

画像情報と深層学習を用いた崩壊地抽出における誤判別傾向の検討

長岡技術科学大学院 金川哲也

東京電力ホールディングス株式会社 岡滋晃

長岡技術科学大学 高橋一義

1. はじめに

我々が生活する領域のほぼ全てを網羅している電気・ガス・水道をはじめとしたライフラインは現代社会に欠かせないインフラ施設である。故にこれらの設備が被災した場合、社会活動が大きく損なわれる。令和元年に発生した台風 15 号による被害では送電塔 2 基を始めとした複数の設備の損壊により 93 万軒に対する給電が停止し、一部地域では復旧に 2 週間を要するなど大きな混乱をもたらした¹⁾。このような社会的影響を最小限に抑えるためには損傷した設備を早急に復旧させる必要がある。

早期復旧を行う上で重要となるのが被災状況の迅速な把握である。しかし、インフラ施設の一部は山間部などアクセスが難しい場所に存在し、それら設備群に対する被災状況の確認は現地へ赴いての目視点検によって行われている。その結果、災害時の状況把握には多くの時間や人員が必要とされており、早期復旧の妨げとなっている。

このような課題を解決するために注目されているのが深層学習による画像認識である。近年は土木分野における画像認識技術の利用が積極的に研究されており、撮影した画像による橋梁の損傷検出²⁾や UAV 撮影画像による河川の氾濫域の検出とその深度予測³⁾、など様々な例が存在する。

災害時の被災状況把握についても同様であり、即応性と調査範囲に優れる航空写真を利用した土砂流出範囲の自動検出⁴⁾や被災建築物の検出⁵⁾といった形での適用が報告されている。

著者らは発災前後の可視画像を組み合わせることで転移学習を行い、斜面崩壊地を検出する手法の開発を試みている。これまで可視画像を利用した試みでは露出した滑落面や土砂流入といった地表面の変化が大きい崩壊地の検出には成功したものの、土塊が植生を伴ったまま滑落した領域や起伏によって影がかかっていた崩壊地は検出されなかった⁶⁾。

検出性能の向上を行う上では誤判別要因の分析が必

要である。そこで本稿では判別結果に影響を与えた画像領域を可視化する Grad-CAM を用いて、誤判別傾向を検討する。

2. Grad-CAM について

2.1 Grad-CAM の概要

深層学習において画像データを取り扱う際には、畳み込み層(Convolution Layer)とプーリング層(Pooling Layer)を繰り返すことで入力データ中の特徴を抽出する CNN(Convolutional Neural Network)が使用されることが多い。このネットワークは入力データ中に含まれる各要素の位置情報を保持したまま扱うことが可能であり、画像解析の分野に対して優位という特徴を持つ。しかし、最終的に利用者が知ることができるのは解析の結果のみであり、結果に大きく影響した要素や注目度の大きい領域を確認することは困難であった。この欠点に対して考案された手法が分類の結果を利用して着目領域を可視化する Grad-CAM (Gradient-weighted Class Activation Mapping) である⁷⁾。

2.2 Grad-CAM の手法

Grad-CAM は次の図-1 に示す形で着目領域の可視化を行っている。

① CNN による画像分類

CNN による分類の様子を簡易的に示したものが図-3 中の①である。この際に畳み込み層内部には入力画像に対応する特徴マップ $C_1 \sim C_n$ が蓄積され、それを基に分類の結果が出力される。

② 誤差逆伝播

誤差逆伝播とは通常のカテゴリ分類とは逆方向に結果からその算出過程を逆算する手法のことである。Grad-CAM ではこの手法によって最も後ろにある畳み込み層内の要素に対する分類結果の勾配 $G_1 \sim G_n$ を特徴マップ毎に算出する。

③ 重みの計算

総和を計算する際に使用される重み $W_1 \sim W_n$ は特徴


マップごとに勾配の平均を取る操作(Global Average Pooling)によって求められる。この重みが大きいほど分類結果への寄与率は高くなる。

④ 総和の計算

求めた重み $W_1 \sim W_n$ を対応する特徴マップ $C_1 \sim C_n$ に積算し、総和を取って一枚のレイヤとする。

⑤ リサイズとカラーマップ化

算出されたレイヤには既に分類に寄与した領域が示されているものの、元にしたレイヤが畳み込み層であったため入力データよりもサイズが小さくなっている。よって活性化関数 ReLU によってサイズを入力データと等しくなるようにリサイズする。こうして得たレイヤをカラーマップ化し、入力データと重なるように出力することで Grad-CAM は着目領域の可視化を行なっている。



3. データと方法

3.1 使用データ

著者らの先行研究の事例である新潟県中越地震で多くの斜面崩壊が発生した新潟県長岡市山古志地区（旧山古志村）周辺を対象とする。発災前後の画像と崩壊、非崩壊を判断するラベル画像は先行研究のものを流用するが、学習へ使用するパッチについては新しく作り直す。

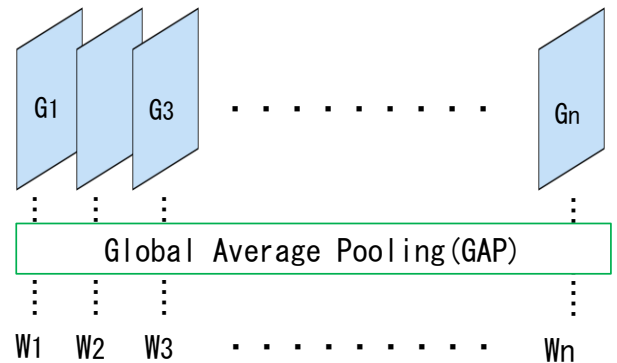
3.2 学習用画像作成

使用する画像は赤(R)、緑(G)、青(B)の3バンドからなり、発災前後合わせて計6バンド存在する。使用する3バンドについては以前の研究に倣い、植生の有無で値が大きく変動する発災前後の緑バンド双方と発災後の赤とする。バンドの割り当てについてはRに発災前の緑、Gに発災後の緑、Bに発災後の赤とする。


3.3 パッチ作成

学習用画像からランダムに四角形領域を切り出して崩壊地(land_slide)と非崩壊地(not_land_slide)の2種のラベルを持つパッチを多数作成する。ラベル付けは図-2のように発災後可視画像から目視で崩壊地を判別したものを基準としてパッチ内の75%以上を崩壊地が占めるものを崩壊地(land_slide)とする。非崩壊地(not_land_slide)については先行研究では25%以下としていたところを0%に変更し、パッチを再作成した。

③勾配からの重み算出



④重み付きの総和



⑤リサイズ




図-1 Grad-CAM の工程

パッチは1辺75m四方とし、各ラベル1000個ずつ作成した。




図-2 崩壊地の目視判別結果。左が発災後画像、右がラベル画像を重ねたもの。青枠内が崩壊地

3.4 転移学習と検証

作成した2000個のパッチを用いて転移学習する。転移学習に使用する学習済みネットワークはGoogLeNetとする。学習完了後は各ラベル1000個ずつのパッチを実際に判別させて検証し、正解率、land_slideの再現率、not_land_slideの再現率の3つの指標によってネットワークの凡その性能を把握する。

3.5 Grad-CAMの適用

検証時にラベルはland_slideであるものの判別結果がnot_land_slideとなっているパッチ(偽陰性)についてGrad-CAMを適用し、着目される領域を可視化する。可視化された領域については傾向ごとにグループ化し、判別に影響を与える要素を検討する。

4. 結果と考察

4.1 転移学習

学習後の検証結果は図-3の混同行列に示すような形となった。この時の正解率は82.8%、land_slide再現率は97.3%、not_land_slide再現率は68.3%である。

		判別結果	
		land_slide	not_land_slide
実際のラベル	land_slide	973	27
	not_land_slide	317	684

図-3 判別結果の混同行列

また、崩壊地を誤判別した27パッチは全てが図-4に示す崩壊地に含まれていた。崩壊地(a)、(b)は山の起伏により生じる影領域、(c)は崩壊地上に植生が残る領域である。今回の判別については先行研究と処理手法は基本的に同様であり、似通った結果が得られている。



図-4 誤判別パッチが存在する崩壊地、水色線内が崩壊地

4.2 Grad-CAM

誤判別した27パッチにGrad-CAMを適用し、判別時に着目された領域の傾向を調査し、3つにグループ化した。

1: 情報量が少ない影領域

ネットワークが影領域の斜面崩壊地に着目していることがわかる(図-5a中央)。影領域のため、情報量が少なく斜面崩壊地にネットワークが着目したものの、結果としてパッチを非崩壊地と判別したと考えられる。同様のパッチは4つ確認された。

このような領域を正しく判別する手法として、入力画像の輝度値を補正しコントラストを向上させることが考えられる。しかし、情報量が少ない影領域ではその効果も期待できないため、判別不能な領域として処理することも方法の一つと考える。

2：植生を伴う崩壊地中の植生

ネットワークが滑落した土塊上に植生が残る崩壊地に着目していることがわかる（発災後画像の緑バンドの画素値が周囲より高い部分、図-5b 中央）。同様のパッチは 14 個確認された。

これらの領域を正しく判別する手法として地形情報の利用が考えられる。植生等に左右される分光情報ではなく、土塊の移動によって生じる高度差を利用すればより正確に崩壊地を検出できると思われる。

3：崩壊地に隣接する非崩壊地

このパッチは大部分が崩壊地であるのものの一部（図-5c 赤丸の中）に非崩壊地が含まれる。ネットワークはこの非崩壊地に強く着目した結果、非崩壊地と判別された。このような誤判別は 9 パッチ確認された。この要因として考えられるのがこの非崩壊地の分光特性の変化が発災前後の崩壊地の変化と類似したことである。

これに対する対策として考えられるのがパッチサイズの変更である。着目領域はパッチ全体からみれば僅かである。そのためパッチを細かく分割し、判別していけば着目領域は除かれ、その他の部分が正しく判別可能になると考えられる。

5. まとめ

本稿では判別結果に影響を与えた画像領域を可視化する Grad-CAM を用いて、誤判別領域の傾向を検討した。その結果、先行研究で誤判別領域の例として挙げられていた「影の影響」「植生が残った崩壊地」の 2 つの特徴を含めてネットワークが着目しているパッチ内の領域を可視化し、その傾向を 3 つにグループ化した。2 点に加えて「崩壊地に隣接する非崩壊地」が誤判別の要因となっていることが判明した。今後は地形情報の利用やパッチサイズが異なるデータを学習に導入するなどしてこれらを捉えられるようにすることで実用的な崩壊地検出手法を構築することが期待される。

しかし、転移学習は一度の学習で使用可能なデータ

に限りがあり、既に使用されるバンドが絞られている。今後は異なる組み合わせのデータによって学習を施したネットワークを複数用意して結果を統合するなど検出に使用されるデータ量を増やす必要があると考える。




図-5 Grad-CAM 適用結果例. 左から順に対象領域周辺のカラー合成画像, 対象地周辺の発災後可視画像, Grad-CAM 結果. 赤い部分が判別に対して影響を与えた領域

参考文献

- 1) 東京電力ホールディングス株式会社: 台風 15 号対応検証委員会報告書 (最終報告), 2020
- 2) Mostafa Aliyari, Enrique Lopez Droguett, Yonas Zewdu Ayele : UAV-Based Bridge Inspection via Transfer Learning, MDPI Sustainability 2021 13(20), 2021, DOI:10.3390/su132011359
- 3) Asmamaw Gebrehiwot, Leila Hashemi-Beni : A METHOD TO GENERATE FLOOD MAPS IN 3D USING DEM and DEEP LEARNING, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLIV-M-2-2020, 2020
- 4) 菊地 輝行, 崎田 晃基, 秦野 輝儀, 吉川 慶, 西山 哲, 大西 有三: 深層学習による崩壊・非崩壊地の自動判読手法の開発, 日本地すべり学会誌 56 巻 5 号 p. 255-263, 2019
- 5) Hiroyuki Miura, Tomohiro Aridome, Masashi Matsuoka : Deep Learning-Based Identification of Collapsed, Non-Collapsed and Blue Tarp-Covered Buildings from Post-Disaster Aerial Images, MDPI Remote Sensing 2020 12(12), 2020, DOI:10.3390/rs12121924
- 6) 高田 竜司, 金川 哲也, 岡 滋晃, 河村 直明, 鬼束 俊一, 高橋 一義: 事前学習済みネットワークの転移学習による斜面崩壊地検出結果の比較, 日本写真測量学会ジャーナル 写真測量とリモートセンシング 60 (6), 350-353, 2021
- 7) Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra : Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization,