

災害前後 SAR 画像と DEM データを用いた CNN による土砂災害検出

Landslide Detection Using CNN with SAR Images before/after the Disaster and DEM

植田 大介^{*1}
Daisuke Ueda

間普 真吾^{*1}
Shingo Mabu

呉本 堯^{*1}
Takashi Kuremoto

^{*1} 山口大学大学院創成科学研究科

Graduate School of Sciences and Technology for Innovation, Yamaguchi University

Remote sensing using synthetic aperture radar (SAR) images has attracted attention as a method of disaster area detection. However, there is a problem that a lot of experts and time are required for wide-area SAR image interpretation. Therefore, in this research, we propose a method that automatically detects landslide disaster areas using convolutional neural network (CNN). The proposed method uses not only the SAR images after disaster occurs, but also the images before the disaster and altitude data (DEM). In the experiments, the accuracy of classification as disaster area and non-disaster area in the testing areas was 75.56%, and intersection over union (IoU) was 21.86% that showed the ratio of the areas classified as disaster to the actual disaster areas. From these results, it was clarified that the landslide disaster areas could be classified by CNN considering the features of SAR images and DEM data before and after the disaster.

1. 背景と目的

台風や記録的な豪雨により土砂災害が発生した場合、その被害把握の方法として航空機を用いた調査が行われている。しかし、その方法では悪天候では調査が困難であるということや、時間を要してしまうという問題がある。そこで、土砂災害が発生した際に、広範囲な被害状況を悪天候下でも一度に観測する方法として衛星画像を用いたリモートセンシングが注目されている。衛星画像は昼夜、天候の影響を受けず広域観測が可能な合成開口レーダ(Synthetic Aperture Radar, SAR)によって得られた SAR 画像が用いられる。

これまでの多くの手法では災害前後の SAR 画像から算出される NDVI(正規化植生指数)の変化量から土砂災害の検出を行っている[三浦 07]。判読は機械的には行われておらず、人の知識や経験が必要となる。また、広範囲にわたる判読には多くの人員と、時間が必要となる。

そこで本研究では、災害前、災害後の SAR 画像に加え、標高データ(Digital Elevation Model, DEM)を用いた機械学習によって土砂災害の検出を試みた。DEM を用いた理由は、土砂災害の要因の一つとして標高が関係していると考えたためである。

2. 対象データ

本研究で対象とした土砂災害事例は平成 29 年 7 月に発生した九州北部豪雨である。この豪雨により福岡県朝倉市では最多雨量 586.0 ミリを記録し、死者 37 人、行方不明者 4 人となった。

この災害直後に観測された SAR 画像(After)、災害前に観測された SAR 画像(Before)、および標高データ(DEM)を機械学習の訓練データ、テストデータとして用いた。さらに国土地理院によって公開されている土砂災害マスク(True Mask)を実際に災害が発生した場所のラベル付け、評価のために用いた。対象領域の SAR 画像全体のサイズは 6648(横)×4360(縦)である。この画像の 1pixel 当たりの実際の解像度は約 3m²である。




図 1. SAR 画像全体



図 2. 学習に用いたデータを画像化したもの(南東部)

After に True Mask をオーバーレイしたものを図 1 に示す。対象領域の南東部の Before, After, DEM のデータがそれぞれ RGB に対応するように合成した画像を図 2 に示す。

3. 提案手法

本研究では、広域な災害前後 SAR 画像と DEM データ(以下、広域画像と呼ぶ)から土砂災害発生地域の検出を目的とする。検出の手順は、まず広域画像をパッチ分割して災害領域(Abnormal, ABN)、非災害領域(Normal, NOR)に分類して、識別器が学習するためのデータセットを作成する。ABN と NOR の分類基準は後述する。次に識別器にデータセットを用いて学習させる。識別器としては画像の識別で高い性能を示す畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)[岡谷 15]を用いる。そして学習後の CNN を用いて土砂災害発生地域を検出する。

3.1 データセット作成方法

広域画像を北西部、北東部、南西部、南東部(NE, NE, SW, SE)に分割して、いずれかを 2 つの領域を訓練画像領域、1 つ

の領域をバリデーション画像領域、残った 1 つの領域をテスト画像領域(未知領域)とする。

これらの領域からランダムに画像を切り取るが、ABN、NOR の画像枚数は同じになるようにする。この理由は、広域画像には ABN の占める割合よりも NOR の占める割合の方が多いため、各クラスに所属する画像枚数を同程度としない場合、学習に偏りが生じてしまうためである。

3.2 ABN、NOR に分類する条件

データセットを作成する際に、パッチ画像を NOR、ABN に分類する必要がある。そのためにパッチ画像の中央部に注目する。True Mask データを参照してその注目領域(4×4pixel)における災害マスク含有率が 100%であるならば ABN。含有率が 0%であるならば NOR。含有率が 1%～99%であるならば棄却する。

3.3 転移学習

識別器は VGG16[Simonyan 14] を用いる。VGG16 は 2014 年の ILSVRC(ImageNet Large Scale Visual Recognition Challenge)で提案された畳込み 13 層と全結合 3 層の計 16 層から成る高い識別精度を示す CNN である。本研究では ImageNet と呼ばれる大規模な画像データセットで訓練済みの VGG16 モデルを用い、SAR 画像識別に転移させて学習を行う。

3.4 検出方法

未知領域に対して検出を行い、結果を予測土砂災害マスク(Predicted Mask)として表示させる。手法の流れは以下のとおりで、ABN、NOR の識別をピクセル単位で行う。

- Step 1 未知領域と同じサイズの 2 次元配列をすべてカウンター値 0 にして用意する
- Step 2 未知領域においてストライド 1pixel で生成したパッチ画像をモデルに識別させる
- Step 3
- NOR と識別された場合
→パッチ画像の注目領域に対応する座標の配列のカウンター値を +0 する
 - ABN と識別された場合
→パッチ画像の注目領域に対応する座標の配列のカウンター値を +1 する
- Step 4 配列の各カウンター値を参照していく。カウンター値が閾値*未満であるならば、NOR ピクセルとする。カウンター値が閾値以上であるならば、ABN ピクセルとする
*本研究では閾値を 8 とした

例として、未知領域が 4×4pixel、注目領域が 2×2pixel、閾値が 3 であるときの Predicted Mask の生成例を図 3 に示す。




図 3. Predicted Mask 生成例

表 1. テスト画像に対する結果の混同行列

		Predicted label	
		NOR	ABN
True label	NOR	4342	658
	ABN	1786	3214




図 4. 予測災害地マスク画像

4. 実験結果

4.1 データセットの内容

3.1 節で述べた方法で、広域画像の分割領域 NW、NE から訓練画像、SW からバリデーション画像、SE から性能評価用のテスト画像となるパッチ画像を切り取った。以下に各枚数を示す。またパッチ画像サイズは 224×224 である。

- 訓練画像:10000 枚(NOR:5000 枚 ABN:5000 枚)
- バリデーション画像: 2000 枚(NOR:1000 枚 ABN:1000 枚)
- テスト画像: 10000 枚(NOR:5000 枚 ABN:5000 枚)

4.2 テスト画像の識別結果

テスト画像を転移学習後の VGG16 によって識別させた結果(混同行列)を表 1 に示す。識別精度は **75.56%**であった。

4.3 予測災害土砂マスク(Predicted Mask)

予測土砂災害マスク(Predicted Mask)と実際の土砂災害マスク(True Mask)を重ねたものを図 4 に示す。青が Predicted Mask (P)、緑が True Mask(T)、赤が Predicted Mask に含まれている True Mask (P∩T)である。検出の性能を評価する指標である IoU は **21.86%**であった。IoU は次式で導出できる。

$$IoU(\text{Intersection over Union}) = \frac{\text{area}(P \cap T)}{\text{area}(P \cup T)}$$

5. まとめと考察

本研究では土砂災害検出に対するリモートセンシングを CNN(VGG16)によって機械的に行う手法を提案した。入力するデータとして災害前後の SAR 画像と、標高データ(DEM)を用いた。その結果、未知領域における災害地域、非災害地域の識別精度は **75.56%**であった。また、災害と識別した地域と、実際の災害地域の合致割合は(IoU)は **21.86%**であった。生成された予測災害域マスクから、1 種類の情報、たとえば標高データ(DEM)のみ依存して識別することはなく、災害前後 SAR 画像も含めた 3 種類の情報から識別を行っていると考えられる。

参考文献

- [三浦 07] 三浦弘之, 翠川三郎: 高分解能衛星画像と数値標高モデルを用いた 2004 年新潟県中越地震での斜面崩落地の検出, 日本地震工学学会論文集, 第 7 巻, 第 5 号, 2007.
- [岡谷 15] 岡谷貴之: 深層学習, 講談社, 2015.
- [Simonyan 14] Karen Simonyan and Andrew Zisserman: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.