017 機械学習を用いた豪雨による土砂崩壊発生地点の予測と説明可能 AI に基づいた予測根拠の分析

Prediction of Locations of Landslide due to Intense Rainfall Based on Machine Learning Techniques and Explainable Artificial Intelligence

21WM1317 桑折 奎吾 Keigo Koori

SYNOPSIS

The July 2018 heavy rainfall in the Western Japan caused extensive disasters over a wide area. From a long-term perspective, the occurrence of such heavy rainfall is on the increase, and it is important to predict where landslides occur. In this study, we developed numerical models for predicting the locations of landslides using Random Forests (RF) and Light Gradient Boosting Machine (LightGBM). Four models with different methods and explanatory variables were developed, and their prediction accuracies were compared. In addition, we also used SHAP, a type of explainable artificial intelligence (XAI) that has been studied in recent years, to provide explanations of the numerical models.

1. 研究背景と目的

平成 30 年 7 月豪雨(西日本豪雨)は,全国で死者・行方 不明者 270 名以上,全壊の住家 6,700 棟以上の甚大な被害 をもたらした¹⁾.広島県では,死者・行方不明者のうち, 約 8 割が土砂災害の犠牲者とされている²⁾.気象庁の資料 によると,激甚な被害を与えうる豪雨の発生は,長期的な 視点では増加傾向である³⁾.したがって,その被害を減少 させるためにも土砂崩壊発生地点の予測は重要である.

現在,各都道府県は土砂災害による被害の防止・軽減を 目的に,土砂災害警戒区域等4の指定を進めている.しか し,指定には多大な労力を要す.また,平成30年7月豪雨 における広島県南部の土砂災害による被災建物のうち,土 砂災害警戒区域内であったものは約20%であり,平成30 年7月豪雨後に指定された警戒区域を含めても約50%に とどまる⁵. これらを踏まえると土砂災害警戒区域の指定 方法や指定状況には改善の余地があると考えられる.

機械学習に基づいた研究成果 %など,防災分野において AIを使用した研究が多く発表されている.しかし,これら の研究で使用された手法を含め,AIの多くの手法は,結果 が導出された根拠が明らかにならないブラックボックスで ある.防災・減災の意思決定には,人々の安全や安心とい う重要な背景が構えていることを考慮すると,AIをできる だけホワイトボックスに近づける必要がある.

そこで本研究では、記録的な大雨である平成 30 年 7 月 豪雨のデータを使用することにより、豪雨の激甚化を考慮 した土砂崩壊発生地点の予測モデル構築を目指す.これに より、人手をかけずに土砂崩壊の危険性を評価できる.ま た、土砂災害警戒区域の基準では見逃されているものの、 実際には土砂災害の危険性が高い地域の発見にも繋がる可 能性がある.さらに、説明可能 AI (Explainable AI, XAI) ⁷⁾の導入により、モデルの予測結果がどのような判断基準 で導出されたのかを明示化した.これにより、ブラックボ ックスであるため説明が難しかった結果に対する根拠を可 視化し、解釈性の高い分析が可能となる.



図-1 広島大学平成 30 年 7 月豪雨災害調査団の土砂崩壊 発生地点の分布図⁸⁾

2. 本研究の使用データ

本研究で用いる土砂崩壊発生地点の分布データは,広島 大学平成30年7月豪雨災害調査団(地理学グループ)が公 開している平成30年7月豪雨による広島県の斜面崩壊の 詳細分布図[®]である(図-1).本データは,発災後に国土地 理院が撮影した航空写真を判読し,斜面崩壊により土砂移 動が生じた範囲をポリゴンデータとして整備したものであ る.なお,本データと発災後に撮影された衛星画像の比較 を行い,両者の整合性を目視で確認した.データの不整合 が見られた地点については,新たに土砂崩壊のポリゴンを 追加するなどした.

機械学習の説明変数には、素因として標高と傾斜角を、 誘因として土壌雨量指数と時間雨量を用いる.標高は国土 地理院が公開している基盤地図情報の数値標高モデル⁹か ら取得した.数値標高モデルでは、10mメッシュごとに標 高値が格納されている.傾斜角は標高データをもとに10m メッシュごとに算出した.土壌雨量指数¹⁰は、降雨が土壌 中に水分量としてどれだけ含むかタンクモデルを通じて定 量化したものである.本研究では株式会社ハレックスのデ ータ¹¹を使用する.数値は5kmメッシュごとに30分刻み で収録されている.期間は平成30年7月6日~7日のもの を使用する.この期間の土壌雨量指数の最大値,30分毎の 差分の最大値(以下,土壌雨量指数の差分最大値)を説明 変数とした.時間雨量データは,三井共同建設コンサルタ ント株式会社がとりまとめた気象業務支援センターの解析 雨量のデータ¹²を使用した.1kmメッシュごとに30分刻 みで数値が収録されている.期間は平成30年7月2日~ 11日のものを使用する.土壌雨量指数と同様に,期間中の 最大値,30分毎の差分の最大値(以下,時間雨量の差分最 大値)を説明変数として用いた.ここで,時間雨量は最大 値を取る時間にややばらつきが見られたため,土壌雨量指 数よりも長い期間のデータを使用した.

使用データは 50 m メッシュごとに集約する.標高と傾 斜角は、50 m メッシュ単位の最大値を説明変数に用いる. 目的変数は、土砂崩壊発生地点の分布データをもとに、土 砂崩壊ポリゴンを含まない 50 m メッシュを 0:非崩壊、土 砂崩壊ポリゴンを含むメッシュを 1:崩壊とした.また、 対象地域に含まれるメッシュのうち、項目ごとの数値にお いて一つでも欠損している場合は、分析対象から除外した. その結果、本研究では 969.293 メッシュを使用する.

3. 機械学習に基づく豪雨による土砂崩壊地点の予測

本研究では,機械学習により1:崩壊と0:非崩壊を50m メッシュごとに予測する2値分類モデルを構築する.手法 はアンサンブル学習のランダムフォレスト¹³と LightGBM ¹⁴⁾を用いる.ランダムフォレスト(RF)は,複数の決定木 を弱学習器として用いたアンサンブル学習のバギングによ る手法である.決定木を並列的に学習させることで,それ ぞれの結果を補い,高い予測性能を得ることが出来る.一 方,LightGBMは,アンサンブル学習のブースティングに よる手法である.ブースティングは前のステップの弱学習 器の結果を次の学習データに反映させるという特徴がある. また,類似した手法である XGBoost と比較すると計算量が 少ないという特徴がある.

表-1 に精度評価のための混同行列を示す.本研究では予 測結果を評価するうえで,正答率,適合率,再現率,F値 の4つの指標¹⁵⁾を導入する.本研究では, Positive が崩壊, Negative が非崩壊に相当する. 正答率は, 全体の事象の中 で正解した割合である. 適合率は、モデルが Positive と予 測した中で,真に Positive なものの比率である.再現率は, 真に Positive なものに対して,モデルがどれだけ Positive と 予測したかを表す. F 値は, Positive の適合率と再現率の調 和平均である. トレードオフの関係である適合率と再現率 の2つの指標を総合的に見るときに使用する.本研究では, RFと LightGBM において, 説明変数のうち, 誘因の組み合 わせを変えた、それぞれ2種類ずつモデルを作成した.4種 類のモデルを作成し、それぞれの精度を比較することで、 モデルの手法と性質と解像度の異なる2つの誘因(土壌雨 量指数,時間雨量)のどちらを使用したモデルが土砂崩壊 地点の予測により有効であるのかを明らかにする.標高, 傾斜角,土壌雨量指数の最大値,土壌雨量指数の差分最大 値の 4 つを使用した RF モデル (RF1), LightGBM モデル (LGBM1)と標高,傾斜角,時間雨量の最大値,時間雨量 の差分最大値の4つを使用したRFモデル(RF2), LightGBM モデル (LGBM2) を作成した. また, 全データ 969,293 メ ッシュを学習データとテストデータに7:3で分割し、学習 データでモデルの構築を、テストデータでモデルの精度の 検証を行う.分割の際は、学習データとテストデータの崩 壊と非崩壊の割合が同程度になるように調整した.

表-1 精度評価のための混同行列

		予測		
		Negative (非崩壊)	Positive (崩壊)	
実際	Negative(非崩壊)	True Negative (TN)	False Positive (FP)	
	Positive (崩壊)	False Negative (FN)	True Positive (TP)	

表-2 谷予測モデルの混同行列と予測精	渡
---------------------	---

RF1			予測						
		非崩壞	M ^a	崩壊					
実	非崩壊	200,57	8	77,004					
際	崩壊	3,294		9,912					
正答率		適合率	適合率 再現		F 値				
0.72		0.11	0.75		0.20				
RF2			予測						
		非崩壞	非崩壊		崩壊				
実	非崩壊	228,93	8	48,644					
際	崩壊	4,213	4,213		8,982				
ĪĒ	三答率	適合率	再現	率 F 値					
0.72		0.16	0.6	8 0.25					
Ţ	CD1/1		予測						
LGBM1		非崩壞	非崩壊		崩壊				
実	非崩壊	195,54	6	82,036					
際	崩壊	3,060	3,060		10,146				
評価指標									
正答率		適合率	再現率		F 値				
0.71		0.11	0.77		0.19				
Ţ	CD) (A								
LGBM2		非崩壞	非崩壊		崩壊				
	毛 非崩壊 210,17								
実	非崩壊	210,17	7		67,405				
実 際	非崩壊 崩壊	210,17 2,867	7		67,405 10,339				
実際	非崩壊 崩壊	210,17 2,867 評価	7 指標		67,405 10,339				
実 際 正	非崩壊 崩壊	210,17 2,867 評価 適合率	7 指標 再現	率	67,405 10,339 F値				

表-2 に 4 つのモデルのテストデータに対する結果を示 す. まず, RF を用いた RF1, RF2 の結果について述べる. RF1 は正答率が 0.72, 再現率が 0.75 となり, 比較的良好な 結果が得られた.一方,適合率は0.11と低く,その影響で F値も0.20と小さかった.このことから実際は非崩壊であ るメッシュをモデルが崩壊と予測した場合が多かったこと が分かる. RF2 では, 正答率が 0.82 と高い数値が得られた. しかし,再現率は0.68とRF1よりも低い結果となり,適合 率 0.16, F 値 0.25 と, RF1 と同様に非崩壊であるメッシュ を崩壊と予測した場合が多かったことが分かる.次に, LightGBM を用いた LGBM1, LGBM2 について述べる. LGBM1 は正答率が 0.71 であったものの, 再現率は RF1, RF2 よりも高い 0.77 となった. また, LGBM2 は, 正答率 が 0.76 と RF2 に次いで高いうえ,再現率は 0.78 と 4 つの モデルの中で最も高い値となった.防災上の観点からは, 崩壊に対する見逃しが少ないモデルの意義が大きい.した がって,適合率は低いものの再現率が8割近くと最も高い, LGBM2 が最も良好なモデルと考えられる.

図-2 は LGBM2 のテストデータの予測結果を地図上に表 示したものである.表-1 との対応は,青色が TN, 黄色が FP, 赤色が FN, 緑色が TP となる. LGBM2 は, 図の中央 から西側の範囲で、黄色(FP)または緑色(TP)のメッシ ュが多く、広範囲で崩壊箇所と予測されている.一方、中 央から東側は黄色及び緑色のメッシュは少なく、中央から 西側と比較すると赤色(FN)のメッシュが目立ち,崩壊の 見逃しが多いことが分かる. 中央から東側の地域は, 西側 の地域と比較すると標高や時間雨量の説明変数の値が小さ い傾向が認められる. LGBM2 はこれらの説明変数の値が 大きいメッシュを崩壊と予測し、小さいメッシュは非崩壊 と見なす傾向があるため、東側と西側で予測結果の分布傾 向に差異が生じたと考えられる.次章で XAI により、モデ ルの予測結果と説明変数の関係性を詳細に分析する.

4. XAI を用いた分析

本研究では,モデルの予測結果の根拠の明確化のために, 前章のモデルの予測結果について XAI⁷⁾を適用する. 本研 究では, SHapley Additive exPlanations (SHAP)¹⁰を XAI の 手法として採用した. SHAP は、協力ゲーム理論の Shapley 値の概念を援用して, 個別のインスタンスの予測値に対す る根拠を説明する方法である.具体的には、「特定のインス タンスに対する予測値」と「平均的な予測値」の差分を説 明変数ごとの貢献度に分解し、それぞれの説明変数が予測 値に与える平均的な影響を表す SHAP 値という値を求め, 説明を行う手法である.各インスタンスの SHAP 値を集約 し、総合的な分析を行うことで、どの説明変数が、どのよ うにモデル全体の予測に強く影響しているのかを明らかに できる.本研究では、オープンソースのパッケージ ¹⁷を使 用して SHAP 値を計算する.本研究の場合, SHAP 値が正 であればその説明変数は崩壊との予測に寄与し、負であれ ば非崩壊側の予測に寄与することを意味する.

最も有用と判断した LGBM2 の予測結果の一部について, SHAP 値の計算を行った.図-3 に説明変数別にメッシュご との SHAP 値の分布をまとめた蜂群図(beeswarm plot)を 示す.蜂群図は、1次元の散布図で一つ一つのデータが重 ならないように、同値のデータは軸に対して垂直方向に向 かって描画される. 横軸は SHAP 値を表し, 説明変数の並 びは, SHAP 値の絶対平均 (mean absolute value) が大きい 順に上から並んでいる.この並びは、モデルの結果に対す る影響度の強さを表現している.また,色分けについては, 赤色に近いほど、その説明変数の値が大きく、青色に近い ほど小さな値であることを示している.

図-3 によると、LGBM2 は時間雨量の最大値の影響度が 最も強く、次いで傾斜角、標高、時間雨量の差分最大値の 順となっている. つまり, LGBM2 は標高, 傾斜角の地形的 な素因を考慮しつつ,誘因である時間雨量の最大値を最も 影響度の高い根拠として予測結果を導出している.また, 各メッシュの SHAP 値が 0 付近ばかりに集まっている説明 変数も見受けられない. このことから, いずれの素因・誘 因も結果に影響を与えていることが分かり、説明変数とし て妥当であったと考えられる. SHAP 値の色分けに注目す ると、時間雨量の最大値と傾斜角については、値が大きけ れば大きいほど SHAP 値も正の方向に大きくなる傾向が見 受けられる. つまり, 説明変数の値が大きいほど, 崩壊と 予測されやすくなる.ただし,標高と時間雨量の差分最大 値については,明瞭な傾向は確認できない.特に標高につ いては、値が非常に大きい場合に負の SHAP 値を取ってい るメッシュがあることが確認できる.





LGBM2の説明変数ごとの SHAP 値の分布 図-3



図-4 LGBM2の各説明変数とSHAP 値の関係

さらに各説明変数の値と SHAP 値の関係について詳しく 分析する. 図-4 は LGBM2 について, それぞれの説明変数 を横軸, SHAP 値を縦軸に取ったメッシュの分布を表す散 布図である. LGBM2 では、時間雨量の最大値は、値が大き くなるほど SHAP 値も大きくなる傾向がある. 傾斜角につ いては、傾斜角が0°から30°付近までは値の増加にとも ない SHAP 値も大きくなるが, 傾斜角が 40°程度よりも大 きくなると SHAP 値はやや低下気味の横ばいとなる.しか し、SHAP 値は正の値を持つ場合が多いため、依然として 崩壊と予測される要因になりやすいことが分かる.標高は, 上に凸の分布となっている. 300~400 m で SHAP 値のピー クとなり、標高 400m 以上になると SHAP 値は急激に低下 する.この点は、図-3で示したように、標高が非常に大き いと SHAP 値が非常に小さくなることと対応している.ま た,時間雨量の差分最大値は,明瞭ではないが標高と同じ

ような上に凸の分布である. 20 mm/h 程度でピークとなり, 以降は値の増加とともに SHAP 値が低下し, 30 mm/h 程度 で負の SHAP 値が多くなることが確認できる. このことか ら,本研究で用いたデータセットでは,標高 300 m 程度, 時間雨量の差分最大値 20 mm/h までのメッシュとそれ以 上の値を持つメッシュでは,土砂崩壊に関する要因等が異 なる可能性が示唆される. 土砂崩壊の要因をさらに細かく 評価するには,植生や地質の違いなどを考慮することが有 効と思われる.

5. 土砂災害警戒区域外の土砂崩壊に対する予測結果

本研究の予測モデルの結果と土砂災害警戒区域の比較を 行う.三浦・池奥⁵により広島県南部における,平成30年 7月豪雨時の土砂の流入による被災建物と土砂災害警戒区 域の関係についての分析が行われている.その中で,土砂 災害警戒区域が被災建物を含んでいた割合の特に低い地域 が4つ例示されている(広島市安芸区 矢野,坂町 坂東・ 坂西,坂町 小屋浦,呉市 天応西条).これらの地域は発災 後の土砂災害警戒区域のデータにおいても,被災建物は 50%程度しか含まれていない.この4つの地域の土砂災害 警戒区域外の土砂崩壊に対する本研究の予測結果を確認し た.使用するデータとして,土砂崩壊の範囲は本研究の目 的変数として使用した広島大学のもの⁸⁰とする.土砂災害 警戒区域は広島県の公式ページ「土砂災害ポータルひろし ま」¹⁸⁾で公開されている GIS データを使用した.

図-5 に坂町 坂東・坂西に対しての LGBM2 の予測結果 を示す.薄い橙色で示した範囲が土砂災害警戒区域,赤色 で示した範囲が実際の土砂の崩壊範囲である.そのうち黒 線で囲んだ範囲が土砂災害警戒区域外での土砂崩壊の範囲 である.図-5より,黒枠内の多くの崩壊メッシュに対して LGBM2 は正しい予測をしていることが分かる.同様に,そ の他3つの地域においても土砂災害警戒区域外の多くの崩 壊メッシュを正しく予測していたことが分かり,一定の有 用性があると考えられる.

6. 結論

本研究では、平成 30 年 7 月豪雨のデータをもとに、機械 学習によって土砂崩壊発生地点の予測を行う二値分類モデ ルを構築した.説明変数を標高、傾斜角、土壌雨量指数と したモデル(RF1, LGBM1)と標高、傾斜角、時間雨量と したモデル(RF2, LGBM2)の4 種類を構築した.テスト データで精度を確認したところ、再現率が 0.78 と、崩壊の 見逃しが少なかった LGBM2 が防災上の観点から最も有用 であると判断した.

モデルの判断根拠の明確化のために,説明可能 AI(XAI) の手法の一つである SHAP を用いて分析を行った. LGBM2 は時間雨量の最大値,傾斜角,標高,時間雨量の差分最大 値の順に結果への影響度が高いことが明らかになった.ま た,影響度の高い2つの説明変数は数値が高いほど崩壊と 予測することに寄与するが,標高,時間雨量の差分最大値 は特定の範囲の値が崩壊の予測に寄与する傾向が見られた.

最後に,実際に土砂災害警戒区域外で大きな被害が発生 した地域に対しての LGBM2 の予測結果を確認したところ, 土砂災害警戒区域外の多くの崩壊メッシュを正しく検出し ていることが分かった.

今後の課題として、モデルが見逃した崩壊メッシュの傾 向や XAI による分析で示唆されたように、本研究では考慮 していない植生等の新たな説明変数の導入など精度向上へ の検討が必要である.また、他地域、他災害への適用性の 検討も同様に重要である.



図-5 土砂災害警戒区域外での被害が大きかった地域に対しての LGBM2 の予測結果(坂町 坂西・坂東)

参考文献

- 消防庁:平成30年7月豪雨及び台風12号による被害 状況及び消防機関等の対応状況(第60報),2019.
- 海堀正博,長谷川祐治,山下祐一,崎田博史,中井真 司,桑田志保,平松晋也,地頭園隆,井良沢道也,清 水収,今泉文寿,中谷加奈,柏原佳明,加藤誠章,鳥 田英司,平川泰之,吉永子規,田中健路,林拙郎:平 成 30 年 7 月豪雨により広島県で発生した土砂災害,砂 防学会誌, Vol.71, No.4, pp.49-60, 2018.
- 3) 気象庁:特集 激甚化する豪雨災害から命と暮らしを 守るために,気象業務はいま 2020, pp.8, 2020.
- 国土交通省:土砂災害防止法の概要,第1回土砂災害
 防止対策小委員会 配布資料,2019.
- 三浦弘之,池奥和歩:2018年7月豪雨災害における広 島県での土石流による被害地域と土砂災害警戒区域の 空間分析,地域安全学会論文集, No.37, pp.11-19, 2020.
- 古川昭太,丸山喜久:共分散構造分析と機械学習に基づく地すべりと土砂崩壊地点の地形的特徴の評価,土 木学会論文集 A1, Vol.74, No.4, pp.369-380, 2018.
- 恵木正史:XAI(eXplanable AI)技術の研究動向、日本セキュリティ・マネジメント学会誌, Vol.34, No.1, pp20-27, 2020.
- 8) 広島大学平成 30 年 7 月豪雨災害調査団(地理学グループ):平成 30 年 7 月豪雨による広島県の斜面崩壊の詳細分布図(第二報), 2019.
- 9) 国土地理院:基盤地図情報ダウンロードサービス, https://fgd.gsi.go.jp/download/ref_dem.html
- 10) 気象庁:土壤雨量指数, https://www.jma.go.jp/jma/kishou/know/bosai/dojoshisu.html
- 11) 株式会社ハレックス: DreamAll, https://www.halex. co.jp/service/api4.html
- 12) 三井共同建設コンサルタント株式会社:全国ダム・降 雨・土地利用データ整理業務報告書, 2019.
- 13) 波部斉: ランダムフォレスト, コンピュータビジョン とイメージメディア, Vol.2012-CVIM-182, No.31, pp.1-8, 2012.
- 野村総合研究所:LightGBM, https://www.nri.com/jp /knowledge/glossary/lst/alphabet/light_gbm
- 株式会社システム計画研究所編: Python による機械学 習入門,オーム社, 2016.
- 森下光之助:機械学習を解釈する技術,技術評論社, 2021.
- 17) Scott Lundberg : SHAP, https://github.com/slundberg/shap
- 18) 広島県:土砂災害ポータルひろしま, https://www.sabo .pref.hiroshima.lg.jp/portal/top.aspx