

機械設備の AI を活用した異常検知について

(国研) 土木研究所 寒地土木研究所 寒地機械技術チーム ○平地 一典
永長 哲也

河川に設置されている機械設備は、洪水被害防止の基盤設備である。しかしながら、近年、設備の老朽化の進行により、故障による稼働停止が懸念され、効率的で効果的な維持管理が求められている。そこで、実排水運転時の運転データを元に、機械学習等の AI アルゴリズムによる異常検知モデルを試作し、このモデルによる異常検知性能の検証を行ったので報告する。

キーワード：機械設備、異常検知、機械学習、AI

1. はじめに

河川に設置されている排水機場ポンプ設備等(写真-1)の機械設備は、洪水被害防止を目的に設置された極めて重要な社会基盤設備であり、豪雨や異常出水時には確実に稼働することが要求される。そのためには設備の万全な整備が不可欠であり、これまで管理者は、定期的に整備する「時間計画保全」の考え方で維持管理を実施している。この手法は、確実な整備が行えるという点でメリットが大きいですが、内部劣化の有無によらずに定期的に整備を行うため、経済的で不利な場合がある。さらに排水機場においては、設置後 40~50 年経過した設備も増加傾向にあり、老朽化の進行による故障頻度上昇の懸念がある反面、整備予算は厳しい状況にある。

そこで、この相反する状況下で効率的で的確な設備維持管理を行うため、土木研究所先端技術チームが中心となり、常用系設備で導入されている「状態監視保全」を「非常用設備」である排水機場ポンプ設備の維持管理において導入するための研究を進めている¹⁾。適切な状態監視保全を行うには、設備の状態を把握するための様々な計測データが必要であり、これまでは、排水機場の管理運転による月・年点検時の短い運転時間のスポットデータを計測し、専門的な知識や解析ツールを用いて診断を行う傾向管理が主流であった。しかし、平時は水量不足で定格運転に達しない場合や計測のための十分な運転時間が確保できないケースもある。そこで、設備の定格運転時の正確な状態を把握するため、常設センサを設置し、実排水運転時の定格運転データを自動取得することで、設備の状態を時系列データで監視できる状態監視モニタリングシステムを構築した。更に取得した実排水運転時の時系列データを元に、機械学習等の AI アルゴリズムによる異常検知モデルを試作し、このモデルによる異常検知性能の検証を行ったので報告する。



写真-1 排水機場全景

2. 分析データの生成

(1) 疑似異常データの生成

機械学習には様々な AI が含まれるが、一般的には、多くのデータを入力された AI が入力されたデータの背後にある本質的なパターンを見つけ出す仕組みであるとされている。また、入力されるデータによって教師あり・なし学習として大別され、教師ありの場合は、正解データを、機械設備においては正常な稼働時の計測データを AI に与え、そのデータからパターンを学習し、分析モデルを構築する。その分析モデルを軸とすることで、正常か異常かわからない計測データの判断を AI によって決定することが可能となる。教師なしの場合は、正常か異常かわからないデータを大量に AI へ入力することで、AI はそれらのデータに共通する特徴を自ら学習し、グループ分けを行う。そうすることで、分析を行う計測データについて、それがどのグループに分けられるのか判断可能となる。

今回の検討で対象としている機械設備では、設備の特

性上、継続的な計測データの収集や特に異常データの収集は非常に困難である。そこで、AIの教師データを生成するため計測データを元にした疑似異常データの一例をポンプ主軸異常とポンプ本体異常について生成した。本報告の分析フローを図-1に示す。

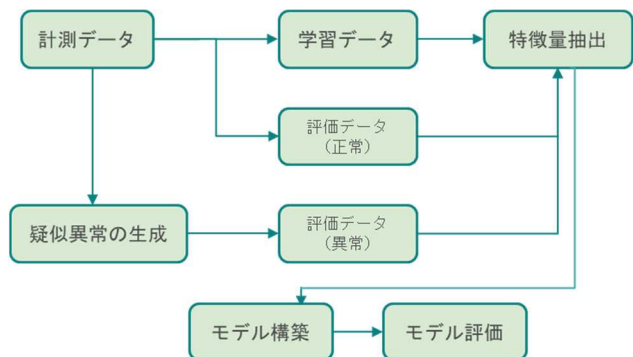


図-1 分析フロー図

(2) 振動理論による疑似異常データの生成

状態監視モニタリングシステムで収集したポンプ主軸の計測データを周波数解析し、生成した加重平均パワースペクトルから、卓越周波数とその振幅を算出した。振動理論²⁾の定義に従う異常種別毎の周波数振幅幅の正弦波を計測データに重ね合わせて疑似異常データを生成した。ミスアライメントの疑似異常データ生成過程の1例を示す。

図-2は計測した正常な時系列波形で、図-3は正常波形をFFT解析したパワースペクトルである。この波形に異常正弦波を差し込んだ時系列波形を図-4に示す。時系列波形からは異常の判別はつきづらいが、図-5示す、差し込み後のパワースペクトルからは振動理論の定義に従う特徴的な周波数成分が確認できる。




図-2 正常な時系列波形




図-3 正常な時系列波形のパワースペクトル




図-4 異常正弦波を差し込んだ時系列波形




図-5 異常正弦波を差し込んだパワースペクトル

次に作成した疑似異常データを元に特徴量の抽出を行った。ここで言う特徴量とは、機械学習で大量のデータをコンピューターに学習させ、データのパターンを見つけ出す際にどの部分を参考にパターンを見つけ出すかを示す指標である。

計測データを学習データ、評価データ（正常）、評価データ（異常パターンごと）に分類し、それぞれに対してFFTによるスペクトル変換を行い、異常パターンごとに周波数の絞り込みや特徴量を際立たせるデータ処理方法であるプリーングを実施し時系列で結合した。図-6に一例を示す。実際には評価データにはミスアライメント以外のその他の異常も付加したデータとなっている。図-7に時系列で結合したスペクトルを示す。

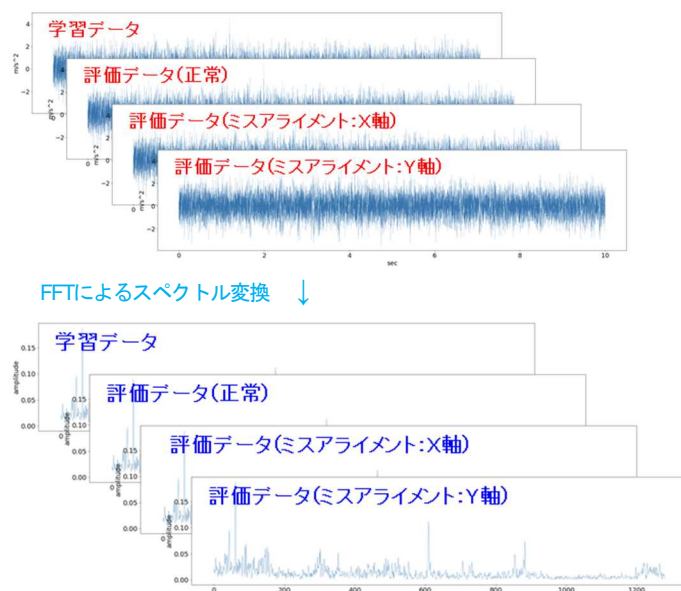


図-6 特徴量抽出 (テーマごとの分類)




図-7 特徴量抽出 (時系列で結合)

(3) 振動シビアリティ (RMS) による疑似異常データ生成

異常の種類によっては、FFT解析による評価だけでなく、速度のRMS値であらわす振動シビアリティによる評価も必要である (ISO10816-3)。ここでは、ポンプ本体の異常については、振動シビアリティを基にした疑似異常データの生成を行った。

疑似異常データの生成にあたっては、計測した加速度データを1ファイルごとに速度データに変換し、式 (1)により振動シビアリティを計算した。

$$\text{RMS} = \sqrt{\frac{X_1^2 + X_2^2 + \dots + X_{n-1}^2 + X_n^2}{n}} \quad (1)$$

- ※ X1, X2, … Xn: 全速度データ
- ※ n: 全速度データ数




図-8 正常データの速度RMS

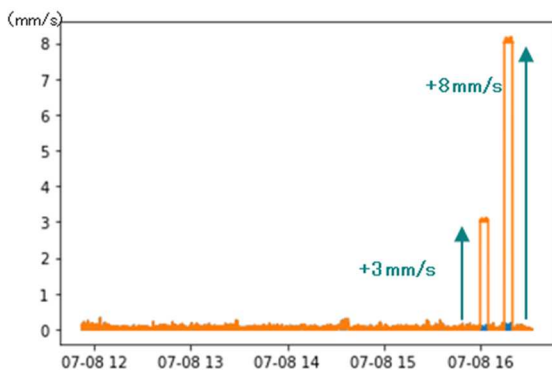


図-9 疑似異常データのRMS

図-8に計測した正常データの速度RMSを示し、図-9

には疑似異常の条件に合うように正常データを変化させた結果を示す。

FFTの場合と同様に疑似異常データを基に特徴量の抽出を行ったが、振動シビアリティの場合にはX, Y, Z軸それぞれのRMSを1ファイルに結合し特徴量抽出 (図-10)とした。

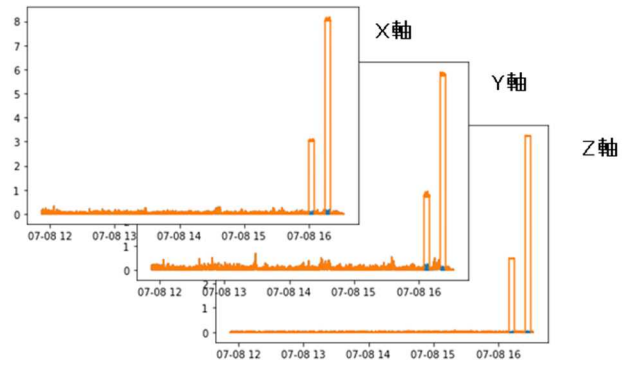


図-10 特徴量抽出 (振動シビアリティ)

3. AIモデルの構築とその評価指標

(1) AIモデルの構築

分析データ生成にて作成した分析データを基に相関モデルを構築した。相関モデルの構築には過年度の研究³⁾においても評価の高かったLOF (Local Outlier Factor) とOCSVM(One Class SVM)の2つのアルゴリズムを使用した。LOFは密度ベースの局所外れ値検知アルゴリズムであり、自身の密度と近傍点の密度を考慮して異常スコアを算出し、分布を仮定せず確率密度にばらつきがある場合でも適用可能である。また、OCSVMは、サポートベクターマシンを利用した外れ値検出方法であり、データの類似度を計算するカーネル関数でデータを特徴量空間に射影することで異常検知を行う。

(2) モデルの評価

構築したAIモデルの異常検知性能の評価には、ROC (Receiver Operating Characteristic Curve) 曲線とROC曲線の下部面積であるAUC(Area Under the Curve)を算出し評価指標とした。図-11にROC曲線を示す。縦軸には真陽性率 (True positive rate) 横軸には偽陽性率 (False positive rate) をプロットしたグラフとなっている。

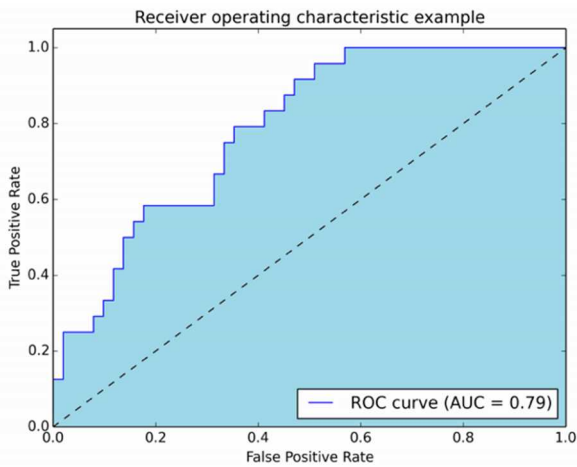


図-11 ROC曲線

比較のため、正常データと一部の異常データ（アンバランス）を切り出し、時系列波形で示したものを図-12に示す。この時系列波形だけでは、異常の判定をすることは困難であると考えられる。




図-12 正常データと異常データの時系列波形

4. 構築したAIモデルによる分析結果

(1) ポンプ主軸異常による検証

構築したAIモデルを用いて、表-1に示す振動理論に基づく疑似異常を正常データ上に生成させ、AIモデルが正確にポンプ主軸の異常を検知できるか検証を行った。

表-1 振動理論による疑似異常の定義

NO	異常パターン	疑似異常発生条件
1	アンバランス (軸曲がり・偏心)	運転時の主軸振動変位データ (X, Yの双方) をFFT処理し、その通常回転卓越周波数のピーク平均値 (初期正常データをストック) の2倍 (設定変更機能有) 超過データを検知
2	軸曲がり	主軸運転起動時 (回転数 0) 定常回転数) 及び停止時 (定常回転数 回転数 0) の主軸振動変位データをFFT処理し、卓越周波数が一定 ($\pm 20\%$ 以内 設定変更機能有) のデータ
3	ミスアライメント (芯ずれ)	運転時の主軸振動変位データ (X, Yの双方) をFFT処理し、その回転卓越周波数の2又は3倍 ($\pm 10\%$ 以内 設定変更機能有) の卓越周波数データ (回転卓越周波数ピーク平均値以上)
4	ポンプ主軸・軸受異常 (緩み・ガタ)	運転時の主軸振動変位データ (X, Yの双方) をFFT処理し、その回転卓越周波数の1/2又は1/3倍 ($\pm 10\%$ 以内 設定変更機能有) の卓越周波数データ (回転卓越周波数ピーク平均値以上)
5	羽根異常 (摩耗)	運転時の主軸振動変位データ (X, Yの双方) をFFT処理し、その回転卓越周波数の2 (羽根枚数) 倍 ($\pm 10\%$ 以内 設定変更機能有) の卓越周波数データ (回転卓越周波数ピーク平均値以上) を検知

分析データは、計測したデータから学習データ、評価データ (正常)、生成した疑似異常データの順に追加し作成した (表-2)

表-2 振動理論による分析データの概要

NO	データパターン	データの詳細
1	学習データ (正常)	時系列正常データのFFT特徴量変換データ
2	評価データ (正常)	上記の一部を評価データとしてランダム抽出
3	アンバランス (x)	回転周波数成分 (N) の振幅を2倍に設定
4	アンバランス (y)	回転周波数成分 (N) の振幅を2倍に設定
5	ミスアライメント (x)	2倍の回転周波数成分 (2N) の振幅をNの平均値に設定
6	ミスアライメント (y)	2倍の回転周波数成分 (2N) の振幅をNの平均値に設定
7	ミスアライメント (x)	3倍の回転周波数成分 (3N) の振幅をNの平均値に設定
8	ミスアライメント (y)	3倍の回転周波数成分 (3N) の振幅をNの平均値に設定
9	主軸軸受異常 (x)	1/2倍の回転周波数成分 (1/2N) の振幅をNの平均値に設定
10	主軸軸受異常 (y)	1/2倍の回転周波数成分 (1/2N) の振幅をNの平均値に設定
11	主軸軸受異常 (x)	1/3倍の回転周波数成分 (1/3N) の振幅をNの平均値に設定
12	主軸軸受異常 (y)	1/3倍の回転周波数成分 (1/3N) の振幅をNの平均値に設定
13	羽根異常 (x)	5倍の回転周波数成分 (5N) の振幅をNの平均値に設定
14	羽根異常 (y)	5倍の回転周波数成分 (5N) の振幅をNの平均値に設定

正常データにより学習したAIモデルに生成した疑似異常データを入力して分析を行った。図-13は、LOFを用いたAIモデルによる分析結果である。3~14の各異常パターンの評価期間中に異常の検知はできているが、正常データによる評価期間にも異常を検知する誤検知が発生している。AUCの値も0.91と精度の悪いモデルとなっている。考えられる原因としては、計測データの数が少ないため、学習データの正常パターンも少なくなっており、このLOFの分類では正常データであっても誤検知が発生したものである。

次にOCSVMを用いたモデルによる分析結果を図-14に示す。このモデルによる分析結果では、評価期間での誤検知なく、各異常パターンの評価期間での異常を検知しており、誤検知も少なく精度の高いモデルとなっている。AUCの値も0.99と高い値を示す結果となった。よって、ポンプ主軸の異常検知においては、OCSVMを用いたモデルが性能の良いモデルであることがわかった。




図-13 LOFによる分析 (主軸)




図-14 OCSVMによる分析 (主軸)

(2) ポンプ本体異常による検証

ポンプ本体異常の検証のため、振動シビアリティによる疑似異常を表-3に示すように定義し、ポンプ主軸同様、表-4に示すように異常評価データを作成した。

表-3 振動シビアリティによる疑似異常の定義

NO	異常パターン	疑似異常発生条件
1	ポンプ異常・注意	運転時のポンプ本体加速度振動データ(X, Y, Z)を速度に変換し、その実効値(振動シビアリティ)が正常時の3mm/s以上(設定変更機能有)を検知(X, Y, Zの何れか)の場合に異常種別「ポンプ異常・注意」のアラートを発報
2	ポンプ異常・危険	実効値が正常時の8mm/s以上(設定変更機能有)を検知(X, Y, Zの何れか)の場合に異常種別「原動機異常・危険」のアラートを発報

表-4 振動シビアリティによる分析データの概要

NO	データパターン	データの詳細
1	学習データ(正常)	時系列正常データのFFT特徴量変換データ
2	評価データ(正常)	誤検知しないことを検証するための評価データ(正常)
3	ポンプ異常・注意(X軸)	振動シビアリティが正常時の3mm/s以上
4	ポンプ異常・注意(Y軸)	振動シビアリティが正常時の3mm/s以上
5	ポンプ異常・注意(Z軸)	振動シビアリティが正常時の3mm/s以上
6	ポンプ異常・危険(X軸)	振動シビアリティが正常時の8mm/s以上
7	ポンプ異常・危険(Y軸)	振動シビアリティが正常時の8mm/s以上
8	ポンプ異常・危険(Z軸)	振動シビアリティが正常時の8mm/s以上

ポンプ主軸と同様にLOFとOCSVM 2つのアルゴリズムを用いたAIモデルについて、検証を行った。検証結果を図-15~16に示す。LOFの分析結果では各異常パターンの評価期間に誤検知もほとんどなく、AUROCの値も0.995と精度の高いモデルとなっている。一方、OCSVMの分析結果では、評価期間に特定の異常で誤検知が幾つか発生しており、AUROCの値も0.92とLOFに比べると精度が悪いモデルとなっている。よって、ポンプ本体の異常検知においては、LOFを用いたモデルが性能の良いモデルであることがわかった。




図-15 LOFによる分析(本体)




図-16 OCSVMによる分析(本体)

5. まとめ

本検証結果から、AIを用いた異常検知で重要な教師データとなる異常データの取得が困難な機械設備であっても、振動理論に基づいた疑似異常データを用いることで、AIを用いた異常検知システムの検証が可能であることがわかった。機械学習のアルゴリズムには多数の種類があり、今回の報告ではその一部を利用して評価を行った。

学習データを数多く集めることで、より精度の高いモデルが構築できることも予想されるので、計測データの収集にも尽力し、今後も継続して評価を行う予定である。また、排水機場の異常検知に最適な手法について検討を行うことで、設備点検における施設管理者の点検精度の向上や負担軽減につなげていきたい。

謝辞：本研究にあたり、設備提供を頂いた北海道開発局札幌開発建設部施設整備課、札幌河川事務所の皆様に多大なる謝意を表します。

参考文献

- 1) 中島淳一, 梶田洋規, 藤野健一: 河川ポンプの多様な診断, 土木技術資料第59巻・第8号, 2018
- 2) 振動技術研究会: ISO 基準に基づく機械設備の状態監視と診断(振動 カテゴリーIII), 2010
- 3) 新田恭士, 上野仁士, 中島淳一: 排水機場ポンプ設備の異常診断について, ポンプNO. 60, 2018