

表層ひずみ速度データを用いた ElasticNet による異常検知手法の検討

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 平岡 伸隆, 吉川 直孝

東京都市大学 正会員 伊藤 和也

1. はじめに

近年の日本では、ICT 技術を用いた計測機器や監視システムが開発され、斜面モニタリングに活用されている。これらの技術を用いて斜面崩壊時の表層データについて計測できるが、どのような値を計測したときに異常と判断するかについては検討段階にある。本研究では、遠心場での斜面崩壊実験で計測した表層ひずみデータの時系列データを用いて、機械学習のモデルである ElasticNet によりデータを予測し、予測値と計測値の残差により斜面の異常を検知する手法について検証した。

2. 遠心模型実験

本報告で用いた表層ひずみデータについては、平岡ら¹⁾が実施した 2 ケースの遠心模型実験の結果を用いた。実験では、20G の遠心力を載荷し、斜面高さ 5m、Case1 では斜面勾配 60°、Case2 では斜面勾配 40°を採用した。土試料は茨城県笠間産まさ土を使用し、礫分を除くため 2mm ふるい通過試料を用いた。最適含水比 17.3%に設定し、乾燥密度 1.50g/cm³で作製した。20G の遠心力を載荷した後に、崩壊するまで水位を上昇させた。計測機器は斜面表層に 8 基の遠心場用表層ひずみ計を設置高さ 0.5m、1.5m、2.5m、4.5m に各段 2 基設置した。遠心場用表層ひずみ計により得られ表層ひずみ時系列データを用いて異常検知できるかについて検討する。また、本報告では見かけの回帰が発生することを防ぐため、データの差分を取り速度を算出し予測に用いた。図 1、図 2 に斜面の崩壊過程を示す。地下水が上昇して法先に地下水水位が到達すると、法先から湧水が確認された。その後、Case1 では 1165 秒経過後に法先が崩壊をはじめ、1370 秒後に高さ 1.5m、1474 秒後に高さ 2.5m、1497 秒後に法肩から大きく崩壊した。Case2 では 1098 秒経過後に法先が崩壊をはじめ、1639 秒後に高さ 1.5m まで崩壊したが法肩までの崩壊には至らなかった。この結果を用いて異常検知手法について検討を行った。

3. 異常検知手法

本研究では、遠心模型実験により得られた表層ひずみ速度データを用いて機械学習による異常検知手法について検討する。機械学習のモデルの中から ElasticNet を用いて検証を行った。ElasticNet は線形回帰に正則化項を取り入れた手法であるリッジ回帰とラッソ回帰の長所と短所を補ったモデルである。異常検知を行う上で崩壊時のデータが観測されていない場合では、正常時のデータを用いて学習させる。これにより作成されたモデルでは、崩壊データが計測されたときに計測値と予測値に差が生まれることから異常と判断できる。

本研究では、実験開始後に地下水水位上昇の影響が少ない ch22 のデータを学習データとしてモデルを作成する。最初の 500 秒




図 1 崩壊の様子 (Case1)




図 2 崩壊の様子 (Case2)

キーワード 斜面崩壊, 異常検知, 機械学習, 労働災害

連絡先 〒158-8557 東京都世田谷区玉堤 1 丁目 28-1 東京都市大学 TEL : 03-5707-0104 E-mail : g2281642@tcu.ac.jp

(5000プロット)を学習データ, 次の200秒を検証データ, 残りのデータをテストデータとして3つに分割した. その後, データの前処理として標準化を行った. 学習用に入力値と目標値が必要となるため, それぞれのケースで時系列データの窓サイズ, スライド幅, 予測サイズを設定した. 本研究ではスライド幅と予測サイズに関しては共通に1とし, ハイパーパラメータには, 窓サイズ(3~200までの整数値), 正則化項の係数 α (0.001~1までの実数値), 正則化の比率 $l1ratio$ (0~1までの実数値)を設定し, 最適化手法であるTree-structured Parzen Estimator(TPE)を用いて, 推測値と計測値の平均二乗誤差が小さくなるようにパラメータを探索した. ハイパーパラメータ探索の結果, Case1の窓サイズは141, 正則化項の係数は $\alpha=0.017$, 正則化の比率は $l1ratio=0.36$, Case2の窓サイズは137, 正則化項の係数は $\alpha=0.0011$, 正則化の比率は $l1ratio=0.0012$ であった.

各手法の窓サイズの表層ひずみデータから次の1個の表層ひずみについて予測するモデルが作成された. 異常度の設定方法として検証期間の誤差から平均, 分散を求め, 正常時の誤差が正規分布に従うと仮定してマハラノビス距離を算出した. 異常度の閾値はホテリング理論より, 確率を0.01と設定すると閾値が6.63となる. この値をマハラノビス距離が上回る時を異常と定めた. Case1の推測結果を図3に示す. Case1で学習したモデルでは高さ2.5m崩壊後に計測値と予測値に乖離が生じ異常検知したことがわかる. 斜面に設置した8つのひずみ計の異常検知したセンサーの数と時間の関係を図4に示す. 法先崩壊前には1基から2基のひずみ計の計測値から異常検知があり, 高さ2.5m崩壊前には6基から7基異常検知した. 法先崩壊前の検知数が少ないのは, 異常時でも一定の精度を保ち, 正常時と異常時の予測結果に変化が起きづらいことに起因すると考えられる. Case2の推測結果を図5に示す. 法肩まで崩壊に至らなかったデータでは, 計測値と予測値に乖離が生じず異常と判断しなかったことがわかる. 8つのひずみ計の異常検知したセンサーの数と時間の関係を図6に示す. 法先付近に設置し崩壊に巻き込まれた2機のセンサに加え, 最大で4基のセンサが異常を検知したことがわかった. この結果からセンサの設置位置についても検討していく必要がある.

4. まとめ

遠心模型実験により得られた表層ひずみ速度データを用いて機械学習による異常検知手法の検討を行った. 今回検証したモデルは, 法肩まで崩壊したケースではすべてのセンサで異常を検知し, 崩壊しなかったケースでは斜面下部に設置し崩壊に巻き込まれたセンサが異常を検知することがわかった. 今後は異常度の設定方法やセンサの設置位置などを検討する必要がある.

参考文献

1) 平岡伸隆, 吉川直孝, 伊藤和也(2021): 掘削工事中の地下水位変動による斜面崩壊とその対策, 土木学会論文集C(地盤工学), Vol.77, No.2, pp.140-158.




図3 ひずみ速度推測結果 (Case1)




図4 異常検知数の時系列変化 (Case1)

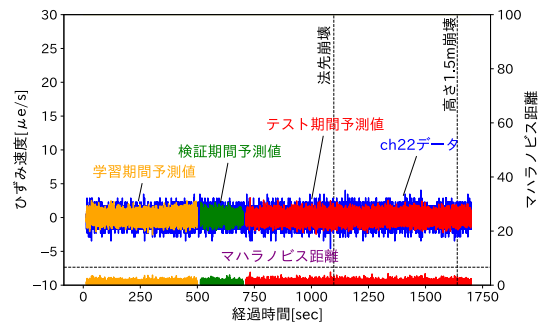


図5 ひずみ速度推測結果 (Case2)




図6 異常検知数の時系列変化 (Case2)