

機械学習を用いた貯水池への流入濁度の予測とアンサンブル降雨予測活用の検討

Prediction of Turbidity Inflow into Dam Reservoir with Machine Learning and Application of Ensemble Rainfall Forecast

○古家 諒也・Sameh A. KANTOUSH・Vahid NOURANI・小林 草平・小柴 孝太・角 哲也
 ○Ryoya FURUIE・Sameh A. KANTOUSH・Vahid NOURANI・Sohei KOBAYASHI・Takahiro KOSHIBA・
 Tetsuya SUMI

This study develops a machine learning-based model to predict turbidity inflow into a dam reservoir using real operational data from the Miwa Dam. A FFNN model was developed with observed hydrological and turbidity data, accounting for multiple input variables and different lead times. The model outperformed conventional rating-curve methods. Ensemble rainfall forecasts were integrated to generate probabilistic discharge and turbidity predictions. Results demonstrate the model's capability to support the operation of a sediment bypass tunnel. The proposed framework enhances adaptive and reliable reservoir sediment management (86 words).

1. はじめに

気候変動や電力需要の増大によりダムの重要性が高まる中、長期的な運用には貯水池の堆砂対策が不可欠である。対策の一つに、出水時に流入する土砂を、貯水池を迂回して流下させる「土砂バイパストンネル」(以後 SBT)がある。浮遊砂を流下対象とする SBT は、主に観測流量に基づき運用されるが、流量と浮遊砂濃度(以後 SSC)は必ずしも一対一に対応しないため、SSC の予測により SBT の運用効率を向上させられる可能性がある。本研究では、SSC の観測指標である濁度の予測を、非線形挙動を表現できる機械学習モデルにより試みた。また、近年の研究でダム運用高度化への活用が検討される JWA アンサンブル降雨予測を組み合わせ、アンサンブル濁度予測を検討した。

研究対象には、天竜川水系三峰川に位置する美和ダム流域を選定した(流域面積は 311 km²)。中央構造線の影響により土砂生産量が多く、2005 年から SBT が、2021 年からはストックヤード(SY: 浚渫した土砂を溜めておき、出水時に SBT から流下させるための施設)が運用されている(図-1)。

2. 研究手法

濁度データは、貯水池流入地点の飯島堰堤に設置された濁度計の観測データを用いた。機械学習モデルは Feedforward Neural Network(以後 FFNN)を採用し、濁度と相關の高い入力変数の組み合わせを複数試行して、より精度の高いモデルを構築した。なお、FFNN の出力は 1 時間後の濁度とし、

得られた出力を次の予測の入力に用いて複数時間先予測を行った(図-2)。データは、4 イベントをテスト、残りの 16 イベントの 70%を学習、30%を検証データとした。評価には RMSE や NSE を用い、従来の SSC 推定式である Rating Curve ($y = a Q^b$) と比較した。また、得られた FFNN モデルに対し SHAP 手法を適用し、感度分析を行った。

JWA アンサンブル降雨予測は、全 51 メンバーに加え、最大 24 時間累積雨量に基づいた 3 グループ(上位: 1~5 位、中位: 6~15 位、下位: 47~51 位)を用意し、RRI モデルに入力して流出解析を行った。また、雨量と流量の予測値を FFNN に入力することで、アンサンブル濁度予測を行った。

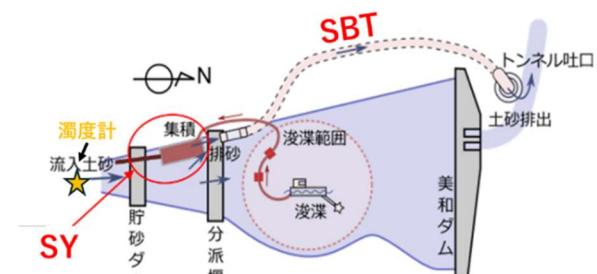


図-1 美和ダムの堆砂対策施設

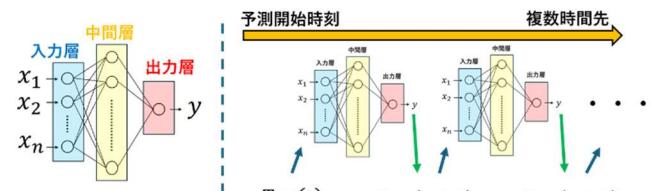


図-2 FFNN の構造と複数時間先予測の方法

3. FFNN モデルによる濁度予測

表-1に、試行した入力変数の組み合わせとその結果を2通り示す。また、図-3、図-4に入力変数②の結果を示す。複数時刻先の予測では精度は減衰するものの、ピーク値などの観点からRating Curveよりも高い精度が確認された。

SHAPによる感度分析の結果、1時刻前の濁度($Tur(t)$)が出力結果に対して正の方向に最も大きな影響を持つ場合が確認された。また、1時刻前の流量($Q(t)$)は負の方向に影響を示したことから、流量の上昇・下降によってモデルの応答が変化し、濁度の履歴効果が表現された可能性が示唆された。

表-1 FFNN による濁度 $Tur(t + 1)$ の予測結果

	入力変数	学習	検証	テスト
①	$Tur(t)$	RMSE [ppm]	439	317
	$Tur(t - 1)$		405	
	$Q(t + 1)$	NSE		
	$Q(t)$		0.93	0.96
②	$Tur(t)$	RMSE [ppm]	449	323
	$Tur(t - 1)$		380	
	$Q(t + 2)$	NSE		
	$Q(t + 1)$		0.93	0.95
	$Q(t)$			0.94

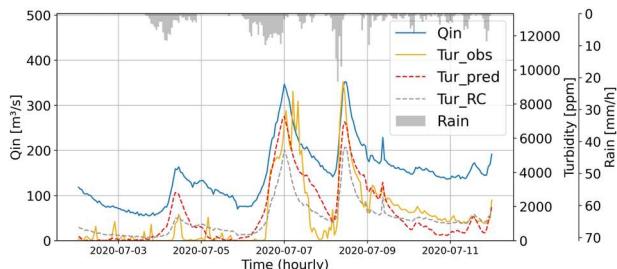


図-3 学習出水に対する複数時刻先予測の結果

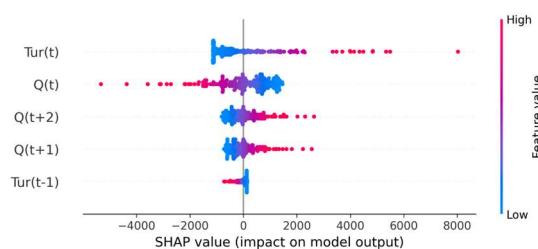


図-4 SHAP による FFNN 感度分析の結果

4. アンサンブル流量・濁度予測

2023年6月2日の出水を対象に、RRIモデル、及び入力変数②のFFNNによる予測を行った(図-5)。約3日前(5月30日21時)の予測では、上位予測が実測流量に近い値を示した。濁度の予測では、ピーク値は過小評価であるものの、流入濁質量の総量では上位予測により実測に近い結果が得られた。また、流量と濁度を時系列につないだヒステリシスループでは、時計回りのループが確認され、FFNNにより流量と濁度の履歴効果を表現できている可能性が確認できた(図-6)。

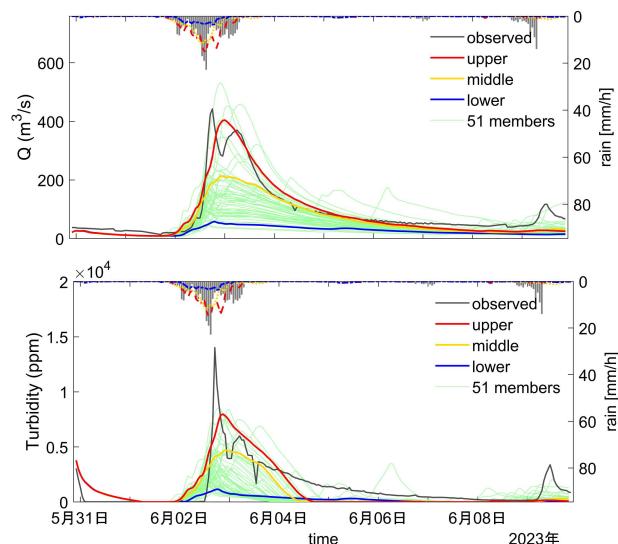


図-5 アンサンブル Q (上)・濁度 (下) 予測

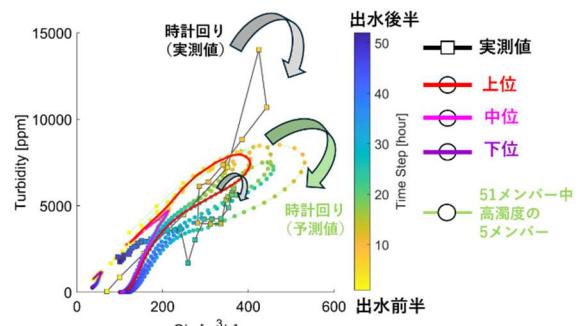


図-6 予測の Q-Tur ヒステリシスループ

5. 結論

入力変数を選定したFFNNモデルにより、Rating Curveよりも高い精度での濁度予測が可能になった。アンサンブル降雨予測により、流量や流入濁質量の予測が可能になった。履歴効果の再現も確認できたことから、SBT等の運用タイミングの判断にも活用が期待される。今後、異なる機械学習モデルの適用などにより、モデルの精度向上の可能性も期待される。