

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

鹿児島大学 正会員 ○伊藤 真一, 酒匂 一成

鹿児島大学 学生会員 松尾 風雅

中電技術コンサルタント 正会員 荒木 義則, 岩田 直樹

1. はじめに

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、土砂災害防止法に基づいた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不可能になるため、土石流の発生源である侵食が起こっている地点の把握すら困難である。火山において侵食を引き起こす要因としては、地形、地質、降雨、降灰量など様々な要因が考えられるが、立ち入り禁止区域において最も詳細なデータを得られるのは、航空レーザー測量などに基づく地形情報であると考えられる。筆者らはこれまでに、桜島を対象とした分析を行い、地形的特徴と侵食傾向の関係について明らかにした¹⁾。しかし、既往の研究¹⁾では、地形的特徴からその地点における侵食の有無や程度を予測するモデルの構築には至っていない。そこで本研究では、ニューラルネットワーク (Neural Network, 以下 NN) を用いて、桜島における侵食発生予測モデルの構築を試みる。

2. 使用データ

本研究では、桜島において平成 24 年から平成 30 年までの 7 年間に毎年計測された数値標高モデル (Digital Elevation Model, 以下, DEM) のデータを用いた。DEM データの間隔は 5m であり、対象範囲は桜島の火口付近の南北に 4,250m、東西に 3,750m の範囲とした。このことから、対象範囲における DEM データの個数は 637,500 個であり、そのデータが 7 年分蓄積されている。

NN におけるラベルとして、同一地点における 2 年間の DEM データの差分から地形変化量を算出した¹⁾。本研究では、地形変化量が 1 年間で 1m 以上侵食された地点のラベルを 1 として、それ以外の地点のラベルを 0 とした。入力ベクトルに関しては、既往の研究¹⁾を参考に、DEM データの 1 階微分である傾斜と 2 階微分であるラプラシアンを全ての地点で算出した。

3. 解析手法

本研究では、Python 用の NN フレームワークである Keras²⁾を用いて、桜島における侵食発生予測モデルの構築を試みた。図-1 は本研究で用いた NN モデルの構成図を示している。本モデルはそれぞれ 32 個の隠れ層を持つ三つの中間層と一つの出力層で構成されており、中間層の活性化関数は ReLU、出力層の活性化関数は Sigmoid とした。出力層からは予測値のスコア (0 から 1 の値) が出力される。入力ベクトルに関しては、各ラベルに対応する地点の近傍の 400 個 (100m×100m) の傾斜とラプラシアンを用いた。つまり、800 個の入力 (傾斜: 400 個, ラプラシアン: 400 個) から各地点におけるラベル (1m 以上侵食された or 侵食されていない) を推定するモデルを構築した。NN の学習に用いるデータとしては、平成 24 年から平成 28 年までのデータを訓練データとして用い、平成 28 年から平成 30 年までのデータを検証データとした。なお、学習データや検証データの入力ベクトルは、2 年間のうちの年代の古い方の地形的特徴 (傾斜, ラプラシアン) を用いた。




図-1 NN モデルの構成図

キーワード ニューラルネットワーク, 地形情報, 侵食

連絡先 〒890-0065 鹿児島県鹿児島市郡元 1-21-40 鹿児島大学工学部海洋土木工学科 TEL: 099-285-8482

4. 解析結果

図-2 は学習データと構築された NN による予測結果の比較を示している。(a)学習データにおける青色で示された地点は実際に 1 年間で 1m 以上侵食された地点であり、(b)予測結果における青色の地点は 1m 以上侵食されると NN が予測した地点である。同図は平成 24 年から平成 25 年の結果を示しているが、その他の年も概ね同様の傾向であった。まず、全体的な傾向としては、溪流沿いの急斜面で侵食される地点が多いという学習データの特徴を NN によって表現できていると考えられる。地点ごとに着目すると、地点 A 付近の予測結果は、侵食傾向にある学習データの特徴を良好に再現できている。それに対して、地点 B や地点 C では、予測結果でも侵食傾向自体は表現できているものの、学習データと比較すると侵食される地点の割合が少ない。反対に、地点 D や地点 E は、実際の学習データはそれほど侵食されていないのに対して、予測結果は多くの地点で侵食されると予測されている。このように学習データと NN による予測結果に違いが生じた理由として、学習に用いた入力ベクトルが影響していると考えられる。図-3 は対象地域における地質図を示している。侵食傾向が強い地点 A、地点 B、地点 C が該当する灰色の地質は、斜方輝石単斜輝石安山岩溶岩及び火砕物である。それに対して、地点 D や地点 E が該当する地質は分類がデイサイトである。このことから、侵食傾向には地形情報だけではなく、地質情報も大きく影響していることが明らかになった。今後は、これらの地質情報も NN に学習させることで、より高精度な NN モデルの構築を目指す予定である。

5. まとめ

本研究では、ニューラルネットワークを用いて桜島における侵食発生地点を予測するためのモデルの構築を試みた。得られた知見を以下に示す。

- (1) NN により構築された予測モデルを用いると、溪流沿いの急斜面で侵食される地点が多いという全体的な傾向は表現できるが、地点によっては学習データを表現できない地点もあることがわかった。
- (2) 学習データと NN による予測結果に違いが生じた理由として、地質情報の影響が大きいことがわかった。今後は、地形情報だけでなく地質情報も学習させた NN モデルの構築が必要である。

参考文献

- 1) 松尾風雅, 伊藤真一, 酒匂一成, 荒木義則, 岩田直樹: 桜島における地形的特徴と侵食傾向の関係, 土木学会西部支部研究発表会, pp.345-346, 2020.
- 2) Francois Chollet : Python と Keras によるディープラーニング, マイナビ出版, 2019.
- 3) 産業技術総合研究所 地質調査総合センター: 日本の活火山, 桜島火山地質図(第 2 版), https://gbank.gsj.jp/volcano/Act_Vol/sakurajima/map/volcmap01.html.




図-2 学習に用いたラベルと予測結果の比較