

## 〈論文〉

## 雨水ポンプ所への雨水流入量の機械学習による予測手法の評価

陰山 晃 治<sup>1)</sup>, 崎村 茂 寿<sup>1)</sup>, 田所 秀 之<sup>2)</sup>, 山本 智 裕<sup>3)</sup>

<sup>1)</sup> (株)日立製作所 研究開発グループ 脱炭素イノベーションセンタ 環境システム研究部  
(〒319-1292 茨城県日立市大みか町7-1-1 E-mail: koji.kageyama.gf@hitachi.com, shigetoshi.sakimura.zp@hitachi.com)

<sup>2)</sup> (株)日立製作所 制御プラットフォーム統括本部 社会制御システム設計部  
(〒319-1293 茨城県日立市大みか町5-2-1 E-mail: hideyuki.tadokoro.dw@hitachi.com)

<sup>3)</sup> (株)日立製作所 水・環境ビジネスユニット 社会システム本部 東部プロジェクトマネジメント第一部  
(〒101-0021 東京都千代田区外神田1-5-1 E-mail: tomohiro.yamamoto.bh@hitachi.com)

## 概 要

内水氾濫を防止する雨水ポンプの運転支援を目的に、機械学習を用いた流入量予測手法を評価した。同一条件下で重回帰モデル、全結合型ニューラルネットワークモデル、CNN+RNNモデルの3種類の予測手法を比較した結果、短期予測には重回帰モデル、長期予測にはCNN+RNNモデルが適することが分かった。これらを組み合わせたハイブリッドモデルを用いることで、予測誤差の絶対値の平均値は対象としたポンプ所の雨水ポンプの揚水量に対する比率として、5分将来の予測値で0.2%、60分将来では8.5%となる見込みを得た。

キーワード：流入量予測, AI, 全結合型ニューラルネットワーク, 畳み込みニューラルネットワーク, 回帰型ニューラルネットワーク

原稿受付 2022.12.13 原稿受理 2023.2.14

EICA: 27(4) 71-81

## 1. はじめに

局所的な大雨の発生頻度が増加しており、雨水による水害リスクも高まりつつある。分流式下水道を採用している地域の場合、雨水は地下に整備された雨水管へ流入する。雨水管に流入した雨水は合流しながら標高が低い管に向かって流下する。最下流の雨水管の水位が近隣の河川水位より低い場合、雨水はポンプ所の雨水ポンプで揚水されて河川へ放流される。雨水ポンプの運転が不適切な場合、内水氾濫が発生し地域に被害が発生する可能性もある。

雨水ポンプは多くの場合自動運転モードで運転されるが、大雨の場合には運転員が広域の降雨情報を目視確認し、蓄積した経験を活用して必要に応じ手動介入する場合もある。より適切な対処が取れるよう、雨水ポンプ所への雨水流入量の将来予測とその予測値に基づく運転ガイダンスを提示できる運転支援システムが求められている。

雨水流入量を単純な式で予測する手法として重回帰モデルがある<sup>1)</sup>。これは、雨量や現時点より過去の流入量など予測で使う説明変数に係数を乗じ、その線形和として次の時刻の流入量を算出する方法である。10~30分将来の予測誤差の絶対値の平均がポンプ1台の吐出量の43.0~53.5%であり、ポンプ1台を待機運転すれば実用になるとの報告がある<sup>1)</sup>。

重回帰モデルの延長線上にあるモデルとして、降雨

強度の2乗や3乗の項を説明変数として用いた非線形のARX (Auto Regressive eXogenous) モデルも提案されている。この手法は線形重回帰モデルよりも精度が良く、英国道路研究所で開発されたRRL (Road Research Laboratory) 法と同程度の精度であったと報告されている<sup>2)</sup>。

RRL法は都市域の雨水流出現象を把握するため計画時に用いられる手法である。雨水の流出割合を考慮した有効降雨の算出、管路長に基づく流出地点までの到達時間の算出、それらの掛け合わせによって雨水流入量を求めるものである<sup>2,3)</sup>。RRL法については修正RRL法<sup>4)</sup>や動的RRL法<sup>5)</sup>など複数のバリエーションに関する報告もある。このうち、修正RRL法は浸透域と不浸透域を区別して有効降雨量に補正を加えたものである。動的RRL法は流入点及び流下時間を動的に求めるものであり、集中豪雨時に管渠内で水が貯留された場合、雨水流入点が移動する現象を反映した手法である。

一方でIT技術の進歩にとまない、ニューラルネットワークに代表される機械学習が様々な分野で実用化されつつある。雨水流入量や管内水位の予測についても例外ではなく、適用事例が報告されている。典型的な例として、全結合型ニューラルネットワークを適用した事例が複数報告されている<sup>6-8)</sup>。たとえば降雨量、ポンプ井水位、ポンプ吐出量などを説明変数とする全結合型ニューラルネットワークを用いることで、ほぼ

満足のいく流入量の予測精度が得られたとの報告がある<sup>6)</sup>。流入量の予測ではなく流入渠水位を全結合型ニューラルネットワークで予測する取組みもあり、比較的変動の小さい降雨では2層、短時間に降雨強度50 mm/hを超過するような降雨では4層のモデルが優れており、予測対象とする降雨強度を変えた複数のモデルを構築し、状況に応じて最適なものに切り替えて精度を向上すべきとの報告もある<sup>7)</sup>。さらに、流出解析を実施して求めた模擬データ結果を教師データとして追加する取組みもある。予測段階まで達しておらず再現状況の確認までしか報告されていないが、水位の挙動は立ち上がり部分などの特徴が再現できたと報告されている<sup>8)</sup>。

これら既往の論文ではそれぞれ異なる流域における異なる対象を異なるモデルで予測しているため、各モデルの予測性能を横並びで評価することは困難である。

本論文では同一流域における同一対象を異なるモデルで予測することにより、モデルの予測性能の評価を試みた。物理モデルに基づかないブラックボックスの機械学習モデルとして、上述した重回帰モデルと全結合型ニューラルネットワークモデルに加え、降雨の2次元の位置関係と時系列データを取り扱う点を考慮した独自のニューラルネットワークモデルも比較対象とした。

## 2. 方法

### 2.1 説明変数

評価にあたり、東西が約3 km、南北が約5 kmのM流域を対象とした。M流域には雨水を河川へ放流する複数台の雨水ポンプ（1台あたり揚水量：300（小）、600（大） $\text{m}^3/\text{min}$ ）を備えたSポンプ所が整備されている。設置場所により程度は異なるが、このSポンプ所への雨水の流入量予測の説明変数として水位は相関性が高いと考えられた。今回はFig. 1に示す

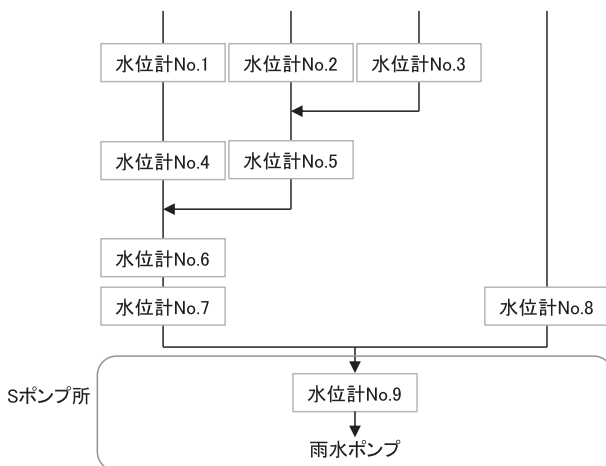


Fig. 1 Water level gauge diagram at M basin

水位計1~9で水位情報を得られると仮定した。

流入量予測の説明変数として、降雨強度の空間分布も有効である。そこで、流域を小さな矩形に分割したメッシュそれぞれについてレーダー雨量計で計測される降雨強度情報を用いた。今回用いたレーダー雨量計のデータ仕様では緯度方向と経度方向への分割刻み幅は150 mであったため、M流域を150 m刻みで分割した総数888個（ $=24 \times 37$ ）のメッシュの降雨強度情報を用いると仮定した。

さらに、予測する時点から過去の流入量も将来の流入量の予測に有効な情報であるため、説明変数として用いた。

### 2.2 下水道/河川統合解析ソフトウェアによる模擬流入量データの生成

モデルの予測性能の評価には、モデルの学習データおよび評価データとして、説明変数および予測対象である水位、降雨強度、流入量の情報が揃った時系列のデータがセットで必要となる。大雨時の流入量実績データは短期間に多数得られないため、本論文では下水道/河川統合解析ソフトウェア「InfoWorksICM」にさまざまな降雨強度データを与えて複数ケースの計算を実施し、模擬流入量データや模擬水位データを生成した。

まずInfoWorksICMに雨水管の管断面形状やサイズ、長さ、埋設深度、マンホールの位置情報などの情報を設定し、地表面に降った雨水が流入するマンホールを割り当てる。設定した管網情報にM流域での2020/7/5~10/18の降雨強度の実績値を与えて算出した水位と流入量を評価データとして用いた。一方、学習データはFig. 2の太枠矩形で示すように東西および南北に15 km離れたA~D、東西に3.6 km、南北




Fig. 2 Positional relationship between M basin and surrounding area A~H

に 5.6 km 離れた E~H の領域における同期間の降雨強度の実績データを与えて求めた流入量と水位を用いた。

### 2.3 流入量予測モデル

流入量の予測範囲に関し、溢水の生じないポンプ運転制御には 1 時間未満の予測が必要とされている<sup>1)</sup>。毎分の流入量予測は計算量が多いと考えられたため、本論文では 5 分将来、10 分将来、20 分将来、40 分将来、60 分将来の 5 時点における流入量予測を試みた。

#### (1) 重回帰モデル

重回帰モデルでは、式(1)で示すように説明変数の線形和で予測対象の値を計算する。右辺の水位と流入量は、現在から過去まで 1 分刻みで合計 64 分間のそれぞれ 64 個の時系列データを用いた。降雨強度データは 1 時刻だけでも 888 個と多いため 1 分刻みではなく、現在、8 分過去、16 分過去の 3 時刻のデータを用いた。結果として、説明変数の個数は以下の計 3304 項目となる。

- ・水位：9 センサ×64=576 項目
- ・流入量：1 項目×64=64 項目
- ・降雨強度：888 個×3 (現在, 8 分過去, 16 分過去)  
=2664 項目

$$\hat{Q}(k, t) = \sum a(k, i) \cdot L(t-i) + \sum b(k, i) \cdot Q(t-i) + \sum c(k, i, m) \cdot R(j, t-m) \quad (1)$$

ここで、

- $\hat{Q}(k, t)$  : 現在時刻  $t$  における  $k$  分将来の流入量予測値 ( $k=5, 10, 20, 40, 60$ )
- $L(t-i, n)$  : 水位計  $n$  での時刻  $t-i$  における水位 ( $i=0, 1, 2, \dots, 63, n=0, 1, 2, \dots, 8$ )
- $Q(t-i)$  : 時刻  $t-i$  における流入量 ( $i=0, 1, 2, \dots, 63$ )
- $R(j, t-m)$  : 時刻  $t-m$  における降雨強度 ( $j=0, 1, 2, \dots, 887, m=0, 8, 16$ )
- $a(k, i, n)$  : 水位項の係数 ( $k=5, 10, 20, 40, 60, i=0, 1, 2, \dots, 63, n=0, 1, 2, \dots, 8$ )
- $b(k, i)$  : 流入量項の係数 ( $k=5, 10, 20, 40, 60, i=0, 1, 2, \dots, 63$ )
- $c(k, i, m)$  : 降雨強度項の係数 ( $k=5, 10, 20, 40, 60, i=0, 1, 2, \dots, 63, m=0, 8, 16$ )

#### (2) 全結合型ニューラルネットワークモデル

全結合型ニューラルネットワーク (NN, Neural Network) モデルは、説明変数を線形・非線形変換する処理単位 (ノード) が層ごとにネットワークとして結合した数理モデルである。層数および各層のノード数が明記されていた文献<sup>8)</sup>に基づき、Fig. 3 に示すような第一中間層：10 ノード、第二中間層：5 ノード、出力層：1 ノードの全結合型 NN モデルを準備した。重回帰モデルに比べてモデルの数式が複雑となるため、




Fig. 3 Fully connected neural network model

係数の個数は 31191 個となり大幅に増加した。重回帰モデルの場合と同じく、説明変数は以下の計 3304 項目となる。

- ・水位：9 センサ×64=576 項目
- ・流入量：1 項目×64=64 項目
- ・降雨強度：888 個×3 (現在, 8 分過去, 16 分過去)  
=2664 項目

#### (3) CNN+RNN モデル

全結合型 NN モデルの進化したモデルとして、画像認識など 2 次元データについては畳み込みニューラルネットワーク (CNN, Convolution Neural Network) モデル、文章認識など時系列データについては回帰型ニューラルネットワーク (RNN, Recurrent Neural Network) モデルの適用がさまざまな分野で進んでいる。降雨強度データは上述のように  $24 \times 37$  の 2 次元データでありそれぞれの位置関係が意味を有する。したがって 1 次元の説明変数としてしか扱えない重回帰モデルや全結合型 NN モデルに対し、2 次元の位置関係の情報を考慮できる CNN モデルを適用することで予測精度を向上できる可能性があると考えた。一方、水位や流入量は時系列データであり、過去の時刻の値が影響するため RNN が適している可能性があると考えた。これらを組み合わせた構造を Fig. 4 で示す「CNN+RNN モデル」として考案した。全結合型 NN モデルと同様にモデルの数式は複雑であり、係数の個数は 25551 個となった。

重回帰モデルや全結合型 NN モデルの場合と同じく説明変数は以下の計 3304 項目とした。

- ・水位：9 センサ×64=576 項目
- ・流入量：1 項目×64=64 項目
- ・降雨強度：888 個×3 (現在, 8 分過去, 16 分過去)  
=2664 項目






Fig. 4 CNN+RNN model

### 3. 結果

#### 3.1 模擬流入量データ

Fig. 2 で示した A~H の領域における 2020/7/5~10/18 の降雨が M 流域に発生したと仮定して算出した流入量の計算結果を Fig. 5 に示す。期間の合計は約 220 日間である。これを学習データとして用いた。これに対し、M 流域へ同期間の M 流域の降雨強度データを与えて算出した流入量の計算結果を Fig. 6

に示す。期間は約 29 日間であり、この結果が評価データすなわち正解値となる。重回帰モデル、全結合型 NN モデル、CNN+RNN モデルで求めた流入量予測値とこの正解値の比較結果を以下に述べる。

#### 3.2 流入量予測モデルによる予測結果

##### (1) 重回帰モデル

重回帰モデルで求めた流入量予測値のトレンドグラフを Fig. 7 に示す。図中の黒線が予測値であり、灰

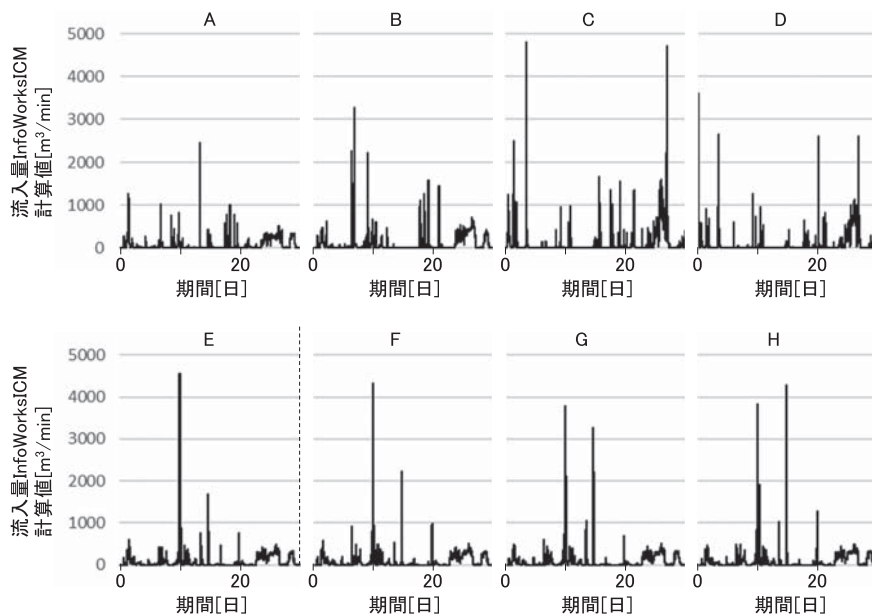


Fig. 5 Training data prepared by InfoWorksICM




Fig. 6 Test data prepared by InfoWorksICM

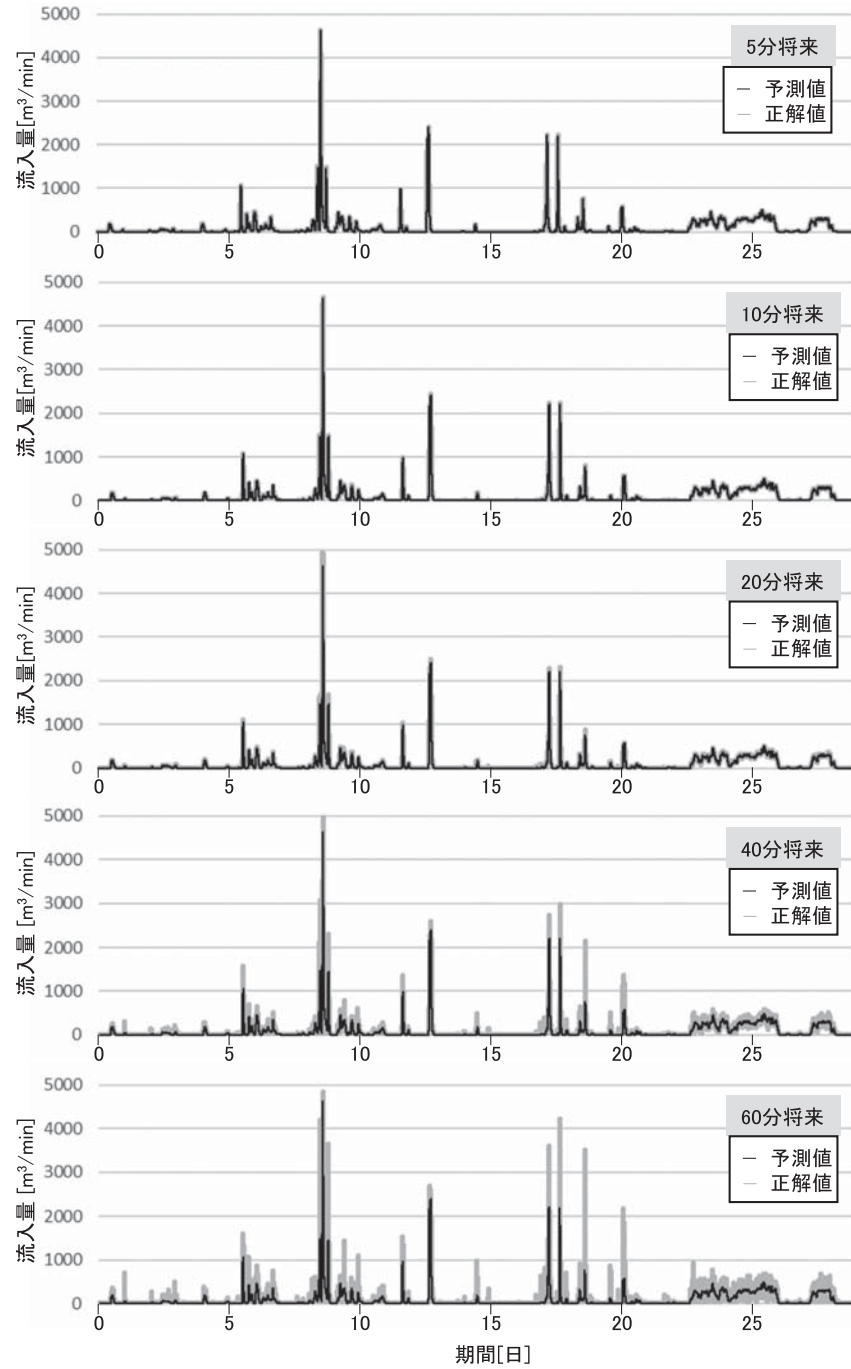


Fig. 7 Trend of inflow prediction value (multiple regression model)

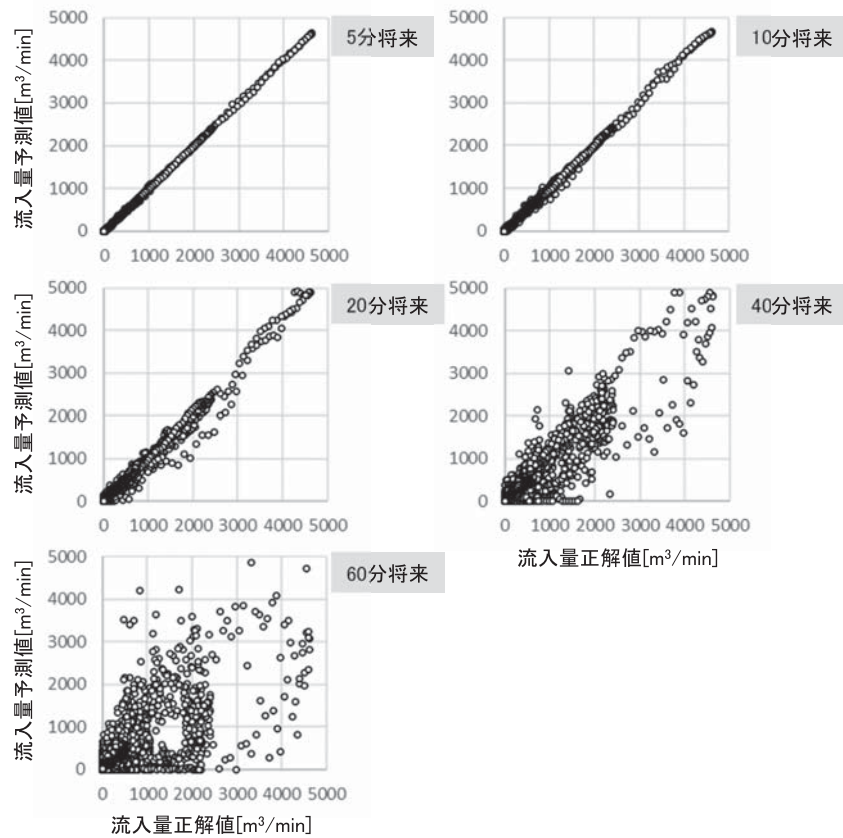


Fig. 8 Correlation diagram of inflow correct value and prediction value (Multiple regression model)

色線が Fig. 6 に示した正解値を示す。最上段のトレンドグラフは 5 分将来の予測値であるが、正解値との違いはほぼ確認できず良好な予測結果となった。下段へ行くにしたがって流入量のピーク高が異なる、あるいはピークが無い期間にピークが存在するよう予測するなど、予測値と正解値との違いは増大した。すなわち、短期予測に比べて長期予測は難しいことが分かった。

Fig. 7 のようにトレンドグラフでは予測値と正解値が重なっている部分も多く詳細な把握が困難なため、予測値と正解値を相関図としてプロットした結果を Fig. 8 に示す。5 つのグラフは 5 分将来から 60 分将来までの結果であり、5 分将来から 20 分将来までの流入量の予測値は正解値と比較的良く一致した。一方、40 分将来や 60 分将来の予測値については大幅に外れている点も確認でき、流入量正解値が 2500  $\text{m}^3/\text{min}$  以上の箇所ではプロットが環状となる箇所があった。これは Fig. 6 の 8 日目に一度だけ生じた流入量 4500  $\text{m}^3/\text{min}$  に達する大雨時の予測結果であり、正解値に対して予測値が時間遅れとなったため相関図ではプロットが環状に並んだものである。

評価データには流入量が 4500  $\text{m}^3/\text{min}$  に達する大雨が 1 回しか無いのに対し流入量が 0  $\text{m}^3/\text{min}$  となる点が多数あるため Fig. 8 から受ける印象より小さい値だが、単純計算で求めた予測誤差の絶対値の平均値は 5 分将来で 0.7  $\text{m}^3/\text{min}$ 、10 分将来で 1.9  $\text{m}^3/\text{min}$ 、

20 分将来で 6.1  $\text{m}^3/\text{min}$ 、40 分将来で 20.3  $\text{m}^3/\text{min}$ 、60 分将来で 43.5  $\text{m}^3/\text{min}$  となった。

## (2) 全結合型 NN モデル

全結合型 NN モデルで求めた流入量予測値と正解値との相関図を Fig. 9 に示す。Fig. 8 の結果と同様、近い将来に比べ遠い将来の予測値は正解値と合致しづらい傾向が確認できた。40 分将来や 60 分将来の予測値に関しては、Fig. 8 の重回帰モデルの結果に比べてより正解値に近かった。一方で、20 分将来の予測結果には、流入量の正解値が約 2500  $\text{m}^3/\text{min}$ ～約 4500  $\text{m}^3/\text{min}$  の箇所では環状となる箇所が認められた。これは Fig. 8 の重回帰モデルの結果では明確に認められず、モデルが複雑になると逆に予測の時間遅れが発生する場合もあることが分かった。

予測誤差の絶対値の平均値は、5 分将来で 1.1  $\text{m}^3/\text{min}$ 、10 分将来で 2.6  $\text{m}^3/\text{min}$ 、20 分将来で 4.8  $\text{m}^3/\text{min}$ 、40 分将来で 16.9  $\text{m}^3/\text{min}$ 、60 分将来で 30.8  $\text{m}^3/\text{min}$  となった。すなわち、重回帰モデルの結果に比べ 20 分将来、40 分将来、60 分将来の予測精度は向上したが、逆に 5 分将来と 10 分将来の予測精度は低下した。

## (3) CNN+RNN モデル

CNN+RNN モデルで求めた流入量予測値と正解値との相関図を Fig. 10 に示す。10 分将来や 20 分将来の予測結果には明確に環状となる箇所が認められ、流入量 4500  $\text{m}^3/\text{min}$  に達する大雨時について予測の時

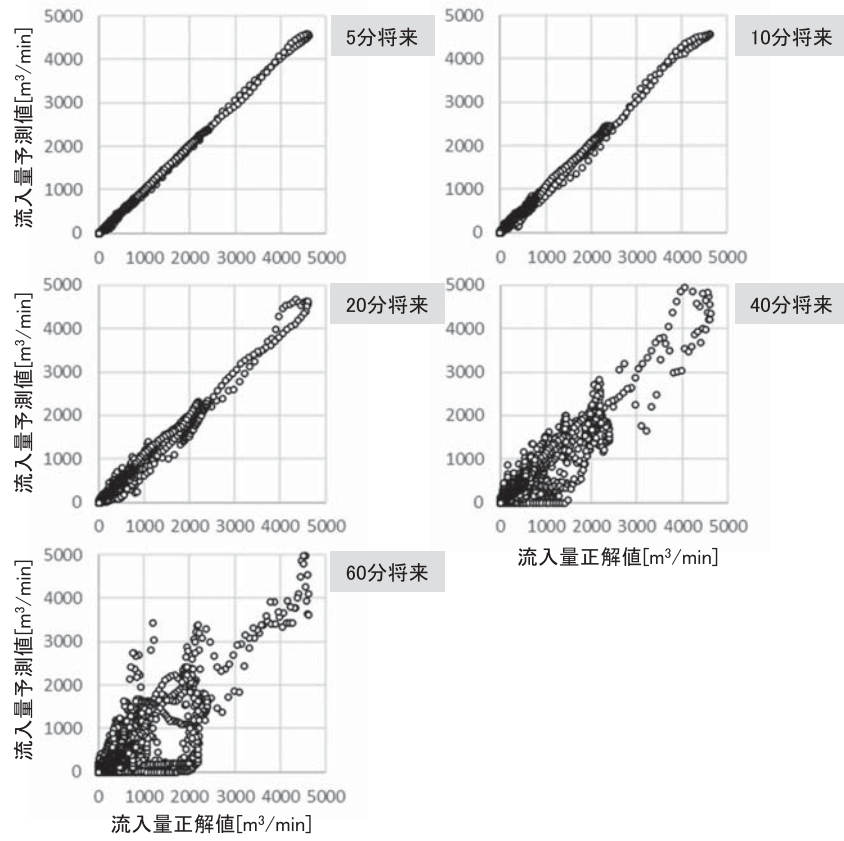


Fig. 9 Correlation diagram of inflow correct value and prediction value (Fully connected neural network model)

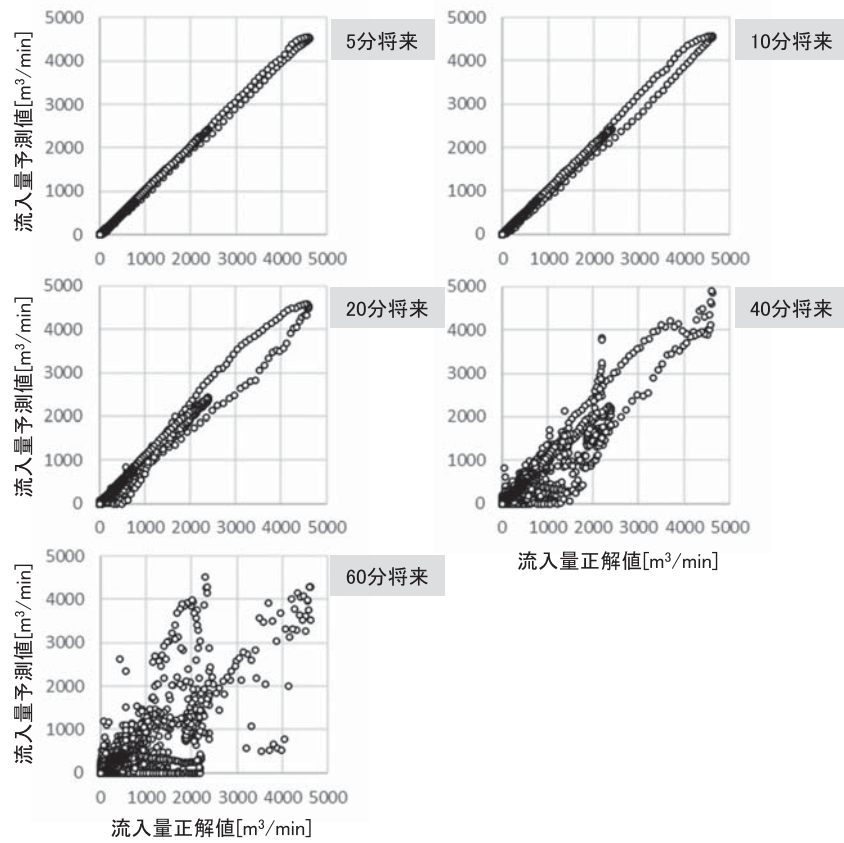


Fig. 10 Correlation diagram of inflow correct value and prediction value (CNN+RNN model)



間遅れがより増大したと言える。ただし 20 分将来の予測結果で流入量の正解値  $2500 \text{ m}^3/\text{min}$  以下の範囲に限定すると、Fig. 9 よりも Fig. 10 の流入量予測値のほうが正解値と一致することも分かった。

予測誤差の絶対値の平均値は、5 分将来で  $6.8 \text{ m}^3/\text{min}$ 、10 分将来で  $3.9 \text{ m}^3/\text{min}$ 、20 分将来で  $4.7 \text{ m}^3/\text{min}$ 、40 分将来で  $13.0 \text{ m}^3/\text{min}$ 、60 分将来で  $25.4 \text{ m}^3/\text{min}$  となった。すなわち、全結合型 NN モデルの結果に比べ 20 分将来、40 分将来、60 分将来の予測精度は向上したが、逆に 5 分将来と 10 分将来の予測精度はさらに低下した。

## 4. 考 察

### 4.1 予測誤差の比較

予測誤差の絶対値の平均値を比較した結果を Fig. 11 に示す。予測誤差は予測する時刻がより将来であるほど増大する傾向を示し、短期予測より長期予測の精度が低いことをいずれの結果でも確認できた。

5 分将来と 10 分将来を対象とした場合、3 つのモデルの中で予測誤差が最小となったのは重回帰モデルであった。一方、20 分将来、40 分将来、60 分将来を対象とした場合の予測誤差は全結合型 NN モデルのほうが重回帰モデルより小さくなり、CNN+RNN モデルでは予測誤差はさらに小さくなった。これは以下のように説明できると考えられた。

地表に到達した雨水は地表面を流れて下水管に流れ込み、より太い下水管へ次々に合流し、幹線をさらに流下して最終的にポンプ所へ到達する。したがって、降雨強度が増加するタイミング、幹線水位が上昇するタイミング、ポンプ所への流入量が増加するタイミングには時間差が生じる。したがって、直前までの流入量やポンプ所への到達時間程度上流の幹線水位は、短期予測への影響が降雨強度よりも大きいと考えられた。本報告のように大雨時の学習データが潤沢ではない条件下では、モデルパラメータの個数が少ない重回帰モデル (3304 個) のほうが、モデルパラメータの個数が多い CNN+RNN モデル (25551 個) よりも適切に学習された可能性が高い。その結果、短期予測につい

ては重回帰モデルの予測精度が高かったと考えられた。

一方、時間差があるため降雨強度は長期予測への影響が直前までの流入量や幹線水位よりも大きいと考えられた。その影響に対し、全結合型 NN モデルは重回帰モデルより複雑な構造であるため柔軟性が高く、結果として長期予測では予測精度が向上したと考えられた。さらに CNN+RNN モデルは降雨強度の 2 次元の位置関係も考慮できるため、長期予測の予測精度がもっとも高かったと考えられた。

### 4.2 予測モデルの係数値

全結合型 NN モデルや CNN+RNN モデルは説明変数が相互に影響しているため、学習時にチューニングされた係数の数値そのものを議論することは困難である。しかし、重回帰モデルの係数はそれぞれ独立した説明変数に乘じられているため、4.1 節の考察の妥当性の確認に活用できると考えた。

学習の結果として求められた重回帰モデルの係数値を Fig. 12 に示す。5 つのグラフは 5 分将来から 60 分将来までの結果である。係数は横軸方向に向かって水位の項  $a_i$  ( $i=1\sim 576$  ( $=9\times 64$ )), 流入量の項  $b_j$  ( $j=1\sim 64$ ), 降雨強度の項  $c_k$  ( $k=1\sim 2664$  ( $=3\times 24\times 37$ )) の順で示した。

まず、水位項の係数  $a$  と降雨強度項の係数  $c$  の振幅の相対関係を評価した。5 分将来の場合、水位項の係数  $a$  の振幅は降雨強度項の係数  $c$  に比べて数倍以上である。10 分将来や 20 分将来ではその比率は減少し、40 分将来では逆に水位項の係数  $a$  よりも降雨強度項の係数  $c$  の振幅のほうが大きい。これは 60 分将来の結果でも同様となった。このことから、短期予測では直前までの水位の情報が大きく影響するが、長期予測となるにつれて降雨強度の情報の影響が増大することが分かった。

次に、流入量項の係数  $b$  の振幅と降雨強度項の係数  $c$  の振幅の相対関係を評価した。5 分将来と 10 分将来の結果では、流入量項の係数  $b$  の振幅と降雨強度項の係数  $c$  の振幅の比率は同程度であった。これらに比べて 20 分将来の結果ではわずかながら降雨強度項の係数  $c$  の振幅の比率が増え、以降 40 分将来や 60 分将来




Fig. 11 Mean absolute value of prediction error






Fig. 12 Coefficient value of the multiple regression model

の結果では降雨強度項の係数cの振幅の比率がさらに増大した。このことから、短期予測では直前までの流入量が大きく影響するが、長期予測となるにつれて降雨強度項の影響が増大することが分かった。

以上のように、短期予測には直前までの水位や流入量の情報が大きく影響するが、長期予測には降雨強度の影響が増大した。降雨強度は2次元の位置関係を有するため、その情報を考慮できるCNN+RNNモデルのほうが長期予測に適していた可能性が高いと言える。

### 4.3 ハイブリッドモデル

雨水ポンプの運転支援システムにおいて、流入量の予測精度は高いことが望ましい。予測モデルは必ずしも一種類である必要はないため、5分将来と10分将来の流入量予測には重回帰モデル、20分将来より先の予測にはCNN+RNNモデルを用いるハイブリッドモデルとすることが有効と考えた。CNN+RNNモデルに比べて重回帰モデルは学習や予測に必要な計算量が少ないため、5分将来から60分将来の予測値を揃えるために必要な計算時間もすべてCNN+RNNモデルを用いる場合に比べて削減できる。

ハイブリッドモデルを用いる場合、その予測誤差は、5分将来と10分将来は重回帰モデル、20分将来より先の予測にはCNN+RNNモデルに関するFig. 11の値が該当する。すなわち、予測誤差の絶対値の平均値

は5分将来で0.7 m<sup>3</sup>/min、10分将来で1.9 m<sup>3</sup>/min、20分将来で4.7 m<sup>3</sup>/min、40分将来で13.0 m<sup>3</sup>/min、60分将来で25.4 m<sup>3</sup>/minとなる。

これらの数値をSポンプ所の雨水ポンプ(小)1台の揚水量300 m<sup>3</sup>/minに対する比率に換算すると、5分将来で0.2%、10分将来で0.6%、20分将来で1.6%、40分将来で4.3%、60分将来で8.5%となった。予測誤差の絶対値の平均値で考えると数値は小さいが、大雨のため流入量が多い場合で、かつ40分将来や60分将来の長期予測の予測誤差はまだ大きいと、学習データの追加などにより予測精度の向上を図っていく必要がある。

## 5. ま と め

本論文では、内水氾濫を防止する雨水ポンプの運転支援を目的として開発した流入量予測技術について述べた。降雨時の流入量実績データは短期間に多数得られないため、設計用の下水道/河川統合解析ソフトウェアで生成した模擬データを学習や評価に用いた。同一流域における同一対象に対して①重回帰モデル、②全結合型ニューラルネットワークモデル、および③畳み込みニューラルネットワークと回帰型ニューラルネットワークを組み合わせたCNN+RNNモデルを適用し、予測誤差の平均値で評価した。得られた主

な結果を以下に示す。

- (1) 短期予測より長期予測のほうが予測誤差の平均値は大きい傾向であった。
- (2) 5分将来および10分将来の短期予測では重回帰モデルの予測誤差の平均値が最小であった。比較的下流に設置した水位計からの流達時間程度将来の予測であれば、その水位情報を説明変数に含む重回帰モデルで流入量を十分予測できると考えられた。一方20分将来、40分将来、60分将来の長期予測ではCNN+RNNモデルの予測誤差の平均値が最小であった。降雨強度の影響が大きくなる長期予測の場合、柔軟性が高い全結合型ニューラルネットワークモデルのほうが重回帰モデルより精度は向上したが、CNN+RNNモデルはさらに降雨強度の2次元の位置関係も考慮できたため予測精度をさらに向上できたと考えられた。
- (3) 重回帰モデルの係数値を評価した結果、短期予測では直前までの水位と流入量の影響が大きいが、長期予測では降雨強度の影響が増大し60分将来では水位よりも降雨強度の影響が大きくなる結果を得た。
- (4) 短期予測では重回帰モデル、長期予測ではCNN+RNNモデルを用いるハイブリッドモデルを考案した。それぞれのモデルの有利な面を活用することで、流入量の予測精度を高められると考えられた。今回対象としたSポンプ所の雨水ポンプ(小)1台の揚水量 $300\text{ m}^3/\text{min}$ に対する比率へ換算すると、予測誤差の絶対値の平均値は5分将来で0.2%、10分将来で0.6%、20分将来で1.6%、40分将来で4.3%、60分将来で8.5%となった。

今後は学習データの追加などにより、大雨のため流入量が多い場合の長期予測の予測精度の向上を図るとともに、実績データを用いた学習および予測精度の評価を進めていく。

#### 参考文献

- 1) 塩谷 真, 嶋内繁行, 小笠原 均: 雨水排水系における流入量予測とゲート・ポンプ・バルブの協調制御, 第1回環境システム自動計測制御国内ワークショップ講演集, pp.45-48 (1980)
- 2) 村井雅彦, 山田利広, 坂本義行, 長岩明弘: 省エネルギー・環境システムにおけるOR エネルギー・上下水道管理システムの運用改善, オペレーションズ・リサーチ, No.4, pp.9-14 (2009)
- 3) 山田富美夫, 中島かねみ: 下水道雨水流入予測システムの機能開発に関する研究, 第5回環境システム自動計測制御国内ワークショップ講演集, pp.180-183 (1994)
- 4) 高見澤真司, 夜明 徹, 青木 隆: 下水道プロセスにおける計測制御技術, 富士時報, Vol.71, No.6, pp.44-49 (1998)
- 5) 植木 茂, 荻島美住, 鶴飼誠治, 田所秀之, 栗栖宏光: 雨水排水ポンプ場における流入予測技法, 第5回環境システム自動計測制御国内ワークショップ講演集, pp.184-187 (1994)
- 6) 花田真児, 土屋和広, 竹内正則: ニューラルネットワーク応用の雨水流入量予測システム, 富士時報, Vol.71, No.3, pp.15-16 (1998)
- 7) 大森稔寛, 大西明和, 田辺隆雄, 柴田敬介: 人工知能を用いた雨水幹線およびポンプ場流入渠の水位予測システムの構築と検証, 第56回下水道研究発表会講演集, pp.176-178 (2019)
- 8) 福本 徹, 浅田勇次, 宮部貴志: AIモデルを活用したリアルタイム浸水予測手法に関する検討, 第56回下水道研究発表会講演集, pp.194-196 (2019)

# Evaluation of Forecast Method of Rainwater Inflow to Rainwater Pump Station by Machine Learning

Koji Kageyama<sup>1)†</sup>, Shigetoshi Sakimura<sup>1)</sup>, Hideyuki Tadokoro<sup>2)</sup> and Tomohiro Yamamoto<sup>3)</sup>

<sup>1)</sup> Hitachi, Ltd., Research & Development Group, CSU-Decarbonized Energy, Environmental Systems Research Department, Chief Researcher, Researcher

<sup>2)</sup> Hitachi, Ltd., Hitachi Insight Group, Control System Platform Division, Water Control Systems Engineering Department, Engineer

<sup>3)</sup> Hitachi, Ltd., Water & Environment Business Unit, Water Solutions Division, East Japan Project Management Department Section 1, Senior Engineer

† Correspondence should be addressed to Koji Kageyama :

Hitachi, Ltd., Research & Development Group, CSU-Decarbonized Energy,  
Environmental Systems Research Department, Chief Researcher

E-mail : koji.kageyama.gf@hitachi.com

## Abstract

A machine learning-based inflow forecast method was evaluated for the purpose of assisting the operation of rainwater pumps to prevent inland flooding. We compared three types of prediction methods under the same conditions : a multiple regression model, a fully-connected neural network model, and a CNN+RNN model. As a result, it was found that the multiple regression model is suitable for short-term forecasting, and the CNN+RNN model is suitable for long-term forecasting. By using a hybrid model that combines these, the average absolute value of the prediction error is expected to be 0.2% in the 5-minute future and 8.5% in the 60-minute future as a ratio to the pumping volume of the rainwater pump at M Pumping Station.

**Key words :** inflow forecast, AI, fully connected neural network, convolutional neural network, recurrent neural network