

深層学習による桜島の侵食発生地域予測に対する基礎的研究

伊藤 真一¹・酒匂 一成¹・荒木 義則²・岩田 直樹²・小泉 圭吾³

A fundamental study on prediction of eroded areas at Sakurajima

Shinichi ITO¹, Kazunari SAKO¹, Yoshinori ARAKI²,
Naoki IWATA² and Keigo KOIZUMI³

Abstract

After a volcanic eruption, urgent field surveys should be conducted because the susceptibility of debris flows increases. However, under the condition of volcanic activity, it is difficult to survey eroded areas near the craters. Thus, some indirect surveys using topographical information are necessary to sophisticate the disaster prevention system in volcanic regions. This study estimated a deep learning model to predict eroded areas by inputting the angle and Laplacian of a 100m times 100m area, discussed the quantitative accuracy of the estimated model. The analytical results revealed that the deep learning results smoothed by median filter could reproduce the training data with high accuracy and precision.

キーワード：深層学習, 桜島, 侵食, 地形, 土石流

Key words: Deep learning, Sakurajima, Erosion, Topography, Debris flow

1. はじめに

鹿児島県の中央に位置する桜島は、現在も活発に火山活動を続けており、降雨時には頻繁に土石流が発生している¹⁾。そのため、桜島では、砂防堰堤の整備、ワイヤーセンサー・監視カメラの設置、1年間隔での航空レーザー測量などの様々な防災対策が実施されており、その結果、土石流に

よる人的被害は減少している。しかし、桜島の火口付近は噴石などの影響から立ち入り禁止区域が設定されており、土石流の発生源である溪流上部の調査は不可能である。火山噴火時には土砂災害防止法に基づいて緊急調査を実施する必要があるが、桜島のように土石流発生域への立ち入りが現実的に困難な状況は他の火山地域でも考えられ

¹ 鹿児島大学
Kagoshima University

² 中電技術コンサルタント株式会社
Chuden Engineering Consultants

³ 大阪大学
Osaka University

る。つまり、火山噴火後に大量の火山灰が渓流上部に堆積し降雨時には土石流発生の危険性が高いにも関わらず、どの渓流が危険なのかという予測が難しいという状況が想定される。したがって、様々なデータが計測されている桜島を研究対象地域として、火山噴火後の降雨によって土石流の起点となる侵食が発生する渓流を予測できるモデルの構築が可能となれば、他の火山地域における防災対策の策定に対しても有効であると考えられる。

このような状況において、航空レーザー測量による数値標高モデル (Digital Elevation Model, 以下 DEM) データは、立ち入り禁止区域内の情報を上空から入手することができるため、土石流発生の危険性が高い渓流を予測するための貴重なデータであるといえる。近年では、ドローンを用いて DEM データの取得や降灰厚を測定するための調査研究^{2,3)}も行われており、DEM データの有効活用方法の検討は重要である。したがって、まずは DEM データが毎年計測されている桜島において、降雨によって侵食が発生する危険性が高い渓流を地形情報に基づいて予測できるモデルの構築方法の確立が望まれる。

以上の背景から、筆者ら^{4,5)}はこれまでに、ニューラルネットワークを用いて深層学習 (Deep learning) による桜島の侵食発生場所予測モデルの構築に関する研究を行ってきた。既往の研究^{4,5)}では、傾斜やラプリアンといった地形的特徴を入力して、その地点で侵食が発生したかを予測するモデルを構築したが、それらのモデルは未学習のテストデータに対する予測性だけでなく学習データの再現性にも問題があった。これらの結果は、学習データにおいて侵食された点が侵食されなかった点よりも圧倒的に少ないというデータの不均衡問題⁶⁾が原因であると考えられるが、そもそも深層学習によってその地点が侵食されるかどうかを予測するモデル自体が難しいという可能性も考えられる。ここで、上述のような火山噴火後の降雨によって土石流が発生する渓流を予測するという問題を考えるのであれば、その地点が侵食されるかどうかではなく、ある地点周辺のエリ

アが平均的に侵食傾向かどうかを予測できるモデルでも十分有効であると考えられる。さらに、そのような平均的に侵食傾向であるかという侵食発生地域予測モデルは、その地点が侵食されるかどうかという既往の研究の侵食発生地点予測モデルよりも、データの不均衡問題という観点で考えると精度の高いモデルを構築できる可能性が高い。これらを踏まえて、本研究では、深層学習によって桜島の侵食発生地域予測モデルの構築が可能かどうかを明らかにすることを目的とする。また、既往の研究では、構築されたモデルの精度検証に関する定量的な評価が不十分であったことも問題点としてあげられるため、本研究では、混同行列を用いて、構築された予測モデルの精度についても定量的に議論し、予測結果の精度向上のための手法についても検討する。

2. 使用データと地形情報の前処理

2.1 使用した DEM データ

本研究では、平成24年と平成25年に航空レーザー測量によって計測された DEM データを用いて分析を行った。対象範囲は桜島の火口付近の南北に4,250 m、東西に3,750 m の範囲である。DEM データの間隔は 5 m であるため、対象範囲内には南北に850点、東西に750点の合計637,500 点の標高データが含まれており、平成24年と平成25年の2時期のそれらのデータが蓄積されている。なお、DEM データの高さの精度は標準偏差で0.3 m 以内である。

2.2 地形変化と地形的特徴を表す評価指標

同一地点における2時期の DEM データの差分を算出することで、その地点における堆積量や侵食量を概算できる。本研究では、この各地点における DEM データの差分値を地形変化量と定義する。地形変化量がマイナスの地点は、侵食だけでなく崩壊の地点も含まれていると考えられるが、本研究では、それらを区別せず便宜的に侵食と呼ぶことにする。図1は平成24年から平成25年における地形変化量の分布を示している。地点によっては数 m のオーダーで標高値が変化しているこ

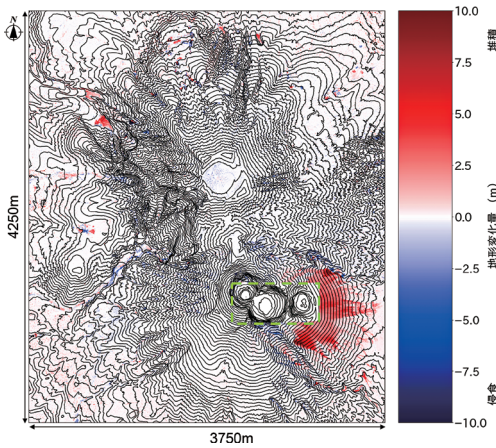


図1 地形変化量の分布図(平成24年から平成25年)

とがわかる。火口付近の赤色の堆積傾向が卓越した領域は火山噴火による降灰の影響を強く受けており、青色で色付けされた溪流は降雨時に侵食が発生したと考えられる。この地形変化量によって地形の侵食傾向を把握することとした。なお、図1における枠線で囲まれた範囲は、火山の爆発の影響によって、1年間での地形変化量が非常に大きい範囲である。これらは降雨による侵食や堆積ではないにも関わらず、分析結果に多大な影響を与えるため、本研究ではこの範囲における地形変化量は考慮しないこととした。

DEMデータから算出される地形的特徴として、DEMデータの1階微分である傾斜⁷⁾と2階微分であるラプラシアン⁸⁾を各地点で算出した。対象とする地点(Z)の近傍の8点(Z_N, Z_{NE}, Z_E, Z_{SE}, Z_S, Z_{SW}, Z_W, Z_{NW})を図2のように定義すると、傾斜は各地点の標高値を用いて次式のように算出される。

$$I = \frac{360}{2\pi} \cdot \arctan \left\{ \sqrt{\left(\frac{dz}{dx}\right)^2 + \left(\frac{dz}{dy}\right)^2} \right\} \quad (1)$$

ここに、

$$\frac{dz}{dx} = \frac{(Z_{NW} + 2Z_W + Z_{SW}) - (Z_{NE} + 2Z_E + Z_{SE})}{8\Delta x} \quad (2)$$

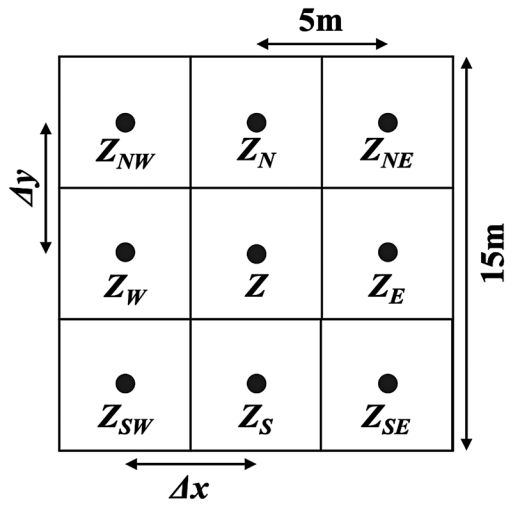


図2 地形的特徴の計算における各記号の定義

$$\frac{dz}{dy} = \frac{(Z_{NW} + 2Z_N + Z_{NE}) - (Z_{SW} + 2Z_S + Z_{SE})}{8\Delta y} \quad (3)$$

である。また、ラプラシアンは式(4)のように算出した。式(4)からもわかるように、ラプラシアンはプラスが凹地形、マイナスが凸地形を表している。

$$\text{lap} = \left(\frac{Z_E 2Z + Z_W}{\Delta x^2} \right) + \left(\frac{Z_N 2Z + Z_S}{\Delta y^2} \right) \quad (4)$$

図3は平成24年における傾斜の分布図を、図4は平成24年におけるラプラシアンの分布図をそれぞれ示している。これらの地形的特徴を用いて、桜島の侵食発生地域を予測できる深層学習モデルの構築を目指す。

3. 解析手法

3.1 深層学習

深層学習の基本となるニューラルネットワークは、脳をコンピューター上のシミュレーションによって模擬しようとする情報処理技術の一つである。図5はニューラルネットワークの概念図を示している。入力層に与えられた情報が中間層を通じて変換され最終的に出力層から予測値が算出される。中間層や出力層に活性化関数を導入するこ




図3 傾斜の分布図(平成24年)

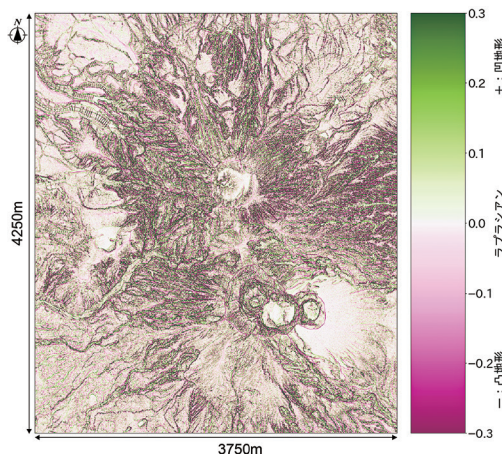


図4 ラプラシアン分布図(平成24年)

とで非線形のモデル化が可能となり、中間層を増やした学習は深層学習と呼ばれる。モデルの構築に関しては、出力層からの予測値と真の目的値(ラベル)の誤差である損失関数(Loss Function)を小さくするように最適化が行われる。

本研究では、Python用のニューラルネットワークフレームワークであるKeras⁹⁾を用いて、桜島における侵食発生地域予測モデルの構築を試みた。図6は本研究で用いた深層学習モデルの構成図を示している。合計6つの中間層と1つの出力層から構成されており、中間層の活性化関数とし




図5 ニューラルネットワークの概念図

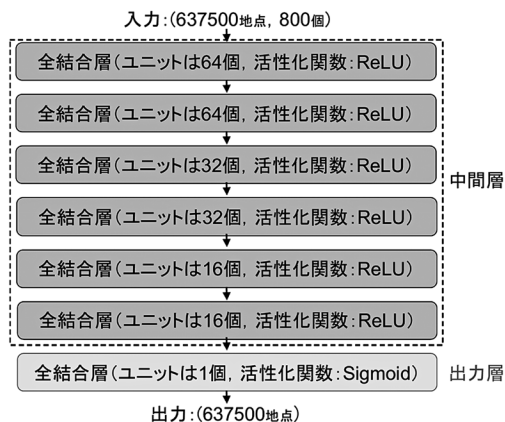


図6 本研究で用いた深層学習モデルの構成図

てはReLU (Rectified Linear Unit)を用いて、出力層の活性化関数はSigmoidを用いた。ReLUはランプ関数とも呼ばれ、次式のように表される。

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (5)$$

上式を微分したReLUの導関数は、

$$f(x) = \begin{cases} 0, & x \leq 0 \\ 1, & x > 0 \end{cases} \quad (6)$$

のように表されるため、中間層を増やした深層学習を行なった場合もモデルの推定時に勾配消失が起こりにくくなるという特徴がある。次に、Sigmoid関数は次式のように表される。

$$f(x) = \frac{1}{1 + e^{-ax}} \quad (a > 0) \quad (7)$$

Sigmoid 関数は 0 から 1 の値を取るため、出力層からは Sigmoid 関数の予測値に基づくスコア (0 から 1 の値) が出力される。なお、モデル構築時における最適化アルゴリズムとしては RMSprop、損失関数としては `binary_crossentropy` を用いた。

3.2 適用データ

深層学習に適用するデータは、真の目的値であるラベルと入力層に代入する入力ベクトルが必要である。ラベルに関しては、既往の研究⁵⁾では、各地点における地形変化量から 1 年間で 1 m 以上侵食された地点のラベルを 1 とし、それ以外のラベルを 0 としていた。図 7 は既往の研究における地形図とラベルの関係を示している。青色で色付けされた地点がラベルが 1 となった (侵食された) 地点であり、白色の地点はラベルが 0 であった (侵食されなかった) 地点を表している。多くの地点のラベルが 0 であり、ラベルが 1 の地点は少ないことがわかる。これに対して、本研究では、対象地点の周辺の $20 \times 20 = 400$ 点 (100 m \times 100 m の範囲) の地形変化量の平均値を算出し、その平均値が 30 cm 以上侵食されていた場合のラベルを 1 とし、それ以外のラベルは 0 とした。この 30 cm 以上という値は DEM データの計測精度を考慮して決定した。図 8 は本研究における桜島の地形図とラベルの関係を示している。図 7 と比較すると、ラベルが 1 となる領域がまとまっておりその面積も広いことがわかる。入力ベクトルに関しては、ラベル作成時に用いた範囲 ($20 \times 20 = 400$ 点) における傾斜とラプラシアンを用いて合計 800 個の入力ベクトルを作成した。つまり、本研究は、対象とする地点の周辺の地形的特徴 (400 点の傾斜と 400 点のラプラシアンの合計 800 個) から対象とする地点の周辺が平均的に侵食されているかどうか (侵食される: 1, 侵食されない: 0) を予測するための深層学習モデルを合計 637,500 点のデータから構築しようとするものである。

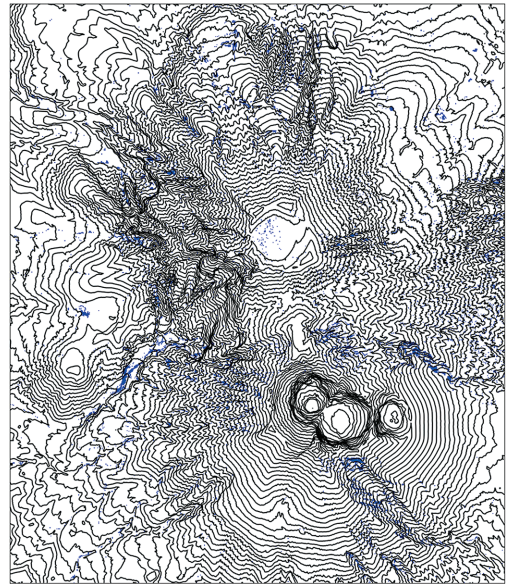


図 7 桜島の地形図とラベルの関係 (既往の研究)




図 8 桜島の地形図とラベルの関係 (平成 24 年から平成 25 年)

4. 解析結果と考察

図9は深層学習によって構築されたモデルに対して入力ベクトルのみを与えた場合の再現解析結果を示している。なお、これ以降は深層学習モデルによる出力が0.5以上であった地点を侵食される：1、0.5以下であった地点を侵食されない：0と判断することとする。この結果は、図8に示すラベルの傾向を概ね再現できているように見えるものの、ノイズ（周辺の点は侵食されないと予測されているにも関わらず、対象地点では侵食されると予測されている点）が多く含まれていることもわかる。本研究で用いた深層学習モデルでは、出力層のSigmoid関数によって0から1のスコアが各地点で算出されるため、地形情報の類似性によってはスコアが0.5程度の曖昧な予測結果となり、それらがノイズとなっている傾向がある。これらのノイズの影響による誤差を定量的に評価するために、混同行列¹⁰⁾を用いて精度、適合率、再現率を算出した。混同行列とは、2クラス分類の評価結果を表現する方法の一つであり、真陽性 (True Positive)、真陰性 (True Negative)、偽陽性 (False Positive)、偽陰性 (False Negative)




図9 深層学習によって構築されたモデルを用いた再現解析結果

を表1のように表現したものである。また、精度、適合率、再現率はそれぞれ以下のように表される。

$$\text{精度} = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$\text{適合率} = \frac{TP}{TP + FP} \quad (9)$$

$$\text{再現率} = \frac{TP}{TP + FN} \quad (10)$$

以上の式からもわかるように、精度は正確な予測を全てのサンプル数で除した割合であり、適合率は陽性であると予測されたもののうちで実際に陽性であったものの割合を表した指標である。再現率は実際に陽性であったもののうちで陽性と予測されたものの割合を示している。そのため、適合率と再現率はトレードオフの関係にあることが知られている。表2は学習データと深層学習による再現解析結果の混同行列を示している。精度は94.8%、適合率は56.1%、再現率は84.2%という結果が得られた。適合率が低いことから、侵食されると予測された点が多く、これは上述したノイズの影響であると考えられる。そのため、本研究では、モデルによる予測結果の適合度を向上させるための手法としてメディアンフィルタ¹¹⁾によるノイズの除去を試みた。メディアンフィルタは図10に示すような画像処理技術の一つであり、対象とする点の周辺の画素の中央値をその点の画素に変更することでノイズを除去して平滑化する技術である。図11はメディアンフィルタで処理した後

表1 混同行列

		予測	
		0	1
実績	0	真陰性 (TN)	偽陽性 (FP)
	1	偽陰性 (FN)	真陽性 (TP)

表2 学習データと深層学習による再現解析結果の混同行列

		予測	
		0	1
実績	0	542296	25247
	1	6069	32288

の再現解析結果を示しており、表3はフィルタ処理後の混同行列を示している。図11の結果は図8に示すラベルと概ね一致しており、表3からは精度は98.5%、適合率は95.3%、再現率は79.5%と




図10 メディアンフィルタの概念図




図11 メディアンフィルタで処理した後の再現解析結果

表3 学習データと深層学習による再現解析結果の混同行列(メディアンフィルタ処理後)

		予測	
		0	1
実績	0	566031	1512
	1	7872	30485

いう結果が得られた。精度と適合率に関してはフィルタ処理前よりも値が上昇しており、精度の向上が確認できる。再現率に関しては、フィルタ処理前よりも値が低下しているが、これはラベルにおける侵食範囲と比較してフィルタ処理によって予測された侵食範囲がやや狭くなったことが影響していると考えられる。ただし、本研究の目的は侵食が発生する地域を予測できるモデルの構築であるため、フィルタ処理後の図11や表3の結果は本研究の目的を十分に達成していると考えられる。したがって、本研究で行ったような深層学習の結果とメディアンフィルタを組み合わせる手法は、地形情報に基づいて桜島における侵食発生地域予測モデルを構築するための手法として有効であるといえる。

最後に、今後の検討課題について示す。図12は平成25年から平成26年のDEMデータから算出した地形変化量の分布を示しており、図13はそこから算出した地形図とラベルの関係を示している。平成25年から26年は降灰量が多かったのに対して降雨量が少なかったことから、侵食されたエリアが少ないことがわかる。このようなデータに対す




図12 地形変化量の分布図(平成25年から平成26年)




図13 桜島の地形図とラベルの関係(平成25年から平成26年)

る予測を試みる場合、本研究では傾斜やラプランアンなどの地形情報のみを学習させてモデルを構築しているため、図13に示すラベルは深層学習モデルによって予測できないと考えられる。この問題を解消するためには、地形情報だけでなく降雨情報や降灰情報も学習させたモデルを構築する必要があるが、降雨情報や降灰情報をどのように与えてニューラルネットワークに学習させるかは今後の検討課題である。また、今後は深層学習のアルゴリズムとして畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)の適用も検討する予定である。

5. まとめ

本研究では、深層学習によって桜島の侵食地域発生予測モデルの構築が可能かどうかを明らかにすることを目的として、構築された予測モデルの精度について定量的に議論した。得られた知見を以下に示す。

- (1) 対象とする地点の周辺(20×20=400点)の地形的特徴に関する入力ベクトルを用いて対象とする地点の周辺が平均的に侵食されている

かどうかを予測する深層学習モデルを構築した。構築されたモデルを用いて再現解析を行うと、ノイズは多く含まれるもののラベルの傾向は概ね再現できることがわかった。

- (2) メディアンフィルタを用いて再現解析結果の平滑化を行うと、ラベルの傾向を良好に再現できることがわかった。この平滑化された深層学習モデルの再現解析結果は、実際のデータであるラベルを精度98.5%、適合率95.3%、再現率79.5%で再現することができており、深層学習の結果とメディアンフィルタを組み合わせる手法は、桜島における侵食発生地域予測モデルを構築するための手法として有効であることが明らかになった。
- (3) 本研究で試みた深層学習モデルの構築方法を用いることで、地形情報から侵食が発生する地域を予測することはできるが、より実用的なモデルとするためには降雨情報や降灰情報を学習させたモデルを構築する必要がある、今後はそれらの学習方法に関する検討が必要である。

謝辞

本研究に対して、国土交通省九州地方整備局大隈河川国道事務所からLPデータ等の基礎データをご提供いただきました。ここに記して謝意を表します。

参考文献

- 1) 国土交通省九州地方整備局大隈河川国道事務所、令和2年土石流調査情報(桜島地域)第一報、<http://www.qsr.mlit.go.jp/osumi/files/Content/1010/pdf/200107report.pdf>、2021年3月9日。
- 2) 荒木義則・木下篤彦・秦雅之・河井恵美・小竹利明・山田拓・柴田俊・亀井稔・松岡和行・南口由行：大規模土砂災害における無人航空機を活用した緊急調査の試行的研究、第10回土砂災害に関するシンポジウム論文集、Vol.10, pp.73-78, 2020。
- 3) 皆川淳・島田徹・永田直己・金崎裕之・永谷圭司・羽田靖史・糸山国彦：ドローンを用い

- た火山噴火時の土石流予測システム, 砂防学会誌, Vol.72, No.6, pp.63-66, 2020.
- 4) 伊藤真一・松尾風雅・酒匂一成・荒木義則・岩田直樹: 桜島における侵食発生地点予測に対するニューラルネットワークの適用, 令和2年度土木学会全国大会第75回年次学術講演会, III-20, 2pp., 2020.
 - 5) 伊藤真一・松尾風雅・酒匂一成・荒木義則・岩田直樹・小泉圭吾: ニューラルネットワークを用いた桜島における侵食発生場所予測モデルの構築, 第10回土砂災害に関するシンポジウム論文集, Vol.10, pp.61-66, 2020.
 - 6) 宮本 崇・浅川 匡・久保久彦・野村泰稔・宮森保紀: 防災応用の観点からの機械学習の研究動向, AI・データサイエンスシンポジウム論文集, Vol.1, pp.445-452, 2020.
 - 7) 独立行政法人土木研究所 土砂管理研究グループ 地すべりチーム: 土木研究所資料 地すべり地における航空レーザー測量データ解析マニュアル, 土木研究所資料, No.4150, 2009.
 - 8) 佐藤丈晴・中島翔吾: 大規模崩壊の兆候となる微地形の抽出方法-天川村における評価事例-, 日本地すべり学会誌, Vol.52, No.3, pp.141-145, 2015.
 - 9) Francois Chollet: Python と Keras によるディープラーニング, マイナビ出版, 2019.
 - 10) Andreas C. Muller, Sarah Guido: Python ではじめる機械学習, オライリージャパン, 2017.
 - 11) Thomas S. Huang, George J. Yang, and Gregory Y. Tang: A fast two-dimensional median filtering algorithm, IEEE Transactions on Acoustics, Speech, and Signal Processing, Vol.27, No.1, pp.13-18, 1979.
- (投稿受理: 令和3年3月31日
訂正稿受理: 令和3年7月2日)

要 旨

火山噴火時には、降灰後の降雨によって土石流が発生する危険性が高まるため、緊急調査を実施する必要がある。しかし、火山活動が活発な状況下では、土石流発生域への立ち入り自体が困難になる。そのため、火山地域における防災システムの高度化のためには、地形情報に基づいて侵食発生地域を特定できる方法の確立が必要である。本研究では、深層学習によって桜島の侵食地域発生予測モデルの構築が可能かどうかを明らかにすることを目的として、構築された予測モデルの精度について定量的に議論した。その結果、100 m × 100 m の範囲の傾斜とラプリアンを入力してその範囲が平均的に侵食傾向かどうかを出力する深層学習モデルを構築し、深層学習の結果に対してメディアンフィルタによる平滑化を行うことで、学習データを良好に再現することができ、精度や適合度も高い結果が得られることがわかった。