

半教師あり学習を用いた深発月震の震源ラベルの再付与の検討

中島 康平^{*1}, 山本 幸生^{*2}, 山田 竜平^{*3}, 廣田 雅春^{*4}, 荒木 徹也^{*5}, 石川 博^{*1}

Examination of Relabeling of Nest Label for Deep Moonquakes by Semi-supervised Learning

NAKAJIMA Kouhei^{*1}, YAMAMOTO Yukio^{*2}, YAMADA Ryuhei^{*3}, HIROTA Masaharu^{*4},
ARAKI Tetsuya^{*5}, ISHIKAWA Hiroshi^{*1}

Abstract

Between 1969 and 1977, about 13,000 moonquakes were observed by NASA's Apollo missions. In particular, kinds of “deep moonquakes” are the ones most frequently observed. Waveforms of the deep moonquakes from the same nest are similar to each other. Based on this characteristic, there have been studies to estimate the deep moonquake nests from the waveform analysis. At present, the nest-label is assigned to each deep moonquake based on the classification criteria using cross-correlation coefficients. However, more recent studies using machine learning suggest that the current method's results may contain errors. Therefore, in this paper, we extracted deep moonquakes using machine learning, which may have been given the wrong nest-labels. Furthermore, we reassign the nest-labels by semi-supervised learning. As a result, 194 out of the 994 deep moonquakes in the dataset were re-labeled. Results of the re-classification of the deep moonquakes presented in this paper may lead to a review of the current classification results by lunar experts.

Keywords: Self-training, Logistic Regression

概要

1969年から1977年にかけて行われたNASAのアポロミッションにより、約13,000件の月震が観測された。特に、深発月震は観測された件数が最も多い種類の月震であり、同一の震源から発生した深発月震は、波形が類似していることも明らかになっている。この特性から、深発月震の波形から月震の震源を推定する研究が行われてきた。現在は、相互相関係数を用いた分類基準に基づき、それぞれの深発月震に震源ラベルが付与されている。しかし、近年の機械学習を用いた研究により、既存の分類基準に基づいた分類結果に誤りが含まれている可能性が示唆されている。そこで本研究では、機械学習を用いた手法により、誤った震源ラベルが付与されている可能性がある深発月震の抽出を行った。その後、半教師あり学習を用いて、震源ラベルの再付与を行った。実験の結果、利用したデータセット内の994件の深発月震のうち、194件の深発月震の震源ラベルが再付与された。本研究で行った深発月震の再分類結果は、専門家による現在の分類結果の再検討につながることが期待される。

* 2020年12月4日受付 (Received December 4, 2020)

^{*1} 東京都立大学大学院 システムデザイン研究科 (Graduate School of Systems Design, Tokyo Metropolitan University)

^{*2} 宇宙航空研究開発機構 宇宙科学研究所 (Institute of Space and Astronautical Science, Japan Aerospace Exploration Agency)

^{*3} 会津大学 復興支援センター (The Univer Of Aizu, Revitalization Center)

^{*4} 岡山理科大学 総合情報学部 (Faculty of Informatics, Okayama University of Science)

^{*5} 群馬大学 工学部 (School of Science and Technology, Gunma University)

1 はじめに

1969 年から 1977 年にかけて行われた NASA のアポロミッションにより、月の観測装置である Apollo Lunar Surface Experiments Package (ALSEP) が月面に設置された。ALSEP による実験の一つとして、Passive Seismic Experiment (PSE) と呼ばれる月震の観測が行われた。PSE によって観測された月震データは、長周期地震計の 3 軸成分と短周期地震計の上下動成分で構成されており、全て Web 上で公開されている [15]。また、現在でもその月震データの解析は続けられており、月震発生の要因の解明、月震の活動度、月の内部構造の推定について多くの知見が得られている [9], [6]。

Web 上で公開されている月震データは、約 13,000 件であり、それらのイベントは月震の発生深度や、発生要因に基づいて、熱月震、人工衝突の信号、隕石衝突、浅発月震、深発月震の 5 種類に分類されている。この中で、深発月震は、観測された数が約 7,300 件と最も多く、同一の震源から周期的に揺れが発生することが分かっている [2]。また、同一の震源から発生した深発月震は、波形が類似していることも明らかになっている [5]。これらの特徴から深発月震は、地球や太陽からの潮汐が関連して発生していると考えられており、現在も解析が行われている [13]。

深発月震を用いて月の内部構造などの解析を行うためには、それぞれの深発月震に、その深発月震が発生した震源を表す震源情報が付与されていることが望ましい。月震の震源は、3 点以上の観測点で振動が観測された際の、観測点ごとの観測時刻の差から推定することができる。しかし、ノイズや揺れの微弱さなどの影響により、多くの深発月震イベントは観測点の数が不足している。そのため、これまでの研究では、深発月震の波形の類似性を利用した震源の推定が行われている。ALSEP により月震データが取得された 1970 代には、同一の震源の深発月震は波形が類似しているという特徴に基づいて、目視による深発月震の分類が行われた [10]。その後、2003 年に Nakamura らによる波形の相互相関係数を用いた深発月震の分類基準が作成された [8]。ALSEP に含まれる深発月震イベントの一部には、A1, A6 のように Axx と分類基準に基づいた震源ラベルが付与されており、109 のクラスに分類されている。本論文では、このデータセットを用い、以下では月震データセットと呼ぶ。

ここで、深発月震にはノイズが多く含まれるため、従来の分類基準による分類では、誤った震源ラベルが付与されている可能性がある。近年の機械学習を用いた研究では、従来の分類基準の妥当性には、疑問が残るところがある。後藤らは、Self-Organizing Map (SOM) を用いた深発月震の震源の可視化を行った [16]。加藤らは、既存の分類結果を機械学習で再現可能かを検証した [14]。これらの研究では、既存の震源ラベルには一定の妥当性はあるが、一部の震源ラベルについて誤りが含まれている可能性を指摘した。

そこで、本研究では、機械学習を用いて震源ラベルが誤っている可能性がある深発月震イベントを抽出する手法を提案する。また、震源ラベルが誤っている可能性があると評価された深発月震イベントに対して、震源ラベルの再付与を行う。深発月震イベントの震源ラベルの妥当性の評価に、半教師あり学習の一つである Self-training [7] を元とした手法を用いる。本研究で提案する手法による深発月震の再分類結果は、今後、専門家による現在の分類結果の見直しの検討につながることが期待できる。

本論文の構成は次の通りである。2 章では、機械学習により従来の基準に類似した月震分類を再現可能な特徴量と分類器の検討を行う。3 章では、震源ラベルが誤っている可能性のある深発月震イベントの抽出、震源ラベルの再付与及び、再分類結果の妥当性の検証を行う。4 章では、本研究のまとめと今後の課題を述べる。

表 1 月震データセット

震源名	A1	A6	A8	A9	A10	A14	A18	A20	A23	合計
イベント件数	261	85	93	94	108	87	106	106	54	994

2 既存の分類結果に類似する分類結果を得るための特徴量と分類器の検討

2.1 検討する特徴量と分類器

誤った震源ラベルが付与されている可能性がある月震イベント^{*1}の抽出、震源ラベルの再付与を行うために、既存の分類結果に類似する分類結果を再現可能な特徴量と分類器を比較する。本研究では、従来の分類基準 [8] によって作成された月震データセットには一定の妥当性はあるが、一部誤った震源ラベルが付与された月震イベントが含まれていると考える。そこで、機械学習を用いて従来の分類基準に類似する分類結果を得ることを試みる。その結果、従来の分類基準による分類結果と、選定した特徴量と分類器による分類結果を比較する。従来の分類基準による分類、従来の分類基準に類似した分類結果を示す機械学習による分類、これら 2 つの手法による分類結果が一致する月震イベントは、付与されている震源ラベルが正しい可能性が高いと考えられる。一方で、分類結果が一致しない月震イベントは、付与されている震源ラベルを再検討する余地があると考える。

本研究では、機械学習によって従来の基準による分類結果に類似する分類結果を得るために、以下の 2 つの特徴量を比較する。

- 周波数スペクトル
- パワースペクトル密度

周波数スペクトルは、月震^{*2}の振幅を周波数成分毎に計算した値である。パワースペクトル密度は、単位周波数あたりの周波数スペクトルであり、これまでの機械学習を用いた月震分類の研究でも利用されている特徴量である [17]。

分類性能を比較する分類器は、サポートベクターマシン (SVM) [12]、ランダムフォレスト [1]、ロジスティック回帰 [3] とする。これらの手法では、分類器が予測結果を決定する際に、どの程度の確信を持って決定したのか求めることができる。後述する提案手法では、これらの特徴を持った分類器を利用する必要があるため、本研究では、これらの手法について比較する。

2.2 データセット

本研究では、観測期間が最も長く、イベント件数が多いアポロ 12 号のミッションで取得された月震イベントを利用する。その中でも、Peaked モードと Flat モードが存在しており、これらは周波数応答が異なる。本研究では、イベント件数の多い Peaked モードで観測された月震イベントのみを利用する。月震イベントは、X 軸、Y 軸、Z 軸の 3 方向の波形が観測されており、以下ではそれぞれを LPX、LPY、LPZ と表記する。本研究では、従来の分類基準により震源ラベルが付与された月震イベントが 50 件以上存在する 9 つの震源を対象として実験を行う。実験対象の震源と、震源ごとの月震イベントの件数を表 1 に示す。

^{*1} 一つの深発月震の月震波形データを月震イベントと記述する。

^{*2} 本章以降、深発月震を月震と記述する。

表 2 特徴量と分類器の組み合わせごとの平均 macro-F1 値

特徴量	分類器	平均 macro-F1 値
周波数スペクトル	SVM	0.70
周波数スペクトル	ランダムフォレスト	0.20
周波数スペクトル	ロジスティック回帰	0.72
パワースペクトル密度	SVM	0.45
パワースペクトル密度	ランダムフォレスト	0.36
パワースペクトル密度	ロジスティック回帰	0.57

2.3 実験設定

2.1 節で述べた特徴量と分類器を組み合わせて、月震の多クラス分類を行う。組み合わせごとに 5 交差検定を行うことで、macro-F1 値を算出する。macro-F1 値は、多クラス分類におけるクラスごとの F1 値の平均値である。macro-F1 値が高い特徴量と分類器の組み合わせほど、既存の分類結果に近い結果を再現可能な組み合わせであると考えられる。

実験で用いる月震には、ノイズ除去を目的とした前処理として、全ての月震イベントに対して、平均引き、トレンド引き、0.3~1.5Hz のバンドパスフィルタ処理、スパイク除去を行う。また、月震波形は、LPZ の P 派到達時刻から約 15 分間の波形を用いる。

次に、特徴量として比較する周波数スペクトル、パワースペクトル密度をそれぞれの月震イベントから計算する。ここで、周波数スペクトルの計算には、Python の数値計算ライブラリである Scipy [4] の numpy.fftreq を用いた。また、パワースペクトル密度の算出には、Scipy の psd を用いた。SVM の実装には Scikit-learn [11] の SVC、ランダムフォレストの実装には Scikit-learn の RandomForestClassifier、ロジスティック回帰の実装には Scikit-learn の LogisticRegression を用いた。また、これらの手法のハイパーパラメータは、グリッドサーチにより決定した。

2.4 月震分類に有効な特徴量と分類器の検討結果

それぞれの特徴量と分類器の組み合わせによる 5 交差検定の macro-F1 値を表 2 に示す。いずれの特徴量との組み合わせでも、ロジスティック回帰を分類器に用いた場合が最も macro-F1 値が高い結果となった。この原因是、月震が線形分離可能であり、非線形分離を行う SVM やランダムフォレストを分類器に用いた場合に、過学習を起こしたためと考えられる。macro-F1 値は、周波数スペクトルとロジスティック回帰の組み合わせが最も高い値となった。この結果から、周波数スペクトルとロジスティック回帰の組み合わせが、従来の手法による月震分類結果に近い分類を再現可能であると考えられる。よって以降、特徴量には周波数スペクトル、分類器にはロジスティック回帰を用いた手法を用いる。

3 半教師あり学習を用いた震源ラベルの再付与

3.1 誤った震源ラベルが付与されている可能性がある月震イベントの抽出手法

月震データセットの中で誤った震源ラベルが付与されている可能性がある月震イベントの抽出手法について述べる。抽出手法の流れを図 1 に示す。はじめに、月震データセットに対して、周波数スペクトルを特徴量に

用いたロジスティック回帰による教師あり学習を行う。教師あり学習の流れは、図1の①～③である。はじめに、月震データセットを学習データとテストデータに分割する。その後、学習データを用いて、分類器が震源ごとの月震の特徴を学習する。学習を終えた分類器にテストデータを入力して、震源ラベルの予測を行う。本研究では、教師あり学習によりロジスティック回帰が予測した震源と、従来の分類基準により付与された震源ラベルが異なる月震イベントは、誤った震源ラベルが付与されている可能性があると考える。

しかし、この方法では、同一の月震イベントに対する予測でも、学習データに含まれるデータによって異なる結果を示すことがある。また、図1の①～③に示すように、ロジスティック回帰を用いて震源を予測可能な月震イベントはテストデータのみであり、学習データに含まれる月震イベントの震源を予測することはできない。そこで本研究では、次の処理を繰り返すことで、データセットに含まれる全ての月震イベントに対して、ロジスティック回帰の予測と月震イベントに付与された震源ラベルが一致した確率を計算する。

1. 月震データセットをランダムに学習データとテストデータに分割する。
2. 学習データを用いて学習したロジスティック回帰でテストデータの震源を予測する。
3. ロジスティック回帰の予測と月震イベントに付与された震源ラベルが一致する月震イベントを数える。
4. 1に戻る

この処理を N 回行う。特徴量が月震分類に有効であり、月震イベントに付与された震源ラベルが正しければ、ロジスティック回帰の予測は震源ラベルと高確率で一致すると考えられる。よって、ロジスティック回帰の予測と既存の震源ラベルが一致する確率が閾値 p を下回る月震イベントを抽出する。こうして抽出された月震イベントを誤った震源ラベルが付与された月震イベントとする。また、分類モデルの予測と既存の震源ラベルが一致しない確率が閾値 p 以上の月震イベントは、正しい震源ラベルが付与された月震イベントとする。

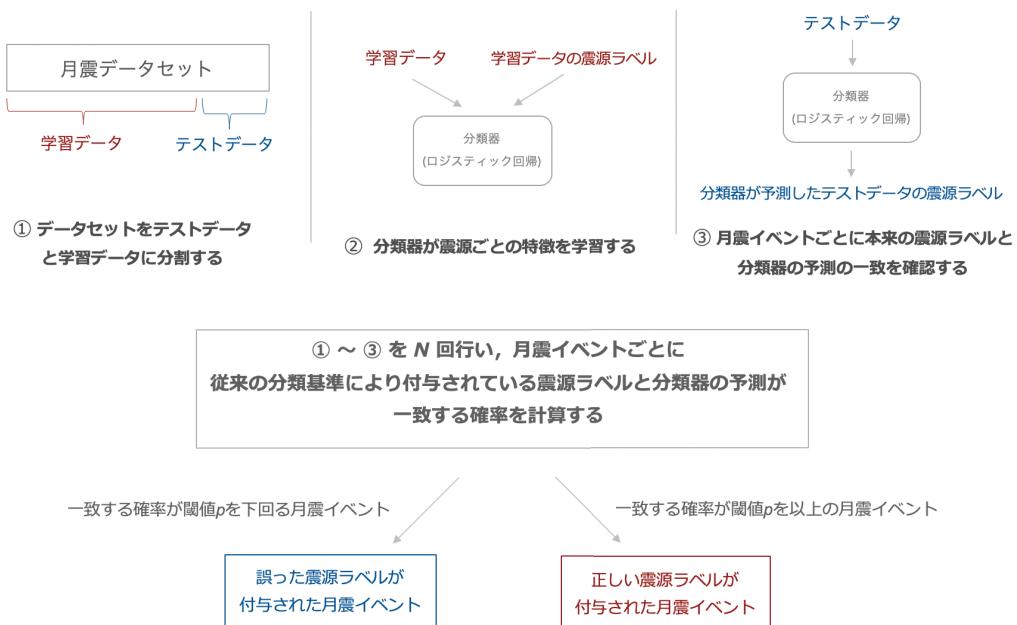


図1 誤った震源ラベルが付与されている可能性がある月震イベントの抽出の流れ

表 3 震源ごとの誤った震源ラベルが付与されている可能性がある月震イベント件数

震源名	A1	A6	A8	A9	A10	A14	A18	A20	A23
抽出されたイベント件数	27	35	23	11	22	13	23	31	8
表 1 でのイベント件数	261	85	93	94	108	87	106	106	54
表 1 から抽出された割合	10.3%	41.2%	24.7%	11.7%	20.3%	15.0%	21.7%	29.2%	14.8%

3.2 震源ラベルの再付与手法

本研究では、半教師あり学習手法の一つである Self-training を用いて、震源ラベルの再付与を行う。Self-training の流れは次の通りである。

1. ラベル付きデータを学習データ、ラベル無しデータをテストデータとして、教師あり学習を行う。
2. 閾値を th として、ロジスティック回帰による予測が特定のクラスに分類される確率が th 以上のデータにラベルを付与してラベル付きデータとする。
3. 特定のクラスに分類される確率が th 以上のデータが存在しない場合は、いずれかのラベル無しデータにラベルが付与されるまで閾値を下げる。
4. ラベル無しデータが 0 件なら処理を終了する。そうでなければ、1 に戻る。

3.1 節で定義した、正しい震源ラベルが付与された月震イベントをラベル付きデータとして、誤った震源ラベルが付与された月震イベントをラベル無しデータとして、上記の処理を行う。この処理は、誤った震源ラベルが付与された月震イベントの中でも、いずれかの震源に分類される確率が高い月震イベントからラベルが付与される。処理が進むごとに、ラベル付きデータが増加して、より多くの学習データで残りのラベル無しデータの震源推定を行うことになる。この処理が終了した時は、全ての月震イベントがラベル付きデータとなる。

3.3 誤った震源ラベルが付与されている可能性がある月震イベントの抽出結果

本節では、表 1 の月震データセットに対して、3.1 節で提案した手法を用いた実験結果について述べる。3.1 節で提案した手法の処理 1 の月震データセットの分割は、震源ごとに学習データが 80%，テストデータが 20% となるように分割した。分類手法には、ロジスティック回帰を用いており、実装方法、パラメータは 2.3 節と同様である。処理の実装時間を考慮して処理の回数 N は、1,000 回とした。

この設定で、月震イベントごとにロジスティック回帰による予測と既存の震源ラベルが一致する確率を計算した。この確率が、10% を下回る月震イベントを誤った震源ラベルが付与されている可能性がある月震イベントとして抽出した。抽出されたイベント件数、震源ごとの表 1 の月震データセットから抽出された月震イベントの割合を表 3 に示す。表 3 より、合計で 193 件の月震イベントが、誤った震源ラベルが付与されている可能性がある月震イベントとして抽出された。特に、A6 の震源ラベルが付与されていた月震イベントが最も高い割合で抽出されており、85 件のうち 35 件と 41.2% の月震イベントが抽出された。

3.4 震源ラベル再付与の結果

本節では、3.2 節で提案した手法を用いた実験結果について述べる。3.2 節で提案した手法の処理 2 における、震源ラベルを付与する確率の閾値 th は 99% とした。特定の震源に分類される確率が閾値以上のラベル無しデータが存在しない場合、いずれかのラベル無しデータに震源ラベルが付与されるまで、閾値 th を 1% ずつ下げた。こうして、全ての月震イベントに震源ラベルが付与された時に処理を終了した。

震源ラベルの再付与が終了した後の月震データセットの月震イベント件数、表 1 の月震データセットと比較

表 4 震源ラベル再付与後の月震データセット

震源名	A1	A6	A8	A9	A10	A14	A18	A20	A23
再付与後のイベント件数	283	52	97	84	158	74	124	75	47
表 1 でのイベント件数	261	85	93	94	108	87	106	106	54
イベント件数の増減数	22	-33	4	-10	50	-13	18	-31	-7
イベント件数の増減率	8.4%	-38.8%	4.3%	-10.6%	46.3%	-15.0%	17.0%	-29.2%	-13.0%

した震源ごとの月震イベントの増減数、増減率を表 4 に示す。表 4 より、A10 の震源ラベルが付与された月震イベントが最も増加しており、増加率も最も高い結果となった。対して、A6 の震源ラベルが付与された月震イベントは最も減少しており、減少率も最も高い結果となった。また、A8 の震源ラベルが付与された月震イベントは、イベント件数の変化が最も小さく増減率も 4.3% にとどまった。

3.5 再分類結果の妥当性の検証

本節では、本研究で提案した手法による月震データセットの再分類結果の妥当性の検証を行う。妥当性の検証のため、表 1 に示した従来の分類基準のよって分類された、震源ラベル再付与前の月震データセットと、表 4 に示した震源ラベル再付与後の月震データセットのクラスタリングを行う。それぞれの月震データセットのクラスタリング結果に対して、エントロピーと純度を計算する。エントロピー (*Entropy*) と純度 (*Purity*) は、ラベル付きデータセットのクラスタリング結果の評価に利用される指標であり、それぞれ以下のように計算される。

$$\text{Entropy} = \sum_{c=1}^p \frac{n_c}{n} \left(-\frac{1}{\log_2 q} \sum_{i=1}^q \frac{n_c^i}{n_c} \log_2 \frac{n_c^i}{n_c} \right) \quad (1)$$

$$\text{Purity} = \sum_{c=1}^p \frac{n_c}{n} \left(\frac{1}{n_c} \max_i (n_c^i) \right) \quad (2)$$

ここで、 n はデータセット内の月震イベントの総数、 n_c はクラスタ c 内に含まれる月震イベント数、 n_c^i はクラスタ c に含まれる月震イベントの中で、震源 i の震源ラベルが付与されている月震イベント数、 p はクラスタ数、 q は震源数である。

エントロピーは、1つのクラスタに属するデータのラベルの混ざり具合を示している。クラスタリング結果としては、1つのクラスタに属するラベルの種類は少ない方が望ましい。そのため、エントロピーが小さい値を示すほど良い結果であると考えられる。純度は、1つのクラスタ内で最も大きい割合を占めるラベルの割合を示している。クラスタリング結果としては、1つのクラスタには、1種類のラベルのデータが多く属していることが望ましい。そのため、純度が高い値を示すほど良い結果であると考えられる。本研究では、これらの評価指標が良い値を示す月震データセットほど、データセット内の月震イベントに付与されている震源ラベルの妥当性が高いと考える。

クラスタリング手法には、代表的な手法である Hierarchical Agglomerative Clustering (HAC) と k-means 法を用いる。それぞれの手法によるクラスタリング結果のエントロピーと純度をデータセットごとに計算して比較する。

HAC の実装には、Scipy の `cluster.hierarchy` を用いた。クラスタ間の類似度の計算はユークリッド距離を用いて、クラスタの併合は Ward 法で行った。クラスタ数は、本研究で利用している月震データセットの震源数と同様の 9 とした。k-means 法の実装には、Scikit-learn の `cluster.KMeans` を用いた。クラスタ数は、HAC と同様に 9 とした。

表 5 HAC によるクラスタリング結果のエントロピーと純度

月震データセット	エントロピー	純度
震源ラベル再付与前（表 1）	2.33	0.39
震源ラベル再付与後（表 4）	2.17	0.44

表 6 k-means 法によるクラスタリング結果のエントロピーと純度

月震データセット	エントロピー	純度
震源ラベル再付与前（表 1）	2.51	0.32
震源ラベル再付与後（表 4）	2.28	0.38

HAC による月震データセットごとのクラスタリング結果のエントロピーと純度を表 5 示す。表 5 から、HAC によるクラスタリング結果では、震源ラベル再付与後のデータセットの方がエントロピーが小さい値となり、純度が大きい値となっている。また、k-means 法による結果を表 6 に示す。表 6 より、k-means 法による結果でも、震源ラベル再付与後のデータセットの方がエントロピーが小さい値となり、純度が大きい値となっている。いずれの手法によるクラスタリング結果でも、エントロピー、純度ともに震源ラベル再付与後の月震データセットの方が良い値となっている。この結果から、従来の分類基準により分類された月震データセットよりも、震源ラベル再付与後の月震データセットの方が、月震イベントに付与されている震源ラベルの妥当性が高いと考えられる。

4 まとめ

本研究では、Self-training による月震の再分類手法を提案した。提案手法を用いて、月震データセットに含まれる月震イベントの震源ラベルの再付与を行った。最後に、HAC と k-means 法によるクラスタリング結果から、震源ラベル再付与後の月震データセットの妥当性を示した。今後の課題として、再分類手法の説明性の向上があげられる。本研究で提案した手法では、月震の周波数スペクトルを特徴量として、ロジスティック回帰によって月震の震源ラベルの再付与が行われている。そのため、今後は、周波数スペクトルを特徴量として、ロジスティック回帰により月震の分類を行う際に、分類基準となっている周波数帯の可視化を行う予定である。これにより、月震データセットの再分類結果がどのような分類基準によって分類されたのかを示すことができると考えられる。

謝辞

本研究は、東京都立大学傾斜的研究費（全学分）学長裁量枠国際研究環支援及び JSPS 科研費 20K12081 による。

参考文献

- [1] BREIMAN, L. Random forests. *Machine learning* 45, 1 (2001), 5–32.
- [2] BULOW, R., JOHNSON, C., BILLS, B., AND SHEARER, P. Temporal and spatial properties of some deep moonquake clusters. *Journal of Geophysical Research: Planets* 112, E9 (2007).

- [3] COX, D. R. The regression analysis of binary sequences. *Journal of the Royal Statistical Society: Series B (Methodological)* 20, 2 (1958), 215–232.
- [4] JONES, E., OLIPHANT, T., PETERSON, P., ET AL. Scipy: Open source scientific tools for python.
- [5] LAMMLEIN, D. R. Lunar seismicity and tectonics. *Physics of the Earth and Planetary Interiors* 14, 3 (1977), 224–273.
- [6] LOGNONNÉ, P., GAGNEPAIN-BEYNEIX, J., AND CHENET, H. A new seismic model of the moon: implications for structure, thermal evolution and formation of the moon. *Earth and Planetary Science Letters* 211, 1-2 (2003), 27–44.
- [7] MCCLOSKY, D., CHARNIAK, E., AND JOHNSON, M. Effective self-training for parsing. In *Proceedings of the Human Language Technology Conference of the NAACL, Main Conference* (2006), pp. 152–159.
- [8] NAKAMURA, Y. New identification of deep moonquakes in the apollo lunar seismic data. *Physics of the Earth and Planetary Interiors* 139, 3-4 (2003), 197–205.
- [9] NAKAMURA, Y., LATHAM, G. V., AND DORMAN, H. J. Apollo lunar seismic experiment—final summary. *Journal of Geophysical Research: Solid Earth* 87, S01 (1982), A117–A123.
- [10] NAKAMURA, Y., LATHAM, G. V., DORMAN, H. J., AND HARRIS, J. Passive seismic experiment, long period event catalog, final version (1969 day 202-1977 day 273, alsep stations 11, 12, 13, 14, 15, and 16). Tech. rep., Institute for Geophysics, 1981.
- [11] PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., ET AL. Scikit-learn: Machine learning in python. *the Journal of machine Learning research* 12 (2011), 2825–2830.
- [12] VAPNIK, V. N., AND VAPNIK, V. Statistical learning theory. vol. 1 wiley. *New York* (1998).
- [13] 加藤広大, 山田竜平, 山本幸生, 廣田雅春, 横山昌平, 石川博, ET AL. 惑星の位置関係に基づく深発月震分類のための特徴量の検討. 宇宙航空研究開発機構研究開発報告: 宇宙科学情報解析論文誌: 第 7 号 (2018), 43–52.
- [14] 加藤広大, 菊池栄, 山田竜平, 山本幸生, 廣田雅春, 横山昌平, 石川博, ET AL. SVM による深発月震分類のための有効な特徴量の分析. 宇宙航空研究開発機構研究開発報告: 宇宙科学情報解析論文誌: 第 6 号 (2017), 39–50.
- [15] 山田竜平, 山本幸生, 桑村潤, 中村吉雄, ET AL. アポロ月地震データ公開システムの開発. 宇宙航空研究開発機構研究開発報告: 宇宙科学情報解析論文誌: 第 1 号 (2012), 121–131.
- [16] 後藤康路, 山田竜平, 山本幸生, 横山昌平, 石川博, ET AL. 波形の類似性を考慮した大規模月地震データの SOM による可視化システム. 宇宙航空研究開発機構研究開発報告: 宇宙科学情報解析論文誌: 第 3 号 (2014), 137–146.
- [17] 菊池栄, 加藤広大, 山田竜平, 山本幸生, 廣田雅春, 横山昌平, 石川博, ET AL. 深発月震源分類に適した機械学習法の研究. 宇宙航空研究開発機構研究開発報告: 宇宙科学情報解析論文誌: 第 6 号 (2017), 51–62.