

# 深層学習と地震シミュレーションによる地震震源決定手法の開発

課題責任者

杉山大祐 海洋研究開発機構 付加価値情報創生部門 情報エンジニアリング  
プログラム

著者

杉山大祐\*<sup>1</sup>, 坪井誠司\*<sup>2</sup>

\*<sup>1</sup> 海洋研究開発機構 付加価値情報創生部門 情報エンジニアリングプログラム、\*<sup>2</sup> 海洋研究開発機構 付加価値情報創生部門 地球情報基盤センター

地震シミュレーションと機械学習を組み合わせて地震震源を特定する新しい手法を開発した。現実的な 3 次元地球モデルの数値地震波形を計算し、これらの波形を使用して、地球の表面での地震波伝播の空間画像のスナップショットを作成する。これらのスナップショットは時間で並べ替えられ、回帰によって地震震源を特定するためのニューラルネットワークの教師データセットとして使用した。このネットワークを観測された地震波形に適用して、この手法の実現可能性を示した。計算された理論的な地震波形を数値的に増やすことができるため、教師データセットの数を増やすことで震源決定の精度を向上させることができる点にこの手法の優位性がある。任意の場所に地震を配置して教師データセットを作成することができるので、これまで地震が発生したことの無い場所で地震を特定することが可能となる。

**キーワード:** 地震震源決定、数値地震波形、機械学習、スペクトル要素法

## 1. はじめに

地震の位置を特定することは、地震が発生しやすい地域の地震活動を研究するために不可欠である。地震の位置を特定するための従来の手法は、P 波や S 波などの地震波形の関連する到着時間を使用する線形化最小二乗法に基づいている[1-2]。この手法は、地球の 1 次元の内部構造を使用するため、3 次元の構造に拡張することは困難であった。我々は、数値計算された理論的な地震波形と機械学習を組み合わせた地震震源決定に対する新しい手法を提案している[3]。数値地震波形は、現実的な 3 次元地球モデルに対して計算され、これらの地震記象は、地球の表面での地震波伝播の空間画像のスナップショットを作成するために使用される。これらのスナップショットを時間で並べ替え、これらの画像を畳み込みニューラルネットワークの教師データセットとして使用して、震源、深さ、発震時、マグニチュードなどの地震震源パラメータを回帰で推定する。このニューラルネットワークを実際に観測された地震波形データに適用することにより、この手法が地震震源を正確に特定することを示し、更なる精度向上について考察した。

## 2. 地震シミュレーション

ここでは、プログラムパッケージ SPECFEM3D[4-7]を使用して、スペクトル要素法を使用して現実的な地球モデルの理論的な地震記象を計算した。数値地震記象の計算には、Earth Simulator 4 (ES4) を使用した。数値地震記象は領域を  $48 \times 48$ 、すなわちスペクトル要素メッシュの 2,304 スライスに生成して計算した。各スライスは、ES4 上の SX-Aurora TSUBASA の単一コアに割り当てられ、 $768 \times 768$  格子点に細分され、5.6 秒以上の精度で数値地震記象を生成した[8]。SX-Aurora はベクトルプロセッサであり、SPECFEM3D コードはベクトルプロセッサ用に最適化さ

れた。NEC が提供する FTRACE ルーチンを使用して最適化のパフォーマンスを測定したところ、ピークパフォーマンス率は 9.4% であった。計算用のメッシュを生成するために、箱根火山地域の地震観測ネットワークのデータを使用した。Yukutake ら[9]によって構築された箱根地域の 3D 地震波速度モデルを構造モデルとして使用している。神奈川県温泉研究所が運営する地震観測所に対する数値地震記象を、0.1 秒のサンプリング間隔で計算した。次に、地震観測点に対して計算された地震記象から、地震ネットワークを占める  $32 \times 32$  の画像を生成した。

教師データセットを作成するために、 $0.01^\circ$  の空間距離を使用して箱根地域に震源を設定し、地震波伝搬画像を作成した。教師データセットに使用された地震の総数は 3,600 である (図 1)。時間に対する波動伝播画像の例を図 2 に示す。その結果、教師データセットとして  $32 \times 32$ 、時間間隔 0.1 秒で、地表での地震波伝播の約 1,080,000 枚の画像を生成した。ES4 を使用することで、これらの画像を 1 週間以内に計算することが可能となった。

## 3. 3D-CNN

ここでは、ネットワークアーキテクチャとして 3D-CNN を使用した。 $32 \times 32$  の画像が入力として利用され、緯度、経度、深さ、発生時間、マグニチュードなどの震源パラメータが回帰によって推定された。この研究で使用された 3DCNN のアーキテクチャを図 3 に示す。3DCNN は、2DCNN の拡張を反映している[10]。イベントの時系列 (たとえば、図 3 に示す  $x \times y \times t$  から) の 3D 構造は、学習と推定の入力として使用される。6 秒 (60 画像) の時間に対し、60 のスナップショット画像を使用して 20 回 (地震波形が開始してから最大 2 秒後) 推定が実行され、地震波の到着から 8 秒後に震源パラメータが得られた。

3D CNN モデルは、通常、2DCNN と比較して長い学習時間を必要とする。本研究では、これが GPU パフォーマンスで

はなく、I/O ランダムアクセスに関連があることが分かった。この問題を処理するために、完全な教師データセットをメモリに読み込むことで、ES4 の 1GPU ノードを使用した 120 エポックの 5 つのパラメータの学習時間を 2 時間に短縮することが出来た。

#### 4. 3D-CNN の検証

1,080,000 の教師データ画像を、教師データ (80%) と検証データ (20%) に分割した。教師データを分割する際に、検証に関係する地震はテストから除外した (図 1)。ネットワークパラメータは、教師データセットの不一致を最小限に抑えることで震源パラメータを推定するように最適化した。最適化後、検証データセットを使用して結果を検証した。1 つのネットワークを使用して、5 つの震源パラメータを推定した。8 秒後に得られた震源パラメータ値を推定値と見なした。推定値に関連する二乗平均平方根誤差 (RMSE) は、検証データセットからのものと同等であり、すべての地震の推定パラメーターを検証に使用した。

#### 5. 実データに対する汎化

以前の研究[3]で行ったように、開発されたニューラルネットワークを実際の地震計データ用に汎化した。データを調査し、2015 年から 2019 年の間に日本の箱根地域で発生したマグニチュード約 2.0 の 173 の地震を選択した。32×32 の画像は、教師データセットと同じ方法で作成され、パラメータを推定するためのニューラルネットワークの入力として使用した。推定されたパラメータと神奈川県温泉研究所がこれらの地震について報告したパラメータとの間の RMSE を推定した。結果の比較は、提案されたニューラルネットワークが一般的に良い結果を提供することを示している。この結果は、観測所への地震波の到着時間を用いることなく、地震波形伝播の画像を用いて震源パラメータを推定できることを示唆している。この結果は、この手法を使用することで、3D 地球構造を地震震源の決定に明示的に含めることができることも示している。

ここでは、震源パラメータの精度がこの技術でどのように改善されるかを調べた。以前の作業とは異なる方法で教師データセットを生成することを試みた。その結果、観測された地震について計算された理論地震記象を教師データとして含め、検証に使用された地震を教師データセットに含めなくても、推定誤差が減少することが分かった。これらの試験結果はまだ分析中だが、教師データセットのこれらの変更により、一般的な地震位置の精度を維持しながら、地域で一般的な地震位置の精度が向上することが期待できる。これらの検討の結果から、実際の地震観測ネットワークに適用される可能性について検討を続ける予定である。

#### 謝辞

理論地震記象は、地球シミュレーターとスーパーコン

ピューターを使用して計算した。利用した地震波形は、神奈川県温泉研究所、国立防災科学技術研究所、気象庁の観測データを用いた。計算には、Computational Infrastructure for Geodynamics (CIG; geodynamics.org) のオープンソースプログラムパッケージ SPECFEM3D を使用した。

#### 文献

- [1] Bolt, B. A., (1960) The revision of earthquake epicenters, focal depths and origin time using a high-speed computer, *Geophys. J. Int.* 3, 434-440.
- [2] Bondár, I., and Storchak, D., (2011) Improved location procedures at the International Seismological Centre, *Geophys. J. Int.* 186, 1220-1244. DOI: 10.1111/j.1365-246X.2011.05107.x.
- [3] Sugiyama, D., Tsuboi, S. & Yukutake, Y. Application of deep learning-based neural networks using theoretical seismograms as training data for locating earthquakes in the Hakone volcanic region, Japan. *Earth Planets Space* 73, 135 (2021). <https://doi.org/10.1186/s40623-021-01461-w>
- [4] Komatitsch, D. and Tromp, J., (2002a) Spectral-element simulations of global seismic wave propagation-I. Validation, *Geophys. J. Int.* 149, 390-412..
- [5] Komatitsch, D. and Tromp, J., (2002b) Spectral-element simulations of global seismic wave propagation-II. Three-dimensional models, oceans, rotation, and self-gravitation, *Geophys. J. Int.* 150, 303-318.
- [6] Komatitsch, D., Tsuboi, S., and Tromp, J., (2005) The spectral-element in seismology, in *Seismic Earth: Array analysis of broadband seismograms*, *Geophys. Monograph* 157, 205.
- [7] Tsuboi, S., Komatitsch, D., Ji, C., et al. (2003) Broadband modeling of the 2002 Denali fault earthquake on the Earth Simulator, *Phys. Earth Planet. Inter.* 139, 305-312.
- [8] Tsuboi, S., Ando, K., Miyoshi, T., et al., (2016) A 1.8 trillion degrees of freedom, 1.24 petaflops global seismic wave simulation on the K computer. *Int. J. High Perform Comput Appl.* 30, 411-422. DOI: 10.1177/1094342016632596
- [9] Yukutake Y, Honda R, Harada M, Arai R, Matsubara M (2015) A magma-hydrothermal system beneath Hakone volcano, central Japan, revealed by highly resolved velocity structures. *J Geophys Res Solid Earth* 120:3293–3308.

<https://doi.org/10.1002/2014JB011856>

- [10] Tran D, Bourdev L, Fergus R, Torresani L, Paluri M (2015) Learning spatiotemporal features with 3D convolutional networks. In: The IEEE international conference on computer vision (ICCV). pp 4489–4497




図3 3DCNN に用いたネットワークアーキテクチャ




図1. 赤い点は学習に使用された地震を示す。+は観測された地震の震源、三角形は地震観測所を示す。使用された地震の総数は 3600 であり、教師データセットとして 2880 のイベントを使用した。




図2. 学習プロセスに使用される伝播画像の例。色は、それぞれ青から赤に変化するにつれて  $-1.4 \times 10^{-6}$  m から  $1.4 \times 10^{-6}$  m の垂直変位を示す。

# Development of Earthquake Hypocenter Determination Technique Combining Deep Learning with Earthquake Simulation

## Project Representative

Daisuke Sugiyama Information Engineering Program, Research Institute for Value-added Information Generation, Japan Agency for Marine-Earth Science and Technology

## Authors

Daisuke Sugiyama <sup>\*1</sup>, Seiji Tsuboi <sup>\*1</sup>

<sup>\*1</sup> Information Engineering Program, Research Institute for Value-added Information Generation, Japan Agency for Marine-Earth Science and Technology, <sup>\*2</sup> Center for Earth Information Science and Technology, Research Institute for Value-added Information Generation, Japan Agency for Marine-Earth Science and Technology

We develop a new technique combining earthquake simulation and machine learning to locate earthquake hypocenters. We compute numerical seismic waveforms for a realistic three-dimensional Earth model and use these waveforms to create snapshots of spatial images for seismic wave propagation at the surface of the Earth. These snapshots are sorted by time and used as a training dataset for a neural network to locate earthquake hypocenters by regression. We apply this network to the observed seismic waveforms to demonstrate the feasibility of this procedure. Our technique is beneficial because it can improve the accuracy of hypocenter determination by increasing the number of training datasets as the computed theoretical seismic waveforms can be numerically increased. We may arbitrarily put earthquakes to create a training dataset at any location, which will enable us to locate earthquakes at a location where earthquakes have never occurred before.

**Keywords:** earthquake locating technique, numerical seismic waveforms, machine learning, spectral-element method

## 1. Introduction

Locating earthquakes is an essential procedure in seismology to study seismic activity in earthquake-prone regions. The conventional technique for locating earthquakes is based on the linearized least squares procedure using the associated arrival times of seismic waveforms, such as the first arrival P-wave and secondary S-wave data [1-2]. This technique uses the one-dimensional internal structure of the Earth and is difficult to extend to a three-dimensional structure. We have proposed a new technique that combines numerically computed theoretical seismic waveforms and machine learning to locate earthquakes [3]. Numerical seismic waveforms, i.e. numerical seismograms, are calculated for a realistic three-dimensional Earth model and these seismograms are used to create snapshots of spatial images for seismic wave propagation at the surface of the Earth. We sort these snapshots by time and use these images as training dataset for a convolutional neural network to estimate the earthquake hypocentral parameters, such as the epicenter, depth, origin time, and magnitude, by regression. By applying this neural network to the actual observed seismic waveform data, we have shown that this technique accurately locates the earthquake hypocenter.

## 2. Earthquake Simulation

We used the program package SPECSEM3D [4-7] to calculate the theoretical seismograms for the realistic Earth model using the Spectral-element Method. We use the Earth Simulator 4 (ES4), for the computation of numerical seismograms. The numerical seismograms were synthesized using  $48 \times 48$ , yielding 2,304 slices of the spectral-element mesh. Each slice was

allocated to a single core of the SX-Aurora TSUBASA on ES4, and then subdivided into  $768 \times 768$  grid points, thereby enabling the generation of numerical seismograms with an accuracy of 5.6 s and longer [8]. SX-Aurora is the vector processor, and the SPECSEM3D code is optimized for the vector processor. We have measured the performance of the optimization using the FTRACE routine supplied by NEC and found that the peak performance ratio was 9.4%. To generate a mesh for the computation, we select the Hakone volcanic region in Japan, where the data from a seismic observation network can be used. A 3D seismic wave speed model of the Hakone region constructed by Yukutake et al [9] was also used. We calculate the numerical seismograms at the seismographic stations operated by the Hot Springs Research Institute of Kanagawa Prefecture using a sampling interval of 0.1 s. Then,  $32 \times 32$  images occupying the seismic network were generated from the seismograms computed for the seismic stations.

To create the training dataset, the hypocenter was set in the Hakone region using a spatial distance of  $0.01^\circ$  to produce the seismic wave propagation images, and the total number of earthquakes used for the training dataset was 3,600 (Figure 1). An example of a wave propagation image with respect to time is shown in Figure 2. Consequently, approximately 1,080,000 images of seismic-wave propagation at the surface were generated, with a  $32 \times 32$  and time interval of 0.1 s as the training dataset. By using ES4, we could compute these images within a week.

## 3. 3D-CNN

In this study, we used a 3D-CNN as the network architecture.

A  $32 \times 32$  image was exploited as the input, and hypocentral parameters including the latitude, longitude, depth, occurrence time, and magnitude, were estimated by regression. The architecture of the 3D CNN used in this study is shown in Figure 3, with the 3D CNN reflecting an extension of the 2D CNN [10]. A time series of the event (e.g., 3D structure from  $x \times y \times t$  shown in Figure 3) is used as an input for learning and estimation. A duration of 6 s (60 images) was applied, with the estimates performed 20 times (up to 2 second after the seismic waveform started) using 60 snapshot images, thus, yielding the hypocentral parameters 8 s after the arrival of seismic waves.

A 3D CNN model generally requires a longer learning time compared to a 2D CNN. In this study, we realized that this was linked to the I/O random access, instead of GPU performance. To handle this problem, the complete training dataset was loaded into the memory, thereby shortening the learning time to 120 epochs in 2 hours involving learning time of 5 parameters using 1GPU nodes of ES4.

#### 4. Validation and Testing for 3D-CNN

The 1,080,000 training data images were divided into training data (80%) and validation data (20%). In partitioning the training data, the earthquakes involved in the validation were excluded from the testing (Figure 1). The network parameters were optimized to estimate the hypocentral parameters by minimizing discrepancies in the training dataset. After optimization, the results were verified using the validation dataset. One network was used to estimate the five hypocentral parameters. The hypocentral parameter values obtained after 8 s were considered as estimates. The root mean square errors (RMSE) associated with the estimated values were comparable to those from the validation dataset, and the estimated parameters for all earthquakes were used for validation.

#### 5. Generalization for Real Data

We generalized the developed neural network for the real seismographic data, as we did in our previous work [3]. The data were examined and 173 earthquakes with a magnitude of approximately 2.0, which occurred in the Hakone region, Japan, between 2015 and 2019 were selected. The  $32 \times 32$  images were created in the same manner as the training dataset and employed as the inputs for the neural network to estimate the parameters. The RMSE between the estimated parameters and those reported by the Hot Springs Research Institute of Kanagawa Prefecture for these earthquakes was estimated. The comparison of the results showed that the proposed neural network provides good results in general. The results suggest that hypocentral parameters can be estimated using images of seismic wave propagation evolution without considering the arrival times of seismic waves at observatories. The results also demonstrate that the 3D Earth structure can be explicitly included in the earthquake hypocenter determination by using our technique.

Here, we extend our work to examine how the accuracy of the hypocentral parameters may be improved in our technique. We generate learning dataset in different ways from our previous work. We include theoretical seismograms computed for observed earthquakes as training data and found that the estimation errors decreased even though we do not include earthquakes used in the verification are not included in the training dataset. Although we are in the preliminary stage of analysis for these trials, these modifications in the training dataset should improve the accuracy of the earthquake location that are common in the region, while maintaining the accuracy for earthquake location in general. We show the results of these examinations and discuss the possibility of broader use of our method to be applied for the actual seismic observation networks.

#### Acknowledgement

Theoretical seismograms were created using the Earth Simulator and supercomputers in JAMSTEC, Japan. The seismic waveforms utilized were provided by the Hot Spring Research Institute of Kanagawa Prefecture, the National Research Institute for Earth Science and Disaster Resilience, and the Japan Meteorological Agency. The open-source program package SPEC3D from the Computational Infrastructure for Geodynamics (CIG; geodynamics.org) was employed for computation.

#### References

- [1] Bolt, B. A., (1960) The revision of earthquake epicenters, focal depths and origin time using a high-speed computer, *Geophys. J. Int.* 3, 434-440.
- [2] Bondár, I., and Storchak, D., (2011) Improved location procedures at the International Seismological Centre, *Geophys. J. Int.* 186, 1220-1244. DOI: 10.1111/j.1365-246X.2011.05107.x.
- [3] Sugiyama, D., Tsuboi, S. & Yukutake, Y. Application of deep learning-based neural networks using theoretical seismograms as training data for locating earthquakes in the Hakone volcanic region, Japan. *Earth Planets Space* 73, 135 (2021). <https://doi.org/10.1186/s40623-021-01461-w>
- [4] Komatitsch, D. and Tromp, J., (2002a) Spectral-element simulations of global seismic wave propagation–I. Validation, *Geophys. J. Int.* 149, 390-412..
- [5] Komatitsch, D. and Tromp, J., (2002b) Spectral-element simulations of global seismic wave propagation–II. Three-dimensional models, oceans, rotation, and self-gravitation, *Geophys. J. Int.* 150, 303-318.

- [6] Komatitsch, D., Tsuboi, S., and Tromp, J., (2005) The spectral-element in seismology, in Seismic Earth: Array analysis of broadband seismograms, Geophys. Monograph 157, 205.
- [7] Tsuboi, S., Komatitsch, D., Ji, C., et al. (2003) Broadband modeling of the 2002 Denali fault earthquake on the Earth Simulator, Phys. Earth Planet. Inter. 139, 305-312.
- [8] Tsuboi, S., Ando, K., Miyoshi, T., et al., (2016) A 1.8 trillion degrees of freedom, 1.24 petaflops global seismic wave simulation on the K computer. Int J. High Perform Comput Appl. 30, 411-422. DOI: 10.1177/1094342016632596
- [9] Yukutake Y, Honda R, Harada M, Arai R, Matsubara M (2015) A magma-hydrothermal system beneath Hakone volcano, central Japan, revealed by highly resolved velocity structures. J Geophys Res Solid Earth 120:3293–3308. <https://doi.org/10.1002/2014JB011856>
- [10] Tran D, Bourdev L, Fergus R, Torresani L, Paluri M (2015) Learning spatiotemporal features with 3D convolutional networks. In: The IEEE international conference on computer vision (ICCV). pp 4489–4497




Figure 2. Map of an example propagation image used for learning process. Colors indicate vertical displacement from  $-1.4 \times 10^{-6}$  m to  $1.4 \times 10^{-6}$  m as they change from blue to red respectively.




Figure 3. Network architecture used for the 3D convolutional neural network.




Figure 1. Red dots are the earthquakes used for learning. Crosses are epicenters of observed earthquakes. Triangles are seismic observation stations. The total number of earthquakes used is 3600 and we used 2880 events as the training dataset.