される. まず, 畳み込み層では, 画像の特徴を抽出するために, 入力画像データの行列と数 pixel × 数 pixel の Convolutional 行列の畳み込み演算が行われる. 次に, プーリング層では入力画像を特定の領域に分割し, その領域を一つに集約することで, 入力画像が圧縮され, 計算量が削減される. 最後に, 全結合層では活性化関数を用いて, 結果としてラベルが出力される.

本研究では, Pythonの開発環境として Google Colaboratory を使用し, CNNの手法である TensorFlow(version2.8.2)³⁾ の VGG16 を用いた. VGG16は, 16層からなるニューラルネットワークであり, 画像処理の研究でよく用いられる大量のカラー画像である ImageNet⁴⁾ を事前に学習させることで得られたパラメータを自分のモデルに活用できる. このため, 自分でニューラルネットワークを設計する必要がなく, ニューラルネットワークの構造の任意性を排除できる. また, 学習時間が高速できることや, データが少ない場合でも精度を向上できるメリットがある⁵⁾.

3.2 前処理

Fig.3に一例として, Case 1の実験条件における振動データのパワースペクトルを示す. 加速度センサで得られた時間信号を, 高速フーリエ変換(FFT)で周波数信号に変換した. パワースペクトル値は, 0~40kHzの範囲で50Hz間隔の合計800個ある. 周波数が10kHzと23kHz付近でパワースペクトル値のピークとなることがわかる.

CNNの手法としてVGG16を利用するために, 入力データとして画像が必要になる. そのため, 振動データのパワースペクトル値を画像化するための前処理として3つの方法について検討した.

第一の前処理方法は一次元データの画像化である. 800個あるパワースペクトル値のベクトルA

$$A = (a_1 \quad a_2 \quad \cdots \quad a_{800}) \quad (1)$$




Fig.3 振動データのパワースペクトル (Case 1)



Fig.4 10×80pixelのパワースペクトル画像 (Case 1)




Fig.5 パワースペクトルのグラフ画像 (Case1)




Fig.6 時間信号のグラフ画像(Case1)

を次式のような10×80の二次元行列に変換して画像化を行った.

$$A_{10,80} = \begin{pmatrix} a_1 & a_2 & \cdots & a_{80} \\ a_{81} & a_{82} & \cdots & a_{160} \\ \vdots & \vdots & \ddots & \vdots \\ a_{721} & a_{722} & \cdots & a_{800} \end{pmatrix} \quad (2)$$

画像化には、Pythonの画像処理ライブラリであるPillow⁶⁾を用いた。Fig.4に解像度が10×80pixelの画像に変換した画像を示す。画素が白いほどパワースペクトル値が高く、黒いほど低くなっている。

第二の前処理方法は、パワースペクトル値のグラフ画像を、直接VGG16の画像入力データにするものである。Fig.5に、Case 1の実験条件におけるパワースペクトルのグラフ画像を示す。全てのデータに対して同じ軸範囲でグラフ化し、不要な軸ラベルは排除している。画像解像度は288×432pixelであり、第一の前処理手法よりも入力画像のデータ量が増加している。

第三の前処理方法は、パワースペクトルの周波数信号を逆フーリエ変換(IFT)によって時間信号に逆変換したグラフ画像をFig.6に示す。画像解像度は288×432pixelである。

第二と第三の前処理方法では、第一の方法と違ってグラフ画像をそのままVGG16の入力データ画像として学習した。グラフ画像を用いた理由は、人間がグラフからその特徴を抽出するのと同じように、CNNによって特徴抽出されないかと考えたためである。一方、1次元データの画像化に比べて、グラフ画像を入力データとすると特徴量が増加し、分類精度が向上することを期待した。

以上、3つの前処理方法において、キャビテーションエロージョンの有無をラベルとした訓練データ用の画像を640枚、テストデータ用の画像を160枚の合計800枚を入力データ画像として、VGG16で教師あり学習を行った。

4. 実験結果

10×80pixelのパワースペクトル画像、パワースペクトルのグラフ画像および時間信号のグラフ画像を入力データとしてVGG16で学習した際の結果として、正解率と損失をそれぞれ、Table 3, 4および5に示す。表より、10×80 pixelのパワースペクトル画像の正解率76.2%に対し、パワースペクトルのグラフ画像と時間信号のグラフ画像の正解率は85.0%と98.8%となった。パワースペクトル値を二次元行列に変換した画像より、グラフ画像にした方が正解率の向上が見られたのは、入力データの形状が大きくなることで、VGG16で学習できる特徴量が多くなったからだとわかった。

5. まとめ

Table 3 10×80 pixelのパワースペクトル画像での学習結果

	訓練データ	テストデータ
正解率(%)	76.7	76.2
損失	0.493	0.421

Table 4 パワースペクトルのグラフ画像での学習結果

	訓練データ	テストデータ
正解率(%)	75.3	85.0
損失	0.514	0.374

Table 5 時間信号のグラフ画像での学習結果

	訓練データ	テストデータ
正解率(%)	86.3	98.8
損失	0.309	0.0694

キャビテーションエロージョン試験における振動データからエロージョンの様相を予測するため、CNNによる分類について検討をした。その結果、10×80 pixelのパワースペクトル画像で学習したテストデータの正解率は76.2%、パワースペクトルのグラフ画像で学習したテストデータの正解率は85.0%、時間信号のグラフ画像で学習したテストデータの正解率は98.8%となった。これらのことより、パワースペクトルを二次元配列してVGG16に学習させるより、グラフ画像にしてからVGG16に学習させた場合の正解率が高くなることがわかった。

参考文献

- 1) 山田翔太, 本田匠, キャビテーションにおける壁面振動と壊食の関係, 平成30年度日本大学生産工学部機械工学科卒業論文(2019)
- 2) 我妻幸長, あたらしい人工知能技術の教科書 機械学習・深層学習・強化学習で学ぶAIの基礎技術, 翔泳社(2021) p.214
- 3) <https://www.tensorflow.org/> (参照 2022-10-12)
- 4) <https://www.image-net.org/> (参照 2022-10-12)
- 5) 杉山聡, 本質を捉えたデータ分析のための分析モデル入門, ソシム, (2022) p.129
- 6) <https://pillow.readthedocs.io/en/stable/> (参照2022-10-8)