

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

📅 Wed. Sep 18, 2019 9:15 AM - 10:30 AM JST | Wed. Sep 18, 2019 12:15 AM - 1:30 AM UTC | 🏢 ROOM C  
Research Bldg No 8 NS Hall

**[S22]AM-1**

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

9:15 AM - 9:45 AM JST | 12:15 AM - 12:45 AM UTC

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

\*Jun Ogata<sup>1</sup> (1. Data-Driven Anomaly Detection Based on Machine Learning: Smart Maintenance for Wind Energy)

---

9:45 AM - 10:00 AM JST | 12:45 AM - 1:00 AM UTC

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

\*Hiroki Kuroda<sup>1</sup>, Jun Ogata<sup>1</sup>, Hidenori Sakanashi<sup>1</sup>, Takahiko Uchide<sup>2</sup> (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)

---

10:00 AM - 10:15 AM JST | 1:00 AM - 1:15 AM UTC

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

\*Shota Hara<sup>1</sup>, Yukitoshi Fukahata<sup>2</sup>, Yoshihisa Iio<sup>2</sup> (1. Graduate School of Science, Kyoto University, 2. Disaster Prevention Research Institute, Kyoto University)

---

10:15 AM - 10:30 AM JST | 1:15 AM - 1:30 AM UTC

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

\*Keisuke Yano<sup>1</sup>, Takahiro Shiina<sup>2</sup>, Sumito Kurata<sup>1</sup>, Aitaro Kato<sup>2</sup>, Fumiyasu Komaki<sup>1</sup>, Shin'ichi Sakai<sup>2</sup>, Naoshi Hirata<sup>2</sup> (1. Department of Mathematical Informatics, The University of Tokyo, 2. Earthquake Research Institute, University of Tokyo)

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

\*Jun Ogata<sup>1</sup>

## 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。

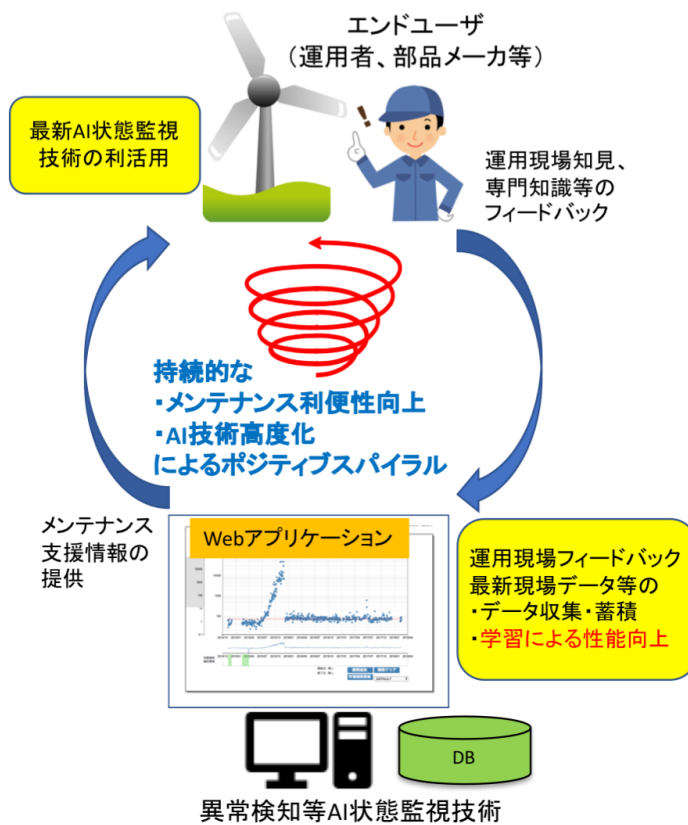
一方、このようなデータ駆動型異常検知技術の実用化を進めるうえでは、システムの早期立ち上げ・運用が重要となる。例えば新しい監視対象機種やセンサを変更した場合など、一からデータを大量に蓄積して学習し直すのではなく、すでに他の環境で学習したモデル・結果を何らかの形で利用（転用）して、新たな環境で異常検知システムを効率的かつ早期に運用可能にできる技術が必要不可欠となる。このような枠組みは、機械学習では転移学習と呼ばれ、現在ホットな研究領域となっている。我々は現在NEDO事業「風車運用高度化技術研究開発」において、こうしたアプローチ（システム転用）を活用することで、あらゆる風車環境において異常検知の早期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



異常検知等AI状態監視技術

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 Kuroda<sup>1</sup>, Jun Ogata<sup>1</sup>, Hidenori Sakanashi<sup>1</sup>, Takahiko Uchide<sup>2</sup>

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 Hara<sup>1</sup>, Yukitoshi Fukahata<sup>2</sup>, Yoshihisa Iio<sup>2</sup>

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かかわらず、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 Yano<sup>1</sup>, Takahiro Shiina<sup>2</sup>, Sumito Kurata<sup>1</sup>, Aitaro Kato<sup>2</sup>, Fumiyasu Komaki<sup>1</sup>, Shin'ichi Sakai<sup>2</sup>, Naoshi Hirata<sup>2</sup>

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。