

深層学習を用いた土砂災害での被害箇所の検出に関する研究

田中 優也[†] 後藤 真太郎[†] 白木洋平[‡]

[†] 立正大学 地球環境科学部

[‡] 立正大学 データサイエンス学部

キーワード：深層学習，物体検出，空中写真，土砂災害，YOLOv5

1 はじめに

日本では近年、台風等による集中豪雨や局地的大雨が増えており、人的被害をともなう土砂災害の頻発化、激甚化が問題である。特に中国・九州地方は、土砂災害警戒区域が集中している[1]。県別では土石流、斜面崩壊（山崩れ、表層崩壊及び深層崩壊）ともに、広島県が約4万7千箇所と全国最多になっている。過去には平成24年7月九州北部豪雨、平成26年8月豪雨、平成30年7月豪雨等、同時多発的に土砂災害が発生している。

被害把握について従来は、地形図や人工衛星画像とGISを用いた技術者による地形判読がなされてきた[2]。しかし、作業には斜面防災にかかる専門知識と経験、高度な技量が必要である。広域化する土砂災害での迅速な被害把握にはあまり適していない。そのため近年では、AIを用いた深層学習による物体検出による手法が提案されている。物体検出とは、入力された画像や動画から定められた物体の位置と種類、個数を特定する技術である[3]。

被害箇所検出の研究として、古木ら[4]は、敵対生成ネットワーク（GAN）を用いたCS立体図および地すべり地形分布図からの土砂移動部検出を行っている。植田ら[5]は、畳み込みニューラルネットワーク（CNN）を用いた災害前後のSAR画像およびDEMから土砂災害の検出を行っている。これらの既往研究では、土砂災害前後の空中写真と地形情報を用いた、画像セグメンテーションまたは画像分類どちらかによる検出が行われている。しかしながら、画像判読の域を出ておらず、土砂災害に関する地質や植生、地形の起伏量、傾斜、降雨量等の要因に関する知見が活かされていない。

以上の背景より、本研究では、空中写真からの

情報だけでなく、地形・地質的な素因（災害発生・拡大に関する潜在的な環境要因）や誘因（直接被害をもたらす動的な発生要因）を組み込んだ検出モデルの構築を目標としている。その中で、本報告は、深層学習による特徴抽出から、災害直後に撮影された空中写真を対象とした被害箇所の検出と分類、精度の検証を目的とする。

2 手法

2.1 物体検出モデル

モデルの構築にはYOLO（You Look Only Once）[6]を使用した。YOLOは検出と識別を1つのニューラルネットワークを使い、同時に行うことで、検出精度は若干劣るものの、検出速度が高速であるという特徴がある[7]（図-1）。広域で同時多発的な被害箇所を、迅速に把握・検出していくためには、YOLOが最適であると判断し適用した。なお、本研究では2020年に公開されたYOLOv5を用いた。物体検出精度の評価指標として、画像中の被害箇所のうちどれだけ言い当てられたかを表す「再現率（Recall）」と、検出結果の正確さを表す「適合率（Precision）」を使用した。これらの指標は0～1の間の値を取り、1に近いほど精度の良いモデルであるといえる。

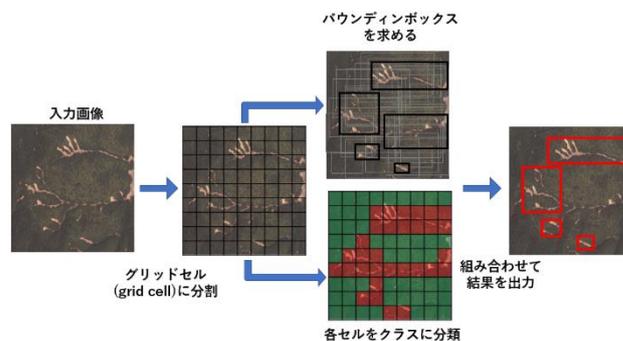


図-1 YOLOの仕組み（[7]をもとに作成）

2.2 学習に用いた画像

学習に必要な画像には、国土地理院[8]によって平成 24 年～26 年にかけて航空機で撮影された、土砂災害発生直後の空中写真（正射画像、斜め写真）を訓練用画像、検証用画像として使用した。

2.3 ラベル付けと学習条件

教師あり学習では、画像の中でどの領域が検出すべき物体であるかを矩形の領域 (Bounding Box) で示すラベル付け作業 (Annotation) が必要となる。YOLOv5 では、あらかじめ正解ラベル入りの様々なデータが含まれているが、土砂災害に対応したデータはなかった為、labelImg で訓練用画像からアノテーションデータを作成した (図-2)。また、元画像から、回転画像と上下左右反転画像を追加し、精度向上のためのデータ拡張を行った。

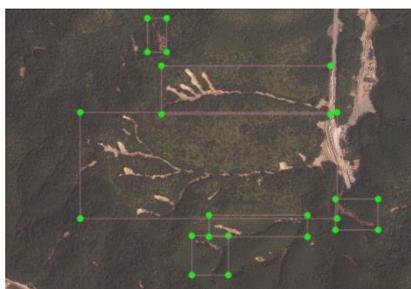


図-2 ラベル付けの例

学習条件を表-1 に示す。本研究では、土砂災害の被害箇所を「土石流」と「がけ崩れ」の2つに分類していく。

表-1 学習条件

利用ネットワーク	YOLOv5
画像サイズ	640×640 (pixel)
画像枚数	464 枚
教師用データ個数	土石流 : 469 がけ崩れ : 1628
学習回数 (epoch 数)	200 回
学習サイズ (batch size)	64

2.4 学習済みモデルを使用した物体検出

作成した学習済みモデルを、テスト用画像として用意した、平成 30 年 7 月豪雨時の空中写真（垂直写真）に適用した。被害地域である広島県を中心とした地域は、マサ土（花崗岩類の風化による

非常にもろい砂状の土壌）が堆積しており、四国や九州に比べ、比較的少なめの雨によっても、簡単に土石流やがけ崩れなどの土砂災害が起こりやすい場所である。そのため、これまでも 150～200mm 程度の雨でも土砂災害が発生しており、特に、一連の雨の後半に強雨があるような降雨パターンの際は、流動性の高い崩壊や土石流等が多数起きることは、過去の豪雨時の土砂災害のときにも共通して見られている[9]。

3 結果・考察

評価指数によるモデルの精度を表-2 に、テスト用画像に適用した結果を図-3 に示す。土石流ラベルは再現率が 0.261、適合率が 0.913 となった。再現率からは、画像中の土砂災害の被害箇所のうち、約 25%を言い当てられていたことがわかる。適合率からは、土石流だと推測したボックスのうち、約 90%が正解していたことがわかる。2つの指標から、「土石流ラベルでは検出漏れが多いが、検出時の正解率は非常に高い」という結果になった。

がけ崩れラベルは再現率が 0.387、適合率は 0.314 となった。再現率からは、約 40%を言い当てられたことがわかる。適合率からは、がけ崩れだと推測したボックスのうち、約 31%が正解していたことがわかる。2つの指標から、「がけ崩れラベルでは検出漏れが多く、誤検出も多い」という結果になった。がけ崩れと検出したボックスの中には、実際には土石流だったもの含まれていた。

被害箇所の土砂の色である茶色には、画像によって明暗があるが、検出の偏りは見られなかった。

表-2 評価指数

クラス	再現率 (Recall)	適合率 (Precision)
土石流	0.261	0.913
がけ崩れ	0.387	0.314
平均	0.324	0.614



図-3 被害箇所の検出結果

検出漏れのある領域は、空中写真からの視認も難しい領域であった。また、テスト用画像の画角は訓練用画像よりも 2.5 倍近く大きく、画像中の特徴量が少なくなったことで検出漏れが起きたと考えられる。土石流ラベルで適合率が高くなったのは、ラベル付け時のデータばらつきが少なく、テスト用画像でも同じ形状・同じ規模の土石流が発生していたからだと推測できる。がけ崩れラベルで再現率・適合率ともに低くなっているのは、ポジティブサンプルとネガティブサンプル間の距離が狭くなりすぎており、分離する境界の精度が良く出ない為だと考えられる。

両方のラベルとも再現率が低くなっているのは、使えるポジティブサンプルのデータが不足していることが最大の原因だと考えられる。また図-4 のように、空中写真の中に被害箇所の色に近い領域が複数存在していたことも原因の一つである。



図-4 誤検出の例

(家屋、海に浮かぶ養殖場、畑に張った泥水)

4 まとめ・今後の課題

本研究では、深層学習による特徴抽出から、災害直後に撮影された空中写真を対象とした被害箇所の検出、分類とその精度の検証を行った。

本研究で得られた結果を以下に示す。

- (1) 深層学習は被害箇所の把握にある程度適用可能である。しかし、本モデルでは検出漏れや被害箇所とよく似た領域の誤検出が多く、現状、現場での使用は難しい。
- (2) 物体検出モデルの評価指数を用いて検証した結果、訓練用画像の不足とポジティブデータの不足が原因で、検出精度が低下していた。特に訓練時とモデル適用時におけるカメラと対象物との距離が違うことで、小さな物体を検出することが出来ず、結果としてモデルの精度を落としていた。

今後の課題として、検出精度向上のため、短径の領域を囲む際に学習が上手くいきやすいラベル付けルールを考えていく必要がある。また、本研究では、前述のように空中写真からの情報だけでなく地形・地質的な素因や誘因を組み込んだ検出モデルの構築を目標としている。今後は、被害箇所の DEM データから、傾斜と累積流量の算出、モデルへの適用について検討していく予定である。

参考文献

- [1] 全国治水砂防協会：各都道府県における土砂災害警戒区域等の指定状況（都道府県）令和 4（2022）年 6 月 30 日現在。
https://www.jstage.jst.go.jp/article/sabo/74/2/74_3/_pdf（参照：2022.11.12）
- [2] 水野正樹，神山嬢子，江川真史，佐藤匠，浦原潤一，林真一郎：単偏波の高分解能 SAR 画像による河道閉塞判読手法（案），国土技術総合研究所資料，2013，第 760 号。
<http://www.nilim.go.jp/lab/bcg/siryuu/tnn/tnn0760pdf/ks076006.pdf>（参照：2022.11.14）
- [3] クリスタルメソッド株式会社：AI による物体検出の手法やモデルを解説します。
<https://crystal-method.com/topics/object-detection/>（参照：2022.11.6）
- [4] 古木宏和，稲垣裕，一言正之，櫻本智美，藤平大：深層学習を用いた地すべり地形自動抽出の試みと教師データの影響，砂防学会研究発表会概要集，2018，No.83，pp.145-146。
<http://www.jsece.or.jp/event/conf/abstract/2018/p>

- df/73.pdf (参照 : 2022.11.10)
- [5] 植田大介, 間普真悟, 呉本堯 : 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, 人工知能学会全国大会論文集, 2018, 第 32 回.
https://www.jstage.jst.go.jp/article/pjsai/JSAI2018/0/JSAI2018_1D102/_pdf/-char/ja (参照 : 2022.11.10)
- [6] Joseph, Redmon; Santosh, Divvala; Ross, Girshick; Ali, Farhadi: You Only Look Once: Unified, Real-Time Object Detection, Computer Vision and Pattern Recognition (CVPR), 2015.
<https://arxiv.org/pdf/1506.02640.pdf> (参照 : 2022.11.12)
- [7] @kindamu24005 : 【YOLO】の仕組みを簡単にまとめてみた【物体検出アルゴリズム】, Qiita, 2022.
<https://qiita.com/kindamu24005/items/efd53c7511a40ddac636> (参照 : 2022.11.16)
- [8] 国土地理院 : 過去の災害関連情報一覧, 台風・豪雨等に関する国土地理院の対応, 2022.
<https://www.gsi.go.jp/kohokocho/kakosai202001.html#taihu1> (参照 : 2022.11.15)
- [9] 海堀正博, 他 : 平成 30 年 7 月豪雨により広島県で発生した土砂災害, 砂防学会誌, 2018, Vol.71, No.4, Pp.49-60.
https://www.jstage.jst.go.jp/article/sabo/71/4/71_49/_pdf (参照 : 2022.11.16)