

2019 年度 卒業論文

長期降雨時系列を入力とした河川水位
推定・予測のための深層学習モデルの開発

Development of a Deep Learning Model for River Water
Level Estimation and Prediction with Long-term Rainfall

高知工科大学

工学研究科基盤工学専攻環境数理コース



学籍番号 1225088

若槻 祐貴

Yuki Wakatsuki

指導教員 中根英昭

端野典平

2020 年 3 月 15 日 提出

要旨

気候変動に伴う豪雨事象の規模・頻度の増加が進行しており、洪水被害を軽減するためのソフト対策として、河川水位予測の重要性が高まっている。統計的手法である深層ニューラルネットワーク (DNN) により、従来の物理モデルよりも高精度に河川水位予測ができることが示された¹⁾。しかし、入力において上流水位情報を使用していることにより、他流域への汎用性や予測時間の延長に伴う精度低下についての課題が存在している。雨量のみを使用したモデル化により、雨量予測時間の延長に伴い、水位予測時間を延長することが可能となる。本研究では、これまでに行った長期降雨のみを入力とした DNN による河川水位推定モデルの開発²⁾に加えて、詳細な分析や本研究の有効性を示すことを目的とする。

四国・四万十川の上中流域をモデル化の対象とし、津野川水位観測所の水位を推定・予測する。DNN モデルには、全結合多層パーセプトロンを採用し、入力には上流 13 地点の雨量観測所のデータ、教師には津野川観測所の水位データを与え、水位推定モデルを構築する。この際、入力雨量時系列の遡り期間の違いによる推定精度を比較することで、最適な遡り期間を検討する。遡り期間は、1 週間から 1 年の間の 6 通りとし、最適だと判断した入力によるモデルをテスト用データに適用し、評価を行う。

各遡り期間における水位推定の精度を比較したところ、期間を延ばすことによって誤差が低減し、1 年遡ることで誤差が最小となったため、最適な遡り期間は 1 年であると判断した。長期の雨量データを使用することで、長時間かけて河川へ流出する地下水等の寄与を含めてモデル化できることが示された。テスト用データに適用したところ、洪水時、渇水時ともに良好に推定できた。モデルの外挿性を検討したところ、学習時を 34~35% 超える短時間流域平均雨量が観測された洪水に対しても適用可能であることがわかった。また、推定精度の低い事例の空間的な降雨分布は、学習時と比較して下流部での割合が大きいことがわかった。さらに雨量データを使用しない数時間先の予測モデルの開発を行った。短時間先の予測においては、入力データに水位情報を用いず雨量のみを用いる本研究手法は、水位情報を用いる先行研究手法¹⁾よりも高い精度で予測できる可能性があることがわかった。Layer-wise Relevance Propagation により、入力要素の出力への寄与度を定量化したところ、各雨量観測所の寄与する時刻や降雨到達時間、観測所間の寄与度の大きさの違いを算出できた。先行研究手法については、予測時間の延長とともに上流の水位変化、雨量の寄与度が相対的に大きくなっていった。

- 1) 一言正之, 櫻庭雅明, 清雄一; 深層学習を用いた河川水位予測手法の開発, 土木学会論文集 B1(水工学), 72, 4, I_187-I_192, 2016.
- 2) 中根英昭, 若槻祐貴, 山本啓, 武田拓巳, 端野典平(2019): 深層学習の河川防災・環境分野への応用—四万十川・鏡川水位, 仁淀川大渡ダム流入量について—, 高知工科大学紀要 16 卷(1), 227-244(2019).

目次

1. 背景	1
2. 対象流域と観測データ	4
2.1. 対象流域	4
2.2. 観測データ	4
3. 手法	6
3.1. データ加工	6
3.2. 多層パーセプトロン	6
3.3. モデル評価指標	7
3.4. ハイパーパラメータ探索	8
4. 結果	10
4.1. 入力雨量時系列の最適な遡り期間の検討	10
4.1.1. 検証用データに対する精度の比較	10
4.1.2. テスト用データに対する推定結果の比較	10
4.2. 最適な入力雨量遡り期間のモデルによる推定・予測	11
4.2.1. 4大洪水事例の推定	11
4.2.2. 外挿性の検討	12
4.2.3. 渇水事例の推定	14
4.2.4. 雨量予測データがない場合の水位予測	15
5. 議論	17
5.1. 先行研究手法との比較	17
5.2. 可視化	19
5.2.1. 長期雨量時系列を使用した提案手法モデル	20
5.2.2. 水位情報を使用した先行研究手法モデル	23
6. まとめと今後の展望	25
7. 謝辞	28
8. 参考文献	29
9. 図	33
10. 表	50
11. 付録	54

1. 背景

地球温暖化の進行によって、気温の上昇だけでなく、大気中の水蒸気量の増加や台風の強度の増大、豪雨等の **extreme events** の増加が予想されている (IPCC, 2014). 特に日本南方海域では世界有数の暖流である黒潮のために海面水温が高く、その上昇速度も大きい (MOE). 2017 年九州北部豪雨 (Cabinet Office, 2018) や 2018 年 7 月豪雨 (ICHARM, 2019), 2019 年台風 19 号による 9 月豪雨 (NHK, 2019) を始めとして、近年、日本列島に上陸する台風や停滞する線状降水帯等による記録的豪雨が多発し、河川の氾濫や浸水害が頻発している. 河川上流の雨量と下流の水位の関係を住民自身が直感することは困難であり、避難の判断を誤って人命が失われた例が記憶に新しい (The Japan Times, 2019). 従って、避難の判断に必要な **accuracy** を持ち、住民自身が使用できる水位予測モデルは、国や自治体による予測や指示を補完するための必要不可欠なツールとなり得る. 近年、深層学習技術の導入によって人工ニューラルネットワーク (**Artificial Neural Network; ANN**) が再び発展し、水文学の諸問題への解決に向けて、応用可能性が大きく広がっている. 災害被害軽減のソフト対策として洪水予測精度の向上が必要である. 日本の川においては、他の世界的な川と比較すると、流路が短く、急勾配であるという特徴がある (MLIT, 2019). そのため、降雨の流下速度が速いことから洪水が頻繁に発生しているという実態があり、より早期の避難判断を行う必要がある. 日本の 1 級河川諸量 (水位、雨量等) は、10 分あるいは 1 時間毎のデータとして公開・保存されており、気象データと共に典型的なビッグデータである. 河川水位は時系列データではあるが、水位時系列の振る舞いそのものから将来水位を予測できるような規則性は乏しい. むしろ、特定の時刻の水位は上流の雨量の過去の時系列に依存しており、水位の時系列的特徴は、対応する雨量時系列の特徴によって担保されている. 過去の雨量と水位の関係は非線形性が強く、時間遅れも複雑である. このような系のモデル化には、ANN が有効である.

ANN のうちの **Multi-layer Perceptron (MLP)** は、水文学における ANN の応用研究において最も使用されている手法である. 線形回帰との大きな違いは、入力層と出力層との間に「隠れ層」が導入されている点であり、これにより、非線形なモデルを構築することが可能となる. MLP を用いた河川流入量の予測 (Garcia-Bartual, 2002; Cheng et al., 2005; Kuok et al., 2010) や 河川水位の予測 (Bustami et al., 2007), 降雨-流出モデルの開発 (El-shafie et al., 2011; Chen et al., 2013) が行われており、ニューラルネットワークによる水文モデルの有効性が確認されてきた. また、従来の物理モデルとの比較も行われており (Daliakopoulos and Tsanis, 2016; Hitokoto et al., 2017), ANN によるモデルの性能が上回るという研究結果も存在する. さらに、MLP モデルをベースとして、衛星データの活用 (Akhtar et al., 2009), 河川流量予測に適切な入力雨量地点の選定 (Adhikary et al., 2018), **Neuro-Fuzzy** と MLP を組み合わせた河川水位予測モデルの開発 (Bazartseren et al., 2003),

Deep Belief Network(DBN)を事前学習器とした流入量予測モデルの開発(Bai et al., 2016), Long short-term Memory(LSTM)を事前学習器とした地下水位予測モデルの開発(Zhang et al., 2018), multilayer perceptron-firefly algorithm を MLP に導入したモデルの開発(Darbandi and Pourhosseini, 2018), 等の研究により水文 MLP モデルの高度化, 他の ANN 手法との比較(Yaseen et al., 2016)等, 多くの応用研究が存在し, MLP を中心とした ANN 手法の有効性が確認されてきた. その他にも RNN や LSTM を用いた降雨-流出モデルの開発(Kratzert et al., 2018)等の他の手法によるアプローチも存在する.

さらに, 近年では計算機の性能向上や機械学習ライブラリの充実により深層構造を持つ ANN, すなわち, Deep Neural Network(DNN)の実装が容易となっており, 様々な分野において応用され, 多くの功績が残されている. しかし, 現在, 水文学分野においては, 他の分野と比較して深層学習が広く使用されていない(Shen, 2018). 本研究では, 隠れ層が 2 層以上の多層化された ANN を DNN と呼ぶ. DNN により, モデルの自由度が増加することで, 複雑なタスクにも適用できることが知られている. 数少ない水文学への深層学習応用研究の成果として, 深層型 MLP による河川流入量の予測(Rao and Giridhar, 2016; Chanu and Kumar, 2018; Oluwatobi et al., 2018)が行われ, 高精度の予測が可能となり, DNN の応用の有効性が示された. しかし, これらの研究はいずれも日または月単位の大きな時間スケールでの推定や予測を行っており, 洪水対策ツールとなる短時間スケールでの深層学習の応用例は数少ない.

洪水を想定した実時間での水文モデル開発は, 浅層型 MLP を用いて, アルノ川における 1~6 時間先の河川流量予測モデルの開発(Campolo et al., 2003), 台風期における 1-3 時間先の降雨-流出モデルの開発(Chen et al., 2013)が行われた. さらに, 世界的に見て急峻である日本の河川のうちの淀川における 1~6 時間先の河川水位変化予測モデル(Hitokoto et al., 2017)が深層型 MLP を用いることによって開発された. しかし, これらの研究(Campolo et al., 2003; Hitokoto et al., 2017)においては, 入力データとして雨量に加えて, 水位や水位変化, 水力発電量といった物理量を使用している. つまり, 対象とする地点よりも上流に水位観測所または貯水池のある流域に対してのみ適用できる手法である. しかし, 実際には, 上流に他の水位観測所や貯水池が存在しない流域は数多く存在するため, それに該当しない流域についての適用可能性について懸念される. 雨量のみを使用した降雨-水位モデルによって, 洪水時の水位予測可能な流域を増やすことができる. さらに, 雨量データのみを入力とした実時間流量予測の研究(Chen et al., 2013)については, 各雨量観測所の 1 時間値 1 要素分のみを使用していることにより, 長時間連続的な降雨のある事例についての適用可能性やより大きな流域に対しての適用可能性等が懸念される. そのため, 長期の雨量データを入力とするような長期スケールの雨量による寄与を考慮したモデル開発により, 流域の大小や降雨パターンに左右されない水文モデルを開発することが必要である.

深層学習モデルは優れた性能を示すが, 非線形なモデルであるため, その入力と出力の関係性を解釈することが難しい. 層が深くなったことで, より解釈性が小さくなり, モデル性

能と解釈性はトレードオフの関係にある。この状況を打開するため、深層学習モデルの出力に対して入力への寄与がどの程度あるかを可視化する手法 **Layer-wise Relevance Propagation(LRP)**(Bach et al., 2015)が開発された。**Sensitivity Analysis**(Simonyan et al., 2014), **Deconvolution Method**(Zeiler and Fergus, 2014)による深層学習モデル可視化手法と比較したところ、**LRP** が優れていることが示された(Samek et al., 2017)。この手法によって、学習済みモデルの重み、各層の各ノードにおける状態を利用して出力側から入力側へネットワーク内の情報を逆伝搬していくことで入力値の各要素の寄与の大きさを測ることが可能となった。深層学習による水文モデルの性能は、従来の統計的手法を上回ってきたが、モデルを解釈する努力は行われていない(Shen, 2018)。

本研究では、最長約 1 年間に遡る長期の雨量時系列のみを入力に用い、河川水位予測のためのニューラルネットワークモデルの構築を試みる。我々は 2017 年度に、河川水位やダムへの流入量を予測するために、数日～1 年遡る上流流域圏の雨量を入力として用いる深層学習手法を検討し(Nakane and Wakatsuki, 2018)、2018 年度には、入力雨量時系列を長くすることによって地下水や土壌水分の影響を含む水文過程をモデル化することが可能であることを示した(Nakane et al., 2019)。しかし、詳細なモデル特性の分析、モデル学習時における情報の漏えい、ハイパーパラメータ選定方法等についての課題が存在している。本研究では、1) これらの課題を解決し、本手法を確立すること、2) 入力データの寄与度を可視化することを通じて、実用化に必要とされる物理的解釈を提供すること、の 2 つを目的とする。本論文で対象とする流域は、西日本の四国にある四万十川の中上流域であり、深層型 **MLP** を用いて高知県西部の津野川観測所の水位を推定・予測する。また、はん濫危険度が高い日本の河川において優れた性能を示した予測モデル(Hitokoto et al., 2017)をベンチマークとし、本研究手法と比較を行うことで、それぞれのモデルの特性を考察し、雨量のみを入力として河川水位を予測する手法の有効性を示す。DNN モデルの可視化には **LRP** を用い、出力値の背後にある水文過程を議論する。

2. 対象流域と観測データ

2.1. 対象流域

本研究では渡川流域を対象とし、本流の一級河川である四万十川を対象河川に選定した。渡川流域の図を **Figure 1** に示す。渡川流域は、西日本の四国地方の南西部に位置する。流域の土地利用は、山地が約 95%、農地が約 4%、宅地等の市街地が約 1%を占めている。流域面積は 2186 km² で年間総雨量は約 2900 mm に及び、特に上流部で大きな雨量が観測されている日本有数の豪雨地帯に位置する(MLIT, a)。四万十川は、幹線流路延長が 196 km であり、大きく穿入蛇行しながら 319 もの支川を合わせ、太平洋へと流れ出る。河床勾配は上流で 1/100 と大きく、窪川盆地で 1/650 程度とやや緩やかになり、中流部では、佐賀取水堰から佐田付近までで 1/380~1/1300 程度である。(文献)また、支川のうちの一つである梶原川には発電用のダムの貯水池が 2 つ存在するが、本流には堰が 1 つ存在するのみである。本流に流れ出た雨水をダム等により人為的に調整できないため、水量の管理は困難である。そのため、河川水位推定によるソフト対策の重要度の高い河川である。

2.2. 観測データ

本研究では、良質なデータの得られる中流域の津野川観測所(**Figure 1 L_03**)を対象水位地点とした。津野川観測所は河口から約 40km 上流に位置しており、下流部の水位観測所と比較して潮汐の影響が小さいことを考慮して選定した。それより上流の船戸、大野見、窪川、芳生野、北川、梶原、影地、大正、日吉、堂ヶ森、近永、目黒、江川崎の 13 地点の雨量観測所(**Figure 1 R_01~R_13**)を対象雨量地点とした。雨量、水位データは国土交通省水文水質データベース、気象庁過去の地点気象データより取得した。10 分あるいは 1 時間ごとに、2002 から現在までのデータが入手可能である。本研究では、地形等の環境変化を考慮して、2008~2018 年の 1 時間ごとのデータを使用した。津野川観測所の 2008~2018 年の水位の変化を **Figure 2 (a)** に示す。冬に水位が低く、夏から秋にかけての豪雨期に毎年のように水防団待機水位近い、あるいはそれを超える高水位が現れている。また、過去に 2 度ははん濫危険水位を超える水位が観測された洪水の事例も存在する。流域内の平均雨量を **Figure 2 (b)** に示す。2013 年以降から 1 時間雨量が 30 mm を超える雨量が頻繁に観測されるようになり、短時間降雨強度が強くなっていると観察できる。本研究では、2008~2014 年のデータを訓練用、2016 年を検証用、2017~2018 年のデータをテスト用に分割した。検証用データでモデルのハイパーパラメータの検討を行い、テスト用データで精度評価を行う。1 時間ごとの実時間推定を行うため、サンプル数はそれぞれ、訓練用データ数は、61368、

検証用データ数は、8784、テスト用データ数は、17520である。

3. 手法

3.1. データ加工

本研究では、津野川観測所の水位を良く再現するために、遡る入力雨量時系列の長さを検討する。遡り期間がそれぞれ概ね1日、1週間、2週間、1ヶ月、3ヶ月、6ヶ月、1年の6通りで実験を行い、この中で最も推定精度が高いものを適切な雨量時系列期間として採用する。入力雨量時系列の時間分解能は、過去に遡るほど分解能を大きくし、データの圧縮を行った。その理由は、表面流出は、地表に達した雨水が直接地表を通過して河道に入り短時間で流出し、ピークに大きく影響するが、地中に侵入して緩やかに河道に流出する中間流出や地下水流出は、水位上昇に表面流出と比較して長い時間遅れを生じ(MLIT, b), 浸透する深さや地質により様々な時間的な広がりを持った水位上昇を形成すると考えられるからである (Nakane et al., 2019) つまり、過去に遡るほど、短時間雨量の情報と現水位との直接的な対応関係は見られなくなり、過去の長時間スケールの降雨によって現在の土壌水分量や湧水量が支配されていると考えられるためである。

以下では、本研究で用いる1時間値データの圧縮方法を説明する。遡り期間の初めの6時間を1時間分解能、遡り期間1年で1ヶ月分解能、という2つの条件を与え、その2点を結ぶ曲線を描く関数を作成した。

$$y_{resolution} = \text{int}\left(6 \frac{-\log 719}{\log 1460} \cdot \frac{\log 719}{\log 1460} x + 1\right) \quad (1)$$

ここで、 x は遡る時間(hr), $y_{resolution}$ で与えられた分解能値はデータを平均化する時間(hr)を示している。各期間とも同じ関数を使用し、それぞれに対応する期間でデータを切り取ることで各遡り期間のデータを作成した。このようにしてデータ数を小さくすることでメモリや計算時間への負荷を軽減することも考慮している。Eq. (1)に従って圧縮された各遡り期間における(a)最大分解能, (b)データ数を Figure 3 に示す。例えば、遡り期間が1年の場合、最大分解能が約1ヶ月のデータとして69要素に与えられる。

雨量観測所と水位を観測している津野川観測所の位置関係や、支流ごとの傾斜や地質の違いが水位の推定・予測に影響を与えることが想定されるため、上流観測点平均雨量ではなく、全13地点の降雨の時系列を入力データとした。入力データ及び教師データは、全地点の訓練サンプルから得られる平均を、各々の観測値から差し引き、最大値と最小値の差で割ることにより、正規化した。

3.2. 多層パーセプトロン

最も広く用いられている ANN の一種である MLP は通常、誤差逆伝搬法によってパラメータの更新が行われる (Rumelhart et al., 1986). 使用した全結合 MLP の構造の一例を Figure 4 に示す. このネットワーク構造は、各層のノードが前層の全ノードからの情報を受け取り、次層の全ノードへ情報を伝達するため全結合 MLP と呼ばれる. MLP の構造は、入力層、隠れ層、出力層から成る. 各ノードは、前層の入力に重みを付加し、入力層から出力層へ向かって伝搬する順伝搬型ネットワーク構造を持つ. 線で繋がれた結合には、それぞれ重みに対応しており、各ノードと重みとの線形和に各層におけるバイアスを加え、活性化関数を作用させて次層へと伝搬する. 重みの更新は、誤差逆伝搬法 (Rumelhart et al., 1986) によって行う. 誤差逆伝搬法により、各重み係数における誤差関数の勾配 (偏微分) を計算し、最適化関数によって更新を行い、この処理をバッチ数 × 学習回数分行う.

本研究では、入力層のノード数は、遡る期間の長さに対応して、1 地点につき 27 から 69 まで変化する. 出力層は 1 つのノードとなる. 入力層から出力層の手前までの隠れ層までは、活性化関数として PReLU 関数 (Maas et al., 2013) を用いて、最終隠れ層と出力層の間は、回帰を行うため、活性化関数は用いない.

通常ニューラルネットワークの学習を行う際に注意しなければならないのが、過学習である. 学習されたパラメータが訓練データの局所解に陥り、訓練データに対してのみ最適化されること (過剰適合) により、汎用性が欠如してしまう現象のことを指す. また、ある重み係数に大きな値が与えられることにより、勾配の爆発や消失の問題を引き起こす. それを回避する方法の一つとして、誤差関数 $L(\mathbf{w})$ にペナルティ項を加える L1-regularization が

$$L'(\mathbf{w}) = L(\mathbf{w}) + \lambda \sum_{i=1}^n |w_i| \quad (2)$$

ある. ここで \mathbf{w} は重みパラメータ, $L'(\mathbf{w})$ は L1 ノルム項を付加した誤差関数である. L1-norm は重み係数の絶対値の和であり、これにより各重み係数の大きさに制限を与え、重み係数の偏りを小さくすることができる. 重み係数が 0 に近づくため、不要な説明変数を省くことで次元削減をし 過学習防止の機能を果たす. 係数 λ により、L1-norm の付加量を調整する.

3.3. モデル評価指標

本研究では、モデル評価のために、観測値とモデル推定値の間における root mean squared error (RMSE), nash-sutcliffe efficiency (NSE) (Nash et al., 1970) を指標として使用すると共に、percentage error of peak (PEP), time error of peak (TEP) という指標を作成して使用した. RMSE は、観測値 y_i とモデル推定値 \hat{y}_i との誤差の指標の一つであり、値が小さいほどモデルの当てはまりが良いことを示す. NSE は、流量の自然変動を考慮してモ

デルの精度を評価する指標で、その値が 1 に近いほどモデルの精度はよいとされ、0.7 以上でモデルの再現性が高いとされている(SCJ). RMSE とは異なり、水位の大きさの異なる事例について相対的な評価を行うことができる. PEP は、ある洪水イベントのピーク時におけるモデルの性能であり、ピーク高に対してどれほどの割合の誤差があるかをパーセンテージで示す指標である. TEP は、ある洪水イベントのピーク時におけるモデル推定値のピーク生起時刻 \hat{t}_p と観測値のピーク生起時刻 t_p との時間差であり、モデル推定値が洪水ピークのタイミングをどれほど良く再現できるかの指標である. この指標は、ある時間連続的な降雨によって上昇した水位がどのタイミングでピークを迎えるか、すなわち、モデルによる洪水到達時間の再現度を測るために重要である.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3)$$

$$\text{NSE} = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4)$$

$$\text{PEP}(\%) = \frac{\hat{y}_{t_p} - y_{t_p}}{y_{t_p}} \cdot 100 \quad (5)$$

$$\text{TEP} = \hat{t}_p - t_p \quad (6)$$

3.4. ハイパーパラメータ探索

ハイパーパラメータ探索手法には、グリッドサーチ法(Gorr et al., 1994)を採用した. 探索範囲は、Table 1 の通りとした. MLP の隠れ層数、ノード数、L1 正則化パラメータの 3 つを探索対象のハイパーパラメータと設定した. L1 正則化パラメータは、Eq. (2)における L1-norm の係数 λ である. また、隠れ層のノード数については、前層のノード数を超えるノード数を持つ構造を排除した. その理由は、前層よりもノード数を大きくすると、入力次元を拡張する操作になるため、最終層の 1 ノードへと情報を圧縮する際には、不適切であると考えたためである. 最終的に、各遡り期間に対して総計 480 通りのハイパーパラメータを探索の組み合わせに設定した. バッチサイズは 100, 損失関数は観測値と推定値の mean squared error(MSE), 最適化関数は、Nesterov-accelerated Adam(Nadam)(Dozat, 2016)とした. 計算コストを考慮して学習回数は 25 とし、学習回数 16-25 における学習済みモデルの検証用データに対する平均 RMSE を計算し、最小の誤差が得られたモデルを最適なアーキテクチャであると判断する. ハイパーパラメータの選定は、各遡り期間に対して行い、

いずれの期間についても最適な組み合わせを吟味した。その後、最適であると判断したアーキテクチャにより学習回数 140 と設定して再学習を行い、91~140 回における 50 モデルの平均値を最終的なモデル推定値とし、評価を行った。

4. 結果

4.1. 入力雨量時系列の最適な遡り期間の検討

4.1.1. 検証用データに対する精度の比較

各遡り期間の検証用データに対する学習回数 16-25 の学習済み 10 モデルの平均 RMSE が最小であったモデルの再学習を行った 50 モデルの平均値による RMSE を Figure 5 に示す。図は、検証用データの全期間に対しての RMSE を示しており、遡り期間を 1 日から 1 週間に延ばすことによって、大幅に誤差が低減していることが読み取れる。さらに遡り期間を延ばすと、3 ヶ月において一時的に増加が見られるが、総合的に見ると、最長である約 1 年の遡り期間を遡ることで最小の誤差が得られていることがわかる。水位推定には、概ね 1 ヶ月程度の期間で誤差が収束し始めるが、期間を延ばすことで、より現実に近いモデル化ができると考えられる。

次に、各水位高における再現性を確認することによって、より詳細に各遡り期間におけるモデルの性能の特性を分析し、どの水位高においてモデル性能の違いが現れるのかを観察した。水位を訓練データにおけるパーセンタイルで分割し、各水位高における RMSE を算出した結果を Table 2 に示す。その結果、渇水時の低水位に対応するパーセンタイル 0-20 においては、1 ヶ月を遡る期間のモデルの誤差が最小であった。しかし、パーセンタイル 20 以上の水位に対しては、いずれも 1 年を遡るモデルの誤差が最小であるという結果が得られた。この結果から、パーセンタイル 20 以上の水位推定には、より長期スケールでの降雨情報が必要であることが考えられる。本流域における長期の流出による水位への影響は、パーセンタイル 20 以上の水位高において強く表れていると考えることができる。高水位においても推定精度が高い理由は、長期の雨量時系列を入力にすることで地下水等の長期の流出の寄与をモデル化できたと考えられる。土壌水分量等のパラメータが洪水時においても寄与するためであると考えられる。以上より、約 1 年を遡るモデルが検討した遡り期間の中において最も適すると判断した。

4.1.2. テスト用データに対する推定結果の比較

ここでは、上で最適な条件と判断した各遡り期間の学習済みモデルを、未使用のデータであるテスト用データに適用し、推定結果の違いを考察する。Figure 6 にテスト用データの観測値とモデル推定結果の散布図を示す。遡り期間を延長することにより、グラフは相関係数 1 の直線の周辺に分布していくことが見て取れる。遡り期間を延長することにより高水位、低水位ともに相関係数 1 の直線に近づいていることが見て取れる。特に、観測点が多く存在する低水位について、遡り期間が 1 日のモデルの推定値は、ばらつきが大きく、観測値

と乖離している点が存在することを観察できる。また、遡り期間が1年のモデルは、他のモデルと比較して中~高水位での外れ値が小さいことも確認できる。検証データに対する結果と同様に、より高水位におけるモデル化が優れているということが言える。1年遡る長期の雨量データを入力とした本手法は、テスト用データ全体に対して、 $RMSE=21.3(\text{cm})$ 、 $NSE=0.956$ であり、高精度に推定できていることがわかった。

次に、各遡り期間における洪水時の推定結果を Figure 7 に示す。図は、洪水時における推定値を学習時に得られた平均化前の 50 個のモデルによる全てを示している。平均値の $RMSE$ はそれぞれ、 $1d:192.0$ 、 $1we:69.5$ 、 $1mo:54.0$ 、 $1yr:52.8(\text{cm})$ であり、遡り期間を延長することにより、推定値は観測値により近づいていくことがわかった。遡り期間が1日のモデルにおいては、値が振動しており、現実的な水位を再現できていないことがわかる。この結果は、表面流出の寄与が大きい洪水時であっても1日の時間スケールの雨量の情報では水位推定には不十分で、より長期スケールでの流出の寄与をモデルに含める必要があることを意味している。また、これら50個のモデルによる推定値のばらつきは、遡り期間に依存することがわかった。50モデルの推定値の標準偏差は、洪水期間で平均するとそれぞれ、 $1d:28.0$ 、 $1we:20.2$ 、 $1mo:15.1$ 、 $1yr:10.4(\text{cm})$ であり、遡り期間を延長することにより、推定値のばらつきはより小さくなっていくことがわかった。そのため、遡り期間を1週間に延長すると、推定の平均値はある程度観測値に近い値を示すが、1週間遡るモデルの不確実性は、1年遡るモデルと比較して約2倍程度であった。この理由として考えられるのは、入力雨量をより多くの時間スケールで入力することによって、DNNの重み係数に偏りが生じにくくなるためであると考えられる。短い時間スケールの雨量データによるモデル化では、入力要素数が少ないため、各要素の相対的な重み係数に偏りが生じやすいと考えられる。特に、洪水時における入力雨量データに大きな値が存在すると、その影響がより強く現れることが考えられる。ある程度の長さの時間スケール（～1週間）によるデータを使用することにより、誤差は収束し始めるが、モデルの不確実性は依然として生じることが推察される。このように、遡り期間を延長することで洪水時におけるモデル推定の誤差、不確実性を減少させることが可能であることがわかった。この点は実用上、モデルの信頼度を評価するとき重要な情報であるので、対象流域ごとに定量化する必要があると考える。

4.2. 最適な入力雨量遡り期間のモデルによる推定・予測

4.2.1. 4大洪水事例の推定

次に、最適であると判断した約 1 年を遡るモデルによる洪水時におけるモデル推定結果を示す。本研究では、テスト用データのうちの 4 大洪水を検討の対象とした。Figure 8 はそれぞれの洪水波形のピークの前後 48 時間についてのモデル推定結果を示している。各事例の特徴としては、case1 は、比較的なだらかに水位上昇が見られ、洪水波形は、概ね左右対称である。case2 は突発的な降雨があり、2008~2018 年の間で最大の短時間雨量が観測されている。それに伴い、急激に水位が上昇している危険な洪水波形である。case3 は、日本において、甚大な被害をもたらした平成 30 年 7 月豪雨時の洪水である。長期間連続して降雨があり、積算雨量はテスト用データの期間中最大であった。洪水波形は複数のピークを有しており、複雑な波形である。case4 は、洪水波形は case2 と似ているが、case2 よりも若干緩やかな水位上昇の見られる洪水であった。言い換えると、case1 と case3 は水位変動が比較的緩やかで、長時間継続する降雨パターンである事例であり、case2 と case4 は水位変動が大きく、パルス的な降雨パターンを示す事例である。Figure 8 より、モデル推定値は、いずれの事例についても立ち上がり、ピーク、立ち下がりについて概ね推定できていることが観察できる。それに加えて、各時刻の精度だけでなく、時間連続的な観点においても、外れ値などが存在せず、滑らかに時間変化を表現できており、現実的な振る舞いであるという特徴も見られる。

各洪水事例についてのスコアを Table 3 に示す。Table 3 より、NSE を観察すると、0.942~0.982 の範囲にあり、各洪水波形の立ち上がり、ピーク、立ち下がりを経合的に高い精度で推定できていることがわかる。洪水間での違いを観察すると、水位変動が大きくパルス的な降雨による洪水に対して NSE が高いことが確認できる。直感的には、主に直接流出が寄与するため、比較的単純な過程に支配されているためであると推察する。次に、PEP を観察すると、3.44~11.3(%)の範囲であった。洪水間での違いを確認すると、NSE の結果とは裏腹に、水位変動が緩やかな洪水に対しての性能の方が高いという特徴が見られる。中間流出や地下水による寄与が大きくなると、立ち上がりや立ち下がり、より複雑な過程によって支配され、洪水波形も複雑になるためであると考えられる。この結果から、モデル推定値の NSE とピーク誤差の間には、トレードオフの関係が成り立っているということが考えられる。TEP については、いずれの事例も入力的时间分解能である 1 時間に収まっており、ピークのタイミングは観測値と大きはずれはないと判断することができる。

4.2.2. 外挿性の検討

統計的モデリングにおいて、パラメータチューニングに使用したデータとテストデータ間で入力のパターンが異なる場合の推定性能、いわゆる、外挿性は重要な指標となる。水文学においては、想定外の降雨による洪水にも適用できるかどうか外挿性であると言える。これまでに経験していない雨量に対しても利用可能な洪水予測モデルであれば、実際の防

災ツールとして大きく資することは明らかである。ここでは、“想定外”を訓練用データを超える規模の豪雨に見舞われた場合や空間的な降雨パターンが異なる場合のことを指す。本小セクションでは、訓練用データとテスト用データにおいて、降雨パターンとモデルの推定精度との関係を分析した結果を示す。

まず初めに、流域全体の降雨特性を分析する。訓練用データとテスト用データの降雨特性を比較するために、訓練用データにおいては、2008~2014年の上位12洪水、テスト用データにおいては4大洪水の計16洪水を対象とし、各洪水における流域平均雨量を算出した。1時間雨量、3時間積算雨量、6時間積算雨量、12時間積算雨量の4つの時間スケールでの雨量を分析する。各洪水イベントについて、Figure 9(a)は、1時間雨量の最大値、Figure 9(b)は、3時間積算雨量の最大値、Figure 9(c)は、6時間積算雨量の最大値、Figure 9(d)は、12時間積算雨量の最大値を示している。訓練時を超える大きな雨量が観測された事例は、Figure 9(a)より、1時間雨量については、case2, case3が確認できる。また、Figure 9(b)より、3時間雨量については、case2, case3, case4は大きく超過している。Figure 9(c)より、6時間雨量については、case2, case4が超過していることが確認できる。Figure 9(d)より、12時間雨量については、case2がわずかに超過している。このことから、case1を除くテスト用データにおいては、3つの時間スケールにおいて、訓練時よりも大きな短時間降雨が観測されている。そのため、これらの事例の推定は外挿を行っていると判断することができる。特に、case2については、いずれの時間スケールの雨量も訓練時を超える値が観測されており、推定の難易度が高いことがわかる。3時間積算雨量、6時間積算雨量においては、訓練時と比較して大きな差があり、いずれも約34~35%もの外挿を行っていることがわかった。言い換えると、モデルは、少なくとも34%以下の3, 6時間積算雨量の外挿が可能である。

次に、地点ごとの降雨特性を分析した。上記と同様の16の洪水事例を対象として、各洪水における地点ごとの雨量を算出した。以下の式のように、洪水 n における地点 i の時刻 t における雨量 $r_{i,t}^n$ のピーク生起時刻 t_p^n の前後12時間の積算雨量 p_i^n を求める。その後、全地点分 p^n を求め、地点 i の総雨量の割合 P_i^n を計算する操作を対象洪水16地点分行う。

$$p_i^n = \sum_{t=t_p^n-12}^{t_p^n+12} r_{i,t}^n \quad (7)$$

$$p^n = \sum_{i=1}^{13} p_i^n \quad (8)$$

$$P_i^n = \frac{p_i^n}{p^n} \quad (9)$$

計算結果を Figure 10 に示す。Figure 10 は、各洪水事例のピークの前後 12(hr)における各地点の積算雨量の割合 P_i^n を示している。割合が大きいほど、その洪水に寄与している雨量が大きいことがわかる。黒線は、箱ひげ図で学習用データの値を示している。地点は、左から上流部→下流部の順に示している。図より、上流部で雨量の大きな割合を占めており、地点を上流部から下流部へ移動するにつれて、徐々にその割合が小さく推移していることがわかる。図より、case1, case2, case4 については、地点ごとの大小関係が学習時の値と同様に変化しており、R_01 を除いて概ね%tile25~75 の範囲内に収まっている。一方、case3 については、地点ごとの大小関係が学習時とは大きく異なっており、相対的に上流部の割合が小さく、下流部の割合が大きくなっていることが観察できる。そのため、学習用データの%tile25~75 をはみ出す地点が複数存在している。R_01, R_05 の割合が小さく、R_09, R_11, R_12 の割合が大きいことが観察できる。この空間的な降雨パターンの相違が、5.2.1において、case3 の推定精度が最も劣る理由であると考えられる。

これらの結果から、河川水位推定モデルにおける推定精度は、単純に流域全体の入力データ、出力データの値の大小ではなく、地点間における空間的な降雨パターンの特異性による影響が大きく現れると考えられる。つまり、DNN モデルにとっては想定外の流域全体の雨量よりも特異性の高い地点間の降雨パターンの方を扱うほうが、圧倒的に推定の難易度が上がる可能性がある。そのため、学習の際には、できるだけ多種多様な空間的な降雨パターンを学習することが重要である。

4.2.3. 渇水事例の推定

次に、渇水を想定した低水位時についての推定結果を Figure 11 に示す。Figure 11 は、低水位期の 2 か月間における観測値とモデル推定結果を示している。遡り期間における推定結果を比べるために、遡り期間が 1 日、1 週間、1 ヶ月、1 年の 4 通りの結果を示す。遡り期間が 1 日の場合、モデル推定値は水位-10(m)程度で一定になっている区間が存在しており、水位変動を表現できていない。また、雨量に対する感度が非常に高く、微量の雨量に対して急激な水位上昇をもたらしており、水位が過大となっていることが観察できる。遡り期間が 1 週間の場合、モデル推定値は、水位低下時において、観測値のような滑らかな減少の様子を表現することができていない。また、観測値では、水位が低下しているにもかかわらず、モデル推定値は基底になっている箇所が存在している。この結果は、低水位時を推定するには、1 週間の雨量情報のみでは不十分であることを示唆している。次に、期間を 1 ヶ月に延長することによって、水位低下を良く再現するようになり、大幅に精度の向上が見られた。その後、期間を 3 ヶ月、1 年に延長することによって、観測値とモデル推定値との間に乖離が見られる結果となった。これらの結果から、低水位時において、1 ヶ月を遡るモ

デルの精度が最も高いという結果が得られた。しかし、1年を遡るモデルの結果を観察すると、水位変動については、概ね推定できていると考えられる。特に2017/12以降の水位減少の挙動を再現できているのは、1ヶ月モデルというよりは、寧ろ1年モデルであるようにも観察することができる。1年を遡るモデルを使用することの利点としては、モデルをシミュレーション道具として利用する場合に1年スケールでのシミュレーションが可能であるということである。例えば、今後1年間において、降雨がない状況を想定した場合のシミュレーションが可能ということになる。そのため、低水位時におけるモデル推定値のバイアス補正をすれば、利用価値があると考えられる。

広幅のべき乗関数の河道断面での水位と流量の関係は Eq. (10)のように近似できることが知られている (MLIT, c; 椎葉ら, 2013)。

$$Q = a(H + b)^2 \quad (10)$$

ここで Q は流量、 H は水位、 a 、 b は係数である。流量 Q は、水位 H の2次式で表されるため、流量が小さくなるほど、単位流量変化あたりの水位変化が大きくなる。観測値の HQ 曲線 (Figure 12) より、津野川観測所においても流量 Q と水位 H は同様の関係が成り立っていることを確認できる。このことから、流量が少ない低水位時には流量の変化に対する水位変化が急激であることがわかる。入力である雨量と直接関係するのは流量であるので、DNN は HQ 曲線のモデル化も暗に行っている。この HQ 曲線のモデル化が低水時は困難であることが示唆される。

低水時の水位予測に重要な要素として、蒸発量が挙げられる。Figure 11 においては、いずれの事例も観測値よりも過大評価となっており、遡り期間が1年の推定結果は、1ヶ月のものと比較して過大評価の度合いが増加している特徴が見られる。このことから考えられることとしては、通常であれば河道に流入していた長期スケールの流出が、蒸発によって取り除かれ、通常時よりも水位が低下していた可能性がある。過去に同量の降雨が観測されていた場合でも気温によって土壌水分量が変化し、それに伴い、河道への流量に違いが表れる。そのため、 HQ 曲線から、蒸発による水位への影響は低水位ほど無視できないことが考えられる。蒸発量またはそれに代わる新たな入力変数 (例えば気温) を導入しモデル化することで、更なる精度向上が見込まれる。

4.2.4. 雨量予測データがない場合の水位予測

雨量予測値が存在する場合、前述までの推定モデルにより、雨量データの精度に応じて、河川水位予測が可能である。しかしながら実際には、前の時刻の観測値の欠測により予測データを作成できない場合や雨量予測用の計算機が故障した場合、また、雨量の予報業務を行

っていない国等の状況下において雨量予測値を入手できない場合等、雨量予測が利用できない場合を想定することができる。そのような状況下では、ある程度の水位予測が可能なモデルで代替することで、防災の最善の策を打つことができる。そのため、雨量予測データが存在しない場合の河川水位予測可能性について検討することは有意義である。本セクションでは、将来の時刻において雨量データが存在しない場合における予測モデルを開発し、モデルの時間的外挿についての検討を行う。

これまでの推定モデルにおいては、雨量データの最新の時刻と同時刻の水位を教師データとして与えていたのに対して、この予測モデルにおいては、雨量データの最新の時刻から t 時間先の水位を教師データとして与える。モデルのアーキテクチャ、実験条件はこれまでと同様にし、予測モデルの学習を行った。学習済みモデルを用いて 4 大洪水事例に対して適用を行った結果を **Figure 13** に示す。各時刻からの予測値を赤線で示し、線の長さで予測時間の違いを示しており、始点は推定値、先端の予測値が 6 時間先の結果である。case1 については、いずれの予測値も観測値に近い値を示していることが観察できる。case4 はピーク前まで過小評価となっているが、推定値と概ね同程度であることから、推定時と遜色ない予測性能があることがわかる。case2 については、予測時間の延長とともに立ち上がりとピークのタイミングにずれが生じていることが見て取れる。case3 については、予測時間の延長にともない、非常に大きなずれが生じている。この理由としては、4. 2. 2 において示した空間的な降雨分布の特異性によると考えられる。case3 は他の洪水と比較して、下流部で大きな降雨の割合を占めていたため、降雨到達時間の短い地点の降雨による表面流出の寄与が大きかったためであると考えられる。そのため、降雨到達時間を超過する地点の降雨の割合が大きいため、著しく遅れが生じていると考えられる。これらの洪水時における各予測モデルの精度の比較を **Figure 14** に示す。規模の大きな case2~4 については、予測時間が 3 時間以内の場合は、概ね同程度であるが、4 時間以降においては差が大きくなっていくことが見て取れる。RMSE が 1.0(m) を基準とし、それを超える時間で比較すると、case2 が 7 時、case3 が 5 時、case4 が 7 時であることがわかった。この結果から、雨量予測データなしの水位予測において、下流部での降雨の割合が高い洪水については、予測時間の増加に伴う誤差の増加が大きいことがわかった。

5. 議論

5.1. 先行研究手法との比較

本セクションでは、入力データの違いに焦点を当て、モデル予測精度の比較と本研究の有効性を示す。本研究の提案手法と先行研究(Hitokoto et al., 2017)では入力データの種類と数が大きく異なる。先行研究では、入力データに 1)対象水位, 2)水位変化, 3)上流雨量の 3種類を用い、予測する時点からの水位変化を予測する。この手法を四万十川に適用し、再現実験を試みる。先行研究再現における入力、教師データを Table 4 の通りに設定した。水位データには津野川観測所の水位 h_i を設定し、水位変化データは 3 地点分(Figure 1, L_1~L_3)の $(h_{i+1} - h_i)/\Delta t$ 用意し、雨量データは、提案手法と同様に 13 地点分(Figure 1, R_01~R_13)を使用した。そして、教師データには、津野川観測所の水位変化 $(h_{i+f} - h_i)/(f\Delta t)$ を予測時間 f ごとに設定した。先行研究再現予測モデルを $H_t(t)$ (予測時間)とする。本節では、先行研究と同様に、対象期間中の上位 24 洪水を学習・検証用の対象データとする。

ここで、注意しなければならないのが、先行研究においては観測雨量を完全な予測データと仮定し、雨量予測値として使用していることである。Table 4 より明らかなように、水位データ、水位変化データについては、予測する時点の時刻を基準として、現時刻とそこから遡る数時間の値を用いる一方で、雨量データについては予測の対象となる時間 t の 1 時間前 $t-1$ までの値を使用している。例えば、6 時間予測を行う場合の入力データと出力データの関係は、Figure 15(H_6)のように図式化でき、雨量データの時刻は現時点から 1 から 5 時間先まで入力する。つまり、先行研究における t 時間予測モデルは、1 時間先の水位を予測するために、現時点から $t-1$ 時間だけ遡る雨量時系列と、 $t-t+2$ 時間遡る水位情報を用いた手法と捉えることができる。

第 3 章で本研究では、雨量時系列から現時刻の水位を推定した。ここでは、先行研究との比較のために、現時点から遡る雨量時系列を用いて、先行研究と同様に、1~6 時間先の水位変化を予測するモデル $P_{CL_t}(t)$ (予測時間)を構築する。例えば、6 時間予測を行う場合の入力と出力の関係は、Figure 15(P_{CL}_6)のように示される。H_6 との違いは、入力に水位情報が含まれていない点である。長期の雨量時系列は、水位情報の代替として使用されている。

さらに、教師として与えるデータが水位変化の場合と水位の場合でモデルの予測精度がどのように変化するかを検討する。第 3 章で構築した水位推定モデルの教師データに 1 時間先の水位を設定することにより、現時点から遡る雨量時系列を用いて、1 時間先水位予測モデル P_L を構築する。Figure 15(P_L)に入力と出力の関係を示す。ここでは、完全予測雨量データが存在するという仮定の下に検討を行っているため、予測水位の時刻と入力雨量の時刻の時間差を考慮すると、本研究の 1 時間先水位予測モデル P_L は、上記の t 時間先水位変化予測モデルと正味の予測時間は等しい。そのため、 P_L は t 時間先水位変化予測モデル全てと比較することができる。P_{CL}_6 との違いは、出力データが水位に変更されているこ

とがである。P_{CL,t}, P_Lは、いずれも推定時に得られた最適なハイパーパラメータの下、学習を行い、モデルを構築した。比較対象の洪水事例は 4.2 と同様のテスト用データにおける 4 大洪水とする。先行研究においては、テスト用データに対しての適用はなされていないが、本研究では、モデルの汎化性を確認するために導入する。

3 つの手法によるモデルの予測結果を Figure 16 に示す。H_tと P_{CL,t}を比較すると、立ち上がりについては、case1 では概ね同様であるが、case2~4 では P_{CL,t}のほうがより観測値に近い値を示していることが見て取れる。ピーク時刻前 2~3(hr)では、P_{CL,t}による 1~6 時間予測値は、概ね観測と一致している。この理由は、入力雨量に対する感度が P_{CL,t}の方が高いためであると考えられる。大きな水位変動が生じる立ち上がりでは、上流の水位情報よりも直近に降った雨による影響が大きいいため、雨量のみの入力によるモデルの方が予測精度が高くなると考えられる。次に、ピーク付近については、H_tによる推定結果が優れていることが見て取れる。ピーク付近では、雨量強度が小さくなり、水位情報がより支配的な要素となるため、H_tによる予測の方が優れていると判断できる。また、出力値である水位変化はピーク前からピーク後において徐々に小さくなり次第に負の値を取る。P_{CL,t}で予測できない理由として、水位差の正負が逆転することにより、雨量データとの関連性が小さくなることが考えられる。しかし、ピーク後数時間においては、先行研究と同程度の予測が可能であることも見て取れる。最後に、立ち下がりについても H_tによる推定結果が優れていることが見て取れる。立ち下がり水位変化においては、上流の水位情報がピーク付近よりもより支配的な要素となり、同様な推定結果の違いが見られる。

P_Lでは、その定義から予測時間に応じて予測結果が変化せず（最新の雨量データの 1 時間先の水位を推定するモデルであるので）、4.2 の推定結果と同様に、立ち上がり、ピーク、立ち下がりのいずれも概ね一致していることが見て取れる

H_t, P_{CL,t}, P_Lの各モデルにおける RMSE を Figure 17 に示す。RMSE は、4 洪水のピーク生起時刻の前後 24(hr)における平均値を示している。まず、H_tについて観察すると、水位情報が入力に含まれているにもかかわらず、予測時間の延長とともに精度が低下することがわかる。予測時間の延長により、将来の水位変化と過去の水位情報との直接的な関係が小さくなることにより、モデル化が困難になると考えられる。また、雨量のみを使用した P_{CL,t}による予測誤差は時間とともに直線的に増加していくことが観察できる。この理由は、雨量のみのデータは水位変化との関連性が小さいためであると考えられる。Hitokoto et al. は別の論文において、出力である水位変化(流量変化)は、貯留量変化と対応しているため、入力雨量を貯留量変化に置き換えることで精度の向上を行っている。そのため、雨量のみのデータは、予測時間の延長とともに水位変化との関連性がより小さくなり、誤差が増加すると考えられる。

上流水位変化を用いる H_tのほうが P_{CL,t}よりも、4~6 時間予測誤差を抑えることができることがわかった。H_tと P_{CL,t}の精度を比較する(Figure 17)と、case2~4 の大きな洪水に対する 1~3 時間先の予測においては概ね同様であるが、4~6 時間予測においては、H_t

の方が顕著に低くなる傾向が見られる。上流の水位変化は遅延を伴って下流へと伝搬されるため、 H_t の入力である上流の水位情報は、将来の対象地点の水位変化を予測する重要な要素であると考えられる。しかし、短時間先の予測においては、 P_{CL}_t は H_t と同様の精度で予測できることから、雨量のみのデータによって、水位情報を代替できることがわかった。上流域に水位観測所がない比較的小さな河川に対しては、 P_{CL}_t が有効である。

P_L の精度は case2~4 において、3 時間以降、 H_t を上回ることから、高精度の予測雨量データが存在していれば、雨量予測時間に応じて、水位情報を用いずに将来の水位を高精度に予測することが可能である。 P_{CL}_t と本研究手法の case2~4 における精度を比較 (Figure 17) すると、1 時間予測においては、 P_{CL}_t が上回るが、2 時間予測では概ね等しく、3~6 時間予測においては、 P_L が上回ることが見て取れる。2 時間先を分岐点とし、教師データとして水位を使うことが望ましいと判断できる。4 大洪水平均 RMSE の結果を見ても同様のことが言える。この理由は、2つ考えられる。1つ目は、誤差の取り得る範囲の違いによることと考えられる。短時間先の予測については、大きな洪水波形における水位変化量が小さいため、予測誤差が小さく抑えられる。しかし、予測時間の延長に伴って、水位変化量が大きくなり、予測誤差の取りうる範囲が大きくなることで、精度が低下することが考えられる。2つ目は、入力データと出力データの関連性の違いによることと考えられる。それぞれのモデルの入力データと出力データの関係について言及すると、水位は、雨量と物理的な対応関係があり、積算雨量とある程度の相関がある。一方で、前述した通り、水位変化は、雨量との直接的な対応関係が小さい物理量に相当する。そのため、予測時間の延長に伴い、貯留変化の影響が大きく現れることから、より長時間先の水位を予測する場合、水位変化ではなく、直接水位を予測することが望ましいと考えられる。

5.2. 可視化

深層学習モデルにより、複雑なプロセスに支配される水文過程を高精度で水位推定・予測可能であることを示したが、モデルの多層構造やパラメータの数の膨大さに起因して、入力と出力の関係性の解釈が難しいという課題が存在する。そこで解釈性を高める手法である Layer-wise Relevance Propagation(LRP)(Bach et al., 2015)を、提案手法モデル、先行研究再現モデルに適用する。LRP は、モデルの出力値について、入力要素がそれぞれの程度寄与しているのかを定量化することができる。出力層を第 ℓ 層目の O_j と定義すると、 O_j が初期の relevance となる。そして、 $\ell - 1$ 層の活性 z_j に対する各ユニットの入力と重みの内積 z_{ij} の割合を使用して入力の方角への relevance を計算する。Relevance を逆伝搬することによって、最終的に入力層へ情報を伝達し、入力次元数の relevance が得られる。この値が大きいほど、どの入力要素が出力値に寄与しているのかを定量的に評価できる。この手法により、水文 MLP モデルが洪水時において、どの入力要素を重要視しているのかを判断する

ことができる。本研究においては、13 地点分の時系列データを入力としているため、時間、空間的な特徴を分析することができる。地点間の降雨到達時間、雨量に対する感度の違い等の観点から、実際の物理過程と照らし合わせることによって、モデルが流域特性を考慮できているかについて考察する。さらに、5. 1 での比較において、先行研究再現手法が提案手法と比較して予測時間が延長した場合の精度が高いという結果が得られたため、先行研究再現モデルの入力要素の寄与度を定量化することにより、短時間先予測モデルと長時間先予測モデルの入力要素の寄与度にはどのような違いがあるかを分析する。

5.2.1. 長期雨量時系列を使用した提案手法モデル

本研究における LRP の概念図を Figure 18 に示す。上付きの数字は層番号、下付きの文字は各層におけるノードを示している。左図は入力→出力の順伝搬方向の情報の伝達を示しており、入力要素と重み係数の積 z_{xx} 、入力の重み付き和とバイアス項の和 z_x はそれぞれ Eq. (50), (51) (Bach et al., 2015) で定義される。右図は出力→入力の逆伝搬方向の情報の伝達を示しており、順伝搬ネットワークに対応する **relevance** が示されている。Relevance は Eq. (57), (58), (62) (Bach et al., 2015) より、下記の Eq. (10)~(14) を用い計算できる。Relevance の初期値には、順伝搬ネットワークの出力値そのものを設定する。その後、順伝搬方向における z_{xx} 、 z_x を使用して、結合された浅層方向のノードのそれぞれに対して逆伝搬方向の情報を計算する。順伝搬方向における活性化前の入力 z_x に対する浅層側の各ノードからの z_{xx} の割合を求め、深層側の各ノードの **relevance** に乗算する。あるノードの **Relevance** は、深層側の層からそのノードに繋がすべての結合について、前述の割合の和を取ったものである。この際、**Relevance** が消失、爆発するのを防ぐために係数 ε を導入する。適切な補正を与えるために、 ε は z_x の絶対値の約 1/100 程度の $\varepsilon = 10^{-6}$ に設定した。これらの計算を浅層側に向かって繰り返し行うことで、入力層の **Relevance** $R_d^{(1)}$ が求まる。

$$R_l^{(5)} = f(x), \quad l = 1 \quad (10)$$

$$R_k^{(4)} = \sum_{l=1}^1 \frac{z_{kl}}{z_l} R_l^{(5)}, \quad k \in \{1, \dots, 128\} \quad (11)$$

$$R_j^{(3)} = \sum_{k=1}^{128} \frac{z_{jk}}{z_k + \text{sign}(\varepsilon, z_k)} R_k^{(4)}, \quad j \in \{1, \dots, 128\} \quad (12)$$

$$R_i^{(2)} = \sum_{j=1}^{128} \frac{z_{ij}}{z_j + \text{sign}(\varepsilon, z_j)} R_j^{(3)}, i \in \{1, \dots, 512\} \quad (13)$$

$$R_d^{(1)} = \sum_{i=1}^{512} \frac{z_{di}}{z_i + \text{sign}(\varepsilon, z_i)} R_i^{(2)}, d \in \{1, \dots, 897\} \quad (14)$$

ここで $\text{sign}(\varepsilon, z_i)$ は、 ε の絶対値に z_i の符号を掛ける演算処理を表す。

提案水位推定モデルの可視化結果を **Figure 19** に示す。この図には、**case2** における入力要素、**relevance**、観測水位、推定水位の4つの情報の時間変化が **R_01**, **R_08**, **R_13** の3つの地点について示されている。入力要素については、各要素番号における時間と分解能の情報が **Table 5** の通りに対応している。3. 1節で述べた通り、実際には69要素を入力としているが、ここでは直近の降雨との関係进行分析するため、14要素までを対象とする。図の注意点としては、入力雨量値が時間とともに要素番号を移動していくことと、遡り時間とともに分解能が粗くなることので、過去に遡るほど情報が圧縮されていることある。例えば、時刻-9(hr)における **E_01** 要素の値は、同分解能の **E_02** における+1(hr)の雨量と同じ値であり、そして-3(hr)の時点でこの雨量は、2時間平均された **E_07** 要素の値に含まれていることが確認できる。

時刻-10(hr)頃から降り始めた大きな降雨群は時刻-4(hr)頃まで続き、この降雨情報は徐々に要素数が小さくなって後の時刻の入力の際の情報として残されている。このような時間-入力要素の雨量マトリックスを作成したのちに、各時刻の出力値に対する入力要素の **relevance** を計算した値が等高線で図に示されている。入力要素、**relevance** の関係を観察すると、**R_01** においては、時刻-10(hr)頃から降り始めた降雨群は、時刻-4(hr)付近の **E_07** において大きくなり始めていることがわかる。この時刻は、水位の立ち上がりに相当し、この降雨群は、立ち上がりに寄与し始めていることが観察できる。その後、時刻+4~+6(hr)付近の **E_08**, **E_09** において地点内で最大の値が表れていることが見て取れる。この結果から、地点 **R_01** における降雨到達時間は、寄与の最も大きい入力要素に対応する8~11時間程度であると推定できる。さらに、+7時間程度まで、降雨群情報に大きな寄与が存在しており、降雨群を追従するように等高線が広がりを持っているという特徴も見られる。この結果から、この地点の降雨が直接流だけでなく中間流などが空間的に複雑な広がりを持ち、時間とともに徐々に遷移していく過程を表現できていると推察できる。また、水位ピーク以降において、大きな **relevance** が表れていることから、水位の立ち上がりよりも立ち下がりに大きく寄与するという地点特性を得ることができたと考える。

次に、他の地点について、同様に観察を行うと、地点 **R_08** においては、時刻-4(hr)付近の **E_06** において **relevance** が大きくなり始め、+1(hr)の **E_08** において、地点内最大の値が表れている。この結果から、**R_08** においては、降雨到達時間は8~9時間程度であると推定できる。そして **R_08** は、水位ピーク付近において大きな寄与があるという地点特性を持

つことがわかる。R_01 と比較すると、降雨到達時間に明確な違いはないが、降雨が最も寄与する時刻が異なることがわかる。それに加えて、寄与する降雨の範囲が大きく異なっており、R_08 においては、等高線の幅が狭く、降雨群を追従するような振る舞いはない。つまり、洪水波形に対して寄与する降雨の時刻が限定的であると判断できる。

最後に、地点 R_13 について議論する。時刻-6(hr)付近の E_02 において、relevance が大きくなり始め、時刻-5(hr)の E_03、時刻 0(hr)の E_05 において、地点内最大の relevance が表れている。この結果から、R_13 においては、降雨到達時間が 2 時間程度であると推定できる。また、ピーク付近でも再び大きな relevance が存在することから、直接流に加えて中間流による降雨による寄与が存在する地点であることが考えられる。水位ピーク以前から大きな寄与のある地点であるため、立ち上がりから水位ピークにかけて寄与する地点であると判断できる。逆に、立ち下がりについては、ほとんど寄与しないという地点特性も表れている。このように、地点ごとに入力要素、relevance、水位を照らし合わせることで、寄与し始める時刻や寄与する時間的な広がりには違いが見られることがわかった。

さらに、ここまでの各地点に対しての分析結果から、降雨到達時間と水位観測所との距離の関係を考察する。Fig. 1 より、水位観測所と各雨量観測所の距離 d_{R_n} は $d_{R_{13}} < d_{R_{08}} < d_{R_{01}}$ であることがわかる。そして、relevance の分析による降雨到達時間 t_{R_n} は、 $t_{R_{13}} < t_{R_{08}} < t_{R_{01}}$ であるため、モデルによる降雨到達時間は水位観測所と雨量観測所の距離を反映していると考えられる。そのため、地点間の降雨到達時間において、実際の物理過程を再現するようなモデル化ができていない可能性を示すことができた。

各地点における雨量の総 relevance によると、モデルは、地点ごとに異なる流出過程の特性を考慮できていることがわかった。Figure 10. で洪水時の各地点の総雨量の割合を示したのと同様に、各地点の総 relevance の割合を Figure 20. に示す。各洪水ピーク生起時刻の前後 12(hr)の積算 relevance を計算し、[0, 1]の範囲で正規化した値の全地点の和に対する割合を示している。Figure 20. より、各地点の降雨の寄与度を定量的に比較することができる。R_01 を除いた上流から下流にいくにしたがって、値が大きくなっていく傾向があることが観察できる。Fig. 8 においては、雨量自体は、上流から下流にいくにしたがって、値が小さくなっているが、Figure 20 の結果では逆の傾向が見られる。この結果から、観測された雨量が大きいのは上流域であるが、モデルが水位推定において重要視しているのは下流域の降雨であることがわかる。

さらに、R_05、R_06 付近において、最小の relevance の値が得られた理由は、ダムの影響であると推察することができる。Figure 1 より、四万十川の支川域にある雨量観測所 R_05、R_06 は、ダムの集水域に位置していることが確認できる。そのため、これらの地域で観測された降雨は、本流との合流点へ流れ出る前に 2 つのダムによって、貯水等の人為的な操作が行われた可能性がある。これが起因して、モデル化するのに雨量そのものとの関連性が小さい地点であるとモデルが判断していると考えられる。この結果から、人為的なダムの操作の可能性がある集水域の雨量については、モデル構築の際に特別な調整をせず

とも、訓練時の重み調整によって自動的に排除できていることが考えられる。

統計的モデリングは、説明変数と目的変数の関係を直接的に結び付けるため、モデル内では、人為的に物理過程を考慮しない。それにもかかわらず、提案手法によるモデリングにおいては、各地点の(1)降雨到達時間について、(2)寄与度の大きさについて、物理過程を考慮できている点が存在することが明らかとなった。可視化技術を用いることにより、モデル出力の精度だけでなく、解釈性を高めることで防災ツールとしての信頼性を高めることができると考える。

5.2.2. 水位情報を使用した先行研究手法モデル

ここでは先行研究再現モデルについて LRP を適用した結果を議論する。5.1で4~6時間先予測において、先行研究再現モデル H_t が提案手法 $P_{CL,t}$ と比較して、精度が高いことがわかった。その理由を入力要素の寄与度の定量化により明らかにすることを目指す。 H_t では、入力要素に 1)対象水位、2)上流水位変化、3)雨量の3種類の異なるデータを使用していた。そのため可視化することにより、1)どの入力要素がモデル化において重要視されているか、2)予測時間によって入力要素の寄与度の分布にどのような違いがあるか、を議論し、モデルの解釈性の向上を試みる。これらの手法による予測精度の違いは、特に、水位の立ち上がり~ピークにおいて、顕著に表れていたため、洪水波形のピークまでを **relevance** 計算の対象時刻とする。

case4 の洪水に対して、1時間予測モデルと6時間予測モデルに LRP を適用した結果を Figure 21 に示す。図は、ピーク生起時刻-12(hr)~ピーク生起時刻の水位上昇期間における各入力要素の **relevance** の平均値を示している。左から、水位(L)、水位変化(CL)、雨量(R)の順に全76入力要素が並べられている。横軸の括弧内は、時刻を表しており、例えば、L(0)は、0時の水位を意味している。各要素は時刻順に並べられている。入力要素記号の地点は、Figure 1, Table 4 と対応している。まず、1時間予測モデル H_1 の結果を観察すると、0時における対象水位変化 $CL_3(0)$ で最大の **relevance** が表れている。0時の水位変化と出力である1時の水位変化の間には、時間差が短く、ある程度相関があるため、出力に大きく寄与していると考えられる。他の要素と比較して突出しており、このモデルにおいて、支配的で重要な要素であると判断することができる。一方で、 H_6 の結果を観察すると、最大の **relevance** は、0時における上流水位変化 $CL_2(0)$ で現れている。他の水位情報については、 $CL_2(-1)$ 、 $CL_2(-2)$ 、 $CL_1(0)$ においても比較的大きな **relevance** の値であることが見て取れる。さらに、雨量データについては、いくつかの要素において比較的大きな **relevance** が表れていることを確認できる。

H_6 を H_1 と比較すると、2つの大きな違いがある。1つ目は、水位情報の寄与度の大きな地点が異なるということである。 H_1 で大きな寄与が見られた対象水位 CL_3 は、 H_6

においてほとんど寄与度がなく、上流側のデータである水位変化 CL_1, CL_2 のデータに寄与度が移動していると見ることができる。予測時間が延長するほど、将来の対象水位変化と過去の対象水位情報との関連性は小さくなっていくため、下流へ伝搬されるまでに遅滞時間が生じる上流の水位情報は、6時間先の対象水位変化を予測する際に重要な要素であると考えられる。そのため、上流の水位情報の相対的な寄与度が増加したと考えられる。2つ目は、雨量データの寄与度が増加している点が存在するということである。複数の雨量要素において、他の水位情報と同程度の高い **relevance** が表れていることを観察できる。予測時間が延長するほど、上流の水位情報の遅滞時間を超過する可能性や降雨-流出の過程による寄与がモデル化に重要となる。そのため、雨量予測データは、 t 時よりも先に到達する流出の寄与を補うために重要な要素となる。したがって、6時間先予測モデルは、1時間先予測モデルと比較して、雨量データの寄与度が増加したと考えることができる。

6. まとめと今後の展望

本研究では、長期雨量時系列データを入力とし、河川水位の実時間推定と1時間予測を行う深層MLPモデルを提案・構築した。日本において比較的ダムが本流にない四万十川に適用し、その性能を議論した後、特徴を把握するための可視化を行った。以下が主な結果である。

■入力雨量時系列の最適な遡り期間の検討

・検証用データに対する精度の比較

対象地点の水位を推定するのに最適な雨量時系列の遡り期間を検討したところ、検証データに対して、期間を遡るごとに誤差が低減し、最終的に1年を遡るモデルが最適であると判断した。水位高における精度の違いを検討したところ、20~100パーセンタイル間においては、1年を遡るモデルが最適であった。このことから長期の雨量時系列を入力にすることで地下水等の長期の流出の寄与をモデル化できたと考えられる。

・テスト用データに対する推定結果の比較

1日、1週間、1ヶ月、1年の4通りの遡り期間のモデルをテスト用データに対して適用したところ、遡り期間を延長することにより高水位、低水位ともに相関係数1の直線に近づき、外れ値が小さくなることがわかった。また、洪水時に対しては、遡り期間を延長することにより誤差とモデル推定値の不確実性が低減した。

■最適な入力雨量遡り期間のモデルによる推定・予測

・4大洪水事例の推定

2017~2018年の4大洪水事例について、1年を遡るモデルによって、立ち上がり、ピーク、立ち下がりのいずれも良好に推定できた。水位変動の大小で洪水事例を分割し、互いのパターンと比較すると、水位変動が小さい洪水はピーク精度がより高く、水位変動が大きい洪水は波形全体の精度がより高いという特徴が見られた。波形全体の精度とピーク精度にはトレードオフの関係が成り立っていることがわかった。また、ピーク時間誤差は、±1時間以内に収まっていた。本研究においては、入力データの最小の分解能であるが、さらに分解能の高い10分データ等を使用することでこのピーク誤差については1時間以内に抑えることができるポテンシャルを有している。

・外挿性の検討

テストデータには、学習時を超える短時間雨量が3洪水事例において観測されており、case2については、3、6時間積算雨量において34~35%超過していたため、提案手法モデルには外挿可能性があることを確認できた。また、水位ピーク付近の全地点に対する各地点の雨量

が占める割合を分析したところ、case3は訓練用データや他のテスト事例と比較して、下流部での割合が大きいことがわかった。

- ・ 渇水事例の推定

低水位期に対しての推定結果を観察したところ、期間を1ヶ月に延長することにより、滑らかに水位変動を表現できることがわかった。1年を遡るモデルは、観測水位よりも過大評価であったが、水位変動については概ね推定できていることから、バイアス補正すれば利用価値があると考えられる。長期間遡ることによって過大評価の割合が増加することから入力変数に蒸発量を加えることで改善の可能性があるが、流量と水位の2次関係から低水位ほどよりその影響が大きいと考えられる。

- ・ 雨量データがない場合の水位予測

雨量予測データが存在しない場合の河川水位予測可能性について検討したところ、洪水のパターンによって精度に違いが見られ、case3については予測時間の延長によって直ちに精度の低下した。case3は他の洪水と比較して、下流部で大きな降雨の割合を占めていたため、降雨到達時間の短い地点の降雨による表面流出の寄与が大きかったためであると考えられる。

○ 議論

提案手法と先行研究手法を比較したところ、4~6時間先水位変化予測モデルでは、先行研究再現モデルの精度が上回っていたが、1~3時間先水位変化予測では、精度に明確な違いはなく、雨量のみの入力でも水位情報を代替できることが示された。また、教師データ(水位と水位変化)の違いが精度へ及ぼす影響を比較したところ、水位の場合は、予測時間が延長するにつれて、水位変化の場合よりも精度が高くなることがわかった。さらに、先行研究再現手法の精度を上回ることも確認できた。雨量の予測可能時間の延長に伴って、水位の予測可能時間も延長するという本手法の利点を示した。

LRPを利用して、提案手法モデルと先行研究再現手法モデルについて、入力素子の各時刻の推定値への寄与度を可視化した。提案手法モデルの場合には、雨量観測所によって、洪水到達時間や寄与する時間的な広がりには違いが見られ、実際の水位観測所との距離を反映していた。また、各地点の総relevanceを分析したところ、上流から下流に向けて寄与度が大きくなり、流出過程の物理的解釈に対応することがわかった。一方、先行研究再現手法の場合、1時間先予測モデルでは対象水位変化の寄与度が大きい、予測時間が長くなると、上流の水位情報、雨量の寄与度が相対的に大きくなることがわかった。これは予測時間延長には長期雨量時系列の入力が有効であることを示唆する。この可視化を常時行うことでDNNモデルの信頼性を高めることが可能であると考えられる。

長期雨量データのみによるモデル化手法は、突発的な降雨による急激な水位上昇におけ

る外挿可能性を高めると考えられる。その理由は、水位の物理的な原因である雨量のみを入力データとして使用しているためであると考えられる。通常、水位などの時系列データは、前の時刻のデータに大きく支配されている自己相関の強いデータであるため、前時刻の目的変数を入力とした ANN モデルの開発を行う例がある (Garcia-Bartual et al., 2002; Campolo et al., 2003; Bustami et al., 2007; Kuok et al., 2010; Hitokoto et al., 2017; Oluwatobi et al., 2018)。しかし、目的変数との過度な依存関係により、急激な降雨時においては、雨量データに対しての感度が鈍くなっている可能性が考えられる。本研究では、可視化手法を用いて、入力的水位データに対して大きな重み係数が与えられ、雨量データに対する重み係数が相対的に小さくなり、結果として、水位データに大きく支配されることを示した。

また、外挿性の検討において、河川水位モデル化における推定精度は、単純に流域全体の入力データ、出力データの値の大小ではなく、地点間における空間的な降雨パターンの特異性による影響が大きく現れることがわかった。つまり、想定外の流域全体の雨量よりも特異性の高い地点間の降雨パターンの方が圧倒的に推定の難易度が上がることが考えられる。そのため、学習の際には、できるだけ多くの空間的な降雨パターンを学習することが重要であると考えられる。そのため、モデル化の対象とする流域の雨量、水位データの観測期間についての検討も実運用化する際には考慮しなければならない。

本研究で提案した DNN モデルは学習済みモデルであれば、スマートフォンアプリケーションソフトとして実装可能と考えられる。このような高精度の簡易モデルは、自治体や住民らが避難の判断を行うための有効なツールになり得る。今後は、(1)より詳細にモデル出力の解釈性を高めること、(2)雨量予測データを活用した数時間先の予測、(3)CNN, RNN 等の他の深層学習手法を適用すること、(4)流域内の他の地点における水位を同時に推定することによって流域の特性を解明することに取り組む予定である。

7. 謝辞

本研究を行うにあたり，終始熱心な助言，ご指導を頂いた指導教官の高知工科大学環境理工学群端野典平准教授，同大学中根英昭名誉教授に感謝の意を表します。

高知工科大学環境理工学群古沢浩教授，柴田清孝教授，百田佐多生准教授，全卓樹教授，渡辺伸一講師には，セミナー等において貴重な助言を頂いたことに感謝致します。

日本工営株式会社先端研究開発センターの一言博士との有益な議論に感謝致します。

流域内のデータを管理・公開して頂いた国土交通省，気象庁，ならびに詳細なデータを提供して頂いた高知県土木部河川課に感謝致します。

本研究を進めるにあたり，多くの示唆を頂き，研究室生活を有意義なものにしてくださった端野研究室のメンバーに深く感謝申し上げます。

8. 参考文献

- Adhikary, S. K., Muttill, N., Yilma, A. G., 2018. Improving streamflow forecast using optimal rain gauge network-based input to artificial neural network models. *Hydrology Research*. 49, 5.
- Akhtar, M. K., Corzo, G. A., An del, S. J. van., Jonoski, A., 2009. River flow forecasting with artificial neural networks using satellite observed precipitation pre-processed with flow length and travel time information: case study of the Ganges river basin. *Hydrol. Earth Syst. Sci.* 13, 1607–1618.
- Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, KR., Samek, W., 2015. On Pixel-Wise Explanations for Non-Linear Classifier Decisions by Layer-Wise Relevance Propagation. *PLoS ONE*, 10, (7), e0130140.
- Bai, Y., Chen, Z., Xie, J., Li, C., 2016. Daily reservoir inflow forecasting using multiscale deep feature learning with hybrid models. *Journal of Hydrology*. 532, 193–206.
- Bazartseren, B., Hildebrandt, G., Holz, K. P., 2003. Short-term water level prediction using neural networks and neuro-fuzzy approach. *Neuro computing*. 55, 439–450.
- Bustami, B., Bessaih, N., Bong, C., Suhaili, S., 2007. Artificial Neural Network for Precipitation and Water Level Predictions of Bedup River. *IAENG International Journal of Computer Science*. 34:2, IJCS_34_2_10.
- Cabinet Office, 2018. Flood and Sediment Disaster. Cabinet Office HP, English Home, Policies, Disaster Management, Reports and Brochures. http://www.bousai.go.jp/kyoiku/pdf/h30_tebikisho_english.pdf.
- Campolo, M., Soldati, A., Andreussi, P., 2003. Artificial neural network approach to flood forecasting in the River Arno. *Hydrological Sciences Journal*. 48, 3, 381–398.
- Chanu, S. N., Kumar, P., 2018. Modelling of Daily Rainfall-Runoff Using Multi-Layer Perceptron Based Artificial Neural Network and Multi-Linear Regression Techniques in A Himalayan Watershed. *Indian Journal of Hill Farming*. 31, 1, 166-176.
- Cheng, C., Chau, K., Sun, YG., Lin, JY., 2005. Long-Term Prediction of Discharges in Manwan Reservoir using Artificial Neural Network Models. *Lecture Notes in Computer Science*. 3498, 1040-1045.
- Chen, S. M., Wang, Y. M., Tsou, I., 2013. Using artificial neural network approach for modelling rainfall–runoff due to typhoon. *Journal of Earth System Science*. 122,

- 2, 399–405.
- Coulibaly, P., Anctil, F., Aravena, R., Bobée, B., 2001. Artificial neural network modeling of water table depth fluctuations. *WATER RESOURCES RESEARCH*. 37, 4, 885-896.
- Daliakopoulos, I. N., Tsanis, I. K., 2016. Comparison of an artificial neural network and a conceptual rainfall–runoff model in the simulation of ephemeral streamflow. *Hydrological Sciences Journal*. 61, 15, 2763-2774.
- Darbandi, S., Pourhosseini, F. A., 2018. River flow simulation using a multilayer perceptron–firefly algorithm model. *Applied Water Science*. 8, 85.
- Dozat, Timothy., 2016. INCORPORATING NESTEROV MOMENTUM INTO ADAM. ICLR 2016 workshop paper. 107, reviewer 10.
- El-shafie, A., Mukhlisin, M., Najah, A. A., Taha, M. R., 2011. Performance of artificial neural network and regression techniques for rainfall-runoff prediction. *International Journal of the Physical Sciences*. 6, 8, 1997-2003.
- García-Bartual, R., 2002. Short term river flood forecasting with neural networks. *Universidad Politecnica de Valencia, Spain*, 160-165.
- Gorr, W. L., Nagin, D., Szczypula, J., 1994. Comparative study of artificial neural network and statistical models for predicting student grade point averages. *International Journal of Forecasting*. 10, 17-34.
- Hitokoto, M., Sakuraba, M., Sei, Y., 2017. DEVELOPMENT OF THE REAL-TIME RIVER STAGE PREDICTION METHOD USING DEEP LEARNING. *Journal of JSCE*. 5, 422-429.
- ICHARM, 2019. Recurrent Water-related Disasters in Japan. http://www.icharm.pwri.go.jp/special_topic/20190220_3rd_plenarysession_PWRD/All%20PPT%20for%20Distribution.pdf.
- IPCC, 2014. AR5 Synthesis Report: Climate Change 2014.
- JMA, 2019. Very-short-range Forecasts of Precipitation and Nowcasts Services. Forecasting Services, JMA HP, Home, Weather Forecasts. <https://www.jma.go.jp/jma/en/Activities/forecast.html>
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., Herrnegger, M., 2018. Rainfall-runoff modelling using Long Short-Term Memory(LSTM) networks. *Hydrol. Earth Syst. Sci*. 22, 6005-6022
- Kuok, K. K., Harun, S., Shamsuddin, S. M., 2010. Particle swarm optimization feedforward neural network for modeling runoff. *Int. J. Environ. Sci. Tech*. 7, 1, 67 -78.

- K. Simonyan, A. Vedaldi, and A. Zisserman, “Deep inside convolutional networks: Visualising image classification models and saliency maps, ” in ICLR Workshop, 2014.
- MLIT, 2019. Geography. MLIT HP, HOME, English, I . Land and Climate of Japan, 1. The Land and the People. https://www.mlit.go.jp/river/basic_info/english/land.html
- MLIT, a. 流域の概要. 国土交通省近畿地方 HP, 政策・仕事, 水管理・国土保全, 河川, 河川整備基本方針・河川整備計画, 河川整備計画, 渡川水系, 基本高水等 1 に関する資料, 1. 流域の概要.. https://www.mlit.go.jp/river/basic_info/jigyo_keikaku/gaiyou/seibi/pdf/watarigawa89-2.pdf
- MLIT, b. 正確な洪水流量ハイドログラフを作ること. 国土交通省近畿地方 HP, 河川, 川の特性や本質を読み取る～淀川水系の流出解析モデルの技術的検討について～. https://www.kkr.mlit.go.jp/river/iinkaikatsudou/yodo_sui/qgl8vl0000007liv-att/100118siryou5.pdf
- MLIT, c. 国土交通省水管理・国土保全局, 河川砂防技術基準 調査編, 平成 24 年 6 月. 第 2 章 第 4 節 p . 29 , 式 2-4-3) . http://www.mlit.go.jp/river/shishin_guideline/gijutsu/gijutsukijunn/chousa/index.html
- MOE. 415 Sea of Japan, Tsushima Current waters. MOE home, Nature and Parks, EBSA home, Offshore Surface.
- Maas, A. L., Hannun, A. Y., Ng, A. Y., 2013. Rectifier Nonlinearities Improve Neural Network Acoustic Models. Stanford University, CA 94305 USA.
- M. D. Zeiler and R. Fergus, “Visualizing and understanding convolutional networks, ” in ECCV, 2014, pp. 818–833.
- NHK, 2019. Typhoon Hagibis aftermath. NHK WORLD-JAPAN, Typhoon Hagibis.
- Nakane, H., Wakatsuki, Y., 2018. Startup of Deep Learning Application to Environmental Research. Kochi University of Technology research bulletin. 15, 1, 111-120. <http://hdl.handle.net/10173/1949>
- Nakane, H., Wakatsuki, Y., Yamamoto, K., Takeda, T., Hashino, T., 2019. Application of Deep Learning to River Disaster Prevention and Environmental Conservation - on the Shimanto River and Kagami River Water Levels, and the Ohdo Dam Inflow of the Niyodo River -. Kochi University of Technology research bulletin. 16, 1, 227-244. <http://hdl.handle.net/10173/00002125>
- Nash JE., Sutcliffe JV., 1970. River flow forecasting through conceptual models. Part I: a discussion of principles. Journal of Hydrology. 10, 282–290.
- OECD, 2015. Climate Change Risks and Adaptation: Linking Policy and Economics, OECD Publishing, Paris. <http://dx.doi.org/10.1787/9789264234611-en>.

- Oluwatobi, A. , Gbenga, O. , Joy, A. , Oluwole, A. , 2018. MODELING AND SIMULATION OF RIVER DISCHARGE USING ARTIFICIAL NEURAL NETWORKS. *Journal of Science*. 20, 2, 362-370.
- Rao, G. S. , Giridhar, M. V. S. S. , 2016. Daily Runoff Forecasting using Artificial Neural Network. *International Journal of Scientific & Engineering Research*. 7, 6, 478-484.
- Rumelhart, D. E. , Hinton, G. E. , Williams, R. J. , 1986. Learning internal representation by error propagation. In D. E. Rumelhart & J. L. McClelland(Eds.). *Parallel distributed processing: Explorations in the microstructure of cognition*(Vol. 1, pp. 318–362). Cambridge, MA: MIT Press.
- Samek, W. , Binder, A. , Montavon, G. , Lapuschkin, S. , Müller, KR. , 2017. Evaluating the visualization of what a Deep Neural Network has learned . *IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS*, 28, 11. 2660-2673.
- SCJ. 日本学術会議：回答，河川流出モデル・基本高水の検証に関する学術的な評価－公開説明（質疑）－， p. 10，平成23年9月28日。
- Shen, C. , 2018. A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*. 561, 918-929.
- The Japan Times, 2019. At least 35 killed and 17 missing after Typhoon Hagibis tears through country, flooding rivers and submerging cities. <https://www.japantimes.co.jp/news/2019/10/13/national/typhoon-hagibis-japan-tokyo/#.XdjKFuj7SUn>
- Yaseen, Z. M. , El-Shafie, A. , Afan, H. A. , Hameed, M. , Mohtar, W. , Hussain, A. , 2016. RBFNN versus FFNN for daily river flow forecasting at Johor River, Malaysia. *Neural Computing and Applications*. 27, 6, 1533-1542.
- Zhang, J. , Zhu, J. , Zhang, X. , Ye, M. , Yang, J. , 2018. Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas. *Journal of Hydrology*. 561, 918–929.
- 椎葉充晴，立川康人，市川温，2013。「水文学、水工計画学」，京都大学学術出版会。111.

9. 図

List of Figures

Figure 1 渡川流域の位置図. 雨量観測所, 水位観測所, ダム, 堰を示す. 青線: 四万十川 (本流).	35
Figure 2 2008~2018 の観測データ. (a)津野川観測所の水位, (b)13 地点の平均雨量. 紫がはん濫危険水位, 赤が避難判断水位, 橙がはん濫注意水位, 黄が水防団待機水位を示す.	36
Figure 3 各遡り期間における(a)最大分解能, (b)圧縮された入力要素数.....	36
Figure 4 全結合 MLP の模式図.....	37
Figure 5 各遡り期間における検証用データ(2016 年)の RMSE.	37
Figure 6 テストデータにおける観測値とモデル推定値の散布図.....	38
Figure 7 洪水時における各遡り期間の水位推定.....	38
Figure 8 テストデータにおける 4 大洪水事例についての推定結果. それぞれの洪水波形のピーク生起時刻の前後 48(hr). 白: 観測値, 赤: モデル推定値, 青: 13 地点平均観測雨量.	39
Figure 9 洪水ピークにおける(a)1 時間雨量の最大値, (b)3 時間雨量の最大値, (c)6 時間雨量の最大値. 青: 訓練用データの上位 12 洪水ピーク, 橙: テストデータの 4 大洪水. .	40
Figure 10 洪水における積算雨量の各地点の雨量の割合. 訓練データ: 上位 12 洪水の箱ひげ図.	40
Figure 11 渇水期(2017/11/1~2018/1/1)について各遡り期間の推定結果の違い.....	41
Figure 12 津野川観測所における HQ 曲線.	41
Figure 13 4 大洪水に対する推定値と 1~6 時間先の予測結果. 赤線は, 各時刻からの推定・予測値を示しており, 先端が 6 時間予測値を表している. 赤線が観測値をなぞるほど予測できていることを示す.	42
Figure 14 4 大洪水に対する推定値と 1~9 時間予測の RMSE. 図 OO の期間中の RMSE の値を示している.	43
Figure 15 先行研究手法, 比較用手法, 本研究手法における入力データの比較. H_6: 先行研究再現 6 時間先予測モデル, PCL_6: 比較用手法 6 時間先水位変化予測モデル, PL: 本研究手法 1 時間先水位高予測モデル. 使用する入力雨量データの最新時刻がいずれの手法においても等しいことを示している. 予測水位変化または水位高の 1 時間前までの情報が使用されている.	43
Figure 16 先行研究手法 H_t, 比較用手法 PCL_t, 本研究手法 PL の 4 大洪水における予測結果.	44

Figure 17 先行研究再現モデル H_t , 比較用手法モデル $P_{CL,t}$, 本研究手法 1 時間先予測モデル P_L , の各予測時間における 4 大洪水に対する平均 RMSE.	45
Figure 18 本研究の全結合多層パーセプトロンモデルにおける LRP の概念図. 左図: 順伝搬, 右図: 逆伝搬.	46
Figure 19 提案水位推定モデルによる洪水における各時刻の入力データ(color map), 各要素における relevance score(contour map), 観測水位, 推定水位. 上図: R_01, 中図: R_08, 下図: R_13. 寄与度の高い領域の入力要素番号(過去の降雨)から降雨到達時間を示す. .	48
Figure 20 洪水における各地点の積算 relevance の割合.	49
Figure 21 case4 における先行研究再現モデルの各入力要素の relevance. 上: H_1, 下: H_6. case4 の洪水ピーク生起時刻-12(hr)~洪水ピーク生起時刻の水位上昇期間の平均 relevance. 入力要素は, Figure 1, Table 4 を参照.	49

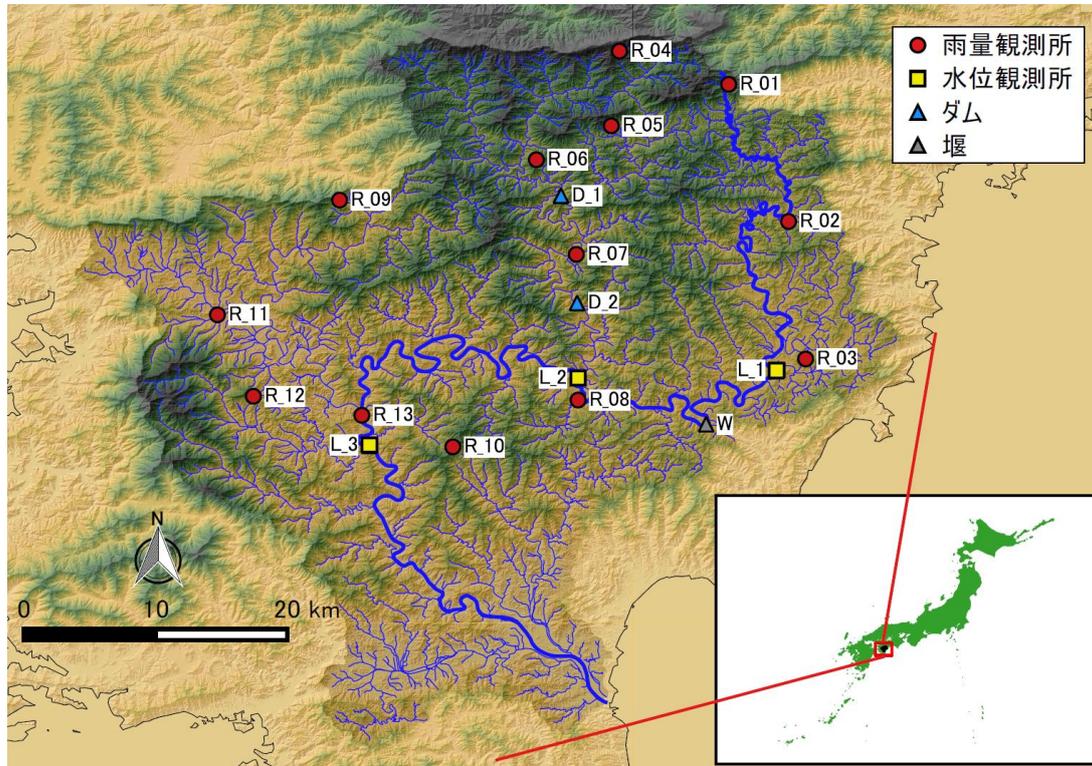


Figure 1 渡川流域の位置図. 雨量観測所, 水位観測所, ダム, 堰を示す. 青線: 四万十川 (本流).

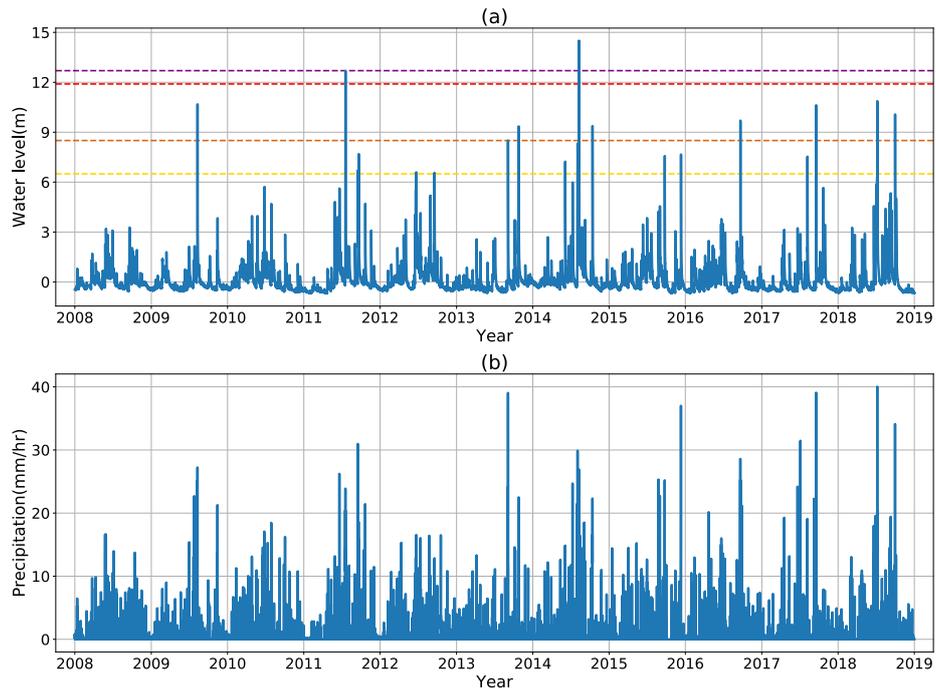


Figure 2 2008~2018 の観測データ. (a)津野川観測所の水位, (b)13 地点の平均雨量. 紫がはん濫危険水位, 赤が避難判断水位, 橙がはん濫注意水位, 黄が水防団待機水位を示す.

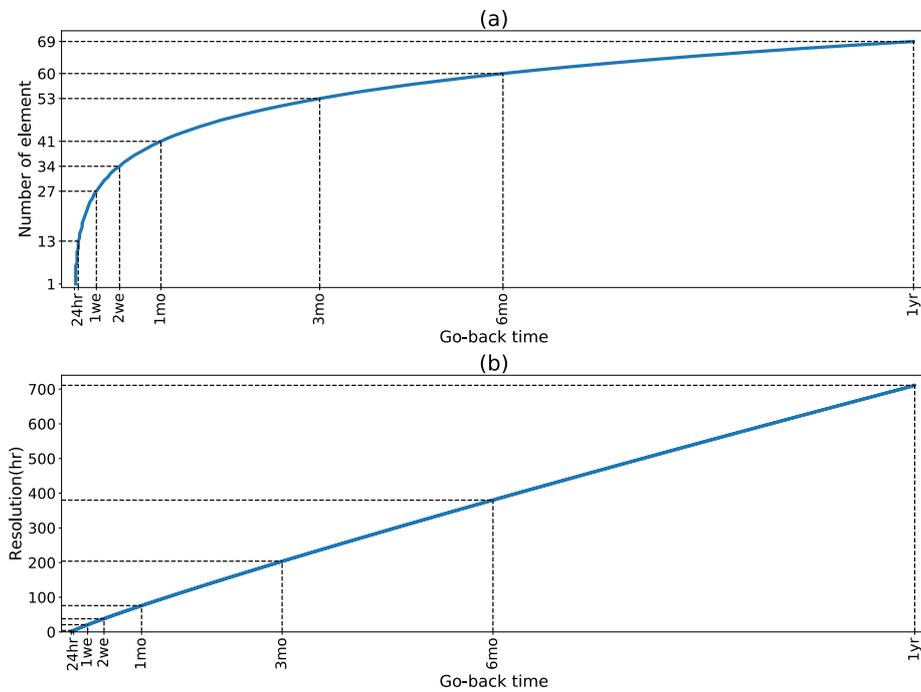


Figure 3 各遡り期間における(a)最大分解能, (b)圧縮された入力要素数

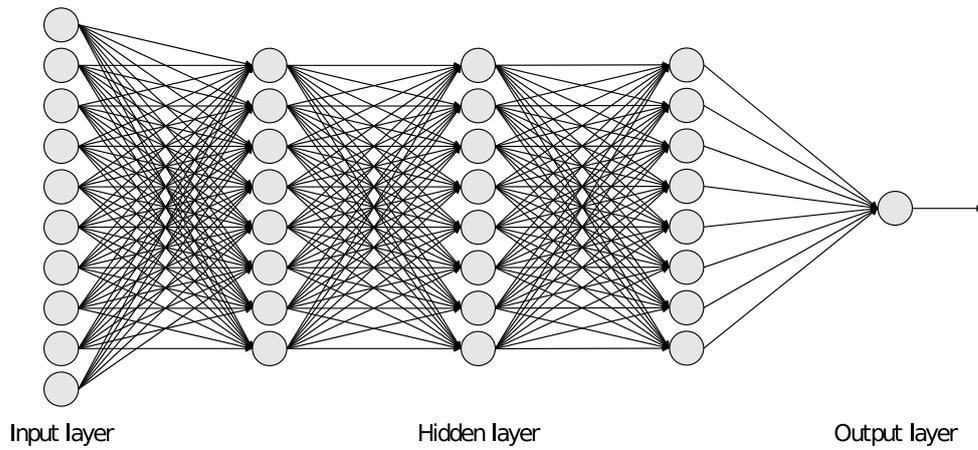


Figure 4 全結合 MLP の模式図

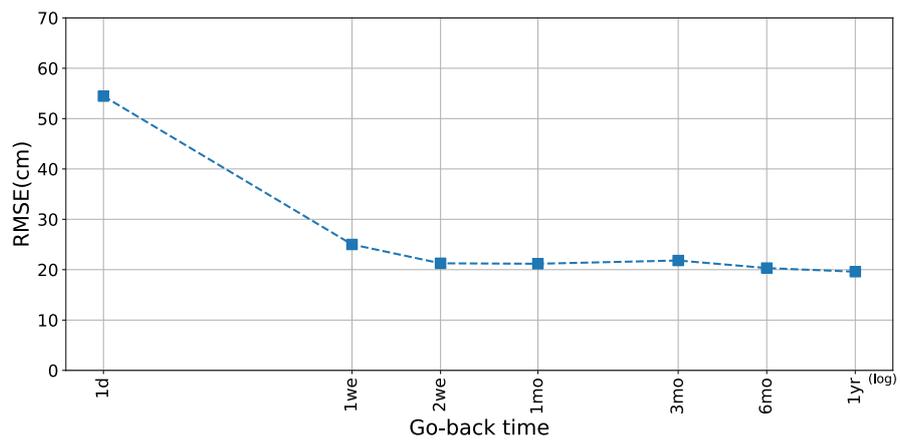


Figure 5 各遡り期間における検証用データ(2016年)の RMSE.

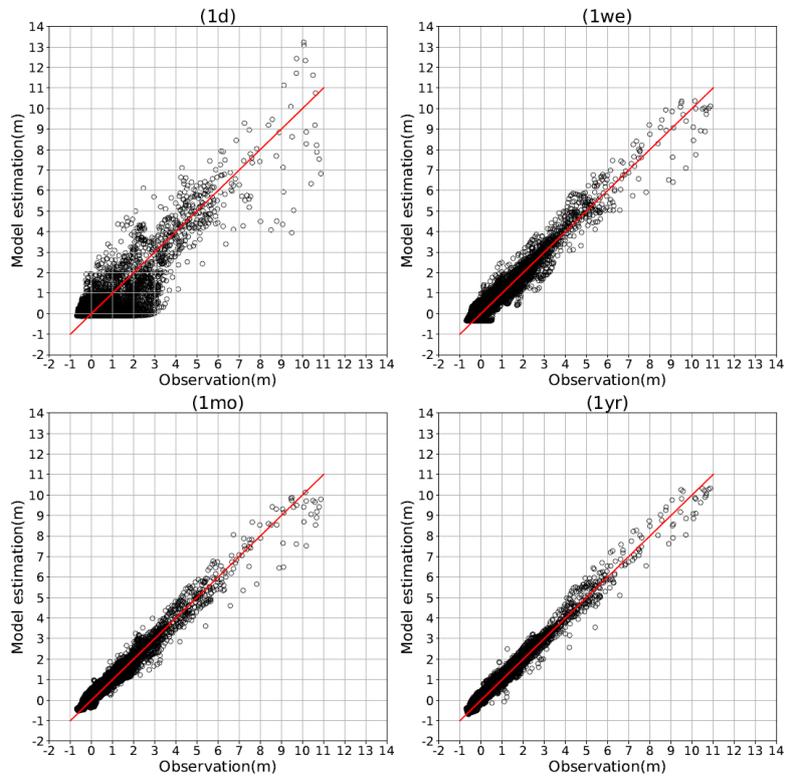


Figure 6 テストデータにおける観測値とモデル推定値の散布図

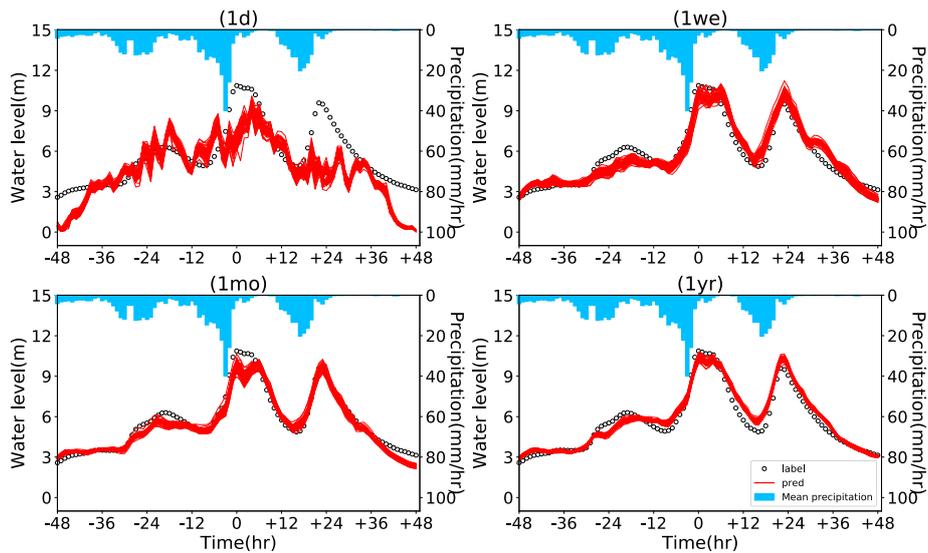


Figure 7 洪水時における各遡り期間の水位推定

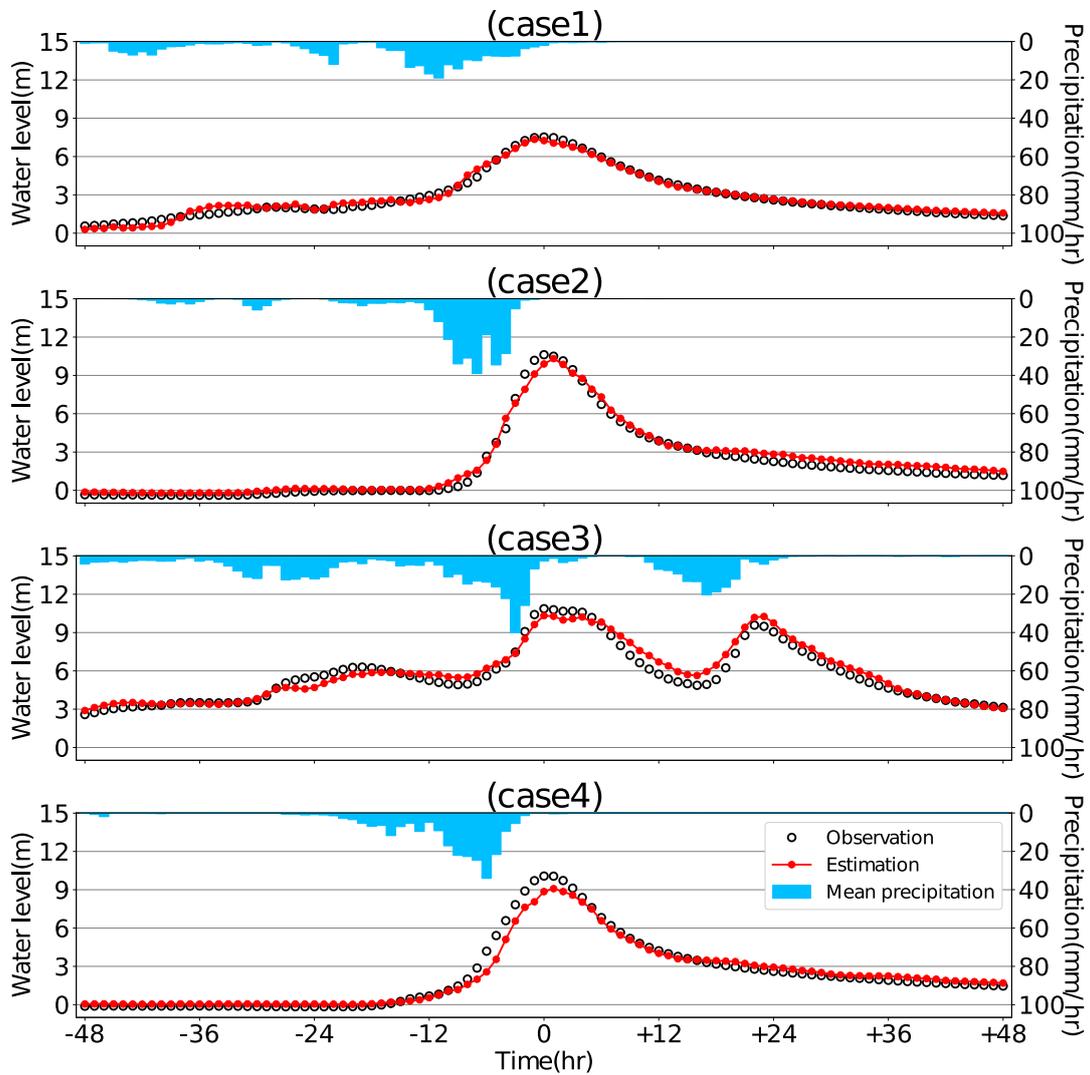


Figure 8 テストデータにおける 4 大洪水事例についての推定結果. それぞれの洪水波形のピーク生起時刻の前後 48(hr). 白: 観測値, 赤: モデル推定値, 青: 13 地点平均観測雨量.

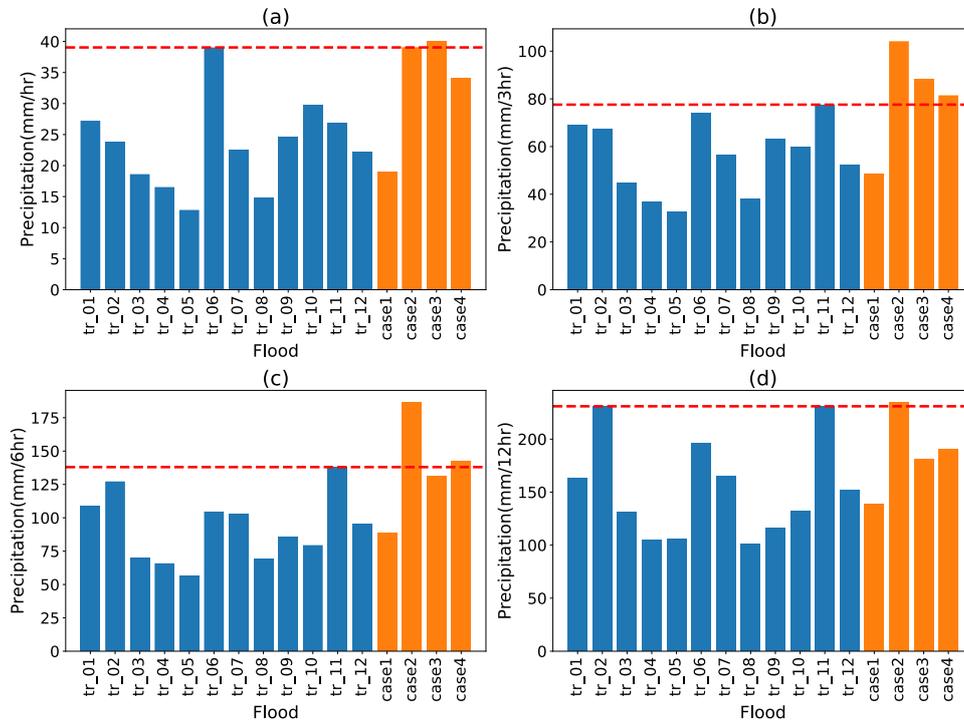


Figure 9 洪水ピークにおける(a)1時間雨量の最大値, (b)3時間雨量の最大値, (c)6時間雨量の最大値. 青: 訓練用データの上位12洪水ピーク, 橙: テストデータの4大洪水.

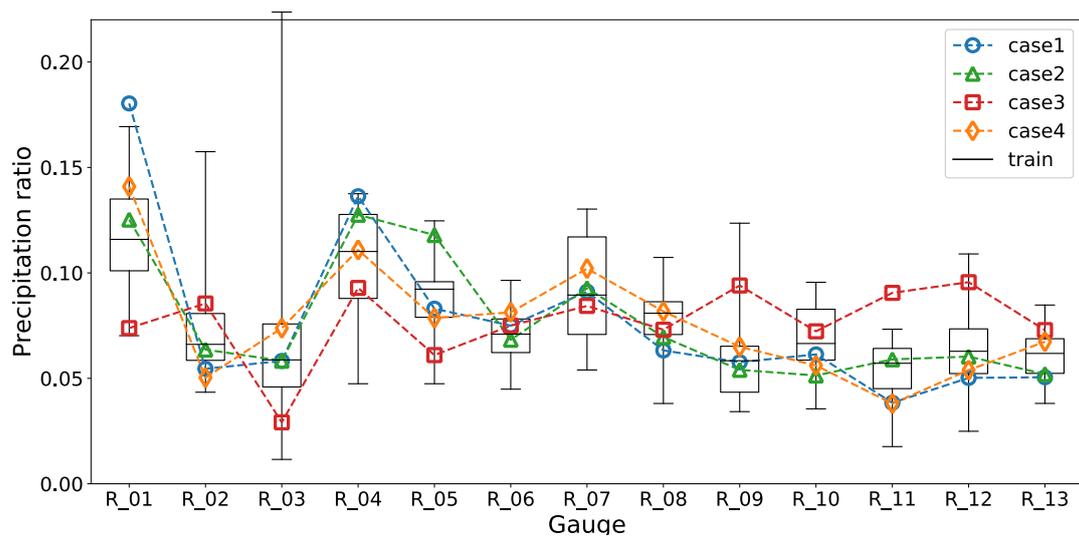


Figure 10 洪水における積算雨量の各地点の雨量の割合. 訓練データ: 上位12洪水の箱ひげ図.

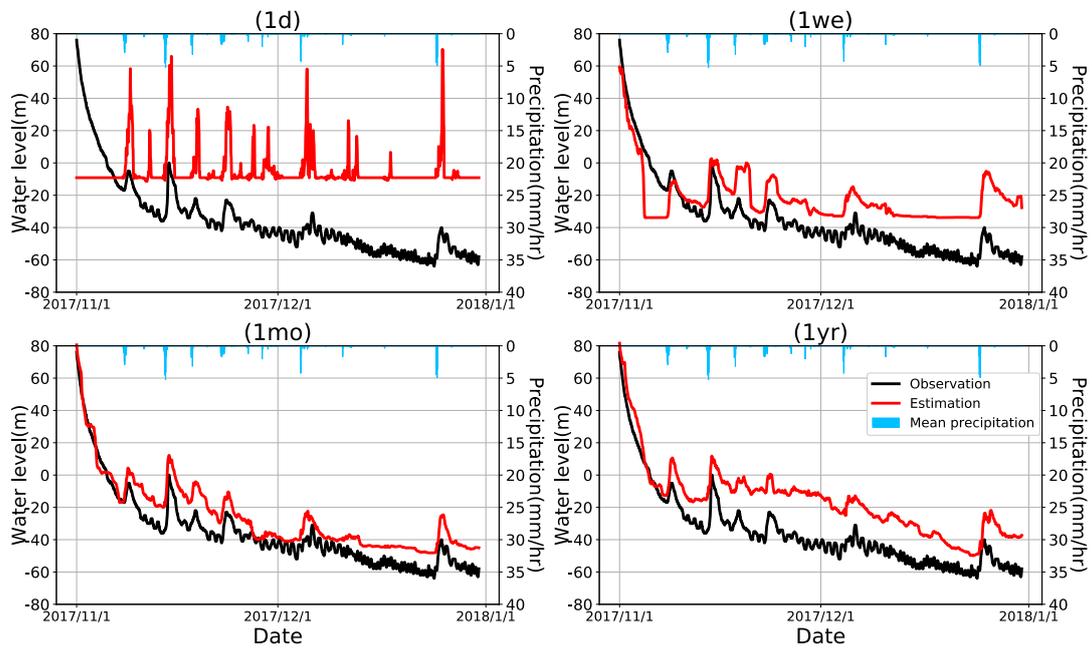


Figure 11 渇水期(2017/11/1~2018/1/1)について各遡り期間の推定結果の違い

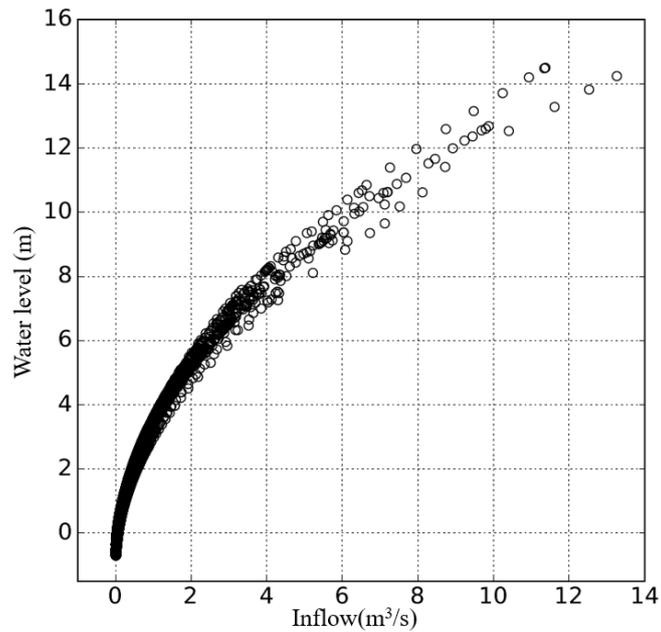


Figure 12 津野川観測所における HQ 曲線.

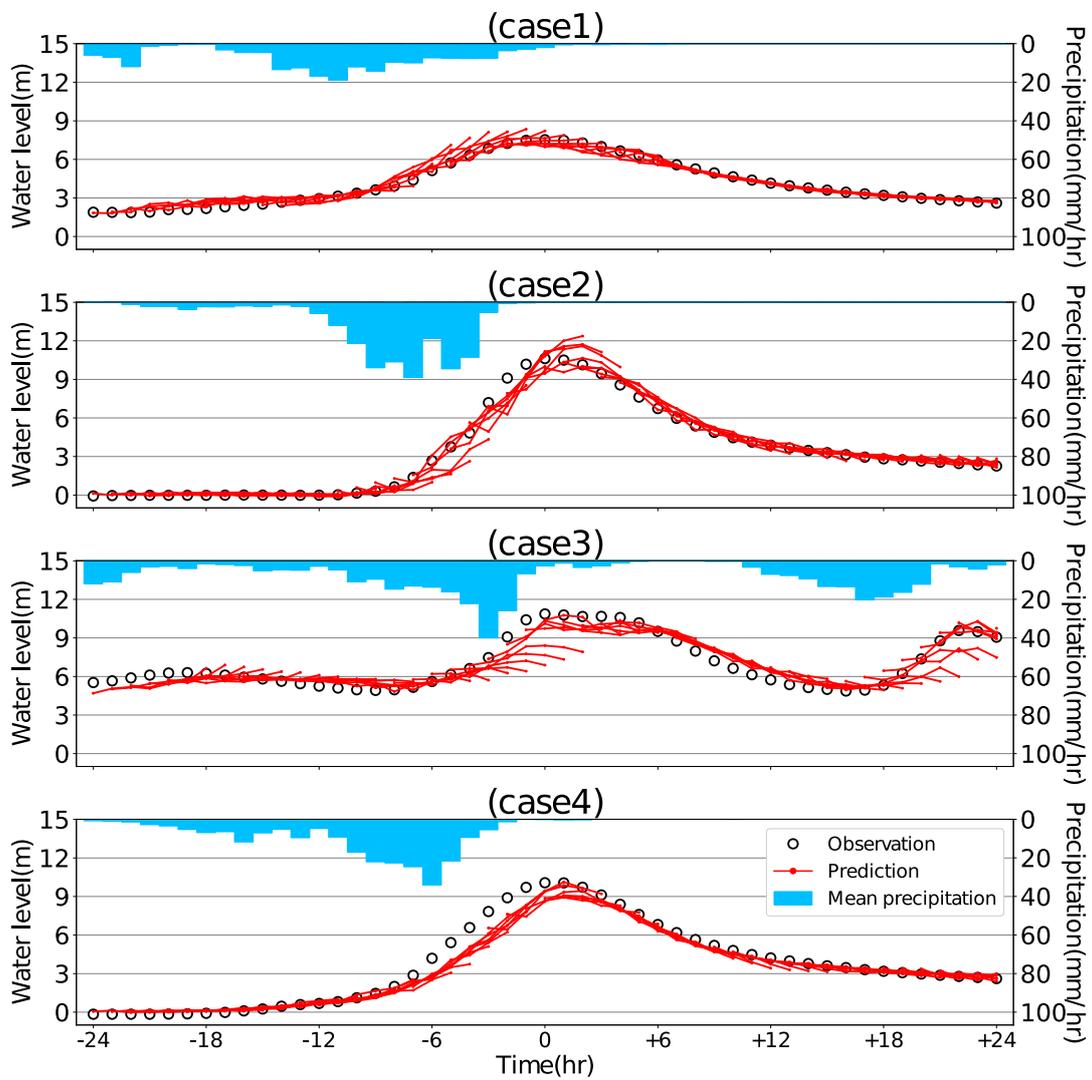


Figure 13 4大洪水に対する推定値と1~6時間先の予測結果. 赤線は、各時刻からの推定・予測値を示しており、先端が6時間予測値を表している. 赤線が観測値をなぞるほど予測できていることを示す.

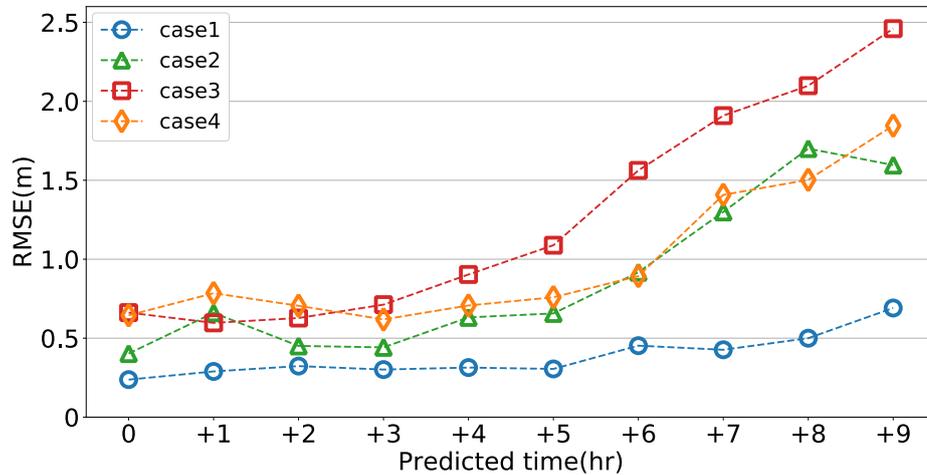


Figure 14 大洪水に対する推定値と 1~9 時間予測の RMSE. Figure 13 の期間中の RMSE の値を示している.

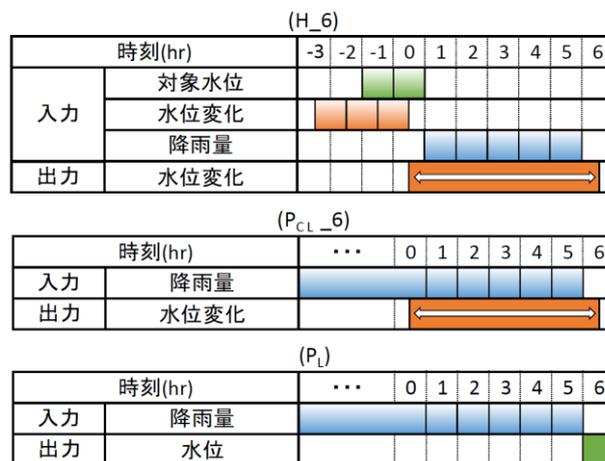


Figure 15 先行研究手法, 比較用手法, 本研究手法における入力データの比較. H_6: 先行研究再現 6 時間先予測モデル, P_{CL}_6: 比較用手法 6 時間先水位変化予測モデル, P_L: 本研究手法 1 時間先水位高予測モデル. 使用する入力雨量データの最新時刻がいずれの手法においても等しいことを示している. 予測水位変化または水位高の 1 時間前までの情報が使用されている.

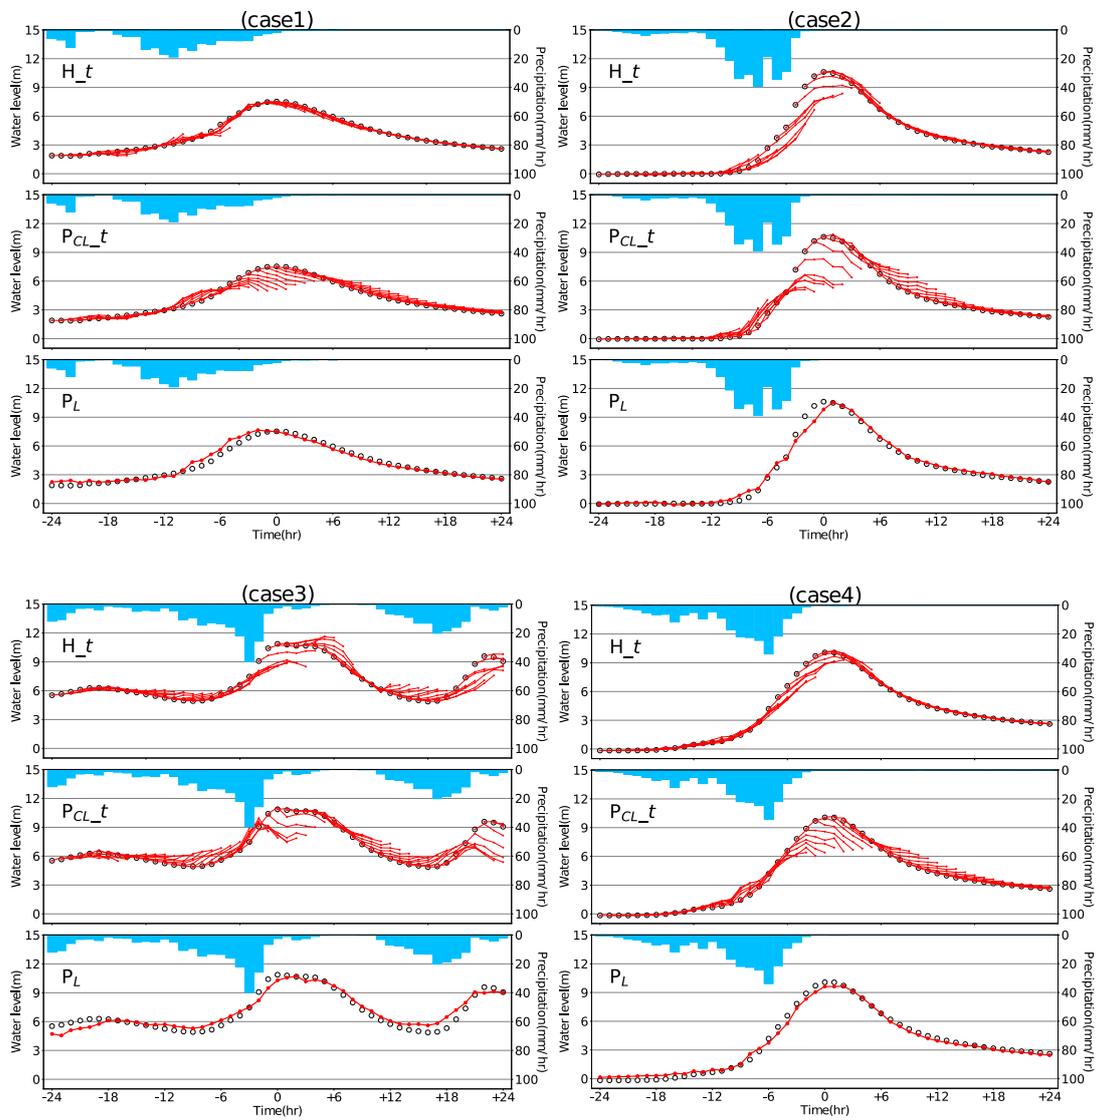


Figure 16 先行研究手法 H_t , 比較用手法 P_{CL}_t , 本研究手法 P_L の 4 大洪水における予測結果.

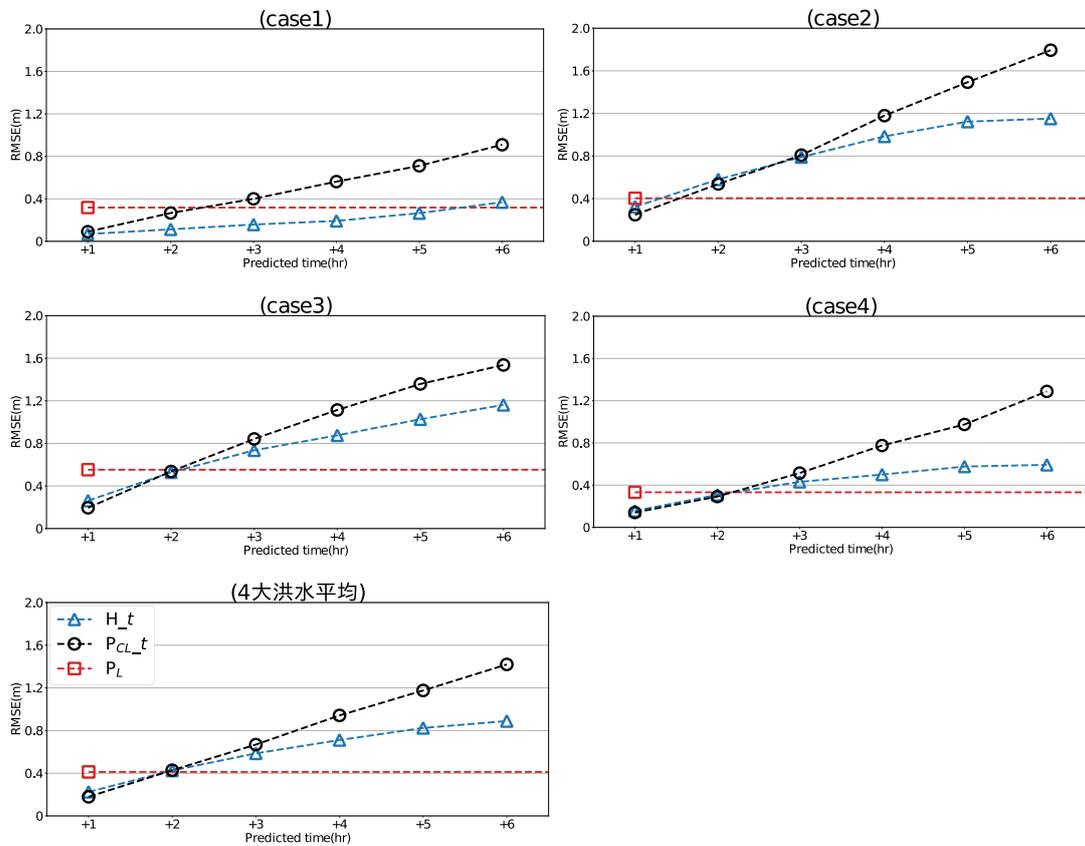


Figure 17 先行研究再現モデル H_t , 比較用手法モデル $P_{CL,t}$, 本研究手法 1 時間先予測モデル P_L , の各予測時間における 4 大洪水に対する平均 RMSE.

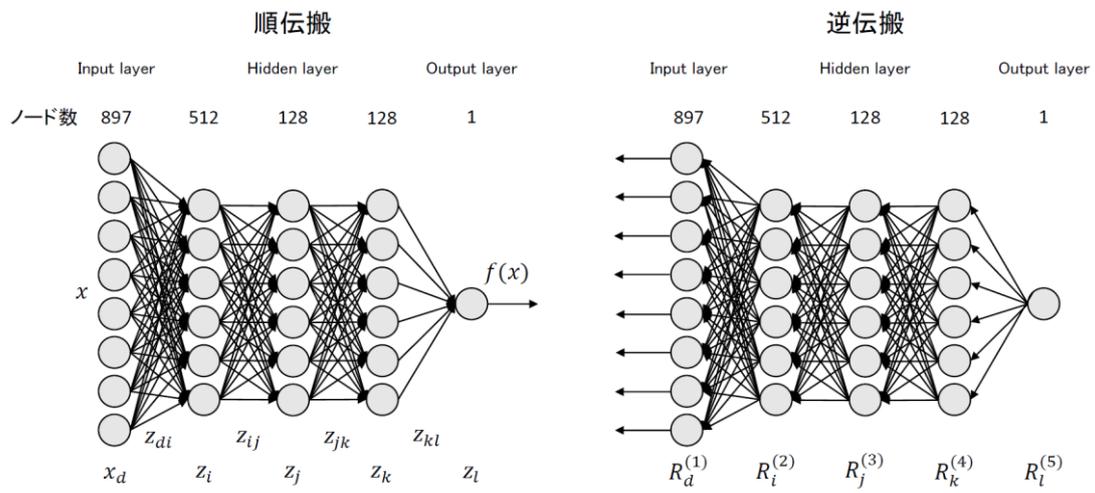
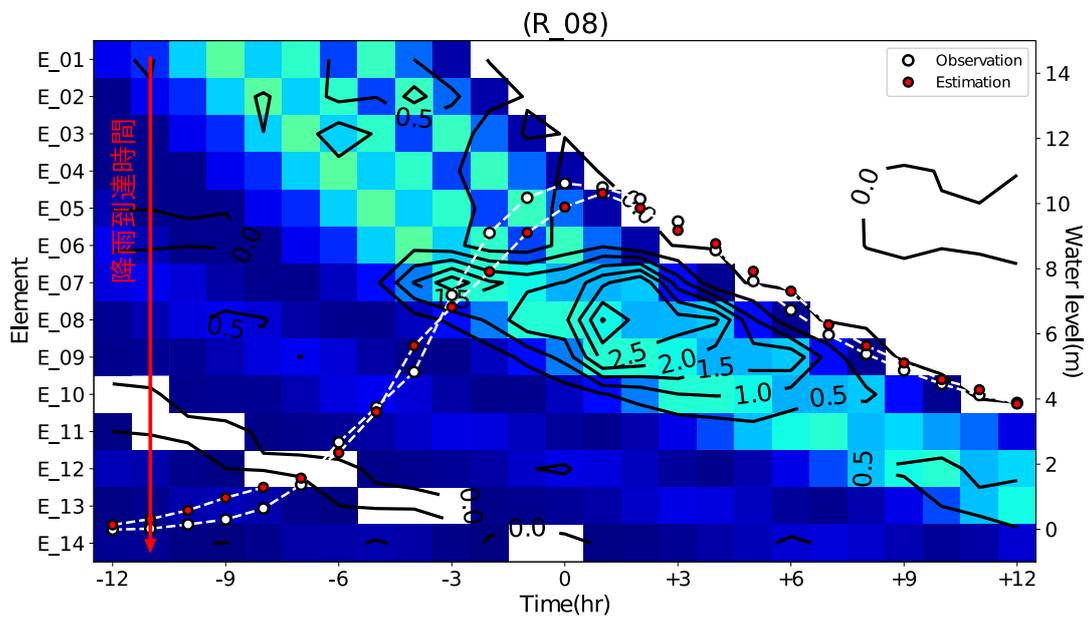
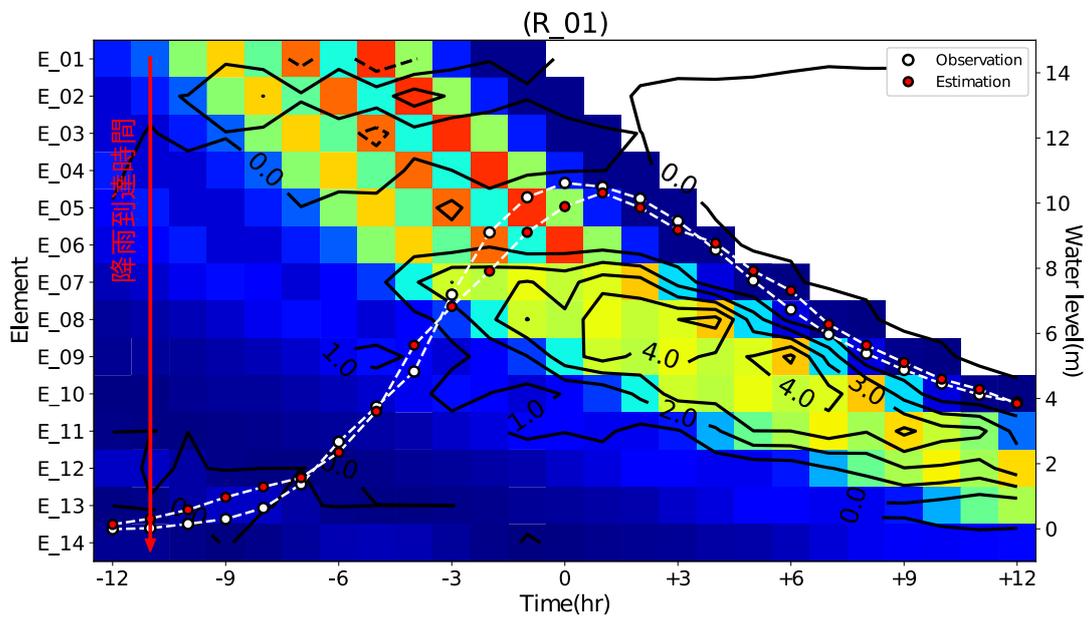


Figure 18 本研究の全結合多層パーセプトロンモデルにおける LRP の概念図. 左図：順伝搬，右図：逆伝搬.



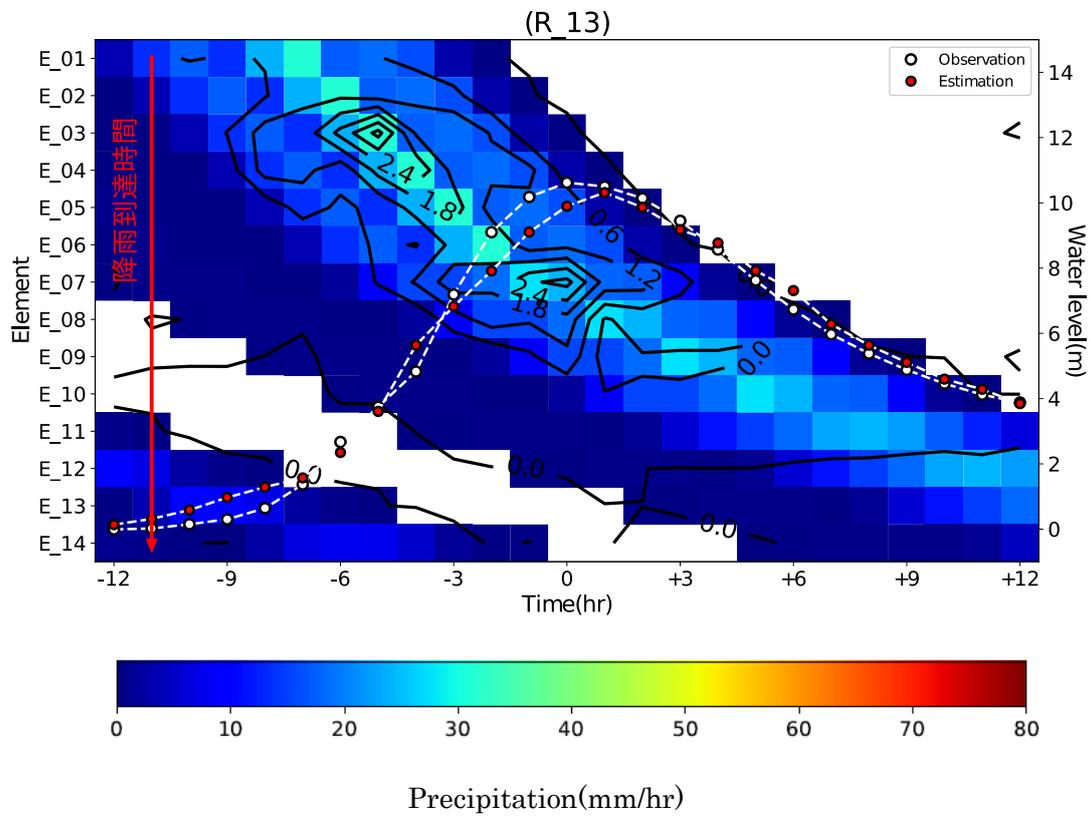


Figure 19 提案水位推定モデルによる洪水における各時刻の入力データ(color map), 各要素における relevance score(contour map), 観測水位, 推定水位. 上図: R_01, 中図: R_08, 下図: R_13. 寄与度の高い領域の入力要素番号(過去の降雨)から降雨到達時間を示す.

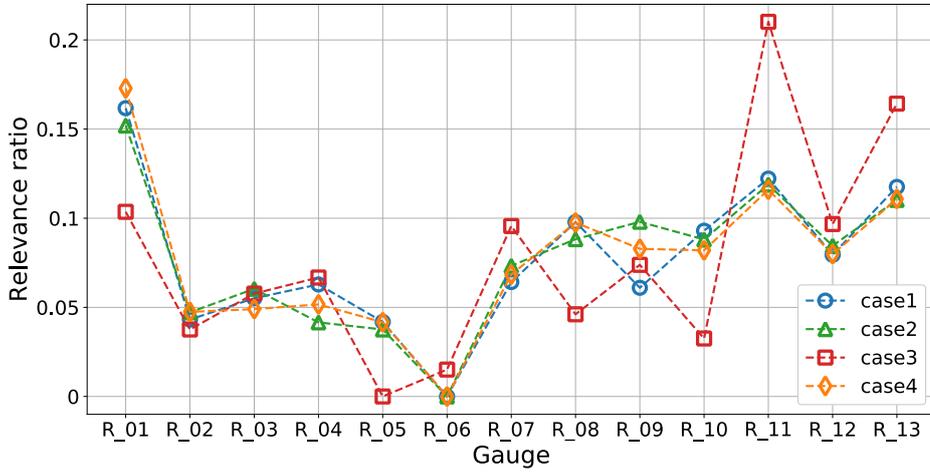


Figure 20 洪水における各地点の積算 relevance の割合.

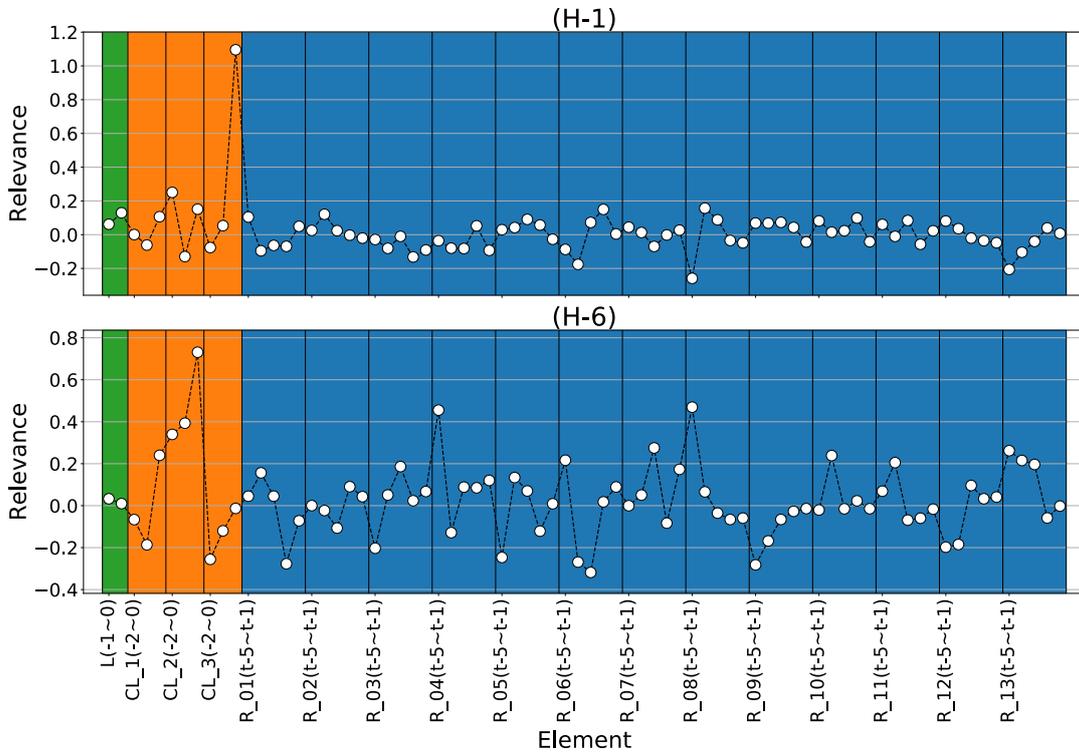


Figure 21 case4 における先行研究再現モデルの各入力要素の relevance. 上: H_1, 下: H_6. case4 の洪水ピーク生起時刻 -12(hr)~洪水ピーク生起時刻の水位上昇期間の平均 relevance. 入力要素は, Figure 1, Table 4 を参照.

10. 表

List of Tables

Table 1	グリッドサーチ法で探索を行うハイパーパラメータセット	51
Table 2	各遡り期間における RMSE の変化. 全検証データに対して, 水位高のパーセンタイルごとの RMSE.....	51
Table 3	大洪水事例における精度評価 RMSE, NSE, PEP, TEP.....	52
Table 4	先行研究再現における入力, 教師データ. 現時刻を 0 とする. h_i は水位, $(h_{i+1} - h_i)\Delta t$ は水位変化, R_i は雨量, $(h_{i+f} - h_i)(f\Delta t)$ は各予測時間の水位変化. i は時刻, f は予測時間数を示す.	52
Table 5	提案手法モデルの各入力要素記号における時間と分解能の関係.....	53

Table 1 グリッドサーチ法で探索を行うハイパーパラメータセット

Layers	Nodes	L1-normalization
2	64	0
3	128	10^{-8}
4	256	10^{-7}
	512	10^{-6}
	1024	

Table 2 各遡り期間における RMSE の変化. 全検証データに対して, 水位高のパーセンタイルごとの RMSE. 下線は最小値を示す.

term	1d	1we	2we	1mo	3mo	6mo	1yr
all	54.5	25.0	21.3	21.2	21.8	20.3	<u>19.6</u>
%ile0-20	49.3	26.1	20.0	<u>16.2</u>	21.7	21.3	21.4
%ile20-40	35.8	20.7	19.4	17.6	20.4	16.5	<u>16.4</u>
%ile40-60	21.5	24.0	19.8	21.8	19.4	16.8	<u>16.1</u>
%ile60-80	31.6	22.4	20.8	21.9	21.3	19.3	<u>17.0</u>
%ile80-100	93.5	29.3	25.6	28.4	25.1	24.5	<u>23.2</u>

Table 3 大洪水事例における精度評価 RMSE, NSE, PEP, TEP

	case1	case2	case3	case4
RMSE(cm)	30.1	38.0	52.6	42.8
NSE	0.973	0.982	0.942	0.976
PEP(%)	3.44	6.42	4.70	11.3
TEP(hr)	-1	1	0	1

Table 4 先行研究再現における入力, 教師データ. 現時刻を 0 とする. h_i は水位, $(h_{i+1} - h_i)/\Delta t$ は水位変化, R_i は雨量, $(h_{i+f} - h_i)/(f\Delta t)$ は各予測時間の水位変化. i は時刻, f は予測時間数を示す.

Input			Output
Type	Number of gauges	Time	
h_i	1	$i = -1, 0$	$(h_{i+f} - h_i)/(f\Delta t)$
$(h_{i+1} - h_i)/\Delta t$	3	-2, -1, 0	
R_i for $f=6$	13	1, 2, 3, 4, 5	
R_i for $f=5$	13	0, 1, 2, 3, 4	
R_i for $f=4$	13	-1, 0, 1, 2, 3	
R_i for $f=3$	13	-2, -1, 0, 1, 2	
R_i for $f=2$	13	-3, -2, -1, 0, 1	
R_i for $f=1$	13	-4, -3, -2, 1, 0	

Table 5 提案手法モデルの各入力要素記号における時間と分解能の関係

Element	Time(hr)	Resolution(hr)
E_01	t	1
E_02	t-1	1
E_03	t-2	1
E_04	t-3	1
E_05	t-4	1
E_06	t-5	1
E_07	t-6~ t-7	2
E_08	t-8~ t-9	2
E_09	t-10~ t-11	2
E_10	t-12~ t-13	2
E_11	t-14~ t-16	3
E_12	t-17~ t-19	3
E_13	t-20~ t-22	3
E_14	t-23~ t-26	4

11. 付録

・LRPの適用結果(R_01, R_08, R_13を除く全地点分)

