

Sentinel 衛星画像の深層学習による令和 6 年能登半島地震被災道路の検出

新潟大学農学部農学科 学生会員 ○ 中川健聖
新潟大学大学院自然科学研究科 正会員 柴野一真
新潟大学自然科学系（農学部） 正会員 鈴木哲也

1. はじめに

令和 6 年 1 月 1 日に発生した能登半島地震は、石川県を中心に甚大な被害をもたらした。のと里山海道をはじめとする幹線道路において広範囲にわたり路面崩壊・斜面崩壊が確認された（図 1；国土交通省道路局，2024）。被災直後は現地へのアクセスが困難であり、道路復旧や復興支援には広域の被災状況を迅速に把握することが不可欠である。従来の被災調査ではヘリコプターや車両による目視点検が主流であるが、大規模災害直後の広域対応には時間・労力のコストが大きい。

光学衛星および合成開口レーダ（SAR）衛星は広域を繰り返し観測できる特性を持ち、大規模災害直後の被害把握手段として有効性が期待される。本研究で使用する Sentinel-2（光学、観測周期約 5 日）と Sentinel-1（SAR、観測周期約 12 日）を組み合わせることで、全天候での時系列変化を捉えることができる。深層学習の発展により衛星画像からの地表変化自動抽出精度は向上しているが、衛星データを用いた被災道路の検出研究は現時点でほとんど存在しない（Khelifi and Mignotte, 2020）。

本研究は、Sentinel-2 光学時系列、Sentinel-1 SAR 時系列、数値標高モデル（DEM）および USGS ShakeMap を入力とし、2 系統の Transformer エンコーダで並列処理するデュアルストリーム型深層学習モデルによる区間単位の道路被災自動検出を試みた結果を報告する。衛星による道路崩壊検出の可能性を示す取り組みとして、衛星の空間分解能・観測頻度の将来的な向上を見据えた基礎的検討と位置付けるものである。

2. 研究対象および解析方法

2.1 対象路線とデータセット

観測対象はのと里山海道である。道路中心線を延長方向 10 m、幅方向 25 m の矩形区間に分割し、各区間を被災あり（1）・被災なし（0）の 2 値で分類した。正解ラベルは、震災後の航空写真（国土地理院，2024）上で被災範囲をポリゴンで囲み、区間の中心点がポリゴン内に含まれる場合に被災ラベルを付与した。被災形態は、斜面・法面崩壊に起因するものを Type 1、路面の沈下・変形・亀裂が主体であり路面のアスファルト舗装が確認できるものを Type 2 とした。

区間は地理的に 2 つのエリアに分割した。徳田大津




図 1 斜面崩壊に伴う道路被災

IC から穴水 IC までを AOI-A（訓練データ，2,611 区間）、穴水 IC からのと三井 IC までを AOI-B（テストデータ，1,143 区間）とし、空間的に隣接しない区間でモデルの汎化性能を評価した。全 3,754 区間のうち被災区間は 301 件（8.0 %）、非被災区間は 3,453 件（92.0 %）であった。テストデータ（AOI-B）における被災区間は 123 件であり、内訳は Type 1 が 114 件、Type 2 が 9 件である。

2.2 衛星特徴量の構成

入力特徴量を動的特徴量と静的特徴量に区別する。動的特徴量として、地震前後を含む 2021 年 1 月～2024 年 6 月の月次合成データを使用した。月次合成は雲被覆率 70 %未満のシーンを対象に SCL（Scene Classification Layer）バンドで雲・雲影・巻雲ピクセルをマスクし、同一ピクセルの有効観測値の中央値を代表値とした 1 か月分の合成画像であり、日本海側特有の冬季の雲・雲影の影響を低減する。地震前 3 年間（2021～2023 年）の月次平均と標準偏差を基準とした Z スコア正規化を施し、地震後の相対的变化量を特徴量として入力した。

Sentinel-2 からは、B2・B3・B4・B8・B11 バンドをもとに NDVI（植生指数）、NDMI（水分指数）、MNDWI（水体指数）、BSI（裸地指数）、EVI（拡張植生指数）、B11（短波赤外）の計 6 特徴量を算出した。大規模な道路崩壊では斜面の植生が除去されて裸地が露出するため、光学センサの反射特性が地震前後で大きく変化する。NDVI や EVI は植生消失を、BSI は裸地化の進行を、NDMI は地表の水分・土壌状態の変化をそれぞれ反映する。

Sentinel-1 からは、偏波 VV・VH 後方散乱係数、交差比（ $CR = VV - VH$ ）、VV 標準偏差の 4 特徴量に、GLCM テクスチャ（VV: contrast, ASM, IDM,




図 2 DualStream Transformer アーキテクチャ

correlation, entropy; VH: 同 5 種; CR: contrast, entropy) 12 次元を加えた計 16 特徴量を使用した。路面が崩壊・変形するとマイクロ波の後方散乱特性が変化し、光学センサで検出困難な小規模な路面損傷も、地表の粗度・含水率変化として SAR 後方散乱に現れる。

静的特徴量 (10 次元) として、DEM から標高・傾斜角・アスペクト ($\sin/\cos$)・曲率・地形粗度・地形湿潤指数 (TWI) の 7 指標, USGS ShakeMap から PGA・PGV・MMI の 3 指標を使用した。以上、動的特徴量 22 次元×6 か月, 静的特徴量 10 次元を各セグメントの入力とした。

2.3 深層学習モデルとアンサンブル

地震後 6 か月分 (2024 年 1~6 月) の Sentinel-2 光学時系列 (6 次元×6 か月) を処理する S2 ストリームと, Sentinel-1 SAR・GLCM テクスチャ時系列 (16 次元×6 か月) を処理する S1 ストリームの 2 系統で構成されるデュアルストリーム型 Transformer を構築した (図 2)。各ストリームは Transformer エンコーダ (埋め込み次元 $d=48$, 4 ヘッド, 3 層, Pre-LN) で月次変化パターンを抽出し, Global Average Pooling で時間方向に集約した。2 ストリームの出力 (各 $d=48$ 次元) を静的特徴量 (10 次元) と結合し, MLP ヘッド ($106 \rightarrow 128 \rightarrow 64 \rightarrow 1$, GELU 活性化, Dropout) に入力して区間ごとの崩壊予測スコアを出力する (Vaswani et al., 2017)。なお, 本モデルは地震後 6 か月分のデータを一括入力するため, 地震後 6 か月のデータが揃った時点で初めて崩壊予測スコアの推定が可能となる。

学習時には, クラス不均衡 (被災 8 % : 非被災 92 %) への対処として, Focal Loss ($\gamma=2.0$, $\alpha=0.85$) (Lin et al., 2017) と pos_weight (負例数/正例数×2.5) を組み合わせた。ラベルスモージング ($\epsilon=0.05$) (Szegedy et al., 2016) によるモデルの過信抑制と, SAM オプティマイザ ($\rho=0.05$, base optimizer: AdamW, 学習率 2×10^{-4}) (Foret et al., 2021) による汎化性能の向上を図った。バッチサイズは 128, 最大 200 エポック, 早期終了 (patience=35) で学習を制

御した。

交差検証は, 隣接セグメント間の空間的自己相関を排除するため, 各セグメントを道路起点からの緯度方向距離順に並べ, 等間隔に 5 分割したブロック交差検証を採用した。各フォールドは連続する区間を検証データとするため, 訓練・検証データ間の地理的分離を担保する。

最終予測は, C_strong (デュアルストリーム Transformer, Focal Loss+Label Smoothing, SAM), v21 (Sentinel-1 SAR 月次 Z スコアに基づくシグナル処理型モデル), v4c (全特徴量を単一ストリームで処理する Transformer モデル) の 3 モデルを rank-Dirichlet アンサンブルで統合した。各モデルの予測スコアをランク変換 ($\text{rank} / (N+1)$) により $[0,1]$ の一様分布に正規化したうえで, Dirichlet 分布からランダムサンプリングした重みベクトルで線形結合し, F1 スコアを最大化する最適重みを探索した。ランク変換を介することでモデル間の出力スコアの分布スケールや偏りの差異を吸収し, 単純な確率平均よりも安定した出力が得られる。

2.4 特徴量重要度の評価とアブレーション実験

各特徴量グループの寄与を定量化するため, Permutation Importance (検証セット上で対象グループの特徴量をランダムシャッフルしたときの ΔAUC , 5 回繰り返しの平均値) および Cohen's d (テストセットの崩壊群・非崩壊群間の平均値差をプールした標準偏差で正規化した効果量, $|d| \geq 0.5$ を中程度以上の目安) を算出した (表 3)。ShakeMap の寄与を検証するため, ShakeMap を除外した静的特徴量 (DEM7 次元のみ) で訓練したモデルと提案手法を比較するアブレーション実験を実施した (表 1)。

3. 結果および考察

3.1 検出精度

テストセクション (AOI-B, 1,143 区間) における検出精度を示す (表 1)。提案手法は $\text{AUC}=0.894$, 平均適合率 (AP) $=0.690$ を達成した。F1 スコアを最大化する最適閾値 $\theta=0.860$ において, F1 スコア 0.712, 適合率 0.755, 再現率 0.675 が得られ, 123 件の崩壊




図3 AOI-Bにおける検出結果の空間分布

区間のうち83件を正しく検出 (TP), 27件の誤検出 (FP), 40件の見逃し (FN) が生じた (図3)。空間分布では、非被災区間 (TN=993件) は路線全体で正確に捉えられた一方、実際の被災箇所周辺では未検出 (FN) および誤検出 (FP) が発生する傾向がみられた。ROC 曲線 (図4) は左上への顕著な凸形状 (AUC=0.894) を示す。PR 曲線 (図5) はランダム分類器の基準値 (AP=0.108) を大きく上回っており、クラス不均衡下でも実用的な識別能力を有することが確認された。

崩壊タイプ別では、Type 1 (斜面・法面崩壊, 114件) の検出率 68.4 %に対し、Type 2 (路面損傷, 9件) は 55.6 %にとどまった (表2)。Type 1 は SAR・光学の両センサに明瞭な地表変化を伴うため比較的

高い検出率が得られた。Type 2 は地表被覆の変化が区間 (10 m×25 m) 単位では希薄となるため識別が困難であった。FN 区間の主な発生要因として、被災面積が区間に対して小さく衛星シグナルの変化量が閾値に達しにくいこと、復旧工事によるブルーシート養生・盛土・アスファルト舗装により衛星観測時点で地表が被覆されていたこと、地震直後の1~2月は積雪・雲の影響により Sentinel-2 の有効観測が制限されたことの3点が考えられる。

ShakeMap のアブレーション実験では F1 が 0.021 低下した。ShakeMap の単独寄与は小さいが、のと里山海道沿いでは北部 (のと三井 IC 付近) ほど地震動強度が高く (MMI VI 以上)、南部 (徳田大津 IC 付近) では MMI V 程度まで低下する空間勾配が確認される。この空間的な地震動分布を静的特徴量として付与することで、光学・SAR 特徴量だけでは識別が困難な境界的な区間の分類精度が向上したと考えられる。アンサンブルの導入により F1 スコアは単体モデルの 0.682 から 0.712 へ、AUC は 0.878 から 0.894 へ向上した。

3.2 特徴量の寄与度

Permutation Importance の結果 (表3)、Sentinel-2 光学特徴量群の重要度が突出して高く ($\Delta AUC=+0.221$)、次いで Sentinel-1 基本量 (+0.058)、GLCM テクスチャ (+0.023) の順であった。DEM・ShakeMap の ΔAUC はほぼゼロであるが、前述のアブレーション実験から ShakeMap は光学・SAR と組み合わせることで境界的区間の分類を補助する役割を担うことが確認された。

個別特徴量の Cohen's d では、標高 (elevation, $d=0.699$)、VV 偏波月平均 (VVmean, $d=0.524$)、EVI ($d=0.499$) が上位を占めた。標高の弁別力が最も高い理由は、崩壊箇所がのと里山海道沿いの急峻な斜面区間に集中しており、平坦な路盤区間との地形的差異が大きいためと解釈される。VV 偏波は地表の粗度・含水率変化を反映する SAR シグナルであり、斜面崩壊に伴う地表状態の変化を地震直後から捉えられることが高い弁別力の要因と考えられる。EVI は植生活力を示す指数であり、崩壊地点では植生が除去されることで EVI の春季回復が生じないという季節パターンが明確な差異として現れる。

特徴量の月次変化に着目すると、Sentinel-2 の NDVI・EVI は 4~6 月にかけて崩壊地点で春季回復が遅延または消失しており、この春季シグナルが崩壊検出における最大の識別手掛かりとなることが確認された。崩壊地点では BSI (裸地指標) の上昇も 4 月以降に顕在化しており、植生消失と裸地化が複合的に崩壊を示唆する。一方、Transformer の Self-attention を分析すると、全区間平均では各月への注目がほぼ均一 ($\approx 1/6$) であったのに対し、高確率崩

表 1 検出スコア結果

手法	F1	AUC	AP
提案手法	0.712	0.894	0.690
ShakeMap なし	0.691	0.885	0.671

表 2 被災区分別検出精度

被災区分	総件数	検出	見逃し	検出率
Type 1	114	78	36	68.4%
Type 2	9	5	4	55.6%
合計	123	83	40	67.5%

表 3 グループ別寄与度

グループ	次元数	Δ AUC	Cohen's d
Sentinel-2	36	+0.221	0.398
Sentinel-1	24	+0.058	0.373
GLCM	72	+0.023	0.244
DEM	7	$\approx$ 0.000	0.248
ShakeMap	3	$\approx$ 0.000	0.089




図 4 ROC 曲線




図 5 PR 曲線

壊区間では Sentinel-1 の 1 月（地震翌月）成分への注目が 0.24~0.30 に上昇していた。Permutation Importance と合わせると，Sentinel-2 光学が検出精度の大部分を担いつつ，地震直後の Sentinel-1 変化が補完的な役割を果たすという二層構造が本モデルの特徴といえる。

4. おわりに

本研究では，光学・SAR 衛星データの深層学習で能登半島地震による道路被災箇所の検出を試みた。デュアルストリーム型 Transformer と rank-Dirichlet アンサンブルの組み合わせにより，テストセクションで $F1=0.712$ ， $AUC=0.894$ を達成した。小規模な路面損傷の検出には課題が残るものの，遠隔からの広域モニタリングによる現地調査支援の可能性が示された。今後は他地域・他路線への汎化性能の検証が課題である。

引用文献

- Foret, P., Kleiner, A., Mobahi, H. and Neyshabur, B. (2021): Sharpness-aware minimization for efficiently improving generalization, ICLR.
- Khelifi, L. and Mignotte, M. (2020): Deep learning for change detection in remote sensing images, IEEE Access, 8, 126385–126400.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K. and Dollár, P. (2017): Focal loss for dense object detection, ICCV, 2980–2988.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z. (2016): Rethinking the inception architecture for computer vision, CVPR, 2818–2826.
- Vaswani, A., Shazeer, N., Parmar, N. et al. (2017): Attention is all you need, NeurIPS, 30.
- 国土交通省道路局国道・技術課 (2024)：令和 6 年能登半島地震 道路構造物（橋梁，土工，トンネル）の被害分析，社会資本整備審議会道路分科会参考資料-1，令和 6 年 3 月 26 日。
- 国土地理院 (2024)：地理院地図，<https://maps.gsi.go.jp/>（参照 2026 年 10 月 7 日）。