機械学習による即時地震動スペクトル予測：残差分析*

東北大学災害科学国際研究所　大野　晋

1. はじめに

著者らは，地震時の構造物応答の即時予測を目指して，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，地震動スペクトルの即時予測を行う手法を提案している[1)2)3)]。ここでは Nested Cross Validation（Nested-CV)[4)] による残差分析の結果を報告する。

2. データ

前線観測点として防災科研 K-NET[5)]の MYG011(牡鹿)，目標観測点として同じく K-NET の MYG013(仙台)を用い，2004/1/30 から 2025/3/31 までのマグニチュード 5.0 以上の 189 地震を対象とした。図 1 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。

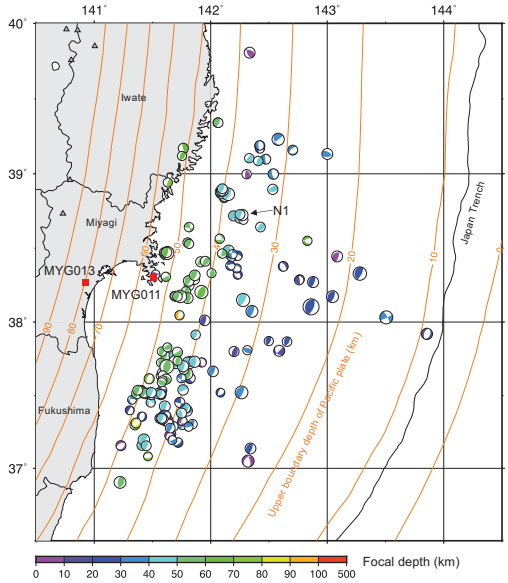

図 1　観測点・震源位置及びメカニズム解（プレート境界深さは文献 6,7）

3. 解析手法

機械学習モデル[1)]を図 2 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

*Realtime Prediction of Strong-motion Spectra using Machine Learning: Residual Analysis by Susumu Ohno

時間窓のスペクトル（0.2-20Hz 間で対数等間隔でサンプリングした周波数におけるフーリエ振幅の常用対数値）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 3)では震源位置情報を入力の別チャンネルに追加していたが，ここでは文献 1)の前線観測点のスペクトルのみを入力とした場合についてのみ検討している。

なお，図 2 に示したハイパーパラメータ（CNN の層数(1)，カーネルサイズ(3*12)，フィルタ数(1), LSTM のセル数(400), 層数(1)）は目標観測点の PGA で 5 つに層別分割(Stratified K-fold split)した Inner-Cross Validation (Inner-CV)により決定している。

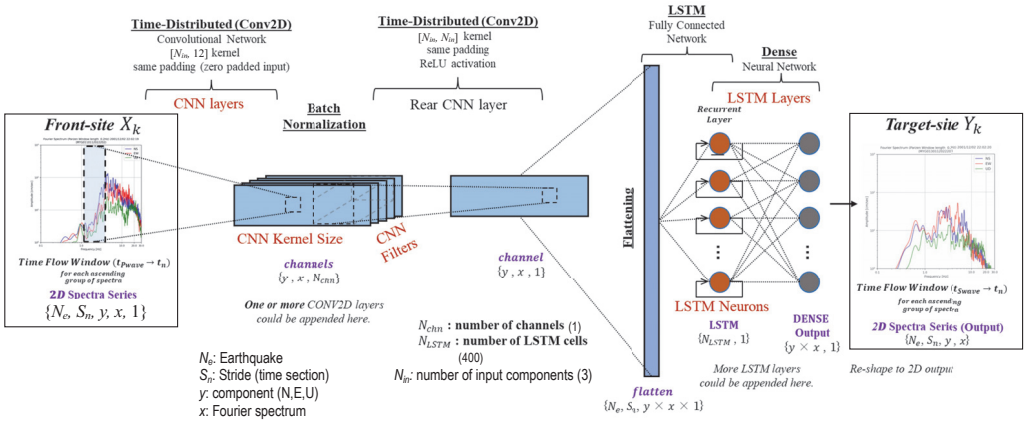

図 2　CNN-LSTM モデル　（文献 1)を修正）

4. 解析結果

前述の通り，5 分割したデータについて Inner CV でハイパーパラメータを決定したのち，Outer-Cross Validation (Outer-CV) で各地震に対する予測値を求めた。図 3 に評価結果の例を示す。(a)が評価誤差，(b)がフーリエスペクトルを示している。(c)(d)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。

地震ごとの残差平均（各周波数の予測値-観測値の平均）の分布を図 4, 図 5 に示す。Nested-CV により，分割ごとにニューラルネットの重み自体は異なるものの，各地震を，学習に用いた Training-Validation Dataset から独立したテストデータとして扱うことが可能となる。図 4 では残差平均を震央位置に示しているが，海岸に近い西側で負の値を取っており，過小評価が多いことがわかる。図 5 では残差平均の Mw 依存性および目標観測点の水平 PGA 依存性を示しているが，Mw に対しては依存性は少ないものの，PGA に対してはその値が大きいほど過小評価になる傾向が読み取れる。原因としては，振幅依存性の学習が不十分なことが考えられる。

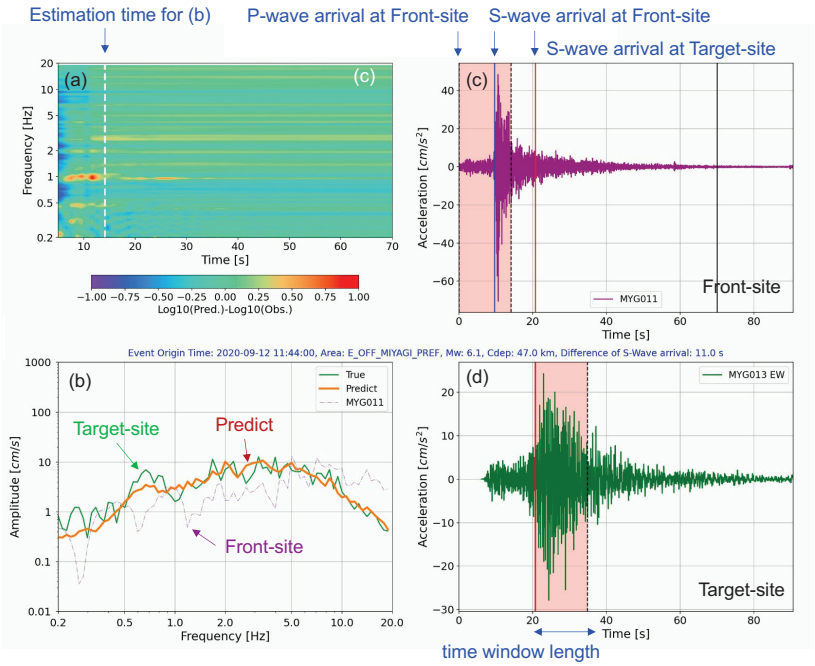

図 3　評価結果例（図 1 中の N1 地震）

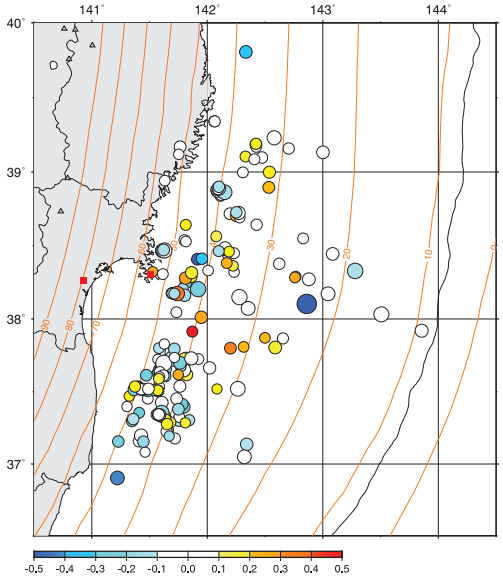

図 4　各地震の残差平均の分布

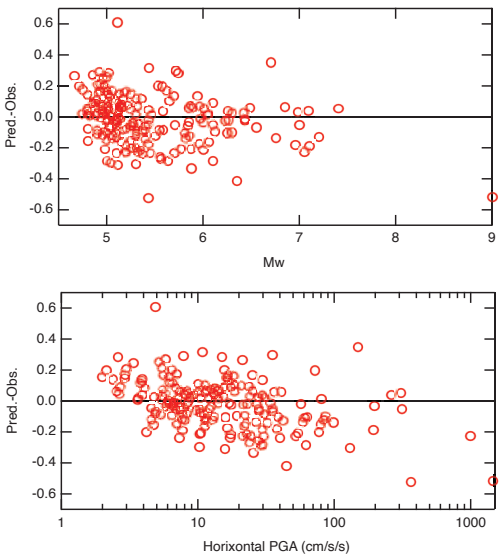

図 5　各地震の残差平均の Mw,
目標観測点 PGA との関係

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に対し，Nested Cross Validation を適用することで，データに用いた全地震に対する予測誤差を評価した。その結果，振幅依存性の学習が不十分な可能性を指摘した。

地震記録のように少ないデータに機械学習を適用する場合，精度向上のための要因分析が難しいことがあるが，Nested-CV は有効な手段と思われる。今後は，文献 3)の震源情報や海域観測網の利用等により，精度向上に取り組む予定である。

謝辞

防災科研 K-NET のデータ [3]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（元東北大大学院生）のプログラムを修正して用いています。対象地震の選定には東北大学工学部 4 年茶之原琉斗氏に協力いただきました。深層学習には Tensorflow[8], Keras[9], scikit-learn[10], Keras-tuner-cv[11]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) 大野晋 (2025) 機械学習による東北地方の地震の即時スペクトル予測，東北地域災害科学研究，61, pp.17-21
4) Varma, S., Simon, R. (2006) Bias in error estimation when using cross-validation for model selection. BMC Bioinformatics 7, 91. https://doi.org/10.1186/1471-2105-7-91
5) 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
6) Kita, S., T. Okada, A. Hasegawa, J. Nakajima, and T. Matsuzawa (2010), Anomalous deepening of a seismic belt in the upper-plane of the double seismic zone in the Pacific slab beneath the Hokkaido corner: Possible evidence for thermal shielding caused by subducted forearc crust materials, Earth Planet. Science Lett., 290, 415-426.
7) Nakajima, J., and A. Hasegawa (2006), Anomalous low-velocity zone and linear alignment of seismicity along it in the subducted Pacific slab beneath Kanto, Japan: Reactivation of subducted fracture zone?, Geophys. Res. Lett., 33, L16309, doi: 10.1029/2006GL026773.
8) TensorFlow: doi: 10.5281/zenodo.4724125
9) Keras: https://keras.io
10) scikit-learn: https://scikit-learn.org/stable/
11) keras-tuner-cv: https://github.com/VZoche-Golob/keras-tuner-cv/tree/kerastuner146