

B会場 | 特別セッション：S21. AIによる地震学の発展

■ 2022年10月25日(火) 10:00 ~ 11:30 | 会場 B会場 4階 (大会議室)

[S21] AM-1

座長:久保 久彦(防災科学技術研究所)、直井 誠(京都大学防災研究所)、岡崎 智久(理化学研究所 革新知能総合研究センター)

10:00 ~ 10:15

[S21-01] [Invited] Detecting slow slip events and accompanying tectonic tremor in geodetic and seismic data, using machine learning

*ROUET-LEDUC Bertrand¹ (1. DPRI, Kyoto University)

10:15 ~ 10:30

[S21-02] 畳み込みニューラルネットワークに基づく西南日本で得られた地震波形紙記録からの深部低周波微動の検出

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

10:30 ~ 10:45

[S21-03] Physics-Informed Neural Networksのばねブロックモデルへの適用

*福嶋 陸斗¹、加納 将行²、平原 和朗^{3,4} (1. 京都大学理学部、2. 東北大学理学研究科、3. 理化学研究所、4. 香川大学)

10:45 ~ 11:00

[S21-04] 地震学逆解析における最適輸送に基づく波形間の距離指標

*岡崎 智久¹、上田 修功¹ (1. 理化学研究所 革新知能総合研究センター)

11:00 ~ 11:15

[S21-05] 機械学習を用いた擬似速度応答スペクトルの予測に関する研究
ーその1 近畿地方の地殻内地震の応答スペクトルのシミュレーションー*川辺 秀憲¹、魏 天増¹、寺藺 快¹ (1. 大阪大学)

11:15 ~ 11:30

[S21-06] 1次元畳み込みニューラルネットワークによる速度応答スペクトル予測

*田屋 大輝¹、古村 孝志¹ (1. 東京大学地震研究所)

[Invited] Detecting slow slip events and accompanying tectonic tremor in geodetic and seismic data, using machine learning

*Bertrand ROUET-LEDUC¹

1. DPRI, Kyoto University

Faults can accommodate stress in a variety of slip modes, from dynamic rupture to slow slip events and aseismic slip. Among these slip modes, slow slip events and often-accompanying tremor remain among the most elusive and poorly understood.

Unraveling the interactions between slip modes is at stake: while laboratory experiments point to aseismic nucleation generally preceding dynamic rupture, observations in the field are far from systematic, and more the exception than the rule.

However, the difficulty in detecting transient slow slip events, either seismically or geodetically, points to a possible observational gap that may explain the rarity of slow deformation detected prior to dynamic earthquakes.

In this presentation, the use of machine learning to improve the detection of slow slip events and accompanying tectonic tremor will be explored, as a tool to fill this observational gap, both in seismic data and in geodetic data.

畳み込みニューラルネットワークに基づく西南日本で得られた地震波形紙記録からの深部低周波微動の検出

Detection of Deep Low-Frequency Tremors from Continuous Paper Records at a Station in Southwest Japan About 50 Years Ago Based on Convolutional Neural Network for Seismogram Images

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

Ryosuke Kaneko^{2,1}, *Hiromichi NAGAO^{1,2}, Shin-ichi Ito^{1,2}, Hiroshi Tsuruoka¹, Kazushige Obara¹

1. 東京大学地震研究所、2. 東京大学大学院情報理工学系研究科

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

The establishment of the High Sensitivity Seismograph Network (Hi-net) in Japan has led to the discovery of deep low-frequency tremors. Since such tremors are considered to be related to large earthquakes adjacent to tremors on the same subducting plate interface, it is important in seismology to investigate tremors before establishing modern seismograph networks that record seismic data digitally. We propose a deep learning method to detect evidence of tremors from seismogram images recorded on paper more than 50 years ago. In our previous study, we constructed a convolutional neural network (CNN) based on the Residual Network (ResNet) structure and verified its performance through learning with synthetic images generated based on past seismograms. In this study, we trained the CNN with seismogram images converted from real seismic data recorded by Hi-net. The CNN trained by fine-tuning achieved an accuracy of 98.64% for determining whether an input image contains tremors. The Gradient-weighted Class Activation Mapping (Grad-CAM) heatmaps to visualize model predictions indicate that the CNN successfully detects tremors without affections of a variety of noises, such as teleseisms. The trained CNN was applied to the past seismograms recorded at the Kumano observatory, Japan, operated by Earthquake Research Institute, The University of Tokyo. The CNN shows the potential to detect tremors from past seismogram images for broader applications, such as publishing a new tremor catalog.

Physics-Informed Neural Networksのばねブロックモデルへの適用

Application of Physics-Informed Neural Networks to spring-slider model

*福島 陸斗¹、加納 将行²、平原 和朗^{3,4}

*Rikuto Fukushima¹, Masayuki Kano², Kazuro Hirahara^{3,4}

1. 京都大学理学部、2. 東北大学理学研究科、3. 理化学研究所、4. 香川大学

1. Kyoto University Faculty of Science, 2. Tohoku University Faculty of Science, 3. RIKEN, 4. Kagawa University

微分方程式を解く方法として、近年新たにPhysics-Informed Neural Networks (PINNs)が提唱された(Raissi et al., 2019)。これは物理法則に従う微分方程式と初期条件や境界条件を損失関数に取り込むことにより、その両方を満たすようなニューラルネットワーク(NN)を構成し、対象とする方程式の解を求める方法である。従って、PINNsにより得られた解は物理法則を満たすものであり、物理的に解釈が可能という点で従来のNNとは大きく異なっている。このように、PINNsによる微分方程式の解法は従来の求解法と大きく異なっているが、従来に比べて少ない計算量で大規模計算が可能、経験則を含む物理的に不完全なモデルにも対応でき柔軟なモデリングが可能、逆問題の解法が容易などの利点がある。地震学の分野においても、波動方程式を用いた地震波伝播の計算(Karimpouli et al., 2020)やdislocationモデルを用いた静的変位の計算(Okazaki et al., 2022)など、PINNsを用いた研究が行われ始めている。

本研究では、断層すべりの時空間発展の数値計算にPINNsを用いることを念頭に、PINNsをばねブロックモデルに適用しスロースリップ(SSE)の再現を試みた。初めに、時間ステップ可変のRunge-Kutta法を用いて準動的運動方程式と摩擦構成則を解き、SSEが再現可能な摩擦パラメータを試行錯誤的に探索した。その結果、再来間隔が2.5年程度、最大すべり速度がプレート速度の10倍程度、継続時間が150日程度のSSEの繰り返し再現可能な摩擦パラメータを求めた。以下で行うPINNsを用いた計算ではこの摩擦パラメータは固定する。また、再現されたSSEのうち1回のSSEのサイクルに注目し、すべり速度が最小になった時刻を初期時刻、その時のすべり速度と状態変数を真の初期値として定義し、その際計算される1回のSSEの時間発展をPINNsで再現することを目的とする。

このような設定の下、損失関数を真の初期値からのずれを表す初期条件の二乗平均誤差と、微分方程式に従った挙動からのずれの二乗平均誤差の重み付き和で定義し、損失関数が最小になるようにNNの学習を行う。初期条件の誤差と微分方程式の誤差の重みは試行錯誤的に決定した。この際、NNの入力はある1つの時刻であり、出力としてその時刻に対応したすべり速度、状態変数の2変数が返される。PINNsでは任意に選んだ多数の評価時刻を順に用いてNNの学習を行い微分方程式の解を求める。この学習に用いる評価時刻の選択には任意性があるため、ここでは、1) 事前の時間ステップ可変のRunge-Kutta法による計算から求まる不等間隔($\Delta t = 10 \sim 867$ hour)の評価時刻と、2) 時間間隔が一定($\Delta t = 50$ hour)の評価時刻、の2種類を用いて学習を行い、計算結果を比較した。なお時間をNNに入力する際は規格化を行っている。また本研究では9層の全結合NNを採用し、活性化関数としてtanh関数を用いた。各層のノード数は入力層が1、中間層がすべて20、出力層が2である。

その結果、等間隔・不等間隔の両方の評価時刻において、それぞれ適切な重みパラメータ下では安定して学習が行われ、正確にSSEの時間発展を再現することができた。また、等間隔においては用いる間隔の大きさを $\Delta t = 50$ hourから長めに变化させてそれぞれ計算を行ったが、最初に仮定した時間間隔の8倍($\Delta t = 400$ hour)を用いても正しい解が求められた。加えて、評価時刻以外の時刻、すなわちNNの学習に用いていない時刻を入力にした場合においても、正しくSSEのすべり速度を再現することに成功した。

地震学逆解析における最適輸送に基づく波形間の距離指標

Optimal Transport Distance Measure in Geophysical Inversion

*岡崎 智久¹、上田 修功¹

*Tomohisa OKAZAKI¹, Naonori Ueda¹

1. 理化学研究所 革新知能総合研究センター

1. RIKEN AIP

地震学の逆解析において、波形間の距離指標の定義が推定結果や計算効率に重要である。近年、確率分布間の距離であるWasserstein距離が従来のL2距離の欠点を解消しうる指標として注目されている。Sambridge ら (2022)は波形のグラフを2次元確率分布に変換した後、時間軸・振幅軸に周辺化した1次元確率分布のWasserstein距離を計算することで、波形を自然に確率分布に変換するとともに高い計算効率を実現した。しかし、正負の値を取る地震波形を確率分布に変換する方法に依然課題がある。

本研究ではSambridgeらの手法では、1次元確率分布への周辺化により距離指標に顕著な縮退が生じ、例えば、逆位相の正弦波の間の距離が0となるという問題を指摘する。その解決法として、計算効率を維持しつつ距離の頑健性を高めるため、sliced Wasserstein距離(Bonneel et al. 2015)の適用を提案する。Sliced Wasserstein距離は一般次元の確率分布に対し、ある方向に射影して得られる1次元確率分布のWasserstein距離を全方向にわたって積分平均することにより定義され、実用上は有限個の方向に対する平均で近似される。本研究では、Sambridge ら (2022)による時間軸・振幅軸に加え、それらと45度をなす2方向に射影した計4方向の1次元 Wasserstein距離の平均を用いることで、正弦波に対し距離の頑健性が向上することを示す。

機械学習を用いた擬似速度応答スペクトルの予測に関する研究

ーその1 近畿地方の地殻内地震の応答スペクトルのシミュレーションー

Study on prediction of pseudo velocity response spectrum by machine learning

-Part1 Response spectrum simulation for crustal earthquake in Kinki district, Japan-

*川辺 秀憲¹、魏 天増¹、寺園 快¹

*Hidenori KAWABE¹, Tianzeng WEI¹, Kai TERAZONO¹

1. 大阪大学

1. Osaka University

1. はじめに

1995年の兵庫県南部地震以降、強震観測網の整備が進み、強震記録の数が大幅に増えている。膨大な強震観測記録を用い精度の高い地震動予測を行う方法として、近年、機械学習が注目されている。大規模な地震の際に構造物の被害を軽減するためには、構造物の建設地点において精度の高い地震動予測が必要である。そこで、本研究では耐震設計を行う際に一つの指標として用いる擬似速度応答スペクトルを対象として、機械学習を用いた予測モデルの構築を目指す。その1（本稿）では、近畿地方の地殻内地震について、対象地域の全ての観測点を対象として予測モデルを構築を目指す。その2では、九州地方を対象として2016年熊本地震の記録を用い、観測地点ごとの最適な予測モデルについて検討する。その3では、東日本を対象として、地殻内地震の予測モデルについて検討する。


2. 検討対象地震及び観測記録

検討対象の地震は、1997年1月から2021年11月までに近畿地方で発生したMj4以上の地殻内地震とする。具体的には、東経134度から137度、北緯33度から36度、深さ20km以浅で発生した地震を対象とする。観測記録は、防災科学技術研究所のK-NET及びKiK-netの地表の記録を用いる。なお、P波の立ち上がりがない波形及びSN比が悪い波形は除外する。結果として、98の地震に対して、計5580個の観測記録を選定した。


3. 解析の概要及び解析結果

予測の対象は水平2成分の減衰5%の擬似速度応答スペクトルとする。本検討では、擬似速度応答スペクトルの予測対象周期は0.25秒から10秒までとし、周期間隔は周期0.25秒とする。ここでは、機械学習のアルゴリズムのうち、深層学習とXGBoostを用いて目的変数とする周期毎の擬似速度応答スペクトルの値の最適な予測モデルの作成を目指す。両手法の周期毎の予測精度を比較し、精度がより高い手法を用いて近畿地方の擬似速度応答スペクトルの予測モデルを構築する。震源の位置及びマグニチュード、震源のメカニズム解、観測点の位置、観測点の地下構造などの情報を組み合わせて複数の入力変数の組み合わせを設定する。一例として、深層学習とXGBoostを用いて計算した観測点ごとの周期0.5秒の擬似速度応答スペクトルと観測記録から計算した擬似速度応答スペクトルの比較を図1に示す。なお、この図の計算では、入力変数（特徴量）を震央距離、方位角、Mj、震源深さ、AVS30、地震基盤深さとしたときの結果である。この図から、XGBoostを用いたほうが、観測記録の再現精度がよいことがわかる。本発表ではこれらの検討結果と最適な予測モデルについて紹介する。

謝辞：本研究では、気象庁および防災科学技術研究所のF-netの震源情報、K-NETおよびKiK-netの地震記録、ならびにJ-SHISの地下構造モデルを使用させて頂きました。ここに記して感謝いたします。



(a) 深層学習



(b) XGBoost

図1 周期0.5秒の計算結果の比較

1次元畳み込みニューラルネットワークによる速度応答スペクトル予測

Prediction of velocity response spectrum by using a 1-D convolutional neural network

*田屋 大輝¹、古村 孝志¹

*Daiki Taya¹, Takashi Furumura¹

1. 東京大学地震研究所

1. Earthquake Research Institute, University of Tokyo

1. はじめに

大地震が生じた際に長周期地震動の早期予測を行うことは、高層ビルが密集する大都市圏の防災において重要な役割を持つ。2004年新潟県中越地震では関東平野において周期数秒の長周期地震動が強く生成し、都心の超高層ビルのエレベーターケーブルが一部損傷するなど被害が生じた。

機械学習は画像認識や自然言語処理の分野で広く活用されており、近年、地震学の分野でも機械学習の活用が進み、地震波形データからマグニチュード推定 (Ristea et al., 2021) や広域の最大加速度 (PGA) の予測 (Jozinović et al., 2020 ; Kubo et al., 2020) などへの活用が進められている。本研究ではこれらの既往研究を発展させ、震源域近傍での強震観測データから遠地の平野の評価地点の速度応答スペクトルを予測する機械学習モデルを検討した。

2. データ・手法

本研究では、新潟県周辺地域で発生した地震を対象として、Hi-net高山観測点 (TAYH : 群馬県高山村) での速度波形データから、Hi-net富岡観測点 (YFTH : 横浜市金沢区) の速度応答スペクトルの予測を行った。2観測点間は約150 km離れており、長周期地震動を形成する表面波の到達には約55秒の時間差がある。なお、事前調査によりYFTHとTAYHとの観測波形とのコヒーレンシーが高い (0.9) ことを確認し、TAYHを予測の入力データ地点として選定した。

学習データには、東経136.4度~139.1度、北緯36.9~38.7度の範囲で2004年4月~2007年10月に発生したMw4.5以上の地震33個について、5分間のHi-net速度波形データを用いた。これらの震源およびMw分布を図1に示す。前処理として、Hi-net波形データには地震計特性補正フィルタ (Maeda et al., 2011) をかけて広帯域化し、0.05~2 Hzのバンドパスフィルターをかけた後に20 Hzにリサンプリングした。また、予測地点における周期0.05~100秒の範囲の速度応答スペクトル (減衰定数5%) を求め、入力波形データとペアとなる教師データセットを用意した。なお、入力波形データは最大速度 (PGV) 値で規格化を行った後に、 $\log(\text{PGV})$ を乗じて振幅の大小の情報を一部残した。また、速度応答スペクトル値も対数化し、振幅を1/10にすることで、予測データの値が0~1の範囲に収まるようにした。

予測モデルは、先行研究のJozinović et al. (2020) によるCNNモデルの構成を参考にしてPythonのKerasライブラリを用いて作成した。本モデルでは1次元データ長6000ポイントの地震波形を3段の畳み込み層に入力し、畳み込み結果を平滑化したのち全結合層を通してデータ長200ポイントの速度応答スペクトルを出力する。活性化関数にはRelu関数を用い、最後の全結合層は学習の収束のために ± 1 で頭打ちとなるtanh関数を用いた。損失関数は観測と予測応答スペクトルの二乗誤差を評価するものを用い、バッチサイズ32で70エポック数の学習を行い、損失率の収束を確認した。なお、ここでは1成分 (EW成分) の予測を行うものとするが、平行して他成分の予測も同様に行うことができる。

3. 結果

学習済みモデルを用いて、新潟県周辺で2011年以降に発生したMw4.5以上の11個の地震の予測性能を確認した。性能評価は、速度応答スペクトルの予測/観測比を周期1~15秒の範囲で平均した値を用いて行った。図2(a)に、2011年3月12日に新潟/長野県境で発生した長野県北部地震 (栄村地震) の予測結果 (赤) と観測値 (黒) を比較する。予測性能の評価値は0.96となり、速度応答スペクトルの良い予測が確認された。図

2(b)に、予測を行った11個の地震の性能評価値の範囲の四分位数を、箱ひげ図を用いて示す。予測の四分位は0.6~1.4の範囲に入っており、やや幅はあるものの実用上十分な予測精度を持つと言える。

次に、地震観測期間とともに学習データを増やすことで予測精度の変化を確認した。2004~2007年の観測データを用いた学習済みモデルに対して、さらに2007~2010年に発生した24個の地震を学習データに追加した。追加学習は、先の学習済みモデルに対して、新たな学習データで再学習する転移学習により行った。図2(b)右に転移学習モデルによる予測性能の評価値を示す。先の予測モデルによる結果と比較して、予測性能の四分位範囲が0.7~1.2に狭まっており、転移学習による予測性能の向上が確認された。

4. まとめと今後の展望

本研究で作成した機械学習モデルにより、震源近傍の観測点での波形データから遠地の平野の長周期地震動の速度応答スペクトルの予測を行った。地震観測データの蓄積に伴い、日常的に転移学習を繰り返し進めることで、予測性能の向上が期待できる。一方で、本予測モデルでは2019年山形県沖地震(Mw6.8)など、予測性能評価値が低い(0.59)ケースも確認され、これは転移学習後(0.55)も大きく改善されなかった。これは、山形県付近の地震活動が低いことが原因と考えられる。転移学習においても学習データのMw分布の偏りに注意が必要であり、Mwの小さな学習データを増やしすぎるとかえって大地震の予測性能が低下する可能性がある。




図1 (a) 学習に用いた地震の震源分布。赤○は2004～2007年の33個の地震、青○は転移学習に用いた2007～2011年の24個の地震。黄☆はテストに用いた11個の地震。(b)それぞれの地震の規模分布。




図2 (a) 横浜地点 (YFTH) における速度応答スペクトルの予測結果 (赤) と観測 (黒) の比較 (2011年3月12日長野県栄村の地震の例)。青線は、2007年～2011年の転移学習データを用いた予測結果。(b)11個の地震の速度応答スペクトルの予測結果の分布 (左:2004～2007年の地震による学習、右:2007～2011年の地震による転移学習)。