

# 機械学習を用いたキャビテーションエロージョンの予測

日大生産工(院) ○大石 翼 日大生産工 沖田 浩平

## 1. 緒言

油圧制御バルブ等の油圧機器においてキャビテーションエロージョンによる材料損傷が問題となっている。機器内部で圧力が飽和蒸気圧より低下することで生じたキャビテーション気泡が、成長した後高圧域で急激に崩壊する。材料壁面近傍でのキャビテーション気泡の崩壊は材料の損傷を生じ、この損傷が進展して製品寿命の低下を引き起こす。このため、動作中の機器内部に生じるキャビテーションの把握が必要であり、可視化によらないキャビテーションの検知手法が求められている。

本研究では、キャビテーションによる材料損傷の予測を目的として、キャビテーション気泡の崩壊によって生じる装置壁面の振動のデータから機械学習によってキャビテーションエロージョンを予測する方法について検討した。

## 2. 実験方法<sup>1)</sup>

油の噴流キャビテーションエロージョン試験に使用した装置の概略図をFig.1に示す。部品②のノズルから噴出したジェットに生じたキャビテーション気泡が試験片表面で崩壊することによって生じる材料損傷に伴う試験片の質量変化を計測し、材料表面の観察を行った。なお、試験片の材料にはアルミニウム(材質: A1070)を用いて、形状は $\Phi 15\text{mm} \times 15\text{mm}$ である。実験条件は流量 $Q$ 、噴流距離 $L$ および背圧 $P_d$ をパラメータとして行った。

キャビテーション気泡の壁面近傍での崩壊を把握するため、エロージョン試験において、装置壁面に生じる振動を部品⑧の加速度センサ(TEAC製圧電型加速度トランスデューサー702FB)で取得し、データロガー(小野測器製DS-3200)で記録した。

## 3. 機械学習による予測

近年、機械学習が様々な分野で注目を浴びており、既知のデータを学習させることで未知のデータを識別・分類することができる。本研究では、前述の噴流キャビテーションエロージョン試験で取得された振動データに対して機械学習を適用した。




Fig.1 キャビテーションエロージョン試験装置の概略図




Fig.2 各流量における振動データのパワースペクトル値の平均と分散 ( $L=5\text{mm}$ ,  $P_d=0.1\text{MPa}$ )

機械学習では、特徴量とラベルのペアを学習データとして、未知のデータをラベル分類する教師あり学習と、データの特徴に基づいてクラスタリングする教師なし学習があり、本研究では振動データを特徴量、実験条件をラベルとした学習データによる教師あり学習を採用し、分類のアルゴリズムにはSVC法<sup>2)</sup>を用いた。なお、機械学習のコード開発環境は、anaconda (Python3.8)のJupyter Notebookで、機械学習パッケージであるscikit-learnを利用した。ここで、噴流キャビテーション試験において取得された振動データ群の例として、噴流距離 $L=5\text{mm}$ および背圧 $P_d=0.1\text{MPa}$ における各流量 $Q$ に対するパワースペクトル値の平均と分散をFig.2に示す。図より、流量が増加すると、パワースペクトルの値が大きくなっていること、また、8kHz、28kHz付近にピークが存在することがわかる。各条件のデータ数は200個で



(a)3.4L/min (0.15mg) (b)4.4L/min (0mg) (c)5.4L/min (0.9mg)

Fig.3 各流量における試験片表面の様子 (L=5mm, Pd=0.1MPa, 括弧内は壊食量)

Table 1 学習データの実験条件

| Case No. | 噴流距離 L(mm) | 背圧 Pd(MPa) | 流量 Q(L/min)   |
|----------|------------|------------|---------------|
| 1        | 5          | 0.1        | 3.4, 4.4, 5.4 |
| 2        | 10         | 0.1        | 3.4, 4.4, 5.4 |
| 3        | 5,10       | 0.1        | 3.4           |
| 4        | 5,10       | 0.1        | 5.4           |
| 5        | 5,10       | 0.1        | 3.4,4.4,5.4   |

あり,これを学習用とテスト用に分けて機械学習に用いた.

#### 4. 実験結果および考察

キャビテーションエロージョン試験の結果として, 噴流距離L=5mm, 背圧Pd=0.1MPaの場合の各流量における試験片表面の様子をFig.3に示す. 図より, Q=3.4L/minでは切削面が残っており, Q=4.4L/minでは表面にピットが確認できるが, どちらも顕著な壊食はみられない. これに対して, Q=5.4L/minでは環状に試験片表面が壊食されていることがわかる. 以下では, 試験片表面の壊食の有無を含む実験条件に対して機械学習による分類を行った.

ここで, 学習データに用いた実験条件についてTable.1に示す. 表において, 例えばCase 1では, L=5mmおよびPd=0.1MPaで流量Q=3.4, 4.4, 5.4L/minの3条件に対して機械学習による分類を行った.

計測で得られるパワースペクトル値は0~40kHzの範囲を50Hz間隔で出力されており, すべてのデータを特徴量した場合, 過学習になる可能性がある. そこで, 特徴量として抽出する周波数刻みとモデルの汎化性能についてk-分割交差検証を適用し, 交差検証を行った結果をFig.4に示す. 特徴抽出の周波数間隔が1,000~10,000Hzと大きくなるにつれて, 実験条件による分類の正答率が96%から87%まで低下している. また, 交差検証による正答率のバラツキについては, 4000Hz間隔で最も大きく, 1000Hz間隔が最も小さくなった. 以上より, 1000Hz間隔で特徴抽出するのが適していることがわかったため, 以降の学習データについては1000Hz間隔で抽出した特徴量を採用した.




Fig.4 特徴量の抽出条件による交差検証結果(Case 1)

Table 2 Case 1に対する分類の混合行列

| Q(L/min) | 3.4 | 4.4 | 5.4 |
|----------|-----|-----|-----|
| 3.4      | 40  | 0   | 0   |
| 4.4      | 0   | 35  | 5   |
| 5.4      | 0   | 1   | 39  |

Table 2にCase 1に対する分類に関する混合行列を示す. Q=3.4と5.4L/minのテストデータ40個はそれぞれ3.4L/minとして40個, 5.4L/minとして39個が正しく分類されているが, Q=4.4L/minでは35個が4.4L/min, 5個が5.4L/minと分類された. ここで, Case 1の学習データであるFig.2を見ると, Q=4.4L/minと5.4L/minのパワースペクトルは平均値に違いがあるものの, 形が似ており, 分散の影響を考えると4.4L/minの振動データが5.4L/minとして分類されたと考えられる.

#### 5. まとめ

キャビテーションによる材料損傷の予測を目的として, 噴流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に対して, 実験条件をラベルとした教師あり学習による分類を行った. その結果, 流量による条件の違いを高精度に分類できることがわかり, 可視化によらないキャビテーション検知の可能性が示された.

発表では, 噴流距離や背圧条件などによるCase 1以外の分類結果についても報告する.

#### 参考文献

- 1) 本田匠, 山田翔太, 油の噴流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) 秋庭伸也, 杉山阿聖, 寺田学, 見て試してわかる機械学習アルゴリズムの仕組み 機械学習図鑑(2019), p.148-153