


## LSTM および LSTM-Autoencoder モデルによる斜面表層ひずみの異常検知の比較

(独) 労働者健康安全機構労働安全衛生総合研究所 正会員 ○平岡 伸隆  
 東京都市大学 学生会員 中根 良太  
 (独) 労働者健康安全機構労働安全衛生総合研究所 正会員 吉川 直孝  
 東京都市大学 正会員 伊藤 和也

### 1. はじめに

切土掘削工事などの建設現場において、斜面動態観測データによって斜面崩壊の予兆を捉え、退避判定や施工計画に反映させることは、安全性・経済性の両面から有効と考える。現在、ICT 技術の向上により様々なセンサが開発され、さらにそれらのデータを集約するシステム構築が安価になっている。ここで課題となるのが、センサから得られたデータがどのように変化したときに斜面に異常があると判定するかである。本研究では、崩壊時の斜面動態観測データを対象に、深層学習の異常検知手法として LSTM および LSTM-Autoencoder による異常検知を適用し、これらの結果を比較する。



1370 秒 1497 秒  
 図1 遠心模型実験の崩壊の様子

### 2. 分析データ

まずは、本研究の分析対象とした実験データについて述べる。遠心模型実験にて勾配 60°、高さ 5 m (換算スケール) のまき土斜面に対して背面から地下水位を上昇させ崩壊させた。このときに斜面表層に設置したひずみ計の観測結果を用いる。崩壊の過程の様子を図1に示す。法先に地下水が到達すると湧水が確認され、その後、1165 秒で左方法先付近が崩壊し、徐々に上部に崩壊が遷移していく進行性崩壊を呈した。1370 秒で高さ 1.5m, 1474 秒で 2.5m, 1497 秒で法肩から崩壊した。データは 10 Hz で計測しており、水位上昇 5 分前を経過時間 0 秒としている。

### 3. 学習モデル

本研究では、以下に示す 2 つの異常検知モデルに対し、ハイパーパラメータの最適化を行い、各パラメータの傾向について考察する。まず 1 つ目は、Long-Short Term Memory (LSTM) モデルによって、入力データの次の時点の計測値を予測するモデルである。このモデルに正常データとして実験初期の計測値を与え学習する。これにより、正常データであれば高い予測精度を持つモデルが構築され、入力データに異常が合った場合には、予測精度が落ち、1 時点先の予測結果と実際に得られた計測結果の残差によって異常度を判定することが可能である。2 つ目のモデルは Autoencoder を用いた異常検知モデルである<sup>1)</sup>。系列データの異常検知ではこちらのモデルの方が一般的である。Autoencoder は入力値を潜在的なベクトルに変換する encoder と、それを元に復元する decoder で構成される。この encoder と decoder に LSTM モデルを使用したものを LSTM-AE と呼ぶ。正常データで学習をさせると、正常データに対しては高い復元精度を持つモデルが構築され、異常データが入力された場合には、復元精度が落ちる。このため、入力データと出力された復元データの残差によって異常度を評価することが可能である。

いずれのモデルにおいても入力データを生成する必要がある。斜面の最上部に設置された ch22 の表層ひずみ計のデータをスライド窓によって分割し、入力データとした。本研究ではスライド窓のスライド幅は 1 に固定し、窓サイズ(window size)を 3~100 までの範囲とした。これは入力に必要な時系列データの個数であり、どの程度の期間のデータが予測・復元に寄与するのか、また実用にあたって何時点分のデータが必要になるのかといった指標となる。なお、LSTM モデルは、この入力時系列データの次時点のデータが予測ターゲットデータになる。また、入力データの前処理として生データのまま取り扱うか、移動平均をかけてノイズを減らすかについて検討した。移動平均の時点数(num sma)を 1, 3, 5, 10, 20 個として、ハイパーパラメータとした。両モデルの LSTM は、層数(num layers)

キーワード 異常検知, 深層学習, 斜面崩壊, LSTM, Autoencoder, 現場計測

連絡先 〒204-0024 東京都清瀬市梅園 1-4-6 TEL 042-491-4512




図2 LSTMモデルにおけるハイパーパラメータ (window size = 17, hidden size = 255, num layers = 3, num sma = 20 が最小)




図3 LSTM-AEモデルにおけるハイパーパラメータ (window size = 4, hidden size = 233, num layers = 3, num sma = 3 が最小)

および隠れ状態サイズ(hidden size)がハイパーパラメータとなり、層数は1, 2, 3層、隠れ状態サイズは4~256を探索範囲とした。異常度の定義はLSTMモデルでは1時点先の予測値と実際の計測値の残差、LSTM-AEモデルでは入力データと出力データの残差とし、これらから求めた検証期間のマハラノビス距離のホテリング理論1% (6.63) を閾値とした。

#### 4. 学習・推論結果と異常検知

500秒間の学習データと同様に、次の200秒間を検証データ、それ以降の850秒間をテストデータとした。損失関数は平均二乗誤差、最適化手法はAdam、学習率は初期設定を0.001として動的、ハイパーパラメータの探索の最適化手法にはTree-structured Paren Estimator Approach (TPE)を用いた。ハイパーパラメータの探索中のepoch数は150、トライアル数を100、目的関数は検証データの誤差として、これを最小化するように最適化した。つまり予測精度や復元精度を向上させるように最適化しており、異常度の検知精度に対して最適化したわけではないことに留意されたい。それぞれのモデルのハイパーパラメータと誤差の関係を図2, 図3に示す。両モデルともhidden sizeやnum layerは大きい方が、精度が高い傾向にある。LSTM-AEのwindow sizeは短いほど精度が上がる傾向が顕著である。また、LSTMモデルは入力データの移動平均数(num sma)が大きいほど精度が高い傾向にあるが、LSTM-AEはそのような傾向が弱い。

Window size, hidden size, num layersは小さい方が、パラメータ数も少なくなり計算が速くなる。最適なパラメータによって計算された異常度の推移を図4, 図5, それぞれのモデルによって斜面に設置された8基のセンサ

サ全てに学習モデルを適用し、異常検知したセンサ数の推移を図6に示す。いずれのモデルでも崩壊前に異常検知数が上昇していく傾向があり、本手法によって崩壊の予兆を捉えることが可能であると考えられる。LSTM-AEモデルの方が早く異常を検知できているが、閾値の設定基準や、異常検知したセンサ数によって危険と捉える判断は変更可能であり、最終的な決定は運用実態をみながら管理者が判断することになる。

**参考文献** 1) Malhotra, P. et al., LSTM-based Encoder-Decoder for Multi-sensor Anomaly Detection, ICML 2016, 2016.




図4 LSTMモデルによる異常検知




図5 LSTM-AEモデルによる異常検知




図6 各モデルの異常検知したセンサ数の推移