

# SVM による深発月震分類のための有効な特徴量の分析

加藤 広大<sup>\*1</sup> 菊池 栞<sup>\*1</sup> 山田 竜平<sup>\*2</sup> 山本 幸生<sup>\*3</sup> 廣田 雅春<sup>\*4</sup>  
横山 昌平<sup>\*5</sup> 石川 博<sup>\*1</sup>

## Analysis of the effective features to classify the deep moonquake sources using the SVM

Kodai Kato<sup>\*1</sup>, Shiori Kikuchi<sup>\*1</sup>, Ryuhei Yamada<sup>\*2</sup>, Yukio Yamamoto<sup>\*3</sup>, Masaharu Hirota<sup>\*4</sup>,  
Shohei Yokoyama<sup>\*5</sup>, Hiroshi Ishikawa<sup>\*1</sup>

### Abstract

NASA had obtained the moonquake data for about 7 years. The data is available to study the lunar internal structure and the focal mechanisms of moonquakes. Classification of sources of the deep moonquakes is one of important issues. The conventional method to classify deep moonquake sources is mutual comparison among waveforms. Recent machine learning approach enables us to improve the detection of moonquake, and classification of the sources. In this paper, we investigate the effective features to classify the moonquake sources. As a result, we showed that power spectral density of moonquake, and distance between the moon and the earth are effective features to classify the deep moonquake sources using the machine learning approach.

**Key Words:** Moonquake, Machine Learning, SVM

### 概 要

NASA が行ったアポロミッションによって、約7年半分に及ぶ月地震データが収集された。これらのデータは、月の内部構造の推定や、月震の発生メカニズムの解明において非常に重要であり、現在も解析が行なわれている。月震は、その発生要因から、深発月震、浅発月震、熱月震、隕石衝突などに分類されており、検出された月震の約半数は深発月震である。月震解析のひとつに、深発月震の震源分類がある。深発月震の震源分類は従来、波形の相互比較から分類が行われてきた。近年の研究によって、これまでの月震波形の検出手法や、震源分類の分類基準を、機械学習を用いて改良可能である事が示唆されている。震源の分類基準を改良するためには、それぞれの震源を分類するのに有効な特徴量を発見することが必要であるが、これらは従来、専門家の知見に基づくものであった。そこで、本研究では、機械学習を用いて、半自動的に震源を分類するのに有効な特徴量を発見する。結果として、月震のパワースペクトルや、月-地球間の距離が震源に適した特徴量であることを示し、深発月震の分類基準を再考するための特徴量発見に機械学習を用いることの有用性を示した。

doi: 10.20637/JAXA-RR-16-007/0004

\* 平成 28 年 11 月 24 日受付 (Received November 24, 2016)

<sup>\*1</sup> 首都大学東京大学院システムデザイン研究科 (Graduate School of System Design, Tokyo Metropolitan University)

<sup>\*2</sup> 国立天文台 RISE 月惑星探査検討室 (Research of Interior Structure and Evolution of solar system bodies, National Astronomical Observatory of Japan)

<sup>\*3</sup> 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)

<sup>\*4</sup> 大分工業高等専門学校情報工学科 (National Institute of Technology, Oita College)

<sup>\*5</sup> 静岡大学情報学部 (Faculty of Informatics, Shizuoka University)

## 1 はじめに

NASA が行った月への有人宇宙飛行計画であるアポロミッションによって、月の観測装置である、Apollo Lunar Surface Experiments Package (ALSEP) が月面に設置された。その ALSEP に含まれる地震計を用いて、Passive Seismic Experiment (PSE) と呼ばれる、月の地震（以後、本論文では月震と表記する）の観測が行われた。観測されたデータは、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いる。また、データは全て Web 上で公開され、データの閲覧、取得が可能となっている [11]\*1。

PSE によって取得されたデータは、月の研究において貴重なデータである。アポロミッションから約 40 年が経過した現在でも解析が行なわれており、月震の発生メカニズムの解明や、月の内部構造の推定に利用されている [5, 3]。

これまでの解析から、月震は、地球の地震と大きく異なる性質を持つ事がわかってきている。まず、地球での地震の発生要因となるプレート運動は月に存在しない。そして、月震は、発生要因から、深発月震、浅発月震、隕石衝突、熱月震などに分類されている。特に、発生頻度の高い深発月震は、同一の震源から繰り返し発生しており、Weber らは [9]、月-地球間に働く潮汐力と関連した発生原因の解明の研究も行っている。また、同一の震源から発生する月震波形が類似していることが知られている。一般に月震イベントの震源は、月震波が震源から観測点まで到達する時間である走時データから、その位置が決定され、月面に設置された複数の地震計の走時データの時間差を利用することで、深発月震の震源位置が推定された。しかし、振幅の小ささやノイズの影響で、走時データを利用した震源推定ができない月震は、月震波形の類似性から震源位置の違いが判別されている。ALSEP によってデータが取得された 1970 年代当初は、同一の震源から発生する月震波形が類似することに着目し、特に目視で分類を行っていた [6]。

その後、計算機の発達に伴い、Nakamura ら [4] による、月震波形の相互相関係数を用いた最短距離法に基づく階層的クラスタリングを用いた月震分類が行われた。これが、現在の震源分類基準となっている。そして、深発月震の震源には、震源ラベルが付与されている (A1, A6 のように Axx とラベリングされる)。しかし、月震データには、非常に多くのノイズが含まれており、ラベルを付与できないものが存在する。また、誤ったラベルが付与される可能性もある。最近の研究では、月震波形の前処理を改良することで、Bulow ら [1] は、新しい A1 震源の月震を多数発見している。また、Endrun ら [2] は、隠れマルコフモデルを用いた手法で、大規模な月震データベースから、これまでに発見されていなかった新たな月震を検出することに成功している。これらの研究により、これまで発見されていなかった月震の検出、未分類であった月震の分類がなされている。また、後藤ら [10] による月震の可視化システムでは、従来の、月震波形の相互相関係数ではなく、周波数成分を特徴量として、教師なし学習のひとつである SOM による深発月震の分類を可視化した。SOM の結果では、複数の震源が混合したクラスタリング結果が得られている。また、ノイズによって波形の性質が埋もれている波形が集まるセルも見られた。これらの結果から、機械学習により、これまでに目視で発見、分類されていた従来の月震波形の検出手法や、震源の分類基準を改良することが可能であると考えられる。

震源の分類基準に着目すると、現在の分類基準は、波形の相互相関のみを考慮した基準であり、これまでに発見されていない震源に起因した要素が存在する可能性がある。つまり、震源の分類基準を再考するために、震源の分類に寄与する新たな特徴量を発見する必要がある。しかし、従来、これらの特徴量を発見することは、専門家の知見に基づく必要があった。本研究では、機械学習を用いることで、人手に頼らず、震源の分類に寄与する新たな特徴量の発見を行う。新たな特徴を発見することは、専門家の月震解析の補助、震源の分類基準の再考、未知の震源の発見につながる。

本論文は、以下の構成に従う。2 章では、深発月震の震源分類に寄与する特徴量の評価手法について述べる。3 章では、実験結果について述べる。4 章では、考察について述べる。5 章では、本論文のまとめを述べる。

\*1 DARTS at ISAS/JAXA <http://darts.jaxa.jp>

## 2 提案手法

本研究では、機械学習における代表的な教師あり機械学習手法のひとつである Support Vector Machine (SVM)[8] を適用し、特徴量の検証を行う。SVM は、正例、負例の 2 つのクラスのデータを分類する手法であり、与えられたデータを 2 クラスに分離する超平面を生成することで、未知データがどちらのクラスに属しているかを判定する。SVM は 2 クラスの分類しかできないため、SVM で多クラス分類を行う方法として、one-versus-one 法と one-versus-the-rest 法がある。 $n$  クラス分類において、one-versus-one は、ある特定のクラスに入るか、別の特定のクラスに入るかを判定する分類器を  $n(n-1)/2$  個利用するものであり、one-versus-the-rest は、ある特定のクラスに入るか、他の  $n-1$  個のクラスのいずれかに入るかを判定する分類器を  $n$  個利用するものである。

検証方法として、従来の震源ラベルを正解ラベルとし、月震から生成した特徴量に基づいて、従来の震源ラベルが SVM によって再現可能かを確認する。このとき、分類性能の検証には  $k$ -分割交差検定を用いる。 $k$ -分割交差検定とは、分類モデルの妥当性を検証する手法である。 $k$ -分割交差検定の手法を以下に示す。

1. データセットを、 $k$  個に分割する
2. 分割されたデータセットの 1 つめテストデータとして、残りの  $k-1$  個を訓練データとする。訓練データを用いて学習した分類モデルで、テストデータに対する分類性能を評価する。
3. 次に、分割されたデータセットの 2 つめをテストデータとして、残りの  $k-1$  個を訓練データとする。2. と同様に分類性能を評価する
4. この作業を、 $k$  回繰り返し  $k$  個のテストデータに対する分類性能の平均を最終的な分類性能とする

交差検定を用いる事で、分類モデルの汎用性と妥当性を評価できる。

本論文では、5 交差検定の結果を機械学習の結果とする。その結果として、SVM による分類結果と、従来の震源ラベルの多くが一致していれば、その特徴量による機械学習を適用することで、従来の分類結果をおおよそ再現が可能である。つまり、その特徴量は、震源を分類するのに適切である。

### 2.1 特徴量

本研究では、機械学習に用いる特徴量として、PSD、J2000 座標系における月-地球間の距離、月の位置 ( $x$ ,  $y$ ,  $z$ )、月の速度 ( $v_x$ ,  $v_y$ ,  $v_z$ ) を用いる。

PSD は、周波数毎の振幅強度を計算したものである\*2。PSD 計算の際に用いたセグメント長は 2048 点とし、窓関数に hanning 窓を用いた。約 15 分間の月震波形データを、セグメント長の半分ずつシフトして計算した PSD の平均値を導出する。導出された PSD をベクトル長が 1 になるよう正規化したものを最終的な特徴量とする。また、月震は、地震と違い、1 時間以上揺れが続くものも存在する。従って、PSD の計算において、震源ごとの特徴の差異が現れやすい時刻を、切り出し位置を推移することで検証する。

J2000 座標系は、地球を中心とし、J2000.0 における平均赤道と平均春分点を基準とした座標系である。ここで、J2000 は 2000 年 1 月 1 日正午であり、その時刻における平均春分点の方向を  $x$  軸とする\*4。

J2000 座標系における月-地球間の距離、位置、速度は、月震発生時刻に基づいて、SPICE\*3 を用いて計算を行う。本論文では、これまでの研究で用いられてきた波形から得られる特徴量を用いずに、震源分類が再現可能であるかを検討する。各特徴ごと、平均値が 0、標準偏差が 1 となるよう正規化し、距離、位置、速度それぞれの組み合わせと分類性能を比較する。

SVM の実装には、scikit-learn[7] の SVC を用いた。多クラス分類法には、one-versus-the-rest を用いた。

表1 データセットの内訳

震源	A1	A6	A7	A8	A9	A10	A18	A21	A33	合計
データ数	138	24	19	24	51	33	36	26	28	379

また、本論文で扱うデータセットは、震源ごとにデータ数が異なる。SVM の学習の際に、データ数のばらつきは、過学習の発生につながる。これらの不均衡データに対応するため、データ数に応じて自動で重みをつけるよう class-weight パラメータを “balanced” に設定した。また、パラメータについては、各条件ごとに rbf と linear カーネルを用いてグリッドサーチを行い、それぞれ一番分類性能のいいパラメータを選択した。

### 3 実験結果

#### 3.1 データセット

表1に、実験に用いたデータセットに含まれる震源の種類と深発月震のイベント数を示す。本データセットに用いる月震イベントは、アポロ12号のミッションで取得されたものである。本データセットは、震源全体の中で比較的月震イベントが多く観測され、解析が進んでいる9震源から、人手でノイズの少ない月震を選定している。前処理として、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、スパイク除去処理を行った長周期地震計のZ軸成分(LPZ)のデータを実験に用いた。

また、ALSEPにおいて、月震データの観測はPeakedモードとFlatモードが存在する。これらの観測モードによって、周波数応答が異なる。そのため、本論文では、Peakedモードで観測された波形のみを用いる。

#### 3.2 評価指標

本論文では、震源の分類の性能を評価するための評価指標として、適合率、再現率、F値を用いる。例として、A1震源における適合率、再現率、F値は以下の式で表される。

$$\text{適合率} = \frac{\text{A1と予測されて正解だった数}}{\text{A1と予測された数}}$$

$$\text{再現率} = \frac{\text{A1と予測されて正解だった数}}{\text{全体のA1の数}}$$

$$F \text{ 値} = \frac{2 * \text{適合率} * \text{再現率}}{\text{適合率} + \text{再現率}}$$

適合率は、分類の正確性を測る指標であり、再現率は、分類の網羅性を測る指標である。適合率と再現率はトレードオフであるため、適合率と再現率の調和平均であるF値は、適合率と再現率のバランスを考慮した評価指標である。

#### 3.3 PSDを用いた場合の結果

本節では、PSDが、震源を分類するのに有効な特徴量であるかを評価するための実験結果について述べる。PSDは約15分間の月震波形から計算を行う。月震波形の切り出し開始点は、各月震のP波到達時刻を基準

<sup>\*2</sup> <http://www.cygres.com/OcnPageE/Glosry/SpecE.html>

<sup>\*3</sup> <http://naif.jpl.nasa.gov/naif>

<sup>\*4</sup> <http://www2.nc-toyama.ac.jp/mkawai/lecture/radionav/tfcoordinate/coordinate.html>

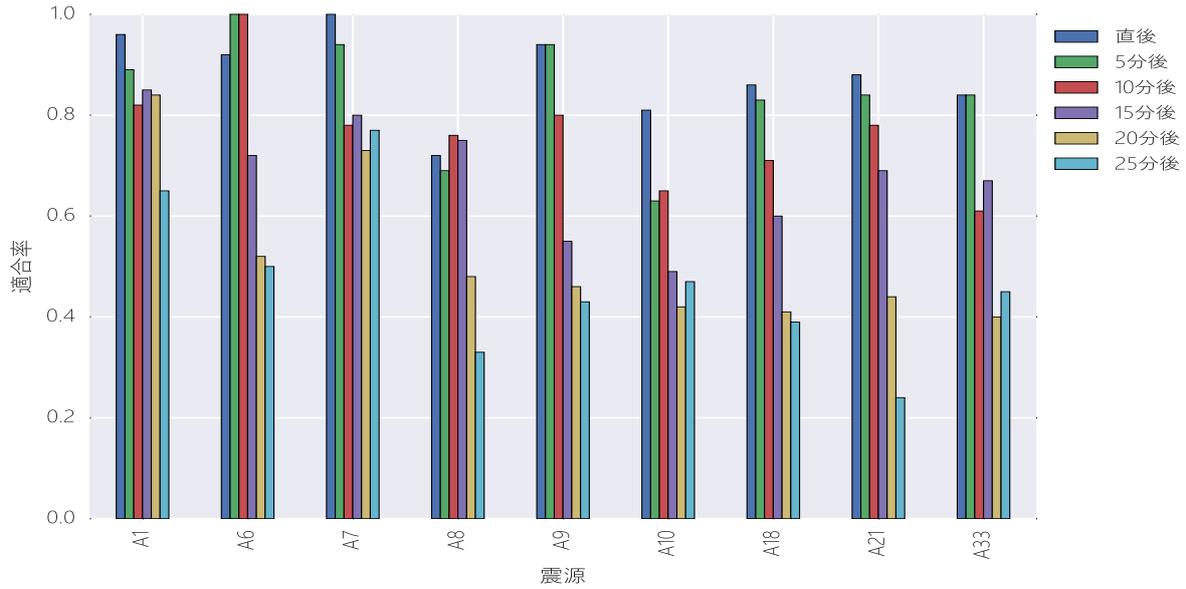


図1 P波到達時刻からの切り出し時刻と適合率

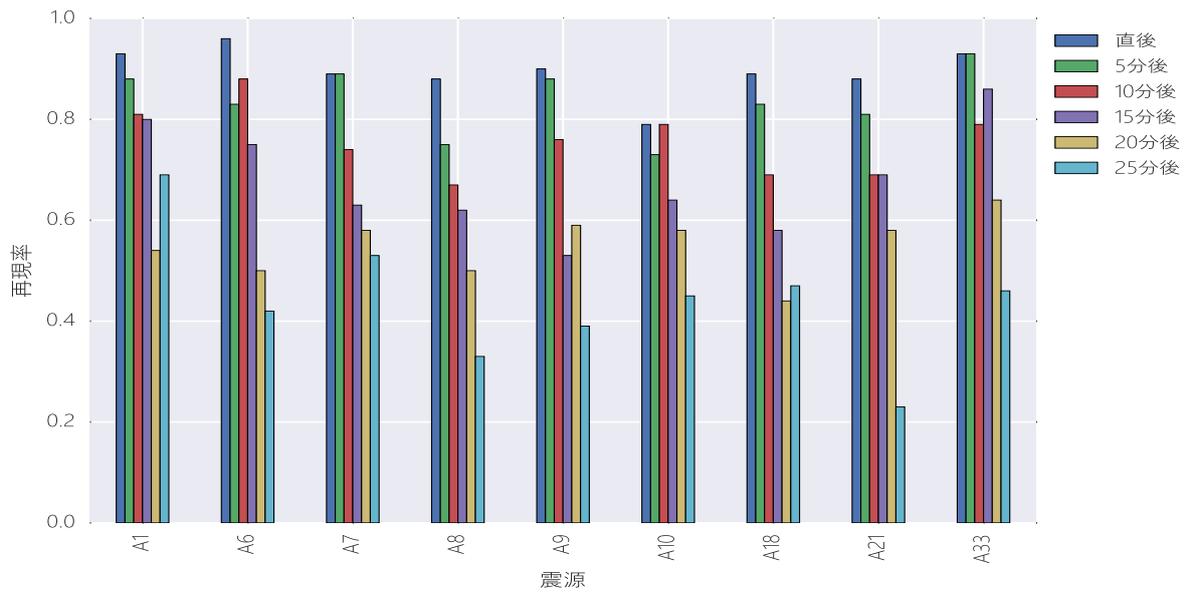


図2 P波到達時刻からの切り出し時刻と再現率

とし、5分毎に切り出し開始点をずらした。切り出し毎のSVMの分類性能を計算し、それぞれの適合率、再現率、F値で評価する。

図1, 2, 3は、PSDを特徴量としたときに、P波到達時刻からの切り出し開始時刻の推移に伴う、適合率、再現率、F値の推移を示したものである。横軸は震源名、縦軸は適合率、再現率、F値の値である。

図1, 2, 3より、適合率、再現率、F値の全ての評価指標において、P波到達直後から15分間の波形のPSDを特徴量とした場合の分類性能が高く、P波到達時刻からの差が大きくなるにつれて、SVMの分類性能が低下していることが示された。

また、P波到達直後から15分間の波形を使用した場合の適合率、再現率、F値の全体平均はそれぞれ0.91, 0.90, 0.90である。

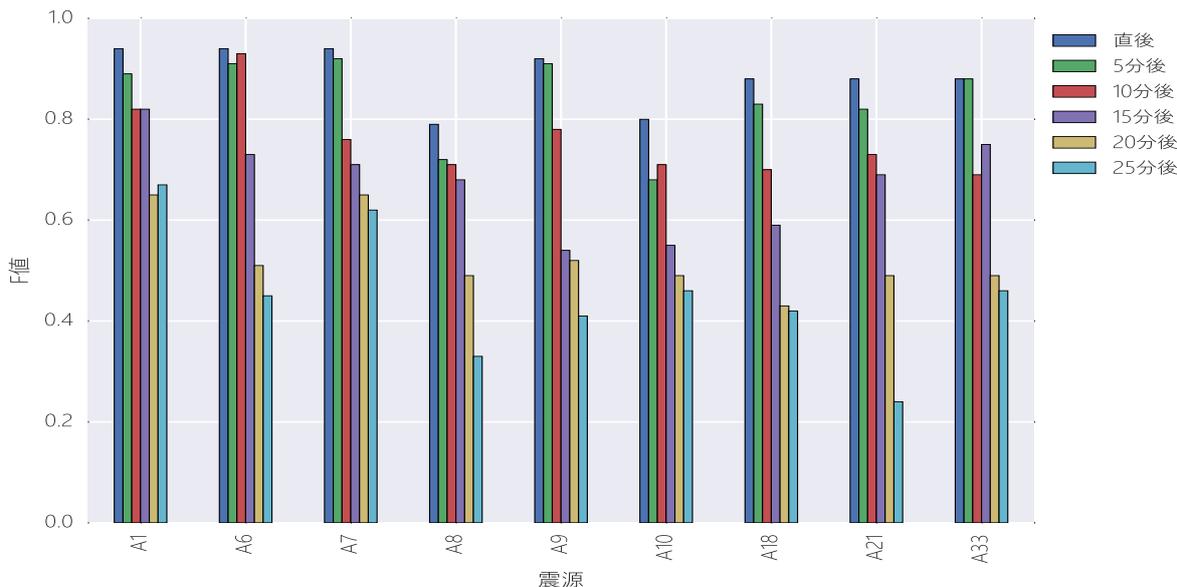


図3 P波到達時刻からの切り出し時刻とF値

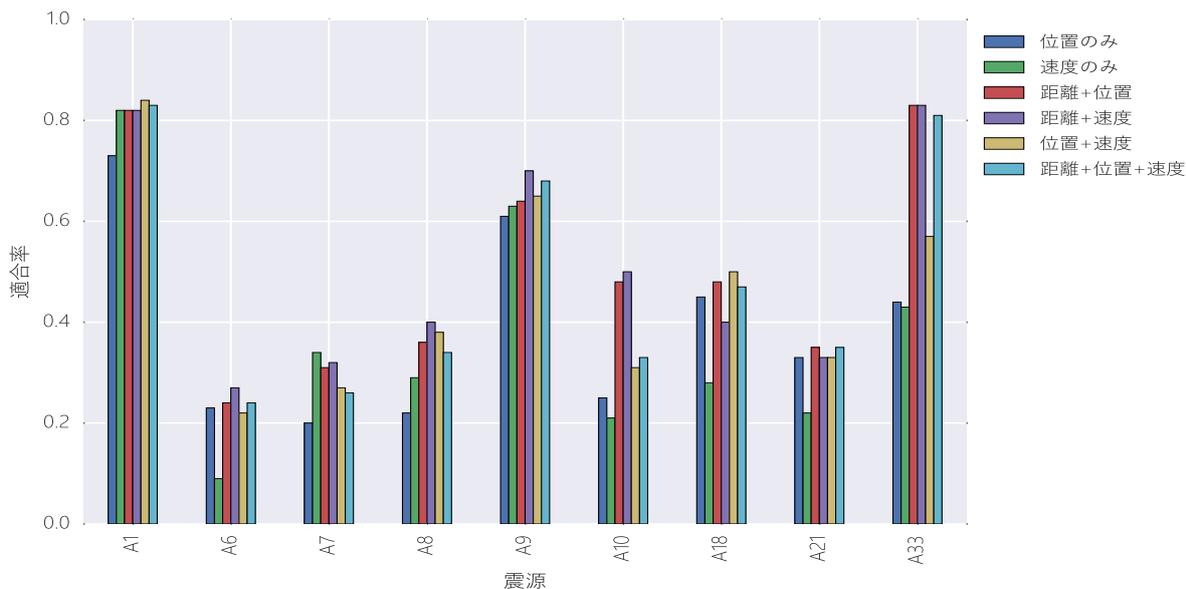


図4 距離，位置，速度それぞれの組み合わせと適合率

### 3.4 月-地球間の距離，位置，速度を用いた結果

図4, 5, 6は，月-地球間の距離，位置，速度を特徴量としたときの，震源別のSVMの適合率，再現率，F値を示したものである。横軸は震源であり，縦軸はそれぞれの分類性能である。はじめに，特徴量として距離，位置 (x, y, z 全てを特徴量とした3次元ベクトル)，速度 (vx, vy, vz 全てを特徴量とした3次元ベクトル) の3要素を特徴量とし，位置，速度，距離+位置，距離+速度，位置+速度，距離+位置+速度の

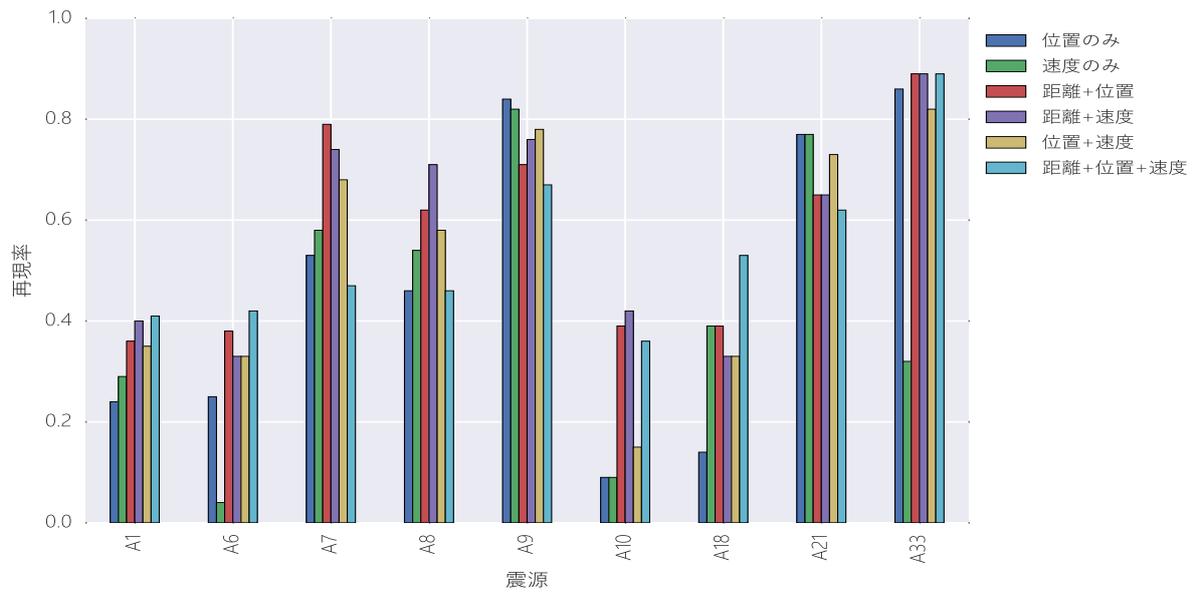


図5 距離，位置，速度それぞれの組み合わせと再現率

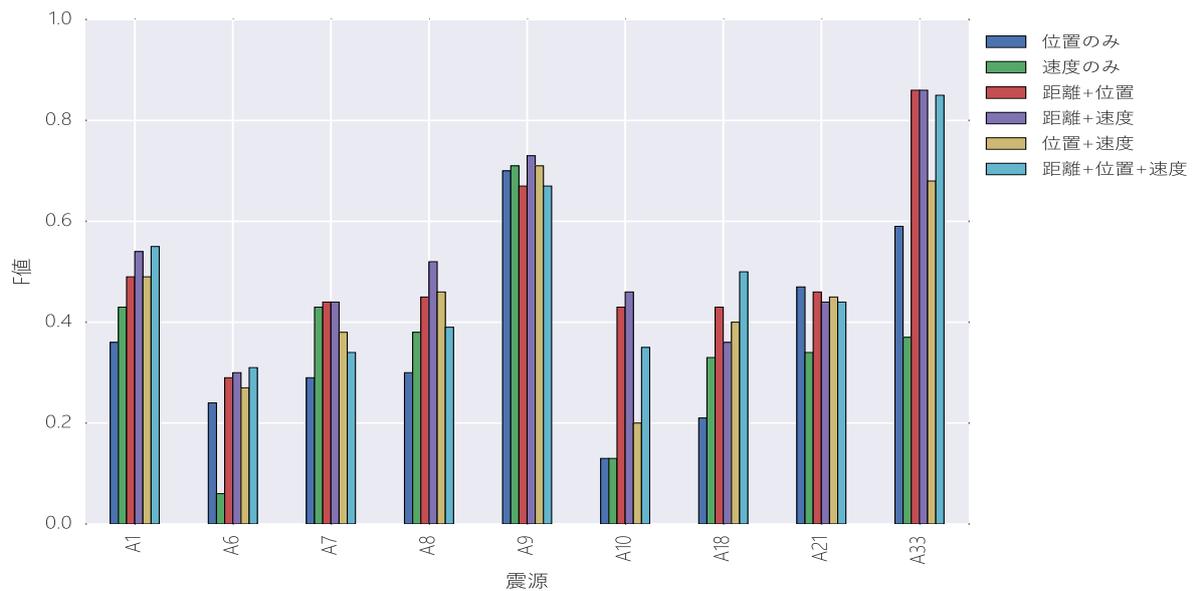


図6 距離，位置，速度それぞれの組み合わせとF値

6種類の組み合わせにおいて、それぞれ分類性能を求めた。

図4より、A1, A9, A33は、距離を特徴量のひとつとして用いた場合に、他の震源に比べて適合率が高いことが示された。また、A1, A9は、位置や速度のみを用いた特徴量において、他の震源に比べて適合率が高い。結果として、これらの特徴量を用いる事で、一部の震源について分類に有効な特徴量である事が示された。

図7は、月-地球間の距離、x座標の位置、y座標の位置、z座標の位置、x座標の速度、y座標の速度、z座標の速度の7つの特徴量から、2つを特徴量として組み合わせた場合の、SVMの震源全体における適合率、再現率、F値を示したものである。横軸は特徴量の組み合わせであり、縦軸はそれぞれの分類性能である。図4, 5, 6の結果で、距離を特徴量とした場合に分類性能が高いことが示されたが、図7で、距離+x軸の速度を特

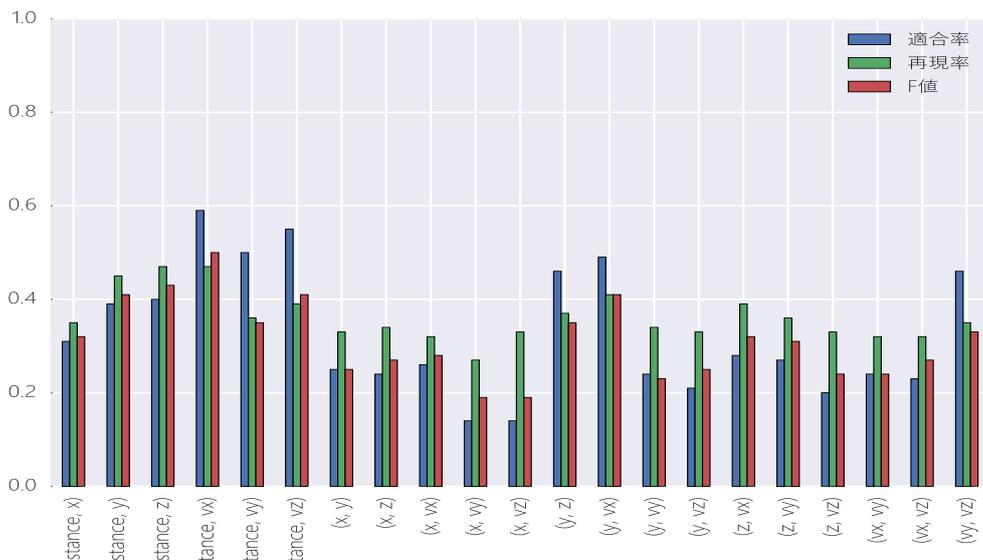


図7 距離，位置 (x, y, z)，速度 (vx, vy, vz) から2つを特徴量としたときの分類性能

表2 距離 +x 軸の速度を特徴量としたときの SVM の分類性能

震源	適合率	再現率	F 値
A1	0.81	0.38	0.51
A6	0.17	0.29	0.22
A7	0.08	0.21	0.12
A8	0.29	0.38	0.33
A9	0.69	0.73	0.70
A10	0.45	0.39	0.42
A18	0.43	0.64	0.52
A21	0.38	0.38	0.38
A33	0.81	0.89	0.85

表3 距離 +z 軸の速度を特徴量としたときの SVM の分類性能

震源	適合率	再現率	F 値
A1	0.86	0.31	0.46
A6	0.23	0.50	0.32
A7	0.13	0.42	0.20
A8	0.34	0.71	0.46
A9	0.38	0.10	0.16
A10	0.09	0.03	0.05
A18	0.34	0.39	0.36
A21	0.25	0.62	0.36
A33	0.53	0.68	0.59

微量としたときに最も分類性能が高いことが示された。また，y 軸の位置 +z 軸の位置，y 軸の位置 +x 軸の速度，y 軸の速度 +z 軸の速度を特徴量としたとき，他の位置，速度の組み合わせと比較して適合率が高い。

図7において，分類性能が高い組み合わせである距離 +x 軸の速度，距離 +z 軸の速度，y 軸の位置 +z 軸の位置，y 軸の位置 +x 軸の速度における震源別の分類性能を表2，3，4，5に示す。

## 4 考察

### 4.1 PSD について

本節では，3.3節の結果について述べる

PSD を特徴量とした機械学習を用いて，震源ラベルを十分に再現できていることから，PSD は震源分類に

表4 y 軸の位置 +z 軸の位置を特徴量としたときの SVM の分類性能

震源	適合率	再現率	F 値
A1	0.75	0.28	0.41
A6	0.11	0.08	0.09
A7	0.19	0.74	0.30
A8	0.17	0.38	0.23
A9	0.62	0.80	0.70
A10	0.23	0.09	0.13
A18	0.30	0.28	0.29
A21	0.33	0.77	0.46
A33	0.12	0.04	0.06

表5 y 軸の位置 +x 軸の速度を特徴量としたときの SVM の分類性能

震源	適合率	再現率	F 値
A1	0.69	0.31	0.43
A6	0.00	0.00	0.00
A7	0.21	0.79	0.33
A8	0.21	0.38	0.27
A9	0.60	0.71	0.65
A10	0.38	0.30	0.34
A18	0.50	0.39	0.44
A21	0.25	0.35	0.29
A33	0.41	0.64	0.50

有効な特徴量であることがわかる。また、分類性能を低下させる要因として、

- 特徴量と手法の組み合わせが適切でない
- 従来の分類基準と SVM による分類基準が一部異なる
- PSD で捉えることができない特徴が月震に含まれている

と考えられる。また、PSD において、深発月震の P 波到達直後が、最も震源ごとに特徴の差が現れていると推測される。これは、時間の経過とともに、月表面で揺れが散乱するため、震源ごとの特徴が埋もれてしまうためと考えられる。

## 4.2 距離, 位置, 震源について

本節では、3.4 節の結果について述べる。

図 4, 5, 6 より、震源ごとに分類性能にばらつきがあり、A1, A9, A33 は他の震源に比べて、分類性能が高い。距離 + 位置, 距離 + 速度の比較を行う。A1, A8, A9, A10 は、距離 + 速度を特徴量とした時の分類性能が、距離 + 位置の分類性能と比べて高い。しかし、A18, A21 は、距離 + 位置の分類性能が距離 + 速度の分類性能に比べて高い。これらの結果から、位置が大きく影響する震源と、速度が大きく影響する震源が異なり、A1, A8, A9, A10 は速度に特徴が現れる震源であり、A18, A21 は、位置に特徴が現れる震源であることが推測される。また、すべての震源は、距離を特徴量のひとつとした時に分類性能が高い。

- 月-地球間の距離そのものが月震発生に寄与している
- 月-地球間の距離と、位置もしくは速度との関係に、月震発生に寄与しているものが存在する

といった推測が可能である。この事は、先行研究 [9] で述べられているよう、深発月震が潮汐力の寄与で発生している事に関連していると考えられる。特に、A1, A9, A33 は、月-地球間の距離や、位置、速度が大きく関わっていることが推測される。しかしながら、4.1 節の分類性能と比較すると、距離や速度、位置のみを用いた SVM の分類性能は十分であるとは言えない。

ここで、距離を特徴量とした場合に分類性能の高さに着目し、図 8 に、震源別の距離の分布を示す。横軸は月-地球間の距離であり、縦軸は、各震源ごと、36 万キロメートルから 41 万キロメートルまでを 5000 メートルずつ分割した際のイベント数を示している。分類性能の高かった A33 の月震は、40 万キロメートル付近の限られた距離で発生している。一方、その他の震源の距離の分布において、震源ごとの距離の分布に多少の差

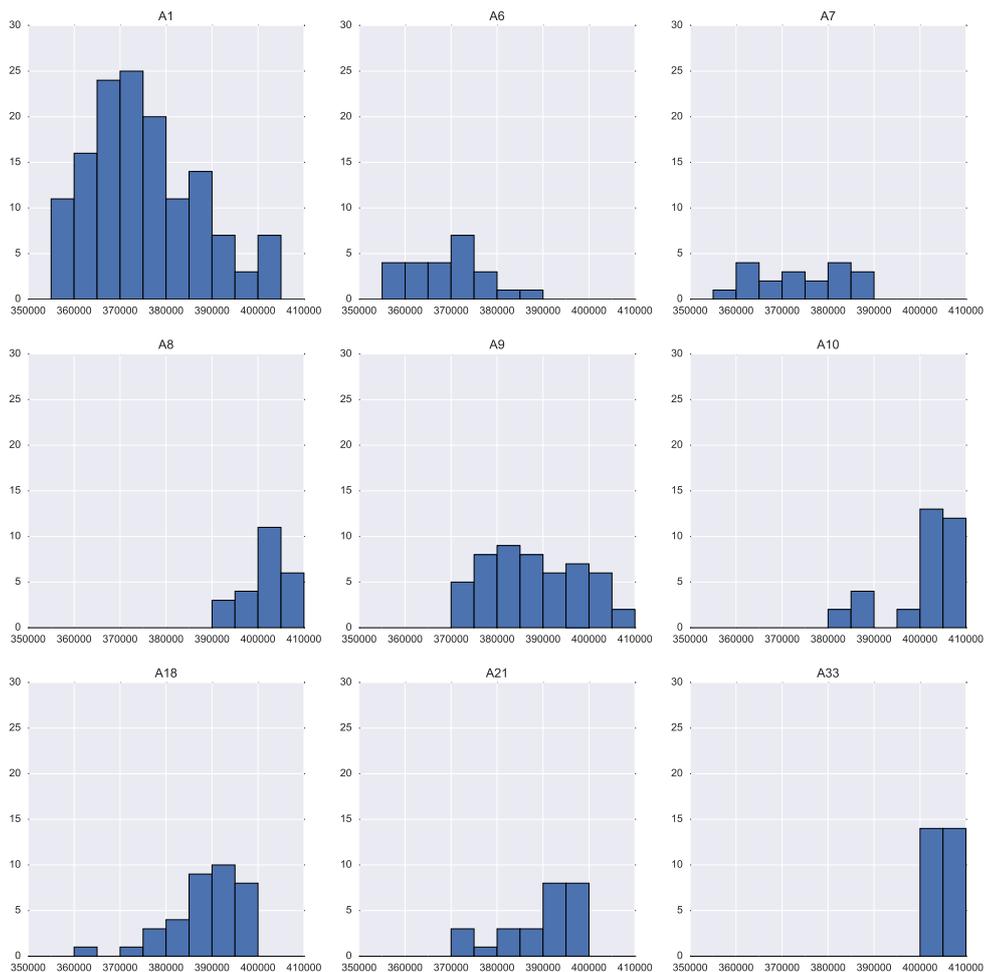


図8 震源別の距離の分布

があることは推察できるが、目視によって震源固有の特徴を発見することは難しい。しかし、機械学習の結果では、距離を特徴量として用いたときに分類性能が高くなっていることから、分類性能に影響する要因として、距離、位置の  $x$ ,  $y$ ,  $z$  成分、速度の  $x$ ,  $y$ ,  $z$  成分の組み合わせによる震源との相関が存在する可能性があり、震源ごとの相関が現れる要因の分析を行う必要がある。

そこで、震源ごとの要因の分析を行う前段階として、図7の分類性能を比較すると、特徴量の組み合わせによって、分類性能が変化していることがわかる。全体の分類性能が最も高い組み合わせである表2の結果では、A9のF値が0.70、A33のF値が0.85である。また、A1の適合率は0.81である。しかし、表3では、A1の適合率は0.86であるが、A9のF値は0.16であり、A33のF値は0.59である。これは、距離+z軸の速度を特徴量としたときに、A9やA33固有の特徴を表現できないと考えられる。また、表4では、A9の分類性能が最も高く、F値が0.70であるのに対し、A33のF値は0.06である。従って、A9は表4の特徴量の組み合わせでも震源の特徴を表現できているのに対し、A33は表4の特徴量の組み合わせでは震源の特徴を表

現できないことが示されている。表5では、A33の分類性能が、表2の分類性能と比べて向上していることから、A33は、x軸の速度に震源の特徴を表現出来る要因が含まれていることが推測される。これらの結果から、震源によって最適な特徴量が異なると考えられ、今後、震源ごとの有用な特徴量の分析を行う必要がある。

## 5 まとめ

本研究では、機械学習を用いて、震源を分類できる深発月震の特徴量の半自動的な発見を行った。手法として、SVMを用いた教師あり学習とその精度を用いて、震源分類結果の再現が可能かを考察した。その結果、月震は開始直後に震源ごとの特徴が現れる傾向が見られること、月震のPSD、月-地球間の距離は震源分類に有効な特徴量であり、月-地球間の距離は特定の震源の推定に利用が可能であることを示した。これらの特徴量を考慮した月震分類基準を作成することで、未だに分類がなされていない深発月震の分類や、未知の震源の発見に貢献できると考えられる。本論文では、先行研究で示されていたスペクトルや、潮汐力と関係がある月-地球間の距離を用いたが、今後は、特徴量間の相関の発見や、これまで言及されていない太陽や他の惑星等の様々な要因を考慮した分析を行う予定である。

## 謝辞

本稿の執筆にあたって多数の有益な助言を頂いた、首都大学東京特任助教の庄司 慶行氏に感謝いたします。本研究(の一部)は傾斜的研究(全学分)学長裁量枠戦略的研究プロジェクト戦略的研究支援枠「ソーシャルビッグデータの分析・応用のための学術基盤の研究」による

## 参考文献

- [1] R. C. Bulow, C. L. Johnson, and PM Shearer. New events discovered in the apollo lunar seismic data. *Journal of Geophysical Research: Planets (1991–2012)*, Vol. 110, No. E10, 2005.
- [2] B. Knapmeyer-Endrun and C. Hammer. Identification of new events in apollo 16 lunar seismic data by hidden markov model-based event detection and classification. *Journal of Geophysical Research: Planets*, Vol. 120, No. 10, pp. 1620–1645, 2015.
- [3] P. Lognonné, J. Gagnepain-Beyneix, and H. Chenet. A new seismic model of the moon: implications for structure, thermal evolution and formation of the moon. *Earth and Planetary Science Letters*, Vol. 211, No. 1, pp. 27–44, 2003.
- [4] Y. Nakamura. New identification of deep moonquakes in the apollo lunar seismic data. *Physics of the Earth and Planetary Interiors*, Vol. 139, No. 3, pp. 197–205, 2003.
- [5] Y. Nakamura, G. V. Latham, and H. J. Dorman. Apollo lunar seismic experiment—final summary. *Journal of Geophysical Research: Solid Earth (1978–2012)*, Vol. 87, No. S01, pp. A117–A123, 1982.
- [6] Y. Nakamura, G. V. Latham, H. J. Dorman, and J. Harris. Passive seismic experiment long-period event catalog. *Galveston Geophysics Laboratory Contribution*, Vol. 491, , 1981.
- [7] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, Vol. 12, pp. 2825–2830, 2011.
- [8] Vladimir Naumovich Vapnik and Vlamimir Vapnik. *Statistical learning theory*, Vol. 1. Wiley New York, 1998.
- [9] RC Weber, BG Bills, and CL Johnson. Constraints on deep moonquake focal mechanisms through analyses of tidal stress. *Journal of Geophysical Research: Planets*, Vol. 114, No. E5, 2009.
- [10] 後藤康路, 山田竜平, 山本幸生, 横山昌平, 石川博. 階層型 SOM に基づいた大規模月地震波形の可視化システム. 第 6 回データ工学と情報マネジメントに関するフォーラム, E1-4, 2014.
- [11] 山田竜平, 山本幸生, 桑村潤, 中村吉雄. アポロ月地震データ公開システムの開発. 宇宙科学情報解析論文誌宇宙航空研究開発機構研究開発報告, No. 1, pp. 121–131, 2012.