

〈研究発表〉

AI を活用した下水流量の予測

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

下水流量の変動予測は、水質の安定化のみならず、雨天時の事故防止やエネルギー効率の良い運転に重要である。また、運転管理の広域化により、下水流量の急激な変動を事前に捉える必要性も高まっている。こうした課題を解決するため、ディープラーニング技術を用いた下水流量の予測を行った。上流のポンプ場の揚水量を移動平均化し、時間遅れを補正した水量を直接予測することでリアルタイムでの予測を可能とした。また、学習時には含まれない中長期の水量の偏りを補正する方法についても検証を行った。

キーワード：予測, ディープラーニング, AI

原稿受付 2021.7.2

EICA: 26(2・3) 35-38

1. はじめに

A 処理場では、現地の熟練技術者により、処理場の特性、季節などの周期性、気象情報等に基づき、数時間の流入水量の変動を予測し、水質の安定化や雨天時の溢水等の事故の未然防止、エネルギー効率の良い運転等に役立っている。このような地域や施設に特化した運転管理のノウハウは、今後、労働人口の減少で継承が難しくなると予想される。また運転管理の広域化が進むことで、より遠方の施設の運転支援が必要となるため、将来の流入水量の変動に合わせた計画運転が益々重要になる。そこで今回、ニューラルネットワーク（以下「NN」という。）を用いて、過去の施設の流入水量を学習して、数時間後の流入水量の予測を行う NN モデルの構築および精度の向上に関する手法について検証を行った。

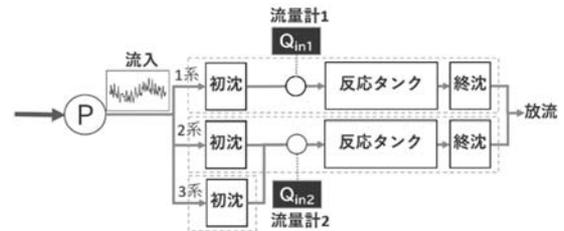


Fig. 1 Diagram of plant A

2. システムの構成

2.1 施設概要

A 処理場の施設概要を Table 1 に、施設の概念図を Fig. 1 にそれぞれ示す。

Table 1 Outline of the plant

排除方式	分流式
処理能力	21,300 m <sup>3</sup> /日 (最大処理能力)
流入水量	11,500 m <sup>3</sup> /日 (2019 年平均)

2.2 データの仕様

A 処理場における流入水量は、1 系および 2 系の流量を合算し、120 分後方移動平均化したデータ（以下「平均水量」という。）を用いた。また、流入水量との相関性が確認された項目も説明変数に加えた。NN の学習および検証に用いるデータの仕様を Table 2 に示す。

Table 2 Data specifications

データ	A 処理場トレンドデータ (分単位) 気象庁過去気象データ (分単位に変換)
期間	学習: 2019/7~2020/12 検証: 2021/1~2021/5
説明変数	多変量時系列 (平均水量, 平日休日, 曜日, 時, 1 時間降水量)
目的変数*	① 平均水量 (1 分後から 5 分後まで 1 分間隔) ② 位相補正した平均水量 (1 分後から 360 分後まで 30 分間隔)

\*①は入力バイアス補正用, ②は予測用

2.3 予測方法

平均水量は、後方移動平均の特性から遅れ位相が発生するため、リアルタイムで流入水量の増減を把握する予測対象として適切ではない。そこで、予測する流



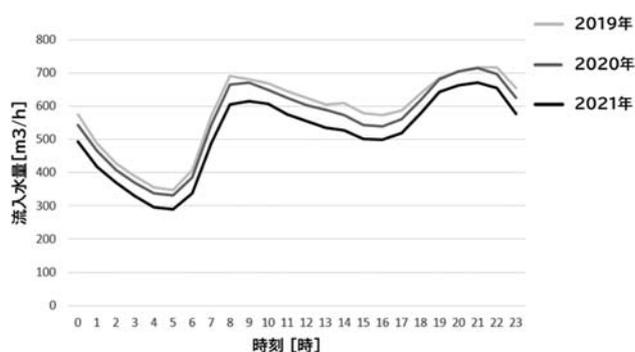


Fig. 6 Average of inflow water volume at plant A

また、同処理場の直近3年の時間別の平均流入水量を算出したところ、対象地域の人口の減少やコロナ禍による生活様式の変化により、流入水量は前年比で平均8.5%減少している (Fig. 6)。

そこで今回、NNによる予測値と実測値との差分(誤差)の平均から、NNが学習しきれなかった入力値のバイアス成分を計算し、その後の予測値に対して補正する(以下、「入力バイアス補正」という。)ことで、予測誤差の低減が可能か、検証を行った。

入力バイアス補正值とは、NNに短期的予測を行わせ、実測値との差分を平均化することで、学習後のNNでは吸収しきれなかった入力データのバイアス成分を算出した値である。NNが短期的予測を行うサンプル数、予測誤差を平均化する対象時間範囲については、いくつかパターンが考えられるが、今回の検証では、5点予測した平均誤差を過去24時間分平均化するパターンで検証を行った。

入力バイアス補正值  $B$  は、現在時刻  $t$  から  $t+n$  までの SMA の平均値を  $ASMA(t)$ 、NN が予測した SMA を  $PSMA$  とすると、以下の式で表される。

$$ASMA(t) = \frac{1}{n} \sum_{i=1}^n (PSMA(m, t+i) - SMA(m, t+i))$$

$$B = \frac{1}{n} \sum_{i=1}^{720} ASMA(t-i)$$

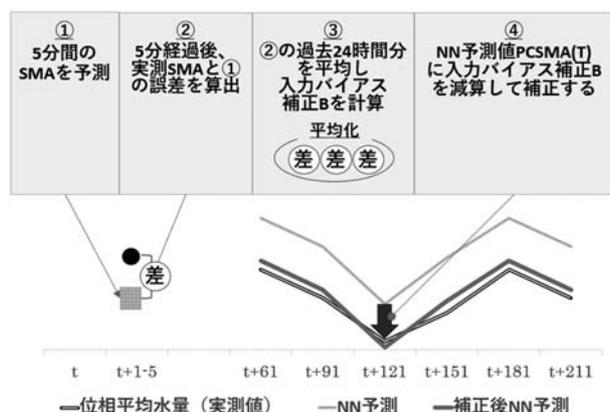


Fig. 7 Diagram of input bias collection

この  $B$  を用いて、予測時刻  $T$  において NN が予測した  $CSMA$  を  $PCSMA$  とすると、入力バイアス補正後の予測値  $ASMA$  は次の式で表される。

$$ASMA(T) = PCSMA(T) + B$$

入力バイアス補正のイメージを Fig. 7 に示す。

### 3. 検証

#### 3.1 下水流量の予測結果

LSTM および CNN のいずれも、構造探索やハイパーパラメータ調整を行ったうえで、検証データを用いて、5か月間の位相補正水量を予測した。また、CNNの予測結果を用いて入力バイアス補正も検証した。各モデルの検証結果を Table 3 に示す。学習時の MSE は 0.0013、MAPE も 3~6% となり、いずれのモデルにおいても実用性のある精度が得られた。

Table 3 Validation results of the NN model

Model	Million Mult-Adds	MSE	MAPE					
			61分後	121分後	181分後	241分後	301分後	361分後
LSTM	81.43	0.00136	3.59%	4.57%	4.80%	5.04%	5.41%	5.71%
CNN	1.25	0.00133	3.98%	<b>4.83%</b>	<b>5.07%</b>	5.27%	5.44%	5.64%
CNN (バイアス補正)			<b>3.97%</b>	4.84%	5.08%	<b>5.22%</b>	<b>5.33%</b>	<b>5.52%</b>

入力バイアス補正は、MAPE を最大で 0.12% 低減する効果が得られ、精度の向上には寄与したが、目標とした MAPE の 1% 以上の低減にはつながらなかった。いずれのモデルも誤差が同様の数値であることから、NN モデルの最適化が進み、教師データと検証データの流入水量の差 8.5% は、NN モデル内のパラメータで調整可能な範囲であったと推察できる。このあたりは、入力値が短期間で大きく変動するデータと全体変動が大きいデータで追加の検証が必要と考える。

#### 3.2 時系列予測における NN モデルの比較

LSTM および CNN のいずれも精度が大きく異なることはなかった。しかしながら、LSTM については、学習時の 1 回の計算量が CNN の 65 倍あり、学習時には大差がついた。また、予測時には大きな差は見られなかった (Fig. 8)。

以上のことから、予測精度だけ鑑みれば、いずれのモデルでも運用が可能であるが、運用中にデータを追加入手して転移学習を行う等、今後もデータが増大していく想定では、LSTM の学習コストは重く、運用開始後の NN の更新には注意が必要である。

#### 3.3 降水時の誤差

CNN の結果を例に、61 分後、181 分後、361 分後の位相平均水量の実測値および予測値の散布図を

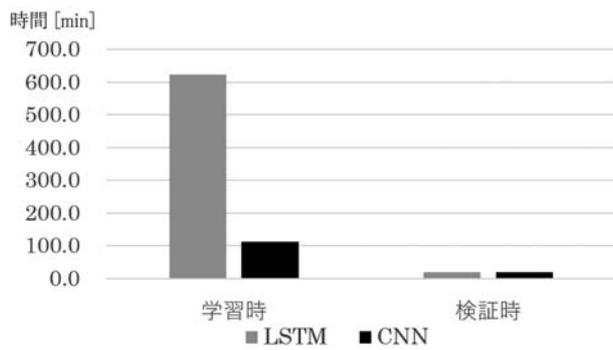


Fig. 8 Comparison of training and validation time with different NN models

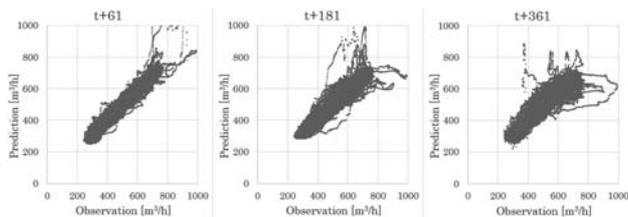


Fig. 9 Correlation between observed and predicted values (CNN)

Fig. 9 に示す。多くのデータは、誤差が少ない比例関係でプロットされているが、一部、大雨の影響による大きな誤差が生じていることが分かる。

A 処理場の下水流量は、降水量が毎時 1 mm であれば、予測への影響は少なかった (Fig. 10)。

しかしながら、短期間の毎時 6 mm を超える降水があった際、降水が観測されていない時点の 6 時間後予測は、通常通りの予測で推移し、降水が観測された時点で予測できなかった流量分、遅れて予測値が上昇する挙動が見られた (Fig. 11)。

このような降水時においても、6 時間先の下水流量の予測精度を安定化させるには、降水が観測された後の短期間の予測で長期の予測を補正することや、気象データに基づいた降水予測モデルを活用する等の方法が考えられる。引き続き、今後の課題として取り組みモデルの改良を進めたい。

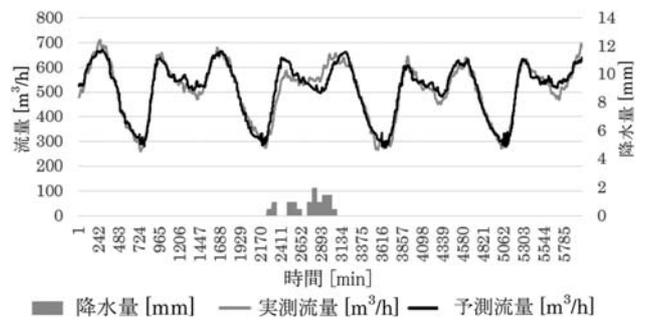


Fig. 10 Effect of precipitation on predictions after 361 minutes (precipitation around 2 mm)

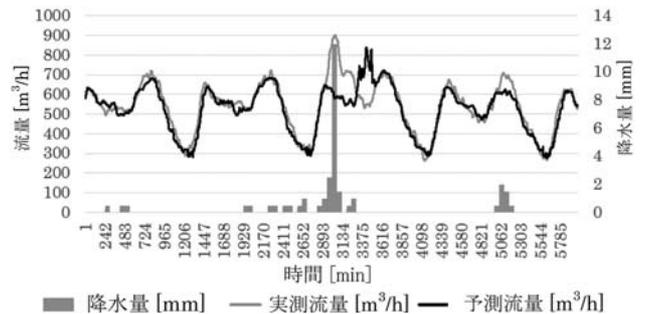


Fig. 11 Effect of precipitation on predictions after 361 minutes (12 mm of precipitation)

#### 4. ま と め

今回、ディープラーニング技術を用いた下水流量予測 AI の検証を行った。流量予測は、多くの場所で様々な手法で実用化されているが、日々進歩しているディープラーニング技術を活用することで、まだまだ精度の向上が見込める分野でもある。今後は、本件の補正技術のさらなる改善や検証を図るとともに、新たな NN モデルの導入、気象データの活用をすすめ、精度の向上や他所への応用を進めていく。

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、運転管理の分野での適用や検証、実用化を推進していきたい。