

# 機械学習に基づく地震時の斜面崩壊予測 に向けた基礎的検討

XIE HAOYANG<sup>1</sup>・劉 ウェン<sup>2</sup>・丸山 喜久<sup>2</sup>

<sup>1</sup>千葉大学大学院融合理工学府 博士前期課程 (〒263-8522 千葉県千葉市稲毛区弥生町1-33)

E-mail: capa6093@chiba-u.jp

<sup>2</sup>正会員 千葉大学 大学院工学研究院 (〒263-8522 千葉県千葉市稲毛区弥生町1-33)

E-mail: wen.liu@chiba-u.jp, ymaruyam@tu.chiba-u.ac.jp

2018年北海道胆振東部地震では、厚真町やその周辺で斜面崩壊が多発し、多くの犠牲者が発生した。既往研究では、斜面崩壊予測方法が提案され予測精度に関する検討が行われてきたが、広域に適用可能なモデルの構築は未だ研究段階である。そこで本研究では、機械学習を用いて地震による斜面崩壊の予測を行い、その精度を検証した。さらに、衛星画像の利用も目指し、正規化植生指数 (NDVI) を機械学習の説明変数に用いることを検討し、NDVIを導入することの効果を明らかにした。

**Key Words:** 2018 Hokkaido Eastern Iburi earthquake, landslide, logistic regression, support vector machine, random forests

## 1. はじめに

2018年北海道胆振東部地震では、厚真町を中心に数千箇所での斜面崩壊が発生した<sup>1)</sup>。斜面崩壊に対する事前対策を効率的に行うには、斜面崩壊が発生する可能性の高い地点を事前に把握することは重要である。

地震によって発生する斜面崩壊は、降雨によるものと同様に、小規模な落石から山体が崩壊するような大規模なものまで存在する。大規模な斜面崩壊は固有の地質と地形条件に起因して発生することが多く、前兆的な地形に関しては発生場所が予測可能とされている<sup>2)</sup>。Keef<sup>3)</sup>は、ニューマーク法<sup>4)</sup>に基づき危険斜面を抽出する方法を提案したが、地盤の多様性の影響により広域的な予測の信頼性は高くない。中村ら<sup>5)</sup>は、厚真川流域の斜面崩壊と地形や地震動の関係性を考慮し、斜面崩壊予測式を構築した。斜面勾配、平均曲率、地震動の最大加速度を説明変数としており、斜面崩壊リスクマップの分類正誤率が40.6%、空振り率が81.4%とされている。

このように、広域に適用可能な斜面崩壊予測手法は未だ研究段階である。近年、急速に発展している

機械学習を利用して、広域に適用可能な斜面崩壊発生予測モデルを構築し、斜面崩壊に関する警戒情報の精度向上を目指すことが期待されている。また、リモートセンシング技術を利用した斜面崩壊予測に関する研究も行われている<sup>6)</sup>。衛星画像は広域性を有しており、面的な被害把握に非常に有用と考えられる。

そこで本研究では、機械学習を用いた地震時の斜面崩壊予測に関する基礎的検討を行う。ロジスティック回帰分析、ランダムフォレスト、サポートベクターマシンの3つの機械学習手法を用いて斜面崩壊に関わる要因を分析し、予測モデルを構築する。さらに、予測モデルに厚真川流域の衛星画像の植生指標を考慮することを検討する。対象地域における将来発生する斜面崩壊を避けるために、予測モデルを用いて斜面崩壊の危険性を評価する。

## 2. 本研究で用いたデータ

本研究では、2018年北海道胆振東部地震の際に丘陵や山地域で大規模な斜面崩壊が多発した震源に

近い厚真町周辺を対象領域とした(図-1)。国土地理院は、2018年9月6日から11日にかけて撮影した空中写真から、「平成30年北海道胆振東部地震に伴う斜面崩壊・堆積分布図」を作成している<sup>7)</sup>。本研究では、これを5次メッシュ(250mメッシュ)単位で集計し、正解データとして使用した。梅田ら<sup>8)</sup>によると、崩壊地では顕著な湧水が確認できず、主に地震時のせん断力によって崩壊が引き起こされたと考えられている。そこで、本研究は標高、傾斜角度、地震動の最大速度(PGV)、微地形区分<sup>9)</sup>、正規化植生指数(NDVI)を説明変数とした斜

面崩壊予測モデルの構築を目標とし、土壌の含水率を考えないこととした。NDVIは、図-2に示す範囲の衛星画像を用いて算出した。本研究で用いた衛星画像は、2018年10月4日に撮影されたSPOT-7光学衛星画像である。パンクロマティック画像の分解能は1.5m、可視・近赤画像の分解能は6.0mである。パンシャープン処理後、1.5m分解能の可視・近赤画像を作成した。

PGVは産業技術総合研究所が公開する地震マップ即時推定システム(QuiQuake)<sup>10)</sup>の推定分布を用

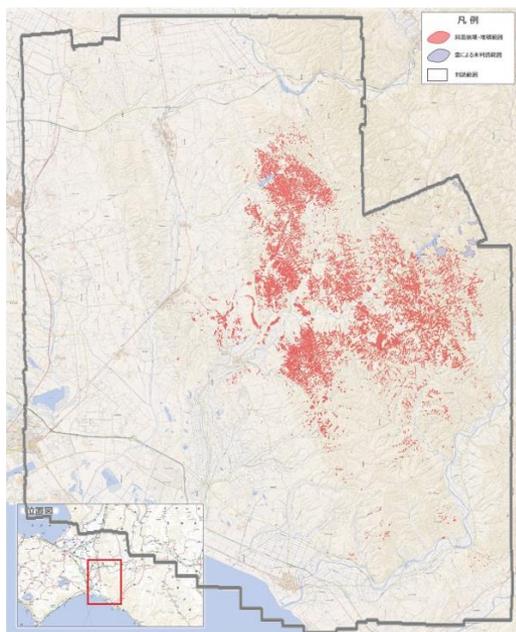


図-1 平成30年北海道胆振東部地震に伴う斜面崩壊・堆積分布図<sup>7)</sup>

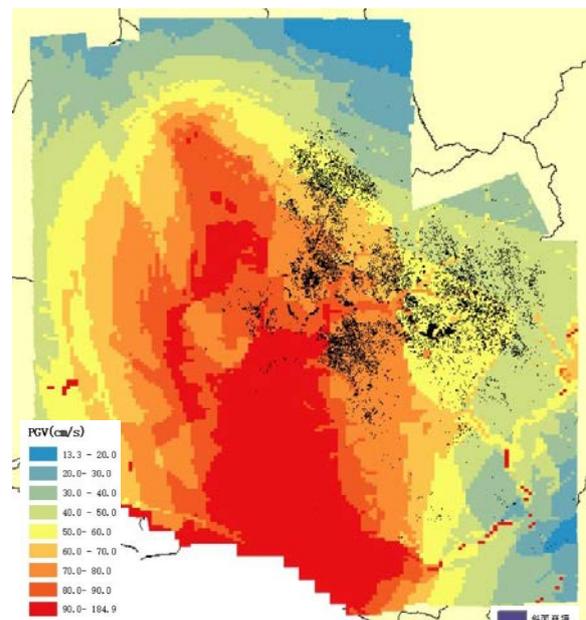


図-3 斜面崩壊地点とPGVの分布

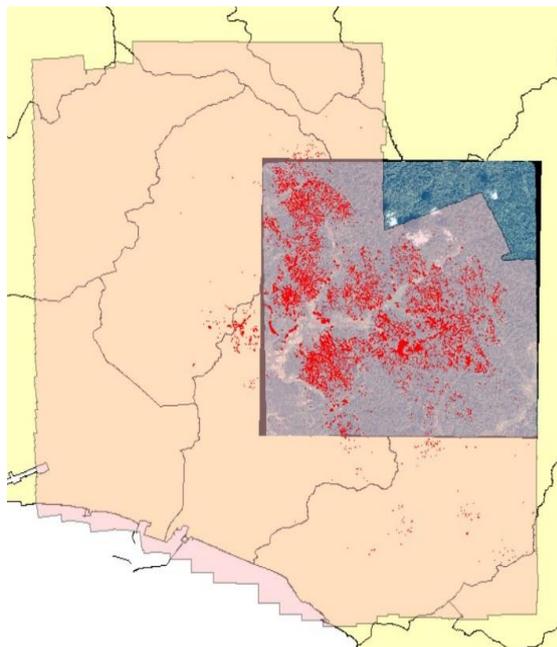


図-2 衛星画像の撮影範囲

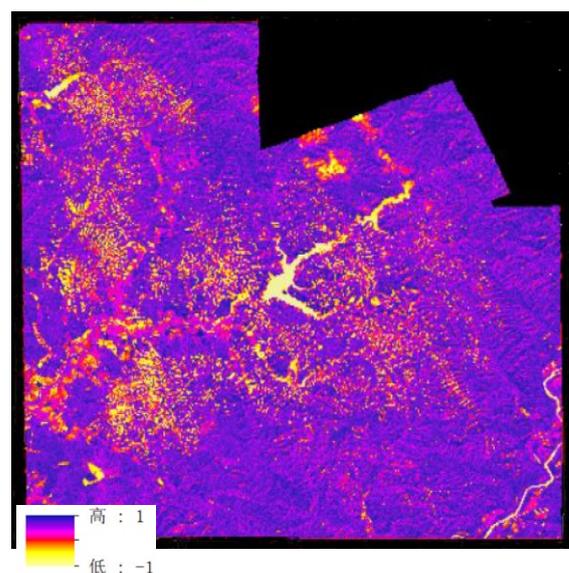


図-4 衛星画像から算出したNDVI

表-1 設定領域の5次メッシュ数の内訳

	学習データ			訓練データ		
	崩壊あり	崩壊なし	合計	崩壊あり	崩壊なし	合計
全判読領域	2796	13271	16067	1219	5668	6887
衛星画像範囲	2611	2246	4857	910	710	1620

いた(図-3)。標高と傾斜角度は、国土交通省が整備する国土数値情報から取得した。これらも、5次メッシュ単位で集計されている。

NDVIは式(1)のように算出される。ここで、NIRは近赤外域の反射率、REDは赤色光の反射率を表す。図-4にNDVIの分布を示す。植生の高い地域ほど1.0に近い値を示す。これを5次メッシュごとに集計し、機械学習に使用した。

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

5次メッシュごとの微地形区分のデータはJ-SHIS地震ハザードステーション<sup>11)</sup>から取得し、ダミー変数化して用いた。

本研究では、機械学習の適用範囲を、国土地理院の全判読領域(図-1の枠線内)と衛星画像の撮影範囲の2通りに設定した。2つの設定領域の5次メッシュ数の内訳は表-1の通りである。機械学習に適用

する際、設定領域が全判読領域の場合、データの75%を教師データ、25%をテストデータとした。設定領域が衛星画像の撮影範囲の場合、データの70%を教師データ、30%をテストデータとした。

図-5に全判読領域の5次メッシュの標高分布と斜面崩壊率を示す。ここで、斜面崩壊率は、当該区間の5次メッシュ数に対する崩壊地を含むメッシュ数の割合を表す。斜面崩壊が生じた標高の最大値は400mを超えるが、崩壊地の標高の多くは100m~400mである。図-6に全判読領域の傾斜角度と斜面崩壊率を示す。傾斜角が15°以上のとき崩壊率は20%を超え、特に20°~51.5°で35%以上となった。図-7に、全判読領域のPGVと斜面崩壊率を示す。斜面崩壊率が最も高いのはPGVが50cm/s~60cm/sのときである。次いでPGVが70cm/s~80cm/sのときに、斜面崩壊率が29.4%であった。図-8に、全判読領域の微地形区分と斜面崩壊率を示す。山地の斜面崩壊率は37.2%、丘陵は35.3%、山麓地は26.4%であった。

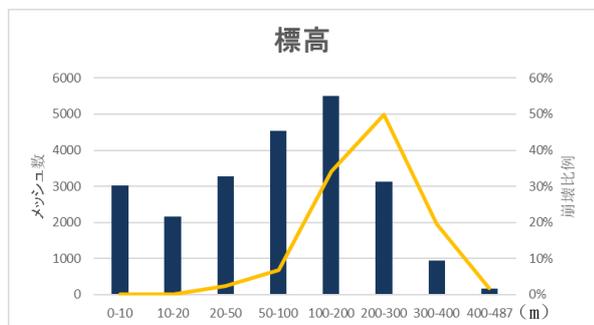


図-5 標高ごとのメッシュ数と斜面崩壊率

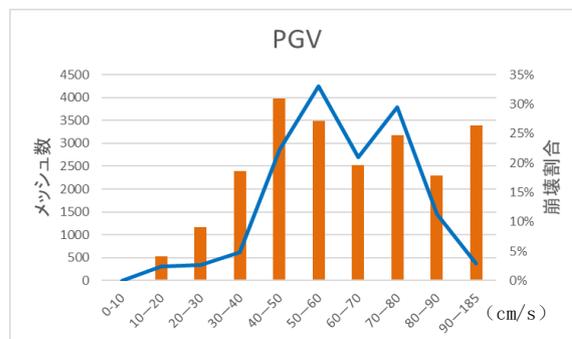


図-7 PGVごとのメッシュ数と斜面崩壊率



図-6 傾斜角度ごとのメッシュ数と斜面崩壊率

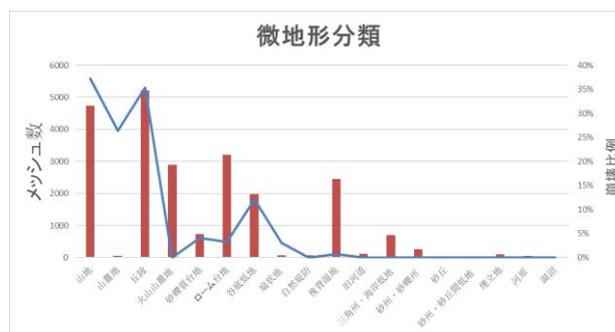


図-8 微地形ごとのメッシュ数と斜面崩壊率

表-2 予測精度評価のための混同行列

		予測結果	
		崩壊あり	崩壊なし
実際データ	崩壊あり	TN	FP
	崩壊なし	FN	TP

### 3. 本研究で用いる精度評価指標

本研究では、機械学習による斜面崩壊の予測精度の評価に、正答率、適合率、再現率、F 値、マッシュューズ相関係数<sup>12)</sup>、ROC 曲線、PR 曲線、Kappa 係数の 8 つの評価指標<sup>13)</sup>を導入する。各指標式は式(2)~(6)の通りであり、式中の式中の TP, FP, FN, TN は表-2 のように定義される。

$$\text{正答率 (Accuracy)} = \frac{TP + TN}{TP + FP + FN + TN} \quad (2)$$

$$\text{適合率 (Precision)} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{再現率 (Recall)} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{F 値 (F-measure)} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

マッシュューズ相関係数

$$(MCC) = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FN)(FN + TN)(TN + FP)(FP + TP)}} \quad (6)$$

また、崩壊ありと正しく判別する率を TPR (sensitivity)、崩壊なしを正しく判断する率を TNR (specificity) とする。

$$TPR = \frac{TP}{TP + FN} \quad (7)$$

$$TNR = \frac{TN}{TN + FP} \quad (8)$$

斜面崩壊予測の際の閾値を変化させて TPR, TNR を算出し、横軸に 1-TNR, 縦軸に TPR をプロットした

ものを ROC 曲線と呼ぶ。ROC 曲線の下部の面積 (Area Under the Curve) は  $AUC_{ROC}$  と呼ばれ、1.0 のときが最良であり、ランダムで全く無効なモデルでは 0.5 となる<sup>14)</sup>。同様に、再現率を横軸に、適合率を縦軸にとった曲線を PR 曲線と呼ぶ。PR 曲線の AUC である  $AUC_{PR}$  も 1 に近いほど良好なモデルであることを示す。 $AUC_{PR}$  は、クラス間のデータ数に偏りのある場合 (不均衡データ) の評価指標として有効である<sup>15)</sup>。

F 値は分類モデルの精度評価指標の一つで、適合率と再現率の調和平均である。マッシュューズ相関係数 (MCC) は 2 クラス分類の予測結果と実際のデータの相関を表すもので、値の範囲は-1 から 1 までとなる。MCC が 1 のときは、予測結果が完璧に正しく分類ができている状態を表す。MCC が 0 のときは、実際のデータと予測結果がほぼ独立とみなせるランダムな状態を表す。MCC が -1 のときは、予測結果と実際のデータが完全な不一致状態にあることを表す。

$\kappa$  係数の計算方法を式(9)~(11)に示す。ここで、 $p_0$  は実際データと予測結果の実際的一致度、 $p_e$  は実際のデータと予測結果が偶然一致する確率である。

$$p_0 = \frac{TP + TN}{TP + FN + FP + TN} \quad (9)$$

$$p_e = \frac{(TP + FN) \times (TP + FP) + (TN + FP) \times (TN + FN)}{(TP + FN + FP + TN)^2} \quad (10)$$

$$\kappa = \frac{p_0 - p_e}{1 - p_e} \quad (11)$$

$\kappa$  係数 (kappa statistic) は、予測結果と実際データ的一致度を評価する指標である。0~1 の値をとり、値が大きいほど一致度が高いことと判断する。一般に、 $\kappa$  係数  $\geq 0.6$  であれば、一致度が十分高いと判断される<sup>16)</sup>。

### 4. 全判読領域の斜面崩壊地点の予測

#### (1) ロジスティック回帰分析

ロジスティック回帰分析は、一つのカテゴリ変数 (二値変数) の確率を、複数の説明変数によって説

明, 予測する多変量解析の一つである. 式(12)のように確率  $p$  をロジットに変換する. ロジットとは目的変数である確率を説明変数と線形な関係になるように変換した値である.  $l$ はロジット,  $p$  は事象が発生する確率,  $\beta_0$  は定数,  $\beta_1 \sim \beta_p$  は回帰係数,  $x_1 \sim x_p$  は説明変数である. ロジットをシグモイド関数によって確率  $p(x)$  に変換する式を式(13)に示す.

$$l = \log\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p \quad (12)$$

表-3 ロジスティック回帰分析の説明変数と回帰係数

全判読領域		
説明変数		回帰係数
		$\beta_0$ -16.37816
$x_1$	標高	$\beta_1$ 5.71E-04
$x_2$	傾斜角度	$\beta_2$ 1.61E-01
$x_3$	PGV	$\beta_3$ 7.47E-02
$x_4$	山地	$\beta_4$ 8.04E+00
$x_5$	丘陵	$\beta_5$ 7.50E+00
$x_6$	火山山麓地	$\beta_6$ 2.53E+00
$x_7$	砂礫質台地	$\beta_7$ 6.82E+00
$x_8$	ローム台地	$\beta_8$ 5.40E+00
$x_9$	谷底低地	$\beta_9$ 6.85E+00
$x_{10}$	扇状地	$\beta_{10}$ 0.00E+00
$x_{11}$	自然堤防	$\beta_{11}$ 0.00E+00
$x_{12}$	後背湿地	$\beta_{12}$ 2.40E+00
$x_{13}$	旧河道	$\beta_{13}$ 0.00E+00
$x_{14}$	三角州・海岸低地	$\beta_{14}$ -1.91E-01
$x_{15}$	砂州・砂礫州	$\beta_{15}$ -1.51E+00
$x_{16}$	砂丘	$\beta_{16}$ 0.00E+00
$x_{17}$	砂州・砂丘間低地	$\beta_{17}$ 0.00E+00
$x_{18}$	埋立地	$\beta_{18}$ -3.72E-01
$x_{19}$	河原	$\beta_{19}$ -5.19E+00

表-4 全判読領域のロジスティック回帰分析の予測結果と精度評価指標

		予測結果	
		崩壊あり	崩壊なし
実際データ	崩壊あり	602	617
	崩壊なし	313	5355

	適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	K係数
崩壊あり	0.66	0.49	0.56	0.49	0.86	0.907	0.653	0.486
崩壊なし	0.9	0.94	0.92					

$$p(x) = \frac{1}{1 + \exp(-l)} = \frac{1}{1 + \exp[-(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)]} \quad (13)$$

ロジスティック回帰分析の説明変数と回帰係数を表-3, テストデータに対する予測結果と実際のデータを比較した結果を表-4に示す. 非崩壊のF値は高かったが, 斜面崩壊の再現率は低かった. 正答率やROC曲線による評価は良好であるが, MCCやK係数による実際のデータと予測結果の一致度は低かった.

## (2) サポートベクターマシン

サポートベクターマシン(Support Vector Machine)では, あるパターン分類問題が線形分離不可能な場合, 非線形写像によって特徴空間と呼ばれる高次元空間にマッピングする. これによって線形分離可能な状態となり, 最適な分離超平面を求めることができる. 式(14)で表されるヒンジ損失関数, 式(15)で表される識別誤りを許容するソフトマージン方法を用いて分類問題を解く<sup>17)</sup>. ここで,  $\omega$ は超平面の法線ベクトル,  $x_i$ は特徴ベクトル,  $b$ はスカラー変数,  $\zeta_i$ はスラック変数である.

$$l_{\text{hinge}}(z) = \max(0, 1 - z) \quad (14)$$

$$\min_{\omega, b, \zeta_i} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m \zeta_i$$

$$\text{s.t.} \quad y_i (\omega^T x_i + b) \geq 1 - \zeta_i \quad (15)$$

$$\zeta_i \geq 0 \quad i = 1, 2, \dots, m$$

表-5 全判読領域のサポートベクターマシンの予測結果と精度評価指標

		予測結果	
		崩壊あり	崩壊なし
実際データ	崩壊あり	804	415
	崩壊なし	356	5312

	適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	K係数
崩壊あり	0.69	0.66	0.68	0.61	0.89	0.893	0.691	0.608
崩壊なし	0.93	0.94	0.93					

$$\kappa(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (16)$$

また、本研究では式(16)で表される Gauss カーネル関数を用いた。グリッドサーチに基づきハイパーパラメータ $\gamma$ と $C$ の最適値を定めた。 $\gamma$ の範囲を $10^{-5}$ ~ $10^5$ 、 $C$ の範囲を $10^{-2}$ ~ $10^2$ と設定して、5分割の交差検証法によって適切なパラメータを求めた。

テストデータに対する SVM の予測結果と実際のデータの比較を表-5の混同行列と精度評価指標に示す。 $AUC_{ROC}$ がロジスティック回帰分析よりも小さいが、FPのメッシュ数も少ない。斜面崩壊の再現率は0.66になった。MCCは0.6を超え、良好な結果を示した。また、 $\kappa$ 係数が0.608となり、予測結果と実際のデータの一致度は十分高いと判断できる。各評価指標の数値によって、SVMの予測結果はロジスティック回帰分析より精度が高いことが分かる。

### (3) ランダムフォレスト

ランダムフォレスト(Random Forest)は、多数の決定木を用いて識別性能の高い新たな識別器を構築しようとするアルゴリズムである。RFでは、バギングにランダム性を追加する。学習データのブートストラップサンプルを作成して、 $d$ 次元の全ての入力ベクトルの中に任意の $k$  ( $k < d$ )次元の入力ベクトルを選択し、各決定木が異なる特徴を持つように学習を行う。決定木学習とは、学習データの特徴に応じて決定木を分類させていく学習手法であり、式(17)の情報利得(Information Gain)が最大となるようにする<sup>17)</sup>。

$$Gain(D, a) = Ent(D) - \sum_{v=1}^V \frac{|D^v|}{|D|} Ent(D^v) \quad (17)$$

ここで、 $D$ は学習データ、 $a$ は特徴、 $D^v$ は学習データ $D$ のうち特徴 $a$ に対応する $v$ 番目のサンプル、 $V$ は個々の木を分割するノード数、 $Ent(D)$ はエントロピーであり、式(18)のように書ける<sup>17)</sup>。

$$Ent(D) = -\sum_{k=1}^{|y|} p_k \log_2 p_k \quad (18)$$

$Ent(D)$ が小さいほど、 $D$ の純度が高い。 $p_k$ は学習データ $D$ のうちクラス $k$ の占める割合である。

本研究では、ランダムフォレストのハイパーパラメータの調整をグリッドサーチで行った。ハイパーパラメータの適当な範囲を設定して、5分割の交差検証法によって適切なパラメータを求めた。また、RFのテストデータに対する予測結果から得られた各特微量の影響度評価には、組み込み法(Embedded)というモデルベース特微量選択方法を使用した。特微量選択とは、有用でない特微量を取り除くことでモデルの複雑さを軽減する手法である。閾値を0.001として特微量を選択した。各特微量の影響度を表-6に示す。傾斜角度の影響が最も高く、微地形分類の影響度は低かった。

RFの予測結果と実際データの比較した混同行列と精度評価指標を表-7に示す。SVMの予測結果に比べると、 $AUC_{ROC}$ と $AUC_{PR}$ の値が大きかった。MCCと $\kappa$ 係数もRFの方が少し高く、それぞれ0.62、0.616であった。総合的に評価すると、RFの予測精度が3つの手法の中で最も高かった。

## 5. 衛星画像範囲の斜面崩壊地点の予測

### (1) ロジスティック回帰分析

機械学習の適用範囲を衛星画像の撮影範囲(図-2)に設定し、説明変数としてNDVIを含めた場合と含めない場合の2通りで分析を行った。ロジステ

表-6 ランダムフォレストの影響度

ランダムフォレスト影響度	
傾斜角度	0.424484
標高	0.287725
PGV	0.24252
山地	0.016848
丘陵	0.015607
谷底低地	0.005418
ローム台地	0.003639
砂礫質台地	0.00198
火山山麓地	0.001287
後背湿地	0.000492

表-7 全判読領域のランダムフォレストの予測結果と精度評価指標

		予測結果	
		崩壊あり	崩壊なし
実際データ	崩壊あり	818	401
	崩壊なし	359	5309

	適合率	再現率	F値	MCC	正答率	$AUC_{ROC}$ 曲線	$AUC_{PR}$ 曲線	$\kappa$ 係数
崩壊あり	0.69	0.67	0.68	0.62	0.89	0.942	0.756	0.616
崩壊なし	0.93	0.94	0.93					

表-8 衛星画像撮影範囲のロジスティック回帰分析の予測結果と精度評価指標

		NDVなし		予測結果						
				崩壊あり	崩壊なし					
						崩壊あり	崩壊なし			
実際データ	崩壊あり	669	241							
	崩壊なし	278	432							
		適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	κ係数	
崩壊あり	0.71	0.74	0.72	0.35	0.68	0.74	0.76	0.346		
崩壊なし	0.64	0.61	0.62							

		NDVあり		予測結果						
				崩壊あり	崩壊なし					
						崩壊あり	崩壊なし			
実際データ	崩壊あり	747	163							
	崩壊なし	171	539							

		適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	κ係数	
崩壊あり	0.81	0.82	0.82	0.58	0.79	0.856	0.871	0.581		
崩壊なし	0.77	0.76	0.76							

表-9 衛星画像撮影範囲のサポートベクターマシンの予測結果と精度評価指標

		NDVなし		予測結果						
				崩壊あり	崩壊なし					
						崩壊あり	崩壊なし			
実際データ	崩壊あり	793	117							
	崩壊なし	252	458							

		適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	κ係数	
崩壊あり	0.77	0.86	0.81	0.53	0.77	0.823	0.826	0.529		
崩壊なし	0.78	0.66	0.71							

		NDVあり		予測結果						
				崩壊あり	崩壊なし					
						崩壊あり	崩壊なし			
実際データ	崩壊あり	763	147							
	崩壊なし	115	595							

		適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	κ係数	
崩壊あり	0.87	0.84	0.85	0.67	0.84	0.911	0.93	0.673		
崩壊なし	0.8	0.84	0.82							

ロジスティック回帰分析の結果を表-8に示す。説明変数にNDVI データを含めると正答率が11%向上し、FPとFNの数185メッシュ減少した。精度評価指標に関しては、全てがNDVIを含めたモデルの方が高かった。NDVIを加えることによって、ロジスティック回帰分析の予測精度は向上するが、κ係数は0.581にとどまり、予測結果と実際のデータの一致度は良好と判断できなかった。

## (2) サポートベクターマシン

VMの結果を表-9に示す。精度評価指標に関しては、斜面崩壊の再現率を除き、全ての指標が説明変数にNDVIを含めたモデルの方が大きかった。特に、

表-10 衛星画像撮影範囲のランダムフォレストの予測結果と精度評価指標

		NDVなし		予測結果						
				崩壊あり	崩壊なし					
						崩壊あり	崩壊なし			
実際データ	崩壊あり	773	137							
	崩壊なし	202	508							

		適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	κ係数	
崩壊あり	0.79	0.85	0.82	0.57	0.79	0.849	0.857	0.571		
崩壊なし	0.79	0.72	0.75							

		NDVあり		予測結果						
				崩壊あり	崩壊なし					
						崩壊あり	崩壊なし			
実際データ	崩壊あり	779	131							
	崩壊なし	88	622							

		適合率	再現率	F値	MCC	正答率	AUC <sub>ROC曲線</sub>	AUC <sub>PR曲線</sub>	κ係数	
崩壊あり	0.9	0.86	0.88	0.73	0.86	0.935	0.951	0.727		
崩壊なし	0.83	0.88	0.85							

表-11 衛星画像撮影範囲のランダムフォレストの影響度

NDVIなし		NDVIあり	
PGV	0.378275	NDVI	0.518128
傾斜角度	0.275573	PGV	0.172347
標高	0.269552	傾斜角度	0.124739
丘陵	0.030045	標高	0.1201
山地	0.012724	丘陵	0.025878
砂礫質台地	0.012307	山地	0.015195
ローム台地	0.010054	砂礫質台地	0.00845
谷底低地	0.007233	谷底低地	0.00739
山麓地	0.002285	ローム台地	0.005344
後背湿地	0.00159	後背湿地	0.001529
扇状地	0.00019	山麓地	0.000719
旧河道	0.000172	旧河道	0.000161
河原	0	扇状地	0.00002
自然堤防	0	河原	0
		自然堤防	0

AUC<sub>ROC</sub>とAUC<sub>PR</sub>は0.911, 0.93となり、判別能力が十分高いモデルと判断できる。混同行列を見ると、NDVIを含めた影響は崩壊なしの識別に強く反映され、説明変数にNDVIを含めない場合よりもTNが137メッシュ増加した。

## (3) ランダムフォレスト

RFの結果を表-10と表-11に示す。全ての精度評価指標が、説明変数にNDVIを含めたモデルの方が大きかった。MCCは0.73、非崩壊のF値は0.85、斜面崩壊のF値は0.88となった。

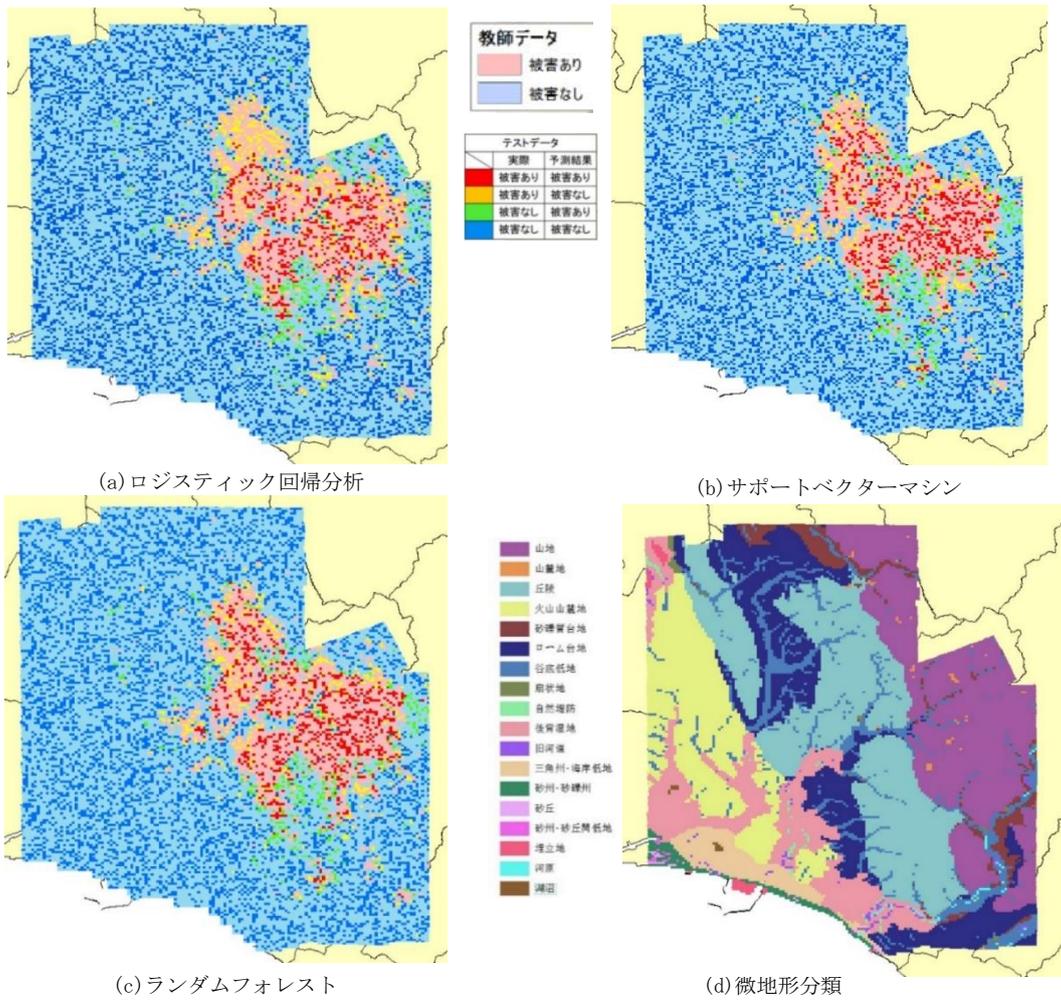


図-9 全判読領域の斜面崩壊評価図と微地形分類図

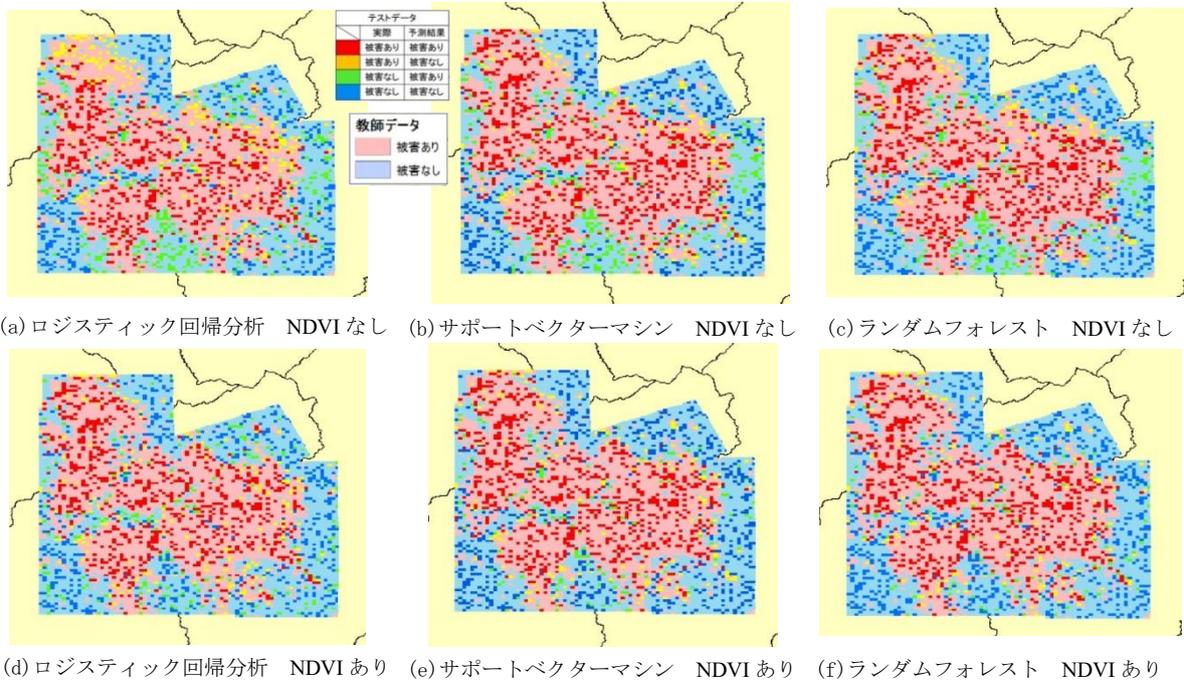


図-10 衛星画像撮影範囲の斜面崩壊評価図

3つの手法のMCCとF値を比較すると、RFが最も高かった。混同行列を見ると、説明変数にNDVIを含めた影響はSVMと同様に非崩壊の識別に反映された。また、NDVIの影響度は0.518となり、斜面崩壊を予測するのに最も重要な説明変数となった。

## 6. 斜面崩壊地点の評価図

ロジスティック回帰分析、SVM、RFの3つの機械学習手法により判別した斜面崩壊評価図を図-9、図-10に示す。予測精度が高かったSVMとRFでは、ロジスティック回帰分析と異なり丘陵地で崩壊を予測する精度が高かった。

説明変数にNDVIを含む場合、FNとFPのメッシュ数は大幅に減った。NDVIを用いることで、微地形分類による誤分類影響を軽減することが分かった。

## 7. まとめ

本論文では、機械学習を利用して地震動強さ、微地形区分、標高、傾斜角度を考慮し、2018年北海道胆振東部地震における斜面崩壊の予測モデルを構築した。機械学習の手法には、ロジスティック回帰分析、RF、SVMの3手法を用いた。全判読領域における正答率は、ロジスティック回帰分析が86%、SVMが89%、RFが89%となり、良好な精度が得られた。各モデルの精度評価指標を比較するとランダムフォレストの結果が最も良好であることが分かった。

さらに、広域の斜面崩壊予測に衛星画像を活用することを目指し、正規化植生指数(NDVI)を機械学習の説明変数として用いた。NDVIを説明変数に含めた場合、ロジスティック回帰分析、SVM、RFの3つのモデルで予測結果と実際のデータの一致度が高くなった。特にSVMとRFで、 $\kappa$ 係数がそれぞれ0.673、0.727となり、一致度が十分高いと判断された。このように、NDVIは斜面崩壊の予測精度の向上に大きく貢献した。

今後は斜面崩壊の地域性に注目し、他の地域で発生した斜面崩壊のデータを使って、本研究の機械学習モデルの汎用性を検討する予定である。

## 参考文献

- 1) 村上泰啓, 水垣滋, 藤波武史: 平成30年北海道胆振東部地震における総崩壊地箇所数及び面積について, 令和2年度砂防学会北海道支部研究発表会, 2p, 2020.
- 2) 千木良雅弘: 地すべり・崩壊の発生場所予測—地質と地形からみた技術の現状と今後の展開—, 土木学会論文集C, Vol. 62, No. 4, pp. 722-735, 2006.
- 3) Keefer, D.: Landslides caused by earthquakes, Geological Society of America Bulletin, Vol. 95, pp. 406-421, 1984.
- 4) Newmark, N. M.: Effects of earthquakes on dams and embankments, Geotechnique, Vol.15, pp.139-160, 1965.
- 5) 中村香也, 真野拓司, 吉川契太郎: 厚真川流域を対象とした予測式による斜面崩壊リスクマップの作成について, 第64回(2020年度)北海道開発技術研究発表会論文, 6p, 2021.
- 6) 大林成行, 小島尚人, 笠博義: 斜面崩壊予測を対象とした衛星マルチスペクトルデータの実利用化について, 土木学会論文集, Vol. 415/VI-12, pp. 71-80, 1990.
- 7) 国土地理院: 平成30年(2018年)北海道胆振東部地震に関する情報, <https://www.gsi.go.jp/BOUSAI/H30-hokkaidoiburi-east-earthquake-index.html>
- 8) 梅田浩司, 千代谷佳織, 柴正敏, 近藤美左紀: 平成30年北海道胆振東部地震に伴う斜面崩壊, 応用地質, 第60巻, 第4号, pp.172-179, 2019.
- 9) 若松加寿江, 松岡昌志: 全国統一基準による地形・地盤分類250mメッシュマップの構築とその利用, 日本地震工学会誌, No.18, pp. 35-38, 2013.
- 10) 産業技術総合研究所: 地震動マップ即時推定システム, <https://gbank.gsj.jp/QuiQuake/>
- 11) 防災科学技術研究所: 地震ハザードステーション, <http://www.j-shis.bosai.go.jp/>
- 12) sammi@DataScience: 不均衡データの評価指標-マッシュアップ相関係数(MCC)とF1スコアの比較, <https://sammi-baba.hatenablog.com/entry/2019/07/31/171213>
- 13) まつけん: 【機械学習】モデル評価・指標についてのまとめと実行, <https://qiita.com/kenmatsu4/items/0a862a42ceb178ba7155>
- 14) Hanley, J.A. and McNeil, B.C.: The meaning and use of the area under a receiver operating characteristic (ROC) curve, Radiology, Vol. 143, No. 1, pp.29-36, 1982.
- 15) 伊藤陽, 奥津大, 古川愛, 子庄司学, 鈴木崇伸: 通信地下管路の震災時点検結果を基にした機械学習による被害予測モデル検討, 第40回土木学会地震工学研究発表会, 2020
- 16) Kundel, H. L. and Polansky, M.: Measurement of observer agreement, Radiology, Vol. 228, No. 2, pp. 303-308, 2003.
- 17) Zhou, Z.H.: Machine Learning, Springer Nature Singapore Pte Ltd., 2021.

# FUNDAMENTAL STUDY ON PREDICTION OF SLOPE FAILURE DURING EARTHQUAKE BASED ON MACHINE LEARNING

Haoyang XIE, Wen LIU and Yoshihisa MARUYAMA

The 2018 Hokkaido Eastern Iburi earthquake caused a large number of slope failures and casualties in Atsuma town and its surrounding areas. In previous studies, many slope collapse prediction methods have been proposed, and the prediction accuracy has been discussed. However, the prediction models suitable for extensive areas are not solidly developed. In view of the current situation, this study uses machine learning to predict the slope failures during an earthquake. In addition, the influence of NDVI of satellite image on the prediction results of machine learning model is discussed.