

Stacked Recurrent Neural Networkによる桜島噴火予測

Predicting Eruptions of Sakurajima by Stacked Recurrent Neural Network

村田 剛志*¹ ヒープ レ*¹ 井口 正人*²
 Tsuyoshi Murata Hiep V. Le Masato Iguchi

*¹東京工業大学情報理工学院情報工学系

Department of Computer Science, School of Computing, Tokyo Institute of Technology

*²京都大学防災研究所火山活動研究センター

Sakurajima Volcano Research Center, Disaster Prevention Research Institute, Kyoto University

Volcanic eruptions sometimes cause severe damage to many people. This paper explains our attempts for predicting volcanic eruptions from time series sensor data obtained from volcanic monitoring systems (strainmeters) located in Sakurajima. Given the time series data of strainmeters for 100 minutes, our goal is to predict future status of the volcano which is either *explosive* or *not explosive* for the 60 minutes immediately after the 100 minutes. We use stacked recurrent neural network for this task, and our method achieves 66.1% F-score on average. We also propose a four-stage warning system that classifies time series sensor data into the following categories: “Non-eruption”, “May-eruption”, “Warning” and “Critical”. The percentage of *explosive* cases in “Critical” category is 51.9%.

1. はじめに

日本は世界有数の火山国であり、世界の活火山の約7%が存在する。火山の噴火は時として甚大な人的・物的被害を及ぼすものであり、2014年の御嶽山や2018年の草津白根山での火山災害は記憶に新しい。火山活動を正確に把握して必要な対応を取ることは、専門家のみならず周辺地域の多くの人々にとっての重大な関心事である。

火山から観測される時系列データは、火山活動の分析において非常に重要である [Sparks 03]。火山から観測される時系列データとしては、地形の歪みや、地震の振動の大きさやエネルギーなどが挙げられる。機械学習を用いた火山活動の分析の例として、Malfante らの研究がある [Malfante 18]。これはペルーのウピナス火山の6年分のデータを対象とし、バリエーションの大きい火山性地震をSVMを用いてタイプ毎に分類するものである。著者らは、日本における有数の活火山である鹿児島県の桜島に設置された装置から観測される時系列データに対して、畳み込みニューラルネットワーク(CNN)を用いて分析した結果について報告した [村田 17][日経 18]。これも観測した100分間で爆発的噴火が起こるか否かを「分類」するタスクについてであった。

本稿では、与えられた100分間の時系列データから、その直後の60分間に爆発的噴火が起こるか否かを「予測」するタスクについて述べる。本稿における火山噴火予測の概要を図1に示す。時系列データにおける時間変化を検出するためにStacked 2-Layer LSTMを用いて実験を行った結果、噴火・非噴火の2クラス平均のF値による精度で66.1%であった。また、与えられた時系列データを“Non-eruption”, “May-eruption”, “Warning”, “Critical”の4つに分類する警告システムを構築したところ、“Critical”に分類された時系列データで爆発的噴火が起こったものの割合は51.9%であった。

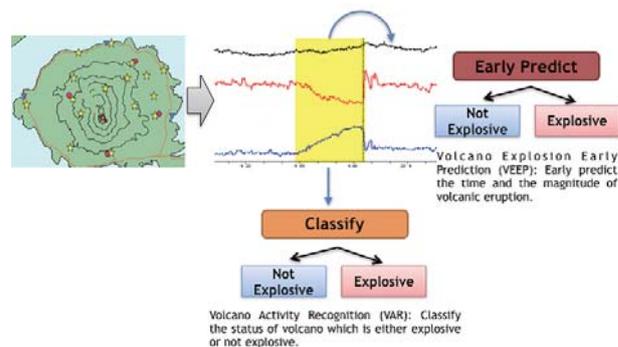


図1: 火山活動分類(下)と火山噴火予測(右)

2. データセット

本稿では、時系列データとして、国土交通省の九州地方整備局の火山活動データを用いる。これは日本で最も活発な火山の一つである桜島の噴火に関するデータである。桜島は時期によっては毎週のように噴火しており、対象データとして適している。

火山から観測されるデータとしては、地震計による最大振幅や振幅二乗和(エネルギー)、傾斜計による火口の上昇や降下、火山ガスの量や成分などもあるが、本稿では伸縮計によって観測される時系列データに注目する。伸縮計は火口方向・直交方向の地面の伸び縮みを観測するものである(図2)。

観測データは数値として毎分記録される。データは全体で2009年から2016年までの8年分あり、日本の火山の時系列データとしては最大級である。ただし、大規模な台風の接近や他地域での地震発生などによるノイズや、観測装置の点検期間中におけるデータ欠損などが起こり得る。

連絡先: 東京工業大学情報理工学院情報工学系 村田剛志

〒152-8552 東京都目黒区大岡山 2-12-1 W8-59

E-mail: murata@c.titech.ac.jp

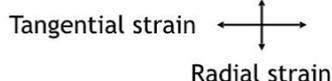
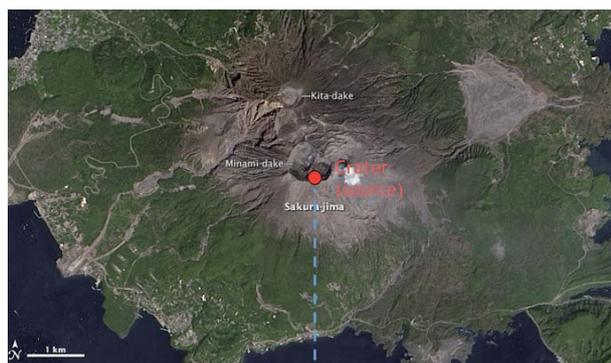


図 2: 伸縮計の火口方向・直交方向

3. モデルアーキテクチャ

本稿においては、火山噴火予測問題を時系列データのパターン認識問題としてとらえる。100 分間の時系列データを入力とし、その直後の 60 分間において爆発的噴火が起こるか否かを予測する。空振による音が 10 パスカル以上のものを爆発的噴火と定義する。

3.1 Recurrent Neural Network

Recurrent Neural Network (RNN) はデータ内の時間的な依存関係を、層内ユニット間の有向の結合によって学習するニューラルネットワークである。時刻 t の隠れ状態 h は以下のように計算される。

$$h_t = \tanh(Wx_t + Uh_{t-1})$$

ここで \tanh は双曲線正接関数、 W と U はそれぞれ入力に対する重み行列と recurrent weight matrix である。予測は最終隠れ状態 h_t を用いて行う。

$$y_t = \sigma(W_p h_t)$$

3.2 Long Short-Term Memory

一般に RNN では、誤差逆伝播法における誤差信号が隠れ層を経るごとに小さくなってしまいう配消失問題があることが指摘されている。Long short-term memory (LSTM) [Hochreiter 97] はこの問題を解決するための改良法の一つである。LSTM は状態変化においてゲートを導入することによってう配消失問題に対処している。各時刻において、LSTM は隠れ状態 h とメモリーセル状態 c を保持して、状態更新と出力を以下のようにコントロールする。

$$f_t = \sigma(W_f x_t + U_f h_{t-1})$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1})$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1})$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1})$$

$$h_t = o_t \odot \tanh(c_t)$$

ここで f_t 、 i_t 、 o_t はそれぞれ忘却ゲート、入力ゲート、出力ゲートである。 σ はシグモイド関数、 \odot は要素毎の積を表している。 W_f, W_i, W_o, W_c と U_f, U_i, U_o, U_c は、各ゲートに付随

した入力重み行列と recurrent weight matrix であり、学習によってパラメータ値を得る。メモリーセル状態 c は、忘却ゲート f_t 、入力ゲート i_t および 1 ステップ前のセル状態によってコントロールされる。このセル状態は全ての時刻の状態を集めることができ、それによって時系列データの長期的な依存関係を把握することができる。LSTM の出力はメモリーセル状態 c と出力ゲート o_t から計算される。

LSTM の隠れ状態 h を別の LSTM への入力とすることによって、より深い構造である Stacked LSTM を作ることができる。1 つ前の層 $l-1$ から作られる層 l の隠れ状態 h は以下で表される。

$$h_t^l = lstm(h_t^{l-1}, h_{t-1}^l)$$

ここで $lstm$ は LSTM のゲートの計算、 h_t^{l-1} は層 $l-1$ の隠れ状態で次の LSTM への入力となるもの、 h_{t-1}^l は時刻 $t-1$ における層 l の隠れ状態である。

3.3 提案モデル

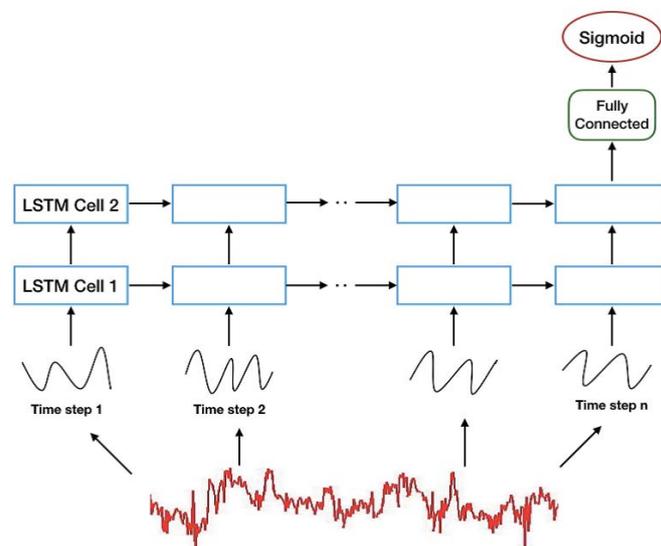


図 3: Stacked 2-Layer LSTM

火山噴火予測のための Stacked 2-Layer LSTM を提案する。提案モデルの全体像を図 3 に示す。まず、入力の時系列データを複数の時間ステップに分割する。各時間ステップは、短時間での動きを把握するためのもので、例えば入力が 100 分の時系列データとしたとき、それを 5 分の時間ステップ 20 個に分割する。この時間ステップの数はハイパーパラメータである。次に、各時間ステップを LSTM セルの入力として与え、動的な振舞いを学習する。LSTM セルは (横方向に) 結合しており、入力時系列データの開始から終了までの時間依存の特徴量を学習する。これを 2 段にした Stacked LSTM にすることで、より複雑な特徴を学習することが可能になる。2 段目の LSTM の最終隠れ状態から全結合層とシグモイド関数を経て最終的な出力が得られ、その値をもとに予測を行う。

3.4 モデルの訓練

モデルの訓練においては、重みつき二値交差エントロピー損失関数を最小化している。正の重みを増やすことによって、火山噴火予測において避けるべき False Negative(見逃し)に

対処している。

$$L = \sum_{i=1}^{batch_size} y_i \log(y_i') \times weight + (1 - y_i) \log(1 - y_i')$$

ここで y は目標値、 y' は予測値である。1 以上の値のパラメータ $weight$ を損失関数に導入し、目標値が 1 であるのに予測値が 0 に近い値である場合により多くの罰則を与えるようにした。このような損失関数を最適化することによって、False Negative の事例数を減らすことができると考えられる。本稿の実験では $weight$ の値は 4 とした。

LSTM セルのサイズは 128 に固定して実験を行っている。モデルの訓練は Adam [Kingma 14] を用いて行い、初期学習率は $1e-3$ とした。ハイパーパラメータのチューニングにはランダムサーチを用いた [Bergstra 12]。

4. 実験結果

本稿の実験では伸縮計の直交方向の時系列データを用いた。もちろん、他の時系列データを用いてさらに精度を向上させることも可能であると考えられる。以下で述べる実験結果は、全て 2015 年のデータを用いたものである。

4.1 火山噴火予測

上述の Stacked 2-Layer LSTM を用い、入力として与えた 100 分間の時系列データに対する出力が閾値以上であるものを噴火、そうでないものを非噴火と予測する。閾値を 0.5 として実験した結果の混同行列を表 1 に示す。また噴火・非噴火のそれぞれの場合の F 値は以下の通りである。

表 1: Stacked 2-Layer LSTM での火山噴火予測の混同行列 (閾値 0.5)

	非噴火 (予測)	噴火 (予測)
非噴火 (正解)	42,708	5,033
噴火 (正解)	1,667	2,184

- 非噴火の場合の F 値 $F_{not_explosive} = 92.7\%$
- 噴火の場合の F 値 $F_{explosive} = 39.5\%$
- 両者の平均の F 値 $F_{avg} = 66.1\%$

対象とする時系列データにおいては、噴火の事例数に比べて、非噴火の事例数が圧倒的に多い。単純に精度を求めると、全ての入力に対して無条件に非噴火と出力したとしても 90% 以上の高精度となってしまうことから、上記のように噴火・非噴火の両方の場合の F 値を求めることで評価を行っている。火山噴火予測においては噴火の場合の F 値が重要である。本稿で述べた Stacked 2-Layer LSTM は、噴火の場合の F 値 ($F_{explosive}$) が 40% 近くに達している。

著者らは、多層 CNN (畳み込みニューラルネットワーク) を用いて同様の火山噴火予測の実験を行っている (図 4) [村田 18]。その実験結果を表 2 に示す。また噴火・非噴火のそれぞれの場合の F 値は以下の通りである。

- 非噴火の場合の F 値 $F_{not_explosive} = 93.4\%$
- 噴火の場合の F 値 $F_{explosive} = 37.6\%$

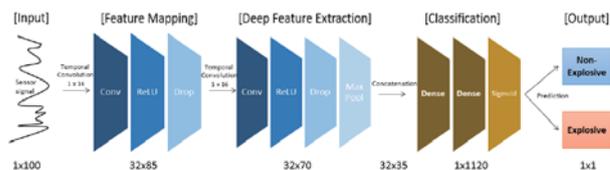


図 4: 多層 CNN (畳み込みニューラルネットワーク) での火山噴火予測

表 2: 多層 CNN での火山噴火予測の混同行列 (閾値 0.5)

	非噴火 (予測)	噴火 (予測)
非噴火 (正解)	43,598	4,143
噴火 (正解)	2,000	1,851

- 両者の平均の F 値 $F_{avg} = 65.5\%$

表 1 と表 2 を比較すると、多層 CNN での火山噴火予測と比べて、Stacked 2-Layer LSTM での火山噴火予測の F_{avg} の方が高精度であり、また False Negative の事例数も少ないことがわかる。

また火山噴火予測において、60 分間のどのタイミングでの火山噴火予測が容易か (困難か) を調べた。60 分間の時系列データを 10 分ずつ 6 つの間隔に分けて、6 つの間隔のどこで噴火が起こったかを、予測に成功した例と失敗した例のそれぞれについて調べた。

- 予測成功: [521, 458, 383, 329, 267, 226]
- 予測失敗: [202, 238, 277, 301, 321, 328]

上記の数字は、10 分ずつ 6 つの間隔のそれぞれでの予測成功と予測失敗の事例数を表している。この結果から、観測した 100 分の直後の 10 分間の火山噴火予測は比較的高精度であるのに対し、観測した 100 分から時間が経つに従って精度が低下していることがわかる。

また、本稿での火山噴火予測に成功した例と失敗した例それぞれの噴火の強度についても調べた。ここでは伸縮計での収縮量を噴火の強度とみなしている。

- 予測成功: 中央値:18.2, 平均値 20.0, 標準偏差 11.4
- 予測失敗: 中央値:9.9, 平均値 11.8, 標準偏差 7.7

上記の数字は、予測で成功した例と失敗した例それぞれの噴火の強度の中央値、平均値、標準偏差を表している。この結果から、本稿の手法は、比較的強度の大きい噴火の予測に成功しており、予測に失敗した噴火の強度は比較的小さいことがわかる。

4.2 4 段階警告システム

前節では噴火か非噴火かの 2 クラス分類を行ったが、Stacked 2-Layer LSTM の出力値の大きさと、爆発的噴火の可能性との間には相関があると考えられる。本節では 3 つの閾値によって時系列データを 4 つのカテゴリに分類し、それぞれのカテゴリにおける爆発的噴火の割合を調べた。閾値としては便宜的に 0.2、0.5、0.8 とした。

- Non-eruption: Stacked 2-Layer LSTM の出力値が 0 以上 0.2 未満

- May-eruption: Stacked 2-Layer LSTM の出力値が 0.2 以上 0.5 未満
- Warning: Stacked 2-Layer LSTM の出力値が 0.5 以上 0.8 未満
- Critical: Stacked 2-Layer LSTM の出力値が 0.8 以上

表 3: 4 段階警告システムの実験結果 (2015 年データ)

	Non-eruption	May-eruption	Warning	Critical
合計	27,967	16,408	6,623	594
非噴火	27,509	15,199	4,747	286
噴火	458	1,209	1,876	308
精度	98.4%	92.6%	28.3%	51.9%

実験結果を表 3 に示す。表 3 における精度は、Non-eruption と May-eruption のカテゴリにおいては非噴火の割合、Warning と Critical のカテゴリにおいては噴火の割合を表している。当然ながらこれらの値は先の 3 つの閾値によって変わってくる。注目すべきなのは、Critical のカテゴリに分類された時系列データにおいては噴火するものの割合が 51.9% になっていることである。このカテゴリに分類される時系列データの事例数はやや少ないが、これらについては爆発的噴火の可能性が十分高く、このような 4 段階警告システムによる火山噴火予測は検討に値すると考えられる。

Kamo ら [Kamo 89] は、桜島の火口の上昇・降下を計測する傾斜計の 5 分間のデータをもとに、あらかじめ定めたルールに基づいて 5 段階に自動分類する手法を提案し実験を行っている。この手法において、最も危険度が高いカテゴリにおける予測精度は 45.76% であった。30 年近く前の研究であり、また用いている時系列データの観測装置も伸縮計と傾斜計とで異なっているが、本稿での 4 段階警告システムによる火山噴火予測はこれよりも高精度である。

5. おわりに

本稿では、桜島周辺で観測される時系列データをもとに、Stacked 2-Layer LSTM を用いて爆発的噴火を予測する手法および実験結果について述べた。実験の結果、多層 CNN を用いたものや関連研究 [Kamo 89] よりも高精度であることが示された。

本稿での火山噴火予測の具体的な応用例としては、以下のものが考えられる。

工事従事者の安全確保 [Kamo 89] をベースにした噴火予測手法は、現在でも桜島で使われている。桜島では火口から 2km までが 1955 年から立ち入り規制されているが、2km 付近での砂防工事があり、その工事従事者の携帯電話に火山噴火予測のメールが届くようになっている。[Kamo 89] では傾斜計のデータだけを使っているが、現在実装されているものは傾斜計と伸縮計の 2 成分 (火口方向・直交方向) から圧力源の体積変化を見積もり、体積変化を指標としている。工事従事者の安全確保のためには、高精度の火山噴火予測が必要である。

降灰予報 気象庁は、蔵王山、草津白根山、桜島、口永良部島、諏訪之瀬島、霧島山 (御鉢)、霧島山 (新燃岳)、霧島山 (えびの高原 (硫黄山) 周辺) の降灰予報 (定時) を行っている

(<http://www.data.jma.go.jp/svd/vois/data/kouhai/jishin/ashfall.html>)。これは火山周辺の風向をもとに、噴火が発生したらという条件つきでの降灰予報になっているが、精度の高い火山噴火予測と組み合わせることによって、周辺住民に対してさらに有益な予報にすることが期待できる。

謝辞

火山データをご提供いただいた国土交通省九州地方整備局大隅河川国道事務所に感謝致します。

参考文献

- [Bergstra 12] James B., Bengio Y. “Random Search for Hyper-Parameter optimization.” *Journal of Machine Learning Research*, Vol.13, pp.281-305 (2012).
- [Hochreiter 97] Hochreiter, S., Schmidhuber, J., “Long Short-Term Memory”, *Neural Computation*, Vol.9, No.8, pp.1735-1780 (1997).
- [Kamo 89] Kamo K., Ishihara K. “A Preliminary Experiment on Automated Judgement of the Stages of Eruptive Activity Using Tiltmeter Records at Sakurajima, Japan”, in Latter J. H. (eds.) *Volcanic Hazards. IAV-CEI Proceedings in Volcanology*, Vol.1, pp.585-598, Springer (1989).
- [Kingma 14] Kingma, D. P., Jimmy B. “Adam: A Method for Stochastic Optimization.”, *The Third International Conference for Learning Representations (ICLR 2015)*, arXiv:1412.6980 (2014).
- [Malfante 18] Malfante M., Mura M. D., Metaxian J. -P., Mars J. I., Macedo O., Inza A., “Machine Learning for Volcano-Seismic Signals: Challenges and Perspectives”, *IEEE Signal Processing Magazine*, Vol.35, Issue.2, pp.20-30 (2018).
- [Sparks 03] Sparks, R. S. J., “Forecasting Volcanic Eruptions”, *Earth and Planetary Science Letters*, Vol.210, No.1-2, pp.1-15 (2003).
- [日経 18] 日本経済新聞, “東工大・京大、AI で火山活動分析 噴火予測めざす”, 2018 年 1 月 15 日 第 9 面 (2018).
- [村田 17] 村田 剛志, ヒープレ, 井口 正人, “深層学習による火山活動認識”, 第 112 回人工知能学会知識ベースシステム研究会, SIG-KBS-B508, pp.38-45 (2017).
- [村田 18] 村田 剛志, “深層学習による桜島噴火予測”, 桜島研究課題研究集会, 2018 年 1 月 6 日 (2018). <http://www.svo.dpri.kyoto-u.ac.jp/svo/topic-news/meeting20180105/>