

SAR 画像を用いた崩壊地判読に対する CNN の適用性の検証

鹿児島大学工学部 学生会員 ○藤門裕武, 笛田泰成
 鹿児島大学学術研究院理工学域工学系 正会員 伊藤真一, 酒匂一成
 中電技術コンサルタント株式会社 正会員 岩田直樹, 鹿瀬一希

1. はじめに

豪雨による土砂災害が発生した場合、迅速かつ的確に崩壊地を把握する必要がある。通常、災害直後の崩壊地判読は、航空写真を用いることが多いが、この方法は費用が高いことや悪天候時には航空写真の撮影ができないことなどが課題として挙げられる。これらの課題を解消するための方法として、人工衛星から得られる合成開口レーダ画像(以下、SAR 画像)が注目されている。SAR 画像は天候・昼夜を問わず観測が可能であるため、同一地点における災害前後の差分(強度差分 SAR 画像)を用いることで崩壊地を判読できる可能性がある。実際に、国土技術政策総合研究所によって SAR 画像を用いた土砂災害判読の手引き¹⁾が提案されているが、これに示されている土砂災害判読調査のフローは技術者による目視の作業が多いこと、小規模な土砂災害の検出率が低いことなどが課題として挙げられる。

そこで、本研究では、近年、様々な分野で活用されている AI 技術に着目し、その中でも画像認識の分野で実績のある Convolutional Neural Network(以下、CNN)による崩壊地判読を試みる。本研究の目的は、CNN による SAR 画像を用いた崩壊地予測モデルの構築を試みて、CNN によって構築されたモデルの適用性と課題について明らかにすることである。

2. 解析手法

CNN は、入力層、畳み込み層、プーリング層、全結合層、出力層から構成されるニューラルネットワークであり、主に画像認識に有効とされている。本研究では、python 用のニューラルネットワークライブラリとして Keras を使用し、3 つの中間層と 1 つの出力層から成るモデルを構成した。中間層に畳み込み層とプーリング層を組み込むことで、入力データから特徴を抽出して、その情報を維持したまま画像を圧縮することができる。中間層では活性化関数として ReLU を使用し、出力層では活性化関数として Sigmoid 関数を使用した。また、モデル構築時の最適化アルゴリズムとしては RMSprop、損失関数としては binary_crossentropy を使用した。

3. 適用データの作成

平成 30 年 7 月豪雨によって多数の土砂災害が発生した中国地方のとある地域を研究対象とした。この地域では多数の土石流が発生し、道路に流木や泥流が流入する被害が報告されている。研究対象として近傍の 2 箇所の地域のデータが得られたため、図-1 に示す地域(エリア①)をモデルの構築に用いる学習データ、図-2 に示す地域(エリア②)をモデルの汎用性能を評価するためのテストデータとして用いた。図中の赤色の領域は実際の崩壊地を意味しており、地理院タイル(平成 30 年 7 月豪雨 正射画像)の崩壊地をトレースして作成した。この 2 箇所の地域における強度差分 SAR 画像データと広島県より提供いただいた DEM データを用いて崩壊地判読モデルの構築を試みる。

まず、CNN モデルに入力する特徴量を算出するためのデータ整理を行った。本研究では、CNN モデルを構築するために、強度差分 SAR 画像のデータだけではなく DEM データから得られる地形的特徴もモデルに学習させることとした。具体的には、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各地点で算出した²⁾。図-3 はエリア①における傾斜の分布図を、図-4 はラプラシアンの分布図をそれぞれ示している。次に、強度差分 SAR 画像の作成方法に関しては、

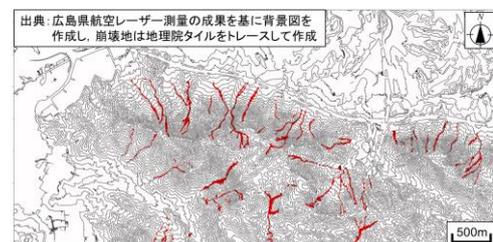


図-1 学習データにおける実際の崩壊地

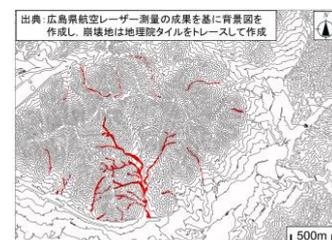


図-2 テストデータにおける実際の崩壊地

災害前後の同一地点における SAR(反射強度: *ref*) の差分を算出することで得られる。ここで、SAR データは緯度・経度でデータが格納されているが、DEM データは平面直角座標系で表されているため、SAR と DEM はデータの座標が一致しない。また、データ間隔も DEM が 1m 間隔であるのに対して SAR は約 2.5m 間隔でデータが格納されているため、CNN によるモデル化のためには、データの位置合わせが必要であると考えた。本研究では、既往の研究³⁾を参考にして重み付けを行うことで、1m 間隔での強度差分 SAR 画像データを作成した。図-5 はエリア①における位置合わせ後の強度差分 SAR 画像の分布図を示している。以上より、図-3、図-4 に示す地形的特徴と図-5 に示す強度差分 SAR 画像の入力データを作成することができた。これと、航空写真を用いて得られた実際の崩壊地(図-1 の赤色領域)をラベルとして用いることで、CNN モデルの構築を試みた。

4. 解析結果及び考察

エリア①のデータを用いて CNN モデルを構築した。図-6 は構築された CNN モデルに学習データを適用した場合の再現結果を示している。図-1 と比較して、学習データに関しては、実際の崩壊地を概ね捕捉できていることがわかる。図-7 は構築された CNN モデルに対して未学習のテストデータを適用した場合の予測結果を示している。図-2 と比較して、全体的な傾向としては、テストデータを用いた場合も溪流沿いの崩壊地を表現できているが、誤って崩壊地と表現した箇所も多いという結果になった。これらは CNN モデルの学習方法に問題があった可能性があるため、より高精度に崩壊地を予測するためには、CNN モデル構築時の中間層の設定や学習回数などの設定について検討していく必要がある。また、学習データに用いる地域が 1 箇所では不十分であり、精度よく予測できなかった可能性も考えられるため、今後はより多くの地域のデータをモデルに学習させることを検討する必要がある。

5. まとめ

本研究では、SAR 画像を用いた崩壊地判読に対する CNN の適用性の検証を行った。結果として、学習データは良好に表現することができたが、テストデータにおいては全体的な傾向は表現できるものの、予測を誤った箇所が多いという結果となった。より高精度な崩壊地予測モデルを構築するために、今後は学習方法の変更や対象地域の拡充などを検討する予定である。

参考文献:

- 1) 鈴木大和ほか: 合成開口レーダ (SAR) 画像による土砂災害判読の手引き, 国土技術政策総合研究所資料, vol.1110, 2020.
- 2) 伊藤真一ほか: 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, 自然災害科学, vol.40, pp1-9, 2021.
- 3) 岩本哲也ほか: 弾性波伝搬問題に対する粒子法の適用性, 応用力学論文集, vol.12, pp.611-622, 2009.

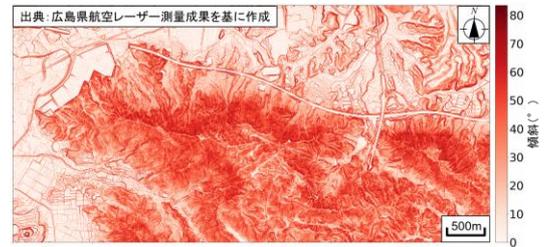


図-3 傾斜の分布図

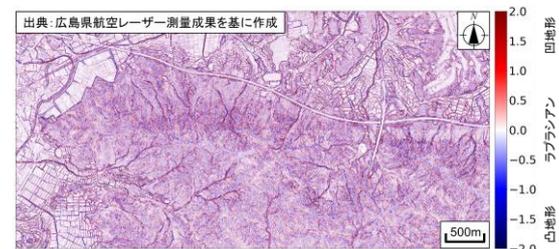


図-4 ラプラシアンの分布図

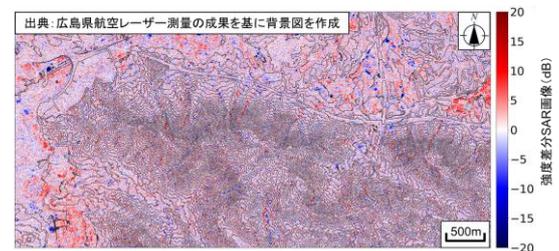


図-5 強度差分 SAR 画像の分布図

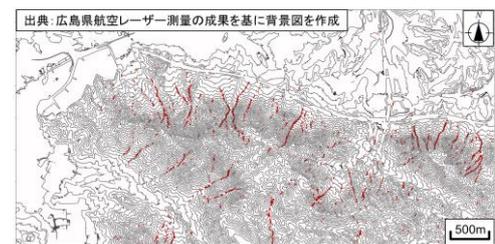


図-6 CNN モデルに学習データを適用した場合の再現結果



図-7 CNN モデルに未学習のテストデータを適用した場合の予測結果