

博士論文

ニューラルネットワークと物理型モデルを用いた
実時間洪水予測の精度向上に関する研究

一言 正之

－ 目 次 －

1.	序論	1
1.1.	研究背景	1
1.2.	洪水予測に関する既往研究と問題点	2
1.2.1.	流出解析技術を基盤とした洪水予測手法	3
1.2.2.	統計的手法による水位の直接予測手法	5
1.3.	本研究の目的	6
2.	従来型ニューラルネットワークによる河川水位予測の精度向上	7
2.1.	ニューラルネットワークの概要	7
2.1.1.	ネットワーク素子（ニューロン）のモデル化	7
2.1.2.	ネットワーク形態のモデル化	9
2.2.	河川水位予測のためのニューラルネットワークの構成	10
2.2.1.	ネットワーク形態の決定	10
2.2.2.	ネットワークの構造	10
2.2.3.	ニューラルネットワーク水位予測モデルの構築手順	13
2.2.4.	ネットワークの学習手順	14
2.3.	ニューラルネットワークの入力層選定に関する検討	17
2.3.1.	対象流域の概要	17
2.3.2.	対象データ	18
2.3.3.	モデルの概要	19
2.3.4.	入力層の選定	19
2.3.5.	ANN 洪水予測の精度検証	23
2.3.6.	入力層選定についてのまとめ	26
2.4.	ニューラルネットワークのネットワーク構成、学習回数に関する検討	27
2.4.1.	対象データ	27
2.4.2.	ANN 洪水予測手法の概要	31
2.4.3.	予測モデルのケーススタディ	33
2.5.	アンサンブル学習に関する検討	40
2.5.1.	対象流域	40
2.5.2.	対象洪水	40
2.5.3.	ニューラルネットワークの設定	40
2.5.4.	ケーススタディによるニューラルネットワークの決定	41
2.5.5.	アンサンブル学習の実施手順と精度評価	42
2.5.6.	アンサンブル学習のまとめ	43
2.6.	従来型ニューラルネットワークによる河川水位予測のまとめ	44

3.	深層学習を適用したニューラルネットワーク水位予測モデルの開発.....	45
3.1.	深層学習を用いた河川水位予測手法.....	45
3.1.1.	ニューラルネットワークの構成.....	45
3.1.2.	学習方法の詳細.....	46
3.1.3.	ネットワークの事前学習.....	48
3.2.	実流域への適用.....	49
3.2.1.	大淀川流域でのケーススタディ.....	49
3.2.2.	遠賀川流域でのケーススタディ.....	62
3.3.	深層学習を適用した河川水位予測手法のまとめ.....	70
4.	物理的手法の適用と、粒子フィルタによる同化手法の検討.....	71
4.1.	分布型モデルの開発.....	72
4.2.	観測データによる水位予測の補正手法.....	84
4.3.	洪水予測モデルへのフィルタリングモデルの組み込み.....	85
4.3.1.	粒子フィルタの概要.....	85
4.3.2.	粒子フィルタとアンサンブルカルマンフィルタの比較.....	89
4.3.3.	流出解析モデルへの粒子フィルタの適用.....	90
4.4.	物理型分布型モデルへの粒子フィルタによる同化手法の適用.....	92
4.4.1.	検討対象の概要.....	92
4.4.2.	モデルの構築.....	92
4.4.3.	再現計算の実施.....	98
4.4.4.	再現計算の結果.....	99
4.4.5.	計算時間の検討.....	109
4.5.	物理的手法の適用と、粒子フィルタによる同化手法の検討のまとめ.....	110
5.	各種水位予測モデルの比較検討.....	111
5.1.	検討対象.....	111
5.2.	比較対象とした水位予測モデル.....	111
5.2.1.	精度比較対象とした統計的水位予測モデルの概要.....	112
5.2.2.	精度比較対象とした物理的水位予測モデルの概要.....	115
5.3.	精度評価.....	116
5.4.	モデルの比較検討のまとめ.....	123
6.	深層学習と物理的手法のハイブリッド水位予測の開発.....	124
6.1.	深層学習による水位予測の課題.....	124
6.2.	ハイブリッドモデルの開発.....	125
6.2.1.	貯留関数法から学習モデルへのアナロジー.....	125
6.2.2.	相関分析による入力因子の検討.....	125
6.2.3.	ハイブリッドモデルの条件設定.....	128

6.3.	ハイブリッドモデルの計算実施	129
6.3.1.	計算条件の設定	129
6.3.2.	ケーススタディの実施	130
6.4.	ハイブリッドモデルと深層学習モデルの比較	131
6.5.	ハイブリッドモデルの計算結果の考察	137
7.	結論	140

1. 序論

1.1. 研究背景

我が国は国土の 7 割を山地が占めており、わずかな低平地に人口が集中している。また日本はアジア・モンスーン地域に属し、温暖で降水量が多く、特に梅雨や台風の時期に集中的に豪雨がもたらされる。こうした背景から、我が国は洪水氾濫に対するポテンシャルが非常に高く、全国各地で洪水氾濫の被害が頻発している。

洪水氾濫の被害を軽減するための対策として、これまでに河道の拡幅、堤防の整備、放水路の建設、洪水調整のためのダムや遊水池などの建設が進められており、治水安全度は着実に向上してきている。こうしたハード対策と並んで、ハザードマップや防災教育・訓練、警戒避難に資するための雨量・河川水位の情報配信、といったソフト対策が併せて進められている（国土交通省，2015a）。特に、流域面積が大きく洪水より大きな被害のリスクがある河川では、指定河川として洪水予報を行うことが水防法により定められており、危険度レベル（図 1-2）に応じた洪水予報が発表されている。ソフト対策のための基本ツールとして、一級水系を始めとする全国の主要な河川で実時間洪水予測システムが導入されている（椿，2013）。

洪水時の切迫した状況において適切な避難判断を行うためには、洪水予測により先の時刻の水位を知ることが重要である。しかしながら、迷わずに避難勧告や交通規制等を決断するためには、極めて高い精度の水位予測が求められる。

以上の背景より、洪水予測の精度向上・信頼性向上のため、水文観測などの設備投資や、予測モデルの開発が研究されている。特に、高精度な実時間洪水予測シミュレーションは水防の現場で強く要望されているものの一つである。



図 1-1 2015 年関東・東北豪雨における鬼怒川の被災状況（国土交通省，2015b）

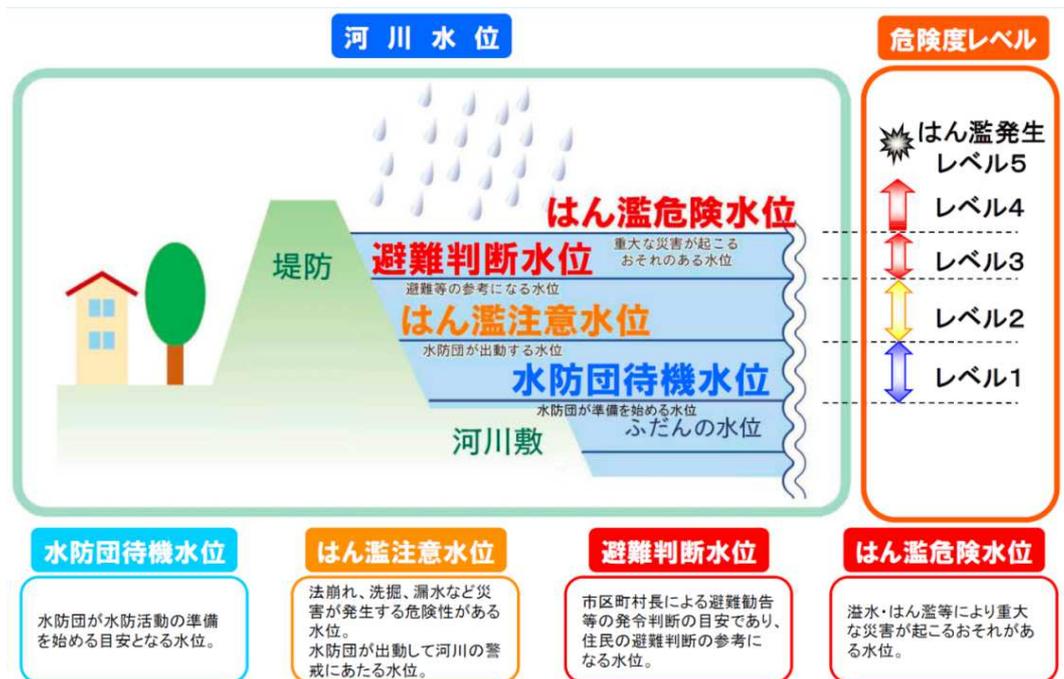


図 1-2 洪水発表の基準となる河川水位および危険度レベル（国土交通省，2007）

1.2. 洪水予測に関する既往研究と問題点

洪水予測の精度向上に向けて、国内では、XバンドMPレーダの導入、より詳細な地形データ、土地利用、地質情報などのデータベース化により、さらに高度な解析が可能となってきている。また、近年の計算機性能の向上に伴い、より精緻かつ大規模な演算が可能となってきている。

洪水予測手法として、様々なモデルが開発されてきた。大きく2つに分類することができる。一つは降雨から流出流量を評価する流出解析技術を基盤とする手法であり、もう一つは上流下流の水位の相関関係などから統計的手法に基づき評価地点の水位を直接予測する手法である（椿、2013）。さらに流出解析を基盤とした手法は、概念モデルによるものと、物理型モデルによるものとに分類される。洪水予測手法の分類を表 1-1に示す。各手法について、以下に概要を示す。

表 1-1 洪水予測手法の分類

大分類	中分類	小分類	長所	短所
直接 水位 予測 手法	統計 手法	時系列解析（線形回帰、AR、ARMA、ARIMA、等）	モデル構築が簡便、 計算が簡易	降雨一流出の非線形性を表現できない
		機械学習 （ANN、SVM、など）	非線形性を含めた高い表現 能力、豊富な使用実績	計算過程がブラックボックス、デ ータが多く必要
	その他	その他（ファジィ、事例ベ ース、など）	最新の知見を反映	実用化の実績が少なく、適用性・ 発展性が不明
流出 モデル	概念 モデル	単位図法	計算が簡単	降雨一流出の非線形性を表現できない
		タンクモデル	計算が比較的簡単、様々な流 出波形を表現できる	パラメータの物理性が弱い
		貯留関数	計算が比較的簡単、全国の洪 水予測システムで実績	パラメータの物理性が弱い
	物理 モデル	分布型モデル	降雨 - 流出の過程を詳細に 表現、 地形や降雨の分布を反映	モデル構築・チューニングが大 変、フィードバックが容易でない
	その他	概念モデルを分布させたモデルなど、様々な手法が考えられる		

1.2.1. 流出解析技術を基盤とした洪水予測手法

(1) 流出解析モデルの分類

流出解析モデルとして、大きく分けて分布型流出モデルと概念型の流出モデルに分けられる。概念型の流出モデルは、タンクモデル（菅原，1972）、貯留関数モデル（木村，1962）、等が提案されている。分布型モデルは様々なタイプのものが開発されており（例えば、鈴木ほか，1996；立川ほか，2004）、我が国でも全国の一級河川でリアルタイム洪水予測に適用されている。分布型モデルの中でも、各メッシュを概念的に扱うモデル（例えば、鈴木ほか，1996）から、不飽和帯の地下水解析の適用などにより、物理的に忠実に水文過程を追跡するモデル（例えば、Tosaka et al., 2000）が提案されている。

(2) 観測データを用いた実時間補正手法

これまでに様々な流出解析モデルが開発されてきたが、どれほど高精度なモデルを構築しても、予測に際しては様々な誤差要因がある。主なものとして、モデル自体の誤差、パラメータの誤差、入力情報（実測・予測降雨）の誤差、水位・流量の観測誤差などが挙げられる。

実時間洪水予測においては、過去の予測情報と現在時刻の観測情報を比較することが可能である。これにより、予測モデルの適合性を検証し、観測情報に適合するように予測モデルをリアルタイムに修正することが可能である。こうした精度向上の方法には様々な手法が考えられてきた。

Hino (1970) は、単位図法を用いた流出モデルに、カルマンフィルタ (Kalman, 1960)

を適用した。日野（1974）は貯留関数にカルマンフィルタを適用した。カルマンフィルタの問題点として、適用範囲が線形の問題に限られている、非線形の強い流出解析への適用は難しい。非線形問題への応用を目指し、拡張カルマンフィルタ（Jazwinski, 1970）の適用が進められてきた。Wood et al.（1978, 1980）は、概念型の流出モデルに拡張カルマンフィルタを適用した。また高棹ほか（1984）はタンクモデルに拡張カルマンフィルタを適用した。しかしながら、拡張カルマンフィルタもやはり非線形の強い問題には適用性が悪いことが指摘されている（Evensen, 1994）。Moradkhani et al.（2005a）は、より非線形の強い問題を扱うため、カルマンフィルタを拡張したアンサンブルカルマンフィルタ（Evensen, 1994）を、比較的構造の単純な流出モデルに適用した。

近年は、非線形・非ガウス型の状態空間モデルのフィルタリング手法として、粒子フィルタの適用が研究されている。Moradkhani et al.（2005b）は、タンクモデルを組み合わせた概念モデル（HyMOD）に粒子フィルタを適用している。Smith et al.（2008）は、3種類の概念モデルに粒子フィルタを適用し、モデルの構成（性能）による粒子フィルタの適用性に違いを議論している。工藤ほか（2011）は、集中型流出モデルと河道内の流れを追跡する河道流モデルを組み合わせた流出モデルに、拡張カルマンフィルタと粒子フィルタを組み合わせ適用し、予測精度向上を図っている。立川ほか（2011）は、不定流モデルに粒子フィルタを適用し、河川水位予測への適用を図っている。DeChant et al.（2012）は、シンプルな概念モデル（HyMod）と、地下水まで概念化したモデル（SAC-SMAモデル）に粒子フィルタを適用し、精度を比較している。高崎ほか（2012）は貯留関数モデルに粒子フィルタを適用し、都市中小河川における適用性を検討している。

複数の同化手法を比較した研究として、Weerts and El Serafy（2006）は、概念モデル（HBVモデル）に粒子フィルタとアンサンブルカルマンフィルタを適用した。比較結果として、少ない粒子数ではアンサンブルカルマンフィルタが勝るが、粒子数が多い場合は粒子フィルタの方が勝る結果を報告している。Liu and Guputa（2007）、Liu et al.（2012）は、水文モデルにおけるデータ同化手法について整理しており、現状と課題を挙げている。その中で、特に物理ベースの分布型モデルでは、粒子フィルタでは状態量の操作が不要なため、カルマンフィルタを基盤とした手法よりも数値不安定が起こりにくいことを利点として挙げている。

このように、流出モデルの同化手法として様々な手法が研究されている。近年は、粒子フィルタの適用に関する研究事例が豊富であり、適用性の広さや実装の容易さの面などからも最も有力な手法の一つと考えられる。

粒子フィルタを分布型モデルに適用した事例は比較的限られる。Noh et al.（2011, 2012）は分布型モデル（WEPモデル）に流出の時間差を考慮した粒子フィルタを適用している。田中・杉浦（2012）は、タンクモデルを組み合わせた分布型モデル（土研

分布型モデル) に粒子フィルタを適用し、誤差上乘せ方式との精度比較を行っている。田中ほか (2013) は、土研分布型モデルに粒子フィルタを適用し、予測雨量の誤差分布を粒子フィルタで表現することを試みた。

なお多くの研究で、フィルタリングによる補正対象はモデル状態量(地中の水分量などに相当する値)となっている。したがって、地下水中の土壌水分分布を適切に表現するモデルを用いることは本質的に重要であると考えられる。一方で、多くの分布型モデルでは地下水の取り扱いが概念化・簡略化されているものが多い。地下水・地表水の両方を水理的に扱うモデルは比較的少なく (Tosaka et al., 2000; Morita et al., 2000; Therrien et al., 2010)、こうしたモデルに対する粒子フィルタの適用は今後の課題の一つである。

1.2.2. 統計的手法による水位の直接予測手法

(1) 統計的手法による水位予測手法の概要

リアルタイムに得られる観測情報を用いて、統計的な手法で水位予測を行う手法も研究されている。統計的な手法では、降雨流出過程の表現はブラックボックス的になるが、物理的な手法に比べて計算が比較的簡易な場合が多く、また HQ 式による誤差を介在しないメリットがある。

統計的な洪水予測手法として、古くは AR、ARMA などの時系列解析 (Box and Jenkins, 1970) や、水位相関法などが用いられてきた。これらの手法には、降雨一流出の非線形性を表現できないという欠点があった。日野・長谷部 (1985) は、線形分離 AR フィルターにより非線形性を考慮できるように改良を加えている。1990 年代ごろからは、ニューラルネットワーク (Artificial Neural Network : ANN) による洪水予測の研究が盛んになっており、これまでに多数の研究・応用事例がある。

(2) ニューラルネットワークによる洪水予測

Maier and Dandy (2000) や Dawson and Wilby (2001) は、既往論文のレビューより、水理・水文分野における ANN の有用性を確認しつつ、以下の 4 つの主な課題を指摘している。すなわち、①学習データと検証データの分離、②学習回数の適切な設定、③学習パラメータや入力層、中間素子数の適切な設定、④入力データの正規化、等をモデル構築の際に注意すべき点として挙げている。さらに、Maier et al., (2010) は 1999-2007 年の水理・水文に関する ANN の論文のレビューを行っている。近年の事例から ANN 実施における様々な注意点を整理しており、特にモデルの入力データの選定やネットワーク構造の設定、モデルの不確実性などは重要な課題として挙げられている。また今後の研究課題の一つとして、ANN と他の手法を組み合わせたハイブリッドモデルの研究が挙げられている。国内における適用事例として、磯部ほか (1994)、稲吉ほか (2003)、槻山ほか (2003)、春原ほか (2006)、高崎ほか (2011)、竹村ほか (2013) が ANN による河川の水位予測を行っているが、入力層選定などモ

デルの設定方法については議論の余地が残されている。

一般に、国内の主要河川流域では、雨量・水位観測データは時空間的に多数存在しており、ANN の学習能力の限界から全てのデータを扱うことは難しく、適切なデータ選定のプロセスが必要となっている。また、ネットワーク構造を大きくすることでモデルの表現力は増大するが、適切な学習がより困難となり精度向上は容易ではない。また統計的手法の一つである ANN の一般的な課題として、過去に経験していない事例に対しては予測精度が落ちることが知られており、洪水予測モデルにおける課題の一つとなっている。

一方で、ANN の新しい学習方法として深層学習と呼ばれる手法 (Hinton,2006) が注目を集めている。深層学習は近年になって開発されたニューラルネットワークの学習手法の一つであり、注目を集めている。深層学習の特徴として、学習モデル自らが、大量の入力データの中から本質的な情報の抽出を行うことが挙げられる。深層学習は、画像認識や音声認識、自然言語処理など様々な分野で研究が進められているが、河川の水位予測に深層学習を適用した事例は見られない。

1.3. 本研究の目的

本研究では、河川水位予測の精度向上・信頼性向上を目的として検討を行った。特に、リアルタイムに得られる観測情報を有効に活用した実時間予測に主眼を置き、統計的手法、物理的手法の両アプローチから検討を行った。

統計的な水位予測手法については、最も盛んに研究が行われているニューラルネットワークに焦点を当てた。まず既存研究のレビューから、ANN 実施において陥りやすい課題と対応方法について整理し、事例検討により精度向上と適用性の検討を行った。続いて、近年様々な分野で応用がすすめられている深層学習の技術を用いた、ANN 河川水位予測モデルを開発した。深層学習を適用した ANN と、従来型の ANN との比較を行い、深層学習による予測精度の向上を確認した。

物理的な水位予測手法については、地下水・地表水の両方を水理的に扱うモデルを洪水予測に適用するため、飽和・不飽和過程を組み込んだ分布型流出モデルを構築した。続いて、構築したモデルに粒子フィルタを適用し、水位予測への適用性を確認した。

最後に、構築した深層学習型の ANN と、粒子フィルタを適用した物理型モデルとを組み合わせたハイブリッドモデルを開発し、それぞれのモデルを上回る予測精度を確認した。

2. 従来型ニューラルネットワークによる河川水位予測の精度向上

2.1. ニューラルネットワークの概要

ニューラルネットワークとは、人間の神経回路を模倣して数理的にモデル化したものである。ニューラルネットワークは非線形回帰分析やパターン認識など、ノイズを含んだ非線形のデータ処理を得意としている。また、高い学習能力もニューラルネットワークの大きな特徴である。学習とは、必要とされる機能を、提示される例（訓練）に基づき自動形成する能力のことである。水文分野においても、非線形な降雨-流出関係を、学習によって表現できることが知られている。

2.1.1. ネットワーク素子（ニューロン）のモデル化

ネットワーク素子の概念図を図 2-1 に示す。ニューラルネットワークは神経回路を構成する最小単位である神経細胞（ニューロン）を多数並列に接続されたシステムを数理的にモデル化したものである。ニューラルネットワークの構成要素は形式ニューロン（ネットワーク素子）である。ネットワーク素子はニューロンの数理的モデルで、次のようなニューロンの機能に着目してモデル化している。

- 樹状突起とシナプスによる情報の修飾
- 細胞体内での信号の加算
- 出力信号の生成

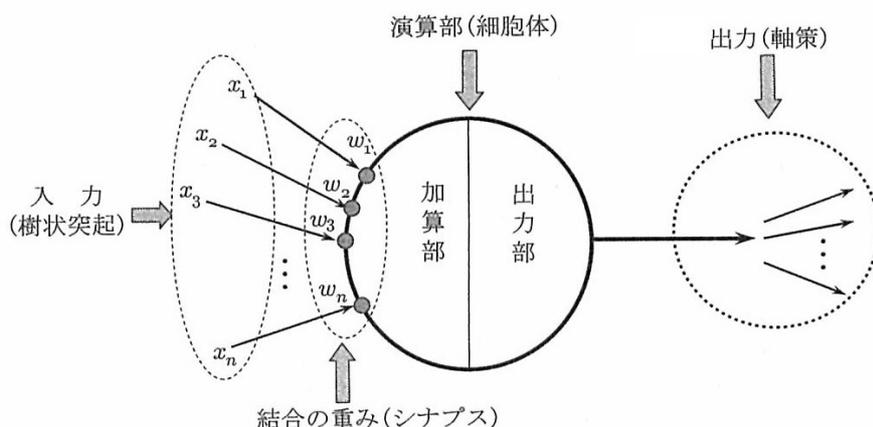


図 2-1 ニューラルネットワーク（ニューロン）の構造概念

図 2-1の、 $x_1, x_2, x_3 \cdots x_n$ は樹状突起による入力信号であり、 $w_1, w_2, w_3 \cdots w_n$ はそれぞれ入力信号に対応するシナプスの結合の重みである。加算部ではそれぞれの入力値 x_i に重み w_i を掛けた代数和 $u = \sum_{i=1}^n w_i x_i$ を求め、出力部は出力信号 $f(u)$ を生成する。形式ニューロンでの入力と出力との関係は、例えば次のようなステップ関数やシグモイド関数を用いて表現できる。

$$y = f(u) = \begin{cases} 1 & u \geq \theta \\ 0 & u < \theta \end{cases} \dots\dots\dots (2.1)$$

$$y = f(u) = \frac{1}{1 + e^{-u}}, \text{ (ただし、 } u = \sum_{i=1}^n w_i x_i \text{) } \dots\dots\dots (2.2)$$

階段型関数とシグモイド関数のグラフを図 2-2に示す。出力関数 $y = f(u)$ は u の関数であり、 u は入力変数 x_i と重み w_i の線形結合である。ニューラルネットワークにおける結合の重み w_i としては、初めの段階ではランダムな値が与えられ、得られた結果を何らかの方法で評価を行い、結果が目標値に近づくように重みを換える計算を繰り返す、徐々に最適な値に置き換えられる。このような目標値と比較しながら計算を繰り返し最適値を求めることを、機械学習という。ニューラルネットワークは、このような形式ニューロンの相互結合により情報の転送・処理を行う。ニューラルネットワークが最も得意なのは、パターン認識・分類、およびノイズが混在しているデータの処理である。ニューラルネットワークが最も早く応用されたのは、手書き文字の識別を含む画像のパターン認識、音声認識などの情報工学に関する分野であった。その後医学の病気の診断、財務分析、経済分析、市場分析や人文科学への応用も進められている。

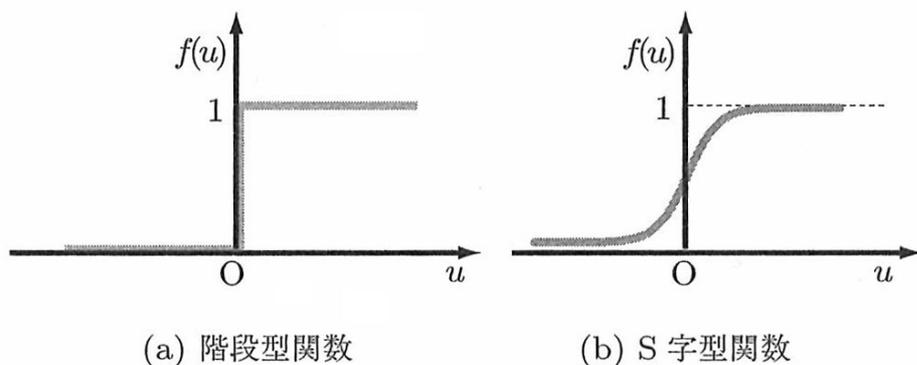


図 2-2 出力関数の例（階段型関数とシグモイド関数）

2.1.2. ネットワーク形態のモデル化

図 2-3のように素子を接続し、入力信号が入力側から出力側に向けて一方向に伝達するように構成したモデルをフィードフォワード型ニューラルネットワークと呼ぶ。フィードフォワード型ニューラルネットワークでは、入力側の値を指定すると、そこから出力層に向けて素子の値が次々と求まる。

一方、ある素子の出力が時間遅れを伴って入力側にフィードバックしてくるような構成のモデルをリカレント型ニューラルネットワーク（図 2-4）と呼ぶ。リカレント型ニューラルネットワークでは、前ステップの計算結果が次ステップに反映されるため、時系列に相関を持つ問題に対して有効とされている。一方で、リカレント型ニューラルネットワークは一般に学習の計算効率の観点からは不利とされている。

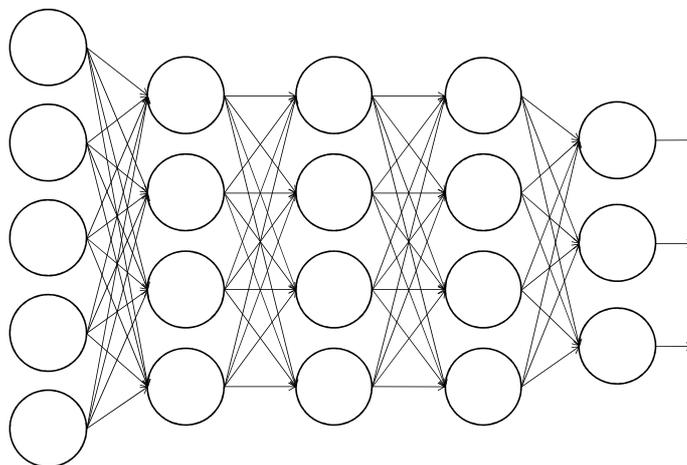


図 2-3 フィードフォワード型ニューラルネットワークの例

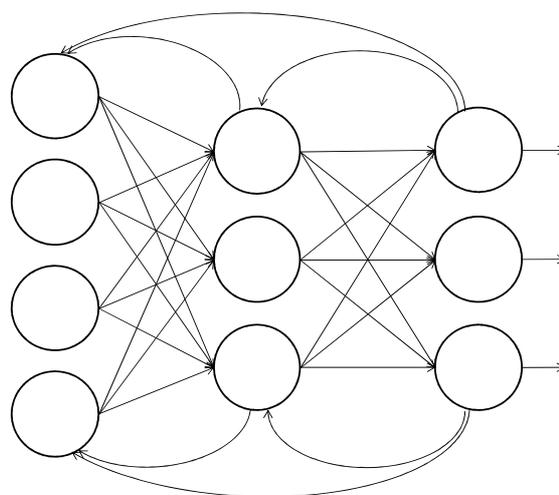


図 2-4 リカレント型ニューラルネットワークの例

2.2. 河川水位予測のためのニューラルネットワークの構成

2.2.1. ネットワーク形態の決定

ニューラルネットワークの構成として、大きく分けてフィードフォワード型とリカレント型がある。リカレント型ニューラルネットワークでは、前ステップの出力結果が次ステップの入力に反映されるため、データ間の時系列的な関係を陰にモデル化することが可能である。一方で、フィードフォワード型ニューラルネットワークでは、入力層に時間遅れを伴うデータを入力することで時系列的な挙動を明示的に表現することが可能である。

理論的には、リカレント型ニューラルネットワークでは、フィードフォワード型よりも複雑な時系列関係まで表現できるポテンシャルを有する。しかしながら、水文分野でのニューラルネットワークの利用を見ると、次のような観点からフィードフォワード型ニューラルネットワークが支配的である (Maier and Dandy, 2000)。

- ① 様々な実問題への適用で、フィードフォワード型が優位である場合が多い
- ② 水文分野の予測問題ではフィードフォワード型の利用がほとんどである
- ③ 計算時間の観点でフィードフォワード型が有利である
- ④ フィードフォワード型で明示的に時系列関係が表現できるので、実用的にはリカレント型の優位性はほとんど見られない

以上より、本研究においてもフィードフォワード型ニューラルネットワークに絞って検討を進める。

2.2.2. ネットワークの構造

本検討で用いるニューラルネットワークの構成概念図を図 2-5に示す。ネットワークは入力層・中間層・出力層から構成される階層型の構成であり、最も基本的なネットワーク構造となっている。

ニューラルネットワークを用いた河川水位予測モデルでは、入力層は上流観測所の雨量や水位変化、出力層は予測地点における予測水位などを設定する。さらに対象流域の規模や地点の特性によっては、潮位や気温など様々な予測因子が考えられる。

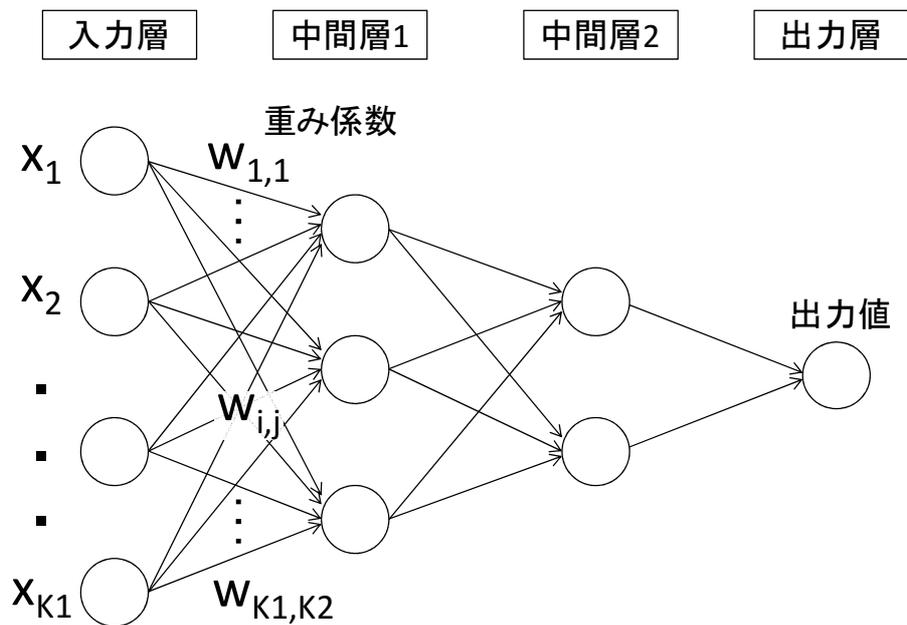


図 2-5 ニューラルネットワークの構成概念図

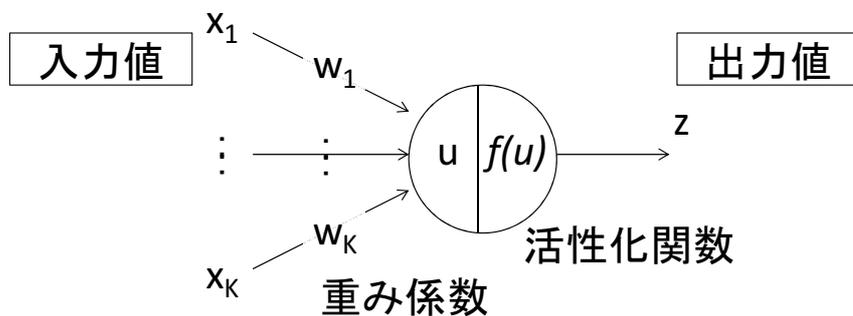


図 2-6 ネットワーク素子（ニューロン）の概念図

ネットワーク内部は、各層が複数個の構成素子（ニューロン）によって構成されており、それぞれの素子が隣の層の各素子と結合される関係となっている。素子の概念図を図 2-6に示す。

素子間の結合は、以下に表す式に従ってデータが伝達されることによって表現される。

$$f(u) = \frac{1}{1 + \exp(-u)} \dots\dots\dots (2.3)$$

$$u = \theta_i + \sum_{i=1}^K w_i x_i \quad \dots\dots\dots (2.4)$$

$$z = f(u) \quad \dots\dots\dots (2.5)$$

ここで、 u は各素子の入力値、 $f(u)$ は活性化関数、 z は素子の出力、 x は入力値、 w は重み係数、 θ はバイアス、 K は各階層の構成素子数である。本稿で以下はバイアスも含めたパラメータベクトル w を改めて重み係数と呼ぶ。これらの式にしたがって、入力層にある数値が与えられれば、ネットワークを通過して出力層に計算結果が吐き出される。

なお活性化関数には様々な関数が使われるが、本検討では最も適用事例の多いシグモイド関数を用いた。

$$f(u) = \frac{1}{1 + \exp(-u)} \quad \dots\dots\dots (2.6)$$

以上をあわせて、単一中間層（入力、出力、中間の3層構造）のニューラルネットワークは次の式で定式化することができる。

$$y_k = \phi_0 \left(\alpha_k + \sum_h w_{hk} \phi_h \left(\alpha_h + \sum_i w_{ih} x_i \right) \right) \quad \dots\dots\dots (2.7)$$

2.2.3. ニューラルネットワーク水位予測モデルの構築手順

予測モデルの実施にあたっては、過去の洪水データを用いた「学習」と、リアルタイムデータとを用いて数時間後までの水位を算出する「予測」の2段階の過程が必要となる。予測計算までの実施手順を図 2-7に示す。

学習に必要な学習データとしては、過去の代表的な洪水事例から、予測地点の水位変化、上流地点の雨量、水位変化の時間ごとのデータセットを設定する。予測のための入力層データとしては、現時刻から数時間前までの上流地点の雨量、水位変化などを設定する。

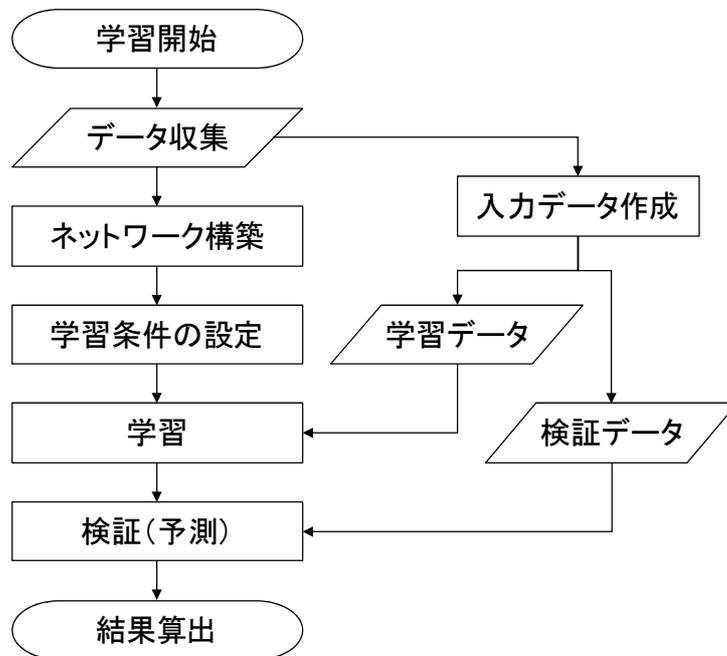


図 2-7 ニューラルネットワークによる予測計算の実施手順

2.2.4. ネットワークの学習手順

(1) 勾配法によるネットワークの最適化

各素子間の結合関数（重み）は、訓練データを学習することによって設定される。訓練データは、入力データと教師データの複数セットで構成される。ネットワークの学習は、出力層と目標出力（実測値）との誤差が小さくなるように、各素子間の重みを勾配降下法によって最小化することで行われる。出力と実績の誤差は以下の二乗誤差 E で評価する。

$$E(w) = \frac{1}{2} \sum_{n=1}^N (d_n - y(x_n; w))^2 \quad \dots\dots\dots (2.8)$$

ここで、 N はサンプルデータ数、 d は目標出力、 y はネットワークの出力値である。ランダムに初期化された w に対して、学習データの各サンプルを用いて勾配降下法の計算を繰り返すことで、 E を極小化する w を得る。勾配降下法では次式のように重みを更新する。

$$w^{(t+1)} = w^{(t)} - \epsilon \nabla E \quad \dots\dots\dots (2.9)$$

ここで ϵ は学習係数であり、 w の更新量を決めるパラメータである。

(2) 誤差逆伝搬法

勾配降下法の適用にあたっては、評価関数の勾配 ∇E を求める必要がある。本検討では ∇E の算出は誤差逆伝搬法 (Rumelhart et al., 1986) などにより行う。誤差逆伝搬法では、学習データが与えられた時の各素子の誤差関数の勾配は次のように求められる。

$$\frac{\partial E_n}{\partial w_{ji}^{(l)}} = \delta_j^{(l)} z_i^{(l-1)} \quad \dots\dots\dots (2.10)$$

ここで、 $\delta_j^{(l)} \equiv \frac{\partial E_n}{\partial u_j^{(l)}}$ はネットワーク第 l 層の u_j による E の微分である。 $\delta_j^{(l)}$ は第 $l+1$ 層の諸量を用いて次式で表わされる。

$$\delta_j^{(l)} = \sum_k \delta_k^{(l+1)} (w_{kj}^{(l+1)} f'(u_j^{(l)})) \quad \dots\dots\dots (2.11)$$

以上より、式(2.10),(2.11)を適用することにより、出力層より順に計算することで、全てのネットワークにおける ∇E を算出することができる。

(3) 学習手順

階層型ネットワークにおける結合の重みを定めるための学習手順を図 2-8に示す。学習手順は以下の通りである。

- ① 入力データ $x_1, x_2, x_3 \cdots x_n$ をニューラルネットワークに与え、最初の段階では結合の重みとして $w_1, w_2, w_3 \cdots w_n$ に小さいランダム値を与えて出力を求める。
- ② 式(2.8)から評価関数を算出する。
- ③ 出力結果と学習用のデータを比較し、新しい結合の重みを式(2.9)により計算する。
- ④ E の収束判定を行い、最適な解が得られるまで②を繰り返す。

ここで、 w_j は j 回目における結合の重み、 η は定数、 δ はニューロンの出力結果と学習用データとの差に関する関数、 O_{net} はニューロンの出力結果である。

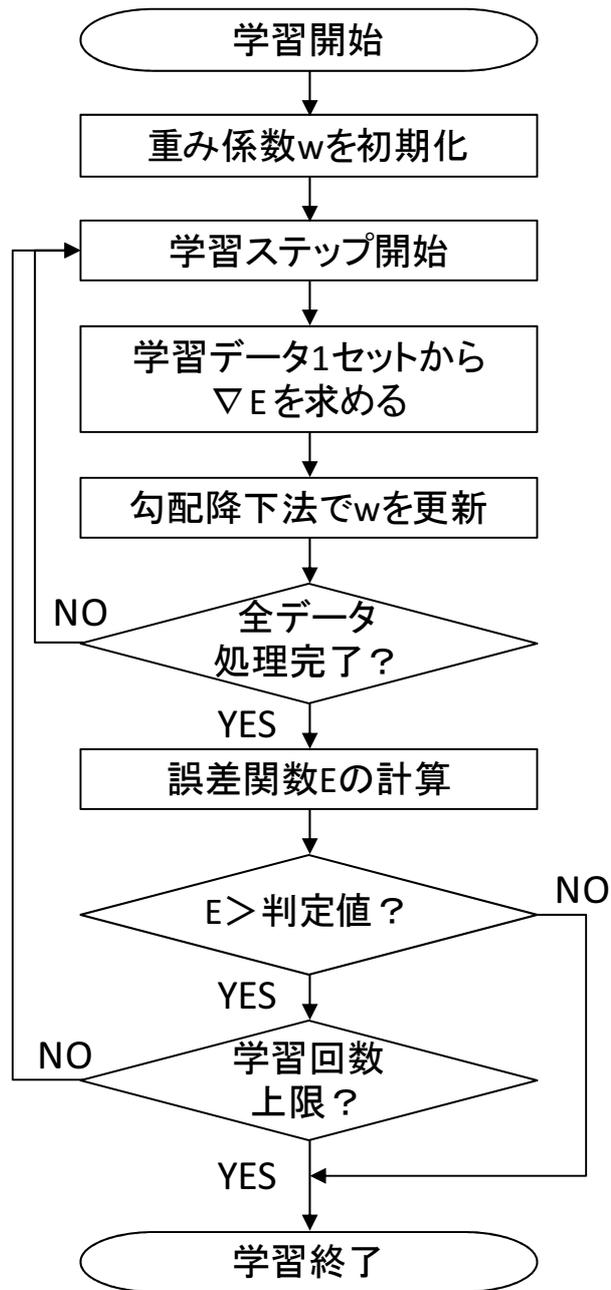


図 2-8 ニューラルネットワークによる学習計算手順

2.3. ニューラルネットワークの入力層選定に関する検討

ANN モデルの課題の一つとして、学習データ（水位や雨量など）をどのように設定するかが挙げられる（ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000b; Maier and Dandy, 2000; Dawson and Wilby, 2001; Maier et al., 2010）。中でも入力層・出力層の選定は予測精度に大きく影響する。既往研究では試行錯誤や、相関分析などにより入出力層の設定が行われているが、確立された手法はない。本研究では、ANN における適切な入力データの設定手順について検討を行い、斐伊川における水位予測モデルを構築し高い精度を確認した。また構築した ANN を用いて、エクセルからの手動データ入力により予測を行う洪水予測システムを構築した。

2.3.1. 対象流域の概要

本研究では、観測データが豊富で、大きなダム等による影響のない斐伊川流域を対象とした。斐伊川流域を図 2-9 に示す。図に示す灘分を基点とした流域面積は 921 km²、河道延長は 83 km である。水位観測所の位置は図中に▲で示す通りであり、本研究の洪水予測対象地点は、最下流に位置する灘分地点とした。雨量観測所の位置は図中に●で示す通りである。

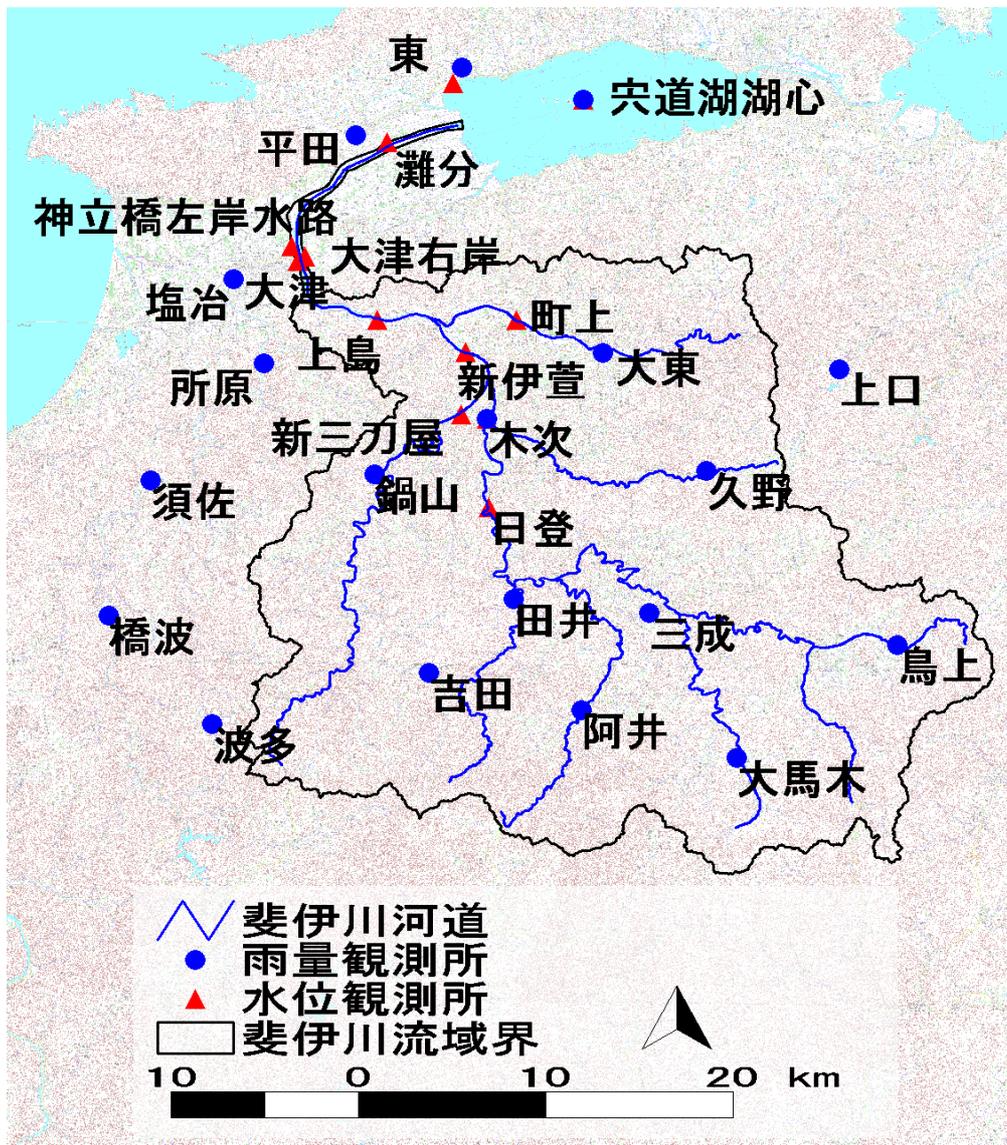


図 2-9 斐伊川流域と水位観測所・降雨観測所の位置図

2.3.2. 対象データ

本研究で用いた観測データは、対象流域内における 14 箇所の雨量観測所、7 箇所の水位観測所である。このうち、洪水予測の対象地点は流域最下流に位置する灘分地点とした。予測に用いる入力データとして、各降雨観測所の時間雨量および対象地点上流の水位もしくは水位変化を用いた。対象出水については、2004～2009 年の中から水位上昇が大きくデータ欠損の少ない 24 出水を選定した。選定に際し、短時間集中型や継続時間の長い降雨など様々なパターンを網羅するよう留意した。

2.3.3. モデルの概要

本研究で用いる ANN は、入力層・中間層・出力層の 3 層で構成する階層型のネットワークを用いた。ANN の学習にはバックプロパゲーション法 (Rumelhart et al., 1986) により行うものとした。

出力層は予測水位、入力層は地上観測雨量や観測水位とした。1 時間後の予測を行う場合、入力層には現時刻から過去数時間分の観測データを、出力層には 1 時間後の灘分水位を設定した。中間層数の設定については確立した手法は得られていないが (ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a)、本検討では入力層数の 2 倍程度に設定すると計算収束性が良かったため、すべてのケースで入力層数の 2 倍に設定するものとした。学習の繰り返し計算回数は 10,000 回を上限とし、収束判定は 1.0×10^{-5} とした。

2.3.4. 入力層の選定

(1) 相関分析による入出力データの選定方針

ANN による洪水予測モデルでは、実績の各種水文データ (入力層) と予測対象 (出力層) との関連性を学習することで将来の予測精度を向上させる。したがって、入出力層の組み合わせは予測精度に大きく影響を及ぼす。入力層の選定にあたっては、①どの観測所の、②どの時刻の値を用いるかを適切に定める必要がある。そこで本検討では、相関分析により入力層候補の中から相関の高いデータを抽出するものとした。

(2) 相関分析のケース設定

相関分析の入出力の組合せを表 2-1 に示す。相関分析の目的変数は、灘分における時刻 0 の水位および水位変化、説明変数は時刻 0~10 時間前における各観測所の時間雨量および水位・水位変化とした。ただし、表 2-1 のケース 1-14 では、相関係数が最大となる時刻が 10 時間よりも大きかったため、14 時間前までの相関係数を算出した。なお時刻 0 の水位変化とは、1 時間前~時刻 0 における水位の変化分である。

(3) 相関分析の結果

水位変化-降雨の相関については、木次観測所の 5 時間前時間雨量との相関が最も高くなった。これは、木次における降雨が灘分まで流下する時間と概ね対応するものと考えられる。一方、水位-降雨の相関については、大馬木観測所の 10 時間前時間雨量との相関が最も高くなった。水位に対しては、雨量の積算値が概ね対応しているものと考えられる。最も相関が高かった時刻の相関分布を図 2-10 に、各時刻の相関係数を図 2-11 に示す。

水位変化-水位変化の相関については、大津の 2,3 時間前水位変化との相関が最も高くなった。これは、観測所間の流下時間と概ね整合する。水位-水位の相関につい

では、各観測所とも高い相関を示しているが、これは水位の絶対値に対して水位変化の幅が小さいためと考えられる。各時刻の相関係数を図 2-12に示す。

(4) 入力層の選定方針

本報告で構築する予測モデルでは、現時刻までの水位が既知である状況を想定している。従って水位予測の精度を高めるためには、現時刻から予測時刻までの水位変化と相関の高いデータを用いる必要がある。以下の検討では、水位変化と相関の高い木次雨量および大津水位変化の値を ANN 入力層の候補とし、精度の検証を行った。

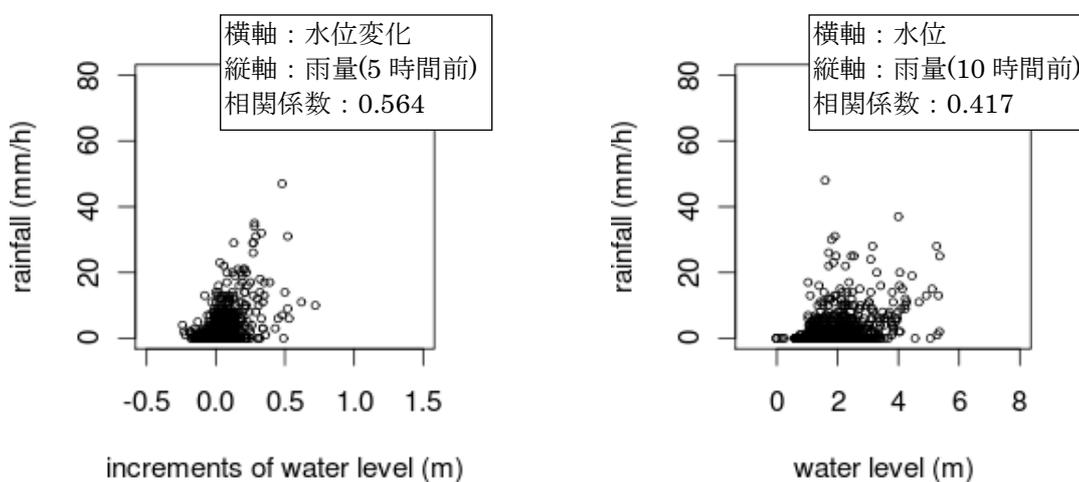


図 2-10 相関分布（左:水位変化-雨量、右:水位-雨量）

表 2-1 相関分析のケース一覧

ケース	目的変数 (出力値)	対象諸量	説明変数 (入力値)	参照時間
1	灘分 水位変化	観測雨量	阿井	0~10 時間前
2			吉田	
3			久野	
4			三成	
5			宍道湖湖心	
6			上口	
7			大東	
8			大馬木	
9			鳥上	
10			田井	
11			東	
12			鍋山	
13			平田	
14			木次	
15		観測 水位変化	新三刀屋	
16			町上	
17			木次	
18			大津	
19			灘分	
20			上島	
21			新伊萱	
22	灘分 水位	観測雨量	阿井	
23			吉田	
24			久野	
25			三成	
26			宍道湖湖心	
27			上口	
28			大東	
29			大馬木	
30			鳥上	
31			田井	
32			東	
33			鍋山	
34			平田	
35			木次	
36		観測 水位変化	新三刀屋	
37	町上			
38	木次			
39	大津			
40	灘分			
41	上島			
42	新伊萱			

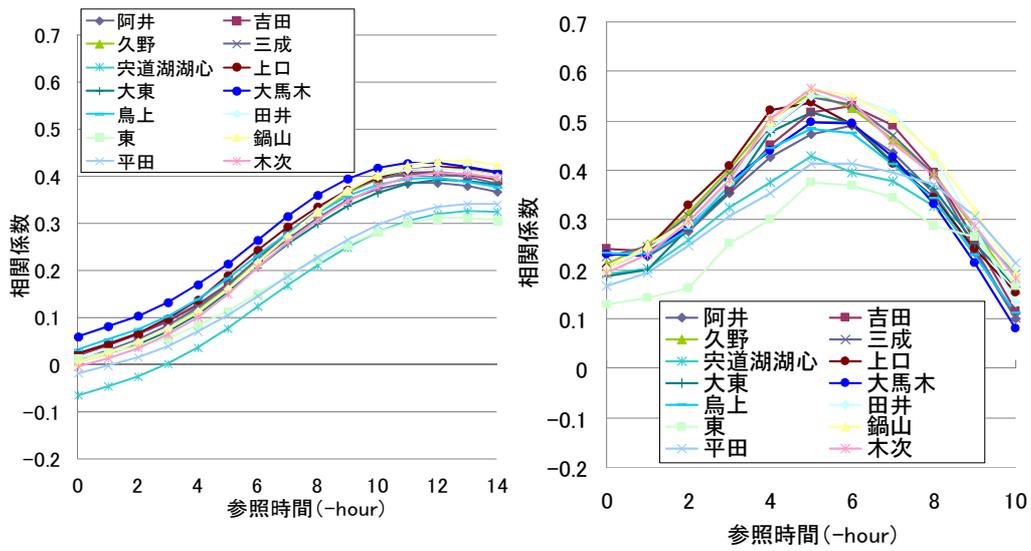


図 2-11 相関係数 (左：水位変化—雨量、右：水位—雨量)

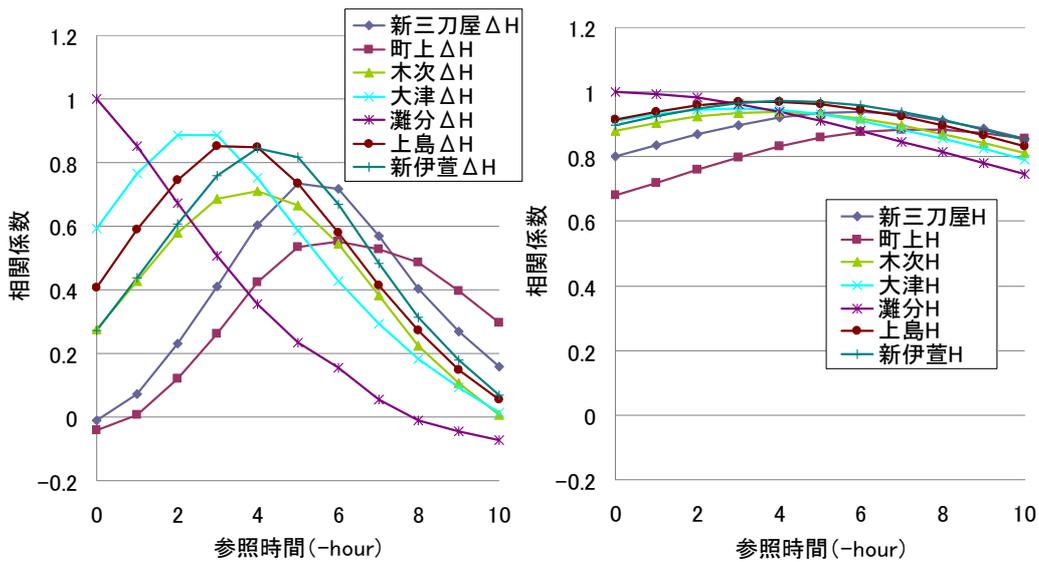


図 2-12 相関係数 (左：水位変化—水位変化、右：水位—水位)

2.3.5. ANN 洪水予測の精度検証

相関分析の結果を踏まえ、ANN 洪水予測の精度検証を行った。入出力層の設定は表 2-2に示す 10 ケースとした。入力層には木次の時間雨量、大津の水位変化を用いた。また、灘分の 1,2 時間前水位は全てのケースに共通して与えた。出力層は予測対象である灘分水位とした。ケース 2-4 を例に、1,2,3 時間後予測の入出力層の設定を表 2-3に示す。表のように、2,3 時間後予測の際は前時間の予測値も入力層に加えるものとした。なお、検証に用いた出水事例は、学習に用いたものと同じ 24 出水である。

(1) ケース 1

ケース 1-1 から 1-5 では、入力層に 1 時間ずつずらした 3 時間分の時間雨量を加えた。全 24 出水における、予測水位と実測水位との二乗平均平方根誤差 (Root Mean Square Error: RMSE) の平均値を図 2-13に示す。ケース 1-1 から 1-5 の中で最も精度が高かったのはケース 1-4 である。ケース 1-4 では、4~6 時間前の降雨を入力層に用いたものであり、水位変化との相関が最も高かった参照時間と一致した。

(2) ケース 2

ケース 2-1 から 2-5 では、ケース 1-4 の入力層に加え、0~4 時間前の大津水位変化を入力層に追加した。この中で最も精度の高かったケース 2-4 は、3 時間前の大津水位変化を入力層に用いたものであり、相関分析で選定した時刻と一致した。また、大津の水位変化データを追加したケース 2-4の方がケース 1-4よりも精度が高くなった。ケース 2-4における 3 時間後水位予測結果の一例は図 2-14に示す通りであり、実測水位を精度良く再現している。この時の 3 時間後予測の RMSE は、24 出水の平均で 0.038m、24 出水中の最大で 0.074m (図 2-14の下の事例) となり、波形全体を通じ高い再現性が示された。またピーク水位の誤差は、24 出水の平均で 0.037m、24 出水中の最大で 0.23m (ピーク時実測水位 1.74m) となった。このようにピーク水位については出水によって精度の違いが現れ、またピーク付近以外でも予測にノイズが生じる場合も数件見られる。しかしながら、ほとんどのケースにおいては十分に高い精度が確認された。

また、ケース 2-4 のモデルを用いて、未学習洪水に対する精度検証を行った (図 2-15)。未学習洪水に対しても、3 時間予測で十分に高い再現性を確認した。

表 2-2 入力層－出力層の設定ケース

CASE	出力層	入力層
1-1	H_0	$H_{-1}, H_{-2}, R_{-1}, R_{-2}, R_{-3}$ (灘分水位, 木次雨量, -)
1-2	H_0	$H_{-1}, H_{-2}, R_{-2}, R_{-3}, R_{-4}$ (灘分水位, 木次雨量, -)
1-3	H_0	$H_{-1}, H_{-2}, R_{-3}, R_{-4}, R_{-5}$ (灘分水位, 木次雨量, -)
1-4	H_0	$H_{-1}, H_{-2}, R_{-4}, R_{-5}, R_{-6}$ (灘分水位, 木次雨量, -)
1-5	H_0	$H_{-1}, H_{-2}, R_{-5}, R_{-6}, R_{-7}$ (灘分水位, 木次雨量, -)
2-1	H_0	$H_{-1}, H_{-2}, R_{-4}, R_{-5}, R_{-6}, \Delta H_0$ (灘分水位, 木次雨量, 大津水位変化)
2-2	H_0	$H_{-1}, H_{-2}, R_{-4}, R_{-5}, R_{-6}, \Delta H_1$ (灘分水位, 木次雨量, 大津水位変化)
2-3	H_0	$H_{-1}, H_{-2}, R_{-4}, R_{-5}, R_{-6}, \Delta H_2$ (灘分水位, 木次雨量, 大津水位変化)
2-4	H_0	$H_{-1}, H_{-2}, R_{-4}, R_{-5}, R_{-6}, \Delta H_3$ (灘分水位, 木次雨量, 大津水位変化)
2-5	H_0	$H_{-1}, H_{-2}, R_{-4}, R_{-5}, R_{-6}, \Delta H_4$ (灘分水位, 木次雨量, 大津水位変化)

表 2-3 入力層－出力層の時系列設定 (case2-4)

1時間後予測

case2-4	5時間前	4時間前	3時間前	2時間前	1時間前	現在	1時間後
灘分水位					○	○	●
木次雨量	○	○	○				
灘分水位変化				○			

2時間後予測

case2-4	5時間前	4時間前	3時間前	2時間前	1時間前	現在	1時間後	2時間後
灘分水位						○	○	●
木次雨量		○	○	○				
灘分水位変化					○			

3時間後予測

case2-4	5時間前	4時間前	3時間前	2時間前	1時間前	現在	1時間後	2時間後	3時間後
灘分水位							○	○	●
木次雨量			○	○	○				
灘分水位変化						○			

○:入力層、●:出力層

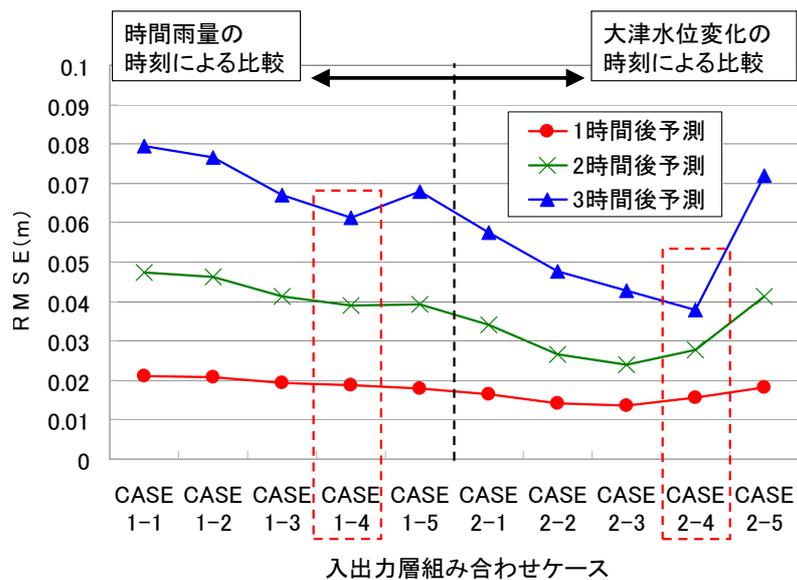


図 2-13 観測水位と予測水位の RMSE

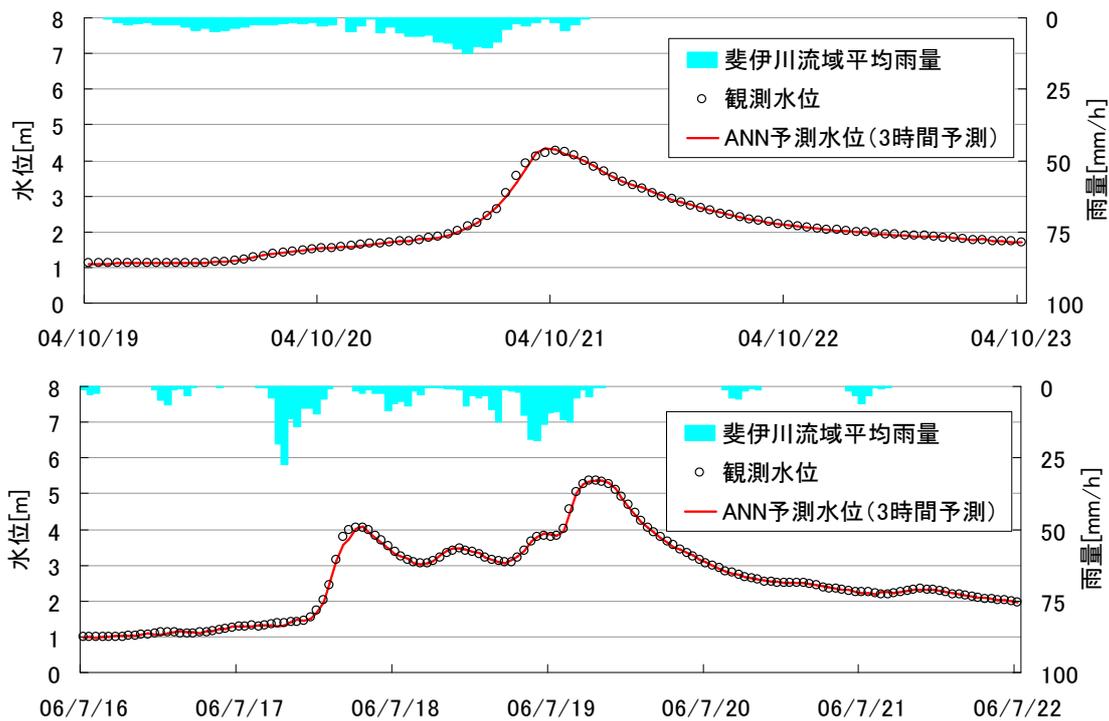


図 2-14 灘分地点における学習済み洪水の予測検証結果(上:2004年10月、下:2006年7月洪水)

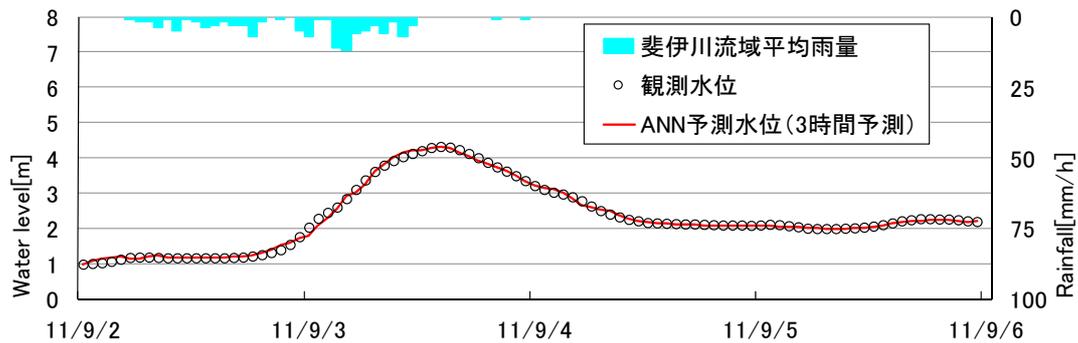


図 2-15 灘分地点における未学習洪水の予測検証結果（上：2004 年 10 月、下：2006 年 7 月洪水）

2.3.6. 入力層選定についてのまとめ

本節では、ニューラルネットワークを用いた洪水予測の精度向上を目的とし、学習データの適切な選定に関する検討を行った。予測対象地点の水位変化を目的変数として相関分析を行い、相関の高い観測所・時刻のデータを入力層に用いることで、精度の高い ANN を構築することができた。選定した入力層を用いて斐伊川における洪水予測検証計算を行い、高い精度を確認した。構築したニューラルネットワークを用いて、手動によるエクセル操作で予測を実施できる予測システムを構築した。一般に ANN の弱みとして、計算過程を物理的に表現することが難しく、モデルがブラックボックスとなっている点が挙げられる。しかしながら本検討より、入出力層の選定において、流域の物理的な降雨－流出過程を踏まえて、適切な観測位置・観測時間のデータを選定することで、予測の精度が向上することが可能となることが確認された。なお、今後の課題としては、学習経験のないような新しい洪水に対し、精度の検証を行う必要があると考える。

2.4. ニューラルネットワークのネットワーク構成、学習回数に関する検討

ANN モデルの課題として、学習経験のない降雨に対する精度検証や精度向上が容易でない点などが挙げられる。予測の精度向上のためには、入力層の組み合わせや、中間素子数・学習回数（学習判定基準）を適切に設定することが必要である。しかしながら、国内の河川を対象とした既往の検討事例では、入力層や中間素子数、学習回数は経験的に定められている場合が多い。モデル設定による予測精度への影響や、演繹的なモデル設定手順について検討されている事例は少なく、ANN 洪水予測手法の適用に向けた今後の課題である。

本研究は、未経験の降雨に対するニューラルネットワーク洪水予測の精度向上を目的として、入力層や中間素子数、学習回数についての分割交差検定によるケーススタディを行った。さらに、条件設定による水位予測精度への影響を確認するとともに、ケーススタディ結果から最適な条件設定を行う手順を試み、精度評価を行った。

2.4.1. 対象データ

(1) 対象流域の概要

本研究の対象である佐波川流域を図 2-16に示す。佐波川は流域面積が 460 km²、幹川流路延長が 56 km の一級河川である。本研究で用いた水位観測所は図中に▲で示す 10 地点、雨量観測所は○で示す 9 地点である。洪水予測対象地点は、佐波川の基準地点である新橋地点とした。

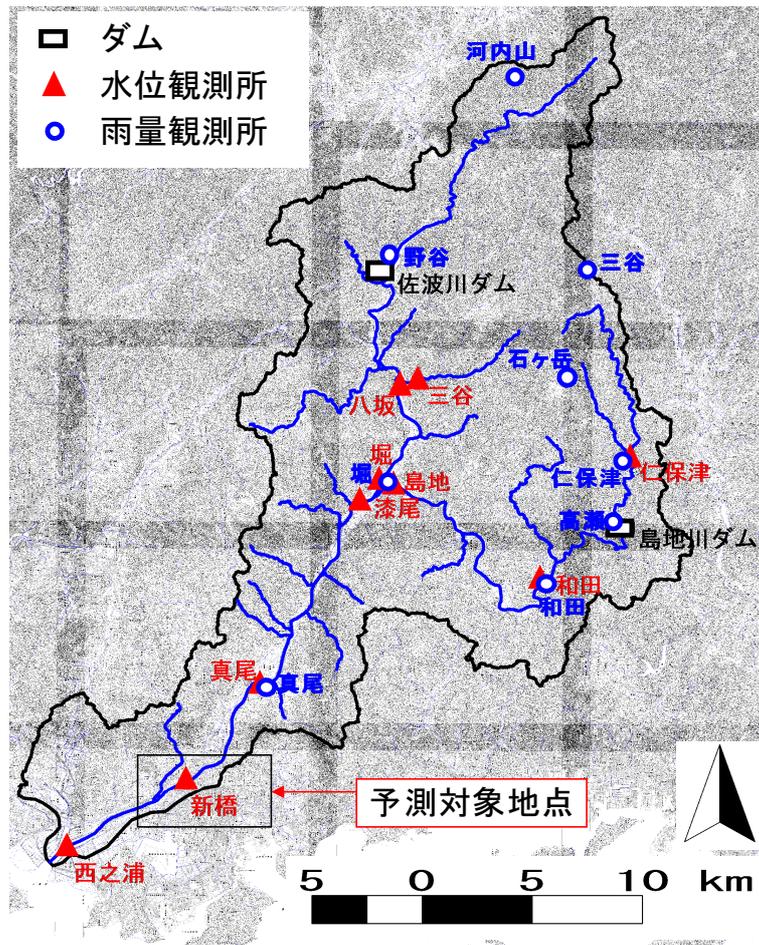


図 2-16 佐波川流域と水位観測所・降雨観測所の位置図

(2) 対象洪水の抽出

ANN モデルの学習および検証に用いる対象出水として、2002～2013 年の中から水位上昇が大きくデータ欠損の少ない 30 洪水を選定した。各洪水について、水位ピークを起点として前 48 時間、後 24 時間を含めた計 73 時間分の時間水位・雨量データを学習データとした。すなわち、学習用水位データとして 30 洪水×73 時間で 2190 個のデータを用いるものとした。

(3) 出水データの特性分析

予測地点（新橋）における水位変化を目的変数として、他の観測データとの相関分析を行った。相関分析に用いた説明変数は、他の水位観測所の水位変化、および各雨量観測所の時間雨量とし、予測地点と 0～10 時間ずらしたデータについて相関係数を算出した。相関分析のケース一覧を表 2-4 に示す。なお、時刻 0 の水位変化とは、1 時間前～時刻 0 における水位変化を表す。

新橋水位変化-他の水位変化の相関分析結果を図 2-17に示す。タイムラグ 1 時間では真尾が最も高い相関を示した。タイムラグ 2 時間では、漆尾が最も高い相関を示し、次いで三谷、堀、和田であった。

新橋水位変化-他の雨量観測所の相関分析結果を図 2-18に示す。タイムラグ 1 時間では真尾が最も高い相関を示した。タイムラグ 2 時間では、堀地点の相関が最も高く、次いで和田、高瀬、仁保津との相関が高くなった。

これらのタイムラグは、各地点における河道水位・降雨についての、新橋地点までの概ねの流下時間を示しており、佐波川流域における降雨→流出が短時間で生じていることを表しているものと考えられる。本検討において相関の高かった地点およびタイムラグは、ANN の入力層の設定に反映させた。

表 2-4 相関分析のケース一覧

ケース	目的変数 (出力値)	対象データ	説明変数 (入力値)	タイム ラグ
1	新橋 水位変化	観測 水位変化	漆尾	0~10 時間
2			堀	
3			八坂	
4			真尾	
5			西之浦	
6			三谷	
7			仁保津	
8			和田	
9			島地	
10		観測雨量	河内山	
11			三谷	
12			野谷	
13			石ヶ岳	
14			仁保津	
15			堀	
16			高瀬	
17			和田	
18			真尾	

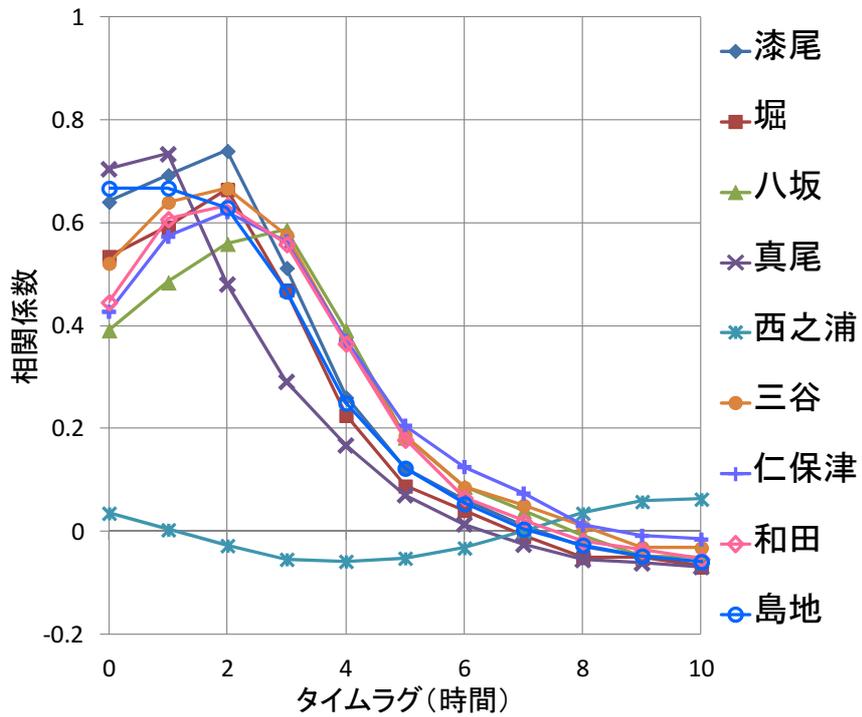


図 2-17 新橋水位変化と上流水位変化との相関係数

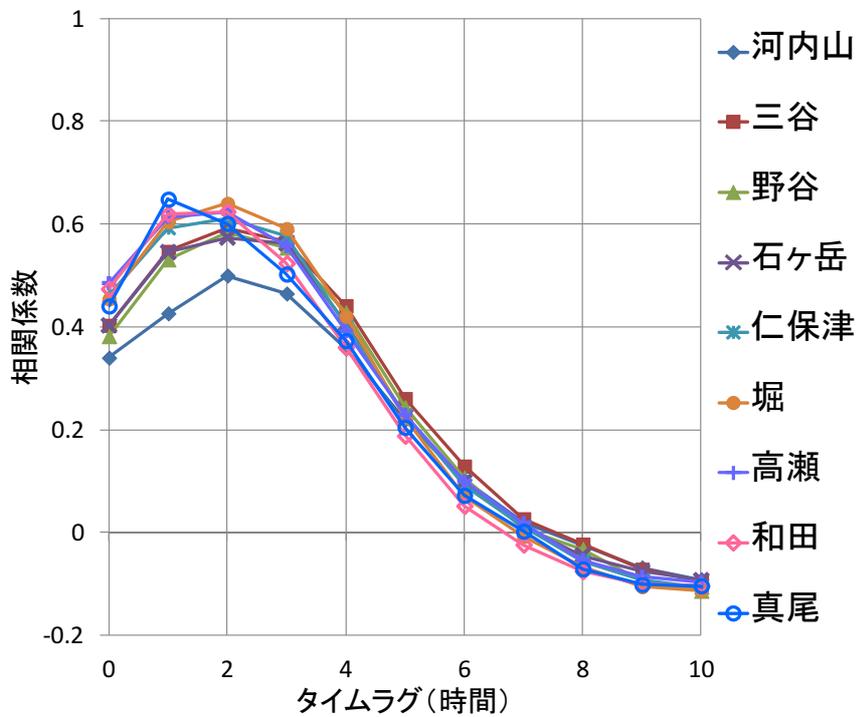


図 2-18 新橋水位変化と上流時間雨量との相関係数

2.4.2. ANN 洪水予測手法の概要

(1) 学習回数および中間素子数の設定方法の基本方針

ANN による洪水予測モデルは、実績の各種水文データ（入力層）と予測水位（出力層）との関連性を学習することで、降雨－流出応答の一般的な関係を表現するものである。実績データの学習段階においては、ネットワーク構造（中間素子数）を大きくし、学習回数を増やしていくことで、出力層の学習データへのフィッティングは向上していく。一方で、過度に中間素子数や学習回数を増やしていくと、学習データのノイズやバイアスの影響を受けやすくなるため、過学習に陥り入出力応答の汎化能力を失うことにつながる。図 2-19（左）に水位変化の挙動を適切に汎化した結果を、図 2-19（右）に過学習により汎化に失敗した結果を模式的に示す。

降雨－流出応答を詳細に表現しつつ、過学習による精度低下を避けるためには、過不足のない学習回数および中間素子数を設定する必要がある。本研究では、学習回数と中間素子数に関するケーススタディを行うことにより、最適な設定を試みるものとした。

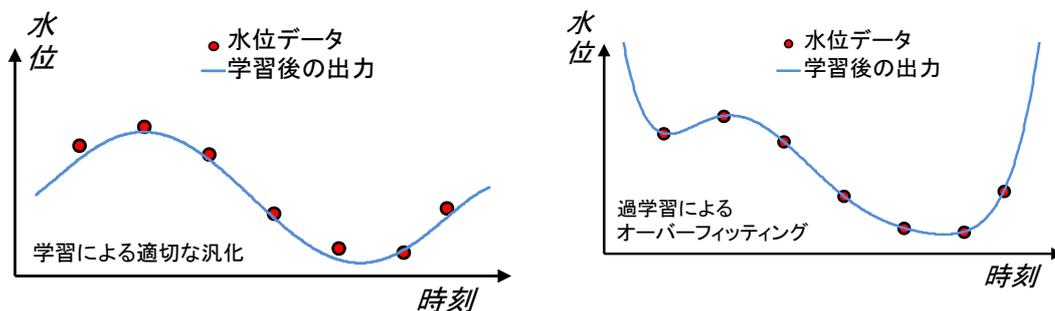


図 2-19 学習による適切な汎化結果（左）と過学習結果（右）の模式図

表 2-5 分割交差検定における分割データの割り当て

データ セット No.	検証用の出水 No. (出水規模順)
1	1,6,11,16,21,26
2	2,7,12,17,22,27
3	3,8,13,18,23,28
4	4,9,14,19,24,29
5	5,10,15,20,25,30

(2) 対象洪水データの分割

対象洪水の学習を行うにあたり、過学習を避けるためには、学習用データと検証用データとを分割する手法（交差検定）が一般的に用いられている（ASCE Task

Committee on Application of Artificial Neural Networks in Hydrology, 2000a; Maier and Dandy, 2000; Dawson and Wilby, 2001; Maier et al., 2010)。交差検定の中でも、限られた出水データをすべて学習に活用する手法として分割交差検定がある。分割交差検定の手順は以下の通りである。

- ①全対象洪水データを k 個のデータセットに分割する。
 - ② k 個のうち 1 個のデータセットを検証データとする。
 - ③残りの $(k-1)$ 個のデータセットを学習データとする。
 - ④設定したデータで学習・検証（精度評価）を行う。
- 以下、②③④を k 回繰り返し、精度指標の平均値を評価する。

本検討では、学習 30 洪水を 5 セット × 6 洪水として分割交差検定を行うものとした。なお、各データセットで洪水規模などを揃えることで、検定ごとの学習効果の偏りを避けるようにした。本検討では、30 洪水を出水規模準に並べ、5 番おきに各データセットの洪水を割り当てることで洪水規模の偏りを極力減らすものとした。表 2-5 に分割データの内訳を示す。

表 2-6 入力層組合せの設定ケース

ケース	出力層	入力層
1	$\Delta H_{(1)}$	$\Delta H_{\text{新橋}(0)}, \Delta H_{\text{新橋}(-1)},$ $\Delta H_{\text{漆尾}(-1)}, \Delta H_{\text{三谷}(-1)}, \Delta H_{\text{堀}(-1)}, \Delta H_{\text{和田}(-1)}$
2	$\Delta H_{(1)}$	$\Delta H_{\text{新橋}(0)}, \Delta H_{\text{新橋}(-1)},$ $\Delta H_{\text{漆尾}(-1)}, \Delta H_{\text{三谷}(-1)}, \Delta H_{\text{堀}(-1)}, \Delta H_{\text{和田}(-1)}$ $R_{\text{堀}(-1)}, R_{\text{和田}(-1)}, R_{\text{高瀬}(-1)}, R_{\text{仁保津}(-1)}$

表 2-7 中間素子数・学習回数に関するケーススタディの設定

中間素子数	学習回数
1~20 (20 ケース、1 刻み)	20~240 (12 ケース、20 刻み)

表 2-8 時系列予測における入力層-出力層の設定（ケース 2）

1時間後予測			
CASE 2	1時間前	現在	1時間後
新橋水位変化	○	○	●
上流水位変化	○		
上流時間雨量	○		

2時間後予測				
CASE 2	1時間前	現在	1時間後	2時間後
新橋水位変化	○	○	○	●
上流水位変化	○	○		
上流時間雨量	○	○		

○:入力層、●:出力層

2.4.3. 予測モデルのケーススタディ

(1) ケース設定

ANN モデルの精度検証のためのケース設定を行った。ケーススタディの設定対象は、①入出力層の組合せ、②中間素子数、③学習回数の3つとした。相関分析結果をもとに設定した入出力層ケースを表 2-6に示す。表中で、 ΔH 地点名(-t) : ある地点での時刻(-t-1)~時刻(-t)における水位変化、R 地点名(-t) : ある地点での時刻(-t)における時間雨量、である。例えば、 ΔH 新橋(-1) は、新橋地点での2時間前~1時間前における水位変化を表す。出力層については、水位よりも水位変化を設定する方が有利である (Dawson and Wilby, 2001; 磯部ほか,1994; 一言ほか,2012) ことが報告されている。本検討においても、現時刻までの水位が既知である状況での水位予測を想定し、水位変化を出力層として設定した。入力層については、ケース 1 では水位変化のみ、ケース 2 では水位変化と時間雨量とを組み合わせで設定した。なお、予測地点自身の水位変化の時刻歴（現時刻と1時間前における1時間水位変化）については、両ケースで共通して設定した。

中間素子数および学習回数のスタディケースは表 2-7に示すとおりとした。表 2-6、表 2-7に示す組合せにより、 $2 \times 20 \times 12 = 480$ のスタディケースを設定した。

なお予測先行時間は、相関分析において新橋水位変化と各観測所水位・雨量との高い相関が見られた2時間後までとした。2時間後まで予測を行う場合の入出力層の設定について、ケース 2 の例を表 2-8に示す。

(2) 検証結果 入力層ケース 1

入力層の組合せケース 1 において、中間素子数、学習回数のケーススタディ時の計算水位と実測水位との RMSE を算出した。学習データに対する RMSE と、検証デー

タに対する RMSE をそれぞれグラフ化した。

学習データの RMSE を図 2-20に示す。学習データに対しては、中間素子数および学習回数の増大に伴い、RMSE はほぼ単調に減少する傾向となった。RMSE が最小値となるのは、中間素子数が 19、学習回数が 240 のケースであった。

一方、検証データの RMSE を図 2-21に示す。検証洪水については、学習回数が 40 を越えるあたりから過学習になっており、学習回数の増大に伴い RMSE が増大する傾向となった。学習回数が 40~60 と比較的少ないケースでは、中間素子数によらず RMSE が小さくなるケースが多く見られる。学習回数が 100 回以上になると、中間素子数が多くなるほど RMSE が増大する傾向が見られる。RMSE が最小値となるのは、中間素子数が 17、学習回数が 40 のケースであった。

なお、検証データに関する RMSE の曲面は滑らかではなく、随所に局所的な RMSE の極小値が存在している。ANN モデル自体が非線形性の強い式であり、検証データ数も有限でノイズを含むものであるため、RMSE の曲面もノイズを含んでいると考えられる。モデル構築に際しては、RMSE の極小値となるケースではなく、大域的に RMSE が小さくなるケースの方が、一般性が高く望ましい設定であると考えられる。なお洪水データが豊富に用意できる場合には、検証用の洪水データをさらに別途用意することで、より確実な精度検証が実施できると考えられる。

(3) 検証結果 入力層ケース 2

入力層の組合せケース 2 において、ケース 1 と同様に中間素子数、学習回数のケーススタディ時の計算水位と実測水位との RMSE を算出した。

学習データの RMSE を図 2-22に示す。ケース 1 と同様に、中間素子数および学習回数の増大に伴い、RMSE はほぼ単調に減少する傾向となった。RMSE が最小値となったのは、中間素子数が 18、学習回数が 240 のケースであった。

検証データの RMSE を図 2-23に示す。検証洪水については、中間素子数が 2~4 程度、学習回数が 100~140 程度のところを中心に RMSE が小さくなる傾向が見られた。RMSE が最小値となるのは、中間素子数が 2、学習回数が 140 のケースであった。RMSE の分布はケース 1 とは異なっており、中間素子数や学習回数の最適値は入力層のケースごとに異なっていることが窺える。なお、中間素子数と学習回数がある程度より大きくなると、過学習となって RMSE が増大する傾向となるのはケース 1 と同様であった。また、RMSE の極小値が随所に存在しているのもケース 1 と同様であり、条件設定に際しては注意が必要である。

なおケース 2 では、ケース 1 に比べて最小ケースでの RMSE が小さくなった。入力層に水位のみを用いたケース 1 に対して、ケース 2 では入力層に雨量データを加えているため、これらの雨量データが精度向上に寄与したものと考えられる。

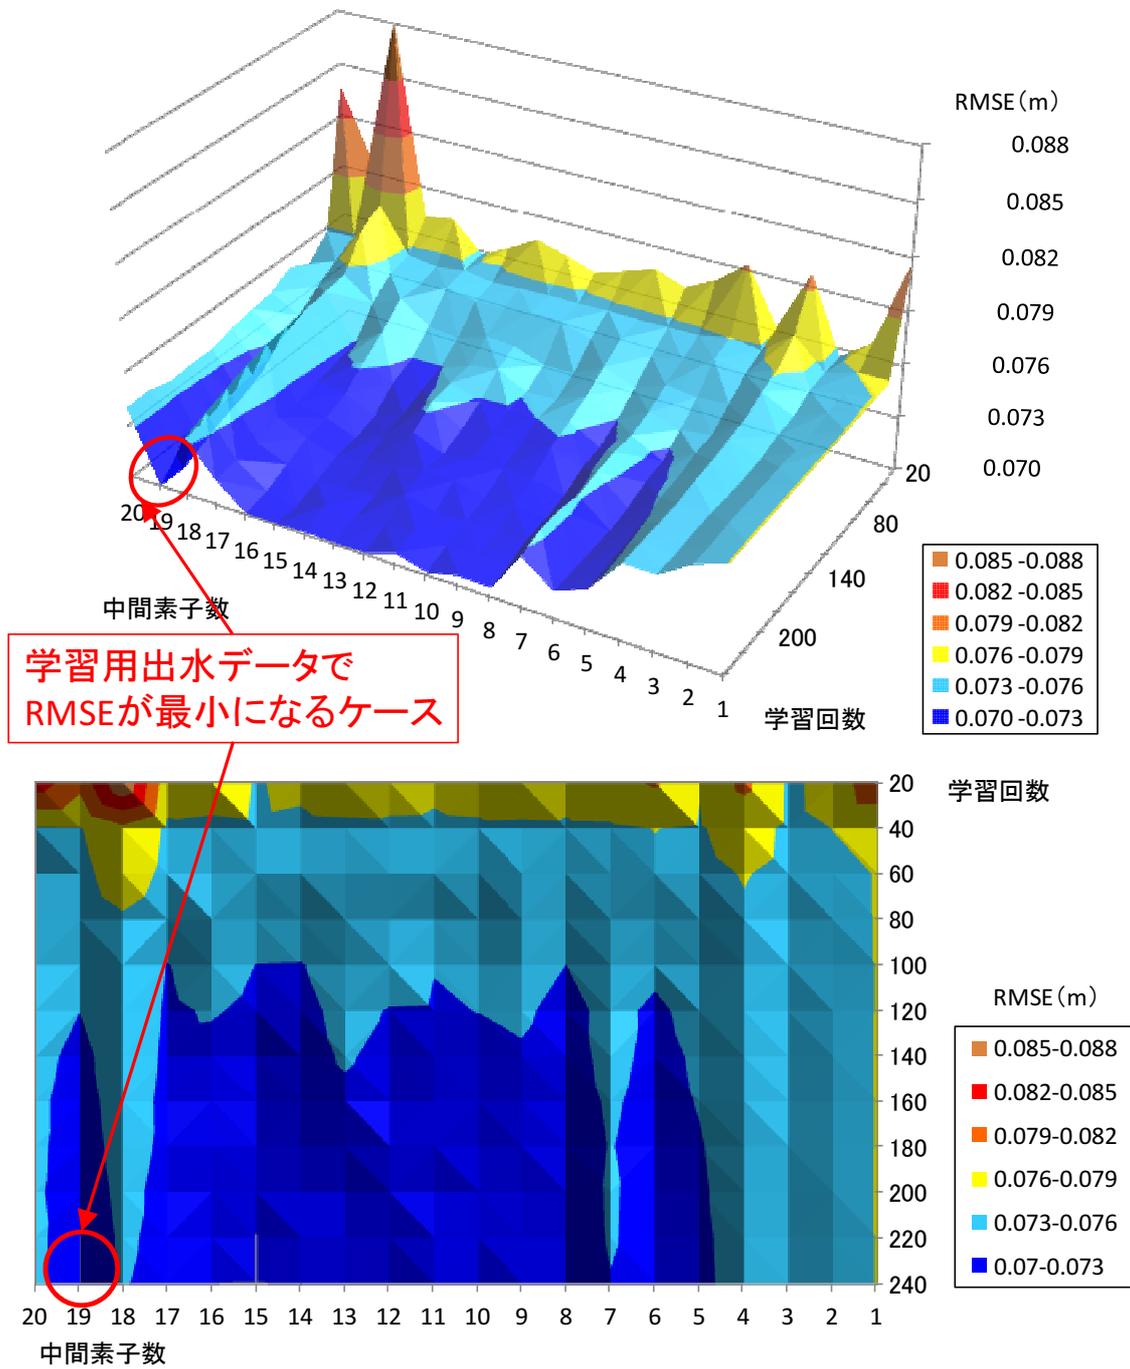


図 2-20 予測水位-実測水位の RMSE (ケース 1、学習データ)

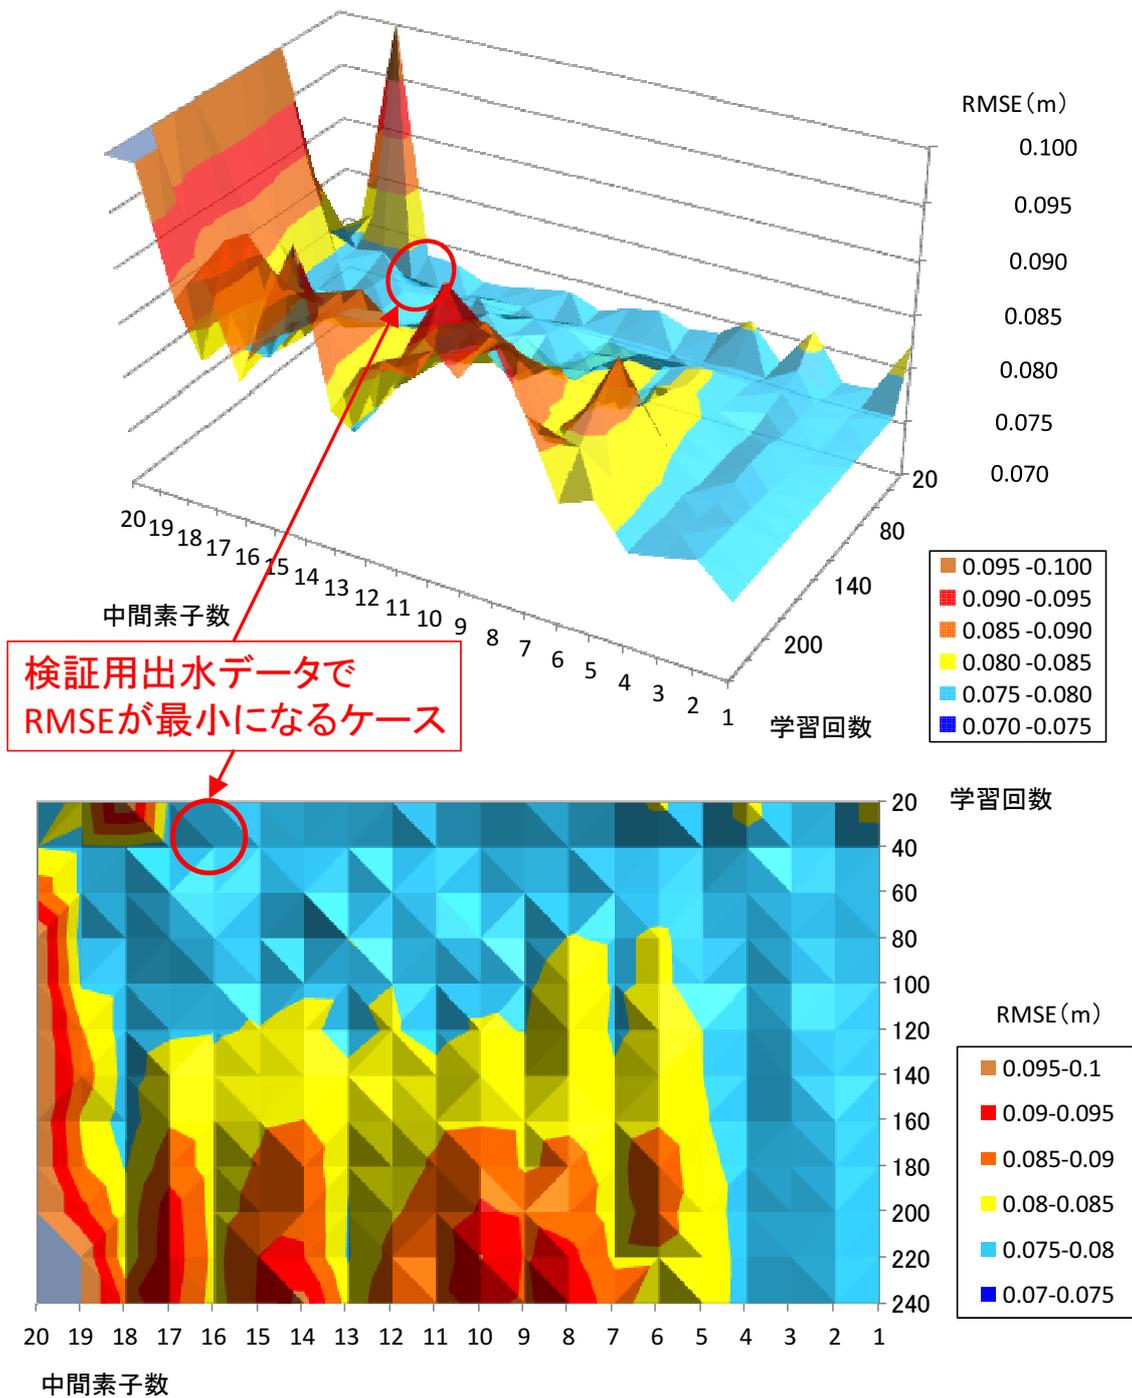


図 2-21 予測水位-実測水位の RMSE (ケース 1、検証データ)

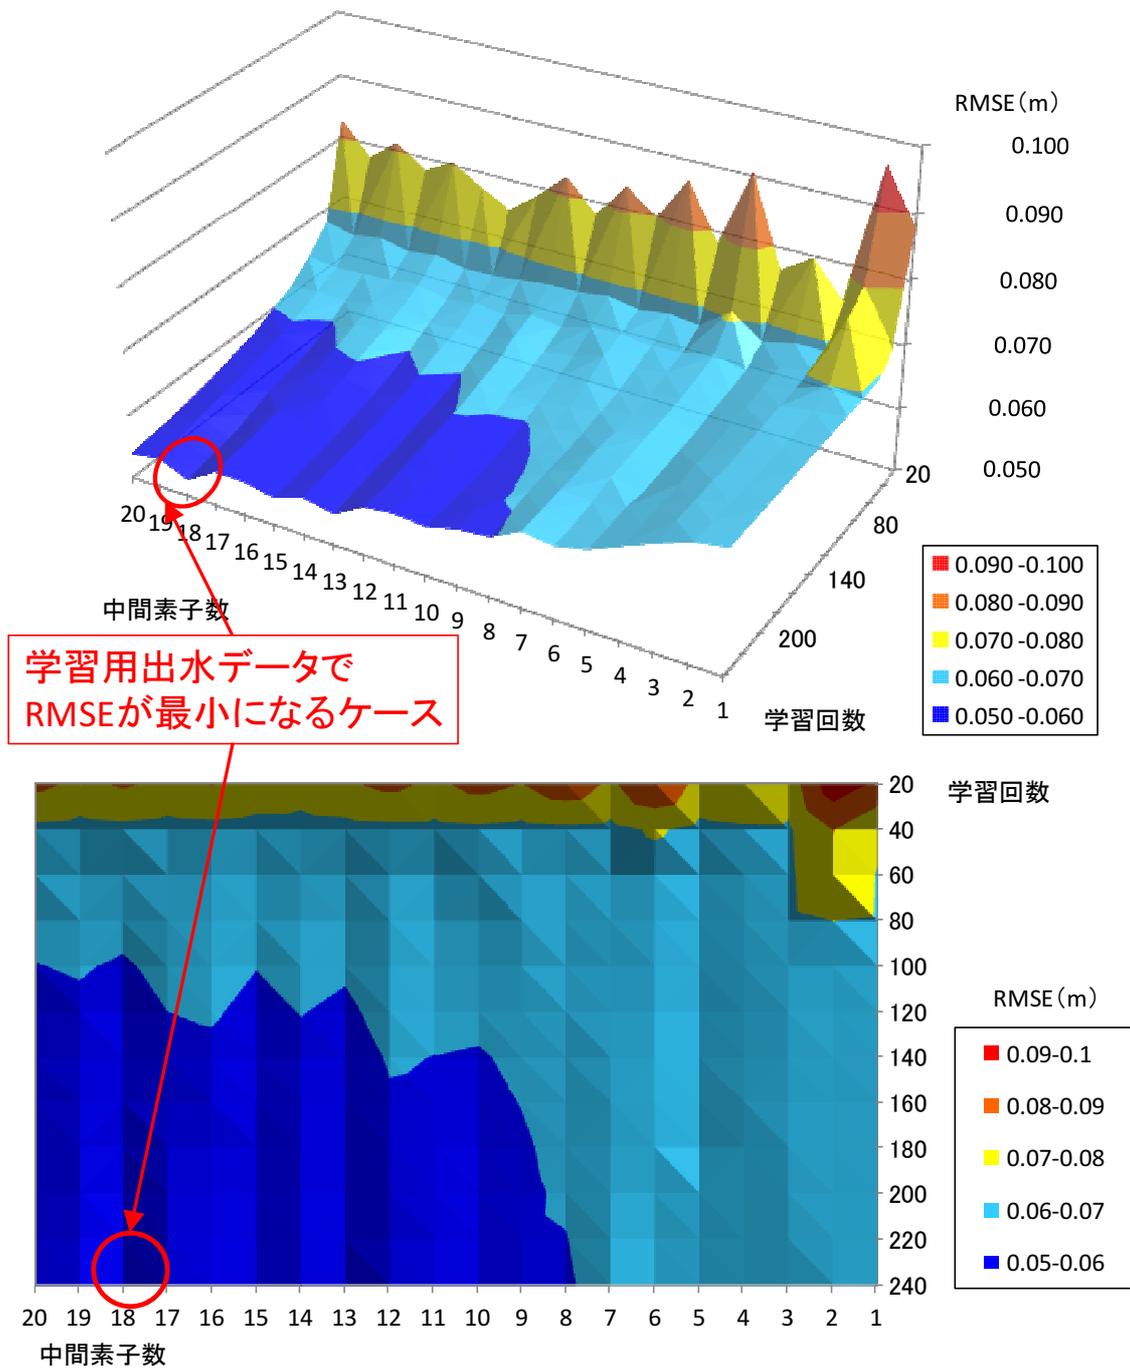


図 2-22 予測水位-実測水位の RMSE (ケース 2、学習データ)

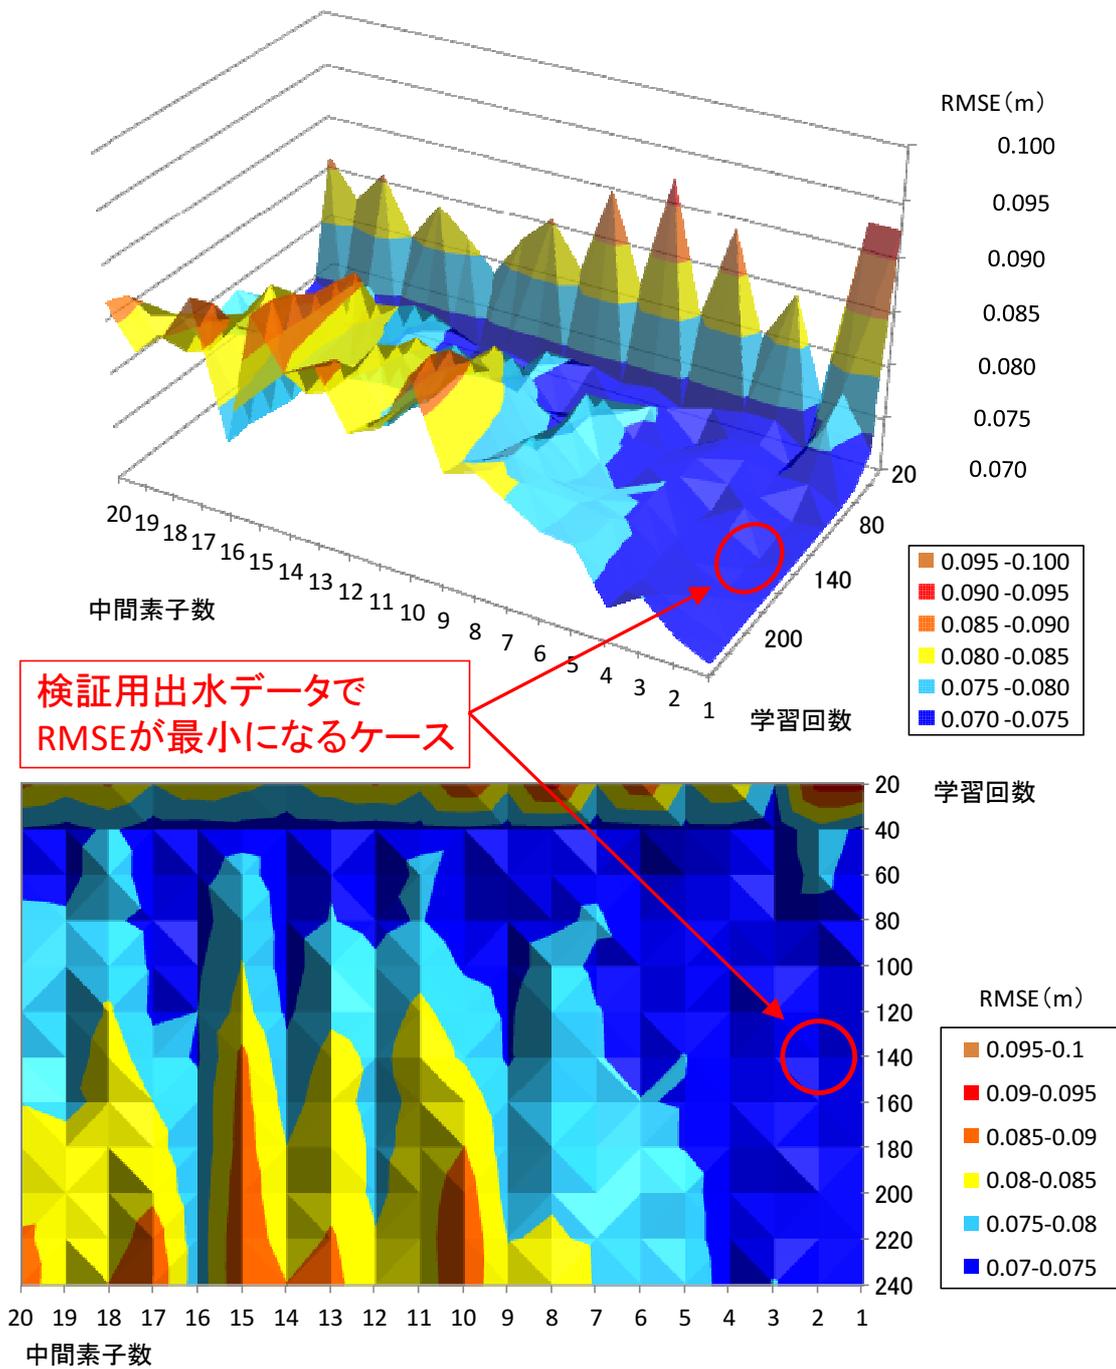


図 2-23 予測水位-実測水位の RMSE (ケース 2、検証データ)

(4) 計算結果

ケース 2 の最適ケースにおける計算結果の例を図 2-24に示す。期間最大の 2009/7/21 洪水では、RMSE が 0.18 m、NS 係数が 0.96、ピーク水位差が+0.45 m となった。期間第 2 位の 2010/7/14 洪水では、RMSE が 0.09m、NS 係数が 0.98、ピーク水位差が+0.27 m である。洪水の急な立ち上がりの部分で予測がやや遅れる傾向となったが、波形全体を通じて高い再現性が確認できた。なお 30 洪水の平均では、RMSE は 0.07 m となり、全体として高い再現性を確認できた。

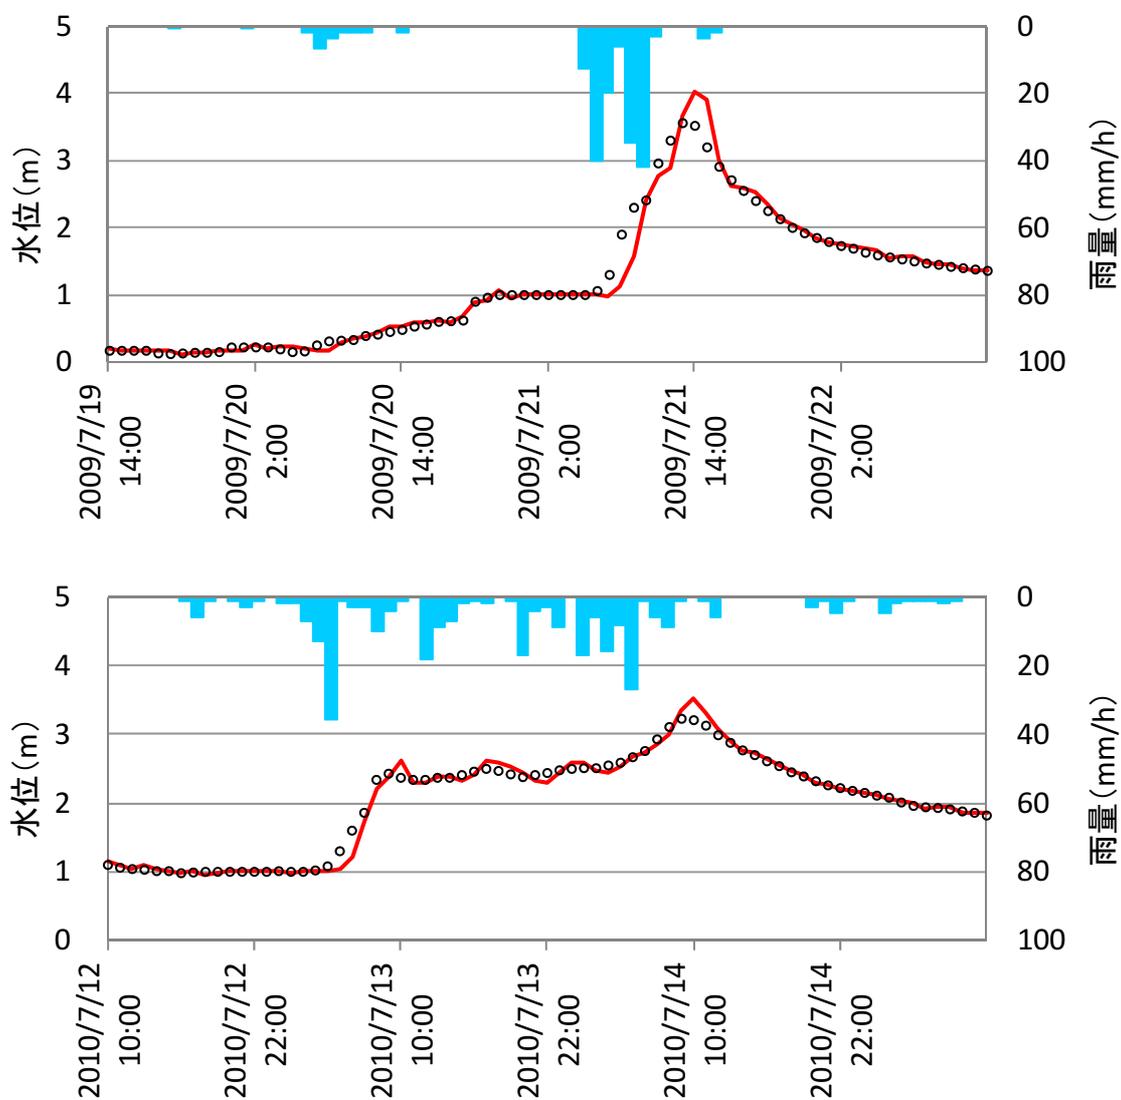


図 2-24 新橋地点の 2 時間後水位の予測計算結果 (上: 2009/7/21 洪水、下: 2010/7/14 洪水)

2.5. アンサンブル学習に関する検討

ANN 洪水予測の精度向上の一つとしてアンサンブル学習 (Anctil and Lauzon, 2004) が研究されているが、国内での適用事例はみられない。本研究では、ANN による洪水予測の精度向上を目的として、国内の 1 級河川を対象として検討を行った。ANN の最適な入力データの組合せ、ネットワーク構造、学習回数に関するケーススタディを行い、予測モデルを構築した。構築したモデルにアンサンブル学習を適用し、単一の学習モデルに比べ予測精度向上を確認した。

2.5.1. 対象流域

対象流域は国内 1 級河川の A 川、B 地点とした。予測地点から上流の流域面積は約 900km²、最上流部までの河道延長は約 80km である。流域内には水位観測所が 8 か所、雨量観測所が 10 箇所設置されている。雨量・水位の時間データをはじめ、水質やダムデータなど様々な観測データが水文水質データベースに公開されている (<http://www1.river.go.jp/>)。

2.5.2. 対象洪水

治水上の重要な河川では、複数の基準地点で洪水予報の発表基準となる河川水位および危険度レベルが段階的に設定されている。もっとも初期の予報レベルとして水防団待機水位が定められており、水防活動の準備を始める目安となっている。本研究で対象とする A 川の B 地点では、2001 年 1 月～2014 年 12 月までに水防団待機水位への到達は 46 回である。本研究では、これら 46 事例に関する基準水位への到達判定を予測対象とし、1～3 時間予測の再現精度を検証した。

学習対象は 2004 年～2013 年の上位 12 洪水とした。各洪水のピークから前後 60 時間を 1 洪水とし、全部で 121 時間×12 洪水=1452 時間分のデータを学習対象とした。

2.5.3. ニューラルネットワークの設定

本検討で用いたネットワークは、入力層・中間層・出力層の 3 層からなる階層型のネットワークとした。ネットワークの学習にはバックプロパゲーション法を用いた。

(1) 相関分析による入力層データの選定

ANN モデルの入力層に用いる観測所を決定するため、B 地点の水位変化と相関の強い地点を選別した (Maier and Dandy, 2000; 一言ほか, 2012)。ここでは、B 地点から最も近い水位観測所 C と、流域中央付近に位置する雨量観測所 D が選別された。

B地点とC地点の水位変化の相関は、タイムラグが2時間の時に最も高くなり、これはC地点からB地点までの洪水流下時間に対応している。またB地点水位変化とD地点の雨量は、タイムラグ6時間で最も相関が高くなり、これは降雨一流出の時間に対応している。

2.5.4. ケーススタディによるネットワークの決定

(1) ケース設定

最適なANNモデルを構築するため、ケーススタディを実施した。ケーススタディの組合せを表2-9、表2-10に示す。表2-9において、 ΔH 地点名(-t) : ある地点での時刻(-t-1)~(-t)における水位変化、R 地点名(-t) : ある地点での時刻(-t)における時間雨量、を表わす。例えば、 $\Delta HB(-1)$ は、B地点での2時間前~1時間前における水位変化を表す。ケース1では、予測地点における直近2時間分の水位変化、上流C地点における2時間分の水位変化、雨量観測所D地点における3時間分の雨量とした。ケース2では、入力層の雨量データを減らして1時間分のみとした。なお、予測は1~3時間後まで行い、2,3時間予測の入力層の一部には予測モデル自身の予測データを用いるものとした。

表 2-9 入力層データの組合せケーススタディ表

ケース	出力層	入力層
1	$\Delta H_{B(0)}$	$\Delta H_{B(-1)}, \Delta H_{B(-2)}, \Delta H_{C(-2)}, \Delta H_{C(-3)}, R_{D(-5)}, R_{D(-6)}, R_{D(-7)}$
2	$\Delta H_{B(0)}$	$\Delta H_{B(-1)}, \Delta H_{B(-2)}, \Delta H_{C(-2)}, \Delta H_{C(-3)}, R_{D(-6)}$

表 2-10 中間素子数・学習回数のケーススタディ

中間素子数	学習回数
1~20 (20 ケース、1 刻み)	25~300 (12 ケース、25 刻み)

(2) ケーススタディの精度評価

対象12洪水に対して、4分割交差検定によりケーススタディを行った。予測水位と実測水位とのRMSE (Root Mean Square Error : 二乗平均平方根誤差) がもっとも小さくなったケース (入力層組合せ2、中間素子数7、学習回数50) を最適なANNモデルとして決定し、以下の検討に用いた。

2.5.5. アンサンブル学習の実施手順と精度評価

(1) 単一学習モデルの再現計算

分割交差検定に用いたデータセットの一つを利用して学習器を作成し、2001年1月～2014年12月の検証期間に対して1時間ごとの予測再現計算を行った。

(2) アンサンブル学習による再現計算

学習用の12洪水データを用いてアンサンブル学習を行った。アンサンブル学習の方法としてBaggingやBoostingといった手法があるが、本研究ではより単純に、学習用12洪水から1事例ずつ除いた11洪水からなるデータセットを12個用意した。それぞれのデータセットより、12個の学習器を作成した。各学習器の算術平均をアンサンブル学習モデルの予測結果とした。

(3) 精度評価

水防団待機水位に到達した46回の洪水について、単一学習モデルとアンサンブル学習モデルの精度検証を行った。各モデルの適合率と再現率を表2-11、表2-12に示す。アンサンブル学習の結果、各予測時刻で単一の学習器を上回る精度が得られた。アンサンブル学習モデルの結果を表2-13および図2-25に示す。

表 2-11 予測時間ごとの適合率 (%)

予測時間	単一学習	アンサンブル
1時間予測	93.6	95.7
2時間予測	67.3	78.7
3時間予測	32.3	47.9

表 2-12 予測時間ごとの再現率 (%)

予測時間	単一学習	アンサンブル
1時間予測	95.7	95.7
2時間予測	71.7	80.4
3時間予測	43.5	50.0

表 2-13 検証期間における3時間予測水位（アンサンブル学習モデル）と実績水位との対比

		実績	
		基準水位到達	基準水位未到達
予測	基準水位到達	23	25
	基準水位未到達	23	113637

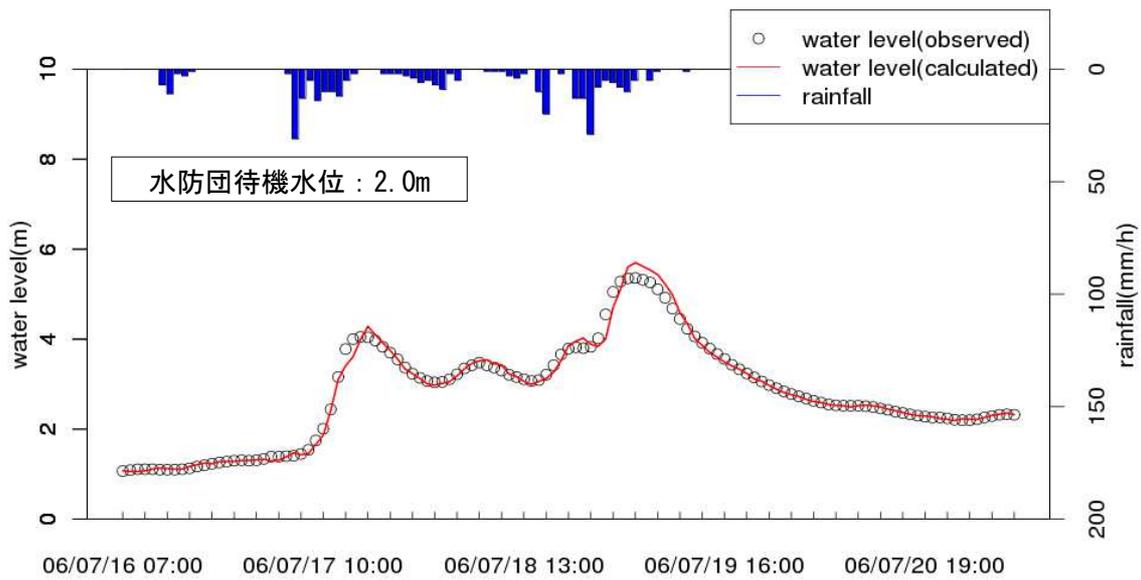


図 2-25 洪水予測結果の時系列 (3 時間予測)

2.5.6. アンサンブル学習のまとめ

本研究では、国内の 1 級河川を対象として、ANN による洪水予測モデルを構築し、アンサンブル学習を適用することにより精度向上を実現した。洪水予測では、防災上の安全側の判断が最優先とされるが、実際の判断は容易ではない。今後は、アンサンブル予測により幅を持った予測情報の適用性など、より活用しやすい予測情報の提供が課題として挙げられる。

2.6. 従来型ニューラルネットワークによる河川水位予測のまとめ

本章では、従来型の ANN による精度向上を目的として検討を行った。主な検討結果を以下に示す。

- ① 入力層とする上流の水位・雨量観測所の選定において、予測地点水位変化との相関分析により妥当な地点を抽出できることを確認した。
- ② 学習回数・中間素子数の設定において、両者を組み合わせたケーススタディにより検証データの誤差評価を行うことで、過学習を避け最適な設定ができることを確認した。
- ③ 学習データを変化させた複数のモデルによりアンサンブル学習を行うことで、元のモデルを上回る精度となることを確認した。

以上3点より、ANN（従来型）の性能を十分に引き出す知見を整理し、水位予測の精度向上につながる成果が得られた。

3. 深層学習を適用したニューラルネットワーク水位予測モデルの

開発

前章でも検討したように、ANN による洪水予測は統計的手法の一種として既往の研究にて広く適用性が確認されている。一方で ANN の課題として、特に入力データサイズやネットワーク構造が大きい場合、過学習などにより汎化性能の向上が容易ではないことが挙げられる。したがって、ANN の精度向上のためには、入力データ候補を適切に選定することが必要となる。しかしながら、予測時間が長い場合などでは、限られた入力データから精度向上を図るのは難しい。

ANN の新しい手法として深層学習と呼ばれる手法が Hinton et al. (2006) によって提案されている。深層学習の特徴として、学習モデル自らが、大量の入力データの中から本質的な情報の抽出を行うことが挙げられる。深層学習は、画像認識 (Krizhevsky et al., 2012) や音声認識 (Seide et al., 2011)、自然言語処理など様々な分野で研究が進められているが、河川の水位予測に深層学習を適用した事例は見られない。本研究では、深層学習を用いた ANN による河川水位予測手法を開発した。一級河川である大淀川水系の一流域を対象に、開発した手法の適用性を検証した。

3.1. 深層学習を用いた河川水位予測手法

深層学習とは、複数の中間層を用いた ANN により学習を行う手法である。これまで様々な深層学習の方法論が提案されている (岡谷, 2015)。本研究で適用した手法の概要を以下に示す。

3.1.1. ニューラルネットワークの構成

ニューラルネットワークの構成は、第 2 章に示したものと同様に、入力層・中間層・出力層からなる階層型のネットワークとした。

3.1.2. 学習方法の詳細

(1) 入力データの正規化

学習データが偏りを含む場合、学習の効果が低下することが知られている。本件検討では学習計算の実施前にデータの正規化を行った。データの正規化は次式で行われる。

$$x_{ni} \leftarrow \frac{x_i - \bar{x}}{\sigma_i} \dots\dots\dots (3.1)$$

ここで、 x_n は正規化後のデータ、 \bar{x} はデータの平均、 σ は標準偏差、添え字の i はサンプルの組を表わす。なお、計算の終了後、式(3.1)の逆の手順を適用することにより求める予測値を得るものとした。

(2) 確率的勾配降下法

通常の勾配降下法では、全学習サンプルに対して計算される誤差関数を最小化するのに対し、本研究で用いた確率的勾配降下法では学習データの一部を取り出して誤差関数を評価する。通常の勾配降下法に比べ、学習の高速化や局所解への収束を避ける上でメリットを有する。

なお、学習データに用いるデータ集合は、あらかじめ固定されたミニバッチを適用するのが一般的である。ミニバッチの大きさを決める系統的な方法は定まっていないが、学習効率や計算コストの観点から 10~100 前後とする場合が多い(岡谷, 2015)。

(3) 学習係数の設定

勾配降下法では、学習係数の設定が学習の成否を左右する重要な因子となる。本検討での学習係数は、近年最もよく使われている AdaGrad (Duchi et al., 2011) によって定めるものとした。AdaGrad では学習係数を以下のように設定する。

$$\varepsilon = \frac{\varepsilon_0}{\sqrt{\sum_{t=1}^T (\nabla E_{t,i})^2}} \dots\dots\dots (3.2)$$

ここで、 ε_0 は学習係数の初期値、 T は現時刻までの計算ステップ数である。

また、重みの修正量にモーメンタムを与えることにより、勾配降下法の収束性の向上を図った。モーメンタムを適用した際の重み係数の更新式は次式のようになる。

$$w^{(t+1)} = w^{(t)} - \varepsilon \nabla E + \mu \Delta w^{(t-1)} \dots\dots\dots (3.3)$$

ここで、 μ は加算の割合を制御するためのパラメータであり、0.5~0.9程度の範囲で設定されることが多い(岡谷, 2015)。

(4) ドロップアウト

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、本研究ではドロップアウト (Srivastava et al., 2014) を適用した。ドロップアウトは、学習計算時にネットワークの素子を確率 p の割合で無効化することで、ネットワークの自由度を強制的に小さくし過学習を避ける狙いがある。学習終了時後の推論時には、素子からの出力を $(1-p)$ 倍することで、推論時に学習時よりも素子が増えることを補償する。ドロップアウトの概念図を図 3-1に示す。

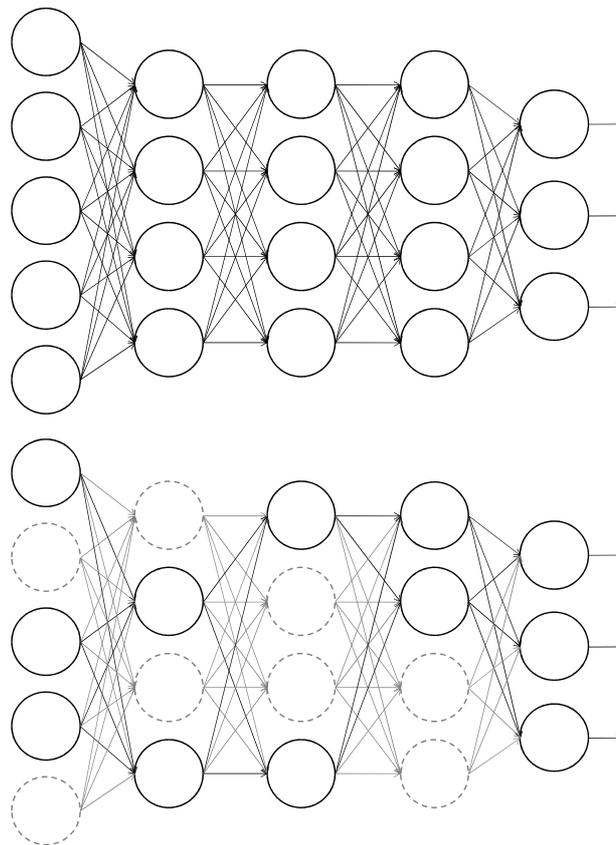


図 3-1 ドロップアウトの概念図

3.1.3. ネットワークの事前学習

ニューラルネットワークに対する誤差逆伝搬法において、勾配消失問題による学習の妨げが大きな課題となっている。特に順伝搬型の多層ネットワークを用いた深層学習の実施にあたっては、事前学習の適用が重要である。

(1) 自己符号化器

勾配消失問題を回避する手法として、自己符号化器による事前学習が有効とされている (Bengio, 2007)。自己符号化器では、図 3-2 のように入力 x と出力 \hat{x} ができるだけ同じになるよう、重みの調整 (学習) を行う。

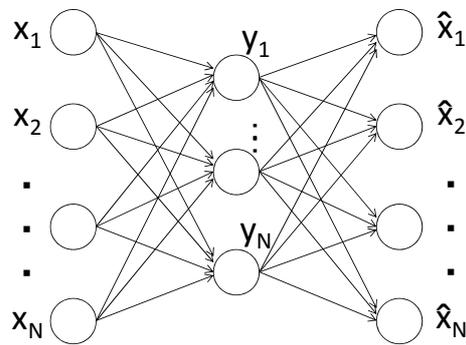


図 3-2 自己符号化器の概念図

(2) デノイジング自己符号化器

自己符号化器を拡張したデノイジング自己符号化器により、さらに精度の高い学習が可能であることが報告されている (Vincent et al., 2010)。デノイジング自己符号化器では、学習データに下記のようにノイズを加える。

$$\tilde{x} = x + \delta x \quad \dots \dots \dots (3.4)$$

ここで、 δ は平均 0、分散 σ^2 のガウス分布に従うランダムノイズである。デノイジング自己符号化器による学習後は、入力を再現できるだけでなく、そのノイズを除去する能力を備えることが期待される。

3.2. 実流域への適用

深層学習を適用した河川水位予測モデルを用いて、実流域でのケーススタディを実施し適用を確認した。適用した流域は国内 1 級河川の大淀川水系（樋渡地点）と遠賀川水系（日の出橋地点）である。

3.2.1. 大淀川流域でのケーススタディ

(1) 大淀川流域の概要

対象流域は、大淀川水系の樋渡（ひわたし）地点流域とした（図 3-3）。流域面積は 861km²、幹川流路延長は 52 km である。周辺に雨量観測所が 14 箇所、流域内に水位観測所が 5 箇所設置されている（表 3-1）。樋渡上流には大きな洪水調整施設がなく、また水位・雨量観測所が多数設置されているため、検討に適している。

(2) 検討対象出水

検討に用いた実績の水位と地上雨量データは、水文・水質データベースより取得した。モデルの構築には、1990 年～2014 年の上位 24 洪水を用いた。各洪水のピークから 72 時間前～48 時間後までを 1 洪水とし、全部で 121 時間×24 洪水=2904 セットの検討データを用意した。なお、1990 年～2014 年の間で氾濫危険水位（9.2m）を超えた洪水は 5 事例あり、そのうち欠測データの多い 1 事例を除いた 4 事例（1990 年、1993 年、2004 年、2005 年）を精度評価の検討対象洪水とした。精度評価対象の 4 洪水の降雨の特徴をみると、総雨量は検討対象 24 洪水中 19 位（244mm）、2 位（608mm）、4 位（439mm）、1 位（759mm）となっており、1990 年洪水以外は総雨量が大きい。また時間雨量では 8 位（31.8mm/h）、11 位（30.0mm/h）、10 位（30.1mm/h）、16 位（25.5mm/h）となっており、いずれも中位程度である。なおここでの雨量は検討対象 14 地点の平均雨量とし、総雨量は検討対象の 121 時間の累積とした。

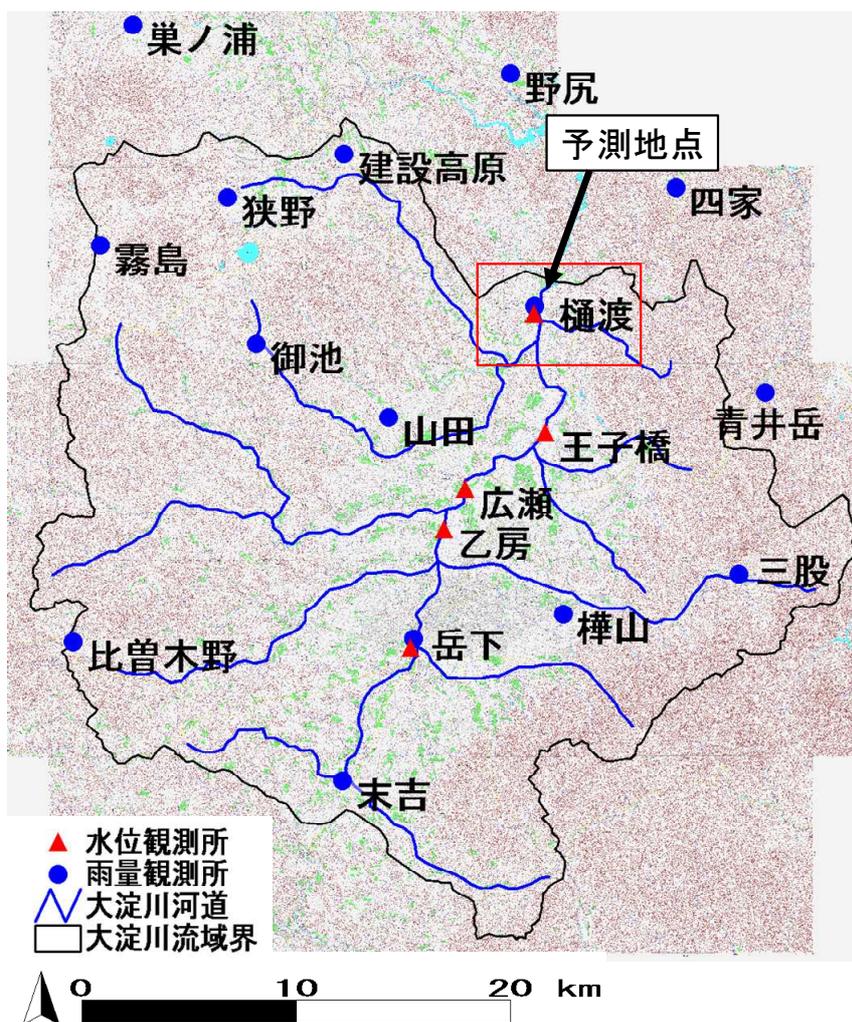


図 3-3 大淀川、樋渡地点流域および観測所の位置図

表 3-1 対象流域の観測所一覧

種別	観測所数	観測所名
水位観測所	5	樋渡、王子橋、広瀬、乙房、岳下
雨量観測所	14	巢ノ浦、野尻、建設高原、四家、狭野、霧島、御池、樋渡、青井岳、三股、樺山、岳下、比曾木野、末吉 (山田は未観測期間があるため除く)

(3) 深層学習を用いた水位予測モデルの設定

1) ネットワーク構造

入力層・二つの中間層および出力層からなる 4 層のネットワークとした。なお 5 層以上のネットワークも有力と考えられるが、本研究では検討対象外とした。

2) 入出力データ

入出力層の組合せは表 3-2の通りとした。入力データは、水位予測に影響を及ぼしうる地点・時刻のデータをできる限り包含するように設定した。前章で実施した相関分析より、樋渡水位変化に対する各水位観測所の水位変化の相関は、タイムラグが 1,2 時間の時に最大となったため、入力層には現時刻から 2 時間前までのデータを設定した。また同様に各降雨観測所についても、タイムラグ 1,2 時間の時に相関が最大となったが、累積雨量が影響する可能性を考慮して予測時刻から 5 時間前までのデータを設定した。

例えば 3 時間予測を行う場合には、出力層は現時刻から 3 時間後までの樋渡の水位変化である。入力層には樋渡の 1 時間前と現時刻の水位、流域内 5 水位観測所の 2 時間前～現時刻における一時間あたりの水位変化、流域内 14 地点の 2 時間前～2 時間後の時間雨量である。以上より、1 つの学習データセットは 87 個のデータより構成される。同様の組合せで、全部で 2904 セットのサンプルを検討データとした。なお将来時刻の雨量には、実測雨量を予測雨量に見立てた完全予測データを用いた。将来時刻の水位は未知であるため、水位変化は現時刻までのものを入力データに用いた。

表 3-2 t 時間予測の入出力層の組合せ

入力			出力
種別	地点	時刻	
時刻水位	樋渡	-1,0	樋渡の水位変化
一時間の水位変化	流域内 5 地点	-2,-1,0	
時刻雨量	流域内 14 地点	t-5,t-4,t-3,t-2,t-1	

(4) ケーススタディの設定

学習に関する各種の設定が、どのように予測精度に影響するか不明である。本研究ではケーススタディにより予測精度の比較を行った。ドロップアウト率(ρ)、学習回数、各層の素子数について表 3-3の通りスタディケースを設定した。各ケースについて自己符号化器にデノイズングの設定あり・無しの場合を計算した。また、学習の基本設定は表 3-4の通りとした。

表 3-3 学習の各種設定に関するスタディケース

ケース番号	学習回数	各層の素子数	ドロップアウト率 (ρ)
1	300	87-10-5-1	0.1
2	1000	87-20-10-1	0.3
3	3000	87-40-20-1	0.5
4	10000	87-60-30-1	

表 3-4 学習の各種設定

種別	観測所名
学習データ期間	1990～2014 の上位 24 洪水
学習データ種類	樋渡水位、上流水位変化、時間雨量
データセット数	2904
バッチサイズ	100
予測時間	1 時間～6 時間
モーメンタム	0.5
学習率	初期値 0.1 として AdaGrad で自動設定
デノイズングの加算ノイズ	平均 0、分散 3% の正規乱数

(5) 予測計算の実施

検証対象 4 洪水に対して leave-one-out 交差検証を行った。具体的には、対象 24 洪水のうち 1 洪水を検証データ、残り 23 洪水を学習データとした計算を 1 セットとし、同様の手順を検証対象 4 洪水について行うことで精度を評価した。なお精度評価の対象は、水位が顕著に上昇し始めた時刻からピーク 6 時間後までの期間における水位の RMSE とした。精度評価期間を図 3-4 中に点線で示す。

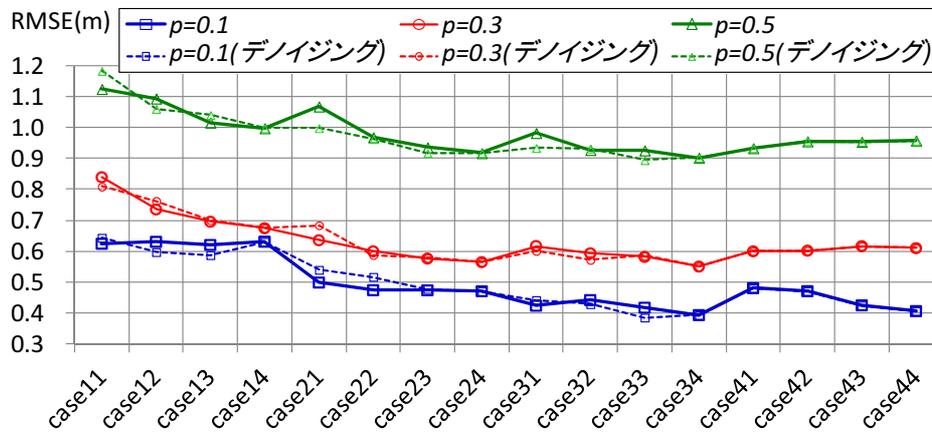


図 3-4 各ケースの RMSE (1～6 時間予測の平均)

(6) ケーススタディの結果

1) 各ケースの比較

ケーススタディの結果について、1~6 時間予測の平均 RMSE をケースごとに整理したものを図 3-4に示す。図中のケース番号は便宜的に表 3-3の番号に対応するものとし、10 の位が学習回数、1 の位が各層の素子数を表わすものとした。例えばケース 12 は、学習回数が 300、各層の素子数が (87-20-10-1) である。ドロップアウト率(p)およびデノイジングの設定は、それぞれ異なる線で表示している。図 3-4より、case33 ($p=0.1$ 、デノイジングあり) の場合が最も再現性が高い結果となった。また、各設定による予測精度への影響は下記の通りである。

学習回数については、3000 (case31~34) とした場合が最も精度が高かった。ただし、3000 と 10000 (case41~44) の差は明確でなく、3000 回程度で十分に学習が収束に近づいているものと推察される。300 (case11~14) では精度が低く、学習が不十分であると考えられる。

各層の素子数については、素子数を増やすほど精度が高くなる傾向が見られた。ただし、(87-40-20-1)と(87-60-30-1)では明確な差が見られず、例えば case31~34 では(87-40-20-1)のケースで誤差最小ケースが得られており、(87-60-30-1)では過学習の影響が表れ始めているものと推察される。

ドロップアウト率(p)については、0.1 にした場合が最も精度が高く、次いで 0.3、0.5 の順となった。ドロップアウト率は、一般的に入力層で 0.1 程度、中間層で 0.5 程度に設定するケースが多いが、本研究では入力層・中間層に対して一律値を設定したため、入力層の一般値に引きつけられた結果となった。

デノイジングの設定有無については、ほとんど差が無いが、設定した方が精度が良くなるケースがやや多い結果となった。

2) 複数ネットワークのモデル平均

ケーススタディで最も精度の高かったケース 33 ($p=0.1$ 、デノイジングあり) に対して、重み係数の初期値をランダムに設定して 10 回の計算を行い、結果の平均をとったものについて精度検証を行った。表 3-5に示すように、10 回計算の平均をとったものの方が精度が高くなる結果となった。

表 3-5 単独モデルと 10 モデル平均の RMSE

計算方法	予測時間					
	1h	2h	3h	4h	5h	6h
単独計算	0.13	0.20	0.29	0.41	0.61	0.67
10 回計算の平均	0.12	0.19	0.27	0.39	0.54	0.65

3) 従来型ニューラルネットワーク（3層ネットワーク）との比較

図 3-5～図 3-8に、深層学習を適用したニューラルネットワークと、従来型ニューラルネットワーク（3層ネットワーク）の結果を合わせて示す。図 3-9に、4 洪水平均での水位誤差（RMSE）の比較を示す。

深層学習を適用した ANN の結果は、従来型 ANN に比べて 1～6 時間予測の水位誤差が低減されている。

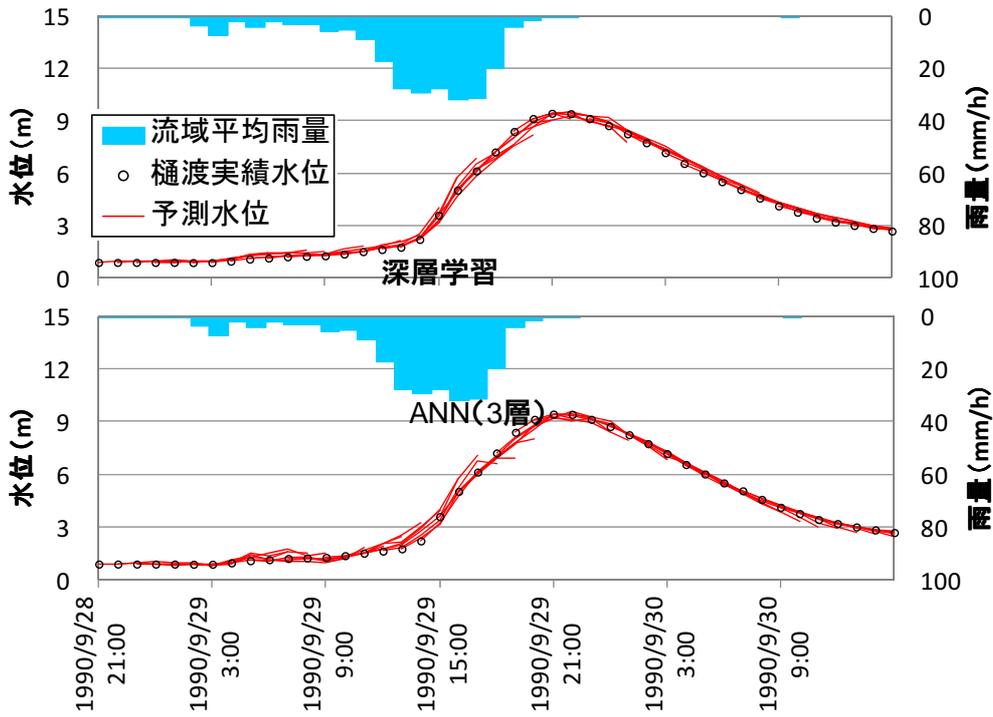


図 3-5 深層学習と従来型 ANN (3 層) との比較 (1990 年洪水、樋渡)

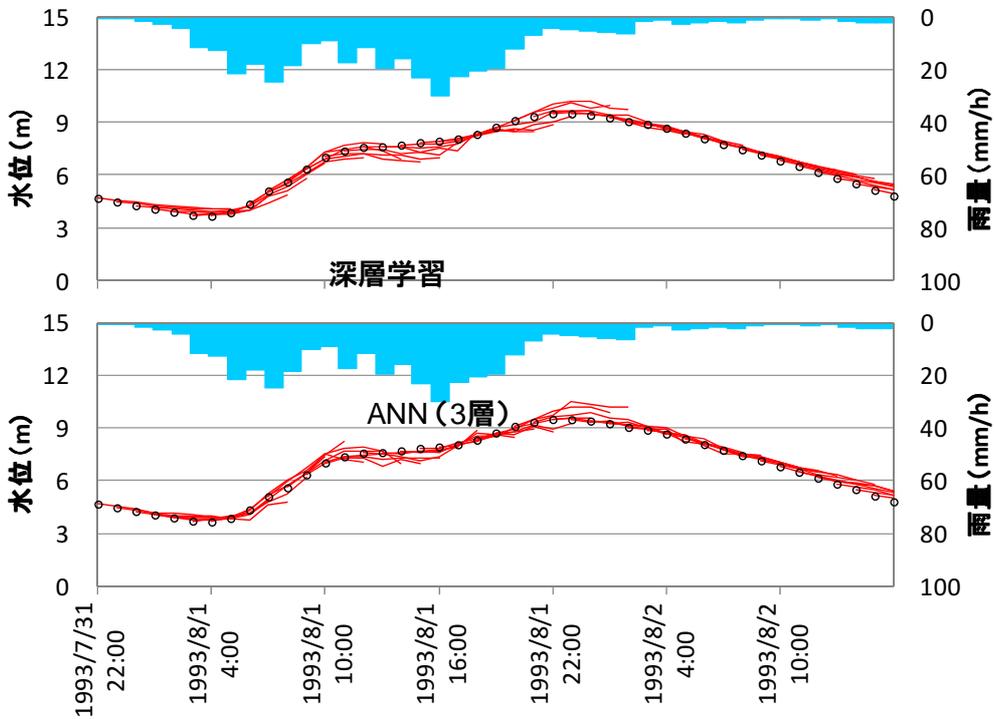


図 3-6 深層学習と従来型 ANN (3 層) との比較 (1993 年洪水、樋渡)

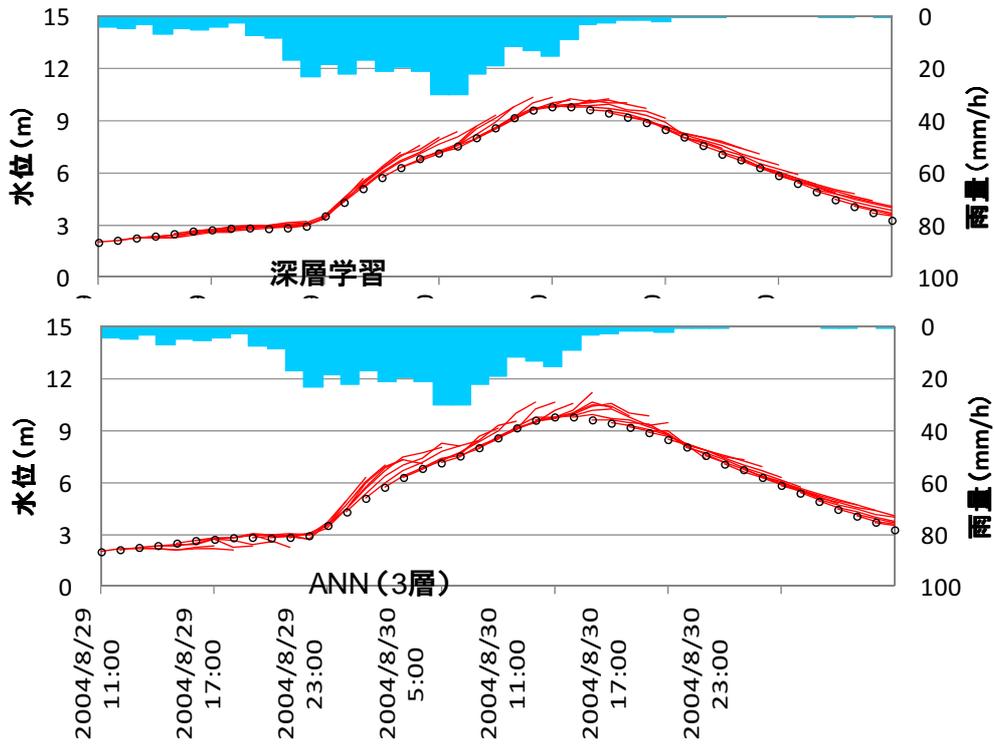


図 3-7 深層学習と従来型 ANN (3層) との比較 (2004 年洪水、樋渡)

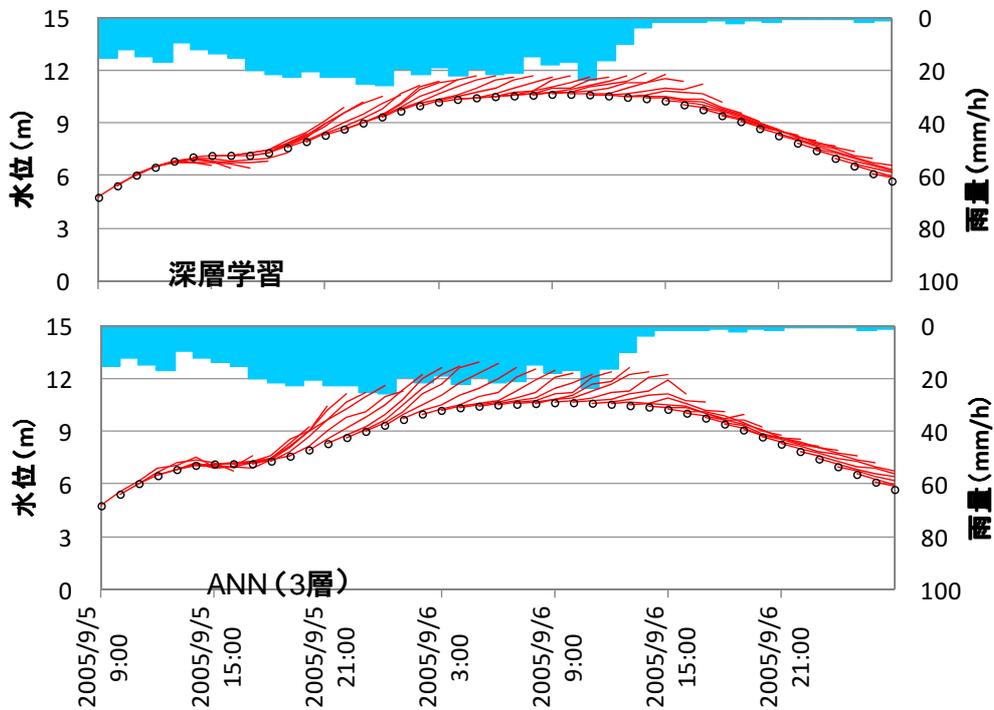


図 3-8 深層学習と従来型 ANN (3層) との比較 (2005 年洪水、樋渡)

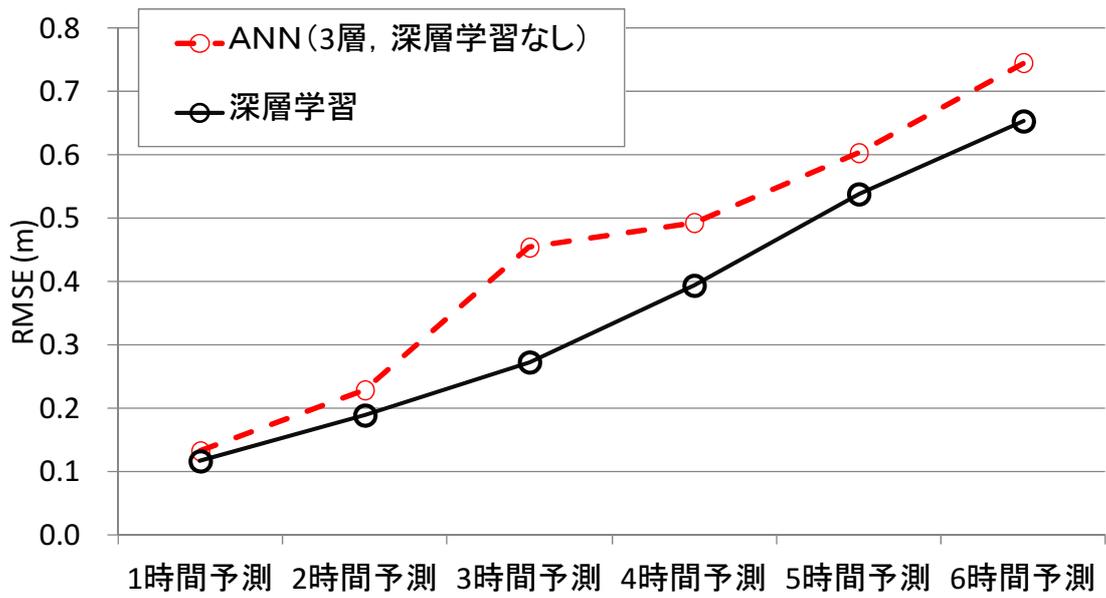


図 3-9 深層学習と従来型 ANN (3 層) との RMSE 比較 (4 洪水平均)

4) 3層 ANN と 4層 ANN との比較

図 3-10～図 3-13に、従来型ニューラルネットワーク（3層ネットワーク）と、深層学習を適用しない4層のニューラルネットワークの結果を合わせて示す。図 3-14に、4洪水平均での RMSE の比較を示す。

深層学習を適用しない4層の ANN の結果は、3層 ANN に比べて精度が下がっている。したがって、単純に中間素子の数を増やすだけでは精度向上につながらないことが考察され、深層学習の技法による精度向上の効果が裏付けられる結果となった。

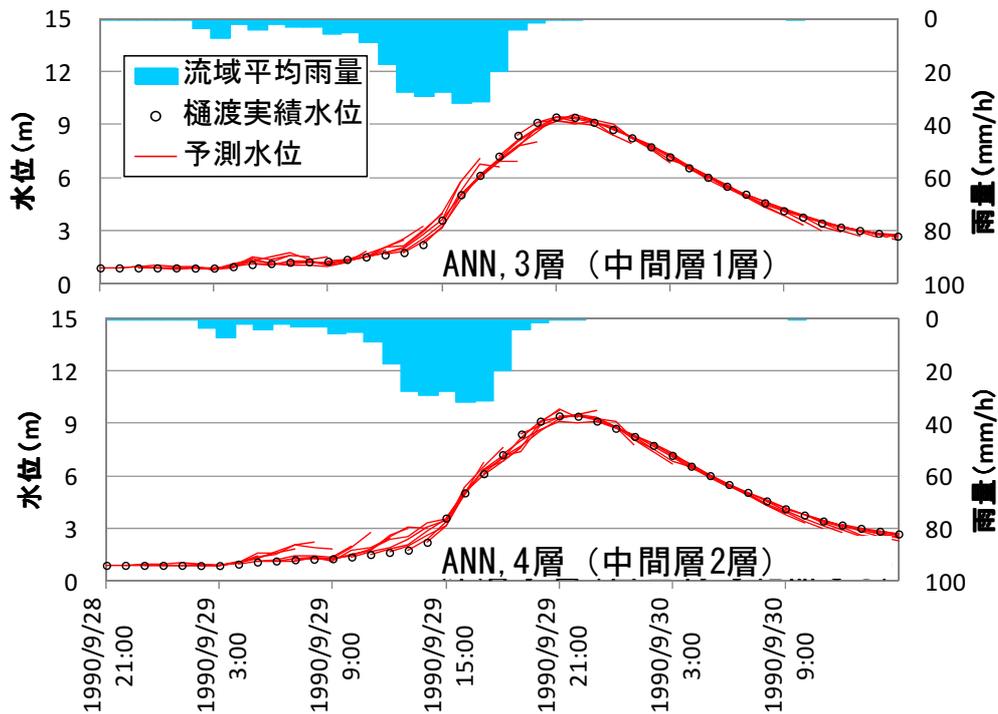


図 3-10 3層 ANN と 4層 ANN との比較 (1990年洪水、樋渡)

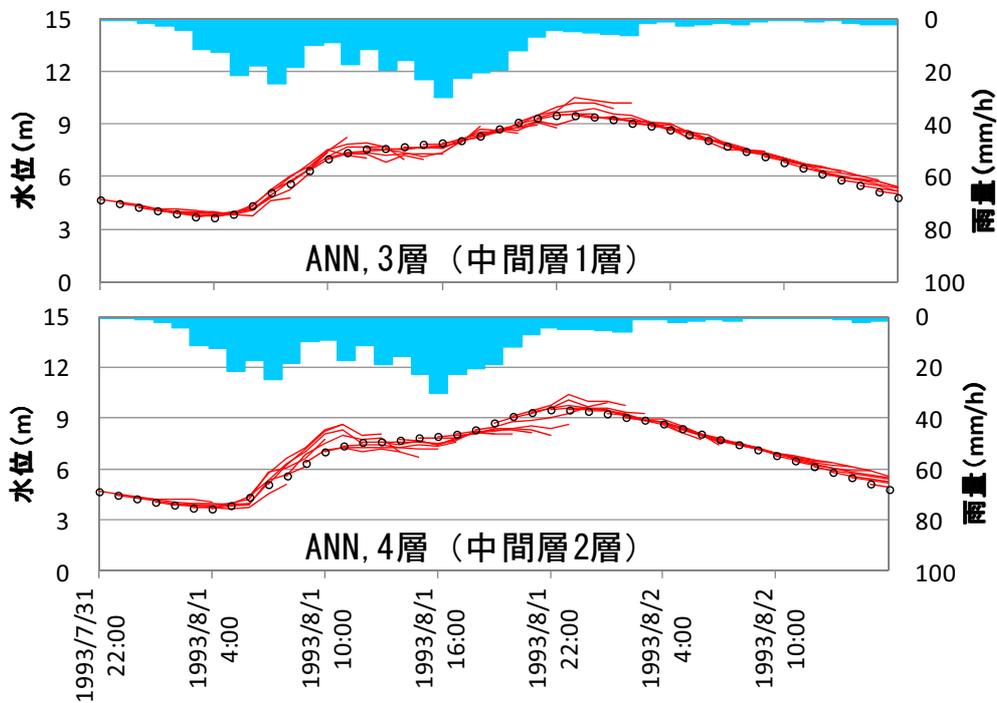


図 3-11 3層 ANN と 4層 ANN との比較 (1993年洪水、樋渡)

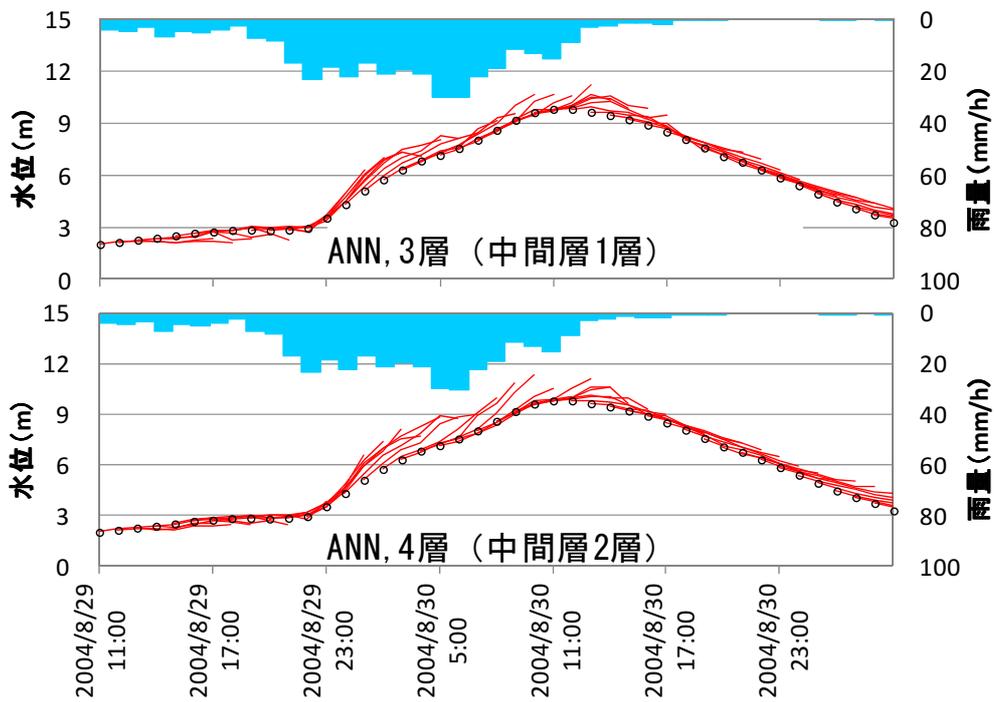


図 3-12 3層 ANN と 4層 ANN との比較 (2004 年洪水、極渡)

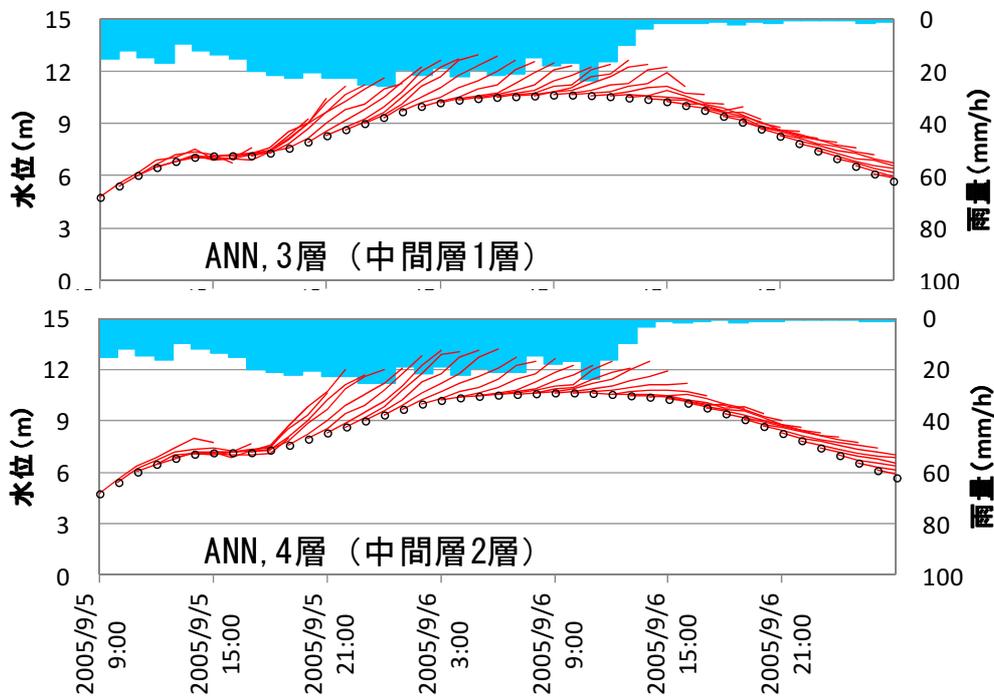


図 3-13 3層 ANN と 4層 ANN との比較 (2005 年洪水、極渡)

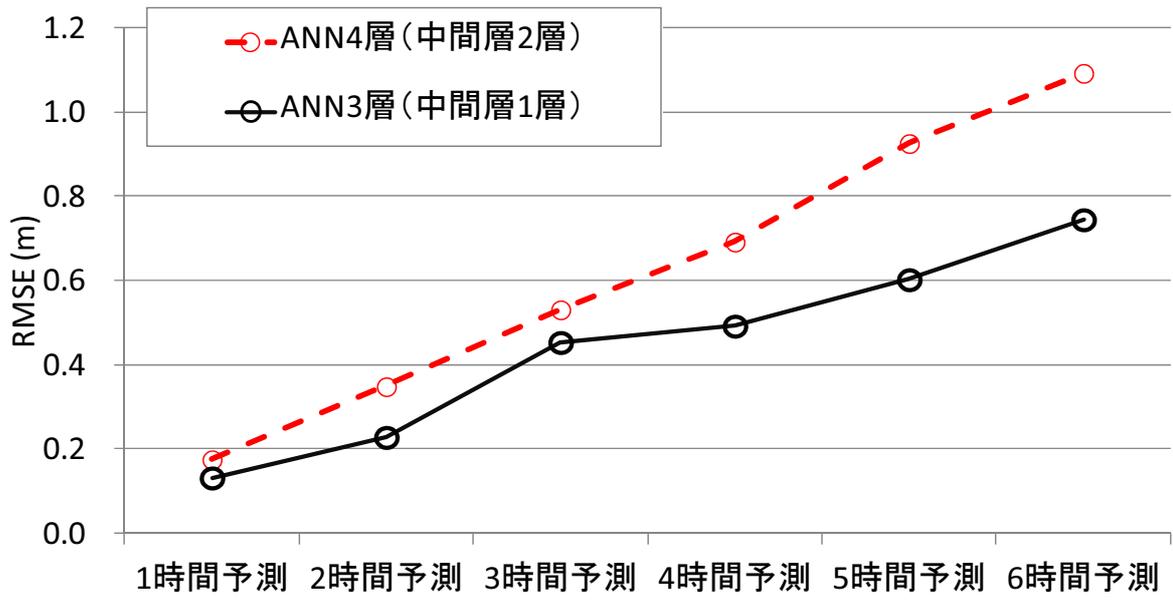


図 3-14 3層 ANN と 4層 ANN との RMSE 比較 (4年洪水、樋渡)

3.2.2. 遠賀川流域でのケーススタディ

(1) 遠賀川流域の概要

遠賀川流域（福岡県）、日の出橋地点を対象流域とした。流域および観測所の位置図を図 3-15に示す。流域面積は 695 km² である。本流域は、前節の大淀川樋渡地点流域（861 km²）よりも一回り小さく、また予測地点直前で二つの支川が合流しているため、より急激な水位上昇が頻繁に見られる。

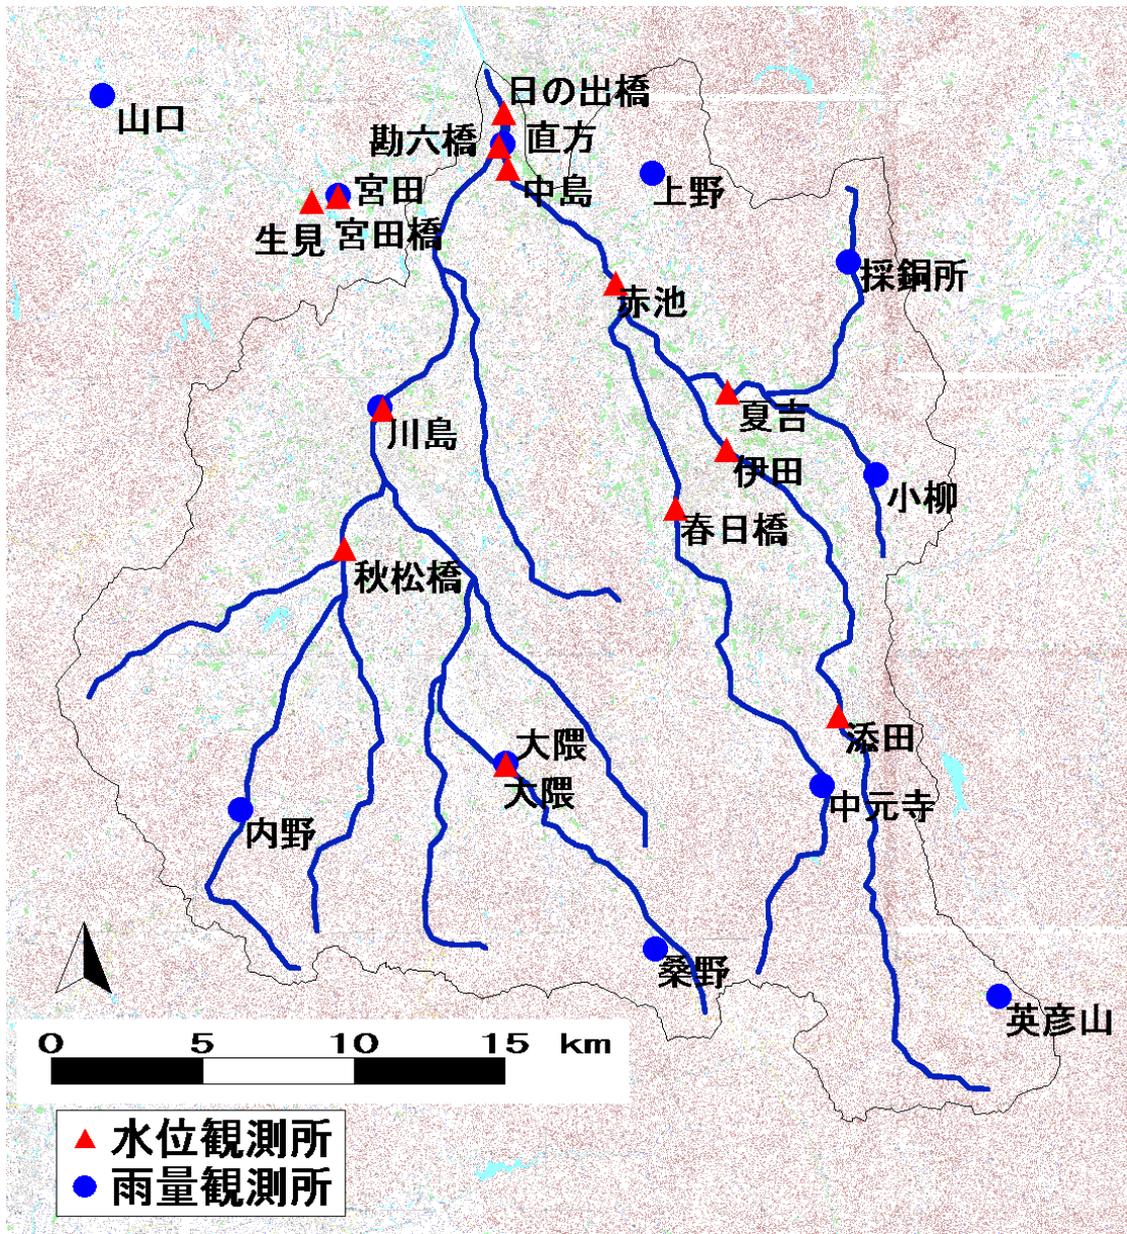


図 3-15 遠賀川、日の出橋地点流域および観測所の位置図

(2) 検討対象出水

2005～2014年の間の上位20洪水の水位雨量データを水水DBより取得した。ピークから72時間前～48時間後までの121時間分を1洪水とする。20洪水×121=2420セットの検討データとした。氾濫危険水位(7.7m)を超えた3洪水を精度検証対象とした。

(3) 深層学習を用いた水位予測モデルの設定

1) ネットワーク構造

入力層・二つの中間層および出力層からなる4層のネットワークとした。

2) 入出力データ

入出力層の組合せは表3-6の通りとした。例えば3時間予測を行う場合には、出力層は現時刻から3時間後までの日の出橋の水位変化である。入力層には樋渡の1時間前と現時刻の水位、流域内11水位観測所の2時間前～現時刻における1時間あたりの水位変化、流域内11地点の2時間前～2時間後の時間雨量である。以上より、t時間予測の入出力層の組合せは表3-7の通りとなり、1つの学習データセットは90個のデータより構成される。同様の組合せで、全部で2420セットのサンプルを検討データとした。なお前節の大淀川におけるケーススタディと同様に、将来時刻の雨量については、実測雨量を予測雨量に見立てた完全予測データを用いた。将来時刻の水位は未知であるため、水位変化は現時刻までのものを入力データに用いた。

表 3-6 対象流域の観測所一覧

種別	観測所数	観測所名
水位観測所	11	日の出橋,秋松橋,添田,伊田,赤池,中島,夏吉,春日橋,大隈,勘六橋,川島
雨量観測所	11	直方,上野,宮田,採銅所,川島,小柳,大隈,中元寺,内野,桑野,英彦山

表 3-7 t時間予測の入出力層の組合せ

入力			出力
種別	地点	時刻	
時刻水位	日の出橋	-1,0	日の出橋の 水位変化
一時間の 水位変化	流域内 11地点	-2,-1,0	
時刻雨量	流域内 11地点	t-5,t-4,t-3,t-2,t-1	

(4) ケーススタディの設定

学習に関する各種の設定が、どのように予測精度に影響するか不明である。本研究ではケーススタディにより予測精度の比較を行った。ケーススタディでは、ドロップアウト率(p)、学習回数、各層の素子数について表 3-8の通りケースを設定した。各ケースについて自己符号化器にデノイジングの設定あり・無しの場合を計算した。また、学習の基本設定は表 3-9の通りとした。

表 3-8 学習の各種設定に関するスタディケース

ケース番号	学習回数	各層の素子数	ドロップアウト率(p)
1	300	90-10-5-1	0.1
2	1000	90-20-10-1	0.3
3	3000	90-40-20-1	0.5
4	10000	90-60-30-1	

表 3-9 学習の各種設定

種別	観測所名
学習データ期間	2005～2014 の上位 20 洪水
学習データ種類	樋渡水位、上流水位変化、時間雨量
データセット数	2420
バッチサイズ	100
予測時間	1 時間～6 時間
モーメンタム	0.5
学習率	初期値 0.1 として AdaGrad で自動設定
デノイジングの加算ノイズ	平均 0、分散 3%の正規乱数

(5) ケーススタディの結果

1) 従来型ニューラルネットワーク（三層ネットワーク）との比較

図 3-16～図 3-18に、深層学習を適用したニューラルネットワークと、従来型ニューラルネットワーク（3層ネットワーク）の結果を合わせて示す。図 3-19に、4洪水平均での水位誤差（RMSE）の比較を示す。

深層学習を適用した ANN の結果は、従来型 ANN に比べて 1～6 時間予測の水位誤差が低減されている。

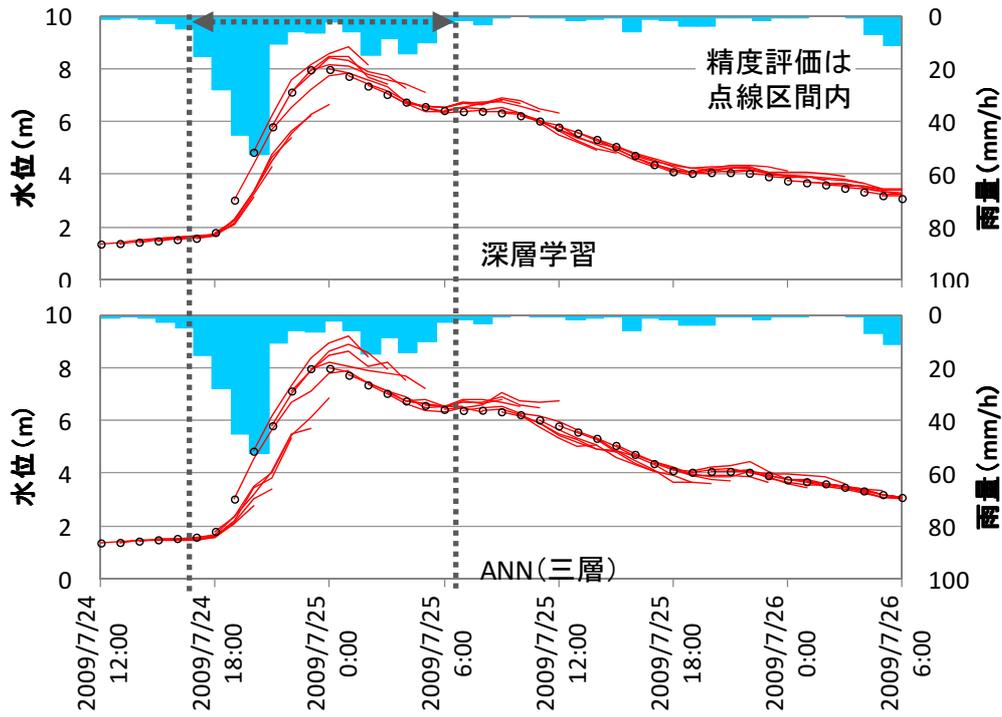


図 3-16 深層学習と従来型 ANN (3 層) との比較 (2009 年洪水、日の出橋)

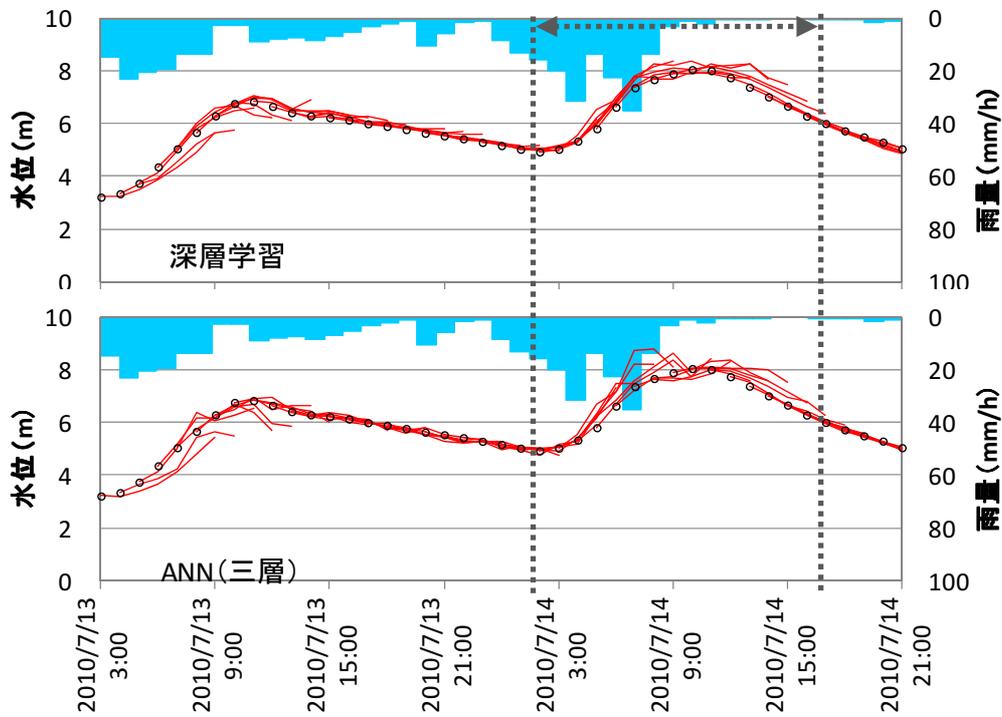


図 3-17 深層学習と従来型 ANN (3 層) との比較 (2010 年洪水、日の出橋)

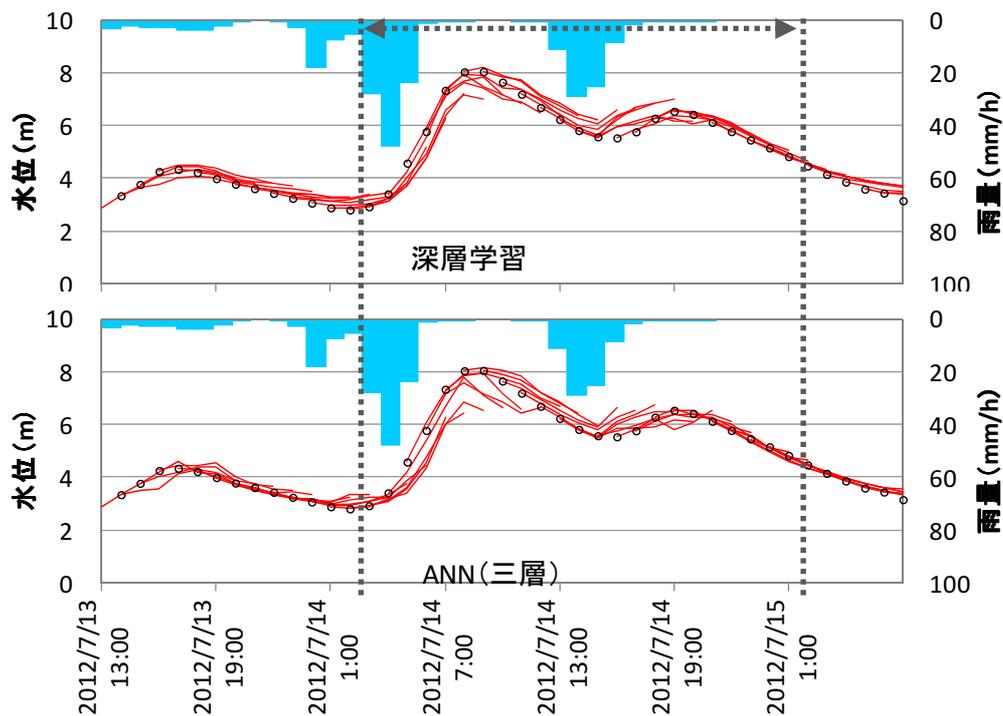


図 3-18 深層学習と従来型 ANN (3 層) との比較 (2012 年洪水、日の出橋)

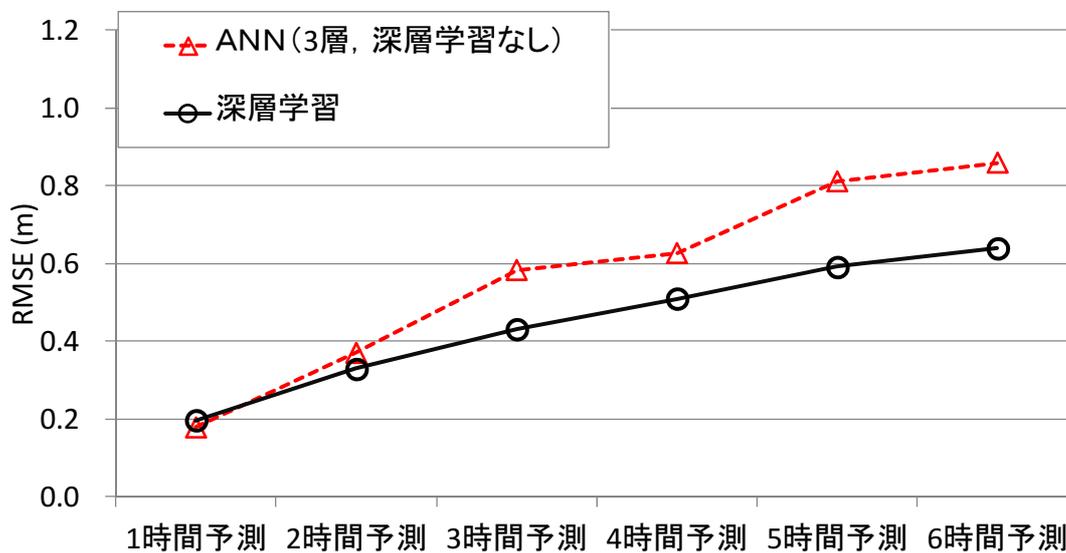


図 3-19 深層学習と従来型 ANN (3 層) との RMSE 比較 (3 洪水平均、日の出橋)

2) 事前学習の有無による比較

図 3-20～図 3-22に、従来型ニューラルネットワーク（3 層）と、深層学習を適用しない4層のニューラルネットワークの結果を合わせて示す。図 3-23に、4 洪水平均での RMSE の比較を示す。

前節でのケーススタディと同様に、深層学習を適用しない4層の ANN の結果は、3 層 ANN に比べて精度が下がっている。したがって、単純に中間素子の数を増やすだけでは精度向上につながらないことが考察され、深層学習の技法による精度向上の効果が裏付けられる結果となった。

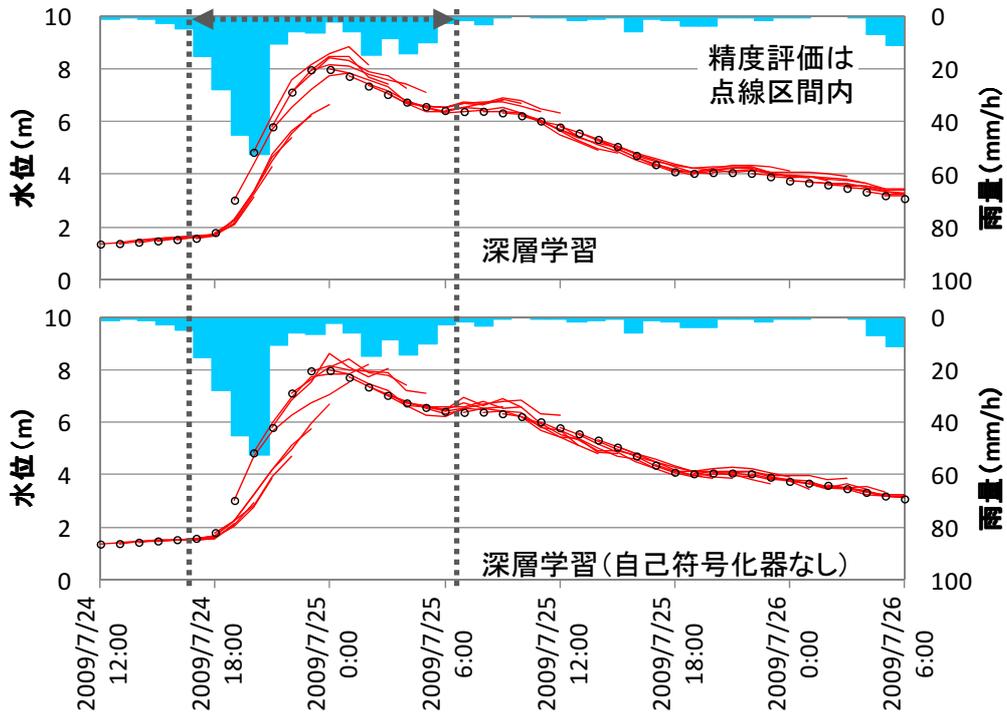


図 3-20 3層 ANN と 4層 ANN との比較 (2009 年洪水、日の出橋)

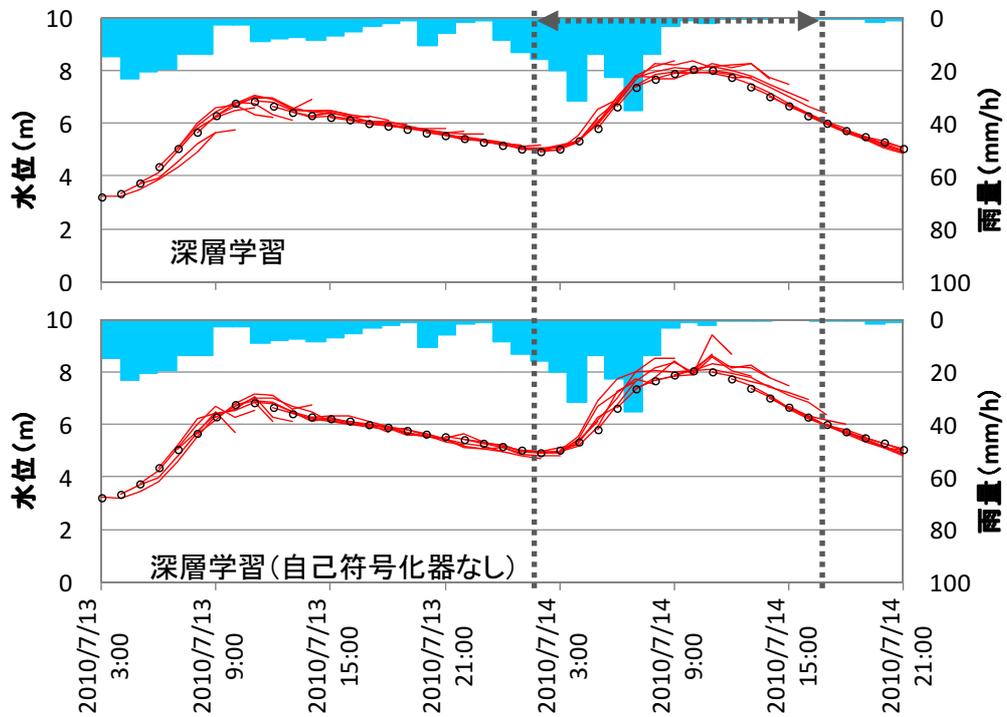


図 3-21 3層 ANN と 4層 ANN との比較 (2010 年洪水、日の出橋)

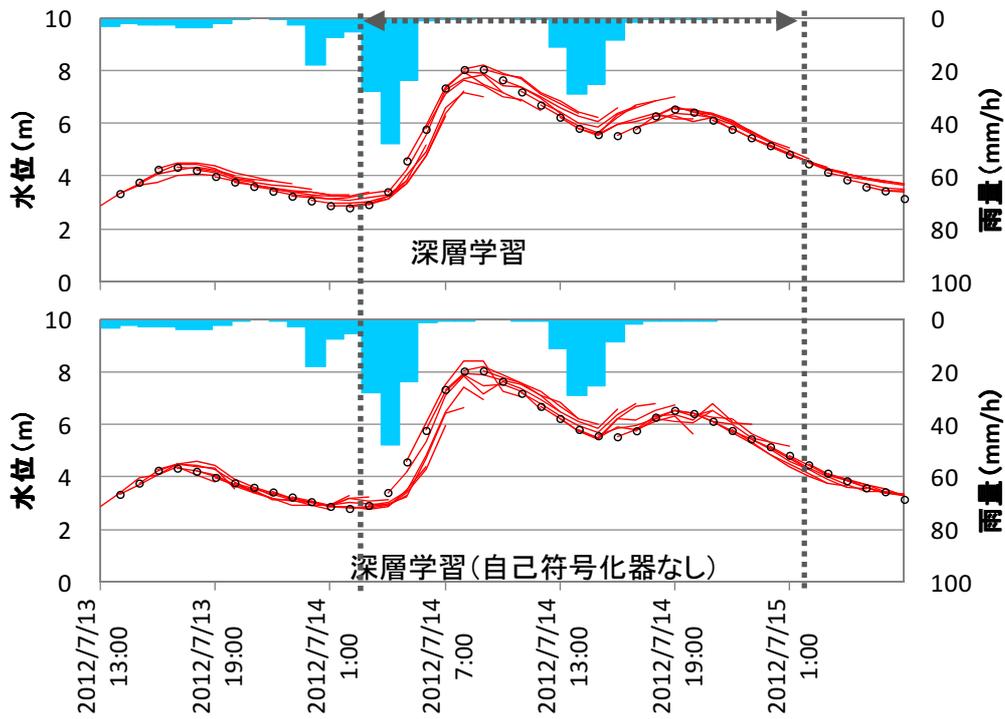


図 3-22 3層 ANN と 4層 ANN との比較 (2012 年洪水、日の出橋)

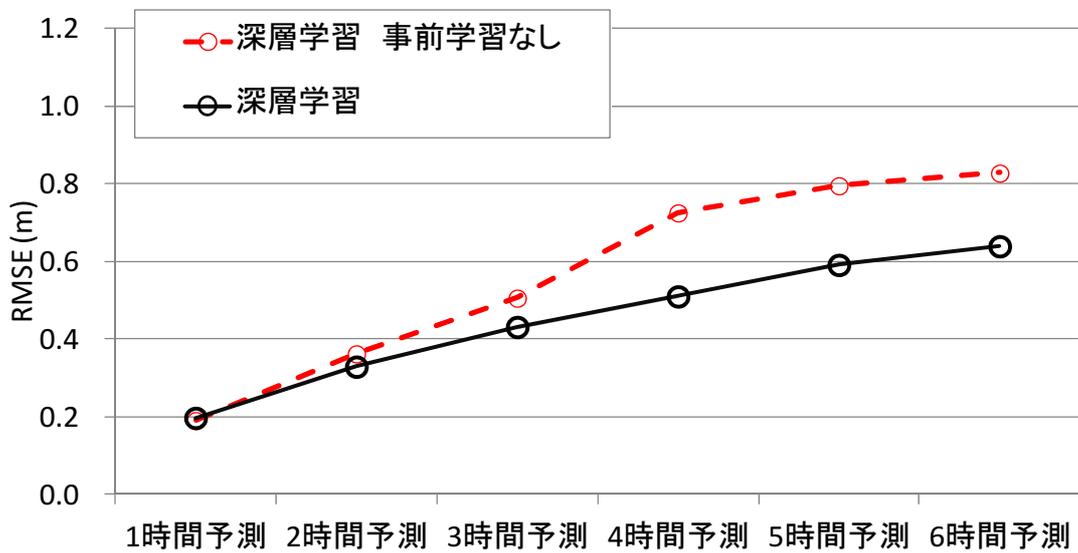


図 3-23 3層 ANN と 4層 ANN との RMSE 比較 (3 洪水平均、日の出橋)

3.3. 深層学習を適用した河川水位予測手法のまとめ

本研究では、深層学習を用いた河川水位予測手法の開発を行い、実河川における適用性の確認を行った。提案手法の結果は、他の手法と比較して高い精度を示しており、今後の活用に向けた有効性が示唆される結果となった。

今後の課題として、①複数の河川におけるケーススタディを行い手法の適用性を確認すること、②リアルタイム予測システムへの適用を前提に、予測雨量の誤差による影響を把握すること、③入力データを含め、学習モデルに関する様々な計算設定条件・パラメータ等についての知見を蓄積すること、等が挙げられる。

4. 物理的手法の適用と、粒子フィルタによる同化手法の検討

物理型モデルによる予測手法は、レーダ雨量データ、標高データ、土地利用データ等の整備・高度化や、計算機の世界向上に伴って、精度向上が期待されている。また、モデルの任意地点で予測水位を算出可能であるため、縦断的な河道の水位把握ができるなど、統計的手法にはないメリットを有している。

一方で様々な誤差要因は不可避である。誤差要因として、例えばモデル自体の誤差、パラメータ設定の誤差、HQ式の誤差等が挙げられる。したがって、物理型モデルを実時間洪水予測に適用する際には、予測誤差を時々刻々とするフィードバック(同化手法)が必要である。観測データを用いた同化手法として、近年では粒子フィルタによる状態量補正が注目されており(田中・杉浦, 2012; 立川ほか, 2011; DeChant and Moradkhani, 2005; Moradkhani et.al., 2005b)、有望な手法の一つと考えられる。

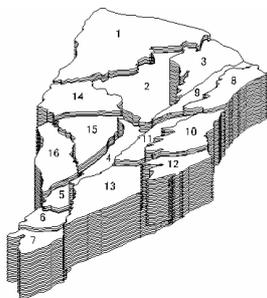
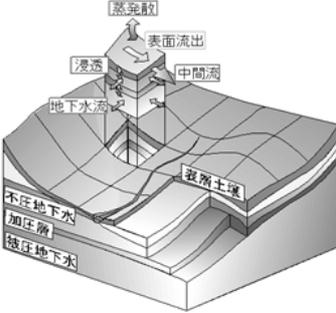
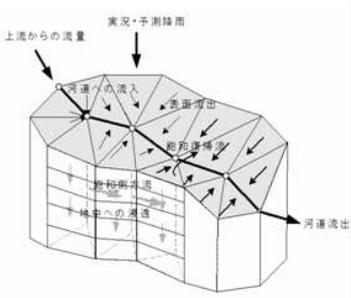
本研究では、高速・高精度な物理型洪水予測モデルの開発および粒子フィルタの適用性検討、精度評価を行った。

4.1. 分布型モデルの開発

我が国の従来の洪水予測システムでは、貯留関数法などの集中型モデルによる流出解析がほとんどであった。しかしながら、近年の水文技術の発展、計算機能力の向上、地形・土地利用といった基礎データの整備等に伴い、より流出予測精度が期待できる分布型モデルの適用が進められている。分布型モデルの特徴の一つとして、レーダ雨量など流域内の平面的な降雨分布を計算に反映できることが挙げられる。また分布型モデルでは、流域内の降雨～流出過程を物理モデルにより、できる限り実現象に忠実に表現しており、平常時・洪水時を含め様々な降雨に対して高い流出計算精度が発揮される。

分布型流出モデルにおける流出計算では、流域を複数のメッシュに分割し、各メッシュにおける降雨～流出過程を物理式に基づいて計算することで、任意の地点における水位・流量を算定する。メッシュ分割の方法によって、分布型モデルはいくつかの種類に分けることができる。当社の保有する代表的な分布型流出モデルとして、表 4-1 に示すような①要素集合型、②グリッド型、③非構造格子型、を挙げることができる。①の要素集合型は、水文学的に均一なブロック毎に分割を行う。②のグリッド型は矩形のメッシュに分割するモデルであり、多くのモデルではこのような矩形のメッシュ分割が行われる。③の非構造格子型では任意の三角形や四角形でメッシュ分割を行うものであり、流域の地形形状を柔軟に表現できるという特徴を持つ。

表 4-1 代表的な流出モデルの概要

モデル分類	要素集合型 (SHER)	グリッド型 (NK-GHM)	非構造格子 (NK-UHM)
流域のモデル化	斜面毎あるいは谷毎に河道近傍とその上流に区分する。	250m の正方形メッシュに分割する。	三角形要素を用いて、流域を適宜分割する。(要素の1辺が約 250m。)
モデル概念図			

本検討で用いる非構造メッシュを用いた流出モデルの概要を以下に列挙する。また、モデルの概念図を図 4-1に示す。

- ① 有効降雨を地表面に供給する。
- ② 浸透能を超える降雨は、地表流へ供給させる。
- ③ 地表より浸透した降雨は、不飽和鉛直浸透流として表土層中を降下する。鉛直浸透流はリチャーズ式により計算を行う。
- ④ 鉛直浸透により基盤へと達した水は、基盤上に表層帯水層を形成する。帯水層中の水は飽和側方流として二次元的に流動する。飽和側方流は Darcy 則に従うフラックスと連続式による計算をする。
- ⑤ 表層が飽和して地下水面が地表に達した場合は、復帰流として地表面へ湧出させる。表面流モデルは、計算負荷を軽減し、実用上の解析精度を損なわない Diffusion Wave モデルを用いる。
- ⑥ 河道に流れ込む表面流は、一次元河道流への入力項として河道に供給する。河道流モデルについては、物理現象に忠実な Dynamic Wave モデルを用いる。

以上の手順により、時間ステップごとの不飽和浸透流、飽和側方流、地表流、河道流を計算する。計算手順を図 4-2に、計算の模式図を図 4-3に示す。

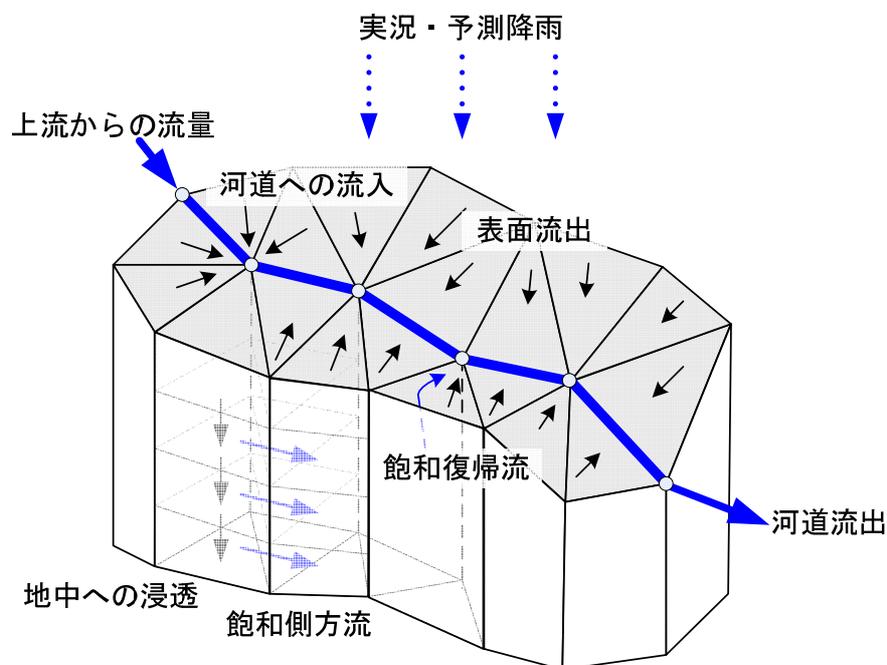


図 4-1 分布型流出モデルの概念図

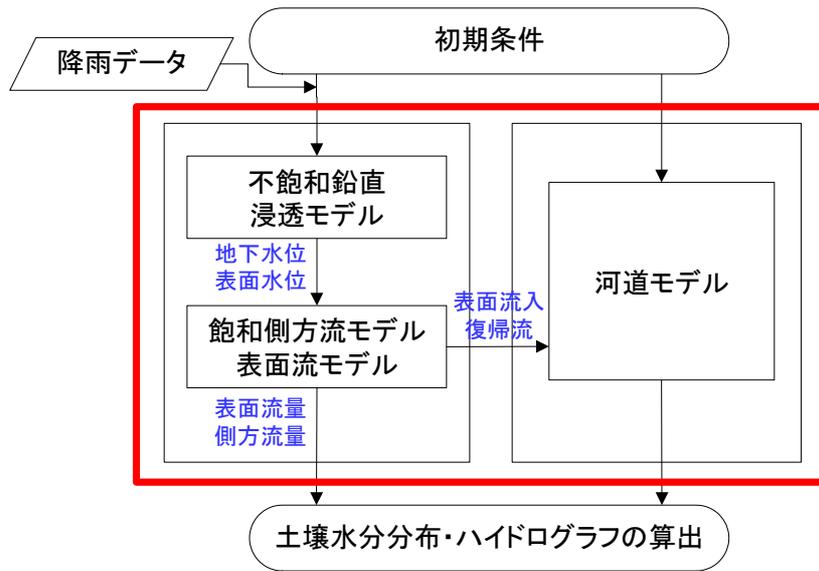


図 4-2 分布型モデルの計算フローチャート

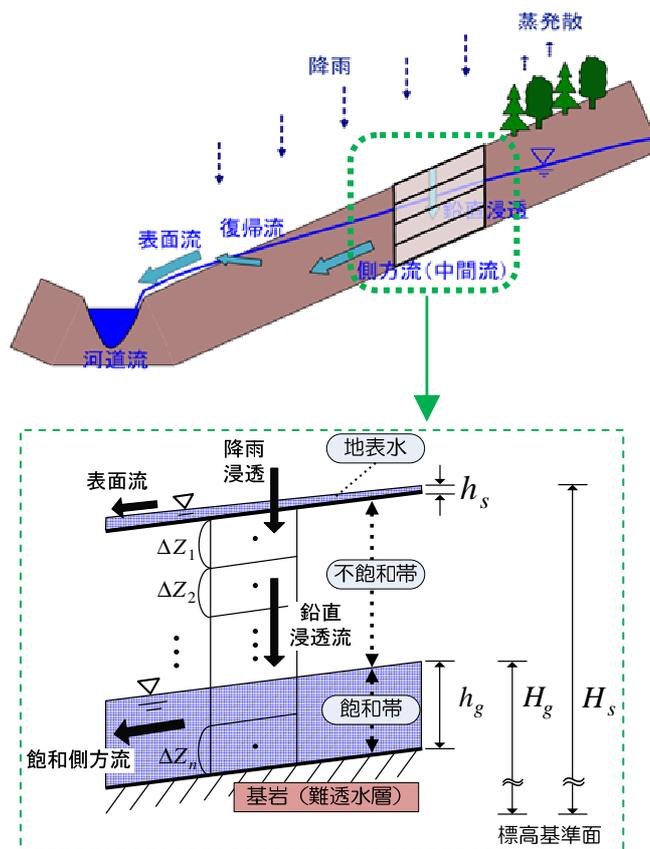


図 4-3 鉛直浸透流・表面流および飽和側方流の模式図

(1) 降雨の設定

モデルの入力条件となるレーダメッシュ雨量は、流出計算のメッシュごとに与える。図 4-4のように、レーダ雨量メッシュ (1km メッシュ) と流出計算メッシュとの位置関係を重ね合わせることで、降雨分布を計算に反映させるものとした。

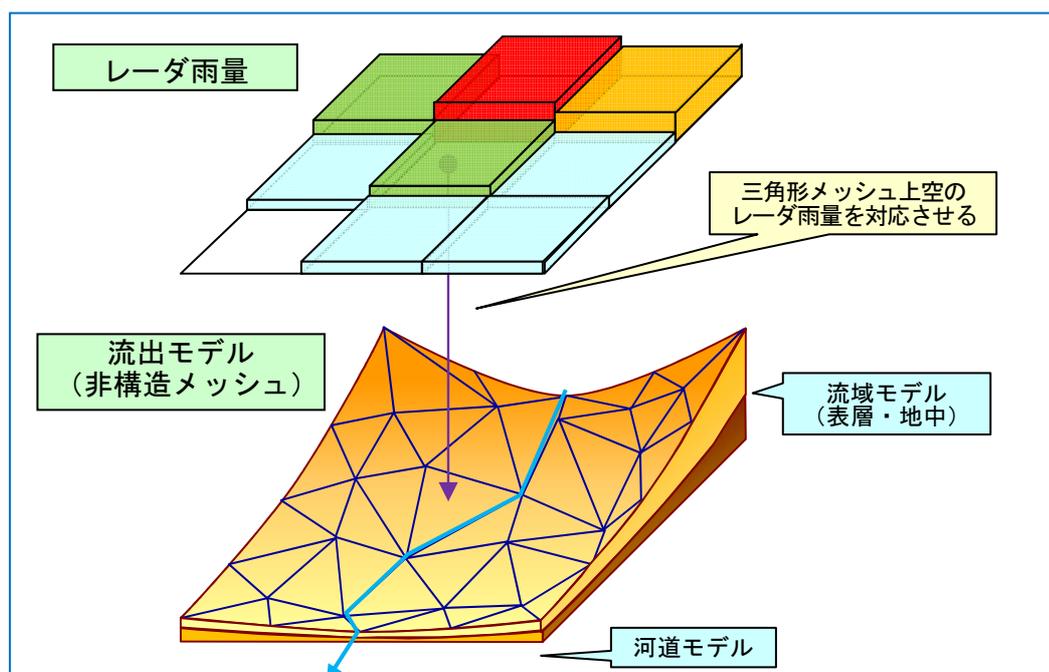


図 4-4 レーダ雨量メッシュと流出計算メッシュの重ね合わせ

(2) 鉛直飽和・不飽和浸透流

鉛直浸透流はリチャーズ式により演算を行う。リチャーズ式の支配方程式は以下の通りである。

$$(S_s S_w + C) \frac{\partial h_w}{\partial t} = - \frac{\partial}{\partial z} \left\{ k \cdot k_r \left(\frac{\partial h_w}{\partial z} - 1 \right) \right\} + q_w \quad \dots \dots \dots (4.1)$$

ここで、 S_s は比貯留係数[m⁻¹]、 S_w は水分飽和率[-]、 C は比水分容量[m⁻¹]、 h_w は圧力水頭[m]、 t は時間[sec]、 z は下向きに正の鉛直座標、 k は飽和透水係数[m/s]、 k_r は相対透水係数[-]、 q_w は側方流や基岩流出等による単位体積あたりの流入出量[m³/s/m³]である。なお、 C 、 k_r は以下の van Genuchten のモデルを用いて表現した。

$$C = \frac{\alpha m (S_w - S_{wr})}{1 - m} S_e^{1/m} (1 - S_e^{1/m})^m \quad \dots \dots \dots (4.2)$$

$$k_r = S_e^{1/2} \left\{ 1 - (1 - S_e^{1/m})^m \right\}^2 \quad \dots \dots \dots (4.3)$$

$$S_e = (S_w - S_{wr}) / (1 - S_{wr}) \quad \dots\dots\dots (4.4)$$

ここで、 S_{wr} は水の残留飽和率[-]、 S_e は有効飽和度[-]、 α, m はモデルの形状パラメータである。ただし $m = 1 - 1/n$ の関係がある。地表面の浸透については、地表面供給量が浸透能を上回る場合には浸透強度＝浸透能とし、逆に浸透能の方が大きい場合は浸透強度＝地表面供給量とした。浸透能を上回る分の降雨は、溢水量として表面流出へ直接供給させた。

$$q_{in} = R, q_{over} = R - q_c \quad \text{at } R \leq q_c \quad \dots\dots\dots (4.5)$$

$$q_{in} = q_c, q_{over} = 0 \quad \text{at } q_c < R \quad \dots\dots\dots (4.6)$$

$$R = rain + h_s / \Delta t \quad \dots\dots\dots (4.7)$$

ここで、 q_{in} は浸透速度[m/s]、 q_{over} は地表面溢水量[m/s]、 q_c は浸透能[m/s]、 R は地表面供給量[m/s]、 $rain$ は降水量[m/s]、 h_s は表面水深[m]、 Δt は計算時間刻み幅[sec]である。なお、地表面の浸透能は、地表の圧力水頭をゼロとして最上層の格子の上半分でもリチャーズ式を解くことにより算出する。以上の式(4.1)～(4.7)を差分法によって離散化し、陰解法を適用して解を求めるものとした。計算の結果、各セルで圧力水頭がゼロを越える分の合計を地下水深として定義し、飽和側方流モデルに受け渡すものとした。

(3) 飽和側方流

表層における地下水流動は飽和側方流モデルとして表現する。飽和側方流は一般的な Darcy 則に従うものとして、モデルの概要を以下に示す。また、表土層中の計算段階で地下水位が表土層厚を超えた場合は、地表面への復帰流としてその分を地表面へ供給するものとする。飽和側方流のモデルは、Darcy 則によるフラックスと連続式による。

$$q_{g_x} = -h_g k_x \frac{\partial H_g}{\partial x} \dots\dots\dots (4.8)$$

$$q_{g_y} = -h_g k_y \frac{\partial H_g}{\partial y} \dots\dots\dots (4.9)$$

$$q_{in} = \phi_e \frac{\partial h_g}{\partial t} + \frac{\partial q_{g_x}}{\partial x} + \frac{\partial q_{g_y}}{\partial y} \dots\dots\dots (4.10)$$

ここで、 q_g は側方流量フラックス[m²/s]、 h_g は地下水深[m]、 ϕ_e は有効間隙率[-]、 H_g は地下水位[m]、添え字の x,y は二次元直交座標系を表す。

(4) 地表面流

表面流出解析モデルは、Horton 流（直接流出）および飽和復帰流の計算を行う際に適用されるモデルである。表面流には Diffusion Wave モデルを適用するものとして、以下にモデルの概要を示す。

$$q_{s_x} = -\frac{1}{n} h_s^{5/3} \frac{\partial H_s}{\partial x} \dots\dots\dots (4.11)$$

$$q_{s_y} = -\frac{1}{n} h_s^{5/3} \frac{\partial H_s}{\partial y} \dots\dots\dots (4.12)$$

$$q_{over} = \frac{\partial h_s}{\partial t} + \frac{\partial q_{s_x}}{\partial x} + \frac{\partial q_{s_y}}{\partial y} \dots\dots\dots (4.13)$$

ここで、 q_s は表面流量[m²/s]、 n はマンニングの粗度係数[s/m^{1/3}]、 h_s は表面水深[m]、 H_s は表面水位[m]、 q_{over} は地表面供給量[m/s]である。式(4.11)~(4.13)についても、飽和側方流と同様に有限要素法を適用した。

(5) 河道への湧出・流出

地下水の復帰流や、地表流が生じることによって、河道へと水が供給される。河道流入量の計算は、図 4-5 のような節点を囲む要素の中心を結んだ多角形で節点面積を定義し、二次元飽和復帰流・二次元表面流によって節点に流入する表面水を河道への供給量として扱うものとした。河道流入の計算は式(4.14),(4.15)の通りである。

$$Q_{riv} = q_{riv} \times Area \quad \dots\dots\dots (4.14)$$

$$q_{riv} = \Delta h_s / \Delta t \quad \dots\dots\dots (4.15)$$

ここで、 Q_{riv} は河川への流出量[m³/s]、 q_{riv} は河川への流出フラックス[m/s]、 $Area$ は節点面積[m²]、 Δt は計算時間刻み幅[s]、 Δh_s は計算 1 ステップにおける表面水深の上昇分[m]である。

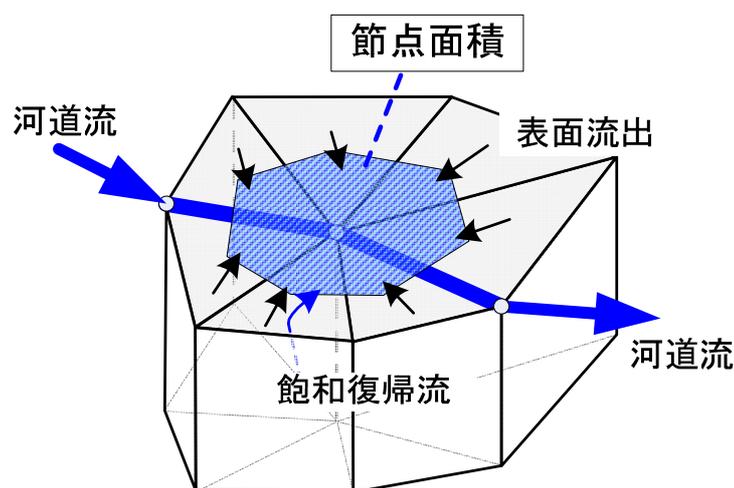


図 4-5 地下水・地表面モデルと河道モデルとの接続の模式図

(6) 河道流

河道流モデルには Dynamic Wave モデルを適用した。

$$q = \frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} \dots\dots\dots (4.16)$$

$$-gA \frac{n^2 u |u|}{R^{4/3}} = \frac{\partial Q}{\partial t} + \frac{\partial u Q}{\partial x} + gA \frac{\partial h_s}{\partial x} \dots\dots\dots (4.17)$$

ここで、 Q は流量[m³/s]、 A は流水断面積[m²]、 u は断面平均流速[m/s]、 R は径深[m]、 g は重力加速度[m/s²]、 q は横流入量[m²/s]である。式(4.16)、(4.17)には有限体積法を適用した。

(7) 流出解析の数値計算法

表面流出及び飽和側方流の二次元モデルには、非構造格子を基本とした計算を用いる。非構造格子の計算には有限要素法や有限体積法の適用が考えられるが、本検討では有限要素法により計算を行うものとした。なお、両モデルは非定常の方程式で支配されるため空間方向と時間方向の離散化が必要となる。

有限要素法による数値計算法を、竹内ほか(2003)に倣い以下に示す。非定常解析の計算において、有限要素に関する方程式(連立1次方程式)を解くことにより次ステップの各未知数を計算する方法を陰解法という。陰解法は安定して計算を進めることができるものの、計算負荷が大きく、記憶容量を多く必要とするという欠点がある。本検討では、連立1次方程式を直接解かず、時間進行を進める陽的有限要素法を適用した。

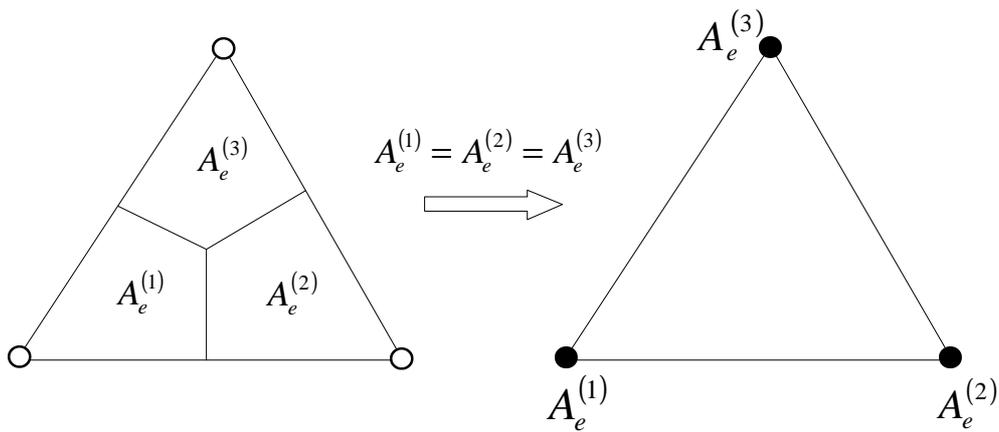


図 4-6 質量の集中化

陽解法においては、要素内に分布する質量を各節点に集中化することで計算を単純化することがしばしば行われる。質量の集中化とは、図 4-6に示すように要素の質量を 3 等分して、それぞれを節点に割り振ることである。具体的には、質量行列の非対角成分を対角成分に集めることにより次式のような集中質量行列を各要素で作成する。

$$\overline{M}_e = \begin{bmatrix} \frac{A_e}{3} & 0 & 0 \\ 0 & \frac{A_e}{3} & 0 \\ 0 & 0 & \frac{A_e}{3} \end{bmatrix} = \frac{A_e}{3} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \dots\dots\dots (4.18)$$

時間方向の離散化に前進差分を用いた場合、質量行列を集中化すると陽解法になる。上式のような陽的に離散化された有限要素方程式は次式のように集中質量行列の逆行列をかけることにより容易に求められる。

$$\frac{1}{\Delta t} \overline{M} u^{n+1} = F + \left(\frac{1}{\Delta t} M - K \right) u^n \dots\dots\dots (4.19)$$

$$u^{n+1} = M^{-1} \Delta t \left\{ F + \left(\frac{1}{\Delta t} M - K \right) u^n \right\} \dots\dots\dots (4.20)$$

ここに、 \overline{M} は集中質量行列である。この式における全体の集中質量行列 \overline{M} の逆行列は、要素毎の集中質量行列 \overline{M}_e を重ね合わせた後にその対角成分の逆数をとることにより求められるので、逆行列の計算が不要になり、陽的に計算を進めることができる（竹内ほか、2003）。

(8) 数値安定化手法の適用

本解析で対象とする双曲型方程式の場合には、通常の有限要素法の離散化は数値的不安定性を引き起こすことが知られている。また、陽解法における質量行列の集中化は過度の減衰を生じることも知られている。こうした問題点を解決するために、いくつかの安定化手法が提案されている。本検討ではそうした手法の代表的な一つであるセレクトィブランピング法を用いる。

セレクトィブランピング法では、上記の式を質量行列の代わりに混合質量行列 \tilde{M} を用いて次のように表す。

$$\frac{1}{\Delta t} \bar{M} u^{n+1} = F + \left(\frac{1}{\Delta t} \tilde{M} - K \right) u^n \quad \dots\dots\dots (4. 21)$$

ここで、混合質量行列は次のように定義される。

$$\tilde{M} = e\bar{M} + (1-e)M \quad \dots\dots\dots (4. 22)$$

e はランピングパラメータと呼ばれ、付加する安定項の大きさを調整する機能を持っている。

$$e=0 \text{ のとき、 } \tilde{M} = M$$

$$e=1 \text{ のとき、 } \tilde{M} = \bar{M}$$

となる。 e が0に近いほど計算は安定するが、一方で解の減衰も大きくなる。一般的には $e=0.7\sim 0.95$ の値を用いる場合が多い。

非構造格子と直交格子の分割の概念図（河道の表現含む）を図 4-9に示す。非構造格子は任意のメッシュサイズによる表現が可能であり、河道や流域の境界の形状を適切に表現することができる。メッシュサイズは、流域の特性を表現するためにできるだけ小さくすることが望ましい。しかしながらメッシュサイズを小さくするとメッシュ総数が膨大になるためリアルタイムの演算は困難になる。流域・河道の表現と計算時間の観点から踏まえ、平均的なメッシュサイズは500mとした。このメッシュサイズにより、山地の起伏や蛇行流路の形状を可能な限り表現した。

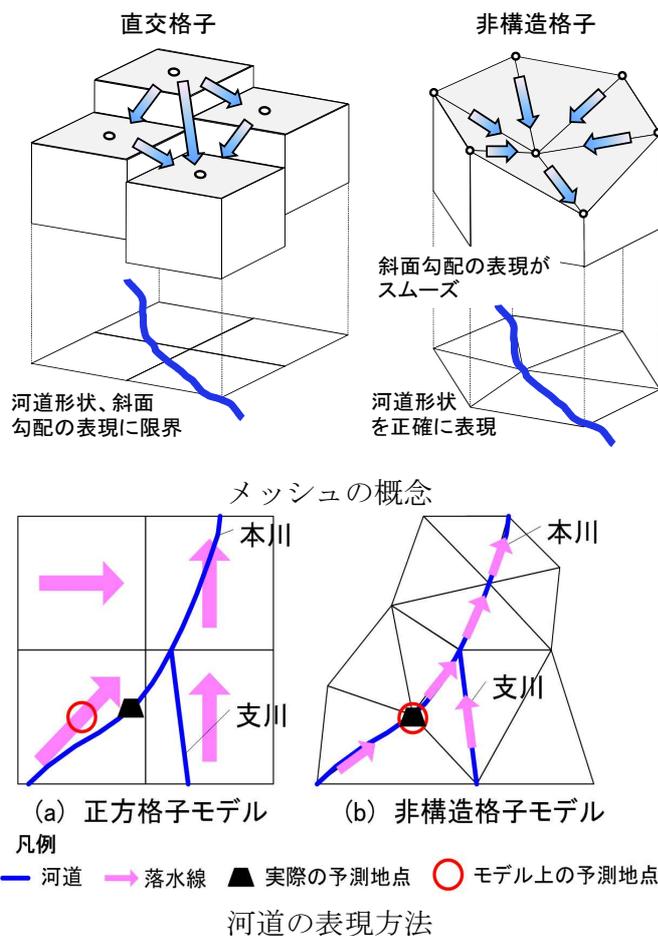


図 4-9 分布型モデルの概念（左図：直交格子、右図：非構造格子）

4.2. 観測データによる水位予測の補正手法

リアルタイムで運用する洪水予測システムでは、実用的な精度を得るために、観測値をモデルに反映させて予測精度向上を図る手法（フィードバック）が必要となる。分布型モデルに対するフィードバックには様々な手法が提案されている（Moradkahn et al., 2005a; Moradkahn et al., 2005b; DeChant and Moradkahn, 2012; 田中・杉浦, 2012）が、状態量やパラメータの分布を適切に補正する手段が難しく、研究途上である。既存の洪水予測システム等では、状態量補正やパラメータの補正を行わずに、予測結果のみを補正するスライド補正（図 4-10）が用いられる場合が多い。一方でデータ同化による状態量補正とは、モデル状態量を修正することで予測結果を補正する方法である（図 4-11）。

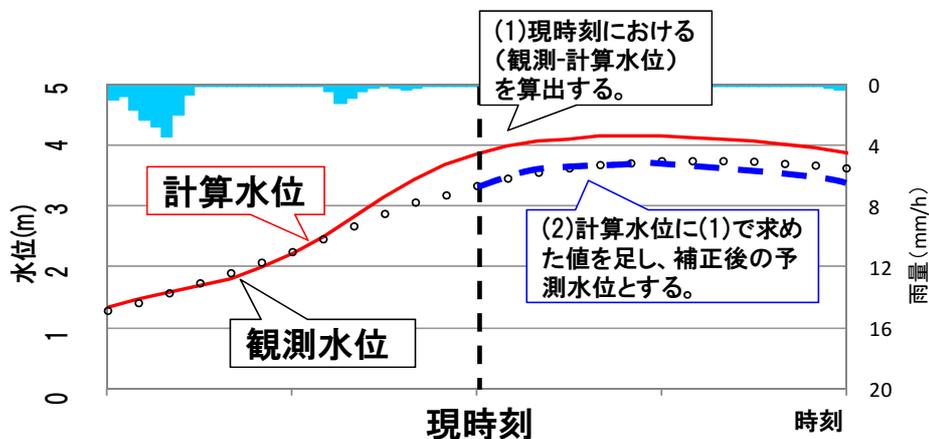


図 4-10 観測データを用いた予測スライド補正の概念図

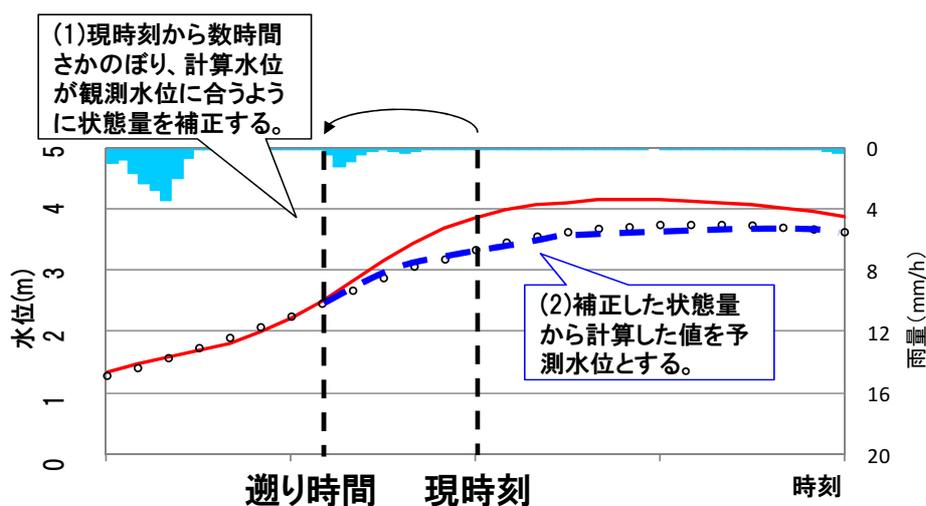


図 4-11 観測データを用いた同化手法例の概念図

4.3. 洪水予測モデルへのフィルタリングモデルの組み込み

4.3.1. 粒子フィルタの概要

粒子フィルタのアルゴリズムについては、立川ほか(2011)が詳しく整理している。以下、立川ほか(2011)に倣いアルゴリズムの概要を示す。

非線形・非ガウス型の状態空間型モデルを考える。

$$\mathbf{x}_t = \mathbf{f}_t(\mathbf{x}_{t-1}, \boldsymbol{\theta}_t, \mathbf{v}_t) \dots\dots\dots (4.23)$$

$$\mathbf{y}_t = \mathbf{h}(\mathbf{x}_t, \boldsymbol{\eta}_t, \mathbf{w}_t) \dots\dots\dots (4.24)$$

\mathbf{x}_t : 時刻 t の k 次元の状態ベクトル

\mathbf{y}_t : 時刻 t の l 次元の状態ベクトル

$\boldsymbol{\theta}_t, \boldsymbol{\eta}_t$: パラメータベクトル

$\mathbf{v}_t, \mathbf{w}_t$: ガウス分布とは限らない確率密度関数に従うシステムノイズと観測ノイズ

一期先の状態 x_t の予測値の確率分布 (事前分布) は、以下の通りとなる。

$$p(x_t | y_{1:t-1}) = \int p(x_t | x_{t-1}) p(x_{t-1} | y_{1:t-1}) dx_{t-1} \dots\dots\dots (4.25)$$

フィルタリングされた状態 x_t の確率分布は、ベイズの定理より以下の通りとなる。

$$p(x_t | y_{1:t}) = \frac{p(y_t | x_t) p(x_t | y_{1:t-1})}{p(y_t | y_{1:t-1})} \dots\dots\dots (4.26)$$

粒子フィルタではこれらの条件付き確率分布、その分布の実現値である独立の多数の粒子を用いて近似する。具体的には式(4.25)の事前分布を以下の通りに近似する。

$$p(x_t | y_{1:t-1}) \doteq \frac{1}{N} \sum_{i=1}^N \delta(x_t - x_{t|t-1}^{(i)}) \quad \dots\dots\dots (4.27)$$

N : 粒子数
 $\delta(\cdot)$: デイラックのデルタ関数
 $x_{t|t-1}^{(i)}$: 時刻 t の i 番目の粒子の事前推定値

\doteq はアンサンブル近似 (あるいはモンテカルロ近似) を表す。なお、このサンプル集合 $\{\mathbf{x}_t^{(i)}\}_{i=1}^N$ のことをアンサンブルと呼ぶ。また、各 $\mathbf{x}^{(i)}$ をアンサンブルメンバーまたは粒子と呼ぶ。また、 N をアンサンブルメンバー数あるいは粒子数と呼ぶ。式(4.27)を式(4.26)に代入し、観測値 y_t を加えた後の事後分布が以下のようにになるように粒子 $x_{t|t}^{(i)}$ を求める。

$$p(x_t | y_{1:t}) \doteq \frac{1}{N} \sum_{i=1}^N \delta(x_t - x_{t|t}^{(i)}) \quad \dots\dots\dots (4.28)$$

式(4.27)、式(4.28)を表現する $x_{t|t-1}^{(i)}$ 、 $x_{t|t}^{(i)}$ は式(4.23)、式(4.24)に従って以下の手順で求める。

①初期化 :

現在時刻を $t-1$ とする。 i 番目の粒子 ($i=1, \dots, N$) についてフィルタリング後の状態量 $x_{t-1|t-1}^{(i)}$ が得られているとする。すなわち、以下が成り立っているものとする。

$$p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) \doteq \frac{1}{N} \sum_{i=1}^N \delta(\mathbf{x}_{t-1} - \mathbf{x}_{t-1|t-1}^{(i)}) \quad \dots\dots\dots (4.29)$$

②予測 :

状態方程式(1)式を用いて i 番目の粒子 ($i=1, \dots, N$) の予測値 $x_{t|t-1}^{(i)}$ を求める。これにより事前分布が式(4.27)より定まる。

$$\mathbf{x}_{t|t-1}^{(i)} = \mathbf{f}_t(\mathbf{x}_{t-1|t-1}^{(i)}, \mathbf{v}_t^{(i)}), \quad \mathbf{v}_t^{(i)} \sim \mathbf{q}_t(\mathbf{v}_t) \quad \dots\dots\dots (4.30)$$

③フィルタリング：

式(4.26)の $p(y_t|x_t)$ は状態 x_t のときに観測値 y_t を得る確率（尤度）であり、式(4.24)から定まる $R(y_t|x_{t|t-1}^{(i)})$ によって得られるとする。式(4.26)の分母の $p(y_t|y_{1:t-1})$ は、次の式(4.31)のとおりである。

$$\begin{aligned} p(y_t|y_{1:t-1}) &= \int R(y_t|x_t)p(x_t|y_{1:t-1})dx_t \\ &\approx \frac{1}{N} \sum_{i=1}^N R(y_t|x_{t|t-1}^{(i)}) \quad \dots\dots\dots (4.31) \end{aligned}$$

式(4.27)、式(4.31)を式(4.26)に代入すると、事後分布として次の式(4.32)が得られる。

$$p(y_t|y_{1:t}) \approx \sum_{i=1}^N w_t^{(i)} \delta(x_t - x_{t|t-1}^{(i)}) \quad \dots\dots\dots (4.32)$$

ここで $w_t^{(i)}$ は正規化した尤度である。

$$w_t^{(i)} = R(y_t|x_{t|t-1}^{(i)}) / \sum_{i=1}^N R(y_t|x_{t|t-1}^{(i)}) \quad \dots\dots\dots (4.33)$$

④リサンプリング：

正規化した尤度(重み) $w_t^{(i)}$ に比例する割合で $x_{t|t-1}^{(i)}$ を復元抽出し、抽出した粒子を $x_{t|t}^{(i)}$ とする。抽出した粒子の合計は N 個とする。それぞれの粒子の重みはすべて $1/N$ となり、最終的に事後分布(4.29)式が得られる。また、リサンプリング後の各粒子の状態量あるいはパラメータにランダムな攪乱を与え、特定の粒子のみが選択されない工夫をする。

⑤時間を更新して①に戻る。

以上①～⑤の手順を繰り返すことにより、常に観測データへの再現性が高いモデルの集団が得られることが期待される。粒子フィルタの手順の概念図を図 4-12に示す。

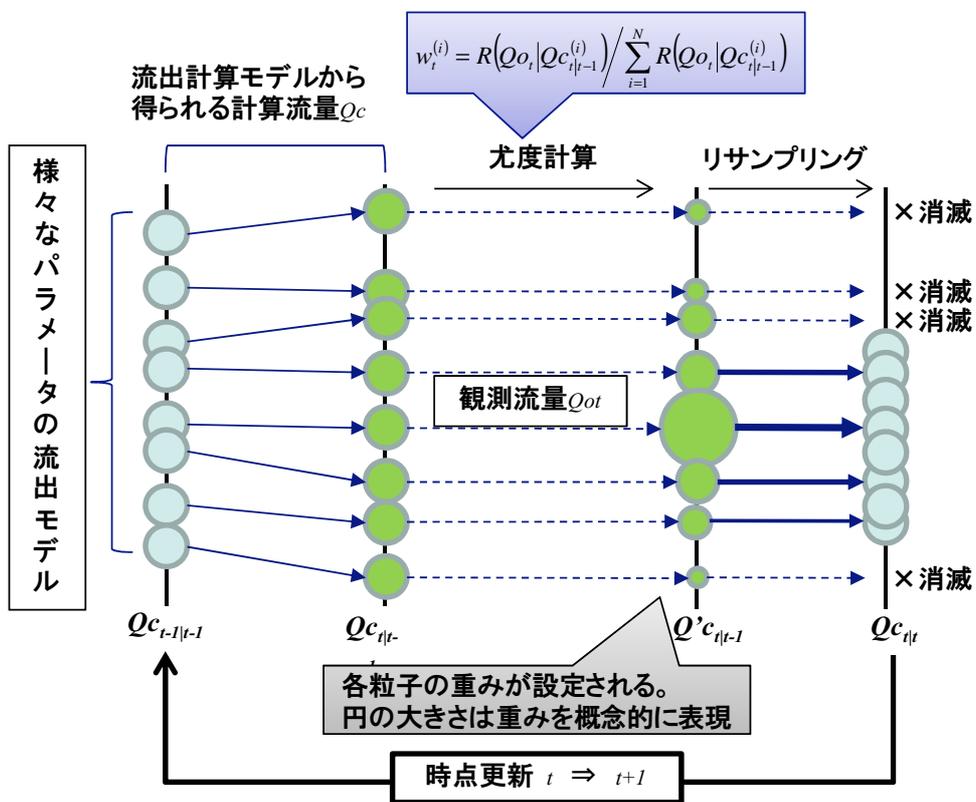


図 4-12 粒子フィルタの概念図

4.3.2. 粒子フィルタとアンサンブルカルマンフィルタの比較

水文モデルに用いられることの多い同化手法として、粒子フィルタと並んでアンサンブルカルマンフィルタが挙げられる。粒子フィルタとアンサンブルカルマンフィルタを比較すると、各粒子それぞれ独立に1ステップ先予測を行う手続きは全く同じである。異なるのはフィルタの手続きの部分である。

アンサンブルカルマンフィルタでは、フィルタの更新式にしたがって各粒子の状態量を観測に合うと思しき方向に動かすことで観測データの情報を取り入れる形になっている。一方、粒子フィルタでは、復元抽出によって観測への当てはまりが良い粒子を複製して増やす。この操作によって観測データの情報を取り込んだ事後確率密度分布が表現され、それがさらに次のステップの予測計算に反映されることになる(樋口ほか, 2011)。各手法の比較概念図を図4-13に示す。

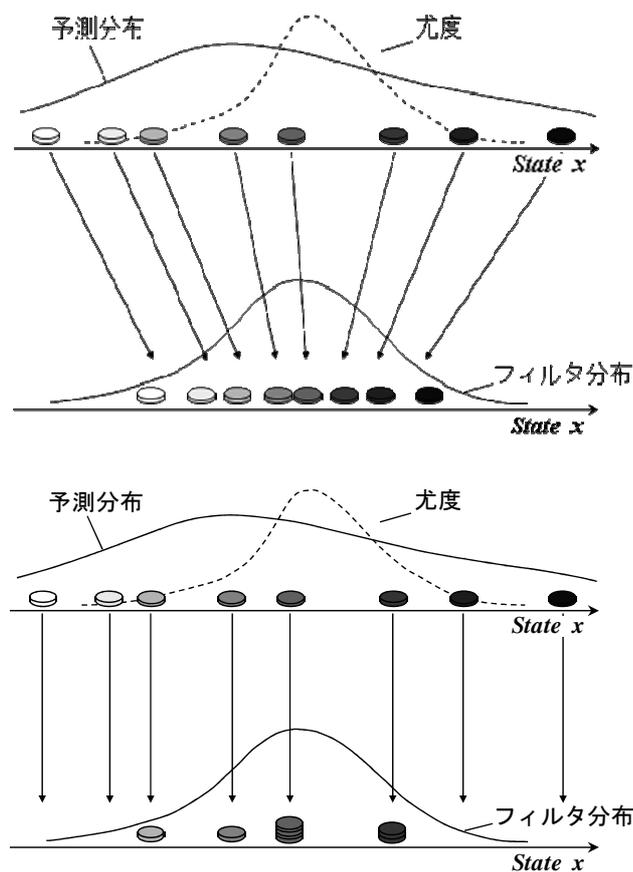


図 4-13 粒子フィルタとアンサンブルカルマンフィルタの比較概念図

4.3.3. 流出解析モデルへの粒子フィルタの適用

(1) 粒子フィルタを組み込んだ流出解析実施方法の概要

構築した分布型流出モデルに、粒子フィルタを組み込んだ。フィルタリングは予測地点の流量で行うものとし、補正する対象は分布型モデルの土壌水分量とした。粒子フィルタを組み込んだ分布型流出解析の計算手順を図 4-14に示す。

土壌水分量に与えるノイズ（補正量）は、表層のセル（厚さ 1.0m）に対する補正率とした。補正率を与えた結果、土壌水分率が 1.0 を超える場合には、超えた分の水分量を地表水に供給させるものとした。フィルタリングの設定条件を表 4-2に示す。

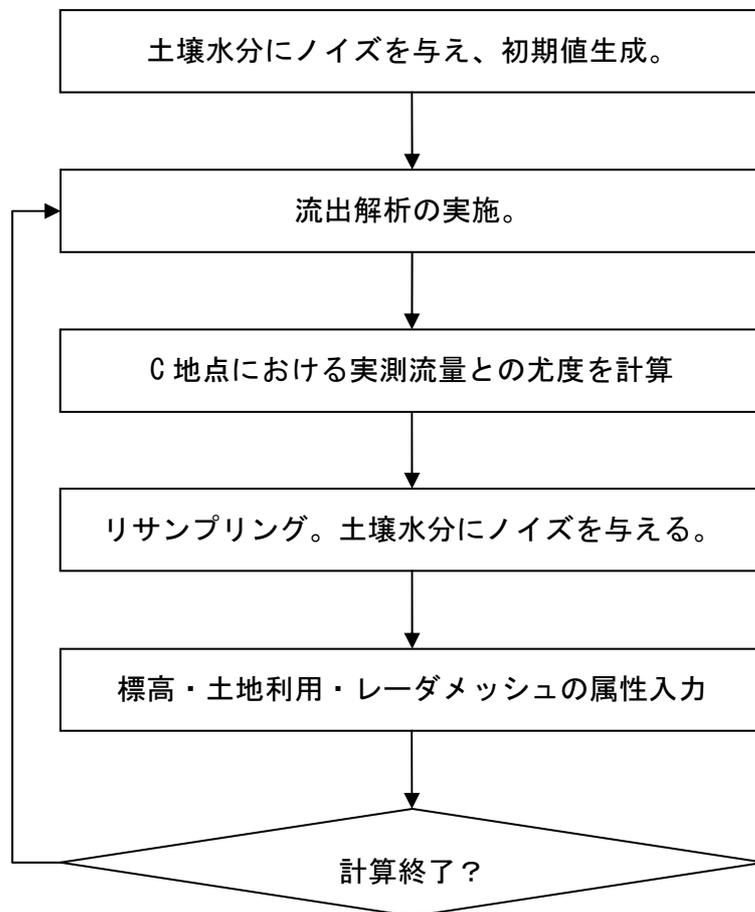


図 4-14 粒子フィルタを組み込んだ分布型流出解析の計算手順

表 4-2 粒子フィルタの設定条件

補正対象	観測ノイズ	リサンプリングノイズ	補正率の上下限	粒子数
Sw（土壌水分率）	10 %	1 %	0.995 ~ 1.01	60

(2) 尤度関数の設定

入力データピッチは1時間とし、1時間ごとにフィルタリングを実施した。観測データから定まる尤度関数を正規分布の確率密度関数とし、以下の通りとした。

$$R(y_t | x_{t|t-1}^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma_y} \exp\left(-\frac{(h_{t,cal}^{(i)} - h_{t,obs})^2}{2\sigma_y^2}\right) \dots\dots\dots (4.34)$$

- $R(y_t | x_{t|t-1}^{(i)})$: 粒子 $x_{t|t-1}^{(i)}$ の尤度
- $h_{t,cal}^{(i)}$: 時刻 t の i 番目の粒子の流量の予測値
- $h_{t,obs}$: 観測値
- σ_y : 観測流量の標準偏差

(3) リサンプリング手法

重み $w_t^{(i)}$ を持つ粒子 $x_{t|t-1}^{(i)}$ によって表現される分布関数を重みが等しい粒子によって表現できるように粒子を選びなおす。ここで選びなおされた粒子が $x_{t|t}^{(i)}$ であり、本検討ではドント方式を用いる。ドント方式によるリサンプリング手順を以下に示す。

粒子の重み $w_t^{(i)}$ が計算された後に、下式より $d_j^{(i)}$ を求める。

$$d_j^{(i)} = w_t^{(i)} / (m_j^{(i)} + 1) \dots\dots\dots (4.35)$$

$m_j^{(i)}$ は最初 0 個として、粒子 i に j 回目までに抽出された個数の総和である。 $j=1, 2, \dots, N$ の順に $d_j^{(i)}$ が最大となる粒子 i に対して配分数 $m_j^{(i)}$ を一つ増やす。これを粒子の総数 N 回分繰り返して復元抽出を行うものとした。

4.4. 物理型分布型モデルへの粒子フィルタによる同化手法の適用

4.4.1. 検討対象の概要

対象流域は、大淀川水系の樋渡（ひわたし）地点流域とした。流域面積は 861km²、幹川流路延長は 52 km であり、雨量観測所が 12 箇所、水位観測所が 5 箇所設置されている。樋渡上流には大きな洪水調整施設がなく、また水位・雨量観測所が複数設置されているため、検討に適している。検討に用いた実績水位、流量および地上雨量データは、水文・水質データベースより取得した。1990 年～2013 年の間で氾濫危険水位（9.2m）を超えた洪水は 5 事例あり、そのうち欠測データの多い 1 事例を除いた 4 事例を検討対象洪水とした。

4.4.2. モデルの構築

本検討で用いたモデルは、一次元鉛直浸透流モデル、飽和側方流モデル、表面流モデルおよび一次元不定流モデルで構成される。地形形状は非構造格子でモデル化し、河道部分が格子の辺となるように格子分割を行った（図 4-15）。節点数は 4000、要素数は 7687、鉛直分割数は 4 であり、格子サイズは三角形の一辺が平均約 500m である。標高データには基盤地図情報（<http://www.gsi.go.jp/kiban/>）の 5m,10m の DEM を用いた。土地利用データには国土数値情報土地利用細分メッシュデータ（<http://nlftp.mlit.go.jp/ksj/index.html>）を用い、透水係数の設定区分に反映させた。用いた標高データ、土地利用区分データを図 4-16、図 4-17に示す。

本川区間の河道断面については、大淀川水系河川整備計画の附図（九州地方整備局ほか、2006）に記載のあった 6 断面をトレースし、各計算断面に補間して与えた。用いた断面データを図 4-18、図 4-19に示す。支川については、一律で幅 100m の矩形断面とした。

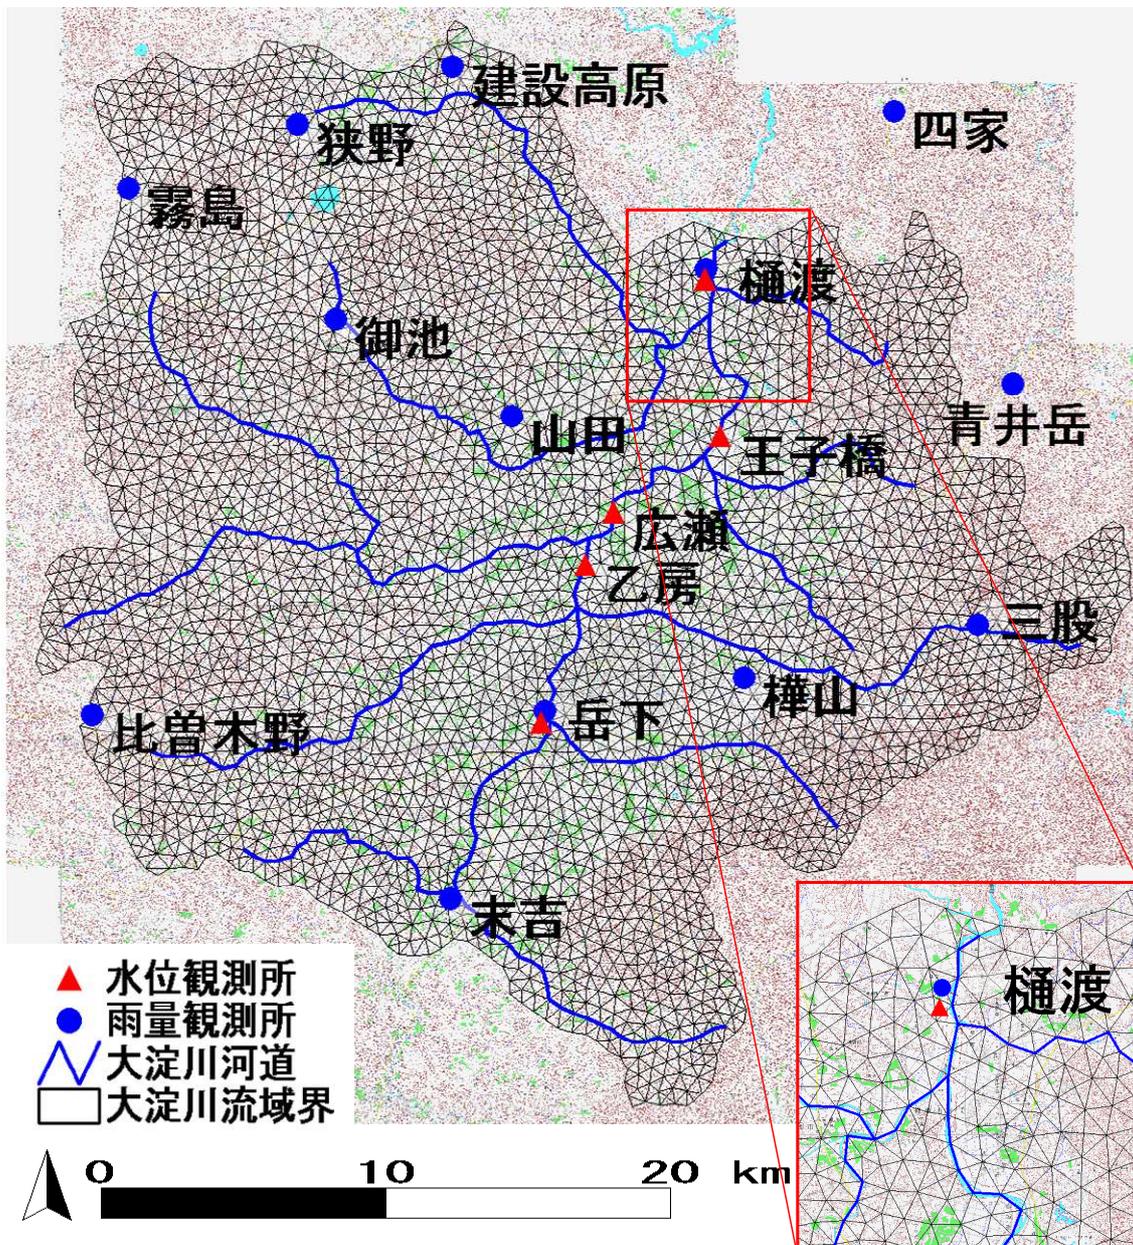


図 4-15 大淀川流域モデルのメッシュ図

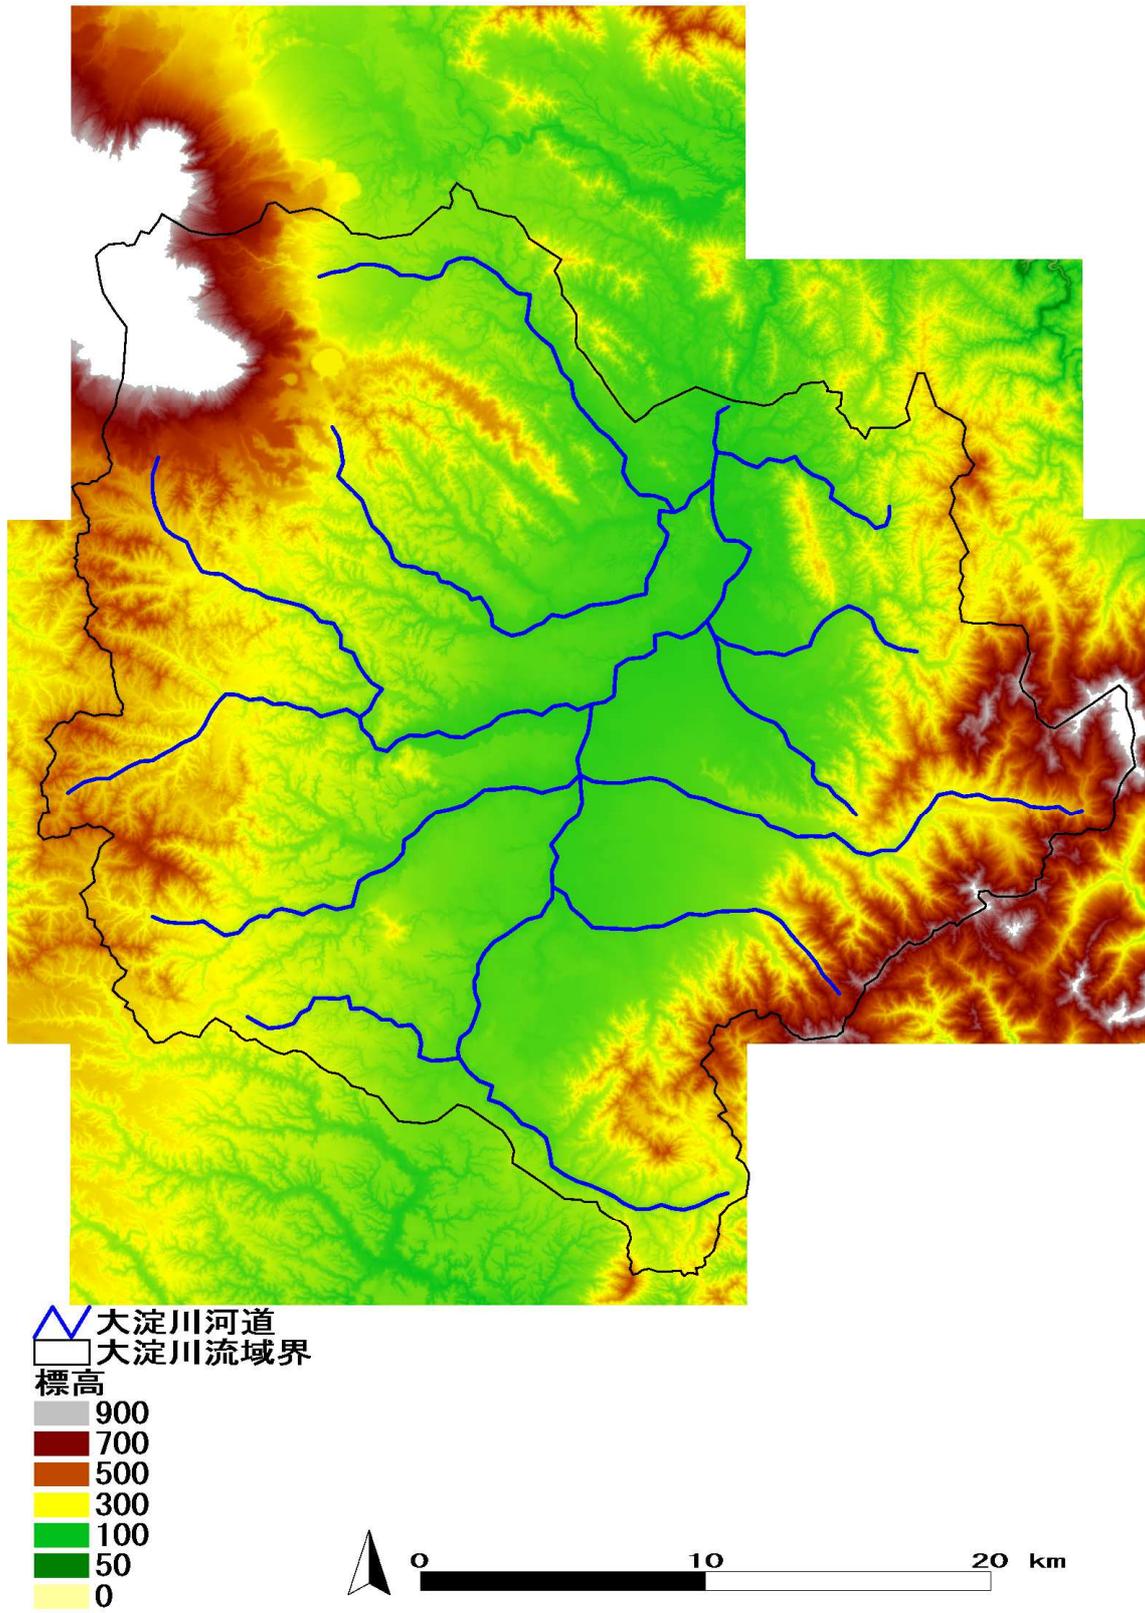
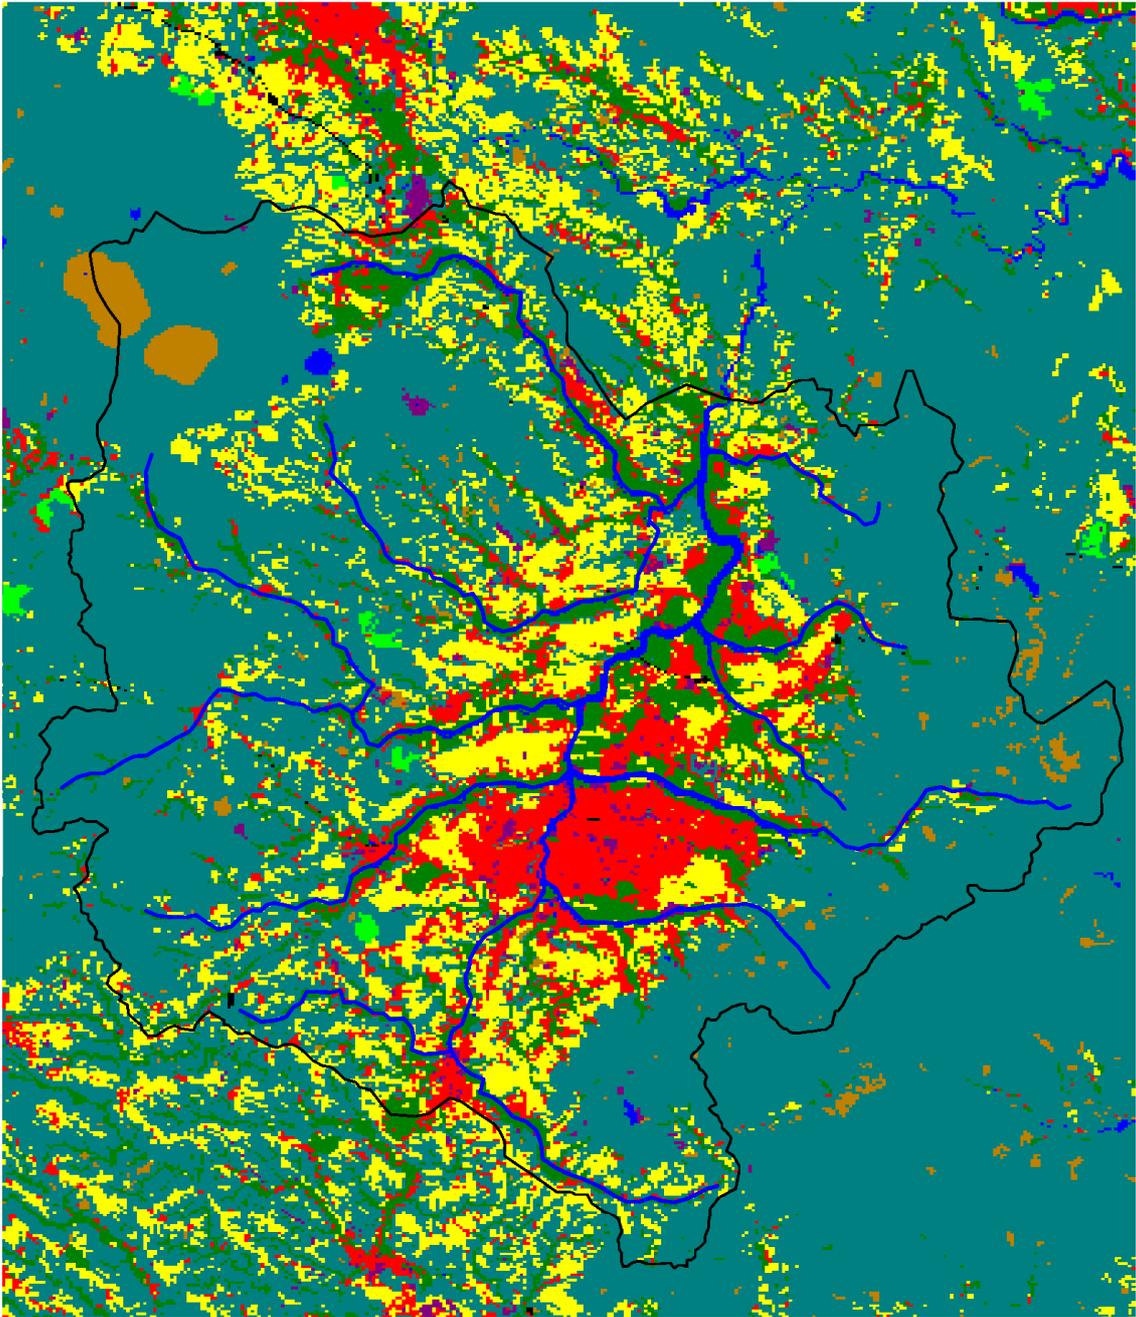


図 4-16 大淀川流域モデルの標高グラデーション図



-  大淀川河道
-  大淀川流域界
- 土地利用
-  田
-  その他の農用地
-  森林
-  荒地
-  建物用地
-  幹線交通用地
-  その他の用地
-  河川及び湖沼
-  海浜
-  海水域
-  ゴルフ場



図 4-17 大淀川流域モデルの土地利用分類図

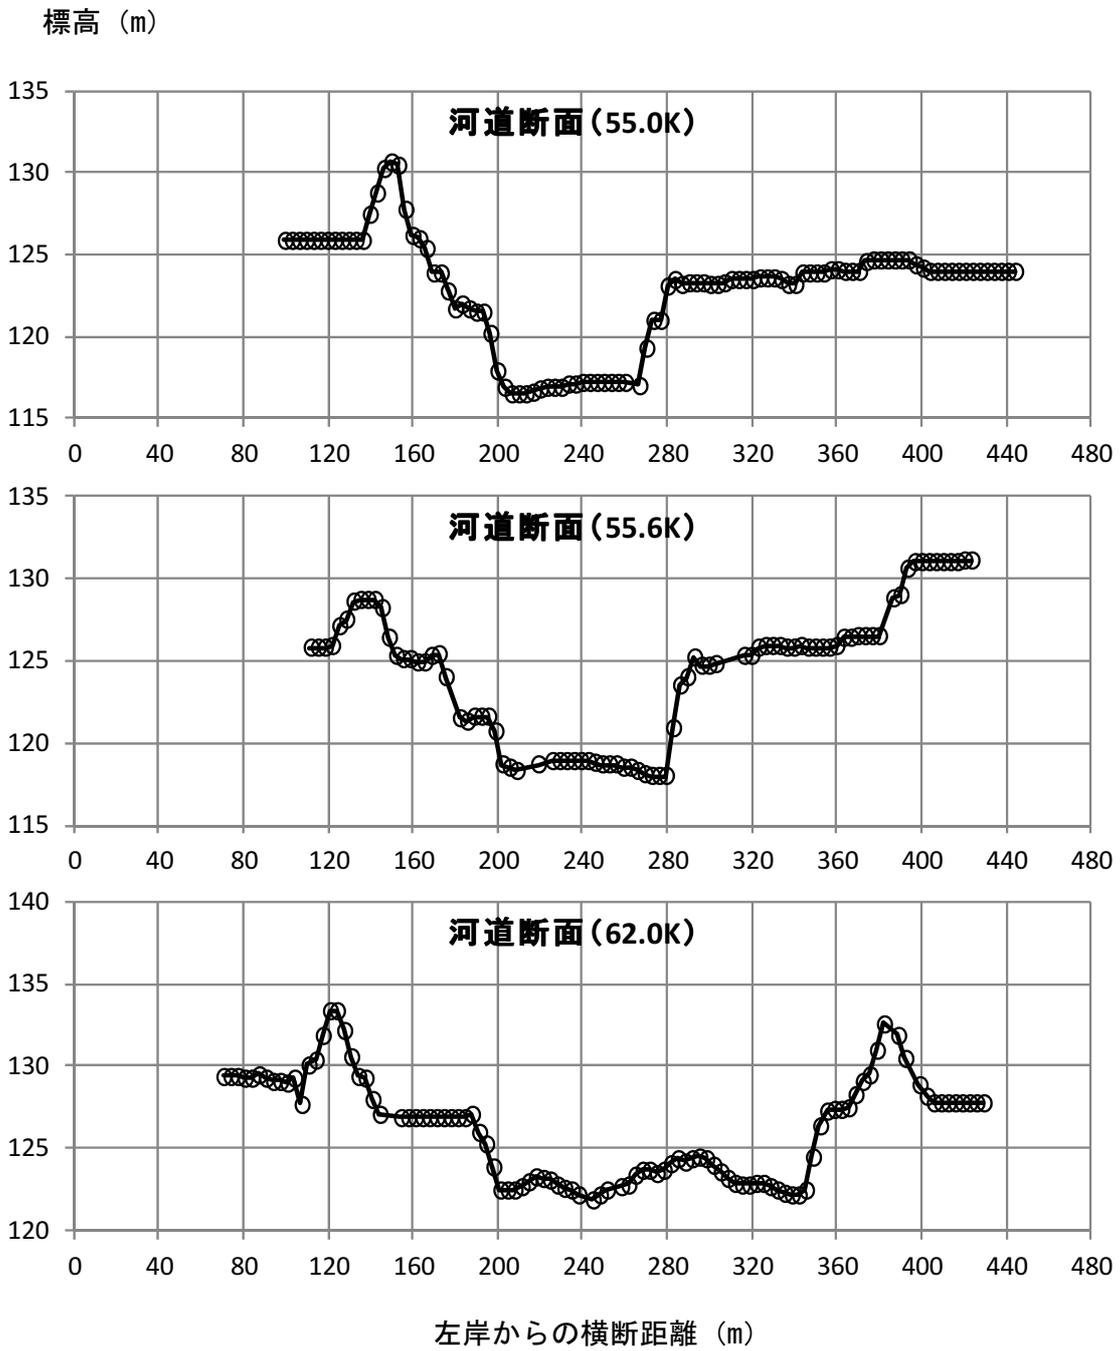


図 4-18 本川区間の河道横断図①

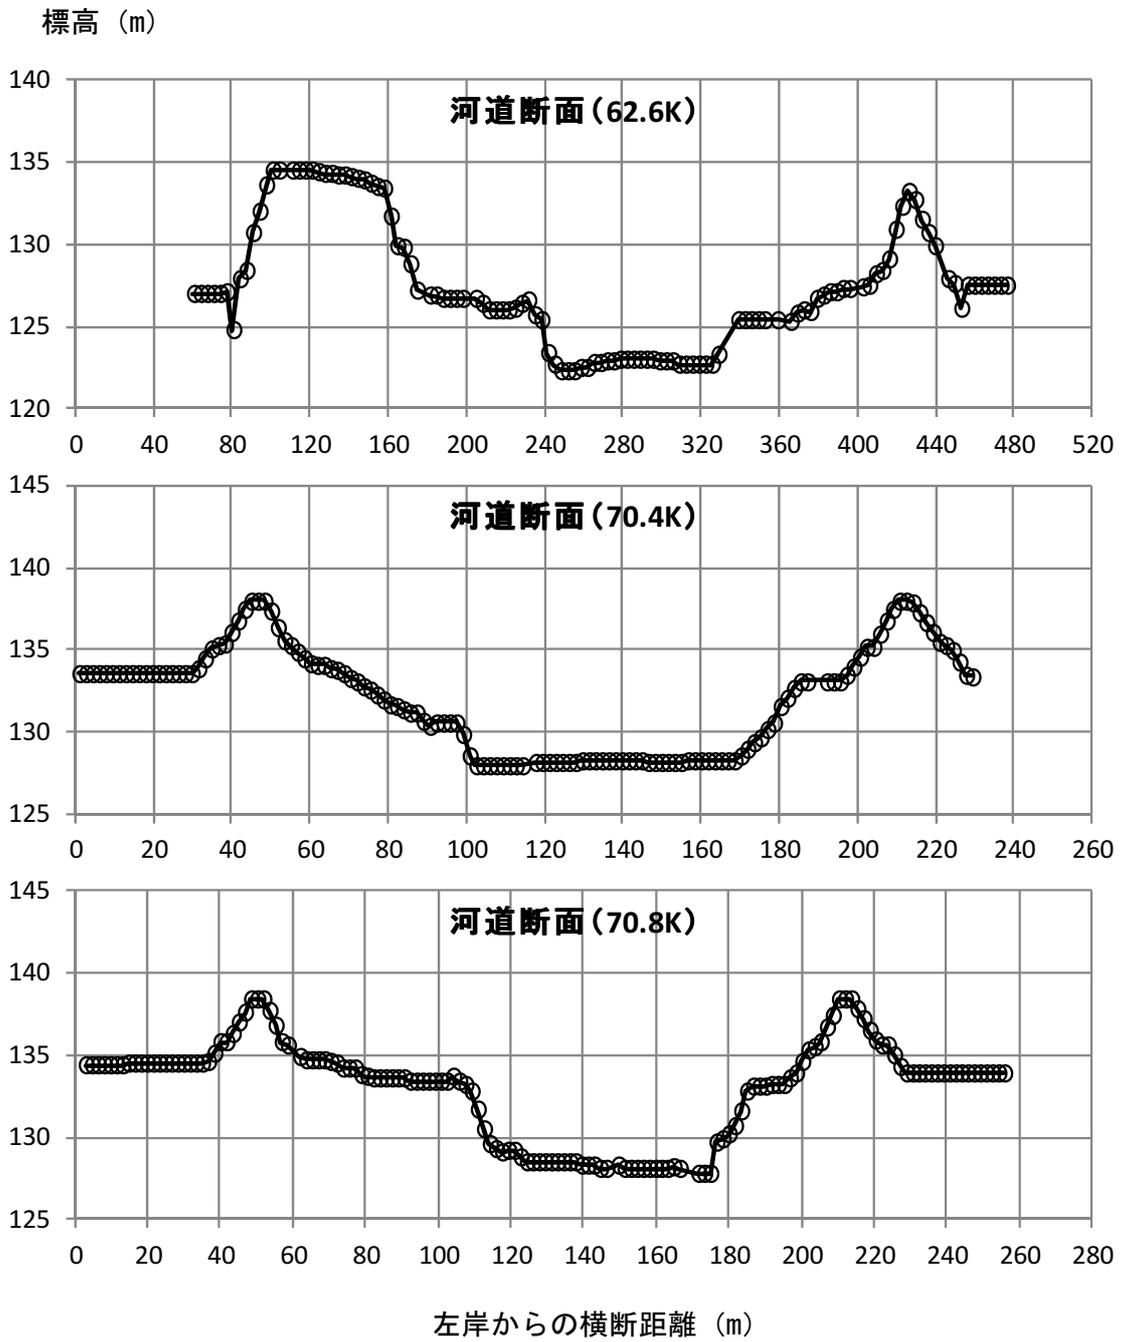


図 4-19 本川区間の河道横断面図②

4.4.3. 再現計算の実施

検証対象 4 洪水について再現計算を行い、モデルパラメータをキャリブレーションした。降雨は地上雨量の 1 時間データを用い、ティーンセン分割によりメッシュの節点ごとに与えた。初期条件は土壌水分率を 1.0 の飽和状態とし、洪水ピーク 60 日前から連続的に計算した。設定した主なパラメータを表 4-3 に示す。なお、透水係数については、雨水貯留浸透技術協会（2000）を参考に、表 4-4 のように土地利用に応じて表 4-3 の値に倍率をかけて設定した。

表 4-3 分布型モデルの主な設定パラメータ

パラメータ	設定値
土層の鉛直透水係数・上流域 (cm/s)	3.0×10^{-2}
土層の鉛直透水係数・中流域 (cm/s)	5.0×10^{-2}
土層の鉛直透水係数・下流域 (cm/s)	1.0×10^{-1}
表層土層厚 (m)	4.0
飽和体積含水率 (間隙率)	0.6
残留体積含水率	0.1
等価粗度係数 ($s/m^{1/3}$)	1.0
河道の粗度係数 (低水路/高水敷) ($s/m^{1/3}$)	0.04/0.08

表 4-4 土地利用と浸透能等の関係

コード	土地利用	浸透度倍率
1	田	1.000
2	その他農用地	1.000
5	森林	2.891
6	荒地	2.891
7	建物用地	0.142
9	幹線交通用地	0.000
10	その他用地	0.555
11	河川地及び湖沼	0.555
16	ゴルフ場	0.555

4.4.4. 再現計算の結果

計算結果を図 4-20 に、精度指標を表 4-5 に示す。1993 年を除く洪水で Nash-Sutcliffe 係数が 0.9 を超えており、十分な再現性を有している。1993 の洪水は他の 3 洪水よりも再現性が低く、雨量データの精度など何らかの誤差要因があったものと考えられる。

表 4-5 分布型モデルによる対象洪水の再現精度

精度指標	1990 年	1993 年	2004 年	2005 年
NS 係数	0.91	0.71	0.95	0.95
RMSE	0.75	1.20	0.66	0.78

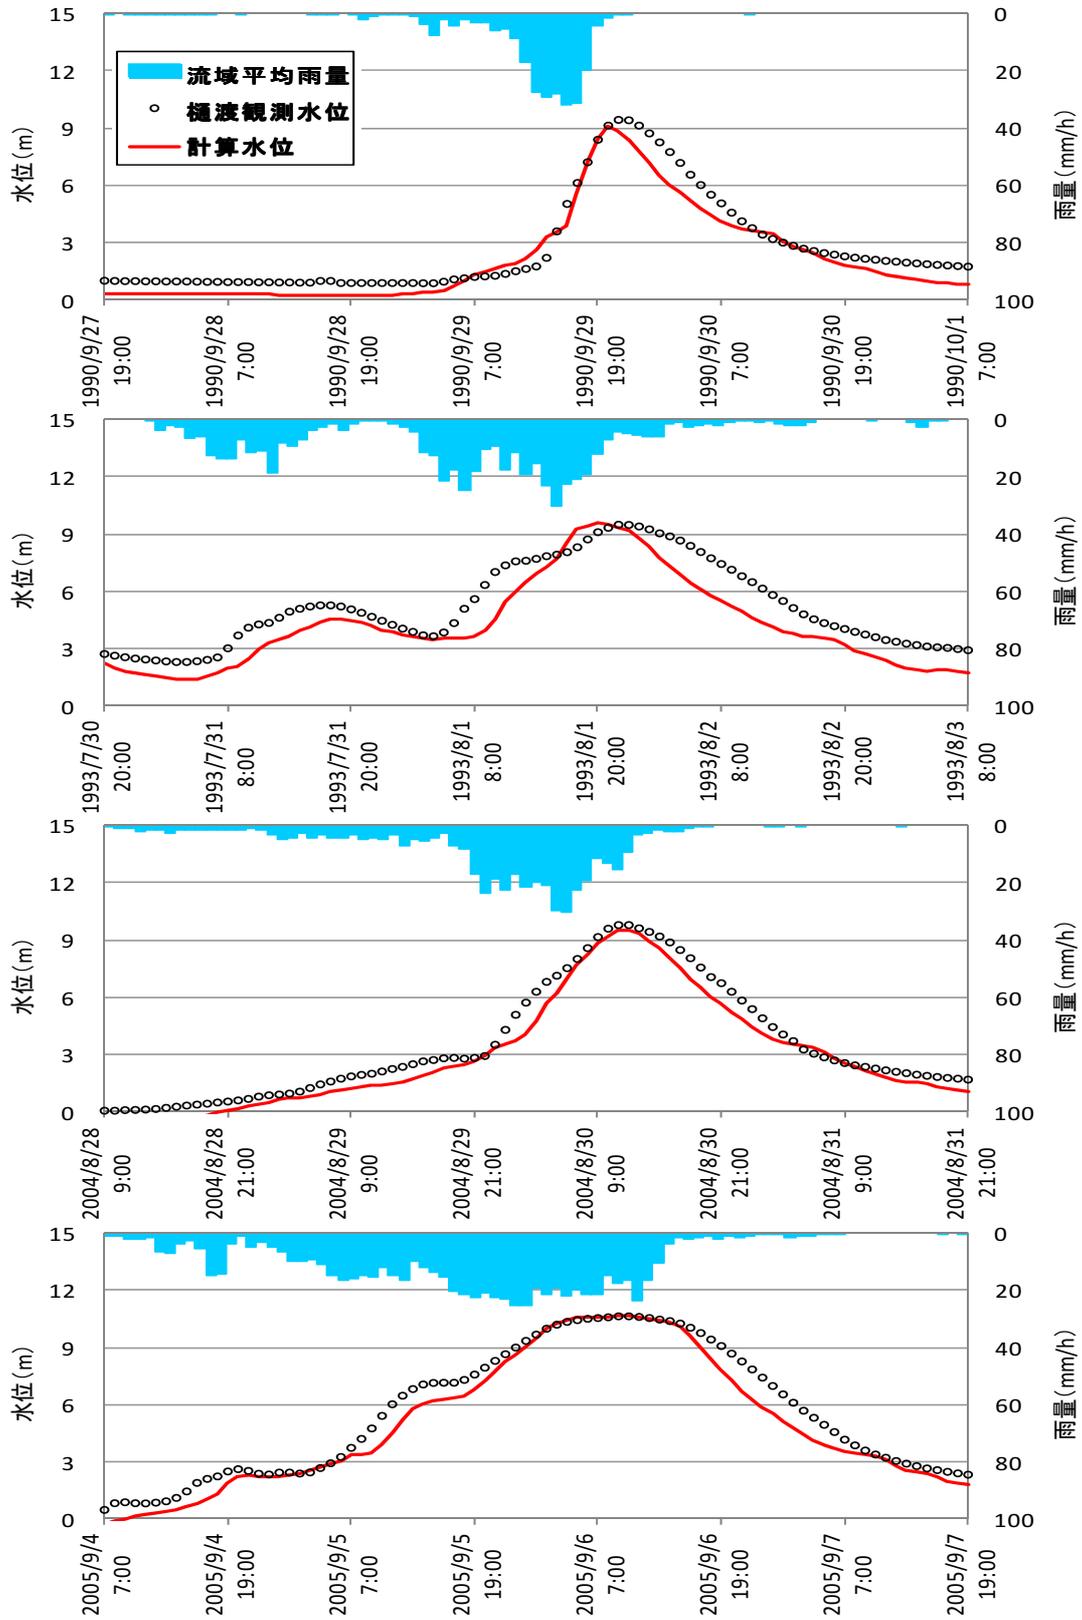


図 4-20 分布型モデルによる再現計算結果

(1) 粒子フィルタの適用による予測実施

前章で構築した分布型モデルに粒子フィルタを適用し、予測計算を実施した。計算条件を表 4-6に示す。リサンプリングノイズは表層グリッド（厚さ 1.0m）の土壌水分率（ S_w ）に対する倍率として与え、 S_w が 1.0 を超える場合には、超えた分の水分量を表面水に供給するものとした。またノイズの上下限は-0.5～1.0 %とした。降雨は実測雨量を予測雨量に見立てた完全予測データを用いた。

表 4-6 粒子フィルタの設定条件

項目	設定内容
観測水位の推定誤差	10 %
粒子数	96
リサンプリングノイズ	分散 0.3% の正規分布

(2) スライド補正の適用

スライド補正は、分布型モデルの計算結果に対して補正値を上乗せすることにより予測誤差の解消を図る手法である。本研究では、現時刻の観測水位と計算水位との差分を補正値として、1～6 時間予測値に一律に加えることで誤差解消を図るものとした。

(3) 計算結果

1) 分布型流出計算と粒子フィルタ適用後の比較

図 4-21～図 4-24に、分布型流出計算の結果（粒子フィルタ適用前）と、粒子フィルタを適用した予測計算結果を合わせて示す。粒子フィルタの適用により、適用前に比べ精度向上していることが確認された。

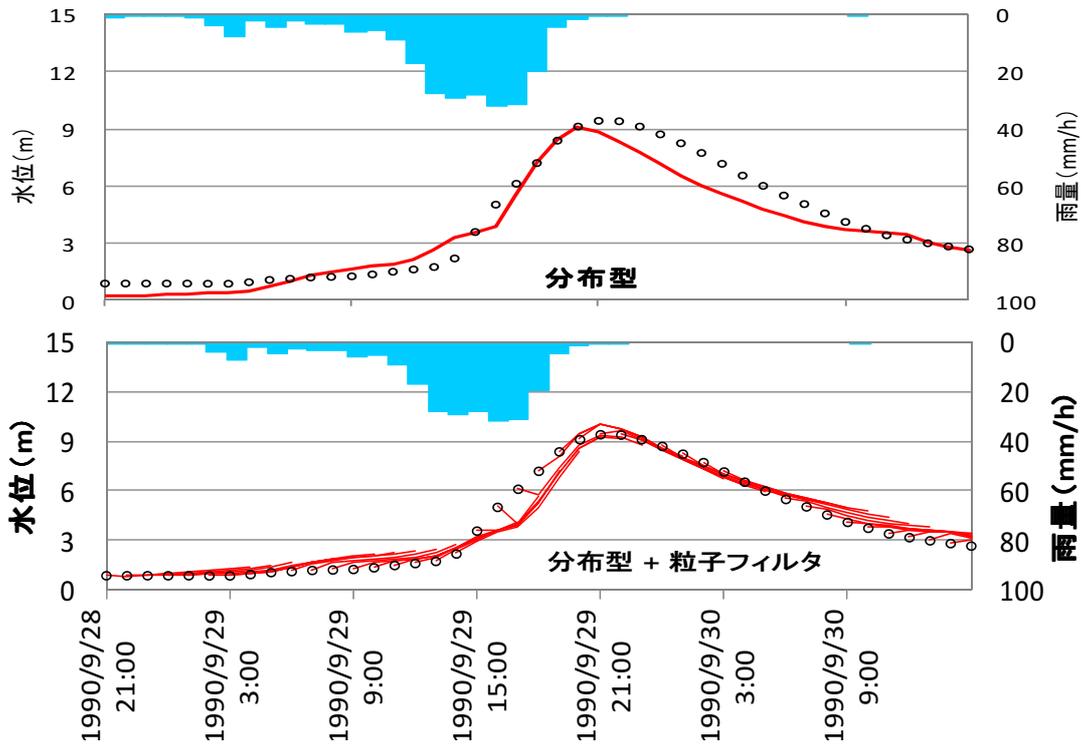


図 4-21 分布型流出モデルの計算結果と粒子フィルタの適用結果(1990年洪水、樋渡)

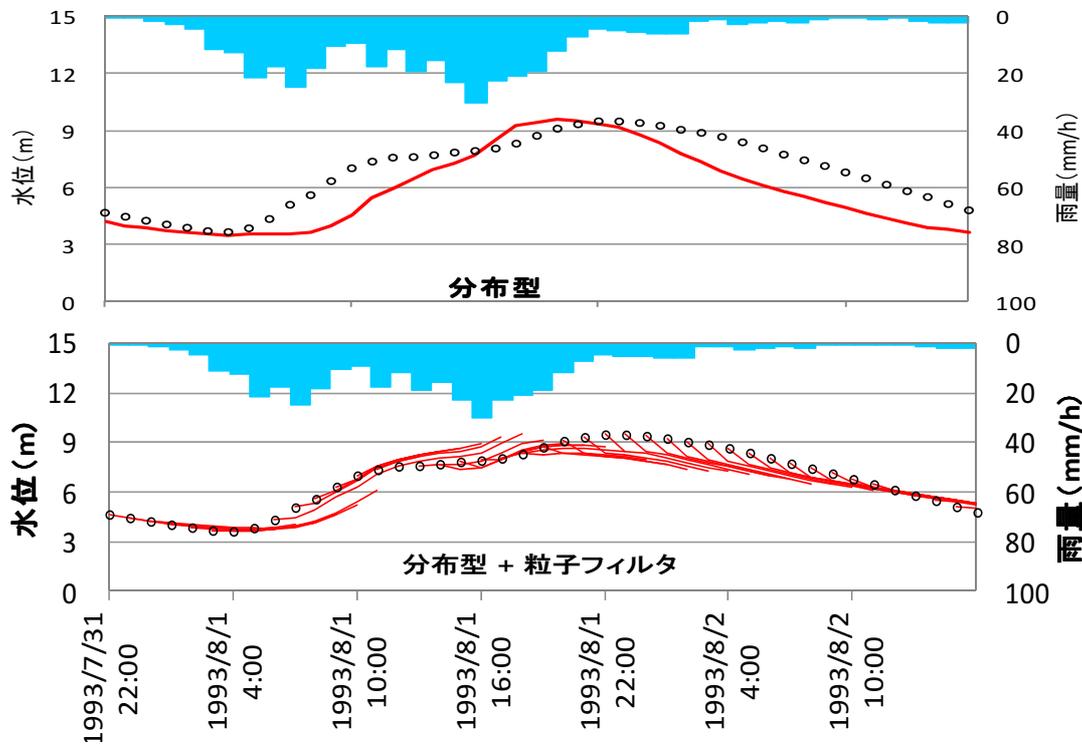


図 4-22 分布型流出モデルの計算結果と粒子フィルタの適用結果(1993年洪水、樋渡)

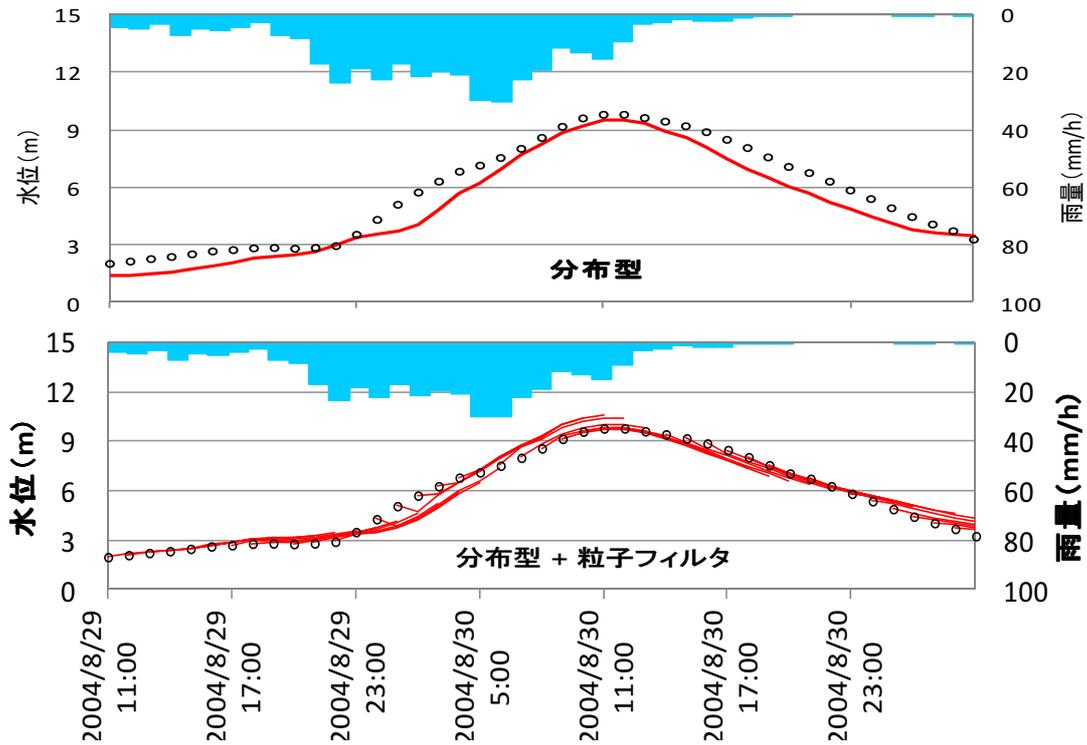


図 4-23 分布型流出モデルの計算結果と粒子フィルタの適用結果(2004年洪水、樋渡)

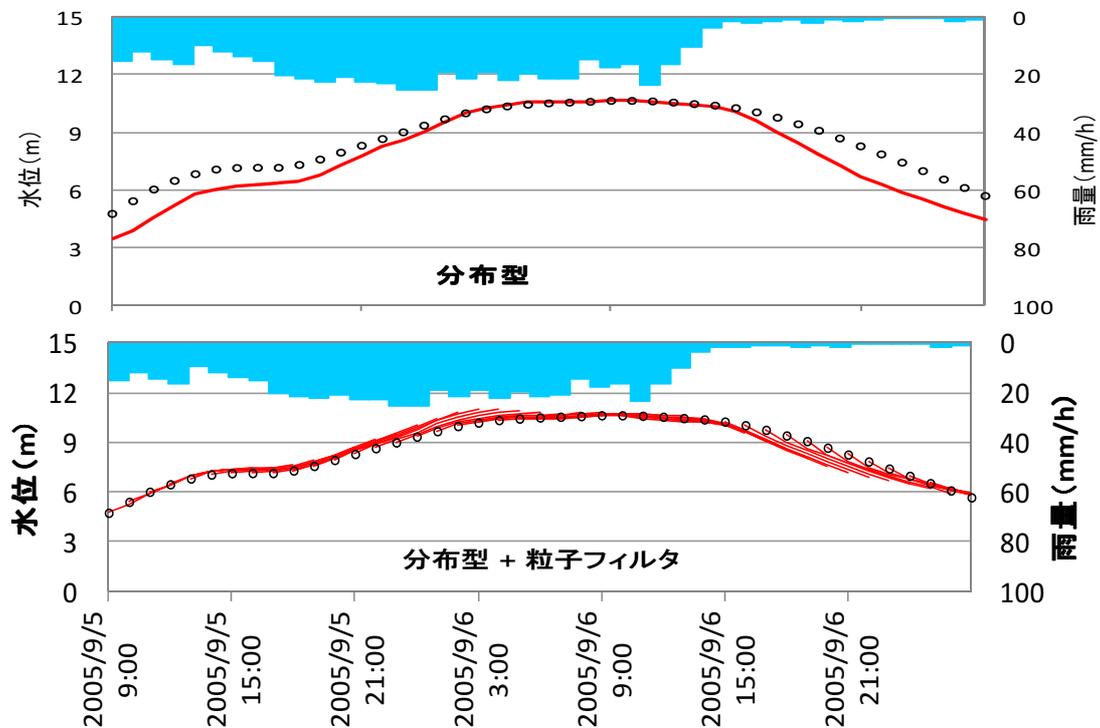


図 4-24 分布型流出モデルの計算結果と粒子フィルタの適用結果(2005年洪水、樋渡)

2) 粒子フィルタとスライド補正の比較

図 4-25～図 4-28に、粒子フィルタとスライド補正の結果を合わせて示す。また、図 4-29～図 4-32に、各洪水における 1～6 時間予測の水位誤差 (RMSE) の比較を示す。図 4-33には、4 洪水平均での 1～6 時間予測の RMSE の比較を示す。

予測時間が 1,2 時間程度の場合は、粒子フィルタに比べスライド補正の方が RMSE が小さくなっている。一方で、4～6 時間予測では粒子フィルタの方が精度が高くなっており、特に 6 時間予測ではスライド補正の結果は補正前よりも誤差が大きくなっている。

スライド補正で現時刻に強制的に合わせた予測では、予測時間が長くなると適用性が低くなってしまふものと考えられる。一方、水位の急な立ち上がり部分など元のモデルの乖離が大きい場合には、粒子フィルタを適用しても補正しきれない場合があることが確認された。

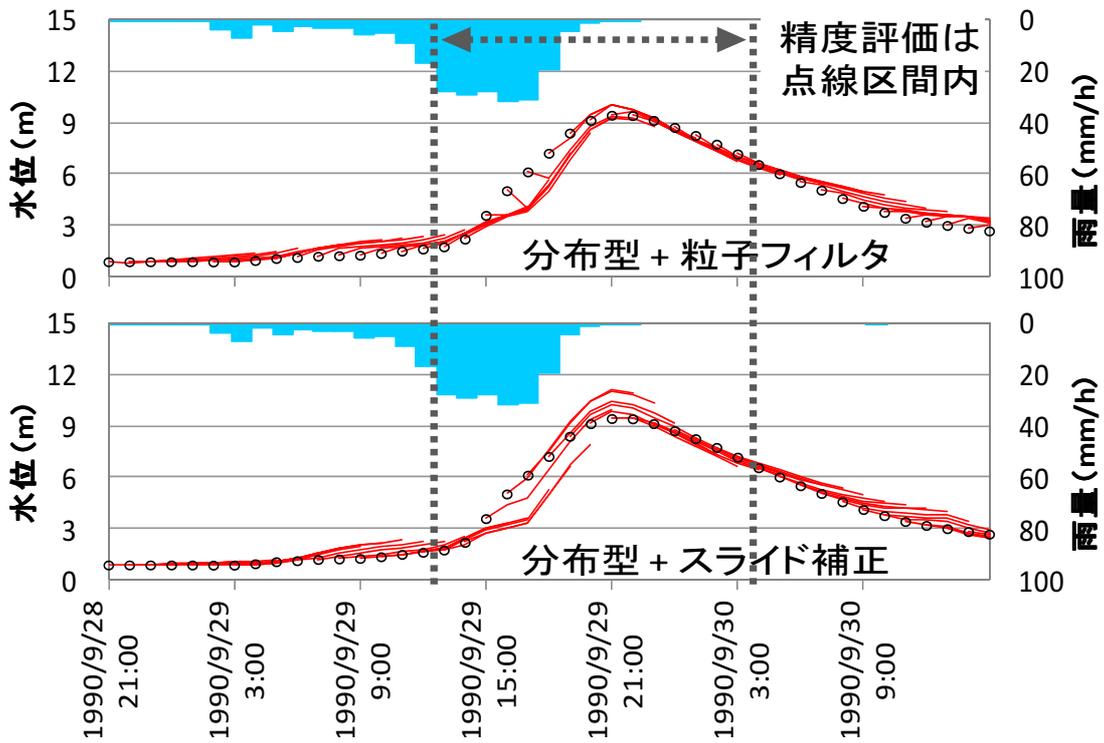


図 4-25 粒子フィルタとスライド補正の比較（1990年洪水、樋渡）

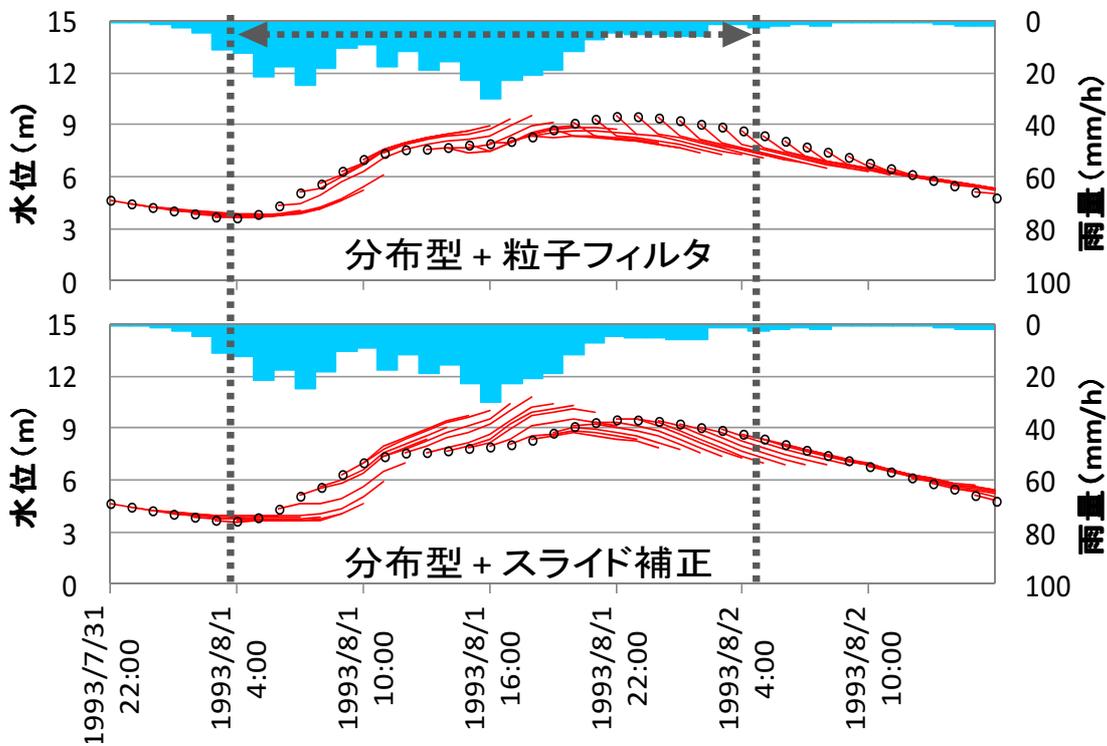


図 4-26 粒子フィルタとスライド補正の比較（1993年洪水、樋渡）

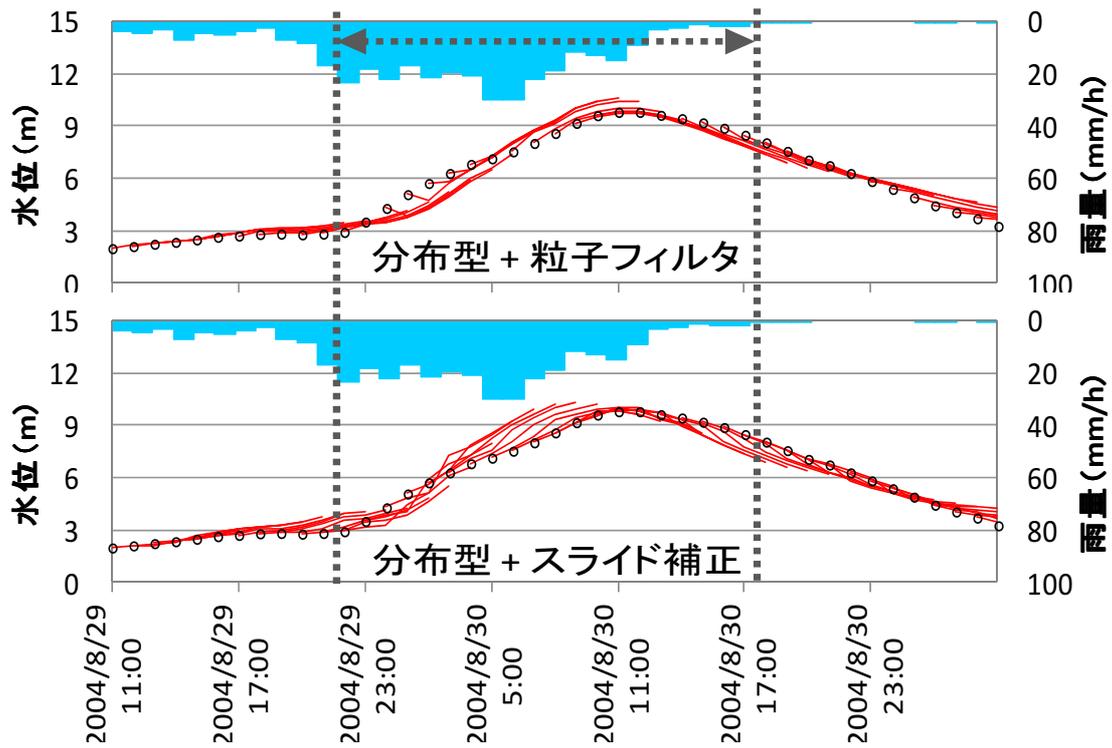


図 4-27 粒子フィルタとスライド補正の比較 (2004 年洪水、樋渡)

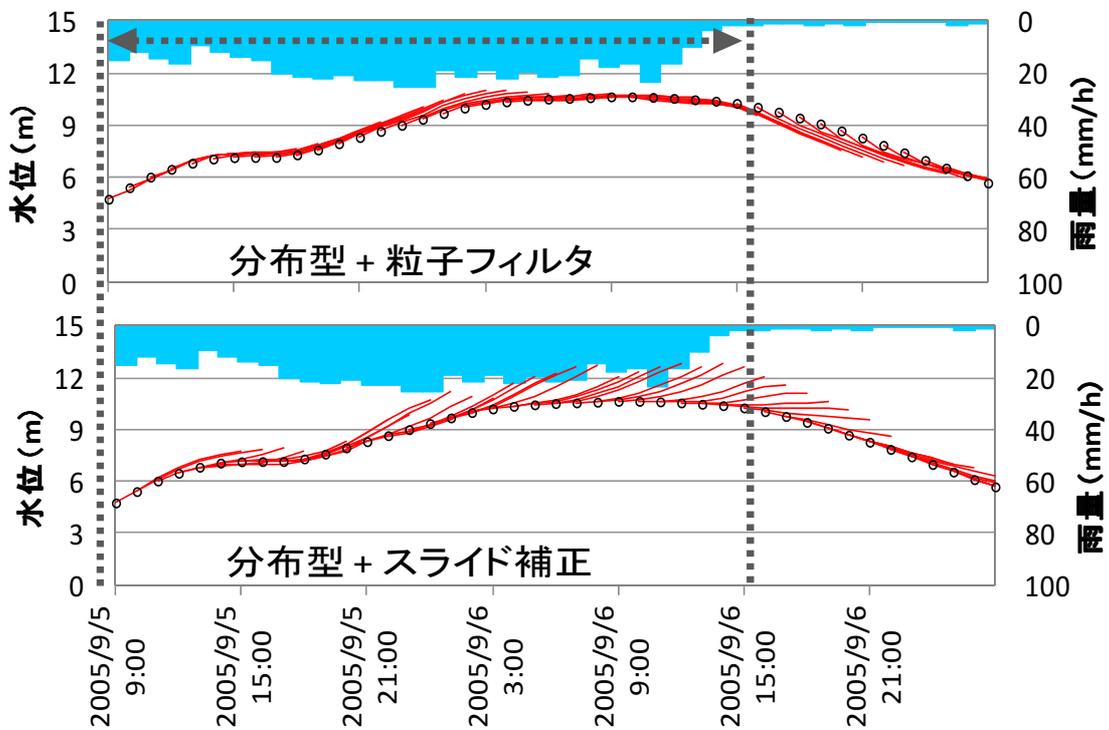


図 4-28 粒子フィルタとスライド補正の比較 (2005 年洪水、樋渡)

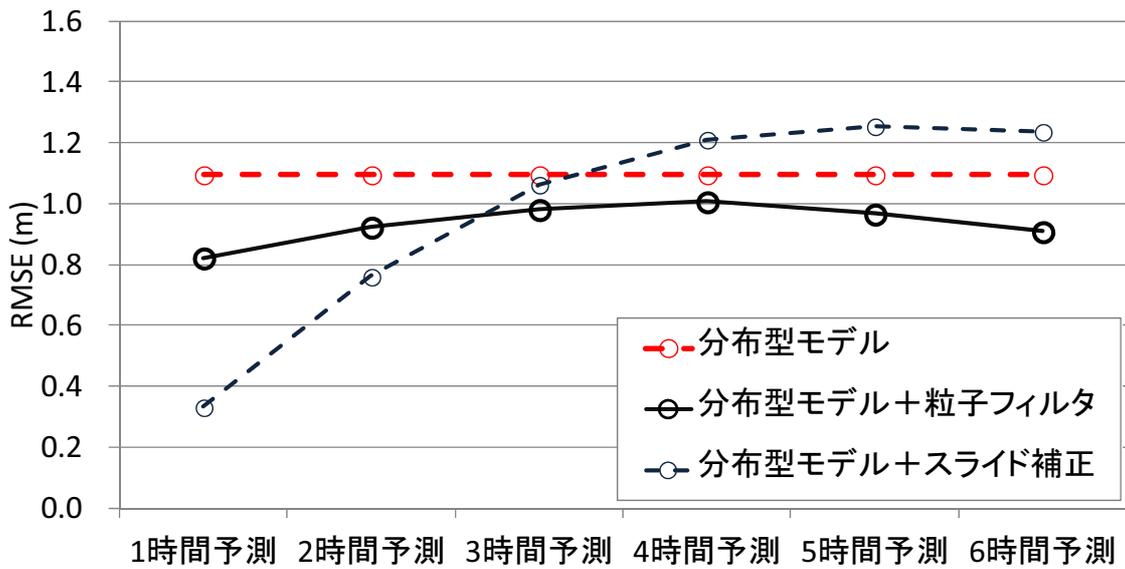


図 4-29 粒子フィルタとスライド補正の RMSE 比較 (1990 年洪水、樋渡)

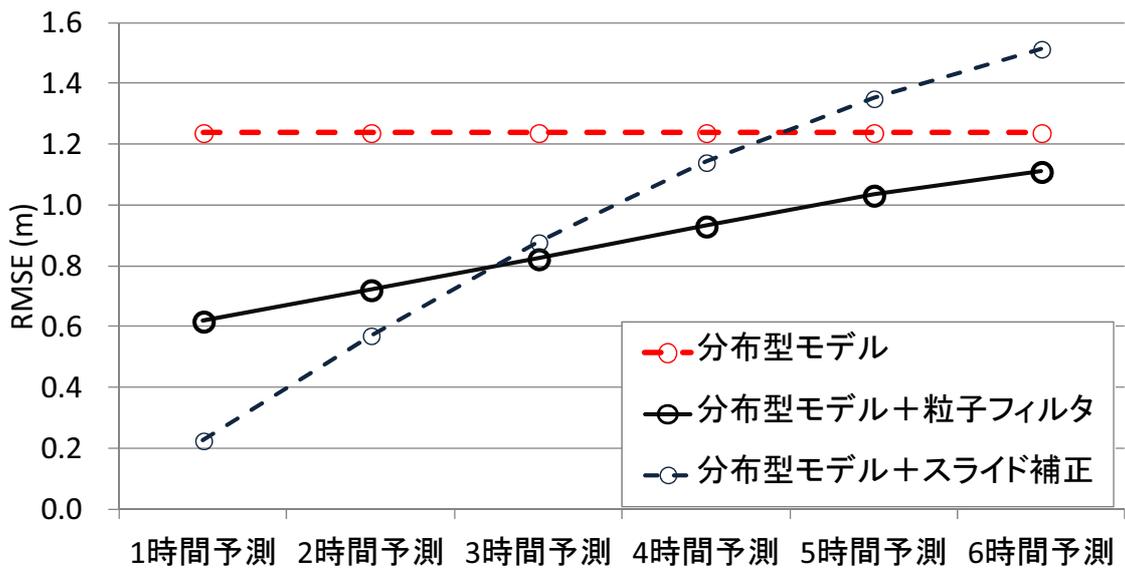


図 4-30 粒子フィルタとスライド補正の RMSE 比較 (1993 年洪水、樋渡)

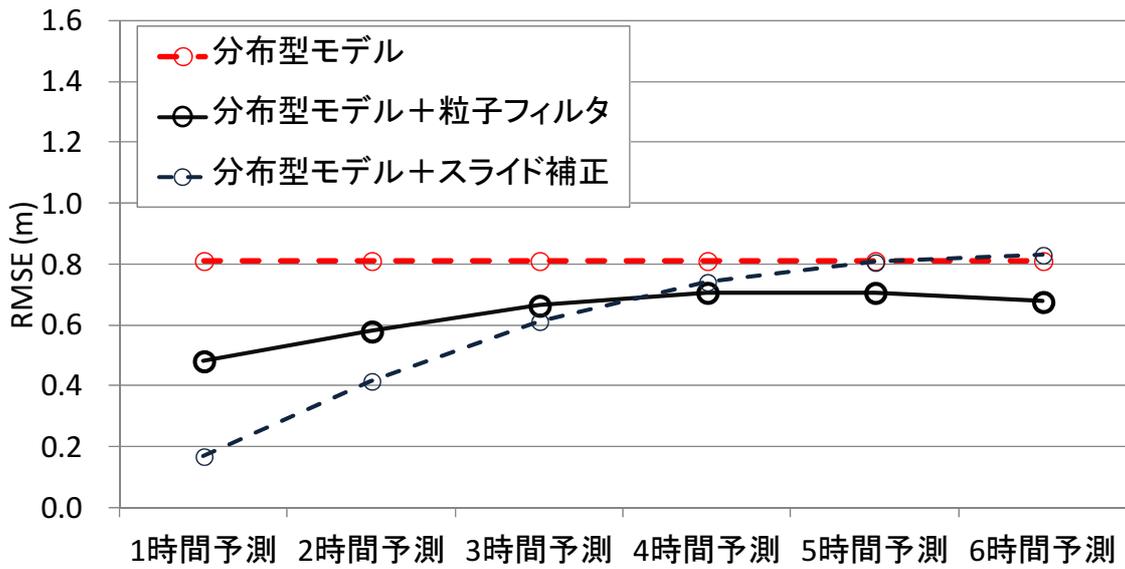


図 4-31 粒子フィルタとスライド補正の RMSE 比較 (2004 年洪水、樋渡)

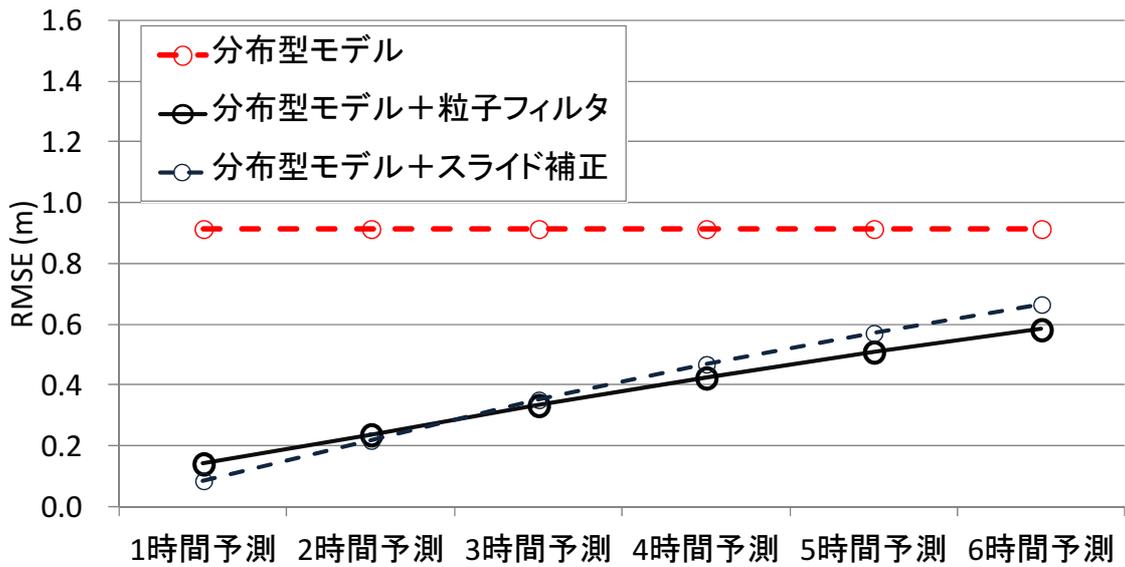


図 4-32 粒子フィルタとスライド補正の RMSE 比較 (2005 年洪水、樋渡)

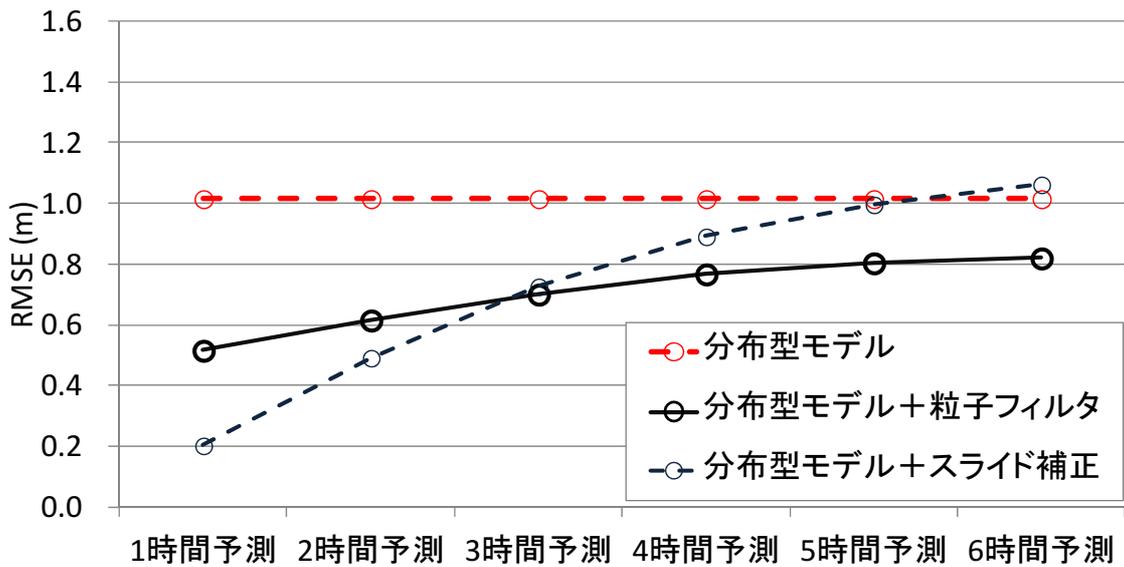


図 4-33 粒子フィルタとスライド補正の RMSE 比較 (4 洪水平均、樋渡)

4.4.5. 計算時間の検討

MPI ライブラリ (openmpi-1.4.3) を用いて、各 CPU に粒子 (モデル) の計算を均等に割り当てた。12 並列、96 粒子 (1CPU あたり 5 粒子) の計算では、6 時間予測に要する計算時間はおおよそ 74.0 秒であり、十分に実時間予測が可能であった。

表 4-7 粒子フィルタ実施の演算環境

項目	仕様
CPU(×2)	intel® Xeon®X5690 (6core) / 12Mキャッシュメモリ
クロック周波数	3.46GHz
メモリ	96GB (DDR3)
OS	Linux(CentOS)
HDD	2TB/7200rpm/SATA
並列環境	MPI(openmpi-1.4.3)
コンパイラ	インテル Composer XE 2011 Linux版(C++)

4.5. 物理的手法の適用と、粒子フィルタによる同化手法の検討の

まとめ

本章では、地下水流動および表層の水理をともに表現するため、飽和・不飽和過程を組み込んだ分布型流出解析モデルを開発した。リアルタイム観測データのフィードバック手法として、粒子フィルタによるデータ同化手法を適用した。

対象洪水に対して、粒子フィルタの予測結果とスライド補正の予測結果とを比較し、1～6時間先まで粒子フィルタによる精度向上を確認した。

5. 各種水位予測モデルの比較検討

天野ほか（2003）は、中小河川を対象に集中モデルと相関モデルとの精度比較を行った。田中ほか（2012）は、分布型モデルに対して、粒子フィルタと誤差上乘せ方式を適用した場合の精度比較を行った。Chau et.al.,（2005）は、学習に遺伝的アルゴリズムを適用したニューラルネットワークモデル（ANN-GA）と、ファジイ理論に基づいたモデル（ANFIS）および線形回帰モデルとの精度比較を行っている。

全国の一級河川で洪水予測システムが稼働しているが、住民の適切な避難判断に役立てるためには、予測に関する誤差に伴う不確実性を低減させる必要がある。洪水予測には様々な手法が開発されてきたが、モデル誤差、パラメータ誤差、降雨誤差など、様々な不確実性は避けられない。一方リアルタイムで観測水位情報が得られる場合、同化手法および予測補正による物理型モデルの不確実性の低減や、統計的な予測手法の適用が可能である。このような様々な手法の精度や適用性の違いを把握することは重要である。天野ほか（2003）は、中小河川を対象に集中モデルと相関モデルの精度比較を行った。また、田中・杉浦（2012）は、全国の洪水予測システムで近年において活用が進められている分布型モデルに対して、粒子フィルタと誤差上乘せ方式を比較した。しかしながら、本研究で検討した深層学習を適用したニューラルネットワークモデルについては、他手法との精度の比較が不明である。また、分布型モデルと粒子フィルタを組み合わせた手法と、統計的手法との精度比較を行った研究事例は見られない。

本研究では、一級河川の大淀川を対象として、複数の予測モデルの精度比較を行った。

5.1. 検討対象

検討対象流域は第3章、第4章で検討した大淀川流域とした。検討対象洪水も同様に、1990年～2014年の間で氾濫危険水位（9.2m）を超えた5洪水のうち欠測データの多い1事例を除いた4洪水とした。

5.2. 比較対象とした水位予測モデル

比較対象とした水位予測モデルは計5種類である。①深層学習を適用したニューラルネットワークモデル、②従来型のニューラルネットワークモデル、③水位・雨量を用いた線形の回帰モデル、および④分布型流出モデルと粒子フィルタを組み合わせた予測モデル、⑤分布型流出モデルと誤差スライド法を適用した予測モデルである。上記の①②③が統計的手法、④⑤が物理的手法と分類することができる。以下に各手法

の概要を示す。

5.2.1. 精度比較対象とした統計的水位予測モデルの概要

(1) 深層学習を適用したニューラルネットワークモデル

第3章で検討した、大淀川に適用したモデルの予測結果をそのまま精度検証に用いた。

ネットワーク構造は入力層・2つの中間層・出力層からなる4層の階層型ネットワークである。入出力層の組合せ、および学習の各種設定は表5-1、表5-2の通りとし、た。重み係数の初期値はランダムに設定して10回の計算を行い、結果の平均をとったものを精度検証対象とした。なお精度検証は、学習対象24洪水から検証対象1洪水ずつを除いたleave-one-out交差検証により行った。

表 5-1 t 時間予測の入出力層の組合せ

入力			出力
種別	地点	時刻	
時刻水位	樋渡	-1,0	樋渡の水位変化
一時間の水位変化	流域内 5 地点	-2,-1,0	
時刻雨量	流域内 14 地点	t-5,t-4,t-3,t-2,t-1	

表 5-2 学習の各種設定

種別	設定内容
学習データ期間	1990～2014 の上位 24 洪水
学習データ種類	樋渡水位、上流水位変化、時間雨量
データセット数	2904
バッチサイズ	100
予測時間	1 時間～6 時間
モーメンタム	0.5
学習率	初期値0.1としてAdaGradで自動設定
デノイジングの加算ノイズ	平均 0、分散 3%の正規乱数
学習回数	3000
各層の素子数	87-40-20-1
ドロップアウト率 (p)	0.1
事前学習	デノイジング自己符号化器

(2) 従来型のニューラルネットワークモデル

従来型のニューラルネットワークモデルとして、深層学習を適用しない3層の階層型ネットワークを用いた。第3章で検討した予測結果をそのまま精度検証に用いた。

入出力データや学習パラメータは深層学習モデルと同様とし、中間素子数は40とした。重み係数の初期値はランダムに設定して10回の計算を行い、結果の平均をとったものを精度検証対象とした。精度検証はleave-one-out交差検証により行った。

(3) 線形回帰モデル

1) 相関分析

統計モデルに用いる観測所を決定するため、樋渡地点の水位変化と相関の強い地点を選別した。相関分析の対象データとして、1990年～2014年の上位24洪水について、各洪水のピークから72時間前～48時間後までを1洪水とし、全部で121時間×24洪水=2904時間分のデータを用いた。目的変数は樋渡の時間水位変化、説明変数は上流水位観測所の時間水位変化および時間雨量とした。上流～予測地点までの遅れを考慮して、1時間ずつデータをずらして各観測所の相関係数を求めた(図5-1)。水位変化-水位変化の相関は、1時間ラグでは王子橋、2時間ラグでは乙房との相関係数が最も高くなった。また水位変化-雨量の相関は、1時間ラグでは樋渡、2時間ラグでは岳下との相関係数が最も高くなった。これらは、各観測所～樋渡までの流下時間に対応していると考えられる。

2) 線形回帰モデルの設定

相関モデルは、樋渡地点水位と上流の水位や雨量データとの相関関係を求め、水位予測を行うための線形の重回帰式を構築した。回帰式の構築に用いた入出力データの組合せは表5-3に示す通りとした。表5-3でR地点名(t)は時刻(t)の時間雨量、 ΔH 地点名(t)は時刻(t-1)～(t)の水位変化を表わす。例えば ΔH 樋渡(1)は、樋渡地点での現時刻～1時間後の水位変化を表す。現時刻の水位にANNの計算結果 ΔH 樋渡(1)を加えたものを1時間予測水位とした。2時間予測以降は、前の計算結果に順次ANNの計算結果 ΔH 樋渡(t)を加えることで算出した。入力層には、樋渡水位変化の2時間分と、上流の相関の高い水位変化・時刻雨量を用いた。4時間予測以降は、上流水位変化の相関が小さくなるため、入力層から除いた。降雨は実測雨量を予測雨量に見立てた完全予測データを用いた。

精度検証に際してはANNと同様に、対象4洪水に対してleave-one-out交差検証により重回帰分析を行い、検証対象4洪水に対する予測精度を求めた。

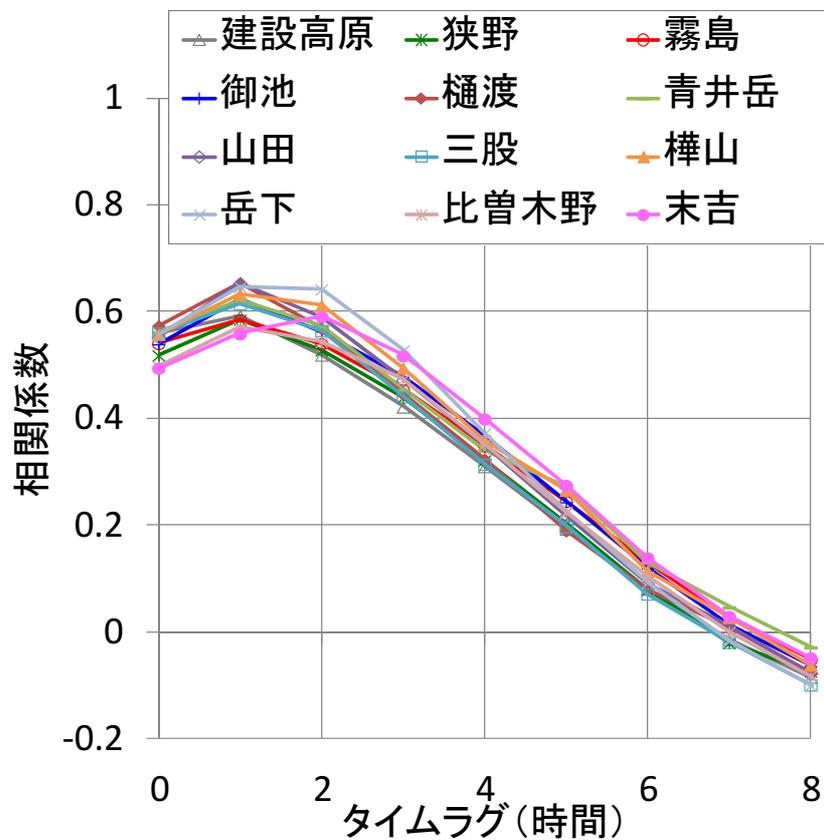
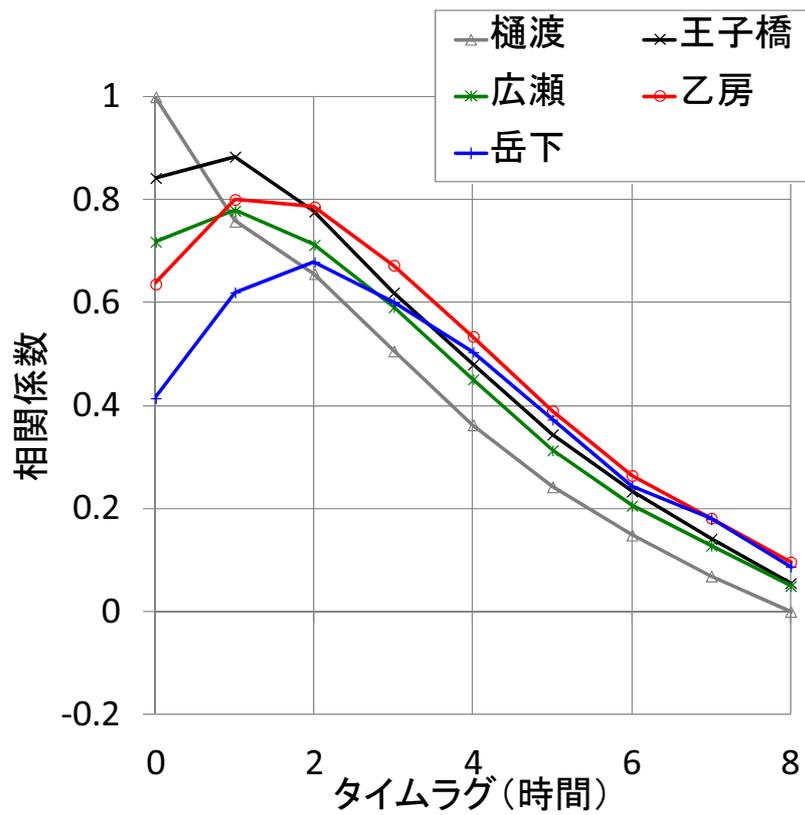


図 5-1 相関係数 (上：水位変化-水位変化、下：水位変化-雨量)

表 5-3 相関モデルの入出力組合せ

モデル No	入力	出力
1	$\Delta H_{\text{種渡}(0)}, \Delta H_{\text{種渡}(-1)}, \Delta H_{\text{王子橋}(0)}, R_{\text{岳下}(-1)}$	$\Delta H_{\text{種渡}(1)}$
2	$\Delta H_{\text{種渡}(1)}, \Delta H_{\text{種渡}(0)}, \Delta H_{\text{乙房}(0)}, R_{\text{岳下}(0)}$	$\Delta H_{\text{種渡}(2)}$
3	$\Delta H_{\text{種渡}(2)}, \Delta H_{\text{種渡}(1)}, \Delta H_{\text{乙房}(0)}, R_{\text{岳下}(1)}$	$\Delta H_{\text{種渡}(3)}$
4	$\Delta H_{\text{種渡}(3)}, \Delta H_{\text{種渡}(2)}, R_{\text{岳下}(2)}$	$\Delta H_{\text{種渡}(4)}$
5	$\Delta H_{\text{種渡}(4)}, \Delta H_{\text{種渡}(3)}, R_{\text{岳下}(3)}$	$\Delta H_{\text{種渡}(5)}$
6	$\Delta H_{\text{種渡}(5)}, \Delta H_{\text{種渡}(4)}, R_{\text{岳下}(4)}$	$\Delta H_{\text{種渡}(6)}$

5.2.2. 精度比較対象とした物理的水位予測モデルの概要

物理的水位予測モデルとして、第4章で検討した2手法（スライド補正を適用した分布型モデル、および粒子フィルタを適用した分布型モデル）精度比較対象とした。これらの手法については、第4章の結果をそのまま精度検証に用いた。

5.3. 精度評価

本検討で構築した深層学習による水位予測結果と、①分布型モデル+スライド補正、②分布型モデル+粒子フィルタ、③ANNモデル(3層)、④水位相関モデルについて、精度を比較した。深層学習と②③の水位予測結果を合わせて図 5-2～図 5-5に示す。また、各洪水の1時間～6時間予測のRMSEを図 5-6～図 5-9に、4洪水平均でのRMSEを図 5-10に示す。なお精度評価期間は水位が顕著に上昇し始めた時刻からピーク6時間後までとし、図 5-2～図 5-5中に点線で示す。深層学習による水位予測結果は、他の4手法に比べて各予測時間で高い再現性を示した。

ANN(3層)との比較では、4洪水の各予測時間において、ほとんどの場合に深層学習の方が精度向上している。これはネットワーク構造が大きくなったことで表現性が増したと同時に、事前学習を始めとした適用手法により過学習が抑えられているためと考えられる。

分布型モデル(粒子フィルタ)との比較では、短い予測時間に対しては深層学習モデルの方が大幅に精度が高い。これは、深層学習モデルでは短時間の水位上昇と相関の高い上流の観測水位情報を入力値に利用しているためと考えられる。長い予測時間に対しても深層学習モデルがやや上回るが、差は小さくなっている。これは上流の水位情報の影響が無くなり、相対的に降雨-流出過程の影響がより大きくなっていることから、分布型の優位性が出やすくなったためと考えられる。また2005年の洪水については分布型の方が精度が高くなっている。2005年洪水は期間最大であり、ピーク付近の水位が他の洪水よりも高いため、学習データの事例不足となった可能性がある。他の3洪水については、いずれも深層学習モデルが分布型モデルを上回る精度となった。

分布型モデルのフィードバックとしては、短い予測時間に対しては、粒子フィルタによる状態量補正よりも、現時刻に強制的に合わせるスライド補正の方が高精度となった。一方で長い予測時間に対しては、粒子フィルタの方が高精度となった。

また水位相関モデルは、3時間以内程度の予測時間ではANN(3層)や深層学習と遜色のない精度を示したが、それ以上に予測時間が長くなると急激に精度が低下した。

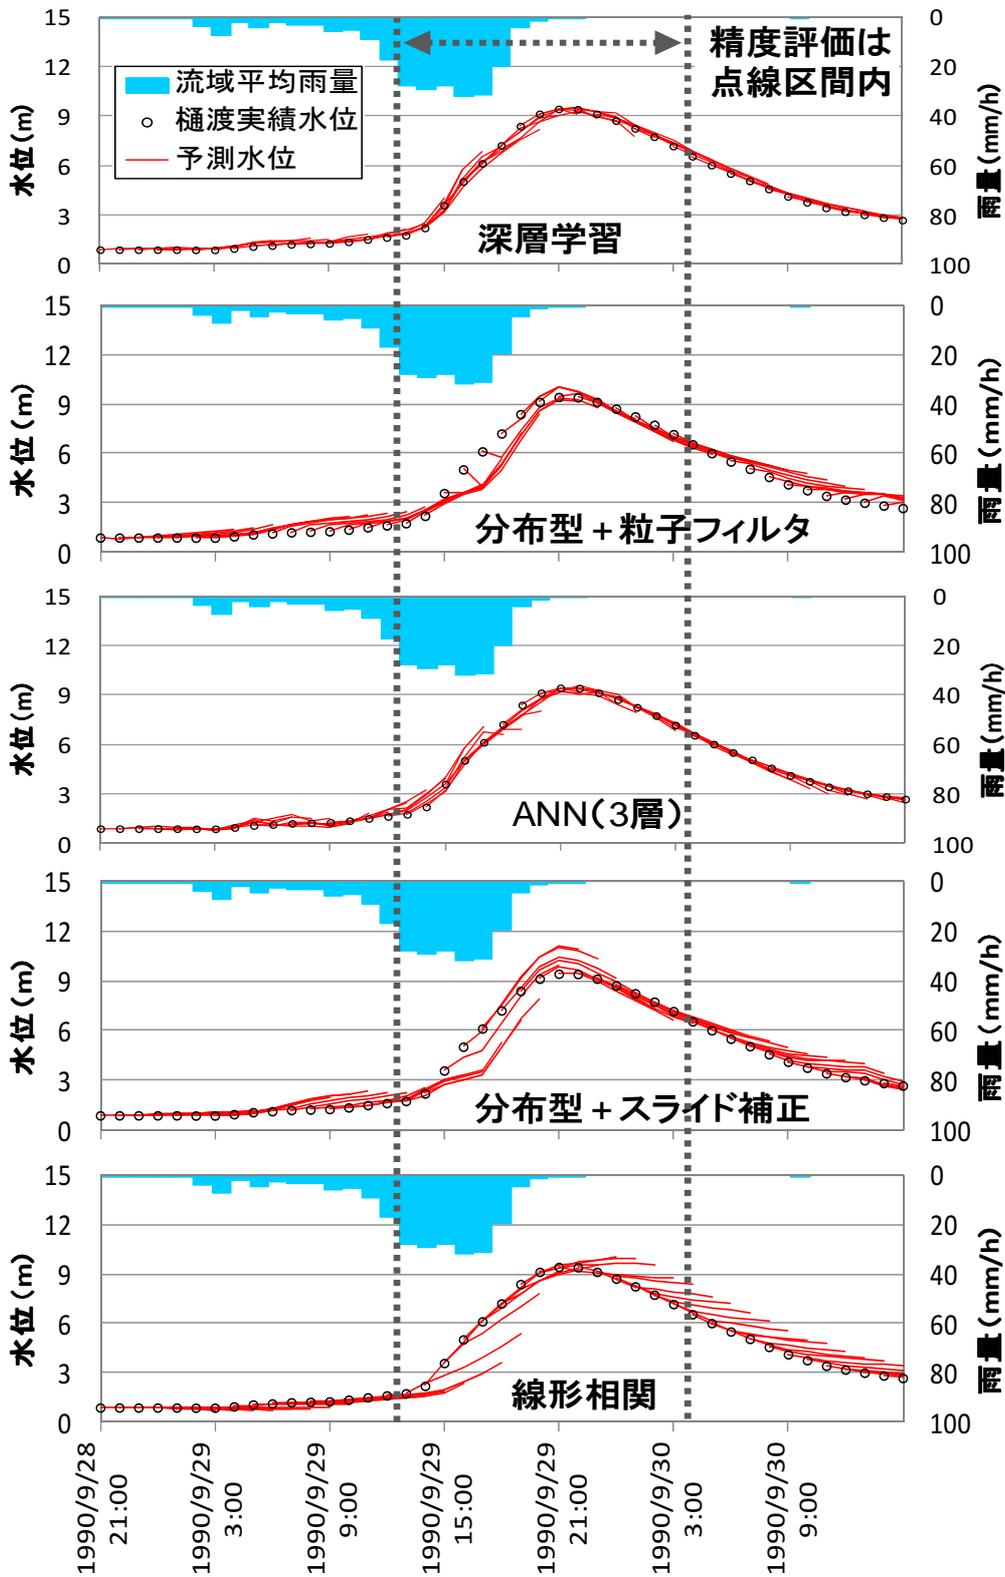


図 5-2 各手法による予測計算結果 (1990 年洪水、樋渡)

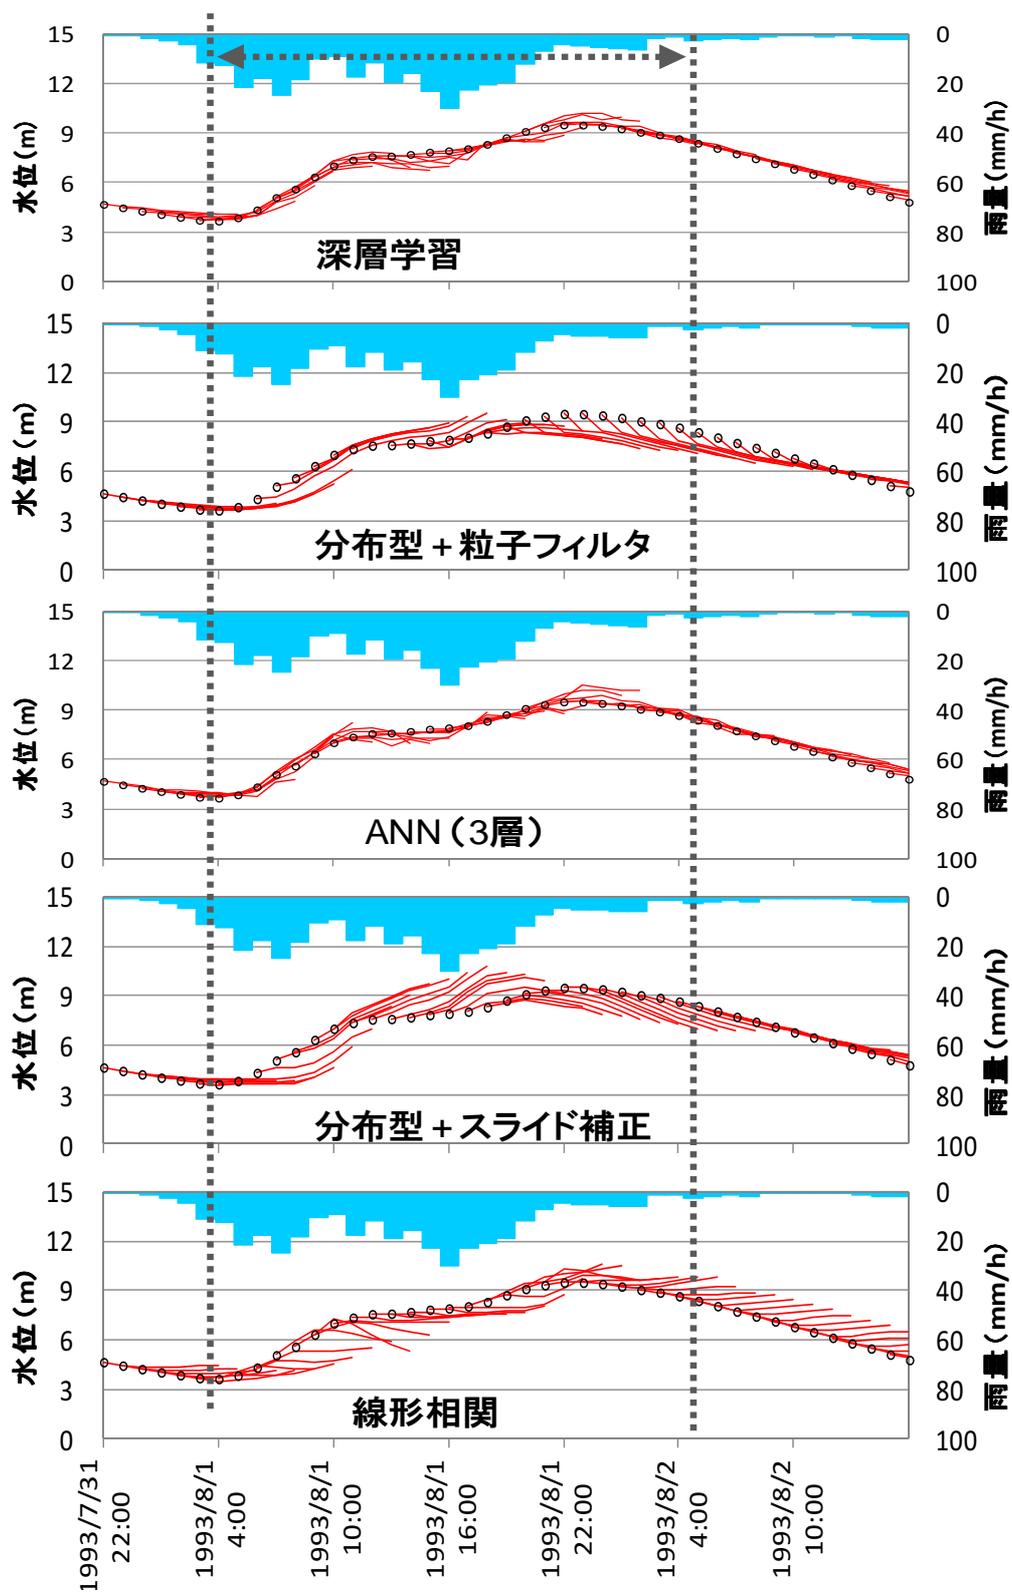


図 5-3 各手法による予測計算結果 (1993 年洪水、樋渡)

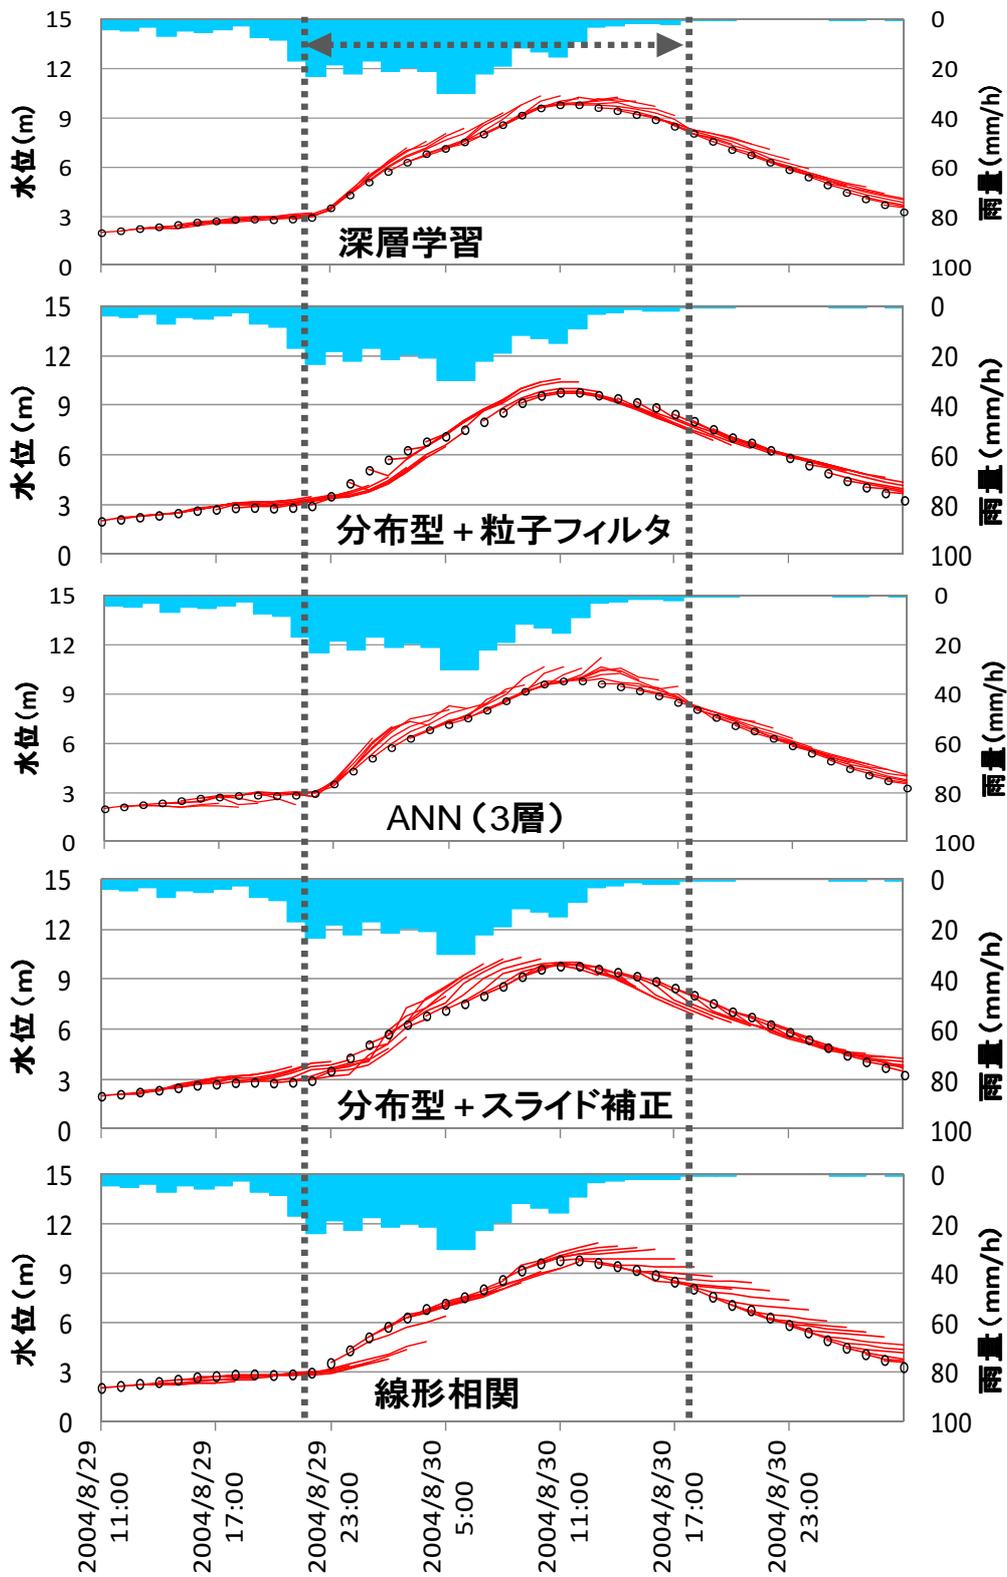


図 5-4 各手法による予測計算結果 (2004 年洪水、樋渡)

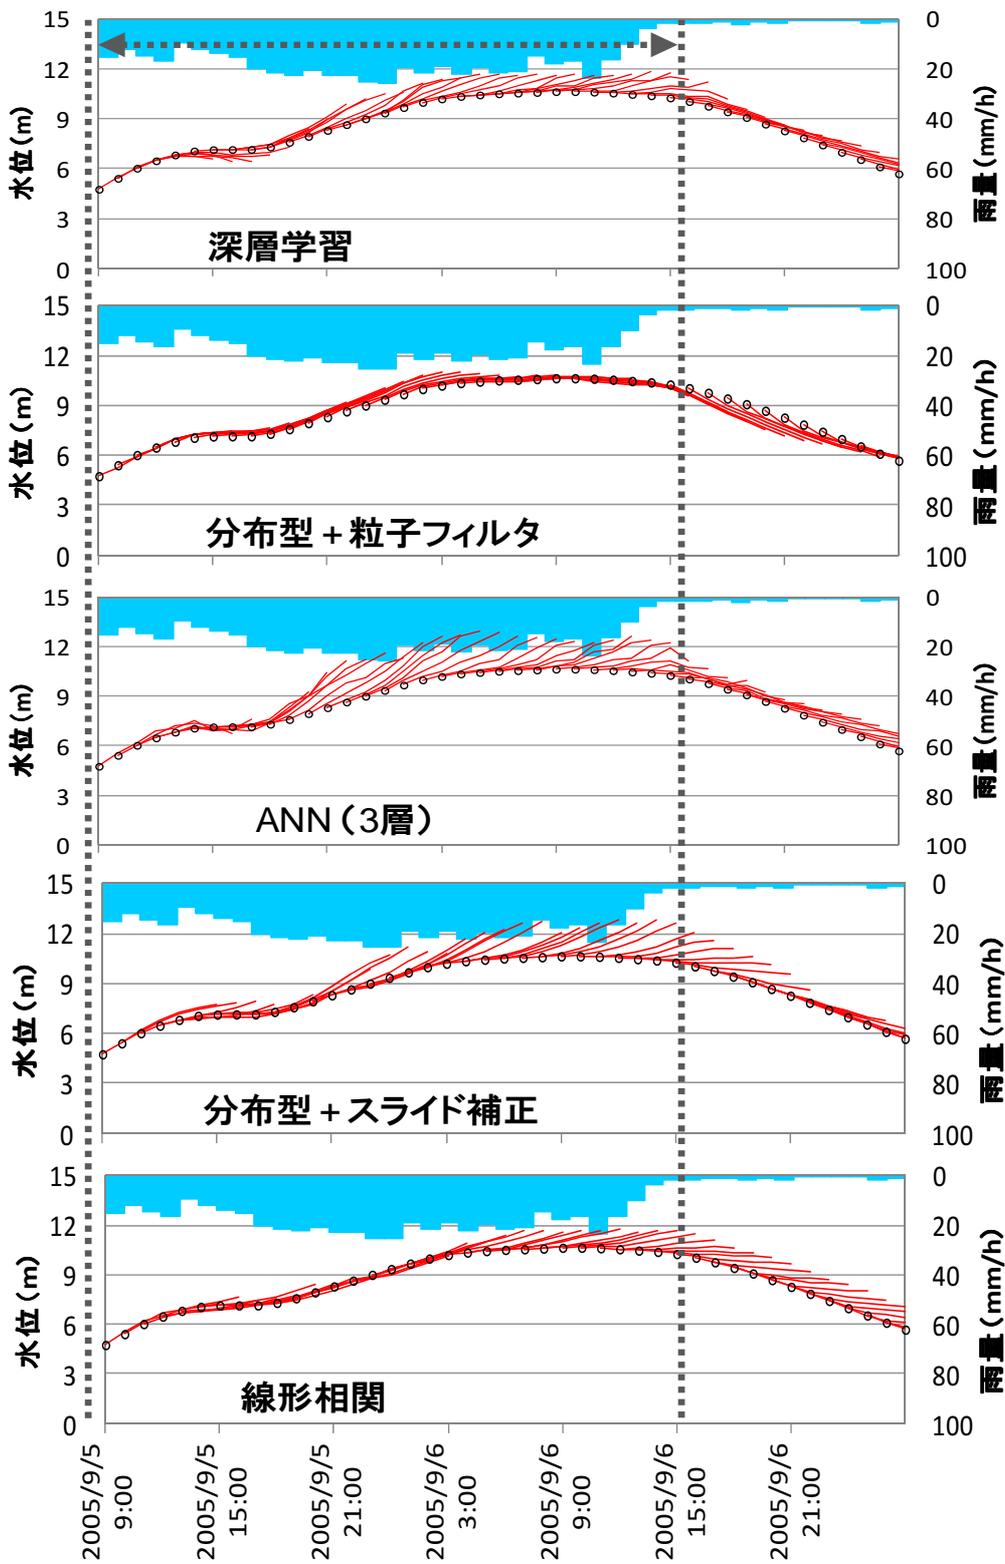


図 5-5 各手法による予測計算結果 (2005 年洪水、樋渡)

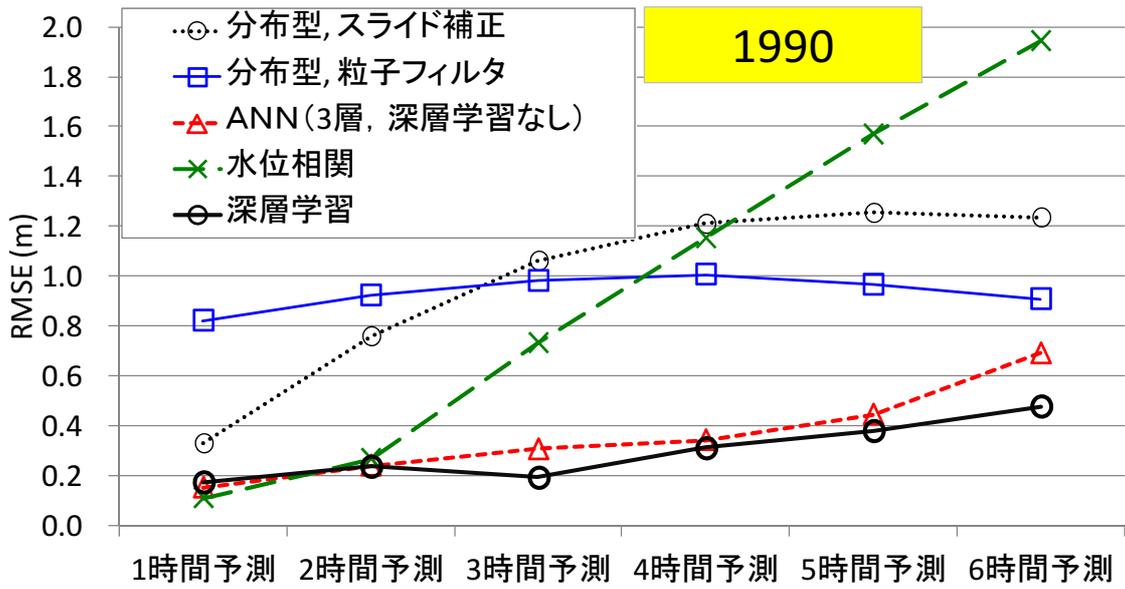


図 5-6 各手法の RMSE 比較 (1990 年洪水、樋渡)

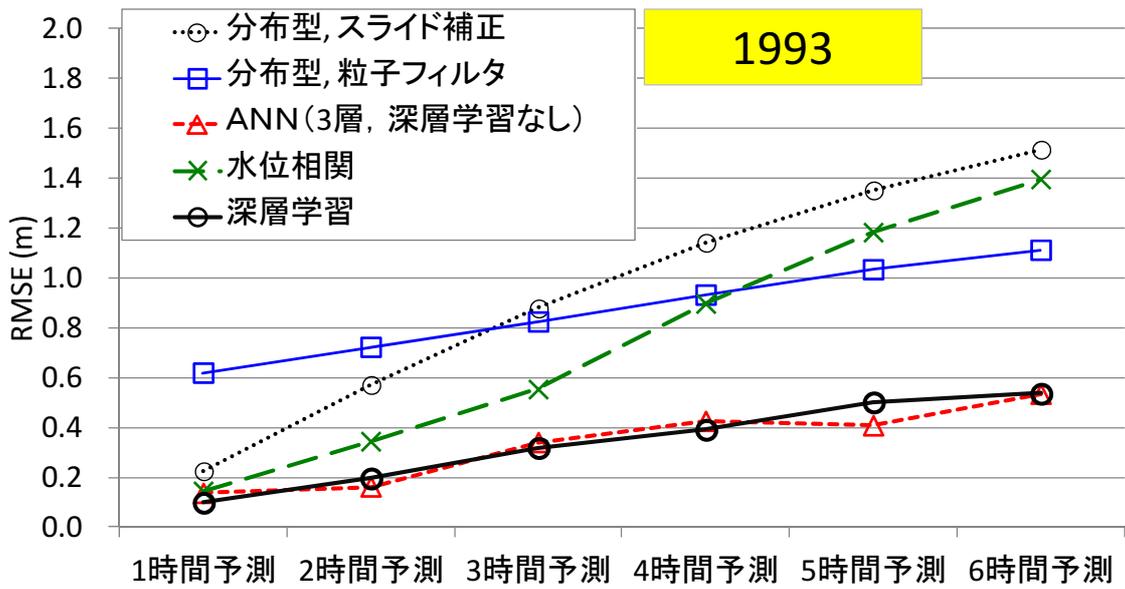


図 5-7 各手法の RMSE 比較 (1993 年洪水、樋渡)

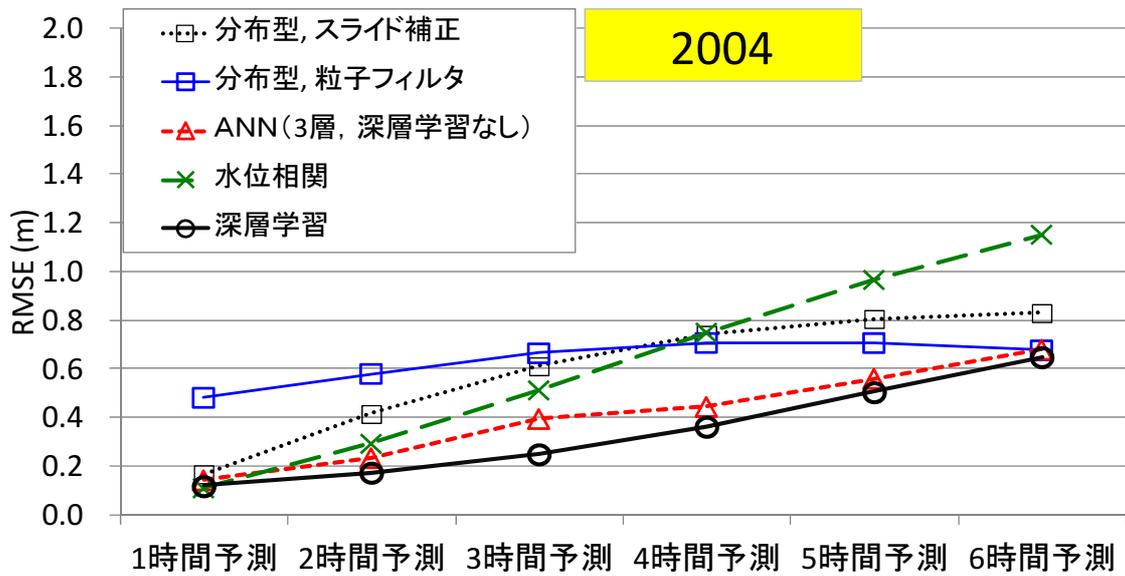


図 5-8 各手法の RMSE 比較 (2004 年洪水、樋渡)

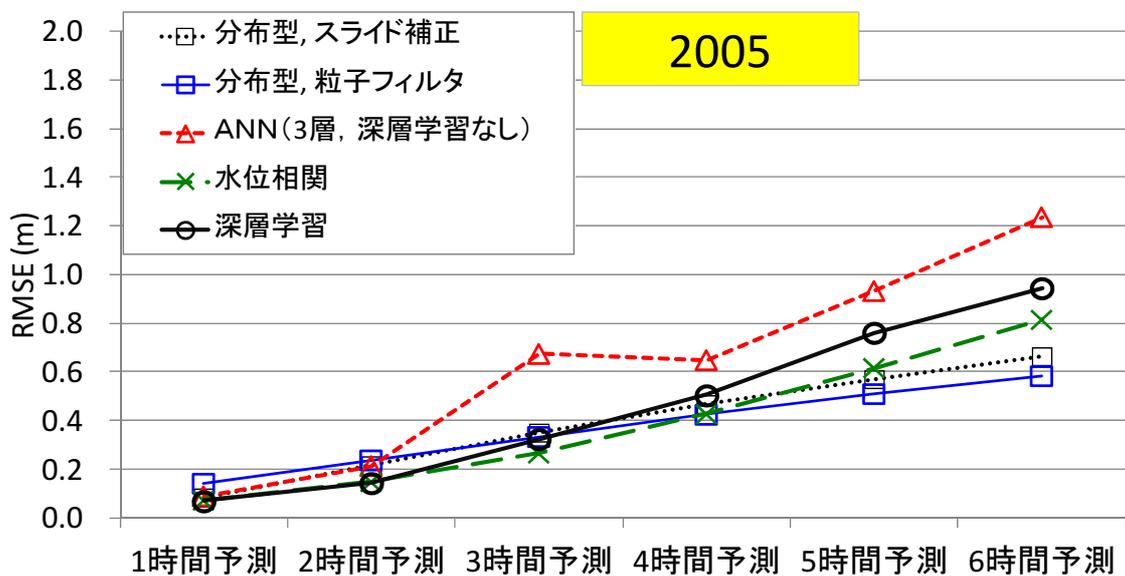


図 5-9 各手法の RMSE 比較 (2005 年洪水、樋渡)

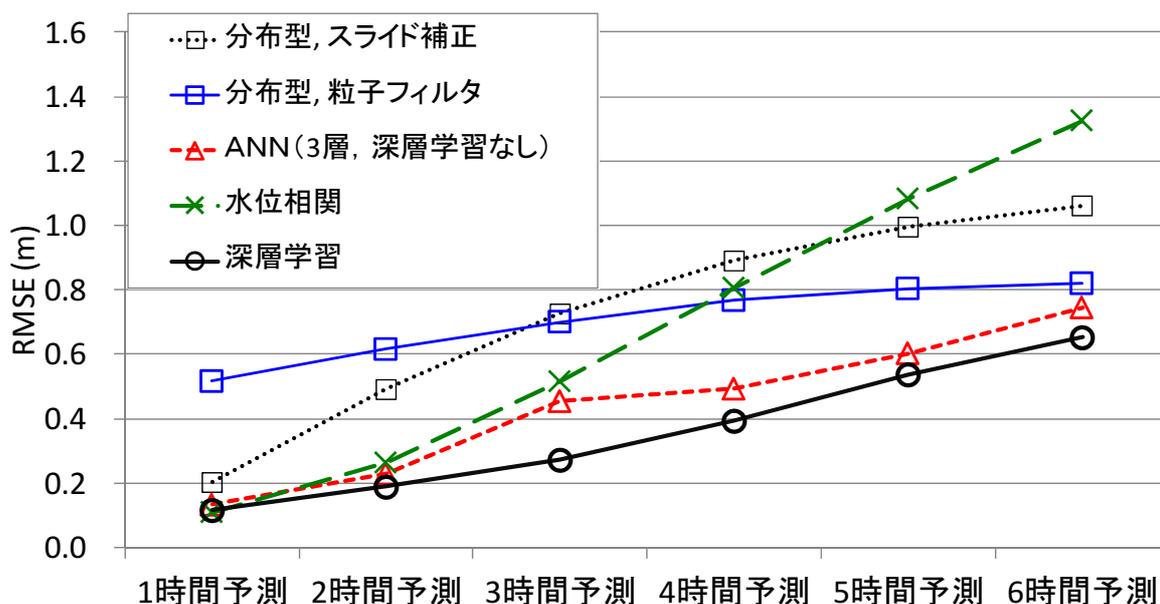


図 5-10 各手法の RMSE 比較 (4 洪水平均、樋渡)

5.4. モデルの比較検討のまとめ

本研究では、複数の水位予測モデル（深層学習、ANN（3層）、水位相関、分布型モデル+スライド補正、分布型モデル+粒子フィルタ）の予測精度比較を行った。深層学習による水位予測結果は、他の4手法に比べて各予測時間で高い再現性を示した。

物理型モデルと統計モデルの比較では、短い予測時間では統計モデルがはっきりと優位であり、長い予測時間では深層学習・ANN（3層）が優位であるものの、物理型モデルとの差は小さくなった。

今後、洪水予測の精度向上を図る上では、上記のようなモデルごとの予測精度の特性を踏まえ、予測時間や精度の目標に応じて適切なモデルを用いることが重要であると考ええる。ただし、予測時間ごとのモデルの特性は、流域の規模や流出特性、上流観測情報の量や質、さらには予測降雨や予測モデルの構造によっても異なるものと考えられるため、今後さまざまな流域で検討を積み重ねることが有益である。

6. 深層学習と物理的手法のハイブリッド水位予測の開発

6.1. 深層学習による水位予測の課題

第2章のケーススタディ①において、期間最大洪水（2005）のピーク水位付近で精度低下が見られた（図6-1、図6-2参照）。ANNを始めとする統計モデルによる予測では、学習経験のない（高水位の）事象に対する適用性が不明とされている。高水位の予測精度向上は課題として非常に重要である。第2章で検討した大淀川（樋渡地点）を対象に、深層学習モデルの改良を行った。

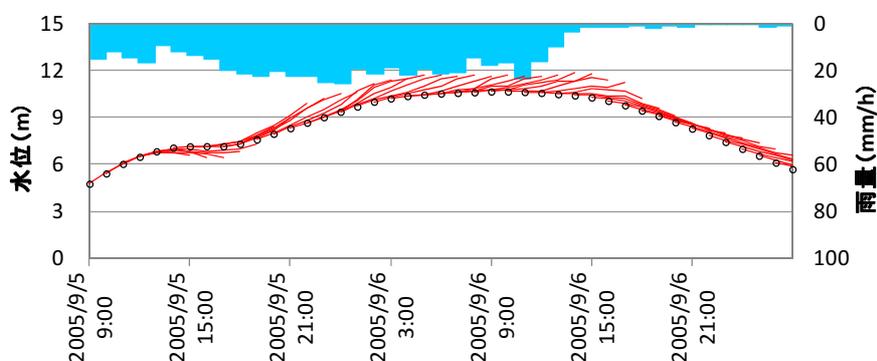


図 6-1 深層学習の適用結果（2005年洪水、樋渡）

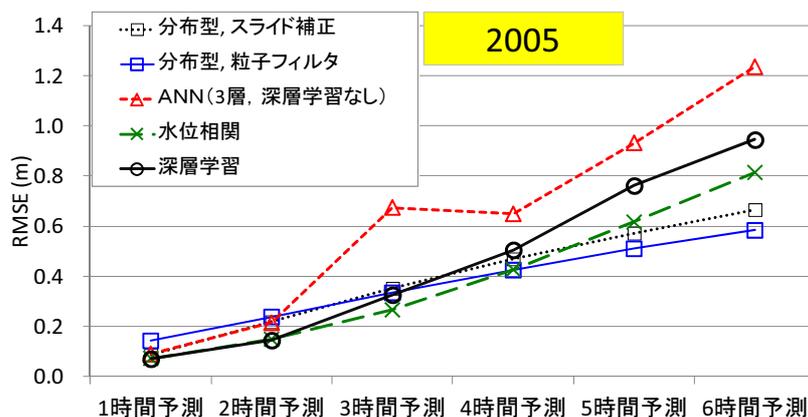


図 6-2 各手法の予測精度比較（2005年洪水、樋渡）

6.2. ハイブリッドモデルの開発

6.2.1. 貯留関数法から学習モデルへのアナロジー

第3章で構築した深層学習モデルは、入力層が $\Delta H, H, r_e$ 、出力層が ΔH となっている。予測精度向上のためには、入力層は出力層 ΔH と相関の強いものが適している。一方で、貯留関数モデルでは降雨-流出を次のように表現する。

$$\frac{dS}{dt} = r_e(t - T_L) - q, \quad S = kq^p \dots\dots\dots (6.1)$$

ここで、 S ：貯留量、 r_e ：有効雨量、 t ：時刻、 T_L ：遅滞時間、 k, p ：流出パラメータ、 q ：流出高である。

式(6.1)より、流量 q が貯留量 S に依存することは明らかである。したがって、現時刻から数時間後までの流量変化 Δq は、貯留量変化 ΔS に依存するものと考えられる。短い時間内では H と Q はほぼ一対一の対応であるため、 ΔH は ΔS に依存する。

以上の考察より、学習モデルの入力層には、 r_e よりも $r_e(t - T_L) - q$ が適している可能性がある。

6.2.2. 相関分析による入力因子の検討

予測地点の ΔH との相関の強さを確認するため、目的変数を ΔH 、説明変数を r_e および $r_e(t - T_L) - q$ とした相関分析を行った。説明変数を r_e とした場合の結果を図6-3に、説明変数を $r_e(t - T_L) - q$ とした場合の結果を図6-4 ($T_L = 0$)、図6-5 ($T_L = 1$)に示す。いずれのケースも説明変数 ΔH とのタイムラグが1,2時間の時に相関係数が高くなり、岳下地点が最も強い相関を示した。岳下地点に関する相関係数を比較したものを図6-6に示す。図6-6より、 ΔH との相関は、 r_e よりも貯留量変化 $r_e(t - T_L) - q$ の方が高い結果となった。なお、貯留量変化の遅滞時間は $T_L = 1$ とした場合の方が相関が高い。

以上の検討より、 $T_L = 1$ として、入力層に貯留量変化の推定値 $r_e(t - T_L) - q$ を与えた場合の検討を行う。

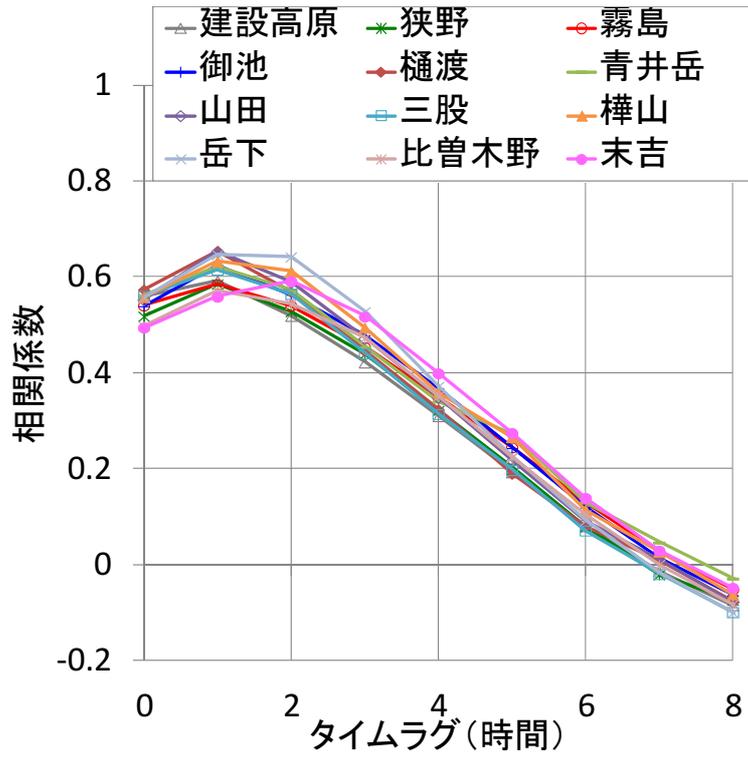


図 6-3 相関係数 (樋渡 ΔH と時間雨量)

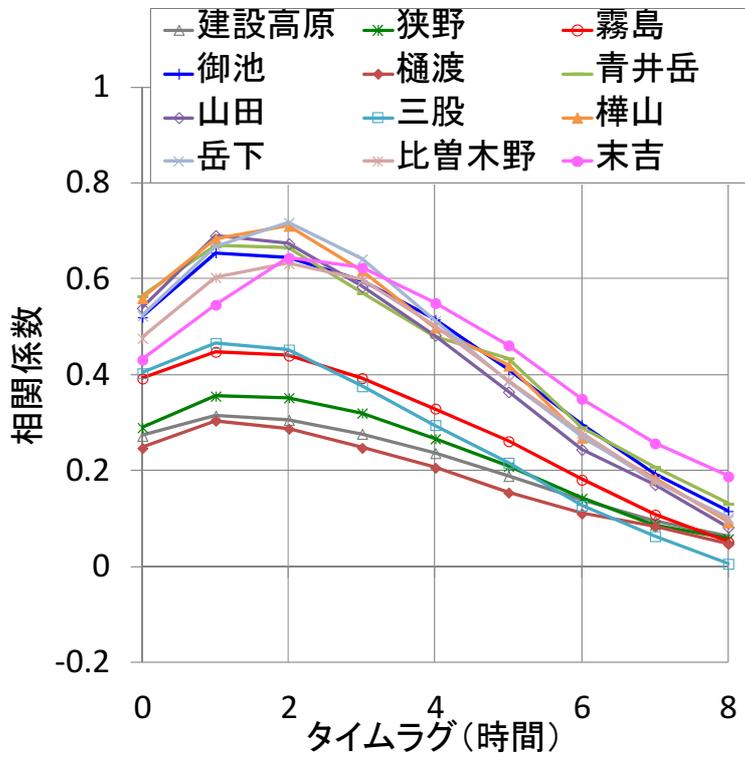


図 6-4 相関係数 (樋渡 ΔH と $r_e(t-T_L)-q$, $T_L=1$)

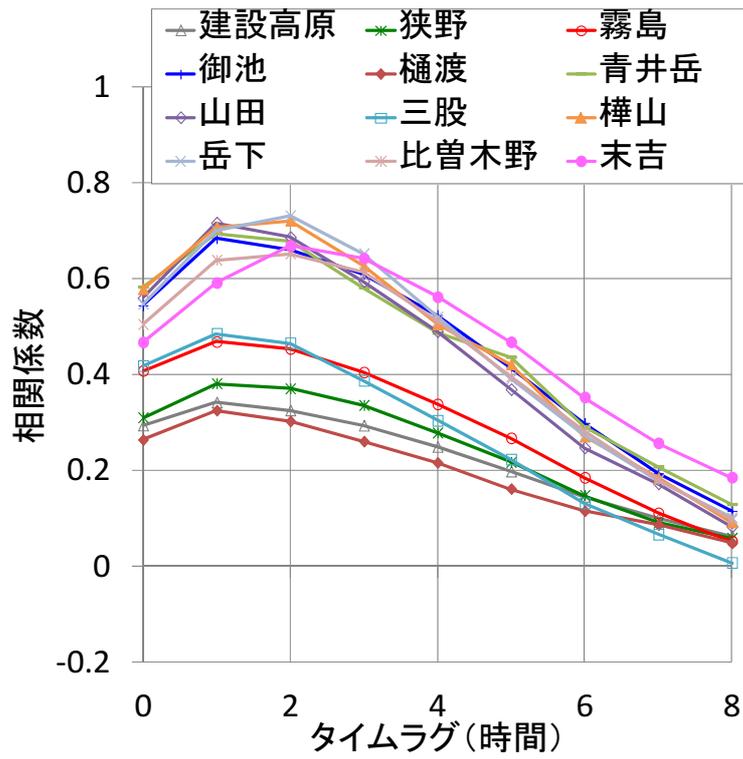


図 6-5 相関係数 (樋渡 ΔH と $r_e(t-T_L)-q$, $T_L=0$)

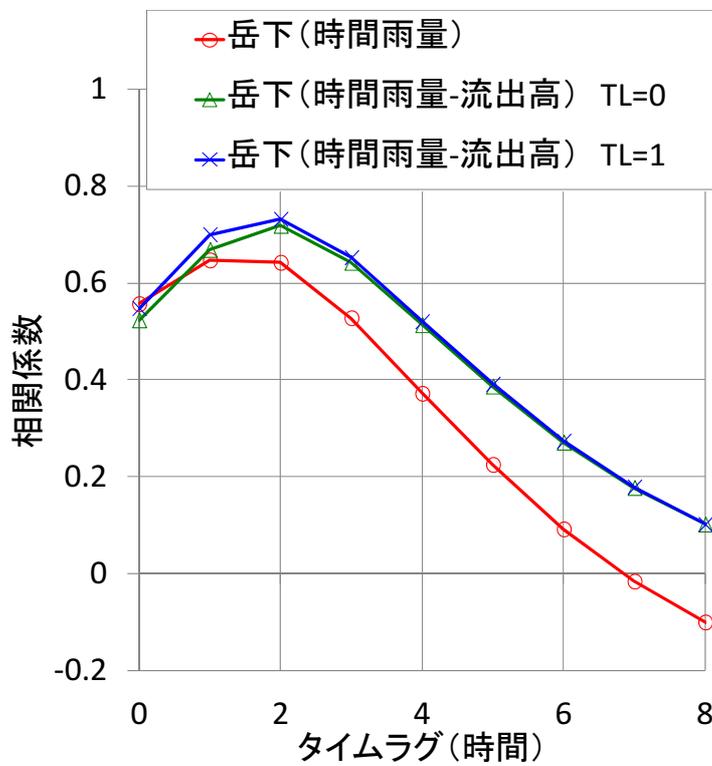


図 6-6 相関係数 (岳下地点)

6.2.3. ハイブリッドモデルの条件設定

第3章で検討した深層学習を適用したニューラルネットワークモデルについて、入力層に降雨 r_e のかわりに貯留量変化の推定値 $r_e(t - T_L) - q$ を与えた場合の検討を行った。入出力層の概念図を図6-7に示す。未来時刻の雨量には、実績雨量を当てはめ、予測誤差を考えないものとした。

入力層の貯留量変化の推定値を求めるためには、流域末端における流出量が必要である。ネットワークの学習時には、実績流量データを用いて貯留量変化を求めることが可能である。一方で、予測時には未来時刻の流量が必要となるため、何らかの予測流量を用いる必要がある。本検討では、物理型モデル（分布型+粒子フィルタ）による流出計算結果を用いるものとした。

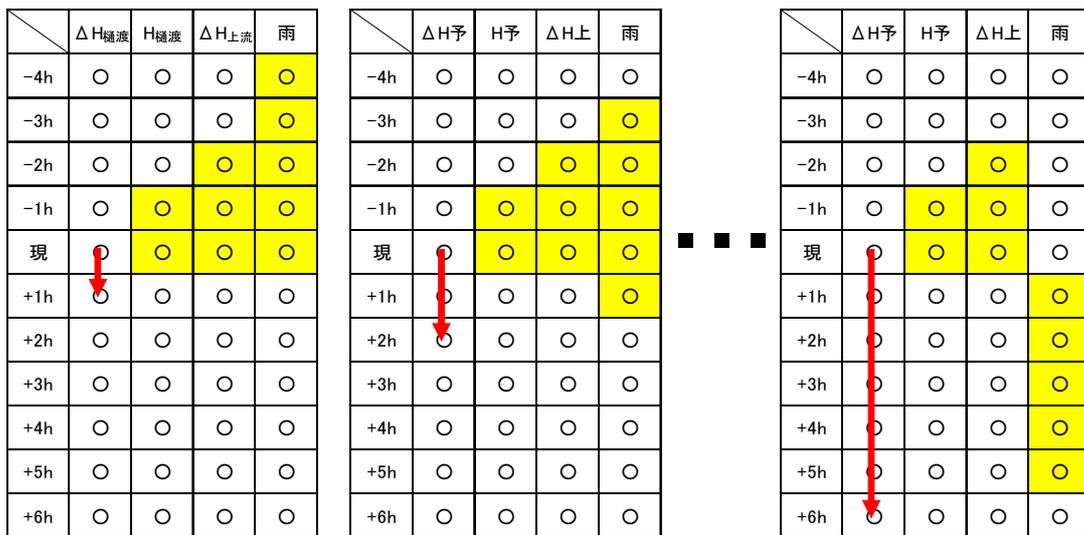


図 6-7 出力層の設定時間の概念

6.3. ハイブリッドモデルの計算実施

6.3.1. 計算条件の設定

入出力層の組合せは表 6-1の通りとした。貯留量変化の推定値は、観測時間雨量から樋渡の流出高を引いた値とし、各雨量観測所について値を作成した。学習に使用したデータの期間や、ネットワーク構造などは第 3 章の検討に倣うものとし、表 6-2の通り設定した。

表 6-1 t 時間予測の入出力層の組合せ

入力			出力
種別	地点	時刻	
時刻水位	樋渡	-1,0	樋渡の水位変化
一時間の 水位変化	流域内 5 地点	-2,-1,0	
貯留量変化 の推定値	流域内 14 地点	t-5,t-4,t-3,t-2,t-1	

表 6-2 学習の各種設定

種別	設定内容
学習データ期間	1990～2014 の上位 24 洪水
学習データ種類	樋渡水位、上流水位変化、時間雨量
データセット数	2904
バッチサイズ	100
予測時間	1 時間～6 時間
モーメンタム	0.5
学習率	初期値 0.1 として AdaGrad で自動設定
デノイジングの 加算ノイズ	平均 0、分散 3%の正規乱数

6.3.2. ケーススタディの実施

ドロップアウト率(p)、学習回数、各層の素子数について表 6-3の通りケースを設定し、各ケースについて自己符号化器にデノイズングの設定あり・無しの場合を計算した。

ケーススタディの結果について、1~6 時間予測の平均 RMSE をケースごとに整理したものを図 6-8に示す。図中のケース番号は、便宜的に表 6-3の番号に対応するものとし、10 の位が学習回数、1 の位が各層の素子数を表わしている。比較の結果、ケース 44 (学習回数 10000、各層の素子数が 87-60-30-1、ドロップアウト率=0.1、自己符号化器にデノイズングの設定なし) が最も精度が高い結果となった。

表 6-3 学習の各種設定に関するスタディケース

ケース番号	学習回数	各層の素子数	ドロップアウト率(p)
1	300	87-10-5-1	0.1
2	1000	87-20-10-1	0.3
3	3000	87-40-20-1	0.5
4	10000	87-60-30-1	

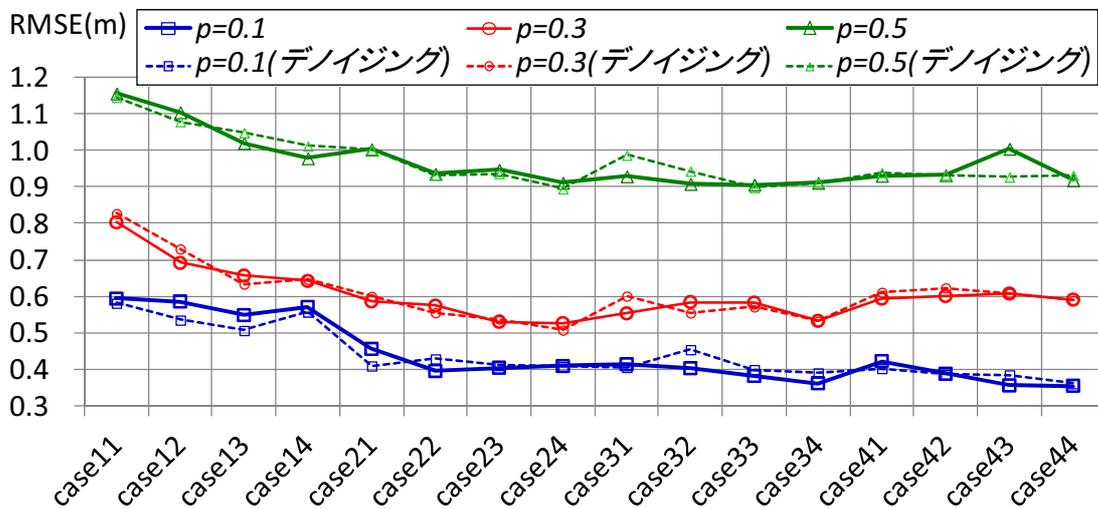


図 6-8 4 洪水平均、1~6 時間予測の平均 RMSE

6.4. ハイブリッドモデルと深層学習モデルの比較

前節まで最も精度の高かったケースについて、重み係数の初期値をランダムに設定して10回の計算を行い、結果の平均をとったものについて精度検証を行った。図 6-9～図 6-12に、ハイブリッドモデルの結果と、第3章で検討した深層学習モデルの結果とを合わせて示す。また、図 6-13～図 6-16に洪水毎に各手法の1時間～6時間予測のRMSEを示す。図 6-17には、4洪水平均での各手法の1時間～6時間予測のRMSEを示す。

計算の結果は、第3章で検討した通常の深層学習モデルを含め、各種の水位予測モデルを上回る精度となった。特に第3章で課題となっていた期間最大の洪水（2005年洪水）において精度が向上した。他の3洪水についても、通常の深層学習モデルと同程度以上の精度であった。

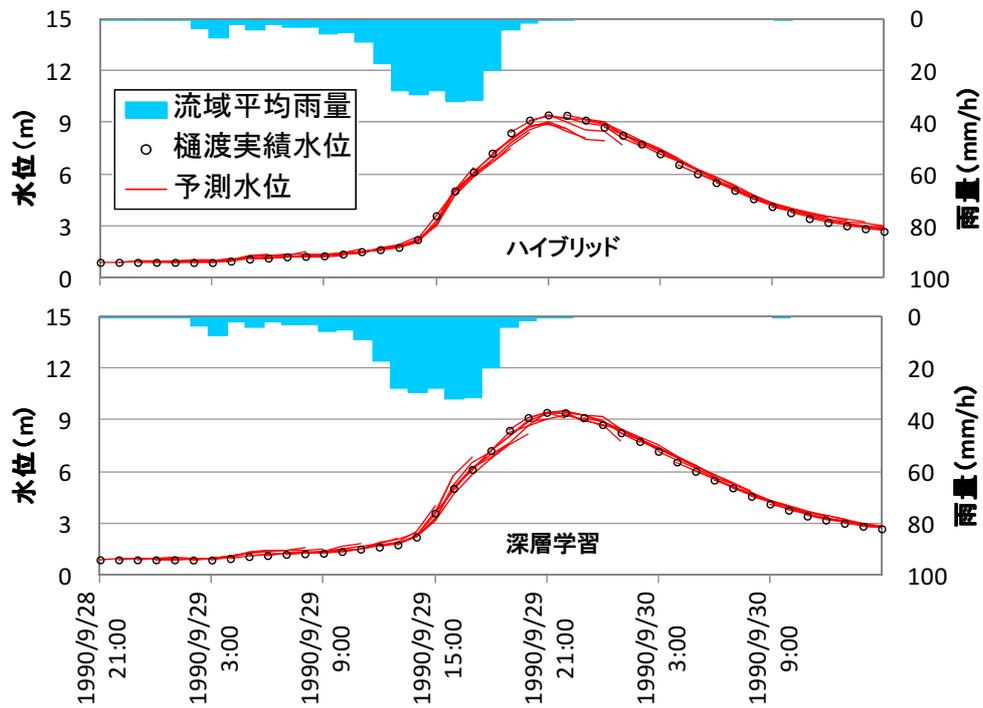


図 6-9 ハイブリッドモデルと深層学習との比較（1990 年洪水、樋渡）

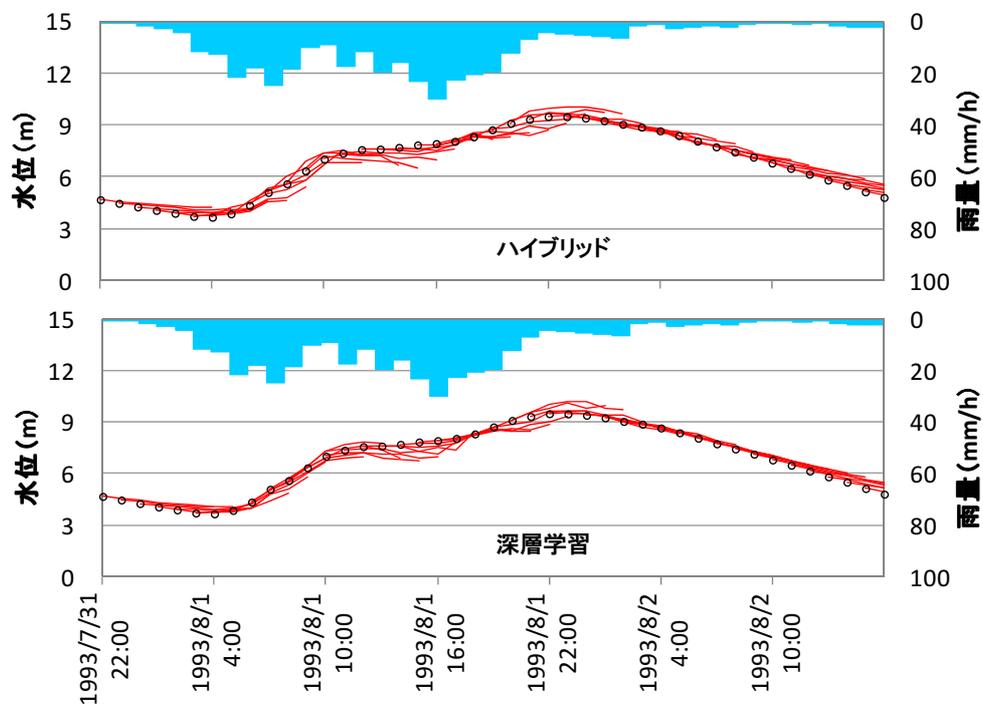


図 6-10 ハイブリッドモデルと深層学習との比較（1993 年洪水、樋渡）

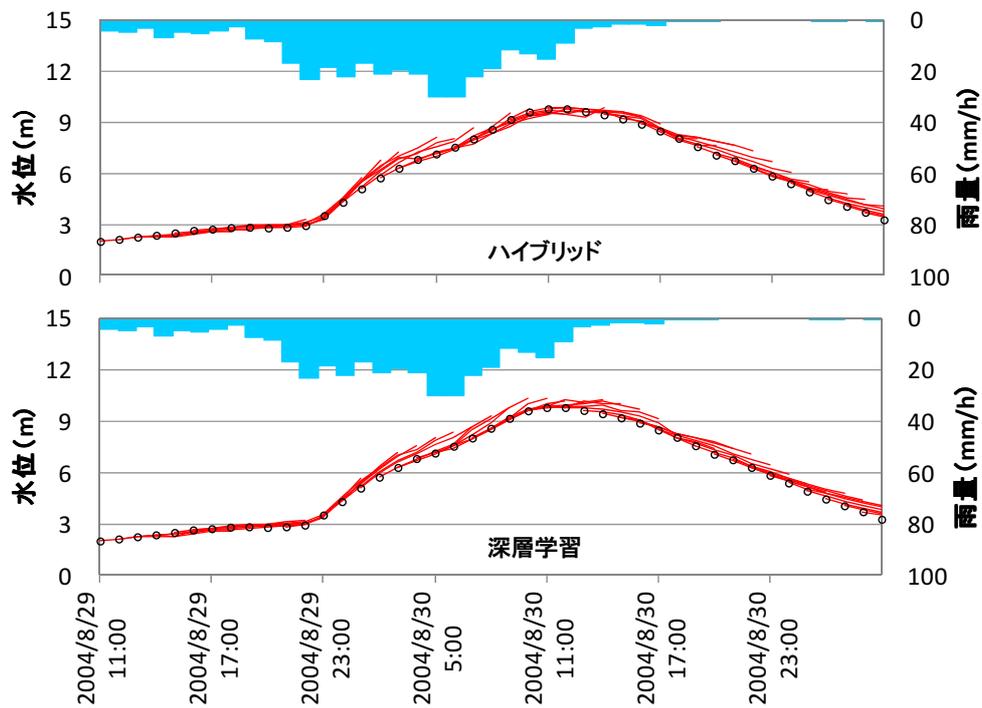


図 6-11 ハイブリッドモデルと深層学習との比較（2004年洪水、樋渡）

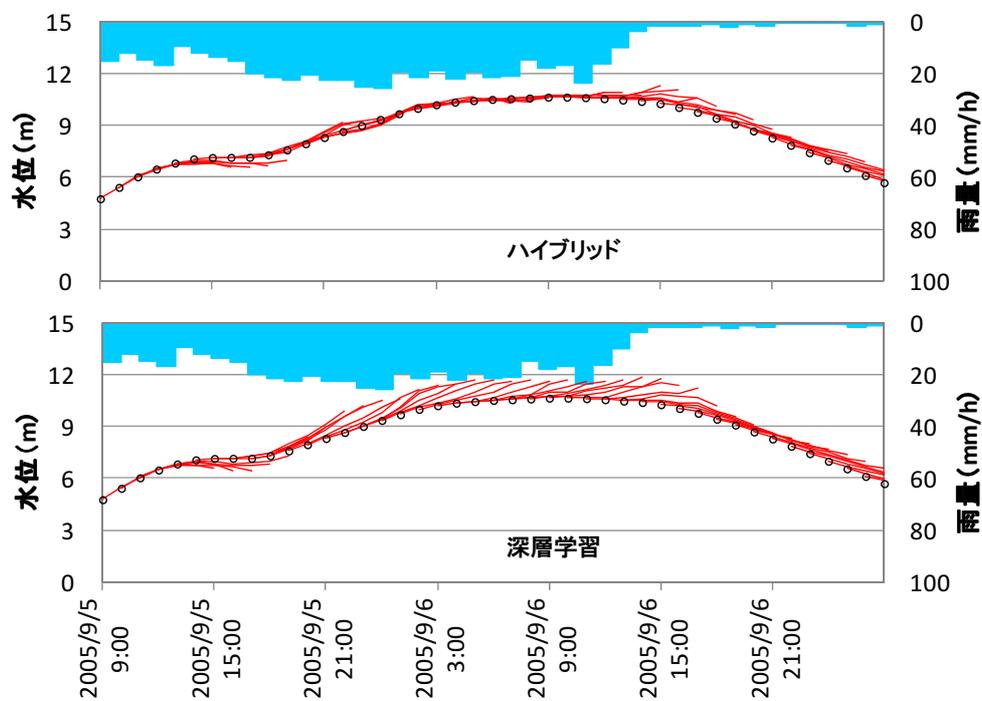


図 6-12 ハイブリッドモデルと深層学習との比較（2005年洪水、樋渡）

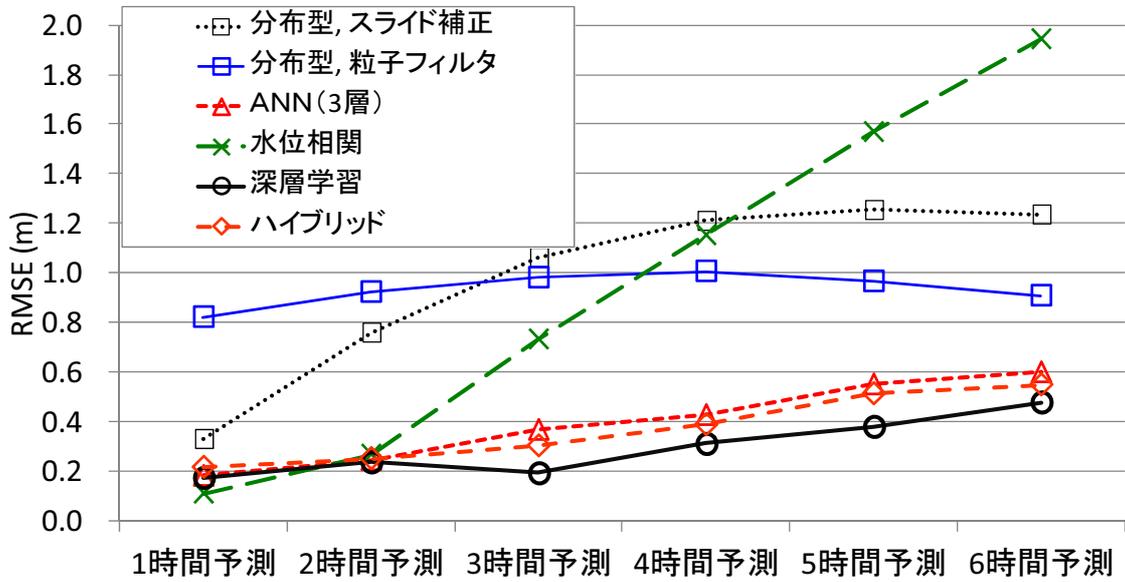


図 6-13 各手法とハイブリッドモデルとの RMSE 比較 (1900 年洪水、樋渡)

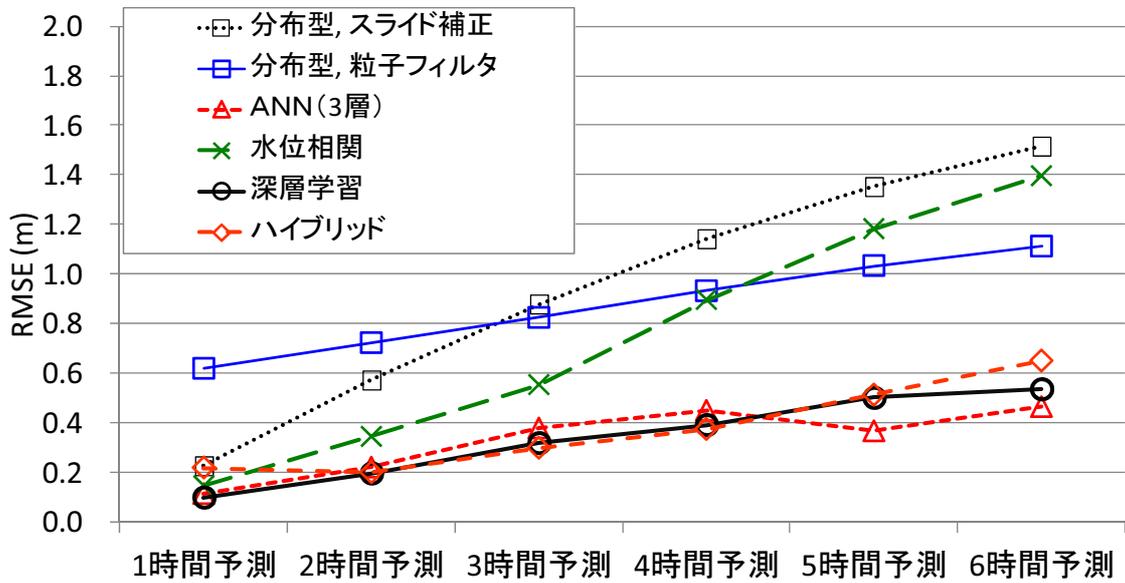


図 6-14 各手法とハイブリッドモデルとの RMSE 比較 (1993 年洪水、樋渡)

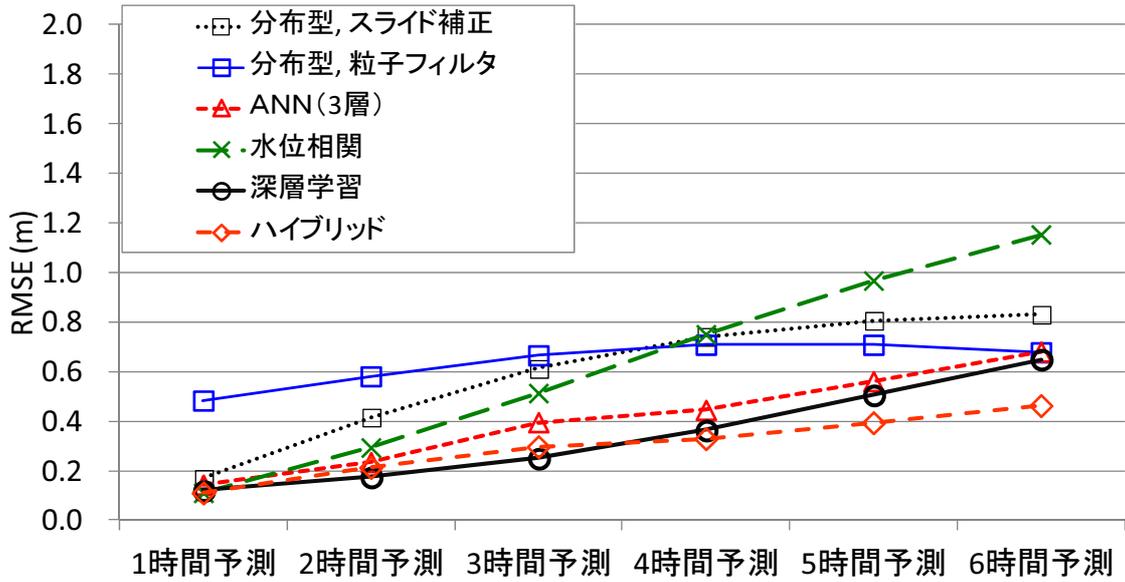


図 6-15 各手法とハイブリッドモデルとの RMSE 比較 (2004 年洪水、樋渡)

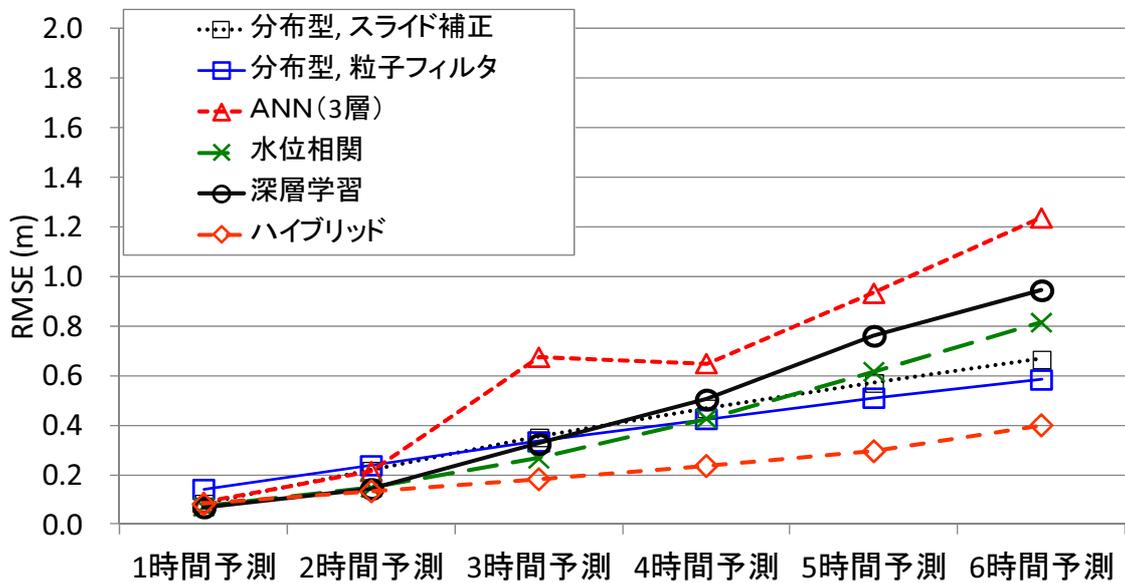


図 6-16 各手法とハイブリッドモデルとの RMSE 比較 (2005 年洪水、樋渡)

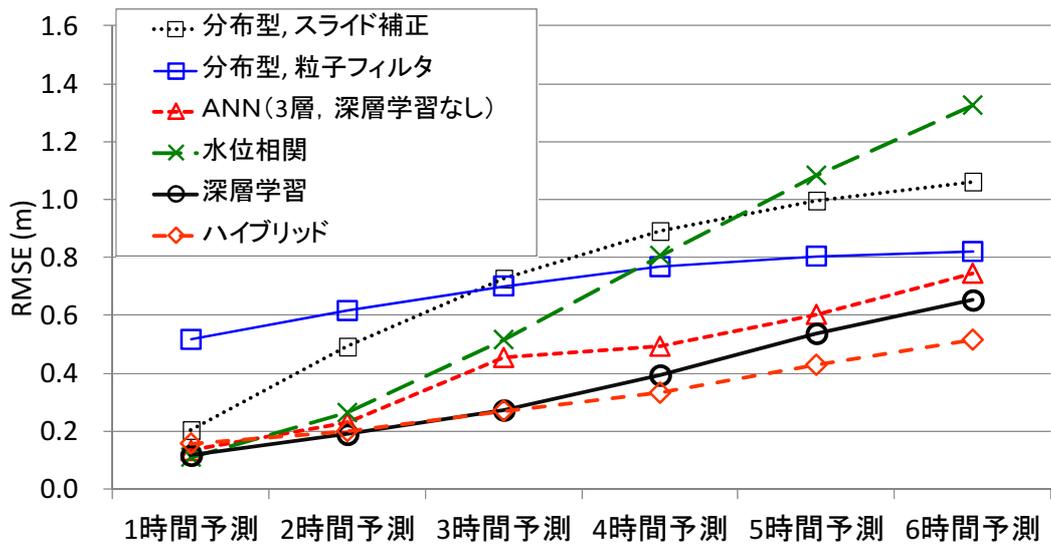


図 6-17 各手法とハイブリッドモデルとの RMSE 比較 (4 洪水平均、樋渡)

6.5. ハイブリッドモデルの計算結果の考察

図 6-18～図 6-21に、ハイブリッドモデルと深層学習モデルとの入出力応答の比較を示す。各図の上はハイブリッドモデルの計算結果および入力データ（貯留量変化； $r_e(t-T_L)-q$ ）を示したものであり、下は深層学習モデルの計算結果および入力データ（雨量）を示したものである。

図 6-21をみると、2005年洪水のピーク付近は、降雨量は大きいものの、貯留量変化は小さいことを確認した。またこの時、降雨量を入力とした学習モデルでは予測が過大となり、貯留量変化を入力値としたハイブリッドモデルでは予測は実績と整合的であった。その他の3洪水（図 6-18、図 6-19、図 6-20）については、降雨量と貯留量変化に大きな違いはなく、水位予測の結果にも大きな違いは無い。

こうしたモデルの挙動の違いは、降雨－流出挙動の直感的な理解とも一致する。

以上より、深層学習と物理的手法とを組み合わせたハイブリッドモデルの適用性が確認された。他河川の様々な洪水に対する適用性は今後の検討事項である。

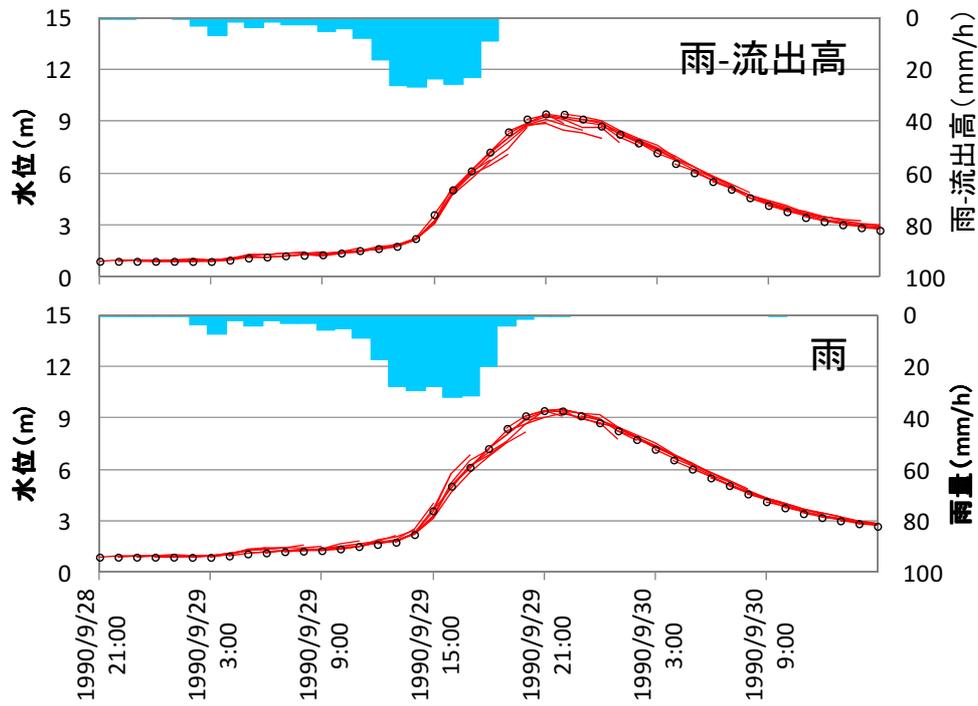


図 6-18 ハイブリッドと深層学習における入出力応答の比較（1990年洪水、樋渡）

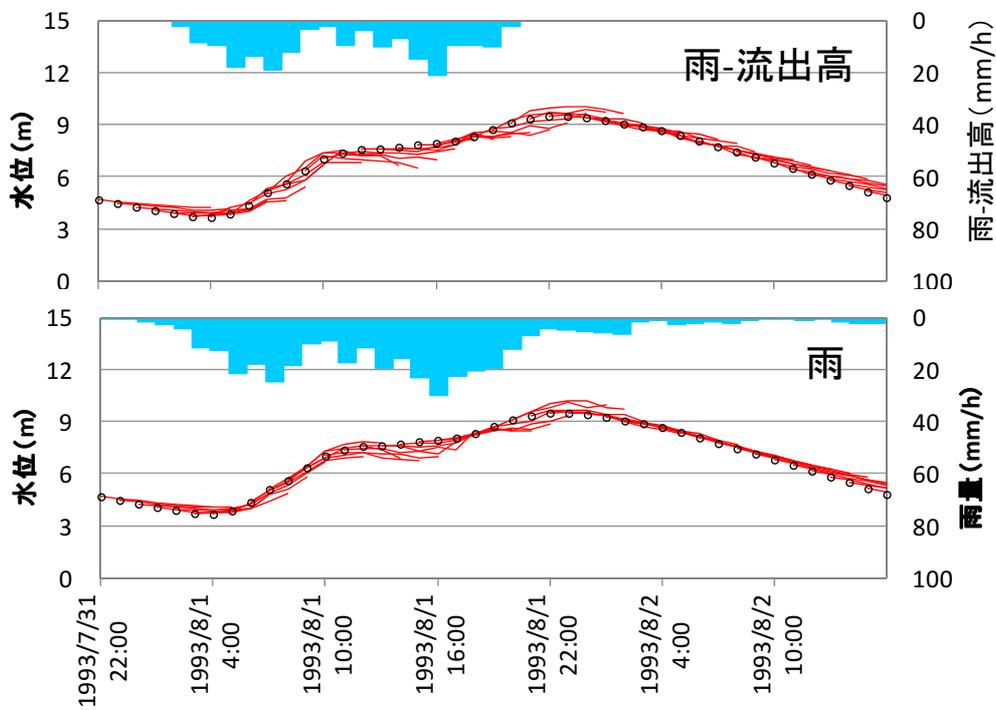


図 6-19 ハイブリッドと深層学習における入出力応答の比較（1993年洪水、樋渡）

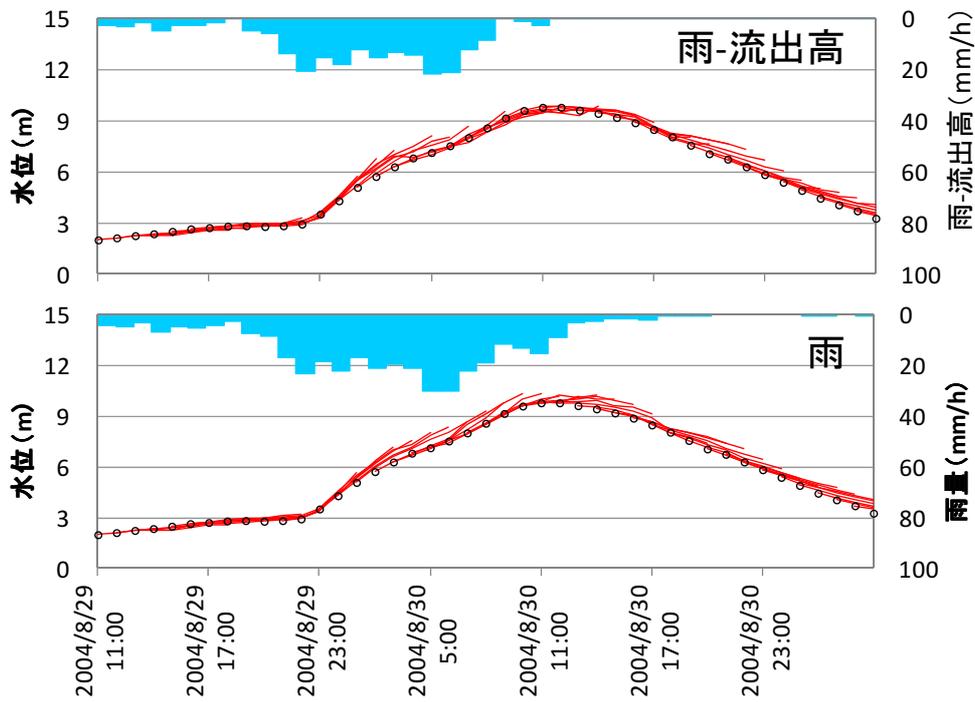


図 6-20 ハイブリッドと深層学習における入出力応答の比較 (2004 年洪水、樋渡)

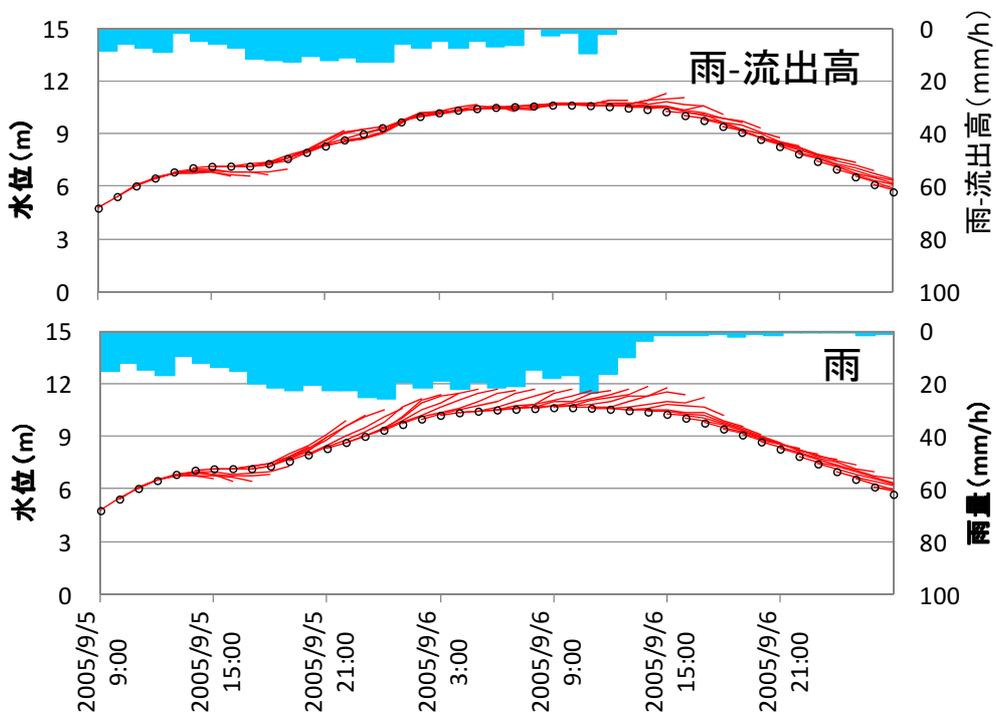


図 6-21 ハイブリッドと深層学習における入出力応答の比較 (2005 年洪水、樋渡)

7. 結論

本論文の結論は次のようにまとめられる。

(1) 従来型ニューラルネットワークによる河川水位予測の精度向上

従来型 ANN (3 層) について、①適切な入力層の選定、②適切な学習回数・中間素子数の設定、③アンサンブル学習、による精度向上を事例検討により確認した。

- ① 入力層とする上流の水位・雨量観測所の選定において、予測地点水位変化との相関分析により妥当な地点を抽出できることを確認した。
- ② 学習回数・中間素子数の設定において、両者を組み合わせたケーススタディにより検証データの誤差評価を行うことで、過学習を避け最適な設定ができることを確認した。
- ③ 学習データを変化させた複数のモデルによりアンサンブル学習を行うことで、元のモデルを上回る精度となることを確認した。

以上 3 点より、従来型の ANN (3 層) の性能を十分に引き出す知見を整理し、水位予測の精度向上につながる成果が得られた。

(2) 深層学習を適用したニューラルネットワーク水位予測モデルの開発

ANN に深層学習を適用した河川水位予測手法の開発を行い、大淀川流域および遠賀川流域の 2 つの実河川における適用性の確認を行った。提案手法の結果は、従来型の ANN (3 層) と比較して高い精度を示し、今後の活用に向けた有効性が示唆される結果となった。従来型の ANN (4 層) は、深層学習や ANN (3 層) よりも精度が落ちることを確認し、深層学習の技法による精度向上の効果が裏付けられる結果を得た。

課題として、大淀川のケーススタディにおいて、期間最大洪水のピーク水位付近で精度低下が見られた。ANN を始めとする統計モデルによる予測では、学習経験のない (高水位の) 事象に対する適用性が不明とされており、高水位の予測精度向上が重要な課題として抽出された。これに対しては、本研究の第 6 章「深層学習と物理的手法のハイブリッド水位予測の開発」で対応を図った。

その他の今後の課題として、①複数の河川におけるケーススタディを行い手法の適用性を確認すること、②リアルタイム予測システムへの適用を前提に、予測雨量の誤差による影響を把握すること、③入力データを含め、学習モデルに関する様々な計算設定条件・パラメータ等についての知見を蓄積すること、等が挙げられる。

(3) 物理的手法の適用と、粒子フィルタによる同化手法

地下水流動および表層の水理をともに表現するため、飽和・不飽和過程を組み込んだ分布型流出解析モデルを開発した。リアルタイム観測データのデータ同化手法として、モデルに状態量補正を行う粒子フィルタを適用した。

大淀川流域の過去の主要洪水に対して、粒子フィルタを組み込んだ分布型流出解析モデルを適用し、予測精度の検証を行った。また分布型流出解析の結果に簡易なスライド補正を行った予測結果との比較を行い、特に長い予測時間に対しての粒子フィルタによる精度向上を確認した。

(4) 各種水位予測モデルの比較検討

本研究では、複数の水位予測モデル（深層学習、ANN（3層）、水位相関、分布型モデル＋スライド補正、分布型モデル＋粒子フィルタ）の予測精度比較を行った。

深層学習による水位予測結果は、他の4手法に比べて各予測時間で高い再現性を示した。

物理型モデルと統計モデルの比較では、短い予測時間では統計モデルがはっきりと優位であり、長い予測時間では深層学習・ANN（3層）が優位であるものの、物理型モデルとの差は小さくなった。

今後、洪水予測の精度向上を図る上では、上記のようなモデルごとの予測精度の特性を踏まえ、予測時間や精度の目標に応じて適切なモデルを用いることが重要であると考えられる。ただし、予測時間ごとのモデルの特性は、流域の規模や流出特性、上流観測情報の量や質、さらには予測降雨や予測モデルの構造によっても異なるものと考えられるため、今後さまざまな流域で検討を積み重ねることが有益である。

(5) 深層学習と物理的手法のハイブリッド水位予測手法の開発

第3章で構築した深層学習モデルでは、期間最大洪水のピーク水位付近で精度低下が課題として挙げられた。この課題への対応として、本研究では深層学習をベースとして物理型モデルとの組み合わせによるハイブリッドモデルを構築した。ハイブリッドモデルの入力層には、降雨の代わりに貯留量変化（降雨量－流出高）を用いるものとした。

実流域に適用した結果、第3章で課題となっていた高水時の予測精度が改善された。また貯留量変化と水位変化との相関について、相関分析やハイドログラフの確認により定量的・定性的に確認し、ハイブリッドモデルの挙動が降雨－流出挙動の直感的な理解とも一致することを確認した。

以上より、深層学習と物理的手法とを組み合わせたハイブリッドモデルの適用性が確認された。他河川の様々な洪水に対する適用性は今後の検討事項である。

謝辞

本研究を進めるにあたって、東京大学大学院工学系研究科システム創成学専攻の登坂博行教授には、特に熱心にご指導いただきました。著者が東京大学工学部および工学系研究科に在籍していた頃から、就職して社会人となった後にも、折に触れて研究のご指導をいただきました。本論文を取りまとめることができたのは、先生の根気強いご指導のお陰です。深く感謝申し上げます。

同専攻の大橋弘忠教授、白山晋准教授、新領域創成科学研究科環境システム学専攻の井原智彦准教授、社会基盤学専攻の知花武佳准教授、首都大学東京大学院都市環境科学研究科の河村明教授には、審査員として有益なコメントをいただきました。深く感謝申し上げます。

電気通信大学社会知能情報学専攻の清雄一助教には、ニューラルネットワークの技法について、大変親切にご教示いただきました。深く感謝申し上げます。

学位取得に向けた活動に際し、日本工営株式会社中央研究所の田中弘前所長、小野寺勝所長、同総合技術開発部の中村茂部長、櫻庭雅明課長を始めとする上司の皆様には様々なご配慮をいただきました。深く感謝申し上げます。

特に櫻庭課長からは、本研究の基礎となった数値計算技術や洪水予測技術全般について、入社以来一貫して熱心にご指導いただきました。また本研究の具体的な進め方や、論文の作成方針についても折に触れご助言いただきました。深く感謝申し上げます。

論文作成中に業務が重なった社内の皆様には、ご迷惑をおかけしたにも関わらず寛大な気持ちで応援いただきました。深く感謝申し上げます。

日本工営株式会社の同僚であり、妻である奈緒子には、業務の忙しい合間を縫って家事・育児を負担してもらい、著者が研究に注力できる時間を作ってもらいました。本当にありがとうございました。

最後に、各種の学会やセミナーを通じてお世話になった方々に、深く感謝を申し上げます。

参考文献

- Anctil, F., & Lauzon, N. (2004): Generalisation for neural networks through data sampling and training procedures, with applications to streamflow predictions. *Hydrology and Earth System Sciences Discussions*, 8(5), 940-958.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000a): Artificial neural networks in hydrology. I : Preliminary Concept, *Journal of Hydrologic Engineering*, Vol.5, No.2, pp.115-123.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000b): Artificial neural networks in hydrology. II : Hydrologic Applications, *Journal of Hydrologic Engineering*, Vol.5, No.2, pp.124-137.
- Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H. (2007): Greedy layer-wise training of deep networks, *Advances in Neural Information Processing Systems* 19, pp.153-160.
- Box, G. E. P., and Jenkins, G. M. (1970): *Time Series Analysis Forecasting and Control*, Holden-day.
- Chau, K. W., Wu, C. L., & Li, Y. S. (2005): Comparison of several flood forecasting models in Yangtze River, *Journal of Hydrologic Engineering*.
- Dawson, C. W., Wilby, R. L. (2001): Hydrological modeling using artificial neural networks, *Progress in Physical Geography*, Vol.25, No.1, p80-108.
- DeChant, Caleb M., and Hamid Moradkhani. (2012): Examining the effectiveness and robustness of sequential data assimilation methods for quantification of uncertainty in hydrologic forecasting, *Water Resources Research* 48.4.
- Duchi, J., Hazan, E. and Singer, Y. (2011): Adaptive subgradient methods for online learning and stochastic optimization, *Journal of machine learning research*, vol.12, pp.2121-2159.
- Evensen, G. (1994): Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics.
- Guingla, P., Douglas, A., Keyser, R., Lannoy, G. J., Giustarini, L., Matgen, P., & Pauwels, V. (2013): Improving particle filters in rainfall - runoff models: Application of the resample - move step and the ensemble Gaussian particle filter. *Water Resources Research*, 49(7), 4005-4021.
- Hino, M. (1970): Runoff forecasts by linear predictive filter. *Journal of the Hydraulics Division*.
- Hinton, G.E., Osindero, S. and Teh ,Y. (2006): A fast learning algorithm for deep

- belief nets, *Neural Computation*, vol.18, pp.1527-1544.
- Jazwinski, Andrew H (1970): *Stochastic processes and filtering theory*. Courier Corporation.
- Kalman, R. E. (1960): A new approach to linear filtering and prediction problems, *Journal of Fluids Engineering*, 82(1), pp.35-45.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012): Imagenet classification with deep convolutional neural networks, In *Advances in neural information processing systems*, pp. 1097-1105.
- Liu, Y., & Gupta, H. V. (2007): Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework, *Water Resources Research*, 43(7).
- Liu, Y., Weerts, A. H., Clark, M., Hendricks Franssen, H. J., Kumar, S., Moradkhani, H., ... & Restrepo, P. (2012). Advancing data assimilation in operational hydrologic forecasting: progresses, challenges, and emerging opportunities (2012): *Hydrology and Earth System Sciences*, 16 (10).
- Maier, H.R. and Dandy, G.C. (2000): Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling & Software*, Vol.15, 2000.
- Maier, H.R., Jain, A., Dandy, G.C. and Sudheer, K.P. (2010): Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions, *Environmental Modelling & Software*, Vol.25.
- Moradkhani, H., Sorooshian, S., Gupta, H. V., & Houser, P. R. (2005a): Dual state-parameter estimation of hydrological models using ensemble Kalman filter, *Advances in Water Resources*, 28(2), 135-147.
- Moradkhani, H., Hsu, K. L., Gupta, H., & Sorooshian, S. (2005b): Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter, *Water Resources Research*, 41(5).
- Morita, M., & Chie Yen, B. (2000): Numerical methods for conjunctive two - dimensional surface and three - dimensional sub - surface flows. *International Journal for Numerical Methods in Fluids*, 32(8), 921-957.
- Noh, S., Tachikawa, Y., Shiiba, M., & Kim, S. (2011): Applying sequential Monte Carlo methods into a distributed hydrologic model: lagged particle filtering approach with regularization, *Hydrology and Earth System Sciences*, 15(10), pp.3237-3251.
- Noh, S. J., Tachikawa, Y., Shiiba, M., & Kim, S. (2012): Ensemble kalman filtering and particle filtering in a lag-time window for short-term streamflow

- forecasting with a distributed hydrologic model, *Journal of Hydrologic Engineering*, 18(12), pp.1684-1696.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986): Learning representations by back-propagating errors. *Nature*, 323, 533-536.
- Smith, P. J., Keith J. Beven, and Jonathan A. Tawn. (2008): Detection of structural inadequacy in process - based hydrological models: A particle - filtering approach, *Water resources research* 44.1.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. (2014): Dropout: A simple way to prevent neural networks from overfitting, *Journal of machine learning research*, vol15, pp1929-1958.
- van Genuchten M.T. (1980): A closed-form equation for predicting the hydraulic conductivity of unsaturated soils, *Soil Science Society of America Journal*, vol.44(5), pp.892-898.
- Seide, Frank, Gang Li, and Dong Yu(2011): Conversational Speech Transcription Using Context-Dependent Deep Neural Networks, *Interspeech*.
- Therrien, R., McLaren, R. G., Sudicky, E. A., & Panday, S. M. (2010): HydroGeoSphere: A three-dimensional numerical model describing fully-integrated subsurface and surface flow and solute transport. Groundwater Simulations Group, University of Waterloo, Waterloo, ON.
- The R Project for Statistical Computing,<http://www.r-project.org/>
- Tosaka, H., Itoh, K., & Furuno, T. (2000): Fully coupled formulation of surface flow with 2 - phase subsurface flow for hydrological simulation. *Hydrological processes*, 14(3), 449-464.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio Y. and Manzagol, P. A. (2010): Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion, *Journal of Machine Learning Research*, vol.11, pp.3371-3408.
- Weerts, A. H., & El Serafy, G. Y. (2006): Particle filtering and ensemble Kalman filtering for state updating with hydrological conceptual rainfall - runoff models, *Water Resources Research*, 42(9).
- Wood, E. F., & Szöllösi - Nagy, A. (1978). An adaptive algorithm for analyzing short - term structural and parameter changes in hydrologic prediction models. *Water Resources Research*, 14(4), pp.577-581.
- Wood, E. F., & Szöllösi-Nagy, A. (1980): Real-time forecasting/control of water resource systems. Pergamon Press.

- 天野卓三, 三輪準二, 水草浩一, 金木誠 (2003): 中小河川における各種洪水予測モデルの適用性に関する研究, 河川技術論文集, Vol.9, pp.61-66.
- 磯部勇, 大河戸輝夫, 羽生田英彦, 小田誠一, 後藤祐輔 (1994): ニューラルネットワークによる水位予測システムの開発, 水文・水資源学会誌, Vol.7(2), pp.90-97.
- 稲吉明男, 長江幸平, 田宮睦雄, 宮田達磨, 眞間修一, 竹村仁志 (2003): 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研究, 河川技術論文集, Vol.9, pp.179-184.
- 雨水貯留浸透技術協会 (2000): 都市域における水循環系の定量化手法・水循環系の再生に向けて.
- 岡谷貴之 (2015): 深層学習, 講談社サイエンティフィック.
- 木村俊晃 (1962): 貯留関数法(II)~(IV-2), 土木技術資料, 4(1,4,5,6,7).
- 九州地方整備局, 宮崎県, 鹿児島県 (2006): 大淀川水系河川整備計画.
- 金明哲 (2007): R によるデータサイエンス, 森北出版株式会社.
- 工藤亮治, 近森秀高, 永井明博 (2011): 粒子フィルタを用いた実時間洪水予測システムの構築と河道任意地点における予測精度の検証, 水文・水資源学会誌, Vol. 24, No. 3, pp.137-148.
- 熊沢逸夫 (1998): 学習とニューラルネットワーク, 森北出版株式会社.
- 国土交通省 (2007): 洪水予報の発表基準となる河川水位及び危険度レベル, www.ktr.mlit.go.jp/ktr_content/content/000019847.pdf (最終閲覧日: 2016年2月14日)
- 国土交通省 (2015a): 平成26年度国土交通省白書.
- 国土交通省 (2015b): 『平成27年9月 関東・東北豪雨』に係る洪水被害及び復旧状況等について
- 菅原正巳 (1972): 流出解析法, 共立出版.
- 鈴木俊明, 寺川陽, 松浦達郎 (1996): 実時間洪水予測のための分布型モデルの開発, 土木技術資料, Vol.38-10, pp.26-31.
- 高棹琢馬, 椎葉充晴, 富澤直樹 (1984): 統計的二次近似理論を適用した流出予測システムの構成, 京都大学防災研究所年報 (B-2), pp.255-273.
- 高崎忠勝, 河村明, 天口英雄 (2011): ニューラルネットワークによる都市中小河川感潮域の水位推定, 水工学論文集, Vol.55, pp.1603-1608.
- 高崎忠勝, 河村明, 天口英雄, 石原成幸 (2012): 粒子フィルタを用いた都市貯留関数モデルによる実時間洪水流出予測特性. 土木学会論文集 B1(水工学), Vol.68(4), pp.511-516.
- 竹内則雄, 檜山和男, 寺田賢二郎 (2003): 計算力学 有限要素法の基礎, 森北出版.
- 竹村仁志, 眞間修一, 吉田武司, 石上尚 (2013): 中流域に洪水調整ダムを有する河川における洪水予測システムの精度検証, 河川技術論文集, Vol.19, pp.247-252.

- 立川康人, 永谷言, 寶馨 (2004) : 飽和・不飽和流れの機構を導入した流量流積関係式の開発, 水工学論文集, Vol.48, pp.7-12.
- 立川康人, 須藤純一, 椎葉充晴, 萬和明, キム スンミン (2011) : 粒子フィルタを用いた河川水位の実時間予測手法の開発, 水工学論文集, Vol.55, pp.511-516.
- 田中耕司, 杉浦正之 (2012) : 歴史的風致地区の浸水被害軽減を支援する洪水予測システムの精度向上, 歴史都市防災論文集, Vol.6, pp.111-118.
- 田中耕司, 辻倉裕喜, 大八木豊, 杉浦正之 (2013) : 予測雨量誤差を考慮した洪水予測システム開発. 土木学会論文集 B1 (水工学), Vol.69(4), pp.1591-1596.
- 槻山敏昭, 外山久典, 笹原和彦, 眞間修一, 関基, 竹村仁志 (2003) : 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検討, 河川技術論文集, Vol.9, pp.173-178.
- 椿涼太, 小林健一郎, 内藤正彦, 谷口丞 (2013) : 洪水予測技術の現状と課題について, 河川技術論文集, Vol.19, pp.1-6.
- 春原常男, 内海博, 井上勝矢, 眞間修一, 吉田武司, 竹村仁志 (2006) : ニューラルネットワークモデルによるダム諸量予測と相模川洪水予測システムの検討, 河川技術論文集, Vol.12, pp.229-234.
- 樋口知之, 上野玄太, 中野慎也, 中村和幸 (2011), 吉田亮 : データ同化入門, 株式会社朝倉書店
- 一言正之, 服部洋佑, 梶正範, 小野寺勝, 桜庭雅明 (2012) : 斐伊川を対象としたニューラルネットワーク洪水予測の精度向上に関する研究, 河川技術論文集, Vol.18, pp.441-446.
- 一言正之, 荒木健, 中川和男 (2014) : 未経験の洪水に対するニューラルネットワーク洪水予測の精度向上に関する研究, 河川技術論文集, Vol.20.
- 一言正之, 桜庭雅明, 坂本俊二 (2015) : 流域内のリアルタイム観測情報を用いた洪水予測の不確実性低減方法の比較, 河川技術論文集, Vol.21, pp.431-436.
- 日野幹雄 (1974) : 水文流出系予測へのカルマン・フィルター理論の適用. 土木学会論文報告集, 1974(221), pp.39-47.
- 日野幹雄, 長谷部正彦 (1985) : 水文流出解析, 森北出版株式会社.