

LSTM Autoencoder モデルによる河川水位観測データの異常検知手法の開発と検証

西田 賢史¹・岡田 治²・田所 正³

¹(一財)河川情報センター 河川情報研究所 研究第2部 研究員

²(一財)河川情報センター 河川情報研究所 研究第2部 主任研究員

³(一財)河川情報センター 河川情報研究所 副所長

河川情報センターでは、全国に配置された多数のテレメータ降水量・水位観測所の観測データを対象に、異常値を自動的に検出するシステムを開発し、令和4年度より24時間体制での精度監視業務を実施してきた。本研究では、従来の 3σ モデルにおいて課題となっていた洪水立上がり時等の誤検出（空振り）を改善するため、時系列データの特徴抽出および自己再構成能力に優れた LSTM Autoencoder（長短期記憶型自己符号化器）を用いた新たな異常検出手法を開発した。正常時の観測データのみを学習させ、再構成誤差を異常スコアとして算出した結果、出水時における急激な水位変動に対しても高い精度で異常値を検出できることを確認した。本手法は、既存の 3σ モデルと併用することにより、異常値検出システムの高度化に資するものと考えられる。

Key Words : 水文観測, 水位観測, 精度監視, 異常値検出, LSTM Autoencoder

1. はじめに

河川情報センターでは、全国に配置された多数のテレメータ降水量・水位観測所の観測データを対象に、異常値を自動的に検出するシステムを開発してきた。¹⁾²⁾³⁾ 令和2年度の河川情報シンポジウムでは、標準偏差などの統計量に基づく 3σ モデルを用いた異常値検出手法について報告し、令和4年度からは24時間体制での精度監視業務として実運用を開始した。この 3σ モデルは、一定期間の平均値および標準偏差に基づいて、観測値が統計的に外れた場合に異常と判定するものであり、非出水時のように水位変動が小さい期間では、突発的なノイズや明らかな異常値を検出するなどの高い信頼性を示した。

一方で、標準偏差などの統計量は、本来、母集団の分布が時間的に一定である静的データに適用することを前提としており、観測値の分布が動的に変化する時系列データに直接適用するのは統計学的に適切とはいえず難しかった。実際、河川の水位データは、非出水時にはほぼ一定量を示すものの、出水時には急激な立上りとピークを有する非線形的な波形を示す。このような動的データに静的統計量である標準偏差に基づく閾値判定を適用すると、立上り期における誤検出（空振り）やピーク付近における検出漏れを抑えることが難しく、実運用上は依然として技術者による目視確認が必要という課題があった。

これらの課題を踏まえ、本研究では、時系列データの時間依存性および非線形的変化を同時に学習できる

LSTM Autoencoder⁴⁾（長短期記憶型自己符号化器）を導入し、水位観測データに対する異常検出精度の向上を図った。学習データを正常時系列に限定し、再構成誤差を異常スコアとして算出したうえで、閾値を0.25とする条件下で検証を実施した。

本稿では、LSTM Autoencoder のモデル構成、学習および検証の手順、異常検出結果の特徴を示すとともに、本手法の水文観測データ精度監視業務への適用可能性についても述べる。

2. LSTM Autoencoder (LSTM-AE) モデルの構成

この課題を踏まえ、本研究では、観測値の時間的連続性と変化傾向そのものを学習することに着目した。

LSTM (Long Short-Term Memory) を基盤とする Autoencoder モデルは、過去の観測系列から正常な変動パターンを再構成できるため、水位の立上がりや短時間の急変といった動的変化を含むデータにも柔軟に対応できる可能性がある。これにより、従来の 3σ モデルで発生していた空振りを抑制し、より安定した異常判定を実現することを目指す。

(1) 入力データと前処理

入力データには、全国の水位観測所から得られる10分間隔の水位観測値を用いた。学習には、明らかに異常値を含まない期間を抽出し、正常時系列データのみを使用した。

入力系列の長さは 72 時点（12 時間相当）とし、時刻窓を 1 ステップ（10 分）ずつずらして学習データを生成した。

各入力データについては、観測値のスケール差を抑えるため、平均 0・分散 1 となるように StandardScaler による標準化を行った。標準化はファイル単位で実施し、各データセットごとにスケーラーを再計算して適用した。これにより、観測点や期間による値のばらつきを軽減し、モデルの学習を安定化させた。ただし、学習時と検証時で同一スケーラーを共有していないため、異常データのスケールリング結果が相対的に抑制され、再構成誤差が小さく評価される傾向がみられた。

今後は、学習データのスケーラーを保存・共通化することで、より厳密な異常判定の比較が可能になると考えられる。

図-1に、時系列水位データからスライド窓により学習データを生成するイメージを示す。このように、波形の立上がりや下降を含む水位変動全体を学習対象とすることで、モデルは時間的依存性を持つ正常変動パターンを再現的に学習できる。




図-1 水位時系列データのスライド窓による学習データ作成イメージ

なお、学習時に用いたこの入力単位（72 ステップの時系列データ）は、以降「推論窓」と呼称し、推論時にも同様の長さで処理を行う。

(2) モデル構造

LSTM-AE モデルの概要を図-2 に示す。

Encoder 部では入力された時系列データを圧縮して潜在空間に写像し、Decoder 部で再構成を行う。

本研究では、Encoder を LSTM（ユニット数 64 および 32）、Decoder を LSTM（ユニット数 32 および 64）の対称構造とし、再構成系列と入力系列の差を学習により最小化させた。LSTM 層の活性化関数にはデフォルトの tanh（ゲートは sigmoid）を用い、損失関数には平均絶

対誤差（MAE）を採用した。出力層は活性化関数なし（線形出力）とし、観測値との再構成誤差を直接評価できるようにした。最適化手法には Adam を使用した。

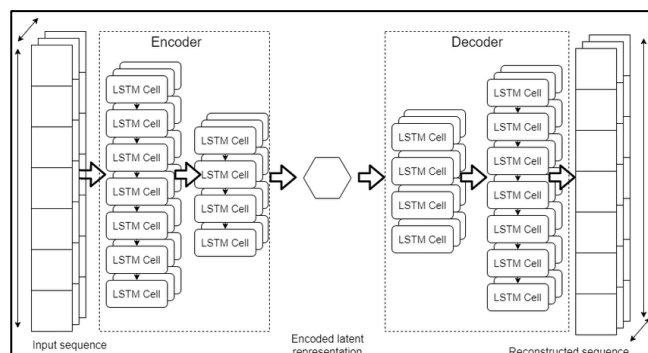


図-2 LSTM-Autoencoder の構成概念図

（出典：ResearchGate「LSTM-Autoencoder Architecture」より）

(3) 学習・検証環境

本モデルの学習および検証は、表-1 に示す比較的標準的な PC 環境（CPU: Core i5-12400, GPU: GeForce RTX 2080, メモリ 16GB）上で実施した。この構成は、近年の AI 学習環境としては中～低スペックに分類されるが、学習・検証を通じて半日以内に全処理を完了できた。

したがって、本モデルは高性能な GPU 環境を必要とせず、一般的なワークステーションでも十分に構築・運用が可能な軽量モデルであると評価できる。

表-1 学習・検証環境

	項目	内容
ハードウェア	CPU	Intel (R) Core(TM) i5-12400
	メモリ	16GB (8GB×2)
	SSD	NVMe SSD (480GB)
	GPU	NVIDIA GeForce RTX 2080 (8GB)
ソフトウェア	OS	Ubuntu 22.04.4 LTS
	CUDA	CUDA 12.7
	Python	Python 3.10.12
	Tensor Flow	Tensor Flow 2.15.1
	Keras	keras 2.15.0
	Library	numpy, scikit-learn etc.

(4) 異常スコアと閾値設定

学習済みモデルに検証データを入力し、推論窓 72 ステップのうち 71 番目の再構成誤差を各時刻の異常スコアとして算出した。

この再構成誤差を異常スコアとし、各時刻のスコアを連続的に出力することで、水位波形全体にわたる異常傾向

を評価した。

異常判定には、再構成誤差 0.25 を閾値として用いた。各時刻における異常スコアがこの閾値を超える場合を異常点とし、そのような異常点を 1 つ以上含む波形を異常波形と判定した。

この閾値は、複数地点の検証結果を比較し、誤検出を抑えつつ異常挙動を適切に捉えられる値として設定したものである。

最終的な出力は、時刻ごとの実測値・再構成値・異常スコアおよび閾値超過の有無を CSV 形式で出力し、波形全体に対する異常判定結果を可視化して確認した。この手法により、時間的連続性を持つ異常挙動を系列単位で抽出することが可能となった。

本研究で使用した LSTM-AE モデルのプログラムは、GitHub 上で公開されているオープンソースのサンプルコードを参考に構築したものである。^{5) 6) 7)}

公開コードを基礎としつつ、学習データ構造や異常スコア出力形式などを本研究の目的に合わせて改良を加えた。

3. 学習検証結果

(1) 学習過程

LSTM-AE モデルの検証には、平成 27 年度（2015 年）から令和 6 年度（2024 年）までの全国の水位観測データを用いた。

学習には同期間のうち、明らかに異常を含まない氾濫注意水位以上に達した 8303 波形を使用し、これらを正常データとしてモデルを構築した。学習率は一般的に安定性の高い 0.001 とし、エポック数 5000、バッチサイズ 256 で学習を行った。

(2) 検証過程

一方、検証データには同期間内で氾濫注意水位以上に至った波形のうち、 3σ モデルおよび目視確認により異常と判断された 187 波形を「異常例」として選定した。

また、同様に氾濫注意水位以上を記録しながらも異常が確認されなかった 231 波形を「正常例」として用いた。

これらの学習データ波形とは別の計 418 波形を用いて、学習済み LSTM-AE モデルの異常検出性能を波形単位で評価した。

異常判定は、再構成誤差（異常スコア）が閾値 0.25 を超える時刻が含まれる波形を「異常波形」とみなすことで行った。閾値 0.25 は、複数の観測点に対して再構成誤差の分布を比較し、実際の異常波形と正常波形の分離が最も明瞭であった範囲をもとに経験的に設定した値である。複数の閾値を試行した結果、0.25 付近で誤検出を抑制しつつ、実際の異常事例を的確に検出できるバランスが得られたため、本研究ではこの値を採用した。

検出結果は波形ごとに異常的中・異常見逃し・空振

り・正常的中の 4 つの区分に整理した。

その内訳を表-2、図-3 に示す。

表-2 LSTM-AE モデルによる検出結果の分類

区分	内容	件数
A 異常的中	実際に異常であり、AI が異常と判定	184
B 異常見逃し	実際に異常だが、AI が正常と判定	3
C 空振り	実際には正常だが、AI が異常と判定	2
D 正常的中	実際に正常だが、AI が正常と判定	229




図-3 LSTM-AE モデルによる検出結果の分類

A) 異常的中例

図-4 に、 3σ モデルでも異常が検出された事例に対して、LSTM-AE モデルが同様に異常を検出した例を示す。




図-4 LSTM-AE および 3σ モデルによる異常検出結果の比較 (異常的中例)

本事例では、観測値と再構成値の乖離が大きくなり、異常スコアが閾値 0.25 を超過する時刻が明確に出現した。

LSTM-AE は時系列のパターンをもとに再構成を行うため、 3σ モデルが異常を検出した区間に加えて、一部の事例ではより早い段階で異常スコアが上昇していた。

これは、 3σ モデルが水位変動の局面（上昇・下降時）において標準偏差が拡大し、閾値が一時的に広がることで異常判定が遅れる傾向を持つのに対し、LSTM-AE は波形形状そのものの逸脱を検出基準としているため、変動初期のわずかな不自然なパターンにも反応できたことによるものである。このことから、LSTM-AE モデルは

統計的外れ値判定を補完し、異常挙動の早期把握に有効であることが確認された。

出水中に発生したスパイク異常を示す。LSTM-AE モデルは 3σ モデルのスパイクフラグと同様に異常を検出している。

B) 空振り例

図-5 に、LSTM-AE モデルが異常と判定したものの、実際には正常な波形であった例を示す。




図-5 LSTM-AE および 3σ モデルによる異常検出結果の比較 (空振り例)

本事例では、水位のピークを過ぎて下降が予想される局面で、一時的に水位が上昇した。この一時的な変動により、再構成値との間にずれが生じ、再構成誤差が増加して異常スコアが閾値 0.25 を超過したため、AI モデルでは異常と判定された。

このように、ピーク後の下降過程における小規模な揺らぎでは、モデルが過敏に反応して誤検出する場合があります。今後はこうした挙動を学習データに反映させることで、より安定した判定が期待される。

C) 異常見逃し例

図-6 に、実際には異常として検出することが望ましい波形であったにもかかわらず、LSTM-AE モデルでは異常判定に至らなかった例を示す。

本事例では再構成誤差 (異常スコア) が全体的に小さく、閾値 0.25 を超える時刻が出現しなかったため、AI モデルは正常と判定した。一方で、 3σ モデルも同様にフラグを立てておらず、結果的に両手法で検出が行われなかった。このことから、変動の振幅が小さい異常や、緩やかな偏差を伴う波形に対しては検出感度が十分でないことが確認された。

このような事例では、LSTM-AE が波形全体の再構成精度を優先しているため、局所的な偏差や短時間の不自然な挙動が誤差に反映されにくい。また、閾値を固定値

として一律に設定していることも、こうした見逃しの要因の一つである。




図-6 LSTM-AE および 3σ モデルによる異常検出結果の比較 (異常見逃し例)

最終的な異常の判断には、AI モデルの判定結果に加え、現場技術者による波形確認と経験的な判断が不可欠である。AI モデルは、こうした微妙なケースを含めた事例を追加学習することで、将来的にはより高精度な検出補助が期待される。

D) 正常的中例

図-7 に、 3σ モデルでは異常と判定されたものの、実際には正常な波形であった事例を示す。




図-7 LSTM-AE および 3σ モデルによる異常検出結果の比較 (正常的中例)

本事例は、水位の変動が比較的急であり、 3σ モデルでは異常と判定されたが、技術者の降雨状況などの確認により最終的に正常と判断された事例である。

この事例では、LSTM-AE モデルにおいて観測値と再構成値が良好に一致し、再構成誤差 (異常スコア) も低水準に保たれており、閾値 0.25 を超過する時刻は出現しなかった。結果として、AI モデルは正しく「正常」と

判定し、誤検出を回避できた。統計的な外れ値判定である 3σ モデルが変動の度合いによっては過敏に反応してしまうのに対し、LSTM-AE は波形形状全体を評価することで安定的な判定を実現している。

この結果から、LSTM-AE モデルは異常検出感度を維持しつつも、平常データに対する誤判定を抑制できる特性を持つことが確認された。

現場での実運用においては、誤警報を減らすことが監視業務の効率化につながるため、このような安定した判定性能は大きな利点となる。

(3) 検証結果のまとめ

本章では、LSTM-AE モデルを用いた異常検出の結果を、 3σ モデルとの比較を交えながら4つの事例（異常的中例、空振り例、異常見逃し例、正常的中例）として示した。

その結果、LSTM-AE モデルは 3σ モデルと同等の異常検出性能を有しており、特に再構成誤差の上昇を通じて異常の兆候を早期に検出することが確認された。

一方で、ピーク後の下降が予測される局面での一時的な水位の上昇など一部で空振りが生じた。また、緩やかな変化を示す異常波形では見逃しが発生するなど、閾値設定や再構成誤差の扱いに課題も見られた。

その中で注目すべきは、 3σ モデルでは異常判定となつた正常波形を、LSTM-AE モデルが正しく正常と判定できた事例が確認された点である。これは、波形全体の時間的パターンを学習する LSTM-AE の特性によるものであり、統計的閾値に依存する 3σ モデルと比べて、より安定した判定を実現できる可能性を示している。

総じて、LSTM-AE モデルは異常の早期検出と誤検出の抑制を両立できる補完的手法として有効である。

ただし、現段階では完全自動判定に頼るのではなく、最終的な異常判断は現場技術者の確認と経験的判断に委ねることが不可欠である。本モデルは、技術者がより迅速かつ的確に異常を把握するための支援ツールとして位置づけられる。

4. 洪水立上がり局面における追加検証

(2025 年 7-9 月)

3σ モデルが立上がり局面に空振りが生じやすいという課題に対し、LSTM-AE モデルで改善できるかどうか検証した。対象は2025年7月から9月のデータから抽出した、立上がりで 3σ モデルで異常と判定されたが、結果として空振りと確認された18波形である。各波形について、 3σ モデルで異常と判定された同一時刻の水位データを、LSTM-AE モデルの再構成誤差（閾値0.25）で再判定した。

その結果、18波形中12波形（66.7%）において、 3σ モ

デルでフラグが立った時刻に LSTM-AE では閾値 0.25 を超過しなかった。これは、LSTM-AE が立上がり局面における一時的な標準偏差拡大の影響を受けず、波形全体の整合性を基準に判定するためである。

一方で、残る6波形（33.3%）では 3σ モデルと同様に閾値超過が見られ、急峻な立上がりを伴う波形を含むケースの一部では依然として誤判定が残ることもわかった。

以上の結果より、LSTM-AE モデルは立上がり局面での空振りを一定程度抑制できることが確認されたが、改善の余地があることも判明した。




図-8 洪水立上がり検証結果



図-9 LSTM-AE および 3σ モデルによる異常検出結果の比較
(2025 年 7 月～9 月 立上がり検証)

5. 考察および今後の展望

本研究では、水位観測データを対象として LSTM-AE モデルを構築し、再構成誤差を用いた異常検出手法の有効性を検証した。その結果、従来から運用されてきた 3σ モデルと遜色のない異常検出性能を示すとともに、 3σ モデルが過剰に反応しやすいケースにおいても、LSTM-AE モデルでは正常と判定できるなど、誤警報の低減効果が確認された。

一方で、LSTM-AE モデルは学習データの範囲に依存するため、学習時に含まれない波形パターンに対しては誤判定や見逃しが発生する場合がある。また、異常スコアの閾値を固定的に設定しているため、地点特性や水位変化の多様性を十分に反映できていないと言える。

3σ モデルは、比較的単純な統計手法による一方で近

隣の観測データも同時に取り入れてチェックするメリットを持つ。LSTM-AE モデルは、学習量に応じてパフォーマンスを向上できるものの、近隣の観測データとのクロスチェック機能は有していない。

このため、これら 2 つのモデルはどちらかを優先するのではなく、リアルタイムデータ監視の現場においては両モデルを併用することによって異常値の抽出精度を高めることが有効である。

いずれにせよ 3 σ モデルや AI モデルの計算結果はあくまで自動抽出による支援情報であり、最終的な異常判断には現場技術者の確認と経験的知見が不可欠である。よって LSTM-AE モデルは、監視業務の効率化と判断支援を目的とした補助的なシステムとして位置づけることが適切である。

今後は、本手法を異常値検出システムへ実際に組み込み、運用現場で効果検証を行うとともに、学習データの追加や、観測所特性に合わせたモデル構築や検出閾値の可能性について検証し、その有効性と適用範囲の拡大を図りたい。

REFERENCES

- 1) 岡田治, 柿沢一弘, 田所正, 中安正晃: AI による洪水予測と水位データの異常検知, 平成 29 年度河川情報シンポジウム開催レポート, 2017.
<https://www.river.or.jp/koeki/events/sympo/h29.html>
- 2) 渡辺有, 田所正, 栗城稔: 水位データの異常値検出手法の開発, 令和 2 年度河川情報シンポジウム開催レポート, 2020.
<https://www.river.or.jp/koeki/events/sympo/r02.html>
- 3) 大石夏樹, 渡辺有, 本永良樹, 澤野久弥, 田所正: 水文観測データ品質向上の取り組み, 令和 5 年度河川情報シンポジウムレポート, 2023.
<https://www.river.or.jp/koeki/events/sympo/r05.html>
- 4) Hochreiter, S. and Schmidhuber, J. : Long Short-Term Memory, Neural Computation, Vol.9, No.8, pp.1735–1780, 1997.
- 5) TensorFlow/Keras Documentation : LSTM Layer and Model API Reference, 2024.
https://keras.io/api/layers/recurrent_layers/lstm/
- 6) Curiously : Time Series Anomaly Detection with LSTM Autoencoders (PyTorch implementation), 2020.
<https://github.com/curiously/Getting-Things-Done-with-Pytorch/blob/master/06.time-series-anomaly-detection-ecg.ipynb>
- 7) Curiously : Time Series Anomaly Detection (Notebook No.14) – Deep Learning for Hackers, 2019.
<https://github.com/curiously/Deep-Learning-For-Hackers/blob/master/14.time-series-anomaly-detection.ipynb>

DEVELOPMENT AND EVALUATION OF AN ANOMALY DETECTION METHOD FOR RIVER WATER LEVEL OBSERVATION DATA USING AN LSTM AUTOENCODER MODEL

Satoshi NISHIDA, Osamu OKADA and Tadashi TADOKORO

The River Information Center has developed an automated anomaly detection system for observation data collected from numerous telemeter rainfall and water level stations nationwide, and has been conducting 24-hour data quality monitoring operations since FY2022.

In this study, to address the issue of false detections (false positives) that frequently occurred during rapid water level rises in the conventional 3 σ model, a new anomaly detection method based on the Long Short-Term Memory Autoencoder (LSTM-AE), which excels in time-series feature extraction and self-reconstruction capability, was developed.

By training the model exclusively on normal observation data and using reconstruction error as an anomaly score, the proposed method demonstrated high accuracy in detecting anomalies even during rapid fluctuations in water level.

When combined with the existing 3 σ model, this approach is expected to enhance the performance and reliability of the anomaly detection system for hydrological observation data.