

# 深層学習によるレーザープロファイラからの地すべり検出の検討

荒木光一† 柏大吾† 伊藤兎† 関家史郎† 山森一彦† 藤平大‡ 櫻本智美‡

† 五大開発株式会社 ‡ 国立研究開発法人土木研究所

## 1. はじめに

地すべりの防災・減災において、現状の地すべりの把握は重要である。近年はレーザープロファイラで詳細な標高を取得できるため、これまでは判読が困難であった地すべりを判読できるようになった。しかしながら、地すべり判読は人間が行うため、多大な時間を要してしまう。

そこで、本稿では、判読の効率化を目指すために、深層学習で標高データから地すべりを検出できるかを試し、どのように利用できるかを検討する。モデルには Pix2Pix[1] を利用し、学習データは図 1 のように標高データから生成した正規化した標高差と地すべり内外を示す地すべりフラグを用いる。

## 2. 学習データの作成方法

正規化した標高差と地すべりフラグは地すべり地形と非地すべり地形のデータから作成する。地すべり地形のデータには地すべり地形全体が含まれるように、非地すべり地形には地すべり地形を含まないように、それぞれ地すべり BOX と非地すべり BOX を作成する(図 2)。

正規化した標高差は、まず各 BOX 内の標高データを取得し、BOX 内で最も標高が低い箇所を 0m とした標高差に変換する。次に、標高差を 1,000m で正規化し、反転でデータ数を増加させる。そして、Pix2Pix で扱うデータサイズである 256×256 にリサイズする。

地すべりフラグは、まず各 BOX 内の標高データを取得し、標高値を地すべり地形内外を示すフラグに変更する。ここで、地すべり地形内の場合には 1 を、地すべり地形外の場合は 0 を設定する。そして、正規化した標高差と同様に、反転とリサイズを行う。

## 3. 評価実験

### 3-1. 学習データと学習

学習データは奈良、新潟、静岡と高知の地すべり判読エリアから作成した。地すべり地形の

A Study on Landslide Detection on Laser Profiler Data using Deep Learning

†Kouichi Araki †Daigo Kashiwa †Usagi Ito †Shiro Sekiya

†Kazuhiko Yamamori ‡Masaru Tohei ‡Tomomi Sakuramoto

†GODAI KAIHATSU Corporation

‡Public Works Research Institute

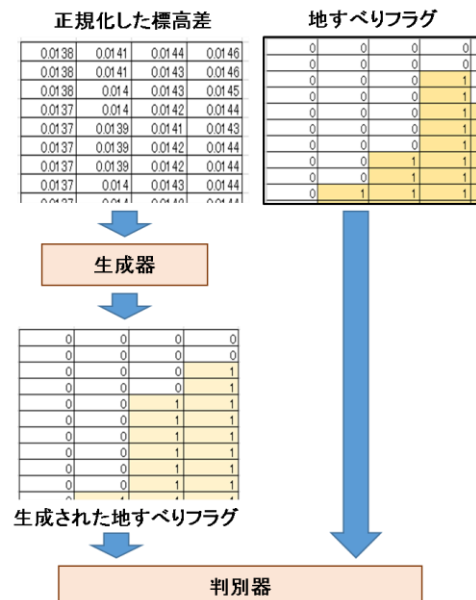


図 1 Pix2Pix のモデルと学習データ




図 2 地すべり BOX と非地すべり BOX  
(赤線：地すべり 青線：非地すべり)

正規化した標高差と地すべりフラグのデータ数は各 5,114 データ、非地すべり地形の各データ数は 2,640 データとなった。

Pix2Pix の最適化には Adam(学習率 0.001)を用いた。バッチサイズは 32 とした。学習には NVIDIA Geforce GTX 1080 で約 107 時間を要した。

### 3-2. 推論データ

推論エリアは高知県大豊町の山岳部(19.9km<sup>2</sup>)とした。推論データは 224m×224m, 448m×448m と 896m×896m の 3 つのウィンドウを元に、推論エリア上をウィンドウサイズの半分の距離スライドさせて作成する。例えば、896m×896m の場合、448m 横にスライドさせてデータを作成する(図 3)。縦方向も同様にスライドさせる。各位置でのウィンドウ内の標高差と地すべりフラグは、各ウィンドウ内の標高データから作成した。




図 3 ウィンドウによる推論データ取得例

### 3-3. 推論後の処理

推論後、各ウィンドウサイズにおいて推論結果が 2 つ以上オーバーラップしている部分を取得する。次に、ウィンドウサイズ間で、各ウィンドウサイズで取得した部分を結合する。

### 3-4. 評価

図 4 に、推論エリアにおける本手法の結果を示す。正解率、再現率と適合率は各面積を元に以下の式で算出した。式中のアルファベットは、図 4 の凡例に対応している。

$$\text{正解率} = (a+b)/(a+b+c+d) * 100$$

$$\text{再現率} = a/(a+b)$$

$$\text{適合率} = a/(a+c)$$

正解率は 65% となり、再現率と適合率はそれぞれ 0.57 と 0.49 となった。推論エリア内で判読された地すべりは 245 個であり、そのうち 221 個 (90.2%) が本手法の結果と重なった。重なり合わなかった地すべりの特徴は規模が小さいものであった。

## 4. 考察

### 4-1. 地すべり判読の効率化


本手法は、広域の地すべり判読において判読範囲を絞ることで判読の効率化に寄与できる可能性が高い。本手法の結果と重ならなかった小規模地すべりの問題は、推論データ作成時のウィンドウサイズを 336m×336m などと増やすことで、また、スライド距離を短くすることで解決できる可能性がある。

一方で、図 4 から分かるように、本手法では各地すべりの形状を抽出することは困難であると考えられる。これは、地すべりの形状を判読するには標高データだけでなく地質や傾斜量なども考慮する必要があるためである。

### 4-2. 推論データ作成の効率化

これまでに深層学習を利用した地すべり抽出の研究 [2] [3] は行われている。これらは学習データとして CS 立体図や地形量など標高データから作成した画像を用いているため、GIS などを利用して画像を作成する必要がある。一方、本手法ではそれらの画像の元となる標高データを直

接利用しているため、画像作成の手間を省くことができる。広域な災害において早急に状況把握をする必要がある場合には、本手法は有効な一手段となりうる。



- (a) 判読と本手法が地すべりとして一致
- (b) 判読で地すべりとなったが本手法では非地すべりとなった
- (c) 判読で非地すべりとなったが本手法では地すべりとなった
- (d) 判読と本手法が非地すべりとして一致

図 4 推論エリアにおける結果

## 5. まとめ

本稿では、基礎検討として、レーザープロファイラで取得した標高データから Pix2Pix で地すべりを検知できるかを確認した。解決すべき問題はいくつかあるが、本手法で判読範囲を絞ることができる可能性があることを確認した。

今後は、より正確に判読範囲を絞るために、今回検知できなかった小規模な地すべりにも対応できるように研究する予定である。

## 参考文献

- [1] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou and Alexei A. Efros, “Image-To-Image Translation With Conditional Adversarial Networks”, CVPR2017, pp. 5967-5976, July 2017.
- [2] 古木宏和, 稲垣裕, 一言正之, 藤平大, 櫻本智美, ディープラーニングによる地すべり地形の自動抽出 -教師データと抽出精度の関係-, 第 57 回日本地すべり学会研究発表会講演集, pp. 183, 2018 年 8 月.
- [3] 篠原崇之, 武田大典, 下村博之, 藤平大, 櫻本智美, “深層学習 (Dilated U-net) による航空レーザーデータを用いた地すべり地形自動抽出手法の検討”, 第 57 回日本地すべり学会研究発表会講演集, pp. 339-240, 2018 年 8 月.