

## 走時の確率トレースを利用した深層学習による震源決定 Hypocenter Determination Using Deep Learning Technique Based on Travel Time Probability Trace

○直井誠  
○Makoto Naoi

We here suggest a novel procedure based on a deep learning technique to make a seismic event catalog from continuous waveform data obtained by dense observation networks. To take advantage of deep learning, we make a one-stop analysis routine, instead of decomposing the process into many ones such as event detection, arrival-time measurement, phase association, and hypocenter determination. We tested the suggested method by assuming AE measurement of hydraulic fracturing experiments in laboratory and confirmed that the method works well for test data that were numerically generated.

### 1. はじめに

連続波形データから地震カタログを作成するには、イベント検出、走時検出、Event Association、震源決定という複数のプロセスを踏むことが多い。古典的には長時間平均-短時間平均比を用いるイベント検出・走時検出方法 (Allen 1978), AR-AICモデルを用いる走時検出手法 (Takanami and Kitagawa, 1998), グリッドサーチによる Event Association 手法 (Zhang et al. 2019) 等を行った後、得られる検出結果から最小二乗法等により震源を推定するという手順でカタログを構築することが一般的である。近年は、それぞれのプロセスにおいて深層学習を始めとした機械学習手法が適用され、成果を挙げている (Zhu and Beroza, 2019; Mousavi et al. 2020)。

一方、深層学習は有効な特徴量を大量の学習データから自動で発見する仕組みであり、学習データが十分に用意できるならば、多くのプロセスに分割するよりも、End-to-endでの処理を行うほうが良い結果が得られると考えられる。地震カタログ作成の例では、連続波形データから直接震源を推定するネットワークを作成することに対応し、実際、1観測点のデータのみからでも、波形の特徴を手がかりにある程度震源を決められることが報告されている (Perol et al. 2018)。その一方、観測波形を用いて波形から直接震源決定を行う場合には、過去に地震が起こっていない場所の地震は震源を推定できなくなるという問題が生じる。理論波形を用いることでこの問題を解決する手法

も提案されているが (坪井・杉山 2019)、モデリングの難しい高周波成分を効果的に使うことが困難で、自動化による恩恵が大きい大量の小さな地震を処理する能力の向上が難しいと考えられる。

そこで本研究では、できるだけ少ないステップで深層学習を用いて連続波形から地震カタログを作成するため、1) 観測波形から走時の確率トレースを計算する、2) 多数の観測点の走時確率トレースから震源座標と発震時刻を推定する、という2つのプロセスを深層学習ネットワークで処理する仕組みを考案した。解析は、Naoi et al. (2020), Tanaka et al. (2021)が実施した、室内水圧破碎実験と同じく、65 x 65 x 130 mmの立方体計上の供試体内で発生したAEデータを想定し、1)のネットワークの学習には同実験で得られた波形データを2)の学習には多数の仮想震源から数値的に作成した確率トレースを用いた。

### 2. 走時検出

走時検出においては Zhu and Beroza (2019)が実体波の走時検出に用いたものと類似した、Unet型 (Ronneberger et al. 2015)のアーキテクチャを採用した。10 MHz samplingで収録されたP波走時前後1024サンプルの波形をネットワークへの入力とし、波形の各ポイントに対して、そのサンプルがP波走時である確率値を模したパルスを出力するよう、同ネットワークを訓練した。訓練には、先行研究において自動処理で得られた震源のうち、よく震源が求まったものに対応する波形

を教師データとして用いた。訓練に用いていない、テストデータに対する結果の例を図1に示す。P波初動を正確に読み取っており、よく検出ができていることがわかる。




図1. P波走時検出結果と確率トレースの例.

### 3. 走時確率トレースを用いた震源決定

16個のAEセンサに対する走時確率トレースを入力として、震源座標3成分、発震時刻1成分の合計4成分を出力する深層学習ネットワークを構築した。訓練に用いる走時確率トレースは、乱数を使って供試体内に設定した仮想震源から生成した。理論走時のタイミングに片幅10サンプルの三角形パルスを設定して得られる理論確率トレースに、乱数を用いてダミーパルスを追加、あるいは削除の処理を行ったものを生成した。震源20万個に対応する訓練データ、震源2万個分の検証データ、1万個分のテストデータを生成して、ネットワークの訓練と性能評価を行った。こうして訓練したネットワークを用い、 $0.5\mu\text{s}$ の標準偏差をもつ正規分布で理論走時に誤差を与え、上記と同じ手順で擾乱を与えた確率トレースに対して震源決定をおこなったところ、数mmの精度で震源が求められることがわかった。

### 4. 結論

本研究では、連続波形データから震源カタログを作成するプロセスの再検討をおこない、深層学習による2ステップで処理を行う手法を提案した。数値的なテストを実施したところ、数値的に生成したトレースに対しては、十分な精度で震源が求まることがわかった。

### 5. 参考文献

- Allen R.V., 1978. Automatic earthquake recognition and timing from single traces, *Bull. seism. Soc. Am.*, 68, 1521–1532.
- Takanami T., Kitagawa G., 1988. A new efficient procedure for the estimation of onset times of seismic waves, *J. Phys. Earth*, 36, 267–290.
- Zhang M., Ellsworth W. L., Beroza G. C., 2019. Rapid Earthquake Association and Location, *Seismological Research Letters* Volume 90, Number 6, 2276–2284.
- Zhu W., Beroza G. C., 2019. PhaseNet: a deep-neural-network-based seismic arrival-time picking method, *Geophys. J. Int.*, 216, 261–273
- Mousavi S. M. et al., 2020. Earthquake transformer — an attentive deep learning model for simultaneous earthquake detection and phase picking, *Nature Communications* volume 11, 3952.
- Perol T., Gharbi M., Denolle M., 2018. Convolutional neural network for earthquake detection and location, *Sci. Adv.*, 4, e1700578.
- 坪井・杉山, 2019. 理論地震記録を教師データとした機械学習による震源決定, *地震ジャーナル* 68, 14–22.
- Naoi M. et al., 2020. Tensile-dominant fractures observed in hydraulic fracturing laboratory experiment using Eagle Ford shale, *Geophys. J. Int.*, 222, 769–780.
- Tanaka R. et al. 2021. Preparatory AE activity of hydraulic fracture in granite with various viscous fluids revealed by deep learning technique, *Geophys. J. Int.*, 226, 493–510.
- Ronneberger O., Fischer P., Brox T., 2015. U-Net: convolutional networks for biomedical image segmentation, *Miccai*, 9351, 234–241.