(28) 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

中村 優志 1·河村 圭 2·若月 強 3

¹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: g061vg@yamaguchi-u.ac.jp

²正会員 山口大学大学院准教授 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

3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

我が国では、地震や豪雨に伴う土砂災害等の自然災害が多く、人的被害・環境被害が問題となっている. 現状では、斜面変動の広域分布を把握するために、作業者が目視により、空中写真から斜面崩壊や土石流などによる土砂移動範囲を抽出することが多い. しかし、この作業は長時間の緻密な目視作業が必要であり、作業者への負担が大きい. そこで、本研究では、目視による土砂移動分布図の作成作業の効率化を目指して、深層学習を利用した土砂移動範囲の自動検出手法の検討および手法の有効性の検証を行った.

Key Words: slope failure, debris flow, aerial photograph interpretation, deep learning, convolutional neural network

1. はじめに

我が国では、地震や豪雨に伴う、土砂災害等の自然災 害が多く、人的被害・環境被害が問題となっている. 現 状では、斜面変動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)や衛星画像から目視に より土砂移動範囲(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 業は長時間の緻密な目視作業が必要であり、作業者への 負担が大きいという問題がある. このことから、本研究 では、過去に撮影された土砂災害地の空中写真および作 業者が空中写真から十砂部を判読した結果を用いて、深 層学習を利用した, 土砂部の自動検出手法の検討および 有効性の検証実験を行った. なお, 本研究では, 深層学 習を利用する際に、土砂部検出対象を「土砂災害地を撮 影した空中写真」とし、正解画像(教師画像)を「作業 者が空中写真から十砂部を判読した結果(以下、判読結 果と記述する)」とした.

2. 土砂部自動検出手法

本研究では、空中写真から「土砂部をピクセル単位で 検出する手法」と「土砂部を一定の領域単位で分類する 手法」を組み合わせ土砂部を自動検出する.以下に、本 研究で提案する、土砂部自動検出手法の手順を記述する.

STEP1: 土砂部検出器の作成

空中写真内に存在する土砂部を検出する土砂部検出器を作成する.具体的には、特徴検出用に設計された学習器(ニューラルネットワーク)に対して、空中写真内に存在する土砂部の特徴を深層学習させる.本学習器を用いて、入力した画像(以下、処理対象画像と記述する)内に存在する土砂部を検出する「土砂部検出器」を作成する.なお、空中写真は、深層学習で学習させる際に、大量のサンプルデータを必要とするため、事前に画像の分割処理を行った.

STEP2: 土砂部検出器による土砂部の検出

STEP1 にて作成した土砂部検出器を用いて、処理対象画像から土砂部を検出する.

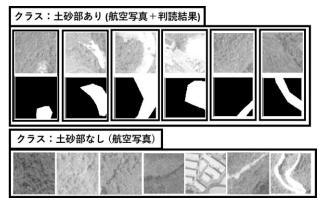


図-1 クラス分けした分割画像の例

STEP3: 土砂部画像分類器の作成

STEP2 で検出した土砂部から、さらに、土砂部検出精度を向上させることを目的として、土砂部の画像分類を行う分類器を作成する. 具体的には、あらかじめ「土砂部あり」、「土砂部なし」というクラス分けをした分割画像を、画像分類用に設計された学習器に深層学習させ、処理対象画像(分割画像)毎のクラス分けを行う「土砂部画像分類器」を作成する. ここで、図-1 には、クラス分けした分割画像の例を示す.

STEP4:土砂部画像分類器による土砂部の画像分類 STEP3にて作成した土砂部画像分類器を用いて、処理 対象画像の画像分類を行う.

STEP1とSTEP3では、土砂部の「検出」と「分類」に用いる深層学習ネットワークとして、それぞれ「U-Net (特徴検出)」と「9層のニューラルネットワーク(画像分類)」を用いた。ここで、図-2と図-3には、これらのネットワーク図を示す。

(1) U-Net (特徴検出)

図-2 に示される U-Net は、医学現場における画像の領域 (ピクセル単位) 検出用に開発された学習器であり、画像に存在する特徴を学習することで特徴検出器を作成する.この検出器により、入力した画像から特徴が検出できる.本研究では、空中写真の分割画像に存在する「土砂部」を検出するために用いる.

(2) 9層のニューラルネットワーク (画像分類)

図-3 に示される9層のニューラルネットワークは、画像の分類に用いられる学習器であり、画像分類を行いたい画像をあらかじめクラス分けし、クラス分けした画像を学習させることで、分類器を作成する。この分類器によって、入力された画像を学習したクラスの特徴に最も近いクラスに分類できる。本研究では、空中写真の分割画像を2クラス(「土砂部あり」および「土砂部なし」)に分類するために用いる。

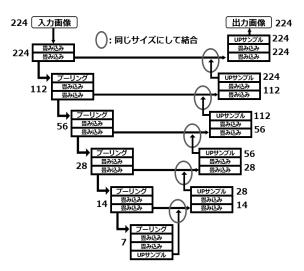


図-2 U-Netのネットワーク図



図-3 9層のニューラルネットワーク図

3. 土砂部自動検出実験

2 章で提案した土砂部自動検出手法の有効性を検証す るために, 空中写真内に存在する土砂部の特徴を検出す る実験 A(前述の STEP1 および STEP2 に相当) と、土砂 部の特徴が存在する画像を分類する実験 B (前述の STE P3 および STEP4 に相当) を実施した. 両実験には、199 9年の広島での十砂災害後のオルソ補正されたグレース ケールの空中写真および判読結果(正解画像)を用いた. また、本実験には、学習器に入力するトレーニングセッ トとして、空中写真および判読結果のうち、土砂部の多 い箇所(10976×6496(pixel))を13箇所ピックアップし、 それぞれを 224×224 (pixel)に分割した、そして、データ のかさましのため、分割した画像を右方向に 56 (pixel)、 112(pixel), 168(pixel)スライドさせた画像も作成した. 上 記の様に作成された分割画像は合計で 73515 ペア (空中 写真と判読結果のペア)であり、そのうち、「土砂部あ り」画像は 11207 ペア (15%), 「土砂部なし」画像は 62308 ペア (85%) となった、さらに、最適な学習デー タを決定する際に用いるバリデーションセットとして, 2842 ペア (トレーニングセットに用いた 13 箇所とは別



図-4 空中写真(テストセット)



図-5 正解画像(判読結果)

表-1 実験Aの学習条件

利用ネットワーク	U-Net
画像サイズ	224×224 (pixel)
トレーニングセット数	16074ペア
バリデーションセット数	222ペア (土砂部が存在するもの)
学習回数 (エポック)	100回
一度の学習枚数 (バッチサイズ)	32

の、土砂部の多い2箇所分の分割画像)、作成した特徴 検出器および画像分類器の精度を検証する際に用いるテ ストセットとして、1421ペア(上記 15 箇所とは別の、 土砂部の多い1箇所分の分割画像)を用意した。ここで、 図-4 と図-5 には、今回テストセットに用いた画像とテ ストセット領域の正解画像を示す。

(1) 実験 A

a) 実験条件

実験 Aでは、分割画像内に存在する、土砂部を U-Net を用いて検出する。ここで、表-1 には、実験 A の学習 条件を示す。トレーニングセットとして、前述の「土砂部あり」画像のうち、判読結果において土砂部が 5%以上存在する画像と、判読結果(正解画像)を 8037 ペア準備した。さらにデータのかさましとして、90°右方向に回転させたものを追加し、計 16074ペア利用した。

まず、学習 100 回それぞれで土砂部検出器を作成する.

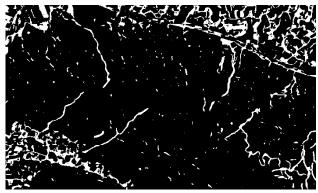


図-6 実験 A 結果

その後,バリデーションセットの内,画像内に土砂が存在するもの(222ペア)を対象に,識別率が最も高かった学習回数の土砂部検出器を用いて,テストセットの空中写真に対して土砂部検出を行った.

b) 実験結果

図-6 には、図-4 のテストセットの空中写真に対して、 土砂部検出を行った結果(分割画像を結合)を示す.

図-5 と図-6 を比較すると、土砂部に関しては、大まかに検出できている。しかし、山間部の一部の道路や河川・市街地や空き地なども多数検出された。また、空中写真では、土砂部が木々やその影で隠れているため、目視のみでは土砂部であると判断し難い箇所(空中写真では途切れているが、正解画像では作業者の経験・知識を基に繋げている)は、検出漏れが目立った。さらに、空中写真には何も無いように見える箇所に対しても、誤検出が目立つ結果となった。

本結果を受け、誤検出箇所の多さが大きな問題である と考え、誤検出を減らすことを目的として行った実験 B について以下に示す.

(2) 実験 B

a) 実験条件

9層のニューラルネットワークを用い、テストセットを画像分類する.ここで、表-2には、実験 B の学習条件を示す.実験 A と同様に、実験 B のトレーニングセットとして、土砂部が 5%以上存在する空中写真の分割画像 (8037枚) と「土砂部なし」画像からランダムに選んだ空中写真の分割画像 (8037枚) を準備した.さらにデータのかさましとして、それぞれを 90°右方向に回転させたものを追加し、合計 32148枚を利用した.

まず、学習 100 回それぞれで土砂部画像分類器を作成する. その後、バリデーションセットを対象として、識別率が最も高かった学習回数の土砂部画像分類器を用いて、テストセットに対して土砂部画像分類を行う. なお、実験 B の結果の精度確認として、実験 A の結果から誤

表-2 実験Bの学習条件

利用ネットワーク	9層のニューラルネットワーク
画像サイズ	224×224 (pixel)
トレーニングセット数	32148枚
バリデーションセット数	2842枚
学習回数 (エポック)	100回
一度の学習枚数 (バッチサイズ)	32

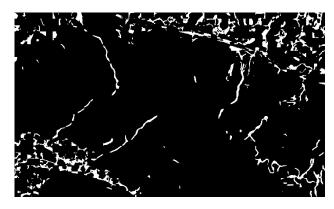


図-7 実験 B 結果

検出箇所の減少具合を確認するため、実験Bで「土砂部なし」と判断された分割画像を非表示とする.

b)実験結果

テストセットに対して画像分類を行った結果を**図-7**に示す. 結果を確認すると,実験Aの時にあった誤検出が実験Bでは減っている. しかし,市街地や河川・道路の誤検出は,やや減少しているものの,土砂部の検出漏れは増加した.

(3) 実験結果まとめ

両実験により、深層学習によって、大まかに土砂部を 検出することに成功した.しかし、誤検出や検出漏れが あるため、さらなる検証が必要である.

土砂部検出器の作成精度の検証を目的とした実験 Aでは、誤検出が多く、特に、市街地や河川・道路の誤検出が目立った.

この誤検出を減らすことを目的に土砂部画像分類器の作成を行った実験Bでは、ある程度の誤検出を減らすことに成功したが、まだ市街地や河川・道路の誤検出は多い。これらの原因として、実験Aでは、トレーニングセットとして、土砂部が存在する画像のみを学習させたため、市街地に対する情報が存在せず、誤検出されたと考えられる。また、実験Bにおいても、「土砂部なし」の画像はランダムで選択したため、山間部よりもサンプルの少ない市街地や河川・道路の情報が少なくなっていたことが考えられる。この改善案として、両実験のトレーニングセットに、市街地等の土砂部の存在しない画像を追加することが考えられる。しかし、意図的にト

レーニングセットとして市街地や河川・道路等の特定の 画像を加えると、それらの特徴に特化した学習が行われ てしまう可能性があり、追加する画像枚数に対して工夫 が必要である。

また、実験Aにおいて、検出漏れが目立つ箇所が存在した。特に検出漏れが目立つ箇所としては、空中写真において、土砂部が、木々やその影により隠れており、途切れてしまっているように見える箇所が挙げられ、正解画像では、作業者が経験・知識により目視で繋げている土砂部である。さらに、実験Bでは、同様の土砂部が実験A以上に検出漏れしていた。この原因として、テストセットの特徴検出・画像分類時に、224×224(pixel)の分割画像単位で、土砂部検出・画像分類が行われたため、画像間で分断された土砂部が上手く検出・分類されなかったことが考えられる。

これらの改善手法として、テストセットの特徴検出・画像分類時に、トレーニングセットのかさましの際と同様に、右方向に 56 (pixel)、112 (pixel)、168 (pixel)スライドさせた画像を作成し、それぞれに対し特徴検出・画像分類結果を出力し、同一箇所 4 枚のうち、「土砂部あり」と判断された割合による判定手法が考えられる. 他の改善手法として、空中写真に勾配情報や地図情報を付与することが土砂部検出精度の向上として考えられるが、空中写真のオルソ補正の難しさにより、各情報にズレが生じるという問題がある.

4. まとめ

本研究では、空中写真を対象とした、深層学習による 土砂部(土砂移動範囲)の自動検出手法および実験結果 を示した、本結果から、ある程度、土砂部の検出ができ ており、自動検出の可能性が示された。しかし、市街地 や、河川・道路の誤検出が目立ち、さらに、木々やその 影により空中写真では隠れている土砂部に対する検出漏 れも確認された。これらの改善を目的とした、さらなる 検証が必要である。

謝辞:本研究の一部は、国立研究開発法人科学技術振興機構イノベーションハブ構築支援事業の支援を受けて実施されました.

参考文献

 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.