

# 高度情報処理技術の河川流量ハイドログラフの特徴抽出に関する研究

長岡技術科学大学 環境社会基盤工学専攻 非会員 ○森山諒  
長岡技術科学大学 環境社会基盤工学 正会員 細山田得三

## 1. はじめに

土木分野での人工知能 (AI) の研究は盛んになりつつあり, その中でも水工学の分野では, 災害予測, 予測降雨の修正, 水質予測, 気象データの高度化, 風速の短時間予測, 画像による植生判別, ダム操作の効率化」などがあげられる. 河川内の水位や流量がある時間から先にどのように変化していくかを予測することは, 施設整備レベルの限界が認識された今日において, 洪水から身を守るために極めて重要な情報源となる. 従来の洪水予測は時間発展を計算するという数値実験 (数値シミュレーション) の形態をとっていた. 数値実験を正しく実施するためには, 様々なパラメータが正しく与えられることが前提であり, それがわからない場合はパラメタリゼーション等と称してバルクな係数で全体を覆ったり, 試行錯誤によって実測結果との整合をとるような工夫がなされてきた. そのため, 数値実験による洪水予測計算の信頼性が損なわれることになると考えられる. 近年導入されてきている人口知能の技術は因果関係という物理的な内部機構に拘泥することなく, 単純に雨が降ってある程度時間がたてば河川の水量が上昇するということがデータとして担保されていれば, その定量的なモデル化を計算機に委ねることができる. そのため人間介入することによって生じる恣意性を排除することにより逆に信頼性を増すことが可能となる. 実際に流出機構に関わる情報について人間はどこまでも知りつくすことはできない. 透水係数の空間分布などがその例である. このような物理モデルに含まれる不可知なパラメータ群を, いったん捨象して単純に過去の入力情報と出力の関係を追うことによって, 定量的に洪水予測を行うことが可能となる. AI は従来の予測技術を補完するにとどまらず, 標準技術として確立していく可能性があると考えられる. 本研究では, 国土交通省信濃川河川事務所が拝借した流量・水位データを用い, 気象庁のアメダスの気象データを入手してこれらを用いて河川の水理



図-1 流量, 水位データの観測

データがどのように説明されるかについて検討を行った. 本研究で使用した深層学習用フレームワークは Python で書かれたニューラルネットワークライブラリの Keras である. Keras の裏で実行されている本体は Google が社内で使用している数値計算のライブラリをオープンソース化した TensorFlow である.

## 2. 本研究に用いた流量, 水位, 気象データ

図-1 には今回使用した流量, 水位データの観測点の概略を示す. 各計測点の特徴は以下の通りである.  
**渡部:**大河津分水路内部であり, 信濃川本川から大河津可動堰で分派している. 河川減水期では信濃川本川への流量確保のために流量が減少する.  
**長岡:**分水路分派点より上流であり, 平常時や出水時において大河津の全流量に近い流量が流下する. JR 東日本の山本山発電所の放流水とその影響を緩和する妙見堰の影響を受ける.

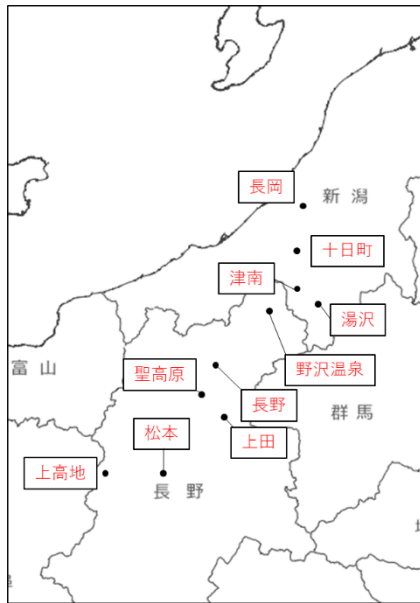


図-2 流量データの観測点

**小千谷**：山間部を流れる信濃川本川と魚野川の合流点よりもやや下流で、山本山発電所の影響を受ける。新潟平野に流れ込む扇状地の上流端であり、信濃川の治水上の基準点である。

**十日町**：河川減水域であり、宮中取水ダムの影響を受ける。

**宮野原**：宮中取水ダムより上流で、さらに上流の東京電力の西大滝ダムの下流に位置する。山間部を流れ、平均河床勾配が他の計測点に比べて大きい。

平常時の信濃川の流量は発電による取水と放流という人為的な影響が表れているが、ある程度大きな出水状態になると堰の機能がなくなるため自然状態と同等になるものと思われる。

流量観測データは、国土交通省北陸地方整備局信濃川河川事務所によって計測されたものを借用した。実際には流量の値は毎正時の水位データを水位流量曲線によって流量に変換されたものである。行政機関が公表する正式な値は水位流量曲線の経年変化も含めて検討され承認されたものであり、それらが流量年表等に掲載される。本研究では一部未確定のものも含まれているが、そのような変動は軽微であり、研究には大きな支障にならないものと判断した。

収集したデータはアメダスの気象データであり、その期間は、2017年1月1日から2018年12月31日の2年間である。対象とした地点は、信濃川中流域における流量に関係があると思われる図-2に示す長

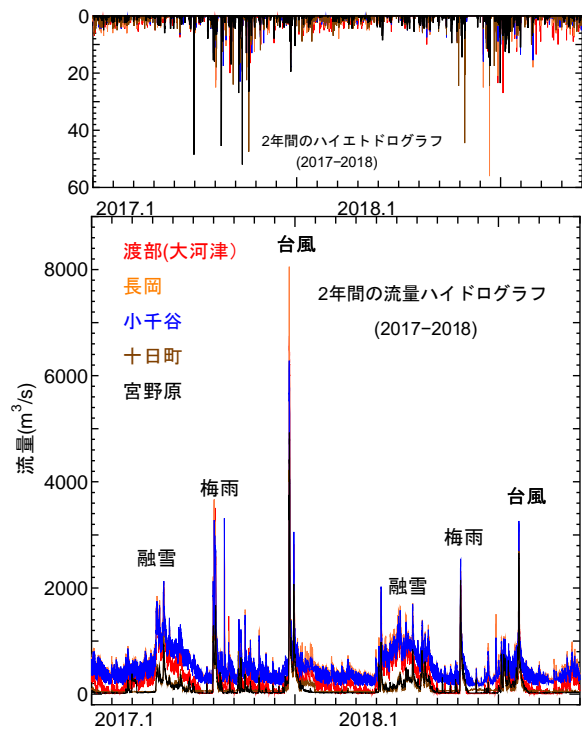


図-3 時系列データ

岡, 十日町, 湯沢, 津南, 野沢温泉, 長野, 聖高原, 上田, 松本, 上高地の10地点である。

図-3には2年間(2017/1/1~2018/12/31)にわたる各流量観測点と降水量の時系列を示す。流量データでは、豪雪地帯を流域に持つ信濃川の特徴である融雪出水が春から初夏にかけて長期にわたって定常的にみられる。また梅雨と単発的な台風による出水がみられる。2年とも最大の出水は台風であることがわかる。上段に示す降水量は降雪を含んでいないことがわかり、融雪出水と降水量の関係は無関係であることが想定される。梅雨期では降水と出水が短時間ではあるが明確であり、深層学習の教師データとして採用可能であると思われる。

### 3. 流量のスペクトル解析による特徴抽出

信濃川の特徴として発電による取水と発電後の放水があり、特に小千谷よりも下流はその影響がある。そのため各流量のデータ2年間分をスペクトル解析して周波数依存性を調べた。1点の観測あたり16384個のデータを用い、FFTによってパワースペクトルを求めた1時間のデータの2年分は17520個であり、データをずらすと1137回のFFTを実施できる。1137回分の各周波数成分の平均値をパワースペクトルとした。その結果、図-4に示す通り、小千谷、長岡、




図-4 流量のパワースペクトル (2年間)

渡部には1日周期およびその倍周期の変動成分がみられ、これは発電所の放水影響とみられる。十日町や宮野原流量データにはそのような変動成分は見られない。時系列を拡大して減水時(2017年1月下旬から2月上旬)の時系列を見ると、小千谷や長岡ではその影響が明確に表れている(図-5)。また、渡部の流量は長岡の流量に比べて200~300m³/s小さく、信濃川本川への分派による低減が見られる。

#### 4. 流量予測

本研究では前述した地点での流量、水位、気象データの梅雨の期間(2018/6/1~2018/6/10)の1時間ごとのを入力データとして、渡部の流量を出力とするニューラルネットワークを構築した。中間層はそれぞれのニューロン数を1000, 800, 100個の3層として、合計5層のニューラルネットワークによって学習を行った。

また、学習データを全データの7割として学習を行い、学習回数(Epoch)を300回とした。また学習に用いた活性化関数は入力した値が0以下の時0になり、1より大きいときに入力をそのまま出力するReLU関数(Rectified Linear Unit, 正規化線形関数)を用いた。最適化手法としてはSGD(Stochastic Gradient Descent, 確率的勾配降下法)の改良版であるAdam(Adaptive moment estimation)を用いて、誤差関

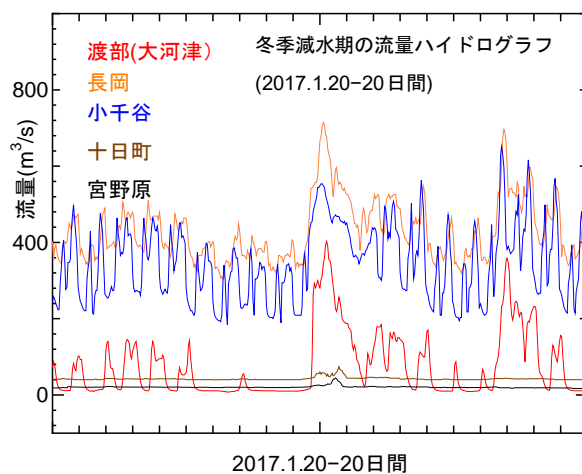


図-5 減水時のハイドログラフ

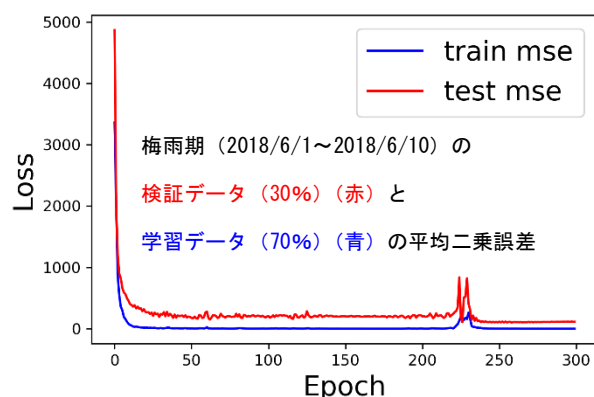


図-6 使用したデータの学習データと  
検証データに対する誤差

数は平均二乗誤差(Mean Square Error : MSE)を用いた。学習が終了した後、残りの3割を検証データとして検証を行った。学習の過程は学習データに対する誤差と検証データに対する誤差を図-6で示す。

また、今回学習したモデルに検証データをあてはめてどれだけ予測できたかを示したグラフを図-7に示す。これらの結果から今回は検証データに対しておおよその予測ができるということがわかった。しかし、ここまで精度が良かった理由として考えられるのは、梅雨という限定された期間に対して恒常的に雨量が多く、直接流量に影響しやすい期間を選択したためであると考えられる。突発的に雨量が急激に大きくなる台風の時期や雨量の影響が小さくなり、融雪出水の多い春先などではあまり精度が良くなかった。また、ほかに考えられることは、6/1~6/10という短い期間で学習を行ったためであると考えら




図-7 使用したデータの予測データと検証データの比較

横軸は時間進行に対応

れる。また、期間を1か月以上などの長期間の学習をした場合、全体として誤差が大きくなった。さらに期間を長くした場合、誤差が収束せず、学習の回数を重ねるごとに誤差が大きくなった。

## 5. まとめと考察

今回の研究は対象地点の流量データ、水位データ、アメダスの気象データを収集し、流量データに対してスペクトル解析を行うことによって小千谷、長岡、渡部には1日周期およびその倍周期の変動成分がみられ、発電所の放水影響を捉えることができた。

また、ニューラルネットワークを用いることで収集したデータから梅雨期の渡部の流量を予測することができた。今回の予測では梅雨期のみでの予測であったため、精度が高まったが、他の期間での精度を高めていくことが今後の課題となると考える。

スペクトル解析の結果から、発電所の取水と放水に関連する時系列データを入力データに組み込むことで更なる精度の向上につながるのではないかと考えられる。また、融雪出水に対しては、春先の流量が多くなっている時期の積雪データ等を組み込むことで融雪に対する因果関係を明らかにすることができ、学習の精度の向上を図れるのではないかと考えられる。

また、2年間という長期間の時系列データを活かすために、今回使用した多層のニューラルネットワーク (Deep Neural Network:DNN) だけではなく、時系列のための時間的な動的振る舞いを示すことができ

る回帰型ニューラルネットワーク (Recurrent Neural Network: RNN) を用いることも視野に入れていく必要があると考えられる。

また、これらをすべて取り入れたうえで、全期間での高精度の予測が可能となれば、近年の突発的な降雨などに対しても高精度な洪水予測を行うこともできるのではないかと考える。

## 謝辞

本研究を進めるにあたってデータを提供してくださった国土交通省信濃川河川事務所の室永武司所長、親松康義様、調直係長に感謝申し上げます。

## 参考文献

- 1) 吉田均, 野村泰稔, 広兼道幸, 一言正之, 小田和広, 秋山孝正, 宇津木真司: AIのインフラ分野への応用, 電気書院, pp63-81, 2019.
- 2) 竹縄知之, 深層学習入門, <http://www2.kaiyodai.ac.jp/~takenawa/learning/>, 最終閲覧日 2019.9.27.
- 3) 我妻幸長: はじめてのディープラーニング, SB Creative, 2018.8.30, 320pp.
- 4) 林正, 浜田正則: 新体系土木工学1, 数値計算法, 技報堂出版, 1983, 249pp.
- 5) 大重美幸, Python3 入門ノート, ソーテック社, 2017, 415pp.
- 6) Tariq Rashid, 新納浩幸訳, ニューラルネットワーク自作入門, ルナテック, 2017, 271pp.