

# ニューラルネットワークを用いた音響診断によるポンプ異常の検出

Detection of abnormality of pumps by acoustic diagnosis using neural network

株式会社 IIU 角皆 学 Manabu Tsunokai Member  
 株式会社 IIU 高瀬 健太郎 Kentaro Takase Member  
 株式会社 IIU 萱田 良 Ryo Kayata Member

A method that applies the neural network to acoustic data to detect abnormalities of horizontal pumps is proposed. In the experiments, running sound of a pump with bearing damage or misalignment was acquired from various distance while another pump in the same room was running or not running as a possible noise source. By applying the neural network to the appropriately processed frequency spectrum of acquired data, abnormality can be accurately detected regardless of the distance between the sensor and the pump or presence of noise. Learned neural networks also showed high interpolation and extrapolation characteristics to magnitude of abnormality and the distance. In addition, by combining the learned neural networks for each of the bearing abnormality and the misalignment, the state of the pump was accurately identified.

**Keywords:** Neural network, Acoustic diagnosis, Condition monitoring, Pump, Bearing, Misalignment

## 1. 背景

日本保全学会では平成 18 年度以降「状態監視技術の高度化に関する調査検討分科会 (CMT 分科会)」を設置し、海外調査、文献調査、検証・確認試験等を通じて状態監視技術及び状態基準保全に対する様々な調査、検討を行ってきた。平成 28 年度の CMT 分科会技術ワーキンググループは、プラントの広範囲を効率的に監視する技術の検討をテーマとしており、本研究はそのような技術の候補の 1 つと考えられる音響診断の高度化を目指し、実験データの取得及び分析・検討を行ったものである。

で、それぞれの状態について、音響センサの位置を 4 通り変化させるとともに、同じ室内にある別のポンプ（以下ポンプ 2 と呼ぶ）の運転・停止状態を変化させて音響データを取得した。全試験条件の一覧を表 1 に、試験環境の模式図を図 1 に示す。音響センサの位置 P1～P4 におけるカッコ内の数値は評価対象のポンプ（以下ポンプ 1 と呼ぶ）と音響センサとの距離を示している。なお、内輪傷はグラインダーによる切削加工、ミスアライメントはモーターと基礎の間に薄板を挟むことにより付与している。

表 1 試験条件

軸受異常試験			ミスアライメント試験		
状態	音響センサの位置	ポンプ2の状態	状態	音響センサの位置	ポンプ2の状態
正常1	P1 (0.16m)	停止	内輪傷小	P1 (0.16m)	停止
		運転		P1 (0.16m)	運転
	P2 (0.63m)	停止		P2 (0.63m)	停止
		運転		P2 (0.63m)	運転
正常2	P3 (1.48m)	停止	ミスアライメント大	P3 (1.48m)	停止
		運転		P3 (1.48m)	運転
	P4 (2.61m)	停止		P4 (2.61m)	停止
		運転		P4 (2.61m)	運転

## 2. 横型ポンプ異常模擬試験

プラント内の主要な機器である横型ポンプを対象とし、軸受異常およびミスアライメントを付与して運転し、音響データを測定した。

### 2.1 試験条件

ポンプの状態は分解組み立てを挟んだ正常 2 種類、軸受内輪傷 2 種類、ミスアライメント 2 種類の、計 6 通り

連絡先: 角皆学、〒110-0008 東京都台東区池之端  
 2-7-17 井門池之端ビル、電話 03-5814-5350  
 E-mail:tsunokai@iiu.co.jp




図 1 試験環境模式図

## 2.2 測定条件

音響データは、サンプリングレート 20kHz、サンプリング時間 1 秒で、各試験条件につき 10 回収録を行った。

## 3. 簡易分析結果

各試験条件における音圧 RMS の平均値を図 2 に示す。本測定結果における音響センサの RMS は以下の要因で変化している。

- ・ポンプ 1 からの距離が遠くなると小さくなる傾向がある。
- ・軸受傷やミスアライメントが存在すると大きくなる傾向がある。
- ・ポンプ 2 の運転中は大きくなる傾向があり、その増加量はポンプ 2 に近い程大きい。

これらの要因は重畳して RMS に影響を与える為、正常と異常を分離する様な測定位置及びポンプ 2 の運転・停止によらない「単一の閾値」を設定する事は出来ない。

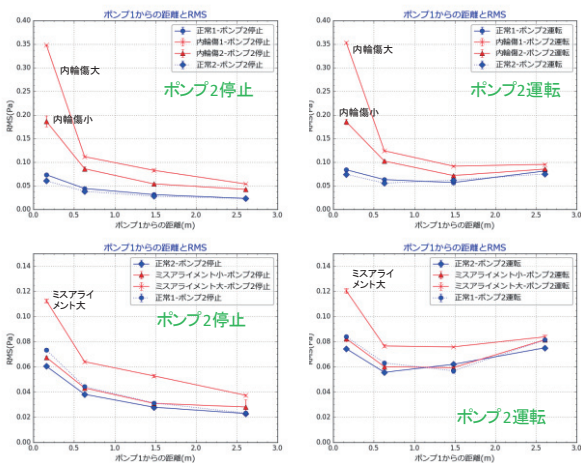


図 2 条件ごとの音圧 RMS の平均値

## 4. ニューラルネットワークの適用

前項に示したように、単純な音圧レベルの評価では正常・異常を判別することはできず、より高度な手法が必要である。ここでは音響データにニューラルネットワークを (NN) 適用し、センサと音源との距離やノイズの有無によらず正常・異常の判別が可能な手法を検討する。

### 4.1 手法の概要




図 3 手法の概要

音響センサによる測定では音源からの距離が遠くなれば信号は小さくなるが、本検討では音源からの距離によらない判定を行うことを目指し、信号を予め RMS によって規格化した。さらに FFT または軸受診断に一般的に用いられる Envelope-FFT 処理を施した後、最後に周波数分解能を落としてデータを圧縮 (短冊ベクトル化) して入力データとした。

それぞれの条件のデータは「学習用データ」と「検証用データ」に分け、各試験条件に対する 10 回の測定の内、1~6 回目の測定結果を学習用、7~10 回目の測定結果を検証用データとした。

### 4.2 軸受傷の評価

#### 4.2.1 正常と異常の判別

まず軸受異常試験のみの評価を行った (正常 1、内輪傷小、大の 3 条件)。図 4 に学習の繰り返し回数に対する正常・異常の正解率のグラフを示す。学習は乱数を使って行われ、結果は試行の度にばらつくため、100 回の学習の平均をプロットしている。2 つのグラフは学習の際にドロップアウトを使用したか否かの違いである。ドロップアウトは学習の際にニューロンをランダムで消去する手法で、これによりモデルが学習用データのみにも最適化しすぎる (過学習) を防ぎ、学習に使用されていないデータに対しても、正しい判定が行える性能 (汎化性能) の向上が期待できる。

ドロップアウトを使用しない左図の場合、早い段階で検証用データの正解率が 0.986 程度で飽和しているのに対し、ドロップアウトを使用した右図では、検証用デー

タの正解率は 2000 回の繰り返し回数まで上昇し続け、0.998 まで達しており、汎化性能が向上していることが分かる。

以上から、内輪傷については高い精度で、音源からの距離やノイズの有無によらず異常判定が可能であり、ドロップアウトを適用することでさらに精度を高めることが出来ると言える。




図 4 軸受異常試験の評価

## 4.2.2 内外挿性の評価

### (1) 傷に対する外挿性

傷の大きさに対する NN の外挿性を評価した。ここで言う外挿性とは、小さな軸受傷のみを異常として学習させた NN が、それよりも大きな軸受傷を異常と判定できることを意味する。表 2 に傷大のデータを除外して学習させた NN で、傷大のデータを評価した際の正解率を示す。数値は 100 回の学習の正解率の平均値で、カッコ内はその標準偏差である。入力データとして 1kHz 以上のハイパスフィルタを施した後エンベロープ処理を行った FFT (Envelope-FFT)、FFT、1.5kHz 以上をハイパスした FFT の 3 種類を評価している。いずれの場合も 0.9 以上の高い正解率で内輪傷大データを異常と判定しており、学習された NN が内輪傷に対して高い外挿性を有していることを示している。

表 2 内輪傷大を除外して学習した NN による評価結果(正解率)

入力	学習から除外して評価した傷
	内輪傷 大傷の大きさに関する「外挿性」
Envelope-FFT	0.997 (0.014)
FFT	0.941 (0.193)
FFT (1.5kHz以上)	0.956 (0.126)

### (2) 距離に対する内外挿性

音源からの距離に対する NN の内外挿性を評価した。

距離に対する外挿性とは、例えば最も遠い P4 のデータを除外して学習した時に、P4 のデータを正しく判定可能か、ということであり、内挿性とは、遠い距離と近い距離のデータのみで学習した際に、中間の距離で取得したデータを正しく判定可能かということを意味している。表 3 に各測定箇所データを除外して学習した NN を用いて、その除外した測定箇所のデータを評価した場合の判定の正解率を示す。ほとんどの場合で 0.9 以上の正解率であるが、入力が FFT の場合の P4 に関する外挿性は 0.709 と、比較的低い値になっている。これは、P4 はノイズ源であるポンプ 2 に最も近いこと、さらにポンプ 2 のノイズの主要な周波数帯が 1kHz 以下の領域に

学習された NN が距離に対して高い内外挿性を持っていることが分かる。

表 3 各距離を除外して学習した NN による評価結果(正解率)

入力	学習から除外して評価した位置			
	P1(0.16m) 距離に関する「外挿性」	P2(0.63m) 距離に関する「内挿性」	P3(1.48m) 距離に関する「内挿性」	P4(2.61m) 距離に関する「外挿性」
Envelope-FFT	0.994 (0.017)	0.992 (0.020)	0.982 (0.036)	0.930 (0.073)
FFT	0.929 (0.095)	0.982 (0.043)	0.977 (0.053)	0.709 (0.120)
FFT(1.5kHz以上)	0.904 (0.126)	0.992 (0.039)	0.972 (0.062)	0.982 (0.044)

## 4.3 ミスアライメントの評価

### 4.3.1 周波数帯の影響

次にミスアライメント試験のデータのみ(正常 2、ミスアライメント小・大)を用いて評価を行った。ミスアライメント等の構造系異常は、軸受異常と異なり低周波領域に変化が現れるため、低周波領域のみの周波数スペクトルを入力とした。図 5 に 0~500Hz 及び 0~2000Hz を入力とした場合のそれぞれの評価結果を示す。0~500Hz の方が、高い精度でミスアライメントの有無の判定が可能であることが分かる。




図 5 ミスアライメント試験の評価





内輪傷 小			内輪傷 大			
	軸受傷NN		ミスアライメントNN	軸受傷NN		ミスアライメントNN
	Env-FFT	FFT_H		Env-FFT	FFT_H	
軸受傷小×32回測定	100	100	0	100	100	1
	100	100	1	100	100	0
	100	100	0	100	100	2
	100	100	0	100	100	0
	100	100	0	100	100	1
	100	100	0	100	100	13
	100	100	0	100	100	1
	100	100	0	100	100	0
	100	100	0	77	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	1	100	100	0
	100	100	7	100	100	0
	100	100	0	100	100	77
	100	100	0	100	100	40
	100	100	2	100	100	15
	100	100	0	100	100	16
	100	100	0	100	100	64
	100	100	0	100	100	66
	100	100	0	100	100	74
	100	100	0	100	100	52
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	6	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
	100	100	0	100	100	0
100	100	0	100	100	0	
100	100	0	100	100	0	

(b)軸受傷データ

ミスアライメント 小			ミスアライメント 大			
	軸受傷NN		ミスアライメントNN	軸受傷NN		ミスアライメントNN
	Env-FFT	FFT_H		Env-FFT	FFT_H	
軸受傷大×32回測定	0	0	100	18	1	100
	0	0	100	21	0	100
	0	0	100	25	1	100
	0	0	100	17	1	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	3	0	100
	0	0	100	1	0	100
	0	0	100	0	1	100
	0	0	100	1	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	22	1	100
	0	0	100	23	1	100
	0	0	100	21	2	100
	0	0	100	21	1	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100
	0	0	100	0	0	100

(c) ミスアライメントデータ

図 8 NN の組み合わせによる状態の識別

### 5 まとめ

本研究では、ポンプに軸受異常やミスアライメントを与え、音響データを取得する試験を行った。音響データはノイズや音源からの距離に影響を受けるため、単純な音響信号レベルのみから正常と異常を識別することは不可能であった。これに対し、音響データに適切な前処理を施しニューラルネットワークを適用することで、距離・ノイズの有無によらず、高い精度で正常・異常の判定が可能となった。また学習された NN は、傷の大きさや距離に対して高い内外挿性を有していることが示された。これは本研究で用いた NN が単層のシンプルなネットワーク構成であることに起因していると考えられる。

また軸受傷・ミスアライメントそれぞれのデータで学習を行った NN を組み合わせ、同一学習データから生成された異なる複数の NN による判定の多数決を採用する手法により、明確な状態の識別が可能であることが示された。

### 参考文献

[1] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting", The Journal of Machine Learning Research, 2017, pp.1929-1958