特集報文：見えないもの「痕跡」を検出する新技術の開発

モニタリングシステムとAI技術による河川ポンプ設備の異常の検出

吉田　潔・上野仁士・中島淳一・　新田恭士

1. はじめに

国土交通省が管理している水門設備や河川ポンプ設備等の河川管理施設は平成30年3月末時点で約1万施設ある。そのうち40年を経過している施設は約半数あり、20年後には約8割に増加するが、厳しい財政の中、維持管理・更新に係るトータルコストの縮減・平準化等が求められている。

河川ポンプ設備の維持管理は予防保全が基本であり、従前は設備状態によらず定期的に整備を行う「時間計画保全」に基づき万全な維持管理を実施してきたが、設備の劣化兆候を監視して必要に応じて整備を行うためコスト的に有利とされている「状態監視保全」の導入を進めている。

河川ポンプ設備の状態監視は、一般に定期点検で計測したスポットデータの傾向等から異常が疑われる場合に、専門技術者による精密診断で異常の種類や箇所を特定し、効率的な整備を行うものである。しかし、構造的な制約により定期点検では負荷をかけた運転ができない場合があることや、必要時のみ稼動する「非」常用設備であるため運転に連続性・定期性がないなど、必ずしも状態監視として望ましいデータが得られていない。

そこで土木研究所では故障の予兆を確実に捉えるため常時運転状態が監視できるモニタリングシステムを構築した。さらに、モニタリングシステムから得られるデータに基づいて、いち早く異常を察知して、修理費用が大きくなる前に必要最低限の費用での整備が可能となるよう、AIによる早期異常検知に取り組んでいる。また、精密診断を行うことができる専門技術者が不足しているため、AI異常検知を支援ツールとして用いることも想定している。

本稿はこれらの取り組み状況を報告する。

2. モニタリングシステムの構築

本研究には、故障の予兆を確実に捉えるため、ポンプ運転時の状態を常時モニタリングし、センサデータを記録するシステムが必要であり、排水機場管理者である国土交通省地方整備局等から試行現場提供に協力頂き、比較的稼働の多い4機場、計8基に平成30年度から2ヵ年かけて常設センサを設置し、モニタリングシステムを構築した。

対象ポンプ設備概要を表-1に、主な設置センサを図-1に示す。また、取付け事例としてS機場の原動機センサ設置状況を図-2に、主ポンプセンサ設置状況を図-3に示す。原動機基部に加速度センサ、ポンプ基部に加速度センサ、ポンプ主軸に変位センサ及び回転計を設置した。測定データはデータ収集ソフトウェアにより、ポンプ主軸回転

表-1　対象ポンプ設備概要

機場名	T機場	S機場	R機場	Y機場
対象号機	2,3号機	1,2号機	1,2号機	1,2号機
口径	1,500mm	2,000mm	1,500mm	1,350mm
全揚程	3.3m	5.3m	5.4m	6.3m
排水量	5m^3/s台	10m^3/s台	5m^3/s台	5m^3/s台
原動機形式	ディーゼル	ディーゼル	ディーゼル	ｶﾞｽﾀｰﾋﾞﾝ
定格出力	320PS/台	1,100PS/台	518PS/台	302PS/台
ポンプ形式	横軸斜流	立軸斜流	立軸斜流	立軸軸流
ポンプ新設	S60,61年度	S55,63年度	H22年度	H16年度

渦電流式変位センサ	圧電式振動加速度センサ
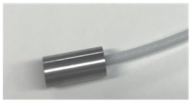	
磁界中の金属体表面に渦電流が発生する原理を利用して、非接触で金属体表面までの距離を測定するセンサ。	圧電素子に変形を加えると電荷が発生する原理を利用して、振動体に固定して振動加速度を測定するセンサ。
周波数範囲：0 ～ 10kHz	周波数範囲：1 ～ 8,000Hz

図-1　主な設置センサ

図-2　S機場ディーゼルエンジン及び加速度センサ

Detection of River Pumping System Abnormality Using Monitoring Systems and AI Technology

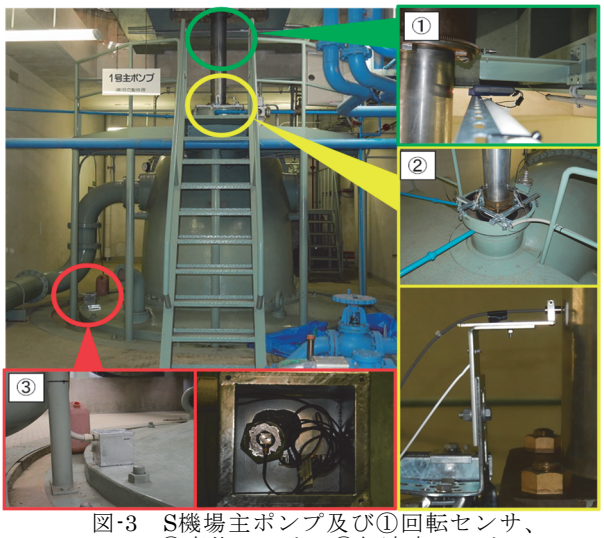

図-3　S機場主ポンプ及び①回転センサ、
②変位センサ、③加速度センサ

をトリガとして自動的に記録開始・停止される。

まだデータ計測を開始していないが令和元年度には、材料が破壊に至る前の小さな変形や微小クラックの発生を検知するアコースティック・エミッション（AE)、原動機の変調を捉える排気温度計及び排気ガス成分センサ等を追加設置した。

なお、既往の研究においては、定期的に実施される軽負荷又は無負荷での「管理運転」時にマグネットスタンド等でセンサを仮設しデータを取得していた。今回、常設センサによるモニタリングシステムを構築したことにより、出水時の高負荷での「本運転」のデータが取得可能となった。令和元年10月の台風出水ではS機場、R機場、Y機場の正常に本運転されている状態監視データをシステムにより自動収集することができた。

3. AI異常検知の有効性の評価

3.1 評価の概要

過去の研究で取得したポンプ運転時の測定データのうち正常時のデータと異常時のデータの比較

表-3　評価したアルゴリズムの概要

試行アルゴリズム	概要
MT(Maharanobis-Taguchi System)	変数間の相関を考慮した距離(マハラノビス距離)が大きければ異常と判定
LOF(Local Outlier Factor)	データの密度を計算して、密度が非常に低い所に現れたデータを異常と判定
OCSVM(One Class Support Vector Machine)	正常データ1クラスの学習により決定した境界面との距離が大きければ異常と判定
SparseCoding	正常データが再現できる辞書データを作成し、入力データ復元の再構成誤差が大きいものを異常と判定
TimeSeriesKNN	入力データ波形と、正常波形との距離が大きいものを異常と判定
SVM(Support Vector Machine)	教師ありデータを学習して作成した境界面により、入力データのクラスを分類する。

が可能なものについて、異常検知モデルを構築し、そのモデルの異常検知の有効性を評価した。評価に用いたデータの計測箇所及び異常内容を表-2に示す。評価には異常検知に実績のあるアルゴリズムを選定した。その概要を表-3に示す。現実には個々の河川ポンプ設備固有の異常データを準備することは不可能なため、今回の評価は正常データのみを学習する教師なしモデルを基本とした。評価は学習に使用しなかった正常データと異常データを用いた。

3.2 教師無し機械学習モデルの評価

図-4上段はO機場ポンプ1号機主軸の正常な時系列変位でありX軸とY軸の位相のずれは軸が楕円状に振動していることを示す。下段は同2号機主軸のアンバランスの疑いがある時系列変位である。図-5はXYそれぞれの正常データをSparse Codingで学習したモデルに、学習に使用したものとは別の正常データ及び異常データを入力した結果である。黒線は入力データの切替り位置を、青線はAIによる異常スコアを示している。図-5においては0から離れるほど異常が大きいとの評価であるが、評価用正常データは異常データと同等以上に異常スコアが大きく、正常（図-5の左側）と異常（同右側）を分類できない。Time Series KNNで学習したモデルによる異常検知結果も同

表-2　AI異常検知評価の対象とした既存データとその異常内容

対象設備	計測場所	号機	計測年度	計測内容	計測パターン					
ディーゼルエンジン	K機場	1号機	H29	排気成分	正常	バルブクリアランス異常	燃料噴射ノズル異常	燃料噴射ポンプ異常	過給器異常	始動弁異常
		2号機	H30	排気成分	正常	タペット異常（重度/軽微）	燃料噴射ノズル異常	燃料噴射ポンプ異常	吸気フィルタ異常（重度/軽微）	無
		2号機	H30	加速度・AE・気筒毎排温	正常	バルブクリアランス異常	燃料噴射ノズル異常	燃料噴射ポンプ異常	過給器異常	無
ポンプ	Y K機場	1号機	H30	回転数・変位・AE	無	主軸アンバランス	無	無	無	無
		2号機	H30	回転数・変位・AE	正常	無	無	無	無	無
	O機場	1号機	H30	回転数・変位・AE	正常	無	無	無	無	無
		2号機	H30	回転数・変位・AE	無	主軸アンバランスの疑い	無	無	無	無
ガスタービン	Y機場	1号機	H29	加速度	正常	無	無	無	無	無

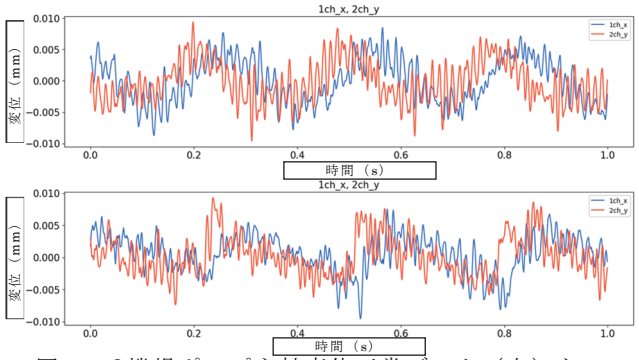

図-4　O機場ポンプ主軸変位正常データ（上）と異常データ（下）

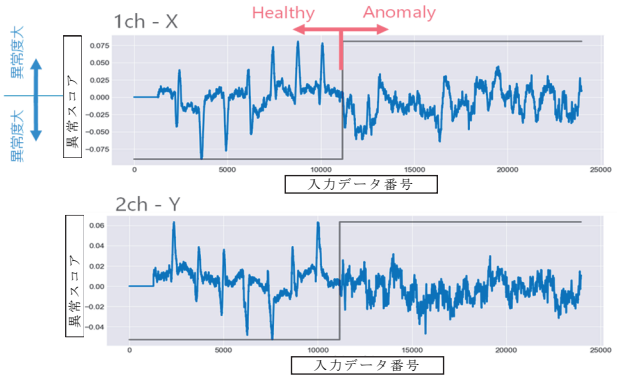

図-5　O機場ポンプ主軸変位Sparse Coding異常検知結果

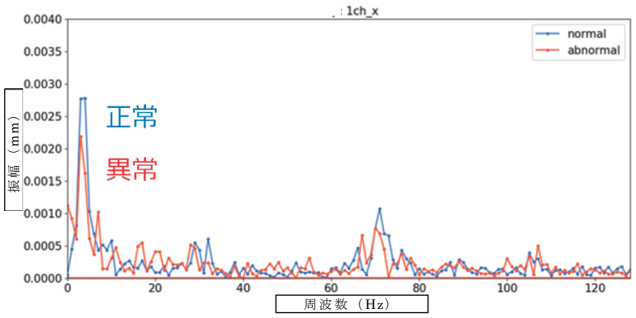

図-6　O機場ポンプ主軸X方向変位周波数スペクトル

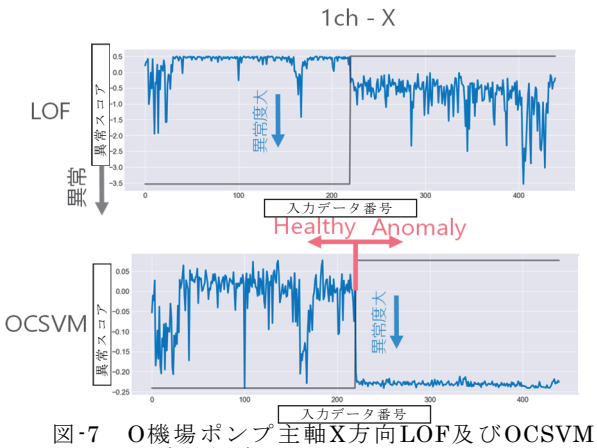

図-7　O機場ポンプ主軸X方向LOF及びOCSVM異常検知結果

様に正常と異常の識別は困難であった。時系列の変位データを対象とする以上のアルゴリズムによる手法では、十分な異常検知性能は得られなかった。

次に、技術者が精密診断で用いる時系列変位データをFFT解析した周波数スペクトルを入力データとし異常検知を行った。図-6は図-4のX方向時系列変位データの周波数スペクトルで横軸が周波数、縦軸が変位である。また、青が正常、赤がアンバランス疑いのデータである。正常データをLOF及びOCSVMで学習したモデルによる異常検知を行った結果を図-7に示す。図-7においては下方ほど異常が大きいとの評価であるが、LOF・OCSVMともに、正常（図-7の左側）と異常（同右側）の異常スコアのレベルに顕著な違いがあり分類可能である。

ディーゼルエンジンおよびガスタービンエンジンの加速度データについても同様な異常検知の評価を行った。ガスタービンエンジンについては既存の異常データがないため、燃焼振動異常を模擬したデータを作成して用いた。異常判定の閾値を変化させた場合の正常異常の正答率を評価するAUROCの結果を表-4に示す。数値が0.5の場合閾値に依らず正答と誤答の割合が等しくランダムに予測していることを示し、1に近いほど正答率が高いことを示している。ポンプ主軸、ディーゼルエンジン、ガスタービンエンジンいずれにおいても時系列波形よりも周波数スペクトルを用いたほうが好成績であった。

3.3 教師有り機械学習モデルの評価

ディーゼルエンジンについては、表-2にあるとおり、更新予定のエンジンを使用して、正常データに加え、バルブクリアランス異常や燃料噴射ノズル異常等を個別に人為的に生じさせO2、CO、CO2、NOx、NO、NO2の濃度データを取得している。これら多変量データをサポートベクタマシンに学習させ異常箇所を判別する「教師あり」モデルを構築し評価した。

排気ガス成分のうちNOの正常及び各種異常発

表-4　AI異常検知評価結果

入力	アルゴリズム	ポンプ主軸				ディーゼル		ガスタービン		
		O機場		YK機場		K機場		Y機場		
		X	Y	X	Y	Z1	Z2	X	Y	Z
時系列波形	SparseCoding	0.499	0.491	0.739	0.747	-	-	0.513	0.518	0.518
	TimeSeriesKNN	0.520	0.554	0.934	0.907	-	-	0.530	0.541	0.533
周波数スペクトル	MT	0.915	0.685	0.987	0.963	0.847	0.907	1.000	1.000	0.901
	OCSVM	0.955	0.998	1.000	1.000	0.992	0.992	1.000	1.000	1.000
	LOF	0.960	1.000	1.000	1.000	0.992	0.988	1.000	1.000	0.999

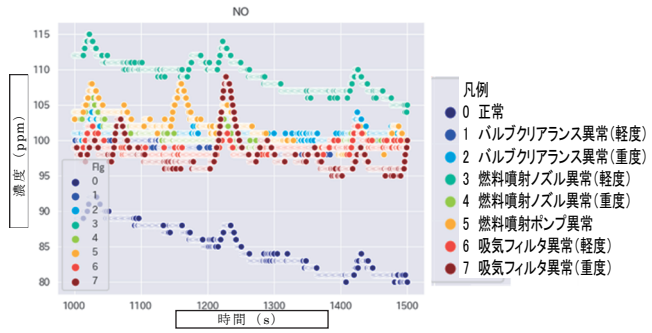

図-8　K機場ディーゼルNO成分濃度時系列データ

表-5　K機場排気ガス異常パターン判別結果

※数値は標本数

入力データ ＼ 判別結果	0 正常	1 バルブクリアランス異常(軽度)	2 バルブクリアランス異常(重度)	3 燃料噴射ノズル異常(軽度)	4 燃料噴射ノズル異常(重度)	5 燃料噴射ポンプ異常	6 吸気フィルタ異常(軽度)	7 吸気フィルタ異常(重度)
0 正常	500	0	0	0	0	0	0	0
1 バルブクリアランス異常(軽度)	0	500	0	0	0	0	0	0
2 バルブクリアランス異常(重度)	0	0	496	0	0	4	0	0
3 燃料噴射ノズル異常(軽度)	0	0	0	500	0	0	0	0
4 燃料噴射ノズル異常(重度)	0	0	0	0	463	0	37	0
5 燃料噴射ポンプ異常	0	0	0	0	0	500	0	0
6 吸気フィルタ異常(軽度)	0	0	0	0	27	0	473	0
7 吸気フィルタ異常(重度)	0	0	0	3	0	0	9	488

生時の時系列濃度を図-8に、正常と7つの異常それぞれの評価データ500セットの異常パターン判別結果を表-5に示す。モデルは合計4000セットの評価データに対して3920セットを正しく判別し、正答率は98.0%となり、十分な判別性能が得られた。

4. まとめ

本稿では、ポンプ設備の異常検知のために構築したモニタリングシステム、及びAIによるセンサデータからの異常検知に向けた各種アルゴリズムの評価結果を紹介した。

国内の河川ポンプでの常設センサによるモニタリングシステム構築は初の試みであり、定期的な管理運転のデータだけでなく、貴重な出水時の実負荷運転のデータも取得し、AI異常検知の開発に供することができるようになった。特にポンプ主軸変位振動、ディーゼルエンジン加速度振動、ガスタービンエンジン加速度振動について、異常検知に実績のある主なAIアルゴリズムを評価し、OCSVM、LOF及びMTについては正常データのみを学習した教師無しモデルで異常データの判別ができた。

本モニタリングシステムは研究段階であり高性能のセンサを設置しているが、今後の研究でAI異常検知に必要最低限のセンサ性能とデータ数を見極め、より安価でシンプルなシステムを提案したい。また、本モニタリングシステムを対象としたAI異常検知モデルを現在構築中であるが、ポンプ主軸については、特定周波数に着目し異常の有無だけでなく、アンバランスや曲がり等の異常種類まで特定できるモデルにトライしている。これらは、本モニタリングシステムに特化した学習モデルであるが、データに異常兆候が見られた場合に専門技術者による異常現象の分析とAI異常度等の関係性の検証を各設備で積み重ね、AIによる異常の知見を蓄積していく中で、今回対象設備以外でも容易に適用できる異常検知・精密診断支援ツールを開発してまいりたい。

謝　辞

本研究にあたり、ご協力頂いた施設管理者、国土交通省関係者には、この場を借りて、厚く御礼申し上げます。

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技術、土木技術資料、第59巻、第8号、pp.22～25、2017
2) 吉田潔、上野仁士、中島淳一、新田恭士：排水機場ポンプ設備のAI異常検知の取り組み、ぽんぷ、No.62、pp.10～13、2019

吉田　潔

土木研究所技術推進本部
先端技術チーム　主任研究員
YOSHIDA Kiyoshi

上野仁士

土木研究所技術推進本部
先端技術チーム　主任研究員
UENO Hitoshi

中島淳一

土木研究所寒地土木研究所技術開発調整監付寒地機械技術チーム　主任研究員
NAKAJIMA Junichi

新田恭士

土木研究所技術推進本部
先端技術チーム　上席研究員、博士（工学）
Dr. NITTA Yasushi