

## 画像分類及びセグメンテーションを用いた土砂移動部自動検出に関する基礎研究

山口大学大学院 学生会員 ○劉 小熙

山口大学大学院 正会員

河村 圭

防災科学技術研究所

若月 強

## 1. はじめに

日本では、険しい山が多いため、地震や台風や豪雨の際に発生する土砂災害の環境被害が問題となっている。土砂災害の広域分布を把握するために、災害後に撮影した空中写真（航空写真）から目視による土砂移動部の判読作業が現在様々な機関で行われている<sup>1)</sup>。しかし、判読作業は長時間の緻密な作業を必要とするため、作業者にとって大きな負担となっている。この作業を効率的に行うため、近年、深層学習の技術を利用し、土砂移動部の検出に関する研究が進められている。中西<sup>2)</sup>らは VGG16 と LeNet を用いて CS 立体図と地質図を入力し、土砂移動部検出を行っている。

張<sup>3)</sup>らは、入力画像のチャンネル数が土砂移動部の検出精度に及ぼす影響を検証するとともに、スライド分割手法を用いた土砂移動部検出手法を提案している。この研究では、土砂検出器の学習時に土砂移動部を含む（以下、土砂ありと記述する）領域の画像のみを訓練データとして利用していることから、土砂あり領域画像における土砂移動部の検出精度は高いが、土砂なし領域画像では誤検出が多い結果となった。

そこで、本研究では、土砂検出精度の向上を目的として、画像分類手法とセグメンテーション手法を組み合わせ合わせたカラー画像から土砂移動部を検出する検出器の開発を行った。具体的には、土砂検出器は、土砂分類器と土砂領域抽出器から構成される。土砂分類器は、入力されたカラー空中写真の分割画像を、都市部と森林部に分類し、さらに土砂移動部を含む画像と土砂移動部を含まない画像に分類するものである。これらは、深層学習モデルである ResNet-101<sup>4)</sup>と ResNeXt-101<sup>5)</sup>を用いて構築した。また、土砂抽出器は、分割画像から画素レベルで土砂移動とそれ以外を分類するセグメンテーションを行う深層学習モデルの U-net<sup>6)</sup>により構築した。

## 2. 提案手法

## 2.1 提案手法の概要

図-1 には、本研究で提案する土砂移動部の自動検出手法の概要を示す。本手法では、まず、STEP 1 にて、空中写真を 224×224pixel の小領域画像に分割する。STEP 2 では、STEP 1 で分割された分割画像群に対して、ResNet-101 をベースとした深層学習モデルにより、「森林」と「都市」の2つのクラスに分類する（以下、この分類器を都市森林分類器と記述する）。続いて、STEP 3 では、STEP 2 で分類された森林画像群と都市画像群それぞれを ResNeXt-101 により構築した別々の土砂領域分類器へ入力する。ここで、森林画像群は、「森林土砂あり」「森林土砂なし」の2クラスに分類される（以下、この分類器を森林土砂領域分類器とする）。都市画像群は、「都市土砂あり」「都市土砂なし」の2クラスに分類される（以下、この分類器を都市土砂領域分類器とする）。さらに、STEP 4 では、CNN モデルの一つである U-net により画素レベルで土砂移動部を抽出する（以下、この抽出器を土砂領域抽出器と記述する）、なお、土砂領域抽出器へは、STEP 3 で土砂ありと分類された画像のみを入力し、土砂移動部を抽出する。STEP 3 で土砂なし領域と分類された画像は、自動的に、すべての画素を土砂移動部ではないと判定する。最後に、STEP 5 では、土砂検出処理を行った分割画像を、元の画像サイズに合成する。

## 2.2 本研究で用いた学習用データ

本研究では、土砂災害に関する知識を有した防災科学技術研究所の研究者が、土砂移動部箇所を判読した結果画像（以下、正解画像と記述する）と空中写真をペアとし、深層学習に利用した。本研究で利用した画像は、2018年の土砂災害後に広島県で撮影した空中写真及び正解画像であり、この領域から、学習用データとして、土砂移動部の多い領域の空中写真（12709×6087pixel）を12箇所選択し、それぞれを224

キーワード ディープラーニング、畳み込みニューラルネットワーク、画像分類、画像認識

連絡先 〒755-8611 山口県宇部市常盤台 2-16-1 山口大学大学院 創成科学研究科 TEL 070-4365-4440

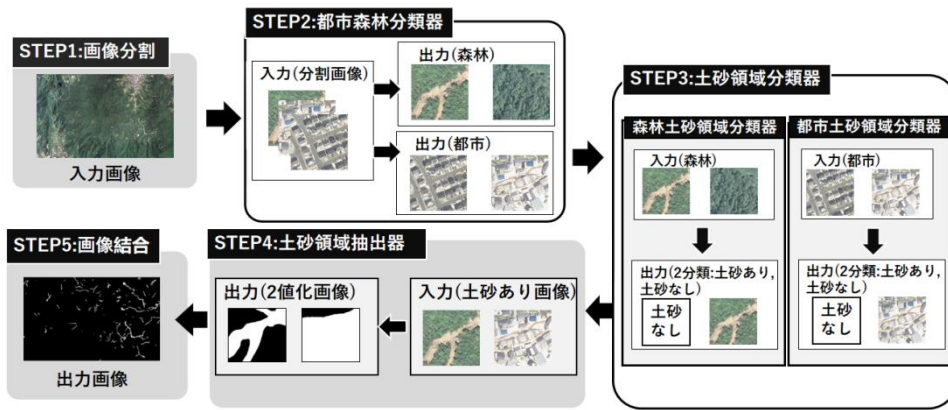


図-1 提案法の概要

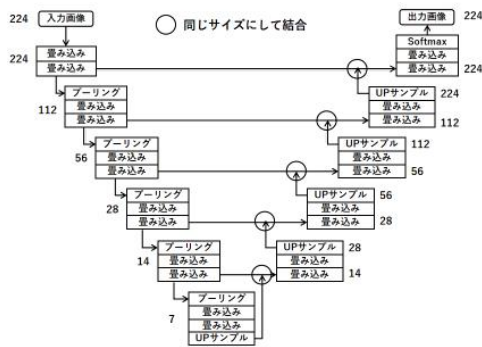


図-2 U-net のネットワーク構成図

×224 pixel に単純分割法で分割した。

### 2.3 土砂分類器の作成

本研究では、ResNet-101 を用いて都市森林分類器を構築し、ResNeXt-101 を用いて土砂領域分類器を構築した。ResNet-101 はネットワーク構成が簡素で実用的であるという利点があり、画像分類問題の分野でよく用いられる。この深層学習モデルは、比較的分類しやすいデータに対して応用される。本研究では、分割画像を「森林」と「都市」の2クラスに分類するために利用した。ResNeXt-101 は、ResNet-101 に基づいて改良された深層学習モデルであり、学習精度が高いという利点があり、難易度の堅い分類データを分類することができる。本研究では、「森林」と「都市」に分類された画像群を、さらに「土砂あり」と「土砂なし」の画像に分類するために利用した。

### 2.4 土砂領域抽出器の作成

図-2 には、土砂領域抽出器に利用した U-net のネットワーク構成図を示す。U-net による画像処理は、まず、入力画像に対して畳み込み層とプーリング層を繰り返し処理した後に、UP サンプル層を用いて畳み込みの結果から特徴マップを復元する。各層の特徴マップは、

図-2 中右側に示すように、2 回の畳み込み層処理後の画像である。最後に、各画素の土砂領域確率は、Softmax 関数によって計算される。各画素に対して求められた土砂領域確率を、閾値を用いて二値化する（値が 0.5 未満であれば土砂なし、値が 0.5 以上であれば土砂あり）。

## 3. 提案手法の検出精度実験

### 3.1 実験目的

本章では、土砂分類器が検出結果に及ぼす効果を検証する。土砂分類器を追加した検出器（以後、検出器 A）と土砂分類器を追加しない検出器（以後、検出器 B）を作成し、その土砂検出精度を比較した。

### 3.2 実験方法

#### (1) データセットの作成

土砂分類器の学習では、2.1 章に記述した空中写真データを用いて、土砂ありと土砂なしの分割画像空中写真を学習データとして用いた。具体的には、2609 枚の森林画像と 1872 枚の都市画像を学習用データとして都市森林分類器を学習した。また、871 枚の都市土砂あり画像と 758 枚の都市土砂なし画像を学習用データとして都市土砂領域分類器の学習を行った。さらに、2072 枚の森林土砂あり画像と 922 枚の森林土砂なし画像を学習用データとして森林土砂領域分類器を作成した。

土砂領域抽出器の学習では、2.1 章に記述した空中写真データを用いて、土砂あり（正解画像における土砂移動領域が 5%以上存在するもの）分割画像のみを学習データとして用いた。学習用データの数を増やすために、学習用データとして選択した土砂ありデータとその正解画像を右に 90 度、180 度、270 度で 3 回の回転処理を行い、学習用データ総数を 4 倍にし、合計は 9264 ペア（空中写真と正解画像のペア）とした。この中で、

表-1 都市森林分類器の学習条件

深層学習モデル	ResNet-101
画像サイズ	224×224 (pixel)
森林画像数	2609 (枚)
都市画像数	1872 (枚)
学習回数	100 (エポック)

表-2 都市土砂領域分類器の学習条件

深層学習モデル	ResNeXt-101
画像サイズ	224×224 (pixel)
都市土砂あり画像数	871 (枚)
都市土砂なし画像数	758 (枚)
学習回数	100 (エポック)

表-3 森林土砂領域分類器の学習条件

深層学習モデル	ResNeXt-101
画像サイズ	224×224 (pixel)
都市土砂あり画像数	2087 (枚)
都市土砂なし画像数	1498 (枚)
学習回数	100 (エポック)

表-4 土砂分類器の分類精度の結果

都市森林 分類器	土砂領域分類器			分類精 度
	種類と総 数	分類総数	分類結果	
森林 (5212)	土砂あり (724)	正解	599	0.91
		不正解	125	
	土砂なし (4488)	正解	4136	
		不正解	352	
都市 (836)	土砂あり (73)	正解	42	0.92
		不正解	31	
	土砂なし (763)	正解	723	
		不正解	40	

表-5 抽出器の学習条件

深層学習モデル	U-net
画像サイズ	224×224 (pixel)
訓練データ数	7408 (ペア)
検証データ数	1856 (ペア)
学習回数	100 (エポック)

80% (7408 ペア) を訓練データとし、残りの 20% (1856 ペア) を抽出器に用いる重みを決定するために利用する検証データとした。図-3 と図-4 には、提案手法の汎用性を評価するためのテストデータ（空中写真と正解画像）を示す。

(2) 分類器の学習条件

表-1, 表-2, 表-3 にはそれぞれ、都市森林分類器、都市土砂領域分類器、森林土砂領域分類器の学習条件を示す。

(3) 分類器の分類精度結果

表-4 には、図-3 に示すテスト画像に対する、土砂分類器の分類結果を示す。表-4 の分類精度は次式(1)より求めた。ここで、分類精度とは正解や不正解に分類されたデータのうち、正しく分類されたものの割合である。

$$\text{分類精度} = \frac{\text{分類の正解数}}{\text{各種類の画像総数}} \quad (1)$$

(4) 抽出器の学習条件

表-5 には、抽出器の学習条件を示す。検出器 A と検出器 B は同じ抽出器を用いた。両者の相違点は入力画像の処理過程であり、検出器 A では入力画像が 3.1 章(2) で記述した分類器の分類を経て土砂領域抽出器により



図-3 空中写真（テスト用）



図-4 正解画像

処理される。一方、検出器 B における入力画像は土砂領域抽出器によって直接処理される。

(5) 抽出器の評価指標

テストデータの土砂部検出結果に対する評価指標は、次式(2)から式(4)までに示す。再現率、適合率、F 値の観点から検出器を評価する。ここで再現率は、正解画

$$\text{再現率} = \frac{\text{正検出領域(TP)}}{\text{正検出領域(TP)} + \text{検出漏れ領域(FN)}} \quad (2)$$

$$\text{適合率} = \frac{\text{正検出領域(TP)}}{\text{正検出領域(TP)} + \text{誤検出領域(FP)}} \quad (3)$$

$$\text{F 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \quad (4)$$

像の土砂部に対して、検出器が土砂部と検出した領域の割合である。適合率は、検出器が土砂部と判定した全ての領域に対して、真に土砂部である領域の割合である。F 値は、再現率と適合率の調和平均の値を示す。また、すべての指標の最良値は1である。

### 3.3 実験結果

図-5 と図-6 には、検出器 A と検出器 B による検出結果（分割画像を結合）を示す。これらを比較すると、図-5 では誤検出の減少が顕著である。さらに、表-6 には、テスト画像の評価指標の結果を示す。表-6 の結果を見ると、再現率は検出器 A が検出器 B よりも低く、一方で、適合率と F 値は検出器 A が検出器 B より高くなった。特に、検出器 B の結果画像を見ると、河川や市街地等において誤検出が多く発生している。一方で、検出器 A は市街地と河川部分の誤検出が減少し、F 値が 0.27 向上している。

### 4. まとめ

本研究では、深層学習を利用して土砂抽出器と土砂分類器を作成した。3 章の実験結果より、土砂分類器を追加した検出器と土砂分類器を追加しない検出器について、以下の知見が得られた。

- 表-6 の結果より、分類器の追加は、再現率はやや低下するが、適合率を向上させ、F 値を向上させることができる。
- 分類後の画像は抽出器に直接入力されることから抽出時に分類ミスがあると検出精度に大きく影響する。

### 参考文献

- 1) 若月強：土砂移動データベース，都市における極端気象の観測・予測・情報伝達 気象研究ノート，Vol.236，pp.305-320，2018.
- 2) 中西宏彰，野呂智之，神山嬢子，鈴木大和，戸舘光，家田泰弘，片嶋啓介，大坪隆三，相澤明宏，潮見礼也：深層学習を用いた画像解析及びクラスタリング



図-5 検出器 A 結果




図-6 検出器 B 結果

表-6 実験結果

	再現率	適合率	F 値
検出器 A	0.74	0.51	0.60
検出器 B	0.84	0.20	0.33

による土砂災害の素因特性の抽出，砂防学会研究発表会概要集，No83，pp.667-667，2018.

- 3) 張堯，河村圭，若月強：スライド分割を用いた深層学習による土砂移動部自動検出に関する研究，土木情報学シンポジウム講演集 45，pp.181-184，2020.
- 4) He, K. M., Zhang, X. Y., Ren, S. Q. and Sun, J.: Deep Residual Learning for Image Recognition, arXiv:1512.03385, 2015.
- 5) Xie, S. N., Ross, G., Piotr, D., Tu, Z. W., et al.: Aggregated Residual Transformations for Deep Neural Networks, arXiv:1611.05431, 2016.
- 6) Olaf, R., Philipp, F., Thomas, B.: U-Net: Convolutional Networks for Biomedical Image Segmentation, arXiv: 1505.04597, 2015.