

複数の気象要因を考慮した融雪期における河川の水位予測

分布画像を用いた深層学習の適用

大野 剛*¹・飯村 浩太郎*¹・高山 百合子*¹

Keywords : snow melting, water level prediction, safety management, deep learning, weather distribution

融雪期, 河川水位予測, 安全管理, 深層学習, 気象分布

1. はじめに

河川工事では安全管理の観点から出水に留意する必要がある。降雨に伴う出水では、工事従事者が天候や河川の水位変化に注視し、出水の危険性がある場合は速やかに対応できるように備える。しかし、気温の上昇や強風などが要因で発生する融雪に伴う出水では、降雨がなくても水位が上昇することがある¹⁾。工事従事者が融雪に伴う出水に気づかない場合、出水への対応が遅れ、作業員や工事敷地内の建設資機材の流出、重機の浸水など様々な人的・物的被害を受けることになる。被害が発生した場合、安全面だけでなく、復旧に伴う追加作業により工程遅延や追加コストが発生するなど、施工管理全般へ影響が発生する。資機材や重機を養生・退避させる場合、数～十数時間以上先の出水を予測することが求められる。24時間程度先までの水位トレンド（上昇または下降）を知ることができれば、退避や復旧のタイミングを把握でき、作業の工程調整や人員の確保、迅速な復旧にもつながる。そのため安全管理だけでなく、工程や品質の管理にも寄与する。

著者らはこれまで、融雪に伴う水位予測手法として、積雪深や気温など融雪に関する気象分布画像を用いて機械学習の一手法である深層学習により翌日の日最大水位の予測方法を検討してきた²⁾。気象分布画像を用いることで、水位上昇に影響する流域全体の気象条件を考慮することが可能であり、また河川の観測所水位や雨量に比べて気象分布画像は、地域を問わず入手が容易である。天気予報の画像を用いることで、長時間先の水位を予測できる利点もある。しかし、日最大水

位を予測する時刻が前日の23:00であったため、例えば最大水位に到達する時刻が翌日の1:00だった場合、日最大水位を正確に予測できたとしても、23:00から2時間後の水位を予測したことになる。そのため、重機や資機材を退避させることが困難な場合があることや、最大水位への到達時刻、水位トレンド、復旧タイミングを把握できないという課題があった。

そこで本研究では、日最大水位の予測方法を24時間先までの水位を予測する方法（以下、本手法）に拡張して実測水位と本手法の予測水位の相関性を確認し、実河川への適用性を検討した。入力値は1時間ごとの気温、降水量、風速の気象分布画像と、積雪深、日照時間のアメダス観測値、および予測地点の観測水位であり、出力は1~24時間先の水位である（図-1）。

融雪時期を対象に機械学習を用いた水位、流量の予測に関する既往研究としては、例えば西原ら³⁾が5年間の融雪時期を対象にダム流入量の日ピーク量と時刻を一定の精度で予測できることを報告している。また山田ら⁴⁾は、深層学習を用いて降水量、気温、積雪深か

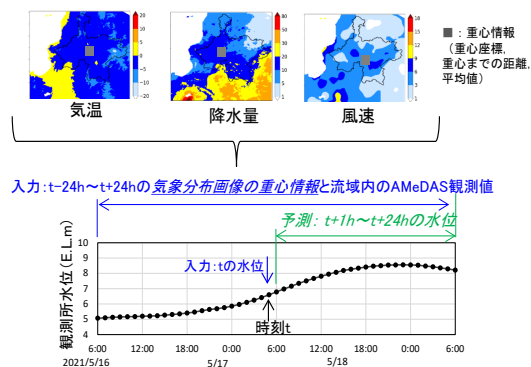


図-1 水位予測手法の概要

Fig.1 Overview of water level prediction

*1 技術センター 社会基盤技術研究部 水理研究室

らダム流入量を予測しており、12～24時間先までの予測流量が実務上利用可能であることを示している。黒沢ら⁹⁾は、融雪時期を対象に、分布型流出モデル、1次元不定量モデルと黒沢らが提案した融雪モデルを用いて、気温と降水量から3時間先の水位を予測している。いずれも予測精度は良好であるものの、山田らや西原らはダムの流入量の予測であり、黒沢らは24時間先の水位予測は対象としていない。

気象分布画像を用いた研究事例としては、荒木ら⁶⁾が畳み込みニューラルネットワークを用いて流域内の面的な雨量データを入力とした水位予測を行っているが、水位の予測時間が1時間である。また入力値の数が画像の全ピクセルを畳み込んだ数となり本手法の座標情報より多くなることから、河川工事への適用に必要な条件となるリアルタイム予測に活用するためには計算負荷が大きい。

2. 気象分布画像を用いた水位予測

2.1 概要

本手法は、融雪に関する気象項目として、降水量、気温、風速、積雪深、日照時間を採用している。入力データは気象庁が配信する1時間ごとの降水量、気温、風速の気象分布画像と、AMeDAS観測地点における1時間ごとの日照時間と積雪深、予測地点の1時間ごとの観測水位であり、1～24時間先の水位を深層学習（多層パーセプトロン）により予測している⁷⁾。深層学習を用いた理由は、複数要因を入力データとする予測モデルを構築するためである。物理モデルを用いる場合、複数の気象要因が相互に複雑に絡み合った融雪モデルの構築や物理法則に基づいた各種パラメータの設定が困難となる。本手法の特徴として、気象分布画像の重心座標などを入力値に用いることと、予測精度を高めるために各気象項目に対し重み付けを行い、入力値に乗じて予測に用いている点があげられる。重心座標の算出方法と重み付け方法については後述する。

本論では、豪雪地帯の中から地域や流域面積が異なる8河川について、2018～2021年の3～5月における水位を予測した。

2.2 水位予測地点の選定

水位の予測地点として、国土交通省が指定する豪雪地帯及び特別豪雪地帯⁸⁾に含まれる水位観測所を8地点選定した（図-2）。水位観測所は水文水質データベース⁹⁾にある観測所であり、水位変動が潮位の影響を受けない地点とした。選定した8地点は、様々な地域や流域

面積を対象に検討することを目的に、全国5地方区分から選定した（北海道：石狩川、天塩川、留萌川、東北：赤川、最上川、北陸：小矢部川、中部：木曾川、中国：江の川）。

2.3 水位の予測方法

2.3.1 流域の作成と水位データの取得

予測地点より上流域を「流域界・非集水域データ」¹⁰⁾から抽出した。8地点の予測地点名（水位観測所名称）と流域面積、流路長は図-2の表中のとおりであり、流域面積が最大となる観測所は石狩川の月形観測所（14,330km²）、最小は留萌川の大和田観測所（270km²）ある。

水位データは水文水質データベース⁹⁾から取得した。取得期間は、水位を予測する2018～2021年の3～5月（融雪時期）とした。2018年以降とした理由は、気象庁が1時間ごとの気温、風速の気象分布画像の配信を開始した時期が2018年であり、これに合わせて2018～2021年の気象分布画像を準備した。

2.3.2 気象分布画像の準備と重心情報の取得

2018～2021年の3～5月を対象に、気象庁が配信する降水量、気温、風速の1時間ごとの気象分布画像を準備した。気象分布画像の種類は、降水量が解析雨量図、気温が推計気象分布、風速が毎時大気解析である。各分布図に対して、予測地点の上流域を抽出し、RGBから0～255の数値に変換した（図-3）。ここで図-3に示す解析雨量図は気象庁が解析する解析雨量（1km格子）から作成しており、本稿では、降水量の色付けは気象庁の解析雨量図を参考に設定した¹¹⁾。なお解析雨量図の色付けは凡例のように降水量により段階的に色が変わっており（例えば20～30mm/hは黄色）、本稿では降水量ではなく凡例の色に合わせて数値変換を行っている。数値に変換後、画像の左下を原点として、重心の座標

No	地域	河川名	流域面積 km ²	幹川流路 延長 km	水位 観測所名称
1	北海道	石狩川	14,330	268	月形
2	北海道	留萌川	270	44	大和田
3	北海道	天塩川	5,590	256	新聞寒別橋
4	東北	赤川	857	70	押切
5	東北	最上川	7,040	229	砂越
6	北陸	小矢部川	667	68	長江
7	中部	木曾川	5,275	229	岩沢
8	中国	江の川	3,900	194	長良

▲：水位予測地点

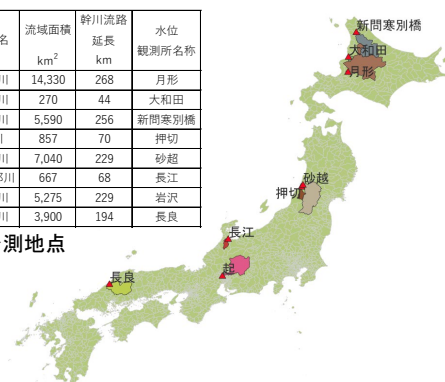


図-2 水位予測地点
Fig.2 Prediction points

(X, Y), 重心座標までの距離 (L) および画像から変換した数値の流域内平均値 (R) の 4 つの値 (X, Y, L, R) を重心情報として求めた。算出した重心情報は、各時間における各気象分布画像の代表値として、後述する学習データの準備および入出力データセットに用いている。

2.3.3 AMeDAS データの整理

積雪深と日照時間として、2018~2021年の3~5月について、AMeDAS 観測値を1時間ごとに取得し、融雪に影響する時間の範囲が過去24時間と仮定して、24時間の累積値を算出した。

2.3.4 深層学習の条件設定とデータセットの作成

深層学習(多層パーセプトロン)は、中間総数を2層、中間層のノード数を入力層のノード数の1.5倍として計算を行った。その他の条件として、活性化関数はRelu関数、学習の反復回数の最大値は1,000回、学習の収束値は 1.0×10^{-6} とした。

深層学習の学習データは時刻tに対して、出力として①t+1~t+24時間の水位、入力として②t=0の水位、③t±24hの重心情報(降水量, 気温, 風速)および④t±24hのAMeDAS24時間累積値(積雪深, 日照時間)を組み合わせたデータセットであり、2018~2021年の3~5月で1時間ごとに準備した。水位を予測する時は上記②, ③, ④を入力値として、①のt+1~t+24の水位を出力する。重心情報は、過去24時間までの降水量, 気温, 風速の影響により融雪が発生し水位が上昇すると仮定して、±24時間の重心情報を用いた。

2.3.5 各気象項目の重み値の算出

上述のデータを用いて水位を予測することを試みたが、後述するように水位の予測結果は実測水位から大きく乖離し、また振動が生じた。そこで、各気象項目に重み付けを行い予測精度を高める方法を考案して採用した。重み値の算出方法は様々考えられるが、今回は試行的に、予測地点上流の気象庁 AMeDAS 観測所における観測値から予測地点の水位を求める重回帰分析

から得られる偏回帰係数を重み値として用いることとした。以下、石狩川月形観測所を事例に重み値の算出方法を示す。まず月形観測所から上流にある AMeDAS 旭川観測所における 2022 年 3~5 月の降水量, 気温, 風速, 積雪深, 日照時間の 1 時間ごとの観測値を取得した。次に各気象項目の 24 時間累積値を求めた。最後に 5 項目を説明変数(入力), 予測地点の水位を目的変数(出力)とした重回帰分析を行い、得られた各気象項目の偏回帰係数を重み値とした。

2.3.6 水位の予測

2018~2021年の水位を深層学習により予測した。予測は1年ずつ行い、予測する年を除いたデータセットを学習し、予測する年の観測水位と各気象項目の値から t+1~t+24h の水位を予測する交差検証を採用した。図-4 は 2021 年 5 月における月形(石狩川)の水位予測結果の例である。黒線が実測水位, 青線が 24 時間分の予測水位結果であり、1時間ごとの予測結果を示している。

3. 水位予測結果

図-5 は各気象項目に付与する重み値である。予測地点により重みの値は異なっていることがわかる。今回は各気象要因を独立した説明変数として重回帰分析に用いたが、例えば気温と日照時間のように実際は従属関係にあることが考えられる。そのため、日照時間、




図-4 水位予測結果(石狩川月形観測所)
Fig.4 Water level prediction results (Tsukigata Observatory)

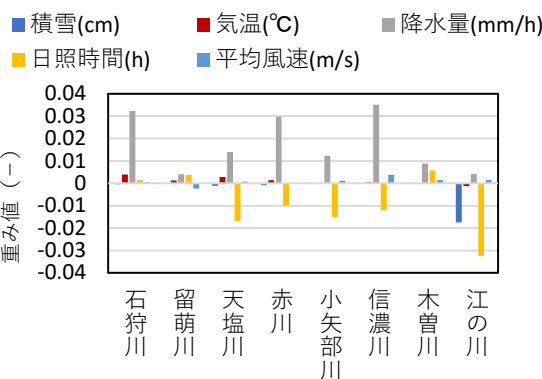


図-5 重み値(偏回帰係数)
Fig.5 Weight value (partial regression coefficient)

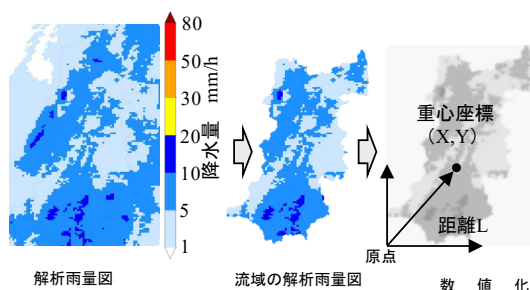


図-3 画像の数値化の方法
Fig.3 Image quantification

積雪の係数がマイナスになっているが、気温の係数に陰的に日照時間の影響が含まれていると考えられる。

図-6 に、水位予測の結果を示す。下段は、図-5 の重み値を入力データに乗じて予測した結果であり、上段は重み付けをしなかった場合の結果である。重み付けをしなかった場合、全予測結果で大きく振動していることが確認できる。一方、重み付けした水位予測結果は、重み付けをしなかった場合に比べて振動幅が低減し、予測水位と実測水位の差異が小さくなっている。実測水位が上昇し出水している時は、予測値が実測値と同様の形状を示しており、本手法により出水を検知できる可能性があることを確認した。

重み付けにより予測精度が良好となった一つの要因として、水位の寄与度が高くなったことが考えられる。図-5 から各気象要因の重み値は 0.04 以下となっているが、入力値である実測水位の重み値は重み付けをして

いないため重み値が 1 である。岡崎ら¹²⁾は、上流の雨量と水位の観測値から水位を予測する場合、上流の水位の方が予測水位への寄与度が高いことを報告している。岡崎らの報告結果をもとに考察すると、図-5 の重み付けにより実況水位の寄与度が相対的に高くなり、予測精度が向上したと考えられる。なお融雪に伴う水位上昇は複数の気象要因が関係していることから、仮に実況水位のみを用いた水位予測を行った場合、どの気象要因によるものかを判断できず、水位の上昇を予測できない可能性がある。そのため、寄与度は低い融雪に関する気象要因を入力する必要があると考える。

河川ごとに振動の幅が異なるのは、学習データ数が異なったためと考えられる。各河川の学習データ数は図-6 の右下に示しており、最小が 1,186 (最上川)、最大が 8,141 (石狩川) である。学習データ数に差異が発生するのは、AMeDAS や水位の観測値の欠測数が予

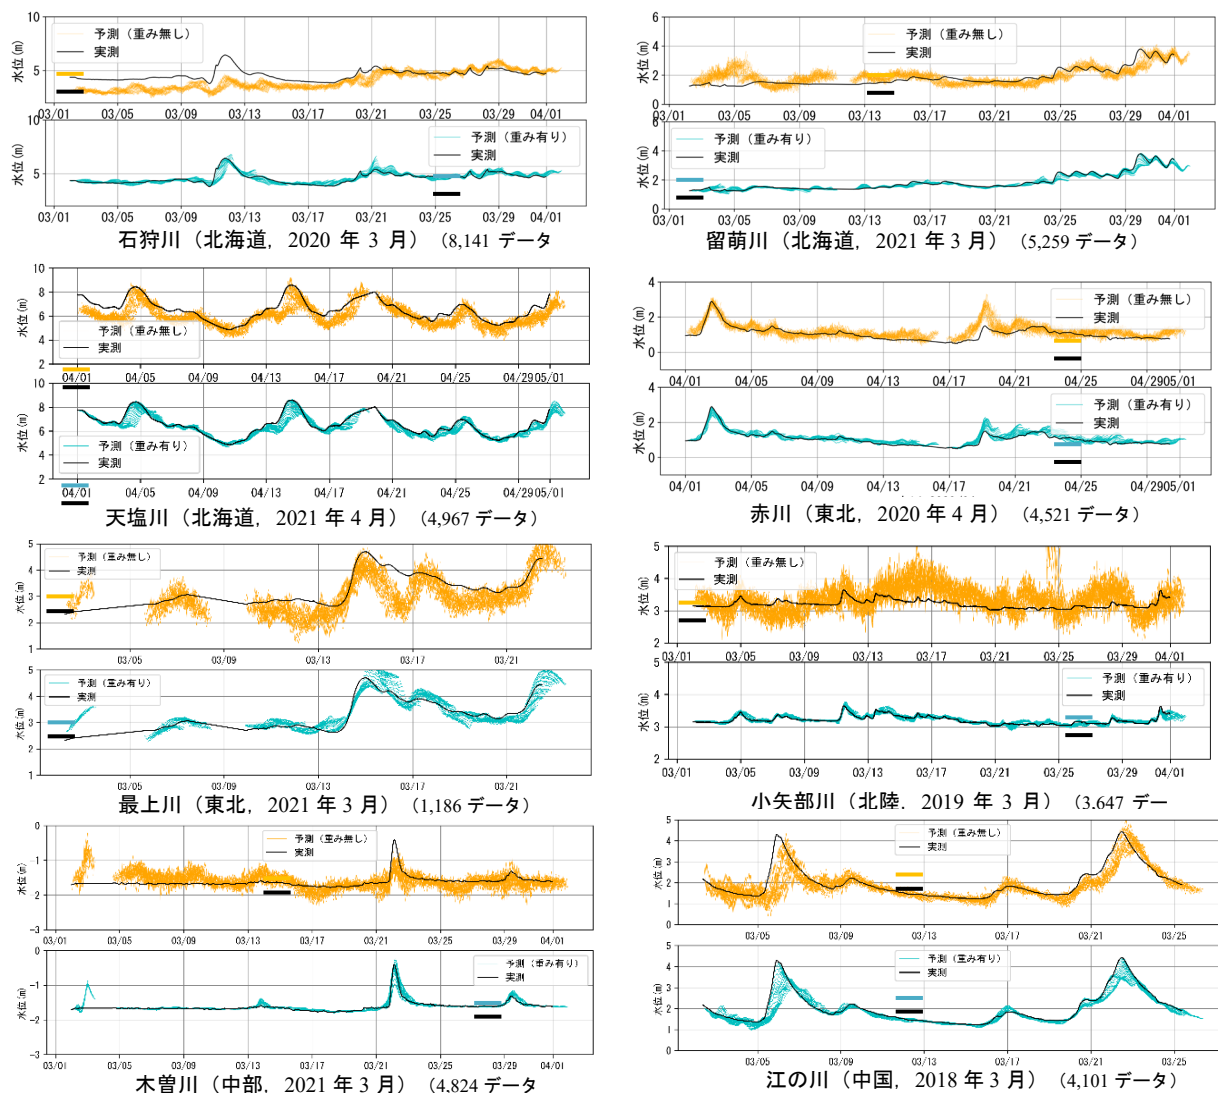


図-6 予測結果の一例 (上段：重みなし，下段：重みあり)
 Fig.6 Example of prediction results (upper: without weights, lower: with weights)

測地点ごとに異なるためである。一般に、深層学習では学習データ数が多いと予測精度が向上する傾向にあることから、振動の発生状況が河川ごとに異なると推察される。

図-7は、重み付けにより予測した水位と実測水位の相関を示したものである。河川ごとに12, 24時間先の予測と実測の回帰式を求め、回帰式の傾きおよび予測値と実測値の相関係数を図の上部に示した。結果から、予測時間が短いと相関係数は高く、相関式の傾きが1に近くなる傾向が示された。予測時間が12hの場合に各河川とも相関係数が高く(最小値: 0.53(最上川)、

最大値: 0.92(江の川)、平均: 0.81)、傾きが0.73以上であり、24時間先の予測に比べて予測精度が良好であった。

以上より、本手法は、入力データへの重み付けにより、地域や流域面積を問わずに融雪期の水位変動を予測でき、出水を検知できることを確認した。ただし、相関性が低い河川があるため、別途予測精度の改善方法を検討する必要がある。

4. 学習データの量が結果に及ぼす影響

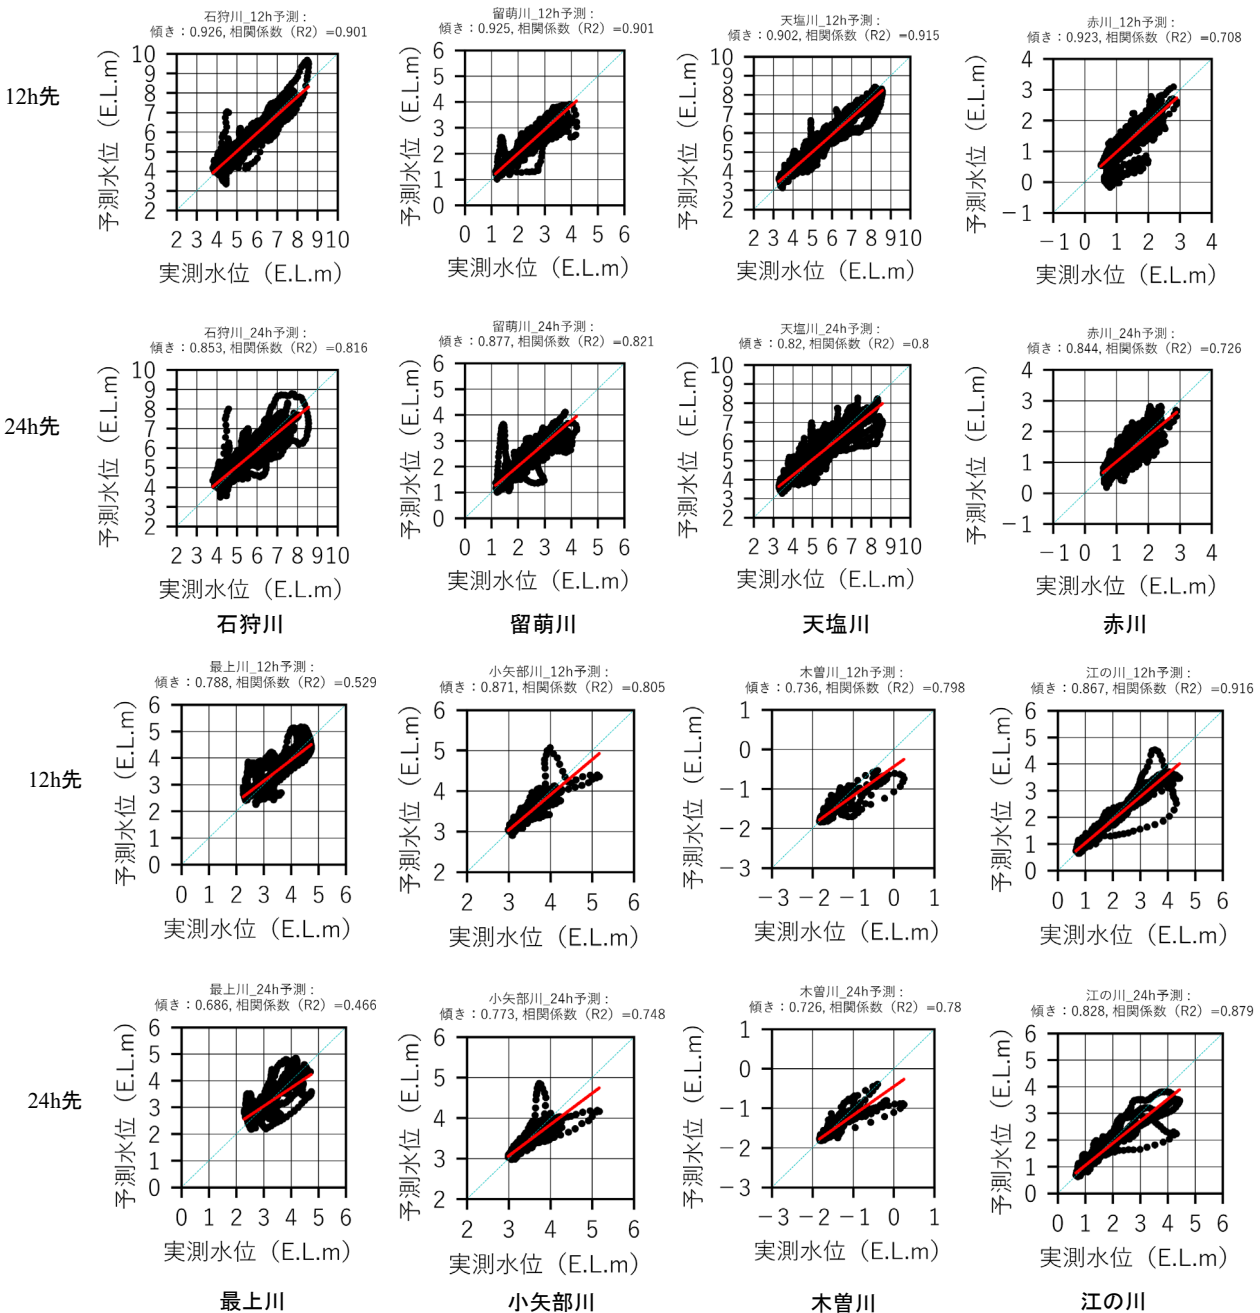


図-7 実測水位と予測水位の比較
Fig.7 Comparison of measured and predicted water levels

3章では2018~2021年の4年分のデータのうち3年分の学習データを用いて水位を予測した。ここでは実河川に適用する際に本手法に必要なデータが少なかった場合を想定し、2020~2021年の2年分(学習データが1年分)で水位を予測し3章の結果と比較した。使用した気象分布画像は2020年、2021年の2年分が準備できる降水量、気温、風速、積雪深の4項目とし、日照時間はAMeDAS観測値を用いた。予測方法は前述の方法と同様として、2020年と2021年の3~5月を予測した。石狩川の月形観測所と赤川の押切観測所における予測結果を図-8に示す。3章の結果と同様に、重み付けにより予測精度が向上する傾向が見られた。しかし図-9に示すように重み付けした際の相関係数の値は3章の結果より小さくなっており、傾きは1から離れる傾向が見られた。このことから、本手法は重み付けにより予測精度は向上するが、学習データが少ないと多様な出水イベントが含まれず、過去にないようなイベントに対して精度よく水位を予測できなくなることが示唆された。この点は既往の研究報告にもあるように、ニューラルネットワークが有する課題でもある¹³⁾¹⁴⁾。

以上より、本手法を実河川に適用する場合は、学習データの量を確保することが重要であり、例えば実測水位と予測水位の差異が大きい場合や、相関性が低いなどの状況になる場合は、RRIモデルなどの物理モデル¹⁵⁾を用いて学習データを増やしたのちに本手法を用いることが必要と考える。


5. おわりに

融雪に関する気象分布画像を用いて深層学習により1時間ごと24時間先までの水位を予測する方法を構築し、予測水位と実測水位の時系列での比較と、予測水位と実測水位の相関に関する定量評価により、実河川への適用性を確認した。その結果、重み付けにより8河川全てで振動が低減し、予測水位と実測水位の差異が小さくなった。また、重み付けがない時と比較して相関式の傾きと相関係数が改善した。

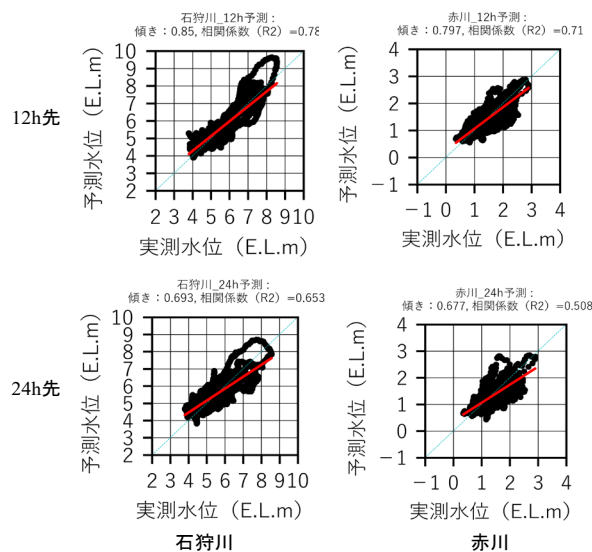
本結果から、本手法により地域や流域面積を問わず融雪期の出水を捉えられる可能性が示された。また河川ごとに予測精度を高めることで、工事への適用可能性が高まると考えられる。

参考文献

1) 伊藤貴寛, 佐々木猛, 長尾鉄彦: 積雪寒冷地の河川における融雪予測の有効性の検討, 平成20年度技術研究発表会,



(a) 水位予測結果



(b) 実測水位と予測水位の比較

図-8 2年分のデータを使用した予測
Fig.8 Prediction using 2 years of data




図-9 学習データ期間と解析精度の関係 (相関式の傾きと相関係数)

Fig.9 Comparison of training data period and prediction precision (proportional coefficient and correlation coefficient)

- 2008.
- 2) 大野剛, 高山百合子, 伊藤一教: 気象分布画像を用いた融雪時期における河川の日最大水位予測と河川工事への適用性検討, 土木学会論文集B1(水工学)第77巻2号, p.I_301-I_306, 2021.
 - 3) 西原照雅, 数馬田貢: 気象・水門観測値から融雪機のダム流入量を予測する1手法, 河川技術論文集, 第19巻, p.259-264, 2013.
 - 4) 山田崇, 横山洋, 柿沼孝治: 深層学習モデルを活用した融雪期のダム流入量予測, 第66回北海道開発技術研究発表会論文, 2022.
 - 5) 黒澤 祥一, 福島 健一郎, 梅原 有理子, 吉田 天, 風間 聡: 融雪モデルと粒子フィルタを用いた米代川における融雪洪水予測, 土木学会論文集B1(水工学)第77巻2号, p.I_307-I_312, 2021.
 - 6) 荒木 健, 箱石 健太, 一言 正之, 島本 卓三, 房前 和朋: 畳み込みニューラルネットワークによるレーダ雨量を用いた河川水位予測, 河川技術論文集, 25巻, p.297-302, 2019.
 - 7) 斎藤康毅: ゼロから作るDeepLearning, pp.39-213, オイラー・ジャパン, 2016.
 - 8) 豪雪地帯及び特別豪雪地帯の指定: 国土交通省, <http://www1.river.go.jp/> (2023.3.15参照).
 - 9) 水門水質データベース: 国土交通省, <http://www1.river.go.jp/> (2023.3.15参照).
 - 10) 国土数値情報 ダウンロードサービス: 国土交通省国土政策局国土情報課, <http://nlftp.mlit.go.jp/ksj/> (2023.3.15参照).
 - 11) 知識・解説_解析雨量: 気象庁, <https://www.jma.go.jp/jma/kishou/known/kurashi/kaiseki.html> (2023.5.10参照).
 - 12) 岡崎 亮太, 中津川 誠, 小林 洋介: ランダムフォレスト法による洪水時の水位予測手法の提案, 土木学会論文集 B1 (水工学) 第74巻4号, I_1459-I_1464, 2018.
 - 13) 槻山敏昭, 外山久典, 笹原和彦, 眞間修一, 関基, 竹村仁志: ニューラルネットワークによる阿武隈川洪水予測の基礎的研究, 河川技術論文集第9号, p173-178, 2003.
 - 14) 稲吉明男, 長江幸平, 田宮睦雄, 宮田達磨, 眞間修一, 竹村仁志: ニューラルネットワークモデルによる二級河川での洪水予測の基礎的検討, 河川技術論文集第9号, p179-184, 2003.
 - 15) 中村要介, 小池俊雄, 阿部紫織, 中村和幸, 佐山敬洋, 池内幸司: 粒子フィルタを適用した RRI モデルによる河川水位予測技術の開発, 土木学会論文集 B1 (水工学), 74巻5号, pI_1381-I_1386, 2019.