

MA3 機械学習を用いた箱根大涌谷における

高濃度火山ガス発生イベントの高精度予測と早期警報

Accurate Prediction and Early Warning of High Concentration of Volcanic Gas in Owakudani, Hakone Using Machine Learning

指導教員 町村尚准教授・地球循環共生工学領域 28H21064 細見幸太郎 (Kotaro HOSOMI)

Abstract: There are many active volcanoes in Japan. To reduce the damage caused by volcanic activity, it is necessary to predict volcanic disasters and to take measures to evacuate people in advance. In this study, we developed a machine learning model to predict the increase in volcanic gas concentration at Owakudani in Hakone. Time series data of the atmospheric environment such as volcanic gas concentration, temperature, and precipitation by location, and image data of fumaroles near the crater were used as input data. These data were trained using a machine learning model to predict the volcanic gas concentration 30 minutes in advance. The prediction model is an ensemble of several models using the stacking ensemble method. As a result of that, the stacking model showed its effectiveness on prediction with AUC scores up to 0.9313.

Keywords: machine learning, stacking ensemble, volcanic gas, prediction, early warning

1. 背景と目的

日本は火山が多い国であり、火山噴火や火山ガス、火山灰による被害も多く報告されている。2015年6月に神奈川県箱根町の箱根山で発生した小規模噴火もその一例である¹⁾。火山災害による被害を防ぐために、現場の種々の環境モニタリングデータを用いて火山ガスの発生を事前に予測し、サイトへの立ち入りを禁止する等の対策が有効である。そこで本研究では、箱根大涌谷での火山ガス濃度の上昇を高精度で予測する機械学習モデルを構築することを目的とした。

2. 分析方法

2. 1. データセットの収集と前処理

図1に対象地の神奈川県箱根山大涌谷の園地周辺を示す。目的変数は、30分後の神山登山口での火山ガス(SO₂)濃度が0.1ppmを超えるか否かの2値変数である。説明変数は園地内の環境状況を示すコンテキストデータ(火山ガス濃度、風向風速、気温、降水量など)と、火山ガスの噴気の画像データを用いた。入力データのサンプル数は、コンテキストデータが418,933、画像データが859であった。2016–2018年を訓練用、2019–2020年を評価用データとして分割した。

2. 2. モデルの訓練と汎化性能の評価

テーブルデータを用いた予測にはLSTM, LGB, XGB, Cat Boost, Random Forest, Logistic Regressionを用いた。画像データを用いた予測には、ImageNetの学習済みモデルを転移学習したモデルを用いた。まず、Optuna²⁾を用いてハイパーパラメータを調整し、層化5分割交差検証による交差検証精度の評価を行った。予測精度の評価指標にはPR-AUCを用いた。次に、アンサンブル手法の一つであるスタッキングを用いて、学習済みのモデルをアンサンブルした。アンサンブルでは第1層の各モデルの予測結果を特徴量とし、第2層のモデルを訓練した。最後に、評価用データを用いて学習済みモデルの未知のデータに対する汎化性能を評価した。



図1 対象地の箱根大涌谷と観測機の位置 (Google Map に著者加筆)

表 1 モデルの汎化性能

Ensemble	Model	Input data	AUC	F1-score	Precision	Recall
第 1 層	Logistic Regression	context	0.793	0.704	0.921	0.570
	Random Forest	context	0.775	0.683	0.900	0.551
	Cat Boost	context	0.821	0.731	0.962	0.589
	XGB	context	0.860	0.840	0.856	0.825
	LGB	context	0.833	0.759	0.954	0.630
	LSTM	context	0.778	0.667	0.930	0.520
	Image Net	image	0.307	0.102	0.056	0.545
第 2 層	Stacking Model	context, image	0.931	0.746	0.958	0.611

3. 結果と考察

3. 1. モデルの汎化性能の評価

表 1 にモデルの汎化性能の評価の結果を示す。まず、第 1 層のモデルの予測精度では、XGB が PR-AUC で 0.860 と良いパフォーマンスを発揮した。次に、画像データを用いた予測モデルでは PR-AUC は 0.307 であった。最後に、第 2 層のモデルのアンサンブルの結果では、PR-AUC は 0.931 であった。以上より、スタッキングを用いた手法が単一モデルの予測精度を上回ることが確認されたとともに、高濃度火山ガスの発生を高精度で予測する機械学習モデルの構築が実現された。

3. 2. モデルの予測根拠

XGB に対して SHAP 値³⁾による特徴量重要度の分析を行った(図 2)。予測への寄与が大きい特徴量は、神山登山口における 30 分前の火山ガス濃度、風向、風速等であった。また、特に北東の弱い風の際に高濃度を示しやすいことが分かった。これは、大涌谷で火山ガス濃度の計測を行った池貝ら⁴⁾の研究結果とも一致している。XGB は Stacking model を良く代表しており($r=0.938$)、Stacking model がドメイン知識と整合した妥当な予測を行っていることが示唆された。

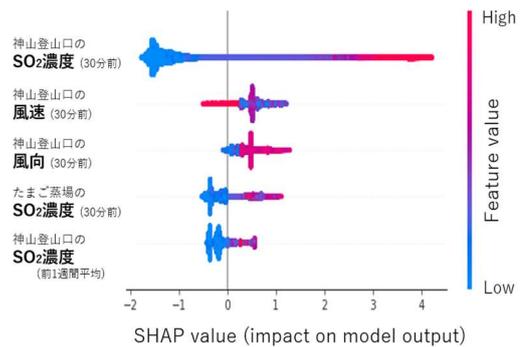


図 2 特徴量重要度の上位 5 項目色(赤～青)は各特徴量の値の大小を示す。

4. 今後の課題

今後の課題は、モデルの予測精度や説明可能性をさらに向上させることである。特に、新たな特徴量の追加やより多様性の高いモデルの組み合わせが有効である。また、より実用的な火山ガス予測システムを構築するためには、現地事業者や行政機関との協力関係を築き、早期警報の呼びかけ等のオペレーションの充実を図ることが必要である。さらに、自然災害の予防における機械学習手法の普及するためには、観測手法やデータの有用性等の知見をさらに蓄積する必要がある。

参考文献

- 1) Mannen, K., Yukutake, Y., Kikugawa, G., Harada, M., Itadera, K. and Takenaka, J.: Chronology of the 2015 eruption of Hakone volcano, Japan – geological background, mechanism of volcanic unrest and disaster mitigation measures during the crisis, *Earth, Planets and Space*, 70:68, 2018
- 2) Akiba, T., Sano, S., Yanase, T., Ohta, T., Koyama, M.: Optuna: A Next-generation Hyperparameter Optimization Framework, *ACM*, 2623:2631, 2019
- 3) S. M. Lundberg et al.: From local explanations to global understanding with explainable AI for trees, *Nat Mach Intell*, vol. 2, no. 1, Art. no. 1, 2020
- 4) 池貝隆宏, 十河孝夫, 代田寧, 吉田直哉, 菅野重和: 箱根大涌谷の火山ガス濃度の推移, 2017 年