

深層学習によるダム流入量から降水量の推定のための基礎的検討

長岡工業高等専門学校 正会員 ○込山 晃市
 学生会員 武樋 力
 正会員 山本 隆広

1. 背景と目的

春先の融雪流出は有用な水資源であるとともに、災害の要因ともなるため、冬季間の降雪による積雪量を把握することが重要である。降雪量の測定は地上降水量計やレーダー観測などにより行われているが、風や雲などの影響が大きい山岳域においての観測精度は十分とは言えない。現在、融雪流出量の推定に様々な水文モデルが用いられているが、冬季山岳域では観測が不十分なうえに地上降水量で計測された降雪量に対して降水量計周辺の風速により捕捉損失を補正する係数の経験的な設定、地域の特性を加味した試行錯誤的なパラメータの設定を行う必要がある。そこで深層学習では複雑な物理的過程をブラックボックスとして扱うことができる点に着目し、本研究ではダム流入量から降水量を推定する深層学習モデル構築とデータセットの作成方法についての検討を行った。

2. 使用データ

本研究では新潟県南魚沼市にある三国川ダム上流域 (76.2 km²) を対象とし、複数の地点データから流域平均降水量、流域平均気温を作成し、観測ダム流入量とあわせてそれぞれ1時間毎の値を用いて4種類のデータセットを作成した。表1にそれぞれのデータセット内容を示す。なお、学習期間は1997年から2016年、検証期間は2017年としている。

3. 研究手法

本研究の最終目標としては融雪期のダム流入量から積雪量を推定し、冬季の降水量を補正する手法を確立することである。本研究では11月から2月を「降雪期」、3月から6月を「融雪期」、7月から10月を「夏季」として分類している。まず夏季のダム流入量から降水量を計算する深層学習モデル（夏季モデル）を構築する。この時、夏季のダム流入量は降雨によるもののみであり、観測降水量においても降雨のみである。融雪期のダム流入量は主に降雨と融雪によるものであるが、観測降水量は降雨のみである。ここで、夏季モデルに融雪期のダム流入量を入力することで算出される計算降水量は降雨と融雪であるとし、計算降水量と観測降水量の差分の合計を融雪期の積算融雪量と仮定する。その積算融雪量から冬季の降雪量及び積雪量の推定が可能ではないかと考えている。

そのための基礎的な研究として、夏季のダム流入量から夏季の降水量を推定する「夏季モデル」の構築と適切なデータセットの作成方法に関する検討を行った。推定された計算降水量と観測降水量の誤差をMAEとRMSEにより評価し、更に計算降水量を流出モデルで計算したダム流入量と観測値の積算流出量を比較する。

表1 作成データセット一覧

DataSet No	Input Value	Result(Answer) value	Number of Data
1	観測ダム流入量 1時間値	流域平均降水量 1時間値	Training:59040 Validation:2952
2	観測ダム流入量 1時間値 + 流域平均気温 1時間値		
3	観測ダム流入量 1時間値 × 24時間	流域平均日降水量	Training:2460 Validation:123
4	観測ダム流入量 1時間値 × 24時間 + 流域平均日気温		

キーワード 深層学習 降水量推定 流出モデル

連絡先 〒940-8532 新潟県長岡市西片貝町 888 番地 長岡工業高等専門学校 教育研究技術支援センター 第5技術グループ

TEL : 0258-34-9283 Email : komiyama@nagaoka-ct.ac.jp

4. 結果

一つのデータセットに対して、様々なパターンの深層学習モデルで流域平均降水量を推定し、流出モデルによって計算されたダム流入量を表2に示す。ただし、ここでは推定された降水量の誤差評価の結果、各データセットにおいて最も誤差の小くなったモデルの結果のみを示す。また、検証期間の2017年8月1日から16日までの流入量の推移を図1に示す。ここで、図表の Q_{obs} は観測ダム流入量、CTLは深層学習モデルに入力した正解値の降水量と、それによる計算結果である。データセットNo.3,4については入力値が時系列データであるため、RNNモデルとの比較のためにNo.3では2種類のモデルについての結果を示す。

4.1 流域平均降水量の誤差評価

表2(1),(2)からNo.1,2とNo.3,4を比較したとき、入力値として気温を加えたほうが誤差は小さくなっており、気温による影響が確認された。No.1,2よりNo.3,4の誤差が小さく、No.3では、RNNモデル(307)で誤差が小さくなることから、誤差評価としては入力値を時系列変化させたほうが優位であると考えられる。しかし、表2(3)(4)よりNo.3,4のほうが積算降水量をCTLよりも過小に推定しておりNo.2ではほぼ同程度の値となった。No.3,4は出力値が日降水量であるため、流入量の変化が急激になるような場合でも、1日の中で平均化されるような推定を行ったことで、全体的に過小傾向となったと考えられる。

4.2 ダム流入量での評価

表2(5)(6)から積算ダム流入量と Q_{obs} を比較すると、すべての結果において過小に計算されていたが、CTLによる計算結果も実測値より低かったことから、CTL自体の降水量が不足している可能性が示唆された。そこで、表2(7)のCTLと比較したとき、モデル102での計算結果がCTLとほぼ同量の計算結果となった。図1より、ダム流入量の波形から、低水時は各モデル結果においてCTLよりも良好な計算結果ともいえるが、ピーク値ではCTLのほうが優れている。102,201モデルでは連続的なダム流入量の増加に対して連続的に降水があると推定しており、減水時の降水が無い時間帯に降水があると推定していることで、最終的な積算ダム流入量は比較的近い値となったと考えられる。302,307,401モデルでは1日分の降水量を推定し、それを1時間毎に与えて計算しているため、局所的な降水を再現することができず、流出モデルでの表面流出量の減少や時間変化に伴うダム流入量の波形の再現性を表現できない点については予想通りであったが、推定された降水量の過小傾向の影響から積算ダム流入量も小さく計算されており、降水量の誤差評価とは異なる結果となった。また、表2(4)(7)からRNNモデルでは降水量と積算ダム流入量のCTL比の減少がほとんど無いことから、降水量の変化パターンの再現度は全結合モデルよりも高かったと考えられる。

5. 最後に

MAEやRMSEを用いた誤差による評価だけでは降水量の推定値の良否判断は不十分であること、ある程度のモデル構成パターンの把握ができたことなど、深層学習活用のための様々な知見を得ることができた。今後もこれまでと異なるアプローチ手法による新たな発見と深層学習活用の可能性を模索したい。

表2 評価結果

DataSet-No	1	2	3		4
Model-No	102	203	302	307	401
(1) MAE	0.631	0.602	0.374	0.309	0.303
(2) RMSE	1.226	1.213	0.574	0.491	0.485
(3) 積算降水量 CTL=1582(mm)	1659	1584	1504	1358	1346
(4)CTL比(%)	104.9	100.1	95.1	85.8	85.1
(5) 積算ダム 流入量(mm)	1416	1362	1293	1211	1205
(6) Q_{obs} 比(%) CTL/ Q_{obs} =86.5	86.6	83.3	79.1	74.1	73.7
(7) CTL比(%)	100.1	96.3	91.4	85.6	85.2
モデル備考	全結合	全結合	全結合	RNN	RNN

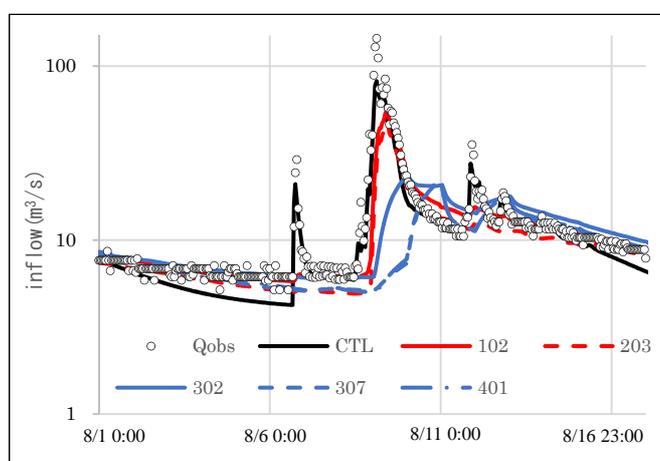


図1 ハイドログラフ (2017年8月1日から8月16日)