

Wed. Sep 18, 2019

ROOM C

Room C | Special session | S22. Potentiality of Machine Learning in Seismology

[S22]AM-1

chairperson:Takahiko Uchide(Geological Survey of Japan, AIST), Hisahiko Kubo(NIED)

9:15 AM - 10:30 AM ROOM C (Research Bldg No 8 NS Hall)

[S22-01] [INVITED]Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy

*Jun Ogata¹ (1. Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy)

9:15 AM - 9:45 AM

[S22-02] Seismic Phase Picking based on Sparsity-Aware Change Detection

*Hiroki Kuroda¹, Jun Ogata¹, Hidenori Sakanashi¹, Takahiko Uchide² (1. Artificial Intelligence Research Center, National Institute of Advanced Industrial Science and Technology, 2. Geological Survey of Japan, National Institute of Advanced Industrial Science and Technology)

9:45 AM - 10:00 AM

[S22-03] Automatic P-wave detection using deep learning and visualization of the decision process

*Shota Hara¹, Yukitoshi Fukahata², Yoshihisa Iio² (1. Graduate School of Science, Kyoto University, 2. Disaster Prevention Research Institute, Kyoto University)

10:00 AM - 10:15 AM

[S22-04] Application of convolutional neural networks to continuous seismic network records

*Keisuke Yano¹, Takahiro Shiina², Sumito Kurata¹, Aitaro Kato², Fumiyasu Komaki¹, Shin'ichi Sakai², Naoshi Hirata² (1. Department of Mathematical Informatics, The University of Tokyo, 2. Earthquake Research Institute, University of Tokyo)

10:15 AM - 10:30 AM

Room C | Special session | S22. Potentiality of Machine Learning in Seismology

[S22]AM-2

chairperson:Hisahiko Kubo(NIED), Yuki Kodera(Meteorological Research Agency, JMA)

10:45 AM - 12:00 PM ROOM C (Research Bldg No 8 NS Hall)

[S22-05] Development of 3D Convolutional Neural

Network to locate hypocenter with theoretical seismograms of time series as training data.

*Daisuke Sugiyama¹, Seiji Tsuboi¹ (1. JAMSTEC)

10:45 AM - 11:00 AM

[S22-06] Discrimination of earthquakes and tectonic tremor signals by applying a convolutional neural network to running spectral images

*Masaru Nakano¹, Daisuke Sugiyama¹, Takane Hori¹, Tatsu Kuwatani¹, Seiji Tsuboi¹ (1. JAMSTEC)

11:00 AM - 11:15 AM

[S22-07] An unsupervised automatic classification algorithm for continuous seismic records using a nonparametric Bayesian approach

*Yuki Kodera¹, Shin'ichi Sakai², Takahito Nishimiya¹ (1. Meteorological Research Institute, Japan

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

11:15 AM - 11:30 AM

[S22-08] Study on Site-specific Ground Motion Evaluation Models Utilizing Machine Learning Method Considering Epicentral Directions

*Toru Ishii¹, Atsuko Oana¹, Kensuke Wada¹ (1. Shimizu Corporation)

11:30 AM - 11:45 AM

[S22-09] Study on Ground Motion Evaluation Models for Kanto Region Utilizing Machine Learning Method

*Atsuko Oana¹, Toru Ishii¹, Kensuke Wada¹ (1. Shimizu Corporation)

11:45 AM - 12:00 PM

Room C | Special session | S22. Potentiality of Machine Learning in Seismology

[S22]PM-1

chairperson:Yuki Kodera(Meteorological Research Agency, JMA), Takahiko Uchide(Geological Survey of Japan, AIST)

2:30 PM - 4:00 PM ROOM C (Research Bldg No 8 NS Hall)

[S22-10] Improving the symmetry of ambient seismic field correlation functions with machine learning

*Loic Viens¹, Tomotaka Iwata¹ (1. Kyoto University, DPRI)

2:30 PM - 2:45 PM

[S22-11] A hybrid approach of Machine learning and Ensemble Kalman Filter for estimating frictional parameters in Nankai megaquake cycle simulator

*Yu Yamamoto¹, Kazuro Hirahara^{1,3}, Hirotaka Hachiya^{1,2}, Atsushi Takahashi¹, Naonori Ueda¹ (1.

Center for Advanced Intelligence Project, RIKEN, 2.
Univ. of Wakayama, 3. Univ. of Kagawa)

2:45 PM - 3:00 PM

- [S22-12] Acceleration of matched-filter search and slip inversion of deep tectonic tremor using nearest neighbor search

*Naoto Mizuno¹, Satoshi Ide¹ (1. School of Science, The University of Tokyo)

3:00 PM - 3:15 PM

- [S22-13] Machine learning of postseismic deformation of the 2011 Tohoku-Oki earthquake based on recurrent neural network

*Norifumi Yamaga¹, Yuta Mitsui² (1. Graduate School of Integrated Science and Technology, Shizuoka University, 2. Faculty of Science, Shizuoka University)

3:15 PM - 3:30 PM

- [S22-14] Automatic detection and classification of the uplifted marine terrace by clustering DEM dataset

*Junki Komori¹, Ryosuke Ando¹, Masanobu Shishikura²
(1. The University of Tokyo, 2. The National Institute of Advanced Industrial Science and Technology)

3:30 PM - 3:45 PM

- [S22-15] Investigation of Prediction Model for Engineering Geomorphologic Classification using Convolutional Neural Network

*Sho Akagi¹, Toshihiko Hayakawa¹ (1. Mitsubishi Space Software Co., Ltd.)

3:45 PM - 4:00 PM

Room C | Special session | S22. Potentiality of Machine Learning in Seismology

[S22]AM-1

chairperson:Takahiko Uchide(Geological Survey of Japan, AIST), Hisahiko Kubo(NIED)

Wed. Sep 18, 2019 9:15 AM - 10:30 AM ROOM C (Research Bldg No 8 NS Hall)

[S22-01] [INVITED]Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy

*Jun Ogata¹ (1. Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy)

9:15 AM - 9:45 AM

[S22-02] Seismic Phase Picking based on Sparsity-Aware Change Detection

*Hiroki Kuroda¹, Jun Ogata¹, Hidenori Sakanashi¹, Takahiko Uchide² (1. Artificial Intelligence Research Center, National Institute of Advanced Industrial Science and Technology, 2. Geological Survey of Japan, National Institute of Advanced Industrial Science and Technology)

9:45 AM - 10:00 AM

[S22-03] Automatic P-wave detection using deep learning and visualization of the decision process

*Shota Hara¹, Yukitoshi Fukahata², Yoshihisa Iio² (1. Graduate School of Science, Kyoto University, 2. Disaster Prevention Research Institute, Kyoto University)

10:00 AM - 10:15 AM

[S22-04] Application of convolutional neural networks to continuous seismic network records

*Keisuke Yano¹, Takahiro Shiina², Sumito Kurata¹, Aitaro Kato², Fumiyasu Komaki¹, Shin'ichi Sakai², Naoshi Hirata² (1. Department of Mathematical Informatics, The University of Tokyo, 2. Earthquake Research Institute, University of Tokyo)

10:15 AM - 10:30 AM

Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy

*Jun Ogata¹

1. Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy


本講演では、機械学習に基づくデータ駆動型異常検知技術、さらにそれらの実用化（どのように実環境・実現場で利用していくか）について、風力発電スマートメンテナンスの取り組みを事例として紹介する。

風力発電機等の大型産業機械の故障停止は、産業・社会に大きな影響を与える。現状は、こうした機器の維持管理のために法令に準拠した定期メンテナンスが実施されることが多い。一方で、機器の劣化、損傷等の経年変化をより正確に、かつ早期に把握することができれば、機器の不具合による危険事象を回避できるだけでなく、機器の状態に応じた費用対効果の高いメンテナンスが可能となる。そこで、近年のセンシング技術や情報通信技術の発展に伴い、遠隔での状態監視システム（Condition Monitoring System; CMS）への期待が高まっている。我々は、CMSにおいて加速度ピックアップから得られる振動データを解析の対象として、信号処理と機械学習に基づくデータ駆動型アプローチにより、異常予兆を精度良く検出するシステムの構築に取り組んでいる。これまでに、NEDO事業「スマートメンテナンス技術研究開発（分析）」（2013～2017年度）において、国内の複数の事業者の協力により、全国27サイト、43基の風車にCMSを設置させていただき、そこで収集された加速度振動データを活用して異常検知の研究開発を行ってきた。センサは風車の主要要素である主軸部、増速機、発電機に対して合計10箇所設置されており、異常検知システムは、各主要要素の異常発生箇所を詳細に特定するために、振動データごとに個別に学習・構築を行っている（1風車につき10の異常検知システムが稼働）。異常検知手法としては、正常稼働状態の振動データのみを学習・モデル化し、そこから乖離したときに異常と判断するアプローチ（外れ値検知）を適用している。本研究ではとくに、特徴量として時間・周波数領域の独自特徴量である「FLAC（フーリエ局所自己相関特徴量）」を導入することで、従来の振動分析法では困難であった主軸受や増速機低速部など低速回転の機器に対しても異常検知が十分可能となることを示した。以上の異常検知システムを実機風車の振動データに適用することで、部品交換意思決定の1～3ヶ月前での異常兆候検知を実現し、90%以上の異常予兆検出性能を達成できた。


一方、このようなデータ駆動型異常検知技術の実用化を進めるうえでは、システムの早期立ち上げ・運用が重要となる。例えば新しい監視対象機種やセンサを変更した場合など、一からデータを大量に蓄積して学習し直すのではなく、すでに他の環境で学習したモデル・結果を何らかの形で利用（転用）して、新たな環境で異常検知システムを効率的かつ早期に運用可能にできる技術が必要不可欠となる。このような枠組みは、機械学習では転移学習と呼ばれ、現在ホットな研究領域となっている。我々は現在NEDO事業「風車運用高度化技術研究開発」において、こうしたアプローチ（システム転用）を活用することで、あらゆる風車環境において異常検知の早期適用・運用を可能とする技術の研究開発を進めている。

前述の異常検知技術は異常予兆を早期に検知する能力としては有効であるといえるが、実際の風力発電事業の中で誰が、どのようにに活用するか、その最良な利用形態を確立することが重要である。我々は、異常検知技術（AI技術）と風力事業者（風車運用現場）をつなぎ、日々の風車メンテナンスを支援するためのインタフェースの研究開発を行っている。具体的には、異常検知の実行結果を各実機風車・機器ごとに可視化することで、いつでも・どこでも風車の状態を把握・検証できるWebアプリケーション「WindCastle」の実装・公開を行っている。異常検知技術の基礎的研究だけでなく、こうしたインタフェースの応用的研究開発を同時に進めるもう一つの狙いは、異常検知システムを、最新の情報（最新データ、ユーザからのフィードバック等）を活用することで継続的に更新・高度化していくことにある。異常検知をはじめとする人工知能技術では、一般的にその検知性能は学習に利用するデータの量や質に大きく依存する。前述の異常検知システムは特定のデータセットによる実験において高い性能を示したものの、実機風車では自然環境・条件の変動ならびに運用

状況の変化等，学習データ中にはない未知の特性・パターンに対していかに対処するかが大きな課題となる．すなわち，こうした「データからの学習」に基づく異常検知システムは，特定のデータセットで一度学習してそれを継続的に使い続ける，ではなく，実運用中においても性能を保つために，様々な変動に追従できるようなシステムを逐次更新（実データによる再学習）していくことが重要となる．



異常検知結果例ならびにWindCastleインタフェース画面



Webアプリケーションを通じた「メンテナンス利便性向上」と「持続的なシステム高度化」

Seismic Phase Picking based on Sparsity-Aware Change Detection

*Hiroki Kuroda¹, Jun Ogata¹, Hidenori Sakanashi¹, Takahiko Uchide²

1. Artificial Intelligence Research Center, National Institute of Advanced Industrial Science and Technology, 2. Geological Survey of Japan, National Institute of Advanced Industrial Science and Technology

P波・S波の初動時刻の自動検測は、特に微小地震の地震波データ解析の第一歩として、地震学の重要な課題の一つに位置づけられる。最近、地震カタログデータを用いた深層学習が自動検測で良好な検測精度を達成することが報告されている(e.g. Ross et al., 2018)。しかしながら、深層学習等の教師付き学習手法は、大量の学習データならびにそれらに対する正確なラベル（教師）情報が必要になる等、システム構築における労力が大きい。一方、入力された地震波形データから直接自動検測を行うアプローチは、深層学習以前より多くの研究がなされており、例えば、地震波形の短時間/長時間パワー比に基づくSTA/LTA法(e.g. Bungum et al., 1971)、自己回帰モデルに基づく手法(e.g. Takanami and Kitagawa, 1988; Leonard and Kennett, 1999)、これらを組合せた手法(Akazawa, 2004)が提案されている。こうした教師付き学習を介さないアプローチは、大量データが存在しない、あるいは地震カタログが整備されていない環境（臨時観測点等）においてもシステムを適用できるといった利便性がある。しかしながら、一定の検測精度を得るためには入力波形データごとに多数のパラメータの調整が必要となる等、システム適用時の問題があった。


信号処理・機械学習分野においても、変化検知問題（または信号セグメンテーション問題）として、地震波自動検測と共通の構造を持つ問題が活発に研究されてきた。とくに近年、時系列信号の潜在的スパース性を変化検知問題に活用するアプローチが注目を集めている(e.g. Angelosante and Giannakis, 2012; Han et al., 2015; Kuroda et al., 2018)。これらの研究は、変化検知問題がスパースベクトル（大半の成分が0のベクトル）の推定問題に帰着できることを明らかにしている。スパースベクトルの推定問題に対してはL1ノルム正則化等の強力な解法が知られているため、これらの解法の応用による精密な変化検知の実現が期待できる。このアプローチの利点として、時系列信号全体から主要変化を検知するため、ノイズへの頑健性が期待できることが挙げられる。また、手法が有するチューニングパラメータは一つのみであり、しかも所望の変化検知数を基準に決定できる。ただし、信号中のスパース性を精度良く顕在化させることは一般的に容易ではない。Kuroda et al. (2018)は低次元表現空間でスパース性を顕在化させることに成功しており、このスパース性を活用する手法はAngelosante and Giannakis (2012)やHan et al. (2015)等の手法と比べて計算コストが低く、数値実験でより優れた検知精度を達成することが確認されている。

本研究では、潜在的スパース性の顕在化による変化検知アルゴリズム(Kuroda et al., 2018)を地震波形データに適用し、自動検測における有効性を検証する。この手法で仮定する信号モデルとしては、次数2の区分的自己回帰モデルを与えた。実験例として、気象庁一元化処理震源カタログから2018年5月3日19時59分に茨城県北部で発生したM 1.6の地震を選び、防災科学技術研究所の高感度地震観測網(Hi-net)の3観測点（足尾(N.ASOH)、伊南(N.INAH)、大子(N.DGOH)）で測定された東西方向速度データに提案法を適用した。提案法が有するパラメータは、簡単のため、気象庁検測値付近の変化を含む条件の下で変化検知数が最小になるように決定した。足尾、伊南観測点については気象庁検測値がないため、気象庁一元化処理震源カタログの震源位置から理論的に計算した走時を使って、地震波到達時刻の目安とした。図1の結果から、提案法が気象庁検測値（または理論値）付近を含む少数の地震波変化を検知していることが確認できる。特に、足尾観測点と伊南観測点ではS/N比が悪いが、このような微小地震の波形データに対して、提案法はノイズ部分には変化を検出せず、地震に伴う変化のみを取り出すことができた。今後の課題として、情報量基準等の客観的指標を用いた変化検知数決定法の開発が挙げられる。また、多数の地震波形データに提案法を適用し、気象庁検測値との比較による性能評価を行う予定である。


謝辞 本研究では気象庁一元化処理検測値と防災科学技術研究所のHi-netの地震波形記録 (doi:10.17598/NIED.0003)を使用しました。

参考文献


Kuroda, H., M. Yamagishi, and I. Yamada, Exploiting Sparsity in Tight-Dimensional Spaces for Piecewise Continuous Signal Recovery, IEEE Transactions on Signal Processing, 2018, doi:10.1109/TSP.2018.2876328.



(a) 足尾観測点(N.ASOH)



(b) 伊南観測点(N.INAH)



(c) 大子観測点(N.DGOH)

図1: 東西方向速度データに対する提案法の適用結果。オレンジの破線と水色の点線はそれぞれ提案法により検知された変化点と気象庁検測値または地震波伝播計算による到達推定時刻に対応する。

Automatic P-wave detection using deep learning and visualization of the decision process

*Shota Hara¹, Yukitoshi Fukahata², Yoshihisa Iio²

1. Graduate School of Science, Kyoto University, 2. Disaster Prevention Research Institute, Kyoto University

P波の到達時刻と初動極性は、震源位置やメカニズム解を決定する上で必須の情報である (Hardebeck & Shearer, 2002, Yang et. al., 2012)。P波の到達時刻の検出を自動で行うアルゴリズムは以前より盛んに研究が進められており、例えば、STA/LTAアルゴリズム (Allen, 1978)、AR-AIC法 (Sleeman & Van Eck, 1999) などがある。最近ではZhu & Beroza (2018) やRoss, et. al. (2018) が深層学習を用いた方法を提案した。一方、初動極性の判別について、既存の手法は人間の専門家よりも精度が低いという問題があった。本研究では、観測された地震波形データからP波の到達時刻と初動極性を検出することの可能な畳み込みニューラルネットワーク (CNN; Convolutional Neural Network) のモデルを開発した。観測データとしては、西日本 (山陰地方、近畿地方北部) の稠密地震観測網で得られた250 Hzの地震波形 (約13万個) と定常観測網で得られた100 Hzの地震波形 (約4万個) を使用し、到達時刻と初動極性の正解データとしては専門家による検出結果を用いてCNNの訓練を行った。その結果、訓練に用いていない地震波形に対するCNNによる到達時刻について、専門家とCNNの検出時刻の差の平均と標準偏差はそれぞれ、-0.002 sと0.040 s (250 Hz)、-0.009 sと0.071 s (100 Hz) となった。また、初動極性の検出結果は専門家が検出した結果に対し、約98 % (250 Hz) と約95 % (100 Hz) の一致精度を有した。これはRoss et. al. (2018) の結果と同等である。次に、初動極性検出結果について地域ごとの再訓練の必要性を調べるため、地震波形を観測地域で分け、片方の地域の波形データを用いてCNNを訓練し、もう一方の地域のデータに適用した。その結果、一致精度は最大でも約2 %の減少に留まり、地域ごとにCNNを再訓練させる必要性が低いことが分かった。また、現在の深層学習を用いた研究では、ニューラルネットワーク部分がブラックボックス的、つまりCNNがどのように結果を出力するかがわかりづらいという課題がある。そこで本研究では、Selvaraju, et. al. (2017) のGrad-CAMと呼ばれる可視化技術を用いて、CNNによる初動極性検出の決定プロセスの可視化を試みた。CNNが重視している箇所を可視化することにより、訓練されたCNNが到達時刻の検出結果のズレに柔軟に対応していることが分かった。また、多くの波形に対して初動到達直後よりもむしろ直前を重視していることも分かった。この特徴は、初動極性検出の専門家の判断基準に極めて近く、初動極性そのものの定義をCNNには与えていないにも関わらず、人間と同等の判断力を身につけていると考えられる。

Application of convolutional neural networks to continuous seismic network records

*Keisuke Yano¹, Takahiro Shiina², Sumito Kurata¹, Aitaro Kato², Fumiyasu Komaki¹, Shin'ichi Sakai², Naoshi Hirata²

1. Department of Mathematical Informatics, The University of Tokyo, 2. Earthquake Research Institute, University of Tokyo

1. 背景

現在、首都圏には、稠密に配置された約300個の観測点をもつ首都圏地震観測網 (Metropolitan Seismic Observation network; 通称MeSO-net) があり、地震波形が連続的に収集されている。必ずしも地震観測点として適していない首都圏での測定のため、収集されたデータには、通常の地震波形に加えて地表面付近の様々な環境ノイズが含まれている。しかし、それらの環境ノイズは、観測点個別のものが多く複数の観測点で比較することにより軽減することが期待される。そこで、これらのデータの中から複数観測点の波形の情報を統合し、効率的かつ徹底的に地震波形だけを検知することを試みた。本発表では、畳み込みニューラルネットとグラフ分割を用いた複数観測点での地震検知法を提案し、MeSO-net データを用いてその精度を検証する。

2. 提案手法

畳み込みニューラルネットとグラフ分割を用いた複数観測点連続波形での地震検知法を提案する。畳み込みニューラルネットは「膨大な数のフィルタとの畳み込み・プーリング」と呼ばれるダウンサンプリング法・全結合ニューラルネット」を利用した学習器であり、画像処理・波形処理において広く活用されている。地震学においても畳み込みニューラルネットの単観測点連続波形への適用は広く検討されている。しかし、畳み込みニューラルネットは、画像のように入力の各要素が等間隔で配置されていることを想定しており、複数観測点連続波形にそのまま利用してしまうと、観測点の空間配置の不等間隔性を考慮することができない。そのため、単に畳み込みニューラルネットを適用しただけでは、複数観測点を用いることによる検知精度の向上および誤検知率の減少はそれほど期待できないと考えられる。

そこで、本研究では、グラフ理論の分野で研究されているグラフ分割の技法を畳み込みニューラルネットに導入し、観測点の空間配置を考慮した畳み込みニューラルネットを提案する。観測点間のグラフの構成法には自由度が存在するが、交差検証法を用いることでデータから決定することができる。

3. 解析結果

提案手法の精度検証を2011年9月4日から16日のMeSO-net 連続観測波形を用いて行った。複数観測点として成田付近の13観測点を選択し、畳み込みニューラルネットの時間入力長を20秒(50Hzまでダウンサンプリング)とした。提案手法の精度を既存手法と精度を比較し、特に誤検知率を抑えることに成功した。解析結果の詳細については当日報告する。

Room C | Special session | S22. Potentiality of Machine Learning in Seismology

[S22]AM-2

chairperson: Hisahiko Kubo(NIED), Yuki Kodera(Meteorological Research Agency, JMA)

Wed. Sep 18, 2019 10:45 AM - 12:00 PM ROOM C (Research Bldg No 8 NS Hall)

[S22-05] Development of 3D Convolutional Neural Network to locate hypocenter with theoretical seismograms of time series as training data.

*Daisuke Sugiyama¹, Seiji Tsuboi¹ (1. JAMSTEC)

10:45 AM - 11:00 AM

[S22-06] Discrimination of earthquakes and tectonic tremor signals by applying a convolutional neural network to running spectral images

*Masaru Nakano¹, Daisuke Sugiyama¹, Takane Hori¹, Tatsu Kuwatani¹, Seiji Tsuboi¹ (1. JAMSTEC)

11:00 AM - 11:15 AM

[S22-07] An unsupervised automatic classification algorithm for continuous seismic records using a nonparametric Bayesian approach

*Yuki Kodera¹, Shin'ichi Sakai², Takahito Nishimiya¹ (1. Meteorological Research Institute, Japan Meteorological Agency, 2. Earthquake Research Institute, the University of Tokyo)

11:15 AM - 11:30 AM

[S22-08] **Study on Site-specific Ground Motion Evaluation Models Utilizing Machine Learning Method Considering Epicentral Directions**

*Toru Ishii¹, Atsuko Oana¹, Kensuke Wada¹ (1. Shimizu Corporation)

11:30 AM - 11:45 AM

[S22-09] Study on Ground Motion Evaluation Models for Kanto Region Utilizing Machine Learning Method

*Atsuko Oana¹, Toru Ishii¹, Kensuke Wada¹ (1. Shimizu Corporation)

11:45 AM - 12:00 PM

Development of 3D Convolutional Neural Network to locate hypocenter with theoretical seismograms of time series as training data.

*Daisuke Sugiyama¹, Seiji Tsuboi¹

1. JAMSTEC

我々は、昨年の地震学会秋季大会において、理論地震波形記録を生成し、これを教師データ（ある入力データとその正解となるデータを対応付けたもの）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について報告した。前回の発表では、関東地方領域にて、震源や規模の異なる多数のパターンの仮想地震を網羅的に計算し、得られた理論地震波形記録から、ある時刻における地表の空間的な地震波伝播画像を生成して、この画像を用いて深層学習を行い、震源パラメータを自動推定するニューラルネットワークを構築することが出来ることを示した。

我々は、このニューラルネットワークによる震源パラメータ推定精度をさらに高めることを目的とし、学習対象を時系列方向に発展させる試みを行った。例えば、地震波形の広がり方から震源近くの細かな振動など、前回用いた地表の変位分布だけでなく、その映像的な時間発展のパターンも学習の対象とする。このような時間発展パターンを学習するため、我々は、ある時間範囲の理論地震波形記録の地表の変位分布を、図1のような3次元形状データに変換した。このようなデータを、3次元形状データ及び映像における動きの学習に特化した3次元畳込みニューラルネットワーク（3D CNN）を用いて学習を行い、実際の観測データの推定を行うことができる推論モデルを得る。


なお、理論地震波形記録生成については、前回と同様にスペクトル要素法のSPECFEM3D_GLOBE(https://geodynamics.org/cig/software/specfem3d_globe/)を用いているが、今回は対象範囲について関東地方から日本列島規模まで広げ、256コア、1 chunkを用いて計算した。用いた3次元地球モデルはS20RTSで、モデルの精度の設定値であるNEXは256、周期は17秒である。震源深さや位置など震源パラメータを変化させた4,200個の仮想地震に対して約5分間の理論地震波形を計算し、約300万枚の地震波伝播画像を生成した。これを用い、数十秒程度の時間発展パターンを3次元形状データとして生成し、教師データとした。もちろん、この3次元形状データはk-Netなどの実際の地震波形観測データからも同様に自動的に生成が可能であり、自動的な震源パラメータの推定も可能である。

このように生成した教師データを基に、先に述べた3D CNNを用いた深層学習を行った。3層の3D畳込み層を用い、86x86の空間伝搬データを時系列方向に20個用い、各震源パラメータを推定する推論モデルを機械学習により生成した。深層学習フレームワークはTensorFlow (<https://github.com/tensorflow>)とnnabla (<https://github.com/sony/nnabla>)を用いた。教師データの生成および機械学習は海洋研究開発機構・地球情報基盤センターが運用する計算クラスタであるDAシステムのGPGPUノードを利用して並列に行い、ニューラルネットワークから推論モデルを構築した。

学習は4,200個の地震の各イベント85:15に分割し、85%である3,570個を学習に用い、学習に使用しない残り15%の630個の地震を用いて交差検証を行ったところ、概ね良好な結果が得られた。最終的に完成した推論モデルの詳しい推定結果、および実際の観測データに適用した場合の推定結果について発表の際に述べる。

謝辞

本研究は科研費19K12011の助成を受けたものです。また、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。



Discrimination of earthquakes and tectonic tremor signals by applying a convolutional neural network to running spectral images

*Masaru Nakano¹, Daisuke Sugiyama¹, Takane Hori¹, Tatsu Kuwatani¹, Seiji Tsuboi¹

1. JAMSTEC

近年の地震・地殻変動観測網と観測データ解析技術の発達により、プレート境界地震の震源域周辺において、低周波微動、超低周波地震、スロースリップ等のスロー地震が発生していることが明らかになっている。スロー地震の発生メカニズムを解明し、発生状況をモニタすることで、巨大地震の発生メカニズムと準備過程について理解が深まると期待されている。その中でも低周波微動は、低周波成分が卓越し、数十秒以上継続するシグナルとして観測される。低周波微動の検知には主にエンベロープ相関法が用いられるが、この手法では通常の地震動も同時に検出してしまうため、地震カタログを用いたり、目視によるチェックによって、低周波微動のイベントだけを抽出する必要がある。

一方で、低周波微動と通常の地震動のシグナルは卓越する周波数成分と継続時間が異なり、これらの情報からシグナルを判別できると考えられる。すなわち、低周波微動は通常の地震動と比べて10Hz程度以下の低周波成分が卓越し、またシグナルの継続時間は数十秒以上と、ローカルな地震と比べて長時間シグナルが継続する。シグナルに含まれる周波数成分と継続時間を同時に表現する手法として、ランニングスペクトルがある。そこで本研究では、ランニングスペクトルの画像認識によって低周波微動および通常の地震動を判別する手法を開発した。

画像に含まれる共通した特徴を自動で学習、認識し、判別する技術として、畳み込みニューラルネットワーク（CNN）が主に用いられる。通常のCNNによる画像認識では、シグナルの特徴が画像のどこに現れても認識できるように設計する。一方地震動の場合、シグナルの現れる時刻、すなわちランニングスペクトル画像の横方向の位置はどこでも構わないが、周波数成分については震源の物理プロセスを反映しているため、周波数の絶対値（画像の縦方向の位置）はシグナルの判別に重要な情報となる。従って、本研究では画像の縦方向（＝周波数）には位置感度を持たせつつ、横方向（＝時刻）の位置には影響を受けない、非対称な画像認識手法を新たに考案し、低周波微動と通常の地震動を判別する手法を開発した（SRSpec-CNN; Nakano et al., 2019 SRL）。

CNNによる画像認識では通常、画像に含まれるシグナルの特徴を抽出する畳み込み層と、シグナルの位置感度を軽減するためのプーリング層、これらの層の出力とシグナルの関連付けを行う全結合層から構成される。通常のプーリング層は、画像の縦横の両方向に適用し、シグナルの特徴が画像のどこに現れても適切に認識できるように構成する。しかし今回開発したSRSpec-CNNでは、プーリング層を画像の横（時間）方向のみに適用することで、縦方向（周波数）には位置感度を持つよう構成した。この点が通常のCNNとは異なる。

今回開発したSRSpec-CNNをDONETで観測された低周波微動と通常の地震動、ノイズの記録から作成したランニングスペクトル画像を用いて学習させ、シグナルの判別精度評価を行った。画像は64×64ピクセルとし、横方向は時間（225秒）、縦方向は周波数（2-10 Hz）に対応する。この時、二つの観測点（KMB06とKMD13）のデータは学習に用いず、新しく観測点が追加された場合を想定した性能評価試験に用いた。また、比較のためにプーリング層を通常のCNNと同じ構成とした場合のシグナル判別も行った。

その結果、通常のCNNの場合は正解率（予測結果全体の中で、答えが正解と一致している割合）が95.9%だったのに対し、今回開発したSRSpec-CNNでは97.4%に向上した。さらに学習パラメータを最適化することで、最終的に99.5%の正解率を達成した。また、除外した二つの観測点のデータに対し、学習済みのネットワークを用いてシグナル判別を行ったところ、正解率は99.2%と、やはり高い判別性能を示した。つま

り、既に観測網を展開している領域でのシグナルの一般的な特徴を学習しているため、観測網に新しい観測点を追加しても改めて学習をやり直す必要はない。

本研究ではシグナルの学習と判別において、シグナルが明瞭でないものや一つの画像に複数イベントが含まれているような、ノイジーなデータは除去した。今後はノイジーなデータにおける判別率の向上についても検討していく必要がある。

An unsupervised automatic classification algorithm for continuous seismic records using a nonparametric Bayesian approach

*Yuki Kodera¹, Shin'ichi Sakai², Takahito Nishimiya¹

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、地震、人為的活動、機器ノイズなどの様々な要因で生じた信号が記録されている。これらの信号を自動的に抽出・分類することができれば、地震計付近で発生している定常的・非定常的な自然現象の自動検出や、リアルタイム処理に用いている地震計の自動ヘルスマニタリング等につながると期待される。本研究では、これらへの第一歩として、機械学習を用いて連続波形記録を自動的に分類する手法の開発に取り組んでいる。個々の地震計の観測環境は様々であることから、教師データがあらかじめ存在することは想定せず、教師なし学習を前提として手法を構築する。

小寺・酒井（2018，地震学会）は、10次元に集約した離散的な周波数スペクトルを特徴量として、周波数領域および時間領域で多段階のクラスタリングを行うことで、連続波形記録を10種類の時系列データに分類する手法を提案し、自然地震、鉄道ノイズ、バックグラウンドノイズが自動的に分類可能であることを示した。しかしながら同手法は、時間領域でのクラスタリングを行う際にスペクトラルクラスタリングを用いているという問題点がある。スペクトラルクラスタリングは、分類されるクラスタ数をハイパーパラメータとして陽に与える必要があるため、その値を設定する際に恣意的な判断が入り得る。そこで本研究では、分類の客観性をより高めるため、ノンパラメトリックベイズモデルのひとつである無限関係モデル（IRM; Kemp et al., 2006）を用いて時間領域のクラスタリングを行った。IRMは無数個のクラスタの存在を許容した生成モデルであり、学習データに基づいて有効なクラスタ数が自動的に計算される。先行研究同様、時系列データがマルコフモデルで遷移すると仮定して遷移行列を生成し、その行列に対してIRMを適用した。

上記手法をMeSO-netの観測点E.JDJM（川北・酒井，2009）および気象庁の紀伊半島沖OBSの臨時観測点TN042A（山崎・他，2008）における72時間の連続波形記録（期間はそれぞれ2017年3月1～3日，2004年9月22～24日）に適用した。IRMにより、E.JDJMは10種類、TN042Aは6種類のクラスに分類され、学習データに応じてクラス数が自動的に調整されることを確認した。E.JDJMにおける地震と鉄道ノイズ、TN042Aにおける振幅の大きな余震と低周波微動は別々のクラスに分類された。一方で、それぞれの信号とクラスは基本的には一対一の対応にはなっておらず、例えばE.JDJMの鉄道ノイズは5種類程度のクラスに細分化されるといったことが生じた。より直観的に理解しやすい分類とするためには、細分化されたクラスを更にまとめ上げるといった処理が必要になるだろう。

Study on Site-specific Ground Motion Evaluation Models Utilizing Machine Learning Method Considering Epicentral Directions

*Toru Ishii¹, Atsuko Oana¹, Kensuke Wada¹

1. Shimizu Corporation

新たな観点の地震動評価による新たな知見獲得を目指し、堆積平野内や周辺で得られた水平地震動観測記録を教師データとする機械学習により、地点固有の地震動評価モデルの作成を試みた。各地点では地盤特性が共通なので、震源・伝播特性を記述する各パラメータを入力する「特徴量」とし、観測記録から求められた地震動指標を「目的変数」とすることにより、両者を関連付けて機械学習を実施した。

機械学習には、勾配ブースティングと決定木を組み合わせた手法「勾配ブースティング木」を用いた。「目的変数」として、地震動の最大加速度 $PGA[cm/s^2]$ および複数の周期 $T[s]$ での減衰定数 $h=5\%$ の擬似速度応答スペクトル ${}_pS_v[cm/s]$ と速度応答継続時間スペクトル $TS_v[s]$ （パラメータ $p1=0.03$, $p2=0.95$ ）を検討した。大振幅になるとデータ数が減る PGA と ${}_pS_v$ は、モデル精度を高めるために機械学習に適した解析上のデータ分布となる常用対数（ $\log_{10}PGA$, $\log_{10}{}_pS_v$ ）に変換して入力した。「特徴量」としては、地震のモーメントマグニチュード M_w 、震源深さ $H[km]$ 、震源距離 $X[km]$ 、震央方位 $\Lambda[degree]$ を与えた。 Λ は真北を 0° として時計回りに定めたが、真北を境に不連続量となるので、解析上のデータには $\sin \Lambda$ と $\cos \Lambda$ のペアを与えた。一特徴量のデータ列のみシャッフルして置き換え機械学習により再評価した時に評価精度の悪化した度合いにより、モデルへのその特徴量の「影響度」とした。

K-NET観測点TKY028での「地震動評価モデルT」の検討例を図1～4に示す。 Λ の影響度は特に TS_v で大きく、周期によっては $M_w \cdot X \cdot H$ と同等以上になった。この例では、評価値／観測値の比の平均は約1.1、その常用対数標準偏差は振幅では0.2強、継続時間では0.1強で、評価値の大半は観測値の倍半以内に収まった。従来の距離減衰式等で扱われなかった震央方位や応答継続時間を考慮し、地点・周期毎に地震動特性が変化する様子の定性的・定量的な分析・検討も可能で、地震波の三次元伝播特性の違いを簡便な評価モデルに反映出来る可能性がある。

AIとBig Dataを生かす上で良質・大量のデータと情報の得られる地点毎に地震動評価モデルを作成することには大きな利点がある。今後、データの粗密に起因するモデル精度のアンバランスを改良するための工夫や、データ数が少なく外挿領域に当たる大地震・大振幅地震動・長時間地震動の評価上の工夫も必要となろう。

謝辞

本研究には、気象庁の地震情報と防災科学技術研究所の陸海統合地震津波火山観測網の公開データ、および、機械学習ツール DataRobot と描画ツール GMT を使用した。これらの開発・運用・管理に携われた全ての皆様に心より感謝申し上げます。

参考文献

石井・小穴・和田, 日本地震工学会大会 2019 梗概集 (投稿中)




図 1 TKY028 で観測されたモデル T 検討用地震の震央


地震動指標<周期 T >

図 2 モデル T の各地震動指標に対する各特徴量の影響度





図 3 モデル T の地震動指標(目的変数)の観測値と評価値の相関図(散布図)の例



$M_w=6$, $H=10\text{km}$, $X=180\text{km}$ の条件で Δ を 5° 刻みで変化させて最大値により基準化して示したもの

図 4 モデル T の地震動指標(目的変数)の評価値の震央方位依存性の検討例

Study on Ground Motion Evaluation Models for Kanto Region Utilizing Machine Learning Method

*Atsuko Oana¹, Toru Ishii¹, Kensuke Wada¹

1. Shimizu Corporation

日々蓄積されていく地震動観測記録が最大限に活用され随時更新される地震動予測モデルの構築を目指し、その予備的な検討として、関東地方において過去に得られた地震動観測記録を用いて、機械学習による地震動評価モデルの作成を試みた。

検討には、防災科学技術研究所のK-NETのうち関東地方に展開された強震観測点138地点（図1）で得られた地表記録を用いた。具体的には、気象庁の震度データベースで1996年～2019年1月15日に最大震度が4以上でかつ東京都千代田区で震度2以上となった地震のうち、関東地方で震度が記録された地点数が非常に少ない地震を除いた上で、地震規模と震源位置が偏り過ぎないように代表的な地震を選んだ。選択した地震は、関東地方を中心に一部遠方にまで広がっている（図2）。これらの地表記録のうち、加速度三成分合成振幅最大値が 1 cm/s^2 以上の観測点での水平二成分の波形データを選択し、データに含まれるノイズや別地震を判別して、検討に用いることが適切な波形を取捨選択した結果、総計11488波形となった。選択したデータの震源距離 X [km]とモーメントマグニチュード M_w の分布を図3に示す。

地震動評価モデルの目的変数は、最大加速度 $PGA[\text{cm/s}^2]$ と複数の周期 $T[\text{s}]$ における減衰定数5%の擬似速度応答スペクトル $S_v[\text{cm/s}]$ および速度応答継続時間スペクトル $TS_v[\text{s}]$ （石井, 2012）とした。なお、 PGA と S_v は振幅の大きなデータが少なく、絶対値のままではデータの分布形状が偏っていたため、機械学習ではそれぞれの常用対数を与えることにした。地震動評価モデルの特徴量（説明変数）は、モーメントマグニチュード M_w 、震源深さ $H[\text{km}]$ 、震源距離 $X[\text{km}]$ 、震央方位 $\Lambda[\text{degree}]$ 、地震基盤面深さ $D28[\text{m}]$ （J-SHISで公開されている深部地盤モデルの第28層の下面深さ）、表層30m平均S波速度 $AVS30[\text{m/s}]$ の6種類とした。 Λ は真北を 0° として時計回りに定めたが、真北を境に不連続量となるので、 $\sin \Lambda$ と $\cos \Lambda$ のペアを与えた。機械学習手法には、勾配ブースティングと決定木を組み合わせた勾配ブースティング木を用いた。

ある特定の特徴量のみをランダムに並べ替え、その他の特徴量を元のままとしたときの目的変数の評価精度の変化の度合いにより、目的変数に対する各特徴量の影響度を調べた（図4）。 M_w の影響度は周期と共に増大し、 X の影響度や TS_v に対する H の影響度は周期と共に減少した。 $AVS30$ の影響度は周期1秒で相対的にやや大きめ、 $D28$ の影響度は周期1秒以上で大きめ、 Λ の影響度は相対的には周期1秒以下で大きめとなった。目的変数の観測値と評価値の分布の例を図5に示す。評価値／観測値の比の平均はほぼ1、その常用対数標準偏差は地震動の振幅では0.2弱程度、応答継続時間では0.1程度で、評価値の大半は観測値の倍半以内にとまり、全体として良くモデル化された。

作成した地震動評価モデルを用いて、 M_w に応じた PGA の距離減衰特性を検討した例を図6(a)に示す。特徴量の与条件は、茨城方面を震源とする地震をSIT006秩父で観測する場合等を考慮して設定し、プレート境界地震による岩盤サイトでの揺れを想定した。参考として、Morikawa and Fujiwara(2013)の距離減衰式（ M_w6 と $M_w6.5$ ）の平均も重ね描いた。 M_w と X に応じた PGA の傾向は、大局的には既往の距離減衰式と同様にモデル化されていると言える。ただし、 M_w5 や M_w6 の場合に比べて $M_w6.5$ の場合は、 $X < 60\text{ km}$ の傾きが小さく、ステップ関数状になっている。 $M_w6.5$ では $X < 60\text{ km}$ の学習データが少なかった（図3）ため、十分な信頼性が確保できていない可能性がある。 Λ による $S_v(T=1\text{秒})$ の距離減衰特性の検討例を図6(b)に示す。ここでは、都心からみて北東・南・南西方向（ $\Lambda=45, 160, 230^\circ$ ）のプレート境界地震および北西方向（ $\Lambda=320^\circ$ ）の内陸地震を念頭に置いた。これら4ケースを比べると、同じ M_w と X でも Λ によって振幅の大きさに差が生じている。プレート境界地震を想定した3ケースでは南方向が最も小さく、北東方向と南西方向の大小関係は50 km程度を境に入れ替わっている。また、北西方向は距離減衰の傾きが相対的に小さい。 $X < 100\text{ km}$ では顕著に振幅が小さいが、 $X > 150\text{ km}$ では南方向を上回っている。このような違いは、震源特性の地域性や伝播経路特性の違いがモデルに反映された結果と考えられ、 Λ を考慮することによって、既往式よりも細かな地域特性を考慮した地震動評価モデルを作成できる可能性を示唆している。一方で、データの偏りがモデルに影響を及

ばしている可能性もあるため、今後さらなる検討が必要である。




図1 関東地方の K-NET 観測点 図2 検討地震の震央





図4 地震動評価モデルの各地震動指標に対する各特徴量の影響度



(a) M_w に応じた PGA (b) Λ に応じた $pS_v(T=1s)$

図6 距離減衰特性に関する検討例




図3 震源距離 X と M_w の分布





図5 目的変数の観測値と評価値の例

参考文献: 石井(2012): 日本建築学会構造系論文集, 第77巻, 第676号, pp.843-850. Morikawa and Fujiwara(2013): Journal of Disaster Research, Vol.8, No.5, 2013, pp.878-888.

謝辞: 気象庁の地震情報と防災科学技術研究所による公開データ、および機械学習ツール DataRobot と描画ツール GMT を使わせて頂きました。心より感謝申し上げます。

Room C | Special session | S22. Potentiality of Machine Learning in Seismology

[S22]PM-1

chairperson: Yuki Kodera (Meteorological Research Agency, JMA), Takahiko Uchide (Geological Survey of Japan, AIST)

Wed. Sep 18, 2019 2:30 PM - 4:00 PM ROOM C (Research Bldg No 8 NS Hall)

[S22-10] Improving the symmetry of ambient seismic field correlation functions with machine learning

*Loic Viens¹, Tomotaka Iwata¹ (1. Kyoto University, DPRI)

2:30 PM - 2:45 PM

[S22-11] A hybrid approach of Machine learning and Ensemble Kalman Filter for estimating frictional parameters in Nankai megaquake cycle simulator

*Yu Yamamoto¹, Kazuro Hirahara^{1,3}, Hirotaka Hachiya^{1,2}, Atsushi Takahashi¹, Naonori Ueda¹ (1.

Center for Advanced Intelligence Project, RIKEN, 2. Univ. of Wakayama, 3. Univ. of Kagawa)

2:45 PM - 3:00 PM

[S22-12] Acceleration of matched-filter search and slip inversion of deep tectonic tremor using nearest neighbor search

*Naoto Mizuno¹, Satoshi Ide¹ (1. School of Science, The University of Tokyo)

3:00 PM - 3:15 PM

[S22-13] Machine learning of postseismic deformation of the 2011 Tohoku-Oki earthquake based on recurrent neural network

*Norifumi Yamaga¹, Yuta Mitsui² (1. Graduate School of Integrated Science and Technology, Shizuoka University, 2. Faculty of Science, Shizuoka University)

3:15 PM - 3:30 PM

[S22-14] Automatic detection and classification of the uplifted marine terrace by clustering DEM dataset

*Junki Komori¹, Ryosuke Ando¹, Masanobu Shishikura² (1. The University of Tokyo, 2. The National Institute of Advanced Industrial Science and Technology)

3:30 PM - 3:45 PM

[S22-15] Investigation of Prediction Model for Engineering Geomorphologic Classification using Convolutional Neural Network

*Sho Akagi¹, Toshihiko Hayakawa¹ (1. Mitsubishi Space Software Co., Ltd.)

3:45 PM - 4:00 PM

Improving the symmetry of ambient seismic field correlation functions with machine learning

*Loic Viens¹, Tomotaka Iwata¹

1. Kyoto University, DPRI

Seismic interferometry is a well-established method to retrieve the seismic wave propagation between a pair of seismic stations. Under the assumption that the ambient seismic wavefield is equipartitioned, the correlation function between the two sensors should yield the inter-station Green's function. However, such a condition is rarely fulfilled on Earth, as the ambient seismic field is generated by uneven distributions of sources, for example from ocean waves at low frequencies (<1 Hz). This uneven source distribution generally leads to non-symmetric correlation functions which can also be corrupted with non-physical wave arrivals. We focus on one year of continuous data recorded by Hi-net stations located in the Kii peninsula, Japan, and compute correlation functions between station pairs using short 15-min time-windows and stack them over 30 minutes. As the source of the ambient seismic field varies through the year, the raw stack of correlation functions over one year is strongly asymmetric for most station pairs. We propose to use machine learning techniques (e.g., Principal Component Analysis (PCA) and autoencoders) to reduce the dimensionality of the correlation function dataset for each station pair. By selecting correlation functions from the latent/low-dimension space of both methods, we show that the symmetry between the acausal and causal parts of the correlation functions can be improved. This additional processing step could help us to retrieve a better approximation of inter-station Green's functions, and therefore be useful for imaging purposes.

A hybrid approach of Machine learning and Ensemble Kalman Filter for estimating frictional parameters in Nankai megaquake cycle simulator

*Yu Yamamoto¹, Kazuro Hirahara^{1,3}, Hirotaka Hachiya^{1,2}, Atsushi Takahashi¹, Naonori Ueda¹

1. Center for Advanced Intelligence Project, RIKEN, 2. Univ. of Wakayama, 3. Univ. of Kagawa

はじめに

南海トラフ沿いに沈み込むフィリピン海プレートは、繰り返し巨大地震を引き起こし。次の巨大地震発生が危惧されている。岩石の摩擦則に基づいて、南海トラフ巨大地震発生サイクルシミュレーション（ECS）研究が行われている。しかし、従来研究では、摩擦パラメータを手動で調整し、南海トラフ巨大地震履歴を再現しようとしているが、200年~90年と大きく変動する地震間隔をうまく再現できていない (Hyodo et al., 2006)。

そこで、複雑な地震間隔を説明する摩擦パラメータを自動的に探索するために、本研究では、機械学習のニューラルネットワーク(NN)と逐次データ同化手法の一つであるアンサンブルカルマンフィルタ(EnKF)とを組み合わせたハイブリッド手法を提案する。具体的には、シミュレーションによる断層のすべり速度履歴から摩擦パラメータを予測する逆関数を定義し、機械学習を用いて、汎化的な摩擦パラメータ分布を推定する。さらに、得られた摩擦パラメータ分布をEnKFの初期アンサンブルに用いて、真の南海トラフ巨大地震履歴から摩擦パラメータの周辺化分布を求める。

予備的な研究段階ではあるが、ECSデータと真の南海トラフ巨大地震履歴データを用いた単純な離散3セルモデル実験を通して、提案法が多様に変化する真の南海トラフ巨大地震をより正確に再現できる可能性があることを示す。

データ & 解析手法

通常のECSでは、プレート境界面を臨界サイズより細かいセルに分割するが、多大な計算コストが必要である。そこで、本研究では、南海トラフ沿いのプレート境界面の破壊断層セグメント（南海・東南海・東海）に対応する相互作用を有する離散3セルモデルを用いる。具体的には、プレートのすべり発展は速度状態依存則に、また状態変数の時間発展はスローネス則に従うとし (Dieterich,1979; Ruina,1983)、準動的 (Rice,1993) に計算を行った。

各セルの摩擦パラメータに応じて、相互的に地震サイクルが変化する。また、摩擦パラメータのうち、本研究では、A,Lを固定し、Bを所定の区間で動かすことにより、B-Aを変化させている。摩擦パラメータ以外の各種パラメータは固定する。

真の南海トラフ巨大地震履歴データは、1400年に及ぶ地震発生時のみの時系列データである。時間予測 (TP) およびすべり予測 (SP) を仮定して、地震発生時のすべり量を推定し、地震発生履歴データに累積変位データを付加した真値模擬データを作成した。また、すべり継続時間は一定としてすべり速度データに変換してデータとした。南海トラフ巨大地震履歴にはその発生が不確かな地震データも含まれるため、不確かな地震データを含む/含まない場合の組み合わせを考慮した256通りの履歴を用いた。

まず、機会学習を用いた解析について述べる。単独セルにおける地震間隔と摩擦パラメータとの関係に基づき、3セルのBのサンプリング範囲はそれぞれ0.625から0.85、0.6から0.825および0.6から0.825 (MPa) とした。そして、サンプリング範囲を0.025(MPa)間隔で刻み、約80万回のシミュレーションにより、各セルにおけるすべり速度データと摩擦パラメータB-Aとの対データを作成し、すべり速度データに時系列解析の手法である高速フーリエ変換(FFT)を用いて周波数スペクトラムに変換する。そして、各ウィンドウで周波数スペクトラムの最大値を抽出し、NNの特徴量とした。これにより、摩擦パラメータB-Aの変動の影響を受ける、地震の最大間隔を抽出することができる。学習時には、地震の最大間隔の特徴量から、対となる摩擦パラメータを推定する。評価時には、学習したモデルを使用して、真の南海トラフ巨大地震履歴データから、摩擦パラメータを推定する。摩擦パラメータの微小な値を推定するために、分類で荒く摩擦パラメータの範囲を推定し、拡大された残差を回帰する2段階のNNを用いる。


次に、EnKFを用いた解析について述べる。256通りの南海地震履歴データから機械学習により推定された値を256個の初期アンサンブル値とする。同化間隔は、2年間として南海トラフ巨大地震履歴上で地震が発生した年で更新が発生する。EnKFにおける摩擦パラメータの結果は、最後に予測した摩擦パラメータのアンサンブルの平均とする。

最終的に予測したセルそれぞれのB値を当該シミュレーションに入れ、8000年分のすべり速度を求める。そして、8000年分のすべり速度から、真の南海トラフ巨大地震履歴との地震発生時年数と予測した地震履歴の地震発生時年数の誤差の合計が最短になる1400年を取得し、真の南海トラフ巨大地震履歴の地震発生時年数との誤差を比較する。

結果 & 考察

図. 1が示すように、赤枠で囲まれた東海の比較的大きな間隔で起きる巨大地震は、平均地震年数誤差約10年以下の誤差に抑えることができているが、青枠で囲まれた比較的小さな間隔で起きる巨大地震は推定するのが難しい。

これは、NNの特徴量として、地震間隔の最大間隔を用いているため90年の比較的小さな間隔を推定するのが困難になっていることがあげられる。



Acceleration of matched-filter search and slip inversion of deep tectonic tremor using nearest neighbor search

*Naoto Mizuno¹, Satoshi Ide¹

1. School of Science, The University of Tokyo

世界各地の沈み込み帯などにおいてスロー地震の一種である低周波地震やその群発的活動と考えられている深部微動が観測されている。低周波地震の検出には、典型的な低周波地震のテンプレート波形を用意し、それと相互相関の高い波形を検出するマッチドフィルターが広く用いられている。この手法ではテンプレート波形と類似性のないシグナルは検出されないため、シグナルの取り逃しを減らすためには用いるテンプレート波形の数を増やす必要がある。しかし、マッチドフィルターはテンプレート波形の数に比例した計算量がかかるため、大量のテンプレート波形を用いると必要な計算コストが非常に大きくなってしまう。また、低周波地震からグリーン関数を作成し深部微動のすべりインバージョンを行う手法（Ohta and Ide, 2017）では、マッチドフィルターを応用し深部微動のすべり発展を捉えることが可能であるが、大量のテンプレート波形に対するマッチドフィルターを繰り返し行うことと同等の処理が必要となるため、長期間のデータを扱うことは計算コストの点で困難であった。

本研究では近似最近傍探索を用いたマッチドフィルターの高速化を行い、これを応用することですべりインバージョンを高速化した。通常のマッチドフィルターではS波やP波の到達時刻の前後数秒を用いるが、本研究では発生時刻からの数十秒の時間窓を用いた。これによりテンプレート波形と観測波形が最近傍探索におけるデータ点とクエリ点にそれぞれ対応し、マッチドフィルターを最近傍探索として定式化できる。この定式化ではデータの次元が時間窓の長さで観測成分数の積であるので、1万次元程度の高次元データを扱うこととなる。このようなデータの次元が大きい場合における最近傍探索は古典的には愚直な探索より高速化することが困難であったが、近年の研究によって近似解においては大幅な改善が行われている（e.g. Johnson et al., 2017）。本研究では特異値分解を用いた次元削減・近似最近傍探索による枝刈り・GPUを用いた高速化等の工夫を行い大幅な高速化を達成した。Ohta and Ide (2017) のインバージョン手法はマッチドフィルターの拡張として捉えることができるので、マッチドフィルターと同様の方法で近似最近傍探索に帰着し高速化することが可能である。本研究の手法によって先行研究と比較して1000倍以上の高速化が達成され、長期間のデータに対する解析が可能となった。

Machine learning of postseismic deformation of the 2011 Tohoku-Oki earthquake based on recurrent neural network

*Norifumi Yamaga¹, Yuta Mitsui²

1. Graduate School of Integrated Science and Technology, Shizuoka University, 2. Faculty of Science, Shizuoka University

2011年東北地方太平洋沖地震以来、余効変動が続いている。この余効変動の影響により、各種スローイベントの小さなシグナルが隠れている可能性がある。余効変動は、一般に、対数関数や指数関数、またその組み合わせによってフィッティングされている。この余効変動をより正確に表現するために、機械学習手法の1つであるニューラルネットワークを導入し、既存のデータから特徴を学習する。余効変動の時系列データとして、国土地理院のGNSS(Global Navigation Satellite System)観測網に基づく東西成分、南北成分の変位を用いる。観測点数は191点である。191の観測点のうち、153点を学習用の観測点とし、残りの38点をテスト用の観測点とした。テスト用の観測点は、空間的な偏りが生じないように、緯度・経度それぞれを0.5度ずつ区切ったグリッドごとに、1点ずつ選択した。学習時には、観測点ごとに、時系列の前半90%を使用する。学習で用いるデータを用いて、観測点ごとに変位量を0.1~0.9に値を正規化した。時系列データを365日ごとに区切り、連続した365日を入力データとし、その次の日の値を出力データとした。ニューラルネットワークの層は、単純化のために1層に固定し、LSTMを32個設定した。ここでLSTMは、複数のニューロンから構成されるユニットであり、長期時間依存性を学習できる。損失関数には平均絶対誤差を、最適化アルゴリズムにはAdamを用いた。学習したモデルを用いて、2種類の予測実験を行う。実験1では、38点のテスト点で、東北沖地震後365日経過した時点からの余効変動を期間の最後まで予測して、実データと比較する。実験2では、191の全観測点に対し、学習へ使用していない時系列の後半10%について、余効変動の予測および実データとの比較を行う。2種類の実験の両方で、従来の回帰分析を上回る結果を得られた。特に、実験1の結果の時空間分布からは、太平洋側の、特に岩手県沖・福島県沖の領域で、2013年中頃から、予測よりも実データが西向きにずれていくことがわかる。これは、東北沖地震後の余効変動の減衰と、プレート境界の固着状態変化の和を表すと考えられる。

Automatic detection and classification of the uplifted marine terrace by clustering DEM dataset

*Junki Komori¹, Ryosuke Ando¹, Masanobu Shishikura²

1. The University of Tokyo, 2. The National Institute of Advanced Industrial Science and Technology

標高数値モデル（DEM）を使用した新たな海岸段丘の解析手法を開発し、房総半島に分布する完新世海岸段丘である沼段丘に適用した。沼段丘は過去7000年間に相模トラフ沿いで発生したプレート間地震（関東地震）による隆起で形成されたと考えられており、災害発生予測の観点からも調査が重要視されている地形である。しかし近年実施された年代測定調査などから、関東地震について従来の固有地震的な解釈に疑問が呈されてきたため、その形成履歴に関して再評価が求められていた。本研究では、従来の測量や航空写真判読に代わり、より定量的な手法としてDEMを用いた段丘区分を提案した。この手法では、旧汀線アングルを指示する崖基部の地形を抽出した点群データに対し、クラスタリングを使用して年代ごとの標高分布を取得する。解析の結果、房総半島南端部の海岸線沿い約30kmの長さにわたり、連続的に4段の旧汀線アングルの標高分布を得ることができた。今回得られた沼段丘のそれぞれの比高は互いによく一致した分布を示しており、同様な地殻変動を経験したことが示唆される。しかし年代測定から推定された発生間隔が互いに大きく異なっていることを考慮すると、プレート間のすべりの繰返しモデルでは段丘形成の説明が困難である。これらの地質データを総合して、プレート内断層の寄与も含めた地殻変動履歴モデルを構築することが今後求められる。

Investigation of Prediction Model for Engineering Geomorphologic Classification using Convolutional Neural Network

*Sho Akagi¹, Toshihiko Hayakawa¹

1. Mitsubishi Space Software Co., Ltd.

地形・地盤分類メッシュマップ（若松・松岡 2013）は、工学的な分類基準に基づく地形・地盤分類（微地形区分）のデータベースであり、地震動の増幅、液状化、土砂災害などのハザード評価において微地形を参照することを想定して定義されており、各種自然災害に対する防災上の重要な基盤情報となっている。地形・地盤分類メッシュマップは、日本全国を覆う約250m単位のメッシュに対して、標準化された地形分類基準に従う人の判読によって地形の区分（24種類）を決定している。地形分類基準における地形等の情報は分布データ確認による人の判定に基づいている。

本研究では、標高データが持つ地形に関する情報を抽出して微地形区分を予測することを目的として、畳み込みニューラルネットワーク（Convolutional Neural Network）を用いた微地形区分の予測モデルの開発を試みた。人の判読によって構築された微地形区分を機械学習に基づく手法で予測できるようになることで、個人差や時間経過により生じる地形分類の判定のゆらぎの検知と是正、既存の微地形区分の更新や微地形区分が作成されていない地域での新たな地形分類、メッシュスケールの異なる地形分類の構築に役立つと考えられる。また、数値標高データの分布を入力とした予測モデルから得られる特徴量の特性を理解することで、地形にまつわる様々な問題に対して数値標高データを有効に活用するための知見を得ることができると期待される。

畳み込みニューラルネットワークは、入力サンプルである画像データの中で特徴的な形状を抽出し、画像中において特定の形状を持つ文字や物体の識別に効果的な特徴空間に射影する畳み込み層を含むニューラルネットワークの一種である。近年の深層学習の高度化に伴って急速に発展し、画像認識を代表とする多くの分野で応用手法が提案されている。

本研究では、面的な数値標高データを画像データと見做して畳み込みニューラルネットワークに入力し、標高の分布が有する特徴的な形状を学習させて微地形区分の予測に反映することを試みた。微地形区分の識別に有効な形状を学習するため、250mメッシュに割り当てられた微地形区分を教師データとし、予測対象メッシュを含む周辺地域の数値標高データを説明変数に含めた教師あり学習による予測モデルを構築した。

予測モデルは、数値標高データが持つ形状の情報と周辺メッシュの微地形区分の情報をともに取り入れるため、まず数値標高データに対して畳み込み層を適用し、畳み込み層の出力と微地形区分の入力層をマージして予測ラベルを決める出力層に接続する構成とした。予測の汎化性能を考慮し、説明変数とする数値標高データは予測対象メッシュの標高との差分値とした。説明変数とする微地形区分は標高が高い山側のメッシュとし、山側から標高の低い平野のメッシュに向かって逐次的に微地形区分を予測していく手法を採用した。標高が高い地域は地形分類の区分数が少なく比較的容易に地形分類を決定できるため、本手法は地形分類の構築に有効である。

本研究で構築した予測モデルを、北海道十勝平野を覆う約8万の250mメッシュのデータを用いて学習・予測し、本手法の有効性を検証した。予測対象メッシュを中心とした250mメッシュ数値標高データ（9×9メッシュ）と予測対象メッシュより北側にある微地形区分データ（9×4メッシュ）を説明変数とし、予測対象領域の北端から逐次予測した結果を示す。予測結果が南方向に大きく影響している箇所があるものの、入力した微地形区分が逐次予測により概ね再現されており、対象とした範囲の数値標高と微地形区分の関係が学習されていることが確認できた。




図 検証に使用した十勝平野の微地形区分(左)と北端から逐次予測された微地形区分(右)。