

機械学習 (AI) を利用して監視カメラ画像から有色噴煙 (噴火) を検知する試み

Attempt to detect eruptions from surveillance camera images using machine learning (AI)

後藤 進¹, 吉田 真悟¹

Susumu GOTO¹ and Shingo YOSHIDA¹

(Received Jan 8, 2025; Accepted Jan 14, 2026)

1 はじめに

気象庁の活火山監視業務では、現業当番者をはじめ職員たちの目で観測データの監視を行うのと同時に、火山監視・情報センターシステム (Volcanic Observation and Information center System : VOIS) が自動で種々の処理を実行している。VOIS には地震計、空振計の観測データをリアルタイムで処理し、火山性地震や微動の発生状況に異常があった際にはアラームで現業当番者に報知する機能が備わっている (碓井, 2004; 松森, 2013)。この機能は VOIS の運用開始から更新を重ねた現在でも踏襲され、監視の補助を担ってきている。

しかし小規模な噴火に対してはアラームが機能しない場合がある。薩摩硫黄島 (鹿児島県三島村) では 2024 年 9 月 1 日と 3 日に噴火が発生し、福岡管区気象台の地域火山監視・警報センター (以下、火山センター) は噴火に関する火山観測報 (以下、火山観測報) を発表した。当火山で噴火を観測したのは 2020 年 10 月 6 日以来、およそ 3 年 11 ヶ月ぶりのことであった。この噴火では、前駆する地震活動や地殻変動は確認されず、噴火に伴い観測された B 型地震は振幅がさほど大きくなかったために、アラームは鳴動しなかった。噴火当時は当番者が火口からの噴煙に気付いたため早期の確認と観測報の発表に至ったが、常に早期発見が可能であるとは限らない。

たとえ小さな噴火であっても、風下側では火山灰や小さな噴石が遠方まで風に流されて降るおそれがある。いかなる場合においても火山センターが確実かつ迅速な情報提供を遂行するためには、地震動以外の観測項目からもアラームがあることが望ましい。

そこで本研究では、畳み込みニューラルネットワ

ーク (convolutional neural network : CNN, 以下, CNN) を利用した画像認識技術に注目し、火山の噴火画像を学習させた噴煙検知モデルの構築を試みた。気象庁で火山の監視に用いているカメラの映像から噴火を AI が自動で検知できれば、監視業務の補助を担うことが期待できる。

今回の研究は

- ・精度の高い (有色) 噴煙検知モデルの作成
- ・作成したモデルの他火山への転用可能性の検証

の二つを目標に実施した。学習に用いた画像は、現在噴火活動の活発な諏訪之瀬島 (鹿児島県十島村) 火山の平時と噴火発生時の監視カメラ画像から選抜した。モデルの学習には通常、膨大な学習データが必要となるが、本研究では学習済みのモデルを噴煙識別用に追加で学習させる手法 (フラインチュエニング) を採ることで学習データの節約を図った。学習後のモデルに同火山の、学習に用いなかった画像から噴火の有無を分類させ、その精度を検証した。さらに、モデルの噴煙検知能力を他火山に転用できる可能性を検討するため、学習に用いなかった桜島 (鹿児島県鹿児島市) の画像に対する精度検証も行った。

なお、有色噴煙は、火山灰などの火山噴出物を含んでいると考えられる噴煙のことを指し、固体の噴出物を含まない白色噴煙と区別している。気象庁の火山監視業務では有色噴煙の噴出を監視カメラの映像から確認した期間を噴火と記録している。従って、この報文で噴火という用語を使用する場合は、有色噴煙が確認されたことを意味することとしたい。

¹ 福岡管区気象台, Fukuoka Regional Headquarters

2 関連研究

火山現象の識別に CNN を適用した研究はすでにいくつか研究されてきた。山脇・他 (2019) は CNN を利用して焼岳 (長野県松本市, 岐阜県高山市) の監視カメラ画像から雲や霧などのノイズを除去するモデルと, 噴煙と土石流の領域を判別する噴火事象検出モデルを構築した。画像データの獲得には, 焼岳の原画像を編集することで模擬的に噴火事象を再現するなどの工夫が行われた。また, Guerrero Tello et al. (2022) はエトナ山を対象に CNN のモデルで学習を行い, セマンティックセグメンテーションの手法により画像から噴煙に当たる領域を抽出できるようにした。その他, 衛星画像を用いて火山の噴火を検出する研究も複数行われている (Del Rosso et al., 2021 ; Torrisi et al., 2024)。

本研究では, 気象庁が火山監視に用いているカメラからの火山画像を学習させ, 独自に構築した CNN モデルが実際に有色噴煙を検出し, 噴火と判断できるか検証を行った。

3 CNN の概要

3.1 人工ニューラルネットワーク

人工ニューラルネットワーク (以下, ニューラルネットワーク) は, ヒトの学習過程を数学で模式的に表現したモデルである。列に並んだ複数の計算ユニット (ニューロン) が前の列のニューロンから受け取る入力に演算処理を施し, 出力値を次の列に伝えていく。ひとつひとつの列は「層」と呼ばれる。

いま, n 個のニューロンから成る第 1 層の i 番目のニューロンから, 第 2 層の j 番目のニューロンへ数値が渡される場面を考える。第 1 層からの入力 x には, 個別のニューロンの重要度に応じた重みづけ (w) が施される。第 2 層のニューロンが第 1 層の全てのニューロンと結合している場合, 第 2 層のニューロンは n 個の入力 x と入力毎の重み w の一次結合を受け取る。一次結合に対し第 2 層のニューロンは各ニューロンに設定されたバイアス (b) を加算したうえで, その値を活性化関数 (f) に代入することで扱いやすい値に変換する (例: シグモイド関数, ReLU)。以上をまとめると, 第 2 層 j 番目のニューロンが出力する値 y_j は次の式から算出される。

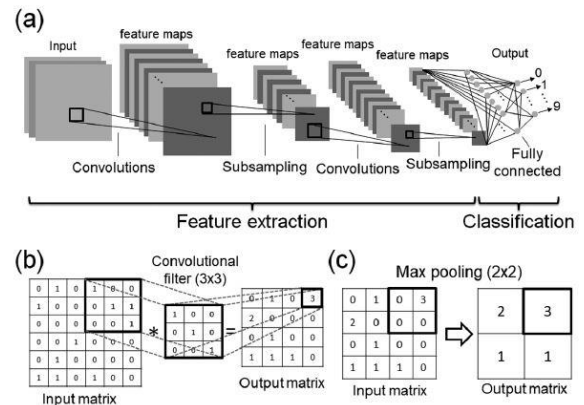


図 1 畳み込みニューラルネットワークのイメージ. (a) 全体構成, (b) 畳み込み層, (c) プーリング層. (松岡・杉山 (2018) より)。

$$y_j = f\left(\sum_{i=1}^n w_i x_i + b_j\right) \quad (1)$$

入力に積算する重みと, バイアスのそれぞれがニューラルネットワークにおけるパラメータにあたる。機械学習においてパラメータは学習を経るなかで適切な値に近づくように自動的に修正される。

3.2 CNN の構成

ニューラルネットワークの中でも, CNN は画像認識に適した学習モデルである。CNN は畳み込み, プーリング処理を行う複数の層と, 最終的な出力を担う全結合層によって構成される (図 1 (a))。

畳み込み層 (図 1 (b)) は入力画像データに対し, フィルタと呼ばれる 2 次元の行列を用いて「畳み込み」の演算処理を施す。フィルタの 1 ピクセルずつには重みが設定されており, 入力画像中の任意の領域の分布がフィルタ中の重みの分布に類似していれば出力される値は大きくなる。つまりフィルタに適合する視覚的特徴が検出される。フィルタを一定の間隔でずらしながら畳み込み処理を入力画像全体に行い, 最終的に出力される二次元データを特徴マップと呼ぶ。画像認識において目標物の特徴を上手く抽出するには, フィルタの各成分の値を適切に調節する必要がある。深層学習では, 学習を重ねることでフィルタを含む種々のパラメータが人の手によらず最適な形に算出される。

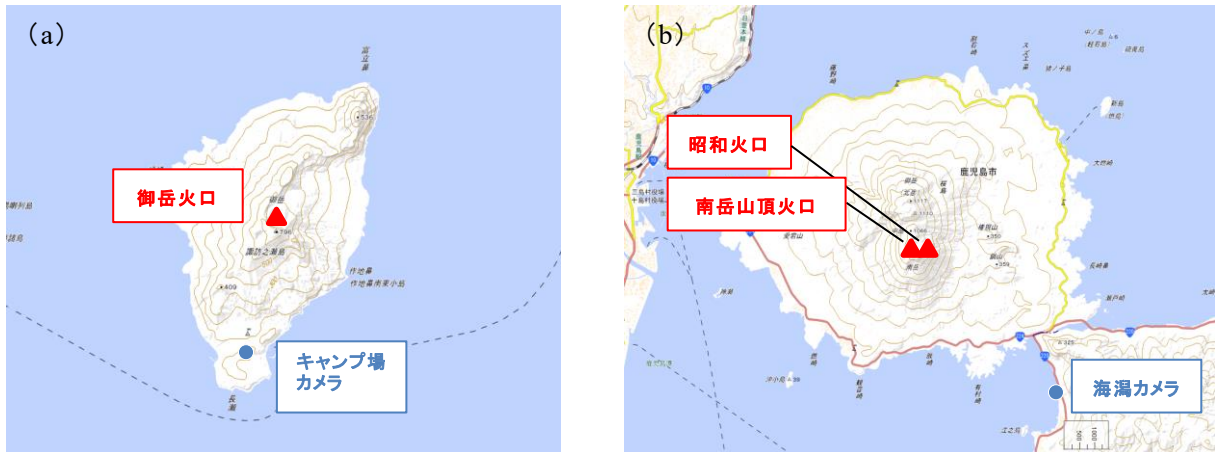


図 2 諏訪之瀬島(a)と桜島(b)における火口と監視カメラの位置関係.

表 1 各火山の監視カメラの座標.

火山	カメラ	緯度	経度
諏訪之瀬島	キャンプ場	29° 36'40"N.	129° 42'21"E.
桜島	海潟	31° 32'21"N.	130° 42'20"E.

プーリング層 (図 1 (c)) では前の畳み込み層で出力された特徴マップの任意の領域から代表値を抽出する. 本研究のモデルで行ったのは max pooling と呼ばれる処理で, 領域内の最大値を抽出する. この処理によって, 画像内の目標物の位置が変化しても領域内であれば同じ値が代表値に選ばれる. つまり位置のずれによる影響が抑えられる. また, 画像のデータサイズが縮小するため, 以降の計算量も減少する.

畳み込み層, プーリング層を複数通したのち, 全結合層で最終的な確率計算が行われて識別結果が出力される.

4 手法

4.1 対象監視カメラと画像データ

今回の調査では, 諏訪之瀬島御岳火口を監視しているキャンプ場監視カメラ (気象庁) 及び桜島を監視している海潟監視カメラ (大隅河川国道事務所) の可視画像を利用した (図 2). 二つのカメラの座標を表 1 に示した.

監視カメラの画像は, 気象庁の火山映像収録伝送装置に 2 秒ごとに保存される. 画像ファイルの仕様は, 幅 640 ピクセル, 高さ 360 ピクセル, 解像度は縦横ともに 96dpi, ビットの深さは 24bit である.

全国の常時観測火山では基本的に可視画像により噴煙監視を行っていることから, 他の火山への適用を視野に本研究の対象は可視画像に限定した. モデルの学習には諏訪之瀬島キャンプ場カメラの 2024 年 9 月 1 日~同月 30 日, 6 時~18 時の期間の画像を使用した. 時間帯を限定した理由は夜間の可視画像での噴煙の識別が日中要比困難だからである.

取得した画像は有色噴煙が映っているものと, 有色噴煙を出していない若しくは雲などのノイズによって噴煙が確認できないものに分け, それぞれ「噴火」, 「静穏」というラベルで分類した (図 3 (a) (b)). モデルの具体的な学習方法は 4.3 に記述した.

4.2 学習モデル

CNN を利用した画像認識モデルは複数公開されており, 一般の人々でもある程度学習が進んだネットワークモデルを手に入れて, 目的に応じた学習に活用することができる (転移学習). CNN は層が深くなるほど複雑な特徴も学習できるようになるが, 反面計算量は膨れ上がり, 要求される計算資源や計算時間まで増加する. したがって使用するモデルは計算コストを考慮して選ぶ必要がある. 本稿の噴煙検知モデルは, CNN の中で転移学習に優れている VGG16 (Simonyan & Zisserman (2014)) をベースに

作成した。

VGG16 は、2014 年に Oxford 大学の VGG (Visual Geometry Group) チームによって発表されたモデルである。このモデルは、ILSVRC (ImageNet Large Scale Visual Recognition Challenge) という大規模な画像認識コンペティションで 2 位を獲得した。

VGG16 は、その名前の通り 16 の層から構成されており (図 4)、 3×3 の小さなフィルタを使用した畳み込み層が特徴のモデルである。また、このモデルは Keras や TensorFlow, PyTorch などの主要な深層学習フレームワークで簡単に利用することができる。

VGG16 は事前に大量の画像を学習したモデルが一般に公開されている。これに個人で追加の学習や層構成の微調整を施すことで、パラメータを再利用しながら目的に合ったタスクに適用することができる (ファインチューニング)。表 2 に今回の実験で使用したモデルの構成を示す。Output Shape は画像及び特徴マップの縦横のサイズと出力チャンネルの数を示している。実験では画像データに対し、モデルに入力する前にサイズの圧縮を施し $200 \times 200 \text{px}$ とした。使用した可視画像は RGB で表現されるため、入力時のチャンネル数は 3 になる。Param には各層のパラメータの数を示している。最後の全結合層の後には、出力を確率分布に変換する Softmax 関数を使用して、2 クラスの分類を行った。



図 3 学習に用いた噴火時の画像 (a) と静穏時の画像 (b) の例。

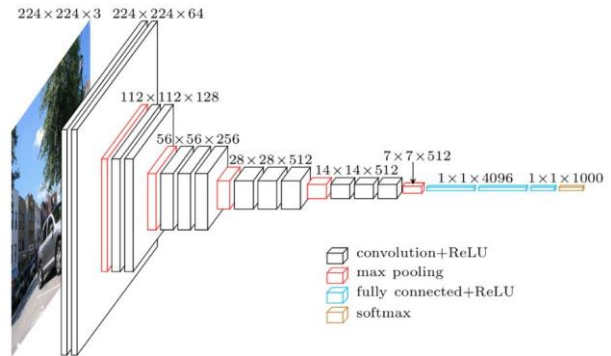


図 4 VGG16 の構成。(赤沼(2018)より)

表 2 VGG16 と新たに付加した全結合層を含めた全体の層構成.

Layer (type)	Output Shape	Param
input_layer (InputLayer)	(200, 200, 3)	0
block1_conv1 (Conv2D)	(200, 200, 64)	1,792
block1_conv2 (Conv2D)	(200, 200, 64)	36,928
block1_pool (MaxPooling2D)	(200, 200, 64)	0
block2_conv1 (Conv2D)	(100, 100, 128)	73,856
block2_conv2 (Conv2D)	(100, 100, 128)	147,584
block2_pool (MaxPooling2D)	(50, 50, 128)	0
block3_conv1 (Conv2D)	(50, 50, 256)	295,168
block3_conv2 (Conv2D)	(50, 50, 256)	590,080
block3_conv3 (Conv2D)	(50, 50, 256)	590,080
block3_pool (MaxPooling2D)	(25, 25, 256)	0
block4_conv1 (Conv2D)	(25, 25, 512)	1,180,160
block4_conv2 (Conv2D)	(25, 25, 512)	2,359,808
block4_conv3 (Conv2D)	(25, 25, 512)	2,359,808
block4_pool (MaxPooling2D)	(12, 12, 512)	0
block5_conv1 (Conv2D)	(12, 12, 512)	2,359,808
block5_conv2 (Conv2D)	(12, 12, 512)	2,359,808
block5_conv3 (Conv2D)	(12, 12, 512)	2,359,808
block5_pool (MaxPooling2D)	(6, 6, 512)	0
flatten(Flatten)	(18432)	0
fc1(Dense)	(128)	2,359,424
Dropout1(Dropout)	(128)	0
fc2(Dense)	(32)	4,128
dropout2(Dropout)	(32)	0
predictions(Dense)	(2)	66
Output_layer	(2)	

4.3 学習

学習を行う際、モデルにはある火山の画像と、それに付された「噴火」または「静穏」の正解ラベルが与えられる。モデルは入力された画像データに対し正しい予測結果を出力できるよう、重みとバイアスという二種類のパラメータを自動的に調整していく（教師あり学習）。学習、つまりパラメータ調整の方向性を決めるものは損失関数と呼ばれる関数である。損失関数の計算には、モデルが正しく予測した時の出力として期待される値（ターゲット）と実際の出力値との誤差が用いられる。一般に分類問題において損失関数にはクロスエントロピーと呼ばれる関数が用いられる。いま、N 個の入力データのうち i 番目のデータに対する出力を y_i 、ターゲットを t_i とおいたとき、クロスエントロピー L は次の式で計算される。

$$L = \frac{1}{N} \sum_{i=1}^N (-t_i \log y_i - (1 - t_i) \log(1 - y_i)) \quad (2)$$

N 個のデータ全てにおいて出力とターゲットの値が一致した時 $L=0$ となる。つまり機械学習は損失関数の値が 0 となることを目指して行われる。

本研究では諏訪之瀬島キャンプ場カメラの画像をモデルに学習させたが、学習量による精度の成長具合を見るために枚数を変えて Ver.1～Ver.3 という 3 つの検知モデルを作成した（表 3）。テストの結果からモデル間の予測精度を比較した。

モデルの画像識別能力が低い状態でテストを行う事を避けるため、学習と並行して性能の確認を実施した。ニューラルネットワークでは学習時間が長くなると、学習データに対して過剰に敏感になり、反面、未知のデータに対する認識精度が悪くなるという現象（過学習）が起こる。モデルが過学習の状態になっていないかを調べるために、学習データから一部を検証用に回し（1）検証用以外のデータで学習、（2）検証用データで精度を確認、という作業を行う。一連の工程を単位（1 epoch（エポック））とし、検証用データを選び直しながら繰り返していくことで、学習の経過を観察することが出来る。

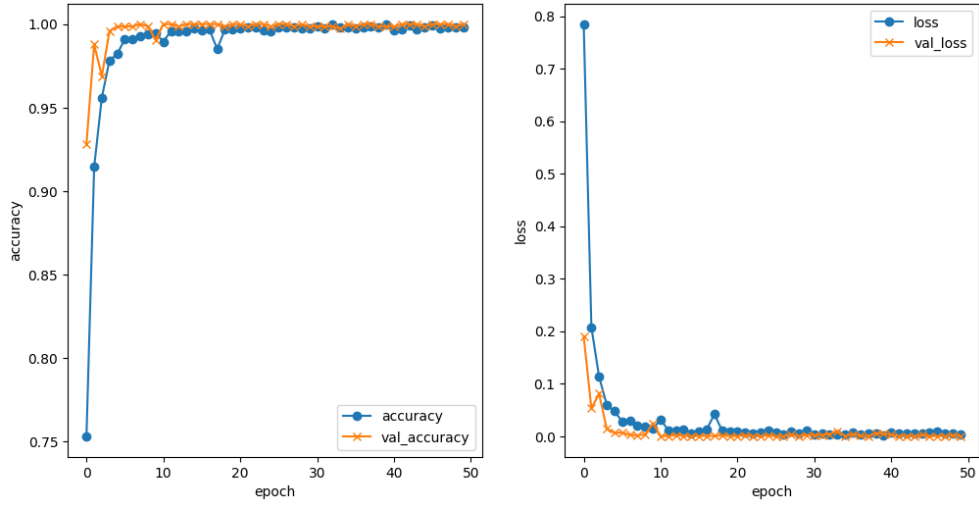
本研究では 1 エポックにつき画像データを学習用と検証用に 8 対 2 の割合で分け、各モデルで 50 エポ

表 3 モデルの学習に用いた画像の枚数.


モデル	噴火画像(枚)	静穏画像(枚)
Ver.1	1,236	2,460
Ver.2	3,113	2,910
Ver.3	10,439	10,109

ックの学習・検証を行った。学習経過を図 5 (a ~ c) に示す。縦軸の accuracy, loss はそれぞれ正答率（問題に対して正しく予測を行えた割合）と損失関数を意味する。青線と橙線はそれぞれ学習データと検証データの結果を表す。結果から、ver.1～ver.3 のいずれのモデルも過学習を起こしていないことが確認された。尚且つ、10 エポック経ていない時点で誤差関数が 0 付近に収束していることから、学習の成果は良好だと考えられる。

(a) Ver.1



(b) Ver.2



(c) Ver.3




図 5 モデルの各学習段階における正答率(左)と損失関数(右)の経過。(a) Ver.1, (b) Ver.2, (c) Ver.3.



図 6 2025 年 2 月 9 日に発生した桜島の噴火.

表 4 予測結果の正誤パターンと評価指標.

		真値	
		噴火	静穏
予測値	噴火	FO	FX
	静穏	XO	XX

$$(\text{誤検知率}) = \frac{FX}{FX + XX}$$

$$(\text{見逃し率}) = \frac{XO}{FO + XO}$$

$$\text{Specificity} = 1 - (\text{誤検知率})$$

$$\text{Recall} = 1 - (\text{見逃し率})$$

4.4 テスト

学習を終えたモデルに、学習に用いなかった画像を読ませ、「噴火」と「静穏」の識別を行わせた。テストデータには 2024 年 10 月の諏訪之瀬島の画像を用いた。学習データと同様、6 時～18 時の時間帯の画像に限定した。モデルの識別能力を精査するため、噴火の画像は噴煙が明瞭に見えるものから、噴火から間もなくわずかに有色噴煙が覗いているもの、雲によって一部が隠れているものまで複数の事例から集めた。噴火時と静穏時からそれぞれ 162 枚ずつ用意した。

また各モデルに対し、学習時とは別の火山である桜島の噴火時の画像（図 6）の識別も行わせた。

表 5 テスト結果から計算したモデル毎の誤検知率と見逃し率.

火山	モデル	誤検知率	見逃し率
諏訪之瀬島	Ver.1	0.24	0.77
	Ver.2	0.33	0.73
	Ver.3	0.30	0.17
桜島	Ver.1	0.16	0.32
	Ver.2	0.51	0.23
	Ver.3	0.43	0.02

4.5 評価指標

テストの結果は、予測結果の正誤によって 4 パターンに分類できる（表 4）。

本稿では、静穏の画像に対しモデルが「噴火」の判定を下した事例を「誤検知」、噴火の画像に対しモデルが「静穏」の判定を下した事例を「見逃し」と呼ぶこととする。噴火（静穏）画像の数のうち誤検知（見逃し）が行われた数の割合を指標として、モデル間で比較することで噴火検知能力の評価を行った。誤検知率と見逃し率はそれぞれ、分類問題における一般的な評価指標である特異率（Specificity）と再現率（Recall）に置き換えることができる。

5 結果と考察

5.1 結果 1 モデルの性能評価

各モデルのテストの結果を表 5 と図 7 に示した。

モデル Ver.3 の成績が他の 2 モデルに比べ優れていることから、今回のケースでは学習のデータセットをより多くすれば識別の精度も向上することが確認できた。一方、モデル Ver.1 と Ver.2 はともに誤検知が比較的低く、見逃しが多い傾向にある。防災の観点から見逃しが多い上記 2 つのモデルを監視に活用するにはさらなる学習が必要であることが分かった。




図 7 テスト結果から計算したモデル毎の誤検知率と見逃し率.

見逃しが最も少なかった Ver.3 は、162 枚中 27 枚あった。27 枚を図 8 にまとめた。この 27 枚の噴火画像は、噴煙の大部分が雲で隠れているなど、人間が見ても判断に迷うようなものが多い。一方の明瞭な噴火画像に対してはもれなく正しい予測を行っている。Ver.3 の精度であれば明瞭な噴火を見逃すことなく、従来のアラームシステムを補完でき、現業の監視の補助が行えると考える。また、Ver.3 では過学習の兆候が未だ見られていないことから、更なる学習によって精度の向上が期待できる。見逃し以外の諏訪之瀬島の予測結果の事例を図 9 にまとめた。

5.2 結果 2 他火山への転用可能性

諏訪之瀬島の画像のみで学習した 3 つのモデルに桜島の噴火画像の識別を行わせた結果、各モデルで見逃しの成績が諏訪之瀬島の場合より優れていることが分かった。特に Ver.3 の見逃し率は 0.02 であり、見逃されたのは 3 事例のみだった。諏訪之瀬島でのテストに比べ見逃し率が減った原因を断定することはできないが、桜島の有色噴煙の噴出量が多いことなどが影響している可能性がある (図 6)。学習枚数の多いモデルほど見逃し率が改善されている傾向は諏訪之瀬島でも見られるが、一方で誤検知の成績は Ver.1 から悪化している。誤検知について改善の必要はあるが、テストの結果は、ある火山で学習を行ったモデルを他の火山の有色噴煙 (噴火) の検知にも転用できる可能性を示している。将来、活動の活発な火山からサンプルを集め、噴火事例の少ない火山の噴火検知に活用できるようになることが期待できる。桜島の予測結果の事例を図 10 にまとめた。

5.3 連続画像による確認

諏訪之瀬島から有色噴煙が出てくる前後の画像を連続的に確認し、噴煙が現れる際のモデルの予測結果の変化を観察した。なお、検証を行うために適切な条件、つまり火口からの噴出物が何もない状態から有色噴煙を出した事例は全体のうち限られているため、この検証では噴火事例を 2024 年 10 月以外の期間からも選出した。モデルには、火山体から有色噴煙が現れた瞬間を起点に前 1 分と後 3 分の計 4 分間 (2 秒間隔) の連続画像 120 枚を用いた。

4 つの事例で試した結果を表 6 と図 11 に示す。結果から、モデルは噴煙が現れてから検知するまでに 10 秒程度、早いものでは 4 秒かかることがわかった。また、一つのイベントが起こっている間はモデルの判断はおおよそ一貫しており、初めに「噴火」の判定が出てから最後までモデルは「噴火」と判断し続けた。ただし 2025 年 1 月 1 日の事例のみ最初の噴火判定から 20 秒の間に 3 枚の画像で「静穏」と判断した。

(正解) 噴火 → (予測) 静穏 (見逃し, XO)



図 8 テストで Ver.3 が誤って「静穏」と予測(見逃し)した諏訪之瀬島の噴火画像全 27 枚.

(正解) 噴火 → (予測) 噴火 (FO)



(正解) 静穏 → (予測) 噴火 (誤検知, FX)



(正解) 静穏 → (予測) 静穏 (XX)




図 9 テストで Ver.3 が正しく予測を行えた画像(左上, 右下)と誤って「噴火」と予測(誤検知)した画像(右上)の例.

機械学習(AI)を利用して監視カメラ画像から有色噴煙(噴火)を検知する試み

(正解)噴火→(予測)噴火(FO)



(正解)静穏→(予測)噴火(誤検知, FX)



(正解)噴火→(予測)静穏(見逃し, XO)



(正解)静穏→(予測)静穏(XX)

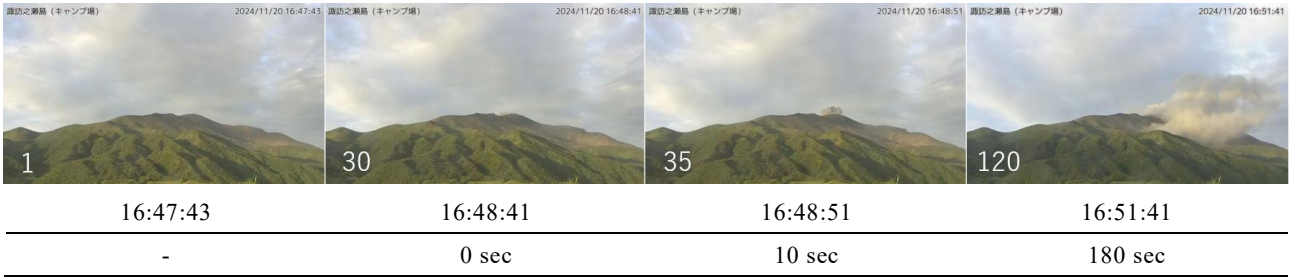


図 10 桜島の噴火時及び静穏時の画像と Ver.3 の予測結果.


表 6 4つの噴火事例における連続画像 120 枚中、噴火前の静穏画像 29 枚と噴火直後の画像 91 枚のうち Ver.3 が誤った予測をしたもの.

噴火事例	誤検知		見逃し	
	画像 (1-29)	rate	画像 (30-120)	rate
(a) 2024.11.20 16:48~	2, 5, 9, 20, 29	0.17	32-34	0.03
(b) 2024.12.13 07:51~	-	0.00	30, 31	0.02
(c) 2024.12.23 12:37~	1-6, 9-14, 16,19, 20, 27	0.55	30-33	0.04
(d) 2025.01.01 13:28~	10, 25	0.07	30-32, 34, 35, 43	0.07


(a) 2024.11.20 16:48~ (誤検知 : 5 枚 (率:0.17) 見逃し : 3 枚 (率:0.03))



(b) 2024.12.13 07:51~ (誤検知 : 0 枚 (率:0.00) 見逃し : 2 枚 (率:0.02))



(c) 2024.12.23 12:37~ (誤検知 : 16 枚 (率:0.55) 見逃し : 4 枚 (率:0.04))



(d) 2025.01.01 13:28~ (誤検知 : 2 枚 (率:0.07) 見逃し : 6 枚 (率:0.07))




図 11 噴火前後の連続画像に対するモデルの予測の変化。各画像左下の数字は 120 枚の連続画像内における順番を示している。各画像の下に撮影時刻と噴煙が現れてからの経過時間を示す。

6 まとめ

本稿では、監視カメラ画像から噴火を検知できるようになることを目標に、CNN を利用し噴煙検知モデルを作成した。学習データ量の異なる3つのモデルの精度を比較し、学習をより多く行わせたモデルで噴煙検知能力が向上することを確認した。

本稿でのもう一つの目標は、ある火山の画像で学習させたモデルの他の火山の噴煙検知への転用である。そのため、モデルの学習では諏訪之瀬島以外の噴火画像を敢えて学習させなかった。桜島に諏訪之瀬島の画像で学習したモデルを転用してみたところ、有効である可能性が示唆された。

人工知能(AI)を活用して業務の効率化を目指す動きは、既にビジネスや技術など広い範囲にわたって展開され、ますます勢いをつけている。気象庁も先端的なAI技術を活用することで、自然現象の予測精度向上や防災気象情報の高精度化・高度化を目指す方針を示した(気象庁, 2025)。火山の監視業務にも先端AIの活用によって業務の効率化や業務の質を向上させる道を探ることが必要と考える。

今後はこの実験で見逃し及び誤検知が発生した事例を調べることでモデルが予測するうえで重要な要因を探し出し、より多くの噴火事例をカバーできるモデルを制作することが望まれる。また本実験では行わなかった、夜間の噴火の検知もできるようになることが望まれる。

謝辞

匿名の査読者並びに編集委員の山里平氏、中村政道氏からのご意見により、本稿は大幅に改善された。桜島海潟カメラの画像の利用には大隅河川国道事務所承認を頂いた。本稿中の地図の作成に当たっては、国土地理院の承認を得て、同院発行の『数値地図50mメッシュ(火山標高)』を使用した。記して感謝の意を表す。

文献

- 赤沼領大 (2018): チャンネル方向並列化を導入したCNNの学習のハイブリッド並列化の提案. 東京大学大学院工学系研究科修士論文.
- Del Rosso, M. P., A. Sebastianelli, D. Spiller, P. P. Mathieu and S. L. Ullo (2021): On-Board Volcanic Eruption Detection through CNNs and Satellite Multispectral

Imagery. *Remote Sens.*, **13**, 3429.

Guerrero Tello, J.F., M. Coltelli, M. Marsella, A. Celauro and J. A. Palenzuela Baena (2022): Convolutional neural network algorithms for semantic segmentation of volcanic ash plumes using visible camera imagery. *Remote Sens.*, **14**, 4477.

気象庁 (2025): “トピックスVI-2 先端AIと協調した気象業務の強化”. 気象業務はいま2025. <https://www.jma.go.jp/jma/kishou/books/hakusho/2025/index7.html#toc-111>, (参照 2025-06-18)

松岡大祐, 杉山大祐, 2018: 畳み込みニューラルネットワークの気象データ解析への応用—熱帯低気圧の検出から雲量推定まで—. 可視化情報, **38**(151), 14-18.

松森敏幸, (2013): 新しくなった火山監視・情報センターシステム (VOIS) の紹介. 験震時報, **76**, 83-131.

Simoyan, K. and A. Zisserman (2014): Very deep convolutional networks for large-scale image recognition.

Torrisi, F., C. Corradino, S. Cariello and C. Del Negro (2024): Enhancing detection of volcanic ash clouds from space with convolutional neural networks. *Journal of Volcanology and Geothermal Research*, **448**, 108046.

碓井勇二, (2004): 火山監視・情報センターシステム (VOIS) の紹介. 験震時報, **68**, 47-55.

山脇正嗣, 上山晃, 中村直人, 木川堅司, 石田孝司, 谷保和則, 吉崎皇淑, (2019): 深層学習による活火山監視効率化に関する研究. 土木学会論文集 F3 (土木情報学), **75** (2), I_22-I_29.

(編集担当 山里平・中村政道)