

## 〈研究発表〉

# AIによる流入量や管内貯留量の推定を用いたポンプ場運転操作ガイダンス

柏崎 拓成<sup>1)</sup>, 湛 記先<sup>1)</sup>

<sup>1)</sup>(株)ウォーターエージェンシー 研究開発部

(〒162-0813 東京都新宿区東五軒町3-25 E-mail:wa03-00018@water-agency.com)

### 概要

下水のポンプ場の多くは、事前に設定された値により、ポンプのオン・オフ操作を行い、ポンプ井の水位が一定の範囲内に留まるような運転がなされている。降雨時は、熟練技術者が手動操作に切替えて、ポンプや流入ゲート操作を行い、下水システムの安全な運転を担保している。こうした熟練技術者が将来にわたり不足することを見据えて、AIによるポンプ場運転操作ガイダンスを開発した。今回のポンプ場で不明であった流入流量や流入管内貯留量は、既存のデータからAIを活用して推定した。これらの推定値とゲートやポンプの操作から、ポンプ井の水位を予測した結果を報告する。

キーワード：予測、ディープラーニング、AI、ポンプ場運転

原稿受付 2024.7.19

EICA: 29(2・3) 28-31

## 1. はじめに

下水のポンプ場では、通常、ポンプの定常的な操作で、ポンプ井の水位を一定の範囲に保つ運転がなされている。降雨時は、流入渠の水位変化、上流や下流施設の状況、雨量計などから、熟練技術者が的確にポンプや流入ゲート操作等を行い、下水システムの安全な運行を行っている。こうした降雨時の運転では、流入側の流量計があることが望ましいが、現実的には設置されていないことも多い。今回、流入流量計の無いポンプ場にて、AIを活用した流入量や管内貯留量の推定を行い、降雨時にも対応したポンプ場の操作ガイダンスの開発を行った。また、同ガイダンスを用いた、流入渠水位、ポンプ井水位の予測もあわせて検証を行った。

## 2. 実験概要

### 2.1 課題

千葉県内のAポンプ場では、ポンプ井の水位が一定の範囲に収まるように、水位によるポンプのオン・オフや台数制御を行っている。降雨等による流入量の増大が見込まれる場合は、過去の流入渠水位の変化や下流のポンプ場の能力などを考慮して、ゲートやポンプの操作を手動で行っている。Aポンプ場の仕様をTable 1、構成をFig. 1に示す。

近年は、集中豪雨により流入水量が急激に変化して

Table 1 Outline of Plant A

施設名称	Aポンプ場 (中継ポンプ場)
ポンプ	φ350 mm×15.2 m <sup>3</sup> /min : 1台
	φ400 mm×26.0 m <sup>3</sup> /min : 1台
	φ400 mm×28.0 m <sup>3</sup> /min : 1台 (予備機)

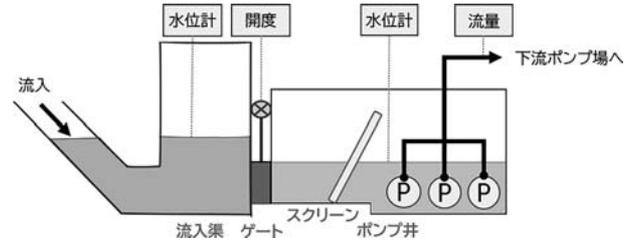


Fig. 1 Configuration of Plant A

おり、技術者の判断がより重要になっている。ただ、今後は、労働人口の減少に伴う熟練技術者の確保など、下水道で共通する将来的な課題もある。

本ポンプ場では、前述の課題解決に加えて、運転管理のDX化を進めるため、流入渠水位、ポンプ井水位をガイダンスする仕組みを開発した。その際、同水位の予測に要する流入流量や流入管内貯留量は不明なため、AIを活用し、既存のデータと組み合わせて必要なパラメータを推定することで、予測をする仕組みを構築し、検証を行った。

### 2.2 システム概要およびデータ

現在の流入渠水位やゲート開度から、将来の流入渠水位およびポンプ井水位を予測するためには、計測機器の無い流量に係るパラメータも必要となる。そこで、流入流量やゲート流量など、計測機器の無いパラメータについては、決定木をベースとした機械学習 (以下、「ML」) を用いて推定を行った。ガイダンスに必要な水位を予測するシステムの概要をFig. 2、MLの学習および検証に用いたデータの仕様をTable 2に示す。

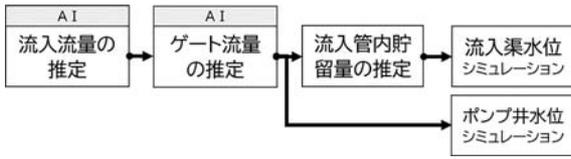


Fig. 2 System configuration

Table 2 Data specifications

データ	A ポンプ場トレンドデータ (分単位)
期間	学習: 2022/04~2023/12 検証: 2024/01~2024/03
変数	流水渠水位, ポンプ井水位, ゲート開度 揚水量, 積算雨量 など

### 2.3 流入流量の推定

正確な流入流量は不明であるが、流入渠水位、ポンプ井水位が平衡状態のとき、揚水量が流入量に等しいことは自明である。流入量を  $Q_{in}$ 、揚水量移動平均180分の時間補正を  $MA_{180}$ 、流入渠水位を  $H_c$ 、ポンプ井水位を  $H_p$  として、以下のように定義した。

$$Q_{in}(t) = \{Ma_{180}(t) | |H_c(t) - H_c(t-1)| \leq 0.1 \text{かつ} |H_p(t) - H_p(t-1)| \leq 0.1 \} \quad (1)$$

$Q_{in}$ を目的変数とし、時間、曜日、雨量などを説明変数として、複数の機械学習の方式を用いて学習を行った。いずれの方式においても、パラメータ探索を実施し、より良い結果が得られたものを採用した。評価は、平均絶対パーセント誤差 (MAPE) で行った。検証データを用いて AI を評価した結果を Table 3 に示す。すべてのモデルで、良好な結果が得られたが、とくに LightGBM (Light Gradient Boosting Machine) については、誤差が少なかった。

同モデルの検証結果を分析したところ、180分積算雨量が0 mmのときの予測誤差の分布が広く、全体の精度を低下する要因であることが分かった (Fig. 3)。

Table 3 Wastewater inflow estimation results

	Random Forest	XGBoost	LightGBM	CatBoost
MAPE	9.15%	8.36%	<b>8.35%</b>	8.53%

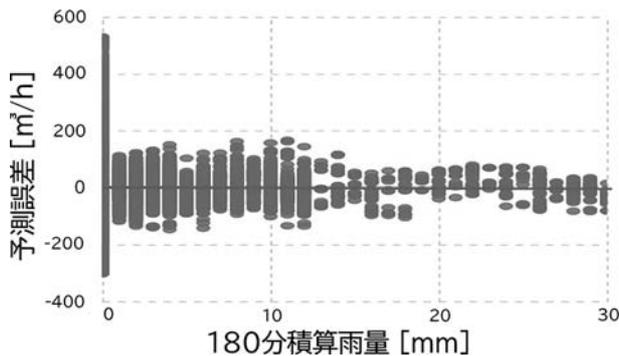


Fig. 3 Accumulated precipitation and prediction error

そのため、学習データを積算雨量が0と0以外に分割したうえで、2つのモデルを分けて学習することとした。この積算雨量別のモデル (Mix) を用いて、検証を行ったところ、さらに精度が改善されることが分かった (Table 4)。

Mix モデルを用いて、検証データによる降雨時の流入流量の推定を行った。積算雨量の増加に伴い、予測した流入流量も追従するように増加した。実績値としている揚水量 (180分移動平均時間補正) と比較したところ、降雨時の揚水量の増加と流入流量の推定値の増加は、ほぼ一致しており、流入流量の推定に、本モデルは利用可能と推察した (Fig. 4)。

Table 4 Results of the combined model

	LightGBM	Mix
MAPE	8.35%	<b>7.98%</b>

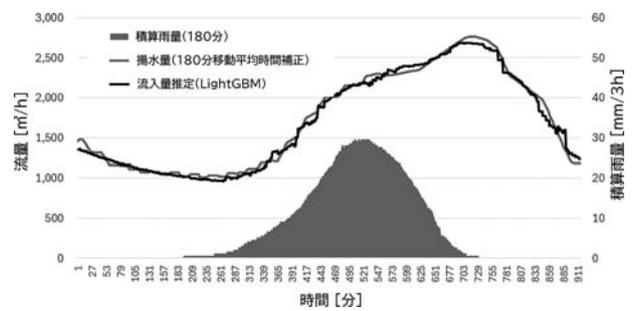


Fig. 4 Estimated inflow vs. precipitation

### 2.4 ゲート流量の推定

ポンプ場では、流入ゲートの開閉で通過する流量を変化させて、流入渠やポンプ井の水位を制御している。そのため、流入ゲートの流量は、将来の水位を予測するポンプ場運転操作ガイダンスには非常に重要となる。一般的に、流入ゲートの流量計算には流量係数が必要となるが、ゲート操作前後の潜り流量やポンプの揚水による影響を受けるため、より複雑な計算を要する。そこで、既存のデータを活用して、MLによるゲート流量の推定を行うことにした。揚水流量を  $Q_{out}$  [m³/h]、ポンプ井水量を  $V_p$  [m³] としたとき、ゲート流量  $Q_g$  [m³/h] を以下のように定義した。

$$Q_g(t) = Q_{out}(t) + V_p(t) - V_p(t-1) \quad (2)$$

$Q_g$ を目的変数とし、ゲート開度、流入渠水位、ポンプ井水位などを説明変数として、2.3と同じ学習方式、パラメータ探索、評価方法を用いて ML を行った。検証データを用いて ML を評価した結果を示す (Table 5)。2.3、2.4のいずれも LightGBM がより良い結果を得られたため、MLの学習方式は LightGBM に統一した。

**Table 5** Gate flow rate predictions (MAPE)

	Random Forest	XGBoost	LightGBM	CatBoost
MAPE	2.10%	1.52%	<b>0.49%</b>	3.34%

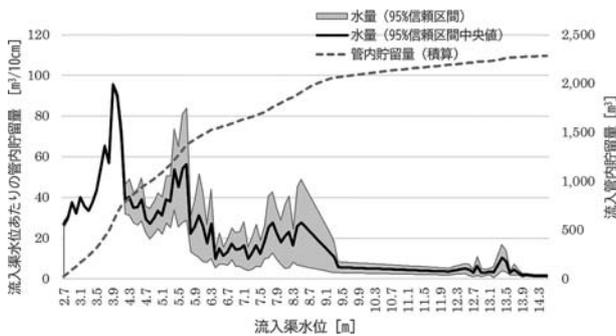
## 2.5 流入管内貯留量の推定

流入渠水位  $H_c$  が  $a$  のときの時刻を  $t$ 、値が  $b$  に変化した時刻を  $t+c$ 、推定流入流量を  $Q_{in}$ 、推定ゲート流量を  $Q_g$  したとき、流入渠水位  $H_c$  が高さ  $a$  から  $b$  に変化する場合の流入渠貯水量の変化量  $\Delta V_c$  を以下のように定義した。

$$\Delta V_c(a, b) = \sum_{t=1}^c (Q_{in}(t) - Q_g(t)) \times \Delta t \quad (3)$$

ただし、流入渠水位の計測データは 10 cm 単位かつ 1 分単位であり、流入渠水位が極端に高い・低いケースはサンプル数が限定されることから、少ないデータでも信頼区間を割り出すことが可能なブートストラップ法を適用した。

管内貯留量の推定の結果を示す (Fig. 5)。流入渠水位が 4.1 m 以内は信頼区間が狭いため、推定された貯留量の誤差は小さいと推察できる。4.2 m 以上はサンプル数が少ないためか、信頼区間は広く、水位当たりの貯留量の誤差は大きい。ただし、今回のガイダンスでは、現在の流入渠水位から、流入量やゲート流量による貯水量の増減量を計算し、将来の流入渠水位を計算する。そのため、流入渠の水量等は、毎分のトレンドを取得することでリセットされ、誤差の蓄積はしないため、各水位における 95% 信頼区間の中央値を推定貯留量として用いることとした。

**Fig. 5** Estimation results of in-pipe storage volume

## 2.6 シミュレーション結果

2.3, 2.4, 2.5 の各項の結果を用いて、流入渠水位、ポンプ井水位シミュレーションを行い、検証データを用いて、精度を確認した。評価方法は、検証データの各時刻において、10 分以内の予測水位と実績の誤差のデータ比率とした。その間のポンプやゲートの操作は、実際に行われた操作と同等のものと仮定した。

予測時間は 10 分間と短目ではあるが、流入渠水位、ポンプ井水位ともに、予測誤差はほぼ 20 cm 以内に

収まり、実用的な精度であった (Table 6, Table 7)。また、降雨時には、流入渠水位の上昇が予測できており (Fig. 6)、流入流量の推定、管内貯留量の推定が概ね機能していることが窺えた。

本シミュレーションの結果から、過去のデータで必要なパラメータを推定して、流入渠やポンプ井の水位予測が可能であることが分かった。

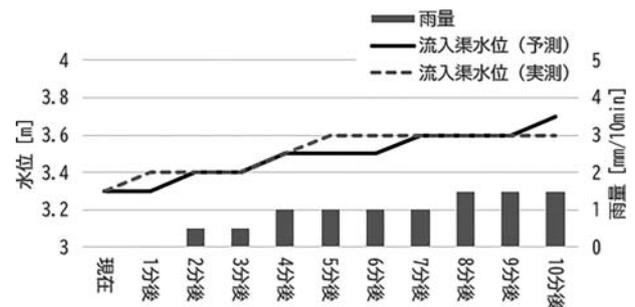
現在、この水位予測をポンプ場運転操作ガイダンスとして、技術者に見える形で情報提供を行っており、引き続き、ガイダンスの長期運用による精度の向上を目指したい。

**Table 6** Inflow channel water level simulation

誤差	3分後	5分後	7分後	10分後
10 cm 以内	97.58%	97.30%	89.43%	80.98%
20 cm 以内	99.27%	99.22%	97.58%	96.60%

**Table 7** Pump well water level simulation

誤差	3分後	5分後	7分後	10分後
10 cm 以内	92.53%	87.21%	62.59%	46.06%
20 cm 以内	96.51%	92.71%	76.63%	66.35%

**Fig. 6** Inflow channel water level predictions (2024/3/1 4:22)

## 3. 結果とまとめ

A ポンプ場におけるポンプ場運転操作ガイダンスの開発に伴い、既存のデータから流入流量、ゲート流量、流入管内貯留量の推定を行い、流入渠水位、ポンプ井水位の予測と検証を行った。結果として、降雨時であっても、多くの誤差は 20 cm 以内に収まり、概ね、期待した結果が得られた。

既存の下水道処理施設は、人による監視や操作を前提として、最低限のセンサー類のみが設置されているところも多い。ポンプ場運転の DX 化、効率化のためには、本報のように、既存のデータを活用した AI による推定や、構築した AI によりデータ生成を行い、さらにそれらを AI で活用する等のシステムが必須になると考える。

今回のポンプ場運転操作ガイダンスでは、流入ゲートやポンプの操作は、現状の運転範囲内を想定している。今後は、様々な運転操作パターンに対するシミュ

レーションや、ガイダンスの予測値と実績値のフィードバックを経て、運転操作ガイダンスの精度向上、他ポンプ場への手法の適用などを目指していきたい。

AIは、当社が持つ長年の水処理技術の知見を活かせる基盤技術であり、今後も引き続き、運転管理の分野で適用や検証を行い、実用化を推進していきたい。

#### 参考文献

- 1) 柏崎拓成，湛記先：下水処理場における AI を活用した予測や画像診断について，第 58 回下水道研究発表会講演集，pp. 761-763（2021）