

第IV部門 衛星 SAR 画像と機械学習を用いた地盤変動推定

京都大学工学部地球工学科 学生会員 ○寺西 由夏
 京都大学大学院工学研究科 学生会員 楠瀬 智也
 京都大学大学院工学研究科 正会員 須崎 純一

京都大学大学院工学研究科 正会員 松島 格也
 京都大学大学院工学研究科 正会員 小谷 仁務
 西日本高速道路株式会社 非会員 藤原 優

1. はじめに

近年、集中豪雨による土砂災害が多発しており、それに伴う人的、物的被害が深刻な問題となっている。災害を事前に予測し、被害を最小限にとどめる方策として降雨量を用いる手法や、衛星測量によって地盤の変動を算出する手法が存在しているが、前者では実際の地盤挙動が考慮できず、後者では2〜3カ月毎の変状しか観測できないという課題が残る。

そこで本研究では、防災対策に活用するにあたって十分な時間幅で入手することのできる気象データを入力値として、実際の地盤変動量を予測する機械学習モデルを提案する。土砂災害の発生個所を予測する観点からは詳細な地盤変動量値である必要はなく、本モデルでは変動量を7クラスに分類することとした。学習モデルには三次元点群向けの分類およびセグメンテーションを行う PointNet[1]を使用する。

2. 提案手法と使用データ

(1) PointNet

三次元点群向けの機械学習アルゴリズムである PointNet ではボクセル化などの処理を行うことなく点群データを扱うことができ、入力順序に依存しない出力、周囲の点との相互作用、剛体変換に対するロバスト性を保証する。本研究で扱うデータは出力の答え合わせに使用する合成開口レーダ (SAR) による地盤変動量を観測できる点が離散的であることから、入力データも空間的な散らばりを持っているため三次元点群に近い特徴がある。

(2) SMOTE

一部のクラスに属する学習データが著しく多い不均衡データはしばしば、機械学習の精度向上の足かせとなる。特に分類課題においてはデータの偏りが大きいことで、単一のクラスにすべてを分類する無

意味な学習を生じやすくなる。本研究においても変動の少ないクラスにデータが偏る様子を見て取ることができたため、オーバーサンプリング手法である SMOTE[2]によるデータ分布の正常化を行った上での学習を実施した。SMOTE では少数派クラス同士の間ランダムに新規点の内挿を行うことで少数派クラスのデータ数を増加させることが可能となる。

(3) 対象地域と使用データ

本研究の対象地域は2019年8月の九州北部での集中豪雨を端緒とする高速道路路面の隆起により、大規模な土砂災害が発生した長崎自動車道武雄 JCT (佐賀県) 周辺の 1.8 km 四方エリアとし、変動が観測されたのは 845,566 点である。変動量算出には2017年2月から2020年10月の間に ALOS/PARSAR2 で撮影された L バンド画像 15 枚を使用した。表 1 に示す開始日と終了日に取得された SAR 画像に対する時系列 SAR 解析から 2 時期間累積変動量を計 14 期間分取得した。この地域では土砂災害発生の約 1 年前から地盤の隆起に関連すると考えられる変動が観測されており、図 1 では災害前の約半年間に土砂災害発生产の東側にわずかに隆起の傾向が見られる。

表 1 対象期間

term No.	開始	終了
1	2017/2/25	2017/6/3
2	2017/6/3	2017/8/12
3	2017/8/12	2017/11/4
4	2017/11/4	2018/2/24
5	2018/2/24	2018/6/2
6	2018/6/2	2018/8/11
7	2018/8/11	2018/11/3
8	2018/11/3	2019/2/23
9	2019/2/23	2019/8/10
10	2019/8/10	2019/11/2
11	2019/11/2	2020/2/22
12	2020/2/22	2020/5/30
13	2020/5/30	2020/8/8
14	2020/8/8	2020/10/31




図1 2019年2月23日から2019年8月10日の間に生じた地盤変動

機械学習の入力データに使用するのは緯度経度およびTE-Japanが提供する1 km メッシュの気象データをもとにドロネー三角形分割による内挿を行った降水量と土壌水分量の総量である。

3. 結果

図2に緯度経度および降水量と土壌水分量(総量)を入力データとした際の対象エリアにおける地盤変動量を7クラスに分類予測した結果を示す。降水量と土壌水分量については対象14期間を用いて標準化を行った値を使用した。また、少数派の変動量を持つクラスに対してはSMOTEによるオーバーサンプリングを行い、すべてのクラスに属する学習データの数が等しくなるように調整を加えた。




図2 2019年2月23日から2019年8月10日までの地盤変動量予測値

4. 考察

図1と図2比べると、解像度は粗いものの、PointNetをベースとした機械学習モデルを用いることで気象データから、大きな地盤の変動が起こる可

能性の高いエリアについて予測できることが確認できる。実際に観測される変動量に比べて解像度が低い原因は2つ考えられる。1つ目に、入力データの気象データは解像度が大きく、変動が少ないことである。1 km メッシュのデータを内挿しているが、元の気象データの隣合うメッシュ間での変動があまり大きくないことで、内挿を行った入力データにおいても近接点同士の特徴量に変化が出づかった可能性がある。また2つ目にはSMOTEによる影響がある。今回は少数派データの数を多数派データに合わせるようにオーバーサンプリングのみを実施していることで、少数派データが存在するエリアにおいて過剰反応を起こしていると思われる。

5. 結論

本研究では、実際の防災に活用する段階には至らないまでも、気象データを用いる機械学習を利用してSAR解析を必要としない地盤変動量の予測をできる可能性を示した。

今後の課題としては考察でも述べた通り、説明変数である気象データと被説明変数の変動量データ間の解像度差を埋めることが挙げられる。また、本研究では予測対象期間以前に同地点で生じた変動の影響や近接点で生じる変動による影響を考慮することができていないため、時空間変化を組み込んだモデルの構築も必要となる。加えて、各クラス値間の序列に関する情報も取り入れることで、大きな隆起が観測されるすぐ近くで極端な沈下をするといった不合理な予測を防ぐことにつながるのではないかと考える。

6. 参考文献

- [1] Charles R. Qi, Hao Su, Kaichun Mo, Leonidas j. Guibas. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. arXiv preprint arXiv : 1612.00593, 2016.
- [2] Nitesh V. Chawla, Kevin W. Bowyer, Lawrence O. Hall, W. Philip Kegelmeyer. SMOTE: Synthetic Minority Over-sampling Technique. Journal of Artificial Intelligence Research. 2002, vol.16, p321-357.