

常時微動記録からサイト增幅特性を推定するための

Attention 機構を用いた機械学習モデルの構築

Construction of the Machine Learning Model Based on Attention Mechanism to Estimate Site Amplification Factor from Microtremor Record

○按田 悠・長嶋 史明・松島 信一

○Yuu ANDA, Fumiaki NAGASHIMA, Shinichi MATSUSHIMA

Site amplification factors (SAFs) directly influence ground motions and building damage. Generally, SAF is estimated through subsurface structure exploration. Previous research has employed deep neural network (DNN) to directly estimate SAFs from the microtremor Horizontal-to-Vertical spectral Ratios (MHVRs). This study constructed a DNN model to directly estimate SAFs from microtremor time history records. The input data consists of time segments obtained from microtremor records measured at 124 stations of K-NET and KiK-net, and the MHVR averaged from the time segments. The target SAFs for machine learning were obtained by Nakano et al. (2023), which were estimated by Generalized Inversion Technique. The attention mechanism is used for learning between segments within the same time frame (Self-Attention) and for learning the output of the self-attention and the MHVR (Cross-Attention). Our DNN model effectively reproduced training and validation data, successfully estimating the SAF for test data.

1. はじめに

サイト增幅特性(SAF)は周波数ごとの地盤增幅率を指し、建物の被害に直接的に影響を与える特性である。観測記録から地盤構造を求める、その地盤構造から SAF を求めることも多いが、観測記録から直接的に SAF を求めることができれば、地盤構造同定に関連する不確実性を除いた推定が可能となる。本研究では、単点微動観測記録から簡便かつ直接的に SAF を推定することを目的とした機械学習モデルの構築を行った。

2. データ概要

入力データは K-NET および KiK-net で観測した 124 地点(図 1)の微動記録から作成する。まず微動記録から 20.48 秒の小区間を 1 秒ずつずらしながら切りだし、小区間を 3 成分の振幅二乗和が小さい順かつ 75% 以上の時間の重複がないようにタイムセグメントを抽出する。得られたタイムセグメントに上側遮断周波数 28.28 Hz、下側遮断周波数 0.07 Hz の 4 次のバタワーズフィルターによるフィルター処理を行い、各タイムセグメントの 3 成分の絶対振幅の最大値で正規化する。正規化した各タイムセグメントで 3 成分合成波形から変動係数を計算し、変動係数の小さい 50 区間を機械学習のための入力データとする。微動水平上下スペクトル比 (MHVR) の計算には上述の 50 区間を用

い、タイムセグメントの前後 1 秒にコサインテーパーをかけ、高速フーリエ変換をし、バンド幅 0.1 Hz の Parzen ウィンドウで平滑化した上で幾何平均を求める。機械学習のターゲットには、Nakano et al. (2023) でスペクトルインバージョン解析 (GIT) により推定された SAF を使用する。MHVR と SAF の対象周波数範囲は 0.1~20 Hz、データ数を 200 点とし、周波数が対数スケールで等間隔となるようにリサンプリングする。また MHVR と SAF の振幅は常用対数値とする。以上の条件で作成したデータセットに対し、観測点単位で $k=10$ の kfold 交差検証を行うために、各分割(観測点)が 1 度ずつテストセットになるように 10 組のデータセットを作成した。各 fold において、テストセットを除いた観測点の全タイムセグメントを観測点の区別なく 9:1 に分割しトレーニングセットとバリデーションセットを作成する。

3. モデル概要

本研究で提案する機械学習モデルの概要図を図 2 に示す。Self-Attention と Cross-Attention は Multi-Head-Attention と呼ばれる Attention 機構から構成される。Attention 機構は入力の全系列を内積と Softmax 関数により一括で処理することで長距離依存性を解決したモデルである。

モデルサイズについて埋め込み次元 $d=128$ 、 \sim

ッド数 $h=4$ とする。学習率は 0.001、バッチサイズは 8、エポック数は 200 とする。損失関数は平均二乗誤差 (MSE)、最適化アルゴリズムには AdamW を使用する。

4. 解析結果

kfold 交差検証を行いつつ機械学習を行った。全 fold を比べたときに、トレーニングやバリデーション、テストの MSE はそれぞれ fold 間で同程度となるようなモデルを作成できた。バリデーションセットの MSE が全 fold で最小となった fold6 の学習結果を図 3 に示す。トレーニングセットに合わせてバリデーションセットの損失関数の値は減少しており、汎化性能の高いモデルであることがわかる。図 4 で示す SAF の予測結果からも、異なるタイムセグメントの入力でも正しい出力となっていることが確認できる。図 5 のテストセットの結果から、学習データに含まれない観測点でも学習済モデルを用いて SAF を予測できることが確認できる。fold6 のテストセットにおけるターゲットと予測結果間の MSE と相関係数は、テストセット 12 観測点平均で MSE は 0.066、相関係数は 0.74 となった。

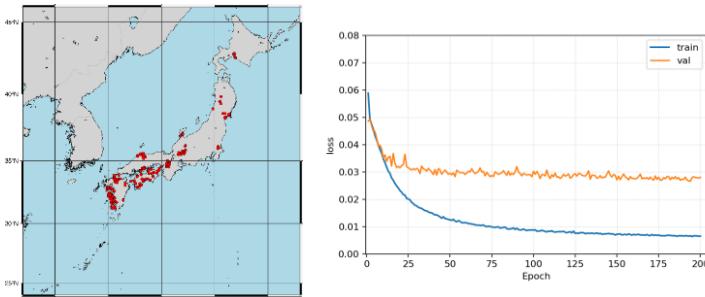


図 1 観測点概要

図 3 fold6 の学習曲線

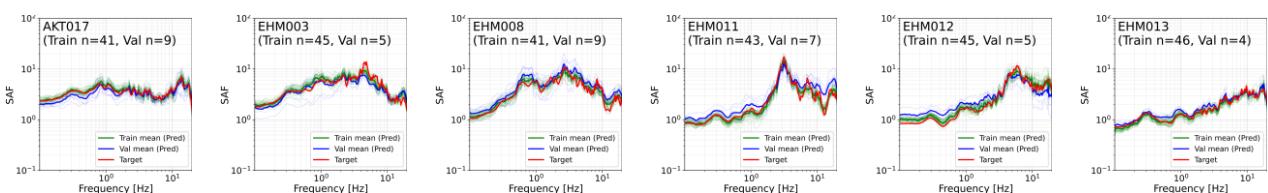


図 4 fold6 におけるトレーニング (緑線)・バリデーションセット (青線) の学習・予測結果

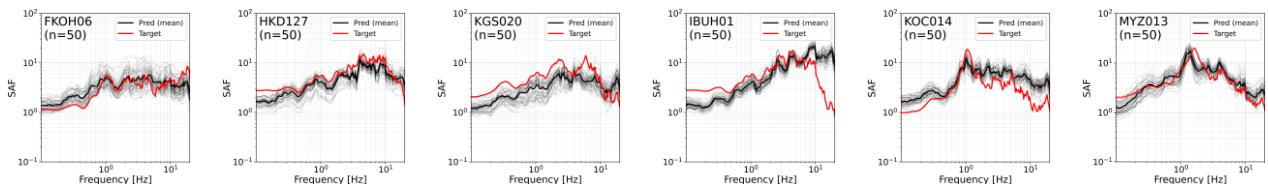


図 5 fold6 におけるテストセットの予測結果 (赤: GIT、黒: 予測)

5. まとめ

本研究では、Attention 機構を用いた機械学習モデルを作成し、単点の常時微動記録からサイト增幅特性を推定した。10 個の fold 全てにおいてトレーニングやバリデーションのデータを再現できるモデルを作成でき、テストセットも 7 割程度の観測点で特徴を再現することができた。

謝辞

本研究では、常時微動記録には九州大学および京都大学の川瀬研究室、京都大学の川瀬・松島・長嶋研究室の歴代学生の協力のもとに観測されたデータを使用した。サイト增幅特性には、安藤ハザマ技術研究所の仲野健一氏の解析結果を使用した。また機械学習の構築には Pytorch を使用した。ここに感謝の意を示す。

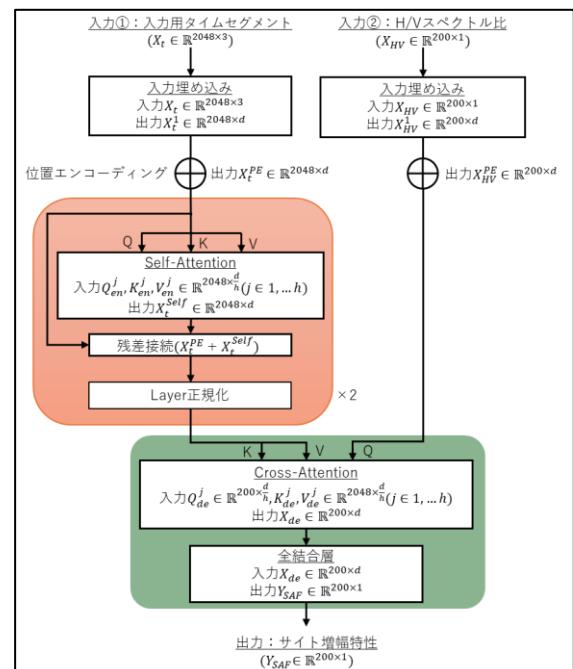


図 2 機械学習モデルフロー図