

Detectron2 を用いた震災画像からの被災領域検出の性能向上に関する研究

岡松智洋¹ 鶴田直之¹ 鳥井真之²

概要: 災害発生後も危険は伴うため、迅速な被災地支援が望まれるものの、被災地に人が出向くことが困難な場合がある。そこで、筆者らは被災直後の地域について被災内容や規模を自動推定するための Detectron2 を用いた画像認識技術について研究を続けている。本稿では、誤認識が多かったカテゴリ定義の見直しを中心として従来研究の精度向上を目指した。実験では、2016年に発生した熊本地震関連の画像に対して被災領域の推定を行ったので報告する。

キーワード: 深層学習, Detectron2, 物体検出

A Study on Performance Improvement of Detecting Disaster Areas from Earthquake Images Using Detectron2

TOMOHIRO OKAMATSU^{†1} NAOYUKI TSURUA^{†1}
TORII MASAYUKI^{†2}

Abstract: Although prompt assistance to disaster-affected areas is desirable because of the dangers involved even after a disaster has occurred, it is sometimes difficult for people to visit the affected areas. Therefore, the authors have continued research on image recognition technology using Detectron2 to automatically estimate the content and scale of the damage in the area immediately after a disaster. This paper aims to improve the accuracy of previous research, mainly by revising the category definitions, which were frequently misrecognised. In the experiments, the authors report on the estimation of the disaster area for images related to the Kumamoto earthquake that occurred in 2016.

Keywords: Deep Learning, Detectron2, Object Detection

1. はじめに

日本は、その位置、地形、地質、気象などの自然的条件から、外国に比べて台風、大雨、大雪、洪水、土砂災害、地震、津波、火山噴火などの自然災害が発生しやすい国土である。2016年（平成28年）4月14日には、熊本地震によって甚大な被害が発生した。筆者らは、熊本地震に関するデータを管理するために、熊本震災ミュージアムDBを構築している[1]。この蓄積されたデータを有効活用したい。応用例としては、被災地の早期支援活動が挙げられる。災害発生後も危険は伴うため、被災地に人が出向くことはできるだけ避けたい。そこで、被災直後の地域の画像を収集、画像認識により被災の内容や規模を自動推定することで、効率的な被災地支援が進められると考えられる。

そこで、筆者らは先行研究[6]で、物体検出ライブラリ Detectron2[2][3]を用い、震災画像から被災領域を自動検出した。この自動検出の性能の向上が本研究の目的である。検出の対象であるカテゴリは以下の6つである。

- 地割れ (crack)
- 土台崩れ (collapse_of_the_foundation)

- 家屋倒壊 (collapsed_house)
- 木材がれき (wood_lumber_calabash)
- 土砂 (earth_and_sand)
- 崩壊斜面 (sloping_slope)

2. 基本技術

2.1 Detectron2



図 1 物体検出とインスタンスセグメンテーション

Detectron2 は Facebook AI Research が開発した物体検出用ライブラリである。ベースは Pytorch であり、Mask R-CNN

1 福岡大学
Fukuoka University
2 熊本大学

Kumamoto University

を使用する。Mask R-CNN は Microsoft が開発したディープラーニングのモデルであり、物体検出とインスタンスセグメンテーションを同時に行うことが可能である。図 1 はこれの検出例である。矩形で囲われている領域が物体検出、ポリゴンによってピクセル単位で塗り潰されている領域はインスタンスセグメンテーションである。

2.2 Detectron2 の利用工程

2.2.1 教師データの作成

まずアノテーションを行う。アノテーションとは画像中の対象に沿った意味のあるタグ付けをする作業である。使用するアノテーションツールは FastLabel[4]である。図 2 のように画像中の領域を多角形でタグ付けを行う。



図 2 FastLabel で作成したアノテーション後の画像

FastLabel にて対象の画像のアノテーションが完了したら COCO(Common Object in Context)形式[5]の JSON ファイルをエクスポートする。学習の際にはこの COCO 形式のファイルを用いる。学習用の画像と COCO 形式の教師データを用いて、Detectron2 で学習を行い、重みファイルを生成する。

2.2.2 推論と評価

学習で生成された重みファイルを使用して MaskR-CNN を構築する。この MaskR-CNN に推論を行いたい画像を入力することで推論を行うことができる。これで物体検出、インスタンスセグメンテーションについての情報を画像上に描画、JSON ファイルに出力することもできる。

検出の判定とモデル評価では、まず Mask R-CNN による推論が正解か不正解かを検出領域毎に判定する。この判定は画像単位で行われる。判定は以下の手順である。

1. 画像中のある検出（推論結果）に対して、IOU 閾値（今回は 0.5）を超え、かつ、最も IOU の値を高くとる教師データを対応づける。IOU 閾値を超える教師データがなければ不正解となる。
 2. 1 において、その検出と対応づけられた教師データのカテゴリが一致していたら正解となる。
- 以上の判定を全ての検出結果に対して行う。

そしてこの判定を終えると評価を行う。評価指標は Precision, Recall, F 値である。Precision の計算方法は式 (1) である。

$$Precision = \frac{\text{検出領域の内正解だった数}}{\text{検出した領域数}} \quad \dots (1)$$

この値は誤検出の少なさを表す。

Recall の計算方法は式 (2) である。

$$Recall = \frac{\text{検出領域の内正解だった数}}{\text{実際に被災領域である領域数}} \quad \dots (2)$$

この値は未検出の少なさを表す。

そしてこの二つの値の調和平均をとり F 値を求める。F 値の計算方法は式 (3) である。

$$F \text{ 値} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad \dots (3)$$

この研究では K 分割交差検証を用いる。今回は K=5 とする。これは全画像の 1/K をテストデータとして選択し、残りを学習データとして性能の評価を行う。それを K 回繰り返し、性能の平均を求めるといふものだ。これでモデルの未知の画像に対する性能(汎化性能)を知ることができる。しかし弱みとしてランダム性が故に結果に揺らぎが生じる。

3. 先行研究の課題と提案手法

3.1 カテゴリ「土台崩れ」を「亀裂」として誤検出

図 3 の白色の検出は亀裂となっているが実際の教師データでは土台崩れとなっている。このように、あるカテゴリを他のカテゴリと間違えている誤検出ではこのケースが最も多く見られた。



図 3 誤検出例

亀裂の検出の内訳を表 1 に示す。このような誤検出は、両カテゴリ間の分類の線引きが曖昧であることが原因であると考えられる。この誤検出をされている教師データのカテゴリを新しく「土台崩れ」から「土台崩れ 2」とする。つまりカテゴリ「土台崩れ」を二つのクラスに分割し、学習を新たに行う。これで両カテゴリ間の線引きを明確化し、このような誤検出が減らせないと考えた。

表 1 亀裂の検出の内訳

カテゴリ	件数
亀裂	1407
土台崩れ	14
家屋倒壊	1
木材瓦礫	0
土砂	0
崩壊斜面	4
いずれでもない誤検出	2601



図 4 土台崩れ改良の概念図

改良前では図 4 の左のようにこの 2 カテゴリの分類をする決定境界が複雑で正しい決定境界が学習できていない。そこで「土台崩れ 2」を追加することで新たに「土台崩れ 2」と「亀裂」の間を分類する新たな決定境界を作り、この課題を解決できないかと考えた。

3.2 小物体に対する検出の性能が低い

先行研究では小物体に対する性能が他の中物体、大物体に比べ性能が低かった (表 2)。

表 2 先行研究での面積ごとの性能

サイズ	precision	recall	F 値
small	0.246	0.302	0.270
medium	0.378	0.511	0.434
large	0.459	0.699	0.554

そこで、ある一定の面積以下の被災領域 (例: 図 5) を検出対象から除外する。除外というのは教師データから削除を行うだけでよい。領域の面積が 15×15 ピクセル以下の教師データを削除し、その上で学習を新しく行う。



図 5 小物体の例

3.3 「家屋倒壊」の誤検出

3.3.1 課題

壊れていない家を「家屋倒壊」としての誤検出をしばしば起こしている (例: 図 6)。そこで、壊れていない家の特徴も新しく学習させるとこのような誤検出も減らせないかと考えた。新カテゴリとして「家」を新しく作製し、アンテーションを行う。その後、6 カテゴリの被災領域のアンテーションに加えて「家」も同時に学習を行う。




図 6 家屋倒壊の誤検出例

4. 実験

4.1 実験の目的と方法

被災領域の自動検出性能の向上を目的とする。3 つの提案手法をそれぞれ適用し、提案手法を適用していない結果と比較する。

3 つの提案手法と適用していない結果全て K 分割交差検証で学習、推論、評価を行う。条件は K=5、学習回数 200000 回、IOU 閾値は 0.5 とする。また今回性能比較するのは物体検出 (バウンディングボックス) に限定し、インスタンスセグメンテーションの性能比較は行わない。

4.2 結果

4.2.1 土台崩れを 2 つのカテゴリに分割

カテゴリの書き換え方は具体的に次のようである。「土台崩れ」の領域を「亀裂」と誤検出している領域の教師データのカテゴリを「土台崩れ 2」に変更する。この検出は K 分割交差検証の学習時に生成された重みファイル 5 つそれぞれを用いて、780 枚の画像 (先行研究で使用された全画像) を推論したときの検出である。そして書き換えた後、新しく K 分割交差検証で学習、推論、評価を行う。

結果を次に述べる。カテゴリ毎の Precision, Recall, F 値を表 3 と表 4 に示す。

表 3 改良前の評価結果

カテゴリ	precision	Recall	F 値
亀裂	0.350	0.369	0.359
土台崩れ	0.368	0.528	0.432
家屋倒壊	0.441	0.515	0.472
木材瓦礫	0.314	0.585	0.400

土砂	0.503	0.717	0.584
崩壊斜面	0.594	0.737	0.657
全体	0.384	0.430	0.405

表 4 土台崩れ改良後の評価結果

カテゴリ	precision	recall	F 値
亀裂	0.375	0.363	0.368
土台崩れ	0.343	0.487	0.402
家屋倒壊	0.426	0.459	0.440
木材瓦礫	0.366	0.741	0.486
土砂	0.509	0.695	0.571
崩壊斜面	0.621	0.779	0.688
全体	0.393	0.412	0.402

表 3 と表 4 を比べると「亀裂」の precision が向上している。しかし「亀裂」の F 値は 1% も向上していない。Recall の値が下がったこと、または交差検証のランダム性による誤差の範囲と考えられる。図 7 に改善例を示す。



図 7 改善例

4.2.2 小さな物体を検出対象から除外する

面積が 15×15 ピクセル以下のものを削除する。この教師データの編集によって元は 5832 個であった教師データが 4237 個まで減少した。表 5 と表 3 を比べると「亀裂」の Precision, Recall, F 値が向上したことがわかる。これは「亀裂」が全体の教師データの中でも、特に面積 15×15 ピクセル以下ものが多いことが原因と考えられる。

表 5 小物体除外後の評価結果

カテゴリ	precision	recall	F 値
亀裂	0.394	0.479	0.431
土台崩れ	0.387	0.524	0.444
家屋倒壊	0.457	0.502	0.476
木材瓦礫	0.259	0.581	0.351
土砂	0.720	0.815	0.750
崩壊斜面	0.626	0.752	0.683
全体	0.425	0.518	0.466

「亀裂」の教師データの面積分布を図 8 に示す。15×15 ピクセルという面積はひとまず決めた値であるので目的や用途に応じて適切な設定を決めることができればさらに性能の向上が望まれる。

能の向上が望まれる。

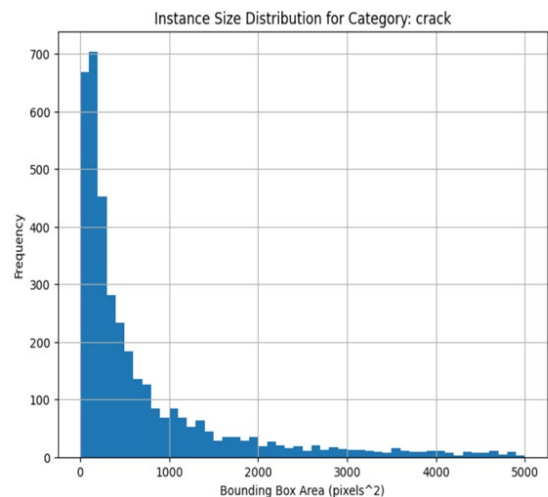


図 8 カテゴリ「亀裂」の面積分布

4.2.3 新カテゴリ「家」の追加

先行研究に使用された 780 枚の震災画像の教師データに加え、新しくカテゴリ「家」の教師データを加えた合計 791 枚の画像(追加の 11 枚も熊本地震時に撮影されたもの)を用いた。まずカテゴリ「家」の追加によって実際「家屋倒壊」がどれほど「家」を誤検出しているのか調べた(表 6)。また表 7 に「家」を含むカテゴリ毎の評価結果を示す。

表 6 「家屋倒壊」の検出の内訳

カテゴリ	件数
亀裂	2
土台崩れ	4
家屋倒壊	381
木材瓦礫	0
土砂	0
崩壊斜面	0
家	39
合計	426

表 7 家カテゴリの改良後の評価結果

カテゴリ	precision	recall	F 値
亀裂	0.379	0.372	0.375
土台崩れ	0.371	0.528	0.435
家屋倒壊	0.360	0.425	0.389
木材瓦礫	0.329	0.693	0.444
土砂	0.512	0.674	0.573
崩壊斜面	0.559	0.748	0.639
家	0.431	0.465	0.446
家以外	0.406	0.437	0.420

表 7 と表 3 を比較すると「家屋倒壊」の性能がむしろ下がってしまっている。考察としては今回追加したカテゴリ「家」の教師データ数が被災領域の教師データ数に比べ、大量であることが原因ではないかと考えている。これによってデータ数の多い「家」の特徴最も特徴の似ている「家屋倒壊」との区別が曖昧になってしまいこのような家屋倒壊の性能が著しく下がる結果となってしまったのではないかと考える。

表 8 カテゴリ毎の教師データの数

カテゴリ	教師データ数
地割れ	4167
土台崩れ	758
家屋倒壊	445
木材瓦礫	368
土砂	57
崩壊斜面	37
家	3387

5. おわりに

5.1 まとめ

3つの提案手法により, Detectron2 を用いた震災画像からの以下の 6 カテゴリの被災領域を対象とした検出の性能の向上を試みた。

まず土台崩れを 2つのカテゴリに分割する手法では性能の向上が望めなかった。むしろ「土台崩れ」の性能が下がってしまっていた。2つ目の手法の、ある一定の面積以下の領域を検出対象外とするものは性能の向上が見られた。3つめの手法である新カテゴリ「家」の追加でも性能の向上は確認できず、むしろ「家屋倒壊」の性能が下がってしまっていた。

謝辞

教師データを作成して下さった(株)正興電機製作所に深くお礼申し上げます。

参考文献

- [1] 廣重法道, 井上雄太, 鬼気拓海, 鶴田直之, 熊本震災ミュージアムデータベースの構築, 月刊地球 号外「基礎データから考える第四紀学の新展開」71 (71) 24-31 (2022.2)
- [2] Git hub 「detectron2」
<https://github.com/facebookresearch/detectron2>
- [3] 「Welcome to detectron2's documentation!」
<https://detectron2.readthedocs.io/en/latest/>
- [4] FastLabel
<https://fastlabel.ai/>
- [5] COCOAPI
<https://github.com/cocodataset/cocoapi>
- [6] 「震災画像からの被災領域検出・分析プラットフォームの構築」福岡大学卒業論文, 2023 年度