

高速道路の斜面災害の分析における Machine Learning の適用*

東北大学 芳賀奈津美 風間基樹 加村晃良

東日本高速道路株式会社 長尾和之

株式会社ネクスコ・エンジニアリング東北 澤野幸輝

1. はじめに

日本の高速道路は 1963 年に供用が始まって以来、現在に至るまで物流の安定化、地域活性、医療貢献、防災等といった様々な面において重要な役割を担ってきた。一方で高速道路沿いの切土盛土斜面では豪雨に対する維持管理が課題となっている。東北地方の高速道路斜面が降雨を誘因として崩壊に至った事例は、切土では 1994 年から 2017 年の間に 92 件、盛土では 1993 年から 2017 年までの間に 90 件報告されている。このような被害を防ぐためには、地質・地形・降雨パターンなどに基づく危険度評価等が求められるが、未だにそのリスク評価方法が明確となっていない。そこで本研究では斜面崩壊の大きな誘因の 1 つと考えられる降雨に着目し、点数化された斜面特性と共に時間雨量と累積雨量をデータセットとして Machine Learning (ML) を適用し、斜面災害のリスク評価について検討を行った。

2. Machine Learning の適用手法

本研究では Tensor Flow を用いてニューラルネットワーク(NN)を構築した。NN は人間の脳神経細胞ニューロンを模擬したネットワークモデルであるパーセプトロンを模倣した数理学習を行うアルゴリズムである (図-1)。脳神経系ではニューロンからニューロンへと信号が伝播するが、その際ある閾値を超えると出力信号が発せられるという様な処理がなされる。これをモデルとした NN ではニューロンを伝わる信号に重みをかけることで入力情報の処理を行う。本研究では入力層、中間層 2 層、出力層から成る 4 層の NN を用いて計算を行い、ステップ数を変化させた際の学習結果の変動を比較した。中間層の活性化関数はシグモイド関数、出力層ではソフトマックス関数を採用した。




図-1 ニューラルネットワーク模式図

3. データセット

深層学習に用いたデータセットの一部を表-1 に示す。学習に用いたデータセットは崩壊データが 92 件、非崩壊データが 801 件である。このうちランダムに選んだおよそ 8 割の 713 (うち崩壊 74, 非崩壊 637) 件を学習データ、残りの 180 (うち崩壊 18, 非崩壊 162) 件を検証データとした。入力項目には地形、土質・地質、構造の 3 項

*Application of Machine Learning in the analysis of highway slope failures
by Natsumi HAGA, Motoki KAZAMA, Akiyoshi KAMURA, Kazuyuki NAGAO, Koki SAWANO

表-1 データセット

崩壊判定	地形	土質	構造	評価合計	年数	時間雨量	1w累積
0	0.7	1	0	0.75	6.9	29	265.6
0	0.7	1	0	0.75	16.5	16	305.8
1	0.7	0.875	0	0.7	20.9	31	297.2
0	0.7	1	1	0.85	23.4	17	295
0	0.7	1	0	0.75	12.1	20.5	274.1
1	1	1	1	1	14.8	39.5	292
1	0.7	0.875	0	0.7	20.8	28	184.8
0	0.7	1	1	0.85	4.9	26.5	201.5

目を点数化したものとそれらの素因の評価点の合計を正規化した4つの数値、1週間累積雨量、1週間内の最大時間雨量を採用した。ここで使用した降雨データは全国の気象レーダーの観測データと雨量計のデータを組み合わせて解析した雨量である。判定は非崩壊を0、崩壊を1として学習させ、試験データの出力は崩壊または非崩壊どちらかの確率が大きい方をそのデータセットに対応する学習結果とした。崩壊斜面を扱ったデータでは崩壊が発見された時刻の直前1週間の累積雨量と直前1週間以内の最大時間雨量を用いた。非崩壊データは崩壊が発生した斜面の供用開始から崩壊発生前までの間に、同斜面が経験した降雨のうち1週間累積雨量が大きかった降雨イベントとその1週間の最大時間雨量をデータセットとして使用した。崩壊、非崩壊合わせたデータセットの1週間累積雨量と最大時間雨量のみを比較した際のグラフが図2である。この図を見ると、1週間累積雨量と最大時間雨量の2軸では崩壊が発生した降雨と発生しなかった降雨境界を見つけることは不可能である。

4. 結果

図-3,4は学習を行った結果である。図-3は学習ステップ数と、学習データの正解率、検証データの正解率を第1軸、崩壊を正しく崩壊と判定できた確率を示す敏感度を第2軸にとり、それぞれの関係を示す。ステップ数を2,000回から20,000回の間で変化させた際の学習率と検証データ正解率はそれぞれ92.0~94.4%、93.3~96.1%の間を推移した。一方で敏感度を見ると44.4~66.7%と低い数値で推移していることがわかる。これは全体の正解率が崩壊データに比べて約8.7倍データ数がある非崩壊データの判定結果に大きく影響されていることを意味する。ステップ数2,000回では学習率、検証データ正解率、敏感度すべてが他のステップ数のときと比較して小さい値となった。4,000回では検証データ正解率が5,000回よりも高くなったが、学習率と敏感度は低いことから精度は高いとは言えない。8,000回を超えると学習率や検証データ正解率は少しずつ変動するものの一定の傾向は見られず、敏感度はやや減少した。ステップ数が大きくなるにつれて計算に係る時間も長くなることも踏まえ




図-2 降雨データ比較

て、本研究で用いた NN の構造とデータセットにおいては、ステップ数は 5,000~6,000 回が適当であると言える。図-4 は ML の結果を検討する際によく用いられる混同行列を使って整理した結果であり、横軸にステップ数、第 1 縦軸に TP, FP, FN, 第 2 縦軸に TN の値をとる。混同行列の表し方は図-5 の通りである。これを見ると崩壊を非崩壊と判定した FP は 6~10 であり、検証データ 18 件の内 33~56% の崩壊を見逃していることを示す。

5. 結論

本研究では高速道路ののり面管理指標の提案を目的として過去ののり面崩壊データの分析と ML 適用の可能性を探った。本研究で得られた結論は以下の通りである。

1. 降雨に起因する斜面崩壊のリスク評価において、精度の向上は必要であるがスクリーニングの一つの手段として ML の適用可能性が示唆された。
2. 学習時のステップ数を 2000~10000 回の間で変化させたところ、学習の正解率にほとんど変化は見られなかった。ステップ回数が大きくなれば計算時間も増大するため、本研究においては 5,000~10,000 回程度が適切と考えられる。
3. 敏感度は 50% 前後を示し、崩壊のおおよそ 1/3~半数近くを見逃す結果となった。安全側の評価を行うためには見逃しを低減させることが重要であると考えられる。

また、これらの結果を踏まえて今後の検討課題としては、見逃しの低減を実現するための機械学習の精度の向上があげられる。具体的には計算に用いる関数の検討、学習に用いるデータセットの要素の追加や削除による質の向上である。さらに盛土の崩壊についても同様に分析を進める必要がある。

6. 参考文献

- 1) 国土交通省気象庁, 各種データ・資料
www.jma.go.jp/jma/menu/menureport.html
- 2) 地理院地図, <http://maps.gsi.go.jp>
- 3) 地盤工学会 (2009): 地震と豪雨・洪水による地盤災害を防ぐために—地盤工学からの提言—, 地盤工学会 2007 年度会長特別委員会




図-3 正解率と敏感度




図-4 結果詳細

		予測	
		1	0
観測	1	True Positive (TP)	False Positive (FP)
	0	False Negative (FN)	True Negative (TN)

図-5 混同行列の考え方