

ポスター会場（2日目） | 特別セッション：S24. 機械学習による地震学の未来の開拓

2020年10月30日(金) 16:00 ~ 17:30 | 会場

S24P

16:00 ~ 17:30

[S24P-01] CNNを用いた水圧破碎AE波形のP波初動極性読み取りとモーメント・テンソル推定

○田中 壘¹、直井 誠¹、陳 友晴¹、山本 和畝¹、今北 啓一¹、堤 直史¹、下田 晃嘉¹、平松 大樹¹、川方 裕則²、石田 毅¹、福山 英一¹、田中 浩之³、有馬 雄太郎³、北村 重浩³、兵藤 大祐³ (1.京都大学、2.立命館大学、3.JOGMEC)

16:00 ~ 17:30

[S24P-02] 連続波形記録の教師なし自動分類：不均衡データに対応するための異常検知処理の導入

○小寺 祐貴¹、酒井 慎一² (1.気象庁気象研究所、2.東京大学地震研究所)

16:00 ~ 17:30

[S24P-03] 畳み込みニューラルネットワークによるノイズ除去と地震検知

○下條 賢梧¹、工藤 祥太¹、岩崎 友理子¹、溜淵 功史² (1.気象庁、2.気象研究所)

16:00 ~ 17:30

[S24P-04] 高ノイズ環境下における機械学習を用いた地震動検出の試み: 市民参加型地震計ネットワークの構築に向けて

○金 亜伊¹、上松 大輝¹、中村 勇士¹、高橋 佑汰²、中村 桃子² (1.横浜市立大学、2.専修大学)

16:00 ~ 17:30

[S24P-05] 理論地震波形記録の時空間伝播を教師データとした機械学習による震源決定の試み

○杉山 大祐¹、坪井 誠司¹ (1.海洋研究開発機構)

16:00 ~ 17:30

[S24P-06] 畳み込みニューラルネットワークに基づく地震波形画像からの深部低周波微動検出に向けた数値実験

○金子 亮介¹、長尾 大道^{1,2}、伊藤 伸一^{1,2}、小原 一成²、鶴岡 弘² (1.東京大学大学院情報理工学系研究科、2.東京大学地震研究所)

16:00 ~ 17:30

[S24P-07] Machine learning models for aftershock forecasting: Application to the 2016 Kumamoto earthquake sequence

○Hanyuan Huang¹、Hiroe Miyake¹ (1.Earthquake Research Institute, University of Tokyo)

CNNを用いた水圧破碎AE波形のP波初動極性読み取りとモーメント・テンソル推定

Determination of *P*-wave first motion polarities and moment tensors for hydraulically-induced AEs using CNN technique

*田中 壘¹、直井 誠¹、陳 友晴¹、山本 和畝¹、今北 啓一¹、堤 直史¹、下田 晃嘉¹、平松 大樹¹、川方 裕則²、石田 毅¹、福山 英一¹、田中 浩之³、有馬 雄太郎³、北村 重浩³、兵藤 大祐³

*Rui Tanaka¹, Makoto Naoi¹, Youqing Chen¹, Kazune Yamamoto¹, Keiichi Imakita¹, Naofumi Tsutsumi¹, Akihiro Shimoda¹, Daiki Hiramatsu¹, Hironori Kawakata², Tsuyoshi Ishida¹, Eiichi Fukuyama¹, Hiroyuki Tanaka³, Yutaro Arima³, Shigehiro Kitamura³, Daisuke Hyodo³

1. 京都大学、2. 立命館大学、3. JOGMEC

1. Kyoto University, 2. Ritsumeikan University, 3. JOGMEC

シェールオイル・ガス開発や地熱開発では、岩盤の透水性を向上させ、資源の流路を確保するために水圧破碎技術が利用されている。本研究では、水圧破碎による亀裂造成プロセスを明らかにするため、室内水圧破碎実験を実施し、実験中に生じるacoustic emission event（以下AE）を測定して、そのモーメント・テンソル（MT）解を推定した。大量のAEのMT推定を効率よく行うために、畳み込みニューラルネットワーク（CNN）によるP波初動極性の読み取りを行い、得られた結果をもとに個々のAEのMT解を推定した。

実験は、65 x 65 x 130 mmの直方体形状の黒髪島花崗岩10個に対して5 MPaの一軸圧縮载荷下で実施した。供試体中央部に穿孔した破碎孔に1 cc/min ($1.6 \times 10^{-8} \text{ m}^3/\text{s}$) で破碎流体を圧入することで水圧破碎を行い、試験中に生じるAEを、供試体に設置したプリアンプ内蔵型の高感度・広帯域のM304Aセンサ16個、共振型のPICOセンサ（共振周波数550 kHz）8個の計24個のAEセンサを用いて14bit, 10 MHzで連続収録した。得られたAEデータからSTAとLTAの比を用いる手法（Allen 1978）による波形抽出を行い、供試体の速度異方性を考慮した非線形最小二乗法（Rothman et al. 1974）を用いてAEの震源位置・発震時刻を推定した。さらに、得られた震源を初期震源としてdouble difference法（Waldhauser & Ellsworth 2000）により震源を再決定した。

上記の処理で得られたすべてのイベントのうち、14個以上のM304Aセンサでシグナルノイズ比15以上の波形が得られたイベントに対してP波初動極性を手動で読み取り、得られた49375個の読み取り結果をCNNの訓練に用いた。図1に本研究で構築したCNNと訓練結果を示す。このネットワークでは、理論走時周辺の150サンプル分の波形を入力とし、その波形の初動極性を0（引き）から1（押し）の連続量で出力する。訓練は、手動読み取りデータの80%を訓練データ、20%を検証データとして行った。M304Aで得られた波形に対する結果ではepoch=72、PICOではepoch=47で訓練・検証データに対する損失の差が最小となった。この時の精度は出力値の閾値を0.5（0.5以上を押し、0.5未満を引き）とした場合、それぞれ95.30%、96.83%、閾値を0.05（0.95以上を押し、0.05未満を引き）とした場合、それぞれ99.22%、99.11%であった。初動極性の自動読み取りにはこれらのepochでの重みパラメータを用い、また、出力値の選定には閾値0.05を採用し、出力値が0.05-0.95である読み取り結果は以降の解析に用いなかった。CNNにより1399767個の波形の初動極性の自動読み取りに成功し、この読み取り結果を元に各波形の理論走時周辺の30サンプルから初動振幅値を読み取り、これらを用いて49299イベントのMT解を推定した。

AEの時空間分布からは、破碎孔での流体圧の急降下（breakdown）を伴う最終的な亀裂造成の準備過程として2つのフェーズが確認された。最初のフェーズ（第1拡大フェーズ）は、破碎孔での流体圧が、breakdownが生じる圧力の10-30%で始まり、破碎孔から時間とともに三次元的に広がるAE活動で特徴づけられる。2つ目のフェーズ（第2拡大フェーズ）は、breakdown圧の90-99%で始まり、破碎孔から最大圧縮軸方向に二次元的に進展するAE活動で特徴づけられる。得られたMT解析結果からは、第1拡大フェーズでは様々な方向の開

口型AEが起こったことが示唆された。第2拡大フェーズでは、AE震源が描き出す面上での開口に対応するメカニズム、すなわち古典的水圧破碎理論から予想される開口型のイベントが支配的であることがわかった。また、第2拡大フェーズでは開口型AEに加え、せん断型AEも生じたことが確認された。これらの結果から、第1拡大フェーズは、既存の空隙を利用して破碎流体が岩体に浸透する過程、第2拡大フェーズは、boreholeから主亀裂が生じ進展する過程に対応すると解釈できる。




図1 (a) P波初動極性読み取り用のCNN. (b, c) M304Aで受振された波形を用いた訓練の結果. (d, e) PICOで受振された波形を用いた訓練の結果.

連続波形記録の教師なし自動分類：不均衡データに対応するための異常検知処理の導入

An unsupervised automatic classification for continuous seismic records: introducing an anomaly detection algorithm to solve the imbalanced data problem

*小寺 祐貴¹、酒井 慎一²

*Yuki Kodera¹, Shin'ichi Sakai²

1. 気象庁気象研究所、2. 東京大学地震研究所

1. Meteorological Research Institute, Japan Meteorological Agency, 2. Earthquake Research Institute, the University of Tokyo

地震計の連続波形記録には、自然地震、人為的活動、機器ノイズといった様々な波形が記録されている。連続波形記録を自動的に分類することができれば、地震計周辺の地球物理的現象の理解や、緊急地震速報といったリアルタイム処理で用いる観測機器の品質管理につながると期待される。本研究では、様々な観測環境下に設置された地震計に適用可能となるよう、教師なし学習による連続波形記録の自動分類手法の開発を行っている。同手法では、まず特徴量としてランニングスペクトルを計算した後、周波数空間でk-means法、時間領域でスペクトラルクラスタリング法を適用し、波形の分類を行う。

連続波形記録を自動分類する上で大きな問題となるのは、一般的に対象となるデータが不均衡（例えば、He and Garcia, 2009）になることである。つまり、波形の大部分は定常シグナル（バックグラウンドノイズなど）であり、非定常シグナル（地震など）は相対的にデータ量が少ない。そのため、そのまま連続波形記録に教師なし学習を適用した場合、定常シグナルのみが過度に細かく分類されてしまう恐れがある。この問題に対処するため、サンプリングに基づく簡易的な異常検知手法（Sugiyama and Borgwardt, 2013）を導入した。周波数空間でのクラスタリングを行う前に、異常検知手法により「正常値」と「異常値」（全データのうち1.0%）のデータ点を抽出した上で、これらのデータ点に対してk-means法を適用するよう、手法を改良した。

この手法を2017年3月1日～7日に記録されたMeSO-net観測点E.JDJM（地下鉄近傍の観測点；川北・酒井, 2009）の連続波形記録に対して適用した。異常検知手法を導入しなかった場合、不均衡データの影響によって地下鉄ノイズは複数のクラスに細分化されていたが、異常検知手法を導入した手法では、地下鉄ノイズは単一のクラスに分類されるようになった。これは、異常検知手法の導入が連続波形記録分類における不均衡データ問題の解決に有効な手段のひとつであることを示している。

畳み込みニューラルネットワークによるノイズ除去と地震検知 Denoise and seismic phase detection with Convolutional Neural Network

*下條 賢梧¹、工藤 祥太¹、岩崎 友理子¹、溜淵 功史²

*Kengo Shimojo¹, Shouta Kudo¹, Yuriiko Iwasaki¹, Koji Tamaribuchi²

1. 気象庁、2. 気象研究所

1. Japan Meteorological Agency, 2. Meteorological Research Institute

気象庁は2016年4月から、自動震源決定手法であるPF法(溜淵・他, 2016, Tamaribuchi, 2018)の運用を開始した。PF法では、まず、連続地震波形データから分散比, Characteristic Function(Allen, 1978), AR-AIC(横田・他, 1981)などを用いて地震波検知・検測を行う(一次検測)。その後、一次検測値を元にグループトリガ(清本・他, 2013)や重点サンプリング法などを用いて震源を計算し、決定する。PF法は従来の自動震源決定手法に比べ、イベント検知能力や震源精度の大幅な向上をもたらしたものの、一次検測の段階でノイズの誤検知やP相・S相の取り違いにより、誤った震源を決定してしまうことも多い。一次検測の段階でノイズの誤検知や相の取り違いを減らすことができれば、PF法の震源精度はさらに向上すると期待される。本研究では、ノイズ/P相/S相の識別を行うモデルを畳み込みニューラルネットワーク(CNN)により構築し、気象庁の保有する検測値、地震波形データを与えて学習させ、その精度を検証する。また、PF法と組み合わせることによって、PF法の震源がどのように変化するかを検証する。

2017年から2018年4月1日までの間に、気象庁一元化地震カタログに記載のあるK,k登録(精度が良く、手動で検測された、低周波地震以外の)イベントの各観測点でのP・S相の検測時刻周辺の4秒間を入力する波形データ(計80万個以上)、相の種類をラベルとして学習モデルに与える。なお、ノイズ波形データはP相到達前の4秒間の波形とする。そして、学習する地震のマグニチュードや、波形のフィルターバンクの有無を変更することにより、複数の学習済みモデルを作成する。フィルターバンク無しの場合は、2 Hzのハイパスフィルターを適用した3成分(上下・南北・東西)波形のみを入力として、学習を行う。一方、フィルターバンク有りの場合は、フィルターなし・2-8 Hzのバンドパスフィルター、5 Hzのハイパスフィルターの異なる周波数帯域でのフィルターを適用した、3種類の3成分波形を入力として、学習を行う。その後、一元化作業で使用される全ての観測点の、2019年4月1日に記録された24時間の連続地震波形データを用いて、学習済みモデルの性能を検証する。検証では、まず連続波形に対しPF法による一次検測を行う(PF法一次検測値)。PF法一次検測値周りの波形を、上記モデルで相分類することにより、ノイズと判定された検測値の削除(デノイズ)や相種別の変更を行う(デノイズ済み一次検測値)。それとは別に、連続波形を4秒間ずつ1秒シフトで直接上記モデルに供給して相判別させ、その結果をさらに検測用CNNモデル(Ross et al., 2018に準拠)に入力した検測値(GPD一次検測値)も用意する。この3つの、PF法一次検測値、それぞれの学習モデルによるデノイズ済み一次検測値、GPD一次検測値をもとに、PF法による震源決定を行い、一元化地震カタログに記載のある震源と一致する数、および過剰な数の変化を比較することにより、各手法の評価を行う。

フィルターバンク無し・M2以上の地震波形を学習データに使ったモデルを、ノイズ確率99%以上の波形を削除するデノイザーとして使用したところ、一致数が410個、過剰が102個と、PF法一次検測値を用いた震源(一致: 412; 過剰: 144)に比べて、一致数をほぼ減らさずに、過剰を減らすことができた。一次検測値数に関しても、デノイズ前の1,243,804から81,620と、3割以上削減する。つまり、PF一次検測値のデノイズ処理により、計算処理時間の短縮や、過剰イベントの抑制といった、震源計算処理の効率化が期待される。同モデルを用いて、一定のP・S相確率値(60%, 70%, 80%, 90%)以上のGPD一次検測を行ったところ、PF法に比べて、一致数が大幅に減り、過剰数が増えてしまう。フィルターバンク有り・M2以上のモデルでも、デノイザーとして使った場合には、一次検測値数を大幅に減らした上で、一致数を減少させないが、GPD一次検測値では一致が減り、過剰

が増えるという, 同様の傾向が見られる.

一方, フィルターバンク有り・M0以上のモデルのGPD一次検測値(P・S相確率が99%以上)を用いたところ, PF法一次検測に比べ, 一致数が422・過剰数が238と, 一致・過剰ともに増加した. 過剰のうち, 一元化地震カタログに登録にない地震は97個とPF法(34個)の約3倍, ノイズ誤検知により決まった震源は23個でPF法(51個)の半分程度に留まった. これらは, ノイズによる誤震源を抑制しつつ, 地震検知能の更なる改善に寄与する可能性を示している. 一方で, 発破も108個とPF法(51個)の2倍以上となっており, 発破検知による過剰震源を抑制することが, 今後の課題である.

高ノイズ環境下における機械学習を用いた地震動検出の試み: 市民参加型地震計ネットワークの構築に向けて

Detection of seismic signals under low SNR condition using an artificial neural network: Toward development of dense low cost citizen seismic network in Japan

*金 亜伊¹、上松 大輝¹、中村 勇士¹、高橋 佑汰²、中村 桃子²

*Ahyi Kim¹, Hiroki Uematsu¹, Yuji Nakamura¹, Yuta Takahashi², Momoko Nakamura²

1. 横浜市立大学、2. 専修大学

1. Yokohama City University, 2. Senshu University

我が国では地震活動が極めて活発である事から高密度な強震観測網が展開されており、地震による大きな揺れが警戒される場合は基本的にどこにいても緊急地震速報を受信することができる。しかし、個人レベルの防災としては、地震による揺れが建物の状況に強く影響される以上、その地域の震度が自分の家の揺れ具合を正確に表しているとは言い切れない。この問題を解決する一つの案として、各家庭に設置できる地震計があればその場所での震度を計測したり、将来的にはその場所での強震動予測を可能にし、次取るべき行動を判断することができる可能性がある（自助）。そこで金他(2015)では市販の安価なMEMS加速度センサーとコンピュータRaspberry Piを組み合わせた小型センサーユニットを作成し、各家庭や公共施設に設置することを提案した。また、災害時における共助のためにそれらのユニットで地域市民参加型地震波計測ネットワーク（Citizen Seismic Network, 以下、CSN）を構築することを提案した。CSNセンサーユニットには平時から有事に利用できるアプリケーションが実装されているほか、ソーシャル・ネットワーキング・サービス(SNS)などと連動させることで市民間のつながりもでき、各地域での地震防災コミュニティネットワークの構築につながる事が期待される。このCSNセンサーユニットの実用化に向けた一つの問題点として、通常の強震計と比べ機械ノイズが高いこと、また設置場所が家庭や公共施設といった高ノイズ環境下であることからノイズと地震動の識別が難しいことがある。本研究ではそのような環境下でも地震動を正確に見分け震度を計算する事を目的に、人工ニューラルネットワーク(ANN)を導入した。CSNプロジェクトでは現在12箇所でCSNセンサーユニットを設置し加速度の観測を行っているが、観測した地震数はANNの学習や検出能力の検証に使用するには十分な数ではない。そこで本研究では既存の強震計より得られた地震データに本センサーのノイズを付加することで疑似データを作り出し、その波形を用いてアルゴリズムの検証を行った。現時点では横浜市強震計ネットワーク（以下、YKN）の保土ヶ谷観測点にて1997年5月12日から2012年9月14日得られた地震記録のうち、目視によってS波初動を認識できるものを選び、ANNの学習および検証に使用しているが、順次データを増やしていく予定である。ANNの学習では、学習を段階的に繰り返し、間違っってS波と判定した入力波形をノイズ教師データとして追加する段階学習を行った（e. g. 山中他, 2004）。この結果、一括学習に比べ学習精度を上げることができ、現在の判定に用いた100個の地震動のうち95%以上、計測震度2以上に限れば100%の地震動を検出することに成功している。しかしまだ誤検出もあるので、より学習データを増やして精度を高めていく。発表では開発中のセンサーネットワークのシステムや上述のアプリケーションも併せて紹介する予定である。

理論地震波形記録の時空間伝播を教師データとした機械学習による震源決定の試み

Development of neural network to locate hypocenter with theoretical seismograms of time series as learning data

*杉山 大祐¹、坪井 誠司¹

*Daisuke Sugiyama¹, Seiji Tsuboi¹

1. 海洋研究開発機構

1. JAMSTEC

我々は、昨年の地震学会秋季大会において、現実的な3次元地球モデルを用いた理論地震波形記録を教師データとして機械学習を行うことにより、震源パラメータの推定を行うニューラルネットワークを構築する試みを日本列島規模の観測網に適用した例について報告した。

前回の発表では、日本列島規模の領域について、陸上の観測点を想定した理論地震波形記録に基づく地表の変位分布画像を用いて、機械学習によりニューラルネットワークを構築することを試み、観測点分布が偏った場合でも震源パラメータの推定を行うことが可能であることを示した。また、変位分布画像の時系列を教師データとした3DCNNの適用についても検討したが、学習時間がかかるために、変位分布画像のみを用いた場合との比較で精度の向上が図れるかについては十分な比較ができなかった。今回、我々はこの3DCNNを用いた震源パラメータ推定の結果について報告し、十分な精度を得られることを示す。

理論地震波形記録は、前回と同様にスペクトル要素法のSPECFEM3D_GLOBE (https://geodynamics.org/cig/software/specfem3d_globe/)を用い、256コアを使って1 chunkを用いて計算した。モデルの精度を表すパラメータであるNEXは256で、用いた3次元地球モデルはS20RTS、精度は周期17秒である。2分間の理論地震波形を約4200個の地震に対して計算し、約300万枚の地震波伝播画像を生成した。

生成した画像を基に、震源パラメータを推定するニューラルネットワークの構築を試みた。ニューラルネットワークは深層学習でよく使われるConvolutional Neural Network (CNN)を3次元に拡張した3DCNNで、convolutionは3層とし、0.2秒毎の画像20枚、すなわち4秒間の時系列から、各パラメータを推定するネットワークを機械学習により生成した。画像の例とネットワーク構成を図1に示した。ニューラルネットワークのフレームワークはTensorFlow (<https://github.com/tensorflow>)を用いた。機械学習は画像の4/5を用い、学習のパラメータ設定を海洋研究開発機構・地球情報基盤センターが運用するDAシステムのGPGPUノードを使用して行った。学習にあたっては教師データをすべてメモリに格納することで、5個の震源パラメータの各120エポック分の学習を78GPU時間で終了することが出来た。学習により構築したニューラルネットワークに対して残り1/5の地震を用いて検証を行った。検証結果は推定した緯度と経度の誤差の標準偏差がそれぞれ0.05°と0.11°であり、日本列島規模の陸上観測点分布による地表の変位分布画像の時系列データを教師データとして、震源パラメータを推定するニューラルネットワークを構築することが可能であることが分かった。

また、我々は、理論地震記録の時系列を含めた学習を発展させるため、時系列に並べた空間伝搬データのそれぞれの前後ステップの動き特徴をベクトル特徴量として抽出することを試みた。動きの特徴の抽出にはOpticalFlowを用い、計算アルゴリズムにはGunnar-Farneback法 Farneback, et al.(2003)を採用した。計算時の詳細なパラメータについては発表の際に報告する。時系列に並べた空間伝搬データに適用して計算を行うことで、その地震波の空間伝搬のベクトル特徴量(図2)が得られる。このようなベクトル特徴量を解析し、地

震波への適用可能性や学習モデルへの組み込みの可能性など検討した結果について報告する。

謝辞

本研究は科研費19K12011の助成を受けたものです。この研究では海洋研究開発機構・地球情報基盤センターの計算機システムを用いました。記して感謝いたします。

図1 地震波動伝播画像の時系列とネットワーク構成





図2 ある地震における地震波の空間伝搬のベクトル特徴量の推移。
tは発震時からの経過時間を示し、左図が空間伝搬図。中図がベクトル特徴量の向きの矢印図。右図がベクトル特徴量を色に対応させた図。



畳み込みニューラルネットワークに基づく地震波形画像からの深部低周波微動検出に向けた数値実験

Numerical experiments towards detection of deep low-frequency tremors from seismic waveform images via convolutional neural network

*金子 亮介¹、長尾 大道^{1,2}、伊藤 伸一^{1,2}、小原 一成²、鶴岡 弘²

*Ryosuke Kaneko¹, Hiromichi Nagao^{1,2}, Shin-ichi Ito^{1,2}, Kazushige Obara², Hiroshi Tsuruoka²

1. 東京大学大学院情報理工学系研究科、2. 東京大学地震研究所

1. Graduate School of Information Science and Technology, The University of Tokyo, 2. Earthquake Research Institute, The University of Tokyo

概要：

深部低周波微動は防災科学技術研究所高感度地震観測網Hi-netの構築によって初めて観測的に見出された[1]ため、それに関するデジタルデータは直近の約20年分しか存在しない。数十年～数百年という地震発生サイクルの時間スケールを考えると、過去の地震波形データにスロースリップイベントに伴う深部低周波微動が記録されているかどうかを詳しく調べ、その特徴をさらに明らかにすることは、地震学において当然検討すべき重要課題である（例えば [2]）。

現在のようなデジタル記録以前においては、地震波形データはペンによって振動を連続的に記録紙に直接書き記したドラム式のアナログ紙記録として保存されていた。このようなアナログ紙記録には、深部低周波微動や通常の地震などの自然現象や、波浪起源の脈動や人為的振動などに由来するノイズの振動が記録されているだけでなく、一定時間ごとに挿入される刻時のためのパルス波形、ペンまたは記録紙の駆動部分の不具合が原因と思われる不自然な波形、ペンの消耗や記録紙の交換によって発生したと思われるデータの欠損なども含まれる。そのため、深部低周波微動を解析対象とする場合、その振幅は微弱でノイズとほぼ同等であり、しかも刻時パルスなどが重畳するため、微動の波形をデジタイズし解析に用いることは極めて困難である。


本研究では、畳み込みニューラルネットワークに基づき、アナログ紙記録から深部低周波微動を自動で検出するためのアルゴリズム開発を目指す。畳み込みニューラルネットワークとは、主に画像認識や手書き文字認証などで用いられる深層学習の手法の一種であり、人間の視覚細胞のはたらきを層の重なりによって数理的なモデルとして表現するのが特徴である。2010年代に入ってから画像認識のタスクにおいて従来の手法を遥かに上回る性能を発揮したことで注目されるようになり、現在ではスマートフォンのアプリなど我々の身近なものまで支える技術である。畳み込みニューラルネットワークの学習において人間が指定するのは主にモデルの構造のみであり、画像から特徴を抽出するために必要な内部のパラメータのチューニングはすべてコンピュータによって自動的に行われるため、人間の労力をあまり必要としない上に人間の画像認識の精度を上回る結果を得られることが期待される。そのため、モデルの構造や学習手法に関する研究は現在も盛んに行われている。例えば、2016年に発表されたResidual Network (ResNet) [3]においては、残差学習の考え方を取り入れており、一定数の層を通過したあとの出力値に元々の入力値を足し合わせるShortcut Connectionと呼ばれるシンプルな構造をモデルに組み込むことによって、深層化による過学習やパラメータ数の増加などのデメリットを軽減しつつ汎化性能を向上させることに成功している。

はじめから多種多様のノイズが入った実データを用いて一からモデルを学習させるのは困難であるため、まずは実際のアナログ記録を参考に振動現象や観測ノイズを模した疑似データを作成し、ノイズの大きさや種類を変えながらモデルの学習を行う。背景ノイズとして脈動を再現した波形と正規ノイズを加え、深部低周波微動が観測された場合と観測されなかった場合の疑似画像をそれぞれ作成し、ResNet と同じくShortcut Connectionの構造を持ったモデルにおいて学習を行った。脈動および微動を再現する波形については、正規ノイズを実際の周波数帯域に合わせてパワースフィルタに通過させることによって作成した。その結果、図


(a)のように学習済みモデルは微動の観測の有無をほぼ確実に正しく判定することができた。また、Grad-CAM [4]に基づきモデルの判定に影響を与えた部分を可視化したヒートマップを作成したところ、図(b)のように微動が観測された場合のデータに関して微動の発生時間帯まで正しく検出できることが確認できた。最終的には実データと同レベルのノイズが入った疑似データで学習させたモデルを初期モデルとして、そこから実データによる学習を行うというファインチューニングと呼ばれる手法を用いる。本研究の目標であるアナログ紙記録からの深部低周波微動の自動検出が達成されれば、現在よりも長期間の深部低周波微動に関するデータベースの構築が可能になることが期待される。

参考文献

- [1] K. Obara, Nonvolcanic deep tremor associated with subduction in southwest Japan, *Science*, 296, 1679-1681, 2002.
- [2] M. Kano and Y. Kano, Possible slow slip event beneath the Kii Peninsula, southwest Japan, inferred from historical tilt records in 1973, *Earth, Planets and Space*, 71(95), 2019.
- [3] K. He, X. Zhang, S. Ren and J. Sun, Deep residual learning for image recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [4] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh and D. Batra, Grad-CAM: Visual explanations from deep networks via gradient-based localization, *International Journal of Computer Vision*, 128, 336-359, 2020.



(a) モデルの学習結果



(b) Grad-CAM に基づくヒートマップ

Machine learning models for aftershock forecasting: Application to the 2016 Kumamoto earthquake sequence

*Hanyuan Huang¹, Hiroe Miyake¹

1. Earthquake Research Institute, University of Tokyo

Machine learning techniques are becoming increasingly prevailing in seismology contributed by the increasing amount of observable information. Considering that the research of seismology now is largely motivated by data from past earthquakes and machine learning mechanism enable itself to extract features and identify unseen signals which may help with earthquake prediction. This research is trying to use mathematically computed parameters known as seismicity indicator to forecast aftershocks on a certain day after the 2016 Kumamoto earthquake sequence. We here used the machine learning techniques as Multiple Linear Regression, Neural Network, k-Nearest Neighbors, and decision tree. To built the dataset based on the unified earthquake catalog extracted from Japan Meteorology Agency, we chose the data including time, magnitude, depth in the range from 1 January 2000 to 1 January 2020 whose magnitude is over 2.0 and depth is shallower than 30 km, in the region of the longitude of 130.0 to 131.3 and the latitude of 32.0 to 33.3, which is located around Kumamoto. To train the model, according to the original data, we refined the data in the unit of a day and count the maximum magnitude, sum number of earthquakes, mean magnitude in one day. Then we calculated the statistic information, the mean value, median value, and maximum value of the magnitudes during the time elapsed 30, 60, 90, 365, and etc., before the target date, and also the mean depth and earthquake energy. However, the linear correlation among energy, depth, and numbers of earthquakes are extremely low even leading the model to perform negatively. Finally, we only use the statistic value of magnitude in different time series as the training features. Few revised training datasets are also applied to different models. We divided the data set and the first 80%, from 1 January 2000 to 31 December 2015, is taken as the training set, the last 20%, from 1 January 2016 to 1 January 2020, is taken as the test set. The 2016 Kumamoto earthquake sequence occurred in April 2016, a series of aftershocks occurred in the Kumamoto region. However, earthquakes with magnitudes over 6 and depth shallower than 30 km have never shown up during the past 20 years in Kumamoto. So, we prepared to focus on the aftershock forecasting after 14 April 2016, the day when the earthquake with magnitudes greater than 6.0 firstly occurred. We tried to forecast the maximum magnitude sequence after the large earthquake in the Kumamoto region. About the results, when observing the training set and its prediction results in many models, because of the huge difference between the quantities of low magnitude earthquakes and high magnitude earthquakes, we found the predicted values are proportionally small compared to real value even when relatively large earthquakes occurred. Because we focus on the sequential series maximum magnitude of each day after the large earthquake, we multiple parameter α (=maximum magnitude in training set/maximum magnitude in prediction results) for each forecast results, which led the models confirmed real values better on high magnitudes. The evaluations for models are based on the loss between real maximum magnitude and predicted maximum magnitude in a day during different forecasting duration. We found the four models performed with relatively good accuracies during 30 days elapsed after 4 June 2016, the first M6.5 earthquake occurred, but deviation increased slightly with time elapsed which may be triggered by the increment of days without earthquakes with magnitude greater than 2.0 occur while these models performed less precisely on that. Focusing on the forecasting duration one month later, the four models also exhibited different characteristics. The Multiple Linear Regression and Neural Network models both predicted magnitudes with low loss, but the Multiple Linear Regression model seems strongly influenced by several certain features leading the prediction of model performed somehow similar to the maximum

magnitude on the last day, which showed low robustness. The decision tree predicted with relatively high loss, and it successfully fit the increasing trend of the M7.3 mainshock. In all the models, the Neural Network model which yielded good prediction accuracies whose mean the loss is around 0.5 performed good robustness and is considered can be applied for future magnitude forecast when earthquakes with magnitudes greater than 6.0 occur again in the Kumamoto region.