

SOINN(自己増殖型ニューラルネットワーク)を活用した ダム流入量予測に関する研究

天 梁 田
方 田 代
匡 信 克
純^{*}
河^{**}
浩^{***}

概 要 出水時のダム管理事務所では、数時間先のダム貯水池への流入量を予想し、ダム下流河川に急激な水位上昇を引き起こさないよう、ゲート放流の開始時刻や放流量を判断する。これらの作業を支援する簡易的なダム流入量予測モデルが導入されているが、予測精度の関係上、最終的なゲート操作は操作員の経験的な判断に依るところが大きい。そこで、出水時のダム操作支援を目的に、自己増殖型ニューラルネットワーク(SOINN: Self-Organizing Incremental Neural Network)を活用し、ダム上流域の水位や雨量からダム流入量を予測する手法を検討した。

キーワード：ダム流入量予測，SOINN，降水短時間予報，ゲート操作

1. はじめに

本論文にて検討対象とする道志ダム上流域は、図-1に示す通り、神奈川県相模川水系道志川に位置し、流域面積が112.5 km²であり、上流域流量が流入量として道志ダムに到達するまでの時間は概ね60~90分程度である。

道志ダムの目的は発電のみであり、操作規程に従い、常時満水位を超えないよう貯水位を維持する操作が求められており、水利権上の最大取水量である発電使用水量11.4 m³/s(宮ヶ瀬ダムへの道志導水路による導水がない場合)を上回る流入が継続すると予測される場合、ゲート放流を行う必要がある。ただし、道志ダムへの移動時間や放流連絡に要する時間、休祝祭日における職員の参集時間等の放流までのリードタイムの確保が必要である。

一方、過去30年間のダム流入量を整理すると図-2のとおり、近年の気候の変化等により最大流入量及び1時間当たりの流入量増加量が増加傾向を示しており、堆砂対策等の必要な措置を講じると共に、安全なダム管理と効率的な水運用を進めていくための精度の高いダム流入量予測システムの構築が不可欠である。

2. ダム流入量予測モデルの枠組み

ダム流入量予測モデルはダム流域特有のものであり、下流域の洪水予報河川等では洪水予報モデルが河川水位を予測している。この

洪水予報モデルは、国土交通省及び都道府県等で運用されており、雨量を入力条件とし、流量を算定する流出解析モデルや流量を水位に変換する河道モデルから構成される。ダム流入量予測モデル、あるいは、洪水予報モデル、いずれも、既往洪水に対してモデルを検証した上でモデル変数を最適化し、確定モデルとする検討過程を経るが、各過程やモデルには入力条件、モデル条件等の不確定性を数多く抱え、リアルタイムでのダム流入量・水位再現も難しい現実がある。この不確定性に対応するためにダム流入量等を対象とした研究として、古くは単位図、貯留関数、タンクモデル等にカルマンフィルターを適用した事例^{1),2)}、近年では分布型流出モデルにカルマンフィルターを適用した事例³⁾等がある。しかし、カルマンフィルター

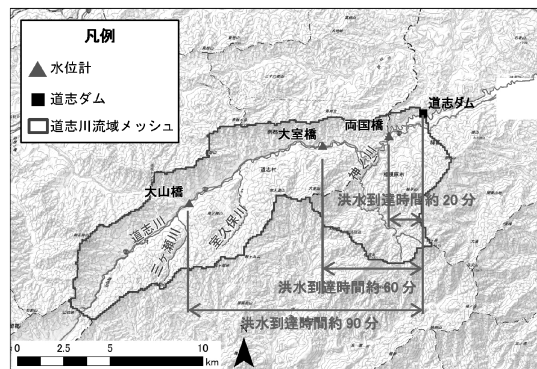


図-1 本研究の対象流域概要(相模川水系道志川)



天方 匡純

梁田 信河

田代 克浩


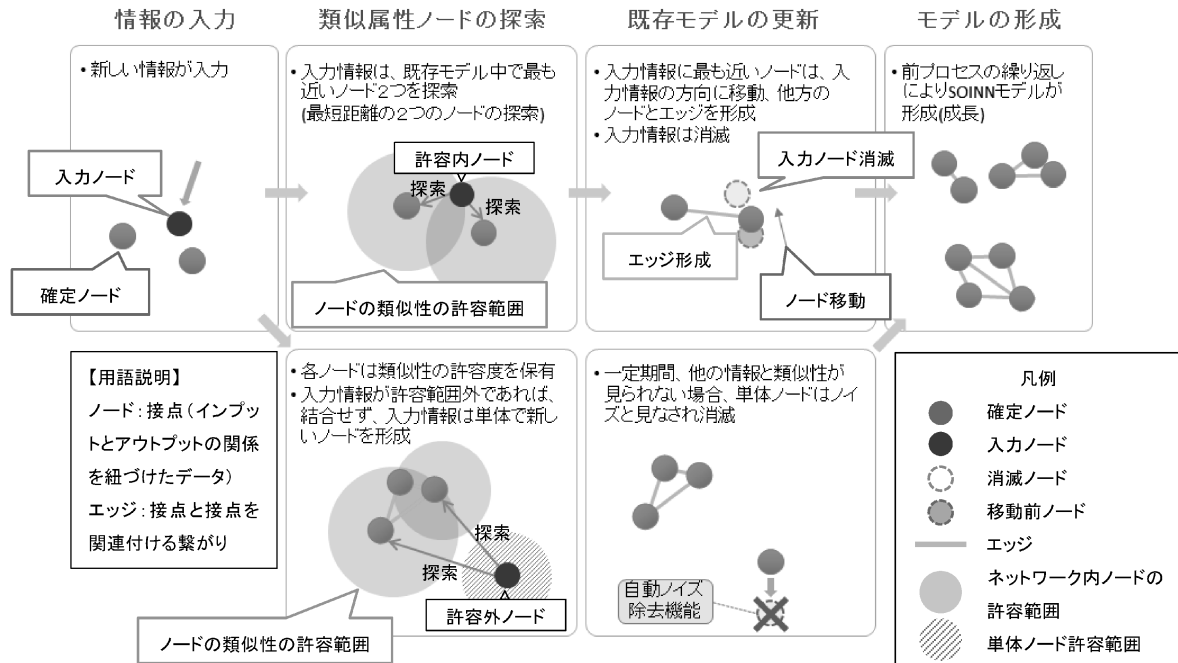


図-2 近年の出水傾向(左：流入量，右：流入量増加量)

* 八千代エンジニアリング(株) 技術推進本部技術開発部 専門部長 amakata@yachiyo-eng.co.jp
 ** 八千代エンジニアリング(株) 東北支店 取締役 支店長 会員 yanada@yachiyo-eng.co.jp
 *** SOINN(株) Senior Engineer kt@soinn.com



図—3 SOINN のアルゴリズム

ターは過去の観測値からモデル変数を最適化するため、急激に雨量とダム流入量等の関係が変化する際に予測精度が悪くなる等の問題がある。一方で、水文学的プロセスを追跡せず、データ間の繋がりから予測を目指す手法がある。これらは、雨量や上流側水位等の上流域水流量から下流域水流量を推定する方法であり、単相関、重相関、ニューラルネットワークモデルといった手法がダム流入量予測^{4),5)}、洪水予測^{6),7)}で適用されている。これらの手法は、モデル化した入力と出力のデータ関係が変わってしまった場合、予測精度が悪くなる等の問題がある。

本論文では、上流域水流量から下流域水流量を推定する手法の一つとして、自ら入力と出力のデータ関係を調整する自己増殖型ニューラルネットワーク(SOINN)を選択し、その適用過程、適用結果等を示す。


3. SOINN の概要

「SOINN(Self-Organizing Incremental Neural Network: 自己増殖型ニューラルネットワーク)」は、東京工業大学長谷川修研究室が開発した人工知能技術であり、Self-Organizing Map(SOM)とGrowing Neural Gas(GNG)に着想を得て構築した、「教師」となる専門技術者がいなくてもオンラインからの自律的な追加学習が可能な教師なし学習手法の一種である⁸⁾。

SOINN は非定常(動的に形状が変化)かつ複雑な形状を持つデータ分布に対して、ネットワーク(学習モデル)を自己組織的に形成し、適切なクラス数(分類)とデータ分布の位相関係を出力することができる。ニューラルネットワークモデル等に適用する従来の学習手法では専門の技術者が人手を掛けて学習モデルを設計する必要があるが、「SOINN」は事前知識が不要で入力データのみからノイズを自動判別し自分自身で学習モデルを作る。さらに、オンライン(リアルタイム)で逐次学習することにより状況に合わせて学習モデルを自動変化させることが可能である。そのため、ノイズを含むデータが継続的に発生し、データ分布が変化することが多い実世界のデータ(IoTのセンサデータなど)において、複雑な関係性を抽出する処理に有効である。

SOINN のアルゴリズムは、図—3 のように整理できる。例えば、雨量をインプット、流量をアウトプットとする場合、互いに対応付ける情報がノードとなる。ニューラルネットワークとは異なり、雨量と流量の対応特性が類似したノード(図—3 の緑丸)同士で自らネットワークを作り、出水時の流量上昇部のデータネットワーク、流量ピーク付近のデータネットワーク、流量減衰部のデータネットワーク等を形成し、再現・予測精度を高めることが可能となる。類似度の閾値は、エッジで連結されたノード(以下、連結ノード)が存在する場合は、連結ノードのうち最も遠いノードとの距離、連結ノードが存在しない場合は、最近傍ノードとの距離となる。ノード間の距離は動的に変化しうるため、それに伴って類似度閾値も変化する⁸⁾。類似ノードのネットワーク化は、弊社の過去のニューラルネットワークモデルの検討^{6),7)}において、予測精度を向上するため、出水時のハイドロの特性を細分化(図—4 参照)し、特性ごとに学習モデルを変え、統合的に予測モデルを構築する行為と類似している。これらのモデル構築を SOINN が自動的に実施するため、モデル構築労力を省力化でき、生産性が向上する。

一方で、流域条件の変化等に伴う流出特性の変化に対しては、実際の観測データの特性変化から、利用しなくなったネットワークやノードはノイズとして自動的に除去し、流出特性の変化に対応したモデルへと自動的に変化していく。このため、従来システムの場合、一度作ったモデルも流域・河道条件等の変化により利用されなくなることもあったが、SOINN によるシステムの場合、そのようなことを防ぐことができる。



図—4 出水規模・波形に応じた予測モデルの適用⁷⁾

4. SOINN の学習

本章では、道志ダム上流域において、SOINNを活用してダム流入量予測モデルを作成するための利用データ及び手順について示す。

(1) 学習・予測過程の概要

図-5に示す通り、学習出水(52出水)に対してダム流入量を予測するSOINNモデルを作成したのち、未学習出水(3出水)に対して予測結果を確認する。

(2) 入力データ

SOINNを活用してダム流入量予測モデルを作成するため、学習出水を決め、その入力データと出力データを整理した。具体的には、平成17年から平成27年までのゲート放流を伴う出水から、①ダム流入量が90 m³/s以上となった出水(道志ダム操作規程ではダム流入量90 m³/s以上を洪水という)、②最高水位が常時満水位-1.5 m以上の出水、③20 mm/3 hr又は総雨量100 mm以上の出水、の条件にて55出水を抜き出し、そこから平成27年に発生した3出水以外の52出水を学習対象とした。入力データは、利用する雨量(観測所雨量、レーダー・アメダス解析雨量、降水短時間予報)の組み合わせによって3つのパターン(表-3参照)を想定し、利用するデータは、雨量(観測所数9地点)、河川水位(観測所数3地点)、ダム流入量、メッシュ雨量(レーダー・アメダス解析雨量と降水短時間予報(いずれもメッシュ数約100個))のいずれかである。各観測所の配置は図-6のとおりとなる(メッシュ雨量は流域全体に網羅されている)。また、データ所管により配信のタイミングが異なるため、表-1の組み合わせによりダム流入量を予測するものと

した。

(3) 出力データ

学習対象とする出力データはダム流入量とするが、予測精度を高めるため、運用時の最新時刻(以下、現時刻という)に最大限活用できるデータとして、入力データとしても活用した。また、6時間先までのダム流入量予測を行うため、疑似的に6時間先までのダム流入量も学習対象に加えた(表-2参照)。

(4) モデルの構築方法

入力と出力(学習対象)のデータの組み合わせの違いにより、表-3の学習条件の3パターンにてダム流入量予測モデルを構築した。それぞれについて説明を加える。

a. 観測所雨量を用いたモデル構築


表-3の学習条件パターンaに該当するモデル構築である。ここでは、メッシュ雨量を用いず、ポイントデータである観測所雨量及び観測所水位を用い、ダム流入量を予測する。モデルの作成に当たっては、入力に観測所雨量、観測所水位、学習対象にダム流入量に対応させ、学習を進める。なお、ダム流入量は入力側でも利用する。

また、6時間先までのダム流入量を予測するため、学習の際には6時間先までのダム流入量を学習対象とする。未学習出水に対する検証(表-3の運用条件参照)の際は、慣例的に行われる実測雨量を予測雨量に見立てることはせず、現時刻までの入力値のみで6時間先までのダム流入量を予測する。

b. メッシュ雨量を追加で用いたモデル構築

表-3の学習条件パターンbに該当するモデル構築である。雨量は、観測所雨量のポイントデータ、そして、レーダー・アメダス

【学習過程】



【予測過程】




図-5 SOINNの学習・予測過程の概要

表-1 ダム流入量を予測するための入力データの組合せ

データの種類の	INPUT/OUTPUT	INPUT			
	ダム流入量	神奈川県企業庁雨量データ	神奈川県県土整備部雨量データ	山梨県雨量データ	気象庁解析・予測雨量
	15分毎	15分毎	10分毎	10分毎	30分毎
学習・予測のタイミング	毎時00分	00分データ使用	00分データ使用	00分データ使用	00分データ使用
	毎時15分	15分データ使用	10分データ使用	10分データ使用	00分データ使用
	毎時30分	30分データ使用	30分データ使用	30分データ使用	30分データ使用
	毎時45分	45分データ使用	40分データ使用	40分データ使用	30分データ使用

表-2 入力・出力フォーマットの概要

洪水イベントNo	観測所水位	水位差分	観測所雨量	メッシュ雨量	道志ダム流入量		
	大山橋 (m)	大山橋 (m)	熊木 (mm)	0時間 (m ³ /s)	1時間先 (m ³ /s)	6時間先 (m ³ /s)
1	-0.01	1.33	-	0	2.04	2.04	2.78
1	-0.01	1.36	0.0	0	2.06	2.08	3.53
1	-0.01	1.33	0.0	0	2.04	2.04	2.80
...
2
2
...

表-3 モデル構築条件の整理

活用データ	学習条件			運用条件(検証時)		
	パターンa	パターンb	パターンc	パターンa	パターンb	パターンc
観測所雨量	●	●	●	●	●	●
観測所水位	●	●	●	●	●	●
ダム流入量	●	◎	●	●	●	●
レーダー・アメダス解析雨量		●	◎		●	●
降水短時間予報						●注2)

◎: 6時間先まで用意するデータ

注1) パターンcは降水短時間予報の利用を想定し、学習条件はレーダー・アメダス解析雨量を6時間先まで用意

注2) 降水短時間予報は6時間先までの予測雨量

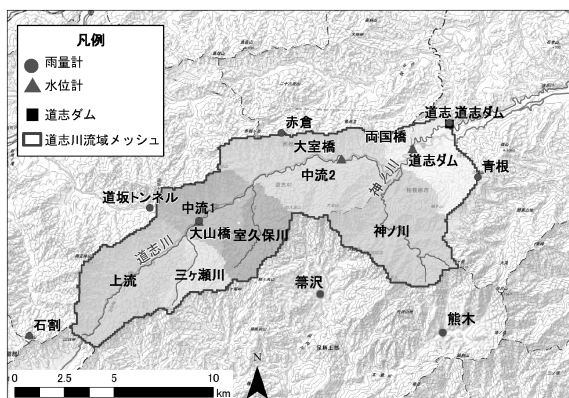


図-6 入力・出力データの整理

解析雨量等のメッシュデータが存在する。レーダー・アメダス解析雨量のメッシュは1km四方であり、道志ダム上流域の場合、100個程度存在する。観測所雨量，レーダー・アメダス解析雨量(1kmメッシュ)，観測所水位を入力データとして，ダム流入量予測モデルを構築する。また，パターンaと同様に，出力側のダム流入量は6時間先までを学習対象とし，入力側は現時刻までのデータセットとする。当該モデルも，未学習出水に対する検証(表-3の運用条件参照)の際は，現時刻までの入力値により6時間先までのダム流入量を予測する。なお，より空間メッシュが細かいXrain⁹⁾(XバンドMPレーダ雨量情報)はデータ蓄積期間が短く，学習対象となる出水数が少なく，モデル特性が偏る過学習となる恐れがあるため，本論文では用いないこととした。

c. 降水短時間予報(予測雨量)を追加で用いたモデル構築

表-3の学習条件パターンcに該当するモデル構築である。降水短時間予報の入力を想定したモデルであり，学習の際には表-3に示すように，レーダー・アメダス解析雨量を予測雨量に見立て，6時間先までを入力する。上記a.とb.の2つのモデルは，未学習出水に対する検証の際は，現時刻までの入力値により6時間先までのダム流入量を予測するが，本モデルでは，現時刻より将来の先行予測の部分で降水短時間予報を活用(表-3の運用条件参照)し，ダム流入量を予測する。

5. SOINNの学習結果

52個の既往出水データについて学習したのち，平成27年の3個の出水(7月3日，7月16日，9月9日)データについて予測精度を検証した。特に，3パターンのモデルの違いによるダム流入量の予測精度の違いを確認した。パターンaとパターンbは現時刻までのデータを使って6時間先までのダム流入量を予測し，パターンcは現時刻までのデータに6時間先までの降水短時間予報を加え，ダム流入量を予測した。以下，出水ごとに，それぞれのパターンにおけるダム流入量予測状況について記載する。

なお，図-10～図-12のいずれも黒い実線が実測値(観測値)，灰色の実線がSOINNによる計算値である。また，例えば，予測する時間が先になるほど，実測値と計算値の乖離が大きくなる。この乖離度を視覚的に表現するため，乖離度の大きさによってグラフの縦軸のメモリが変わるように調整している。すなわち，乖離度が大きい場合，縦軸のメモリが大きくなり，実測値のグラフが小さくなる仕組みである。更に，実測値と計算値の乖離度についてRMSEを用いて整理し，その結果を図-7～図-9に示した。RMSEは以下の式より算定した。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (h_c(i) - h_o(i))^2}$$

N: 総計算ステップ数， $h_o(i)$: i時の実測値，

$h_c(i)$: i時の計算値

RMSEは時系列の実測値と計算値の平均的偏差を示したものであり，正規化されておらず，異なる出水間での精度比較には適さないが，算定式が簡便であり理解しやすいため用いた。

(1) 平成27年7月3日出水について(図-7，図-10参照)

パターンaとパターンbは，降水短時間予報の入力がないため，現時刻よりも先の予測は，主に上流側水位観測点とダム地点の洪水到達時間差によって担保されていると考えられ，洪水到達時間を超える先の予測となる2時間先，3時間先以降の予測精度はパターンcと比較して，劣化程度が大きい。一方，パターンcは，降




図-7 平成27年7月3日のパターン毎の精度検証




図-8 平成27年7月16日出水のパターン毎の精度検証




図-9 平成27年9月9日出水のパターン毎の精度検証

水短時間予報の恩恵を受け，ピーク付近までの予測は3時間先も極めて良好である。また，パターンcは3時間先でも1時間先と同程度のグラフの大きさを維持しており，予測精度の劣化が最も小さい結果となっている。

(2) 平成27年7月16日出水について(図-8，図-11参照)

どのパターンも3出水の中で最も予測精度が悪い出水である。その中でも，予測雨量を活用したパターンcの予測は予測値のブレが最も小さく，予測雨量を活用する利点を後押ししている。ただし，この出水時の降水短時間予報の精度は悪く，その影響を受け，パターンcでも実運用に耐えられない予測精度となっている。

(3) 平成27年9月9日出水について(図-9，図-12参照)

パターンcによるダム流入量予測の良さが見た目に際立つ出水である。3時間先までの予測であれば十分な精度を確保していると言えるレベルである。6時間先まで予測雨量の提供を受けるパターンcは不確実性が軽減され，他パターンに比較して，各段の予測精度の良さを確保している。

以上の3出水のダム流入量予測状況を踏まえると，予測雨量(降水短時間予報)を扱うことで，予測したダム流入量の不確実性が弱まると考えられ，気象庁が提供するプロダクトである降水短時間予報の予測精度が年々向上している状況からも，予測雨量を積極的に活用していくことが好ましいと考えられる。

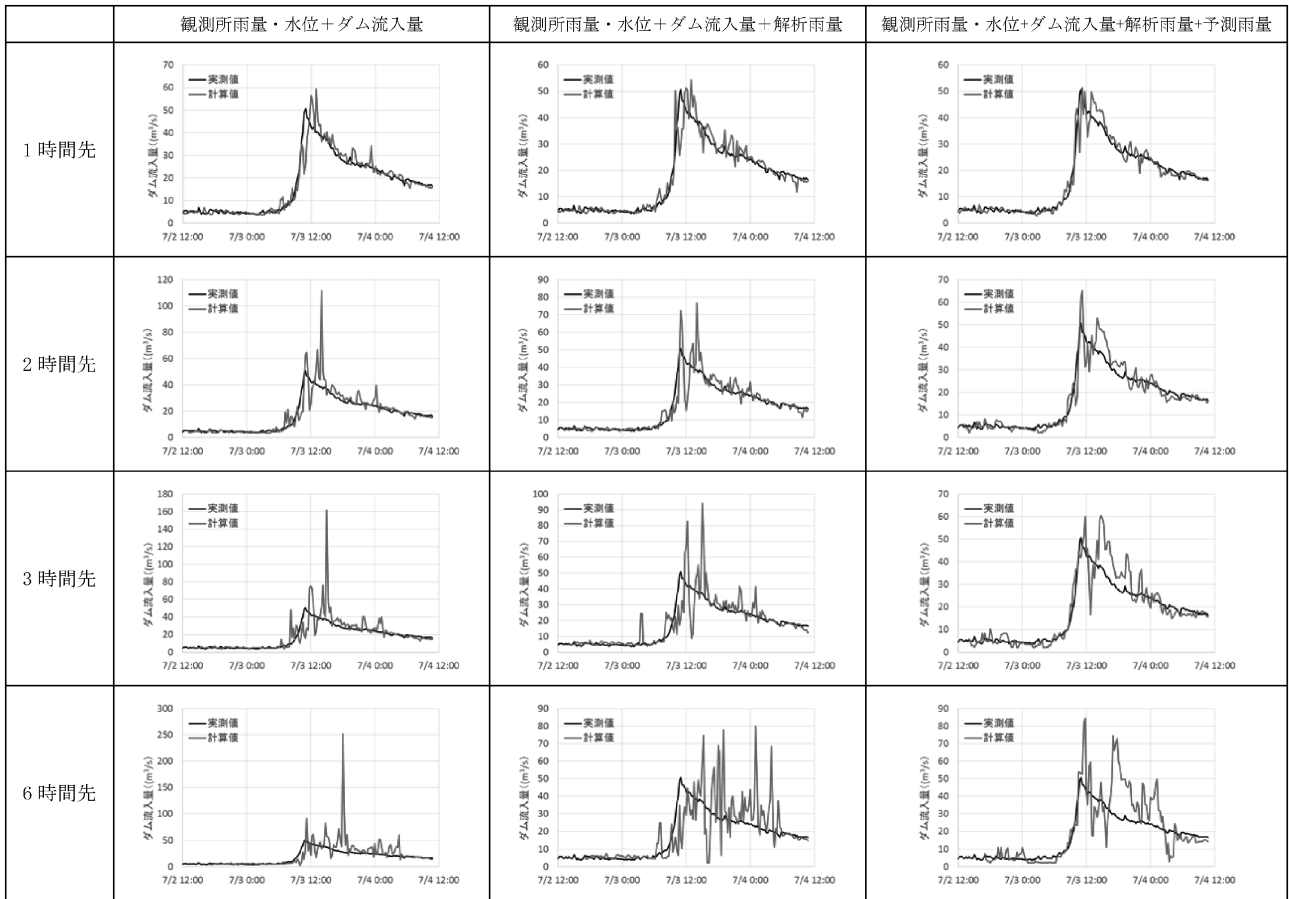


図-10 平成27年7月3日出水に対する各モデルの予測状況

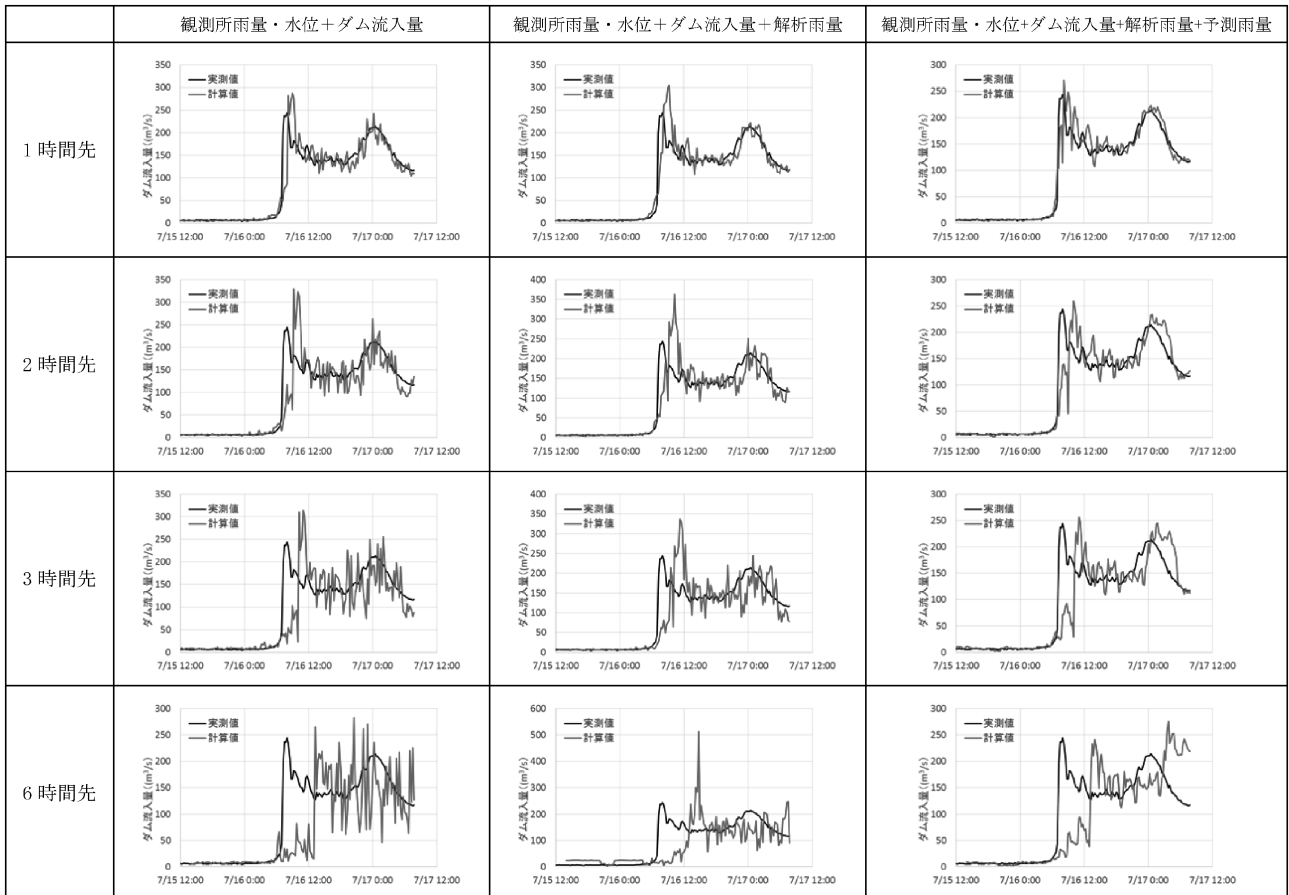


図-11 平成27年7月16日出水に対する各モデルの予測状況

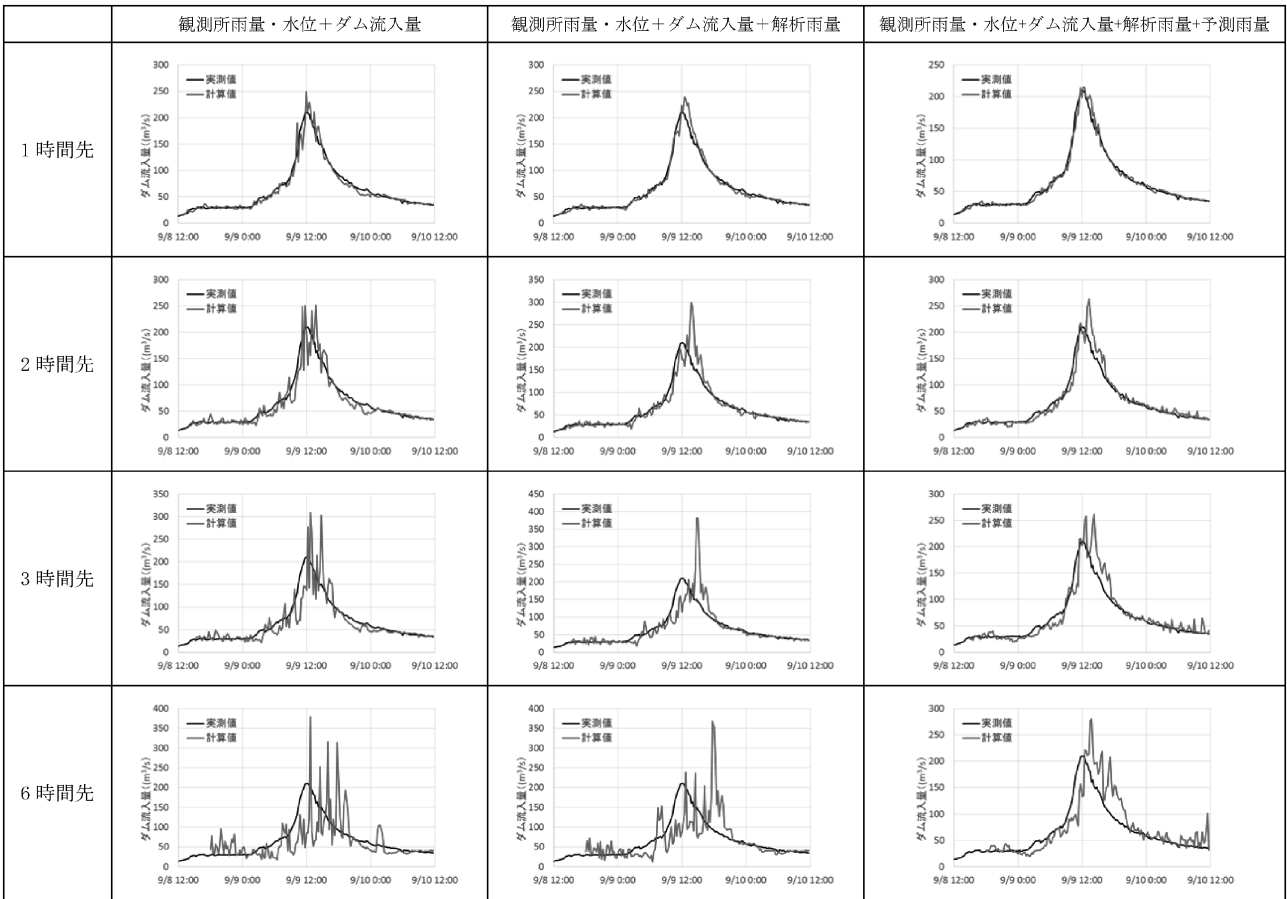


図-12 平成27年9月9日出水に対する各モデルの予測状況

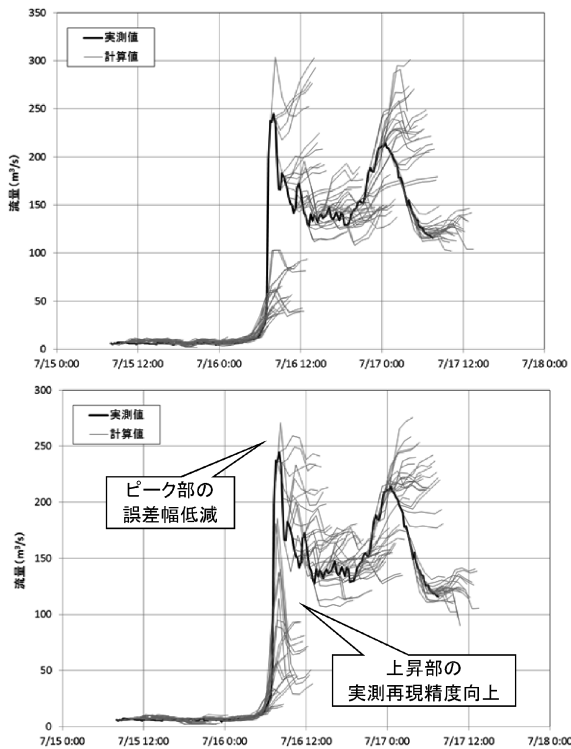


図-13 学習出水数の違いによる予測精度の違い
(上：平成22年までの26出水，下：平成26年までの52出水)

以上の検討結果を踏まえ、道志ダム上流域のダム流入量予測のSOINNの学習モデルとしては、パターンcを採用するものとした。

6. SOINNのその他の効果

図-13は過去の出水データを二分割し、学習データ量によってダム流入量予測精度が変わることを示したものである。灰色の実線(髭状)は、6時間先までの予測を示したものである。上図が26出水を学習した後に平成27年7月16日出水の計算をしたもの、下図が52出水を学習した後に同出水の計算をしたもの(パターンcと同様)である。予測精度向上の確認ポイントとしては、第一に髭状の実測値との乖離度が低減している(図-14~図-16のRMSE参照)こと、第二に出水上昇部の再現性が向上していること、が挙げられる。当該出水の降水短時間予報の予測精度が悪く、入力条件に課題がある出水であるが、学習出水の増加によりダム流入量予測精度の改善が見られる。

SOINNは、図-3のアルゴリズムに従い、新しいデータを得るごとにデータ特性に基づきネットワークを微調整し続けるため、新しいデータを学習するほどに予測精度が高まることが期待できる。また、流域条件の変化等により流出特性が変わった場合も、その特性に追従するようにネットワークが形成されていくため、新たにモデルを再構築する必要もない。

以上のように、SOINNを活用することでこれまで問題点の一つであったシステムのメンテナンス労力を軽減することが可能となり、特に予算の厳しい自治体での活用が期待が持てる。

7. おわりに

従来、6時間先のダム流入量や水位の予測精度を論じる際には、実績雨量を予測雨量に見立て、モデル精度を確認していた。そして、実際の運用の際には、ある雨量の大きさが一定時間継続するシ




図-14 平成27年9月9日出水のパターン毎の精度検証




図-15 平成27年9月9日出水のパターン毎の精度検証




図-16 平成27年9月9日出水のパターン毎の精度検証

ナリオや現時刻雨量の2倍の大きさになるシナリオ等に従い、予測雨量を作成し、実計算を行ってきた。予測雨量(本論文では、降水短時間予報を利用)の精度確保が難しい時代はそれで良かったかもしれないが、気象庁の継続的努力により、天気予報等の予測精度も向上¹²⁾している。今後は、現時刻までの入力条件、現時刻より先の入力条件を明確化し、実運用での予測精度を適切に認識したうえで、モデル改良に必要な機能・データ等を論じていくべきと考える。前出のパターンcでも、上流側水位観測点とダム地点の洪水到達時間を超える先の予測精度の確保は出水によっては難しい。ただし、どの出水も現時刻までの情報を利用するだけより予測雨量(本論文では降水短時間予報を活用)を併用したパターンcの方がダム流入量予測精度は向上(図-7～図-9参照)している。かつ、現在も様々な観測技術や解析技術が進化中であり、予測雨量プロダクトは更なる予測精度の向上が期待できる。

実運用の際には、これらの精度・誤差を踏まえた評価が必要である。予測雨量だけでなく、入力と出力の応答関数等にも誤差が含まれており、結果的に、算出されるダム流入量には必ず誤差が含まれる。そこで、各要因の誤差分布を積み上げ、実管理での意思決定材料として計算値の誤差分布を表現すること等が大切であると考えられる。本論文では、入力と出力の一対一の関係の中で予測技術を紹介しているが、今後は、バイズ確率・統計論等を活用し、出力値を確

率・統計的に表現する研究にも取り組んでいく予定である。

なお、本論文でのモデル検討は終了しており、現在、システム構築中である。今後は、SOINNの自動学習機能に着目し、出水経験数の増加によるダム流入量予測精度の向上、そして、気象庁の雨量予測技術改良によるダム流入量予測精度の向上を確認するため、モニタリングを続けていければと考えている。

謝辞

本検討にあたって、データの提供を始めとして、神奈川県企業庁相模川水系ダム管理事務所から多大な協力を得た。改めて感謝の意を表したい。

参考文献

- 1) 日野幹雄：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，No. 221，pp. 39-47，1974.
- 2) 角屋陸，田中丸治哉：長短期流出両用モデルによる実時間洪水予測，農業土木学会論文集，No. 177，pp. 31-41，1995.
- 3) 藤田暁，大東秀光，上坂薫，椎葉充春，立川康人，市川温：分布型流出モデルに基づくダム流入量実時間予測モデルについて，水工学論文集，第45巻，pp. 115-120，2001.
- 4) 井本文雄，中村正俊：雨量情報に基づく数時間先行のダム流入量のオンライン予測法，電学論 B，113，3，pp. 213-220，1993
- 5) 瀬野英二，村上研二，泉田正則，松本普：広域雨量データを用いたニューラルネットワークによるダム流入量予測，電学論 B，124，4，pp. 561-568，2004.
- 6) 竹村仁志，真間修一，吉田武司，石上尚：中流域に洪水調節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，第19巻，pp. 247-252，2013.
- 7) 関基，木村晃，古山一志，和田高宏，金子祐，穴水秀樹，真間修一：河川特性を反映したニューラルネットワーク洪水予測の精度向上，河川技術論文集，第19巻，pp. 295-300，2013.
- 8) 山崎和博，巻洵有哉，申富饒，長谷川修：自己増殖型ニューラルネットワーク SOINN とその実践，日本神経回路学会誌，Vol. 17，No. 4，pp. 187-196，2010.
- 9) 国立研究開発法人防災科学技術研究所：Xバンドマルチパラメータレーダ，<http://mp-radar.bosai.go.jp/>，(2017.3.7)
- 10) 杉山将：イラストで学ぶ機械学習，講談社，2013.
- 11) 杉山将：統計的機械学習，オーム社，2009.
- 12) 気象庁：数値予報の精度向上，<http://www.jma.go.jp/jma/kishou/known/whitep/1-3-9.html>，(2017.2.1)

ABSTRACT

In order to predict the inflow discharge accurately, we selected to use SOINN that the Hasegawa laboratory of Tokyo Institute of Technology developed. SOINN that is developed by utilizing Self-Organizing Maps and Growing Neural Gas is the unsupervised learning way that can learn additionally digital information from the web environment automatically without the technical expert. In this research, we recognized that SOINN could estimate the inflow discharge after two hours to three hours accurately by using the short-time precipitation forecast. We will expect to monitor the accuracy improvement of the inflow discharge prediction.