

下水道設備の異常検知に資する 動作音計測と解析に関する基礎研究

中日本建設コンサルタント(株)

○ 長谷川 孝, 小川 真澄
中根 進

1. はじめに

終末処理場等の維持管理では、通常、毎日あるいは週に数回の頻度で計器の指示値確認のほか、技術者の五感（音、熱、振動、臭い等）を介した巡視点検を行っている。

本研究では、巡視点検の質の平準化や向上の観点から、巡視点検時に確認する「音」に着目し、機器の動作音を計測、また数値化することで、その特徴量から異常検知の可能性を探ることを目的とする。ここでは、処理場実機器の動作音計測と解析に先立ち、単相 100V-30W の電動機（写真 1.1）を用いた動作音を計測と解析により、特徴量による異常検知が可能か、また AI による機械学習を活用した異常検知が可能か等の基礎的研究を行っている。



写真 1.1 電動機(単相 100V30W)



写真 2.1 電動機(偏心回転負荷)

2. 電動機を用いた計測

単相 100V-30W の電動機に回転負荷を掛け運転し常時状態とし、偏心回転負荷（写真 2.1）を掛けた運転を異常時と想定し、動作音を計測する。サンプリング周波数は 44.1kHz、振幅方向のサンプル分割数は 16 ビットである。

動作音は 20 sec 間で測定したが、処理場における実機に対する定期的な計測を想定し、この計測音を 5 つに分割して定期的に計測したものとする。20 sec 間の電動機の計測音の波形は図 2.1 および図 2.2 であった。




図 2.1 正常時の信号波形





図 2.2 異常時の信号波形

3. 動作音の特徴量の抽出

動作音の特徴量として i 波形(振幅), ii スペクトrogram(中心周波数), iii 音圧レベルを抽出し、正常音と異常音の比較を行う。

3.1 波形(振幅)

正常音を例として ($t = 1 \sim 3 \text{sec}$) の特徴量を示す。振幅を図 3.1 に示すが、その振幅が複数の正規分布で構成されているかを統計用語 R とそのライブラリ mclust を使って調べる。ライブラリ mclust を使うと成分の数は図 3.2 として出力される。

図 3.1 正常音の波形
($t = 1 \sim 3 \text{sec}$)

図中の凡例は、以下である。

E : 各流出成分で分散を共通とするモデル

V : 各流出成分で分散が異なるとするモデル

BIC : ベイズ情報量規準(Bayesian Information Criterion)

成分数 1 つ(横軸)の BIC 値が最大であり、振幅は 1 つの分布で表わせ、特徴的な成分の分布は含まれない。また、振幅の周期性を図 3.3 の振幅コレログラムから調べ、周期性を 23 とし、振幅を成分分解すると図 3.4 を得る。成分分解から特徴として表れやすい不規則変動振幅を図 3.5 に分布で示す。




図 3.3 振幅コレログラム (t = 1~3sec)




図 3.4 波形の成分分解 (正常時 t = 1~3sec)




図 3.2 振幅分布の成分数 (t = 1~3sec)




図 3.5 不規則変動振幅分布 (正常時 t = 1~3sec)

3.2 音圧レベルのスペクトログラム

FFT 解析より、図 3.6 にあるスペクトログラムを得る。スペクトログラムは時間経過ごとの周波数による音圧レベルが視覚的に色で明示されているが、図 3.7 のスペクトル分布の中心周波数を計算し、特徴量とする。




図 3.6 スペクトログラム (正常時 t = 1~3sec)

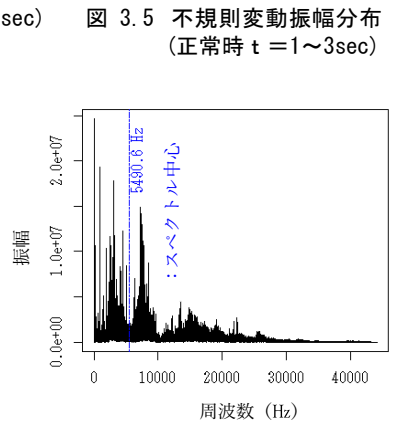


図 3.7 スペクトル分布と中心周波数 (正常時 t = 1~3sec)

4. 特徴量の比較

計測期間中の動作音の振幅の分布を図 4.1 に、成分分解した正常時と異常時の不規則変動振幅の分布を合わせた分布を図 4.2 に示す。この振幅分布では明確な差は認められず、振幅からは異常を検知することができなかった。

定期的な計測を想定した計測音 (2sec 毎の分割) をフーリエ変換し




図 4.1 正常時と異常時の振幅分布




図 4.2 正常時と異常時の不規則変動振幅の分布

分割した時間毎の周波数と振幅の関係から周波数の中心(重心)を求め、スペクトルの中心周波数分布を作成した。正常時と異常時を比較すると図 4.3 となり、分布に差が認められた。また、フーリエ変換のスペクトル中心周波数の分布に差があることから、中心周波数と音圧レベルの関係をみるために 1/3 オクターブ分析を行い、正常時と異常時の比較を行っている。この結果は図 4.4 のとおりであり、正常時と異常時では周波数 2000Hz あたりに差がみられた。

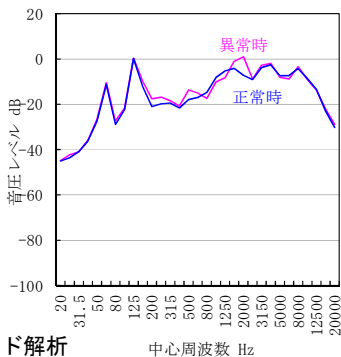


図 4.4
1/3 オクターブバンド解析
(正常時 t = 1~3sec : 異常時 t = 17~19sec)




図 4.3 正常時と異常時のスペクトル中心周波数の分布




図 5.1 正常時と異常時のスペクトル分布

5. One class SVMによる異常検出

異常データはほとんどなく、機器の特性も多種多様と考えられることからモデリングすることが難しいが、今回の事例ではスペクトログラムに差が認められたので、AI 学習の1つである One class SVM(ワンクラスサポートベクターマシン)を使って検出する方法を考える。

フーリエ変換で得られた図 5.1 のスペクトル値に対数を取り、正常時のデータ間で外れ値のない




図 5.2 正常時の間の外れ値検出(外れ数 25/66141)




図 5.3 正常時と異常時間の外れ値検出(外れ数 72/全数 66141)

パラメータを設定する。このパラメータでは、正常時で外れ数が 25 個(図 5.2)に対し、正常時と異常時では外れ数が 72 個(図 5.3)に増加する。正常時のデータを使ってパラメータを設定することにより、異常を検知できると考えられる。なお、設定に用いたパラメータを次に示す。パラメータ: $\sigma = 0.002$ 、 $\nu = 0.0001$

6. まとめ

今回の計測事例の異常は想定したものであるが、動作音の特徴量として正常時と異常時ではスペクトルの中心周波数の分布に差がでること、2,000Hz あたり中心周波数に差があることを明らかにし、定期的にそれら特徴量を比較することにより異常を検知できる可能性を示すことができた。また、定期的に取得するフーリエ変換で得られたスペクトルの対数値から AI 学習によって正常時のデータ間の関係をパラメータで設定し、定期的に比較することによって異常を検知できる手法も示すことができた。異常時の動作音の特徴は不明であるため、本稿では異常を検知できなかった特徴量も棄却できないと考えらえる。

問合わせ先: 中日本建設コンサルタント(株) 事業推進室 長谷川 孝, 水工技術本部 中根 進

お問い合わせフォーム: <https://www.nakanihon.co.jp/contact/index.html>