

機械学習を用いたカースペクトルによる H/V スペクトル比の同定

関西大学 正会員 ○飛田 哲男
応用地質 正会員 山本 航

1. 目的

微動 H/V スペクトルによる表層地盤の構造推定を行うためのツール開発を目的として、本稿では、畳み込みニューラルネットワーク（以下 CNN(Convolution Neural Network)と呼ぶ）¹⁾を用いた微動 H/V スペクトル比の同定手法について検証する。まず K-NET 観測点(大阪近郊 5 地点, 北海道胆振東部 3 地点)における 50gal 以下の微小地震動(1996 年-2021 年 6 月までの 1,677 個) (図-1) の地震動 H/V スペクトル比をカースペクトルに変換し CNN により観測点の分類を行う (学習させる)。次に、各観測点で観測された微動 H/V スペクトルを学習済み CNN に入力し観測点の同定を試みる。

2. カースペクトルを用いた機械学習

CNN に入力するための画像データは、まず、スペクトル波形 (図-2(a)) に対し、最大値を赤、最小値を紫とするカースペクトル (RGB 24bit) (図-2(b)) に変換することで得た。ここでは、横軸を 0.1Hz から 25Hz の算術目盛りとする。図-3 に K-net OSK004 の 18 個の観測地震の地震動 H/V スペクトル比を示す。現状ではカースペクトルの縦軸は、任意の長さとするが、何らかの情報を組み入れることもできる。上で述べた地震動より作成したカースペクトル画像 (1,677 枚) に対し、ここでは Matlab をプラットフォームとして、試みに AlexNet²⁾ による転移学習を行った。作成したカースペクトル画像を 7:3 の割合で学習用と検証用に分割し学習と検証を行ったところ、平均 95.6% の学習精度で観測地点を分類できた。誤分類した地震動を調べたところ、深発地震や震源距離が大きいという、震源特性や経路特性が強く表れる傾向のあるものであった。

3. 同定結果

キーワード H/V スペクトル比, 機械学習, カースペクトル

連絡先 〒564-8680 大阪府吹田市山手町 3-3-35

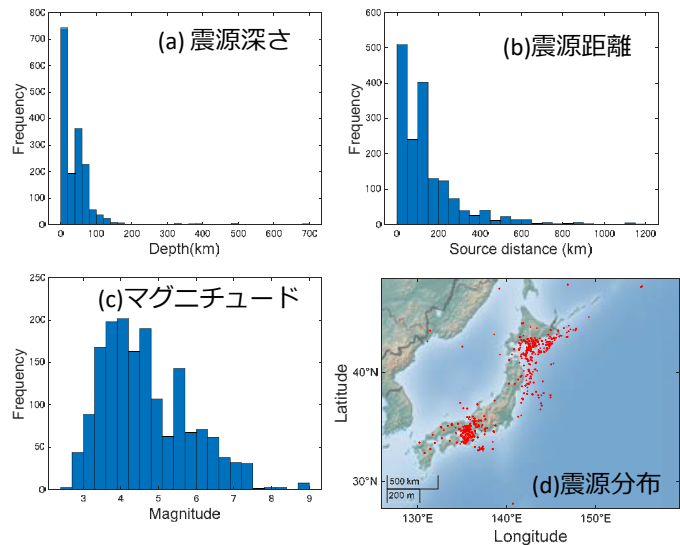


図-1 用いた地震動の情報：(a) 震源深さ, (b) 震源距離, (c) 気象庁マグニチュード, (d) 震源分布




図-2 カースペクトルの作成手順：(a) 算術目盛りで表示したフーリエスペクトル, (b) カースペクトル

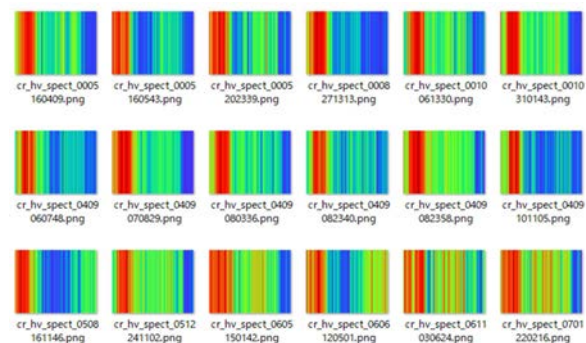


図-3 地震動ごとに作成した地震動カースペクトルの一例 (OSK004)

各 K-NET 観測点で約 15 分の観測を行い、振幅の安定した 20 秒の連続区間を抽出し微動 H/V スペクトル比を求めた。これと、各観測点の地震動 H/V スペクトル比を比較したものが図-4 である。ただし、同図に示す地震動 H/V スペクトル比は、当該地点のその算術平均であり比較のため例示するものである。この比較から、両スペクトル比の卓越振動数や形状に類似した傾向があることがわかる(例えば3)。

学習済みの CNN に対し微動カラスペクトルを入力して観測点の分類を行った結果、表-1(a)の最右列(Recall 欄)に示す再現率の平均は約 28%にとどまった。そこで、図-4 より両スペクトル比の形状が 2Hz から 10Hz の間でよく似ていることに着目し、対象とする振動数を 2Hz から 10Hz に絞り、再度地震動カラスペクトルを学習させ、同様に分類を行ったところ、表-1(b)のように再現率の平均は 50%にやや改善した。しかし、OSK001 のように、範囲を狭くしたことで誤分類される割合が増えたケースもある。このことから、特徴的なピークを外さないようにするなど、検討が必要である。

4. まとめ

本研究では、微動 H/V スペクトルによる表層地盤の構造推定を行うためのツール開発を目的として、機械学習によるスペクトルの同定手法について検証した。本手法により地震動 H/V スペクトルを用いた場合には観測地点を高い精度で分類できたが、微動 H/V スペクトルの場合には 50%程度の正解率にとどまった。

謝辞: 本論文で用いた観測記録(K-NET)は防災科学技術研究所が観測・収集したものです。記して感謝の意を表します。

参考文献

1) 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. 2) Krizhevsky A, Sutskever I, and Hinton GE: ImageNet Classification with Deep Convolutional Neural Networks, Proc. of NIPS, 1097-1105, 2012. 3)大熊裕輝, 松岡昌志, 山崎文雄, 原田隆典: 宮崎県における常時微動 H/V スペクトル比を用いた地震動の推定, 土木学会論文集, No.696/I-58, pp.261-272, 2002.

表-10 検証結果

(a) 1Hz - 25Hz

True Class	Predicted Class								Recall
	HKD127	HKD128	HKD184	OSK001	OSK002	OSK003	OSK004	OSK005	
HKD127	0	1	0	2	16	1	0	0	0.00
HKD128	0	9	0	9	0	1	0	1	0.45
HKD184	0	0	7	13	0	0	0	0	0.35
OSK001	2	0	0	6	8	2	2	0	0.30
OSK002	0	1	0	0	7	0	0	12	0.35
OSK003	0	1	0	7	14	4	2	2	0.13
OSK004	0	0	1	5	0	0	14	0	0.70
OSK005	0	2	0	12	3	3	0	0	0.00

(b) 2Hz - 10Hz

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

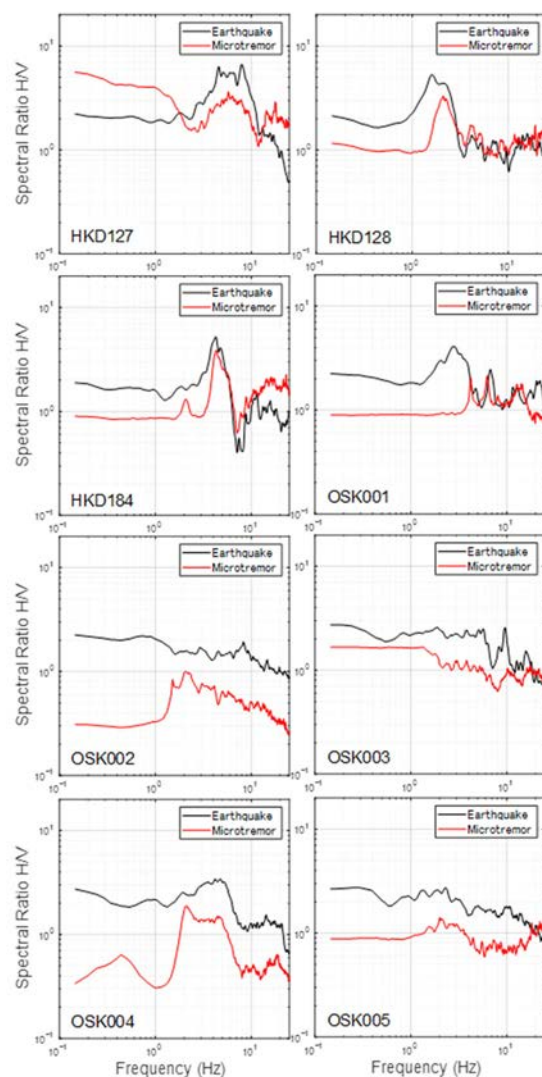


図-4 地震動 H/V スペクトル比 (学習に使用した地震動平均) と常時微動 H/V スペクトル比 (20s をスタックした微動の平均) の比較