

# 機械学習による東北地方の地震の即時スペクトル予測\*

東北大学災害科学国際研究所 大野 晋

## 1. はじめに

緊急地震速報に代表される早期地震警報は、震源に近い観測点での P 波検知により地震規模と位置を推定し、推定震源情報に基づいて S 波主要動の到達時刻を、地震動評価式（経験式）から S 波主要動の振幅（震度）を推定する方法と、データ同化と呼ばれる物理モデルによるシミュレーションと観測値の融合による逐次更新の手法が主なものである。

前者は早期に警報を発することができるが、震源決定と経験式両方の誤差が累積するため振幅の推定精度が低い。後者は精度の良い予測には P 波検知より時間がかかる。いずれも震度を対象としているが、構造物の応答・被害予測には周期情報を含むスペクトルの方が望ましい。

これらの課題に対して、機械学習を用いて、震源に近い前線観測点のスペクトルから目標観測点のスペクトルを逐次的に更新推定することで、スペクトルの即時予測を行う手法を提案している<sup>1)2)</sup>。ここでは入力情報に震源位置を加えたケースについて報告する。

## 2. データ

解析に用いたデータは文献 2 と同じであり、前線観測点として MYG011(牡鹿)、目標観測点として MYG013(仙台)を用い、2004/1/30 から 2023/5/14 までのマグニチュード 5.0 以上の 203 地震を対象とした。図 1 に加速度最大値とマグニチュードの関係を、図 2 に観測点位置と震源位置及び F-net によるメカニズム解を示した。




図 1 加速度最大値とマグニチュードの関係




図 2 観測点・震源位置及びメカニズム解

### 3. 解析手法

機械学習モデルを図3に示す。連続観測記録がリアルタイムで得られることを前提として、震源に近い前線観測点（複数可）と予測対象とする目標観測点を設定し、前線観測点はP波到達以降、目標観測点はS波到達以降について、時間窓を延長更新して、前線-目標観測点間の各時間窓のスペクトルの関係をCNN（特徴量抽出）とLSTM（時間変化学習）モデルを用いて学習させている。

なお、文献1)2)では入力として前線観測点のスペクトルのみを用いていたが、次節で示すように震源域を広く取ると精度が低下し、前線観測点のP波部分のみを用いた場合に特に精度低下が見られた。文献2ではその原因として、前線-目標観測点間の伝達特性に（おそらく入射条件が異なるため）震源域依存性が見られること、それは前線S波-目標S波間よりも前線P波-目標S波間の方が顕著であることを指摘し、震源域を限定すると（具体的には図2の枠で囲んだArea-N,C,Sの領域に限定すると）精度が向上する結果を得ていた。

本稿では、震源位置情報を入力に取り込むために、図3左下のように気象庁震源位置を入力別のチャンネルに追加することを試みた。




図3 CNN-LSTM モデル (文献1)を修正)

### 4. 適用例

まず、前線観測点のフーリエスペクトルのみを入力としたケースについて示す。図1の全地震をトレーニングデータとテストデータに9:1の割合で分割し、全領域のトレーニングデータを対象に機械学習を行い、テストデータの一つであるN1地震（2020/9/12, M6.2）を推定した例<sup>2)</sup>を図4に示す。

(a)(b)が前線P波から目標S波区間を推定した場合、(c)(d)が前線S波から目標S波区間を推定した場合で、(a)(c)が評価誤差を、(b)(d)がフーリエスペクトルを示している。(e)(f)は前線観測点と目標観測点の波形で、時刻を揃えて示している。前節で述べたとおり、S波よりもP波区間の推定精度が低下していることが確認できる。




図4 図1の全領域の地震をトレーニング対象とした場合のN1地震の推定例  
(前線観測点スペクトルのみを入力)

図5は、トレーニングデータを推定対象 (N1地震) と同じ領域である図1のArea-N内に絞った場合の推定例<sup>2)</sup>である。図4よりも全体の推定精度が向上していること、S波を含む方が推定精度は高いが、P波のみでも概略は予測できることがわかる。




図5 図1のArea-N内の地震をトレーニング対象とした場合のN1地震の推定例  
(前線観測点スペクトルのみを入力)

図 6 は、トレーニングデータを図 1 の全領域に戻し、入力情報に震源位置を加えた場合の N1 地震に対する推定例である。図 4 と比較して、P 波区間でも概ね目標観測点のスペクトルを推定できていることがわかる。ただし、P 波区間・S 波区間とも予測スペクトルは全体的に平滑化されており、山谷の再現性は震源域を限定した図 5 の方が良好であることも確認できる。




図 6 図 1 の全領域の地震をトレーニング対象とした場合の N1 地震の推定例  
(前線観測点スペクトル及び震源位置を入力)

## 5. まとめ

機械学習を用いて、震源に近い前線観測点のスペクトルから目標観測点のスペクトルを逐次的に更新推定することで、スペクトルの即時予測を行う手法<sup>1)2)</sup>に対し、震源位置を入力情報として追加することで、広い震源域に対する特に P 波区間での適用性の向上を試みた。その結果、適用性の向上は確認できたが、震源域を限定した方がスペクトルの山谷の再現性は良好であり、データが十分ある場合は震源域を限定した方が再現性は高いものと思われる。

今回用いた機械学習と、単なる観測点間の伝達関数を用いた予測との違いは、非線形性を含む多点多成分間の伝達特性を自動的に学習できること、また応答スペクトルや Wavelet 変換にも適用可能な拡張性にある。今後入力の多点化や wavelet 変換についても今回と同様の検討を行い、モデルの高精度化を進める予定である。

## 謝辞

防災科研 K-NET のデータ<sup>3)</sup>を利用させていただきました。本研究では British University of Egypt の Torky 博士（元東北大学院生）のプログラムを修正して用いています。深層学習には Tensorflow<sup>4)</sup>, Keras<sup>5)</sup>, scikit-learn<sup>6)</sup>を用いました。本研究は JSPS 科研費 JP23K04102 の助成を受けたものです。

## 参考文献

- 1) A. Torky & S. Ohno (2024) A FREQUENCY-BASED SITE FORECASTING METHOD USING DEEP LEARNING, Proc. 18WCEE.
- 2) S. Ohno & A. Torky (2024) SOURCE DEPENDENCY OF SPECTRAL TRANSFER CHARACTERISTICS FOR REALTIME SPECTRAL FORECASTING, Proc. 18WCEE.
- 3) National Research Institute for Earth Science and Disaster Resilience (2019) NIED K-NET, KiK-net, National Research Institute for Earth Science and Disaster Resilience, doi:10.17598/NIED.0004
- 4) TensorFlow: doi: 10.5281/zenodo.4724125
- 5) Keras: <https://keras.io>
- 6) scikit-learn: <https://scikit-learn.org/stable/>