

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

NEURAL NETWORK REFLECTING THE RIVER CHARACTERISTICS
FOR ACCURACY IMPROVEMENT OF FLOOD FORECAST

関基¹・木村晃²・古山一志³・和田高宏¹・金子祐⁴・穴水秀樹¹・眞間修一¹
Motoi SEKI, Akira KIMURA, Kazushi FURUYAMA, Takahiro WADA, Yuu KANEKO,
Hideki ANAMIZU, and Syu-ichi MAMA

¹正会員 八千代エンジニアリング(株) (〒161-8575 東京都新宿区西落合2-18-12)

²国土交通省 東北地方整備局 福島河川国道事務所 (〒〒960-8153 福島県福島市黒岩榎平36)

³国土交通省 東北地方整備局 仙台河川国道事務所 (〒982-8566 宮城県仙台市太白区郡山5-6-6)

⁴正会員 上越市役所 (〒943-8601 新潟県上越市木田1-1-3)

Flood forecast using Neural Network model has operated in Natori River, downstream of Abukuma River since 2003. In this study, we systematically grasped the causes of the error in the current flood forecast based on the accuracy verification using the prior forecasting results. Moreover, we improved and reflected river characteristics in Neural Network model considering the required model accuracy for the practical use.

As a result of accuracy verification of prior forty nine (49) flood forecasts, the practical performance of flood forecast using Neural Network for large river was confirmed. Besides the reflecting the river characteristics, switching scheme of multiple flood forecast models was utilized considering the difference of scale of the flood and its hydrograph. More than three (3) hours' lead time was ensured for the every flood which exceeded the warning water level utilizing the improved flood forecast model.

Key Words : Flood Forecast, Neural Network, River Characteristics, Lead Time

1. はじめに

阿武隈川下流および名取川における洪水予測システムは、かつてメインシステムとして「貯留関数法」、サブシステムとして「水位相関法」、これら2手法による運用であったが予測精度が低く、予測結果がそのまま警報発令等の判断の指標とならないケースが多く見受けられ、河川管理者が自らの経験に基づいた知見等を総合的に勘案して予測を実施していることも少なくない状況であった。

このような実態を踏まえ平成14年度に構築されたニューラルネットワーク洪水予測モデル¹⁾は、当時その予測精度が認められ平成15年度にオフラインシステム化、平成17年度にオンラインシステム化が実施され、図-1に示される5地点の洪水予測モデルとして採用された。貯留関数モデルに比べ予測精度が良好であったのは、ニューラルネットワークモデルの場合、これまでの実績洪水波形における上下流水位の非線形的な相関関係から当該地点の水位を予測するものであり、流出計算のよう

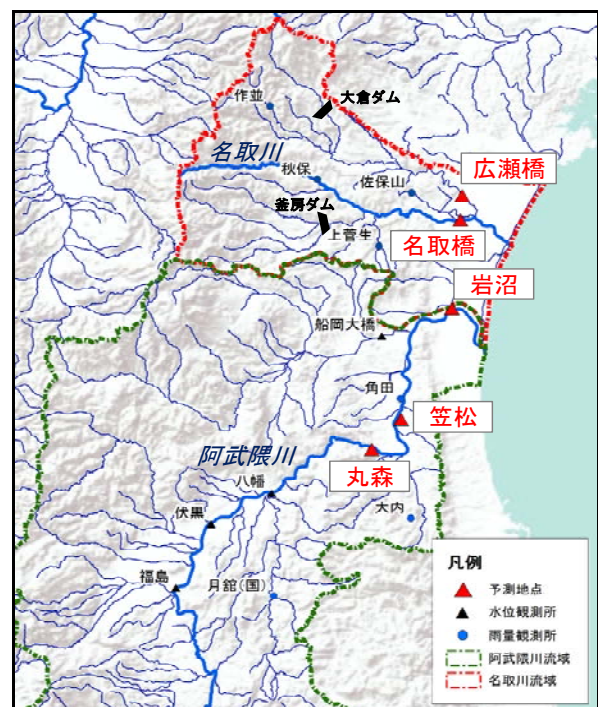


図-1 阿武隈川下流部および名取川洪水予測地点

な流域・河道定数の固定による計算誤差や雨量データを流量に変換してさらにHQ曲線から水位へ変換することによる変換誤差が発生しないという利点によるものと考えられる。

その後、現在まで運用されてきたが、現行の洪水予測モデルでは4~6時間後予測の精度が低いため、十分なリードタイムを確保した精度の高い予測情報の提供が困難となっていること、近年サーバの老朽化によるシステム停止トラブルが頻発していること、などの課題が顕在化している。

本研究では、現行モデルによる洪水予測を実施して10年が経過した現状を踏まえ、これまでの洪水予測の精度を検証し、現行モデルの課題を把握するとともに、現場で求められる精度を踏まえた改良モデルを構築し、その精度向上程度を確認したものである。

2. 対象河川の特徴

対象河川である阿武隈川下流および名取川は、各河川ともに社会経済上重要な位置にあり、河川沿岸域の人口集中度が高く、洪水ははん濫時には多大な被害の発生が想定されることから再現性の高い洪水予測モデルの構築が望まれる河川である。また、表-1に示すように両河川の流域面積には10倍程度の差があり、阿武隈川下流の予測地点では、予測に使用する上流の水位観測所から予測地点までの流達時間が6hr確保可能な観測所を有しているのに対し、最遠点からの洪水到達時間3~4hr程度である名取川の場合、上流の水位観測所からの流達時間が1~2hr程度と短いという特性を有している。

近年発生した洪水では、阿武隈川下流（丸森・笠松）において、はん濫危険水位を超過するような大規模な洪水が発生している。一方、名取川は大規模な洪水が発生していない。

表-1 洪水予測対象地点の諸元と近年の洪水規模

水系名	河川名	観測所名	流域面積 (km ²)	最高水位発生洪水	
				現行モデル構築前 (H14以前)	現行モデル構築後 (H15以降)
阿武隈川	阿武隈川	丸森	4173.0	H14.7.11洪水(22.33m) はん濫危険水位超過	H23.9.22.洪水(21.61m) はん濫注意水位超過
		笠松	4347.4	S61.8.5洪水(17.10m) はん濫危険水位超過	H23.9.22.洪水(15.78m) はん濫注意水位超過
		岩沼	5265.0	S61.8.5洪水(7.62m) はん濫注意水位超過	H19.7.15.洪水(5.48m) はん濫注意水位超過
名取川	名取川	名取橋	431.3	H14.7.11洪水(8.31m) はん濫注意水位超過	H24.6.20.洪水(8.08m) はん濫注意水位超過
	広瀬川	広瀬橋	309.3	H1.8.6洪水(2.22m) はん濫注意水位超過	H24.6.20.洪水(1.85m) はん濫注意水位超過

3. 現行の洪水予測モデルの概要¹⁻⁵⁾

(1) ニューラルネットワークの基本構造

ニューラルネットワークモデルとは、人間の脳の仕組みを模倣した情報処理機構であり、神経細胞が、一定の刺激（入力）に対して反応する（出力）単純な仕組みを数学的にモデル化したものである。洪水予測においては、過去の実績洪水データにおける水位や雨量等の相関関係に基づきモデル化することで、自らのパターン認識能力を高めることや、非線形な連続関数を近似することが可能な手法であり、熟練した河川管理者がこれまで行ってきた過去洪水の経験に基づく予測を定量化することができる手法である。

採用モデルは、図-2に示す階層型のネットワークを採用（3層構造、中間層ユニット数7）し、閾値や重み付けにはシグモイド関数を採用した。

$$f(u_i) = \frac{1}{1 + \exp(-2u_i)} \quad (1)$$

$$u_i = \sum_{i=1}^n \omega_i \cdot x_i - \theta \quad (2)$$

ここで、 x_i : 入力値、 ω_i : 重み、 θ : しきい値

また、学習方法としてバックプロパゲーション法を適用し、ネットワークを最適化する。学習における収束条件は、学習回数100,000回を上限の下で、平均二乗誤差 $E < 0.001$ とした。なお、現行モデルは実測水位と実測地点雨量（テレメータ）を入力値としている。

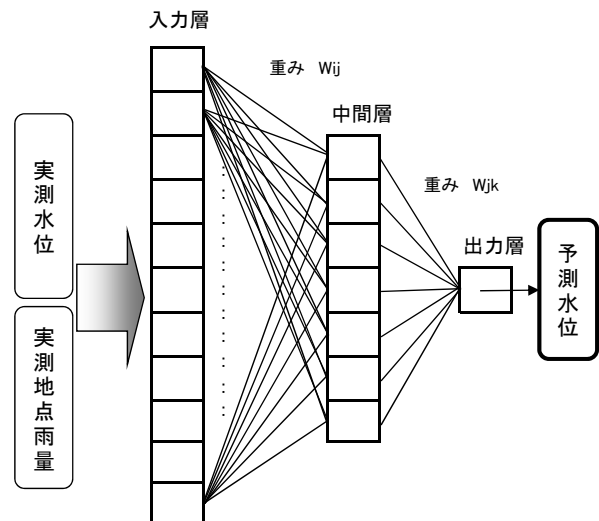


図-2 ニューラルネットワークモデル基本構造

(2) 入力因子の設定について

入力因子については河川特性を踏まえ、次の考え方で選定している。

阿武隈川：テレメータで観測されている水位と雨量から「予測地点水位」と「予測地点上流に位置する水位観測所のうちピーク水位相関が高く、予測に必要な流達時間を有している観測所（当時は1～3時間で選定）」、および「上流側水位観測所と予測地点間残流域を代表する雨量観測所」を選定している。

名取川：流域規模・水位観測所の配置状況より予測に占める雨量の比重が大きいことから、「予測地点水位」と「予測地点上流に位置する水位観測所」および「流域内の複数の雨量観測所」を選定している。

4. 予測誤差発生要因を踏まえたモデル改良方針

(1) 現行モデルの評価と課題把握

現行モデル構築時に使用した洪水に近年の洪水を加えた49洪水を対象とした予測精度検証を実施した。

a) 評価の着眼点

洪水予測では、予測値と観測値が一致することは希であり、水位等の観測誤差や予測モデルの計算誤差に伴う差異が発生する。

洪水予測は通常の治水計画で実施される水理解析と異なり、“絶対的な水位の予測精度よりも予測時刻のずれ”が大きな意味を持ち、水防活動や避難行動の判断基準となる水位への到達を適切に予測することこそ求められる要件である。

つまり仮に予測水位に誤差が生じていても、判断基準となる水位への到達予測時刻が前倒し（早めの時刻に）方向の予測であれば、予測時刻誤差が洪水予報における安全側の余裕時間としてカウントできる（図-3）。

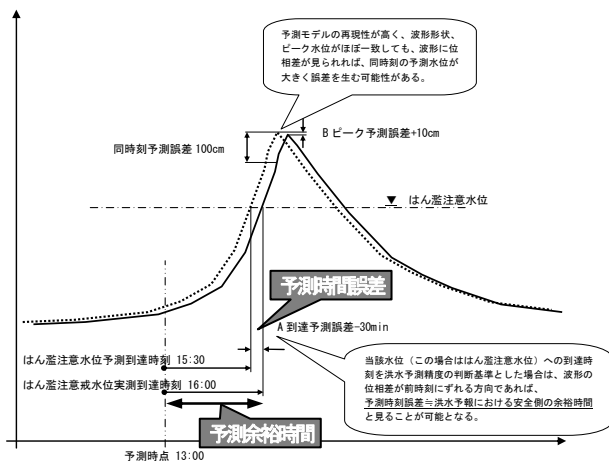


図-3 洪水予測検証の指標

したがって、洪水予測モデルの予測精度評価では、予測水位と実績水位の誤差（RSME、相関係数）に加え基準水位への到達時刻の予測精度に着目した。具体的には、基準水位への予測到達時刻と実際の到達時刻の差を“予測時間誤差”、到達を予測した時刻から実際にその基準水

位に到達を予測した時刻までの差を“予測余裕時間”と定義し、現行モデルを評価した。

b) 予測精度の評価

予測水位と実績水位のRSMEを図-4に示す。各観測所ともに1～3時間後予測までの精度は0.1～0.3m程度と高い精度であるのに対し、4～6時間後予測では0.4～0.7m程度と予測誤差が拡大している。その傾向は名取川の方が顕著である。岩沼地点については近年河床低下が著しく、河道特性が大きく変化しているためモデル構築前後で精度に差異が発生している。また、相関係数についても運用後の洪水に対して3時間後予測であれば $R=0.970$ であるのに対し、6時間後予測では $R=0.903$ と大きく低下する結果となった。




図-4 地点ごとの予測時間別誤差(RSME)

図-5には特徴的な予測結果の一例を示すが、その他の課題として水防団待機水位程度の小規模な洪水における予測精度の課題（課題①）、水位低減部における予測精度の課題（課題②）、岩沼地点では近年の河道特性の変化による影響（課題③および図-4）、潮位の影響を受ける場合の予測精度の課題（課題④）が確認された。

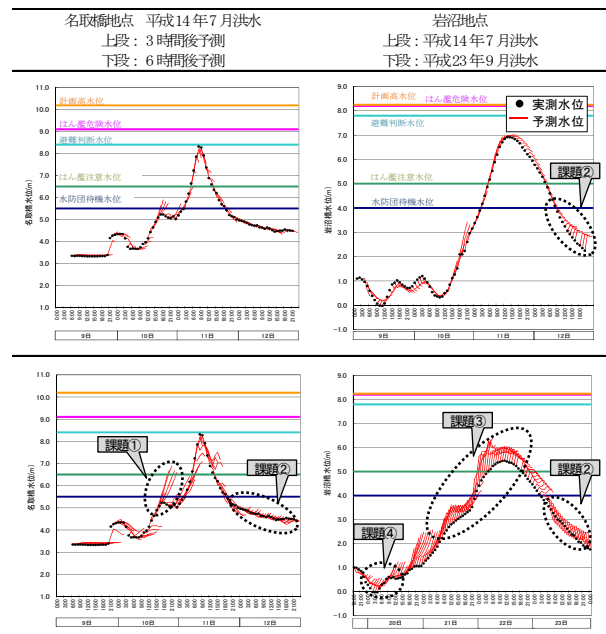


図-5 現行モデルの課題を示す特徴的な予測結果

また、予測余裕時間の評価としては、はん濫注意水位で70%、水防団待機水位で80%の洪水で3時間以上のリードタイムが確保されていた。

c) 適用限界の課題

ニューラルネットワークモデルは、未経験の洪水規模に対する予測精度が著しく低下する特性を有しており、未学習規模の洪水では、危機的な状況を予測できなくなる。現行モデルでは、ニューラルネットワークの認識性能を高めるための工夫として、学習時における入力因子の正規化(0.0~1.0)を最大値で0.9に変換しているのので、学習洪水の最大水位で頭打ちにはならない。しかし、表-2に示すように名取川2地点および岩沼地点では、学習最高水位がはん濫危険水位に達していないため、はん濫危険水位への予測が不可能な状況である。

表-2 洪水予測対象地点の諸元と近年の洪水規模

観測所名	丸森	笠松	岩沼	名取橋	広瀬橋
学習最高水位	22.33m	17.10m	5.48m	8.31m	2.22m
予測限界水位	23.20m	17.50m	6.00m	8.40m	2.40m
はん濫危険水位	22.10m	17.10m	8.20m	9.10m	3.20m

(2) 現行モデルの予測誤差発生要因の把握

洪水予測モデルの精度向上においては、現行モデルにおける予測誤差が発生する要因を系統的に把握し、精度向上に資するモデル改良を実施した。

現行モデルの予測誤差の検証結果、およびそれぞれの観測所における河道特性を踏まえ、ニューラルネット

ワーク予測モデル構築のプロセスごとに誤差発生要因を整理した(図-6)。ニューラルネットワークモデル構築のプロセスとしては、“入力因子の選定・組合せ検討”と“学習パターンの設定”の2つに大別できる。入力因子の選定・組合せ検討プロセスでは、入力因子である雨量・水位の観測値がモデルの予測精度に影響を及ぼし、一方、学習パターン設定プロセスでは、河道断面特性(断面形状)の変化、および学習パターンによる誤差(変数の検証対象とした洪水規模やハイドロ形状)がモデルの予測精度に影響を及ぼす。

(3) 河川特性を踏まえた予測モデルの改良

a) 観測精度の向上

現行モデルではテレメータ雨量を用いているため、面的な降雨分布を十分に捉え切れていない。特に流域が小さく、洪水到達時間の短い名取川ではより観測精度の高い雨量データに加え、予測雨量も精度向上には必要であることからレーダ雨量(実況・予測)を用いるものとした。ニューラルネットワークモデルの構造からダム等施設配置を踏まえた流域単位による平均雨量を適用する。

b) 入力因子の選定

ニューラルネットワークモデルでは、過去の実績洪水データの非線形的な関係性を学習し、モデル構築することから、予測地点の水位変動特性と結びつきの強い入力因子の選定が予測精度を左右する。現行モデルの課題を踏まえ、本検討では予測時間に対応した入力因子を相関解析および平均到達時間より選定するとともに、洪水調

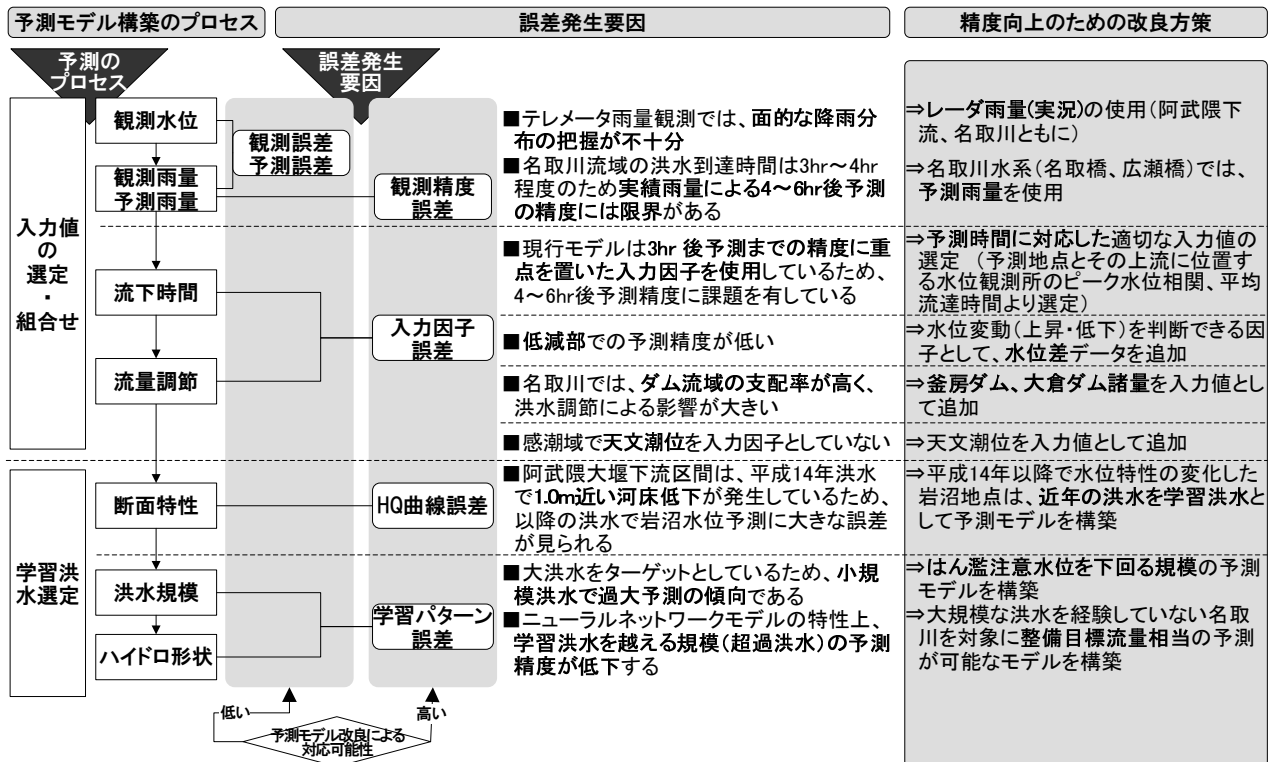


図-6 予測プロセスと誤差発生要因の整理と予測モデル改良方針

節施設運用の反映、ハイドログラフ形状（上昇・低下）を認識するための因子として水位変動量データの追加、および感潮域を対象とした天文潮位データを追加した。

c) 洪水規模・波形に対応したモデル構築

現行モデルでは、大規模な洪水をターゲットに構築したモデルのため、小規模な洪水で過大予測の傾向が確認された。

そこで本検討では、図-7に示す洪水規模に応じた予測モデルを構築し、水位や水位上昇量等を判定基準としたモデル切り替えによる運用とした。また、未経験規模の




図-7 洪水規模・波形に応じた予測モデルの適用

洪水への対応では、はん濫の可能性が予測不能となる事態を回避する目的に実績洪水を整備目標流量規模に引き伸ばしをしたモデル洪水を学習させ、はん濫危険水位までの予測（対象：名取橋、広瀬橋、岩沼）を可能とした。

5. 改良モデルによる予測精度向上の検証

(1) 予測結果の比較

図-8は近年で規模の大きな洪水（阿武隈川：平成23年9月洪水、昭和61年8月洪水、名取川：平成24年6月洪水）を対象に実施した予測結果である。検証結果では、改良モデルによる予測精度の向上が確認できる。全洪水を対象とした阿武隈川・名取川の予測誤差としては、3時間後予測のRSMEで0.29mから0.18m、6時間後予測で0.57mから0.30mへといずれも誤差が縮小しており、改良モデルの高い再現性が示された（図-9）。

予測時間誤差においても図-10に示すように改良モデルではほとんどの洪水で±1時間以内の誤差に収まっている。また、表-3に示す相関係数についても同様に5地点とも全ての予測時間で精度が向上していることが確認できる。




図-8 改良モデルによる予測結果の一例

表-3 改良前後の実測水位-予測水位相関係数

河川名	阿武隈川下流			名取川	
	丸森	笠松	岩沼	名取橋	広瀬橋
観測所名					
現行モデル	0.996	0.991	0.992	0.948	0.967
3hr 後予測					
改良モデル	0.998	0.993	0.995	0.984	0.976
3hr 後予測					
現行モデル	0.980	0.973	0.968	0.824	0.830
6hr 後予測					
改良モデル	0.990	0.980	0.978	0.970	0.939
6hr 後予測					




図-9 改良前後の予測時間別誤差(RSME)

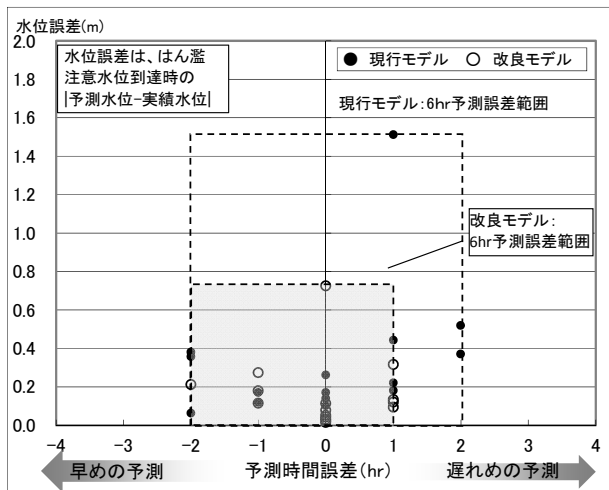


図-10 はん濫注意水位到達予測精度 (名取橋)

(2) 洪水予測におけるリードタイムの確認

図-11に示すように対象洪水うち、水防団待機水位およびはん濫注意水位を越えた全ての洪水で3時間前までに予測が可能であることを確認した。また、実際には基準水位を超過しなかったのに予測では超過しているような過大な予測は大幅に改善されている。

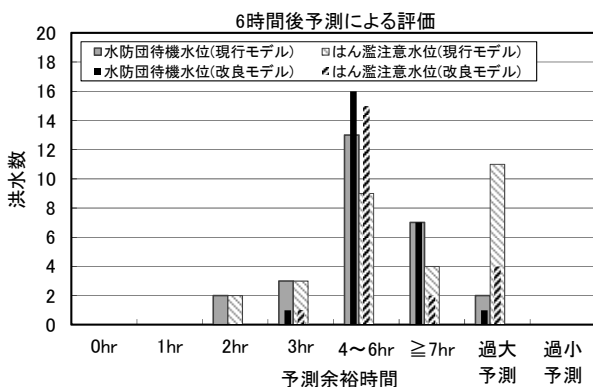


図-11 リードタイムの確保状況 (名取橋)

6. 考察

本研究では、これまでに蓄積された洪水データからニューラルネットワークモデルによる洪水予測の実用性を確認した。また、予測精度向上に向けたモデル改良のコンセプト(誤差発生要因の把握、河川特性を踏まえた改良方法、精度検証方法)を示した。今後は、改良モデルによる洪水予測結果を蓄積し、その予測精度を検証する必要がある。

ニューラルネットワークモデルは、実績の観測データ(水位・雨量)から直接、将来水位を予測するので、モデル構築および予測作業において河川流量データを必要としない。通常の流出解析モデルの場合には、モデル構築時に同定のための流量ハイドログラフが複数必要となり、さらに雨量から流量を算出するのでこれを水位に換算する

ための現況河道の水位-流量曲線を必要とする。これらのデータは直轄管理区間では十分整備されているものの、指定区間における整備状況は未だに低い。ニューラルネットワークモデルは過去の水位観測データが十分得られれば予測モデルの構築は可能であることから、このような指定区間の洪水予測モデルとしても有効な予測手法であると考えられる。

同様に融雪出水の予測も物理的なモデルで実施する場合には、気象・水文データから多くのパラメータを設定し、積雪分布の解析や融雪量を算出する必要がある。しかし、現状では多くの河川で十分な基礎データが得られていない状況が想定される。ニューラルネットワークモデルであれば観測の積雪深や気温等の気象・水文データからブラックボックス的に融雪出水を予測することが可能であることから、積雪地域を流下する河川における融雪出水の予測手法としてもニューラルネットワークモデルの活用が期待できる。

また、予測に使用する入力因子とその重みや閾値さえ構築してしまえば、実際の予測作業はエクセルのような表計算ソフトで計算が可能であることから、大がかりなシステムを導入せずとも対応が可能である。

一方でニューラルネットワークモデルは、学習した洪水に対しては一定の精度が期待できるものの、未学習の洪水(学習規模以上の洪水、河道特性変化後の洪水)の場合には、予測誤差が拡大する課題を有している。今回の改良モデルの構築では、はん濫危険水位までの予測が可能となるよう複数モデルによる運用としているが、将来的には物理モデルとの2手法併用による運用も望まれる。

参考文献

- 1) 槻山敏昭・外山久典・笹原和彦・眞間修一・関基・竹村仁志：ニューラルネットワークによる阿武隈川洪水予測の基礎的検討、河川技術論文集, Vol.9, pp.173-178, 2003.
- 2) 阿部清明、菊池英明、古川浩平、塩月善晴：ニューラルネットワークによる流出解析手法(日流量)に関する研究、土木学会論文集 No.656/II-52,1-13,2000.8
- 3) 磯部勇、大河戸輝夫、羽生田英彦、小田誠一、後藤祐輔：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,第7巻,pp.90-97,1994.
- 4) 稲吉明男、長江幸平、田宮睦雄、宮田達磨、眞間修一、竹村仁志：ニューラルネットワークモデルによる二級河川での洪水予測の基礎的検討、河川技術論文集, Vol.9, pp.179-184, 2003.
- 5) 春原常男、内海博、井上勝矢、眞間修一、吉田武司、竹村仁志：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, 2006.