

## (74) 地形量図を用いた 機械学習による落石発生源の抽出

崎田 晃基<sup>1</sup>・菊地 輝行<sup>2</sup>・西山 哲<sup>3</sup>

<sup>1</sup> 学生会員 岡山大学大学院 環境生命科学研究科 (〒700-8530 岡山県岡山市北区津島中 3-1-1)  
E-mail: pq1i4u6h@s.okayama-u.ac.jp

<sup>2</sup> 正会員 株式会社 J-POWER 設計コンサルタント (〒101-0021 東京都千代田区外神田 2-16-2)  
E-mail: kikuchi-t@jpde.co.jp

<sup>3</sup> 正会員 岡山大学大学院教授 環境生命科学研究科 (〒700-8530 岡山県岡山市北区津島中 3-1-1)  
E-mail: nishiyama.satoshi@okayama-u.ac.jp

斜面災害への対策において点検に用いる図面性能の品質が課題となり、点検時に見落としが発生している。これに対して、航空レーザ測量の活用がブレイクスルーとして期待されている。計測データから作成する地形量図は、地表面の情報を2次元平面上に示す。この手法をスクリーニングに相当する机上調査で利用することで点検結果全体の高度化を図ることが可能である。しかし、判読成果は技術者の判読スキルに左右されることが懸念点である。そこで、本研究ではAIの物体検出を地形量図へ適応し、落石発生源の机上抽出を行うシステムを提案する。地形量図の1種であるウェーブレット解析図をベースに、サポートベクターマシンによる物体検出を適応した。既存の点検結果を元に検証を行った結果、落石発生源を含む段差上の地形を抽出できることを確認した。

**Key Words:** rockfall source, aerial laser survey, wavelet analysis map, support vector machine,

### 1. 緒言

落石被害を軽減するための対策として、「道路防災点検要領」<sup>1)</sup>に従った斜面点検が実施されている。落石は急傾斜で、露岩部分が不安定化し、地下水の浸透や凍結融解などの外力を受けて活動することで発生する。そのため、点検においてはこのような落石発生源を対象に安定度を調査し対策を検討する。点検では初めに航空写真や森林基本図などの図面を用いて点検個所のスクリーニングを行う机上調査が実施される。この机上調査の結果は、現地調査時の調査ルートを選定に利用され、また調査時に携帯する地図となる。すなわち机上調査の結果は点検の結果全体に影響するため非常に重要な過程である。しかしながら、平成9～16年に発生した斜面災害の54%がスクリーニングによる点検対象外から発生している。また、発生した斜面災害の内訳では、落石が上位を占める結果となっている<sup>2)</sup>。そのため、机上調査の高精度化が落石への対策の課題の一つであった。近年、斜面防災においては航空レーザ測量と地形量図の活用が期待される。航空レーザ測量から得られた斜面の点群は、地表面の形状を正確に取得できる。点群を用いて斜面の傾斜角

度や微地形箇所の凹凸度合いなどを解析し、数値として表現する手法が、地形解析技術と呼ばれる。さらに、解析結果に応じて色付けを行い視覚的な効果を高めて図面化したものが、地形量図である。地形解析技術は、解析方法に応じて抽出する地形情報に違いがあり、様々な手法が提案されている<sup>3)</sup>。先行研究<sup>4)</sup>では、地形量図の1種であるウェーブレット解析図<sup>5)</sup>を机上調査用の図面として利用し、落石発生源の抽出を行いその有用性を示した。しかし、点検における見落としの発生は、図面精度だけの問題ではない。より重要な課題は、図面の判読が点検員のスキルに依存することである。このために図面の判読方法についても統一する手法が必要である。

そこで本研究では、落石発生源に対する効率的な点検手法の確立を目的に、地形量図に機械学習による物体検出を適応し、落石発生源の抽出を試みた。具体的には、パターン分類手法の1つであるサポートベクターマシンを利用する。これを先行研究で有用性を示しているウェーブレット解析図に対して適応し、既存の点検結果を用いて落石発生源抽出の学習・検証を実施した。最後にこれらの結果を元に、点検手法としての活用について述べる。

## 2. 物体検出による落石発生源の抽出

### (1) 航空レーザ測量とウェーブレット解析図

地形量解析を行うには斜面の地表面情報が必要なため、航空レーザ測量データから植生やノイズなどを取り除いた DEM(Digital Elevation Model: 数値標高モデル)を作成する。さらに、データ容量の削減や、一律に解析を行うためには TIN (Triangulated Irregular Network: 不規則三角形網) モデルを作成し、内挿補間を行い求めたグリッド化したデータを作成することが一般的である。地形量解析手法は、土木研究所が作成した地すべり地における航空レーザの解析マニュアル<sup>9)</sup>に様々な手法が整理されており、本研究で利用するウェーブレット解析図もその1つである。ウェーブレット解析図は連続ウェーブレット変換という手法を参考に、DEM 内の凹凸箇所を強調するように作成される図面である。

$$C(s, a, b) = \frac{1}{s} \iint z(x, y) \psi\left(\frac{x-a}{s}, \frac{y-b}{s}\right) dx dy \quad (1a)$$

$$\psi(x, y) = (2 - x^2 - y^2) e^{-\frac{1}{2}(x^2 + y^2)} \quad (1b)$$

解析は式-1a に従った演算で、ウェーブレット係数  $C(s, a, b)$  を求める。この演算の概要を示したものを図-1 に示す。この演算では、マザーウェーブレット関数  $\psi$  と地表面形状との相関性を式-1a の畳み込み積分から算出しており、その結果が  $C(s, a, b)$  となる。s は解析のパラメータである。マザーウェーブレット関数には式-1b に示す関数を用いる。この関数は上に凸型の形状を有するもので、その形状から一般にメキシカンハット関数と呼ばれる。

### (2) サポートベクターマシンによる物体検出

AI による物体検出技術は、画像内から特定箇所を探す探索と、探索した画像が識別されるパターンを決定する分類を組み合わせて実施される。本研究ではパターン分類手法の1種であるサポートベクターマシン(support vector machine, 以下 SVM)<sup>7)</sup>を分類過程で用いる。この手法では、2クラスのデータを分離する最適な分類境界を学習パターンから決定し、これに従って未知パターンの分類を行う。中でも SVM の特徴は、分類境界とそれに最も近い学習データとの距離を最大化するように学習を




図-1 ウェーブレット解析の概要図

進めることで、分類の汎化能力を上げる工夫がされているという点である。これにより学習された分類境界  $g(x)$  は次の式(2)で表される。

$$g(x) = \text{sign}\left(\sum_{i=1}^n y_i a_i K(x_i, x) + b\right) \quad (2)$$


$(x_i, y_i)$  は学習パターン  $x_i$  とそれが属するクラス  $y_i$  であり、 $a_i$  は学習から求められるラグランジュ乗数、 $b$  はバイアスである。SVM では線形分離不可能なパターンに対して高次元空間へ写像し分類を行うためのカーネル関数  $K(x_i, y_i)$  を変更することができる。ここでは次の式(3a)に示す線形カーネルと、式(3b)の Radial Basis Function カーネル(以下 RBF カーネル)を用いる。なお、式(3b)内の  $\gamma$  は決定境界の複雑さを調整するパラメータである。

$$K(x_i, x_j) = x_i^T x_j \quad (3a)$$

$$K(x_i, x_j) = (-\gamma \|x_i - x_j\|^2), \quad (\gamma > 0) \quad (3b)$$

SVM を用いた物体検出の流れを図-2 に示す。学習過程では学習用データの切り出しと学習を行う。本研究は、落石発生源箇所とそれ以外の微地形の2クラスに分離するため、既存の点検箇所を元に2つのクラスに該当する範囲をそれぞれ切り出し SVM に学習させた。抽出過程では、スライディングウィンドウ法により画像内から落石発生源箇所を抽出する。スライディングウィンドウ法は、任意のウィンドウサイズを画像の左上から同じ幅で捜査する手法で、ウィンドウ内に含まれる画像を1つのタイルとして生成する。このタイル画像を SVM により分類し、落石発生源箇所として分類された箇所を図面上に提示することで自動抽出を可能とする。

#### a) 学習過程



#### b) 抽出過程




図-2 サポートベクターマシンによる物体検出の流れ

### 3. 実験緒言

本研究では、ウェーブレット解析図を式(1a)で、パラメータ  $s=1$  で作成した。学習に用いるデータは既往の研究<sup>4)</sup>で実施した現地調査の結果を元に作成する。現地調査では岡山県岡山市御津草生地区の一般国道 53 号線沿いの斜面を area1~3 の 3 つに分け実施しており、落石発生源箇所 32 か所と他の微地形 16 か所を確認している。本研究ではこれに 44 か所の平坦斜面を加えた計 92 か所を学習・検証用データとして用意した。これらの微地形箇所と作成したウェーブレット解析図を示したものを図-3 に示す。学習過程では図-2 に示した通りこれらの微地形箇所を正方形に切り取る。切り取った 92 か所のデータセットの 2 クラス間の特徴を示すために、画像内の値でヒストグラムを生成したものを図-4 に示す。ヒストグラムから、落石発生源箇所のデータは、他の微地形に比べてすそ野が広く分布するデータであることがわかる。既往の研究<sup>4)</sup>においても、ウェーブレット解析図の特性として、隣り合ったピクセル間でウェーブレット係数が、負値から正値へ急激に変化する箇所に落石発生源が確認されており、図-4 のヒストグラムの傾向とも一致する。

学習の際には、サポートベクターマシンによる分類が正しく行われているかを検証する必要がある。この 92 か所の学習用データセットを学習と検証の 2 つのデータセットに分けた。また、学習させるデータによって結果にばらつきが出ないように、学習・検証データセットから組み合わせの異なる 10 のサブデータセットを作成し、それぞれで解析を行う K-Fold 較差検証を実施した。式(3a)、(3b)に示した 2 つのカーネルに対してこの交差検証の結果を整理し、まず分類精度について評価する。その後、評価結果もとづき、図-2 の抽出過程に従って落石発生源箇所の抽出を実施する。なお、これらのシステム構築については、python を利用し構築しており、SVM の分類は機械学習用モジュールの scikit-learn<sup>8)</sup>に属するものを用いた。なお、(3b)に示した RBF カーネルのパラメータ  $\gamma$  はデフォルトの設定を利用した。

### 4. 実験結果

#### (1) 学習過程における分類精度の評価

2 つのカーネルを用いた結果の比較として較差検証による分類の結果を表-1 に示す。検証用のデータセットに対して 2 クラスの分類を行い、その結果から正解率 (Accuracy)、適合率 (Precision)、再現率 (Recall) を算出し表に示した。また、K-fold 交差検証により用意した 10 個のサブデータセットすべての平均値を表の右端に記載している。この結果、線形カーネル、RBF カーネルともにすべての項目で約 70%を上回る精度での分類成果を示した。さらに、10 回の交差検証における平均値は、正解率、適合率、再現率の 3 つの指標で 80%を超える精度となっ

た。2 つのカーネルの比較では、RBF カーネルによる分類結果の方が、80%を超える分類結果を示したサブセットの結果が多く、3 つの精度指標における平均値も線形カーネルに比べて高い値を示した。この結果を元に、RBF カーネルを利用した SVM 分類器で物体検出を行う。




図-3 微地形位置を示したウェーブレット解析図と点検結果




図-4 学習・検証用データのウェーブレット係数分布

表-1 2 つのカーネルを用いた K-fold 交差検証結果

| 線形カーネル    | set1 | set2 | set3 | set4 | set5 | set6 | set7 | set8 | set9 | set10 | 平均値   |
|-----------|------|------|------|------|------|------|------|------|------|-------|-------|
| accuracy  | 90%  | 90%  | 89%  | 78%  | 78%  | 78%  | 67%  | 100% | 100% | 67%   | 83.7% |
| precision | 94%  | 75%  | 93%  | 86%  | 86%  | 88%  | 65%  | 100% | 100% | 75%   | 86.2% |
| recall    | 75%  | 94%  | 83%  | 75%  | 75%  | 67%  | 67%  | 100% | 100% | 75%   | 81.1% |
| RBFカーネル   | set1 | set2 | set3 | set4 | set5 | set6 | set7 | set8 | set9 | set10 | 平均値   |
| accuracy  | 100% | 90%  | 89%  | 100% | 78%  | 89%  | 89%  | 100% | 100% | 67%   | 90.2% |
| precision | 100% | 75%  | 93%  | 100% | 86%  | 93%  | 88%  | 100% | 100% | 65%   | 90%   |
| recall    | 100% | 94%  | 83%  | 100% | 75%  | 83%  | 92%  | 100% | 100% | 67%   | 89.4% |



## (2) 物体検出による落石発生源箇所の抽出

前節の結果を元に RBF カーネルによる SVM の物体検出器を用いて、図-2 に示した流れに基づいた物体検出を行った結果を図-5 に示す。物体検出では、道路沿いの人工斜面を対象から取り除き、自然斜面のみを対象に解析を行った。図-5 は、図-3 に示したウェーブレット解析図をベースに示した。また、物体検出器による落石発生源箇所の抽出結果を黄色の枠で、学習・検証に用いた微地形箇所をそれぞれ赤：落石発生源、青：他の微地形として示している。この結果、図内の広い範囲で落石発生源箇所が抽出された。先に示した通り、ウェーブレット解析図では、隣接したピクセルで値が急激に変化している箇所に段差上の地形が存在しており、これを落石発生源として抽出している。この特徴を踏まえて図-5 の結果を確認すると、抽出箇所の大半にこの特徴が表れていることがわかる。

一方、観察対象周辺を詳細に見ると area2 に隣接する南側斜面の一帯は、抽出されていない。この一帯は、傾斜はしているものの平坦斜面であり、上述した地形特徴が表れておらず、抽出されていない事が確認できた。抽出結果の大半は area1,2 や area2,3 間に沿うように太く発達した線状の微地形に沿って抽出されていることがわかる。これは、浸食により形成された谷であり、谷側壁の遷急線箇所が落石発生源として抽出されていると考えられる。これらの抽出された結果の精度を検証するために、学習・検証に用いた範囲の抽出率を表-2 に整理した。この結果、落石発生源箇所は使用した 32 か所すべてを抽出したことが確認された。他の微地形については、60 か所の内 45 か所は抽出されず他の微地形であることを特徴づけることに成功した。しかし、残りの 15 か所については落石発生源として抽出されており、誤判読となった。

## 5. 結論

本研究では、見落としのない点検手法の確立に向け、AI 技術により実施する落石発生源の抽出手法を提案し、机上調査における有用性について検証を行った。解析結果は、RBF カーネルを用いた分類結果においては 90%を超える分類精度を有し、抽出結果では学習・検証に用いた落石発生源箇所すべてを抽出することに成功した。先に述べたとおり、机上調査における見落としを改善することが点検の精度を上げるためには重要であり、本研究で提案する手法はその抽出精度から、落石発生源の机上調査手法において適応性があると考えられる。しかし、結果からもわかる通り、本研究の結果は過抽出の傾向となっている。ただし、防災点検における点検個所のスクリーニングでは、様々な資料を並列的に精査し、最終的な点検個所を決定する。そのため、この結果のみならず、他の既存資料を踏まえたうえで、点検個所を絞り込むスクリーニング手法も検討すべきであ




図-5 提案手法による落石発生源の抽出結果

表-2 提案手法による落石発生源の抽出数

|                 | 抽出数          | 未抽出数        |
|-----------------|--------------|-------------|
| 落石発生源<br>(32か所) | 32<br>(100%) | 0<br>(0%)   |
| 他の微地形<br>(60か所) | 15<br>(25%)  | 45<br>(75%) |

る。今後は、そのようなスクリーニング手法の開発に向け、他の図面を並列的に判読できるシステムの開発や、AI により点検個所の優先順位を決定するためのプロセスの検討を行うことが課題である。

## 参考文献

- 1) 全国地質調査業協会連合会：点検要領, p.2-18, 2006.
- 2) 佐々木靖人, 浅井健一：防災点検の有効性と災害の低減に向けて-10 年間の防災対策の遷移と課題-, <<https://www.zenchiren.or.jp/geocenter/lec-road/docs/bosai-tenken-2018.pdf>>, (入手 2021.6.1).
- 3) Guzzetti, F., Mondini, A.C., Cardinali, M., Fiorucci, F., Santangelo, M. and Chang, K.T.: Landslide inventory maps: New tools for an old problem, *Earth-Science Reviews*, vol.112, pp.42-66, 2012.
- 4) 崎田晃基, 今西将文, 西山哲:航空レーザ測量データを活用した斜面点検に適した微地形解析図面の作成, 第 15 回岩の力学国内シンポジウム概要集, no. 67, pp.377-380, 2021.
- 5) Booth, A.M., Roering, J.J. and Pror, J.T.: Automated landslide mapping using spectral analysis and high-resolution topographic data: Puget Sound Lowlands, Washington and Portland Hills, Oregon, *Geomorphology*, vol.109, pp.132-147, 2012.
- 6) 独立行政法人土木研究所 土砂管理研究グループ 地すべりチーム：地すべり地における航空レーザ測量データ解析マニュアル(案), pp.11-13, 2009.
- 7) Corinna, C. and Vladimir, V.: Support-vector networks, *Machine learning*, vol.20, pp.273-297, 1995.
- 8) Scikit-learn, scikit-learn Machine Learning in Python, <<https://scikit-learn.org/stable/>>, (入手 2021.6.1).