

C会場 | 特別セッション：S22. 地震学における機械学習の可能性

■ 2019年9月18日(水) 10:45 ~ 12:00 | ㊦ C会場 総合研究8号館NSホール

[S22]AM-2

座長:久保久彦(防災科学技術研究所)、小寺 祐貴(気象庁気象研究所)

10:45 ~ 11:00

[S22-05] 理論地震波形記録の時系列空間伝搬を教師データとした3D CNNを用いた機械学習による震源決定

*杉山 大祐¹、坪井 誠司¹ (1. 国立研究開発法人 海洋研究開発機構)

11:00 ~ 11:15

[S22-06] ランニングスペクトル画像認識による地震・低周波微動シグナルの識別

*中野 優¹、杉山 大祐¹、堀 高峰¹、桑谷 立¹、坪井 誠司¹ (1. 海洋研究開発機構)

11:15 ~ 11:30

[S22-07] ノンパラメトリックベイズを用いた連続波形記録の教師なし自動分類

*小寺 祐貴¹、酒井 慎一²、西宮 隆仁¹ (1. 気象庁気象研究所、2. 東京大学地震研究所)

11:30 ~ 11:45

[S22-08] 震央方位を考慮した機械学習による地点固有の地震動評価モデルの検討

*石井 透¹、小穴 温子¹、和田 健介¹ (1. 清水建設株式会社)

11:45 ~ 12:00

[S22-09] 機械学習を用いた関東地方の地震動評価モデルの検討

*小穴 温子¹、石井 透¹、和田 健介¹ (1. 清水建設)

理論地震波形記録の時系列空間伝搬を教師データとした3D CNNを用いた機械学習による震源決定

Development of 3D Convolutional Neural Network to locate hypocenter with theoretical seismograms of time series as training data.

*杉山 大祐¹、坪井 誠司¹

*Daisuke Sugiyama¹, Seiji Tsuboi¹

1. 国立研究開発法人 海洋研究開発機構
1. JAMSTEC

我々は、昨年の地震学会秋季大会において、理論地震波形記録を生成し、これを教師データ（ある入力データとその正解となるデータを対応付けたもの）として機械学習を行うことにより、震源パラメータの推定を行うニューラルネットワークを構築する試みについて報告した。前回の発表では、関東地方領域にて、震源や規模の異なる多数のパターンの仮想地震を網羅的に計算し、得られた理論地震波形記録から、ある時刻における地表の空間的な地震波伝播画像を生成して、この画像を用いて深層学習を行い、震源パラメータを自動推定するニューラルネットワークを構築することが出来ることを示した。

我々は、このニューラルネットワークによる震源パラメータ推定精度をさらに高めることを目的とし、学習対象を時系列方向に発展させる試みを行った。例えば、地震波形の広がり方から震源近くの細かな振動など、前回用いた地表の変位分布だけでなく、その映像的な時間発展のパターンも学習の対象とする。このような時間発展パターンを学習するため、我々は、ある時間範囲の理論地震波形記録の地表の変位分布を、図1のような3次元形状データに変換した。このようなデータを、3次元形状データ及び映像における動きの学習に特化した3次元畳込みニューラルネットワーク（3D CNN）を用いて学習を行い、実際の観測データの推定を行うことができる推論モデルを得る。

なお、理論地震波形記録生成については、前回と同様にスペクトル要素法のSPECFEM3D_GLOBE(https://geodynamics.org/cig/software/specfem3d_globe/)を用いているが、今回は対象範囲について関東地方から日本列島規模まで広げ、256コア、1 chunkを用いて計算した。用いた3次元地球モデルはS20RTSで、モデルの精度の設定値であるNEXは256、周期は17秒である。震源深さや位置など震源パラメータを変化させた4,200個の仮想地震に対して約5分間の理論地震波形を計算し、約300万枚の地震波伝播画像を生成した。これを用い、数十秒程度の時間発展パターンを3次元形状データとして生成し、教師データとした。もちろん、この3次元形状データはk-Netなどの実際の地震波形観測データからも同様に自動的に生成が可能であり、自動的な震源パラメータの推定も可能である。


このように生成した教師データを基に、先に述べた3D CNNを用いた深層学習を行った。3層の3D畳込み層を用い、86x86の空間伝搬データを時系列方向に20個用い、各震源パラメータを推定する推論モデルを機械学習により生成した。深層学習フレームワークはTensorFlow (<https://github.com/tensorflow>)とnnabla (<https://github.com/sony/nnabla>)を用いた。教師データの生成および機械学習は海洋研究開発機構・地球情報基盤センターが運用する計算クラスターであるDAシステムのGPGPUノードを利用して並列に行い、ニューラルネットワークから推論モデルを構築した。

学習は4,200個の地震の各イベント85:15に分割し、85%である3,570個を学習に用い、学習に使用しない残り15%の630個の地震を用いて交差検証を行ったところ、概ね良好な結果が得られた。最終的に完成した推論

モデルの詳しい推定結果、および実際の観測データに適用した場合の推定結果について発表の際に述べる。

謝辞

本研究は科研費19K12011の助成を受けたものです。また、海洋研究開発機構・地球情報基盤センターの計算機システムを用いました。記して感謝いたします。



ランニングスペクトル画像認識による地震・低周波微動シグナルの識別 Discrimination of earthquakes and tectonic tremor signals by applying a convolutional neural network to running spectral images

*中野 優¹、杉山 大祐¹、堀 高峰¹、桑谷 立¹、坪井 誠司¹

*Masaru Nakano¹, Daisuke Sugiyama¹, Takane Hori¹, Tatsu Kuwatani¹, Seiji Tsuboi¹

1. 海洋研究開発機構

1. JAMSTEC

近年の地震・地殻変動観測網と観測データ解析技術の発達により、プレート境界地震の震源域周辺において、低周波微動、超低周波地震、スロースリップ等のスロー地震が発生していることが明らかになっている。スロー地震の発生メカニズムを解明し、発生状況をモニタすることで、巨大地震の発生メカニズムと準備過程について理解が深まると期待されている。その中でも低周波微動は、低周波成分が卓越し、数十秒以上継続するシグナルとして観測される。低周波微動の検知には主にエンベロープ相関法が用いられるが、この手法では通常地震動も同時に検出してしまうため、地震カタログを用いたり、目視によるチェックによって、低周波微動のイベントだけを抽出する必要がある。

一方で、低周波微動と通常地震動のシグナルは卓越する周波数成分と継続時間が異なり、これらの情報からシグナルを判別できると考えられる。すなわち、低周波微動は通常地震動と比べて10Hz程度以下の低周波成分が卓越し、またシグナルの継続時間は数十秒以上と、ローカルな地震と比べて長時間シグナルが継続する。シグナルに含まれる周波数成分と継続時間を同時に表現する手法として、ランニングスペクトルがある。そこで本研究では、ランニングスペクトルの画像認識によって低周波微動および通常地震動を判別する手法を開発した。

画像に含まれる共通した特徴を自動で学習、認識し、判別する技術として、畳み込みニューラルネットワーク (CNN) が主に用いられる。通常CNNによる画像認識では、シグナルの特徴が画像のどこに現れても認識できるように設計する。一方地震動の場合、シグナルの現れる時刻、すなわちランニングスペクトル画像の横方向の位置はどこでも構わないが、周波数成分については震源の物理プロセスを反映しているため、周波数の絶対値 (画像の縦方向の位置) はシグナルの判別に重要な情報となる。従って、本研究では画像の縦方向 (=周波数) には位置感度を持たせつつ、横方向 (=時刻) の位置には影響を受けない、非対称な画像認識手法を新たに考案し、低周波微動と通常地震動を判別する手法を開発した (SRSpec-CNN; Nakano et al., 2019 SRL)。

CNNによる画像認識では通常、画像に含まれるシグナルの特徴を抽出する畳み込み層と、シグナルの位置感度を軽減するためのプーリング層、これらの層の出力とシグナルの関連付けを行う全結合層から構成される。通常プーリング層は、画像の縦横の両方向に適用し、シグナルの特徴が画像のどこに現れても適切に認識できるように構成する。しかし今回開発したSRSpec-CNNでは、プーリング層を画像の横 (時間) 方向のみに適用することで、縦方向 (周波数) には位置感度を持つよう構成した。この点が通常CNNとは異なる。

今回開発したSRSpec-CNNをDONETで観測された低周波微動と通常地震動、ノイズの記録から作成したランニングスペクトル画像を用いて学習させ、シグナルの判別精度評価を行った。画像は64×64ピクセルとし、横方向は時間 (225秒)、縦方向は周波数 (2-10 Hz) に対応する。この時、二つの観測点 (KMB06とKMD13) のデータは学習に用いず、新しく観測点が追加された場合を想定した性能評価試験に用いた。また、比較のためにプーリング層を通常CNNと同じ構成とした場合のシグナル判別も行った。

その結果、通常のCNNの場合は正解率（予測結果全体の中で、答えが正解と一致している割合）が95.9%だったのに対し、今回開発したSRSpec-CNNでは97.4%に向上した。さらに学習パラメータを最適化することで、最終的に99.5%の正解率を達成した。また、除外した二つの観測点のデータに対し、学習済みのネットワークを用いてシグナル判別を行ったところ、正解率は99.2%と、やはり高い判別性能を示した。つまり、既に観測網を展開している領域でのシグナルの一般的な特徴を学習しているため、観測網に新しい観測点を追加しても改めて学習をやり直す必要はない。

本研究ではシグナルの学習と判別において、シグナルが明瞭でないものや一つの画像に複数イベントが含まれているような、ノイジーなデータは除去した。今後はノイジーなデータにおける判別率の向上についても検討していく必要がある。

ノンパラメトリックベイズを用いた連続波形記録の教師なし自動分類

An unsupervised automatic classification algorithm for continuous seismic records using a nonparametric Bayesian approach

*小寺 祐貴¹、酒井 慎一²、西宮 隆仁¹

*Yuki Kodera¹, Shin'ichi Sakai², Takahito Nishimiya¹

1. 気象庁気象研究所、2. 東京大学地震研究所

1. Meteorological Research Institute, Japan Meteorological Agency, 2. Earthquake Research Institute, the University of Tokyo

地震計の連続波形記録には、地震、人為的活動、機器ノイズなどの様々な要因で生じた信号が記録されている。これらの信号を自動的に抽出・分類することができれば、地震計付近で発生している定常的・非定常的な自然現象の自動検出や、リアルタイム処理に用いている地震計の自動ヘルスマニタリング等につながると期待される。本研究では、これらへの第一歩として、機械学習を用いて連続波形記録を自動的に分類する手法の開発に取り組んでいる。個々の地震計の観測環境は様々であることから、教師データがあらかじめ存在することは想定せず、教師なし学習を前提として手法を構築する。

小寺・酒井（2018, 地震学会）は、10次元に集約した離散的な周波数スペクトルを特徴量として、周波数領域および時間領域で多段階のクラスタリングを行うことで、連続波形記録を10種類の時系列データに分類する手法を提案し、自然地震、鉄道ノイズ、バックグラウンドノイズが自動的に分類可能であることを示した。しかしながら同手法は、時間領域でのクラスタリングを行う際にスペクトラルクラスタリングを用いているという問題点がある。スペクトラルクラスタリングは、分類されるクラスタ数をハイパーパラメータとして陽に与える必要があるため、その値を設定する際に恣意的な判断が入り得る。そこで本研究では、分類の客観性をより高めるため、ノンパラメトリックベイズモデルのひとつである無限関係モデル（IRM; Kemp et al., 2006）を用いて時間領域のクラスタリングを行った。IRMは無数個のクラスタの存在を許容した生成モデルであり、学習データに基づいて有効なクラスタ数が自動的に計算される。先行研究同様、時系列データがマルコフモデルで遷移すると仮定して遷移行列を生成し、その行列に対してIRMを適用した。

上記手法をMeSO-netの観測点E.JDJM（川北・酒井, 2009）および気象庁の紀伊半島沖OBSの臨時観測点TN042A（山崎・他, 2008）における72時間の連続波形記録（期間はそれぞれ2017年3月1～3日, 2004年9月22～24日）に適用した。IRMにより、E.JDJMは10種類、TN042Aは6種類のクラスに分類され、学習データに応じてクラス数が自動的に調整されることを確認した。E.JDJMにおける地震と鉄道ノイズ、TN042Aにおける振幅の大きな余震と低周波微動は別々のクラスに分類された。一方で、それぞれの信号とクラスは基本的には一対一の対応にはなっておらず、例えばE.JDJMの鉄道ノイズは5種類程度のクラスに細分化されるといったことが生じた。より直観的に理解しやすい分類とするためには、細分化されたクラスを更にまとめ上げるといった処理が必要になるだろう。

震央方位を考慮した機械学習による地点固有の地震動評価モデルの検討

Study on Site-specific Ground Motion Evaluation Models Utilizing Machine Learning Method Considering Epicentral Directions

*石井 透¹、小穴 温子¹、和田 健介¹

*Toru Ishii¹, Atsuko Oana¹, Kensuke Wada¹

1. 清水建設株式会社

1. Shimizu Corporation

新たな観点の地震動評価による新たな知見獲得を目指し、堆積平野内や周辺で得られた水平地震動観測記録を教師データとする機械学習により、地点固有の地震動評価モデルの作成を試みた。各地点では地盤特性が共通なので、震源・伝播特性を記述する各パラメータを入力する「特徴量」とし、観測記録から求められた地震動指標を「目的変数」とすることにより、両者を関連付けて機械学習を実施した。

機械学習には、勾配ブースティングと決定木を組み合わせた手法「勾配ブースティング木」を用いた。「目的変数」として、地震動の最大加速度 PGA [cm/s^2]および複数の周期 T [s]での減衰定数 $h=5\%$ の擬似速度応答スペクトル ${}_pS_v$ [cm/s]と速度応答継続時間スペクトル TS_v [s] (パラメータ $p1=0.03$, $p2=0.95$)を検討した。大振幅になるとデータ数が減る PGA と ${}_pS_v$ は、モデル精度を高めるために機械学習に適した解析上のデータ分布となる常用対数 ($\log_{10}PGA$, $\log_{10}{}_pS_v$) に変換して入力した。「特徴量」としては、地震のモーメントマグニチュード M_w 、震源深さ H [km]、震源距離 X [km]、震央方位 Λ [degree]を与えた。 Λ は真北を 0° として時計回りに定めたが、真北を境に不連続量となるので、解析上のデータには $\sin \Lambda$ と $\cos \Lambda$ のペアを与えた。一特徴量のデータ列のみシャッフルして置き換え機械学習により再評価した時に評価精度の悪化した度合いにより、モデルへのその特徴量の「影響度」とした。

K-NET観測点TKY028での「地震動評価モデルT」の検討例を図1～4に示す。 Λ の影響度は特に TS_v で大きく、周期によっては $M_w \cdot X \cdot H$ と同等以上になった。この例では、評価値／観測値の比の平均は約1.1、その常用対数標準偏差は振幅では0.2強、継続時間では0.1強で、評価値の大半は観測値の倍半分以内に収まった。従来の距離減衰式等で扱われなかった震央方位や応答継続時間を考慮し、地点・周期毎に地震動特性が変化する様子の定性的・定量的な分析・検討も可能で、地震波の三次元伝播特性の違いを簡便な評価モデルに反映出来る可能性がある。

AIとBig Dataを生かす上で良質・大量のデータと情報の得られる地点毎に地震動評価モデルを作成することには大きな利点がある。今後、データの粗密に起因するモデル精度のアンバランスを改良するための工夫や、データ数が少なく外挿領域に当たる大地震・大振幅地震動・長時間地震動の評価上の工夫も必要となろう。

謝辞

本研究には、気象庁の地震情報と防災科学技術研究所の陸海統合地震津波火山観測網の公開データ、および、機械学習ツール DataRobot と描画ツール GMT を使用した。これらの開発・運用・管理に携われた全ての皆様に心より感謝申し上げます。

参考文献

石井・小穴・和田, 日本地震工学会大会 2019 梗概集 (投稿中)

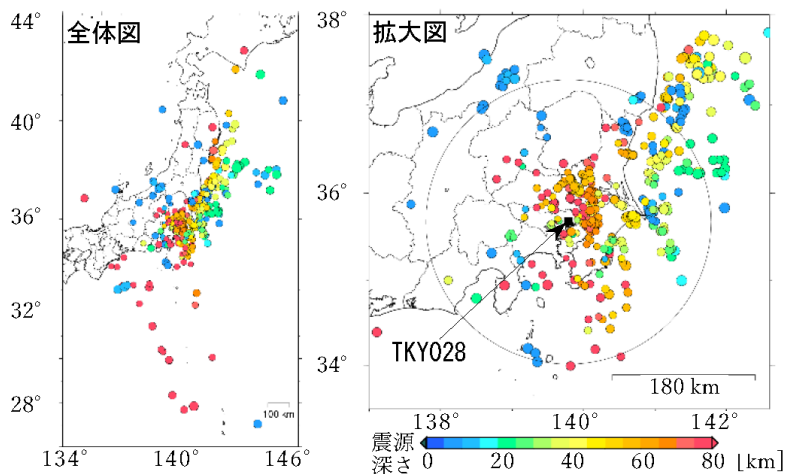


図 1 TKY028 で観測されたモデル T 検討用地震の震央




図 2 モデル T の各地震動指標に対する各特徴量の影響度

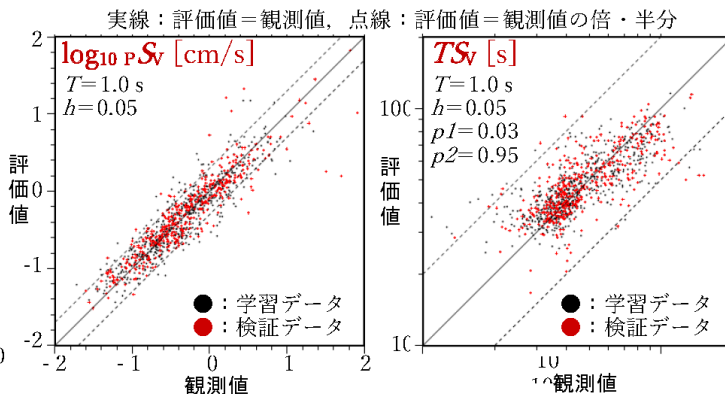
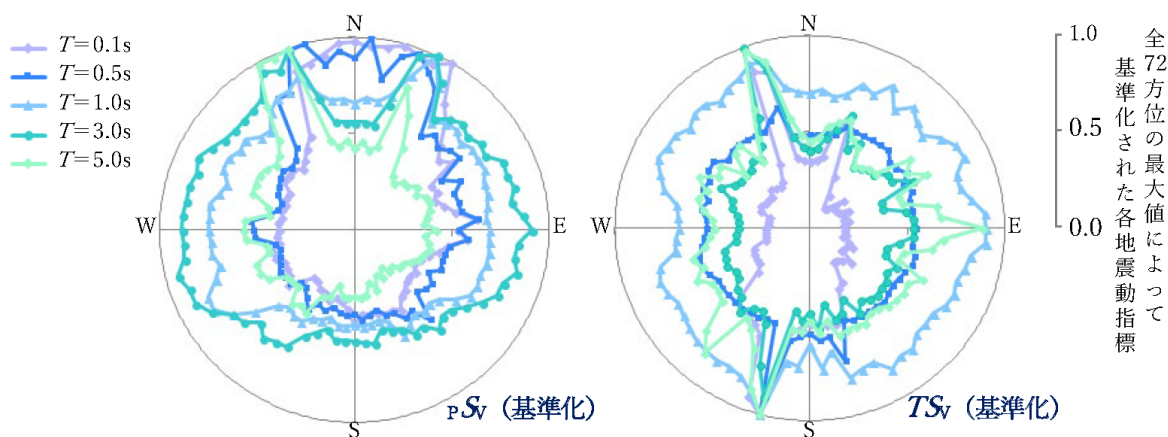


図 3 モデル T の地震動指標(目的変数)の観測値と評価値の相関図(散布図)の例



$M_w=6, H=10km, X=180km$ の条件で A を 5° 刻みで変化させて最大値により基準化して示したもの
図 4 モデル T の地震動指標(目的変数)の評価値の震央方位依存性の検討例

機械学習を用いた関東地方の地震動評価モデルの検討

Study on Ground Motion Evaluation Models for Kanto Region Utilizing Machine Learning Method

*小穴 温子¹、石井 透¹、和田 健介¹

*Atsuko Oana¹, Toru Ishii¹, Kensuke Wada¹

1. 清水建設

1. Shimizu Corporation

日々蓄積されていく地震動観測記録が最大限に活用され随時更新される地震動予測モデルの構築を目指し、その予備的な検討として、関東地方において過去に得られた地震動観測記録を用いて、機械学習による地震動評価モデルの作成を試みた。

検討には、防災科学技術研究所のK-NETのうち関東地方に展開された強震観測点138地点（図1）で得られた地表記録を用いた。具体的には、気象庁の震度データベースで1996年～2019年1月15日に最大震度が4以上でかつ東京都千代田区で震度2以上となった地震のうち、関東地方で震度が記録された地点数が非常に少ない地震を除いた上で、地震規模と震源位置が偏り過ぎないように代表的な地震を選んだ。選択した地震は、関東地方を中心に一部遠方にまで広がっている（図2）。これらの地表記録のうち、加速度三成分合成振幅最大値が 1 cm/s^2 以上の観測点での水平二成分の波形データを選択し、データに含まれるノイズや別地震を判別して、検討に用いることが適切な波形を取捨選択した結果、総計11488波形となった。選択したデータの震源距離 X [km]とモーメントマグニチュード M_w の分布を図3に示す。

地震動評価モデルの目的変数は、最大加速度 $PGA[\text{cm/s}^2]$ と複数の周期 T [s]における減衰定数5%の擬似速度応答スペクトル $S_p S_v[\text{cm/s}]$ および速度応答継続時間スペクトル $TS_v[\text{s}]$ （石井, 2012）とした。なお、 PGA と $S_p S_v$ は振幅の大きなデータが少なく、絶対値のままではデータの分布形状が偏っていたため、機械学習ではそれぞれの常用対数を与えることにした。地震動評価モデルの特徴量（説明変数）は、モーメントマグニチュード M_w 、震源深さ H [km]、震源距離 X [km]、震央方位 Λ [degree]、地震基盤面深さ $D28$ [m]（J-SHISで公開されている深部地盤モデルの第28層の下面深さ）、表層30m平均S波速度 $AVS30$ [m/s]の6種類とした。 Λ は真北を 0° として時計回りに定めたが、真北を境に不連続量となるので、 $\sin \Lambda$ と $\cos \Lambda$ のペアを与えた。機械学習手法には、勾配ブースティングと決定木を組み合わせた勾配ブースティング木を用いた。

ある特定の特征量のみをランダムに並べ替え、その他の特征量を元のままとしたときの目的変数の評価精度の変化の度合いにより、目的変数に対する各特征量の影響度を調べた（図4）。 M_w の影響度は周期と共に増大し、 X の影響度や TS_v に対する H の影響度は周期と共に減少した。 $AVS30$ の影響度は周期1秒で相対的にやや大きめ、 $D28$ の影響度は周期1秒以上で大きめ、 Λ の影響度は相対的には周期1秒以下で大きめとなった。目的変数の観測値と評価値の分布の例を図5に示す。評価値／観測値の比の平均はほぼ1、その常用対数標準偏差は地震動の振幅では0.2弱程度、応答継続時間では0.1程度で、評価値の大半は観測値の倍半分以内に収まり、全体として良くモデル化された。

作成した地震動評価モデルを用いて、 M_w に応じた PGA の距離減衰特性を検討した例を図6(a)に示す。特徴量の与条件は、茨城方面を震源とする地震をSIT006秩父で観測する場合等を考慮して設定し、プレート境界地震による岩盤サイトでの揺れを想定した。参考として、Morikawa and Fujiwara(2013)の距離減衰式（ $M_w 6$ と $M_w 6.5$ ）の平均も重ね描いた。 M_w と X に応じた PGA の傾向は、大局的には既往の距離減衰式と同様にモデル化されていると言える。ただし、 $M_w 5$ や $M_w 6$ の場合に比べて $M_w 6.5$ の場合は、 $X < 60\text{ km}$ の傾きが小さく、ステップ関数状になっている。 $M_w 6.5$ では $X < 60\text{ km}$ の学習データが少なかった（図3）ため、十分な信頼性が確保できていない可能性がある。 Λ による $S_p S_v(T=1\text{秒})$ の距離減衰特性の検討例を図6(b)に示す。ここでは、都心からみて北東・南・南西方向（ $\Lambda=45, 160, 230^\circ$ ）のプレート境界地震および北西方向（ $\Lambda=320^\circ$ ）の内陸地震を念頭に置いた。これら4ケースを比べると、同じ M_w と X でも Λ によって振幅の大きさに差が生じている。プレート境界地震を想定した3ケースでは南方向が最も小さく、北東方向と南西方向の大小関係は50

km程度を境に入れ替わっている。また、北西方向は距離減衰の傾きが相対的に小さい。 $X < 100$ kmでは顕著に振幅が小さいが、 $X > 150$ kmでは南方向を上回っている。このような違いは、震源特性の地域性や伝播経路特性の違いがモデルに反映された結果と考えられ、 Λ を考慮することによって、既往式よりも細かな地域特性を考慮した地震動評価モデルを作成できる可能性を示唆している。一方で、データの偏りがモデルに影響を及ぼしている可能性もあるため、今後さらなる検討が必要である。

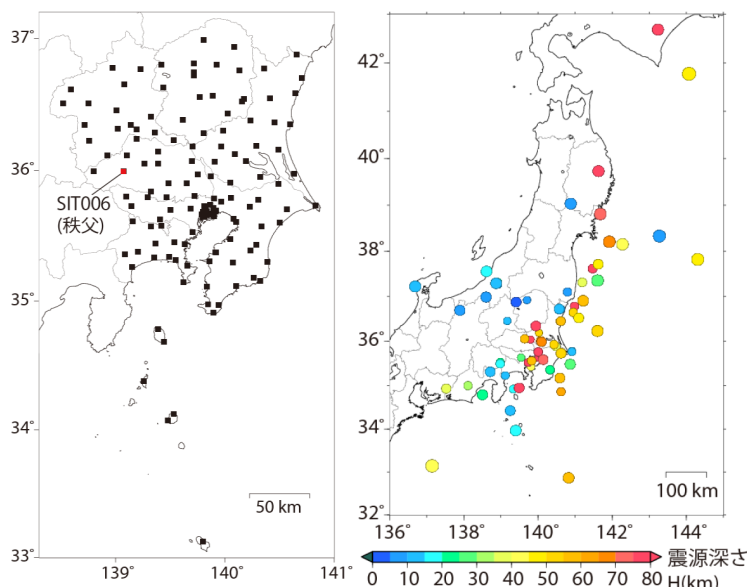


図1 関東地方の K-NET 観測点 図2 検討地震の震央

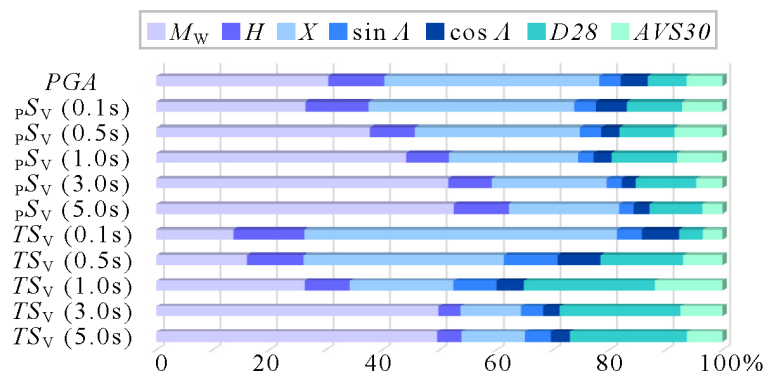



図4 地震動評価モデルの各地震動指標に対する各特徴量の影響度



(a) M_w に応じた PGA (b) Λ に応じた $pS_v(T=1s)$
図6 距離減衰特性に関する検討例




図3 震源距離 X と M_w の分布


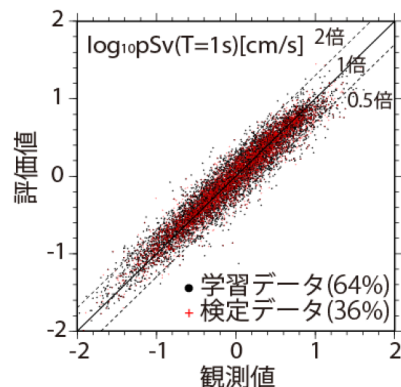


図5 目的変数の観測値と評価値の例

参考文献：石井(2012): 日本建築学会構造系論文集, 第77巻, 第676号, pp.843-850. Morikawa and Fujiwara(2013): Journal of Disaster Research, Vol.8, No.5, 2013, pp.878-888.

謝辞：気象庁の地震情報と防災科学技術研究所による公開データ、および機械学習ツール DataRobot と描画ツール GMT を使わせて頂きました。心より感謝申し上げます。