IoTリアルタイム情報とAI技術を活用したマンホールポンプの状態監視異常検知モデルの開発実証

なかむらもとき まそかっし ほりたかなり じょうがんたくみ うわいひろのり 中村元紀1・阿曽克司1・堀孝成1・城 岸 巧1・上井裕徳1

1 (株) 新日本コンサルタント (〒930-0857 富山県富山市奥田新町1番23号)

下水道の管路ネットワークのなかで中継の役割を担う汚水マンホールポンプは、下水道事業における比較的住民に近い重要なアセットの要素の一つである。地方自治体のMP維持管理は、熟練技術者の高齢化、若手技術者の減少の中、点在するMPを24時間体制で緊急時の対応かつ適切な維持管理(日常点検・清掃等)を実施しており、人手不足などの課題が顕在化している。本実証では、これまでの維持管理において蓄積された運転データ・点検データを教師データとしたMPの異常検知を行う「AIエンジン搭載検知予測システム」を構築することで、点検の効率化、予防保全活動への展開、夜間待機体制緩和などによる労働環境の改善等を図るものである。

Key Words : 汚水マンホールポンプ、AI技術、異常検知、維持管理手法

1. はじめに

下水道の管路ネットワークのなかで中継の役割を担う汚水マンホールポンプ(以下「MP」と記載、図-1)は、下水道事業における重要なアセットの要素の一つである。

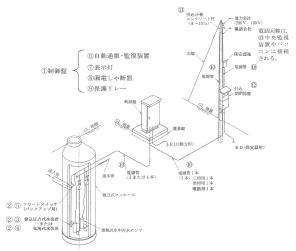


図-1 マンホールポンプ概要1)

行政の下水道部局では、数多くのアセットを保有・管理し、住民サービスに直結する多くの便益を生み出している。MPは全国で約1,400の自治体・事業体で導入されており、その箇所数は約47,000箇所である。高度経済成長期に築造された多数のMPを有する地方自治体の維持管理の現状は、熟練技術者の高齢化、若手技術者の減少の中、点在するMPを24時間体制で緊急時の対応かつ適切な維持管理(日常点検・清掃等)が必要であり、人手不足など

の課題が顕在化している。

この様な背景のもと、本実証では、これまでの維持管理において蓄積された運転データ・点検データを教師データとしたMPの異常検知を行う「AIエンジン搭載検知予測システム」を構築することで、点検の効率化、予防保全活動への展開、夜間待機体制緩和などによる労働環境の改善等を図るものである。

2. 課題解決

本システムの開発に当たっては、MPの異常検知 を行うために、AI技術に適用する教師学習データの 準備が不可欠である。本実証では、IoTデバイスに よるリアルタイム電流値 (ポンプ稼働電流) の細か なデータ(サンプリング周期が20Hz)を学習させて 「早期異常検知モデル」の構築を行う。しかしなが ら、MPにおける「異常」は一般的にはあまり発生 しておらず、リアルタイム電流値で得られる時系列 データから「異常」の特徴を定義することは複雑で 難しい。仮に「異常」が定義できたとしても、ほと んどの状態が「通常」に偏っていて、全状態に占め る「異常」の割合(以下、異常確率)がとても小さ い。そのため、リアルタイム電流値で得られるデー タから「通常」と「異常」を区別する識別器を作る 場合、誤認する確率は異常確率よりも大きくなり、 すべての出力を「通常」とする方が高い評価になっ てしまうという可能性が高かった。

そこで、初めから無理にリアルタイム電流値で得られる時系列データから「異常」を定義せず、日報データまたはリアルタイム電流値で得られる時系列データから「通常」を定義して、その状態から逸脱

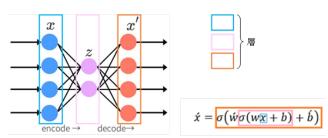


図-2 3層オートエンコーダ概要

ここで、x は入力層、z は中間層、x は出力層、w, w は重み、b, b はバイアス、 σ は活性化関数(主にシグモイド関数が用いられる)を表す。

AEは、PCAと同様に、入力xから中間層zで次元が少なくなることから次元圧縮手法といわれている。(PCAが線形であるのに対し、AEは非線形であることで、より複雑な表現力を獲得できる。)図-2(この例では3層)と数式を比べると明らかなように、層は活性化関数の再帰構造になっている。層はハイパーパラメータ(設計者が決定するパラメータ)で、層を増やすとより複雑な入力を再現できるようになるが、計算困難性(計算量の増大、過学習の発生など)が増すため、適切に設定する必要がある。

AEにより「通常」が再現可能になった後、入力 データとAEの出力(「通常」)との差(または 比)によって「異常」を区別する。 (この時の違い を区別するための値を閾値と言うが、これもハイ パーパラメータである。)仮の「異常」を決めて、 過去の異常履歴(緊急出動記録等)と突合して、現 実的な閾値を決定する。(調整については各種ハイ パーパラメータの設定により行う。)これにより、 日報データまたはリアルタイム電流値で得られる時 系列データから「通常」と「異常」の区別が可能に なる。この「通常」・「異常」のラベルとリアルタ イム電流値から得られる時系列データとの関連を学 習させることで、リアルタイム電流値で得られる時 系列データから「通常」・「異常」または異常であ る確率を出力する「異常検知識別器」が構築できる。 「異常検知識別器」の構築は、精度向上が期待で

きるニューラルネットワークを用いた深層学習(多層パーセプトロンなど)を採用した。AE側のシステムと検知側のシステムを直列につないだ時(システムを直列につなげた場合、各システムの正解率の積がシステム全体の正答率になるため)に拡大する誤差がニューラルネットワークを用いることで軽減される可能性(精度向上)が期待できる。

(1) AEを用いた「異常検知識別器」

この「異常検知識別器」は、「早期異常検知モデル」を開発するための電流値の「異常」データを峻別することが目的であり、「早期異常検知モデル」はリアルタイム電流値の細かなデータ(サンプリング周期が20Hz)を学習させるが、電流値が観測されるまでそのようなデータは存在しないことから、「異常検知識別器」の構築は、既存データである日報データ等(サンプリング周期は最小で1時間)を

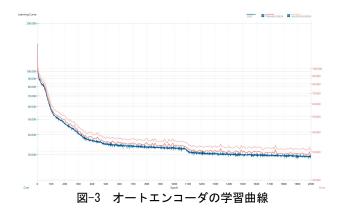
「異常検知識別器」の構築は、既存アータである日報データ等(サンプリング周期は最小で1時間)を活用した。AEを用いて、ある時点の状況(データ)を復元し、その誤差が閾値を超えた時間帯を異常状態の時間帯とする。このようなAEを作成する上での、要件を以下に示す。

- ① 全国的な技術展開を図るため汎用性を確保すること
- ② 「早期異常検知モデル」で用いるデータとの サンプリング周期の違いを考慮し、幅広に データを収集すること

これらの要件を満たすように、各MP施設における各ポンプの稼働回数、稼働時間を入力し、AEで再現することとした。ここで、全国展開時新たなポンプの形式や出力などの属性が発生すると、同じシステムが適用できないことから、ポンプ属性など汎用性を阻害しそうな項目を入力値に含めないこととしている。

AEは入力の復元が主なタスクであるため、入力と出力が同じである。1時間分のデータの入力は、ポンプNo.1の運転回数、運転時間、ポンプNo.2の運転回数、運転時間の4項目では、いくら熟練した技術者が異常の判別を担当したとしても、実用上の判断は下せない。熟練した技術者は、日々のポンプ運転の流れの中で、いつもとの違いを感じ取っていることから、24時間分のデータから「いつもの状態(正常)」を獲得することとした。

以上を基にAEのネットワーク構築した。運転回数と運転時間では数値の取りうる幅が、2 桁程度異なることから入力処理を分離した。このAEのネットワークに損失関数(HuberLoss)を適用し、オプティマイザーはAdam(α =0.001、 β 1=0.9、 β 2=0.999、 ϵ =1e-8)を用いた。訓練用データ(4,346,997)と評価用データ(711,258)で、バッチサイズ64、2000エポックの訓練を行った。学習には、Nvidia社製DGX-Staion(GPU:TeslaV100)、深層学習フレームワークはSONY社製 Neural Network Console version 1.6.7263.14761 及び NNabla (Version 1.1.0, Build 190820052242)を用い、53時間以上かかった。学習曲線を図-3に示す。



(2) 「早期異常検知モデル」の構築

「IoTリアルタイム情報(電流値)」および「異 常検知識別器」を用いることで、「異常」データを 識別し、早期異常検知のための学習データの作成を 自動化し、1年間の計測期間で蓄積した学習データ を基に「早期異常検知モデル」の構築を行った。

「早期異常検知モデル」は、MPが故障に至る前の 状態で「異常」の種を検知することと夜間待機 (18:00~翌9:00の時間:15時間)の緩和を目的と し、この15時間に異常が発生する予兆を捉えること とした(図-4)。異常が発生した時刻より前の時間 帯における15時間分のデータを予兆データセットと し、それ以外を正常データセットとして学習させる。 予兆データについては、「異常検知識別器」を用い て正常と異なる特徴(異常因子)を仕分けして追加 することにより、学習データは現在考えられる異常 要因がカバーされ、深層学習による異常確度(異常 の発生しやすさ)を出力するネットワークの構築し た。

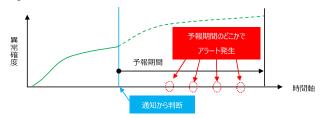


図-4 早期異常検知イメージ

構築までのプロセスは次のとおりである。

- ①AutoML/NASによる学習
- ②評価データによる選定
- ③システムへの設置

多層SE構造によりマルチスケールで特徴が獲得し やすいネットワークをベースネットワークとして学 習を開始し、AutoML/NASにより300~400個程度の学 習済みネットワークを自動で作成する。AutoML/NAS による学習とは、ニューラルネットワークの学習に おいて、一般にハイパーパラメータと呼ばれる技術 者が設定するパラメータをソフトウエアで自動的に 設定したり(AutoML)、ネットワーク構造を自動的 に変更(NAS:ネットワーク構造自動検索)して、 自動的にチューニング作業を進める機能の総称であ る。²⁾³⁾

ネットワークへの入力項目は以下のとおりである。

- ①同一MPの異常3件以上を含む学習データ
- ②ポンプの定格電流
- ③アラート設定値

こうして作られた300~400個の学習済みネット ワークに評価データを入力し、正常/異常の正解数 の組が最も最適なネットワークを選定する。一般に すべてを正解するような完全なAIは発見できないた め、パレート最適解により現実的なAIを選定する。 施設の特性や現場の要望などを考慮し、見逃し低減 を重視したAI (図-5緑の円) か空振り低減 (図-5赤 の円内)を重視したAIのどちらかを選定する必要が ある。選定にあたり可視化する場合は、対数軸で表 示することにより、正常/異常のデータ数が異なる ことによる見づらさを解消できる場合がある。

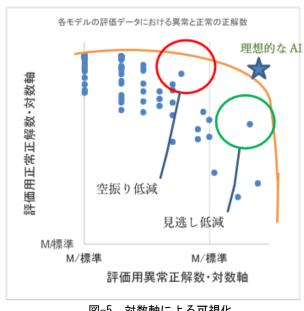


図-5 対数軸による可視化

3. 研究成果

(1) 既存アラートの的中精度

本実証で構築した「早期異常検知モデル」は、 IoTリアルタイム情報から30分毎に異常確度を算出 し、異常確度が60%を超えた段階で異常予報通知を 行う。通知内容としては、予測時刻から15時間先ま での間の異常確度を表示し、実際に15時間以内に緊 急出動に至った事象の的中精度は87.5% (過去の異 常における電流値データを再現することで的中率を 算定)となった。

表-1 既存アラートの的中精度の結果

76.57%	0
64.94%	0
82.82%	0
78.77%	0
18.68%	×
68.87%	0
. 88.16%	0
62.46%	0
的中率	87.5%
	64.94% 7 82.82% 8 78.77% 18.68% 6 68.87% 8 81.6% 0 62.46%

昨年度の既存アラート(出動履歴)が多かった3施設において、8件の既存アラートのうち、7件を早期異常検知できていた。早期検知できなかった1件の異常は突発性の詰まりがあり、30分毎の異常確度において、反応が困難であったと考えられる。

今回のモデル構築にあたっての学習データには、 突発的な詰まり等の異常を含んでおらず、予兆が確認できるしさ等の堆積物による異常因子(ポンプ槽 内やインペラに付着した異物)を対象としている。

(2) 異常確度による点検清掃の効果

異常確度が60%を超えた段階でMP点検及び清掃を実施し異常因子の除去をしたことにより異常確度の低下効果が確認できた(図-6)。

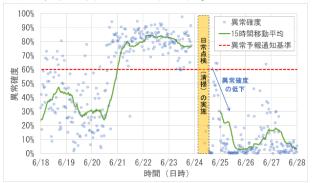


図-6 異常確度の推移(日常点検実施時)

本システムの異常予報通知のタイミングで点検及び清掃を実施することにより、異常発生回数の低減及び日常点検の効率化が図られ、状態監視保全への移行、点検頻度の削減による維持管理コスト削減、夜間待機体制の緩和による人的リソースの削減効果を実規模実証にて検証を行った。

また、既存アラートが頻発していた施設(老朽化対策として更新された実績)に対して、ポンプの更新による異常確度の低下についても確認することができている(図-7)。

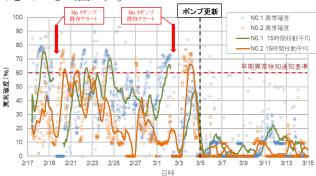


図-7 異常確度の推移(ポンプ更新時)

(3) 実際の運用による実績

今回、維持管理業者の協力の基、実際の運用における検証を試みた。運用方法については、過去の点検実績から、異常確度が60%を超過すると第一予報通知(異常警戒)を発報し、出動の待機体制を確保し、第一予報通知発報後、異常確度が60%以上が6時間経過した時点で第二予報通知(出動判断)を発

報し、現場でポンプの引上げ点検を行うこととした。 No. 1ポンプで第一予報通知の発報 (7/8 5:30) があり、維持管理業者は異常警戒体制とし、その後6時間が経過しても異常確度は低下せず、第二予報通知が発報 (7/8 11:30) したため、現地へ出動しポンプの引上げ点検を実施した結果、ポンプ内部に(布切れのような)しさが絡みついている状態を確認することができた(写真-1)。これは一例ではあるが、早期異常検知モデルによる異常確度によって現在の運転状態を可視化し、リアルタイムで監視できる可能性が期待される。

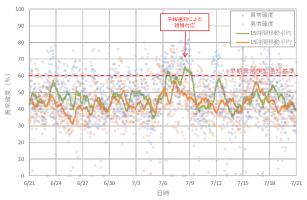


図-8 異常確度の推移(早期異常検知による点検時)





写真-1 早期異常検知による点検時のポンプ状況

4. 今後の予定

今回の実証は一自治体での結果であるため、必ずしも、他の自治体で運用して同様の結果が得られるとは限らないが、今後、学習データの蓄積が進むことで、AIモデルの精度向上(アップデート)が可能であり、今後も自主的なデータ収集及び解析を継続していく。また、多数のMPを有する地方自治体において財政状況及び整備状況に応じた段階的導入を検討の上、本システムの水平展開を図るとともにMP維持管理における支援に努める所存である。

本論文は令和元・2年度下水道革新的技術実証事業の実証研究の成果の一部をまとめたものである。 実証研究は国土交通省国土技術政策総合研究所下水 道研究部下水道研究室ならびに共同研究体構成員で ある日水コン・エコモット・北海道大学・富山市の ご助言を頂いた。ここに感謝の意を表します。

参考文献

- 1) (財) 下水道新技術推進機構,下水道マンホールポンプ 施設技術マニュアル-1997年6月-,P10
- 2) Hanxiao Liu, Karen Simonyan, Yiming Yang, DARTS: Differentiable Architecture Search, arxiv:1806.09055, 2018
- Han Cai, Ligeng Zhu, Song Han, ProxylessNAS: Direct Neural Architecture Search on Target Task and Hardware, arxiv1812.00332, 2018