

## (7) 時系列 DInSAR 解析結果と地形特徴量を用いた 深層学習による地表面変動の把握

菊地 輝行<sup>1</sup>・庄路 友紀子<sup>2</sup>・重岡 優希<sup>3</sup>・清水 則一<sup>4</sup>

<sup>1</sup>正会員 株式会社 J-POWER 設計コンサルタント 地質事業部 (〒101-0021 東京都千代田区外神田 2-16-2) E-mail: kikuchi-t@jpde.co.jp

<sup>2</sup>正会員 電源開発株式会社 茅ヶ崎研究所 (〒253-0041 神奈川県茅ヶ崎市茅ヶ崎 1-9-88) E-mail: Yukiko\_Shouji@jpower.co.jp

<sup>3</sup>非会員 株式会社 J-POWER ビジネスサービス 社会環境部 (〒104-0045 東京都中央区築地 4-6-4) E-mail: Yuuki\_Shigeoka@jpbs.co.jp

<sup>4</sup>正会員 山口大学 名誉教授 (〒753-8511 山口県山口市吉田 1677-1) E-mail: nshimizu@yamaguchi-u.ac.jp

本研究の目的は、地表面変動の可能性箇所を確実にかつ自動的に検出することにある。地すべりや斜面崩壊の予兆や発生予察は、これまで熟練した技術者が、地形、地質、過去の履歴をもとに推定している。この場合、広範囲、他箇所を一気に判断するのは難しく、技術者によってばらつきが生じることもある。そこで地形判読に深層学習を導入して客観性を担保する試みが行われているが、教師データの不足や実際の崩壊事例が少なく、十分な成果が出ているとは言えない。

本研究では、地質、地形などの条件に加えて実際の変位の履歴を加えると、より確実に地表面変動箇所を検出できると考えた。DInSAR による変位分布を入力データとし、実際に地表面変動が生じている地形的特徴の明瞭な箇所を教師データとして、深層学習による自動検出する方法を検討する。

**Key Words:** DInSAR, Landslide, Convolutional Neural Network, Deep Learning

### 1. はじめに

近年、自然災害が多発している。経験のない豪雨・地震も多く発生しており、山地では地すべりや深層崩壊の影響を受ける可能性が高まっている。地すべり発生の誘因の予測は、一つは気象災害や地震の発生であり、降雨予測や地震予知に関する技術開発が進んでいる。しかし地形・地質・過去の情報蓄積のみで専門家による推定では、汎用性の問題から広範囲を一度に判読するのは難しい。そこで、これらの地形・地質情報に加えて実際の変位の履歴を加えると、より確実に地すべり可能箇所を検出できると考えられる。近年は、リモートセンシングを用いた変位計測が注目されている。特に DInSAR (Differential Interferometry Synthetic Aperture Radar: 差分干渉合成開口レーダー) は、定期的に地球を周回する衛星を用いた手法であり、過去にさかのぼって履歴を検出できる利点がある。

そこで、本研究では、この2種類、時系列データと地

形的特徴の解析を組み合わせ、近年活用例が増加している画像による機械学習手法<sup>1)</sup>を用いて分類モデルの作成を試みたので報告する。

### 2. 対象地域の地形・地質

対象地点は、図-1 に示す中部日本、静岡県西部の赤石山地の南縁部に位置する。この付近の山地は海拔約 800m の山頂部を持ち、急傾斜の斜面が多い幼年期地形を呈する。また天竜川が、北から南へ流れ、比高差は 700m に達する。対象地を含む両岸の斜面には、多くの地すべり地や崩壊地が分布している<sup>2)</sup>。基盤岩は、西南日本外帯の三波川帯の結晶片岩より構成されている。この結晶片岩は、地質構造に伴う異方性が顕著である。このため剥離性に富み、表層の緩みと風化により脆弱化して、地質構造が地形に反映されやすい。この結果、地すべりが多く認められる。

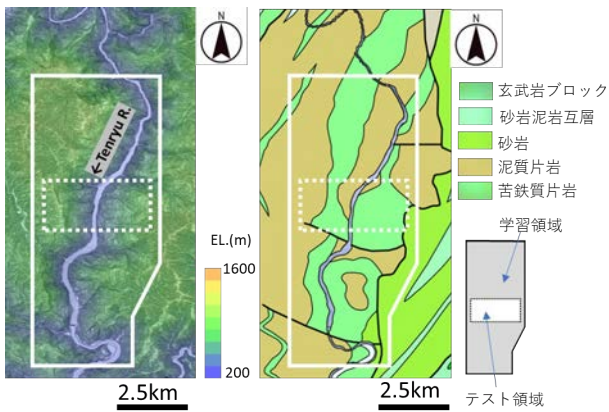


図-1 調査箇所 (a)標高分布図, (b)地質図 (GSI, AIST、20 万分の1日本シームレス地質図 V2) <sup>3)</sup>

表-1 使用データ一覧

データの種類	JAXAALOS-2 データ	DEM
使用データ	2014/8/22～ 2020/2/14 間の 15 データ (北行軌道)	2015/12/28～ 2016/1/13 撮影
空間分解能	2～3m	0.25m
その他の仕様	干渉画像のペア数：40 ペア	有人回転翼機 (アジア航測)

### 3. データセッティング

対象範囲は 11×5.3 km で河川の両側を含む地形とした。DEM データは、表-1 に示す DEM を用いた。これは電源開発株式会社により取得されたものである。数値解析には、ダウンスケールして 1m グリッドデータを作成した。

#### (1) 地形的特徴を表すパラメータ

地形・地質に影響を与える地形的特徴の定量化の手法として DEM を用いて 8 つのパラメータを作成した。既往文献では多数のパラメータを用いることが試みられ<sup>4)</sup> 山体重力変形や降雨表流水が反映されるように配慮した。採用したパラメータは、傾斜量<sup>5)</sup>、固有値比<sup>6)</sup>、曲率<sup>7)</sup>、地上・地下開度<sup>8)</sup>、地形的湿潤指数<sup>9)</sup>、ウェーブレット<sup>10)</sup>、標高である。

傾斜量は、地すべり・斜面崩壊に関する最も重要な要素である。DEM の各メッシュの水平面からの傾きを示し、中心から 3×3m の範囲の最急勾配とした。固有値比は、地表面の単位斜面における法線ベクトルのばらつきを示し、周囲の地表面との相対的な違いを示す。固有値比は、地すべり活性度の指標として有効であると報告されている<sup>11)</sup>。固有値比の計算は、対象地点に隣接する 3×3m を用いて算出した。曲率は、地形の凹凸の指標である。曲面上で 2 点間を結ぶ最短距離の曲線の曲率の最大値と最小値の平均として定義する。考慮範囲は、片側 10m (10 pixel) とした。地上開度・地下開度は着目地点から距離 50m の範囲内である方位の空を見ることができると天頂角または天底角の最大値を 8 方位について平均した。地形的湿潤指数は、地形条件をから恒常的な水の集まりやすさや溜まりやすさを表す。ウェーブレットは 2 次元の連続ウェーブレット変換によって求め、地表面の凹凸度合いを強調するのに有効である。これらの指標のほかに標高を用いた。作成した各パラメータの画像を図-2 示す。

#### (2) DInSAR による地表面変位分布

広域的な観測が可能な衛星 SAR は、地表から 500～

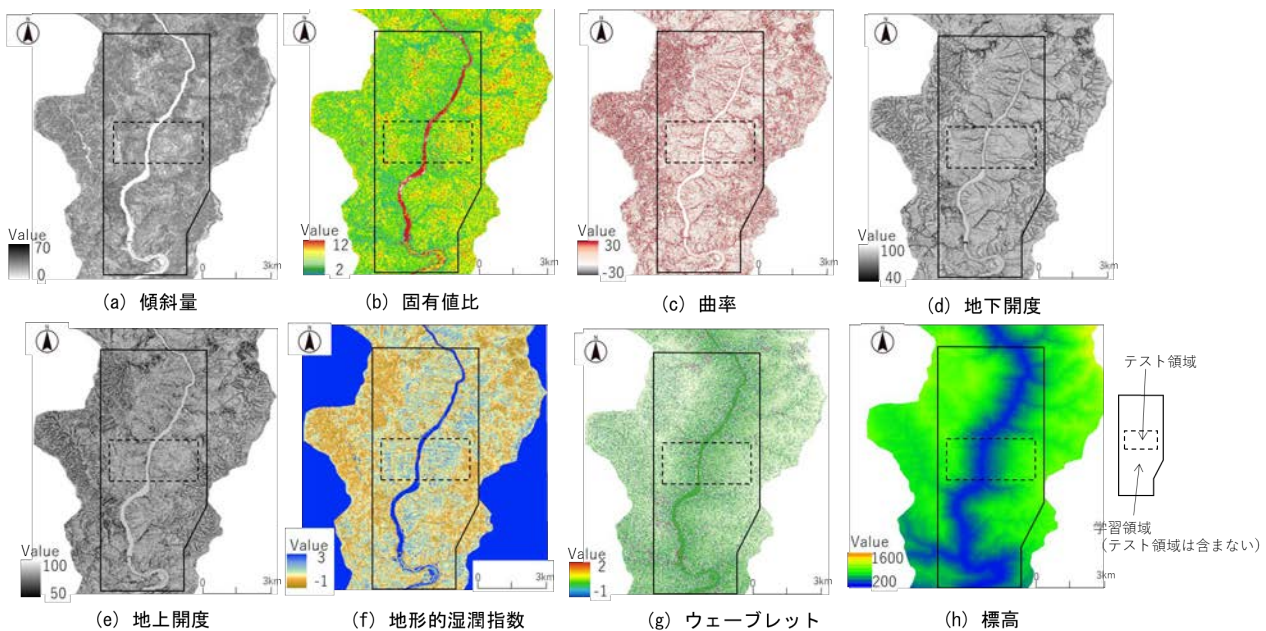


図-2 特徴的な地形を示すことができる 8 つのパラメータ処理結果

700kmの軌道を周回する人工衛星に搭載されたレーダーで、地表に向けて照射したマイクロ波の反射波を受信し、強度と位相を観測する<sup>12)</sup>。DInSARは、同一の場所に対して異なる2時期に観測したSARデータに含まれる反射波の位相を用いて各位置の位相差を求め、地形（標高）の影響と衛星位置の相違に起因する影響を除き衛星と地表面を結ぶ視線方向の変位を抽出する<sup>13)</sup>。SBAS-DInSARは、衛星の基線長（2時期の衛星間距離）および観測時期の間隔に制限を与え、制限値以下の衛星間距離と観測時期間隔に対するすべてのSARデータについてDinSAR解析を行う。本研究では、変位の時系列モデルとして、干渉位相の変化をSARの観測時期間隔で一定と仮定する線形モデルを用いた。解析は、SARscape（sarmap社製、スイス）を用いて実施した。計測時期は表-1に示す2014/8/22～2020/2/14間の15時期の変位量を抽出した。

#### 4 深層学習

深層学習は、人間の脳神経回路を模した多層構造を有する解析手法である。本研究は、画像認識で用いられる畳み込みニューラルネット（Convolutional Neural Network、以下「CNN」）によって解析を行った。CNNは、ニューラルネットにおける多層構造において、各層のまとまりを示す特徴量を作成する畳み込み層とこれらを圧縮するプーリング層を複数含む機械学習手法の1種である。本研究は、同じ座標を有する画像について異なる解析図、すなわちモーダル情報として多数の視点を持たせた。これにより多数の要因および時系列的な情報が蓄積された地表面の特性について判別が可能となる。

##### (1) 教師データ作成

教師データの作成は、図-3(1)に示すフローで実施した。第一に、地形・地質に影響を与える地形的特徴の定量化の手法としてDEMを用いて8つのパラメータを作成した。これに15時期、すなわち14期間のDInSARデータを加えた22要素のデータを作成した。次に、説明変数に相当する4つの特性（y0～y3）を有するグループに区分した。最後に50mメッシュで分割して教師データとした（これをタイルと呼ぶ）。タイルの大きさは、滑落崖などの地形的特徴がとらえられ、調査領域で最も小さい一つの移動体が把握できる1辺50mとした。

##### (2) モデル構築

深層学習は、Windows10、CPU:Corei7(32GB)、GPU:NVIDIA 3060(16GB)を用いてNeural Network Console (SONY社製、東京)を用いて実施した。計算は、パラメータ調整の繰り返し計算を240時間実施、最終的に施行した278種類のモデルを探索し、図-3(2)に示すホールド

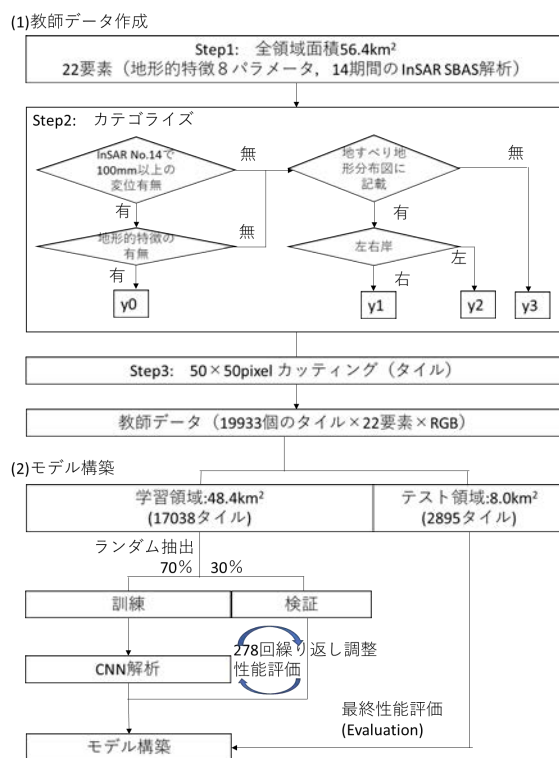


図-3 深層学習の実施フロー

表-2 性能評価結果

説明変数	再現率 (8パラメータ)	再現率 (22要素)
y0	0.71	0.96
y1	0.49	0.97
y2	0.76	0.98
y3	0.43	0.84
再現率(平均)	0.60	0.94
正解率	0.50	0.87

アウト手法<sup>14)</sup>により最も誤差が少ないモデルを採用した。

#### 5 結果（モデル性能評価と判定結果）

##### (1) モデルの性能評価

学習済みモデルの評価は、混同行列（多クラス分類の結果をまとめたマトリックス）で行った。再現率は、各説明変数の正答の割合を示す。また正解率は、予測結果全体がどれくらい真の値と一致しているかを示す。この結果、再現率は、地形条件を代表した8パラメータよりも、DInSARデータを用いた結果が上昇しており時系列データの優位性が確認できた。

##### (2) テスト領域の判定結果

図-4には、テスト領域の判定結果(a)と地表面変位量

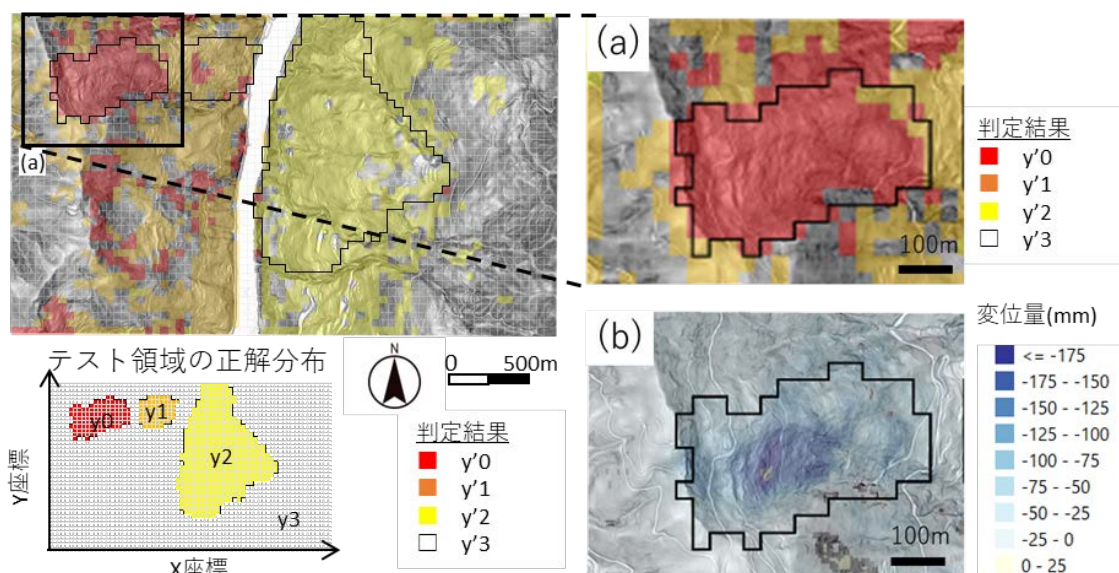


図-4 テスト領域における解析結果と地表面変位 100mm 発生箇所の拡大図 (a) 深層学習評価結果, (b) DInSAR 解析結果のうち第 1～15 回の解析結果 (2014/8/22～2020/2/14)

の事例(b)を示す。この判定結果は、全 22 要素を用いたもので、地形的特徴と広域の地表面変形の時系列情報を付加したものである。この比較によれば地表面変形の判定を精度よく行えることができています。一方で目的変数となる  $y'0$  は図-4 (a) の北側にも分布している。この箇所は DInSAR 第 1～15 回の計測結果で変位量が 100mm 以下でありながら選択されており、今後の変位の蓄積で 100mm に拡大する可能性のある箇所として知見を得ることができる。

本研究を進めることで、地表面変位発生箇所が広範囲に自動的に検出でき、かつ見落としも無くなり確実性向上に寄与することができる。

**謝辞：**本研究で用いた ALOS-2 データは山口大学と宇宙航空研究開発機構(JAXA)の連携協定に基づき、JAXA から提供いただいた。また、検討対象とした現場情報や DInSAR の結果を掲載することにご理解いただいた関係者の方々に感謝いたします。

#### 参考文献

- 1) 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, 地すべり学会誌, 56 巻, 5 号, pp.1-10, 2019.
- 2) 菊地輝行, 秦野輝儀, 千田良道, 西山哲: S-DEM データを利用した地すべり地における変動ベクトル解析技術の開発, 応用地質, 57 巻, 6 号, pp. 277-288, 2017.
- 3) 産総研地質調査総合センター: 20 万分の 1 日本シームレス地質図 V2, <<https://gbank.gsj.jp/seamless/v2.html>>, (入手

- 2022.6.3) .
- 4) Aleotti, P. and Chowdhury, R.: Landslide hazard assessment: summery review and new perspective, Bull Eng Geol Env, Vol.58, No.1, pp.28-44, 1999.
- 5) Burrough. P. A., McDonnell, R. A. and Lloyd, C. D. : Principles of geographical information systems, Oxford university press, 2015.
- 6) Woodcock, N.H. and Naylor, M. A. : Randomness testing in three-dimensional orientation data, J Structural Geol, Vol. 5, No.5, pp.539-548, 1983.
- 7) 千葉達郎, 鈴木雄介, 平松孝晋: 地形表現手法の諸問題と赤色立体地図, 地図, 45 巻, 1 号, pp.27-36, 2007.
- 8) 横山隆三, 白沢道生, 菊池祐: 開度による地形特徴の表示, 写真測量とリモートセンシング, 38 巻, 4 号, pp.26-34, 1999.
- 9) Beven, K. J. and Kirkby, M. J. : A physically based, variable contributing area model of basin hydrology, Hydrol Sci Bull, Vol.24, pp.43-69, 1979.
- 10) Booth, A. M., Roering, J. J. and Prnon, 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.
- 11) Kasai, M., Ikeda, M., Asahina and T., Fujisawa, K.: Li-DAR-derived DEM evaluation of deep-seated landslides in a steep and rocky region of Japan, Geomorphology, Vol.113, pp.57-69, 2009.
- 12) 大内和夫: リモートセンシングのための合成開口レーダの基礎 [第 2 版], 東京電機大学出版局, p.384, 2009.
- 13) Ferretti, A. : Satellite inSAR Data: Reservoir Monitoring from Space, European Association of Geoscientists & Engineers, 2014.
- 14) Kohavi, R. : A study of cross-validation and bootstrap for accuracy estimation and model selection, Ijcai, Vol. 14, No.2, pp.1137-1145, 1995.