

# 深層学習による地動観測点の特定

飛田 哲男<sup>1</sup>・山本 航<sup>2</sup>

<sup>1</sup> 正会員 関西大学教授 環境都市工学部都市システム工学科 (〒564-8680 大阪府吹田市山手町 3-3-35)  
E-mail: [tobita@kansai-u.ac.jp](mailto:tobita@kansai-u.ac.jp) (Corresponding Author)

<sup>2</sup> 応用地質株式会社 流域・砂防事業部防災技術部 (〒331-8688 埼玉県さいたま市北区土呂町 2-61-5)  
E-mail: [yamamoto-wataru@oyonet.oyo.co.jp](mailto:yamamoto-wataru@oyonet.oyo.co.jp)

本研究では、畳込みニューラルネットワーク(CNN)による深層学習を用いて効率的に地動観測点を特定する方法を提案する。本手法は、観測地点の加速度スペクトルを振幅に応じたカラースペクトルに変換し、それを用いて深層学習を行う。まず、複数の1次元モデル地盤に対しランダム波を与え、カラースペクトルに変換した地表面応答の加速度フーリエスペクトルを用いて本手法の適用性を検討した。その結果、99%以上の精度で地盤モデルを特定できた。次に、8地点のK-NET観測点で得られた50gal以下の地震動による地震動H/Vスペクトル比を用いた場合には、95%以上の精度で観測地点が特定できた。誤分類した地震動は、震源距離が大きいなど特殊な地震動であった。さらに、学習済みのCNNに対し常時微動H/Vスペクトル比を入力し観測点の特定を試みたが、精度は50%程度であった。

**Key Words:** earthquake, microtremor, H/V spectrum, deep learning, convolution neural network

## 1. はじめに

平成23年(2011年)東北地方太平洋沖地震、平成28年(2016年)熊本地震など、近年多くの地震による被害が発生している。また、今後南海トラフ巨大地震の発生が予測されており、広域にわたる地震被害の発生が懸念されている。こうした地震被害を最小限に抑えるためには、事前に地震被害分布を推定することが重要である。そのためには広域の地盤振動特性を統一かつ適切に求める必要がある。液状化被害の予測や建設物の耐震性を考慮する際には、原位置調査結果から地震波の入力基盤までの地盤モデルを作成し、数値解析によって安全性を評価することが多い。しかし、地盤情報が不足している地点では、新たに調査を実施する必要がある。

地盤調査には、PS検層やボーリング調査があるが、調査スペースを確保する必要性、調査期間、費用等の制約から容易に実施することはできない。これに対して、比較的費用が安価であり、調査期間も短い物理探査の一つに、常時微動観測による方法がある。この方法では、常時微動から卓越周期を求め簡易的に地盤種別を分類する。例えば、Kanai and Tanaka<sup>1)</sup>は、常時微動を用いて、平均周期と最大周期もしくは卓越周期と最大振幅によって簡易な地盤種別判定法を提案してい

る。またNakamura<sup>2)</sup>は、常時微動スペクトルの水平、鉛直成分の比を取りH/Vスペクトル比を定め、そのピーク周波数が、観測地点の表層地盤の固有振動数と一致することを示した。その後、このH/Vスペクトル比は、工学的基盤深さの推定や堆積層厚の推定に広く利用されている。

機械学習を地震学、地震工学に適用する試みについては、これまでに多くの研究がなされてきている<sup>例えは3)</sup>。また、土木学会地震工学委員会においても「防災・減災へのAI・IoT技術の利活用に関する研究小委員会(丸山喜久委員長)」において精力的に研究活動が継続されているところである。本研究では、近年飛躍的に技術が向上している機械学習の一種である深層学習による画像認識技術(Convolutional Neural Network, 以下CNN)と波動スペクトルを組み合わせることによって観測地点の特定を試みる。ここでは、その方法として2つの方法を検討する。1つは、有限要素法による1次元地盤モデルを用いる方法である。表層厚の異なる仮想的な2層地盤モデルと多層地盤モデル地盤の2ケースに対し、本手法を適用し地盤モデルを特定する。2つ目は、強震観測網K-NETで観測された地震動を利用し、観測点を特定する。いずれの方法においても、図-1に示す方法で表層の加速度スペクトル

を振幅の値に対して色分けしたカラースペクトル画像に変換する<sup>7)</sup>。このカラースペクトルを、畳み込みニューラルネットワークの入力として使用し、画像解析により地盤モデルおよび観測地点を特定することを試みる。なお、今回の検討ではH/Vスペクトル比の振幅については、最大値で正規化しているためカラースペクトルに振幅の絶対値は反映されていない。このためカラースペクトルに含まれる情報は、各振動数における相対的な振幅の大小のみである。

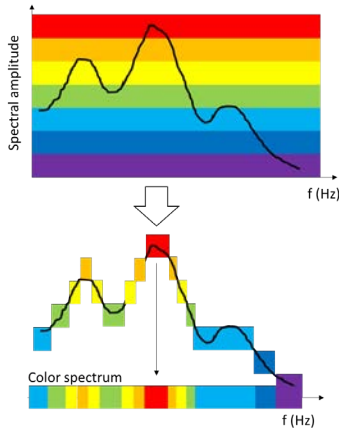


図-1 スペクトル波形のカラースペクトル画像への変換

## 2 深層学習による地盤モデルの特定

### (1) 2層地盤の場合

数値解析には、多重せん断ばねモデルを構成測とする有限要素法(FE)を使用する。地表面の応答加速度を得るため、2層地盤を想定した地震応答解析を行う。本研究では地下水面の設定は行わず、全応力解析を採用し、地盤深さ20mまでの1次元のメッシュ(図-2左)に対して解析する。解析メッシュの寸法は一边0.5mの正方形とし、これを高さ20mまで積み上げる。総節点数82、総要素数40である。この時、同一深度の節点自由度はx方向、y方向どちらも同一とする(MPC拘束)。地盤モデルは、図-2に示すように表層の厚さを2, 6, 10, 14mと変化した4ケースの2層地盤モデルとする。設定した地盤モデルの物性値を表-1に示す。土の単位体積重量は表層をローム層と想定し1.35 tf/m<sup>3</sup>、基盤を礫層と想定し2.10 tf/m<sup>3</sup>に設定する<sup>9)</sup>。また、S波速度については表層を100 m/s、基盤を700 m/sと設定し、ポアソン比νは0.33を用いる。これらの値を(1)、(2)式に代入することで、各層の初期せん断剛性G<sub>ma</sub>と体積弾性係数K<sub>ma</sub>を求める。各層の内部摩擦角については、簡易設定法<sup>10)</sup>を使用し表層のN値を5、基盤のN値を50と仮定し推定する。

$$G_{ma} = \rho V_s^2 \quad (1)$$

$$K_{ma} = \frac{2}{3} \left( \frac{1+\nu}{1-2\nu} \right) G_{ma} \quad (2)$$

入力波は、振幅約20 gal、継続時間20秒のランダム波(ホワイトノイズ)(図-3)を100波作成し、これをそれぞれの2層地盤モデルの最下端に時間間隔Δt=0.01(s)で入力する。

次に、解析の結果得られる水平応答加速度をバンド幅0.4HzのParzen windowで平滑化し、水平加速度フーリエスペクトルを得る。なお、周波数領域は0.1 Hzから25 Hzの範囲を考慮する。このスペクトルを振幅の最大値で正規化し、最大値を赤、最小値を青とするカラースペクトルを作成する。図-4に示すように、カラースペクトルの横軸は振動数に対応するが、対数目盛ではなく算術目盛とする。同図より4ケースのカラースペクトルを比較すると、Case 1からCase 4へと卓越周波数(濃赤色)の位置が低周波側に移動していることが分かる。

次に作成したカラースペクトルを学習画像としてCNNを用いた深層学習を行う。使用した機械学習ツールは、米国Math Works社の数値解析ソフトウェアであり、プログラミング言語でもあるMATLAB (R2021a)<sup>13)</sup>である。CNNシステムの構築にはDeep Learning Toolboxを用いる。

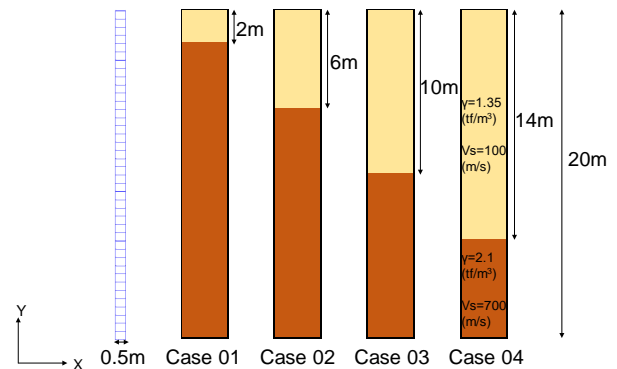


図-2 2層地盤モデルのメッシュ図と層分割図

表-1 2層地盤モデルの物性値

土層名	表層	基盤
質量密度 ρ (g/cm <sup>3</sup> )	1.35	2.10
基準初期せん断剛性G <sub>ma</sub> (kPa)	1.35 × 10 <sup>4</sup>	1.03 × 10 <sup>6</sup>
基準体積弾性係数K <sub>ma</sub> (kPa)	3.52 × 10 <sup>4</sup>	2.68 × 10 <sup>6</sup>
基準拘束圧 σ <sub>ma</sub> ' (kPa)	98	98
拘束圧依存係数 m <sub>G</sub> , m <sub>K</sub>	0.5	0.5
間隙率 n	0.45	0.45
内部摩擦角 φ <sub>f</sub> (°)	34.1	43.6
粘着力 c	0	0
履歴減衰上限値 h <sub>max</sub>	0.24	0.24




図-3 ランダム波による入力加速度と地表面応答加速度の一例  
(a)入力, (b)地表面

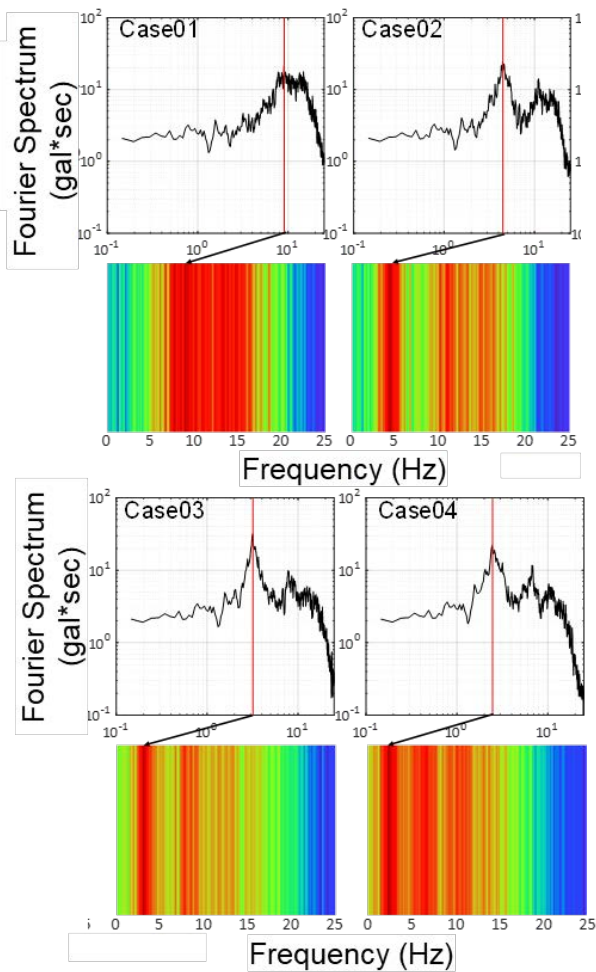


図-4 2層地盤モデルの地表面水平応答加速度フーリエスペクトルとカラースペクトルの例

CNNの学習プロセスでは大量の学習データを用いて学習を行うのが理想的である。そこで、本研究では、解析または観測で得られたカラースペクトル画像に加え、試みとして事前学習済みのネットワークであるAlex Net<sup>11)</sup>による転移学習の枠組みを用いる（別途行った解析ではAlex Netを使わず、カラースペクトル画像のみを

学習させた場合でも学習精度に大きな差はないことが確認された）。入力画像はAlexNetで必要とされる画像サイズ227×227pixelに加工して用いる。使用画像は各ケースのランダム波100波に対応する100枚の画像に対して学習用と検証用を7：3の割合で分割して使用する。したがって学習用の画像は計280枚、検証用の画像は計120枚である。

また勾配降下法のアルゴリズムとしてはSGD（確率的勾配降下法）を使用し、ミニバッチサイズは32とする。さらに最大エポックは20とし、学習率は0.001とする。検証に使用する画像はエポックごとにシャッフルされるように設定する（表-3）。解析環境の概要を表-4に示す。

CNNの学習は計10回行うこととし、その平均の学習精度で学習モデルを評価する。

学習の結果、全ての試行において検証用のカラースペクトルを完全に分類できた。学習時の学習曲線と損失関数の一例を図-5に示す。黒線は学習用画像、赤線は検証用画像を使用した場合における、学習曲線（同図(a)）と損失関数（同図(b)）を表している。学習曲線において、学習を開始してから、学習反復40回あたりまで学習精度が徐々に上昇し、学習反復40回を超えたあたりから、学習精度が収束していることが分かる。損失関数からも同じ傾向が見られ、学習が正常に行われていることがわかる。

本解析で用いた表層厚の異なる4ケースは、CNNにより何らかの特徴量をもとに分類されている。そこで、その判断根拠となった特徴量をDeep Learning Toolboxのヒートマップを作成する関数Occlusion Sensitivity<sup>12)</sup>を使用して可視化することを試みる。図-4で示したカラースペクトルに対して特徴量の可視化を行った結果を図-6に示す。ここでは赤く表示されている部分が画像を分類する際に、深層学習が重視している部分であることを示す。すべてのケースで、それぞれの1次卓越周波数付近を画像の特徴量として認識しており、Case 2においては、2次の卓越周波数付近も画像の特徴として強く捉えていることが確認できる。したがって、このモデルでは表層厚の違いを、1次、2次の卓越周波数付近の色で判断していることが推測できる。

表-3 設定したハイパーパラメータ

Solver	SDG
Mini Batch Size	32
Max Epoch	20
Initial Learn Rate	0.001
Shuffle	Every-Epoch

表-4 解析環境

CPU	Intel (R) Xeon (R) CPU E3-1225 v5 @ 3.30GHz
Memory	8.00 GB
GPU	NVIDIA Quadro P600
GPU Memory	2.00 GB
OS	Windows 10
Software library	Deep Learning Toolbox
MATLAB	R2021a

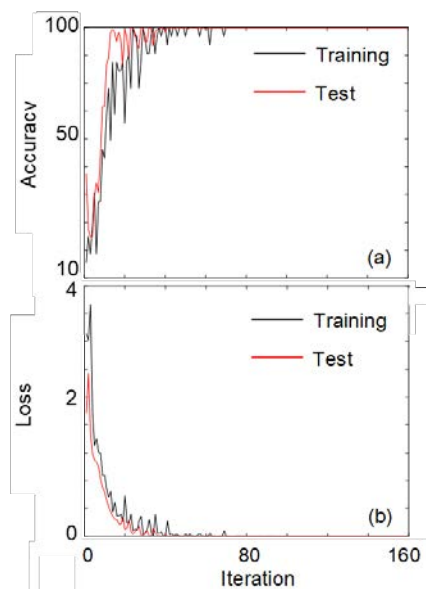


図-5 2層地盤モデル：(a)学習曲線，(b)損失関数

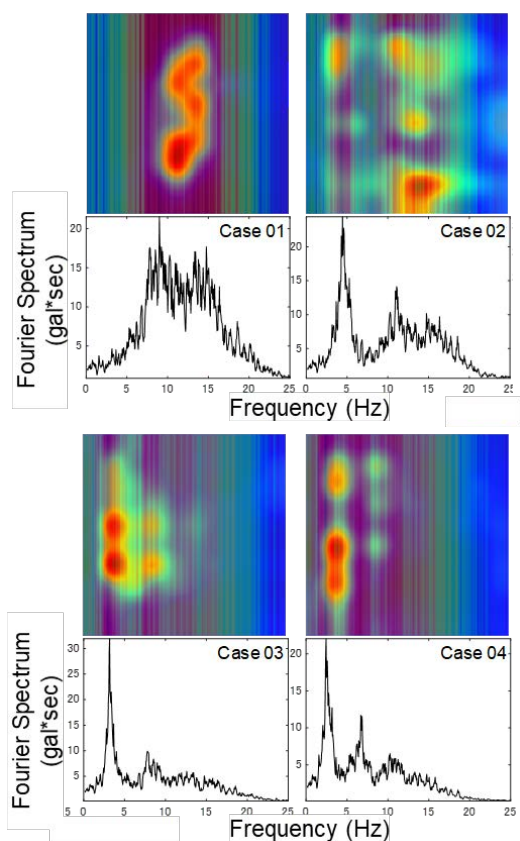


図-6 2層地盤のサイト特性の分類に対してヒートマップにより可視化された特徴量とスペクトル波形の例

## (2) 多層地盤モデル

ここでは、多層地盤モデルを作成し2層地盤の場合と同様に地盤モデルの特定を試みる。モデル地盤の対象地点は強震観測網K-NET<sup>14)</sup>の観測地点5地点（OSK001，OSK002，OSK003，OSK004，OSK005）とする（図-7）。

解析手法、メッシュおよび入力波は2層地盤の場合と同条件とする。公開されている大阪府内5地点のGL-20m以浅の地盤情報をもとに5つの地盤モデルを作成する（図-8，図-9）。同モデルにおける各層の境界はS波速度境界に設定する。また、各層の単位体積重量については、深度1 mごとに求められている単位体積重量を各層で足し合わせ、各層の層厚で除することによって平均値を求める。設定した地盤の物性値を表-5に示す。

2層地盤の場合と同様に、ランダム波による地震応答解析、カラースペクトルの作成、CNNによる分類の流れで解析を行ったところ、学習精度の平均は99.1%であり、この場合にも高い精度でカラースペクトル画像から5つの地盤構造を特定することができた。最も精度が高かったものでは、検証画像すべてを分類する結果が示された。したがって実地盤に近い地盤モデルもCNNによって分類できることが示された。

図-10 に本解析のヒートマップを示すが、先と同様スペクトル波形の主として1次ピーク付近の特徴に基づいて分類がなされていることがわかる。ただし、OSK002は1次ピークの振動数が約7 Hzであるが、10 Hzから15 Hzの特徴量によって分類されていることがわかる。これは、OSK001の1次ピークも約7 Hzと近いところにあることに起因する可能性が高い。

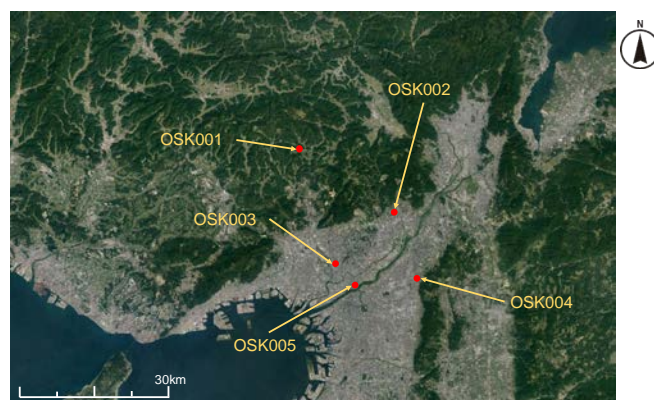


図-7 対象とした大阪府内の K-NET 観測点 5 地点 (google earth に加筆)

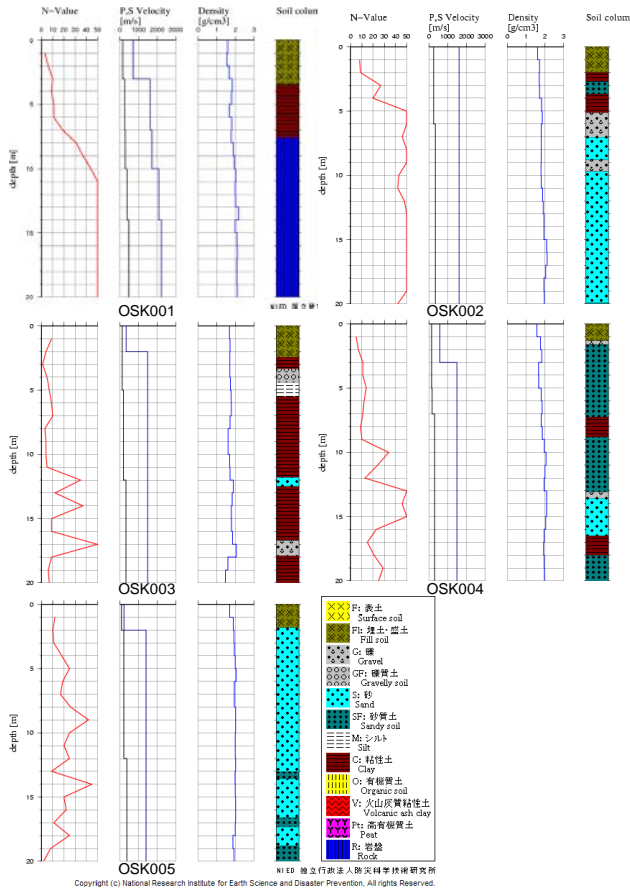


図-8 K-NET観測地点の地盤情報<sup>14)</sup> (OSK001-OSK005)




図-9 多層地盤モデル (OSK001-OSK005)

表-5 設定した地盤モデルの物性値 (OSK001-OSK005)

地盤モデル名	深さ H (m)	S波速度 Vs (m/s)	質量密度 $\rho$ (g/cm <sup>3</sup> )	基準初期せん断剛性 $G_{max}$ (kPa)	基準体積弾性係数 $K_{max}$ (kPa)	内部摩擦角 $\phi_1$ (°)
OSK001	GL 0~3	160	1.59	4.07E+04	1.06E+05	34.6
	GL -3~-7	260	1.77	1.20E+05	3.12E+05	36.8
	GL -7~-10	290	1.86	1.56E+05	4.08E+05	43.4
	GL -10~-14	390	2.04	3.10E+05	8.09E+05	43.6
OSK002	GL 0~6	240	1.74	1.00E+05	2.61E+05	41.0
	GL -6~-20	330	1.92	2.09E+05	5.45E+05	43.6
OSK003	GL 0~5	130	1.70	2.87E+04	7.49E+04	34.2
	GL -5~-12	190	1.69	6.10E+04	1.59E+05	36.0
	GL -12~-20	320	1.77	1.81E+05	4.73E+05	38.3
OSK004	GL 0~5	140	1.70	3.33E+04	8.69E+04	35.9
	GL -5~-7	170	1.83	5.29E+04	1.38E+05	36.5
	GL -7~-20	300	1.98	1.78E+05	4.65E+05	40.8
OSK005	GL 0~2	80	1.79	1.15E+04	2.99E+04	36.3
	GL -2~-12	210	1.97	8.69E+04	2.27E+05	39.8
	GL -12~-20	380	1.97	2.84E+05	7.42E+05	38.4

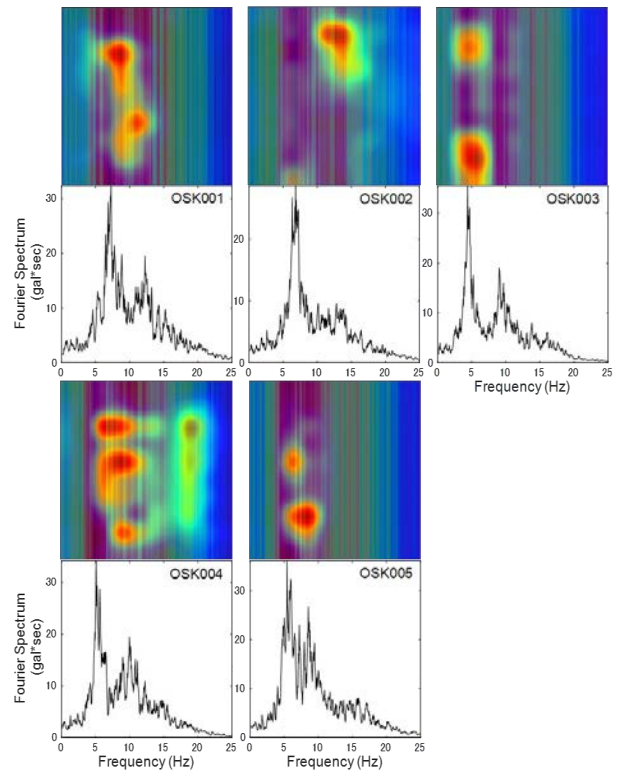


図-10 K-NET観測地点の地盤モデルに対するサイト特性の分類に対してヒートマップにより可視化された特徴量とスペクトル波形の例

### 3. 観測地震動を用いた地盤構造分類

ここでは K-NET 観測地点の実地震動に対して先と同様の分類を試みる。観測地点は、大阪市近郊の 5 地点に北海道厚真町近郊の 3 地点を加えた計 8 地点とする。使用する地震動は 1996 年 1 月から 2021 年 6 月までの地盤の非線形性の影響が小さいと推定される最大加速度が 50 gal 以下の計 1,677 波を抽出し使用する。図-11 にこれらの波形の震源深さ、震源距離、マグニチュードの頻度分布および震央位置を示す。観測地震動を用いる本検討では、前章までのランダム波を用いた地盤モデルの場合とは異なり、図-12 に例示する地震動 H/V スペクトル比を用いてカラーспекトルを作成する。図-13 に作成したカラーспекトルを一観測地点あたり 18 枚例示する。同図より、同じ観測地点でも、伝播特性、震源特性、地盤の非線形化の影響により色の配置がやや異なることがわかる。表-6 に学習用(Train)と検証用(Test)のカラーспекトル画像の枚数を観測地点ごとに示す。

CNN による分類の結果、学習精度の平均は 95.6% であり、観測地震動を学習させた場合においても、各観測地点をカラーспекトルを用いてほぼ正確に特定できることが示された。また図-14 に示す学習曲線と損失関数は、両者とも一定値に収束していることから、学習は正常に

行われていることが確認できる。最も精度の高い学習モデルにおける検証画像の正答数を表-7に示す。北海道3地点においてすべての検証用画像を正確に特定できたが、大阪4地点では誤って分類された地震動 H/V スペクトル比が18波あることが確認できる。そこで、OSK002を例として誤分類の原因を考察する。OSK002に対し誤分類した地震動 H/V スペクトル比は表-7に示す9波であった。この9波がそれぞれのサイトに分類される確率を表-8に示す。同表中、際左列のNo.は9つの地震動 H/V スペクトル比、Category欄の数値は、それぞれの地震動 H/V スペクトル比が各サイトに分類される確率を示している。同表より、No.1の地震動 H/V スペクトルに着目すると、この地震動 H/V スペクトル比が OSK002 に分類される確率は44%、OSK005に分類される確率は55%である。この地震動 H/V スペクトル比の場合、分類に際して OSK002 の特徴もある程度とらえられているものの OSK005 として分類されてしまったことが推測される。一方、No.2の地震動に着目すると、OSK005 に誤分類される確率は100%である。図-15に、高い確率で誤分類されたNo.2, No.4, No.7と、学習に使用した OSK002 (ランダムな10波の平均)の地震動 H/V スペクトル比との比較を示す。同図よりNo.2とNo.4の地震動 H/V スペクトルが OSK002 の波形と大きく異なっていることがわかる。しかし、No.7の地震動 H/V スペクトル比は学習に使用された10波の平均と類似しているように見受けられる。そこで、さらに考察を進めると OSK001 に誤分類されたNo.4は震源深さ333kmの深発地震であり、使用した地震動の中でも極めて特徴的な地震であることが確認できた。また、OSK004に誤分類されたNo.7地震動は、こちらも震源距離が505kmであり、こちらも学習に使用した地震動の中では特徴的な地震であることが分かった。しかし、No.2地震動に関しては、震源距離、震源深さ共に学習に使用した地震動との大きな違いは無く、その他未確認の特徴を有する地震動であることが推測される。

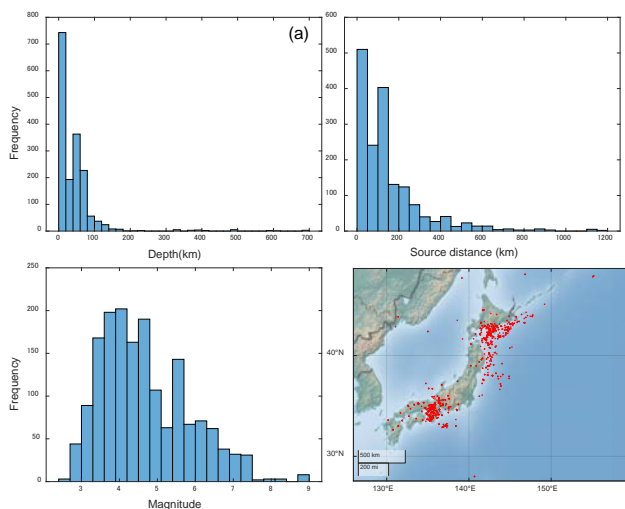


図-11 本研究で用いた強震記録(1,677波)<sup>14)</sup>の位置と諸元

このことから、本手法を利用して誤分類された地震動に着目することで、特徴的な地震動を容易に抽出することもできることがわかった。




図-12 各地点における地震動 H/V スペクトル比の例(ランダムな10波形)




図-13 地震動 H/V スペクトルのカラースペクトルの例(つづく)




図-13 地震動 H/V スペクトルのカラーспекトルの例

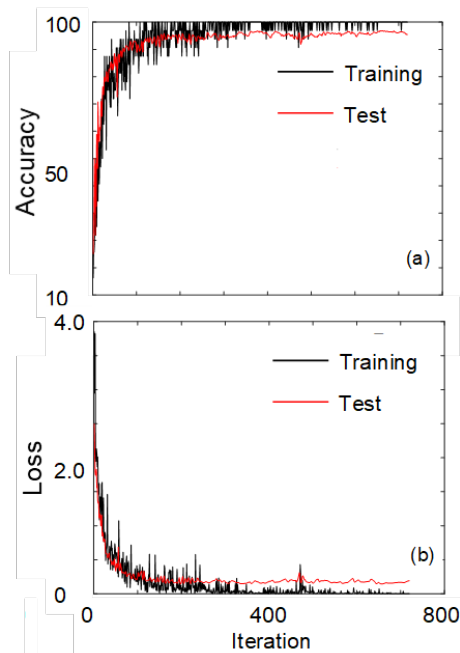


図-14 観測地震動による観測点の特定に対する(a)学習曲線と(b)損失関数

表-6 学習と検証に使用した画像枚数の内訳

Category	Train	Test	Total
HKD127	175	75	250
HKD128	175	75	250
HKD184	175	75	250
OSK001	176	76	252
OSK002	138	59	197
OSK003	127	55	182
OSK004	151	64	215
OSK005	57	24	81

表-7 地震動 H/V スペクトルによる観測点の特定結果

True Class	Predicted Class								Recall
	HKD127	HKD128	HKD184	OSK001	OSK002	OSK003	OSK004	OSK005	
HKD127	75	0	0	0	0	0	0	0	1.00
HKD128	0	75	0	0	0	0	0	0	1.00
HKD184	0	0	75	0	0	0	0	0	1.00
OSK001	0	0	0	76	0	0	0	0	1.00
OSK002	0	0	0	1	50	4	1	3	0.85
OSK003	0	0	0	0	1	52	2	0	0.95
OSK004	0	0	0	1	1	0	62	0	0.97
OSK005	0	1	0	0	3	0	0	20	0.83

表-8 OSK002に対して地震動 H/V スペクトルを誤分類した地震動と判定基準となった確率

Eq. No.	Category								True Class	Predicted Class
	HKD127	HKD128	HKD184	OSK001	OSK002	OSK003	OSK004	OSK005		
1	0.00	0.00	0.00	0.00	0.44	0.01	0.00	0.55	OSK005	OSK005
2	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	OSK005	OSK005
3	0.00	0.00	0.00	0.00	0.32	0.00	0.00	0.67	OSK005	OSK005
4	0.00	0.00	0.00	0.94	0.04	0.01	0.00	0.00	OSK002	OSK001
5	0.00	0.00	0.00	0.00	0.36	0.64	0.00	0.00	OSK002	OSK003
6	0.00	0.00	0.00	0.04	0.25	0.69	0.00	0.00	OSK002	OSK003
7	0.01	0.00	0.00	0.00	0.00	0.01	0.96	0.01	OSK002	OSK004
8	0.00	0.00	0.00	0.00	0.47	0.52	0.00	0.01	OSK002	OSK003
9	0.00	0.00	0.00	0.03	0.47	0.48	0.00	0.02	OSK002	OSK003




図-15 誤分類された地震動 H/V スペクトル比 (No.2, No.4 and No.7) と学習に使用した OSK002 における地震動 H/V スペクトル比 (ランダムな 10 波の平均) との比較

#### 4. 地震動 H/V スペクトル比を学習させたモデルを用いた常時微動観測点の分類

本章では、常時微動 H/V スペクトル比を用いて観測点を特定することを試みる。常時微動観測点は前章で述べた K-NET 観測点 8 地点である。使用した機器は白山工業の微動観測装置 JU-410 であり、各 K-NET 観測点付近で 15 分程度の現地計測を行った。

対象とした 8 観測点における、地震動 H/V スペクトル比と常時微動 H/V スペクトル比を図-16 に示す。同図に示す H/V スペクトル比は、地震動 H/V スペクトル比については学習に使用した全地震動の平均、常時微動 H/V スペクトル比については、ノイズの含まれない連続した 20 秒間の H/V スペクトル比 20 波の平均である。同図より 2 Hz から 10 Hz の周波数帯域で両者のスペクトル波形

のピークを与える振動数範囲が概ね一致することが確認されたため、この周波数帯域を対象とし、地震動のカラースペクトルを学習させたモデルを使用して常時微動観測点の特定を試みる。

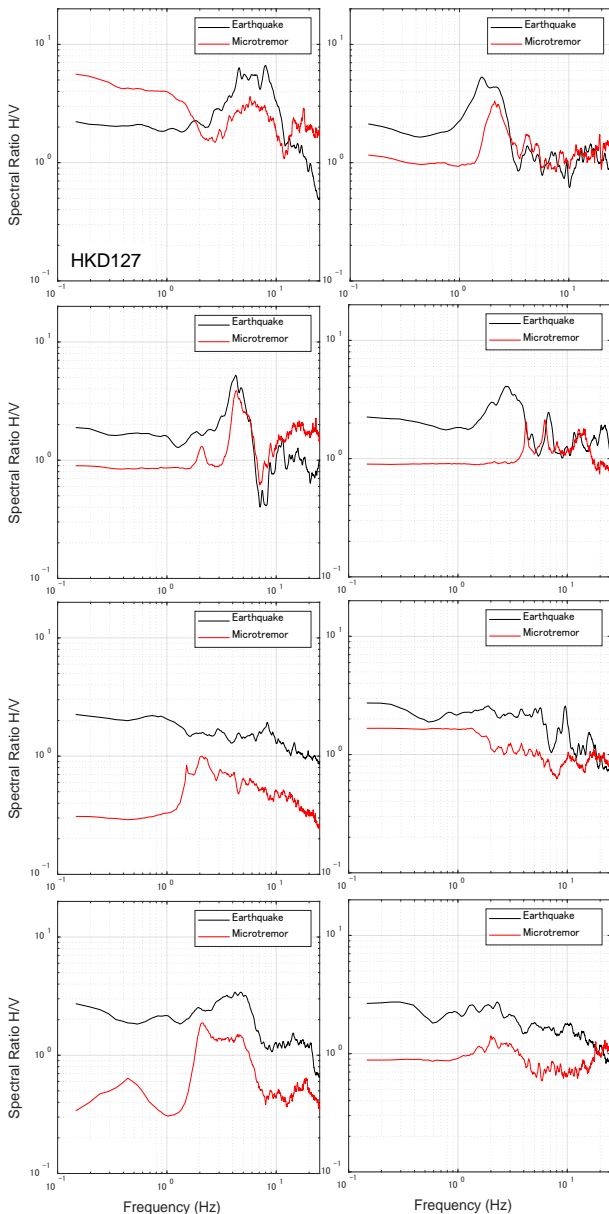


図-16 地震動 H/V スペクトル比（学習に使用した全地震動の平均）と常時微動 H/V スペクトル比の比較

表-9 2Hz から 10Hz の周波数領域の常時微動記録から作成したカラースペクトルを学習モデルで検証した結果

True Class	Predicted Class								Recall
	HKD127	HKD128	HKD184	OSK001	OSK002	OSK003	OSK004	OSK005	
HKD127	18	0	0	0	1	1	0	0	0.90
HKD128	0	10	0	0	1	5	2	2	0.50
HKD184	2	0	9	0	0	2	7	0	0.45
OSK001	8	2	0	0	8	1	1	0	0.00
OSK002	0	0	0	3	8	1	1	7	0.40
OSK003	0	0	0	0	5	12	0	3	0.60
OSK004	0	0	0	0	0	1	19	0	0.95
OSK005	0	0	0	6	7	2	1	4	0.20

表-9に示す検証結果より、平均の精度は50%程度であるが、HKD127については90%正答率となった。OSK004についても同様に95%と高い正答率となった。これは、図-16に示すように2~10Hzの周波数帯域でのH/Vスペクトル波形が類似しているためであると推察される。一方、OSK001については、図-16より2~10Hzの周波数帯域での地震動H/Vスペクトル比と常時微動H/Vスペクトル比の卓越周波数に大きなずれがあるため、正答率が0%となったものと推測される。OSK005では2~10Hzの周波数帯域では両者のスペクトルの形状が類似していると思われたが、再現性は低く20%となった。表-9より、OSK005は、OSK001とOSK002に多く誤分類されている。なぜこのように誤分類されたかについては、今後精査が必要であるが、微小地震による地震動H/Vスペクトルと常時微動H/Vスペクトルのピーク周波数が一致しない場合には、どちらかのスペクトルの求め方を再検討する必要があるものと思われる。

## 5. 結論

本研究では、機械学習の一種であるCNN (Convolutional Neural Network)を用いた画像解析により、地盤のH/Vスペクトルをカラースペクトルに変化した画像を用いて地動観測点を特定する方法について検討した。得られた結論は以下の通りである。

- 1) 有限要素法を用いて1次元の地震応答解析を(1)表層厚の異なる2層地盤モデル4ケース、(2)K-NET観測地点の地盤情報を元に作成した多層地盤モデル5ケースに対して行った。各ケースから得られた地表面応答加速度フーリエスペクトルのカラースペクトルを作成し、画像解析によるアプローチで地盤モデルが特定できるかどうかを検討した。その結果、(1)、(2)どちらも地盤モデルを全て特定できた。また、ヒートマップを用いて特徴量の可視化を行ったところ1次、2次の卓越周波数付近を特徴量として学習していることがわかった。
- 2) K-NET観測点8地点（大阪5地点、北海道3地点）で観測された最大加速度50gal以下の地震動を基に作成したカラースペクトルから、観測地点の特定を行った。その結果、平均の特定精度は95.6%であった。また明らかに誤分類が生じたものには、震源深さ333kmである深発地震や、震源距離が505km遠方で生じた地震が含まれていることが分かった。
- 3) 対象としたK-NET観測点で実測した常時微動H/Vスペクトル比と地震動H/Vスペクトル比の相関性を確認した。そこで地震動H/Vスペクトル比と常

時微動 H/V スペクトル比が一致していると思われる 2Hz から 10Hz の周波数帯域に着目し、地震動のカラースペクトルを学習させたモデルを用いて常時微動観測点の分類を試みたところ平均精度は 50% と低調であった。また、各地点の精度に偏りがみられる結果となった。

以上の成果から、K-NET 観測点で観測された地震動に対しては、本手法を用いることで地震動 H/V スペクトルの形状から観測点を分類することができた。このことは、ローカルサイト特性から地盤構造が推定できることを示している。しかし、現段階においては、地震動 H/V スペクトル比を学習させたモデルを用いて常時微動観測点を高い精度で特定するには至っていない。これを実現するためには、常時微動 H/V スペクトル比と地震動 H/V スペクトル比の違いを検証する必要がある。さらに、地盤構造が既知の地点で常時微動観測を実施し、微動データそのものを学習データとして用いる方法が必要であると考えられる。K-NET 観測網のように、様々な地点での地盤構造がリンクされた微動観測データが整備され、誰でも簡単に利用することができるようになれば、本手法を用いて地盤構造推定ができる可能性がある。

#### 謝辞：

本研究では、防災科学技術研究所の強震観測網 (K-NET) の強震観測記録を使用しました。記して謝意を表します。

#### REFERENCES

- 1) Kanai K. and Tanaka T.: On Microtremors VIII, Bulletin of the Earthquake Research Institute, the Univ. of Tokyo, Vol.39, No.1, pp.97-114, 1961.
- 2) Nakamura, Y.: A method for dynamic characteristics estimation of subsurface using microtremor on the ground surface, Quarterly Report of RTRI, Vol.30, No.1, pp.25-33, 1989.
- 3) 恒川裕史：ニューラルネットワークを用いた地震動の初期微動による主要動予測手法，日本フアジイ学会誌，Vol. 9, No. 4, pp. 551-559, 1997.
- 4) Emami, S.M.R., Harada, T. and Iwao, Y.: Prediction of peak horizontal acceleration using an artificial neural network model, Structural Eng./Earthquake Eng., JSCE, Vol. 13, No. 2, pp. 111s-118s, 1996.
- 5) 柳瀬匡雄，丸山喜久：液状化地点の予測に向けた共分散構造分析とサポートベクターマシンの利用，土木学会論文集 A1 (構造・地震工学)，Vol. 75, No. 4 (地震工学論文集第 38 巻)，pp. I\_133-I\_143, 2019.
- 6) Kubo, H., Kunugi, T., Suzuki, W. Suzuki, S. and Aoi, S: Hybrid predictor for ground-motion intensity with machine learning and conventional ground motion prediction equation, Scientific Reports, 10, 11871 (2020). <https://doi.org/10.1038/s41598-020-68630-x>
- 7) 遠藤理平：光の波長から RGB を算出する関数の定義，NPO 法人 natural science, <https://www.natural-science.or.jp/article/20160513143413.php>, 2016 (参照 2022.9.7) .
- 8) Iai, S., Matsunaga Y., and Kameoka, T.: Strain space plasticity model for cyclic mobility, Soils and foundations, Vol. 32, No. 2, pp.1-15,1992.
- 9) 大崎順彦：新・地震動のスペクトル解析入門，鹿島出版会，1994.
- 10) 森田年一，井合進，Hanlong Liu，一井康二，佐藤幸博：液状化による構造物被害予測プログラム FLIP において必要な各種パラメタの簡易設定法，港研資料，No.869, 1997.
- 11) Krizhevsky A, Sutskever I, and Hinton GE : ImageNet Classification with Deep Convolutional Neural Networks, Proc. of NIPS, pp. 1097-1105, 2012.
- 12) Zeiler M.D., Fergus R.: Visualizing and Understanding Convolutional Networks. In: Fleet D., Pajdla T., Schiele B., Tuytelaars T. (eds) Computer Vision – ECCV 2014. ECCV 2014. Lecture Notes in Computer Science, vol 8689. Springer, Cham, 2014.
- 13) The Math Works, Inc., MATLAB, 2022a.
- 14) National Research Institute for Earth Science and Disaster Resilience: NIED K-NET, KiK-net, National Research Institute for Earth Science and Disaster Resilience, doi:10.17598/NIED.0004, 2021

## IDENTIFICATION OF SEISMIC OBSERVATION SITES BY THE DEEP LEARNING

Tetsuo TOBITA and Wataru YAMAMOTO

We propose a method for efficiently identifying ground motion observation points using deep learning with convolutional neural networks (CNN). In this method, the observed acceleration spectrum is converted into a color spectrum according to the amplitude. First, random waves were applied to multiple one-dimensional numerical model grounds, and the applicability of this method was examined using the acceleration

Fourier spectrum of the ground surface response converted into a color spectrum. As a result, the model grounds were identified with an accuracy of 99% or more. Next, when using the H/V spectral ratios of seismic ground motions of less than 50 gal obtained at eight K-NET stations, the stations could be identified with an accuracy of 95% or more. The misclassified seismic motions were special seismic motions such as long hypocentral distances. Furthermore, when the microtremor H/V spectrum ratio was input to the trained CNN, the accuracy was as low as about 50% on average.