

(8) UNet および UNet++を用いた空中写真からの土砂移動領域抽出の比較

菅原 駿輔¹・劉 小熙²・河村 圭³・若月 強⁴

¹非学生会員 山口大学大学院 創成科学研究科電気電子情報系専攻
(〒755-8611 山口県宇部市常盤台 2-16-1)

E-mail: c106vgw@yamaguchi-u.ac.jp

²学生会員 山口大学大学院 創成科学研究科電気電子情報系専攻
(〒755-8611 山口県宇部市常盤台 2-16-1)

E-mail: b502vgv@yamaguchi-u.ac.jp

³正会員 山口大学大学院教授 創成科学研究科電気電子情報系専攻
(〒755-8611 山口県宇部市常盤台 2-16-1)

E-mail: kay@yamaguchi-u.ac.jp

⁴非会員 防災科学技術研究所 水・土砂防災研究部門
(〒305-0006 茨城県つくば市天王台 3-1)

E-mail: waka@bosai.go.jp

日本は、山地や丘陵地で覆われ、地震や集中豪雨に伴う土砂崩れなどの災害が多いことが問題となっている。現状では、土砂災害部の判定は、災害後に撮影した空中写真から目視による判読作業で行われている。しかし、この作業は経験者による長時間の目視作業が必要であり、作業への負担が大きい。この作業の効率化のため、近年、空中写真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が進められている。本研究では、UNetによる土砂移動部の自動検出精度を改善するために、誤検出を抑制できる特徴があり、土砂移動部検出精度の向上が期待できるUNet++を識別器として適用し検証を行った。

Key Words: debris flow, deep learning, image recognition, UNet, UNet++

1. はじめに

日本の気候は、主に温暖湿潤気候であるため、夏には大雨の頻度が多く、斜面崩壊や地すべりなどを含む土砂災害を招く可能性がある。現状では、土砂災害部の判定は、災害後に撮影した空中写真や衛星画像から、目視により土砂移動部（以下、土砂部と記述する）を判読して、土砂移動分布図を作成している¹⁾。しかし、この作業は長時間の目視作業が必要であり、作業への負担が大きいという問題がある。このことから、近年、この作業の効率化を目的とし、空中写真の土砂部自動検出に関する研究が進められている。

石井ら²⁾はUNet³⁾を利用し、土砂災害警戒区域を自動的に設定可能とするシステムを構築した。河村ら⁴⁾も、UNetを利用し、ピクセル単位の土砂部検出器と領域単位の土砂部分類器を組み合わせた手法を提案した。さらに、張ら⁵⁾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確認した。しかし、UNetは、土砂部のある（以下、土砂

ありと記述する）箇所を含む領域の画像を訓練データとして学習しているため、土砂あり領域における検出精度は高いが、土砂部でない（以下、土砂なしと記述する）箇所の誤検出（偽陽性）が多いことが課題として挙げられた。さらに、学習の際には、早い段階で過学習が発生し、識別器の汎用性が高まらないという問題も発生していた。そこで、本研究では、Zhouら⁶⁾が提案したUNet++を利用することで識別機の性能向上を図るとともに、さらに、損失関数の工夫により、再現率と適合率のバランスを調整することを検討した。

2. 土砂部自動検出方法

(1) UNetの構造

図-1にはUNetの構造を示す。UNetの推論過程では、EncoderのE¹⁻¹は、224×224pixelの入力画像に対し2回Convolution処理を行い、特徴マップ¹を作成する。この特徴マップ¹に対する処理は、「処理a」

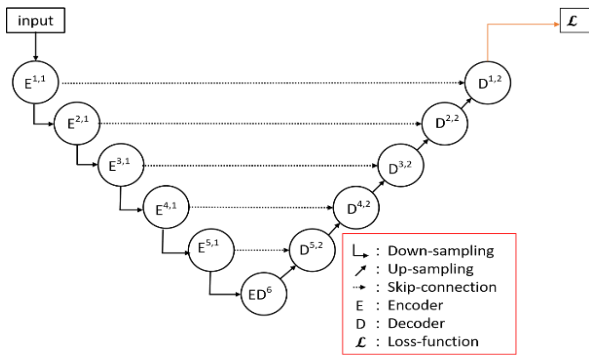


図-1 UNetの構造図




図-2 UNet++の構造図

と「処理b」がある。処理aは、 $E^{1,1}$ と $D^{1,2}$ を繋げる skip-connection により、 $D^{2,2}$ の出力と結合され、 $D^{1,2}$ への入力となる。処理bは、Maxpooling 処理であり、特徴マップ¹の縦横の長さを半分に圧縮し、次の Encoder の $E^{2,1}$ への入力となる。ここで、Eの右肩付き数字1,1は、順に、EncoderのID番号、Decoderを含む同一層内でのID番号である。図-1の左側の流れでは、処理bを ED^6 まで繰り返す、特徴マップ⁶を作成する。図-1の右側の流れでは、この特徴マップ⁶を Decoder の $D^{5,2}$ への入力とし、アップサンプリング処理により、縦横の長さを倍に復元する。同じ作業を $D^{1,2}$ まで繰り返す、出力データを入力データと同じ画像サイズに戻す。

(2) UNet++の構造

図-2には、UNet++の構造を示し、UNetと異なる部分は赤色で表示する。UNet++では、複数の Decoder が追加され、4つのブランチネットワークが構成されている。UNet++の推論過程では、この4つのブランチネットワークを利用し、 $D^{1,6}$ だけでなく、各ブランチネットワークで、土砂移動部を検出する。学習の際は、4つのブランチネットワークにより、4つの誤差を算出し、 $D^{1,6}$ の誤差と共に、平均値を求める。この平均値を誤差として利用し、各 Encoder を構成するニューラルネットワークを学習する。なお、層内の Encoder と Decoder の間にある skip-connection は誤差の逆伝播の経路となる。これ

表-1 実験条件

利用ネットワーク	UNet		UNet++	
画像サイズ	224*224(pixel)			
損失関数	F _{0.5}	F ₁	F ₂	F ₃
トレーニングデータ数	7408 ペア			
バリデーションデータ数	1856 ペア			
学習回数(エポック)	100 回		300 回	
バッチサイズ	16			
最適化手法	Adam (学習係数=0.00001)			

らの処理により、ダウンサンプリング過程の各段階の特徴マップは土砂部の検出にも利用され、UNetでは失われた詳細情報を保つことが期待できる。

3. 土砂部自動検出性能の比較実験



(1) 実験目的

UNet と UNet++を適用した識別器の土砂部自動検出精度を比較する。



(2) 実験方法

表-1には、実験条件を示す。本実験では、2018年に広島市で発生した西日本豪雨の直後に撮影した空中写真(27.3km×40km)から専門技術者が土砂部判読を行った結果を学習データ(訓練データと検証データ)とテストデータとして利用した。学習データの作成は、この領域から、土砂部の多い領域(12709×6087pixel)とそれぞれに対応した判読結果画像(以下、正解画像と記述する)を12ペア選択し、それぞれの画像を224×224 pixelに分割した。画像の分解能は1pixelあたり約0.37mである。分割画像の領域において、正解画像における土砂部領域が5%以上存在するものを「土砂あり」画像と定義し、学習用データとして用いた。具体的には、本実験では2316ペアを学習用データとして選択した。さらに、学習用データを増加させるために、「土砂あり」データとそれに対応した正解画像に対して、右方向へ90度、180度、270度で3回の回転処理を行い、データを4倍に水増しした。上記の作業により得られた、最終的な学習用データセット数は、合計で9264ペアである。この中で、約80%(7408ペア)を訓練データとし、残りの約20%(1856ペア)を検証データとした。

本実験では土砂部検出器の汎用性を評価するために4領域(test1からtest4)をテストに利用した。図-3(a)にはtest4の空中写真と正解画像を示す。テスト画像は、先の学習データとして利用した12ペア以外の領域である。test4領域の特徴は山間部の土砂移動部が多い領域である。



(a) test4 の空中写真 (左) と test4 の正解画像 (右)



(b) test4 の UNet++ (損失関数 $F_{0.5}$) での検出結果 (左) と UNet++ (損失関数 F_3) での検出結果 (右)

図-3 テスト画像と検出結果画




図-4 UNet++の訓練データと検証データの検出精度の推移 (学習回数: 300回)




図-5 UNetの訓練データと検証データの検出精度の推移 (学習回数: 100回)

また、本実験では、識別器の学習に用いる損失関数は、

式(1)を利用したが、式中の損失関数係数 β をそれぞれ 0.5, 1, 2, 3 に変更し学習させることで識別器の性能変化を比較した。

$$F_{\beta} = (1 + \beta^2) \frac{\text{recall} * \text{precision}}{\beta^2 * \text{recall} + \text{precision}} \quad (1)$$

(3) 評価指標

本研究では、テストデータの検出結果を、次式の再現率、適合率、 F_1 値の3つの指標で評価した。

$$\text{再現率 (recall)} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

$$\text{適合率 (precision)} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

$$F_1 \text{ 値} = \frac{2 * \text{再現率} * \text{適合率}}{\text{再現率} + \text{適合率}} \quad (4)$$

ここでTP (True Positive) は真陽性と呼ばれ、土砂部が正しく検出された箇所 (画素数) を示す。FN (False Negative) は検出漏れを表し、偽陰性と呼ばれる。FP (False Positive) は誤検出を表し、偽陽性と呼ばれる。なお、全ての評価指標の最良値は1.0である。

(4) 実験結果

図-4、図-5には、それぞれ UNet++ と UNet に対して 300 回と 100 回の学習を行った際の損失関数の値の推移を示す。各モデルの学習データに対する最終学習回の検出精度は、0.9 を超えている。検証データに対する検出精度は、UNet++ の F_1 が 0.78 であり、それ以外の検出精度は 0.8 を超えている。また、学習回数が 100 回周辺の損失関数の値の変化をみると、図-4 では値が増加傾向にあるが、

表-2 損失関数係数 β の影響結果

		test1			test2			test3			test4		
		再現率	適合率	F値	再現率	適合率	F値	再現率	適合率	F値	再現率	適合率	F値
F _{0.5}	UNet++	0.84	0.28	0.42	0.77	0.34	0.47	0.65	0.40	0.50	0.76	0.36	0.49
F ₁	UNet++	0.80	0.34	0.48	0.71	0.40	0.51	0.60	0.47	0.53	0.72	0.42	0.53
	UNet	0.86	0.15	0.26	0.79	0.21	0.34	0.70	0.25	0.37	0.8	0.22	0.35
F ₂	UNet++	0.78	0.35	0.48	0.67	0.40	0.50	0.58	0.47	0.52	0.69	0.45	0.54
	UNet	0.75	0.22	0.35	0.65	0.29	0.40	0.57	0.33	0.42	0.66	0.35	0.46
F ₃	UNet++	0.74	0.40	0.52	0.64	0.48	0.55	0.52	0.51	0.52	0.66	0.48	0.56
	UNet	0.67	0.27	0.38	0.56	0.33	0.41	0.50	0.39	0.44	0.56	0.41	0.47

図-5 の値は変化していないことから、UNet++はUNetより学習が遅い傾向がある。

表-2には、損失関数係数 β を変化させて識別器を学習させた際の4つのテスト画像の性能指標の結果を示す。この結果を見ると、再現率はF₁では、UNetよりUNet++の方が低い。一方で、適合率とF値は、全ての損失関数係数において、UNetよりUNet++の方が高い。これにより、UNet++は、UNetよりも識別器としての性能が高いと言える。特に、適合率が大幅に向上していることから、UNetよりも誤検出が抑制できている。また、損失関数係数 β の値を増加させると、UNetまたUNet++ともに、再現率は低下するが、適合率とF値は向上した。図-3の(b)は、UNet++を用いたテスト画像(test4)に対するF_{0.5}とF₃の土砂部検出結果である。F_{0.5}の画像は、正解画像やF₃の画像と比較して、誤検出が多い結果となっている。一方で、F₃の画像は、F_{0.5}の画像と比較すると誤検出が減少しており、表-2の性能指標を見ると、F_{0.5}に比べて再現率は0.1低下しているが、適合率が0.12向上し、F値も0.07向上している。これらの結果により、損失関数係数 β の調整により、識別器の再現率と適合率の性能を調整することができることが分かった。

4. まとめ

本研究では、UNet 識別器で土砂部自動検出を行う際に生じた誤検出を抑制することを目的として、UNet++の導入を検討した。実験結果より、UNet++識別器では、UNet 識別器と比較して、F値が向上したことから、土砂部検出の性能が改善したと言える。さらに、損失関数係数 β を変化させて識別器を学習させると、再現率また適合率に対する性能のバランスを変化させることができることが分かった。しかし、再現率と適合率の値にはトレードオフの関係があり、例えば、再現率を高めたい場合は、適合率は

低下する。実用的には、テスト画像に対する再現率が0.8以上を維持しながら、適合率を向上させることが望ましいことから、今後もさらに識別器の改善を進める必要がある。

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) 石井唯嵩，広兼道幸，倉本和正，西原尚輝：社会的要因を考慮した土砂災害警戒区域設定に対する深層学習の適用，土木学会論文集 F6，Vol.74，No.2，pp. I_193-I_199，2020.
- 3) Olaf, R., Philipp, F., & Thomas, B.: U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention - MICCAI*, pp 234-241, 2015.
- 4) 河村圭，中村優志，若月強，佐村俊和：深層学習を用いた空中写真からの土砂移動範囲自動検出に関する研究，土木学会論文集 F3，Vol.74，No.2，pp. I_132-I_143，2019.
- 5) 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，Vol.45，pp.181-184，2020.
- 6) Zhou, Z. W., Md, M. R. S., Nima, T., & Liang, J. M.: UNet++: A Nested U-Net Architecture for Medical Image Segmentation, <<https://arxiv.org/abs/1807.10165>>, (入手2022.7.19).