

深層学習を用いた P 波初動の極性検出 P-wave Polarity Determination from Waveform Data Using Deep Learning

○原 将太・深畑 幸俊・飯尾 能久

○Shota HARA, Yukitoshi FUKAHATA, Yoshihisa IIO

In order to determine focal mechanisms of earthquakes, it is necessary to determine first-motion polarities of P-wave. Researches on various automatic determination algorithms has been developed, but the accuracy of conventional algorithms has been significantly lower than that of human experts. Therefore, check by human experts is commonly needed, when we apply an automatic determination algorithm to observed waveform data. In this study, we develop a model of the convolutional neural network (CNN) that can determine P-wave first-motion polarities of seismic waveforms, in which P-wave arrival times determined by human experts are given beforehand. We use about 30 thousand 100 Hz and about 100 thousand 250 Hz waveform data observed in the San-in area, Japan, to train and test the CNN. The trained CNN is then applied to waveform data observed in the northern Kinki area, Japan. The P-wave polarities determined by the CNN have the accuracy of about 95% for 100 Hz data and about 98% for 250 Hz data.

1. 背景

地震の P 波の到達時刻と初動極性は、震源位置やメカニズム解を決定する上で必須の情報であり (Hardebeck & Shearer, 2002, Yang *et al.*, 2012), 専門家により手動で検出されたものが使われることが多い。しかし、P 波の到達時刻の検出を自動で行うアルゴリズムは以前より盛んに研究が進められており、ほぼ実用レベルに達している。例えば、Allen (1978) の STA/LTA アルゴリズム、Sleman & Van Eck (1999) の自己回帰法が使用されている。最近では、Zhu & Beroza (2018) が深層学習を用いた方法を提案した。日本では、P 波の到達時刻や初動極性の自動決定について、堀内ら (2009) が開発したアルゴリズムが使用されることが多い (Matsumoto *et al.*, 2018, Iio *et al.*, 2017 など)。しかし、極性検出については、観測された地域に応じて専門家がパラメータを調整する必要がある、自動化の障害となっている。

本研究では、極性検出に畳み込みニューラルネットワーク (Convolutional Neural Network, CNN) を用いた。CNN は LeCun *et al.* (1998) によって導入され、特に画像認識の分野で威力を発揮している手法である。専門家は、波形の画像を見ることで初動極性を判断しており、CNN によって人の判断により近い自然な深層学習モデルを実現できると考えた。

同様に CNN を用いて Ross *et al.* (2018) は、カリフォルニアで得られた地震波形に対して、専門家の極性検出との一致率が 95% に達したことを報告している。本研究では、Ross *et al.* (2018) と同等の一致率を西日本で観測された地震波形についても得られるかどうか検証すると共に、地域依存性や、サンプリング周波数依存性についても調べた。

2. データ

サンプリング周波数が 100 Hz の地震波形と、250 Hz の地震波形のうち、P 波の到達時刻と初動極性が専門家によって既に検出されているものを用いた。観測点の地域は、鳥取・島根地方 (2015 年 4 月～2015 年 9 月) と近畿地方北部 (2016 年 3 月～9 月) である。サンプリング周波数 100 Hz の地震波形は、気象庁、防災科学技術研究所 (Hi-net), および京都大学の定常観測点の波形で、合計 40,169 個 (鳥取・島根が 30,231 個, 近畿北部が 9,938 個) の波形を使用した。サンプリング周波数 250 Hz の地震波形は、満点地震計 (飯尾 2011) により稠密地震観測網 (鳥取・島根: 飯尾他 2017, 近畿北部: 三浦他 2010) で得られた波形であり、合計 127,200 個 (鳥取・島根が 103,823 個, 近畿北部が 23,377 個) である。

3. 手法

地震波形データのうち、P 波到達時刻の前後 75

プロット (100 Hz なら 1.5 秒間, 250 Hz なら 0.6 秒間), 計 150 プロットを切り出して用いた. P 波到達時刻は専門家が検出したものをそのまま用いた. また, 地震波形は地震の大きさなどにより振幅が異なるため, z-score 正規化を行った.

CNN の具体的なモデルとしては 150×1 の 1 次元波形を 125×30 , 100×70 , と整形する畳み込み層 (Convolution layer) と全結合層 (Fully connected layer) からなるものを用いた (Figure 1). 隠れ層の活性化関数には勾配消失問題を解決できる ReLU 関数を用い, 出力層では確率値を得るために Softmax 関数を用いた.

正解データには専門家による P 波初動極性の検出結果 (Up, Down の 2 値) を用いて訓練を行った. 鳥取・島根地方の全波形を 9:1 の割合で訓練データと検証データに分けて学習させた後, 近畿地方北部の波形に対して学習済みの検出モデルを適用し, 人の検出結果との一致率を調べた.

4. 結果

極性検出の結果は以下の表 (Table 1) により分類できる.

	U_{CNN}	D_{CNN}
U_{human}	TU	FD
D_{human}	FU	TD

Table 1 検出結果の分類

TU は CNN が Up と予測して, 専門家 (human) も Up と検出した波形数. FU は CNN が Up と予測して, 専門家は Down と検出した波形数. FD, TD についても同様である. 精度の比較には TU と TD の波形数を足したものを全体で割ることで得られる Accuracy という指標を用いた. 例えば, Accuracy が 95 % であれば, 1,000 個の地震波形の極性を検出させたとき, 人と結果が一致する波形数が 950 個になる.

鳥取・島根地方の地震波形データで訓練した CNN を近畿地方北部の地震波形に適用した結果は, 98.8 % (250 Hz) と 95.4 % (100 Hz) の Accuracy を有した. このため, 地域に応じた極性検出モデルのパラメータ調整は必要ないと考えられる. また, サンプル周波数に応じて Accuracy が 3 % 以上異なるという興味深い結果も得られた.

5. 謝辞

本研究では, 気象庁, 防災科学技術研究所, および京都大学の定常観測の地震波形データを使わせて頂きました.

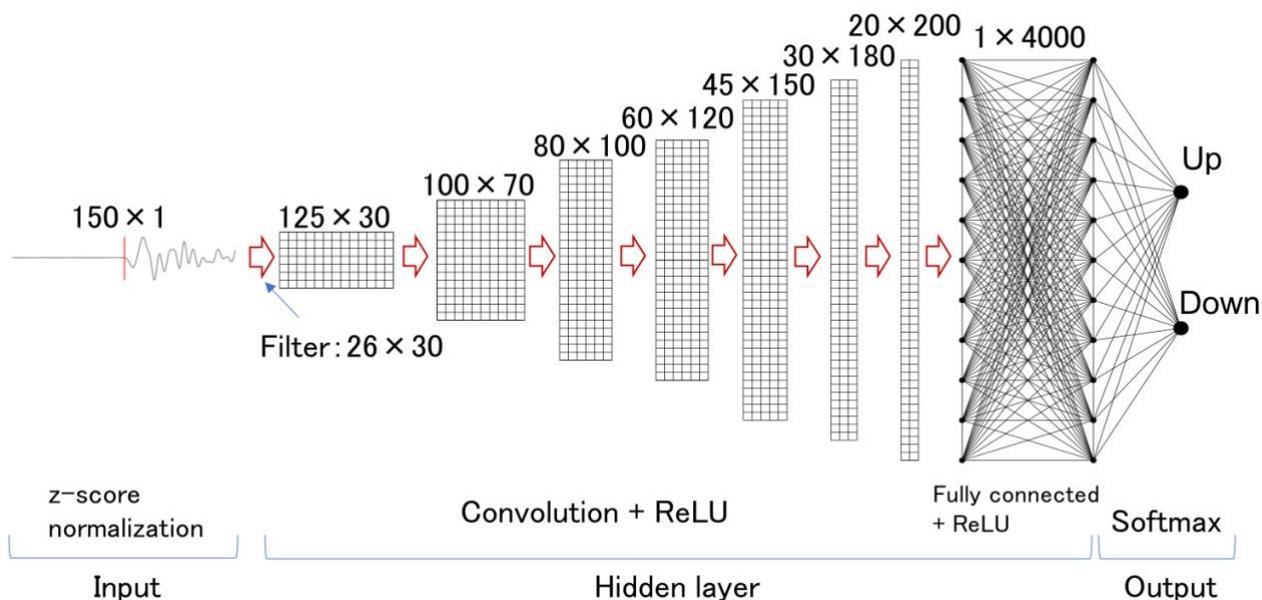


Figure 1 初動極性の検出を行う CNN のモデル