Deep Learning による航空画像からの雪崩自動検出器の開発

Development of an automatic detector of avalanches in an aerial image using Deep Learning

北海道大学大学院工学院	$\bigcirc \frac{1}{2}$	学生	員	横山	傑	(Suguru Yokoyama)
防災科学技術研究所雪氷防災研究センター	- 3	非会	員	伊藤	陽一	(Yoichi Ito)
北海道大学大学院工学研究院	Ī	E	員	松本	高志	(Takashi Matsumoto)

1. 序論

日本は有数の地震多発国家として知られると共に、国 土の約半分が豪雪地帯でもある。豪雪地帯においては地 震による地形の変化により、新たな雪崩危険箇所を誕生 させる事が数多く確認されている。その為、雪崩の発生 状況を把握し、将来の雪崩の発生を予測することは大変 重要である。しかしながら現在、雪崩発生状況の把握は、 膨大な範囲の航空画像から目視で行われており、雪崩を 航空画像から自動検出する検出器が開発されたならば、 当分野の効率的な検討作業に大きく貢献するものと考え られる。

近年、航空画像や衛星画像から道路のエッジを抽出す る研究や、建物や道路などの地物を推定する研究、地上 の熱源を検出する研究など、空中画像と Deep Learning を組み合わせて地形の自動認識を試みる研究が多い。特 に、これらのような物体検出タスクでは、画像の画素毎 にクラスを分類する Semantic Segmentation が高い評価を 受けている。

本研究では、平成 16 年 10 月 23 日に起きた新潟県中 越地震の中心的被災地である、新潟県古志郡山古志村 (現長岡市)の積雪期航空画像を Deep Learning を学習さ せることで、航空画像から雪崩を自動的に検出する検出 器を開発することが目標である。具体的には、図-1 の ような航空画像を入力すると、雪崩箇所を赤で示す図-2 のような画像を出力する事を目指す。雪崩には、全層 雪崩と表層雪崩などがあるが、今回は全層雪崩のみを考 慮する。なお、検出器には Semantic Segmentation タスク によく使われる、Fully Convolutional Networks(FCN-8s)¹⁾ を用いる。

2. 手法

まず、図-3 のような画像を 56 枚集めた。この画像 は新潟県古志郡山古志村(現長岡市)の上空から撮影され た 4777×4810pixel の写真である。また、雪崩発生箇所 が記された、撮影対象地域全体の地図(図-4)を入手し た。図のような画像が地図のどこに対応するのかが体感 的に分かりくい為、56 枚の画像を図-5 のようにパノラ マ合成をした。このパノラマ合成画像と地図を比較し、 雪崩発生箇所の比較的多い箇所を図-1 のように切り取 り、4673×3410pixel に圧縮した。地図を参考にしなが ら雪崩発生部位を図-6 のように赤、背景を黒で塗り潰 した。この画像と図上を 256×256pixel のサイズの slide window を 128pixel 間隔で走査して切り取り、それぞれ 875 枚の学習データと教師データとした。なお学習デー



図-1 入力画像例



図-2 出力目標例





図-3 航空写真

タはグレースケール画像とし、教師データは2値画像と して学習させた。本論文では、学習データが少ない為、 検証データでの評価は次回の論文にて示す予定である。



図-4 雪崩箇所地図



図-5 パノラマ画像



図-6 教師データ

3. 学習と結果

GTX1070の開発環境下で、表-1のような FCN-8s を 構築し、作成した学習データをミニバッチ数 25 で 30epoch 学習させた結果が図-7 である。学習時間は、 570 秒であった。学習に使用した学習データにて評価し た結果、99%の精度で学習できていることが分かる。

4. 結論

本論文では、雪崩自動検出器のコアとなる FCN-8s を 学習させた。しかしながら、本来 deep learning を学習す



図-7 学習結果

表-1 学習パラメーター

層種	パッチ	ストライド	出力マップサイズ	関数
data	-	-	$1 \times 256 \times 256$	-
conv1_1	3×3	1	$64 \times 256 \times 256$	ReLU
conv1_2	3×3	1	$64 \times 256 \times 256$	ReLU
pool1	2×2	2	64 imes 128 imes 128	-
conv2_1	3×3	1	128 imes 128 imes 128	ReLU
conv2_2	3×3	1	128 imes 128 imes 128	ReLU
pool2	2×2	2	$128 \times 64 \times 64$	-
conv3_1	3×3	1	$256 \times 64 \times 64$	ReLU
conv3_2	3×3	1	$256 \times 64 \times 64$	ReLU
conv3_3	3×3	1	$256 \times 64 \times 64$	ReLU
pool3	2×2	2	$256 \times 32 \times 32$	-
conv4_1	3×3	1	512×32×32	ReLU
conv4_2	3×3	1	512×32×32	ReLU
conv4_3	3×3	1	512×32×32	ReLU
pool4	2×2	2	$512 \times 16 \times 16$	-
conv5_1	3×3	1	$512 \times 16 \times 16$	ReLU
conv5_2	3×3	1	$512 \times 16 \times 16$	ReLU
conv5_3	3×3	1	$512 \times 16 \times 16$	ReLU
pool5	2×2	2	512×8×8	-
upsample4	4×4	2	2×256×256	ReLU
upsample5	8×8	4	2×256×256	ReLU
upsample6	16×16	8	$2 \times 256 \times 256$	ReLU

るためには、数万枚の学習データが必要とされるが、本 研究では数百枚と、圧倒的に少ない。その為、学習に用 いていない検証データによる評価が行えていない 段階である。直近の課題としては、新たに学習データを 作成し、かつ U-Net²⁾や SegNet³⁾などの、Fully Convolutional Networks 以外の deep learning も学習させ、 精度を比較検討することがあげられる。その中で最も精 度の高い deep learning を用い、かつ全層雪崩、表層雪崩、 ひび割れなど、検出対象を増やすことが最終的な目標で ある。

参考文献

1) J. Long, E. Shelhamer, T. Darrell: Fully Convolutional Networks for Semantic Segmentation, arXiv:1411.4038 [cs.CV], 2014.

2) O. Ronneberger, P. Fischer, T. Brox: U-Net: Convolutional Networks for Biomedical Image Segmentation, arXiv:1505.04597 [cs.CV], 2015.

3) V. Badrinarayanan, A. Kendall, R. Cipolla: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, arXiv:1511.00561 [cs.CV], 2016.