

ダムの安全管理における計測データを用いた AI による異常検知の検討

国土交通省 国土技術政策総合研究所 正会員 ○二階堂 良平 小堀 俊秀 金銅 将史

1. はじめに

わが国の管理ダムでは、目視等による点検と併せ、様々な計測データを継続的に取得・活用してダムの安全管理が行われている。これらデータの計測が行われる日常点検、地震後等の臨時点検、原則3年ごとの定期検査、30年程度経過したダム等を対象に行われるダム総合点検などでは、計測データに見られる通常又は既往とは異なる傾向や変化から、ダムの状態に何らかの変化が生じ、詳細な原因の調査や監視の強化、対策の検討などが必要と判断されることがある。しかし、ダム管理の現場からは、このような判断を行う上で、安全管理データに対する具体的な管理基準が明確でないといった技術的な面での異常有無の判断の難しさを挙げる声のほか、ダム管理者の知識・経験値により判断に差が出るといった声も聞かれる。管理ダムの数が増える中、全てのダムを経験豊かな職員で維持管理していくことが難しくなっている現状が窺われる。

本研究は、このような現状に対し、安全管理データに基づく異常有無の判断をダム管理者が的確に行うことを可能とするための支援技術としてAIの活用可能性を試行的に検討したものである。ダム施設の異常検知を目的に、ダムで大量に取得・蓄積されている各種時系列データを学習させ、その予測モデル構築を試みた。

2. 手法および結果

2.1 試行対象データ

予測計算の試行対象は、堤高119mの重力式コンクリートダムの堤体変形量（プラムラインでのダム上下流方向変位の計測値（以下、変形量とする））とした。

2.2 予測モデルの構築

本研究では、AIによる分析技術として利用が広がり、データが持つ特徴量を自動的に抽出できる深層学習（Deep Neural Network）に着目した。中でも、中間層の出力を次のステップの入力の一部とすることで時系列を扱えるようにした再帰型ニューラルネットワークがあるが、その発展形として、情報の取捨選択機能があるゲートを有し、時系列が持つ長期依存性の効率的な

学習を可能としたLSTM（Long Short-Term Memory）に着目した。本研究では貯水位変化や温度履歴の影響など長期依存性を持つ可能性のあるダムの計測データを扱うため、このLSTMを用いることとした。

LSTMを用いた予測モデル（以下、LSTMモデル）の入力条件を表-1に、概要図を図-1に示す。変形量の説明変数は貯水位、外気温、堤体温度とした。なお、コンクリートダムの変形量は貯水位及び外気温と相関性が高いことが分かっているが²⁾、建設時に水和熱で上昇した対象ダム堤体内の温度が現在も低下中のため、計算期間の変形量には堤体温度低下による影響もあると考え、本試行では堤体温度も説明変数とした。

LSTMモデルの過去データ入力期間（長期記憶として考慮する期間）は、後述する重回帰モデルによる変形量予測において、外気温からの時間遅れを1ヶ月程度とした場合に予測精度が高かったことを踏まえ、過去28日（4週間）とした。また、LSTMモデル構築にあたっての学習および検証は、得られているデータのうち、表-1に示す期間のデータを用いて行った。

表-1 入力条件

目的変数	説明変数	計算期間
上下流方向 プラムライン (変形量)	貯水位	○学習期間 (7年8ヶ月) 2011.12.30~2019.8.31
	外気温 堤体温度 (過去28日)	○検証期間 (0年9ヶ月) 2019.9.1~2020.5.31 ○予測期間 (0年6ヶ月) 2019.6.1~2020.11.30

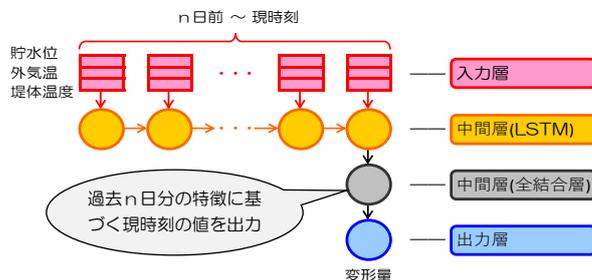


図-1 構築した LSTM モデルの概要

2.3 堤体変形量の予測結果

LSTMモデルによる変形量予測の結果を図-2に示す。比較のため、同図には変形量予測の従来手法として重回帰モデルによる予測結果も示した。重回帰モデルの

キーワード 深層学習、再帰型ニューラルネットワーク、LSTM、変形量、異常検知

連絡先 〒305-0804 茨城県つくば市旭1番 国土交通省 国土技術政策総合研究所 TEL 029-864-8173

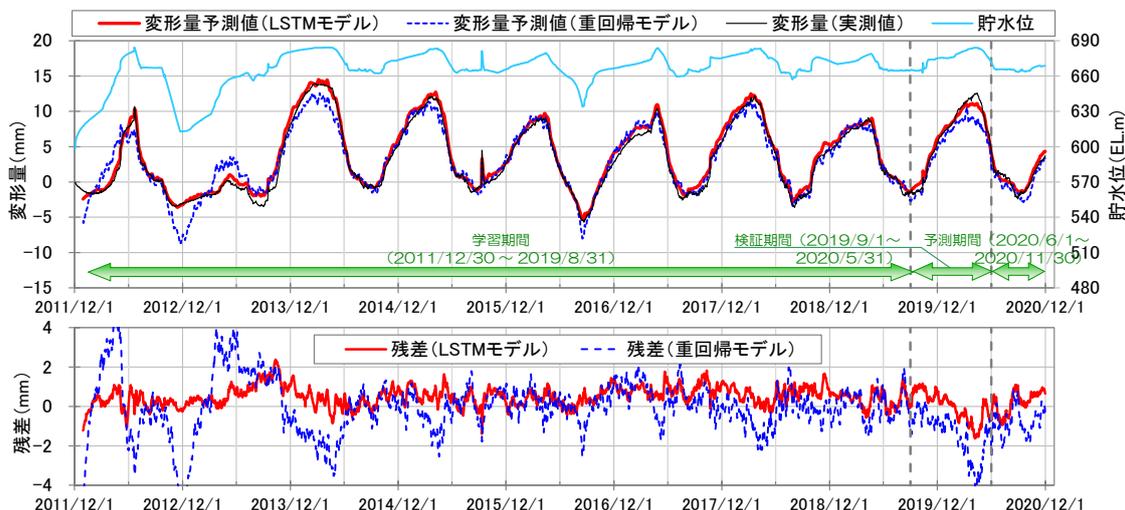


図-2 変形量予測結果（上：変形量の予測値と実測値の推移、下：実測値と予測値の差）

分析期間は LSTM モデルでの学習期間，説明変数は LSTM モデルと同一である．図-2 より，LSTM モデルによる予測値は実測値の変動をよく表現できており，実測値との差は概ね 1mm 以内である．また，重回帰モデルによる予測値より全体的に実測値との差は小さく，特に実測値の変動のピーク部の予測精度は LSTM モデルの方が良い結果を得た．以上より，変形量について，LSTM モデルを用いて精度の高い予測ができる見通しが得られた．

2. 4 異常検知手法の検討

上記の結果から，LSTM を用いることにより，重回帰モデルのような従来手法と同等以上の精度の予測モデルを構築可能と考えられる．さらに，貯水位等の説明変数に対してある程度の関係性や季節変動などの周期性を持つと考えられる計測データについて，そのパターンを十分に学習させることで，実測値との乖離から異常検知の判断支援に活用可能なモデルへと発展できる可能性がある．一例として，2. 3で示した LSTM モデルでの変形量予測の試行結果に対し，実測値との差の標準偏差 σ の2倍（ $\pm 1.45\text{mm}$ ）を閾値とした異常判定の案を図-3 に示す．今後の計測で計測値が閾値を超える場合や経時的にシフトする傾向があれば異常と判定されることとなる．なお，異常判定の閾値は，今後データを積み重ねて検討する．

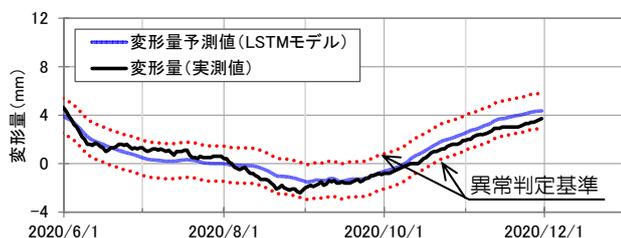


図-3 変形量データに対する異常判定案

3. LSTM をダムの安全管理における判断支援に活用する際の優位性と留意点

LSTM はその特徴や上記の試行結果から，ダムの安全管理における計測データに基づく異常検知への活用の際に，変形量に対する外気温の影響等，時間遅れを有すると考えられるもののその程度が不明確な場合でも，ある程度の過去データを学習させることで，自動的に時間遅れを考慮した予測値が得られる可能性がある．

一方，留意点としては次の点がある．①計測間隔が不規則なデータや欠測を含むデータは直接適用するのが困難であり，適切な前処理が必要となる．②学習データが限られると過学習を起こしやすいため，可能な限り多様な条件下での多くのデータが得られていることが望ましい．③予測精度を高められる反面，LSTM モデルには膨大な数のパラメータが含まれ，中身がブラックボックスと言える面もあり，最終的な異常有無の判断は現地状況等を確認した上で行うことが望ましい．

4. 結論と今後の展望

ダムで蓄積された変形量の時系列データを LSTM で学習させた予測モデルを試行的に構築し，当該モデルによる変形量の予測値と実測値を比較した．その結果，従来の重回帰モデルと同等以上の予測精度が期待できる結果が得られた．今後は，更なる精度向上検討や変形量以外のデータでの試行，異なる複数の計測データからの異常有無の判断支援に活用できる予測モデルなど，ダムの安全管理における判断支援技術としてより実務的に活用可能なものとなるよう検討を行いたい．

参考文献

- 国土交通省：ダム総合点検実施要領・同解説，2013．
- 飯田隆一：ダムの安全管理，（一財）ダム技術センター，93-107，2006．