

機械学習と力学モデルを併用した 広域斜面崩壊予測の精度評価

ACCURACY EVALUATION OF WIDE-AREA SLOPE FAILURE PREDICTION
COMBINING MACHINE LEARNING AND PHYSICAL MODEL

坂本 達彦¹・笠間 清伸²・古川 全太郎³

Tatsuhiko SAKAMOTO, Kiyonobu KASAMA and Zentaro FURUKAWA

¹九州大学大学院工学研究院 (〒819-0395 福岡市西区元岡 744 番地)

E-mail: sakamoto.tatsuhiko.552@s.kyushu-u.ac.jp

²九州大学大学院工学研究院 (〒819-0395 福岡市西区元岡 744 番地)

E-mail: kasama@civil.kyushu-u.ac.jp

³九州大学大学院工学研究院 (〒819-0395 福岡市西区元岡 744 番地)

E-mail: z.furukawa@civil.kyushu-u.ac.jp

Key Words: slope failure, physical model, machine learning, Geographic Information System

1. はじめに

九州地方では、地理的な条件から、台風の上陸率が高い。また、地球温暖化などの気象条件の変化も指摘されている。これらのことから、局所的な集中豪雨が発生し、土砂災害が頻発している状況にある。平成 29 年 7 月九州北部豪雨では福岡県朝倉市、東峰村および大分県日田市を中心とする広域的な土砂災害が発生した。今後このような災害を軽減するためには、災害関係情報を迅速かつ効率的に活用することが極めて重要である¹⁾。本文では、広域かつ高精度で、リアルタイムに斜面崩壊の発生時間と位置を推定できるシステムを開発することを目的として、気象レーダー情報や地盤情報データベースなどの地形・地質・降雨の空間情報を GIS 上で統合し、降雨時の地下水位変動や浸透流を考慮した力学モデルおよび機械学習を併用して、平成 29 年 7 月九州北部豪雨での斜面崩壊予測に適用し、それぞれのモデルの精度評価を行った。

2. 広域斜面崩壊評価システム

対象地域は、平成 29 年 7 月九州北部豪雨で被災した福岡県朝倉市の北緯 33°25'7" 東経 130°44'27" か

ら北緯 33°20'59" 東経 130°52'29" で囲まれる東西 12.35km, 南北 7.3km の領域である。この地域の地形を 10m×10m のメッシュ状に分割し、斜面安定解析を行った。図-1 に、機械学習と力学モデルを併用した広域斜面崩壊の概要図を示す。

(1) 解析に用いたデータ

力学モデルと機械学習で用いた入力情報を以下に

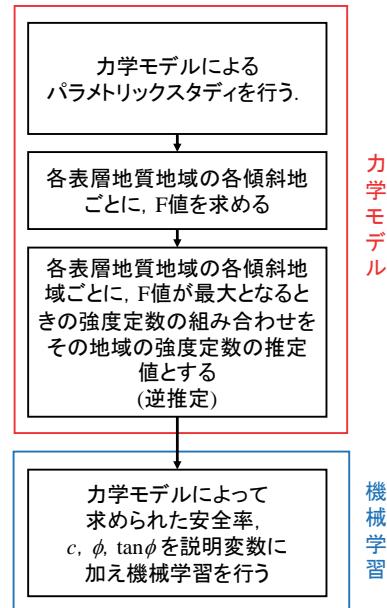


図-1 解析の概要

示す。標高データは、国土地理院から入手した 10m ごとのデータを用いた。表層地質データは、産総研地質図 NAVI より入手した。降雨量は C-X 合成バンドで測定された降雨データであり 250m 間隔で測定されたものである。2017 年 7 月 5 日～6 日の 10 分ごとの降雨データを用いた。崩壊地域は、平成 29 年 7 月 6 日 0:00 でのデータを用いた。図-2 に崩壊地を赤色で示す。対象地域全体のメッシュが 901,550 個

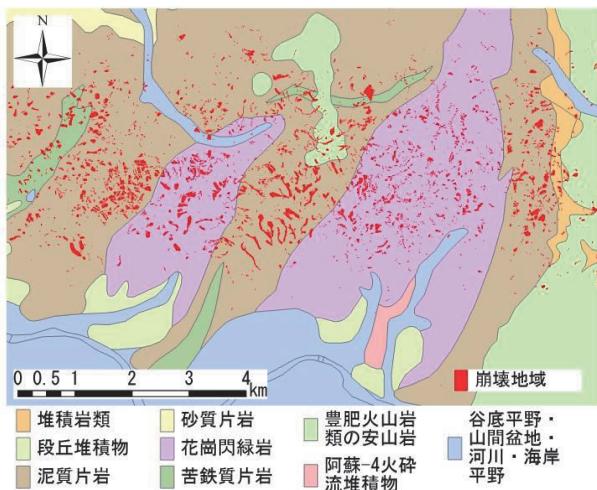


図-2 対象地域の表層地質分布と崩壊地域

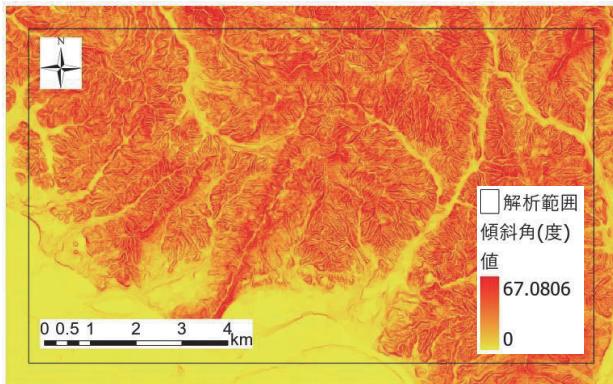


図-3 対象地域の傾斜

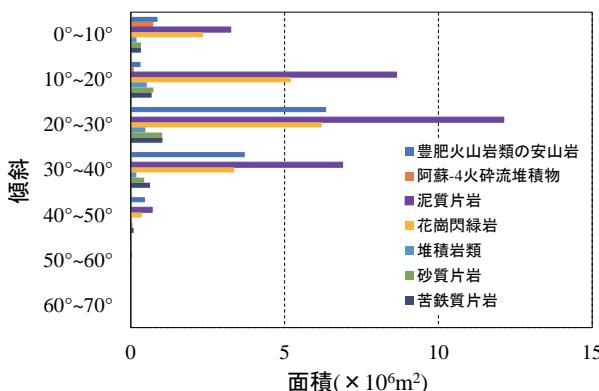


図-4 各地域の傾斜ごとの面積 (m^2)

(1,235 個 \times 730 個)に対して、崩壊地域のメッシュは 29,779 個である。

傾斜角は、対象のメッシュを中心とする 3×3 のメッシュの、東西方向の標高変化率と南北方向の標高変化率から求めた。集水面積は、対象のメッシュに雨が流れるメッシュの数を表すデータである。集水面積の大きいメッシュは流れが集中するエリアで、流路の特定に使用できる。累積流量が 0 のメッシュは、局所的な高地で尾根の特定に使用できる。また、集水面積の計算に用いる流向データは、対象のメッシュが隣接する 8 方向のメッシュから標高の差が最も大きい方向をとる。

以下の図-2～4 に、対象地域の表層地質分布、傾斜、各地域の面積を示す。対象地域では、泥質片岩地域の面積が最も大きく、全体の約 46%を占める。傾斜は $20^\circ \sim 30^\circ$ の傾斜の面積が最も大きく、約 40%を占める。

(2) 力学モデルを用いた解析

降雨量から表面流と斜面浸透量を計算し、メッシュごとに、以下の式(1)に示す無限斜面における安全率計算式を用いて斜面崩壊危険度予測を行った。この力学モデルを用いた斜面崩壊危険度予測モデルの特徴を図-5 に示す。

$$F_s(Z,t) = \frac{\tan\phi}{\tan\delta} + \frac{c - \psi(Z,t)\gamma_w \tan\phi}{\gamma_{sat} Z \sin\delta \cos\delta} \quad (1)$$

ここで、 t は時間(s), $Z = z/\cos\delta$ は崩壊深度(m), z は斜面に垂直な成分, ϕ は土の内部摩擦角($^\circ$), c は粘着力(kPa), δ は傾斜角($^\circ$), $\psi(Z,t)$ は崩壊深度 Z と時刻 t における水圧(m), γ_w は水の単位体積重量(kN/m³), γ_{sat} は土の飽和単位体積重量(kN/m³)を表す。降雨浸透中の水圧 $\psi(z,t)$ の計算方法として、鉛直下方向に浸透が発生するモデルを用いた。

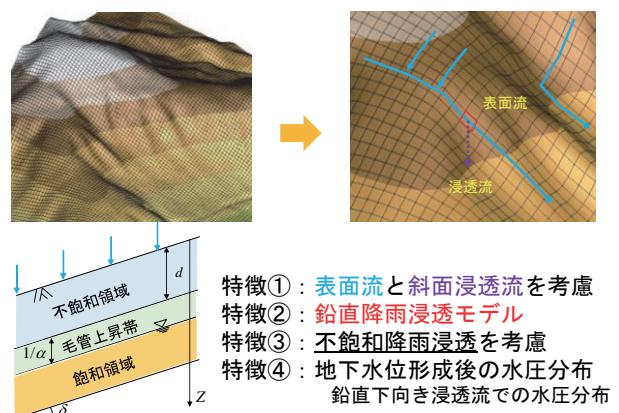


図-5 力学モデルを用いた斜面崩壊危険度予測の特徴

このモデルの飽和領域における水圧計算式と水圧の上限値の計算式を式(2), 式(3)に示す。

$$\psi(Z,t) = (Z-d)\beta$$

$$+ 2 \sum_{n=1}^N \frac{I_{nz}}{k_s} \left\{ H(t-t_n) [D_1(t-t_n)]^{1/2} \operatorname{ierfc} \left[\frac{Z}{2[D_1(t-t_n)]^{1/2}} \right] \right\}$$

$$+ 2 \sum_{n=1}^N \frac{I_{nz}}{k_s} \left\{ H(t-t_{n+1}) [D_1(t-t_{n+1})]^{1/2} \operatorname{ierfc} \left[\frac{Z}{2[D_1(t-t_{n+1})]^{1/2}} \right] \right\} \quad (2)$$

$$\psi(Z,t) \leq Z\beta = Z[\cos^2 \delta - (I_{ZLT}/k_s)] \quad (3)$$

ここで, d : 地表面から地下水位までの深さ(m), $\beta = \cos^2 \delta - (I_{ZLT}/k_s)$, k_s は鉛直方向の飽和透水係数(m/s), I_{ZLT} は平均の地下浸透量(m/s), I_{nz} は分割した n 番目の雨量(m/s), $D_1 = k_s/S_s \cos^2 \delta$ は比貯留率, N は時間間隔の総数, $H(t-t_n)$ はヘヴィサイドの階段関数, t_n は n 番目の時間間隔のときの時間, $\operatorname{ierfc}(h) = (1/\sqrt{\pi}) \exp(-h^2) / \operatorname{erfc}(h)$ は誤差関数を示す。

斜面の崩壊深度は、平成29年7月九州北部豪雨における崩壊前後のLPデータの差の平均値を用いた。斜面の物理定数は、朝倉市に主に堆積する花崗閃緑岩を対象にした現地調査結果²⁾を用いた。花崗閃緑岩地域の物理特性の平均値を表-1に示す。斜面の不飽和浸透特性を考慮するために、朝倉市の花崗閃緑岩風化土を対象に得られた水分特性曲線³⁾を式(4)の形に近似することで、 $\alpha = -6.514(m)$ を求めた。式(5)に不飽和領域における水圧の計算方法を示す。

$$\theta = \theta_r + (\theta_s - \theta_r) \exp(\alpha \psi + 1) \quad (4)$$

$$\psi(Z,t) = \frac{1}{\alpha \cos \delta} \ln \left[\frac{k(Z,t)}{k_s} \right] + \psi_0 \quad (5)$$

ここで、 θ は体積含水率, θ_r は残留体積含水率, θ_s は飽和体積含水率, α は毛管上昇高さの逆数(1/m), $k(Z,t)$ は鉛直方向の不飽和透水係数(m/s), ψ_0 は崩壊深度が0mのときの水圧(m)を示す。

力学モデルを用いた解析では、強度定数を変化させるパラメトリックスタディを行い、表層地質および傾斜ごとの各地域で、(4)に示す精度指標に基づき、F値が最大となるときの強度定数は、その地域の実際の強度定数の値に最も近い値であると仮定し、地域ごとの c , ϕ を逆推定した。パラメトリックスタディにおいて、 c は $20^\circ \sim 40^\circ$, ϕ は $0.5\text{kPa} \sim 7.0\text{kPa}$ の間で変化させた。本文では、適合率と再現率の調和平均であるF値に着目することで、両方の値が大きくなる手法を評価した。

(3) 機械学習を用いた解析

機械学習では、対象地域を $10\text{m} \times 10\text{m}$ のメッシュで区切り、メッシュごとの標高、傾斜、表層地質、集水面積、土壤雨量指数⁴⁾、平成29年7月5日の0:00～7月6日0:00の間の最大10分間雨量、最大30

分間雨量、最大1時間雨量、最大1.5時間雨量、最大3時間雨量、最大6時間雨量、最大12時間雨量、総雨量に加え、力学モデルで得られた安全率、力学モデルのパラメトリックスタディにより逆推定することによって求めた粘着力 c 、内部摩擦角 ϕ 、および $\tan \phi$ を説明変数とした。

全体の70%のデータをランダムに抽出し、平成29年7月6日0:00時点の崩壊の有無を目的変数として機械学習を行い、崩壊の有無を判断する分類モデルを作り、残り30%のデータで分類モデルの精度評価を行った。一般的に機械学習では、学習データを7割～8割、テストデータを2割～3割で行うため、本研究では、データの70%を機械学習、30%をモデルの精度評価という割合にした。本文では、交差検証は行っていない。

機械学習の手法は、決定木、ランダムフォレスト、勾配ブースティング決定木およびXGブースト⁵⁾を用いた。決定木は条件分岐を繰り返すことでサンプルを分類する機械学習の手法である。ランダムフォレスト、勾配ブースティング決定木およびXGブーストは、決定木という機械学習モデルを複数組み合わせることでより強力な機械学習モデルを構築する手法である。ランダムフォレストは少しずつ異なる決定木を複数合わせ平均することで分類の精度を高める手法である。勾配ブースティング決定木は、一つ前に作成した決定木の予測値に新しい決定木の予測値を加え目的関数との誤差を修正することで分類の精度を高めるブースティングを用いた手法である。XGブーストは勾配ブースティング決定木の一種であり、目的関数との誤差を小さくすることで、より高い精度で分類を行うことができるとされている。

機械学習を行った際、説明変数が斜面崩壊の有無

表-1 入力定数

物理特性	花崗閃緑岩帯の 5地点の平均値
土粒子密度 ρ (g/cm ³)	2.60
含水比 w (%)	17.57
乾燥密度 γ_d (kN/m ³)	14.42
飽和度 S_r (%)	56.76
透水係数 k_s (10^{-6}m/s)	6.32
湿潤密度 γ (kN/m ³)	16.87
飽和密度 γ_{sat} (kN/m ³)	18.64
間隙比 e	0.794

の判断に寄与したかを表す重要度を求めた。重要度 $I(j)$ は次の式(6), 式(7)で導かれる。

$$G(k) = \sum_{i=1}^n p(i) \times (1-p(i)) \quad (6)$$

$$\begin{aligned} I(j) &= \sum_{i=1}^{n \in F(j)} ((N_{parent}(i) \times G_{parent}(i)) \\ &\quad - (N_{left_child}(i) \times G_{left_child}(i)) \\ &\quad + N_{right_child}(i) \times G_{right_child}(i))) \end{aligned} \quad (7)$$

ここで, $G(k)$ はジニ不純度, $p(i)$ はノード k におけるターゲットラベル i の頻度, n はターゲットラベルの数, $F(j)$ は特徴量 j が分割対象となるノードの集合, $N_{parent}(i)$ はノード i におけるサンプル数, $N_{left_child}(i)$ はノード i の子ノードのうち左側のノードのサンプル数, $N_{right_child}(i)$ はノード i の子ノードのうち右側のノードのサンプル数, $G_{parent}(i)$ はノード i におけるジニ不純度, $G_{left_child}(i)$ はノード i の子ノードのうち左側のノードにおけるジニ不純度, $G_{right_child}(i)$ はノード i の子ノードのうち右側のノードにおけるジニ不純度を表す。重要度は、ターゲットラベル k が含まれるノードごとに、重みをかけたジニ不純度の減少の平均をとることで求めることができる。

(4) 精度の検証方法

斜面崩壊危険度評価手法の精度を評価するために適中率, 適合率, 再現率, F 値およびスレットスコアという指標を用いた。それぞれ次の(8)~(12)の式で定義される。

$$PA = (TP+TN)/(TP+FP+FN+TN) \quad (8)$$

$$PP = TP/(TP+FP) \quad (9)$$

$$PR = TP/(TP+FN) \quad (10)$$

$$PF = 2 \times (PP \times PR) / (PP + PR) \quad (11)$$

$$PT = TP/(TP+FP+FN) \quad (12)$$

ここで, PA は適中率, PP は適合率, PR は再現率, PF は F 値, PT はスレットスコア, TP は解析と実際の崩壊が合致した斜面面積, FN は解析で未崩壊と判定されたが実際には崩壊した斜面面積, FP は解析で崩壊と判定され実際には崩壊しなかった斜面面積, TN は解析と実際の崩壊が合致しなかった斜面面積を表す。表-2 に TP, FP, FN, TN の定義を示す。適中率, 適合率, 再現率, F 値, スレットスコアは 1 に近づくほど精度が良い。

3. 結果と考察

表-3 に力学モデルのみと、機械学習と力学モデルを併用した解析の予測精度を示す。また、表-4 に XG ブーストによる斜面崩壊危険度予測の混同行列を示す。力学モデルの F 値は、逆推定した c , ϕ を入力データとして解析を行った際の対象範囲全体の F 値である。力学モデルと比較して、機械学習を用いたモデルは、適中率、適合率、F 値およびスレットスコアが大きくなっている。機械学習の方が、力学モデルと比較して適中率が大きい理由は、機械学習モデルの方が、崩壊していない地域を正確に予測することができる。

表-2 TP, FP, FN, TN の定義

		実際	
		崩壊あり	崩壊なし
予測	崩壊あり	TP	FP
	崩壊なし	FN	TN

表-4 XG ブーストの混同行列

		実際	
		崩壊あり	崩壊なし
予測	崩壊あり	2,315	3,303
	崩壊なし	6,803	258,044

表-3 力学モデル機械学習を併用した際の精度

危険度予測手法	検証データ数	適中率	適合率	再現率	F 値	スレットスコア
力学モデル	901,550	0.5481	0.0584	0.6084	0.1065	0.0563
決定木	270,465	0.9574	0.3246	0.2430	0.2780	0.1614
ランダムフォレスト	270,465	0.9672	0.5440	0.1676	0.2562	0.1469
勾配ブースティング決定木	270,465	0.9670	0.6316	0.0513	0.0949	0.0498
XG ブースト	270,465	0.9626	0.4121	0.2539	0.3142	0.1864

できるためと考えられる。機械学習の方が、力学モデルと比較して、適合率、F値およびスレットスコアが大きい理由は、力学モデルを用いた解析では、FPが大きくなりすぎてしまうためであると考えられる。再現率は、力学モデルが機械学習と比較して大きくなつた。しかし、適中率と適合率が小さいことを考慮すると、崩壊すると予測する範囲が、実際に崩壊する範囲に比べ、大きくなりすぎていると考えられる。

力学モデルで精度が上がらなかつた理由としては、

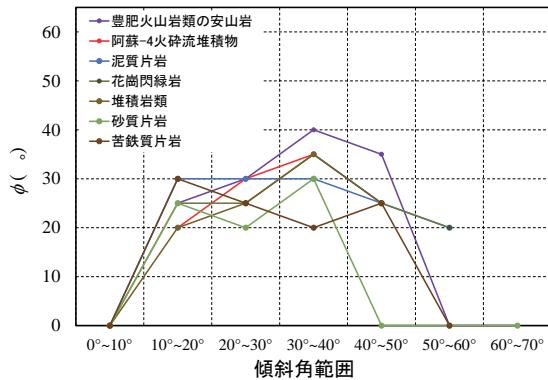


図-6 F値が最大となる傾斜角と内部摩擦角 ϕ の関係

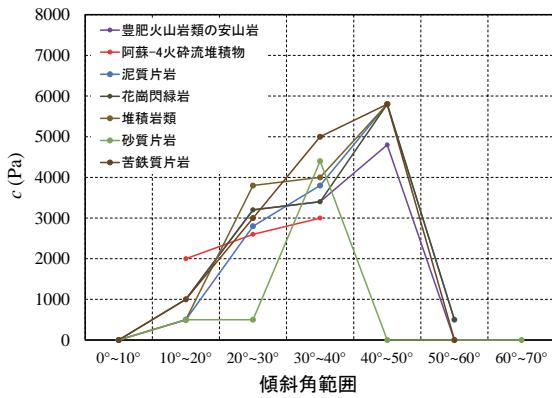


図-7 F値が最大となる粘着力 c と傾斜角の関係

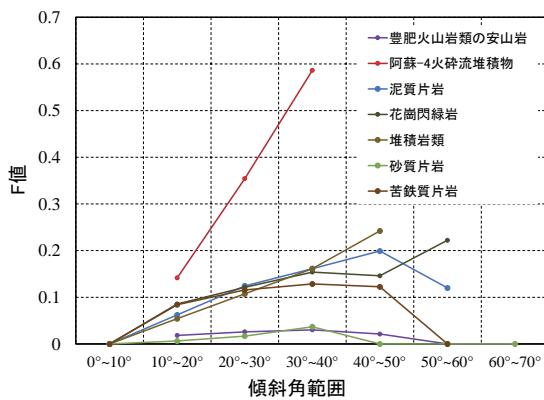


図-8 F値の最大値

以下のことが考えられる。①無限遠斜面を仮定したモデルが、実際の崩壊を予測するためには、単純であった。②崩壊深度を、調査結果をもとに、地質によらず一定と仮定した。③地質と斜面ごとに c 、 ϕ を逆推定したが、より詳細に推定する必要があった。④現地調査で得られた c 、 ϕ を入力した場合⁶⁾でも、より多くの c 、 ϕ を調査する必要があった。

機械学習を用いたモデルは、再現率においては、最も精度が良いXGブーストにおいても0.2539となっており、実際に崩壊した範囲のうち約3/4を崩壊しないと予測している。適合率やF値の値を下げずに、機械学習の再現率を上げることは今後の課題である。

(1) 力学モデルの精度評価

図-6~8に、地質と傾斜ごとに、力学モデルの精度評価によりF値が最大となる時の、強度定数とその時のF値を示す。0°~10°の地域では、傾斜が小さいため、斜面崩壊が起こると予測したメッシュが無く、実際に斜面崩壊が起きなかつたため、F値を計算できない地域と、発生した斜面崩壊を全く捕捉できなかつたため、F値が0となつた地域のいずれかとなつたと考えられる。40°以上の地域では、対象となる範囲が狭いため、発生した斜面崩壊を全く捕捉できずにF値が0となる地域があつた。

阿蘇-4火碎流堆積地域の傾斜角30°~40°の地域でのF値を図-9に示す。グラフからF値は、粘着力が増加するとともに、初めのうちは増加するが、F値が最大値に近い値に達すると、一定に推移する。その後、粘着力がある値を超えると、F値は減少に転じる。F値が増加するときは、力学モデルにより崩壊すると予測した面積が減少しており、その中でもFPの減少量が大きく、TPの減少量は比較的小さいと考えられる。F値が一定に推移しているときは、

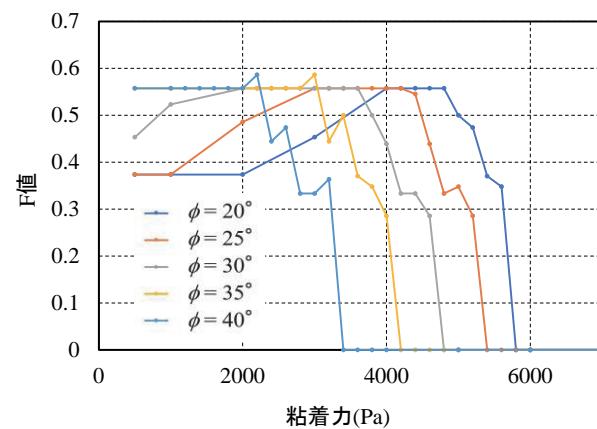


図-9 強度定数毎のF値

力学モデルにより崩壊すると予測した面積は変化していないと考えられる。また、F 値が減少しているときは、TP が減少していると考えられる。

(2) 機械学習と力学モデルを併用した解析の重要度

機械学習と力学モデルを併用した際の各入力定数の重要度を図-10 に結果を示す。決定木とランダムフォレストでは標高や傾斜の地形データの重要度が、他の特徴量と比較して、大きくなつた。勾配ブースティング決定木と XG ブーストでは、最大 6 時間雨量や土壤雨量指数の雨量データの重要度が、他の特徴量と比較して、大きくなつた。力学モデルによって求めた c と ϕ は XG ブーストでは、5 番目と 4 番目に高い重要度となつた。力学モデルの式(1)によって算出した安全率は、決定木とランダムフォレストでは、3 番目に高い重要度となつた。

力学モデルの結果を機械学習の説明変数に用いなかつた場合⁷⁾の F 値と、力学モデルの結果を説明変数に用いた機械学習の F 値を比較すると、決定木と XG ブーストは F 値が大きくなつたが、ランダムフォレストと勾配ブースティング決定木の値は小さくなつた。しかし、F 値の変化は 0.01 以下と小さくなつた。このことから、今回力学モデルを併用する際に用いた説明変数の影響は、他の説明変数で補われたと考えられる。

4. まとめ

福岡県朝倉市の崩壊斜面を対象に、降雨時の地下水位変動や浸透流を考慮した力学モデルを用いて、広域斜面崩壊危険度予測を行い、地質と傾斜別の地域ごとの強度定数を求めた。また、力学モデルの結果と説明変数に加え、機械学習を行い、適中率、適合率、再現率、F 値、およびスレットスコアを用いて精度検証を行つた。

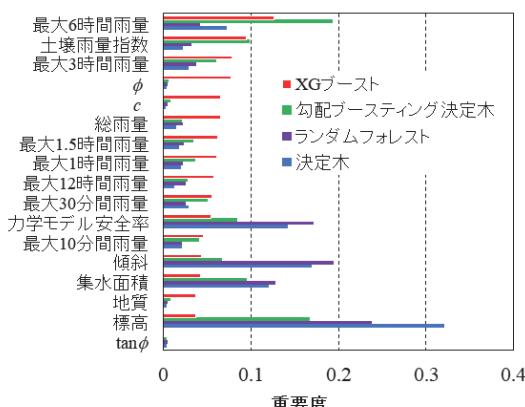


図-10 手法ごとの重要度

- 1) 力学モデルでは、実際の崩壊範囲よりも広い範囲を崩壊すると予測するため、適中率、適合率、F 値の値が機械学習を用いない場合に比べ、小さくなつた。
- 2) 再現率、F 値、スレットスコアの 3 つの精度評価指標で XG ブーストが最も大きい値をとつた。しかし、再現率が低く、実際に崩壊が発生した地域を崩壊しないと予測した。今後の課題として、見逃しの少ないモデルを構築することが挙げられる。
- 3) 本文では、力学モデルを併用する効果は、小さくなつた。今後の課題として、より詳細に c と ϕ を把握する、周辺の崩壊状況を考慮するモデルを作成する、などの手法により精度を向上することが挙げられる。

謝辞：本研究は JSPS 科研費 JP19H00812 と JP20H00266 の助成を受けたものです。

参考文献

- 1) 沖村孝、鳥居宣之、中川渉、原口勝則：土砂災害のためのリアルタイムハザードシステムの作成手順、建設工学研究所論文報告集第 56 号、2014.
- 2) 高橋亮丞、笠間清伸、古川全太郎、山本秀平、中西隆之介：平成 29 年 7 月九州北部豪雨で発生斜面崩壊の形状と土量の分析、自然災害研究協議会西部地区会報第 42 号研究論文集、pp. 75-78, 2018.
- 3) Adel Alowaisy, Noriyuki Yasufuku, Ryohei Ishikura, Masanori Hatakeyama, Shuu Kyono: Continuous pressurization method for a rapid determination of the soil water characteristics curve for remolded and undisturbed cohesionless soils, ScienceDirect, 2019.
- 4) 岡田憲治：土壤雨量指数(技術手帳)，地盤工学会誌。57(8), 2009.
- 5) Tianqi Chen, Carlos Guestrin: XGBoost: A Scalable Tree Boosting System, arXiv.org Cornell University, 2016.
- 6) 高田義人、坂本達彦、笠間清伸、古川全太郎：九州北部豪雨における広域斜面崩壊危険度予測システムの精度について、第 56 回地盤工学会研究発表会発表講演集、2021.
- 7) 坂本達彦、笠間清伸、古川全太郎：機械学習を用いた広域斜面崩壊危険度評価、令和 3 年度土木学会西部支部研究発表会講演概要集、2022.

(2022. 5. 30 受付)