

A-23

衛星画像の深層学習による地震時の土砂崩壊箇所の自動検出

19T0221Y 原 恭也
指導教員：丸山 喜久，劉 ウェン

1. 研究背景と目的

日本では、地震・豪雨が多いことや山地が国土の約6割を占めることが原因となり、人的被害を伴う土砂災害がしばしば発生している。特に、2018年9月6日に発生した北海道胆振東部地震では、震源に近い厚真町を中心に発生した土砂崩壊が主な原因となり、死者43名、負傷者782名と甚大な被害をもたらした（2019年8月20日時点の被害状況）。国土地理院等では土砂災害の分析及び減災を目的として斜面崩壊・堆積分布図¹が作成されている。しかし、斜面崩壊箇所の判読、抽出は作業員が被災地域の衛星画像から目視で行っているため、作業員の負担が大きく、また被害の迅速な把握も難しい状況にある。

そこで本研究では、地球観測衛星が撮影する画像を用いて、土砂崩壊箇所を自動検出する手法を深層学習により構築することを目的とする。

2. 用いる深層学習手法

本研究では、深層学習手法の中でも画像認識に広く使われているCNN(Convolutional neural network)を用いる。CNNとは、人間の脳の視覚野と似た構造を持つ畳み込み層と、畳み込み層の出力を縮約しデータの量を削減する層であるプーリング層を持つ多層ニューラルネットワークである。全結合層のみで構成される多層ニューラルネットワークと比較すると、画素同士の位置的な関係も考慮した特徴抽出ができるという利点があるため、画像分類や物体検出によく用いられている²⁾。

3. 衛星画像の詳細とデータセット作成

(1)衛星画像の詳細

本研究では、地球観測衛星の一つであるSPOT-6,7が北海道胆振東部地震発生後の2018年10月4日に撮影した衛星画像を用いる。撮影対象地域は北海道厚真町周辺であり、画像の大きさは縦14396画素、横13248画素である。また、青・緑・赤・近赤外線³⁾の4つの波長帯の電磁波を記録したマルチスペクトル画像であり、解像度は1.5mである。

(2)データセット作成

SPOT-6,7の観測波長のうち、赤・緑・青に対応したものを合成して作成したトゥルーカラー合成画像と、近赤外線・赤・緑に対応したものを合成して作成したフォールスカラー合成画像の2つを用意した。

それぞれの画像を正規化し、縦128画素、横128画素のメッシュで分割後、土砂崩壊箇所が映っているものを「崩壊あり」、そうでないものを「崩壊なし」として2つに分けラベル付けを行い、トゥルーカラー合成画像を用いたデータセット1と、フォールスカラー合成画像を用いたデータセット2を作成した。図1にラベル付けの例を示す。また、ラベル付けの際、雲や影によって地表が見えない画像は除いた。

画像例				
ラベル	崩壊あり	崩壊あり	崩壊なし	崩壊なし

図1 ラベル付けの例

本研究では分割後の画像が合計8037枚得られた。内訳は、「崩壊あり」の画像が5127枚、「崩壊なし」の画像が2910枚となった。この画像を6:2:2に分け、それぞれ訓練データ、検証データ、テストデータとし、モデルの学習と汎化性能の確認を行った。データセットの詳細な内訳は、表1の通りである。

表1 データセットの詳細な内訳

	崩壊あり	崩壊なし
訓練データ	3448枚	1377枚
検証データ	803枚	803枚
テストデータ	876枚	730枚

4. ネットワークの構造とハイパーパラメータ

ネットワークの構造は、畳み込み層を2から3層連続して配置させることでシンプルな構造で多層化を実現したvgg16³⁾の構造をベースとし、構築した（図2）。また、構築したネットワークのハイパーパラメータを表2に示す。




図2 本研究で用いたネットワーク構造

表2 ハイパーパラメータの詳細

活性化関数	ReLU (中間層)
	Softmax (全結合層)
最適化アルゴリズム	Adam
学習率	0.0001
ミニバッチサイズ	32
損失関数	Cross-entropy Loss
最大エポック数	100
Dropout rate	0.1
Weight decay (荷重減衰係数)	0.0006

5. 学習結果と評価

図2に示したネットワークと表2に示したハイパーパラメータに基づき、データセット1を適用して学習を行ったモデルをモデル1、データセット2を適用して学習を行ったモデルをモデル2として学習を行った。なお、訓練データを学習させる際、画像の回転処理を行い画像の枚数を4倍に拡張した。

各モデルの学習結果として、100エポックの中で最も検証データの損失関数が小さいエポックでの正解率と損失関数値を表3に示す。

また、表3に示したエポック数まで学習を行った各モデルを各テストデータで評価した結果を表4と表5に表す。各テストデータの判別結果を表4では混同行列で示し、表5では性能評価指標で示した。

表3 データセット別の学習結果

	エポック数	正解率	損失関数値
モデル1	18	0.8873	0.2837
モデル2	21	0.9172	0.2382

表4 モデル1, 2のテストデータの混同行列

モデル1		予測結果	
		崩壊あり	崩壊なし
実際の結果	崩壊あり	770	106
	崩壊なし	63	667
モデル2		予測結果	
		崩壊あり	崩壊なし
実際の結果	崩壊あり	790	86
	崩壊なし	48	682

表5 モデル1, 2のテストデータによる精度指標

	モデル1		モデル2	
	崩壊あり	崩壊なし	崩壊あり	崩壊なし
正解率	0.89		0.92	
適合率	0.92	0.86	0.94	0.89
再現率	0.88	0.91	0.90	0.93
F 値	0.90	0.89	0.92	0.91

6. 考察

モデル1, 2で学習を行ったところ、データセット2を用いて学習したモデル2の方が、検証データの正解率が高く、損失関数が小さい結果となった。この結果フォールスカラー合成画像をデータセットとして用いた方が、精度が高くなることが分かった。フォールスカラー合成画像の方が植生の有無を表すのに適しているため、土砂崩壊箇所を認識しやすかったと考えられる。

しかし、どちらのモデルも表3に示したエポック数以降、検証データの損失関数が増加傾向にあり、過学習の恐れがある。過学習は、一般にはデータに対して過剰に複雑なモデルを適応させることや、不適切なハイパーパラメータの設定、訓練データの不足や偏り、データ内のノイズなどが原因となって起こるものである。今回は、手動でハイパーパラメータの設定を行ったこと、訓練データの内訳が崩壊ありに偏っていることが起因して過学習が起こったと考えられる。

また、テストデータの性能評価では、モデル1, 2ともに全指標で9割程度の精度を示し、崩壊あり、崩壊なしの判別に関して汎化性能が高いことが確認できた。

7. 結論と今後の展望

今回構築したモデルによって、土砂崩壊箇所が映っている画像と写っていない画像を92%の精度で判別することができた。しかし、今回構築したモデルでは縦128画素、横128画素の大まかな範囲での土砂崩壊箇所検出となり、実際の土砂崩壊範囲までは特定することができない。よって、今後はアノテーションに基づく画像認識により、土砂崩壊の影響範囲まで特定できるようなモデルの検討を行う。

参考文献

- 1) 国土地理院：平成30年北海道胆振東部地震に伴う斜面崩壊・堆積分布図（北海道厚真町周辺）、https://saigai.gsi.go.jp/3/20180906/iburi-hokai_2-zentaizu.pdf
- 2) 石川聡彦：Pythonを動かして学ぶ！あたらしい深層学習の教科書，翔泳社，2018。
- 3) Karen Simonyan and Andrew Zisserman (2014)：Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv:1409.1556 [cs] (September 2014)