

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

著者	一言 正之
学位授与年月日	2016-04-14
URL	http://doi.org/10.15083/00074970

論文の内容の要旨

論文題目 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
氏 名 一言 正之

本研究は、河川水位予測の精度向上・信頼性向上を目的として、ニューラルネットワーク (Artificial Neural Network; ANN) を用いた予測手法の精度向上、物理型モデルをベースとして観測データの同化手法を組み合わせた予測手法の精度向上、各手法の比較および課題の抽出、そして物理型モデルとニューラルネットワークを組み合わせたハイブリッドモデルの開発を行ったものである。以下に各研究の内容・成果について概要を示す。

(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

まず、従来型手法である 3 層の階層型 ANN を対象に精度向上の検討を行った。既往研究のレビューより、ANN の精度向上のための注意点として、①入力データの適切な選定、②過学習の回避、③乱数に起因する誤差 (再現性の欠如) への対応、等を抽出した。以下の三つの事例検討により、各注意点への対応を検討した。

①への対応として、斐伊川を対象として、適切な入力層の設定に関する検討を行った。ANN 水位予測モデルでは、時空間的に多数の水位・雨量観測でデータが入力層の候補となる。既往の検討事例では、入力層に用いるデータ選定は試行錯誤的に行われていることが多い。本検討では、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選定することで、ANN の精度向上を確認した。

②への対応として、佐波川を対象として、中間素子数・学習回数に関する検討を行った。ANN 水位予測モデルの中間素子数や学習回数は、既往研究では十分に検討されずに設定される事例が多い。本検討では、中間素子数や学習回数に関するケーススタディを行い、学習段階・予測段階における誤差の変動を示し、適切な設定方法を確認した。

③への対応として、ANN 水位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アンサンブル学習を適用し、精度評価を行った。ANN 水位予測の精度向上の一つとしてアンサンブル学習が研究されているが、国内での適用事例はみられない。単一の学習モデルに比べ、12 アンサンブルの学習モデルを適用し精度向上を確認した。

(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

水位予測をさらに長い時間に適用するためには、対象流域に多数存在する降雨・水位の観測データを反映することが望まれる。しかしながら、従来型の ANN では入出力応答の表現能力に限界があるため、入力データが過多となることは望ましくない。一方で深層学習と呼ばれる手法では、大量の入力データに対しても学習能力が高いとされており様々な分野で研

究が進められているが、河川の水位予測への適用事例は見られない。本研究では、ANN 水位予測モデルに深層学習適用し、一級河川である大淀川水系および遠賀川水系の一流域にてケーススタディを行った。

一つ目のケーススタディでは、大淀川水系の樋渡水位観測所を対象とした。対象流域は面積が 861km²、水位観測所が 5 箇所、雨量観測所が 14 箇所である。検討データとして、1990 年から 2014 年までの上位 24 洪水を抽出した。

二つ目のケーススタディでは、遠賀川水系の日の出橋水位観測所を対象とした。対象流域の面積は 695km²、水観測所が 11 箇所、雨量観測所が 11 箇所である。検討データとして、2005 年から 2014 年までの上位 20 洪水を抽出した。

各ケーススタディで、予測は 1 時間ごとに 6 時間先まで出力し、各予測時間に対して深層学習モデルを作成するものとした。WEB で公開されている水文・水質データベースから水位・雨量データを取得した。ピークの 72 時間前から 48 時間後までの 121 時間分を 1 洪水として学習データ、検証データを作成した。予測に用いるネットワークは 4 層の階層型ネットワークとした。ネットワークの出力層は、予測地点における現時刻から予測時間までの水位上昇とした。入力層は、予測地点自身の水位、流域内の各水位観測所における一時間あたりの水位変化、流域内の雨量観測所における時間雨量とした。ネットワークの事前学習にはデノイジング自己符号化器を適用し、また過学習を避けるため入力層と中間層にドロップアウトを適用した。学習回数などの条件設定はケーススタディにより決定し、予測精度は leave-one-out 交差検証により上位の 3,4 洪水を対象として評価した。

深層学習モデルの予測結果は、両ケーススタディにおいて従来型 ANN に比べて 1~6 時間予測の水位誤差 (RMSE) が低減され、高い適用性が示された。一方で課題として、一つ目のケーススタディで期間最大洪水のピーク付近で予測が過大となる傾向が見られ、これについては後段のハイブリッドモデルにて対応を図った。

(3) 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

物理型モデルは、近年における計算機の高速度化や、地形・降雨データの精度・解像度の向上、さらにはリアルタイム観測データによる同化手法の研究に伴い、精度向上が期待されている。本研究では、物理型の分布型モデルを構築するとともに、粒子フィルタによるデータ同化により精度向上の検討を行った。

流域全体の河道網や降雨-流出機構を表現するモデルとして、表層土壌の飽和・不飽和流動モデルを組み込んだ分布型モデルを構築した。モデルは①表層の一次元飽和・不飽和浸透流、②表層の二次元飽和側方流、③二次元地表流動、④河道の一次元不定流モデルで構成した。構築したモデルにメモリ分散型の並列計算を適用し、リアルタイム予測へ向けて計算高速化を図った。

対象流域および対象洪水は、前章のケーススタディ①と同様に、大淀川流域の樋渡地点流域における 4 洪水とした。流域を一辺約 500m の非構造格子でモデル化し、対象 4 洪水によ

りモデルのキャリブレーションを行った。

流域内のリアルタイム観測水位データを用いて、粒子フィルタによる状態量の同化手法、および計算結果に対して現時刻の観測水位と計算水位との差分を補正值として加えるスライド補正を適用した。粒子フィルタの粒子数は 96 とし、フィルタリングは 1 時間ごとに行った。モデルの初期条件は、モデル状態量（土壌水分率）にランダムなノイズを与えることで作成した。粒子フィルタを適用した予測計算精度は、スライド補正に比べ、予測時間が長くなるほど優位となった。一方で水位の急な立ち上がり部分などモデルの乖離が大きい部分では、粒子フィルタでは十分に追従できない場合が見られた。

（４）各種水位予測モデルの精度比較

前章までに開発したモデルを含め、各種の河川水位予測手法について、大淀川水系を対象に精度比較を行った。比較対象は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 水位予測、④相関モデル、⑤深層学習モデルである。各予測時間で、深層学習モデルは最も高精度であり、次いで ANN（3 層）となった。線形回帰モデルは、3 時間予測までは分布型を上回る精度であったが、長い予測時間では精度が低下した。分布型+粒子フィルタは、5,6 時間予測では深層学習・ANN（3 層）に次ぐ精度であったが、短時間の予測では精度が劣った。また分布型+スライド補正は、短い予測時間では粒子フィルタを上回る精度を示したが、長い予測時間では精度が低下した。

短い予測時間までは、上流水位観測所の影響が強いため、これらを入力データに用いている統計モデルが有利と考えられる。一方、予測時間が長くなると降雨・流出の表現が重要となるため、物理型のモデルが有利になるものと考えられる。以上のように、手法によって予測時間ごとの精度が異なっているため、今後は目標とする予測時間や精度に応じて適切な対応策を用いることが重要である。

（５）深層学習と物理的手法のハイブリッド水位予測の開発

前章までに、深層学習モデルの高い精度を確認したが、一方で期間最大洪水では精度が落ちる課題が残されていた。本章では、大規模洪水時における深層学習モデルの精度向上を目的として、物理型モデルとのハイブリッド水位予測手法を開発した。

はじめに、貯留関数モデルやタンクモデルにおける流出理論の分析により、現時刻から数時間先の水位変化は、降雨量よりも流域の水分貯留量の変化に強く依存するものと仮定した。そこで深層学習モデルの入力層に、雨量の代わりに水分貯留量の変化に相当する値（有効雨量－流末からの流出量）を用いるモデルを考えた。

提案したモデルを、大淀川水系の樋渡地点の流域に適用した。流末からの湧出量として、学習時には実測データを、予測時には物理モデルによる流出計算結果を用いた。予測に用いるネットワークは 4 層の階層型ネットワークとした。対象 4 洪水の精度評価はクロスバリデーションによって行うものとし、学習回数などの条件設定はケーススタディにより決定した。

計算の結果は、前章までに検討した通常の深層学習モデルを上回る精度となった。特に課題となっていた期間最大洪水において精度が向上した。他の検討対象洪水についても、通常の深層学習モデルと同程度以上の精度であった。なお期間最大洪水のピーク付近は、降雨量は大きいものの、貯留量変化（雨量－流出高）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。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ものであった。