

2020 年度 修士論文

水位予測向上のための広域雨量データを
用いた CNN 手法の検討

Exploiting CNN Approach with Spatial Rainfall Data
for Better Stage Prediction

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 1235017

山本 啓

Kei Yamamoto

指導教員 端野典平

2021 年 3 月 15 日 提出

要旨

気候変動により、近年、日本では大雨時の降雨強度や降雨量が増加しており、洪水災害が多発している。2020年7月の大雨により82人が死亡し、1時間あたり50mm以上の降雨を観測した雨量計の数は1982年7月上旬以来最大であった。そのため、より良い水位予測の需要が高まっている。本研究は、地方自治体や洪水浸水想定区域の個人が避難判断のための情報を入手できるように、十分な精度を備えた単純な水位予測モデルを開発することを目的としている。これまでの研究では、流域面積の小さい河川を対象に、多層パーセプトロン（MLP）と上流の2地点の降雨データのみを使用して、水位を高精度に推定できることを示した。この際、推定時から1年前の時系列データを入力としたが、数時間先の水位を予測することは困難であった。畳み込みニューラルネットワーク（CNN）は、MLPよりも降水の局所的な空間パターンを捉えることができる可能性がある。したがって本研究ではCNN手法を用いて、使用する雨量データの領域の拡大の、水位推定と予測への影響を調査することを目的とする。

本研究では、高知県高知市に流れる鏡川を対象河川として、中流に位置する宗安寺観測所の水位を推定・予測した。モデル開発には3次元のCNNを採用し、入力には鏡川全域を覆う範囲の解析雨量データ、教師データには宗安寺観測所の水位データを与え、水位推定・予測モデルを構築した。入力データは3次元であり、次元にはそれぞれ、緯度、経度、深さ方向には時系列データを使用した。この際、最初の6時間は1時間分解能で最終が1ヶ月分解能になるような時系列を作成し、遡る期間が1週間から1年の時系列6通りを比較した。また、領域を拡大したことによる予測精度の違いの比較を行う。

遡り期間を比較した結果、遡る期間が1ヶ月のモデルの誤差が最小であったため、最適な遡り期間は1ヶ月であると判断した。これは鏡川の地下水等が土壌に浸透し河川に流出する過程を1ヶ月の雨量時系列データによりモデル化することが出来ることを示唆する。検証データに適用しモデルの性能の比較を行った結果、MLPモデルよりもCNNモデルの方が良好に水位を推定できる可能性があることが分かった。鏡川のような中小河川であっても雨量観測点が少なく河川全域を観測所のみで考慮することが困難であるため、空間解析雨量データを使用したCNNモデルによる水位推定モデルの開発は有効であると考ええる。また、直近の雨量データを使用しない数時間先の水位予測モデルにおいては、CNNモデルもMLPモデルと同様に予測の時間が増加するにつれてピークの値、時間のずれ共に増大することが分かった。しかし、1～2時間予測に関しては推定値と同程度で予測することができ、推定精度の高いCNNモデルの方がより高い精度で予測できる可能性がある。

内容

第1章 序論（研究の背景と目的）	3
1-1 背景	3
1-2 目的	4
1-3 対象流域（鏡川）	4
第2章 研究方法	6
2-1 使用したデータ	6
2-2 データの詳細	6
2-3 先行研究のモデル構造	8
2-4 水位推定・予測モデルの構造	8
2-5 水位予測モデルの作成	9
2-6 モデルの評価指標	10
第3章 結果・考察	11
3-1 雨量時系列の遡り期間の違いによる精度の比較	11
3-2 2次元CNNモデルと3次元モデルの精度の比較	14
3-3 テストデータにおける洪水2事例に対する推定精度の比較	17
3-4 水位予測結果	20
3-5 CNNモデルの領域の重要度調査	25
3-6 鏡ダムによる水位変化への影響の調査	27
第4章 まとめ	28
謝辞	30

第 1 章 序論（研究の背景と目的）

1-1 背景

近年、日本全国のアメダスにおける降水量の観測では、1 時間降水量 50 mm 以上及び 80 mm 以上の短時間強雨の年間発生回数はともに増加している。50 mm 以上の場合、1976～1985 年の 10 年間平均では全国の 1300 地点の観測所で約 226 回だったが、2009～2019 年の 10 年間平均では約 327 回と約 1.4 倍に増加している。日降水量 200 mm 以上及び、日降水量 400 mm 以上の大雨の年間日数には増加傾向が現れている（気象庁、2019）。このように気候変動に伴い、大雨時の降雨強度や降雨量が増加していることは明らかであり、これにより洪水災害が多発している。例えば、2020 年 7 月の大雨により 82 人が死亡し、1 時間あたり 50mm 以上の降雨を観測した雨量計の数は 1982 年 7 月上旬以来最大であった。近年、局所的な降雨の頻度や規模が増加していることから、流域面積の小さい中小河川においても洪水の危険度が高まっていることが示唆される。そのため、より良い水位予測の需要が高まっている。深層学習を用いた河川水位予測は行われている。例えば、大淀川における 1～6 時間先の水位変化予測モデル（一言ら、2016）の開発である。しかしこの研究では、入力データとして水位変化などの物理量が使用されている。そのため上流に水位観測所が必要になる。しかし、中小河川では水位観測所が上流に設置されていない可能性があり、そのような河川には適用できない。そのため、雨量データのみを用いた水位推定・予測モデルの開発は重要である。

これまでの研究では、流域面積の小さい河川を対象に、多層パーセプトロン（MLP）と上流の 2 地点の雨量データのみを使用して、水位を高精度に推定できることが示した（中根ら、2019）。この際、推計時から 1 年前の時系列データを入力とした。しかし、数時間先の水位を予測することは困難だった。これは、上流の 2 地点で観測された降雨量が、河川全体の降雨分布を考慮しておらず、数時間先の水位に関する情報が含まれていないためと考えられる。深層学習の手法として、畳み込みニューラルネットワーク（CNN）は、MLP よりも降水の局所的な空間パターンを捉えることができる可能性がある（Shen et al, 2018）。このことから、広域雨量データのみを使用した推定・予測モデルの開発は必要である。

1-2 目的

本研究では、深層学習を用いることで、河川氾濫時に地方自治体や個人が避難判断のための情報を入手できるように、十分な精度を備えた単純な水位予測モデルを構築する方法について CNN を用いて検討・調査する。特に、①入力雨量データを観測所が位置する地点のデータから鏡川全域を覆うデータに拡張することで予測精度の向上がみられるか確認すること、②学習していない過去最大の水位を記録した 2014 年 8 月に着目し、前例のない豪雨に対する水位推定を深層学習によって高い精度で再現することを目的とする。

1-3 対象流域（鏡川）

鏡川は流域面積が 170 km²、流路延長が 31 km の中小河川であり、また水位周知河川に指定されている。水位周知河川とは、「洪水予報指定河川（国土交通大臣は、二以上の都府県の区域にわたる河川その他の流域面積が大きい河川で洪水により国民経済上重大な損害を生ずるおそれがあるものとして指定した河川）以外の河川のうち、河川法に規定する指定区間内の一級河川又は同法に規定する二級河川で洪水により相当な損害を生ずるおそれがあるものとして指定した河川について、特別警戒水位(氾濫危険水位)を定め、当該河川の水位がこれに達したときは、その旨を当該河川の水位又は流量を示して関係都道府県知事に通知するとともに、必要に応じ報道機関の協力を求めて、これを一般に周知させなければならない。(水防法第 13 条)」(国土交通省：川の防災情報)である。それに加えて、鏡川では 2014 年 8 月に台風 12、11 号が相次いで接近した際高知市全域 33 万人に避難勧告が出された。この事例では、降雨のピーク時刻から水位のピーク時刻まで、2.5 時間差ほどであった。また、水位に関しては、4.97m の過去最大の水位を記録した。本研究の対象水位観測所である宗安寺観測所では特別警戒水位が設定されていない。宗安寺観測所より下流側に位置する東立石町の別の水位観測所では、最大水位 4.84m 記録し氾濫危険水位を 0.24m 上回った。宗安寺では、氾濫はしなかったもののかなり危険な状態であった。鏡川の流域図を図 1 に示す。

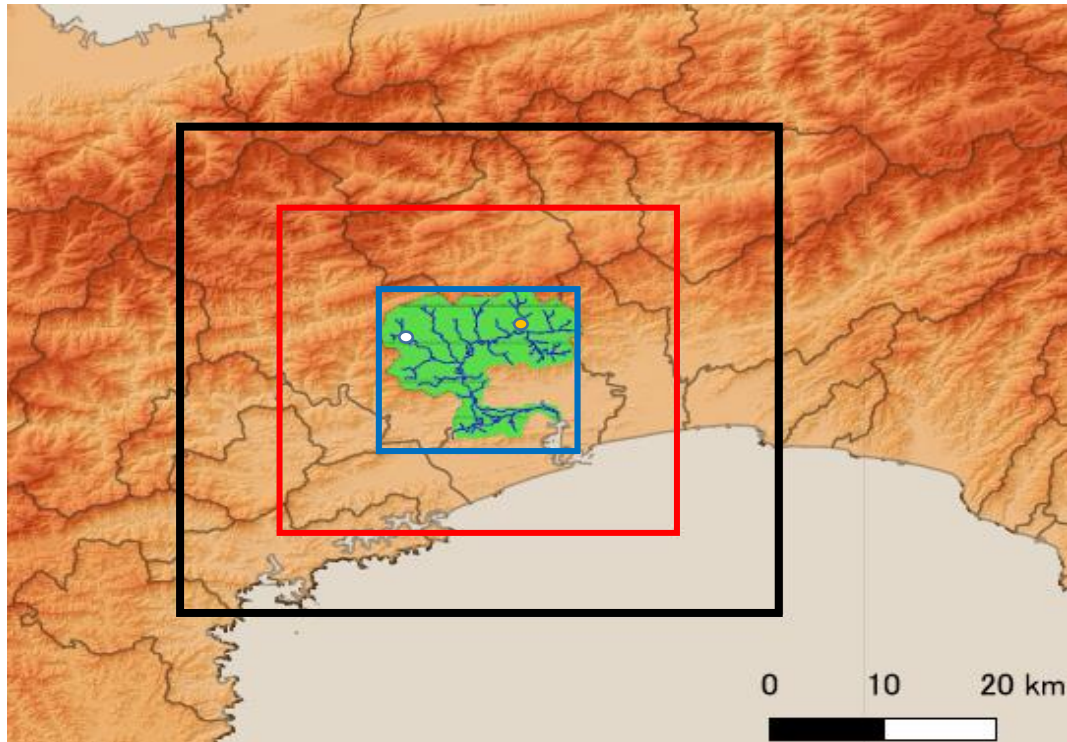


図 1 鏡川の流域図 青枠は $21\text{ km} \times 16\text{ km}$ 、赤枠は $42\text{ km} \times 32\text{ km}$ 、
黒枠は $63\text{ km} \times 48\text{ km}$

第2章 研究方法

2-1 使用したデータ

本研究では、鏡川の鏡ダム下流の高知平野の入り口に位置する宗安寺観測所を対象水位地点とした。鏡川の中流に位置しており、潮汐の影響は小さいと考えられる。地上雨量計データについては、水位地点より上流の平石、柿ノ又観測所の2地点を対象雨量地点とした。それに加えて、鏡川全域を覆う任意の範囲を対象雨量範囲とし、2種類の雨量データを作成した。水位データは、高知県土木部河川課から提供していただいた宗安寺観測所での水位を使用している。雨量については、解析雨量データを気象庁から取得した。解析雨量とは、「国土交通省水管理・国土保全局、道路局と気象庁が全国に設置しているレーダー、アメダス等の地上の雨量計を組み合わせ、1時間の降水量分布を1km四方の細かさで解析したもの。データは30分毎1時間雨量となる。」(気象庁)である。本研究で解析雨量を使用した理由としては、欠測値がほとんどないことがあげられる。本研究の対象期間において、欠測値は見られなかった。また、中小河川のように観測所が少ない領域においても、任意の範囲で面的な雨量分布を得ることが出来る。そのため、地上雨量計では捉えることが出来ない局所的な雨量も把握することが出来る強みがあるためである。先行研究では2地点の観測所を対象としており、1km四方に観測所が含まれるように解析雨量データを取得している。本研究では、範囲を対象としたため、中心に水位観測所である宗安寺が位置するように取得した。範囲は、21 km×16 km、42 km×32 km、63 km×48 kmの範囲の3種類を使用した。

2-2 データの詳細

解析雨量データを上記の通り3種類の範囲のデータを使用した。しかし、本研究で使ったGPUはGeForce RTX 2080 SUPERで11G byteのメモリがあるが、21 km×16 kmより広範囲の場合、そのメモリを超えてしまい、1 km四方のデータでの使用が困難であったため、42 km×32 km、63 km×48 kmのデータはそれぞれ、2 km、3 kmの四方のデータになるように平均し、3種類の範囲の雨量データの作成を行った。それぞれの範囲は、図1の流域図の青枠の範囲が1 km×1 km、赤枠の範囲が2 km×2 km、黒枠の範囲が3 km×3 kmを示している。

本研究では、雨量データは入力データとして用いる際そのまま用いるのではなく時系列的な特徴を持たせた。上流での雨が地下には浸透せず河川を流れ水位上昇に影響するモデル化として、ある時刻から1時間ごとに遡る1時間データを6データ(6時間分)作成し、雨が森林や地層を通して地下に浸透して湧水として河川に流出する場合には、水位に影響するには数か月から1年以上かかると考え、そのモデル化としては1時間分解能で6時間遡って以降2時間、3時間、最終1か月と複数のデータを平均する時間平均データを作成した。この1時間データ、時間平均データを組み合わせることである時刻から1年遡る雨量時系列データを作成した(若槻ら, 2020)。この際の、要素数と遡り期間の関係を図2に示

す。作成した雨量時系列データの遡り期間を、1 週間、2 週間、1 か月、3 か月、6 か月、1 年の時系列の内 6 通りの時系列で最も適した時系列の調査を行った。本研究では、雨量データは 2008 年から 2014 年の内、2009 年から 2012 年を訓練データ(学習モデル作成用)、2013 年 2 月から 2013 年 11 月までを検証データ(ハイパーパラメータの調整用)、2014 年の 1 月から 2014 年 8 月までをテストデータ(最終的なモデルの評価)の 3 種類に分割した。推定モデル作成時の入力データは 2009 年から 2014 年の雨量時系列データ、教師データは同じ期間の宗安寺の水位データとした。ここで、検証データを 2013 年の 1 年分ではなく 2 月から 11 月の 10 か月分にした理由として、1 時間ごとに遡る 1 時間データによって、2013 年の 1 月は訓練データの最後の 1 か月分、12 月はテストデータのはじめの 1 か月に情報が漏れてしまうのではないかと考え、本研究では取り除いている。また、テストデータが 8 月までの理由としては、8 月の豪雨以降地形の変化等により宗安寺の基底水位が変化してしまった可能性があるためである。データ数はそれぞれ、訓練データ:69903 データ、検証データ:14461、テストデータ:11614 データである。





図 2 各遡り期間における (a) 要素数、(b) 圧縮する要素数の数

2-3 先行研究のモデル構造

先行研究(中根ら, 2019)では、多層パーセプトロンモデル(MLP)を用いている。

多層パーセプトロンは、入力層、隠れ層、出力層の3層から単純な構造のモデルである。

多層パーセプトロンの概略図は図3に示す。




図3 多層パーセプトロンの構造

2-4 水位推定・予測モデルの構造

本研究では、宗安寺の水位を推定・予測する手法として畳み込みニューラルネットワーク(CNN)を用いた。CNNとは、MLPに比べて局所的な空間パターンを捉えることに優れている。

CNNは、画像の局所的な特徴抽出を行う畳み込み層、畳み込み層の出力を活性化関数かけ変換し、プーリング層に入力する。ここで、プーリング層では活性化後に出力される特徴マップにある大きさのフィルタを掛けそのフィルタでの最大値を出力するマックスプーリングを行う。プーリング層から出力される3次元の特徴マップを1次元に変換し、全結合層に入力する。全結合層は、複数のノードから成り、各ノードは、前層の出力に重みを付加し、次の層に入力する。これを繰り返し最終的に出力する。その結合の重みは誤差逆伝播法により、適切な値に収束するように繰り返し更新しながら決定する。この更新の際、毎回すべてのデータを使用せず、データの一部を取り出して学習を行うミニバッチ学習を行っている。これによる、望ましくない臨界点にはまる可能性を小さくできる。また、ミニバッチ分のデータを読み込むことでメモリの削減も行える。CNN概略図は4に示す。各層の活性化関数に

は ReLU 関数、最適化関数には Adam、誤差関数には mean_squared_error (平均二乗誤差) を使用した。

本研究で利用したモデルの構造は、畳み込み層、活性化関数、プーリング層を 1 層、全結合層を 3 層、ノード数はそれぞれ 256 ノード、128 ノード、64 ノードのモデルである。

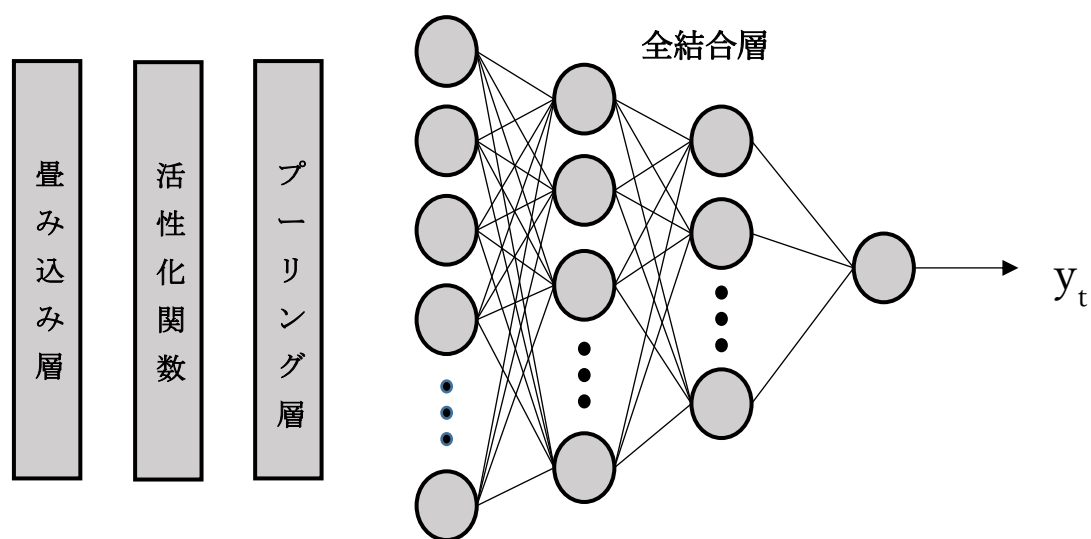


図 4 畳み込みニューラルネットワークの構造

2-5 水位予測モデルの作成

水位予測モデルも推定と同様のモデルを用いた。利用したデータは推定と同様に入力データとして 2009 年から 2014 年の雨量データ、教師データとして同じ期間の宗安寺の水位データを用いた。入力データと対応する教師データを変化させることで予測を行った。図 5 は推定、各予測時間に対する教師データの時刻の対応関係を示している。ある時刻 t から始まる雨量時系列データに対して対応する教師データを時刻 t とした場合は推定であり、対応する教師データの時刻を $t+1$ にすると 1 時間予測、 $t+2$ にすると 2 時間予測、 $t+3$ にすると 3 時間予測となる。

時刻	t+3	t+2	t+1	t	t-1	t-2	t-3	・・・
雨量								
推定								
1時間予測								
2時間予測								
3時間予測								

図 5 推定・予測時間に対する教師データの対応関係

2-6 モデルの評価指標

本研究では、モデルの評価指標として、RMSE(Root Mean Squared Error)と PEP(percentage error of peak)、TEP(time error of peak)を使用した。RMSE は観測値(y_i)と推定値(\hat{y}_i)の誤差の指標である。PEP(ピーク誤差率)は、洪水事例の観測値のピークの値(y_{t_p})に対して、モデルの出力したピークの値(\hat{y}_{t_p})がどれほどの誤差があるかを示す指標である(若槻, 2020)。TEP(ピーク時間誤差)は、洪水事例の観測値のピークの時刻(t_p)に対して、モデルの出力したピークの時刻(\hat{t}_p)とどの程度の時間の誤差があるかを表した指標である(若槻, 2020)。

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

$$PEP = \frac{\hat{y}_{t_p} - y_{t_p}}{y_{t_p}} \cdot 100$$

$$TEP = \hat{t}_p - t_p$$

第3章 結果・考察

3-1 雨量時系列の遡り期間の違いによる精度の比較

本研究では、6通りの雨量時系列の遡り期間の違いによる精度の比較を行った。その際の、検証データでの遡り期間による全体の RMSE の推移、検証データにおける各遡り期間ごとの観測値と推定値の散布図を図 6 に示す。また、水位を 20 パーセンタイルごとに分類し、各遡り期間ごとに RMSE を計算した(表 1)。




図 6 検証データでの遡り期間による RMSE の推移

	1week	2week	1month	3month	6month	1year
0-20	8.871	7.438	4.337	5.364	6.358	4.579
20-40	9.856	8.206	5.343	5.006	6.472	4.784
40-60	10.489	8.414	3.814	6.160	7.409	6.610
60-80	13.477	6.805	6.906	7.728	8.224	8.490
80-100	14.898	12.302	10.875	11.474	11.565	11.613

表 1 20 パーセンタイルごとの RMSE (cm)

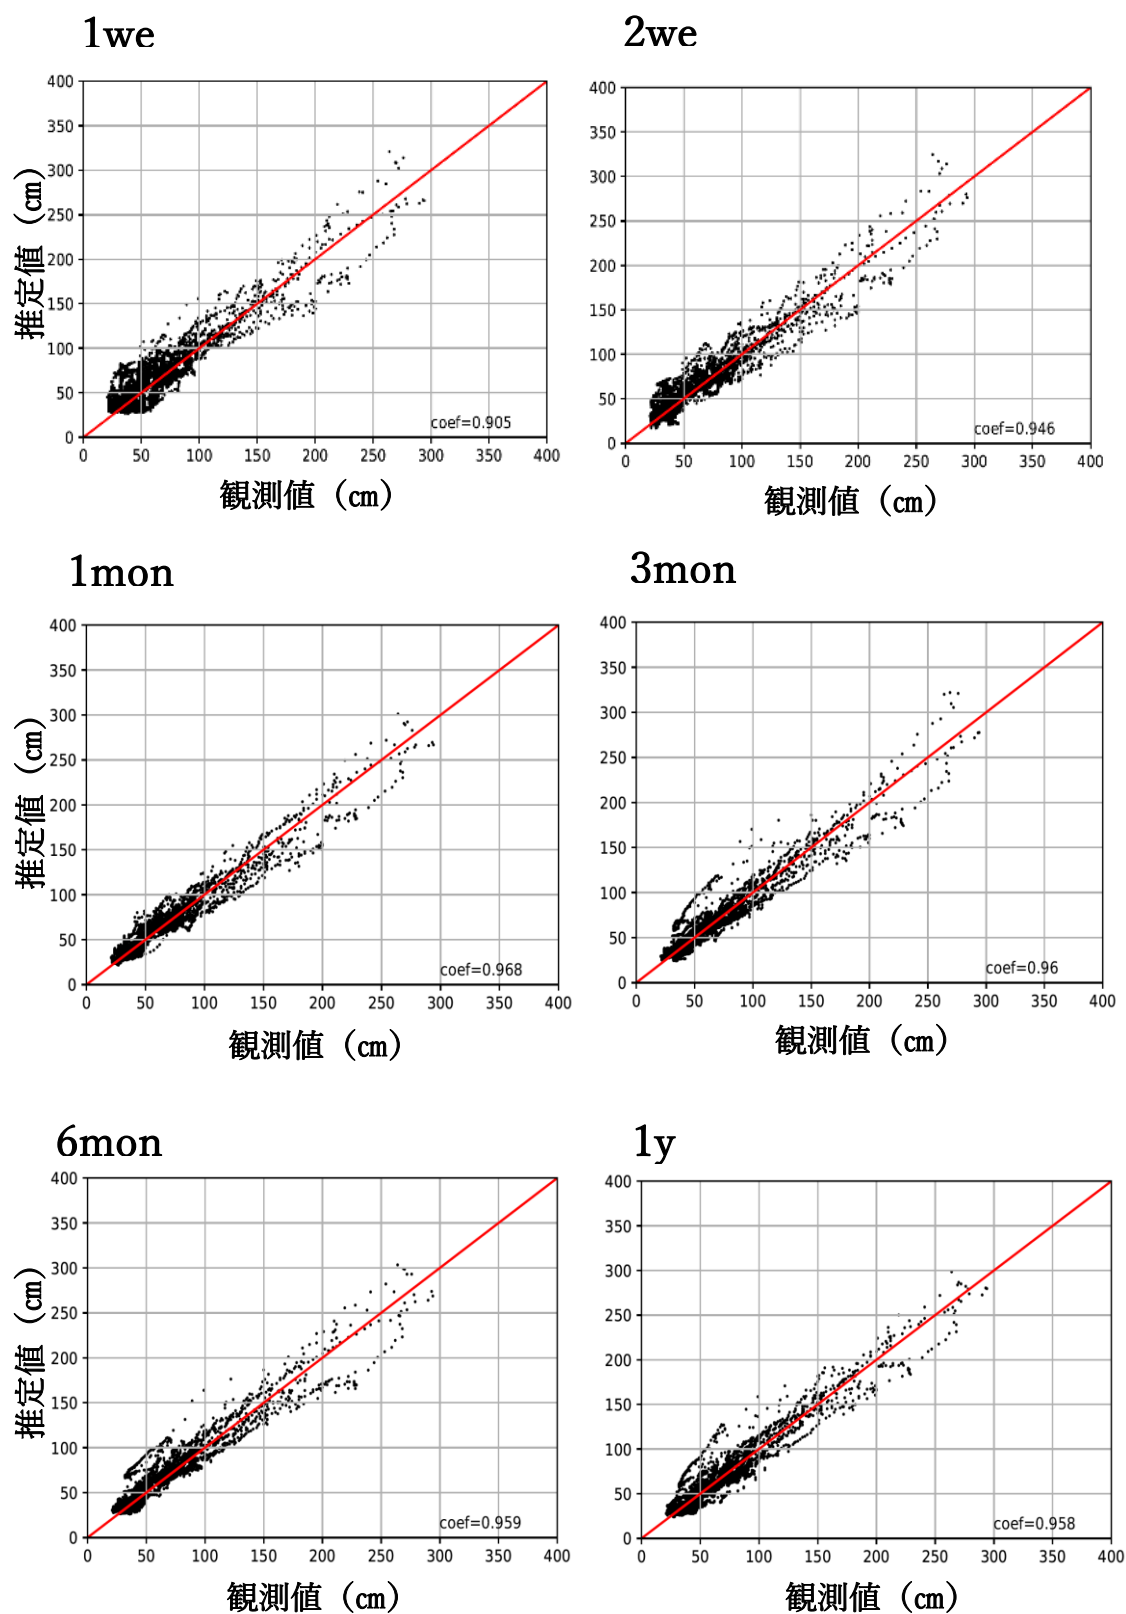


図 7 各遡り期間の観測値と推定値の散布図

表 1 より遡り期間が 1 か月のモデルが全体の RMSE が最も低い結果となった。また、観測値と推定値の散布図より一か月より遡り期間が短い場合、低水位、高水位共にばらつきが大きくなっている。しかし、一か月以上遡ると低水位、高水位ともにかなりばらつきが小さくなることが分かった。20 パーセンタイルごとの RMSE を比べると、遡り期間 1 か月のモデルはどのパーセンタイルにおいても RMSE が低いことが分かる。また、高水位である 80-100 パーセンタイルにおいても 6 通りの内、最も RMSE が低いことから、鏡川において遡り期間は 1 か月が最適であると判断した。

若槻(2019)は、上流 13 地点の雨量を入力とした MLP モデルを使用して、四万十川で水位推定・予測を行った。そして遡り期間による精度の違いを調査した結果、遡り期間を 1 年とした場合が最も誤差が小さく最適であると判断している。一方、鏡川のような流域面積の小さい河川においては、土壌へ浸透した降雨が河川に流出するまでの過程にかかる期間が四万十川と比べ、それほど長い期間を必要とせず、遡り期間が 1 か月で十分であることが分かった。遡り期間 1 か月の雨量時系列データを入力としたことで流出過程が再現できたと考えられる。また、遡り期間を 1 か月にすることで 1 年の際と比べて要素数が 70 から 42 に減らすことが出来るのでメモリの削減にもつながる。

3-2 2次元CNNモデルと3次元モデルの精度の比較

3次元の入力データを使用した際に、畳み込み層において2次元のフィルタを用いた2次元CNNモデルと3次元フィルタを用いた3次元CNNモデルの精度の違いを検証した。ここで3次元CNNモデルのプーリング層では、3次元フィルタを使用し、時系列方向の次元削減を行う場合と、2次元のフィルタを使用することで時系列方向への次元削減は行わない2通りの違いを検証した。それぞれの、検証データ内の洪水2事例の時系列プロットを図8、9に示す。




図8 検証データ内の洪水事例(2013年10月25日)




図9 検証データ内の洪水事例(2013年9月4日)

図 8、9 において、青線が 2 次元 CNN モデル、赤線が 3 次元 CNN モデル(プーリングなし)、緑線が 3 次元 CNN モデル(プーリングあり)を示している。3 種類のモデルを比べると、3 次元 CNN モデル(プーリングなし)が、最も振動が小さくなることがわかる。また、2 番目の洪水に対しても同様に 3 次元 CNN モデル(プーリングなし)が、振動が小さくなったことで滑らかに表現できており、より現実的な推定を行うことが出来ていると考えられる。また、RMSE においては、一つ目の洪水は 2 次元 CNN モデル:13.24(cm)、3 次元 CNN モデル(プーリングなし):16.95(cm)、3 次元 CNN(プーリングあり):17.49(cm)、2 つ目の洪水では、2 次元 CNN モデル:22.05(cm)、3 次元 CNN モデル(プーリングなし):13.84(cm)、3 次元 CNN モデル(プーリングあり):27.56(cm)であり、2 番目の洪水に関しては、3 次元 CNN モデル(プーリングなし)が大幅な改善が見られた。

振動を説明するにあたり、2 次元 CNN モデル、3 次元 CNN モデルの畳み込み処理の例を図 10、11 にそれぞれ示す。図 10 より、2 次元 CNN モデルの畳み込み層では(5, 5, 3)の雨量入力データ(ここで、3 の方向をチャンネル方向と呼ぶ)に対して、(3, 3, 1)の 2 次元フィルタを作用される図のようにチャンネル方向に同じフィルタを作用させ、その計算結果を加算してため畳み込み後の出力が(3, 3, 1)となりチャンネル方向が一つに圧縮されている。例の場合は、チャンネル方向が 3 であったため 3 つの結果を加算しているが、チャンネル方向に雨量時系列データとした本研究では 42 データすべてを加算することになる。よって、時系列方向をうまく処理することが出来ていないと考えられる。一方、3 次元 CNN モデルは図 11 ように、2 次元 CNN モデルと違い、(3, 3, 2)の 3 次元フィルタを作用させる。すると、(5, 5, 3)の入力データが畳み込み層後に(3, 3, 2)の形で出力される。図 11 の場合、入力データの赤の四角と緑の四角にフィルタを作用させる場合と緑の四角と青の四角にフィルタを作用させる。2 次元 CNN モデルの時のようにチャンネル方向をすべて加算することなく、フィルタのチャンネル方向二つ分だけしか加算されない。よって、時系列方向の処理が可能となるため、振動が小さくなったと考えられる。また、時系列方向のマックスプーリングを行わないことで時系列の情報を削減することなく情報が残ることさらに振動が小さくなっていると考えられる。以上より、3 次元 CNN モデルが 3 次元入力データに対して有効であると判断した。また、時系列データに対してマックスプーリングによる次元の削減は効果的ではないと考えられる。

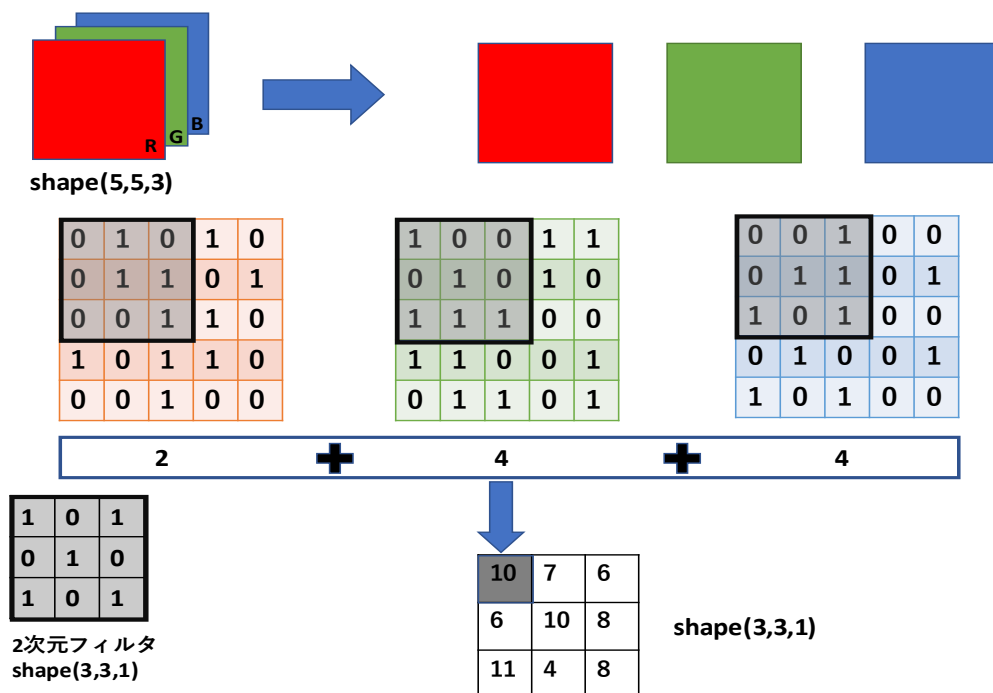


図 10 2次元 CNN の畳み込み処理

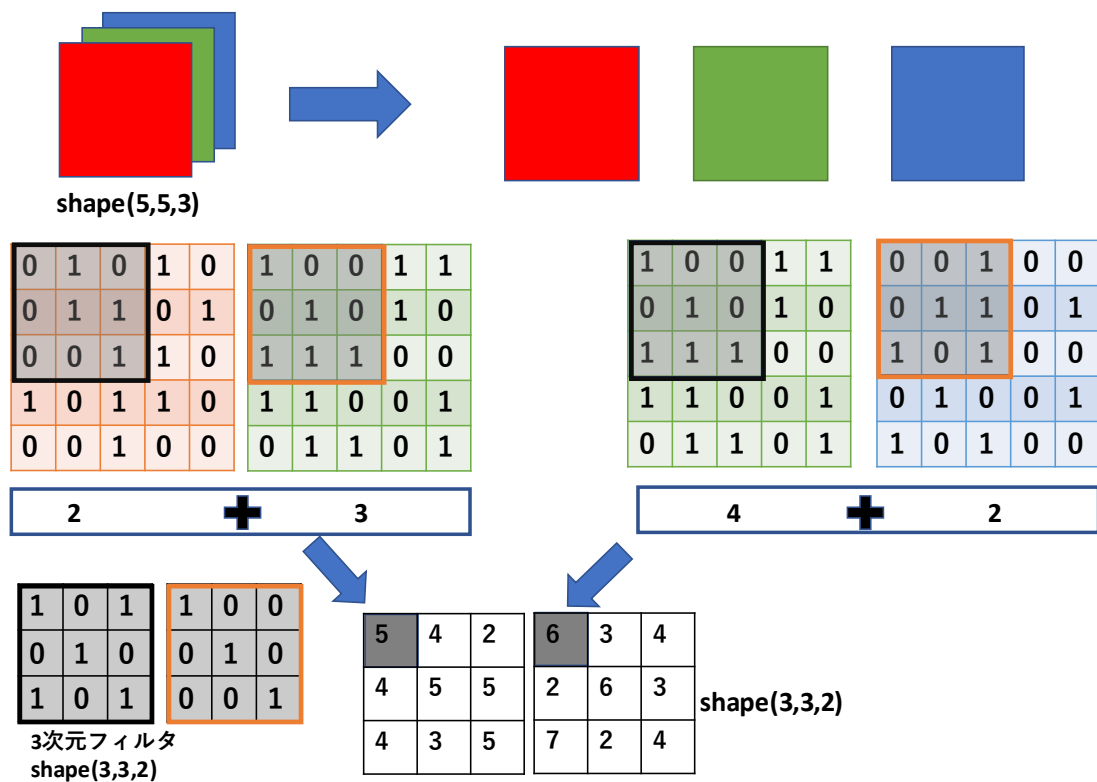


図 11 3次元 CNN の畳み込み処理

3-3 テストデータにおける洪水 2 事例に対する推定精度の比較

検証データで最適であると判断したモデルの構造、時系列の遡り期間の学習モデルを、訓練データにない未使用のテストデータに適用するところで、実際に、洪水を推定することが出来るか確認する。ここでは上流 2 地点の雨量データを入力とした MLP モデルと $2\text{ km} \times 2\text{ km}$ の面データを入力とした CNN モデルの推定精度の比較を行った。図 12、13 は、それぞれの洪水に対するピーク水位の前後 48 時間の時系列プロットを示している。テストデータにおいて、最大の洪水事例の図 12 の場合を cace1、2 番目の事例の図 13 の場合を cace2 とする。ここで、 $2\text{ km} \times 2\text{ km}$ を選択した理由は、 $1\text{ km} \times 1\text{ km}$ 、 $3\text{ km} \times 3\text{ km}$ の CNN モデルに比べて推定の際、RMSE が低かったためである。

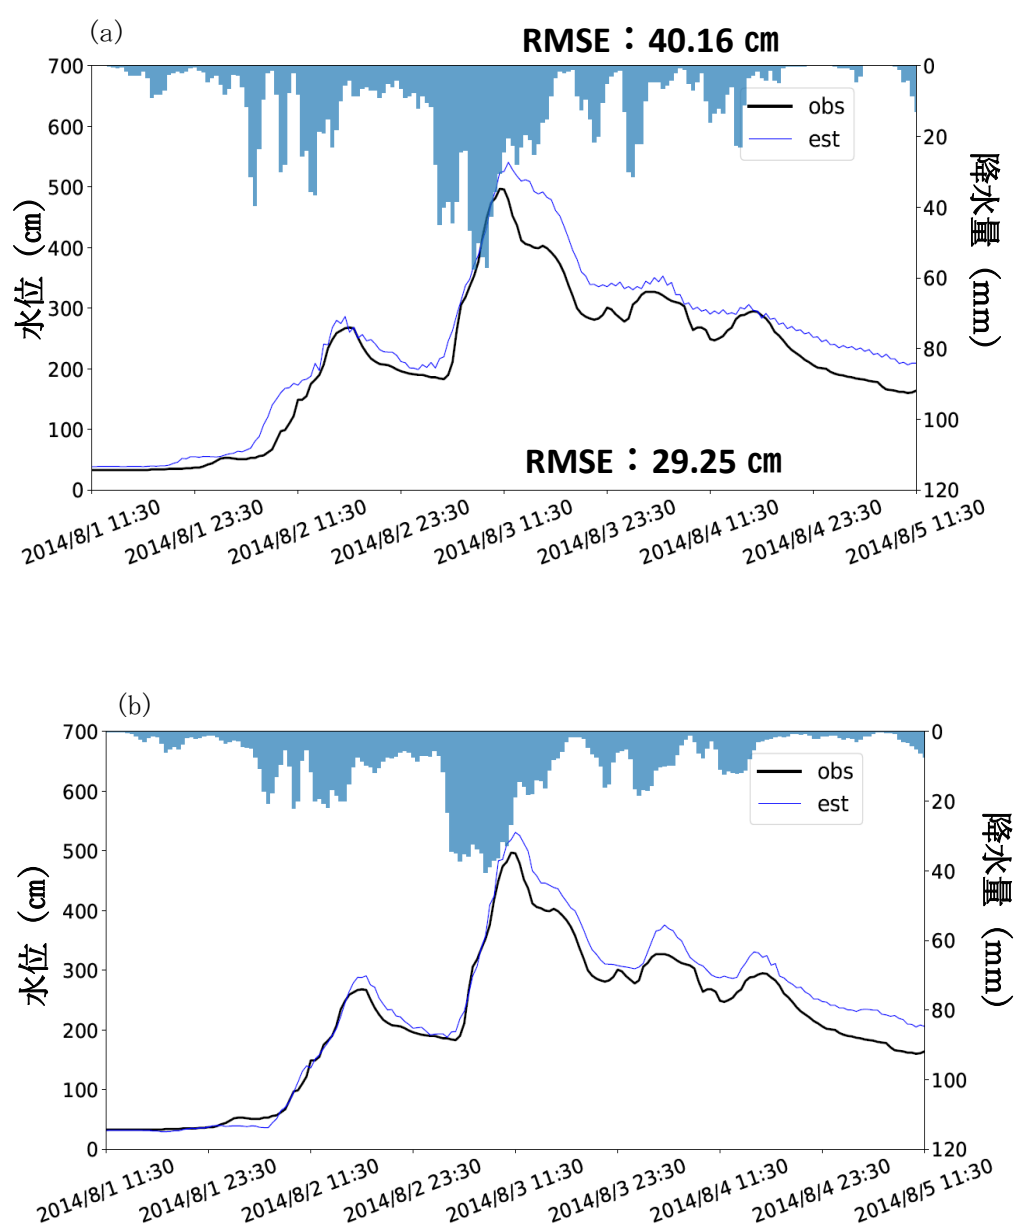


図 12 cace1 の時系列プロット (a)MLP モデル (b) $2\text{ km} \times 2\text{ km}$ CNN モデル





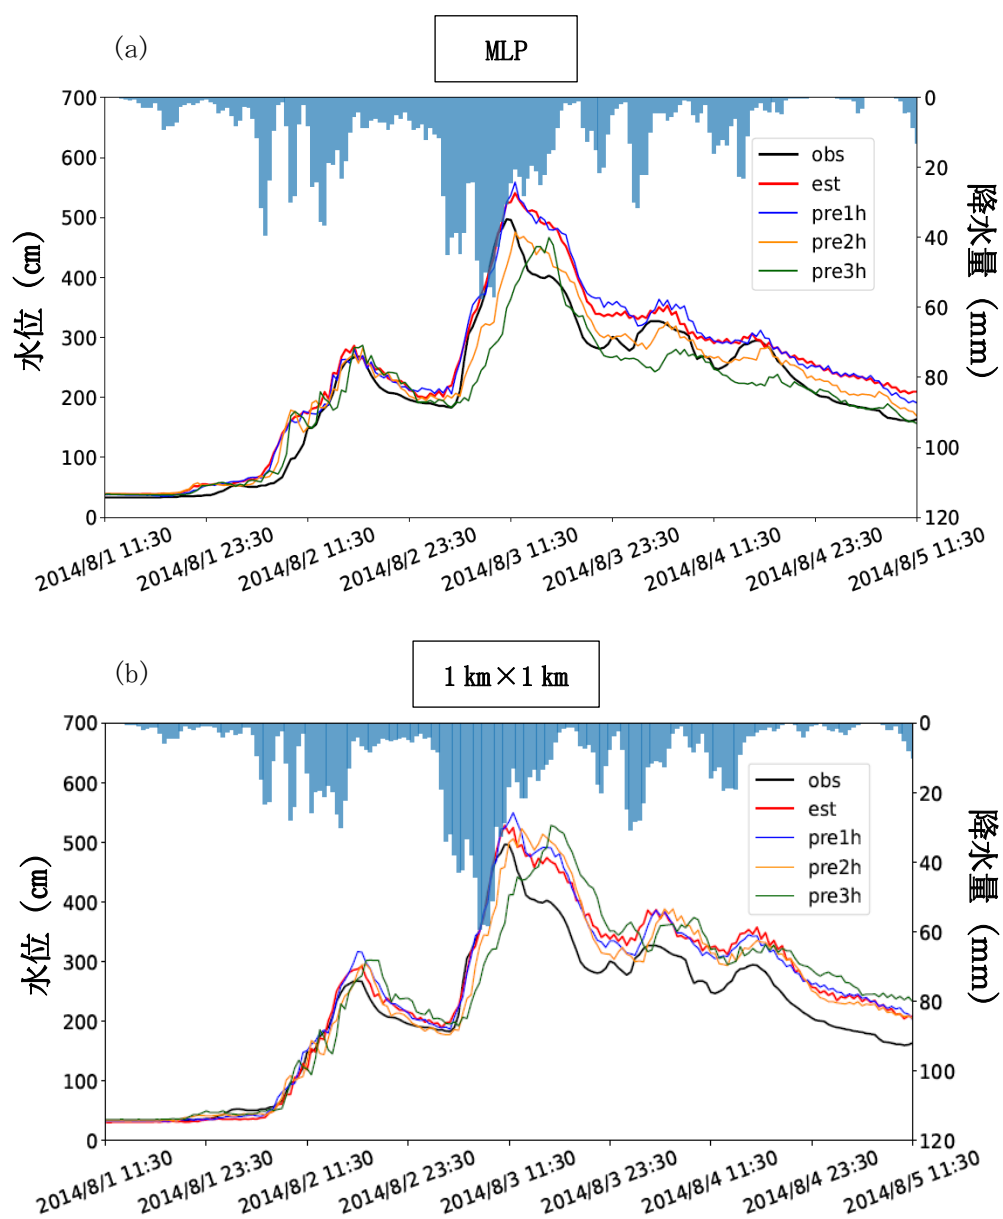
図 13 cace2 の時系列プロット (a) MLP モデル (b) 2 km × 2 km CNN モデル

Cace1 は鏡川での最大の水位を記録した際の洪水を示している。台風 12 号が高知県に接近した際の洪水である。図 12 より、MLP モデル、CNN モデル共に、洪水に対して、立ち上がりにおいて観測値に対して概ね一致しているが、ピーク、立下りにおいては両モデル過大評価であることが分かる。この理由としては、訓練データにピーク後に長期間降雨が降り続ける事例が少なかったためであると考えられる。RMSE において、MLP モデル、CNN モデル比較すると、MLP:40.16(cm)、CNN:29.25(cm)であり、CNN モデルの方が MLP モデルに比べて高精度である。次に PEP についても、MLP:8.81(%)、CNN:6.86(%)であり、RMSE と同様に CNN モデルの方が誤差は小さくピークを再現できていることが見られる。TEP については、0.5(h)～1(h)範囲であり、ピークの時刻に大きなずれはないことが分かる。

Cace2、cace1 の後に基底水位になる前に台風 11 号が接近したこと水位高が上昇した際の洪水である。図 13 より、MLP、CNN モデル共に立ち上がり、ピークにおいては概ね観測値を再現できている。しかし、立下りは共に過大評価であり、CNN モデルにおいては期間中の低水位において常に過大評価であった。RMSE については、MLP:38.59(cm)、CNN:27.01(cm)であり、CNN モデルの方が、誤差が小さいことが分かった。また、PEP においても MLP:3.89(%)、CNN:2.24(%)であり、CNN モデルの方がピークの誤差も小さい。TEP ついては、共に 0.5h のピークのずれであった。

3-4 水位予測結果

テストデータにおける洪水 2 事例において 3 時間予測を行った。推定と同様に、訓練データにない未使用のデータであるテストデータにおいて予測を行った。図 14、15 には、MLP、CNN モデルの予測結果を示している。また、領域の拡大による予測精度の違いを検証するために CNN モデルにおいては、 $2\text{ km} \times 2\text{ km}$ の予測結果だけでなく、 $1\text{ km} \times 1\text{ km}$ 、 $3\text{ km} \times 3\text{ km}$ の予測結果も図 14、15 に示している。また、図 16 は cace1, cace2 の予測時間と RMSE の関係を示している。



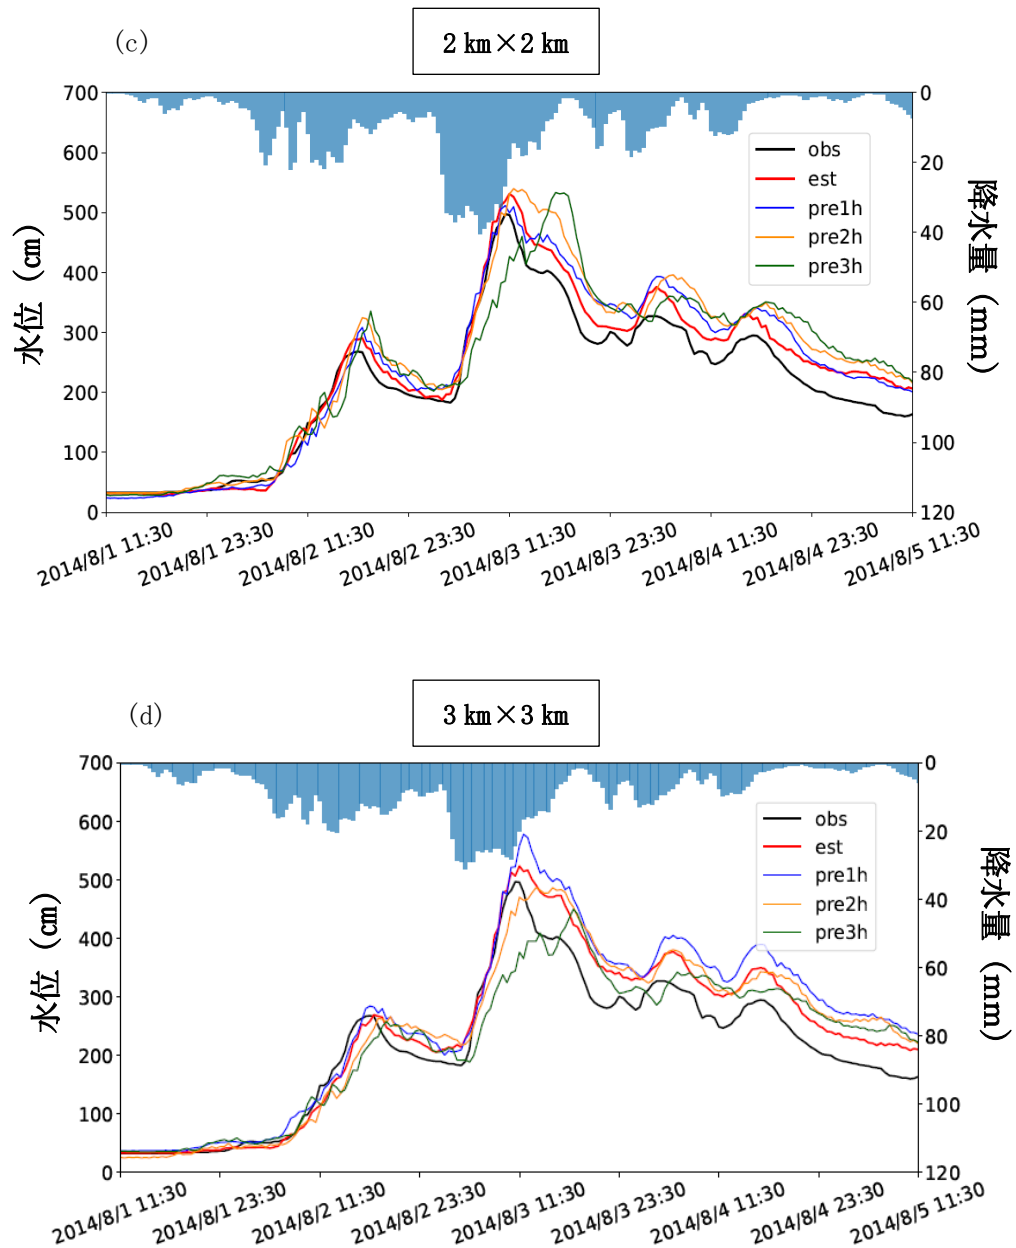
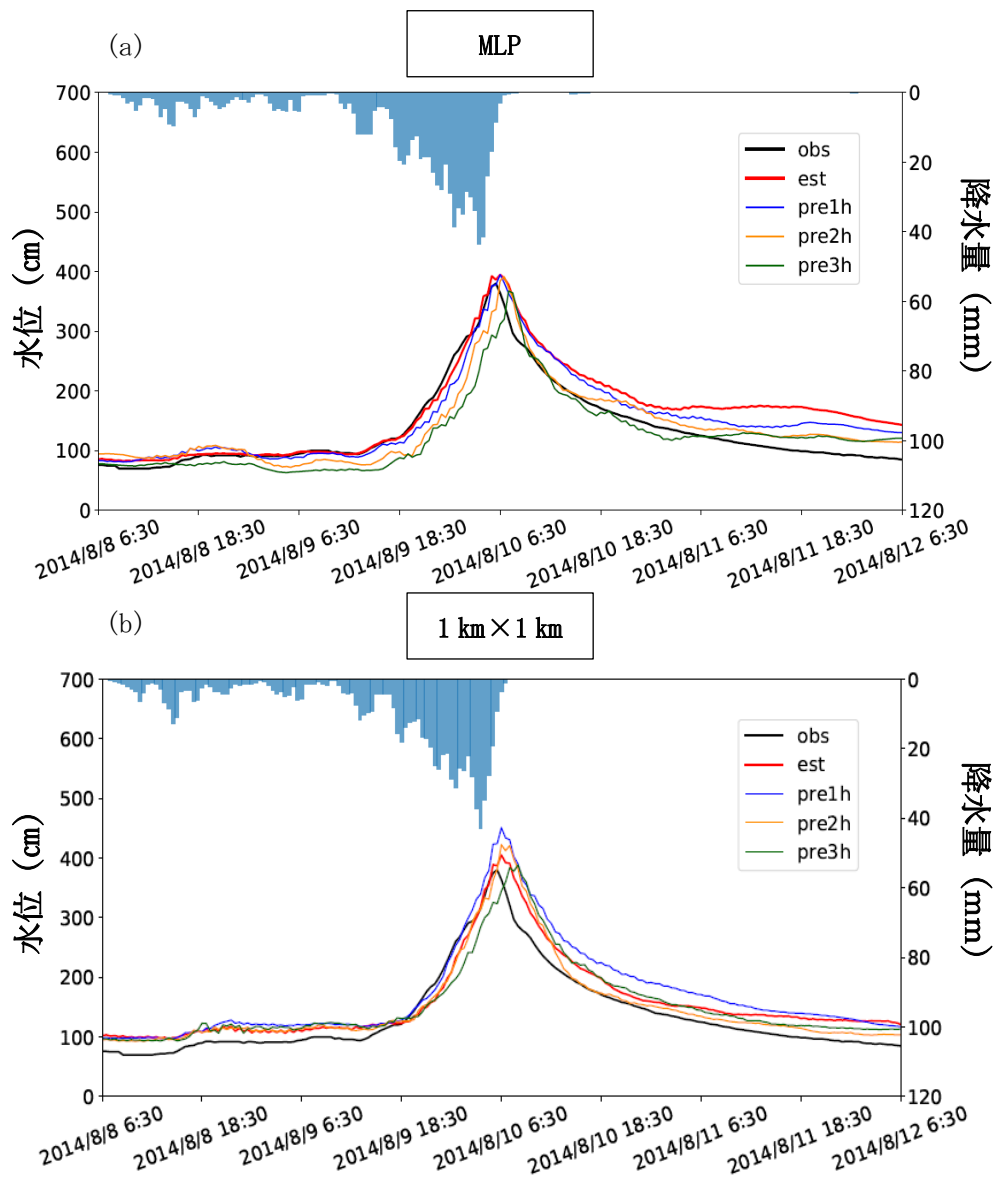


図 14 各モデル(a)MLP モデル (b) $1\text{ km} \times 1\text{ km}$ CNN モデル
(c) $2\text{ km} \times 2\text{ km}$ CNN モデル (d) $3\text{ km} \times 3\text{ km}$ CNN モデルの時系列プロット
(Cacel)



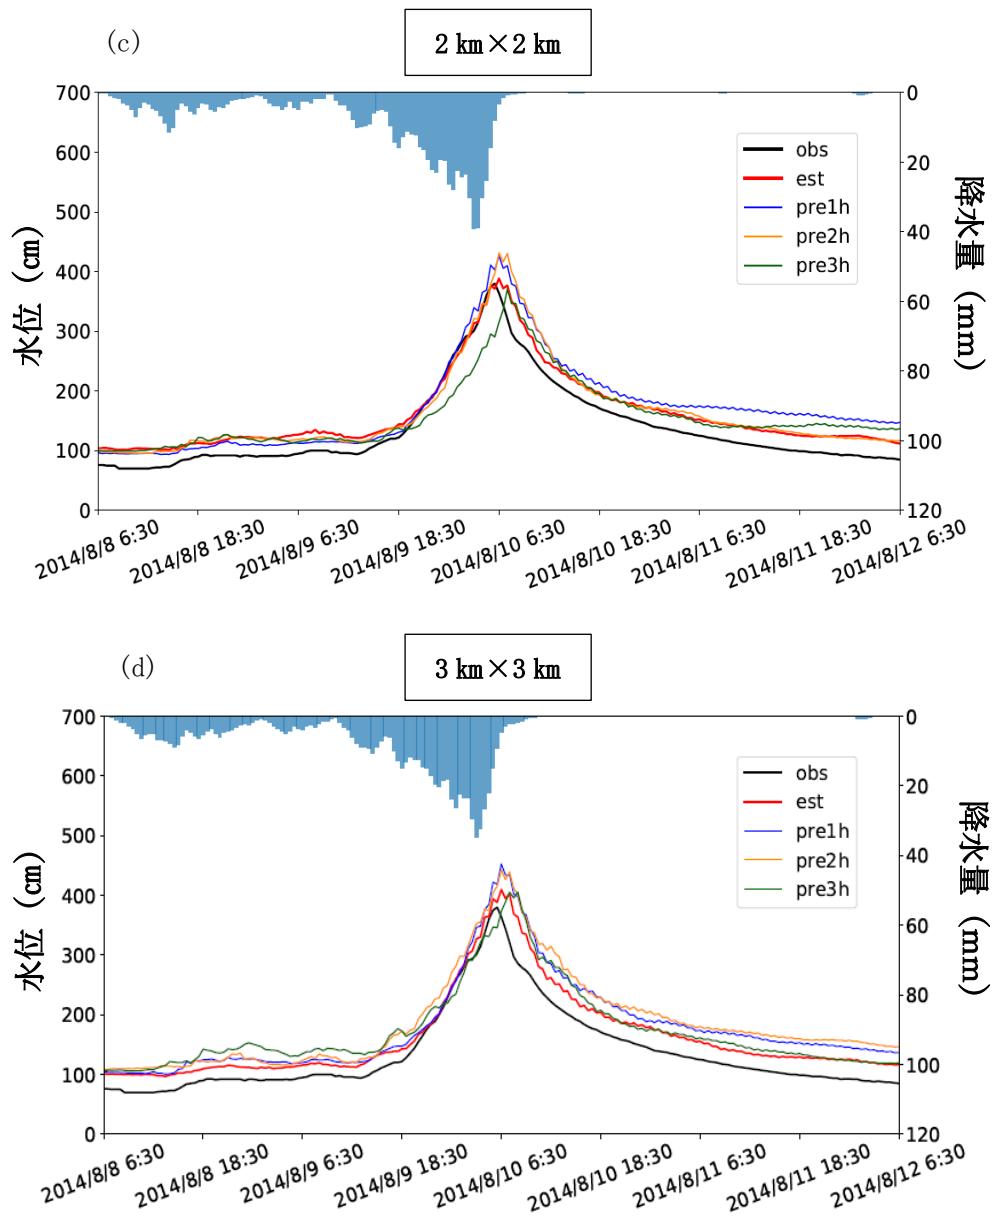


図 15 各モデル(a)MLP モデル (b) $1\text{ km} \times 1\text{ km}$ CNN モデル
(c) $2\text{ km} \times 2\text{ km}$ CNN モデル (d) $3\text{ km} \times 3\text{ km}$ CNN モデルの時系列プロット
(Cace2)




図 16 cace1, cace2 の各モデルの予測時間における推定値に対する RMSE の推移

Cace1 において、図 14 より、MLP、CNN モデル共に 1 時間予測は推定と同程度の精度で予測することが出来た。推定値に対する RMSE を比べると、MLP モデルが 9.537 (cm) であり、他の CNN モデルに比べてわずかに誤差が小さかった。しかし、MLP モデルは、2 時間予測からピークが過小評価になり、ピーク時刻にずれが生じている。また、立ち上がりもずれが生じている。一方、CNN モデルは、1 km×1 km、2 km×2 km のモデルは 2 時間予測において、観測値に対しては過大評価であるものの、推定値に対して、過小評価にならないことが確認できる。これは、領域を拡大したことで、捉えることのできる雨量が増加したからであると考えられる。しかし、3 km×3 km のモデルはわずかに過小評価になることが分かる。この理由として、3 km×3 km の範囲を平均化したことによりピークを再現するために重要な雨量が減少したことによるものであると考えられる。図 16 より、RMSE を比較すると、1 時間予測に関しては、MLP モデルが 9.537 (cm) であり、最も誤差が小さい結果となった。しかし、2 時間予測になると 32.763 (cm) となり、大幅に誤差が増大していることわかる。一方、2 時間予測に関して、CNN モデルは 1 時間予測から大幅に誤差が増大することなく、どのモデルも MLP よりも誤差が小さい結果となった。このことから、推定精度を向上することが出来れば予測精度の更なる向上ができると考えられる。しかし、1 km×1 km のモデルは、立ち上がりにわずかにずれが生じることも確認できる。3 時間以上の予測に関しては、すべてのモデルにおいてピーク時間、立ち上がりにずれが生じている。しかし、CNN の 1 km×1 km、2 km×2 km のモデルにおいては、3 時間予測においても、ピークの値が推定値のピークの値と同様に予測できている。また、RMSE においても、CNN モデルの方が MLP モデルに比べてわずかに誤差が小さい結果となった。

CNN モデルによる領域拡大の効果はあまり見られなかった。この理由としては、鏡川は流域面積が小さく、水位に影響する降雨をとらえるために必要な領域がそれほど広範囲ではないため、本研究では、1 km×1 km (21 km×16 km) の範囲で十分であったと考えられる。しかし、上流 2 地点の観測所を使用した MLP モデルに比べて、2 時間予測に大幅な改善が見られたため解析雨量を用いた面データを使用した領域全域を覆う雨量データの使用による効果は見られた。

Cace2 において、図 15 より、2 時間予測までは、MLP モデルの方がピークを再現できている。しかし、立ち上がりに関して、予測時間が増加するにつれて、時間のずれが起こっていることが分かる。一方、CNN モデルは、すべてピークを過大評価してしまっている。しかし、立ち上がりに関しては、時間的なずれはなく推定と同様に観測値に概ね一致している。3 時間予測については、どちらのモデルも立ち上がり、ピークの時刻にずれが生じていると分かる。

RMSE においては、cace1 と同様に MLP モデルは 2 時間予測から大幅に誤差が大きくなることが分かる。一方、CNN モデルは、予測時間の増加に対しても誤差の大きさにあまり違いが見られなかった。

3-5 CNN モデルの領域の重要度調査

CNN モデルにおいて、領域を拡大したことで流域を含まない部分の雨量データを使用している。その部分が予測において重要であるか調べるために、 $2\text{ km} \times 2\text{ km}$ の CNN モデルの 2 時間予測に対して調査を行った。ここで、 $2\text{ km} \times 2\text{ km}$ を選んだ理由としては、他の CNN モデルよりも RMSE は高かったものの、立ち上がりに関して観測値と概ね一致していたため、領域の変化による立ち上がりの精度の違いも調査できると考えたためである。その方法として、図 17 に示したように、入力する雨量データの外側（図 17 の黒い部分）の雨量データを 0 mm にすることで、その部分の重要度を調査した。その結果を、Cace1 の時系列プロットで図 18 に示す。

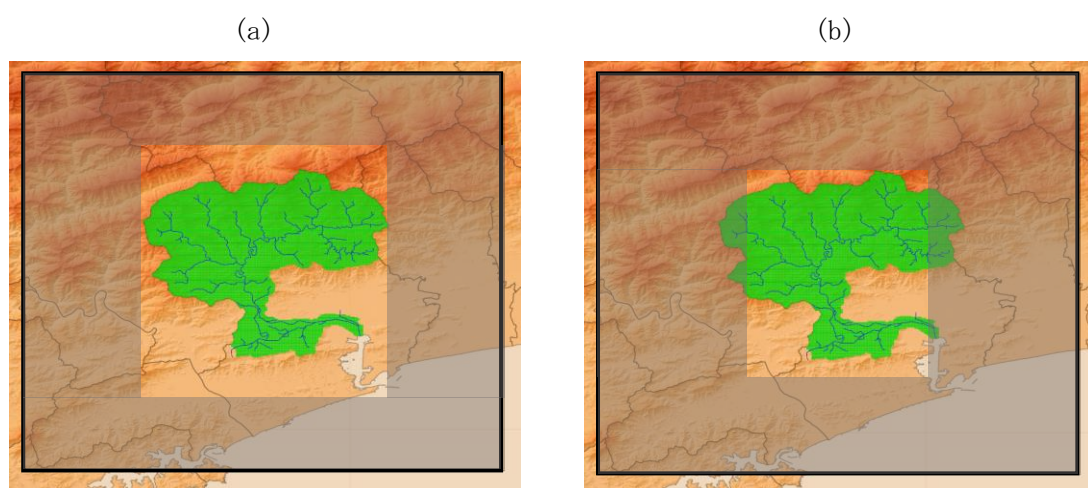


図 17 領域外側の雨量データを 0 mm にした際の流域図
(a)4grid (b)5grid

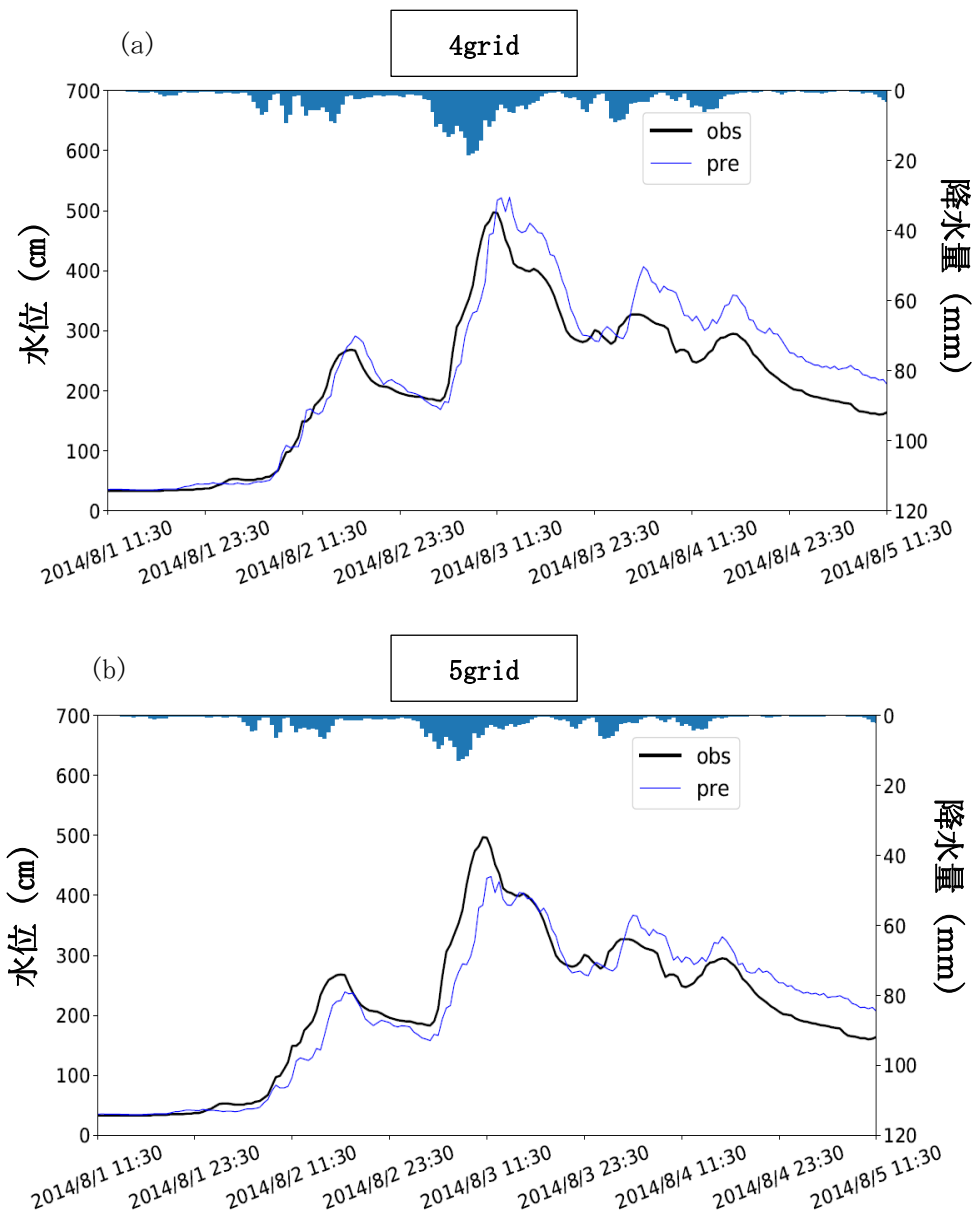


図 18 流域のある範囲の雨量データ (a)4grid 分 (b)5grid 分を 0 mm にした際の時系列プロット

図 18 より、周りから 4 grid 分のデータを 0 mm にした際と、5grid 分のデータを 0 mm に置き換えた際の結果を示している。この結果より、4grid 目のデータを 0 mm にした際に立ち上がりにずれが生じていることから、その grid に立ち上がり重要なデータが含まれていたのではないかと考えられる。また、5grid 目のデータを 0 mm にした際は、ピークが大幅に過小評価になることが見られる。そのため、5grid 目にピークを再現するために重要なデータが含まれていたと考えられる。

3-6 鏡ダムによる水位変化への影響の調査

鏡ダムと宗安寺の水位の変化を調査するために、テストデータにおける cace1、cace2 における $2\text{ km} \times 2\text{ km}$ の CNN モデルの推定結果とダムの放流量の時系列プロットを図 19 に示す。

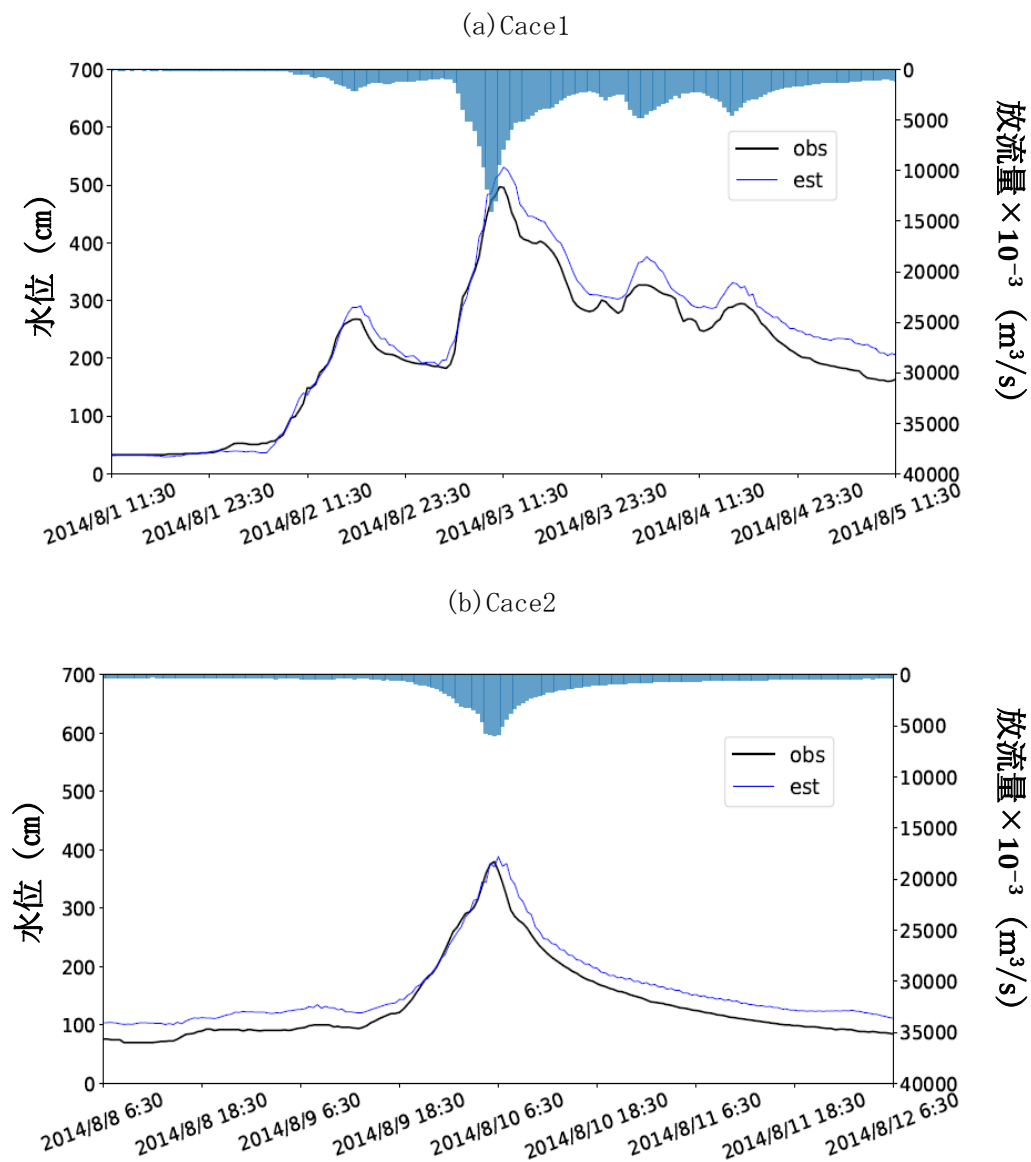


図 19 ダムの放流量と水位の時系列プロット (a) cace1 (b) cace2

図 19 より、大規模な洪水時における宗安寺の水位は、ダムの放流量の影響を大きく受ける可能性があることがわかる。しかし、本研究の推定モデルでは、入力データとしてダムの放流量を含んでいないため、ピーク後の水位過大評価につながっている可能性がある。今後はダム放流量またはダムの操作モデルを含んだモデル開発が必要である。

第4章 まとめ

・雨量時系列の遡り期間の違いによる精度の比較

中小河川である鏡川において雨量時系列データの遡り期間を 6 通りで精度の比較を行った結果、1 か月を遡るモデルが全体の RMSE において最も低く精度が高いことが分かった。また、20 パーセンタイルごとの結果より、最も高水位での精度も最も高いことが分かった。

・2 次元畳み込みと 3 次元畳み込みの精度の比較

入力データを 3 次元とした際に、CNN モデルの構造を 2 次元 CNN, 3 次元 CNN の二通りで水位推定した結果、2 次元 CNN では振動が生じたが、3 次元モデルでは良好に推定することが出来た。これは、3 次元モデルは、2 次元モデルのように畳み込み層において、畳み込み後にチャンネル方向のデータをすべて加算することなく、フィルタのチャンネル方向の数だけの加算になるため時系列データの特徴抽出処理が可能となるため振動が少なくなったと考えられる。また、3 次元モデルの時系列方向のマックスプーリングを行わないことで時系列の情報を削減することなく情報を残すことが出来るためさらに振動が減少することが分かった。

・テストデータにおける洪水 2 事例に対する推定精度の比較

テストデータ内の洪水 2 事例において、MLP モデルと CNN モデルで水位推定を行った。その結果、両モデルとも観測値と概ね一致して推定できているが、2 事例共に CNN モデルの方が MLP モデルに比べ、誤差が小さいことが分かった。また、CNN モデルにおいて、領域を拡大した結果、推定に関しては大きな差なく、その中でも、2 km×2 kmの推定が最も誤差が小さかった。最大水位を観測した cace1 において、両モデルでピーク後の過大評価が見られた。これは、訓練データにピーク後に長期間降水が続く事例が少なかったためであると考えられる。

・水位予測結果

テストデータ内の洪水 2 事例において、MLP モデルと CNN モデルで水位予測を行った結果、MLP モデルは先行研究と同様に 1 時間予測までは推定値と変わらず予測することが出来た。しかし、2 時間以降の予測に関しては、推定値に対する RMSE が著しく悪化し、立ち上がりに時間のずれが生じ、ピークの過小評価が見られた。一方、CNN モデルではすべてのモデルにおいて、2 時間予測までピークに関しては推定値に対して小さい誤差で予測することができた。2 時間予測に関して、MLP のような推定値に対する RMSE が著しく悪化することはなかった。領域を拡大した結果、1 km×1 kmの場合は、立ち上がりに時間のずれが生じた。2 km×2 kmの場合、ピークの値を過大評価したが、立ち上がりの時間のずれは生じなかった。3 km×3 kmの場合は、立ち上がりのずれはなかったがピークを過小評価する結果となった。このように、面データを使用した CNN モデルにしたことで雨域の移動ベクトルを捉えると

ことが出来たため過小評価にならなかった可能性はある。立ち上がりとピーク値の観点から、上流 2 地点のMLPモデルより面データを用いるCNNモデルのほうが、予測時間が 1 時間長くなる結果となった。しかし、鏡川では流域面積が小さく洪水到達時間が約 2 時間半であることから、3 時間予測では水位ピークを再現するための入力情報が空間分布から得られない可能性がある。このため、CNN モデルの領域拡大による予測精度の向上は見られなかったと考えられる。

・CNN モデルの領域の重要度調査

立ち上がりを最も再現できていた $2\text{ km} \times 2\text{ km}$ の 2 時間予測に関して、領域 ($42 \times 32\text{ km}$) の重要度を調査するために入力データの範囲の外側の降雨を 0 mm に設定して予測を行った結果、外側 4grid 分を 0 mm にした際、立ち上がりに時間のずれが生じた。また、さらに 1grid 分を 0 mm にするとピークを過小評価することが分かった。このように、領域を拡大したことで立ち上がりやピークに重要なデータを含むことが出来たと考えられる。

今後の課題として、下記が挙げられる。

- ・本研究の対象である鏡川は流域面積が小さいため、領域を拡大したことによる 3 時間以降の予測精度の向上は顕著に現れなかった。本研究モデルを流域の大きい河川に適用し、雨域の移動ベクトルが捉えられるか検討する必要がある。

- ・宗安寺の水位は鏡ダムの影響を大きく受ける。しかし、本研究では、ダムの情報を入力として陽に含まずに学習しており、テストデータの最大水位事例 Cace1 においてピーク後の過大評価が見られたが、その結果がダムの貯水による影響であるかどうかまで調査できていない。実用化には、ダムの操作モデルや放流量を陽に含むモデルを開発する必要があると考える。

謝辞

本研究を行うにあたり、高知工科大学環境理工学群端野典平准教授には、多大なご指導をいただきましたことに深く御礼申し上げます。

端野研究室の先輩である若槻祐貴氏には、セミナー等で様々なアドバイスをいただきましたことに深く感謝します。

本研究を進めるにあたり、共に協力し支えあった端野研究室のメンバーに感謝します。

雨量及び水位観測データを提供して下さった高知県土木部河川課に深く感謝します。

参考文献

中根英昭, 若槻祐貴, 山本啓, 武田拓己, 端野典平. 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 巻 227 - 244 2019

Shen, C., 2018. A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. Water Resources Research. Volume 54, Issue 11 8558-8593

気象庁. 気候変動監視レポート—2019 2020. 7. 17

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の開発, 土木学会論文集 B1(水工学) 2017

国土交通省: 川の防災情報

(http://www.river.go.jp/kawabou/reference/indexall_ip.html)

(2019. 3. 10 アクセス)

気象庁. 解析雨量

(<https://www.jma.go.jp/jma/kishou/known/kurashi/kaiseki.html>)

(2019. 3. 10 アクセス)

若槻祐貴. 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 令和2年度 高知工科大学環境理工学群 修士卒業論文 2020

瀧 雅人. これならわかる深層学習 入門 2017. 10. 20