

# AI を活用した洪水予測技術の開発について

房前 和朋<sup>1</sup> 島本卓三<sup>2</sup>

<sup>1</sup>九州技術事務所 技術情報管理官 (〒830-8570福岡県久留米市高野町1丁目3番1号)

<sup>2</sup>九州技術事務所 事務所長 (〒830-8570福岡県久留米市高野町1丁目3番1号) .

国土交通省の「第4期国土交通省技術基本計画」ではAI（人工知能）が3本柱の一つとして位置づけられている。九州技術事務所では整備局河川部と連携してAIの技術開発を行い、我が国初となる、レーダー雨量を学習に用いたDNN（ディープラーニング）による「流入量予測AI」「中小河川用洪水予測AI」を開発した。あわせて予測精度の評価を行い良好な結果を得ることができた。

またAIと物理モデルを組み合わせることで河川の縦断的水位を精度よく予測する手法を開発、さらに高密度水位計を用いリアルタイムで誤差を補正する手法を開発した。

キーワード 人工知能（AI）、洪水予測、流入量予測、DNN、ディープラーニング

## 1. はじめに

近年、地球温暖化等の影響で降水量が増加し水害リスクが増大しているといわれており、実際に九州においては九州北部災害等の甚大な被害が頻発している。

平成27年には関東・東北豪雨災害を受け「水防災意識社会再構築ビジョン」が策定され、水防活動や住民の避難等の要となる洪水予測の重要性がますます高まっている。

一方で、平成30年には国土交通省の「第4期国土交通省技術基本計画」が策定され、AIが3本柱の一つとされ、土木分野での活用が期待されている。近年急速にAIが発達しており、特にDNN（ディープラーニング）を用いたAIは様々な問題に対して他の手法を圧倒する性能を示している

DNNを用いたAIによる洪水予測はあまり研究が行われておらず、国内では地上雨量観測所のデータを用いた研究がいくつかあるだけであった。

そこで九州技術事務所では整備局河川部と連携し最先端技術に関する研究体制を構築、DNNを用いたAI（及びVR・UAV等）の技術開発を行っている。

平成29年度に九州技術事務所では、

- (1) レーダー雨量データ・DNNを用いたダム流入量予測AIの開発・評価
- (2) レーダー雨量データ・DNNを用いた中小河川水位予測AIの開発・評価

(3) AIと物理モデルのハイブリッドモデルによる、中小河川の縦断的な水位予測モデルの構築

(4) 高密度水位計を用いた縦断的予測水位の補正手法の開発。

(5) 洪水を経験することで自己学習を行い、自動的に精度向上を行うAIの開発。

等についての研究開発に取り組み、良好な結果を得た。

また得られた知見を土木分野でのAI活用を促進に資するため、河川技術論文集に2本の論文を投稿し掲載された。また2018年6月の河川シンポジウムにて発表を行った。

## 2. DNN（ディープラーニング）とは

(1) 人工知能とは

1940年代にデジタルコンピューターが誕生し、一部の学者が機械に知能を持たせることについて議論を始めた。

1950年代になるとAI（Artificial Intelligence）という言葉が誕生し、AI研究が学術分野として成立した。

AIの研究は1950年代から続いているが、その過程ではブームと冬の時代が交互に訪れてきた。

第一次のブームは1950年代～1960年代である。コンピューターによる「推論」や「探索」が可能となったが、当時のAIでは単純な問題しか解を得られないことが判明し一転して冬の時代を迎えた。

第二次のAIブームは1980年代である。エキスパートシステムと呼ばれる専門分野の知識を取り込んだ上で推

論するプログラムが生み出された。しかし膨大な知識を取り込むことが困難であったため、再び冬の時代を迎えた。

第三次のブームは、2000年代から現在まで続いている。もはや一過性のブームではないという意見も多く、すでに社会のいたるところでAIが活躍している。

このようなAIの発達を考えるうえで、特に注目すべき技術として「ディープラーニング」が挙げられる。

## (2) DNN (ディープラーニング) とは

人工知能の学習技術の中で、脳内の神経伝達の仕組みをモデルにしたものが人工ニューラルネットワーク (artificial neural network, 以下ANN) と呼ばれている。その最新型がDNNである。

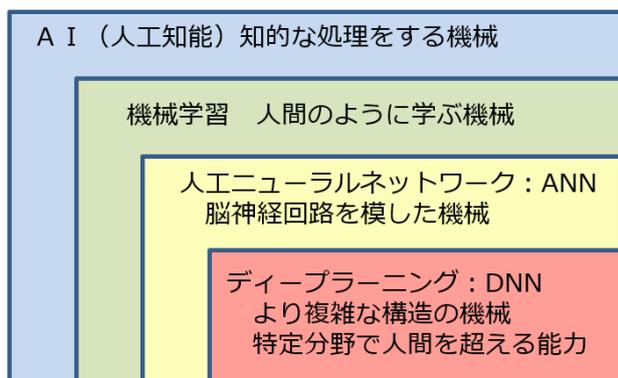


図-1 人工知能技術の関係

人間の脳は「ニューロン」と呼ばれる神経細胞のネットワークでANNはその構造を単純化した「入力層」「中間層」「出力層」の3層で構成されている。ANNは優れたアイデアであるが精度などに課題があり、また当時の技術的ではより複雑な構造とすることができなかった。

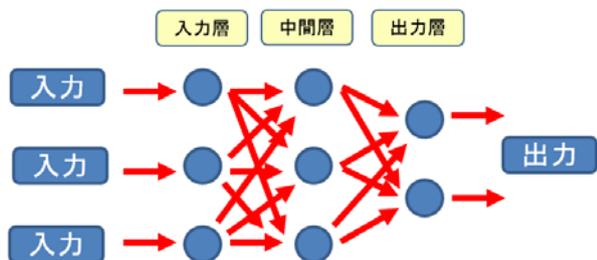


図-2 ANN (人工ニューラルネットワーク)

近年のコンピュータの高性能化や学習技術の開発、ビッグデータの活用等により、4層以上の複雑な構造を持った人工ニューラルネットワークであるDNNが開発された。DNNは、「データのどこに注目すべきか」を自ら判断し、「人間では気が付かない細かな特徴」を把握できることから、様々な問題に対して他の手法を圧倒す

る性能を示している。

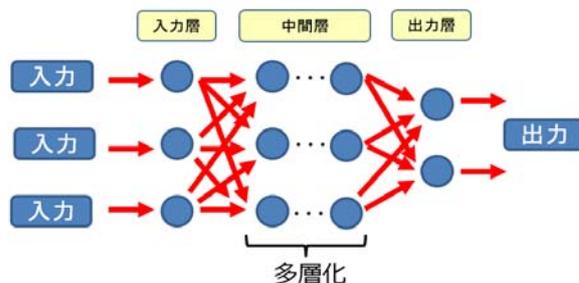


図-3 DNN (ディープラーニング)

## 3. ダム流入量予測AIについて

### (1) 予測手法

ダム流入量予測AIについては、予測精度向上を比較検討するため以下の3種類を作成した。

- ①レーダ雨量を用いたDNN (ディープラーニング)
- ②地上雨量を用いたDNN (ディープラーニング)
- ③レーダ雨量を用いたANN (従来型)

対象流域は、筑後川水系の下笠(しもうけ)ダム流域とした。流域面積は185km<sup>2</sup>であり、雨量観測所が4地点、水位観測所が3地点に設置されている。(図-4)

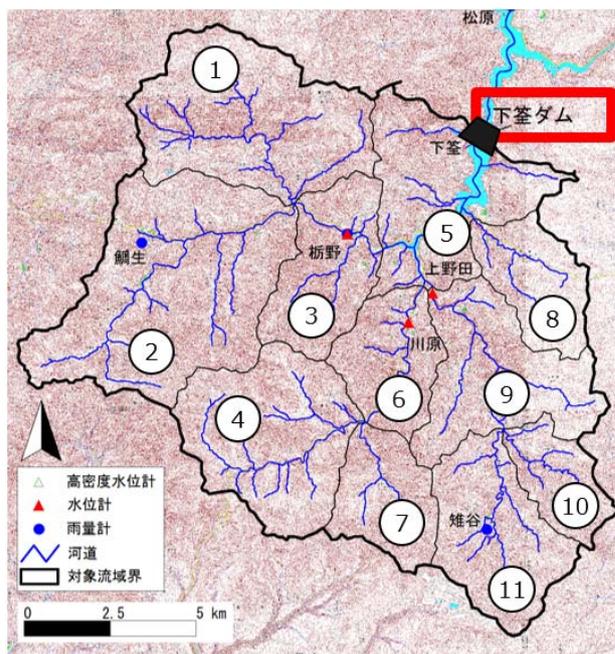


図-4 下笠ダムと観測所、小集水域の位置

検討対象洪水として、レーダ雨量の入手できる2006年以降の22洪水を抽出した。(表-1)

DNNの学習時における勾配消失問題への対応として、本研究では自己符号化器による事前学習を行い、精度向上を図った。活性化関数にはシグモイド関数を用いた。ネットワークの学習には確率的勾配降下法を用い、学習係数の設定にはAdaGradを適用した。誤差関数の勾配の算出には誤差逆伝搬法を用いた。また学習データの

関連性を十分に学習し、かつ過学習による精度低下を避けるため、ドロップアウトを適用した。

表-1 学習・検証の対象出水の一覧

出水ID	ピーク時刻	ダム流入量 (m <sup>3</sup> /s)	レーダ雨量の観測ピッチ	地上雨量の観測ピッチ
1	2012/07/14 08:20	1464.94	5分	5分
2	2006/07/05 00:30	1287.38	5分	60分
3	2009/06/30 01:00	1156.18	5分	60分
4	2016/06/22 11:5	1116.77	5分	5分
5	2007/07/07 02:5	598.16	5分	60分
6	2016/06/23 00:30	848.58	5分	5分
7	2006/07/23 21:40	816.09	5分	60分
8	2015/07/01 05:40	797.86	5分	5分
9	2007/07/04 11:30	791.48	5分	60分
5	2012/07/13 16:30	693.49	5分	60分
11	2011/06/11 08:50	674.52	5分	60分
12	205/05/23 16:40	667.8	5分	60分
13	2013/08/25 5:40	595.83	5分	60分
14	2011/07/06 19:5	591.79	5分	60分
15	2015/06/11 13:30	543.99	5分	60分
16	2009/07/20 13:30	537.69	5分	60分
17	2011/06/20 05:00	535.93	5分	60分
18	2006/07/20 19:20	534.73	5分	60分
19	2017/07/06 04:30	532.43	5分	(未入手)
20	2006/07/20 04:20	527.00	5分	60分
21	2006/06/26 07:00	524.95	5分	60分
22	2012/06/24 20:5	513.31	5分	60分

予測対象は、下笠ダム流域の雨量データを入力データとして、10分~60分後までのダム流入量とした。

雨量データについては、地上雨量を用いた場合と、レーダ雨量を用いた場合とで2通りの入力データを作成した。レーダ雨量については、図-4に示すような下笠ダム流域内の11の小流域ごとに平均雨量を作成し、モデルの入力データとした。地上雨量については、4か所の地点雨量をそのまま入力データとした。

DNN (ディープラーニング) は、入力層・中間層2層・出力層の4層から構成し、学習時には自己符号化器による事前学習を適用した。

ANN (従来型) は入力層・中間層・出力層の3層から構成され、事前学習は行わない。それぞれのモデルで、事前学習以外の学習手順や、学習・検証に用いるデータは同じとした。

### (2) 予測結果の評価

予測流入量と実績流入量とのRMSE (Root Mean Squared Error) による精度評価の結果を図-5に示す。なお、ここでは精度評価期間は流入量ピークの前後2時間とした。また、時刻ごとの予測流入量と実績流入量のグラフを図-6に示す。

図-5より、①レーダ雨量を用いたDNN (ディープラーニング) が最も精度が良い。続いて、③レーダ雨量を用いた従来型ANN、②地上雨量を用いたDNN (ディープラーニング) の順となった。60分予測の精度を見ると、①の予測流入量のRMSEが70 m<sup>3</sup>/s 程度である。

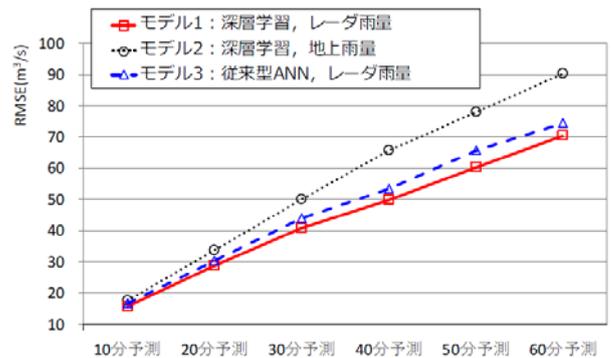


図-5 ダム流入量予測モデルの予測水位RMSE

図-6の洪水ピーク流量1465 m<sup>3</sup>/sに対しての5%程度の誤差にとどまっており、ダム操作などへの実用に向けても十分な精度だろうと考えられる。また、洪水波形の立ち上がりやピークの最大値など、防災上の観点で重要な部分も良く再現できている。

また①と②の比較により、DNN (ディープラーニング) を用いたモデルでは、地上雨量よりもレーダ雨量を入力データとした方が精度が高くなる。

同様に①と③の比較より、DNN (ディープラーニング) モデルの方が従来型ANNモデルよりも精度が高くなる。

上記の結果からレーダ雨量を用いたDNN (ディープラーニング) はダム流入量予測において有用な技術であることが明らかとなった。

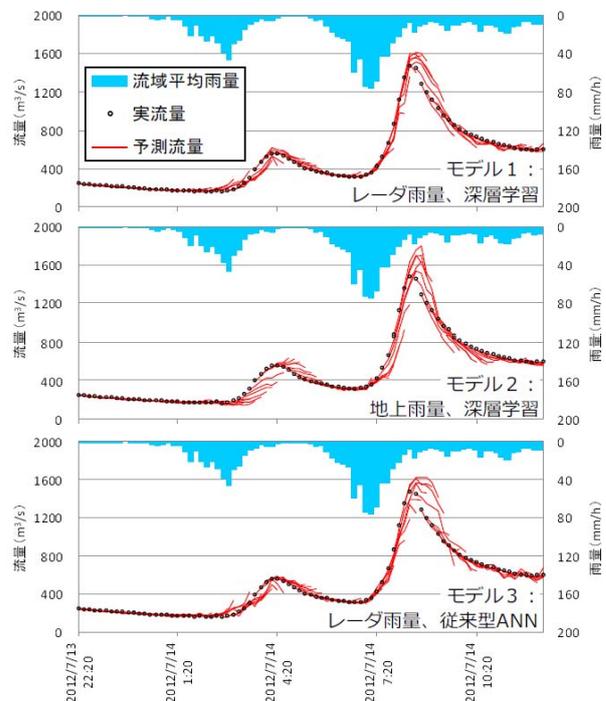


図-6 下笠ダム流入量予測 (10分後~60分後) の結果。

#### 4. 中小河川における水位予測A Iについて

対象河川は、筑後川水系城原川とした。城原川の流域面積は64.4km<sup>2</sup>、幹線流路延長は31.9kmである。上流域は山地に囲まれており、中下流は市街地に囲まれている。中流域の神崎町仁比山付近は扇状地が発達し天井川となっており、横流入河川が少ない。下流域はゼロメートル地帯のはん濫地形で、3.0kにあるお茶屋堰より下流は感潮域となっている。

また、城原川中流域の9.0kから佐賀江川の合流地点までの区間と、佐賀江川から筑後川本川への合流地点までの区間にあわせて、高密度水位計が18基設置されている(図-8)。高密度水位計の設置間隔は基本的に1kmのピッチで、加えて重要水防箇所・野越し箇所などにも設置されている。

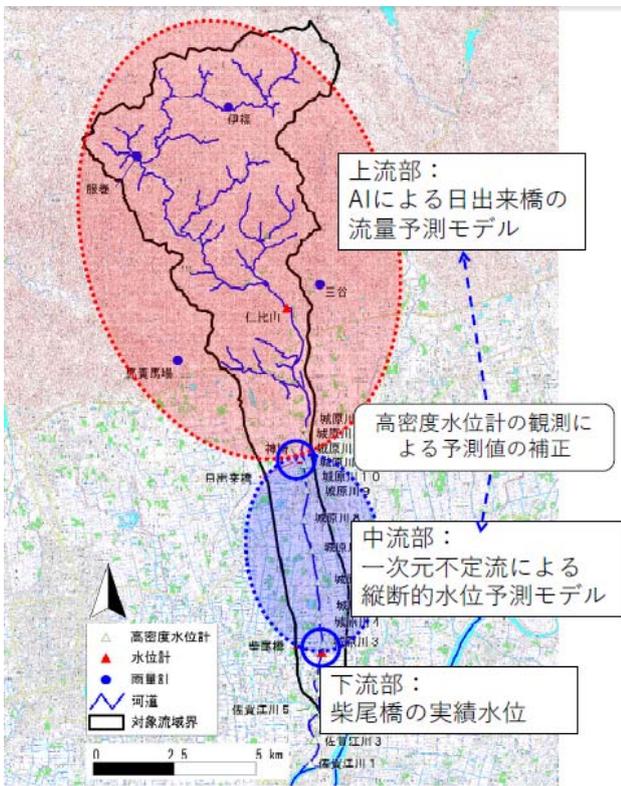


図-8 城原川流域とモデルの概要

上流の雨量データを入力値として、日出来橋の流量を予測するDNN(ディープラーニング)を用いたモデルを構築した。モデルは入力層、中間層2層、出力層からなる2層の階層型ネットワークとした。

レーダ雨量には、国土交通省のCバンドレーダ(同時刻合成レーダ雨量)を用いた。モデルの入力データ作成に当たっては、上流域の小流域ごとに流域平均雨量(10分間の雨量強度)を求め、それらをモデルの入力データとした。小流域は国土数値情報の流域界データを用い図-9に示す8流域とした。

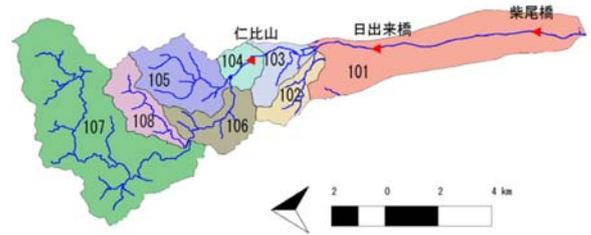


図-9 城原川流域の小流域分割図と流域番号

モデルの構築には、国交省の同時刻合成レーダ雨量が入手できる2006年以降で、日出来橋において氾濫注意水位を超えた23洪水を用いた。各洪水のピークから12時間前~8時間後までを1洪水とし、全部で20時間分の10分データ×23洪水=2783セットのデータを用意した。予測モデルによる10分後~60分後予測の結果を図-10に示す。予測結果は過去の流量実績を十分に再現していることが確認された。

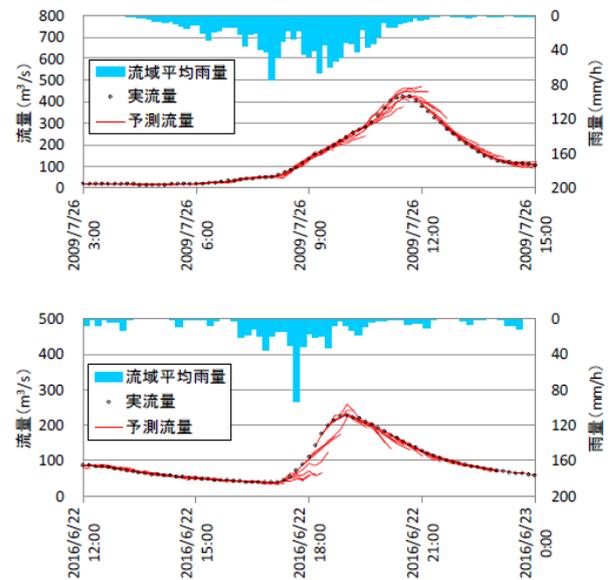


図-10 日出来橋における洪水予測計算結果(2洪水)

このことからダム流入量予測と同様にレーダ雨量を用いたDNN(ディープラーニング)有用な技術であることが明らかである。

#### 5. A Iと物理モデルのハイブリッドモデルによる、中小河川の縦断的な水位予測モデルの構築

対象河川は筑後川水系城原川とし、構築したDNNを用い検討を行った。

##### (1) 縦断的な水位予測モデルの構築

縦断的な水位予測モデルの構築を目的として1次元不定流モデルを構築した。一次元不定流計算の基礎式として、連続式および運動方程式に基づく漸変開水路流れを対象とした式を用いた。モデル化対象範囲は、DNN(ディープラーニング)の流量予測地点である日出来橋

(8.0k)～柴尾橋水位観測所(1.8k)までの6.2kmとした(図-8)。

一次元不定流モデルの精度を確認するために再現計算を実施した。計算条件を表-2に示す。再現対象洪水は、高密度水位計データが観測されている平成28年6月22日～23日の洪水とした。

再現計算結果を図-11に示す。図に示すように、1km毎に設置された高密度水位計のデータと計算水位が良好に整合していることが確認された。

表-2 一次元不定流モデルの再現計算条件

項目		設定値
再現対象洪水		H28年6月22日～23日
上流端境界条件		日出来橋観測流量
下流端境界条件		柴尾橋観測水位
河床横断データ		H26年測量 堰は補間断面を作成して設定 草堰の天端高は高水敷高見合い
再現対象水位		解析区間内の高密度水位計 観測値(9ヶ所)
粗度	低水路	0.020(お茶屋堰下流:1.8k～2.8k) 0.028(お茶屋堰上流:2.0k～8.0k)
	高水敷	0.035
	植生域	0.050
	草堰	0.035

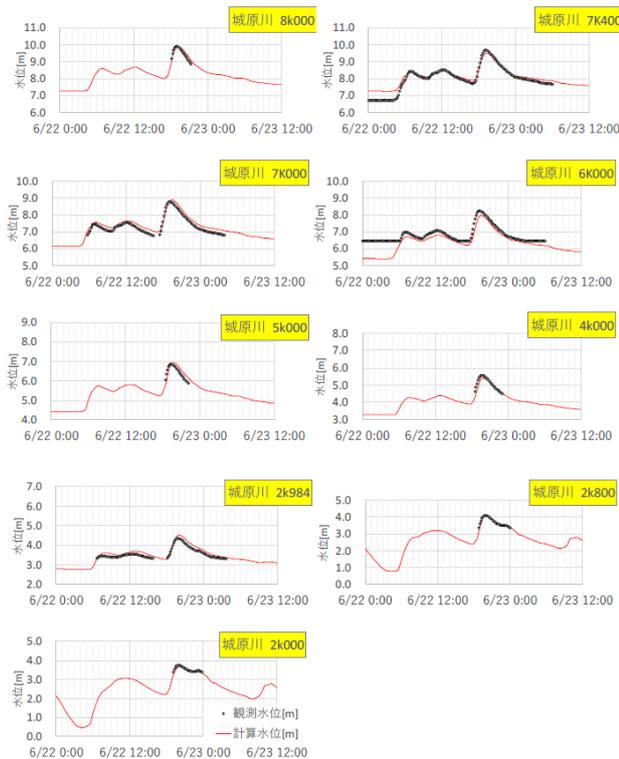


図-11 水位の時系列変化の再現計算結果

(3) DNN (ディープラーニング) による予測流量を用いた一次元不定流計算

DNN (ディープラーニング) および一次元不定流モデルの精度が確認されたため、DNN (ディープラーニ

ング) による予測流量を用いて不定流計算を実施し、縦断水位の再現性を確認した。具体的には、平成28年6月の洪水を対象に、ピーク周辺で高密度水位計の欠測がない6月22日19時20分の予測流量(10～60分予測)(表-3、図-10)を用いて計算を行い、実績水位の再現性を検証した。予測流量は予測時間に応じて適用(60分予測の場合は18時20分から予測流量で計算)した。

計算結果を図-12に示す。いずれのケースにおいても良好な再現結果が得られた。本計算ケースの計算時間は約2秒で、リアルタイム性も十分であると思われる。

このことから、DNN (ディープラーニング) と一次元不定流モデルを組み合わせることで、十分な精度で中小河川の水位縦断予測が可能であることが明らかとなった。また、城原川には「草堰」と呼ばれる独特の構造物がある影響で精度が低下していることが考えられるが、断面の諸元等の観測データを充実させることでさらに予測精度を向上させることができると考えられる。

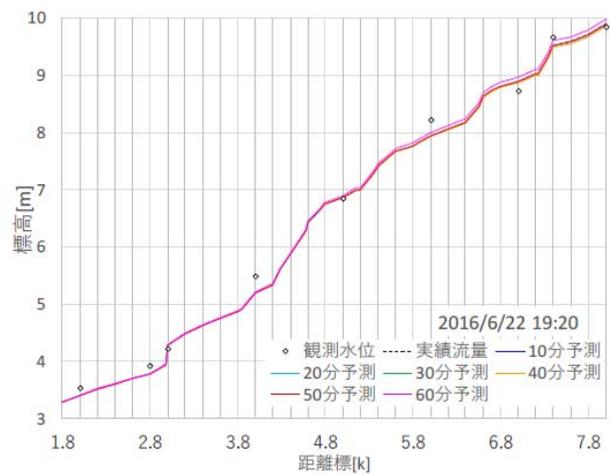


図-12 6月22日19時20分の縦断水位計算結果の比較。

## 5. 高密度水位計を用いた縦断的予測水位の補正手法

対象河川は筑後川水系城原川とし、構築した縦断水位予想モデルを高密度水位計で補正する手法を検討した。

### (1) 水位補正の概要

水位の予測においては、実績流量はH-Q式から換算された流量であり、H-Qループなどの誤差が含まれる。また、洪水などによる河床変動等によってH-Qの関係に変化があった場合にも誤差が発生する。

本検討では、このように入力(境界)条件となる流量に誤差がある状況を想定し、高密度水位計の観測水位を用いて予測水位を補正する手法を検討した。

### (2) 水位補正手法

計算水位の補正は、日出来橋の観測水位がはん濫注意水位に達した際に、当該時刻の高密度水位計観測水位と計算水位のRMSEが0.2m以上であったときに行うこととした。補正は、境界条件であるDNNの予測流量を増減させることによって行った。具体的には、流れの伝播速度

を考慮してRMSEが0.2m以上となった時刻の1時間前からの実績流量および予測流量を1%~20%の割合で増減させたケースで再度計算を行い、最もRMSEが小さくなる補正割合を補正係数として採用し、当該時刻の1時間前からのDNNの予測流量に乗じることによって行った。

検証は平成28年6月洪水のデータを用いて行い、DNNの学習データには、生じうる誤差を想定して、平成27年のH-Q式で換算した流量(図-13)を用いた。実績流量と平成27年H-Q式換算流量では、ピーク流量に約43m<sup>3</sup>/sの差がある。事前の検証計算によって、予測水位補正を適用した場合の計算時間は約15秒で、リアルタイム性が保たれていることが確認されている。

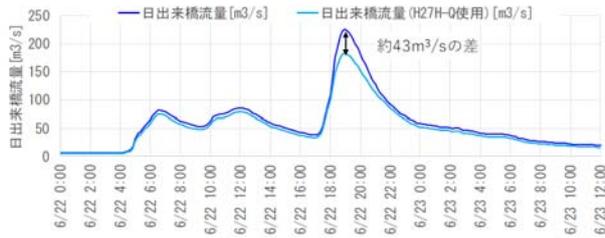


図-13 実績流量と平成27年H-Q式換算流量

### (3) 補正計算の実施

補正計算結果を図-14に示す。図に示すように、高密度水位計の観測水位との誤差を小さくするように流量を補正しているため、補正によって予測水位の精度が改善されている。また、補正流量についても実績流量とほぼ同様の値となっており、本補正手法の有用性が確認された。このことから、実績流量および予測流量に誤差が生じた場合でも、高密度水位計の観測値を用いることで、精度向上が向上できることが確認された。

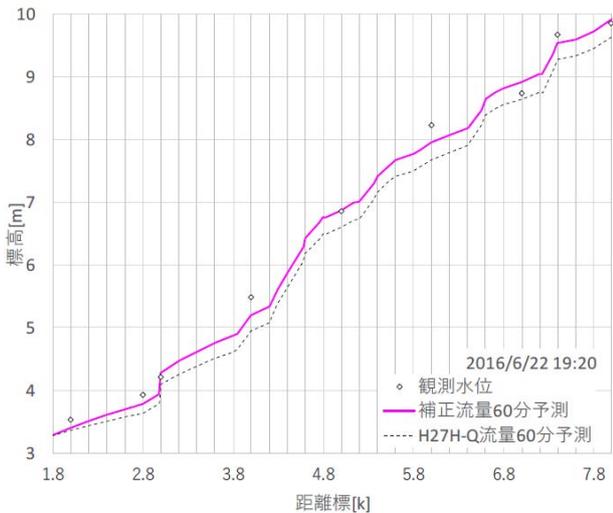


図-14 平成27年H-Q式換算流量を用いた予測水位と補正流量を用いた予測水位。

## 6. 自己学習機能の構築

検討対象は下笠ダムの流入量予測モデルとし、人工知能が洪水を自動的に学習し予測精度を向上させることが

できるか検証を行った仮想的に2006年に予測モデルを構築したものとし、その後10年間にわたり自己学習を続けた場合を模擬した精度検証を行った。

表-3 学習事例数と予測精度の一覧表

学習事例数	10分予測	20分予測	30分予測	40分予測	50分予測	60分予測	平均
1	36.4	98.2	123.6	199.4	196.1	268.9	153.8
2	44.7	52.4	72.4	89.6	162.7	108.0	88.3
3	35.2	46.8	76.3	90.4	113.7	122.5	80.8
4	34.1	56.9	86.5	117.5	119.1	156.4	95.1
5	30.0	44.4	69.3	77.4	103.2	130.6	75.8
6	30.9	51.4	68.4	87.7	141.2	158.6	89.7
7	24.8	53.4	71.9	88.0	102.5	136.1	79.5
8	26.8	40.5	63.7	71.2	101.8	106.2	68.4
9	33.6	46.2	66.0	71.4	107.8	132.8	76.3
10	30.6	46.0	64.8	83.5	97.6	140.9	77.2
11	28.1	41.5	66.3	85.5	94.5	141.0	76.1
12	29.3	45.1	56.8	73.9	91.0	128.3	70.7
13	27.4	47.5	62.4	94.0	72.9	100.5	67.5
14	26.4	40.6	58.7	78.8	102.3	119.2	71.0
15	28.2	43.2	56.7	82.5	69.7	76.4	59.5
16	24.7	40.8	59.8	80.4	103.4	110.8	70.0
17	27.0	58.2	66.2	92.9	88.4	116.4	74.9
18	26.8	46.9	58.4	87.4	85.0	136.2	73.4
19	29.7	46.8	59.5	75.7	76.1	86.4	62.4

学習事例数が増えるにつれて精度が向上しており、8事例程度までは精度向上の明確な精度向上の効果がみられる。学習事例をさらに増やした場合については、精度はほぼ横ばいである。最終的に全19出水を学習し終えたところで最も高い精度を示している。このことから、DNNの自己学習機能は適切な効果を示したと考えられる。

## 7. おわりに

九州技術事務所では、我が国初となる、レーダ雨量を用いたDNNによるダム流入量予測AI・中小河川水位予測AIを構築し十分な精度であることを確認した。

また我が国初となる、DNNと物理モデルを組み合わせた河川の縦断水位予測システムを構築し十分な精度であることを確認した。また中小河川ではHQ等が十分整理されていない場合もあるが高密度水位計を用いることでリアルタイムの補正が可能であることを確認した。さらに工知能の自己学習により洪水予測精度の向上が可能であることを確認した。

九州技術事務所は本研究で、AIが今後の土木を支える重要な技術になりうるという手ごたえを感じた。今後も積極的に取り組んでいきたいと考えている。

最後に、快く九州までAIの講義に来ていただいたJFEエンジニアリング株式会社山根総一郎氏、富士通株式会社、日本工営株式会社、また貴重なアドバイスをいただいた国土技術政策総合研究所河川研究部水循環研究室に感謝の意を表す。