

1次元畳み込みニューラルネットワークを用いた地震波形検測

Seismic Phase Detection and Picking with 1-D Convolutional Neural Network

工藤祥太¹, 下條賢悟¹, 溜淵功史²

KUDO Shota¹, SHIMOJO Kengo¹, and TAMARIBUCHI Koji²

(Received November 26, 2021; Accepted January 17, 2023)

1 はじめに

気象庁では、気象庁、防災科学技術研究所、大学などの関係機関から一元的に収集された地震波形データを用いて、精密に P 相・S 相・最大振幅などの検測を行い、日々震源の決定を行っている（一元化震源）。この一元化震源の決定に、気象庁は 2016 年 4 月から、自動震源決定手法である PF（Phase combination Forward search）法（溜淵・他, 2016, Tamaribuchi, 2018）の活用を開始した。PF 法では、まず、連続地震波形データから分散比, Characteristic Function（Allen, 1978）, AR-AIC（横田・他, 1981）などを用いて地震波検知・検測を行う（一次検測）。その後、一次検測値を元にグループトリガ（清本・他, 2013）や重点サンプリング法などを用いて震源を計算し、決定する。PF 法は従来の自動震源決定手法に比べ、イベント検知能力や震源精度の大幅な向上をもたらしたものの、一次検測の段階でノイズを誤検知し、その結果誤った震源を決定してしまうことも多い（図 1）。一次検測の段階でノイズの誤検知を減らすことができれば、PF 法の震源精度はさらに向上すると期待される。そのためには、PF 法による一次検測をより精度の高い検測手法で置き換えるか、PF 法による一次検測値のうち実際にはノイズであるものを除去するかの二通りが考えられる。

ところで、近年、Deep Learning と呼ばれるアプローチが画像認識・音声認識等さまざまな分野で成功を収めているが、地震波形処理の分野においても、CNN（Convolutional Neural Network: Deep Learning の一手法）を用いた P 相検測（Ross et al., 2018a）、CNN を用

いたノイズ/P 相/S 相の識別（Ross et al., 2018b）がすでに行われ、良い成果を収めている。これらを利用することで、PF 法の一次検測の置き換え、あるいは一次検測値からのノイズ除去（デノイザ）を実施でき、震源精度を向上させられる可能性がある。本研究では、先行研究（Ross et al., 2018a, b）に準拠した P・S 検測モデルおよびノイズ/P/S 識別モデルを作成し、一元化震源の検測値と、その検測値に対応する地震波形データをモデルに与えて学習させ、モデルの精度を検証する。また、学習済みのモデルを PF 法と組み合わせることによって、PF 法の震源がどのように変化するかを検証する。

2 1次元 CNN モデルの学習・評価

2.1 P・S 検測モデル

2.1.1 概要

4 秒間の地震波形データを入力すると、P 相の検測値を出力するモデルと、S 相の検測値を出力するモデルをそれぞれ作成する。P 相および S 相の検測値と、それに対応する地震波形データをセットにして CNN モデルに供給することで学習を進める（図 2）。地震波形データを入力値にしたとき、対応する検測値データに近い値が出力されるようにモデルのパラメータを更新していく。

2.1.2 データ

モデルの学習には、一元化震源の検測値、地震波形データのうち、以下の条件を満たすデータを用いた。

¹ 地震火山部地震火山技術・調査課, Earthquake and Volcanic Engineering Affairs Division, Seismology and Volcanology Department

² 気象研究所地震津波研究部, Department of Seismology and Tsunami Research, Meteorological Research Institute

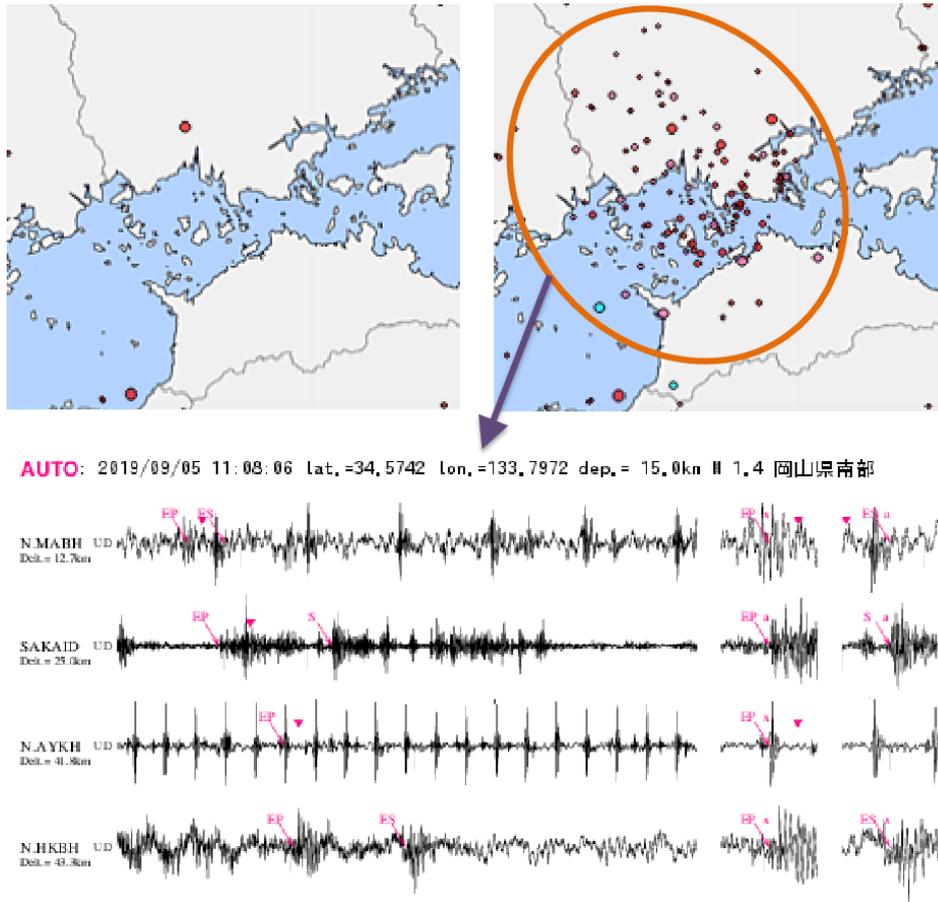


図 1 左上：人手による精査済み震源，右上：PF 法による自動震源，下：ノイズの誤検知事例．

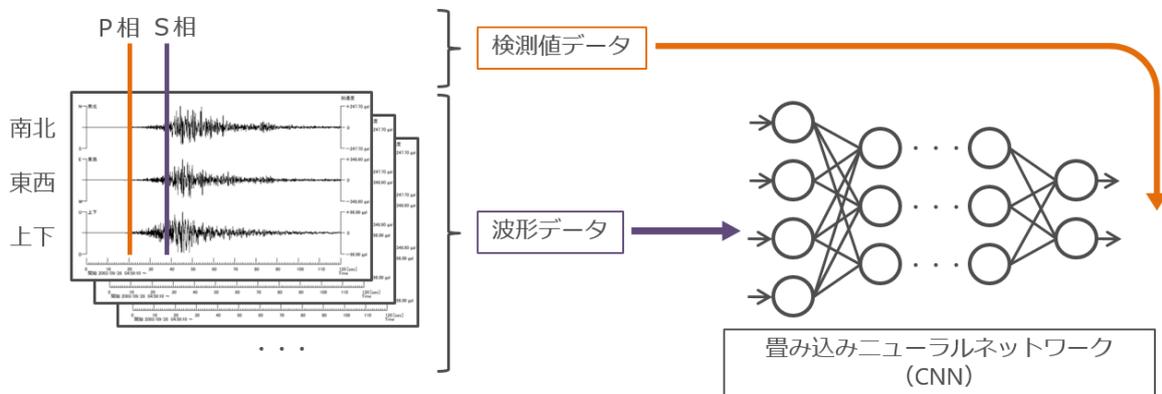


図 2 P・S 検測モデルの概要

期間: 2017年4月1日～2018年4月1日

地震計種別: 速度計

成分: (P相検測モデル)U/D成分(S相検測モデル)

N/S, E/W成分

サンプリング周波数: 100Hzのみ

観測点: PF法で計算に用いている全観測点のうち上記の地震計種別・成分・サンプリング周波数の条件を満たす観測点(1420点)

震源精度: K, k登録(高精度かつ手動で決定した)震源

マグニチュード: 2.0以上

震源深さ: 100km以下

2.1.3 前処理

モデルに供給するデータには、以下のとおり前処理を行った。なお、P相検測モデル用、S相検測モデル用、とそれぞれ前処理を行い、データセットを作成した。

1. 相検測値の10秒前から60秒間の地震波形を切り出し。ただし、P相検測モデル用はU/D成分のみの1チャンネル、S相検測モデル用はN/S, E/W成分の2チャンネル
2. 線形トレンド除去
3. 両端5%にハン窓によるテーパ処理
4. バターワース特性のハイパスフィルタ(2Hz以上通過)を適用
5. 訓練・検証・テストデータに8:1:1の割合で分配。この際、同じ地震についての地震波形が各データにまたがらないようにした
6. 検証・テストデータについては相を中心として、400サンプル(4秒間)を切り出し。ただし、中心位置は±50サンプルの一樣ランダムなぶれを付加
7. 訓練データについては、相を中心とした800サンプルを切り出しておき、モデルの学習時に6.と同様にぶれを持たせて400サンプル切り出す。これによりモデル学習時にデータの水増しを行うことができる

上記の前処理を経て、実際に学習に用いたデータ数を表1に示す。

表1 P・S検測モデルの学習に用いたデータ数

	訓練	検証	テスト
P相検測モデル用	353,198	44,449	44,443
S相検測モデル用	309,082	38,873	38,878

2.1.4 モデル

モデルはRoss et al. (2018a)に準拠した1次元CNNモデルを構築した。モデルの模式図を図3に、モデルの設計を表2、モデルの学習設定を表3に示す。なお、入力層については、P相検測モデルはU/D成分のみ入力するので1チャンネル、S相検測モデルはN/S成分、E/W成分を入力するので2チャンネルとなっている。

2.1.5 学習

モデルの学習は以下の手順に従って行った。

1. 訓練データから波形・検測値のセットをランダムに480個選び、波形を入力層に供給
2. モデルの出力と検測値から求まる損失(MSE: Mean Squared Error)がより小さくなるようにパラメータを更新
3. 1., 2.を繰り返し、訓練データを全て使い切る(1エポック)ごとに損失を検証データについて確認
4. 10エポック以上検証データについての損失に改善が見られなかった場合に学習を打ち切り(早期終了)、最も損失が小さいエポックのモデルを最良モデルとして採用

図4にP相検測モデル、S相検測モデルの学習経過のグラフを示す。訓練データについての損失は、P相検測モデル、S相検測モデルのどちらもエポックが増加するにつれ単調減少している。一方、検証データについての損失は、局所的な増減はあるものの、P相検測モデルについては学習終了まで減少傾向が続いているが、S相検測モデルについては最小値となったエポック以降は逆に増加傾向となり、過学習(訓練データに過度に適合してしまい、未知のデータに対する予測性能が下がった状態)に陥っている。

2.1.6 精度検証

P相検測モデルとS相検測モデルのそれぞれについて、テストデータに対する予測値と真値との差(残差)

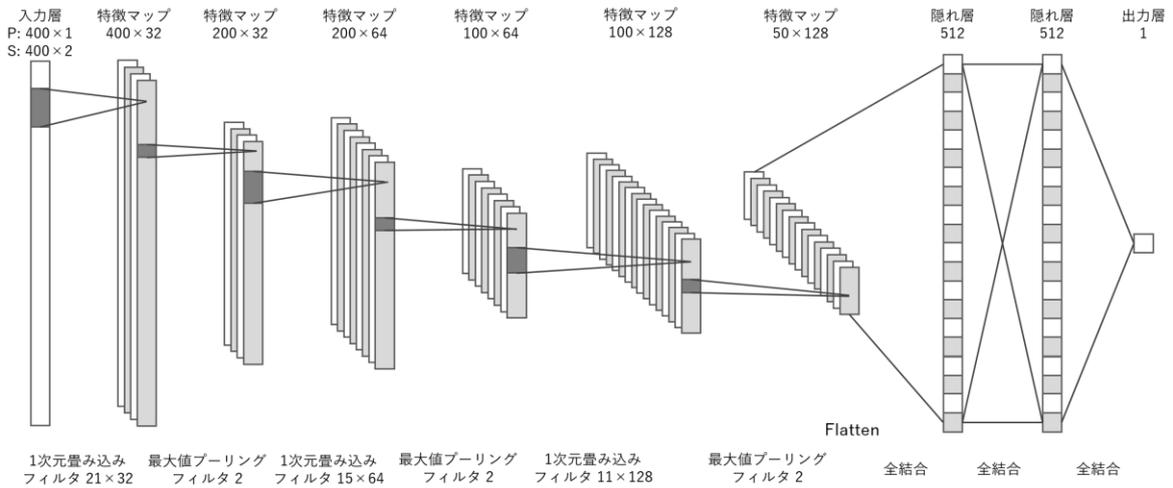


図 3 モデルの設計イメージ. 各層にデータの形状×チャンネル数を付記.

表 2 モデルの設計. C: 一次元畳み込み層, B: バッチ正規化層, P: 最大値プーリング層, F: 全結合層を表す.

	L1	L2	L3	L4	L5	L6
層	CBP	CBP	CBP	FB	FB	F
フィルタ数/ユニット数	32	64	128	512	512	1
フィルタサイズ	21	15	11	-	-	-
活性化関数	ReLU	ReLU	ReLU	ReLU	ReLU	-

表 3 モデルの学習設定

損失関数	平均二乗誤差 (MSE: Mean Squared Error)
最適化手法	Adam (学習率: 0.001)
バッチサイズ	480
モデル採用	10エポック以上検証データについての損失に改善が見られなかった場合に学習を打ち切り (早期終了), 最も損失が小さいエポックのモデルを最良モデルとして採用

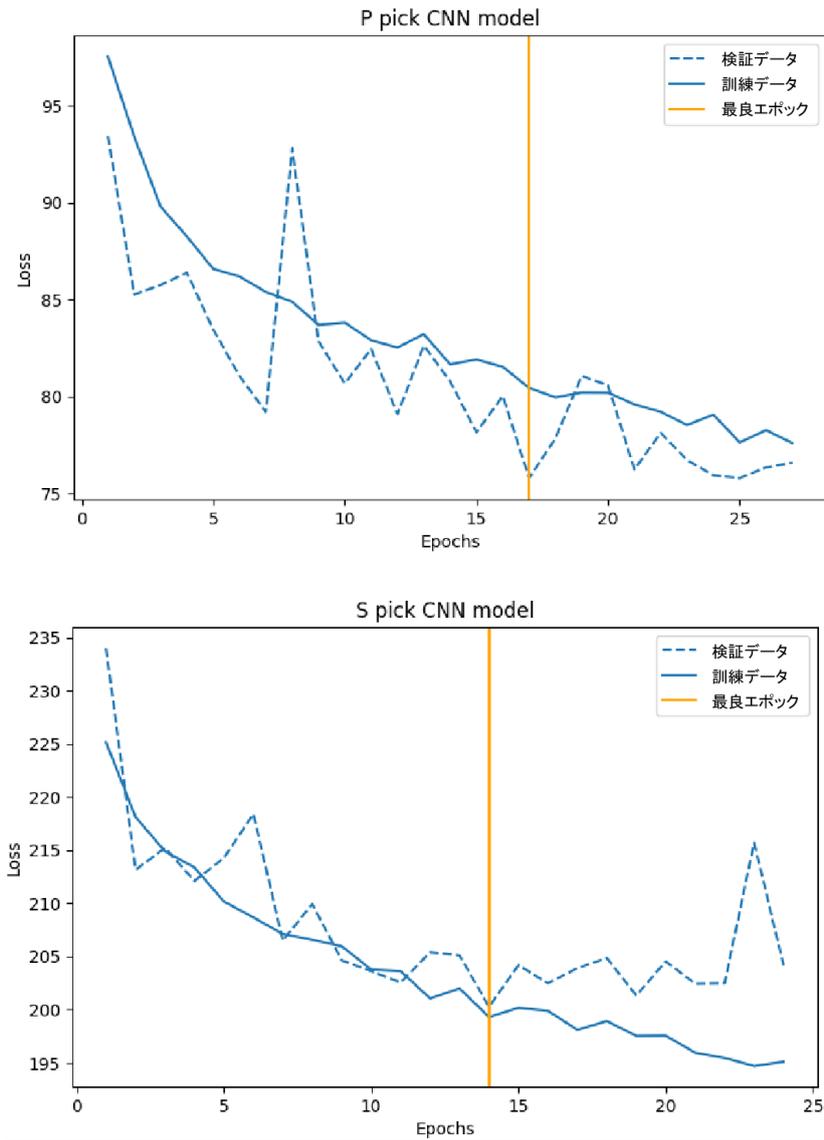


図4 上：P相検測モデルの学習経過，下：S相検測モデルの学習経過．縦軸が損失（MSE），横軸がエポック数．青実線が訓練データに対する損失で，青破線が検証データに対する損失．検証データに対する損失が最小となる位置に橙の垂直線を描画している．

に関する統計量を算出した (図 5, 表 4). 平均はどちらのモデルも 0 に近く, 系統的な誤差はほぼ見られない. 標準偏差は P 相検測モデルの方が S 相検測モデルよりも小さく, ばらつきが少ない. 残差の絶対値の平均である平均絶対誤差も P 相検測モデルの方が S 相検測モデルよりも小さい. 波形データのサンプリング周期が 0.01 秒であることを考えると, P 相検測モデルの検測誤差は非常に小さいと言える.

2.1.7 検測例

学習済みのモデルにテストデータを入力し, 相検測を行わせた例を図 6, 7 に示す. 相の見え方が明瞭な波形に関しては, 人手による検測値 (以降, 真値) とモデルによる検測値 (以降, 予測値) はほぼ一致するが, 相の見え方が不明瞭な波形に関しては, 真値と予測値に差があるという傾向が見られた. 中には, 波形だけ見ると予測値の方が真値よりも正しく相を検測しているのではないかと見られる例もあった (図 7 の一番下).

2.2 ノイズ/P/S 識別モデル

2.2.1 概要

4 秒間の波形を与えた時, その中心, すなわち 2 秒付近に P 相があるか, または S 相があるか, あるいはそれ以外か (以降, 便宜的に「ノイズ」あるいは「N」と表記する) を識別するモデルを作成する. 地震波形データに N, P, S のラベル付けをし, これらをセットにして CNN モデルに供給することで学習を進める. 地震波形データを入力値にしたとき, 対応するラベルと同じクラスに分類されるようにモデルのパラメータを更新していく.

2.2.2 データ

モデルの学習には, 一元化震源の検測値, 地震波形データのうち, 以下の条件を満たすデータを用いた.

期間: 2017 年 4 月 1 日~2018 年 4 月 1 日

地震計種別: 速度計

成分: U/D, N/S, E/W の 3 成分を必ず含む

サンプリング周波数: 100Hz のみ

観測点: PF 法で計算に用いている全観測点のうち上記の地震計種別・成分・サンプリング周波数の条件を満たす観測点 (1420 点)

震源精度: K, k 登録 (高精度かつ手動で決定した)

震源

マグニチュード: 2.0 以上

震源深さ: 100km 以浅

2.2.3 前処理

モデルに供給するデータには, 以下のとおり前処理を行った.

1. P 相検測値の 10 秒前から 60 秒間の地震波形を切り出し
2. 線形トレンド除去
3. 両端 5% にハン窓によるテーパー処理
4. バターワース特性のハイパスフィルタ (2Hz 以上通過) を適用
5. 訓練・検証・テストデータに 8:1:1 の割合で分配. この際, 同じ地震についての地震波形が各データにまたがらないようにした
6. 検証・テストデータについては, P 相を中心とした 400 サンプル (4 秒間), S 相を中心とした 400 サンプル, P 相の 3.5 秒前を中心とした 400 サンプルを切り出し, それぞれ P, S, N とラベル付けする (図 8). ただし, 中心位置は ± 50 サンプルの一樣ランダムなぶれを付加
7. 訓練データについては, P 相, S 相, P 相の 3.5 秒前を中心とした 800 サンプルを切り出しておき, それぞれ P, S, N とラベル付けし, モデルの学習時に 6. と同様にぶれを持たせて 400 サンプルを切り出す. これによりモデル学習時にデータの水増しを行うことができる
8. データの各クラス (N/P/S) のデータ数が均等になるように調整

上記の前処理を経て, 実際に学習に用いたデータ数を表 5 に示す.

2.2.4 モデル

モデルは Ross et al. (2018b) に準拠した 1 次元 CNN モデルを構築した. モデルの模式図を図 9 に, モデルの設計を表 6, モデルの学習設定を表 7 に示す.

2.2.5 学習

モデルの学習は以下の手順に従って行った.

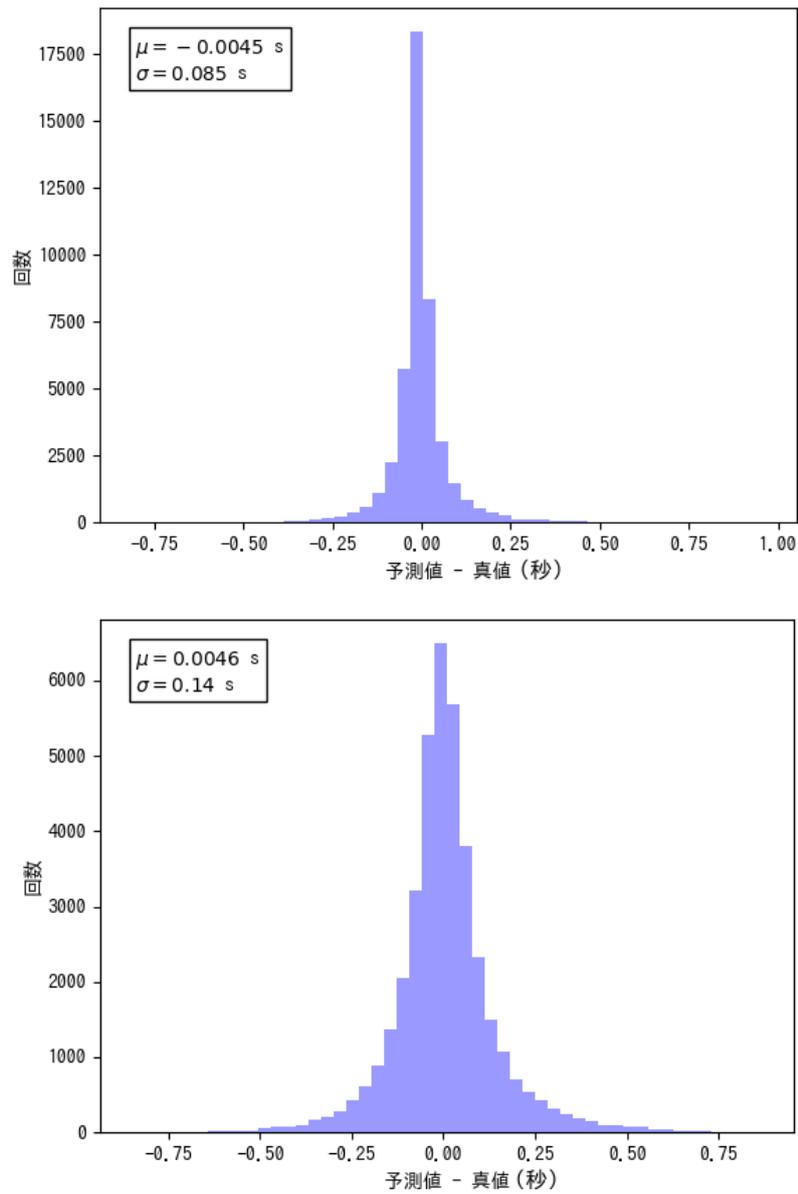


図5 上：P相，下：S相．検測モデルのテストデータに対する予測値と真値の差（残差）についてのヒストグラム． μ ：平均， σ ：標準偏差．

表4 P相，S相検測モデルの予測値と真値の差（残差）の統計量．MAE: Mean Absolute Error（平均絶対誤差）．平均，標準偏差，MAEの単位は秒．

	データ数	平均	標準偏差	MAE
P相	44,443	-0.0045	0.085	0.049
S相	38,878	0.0046	0.14	0.095

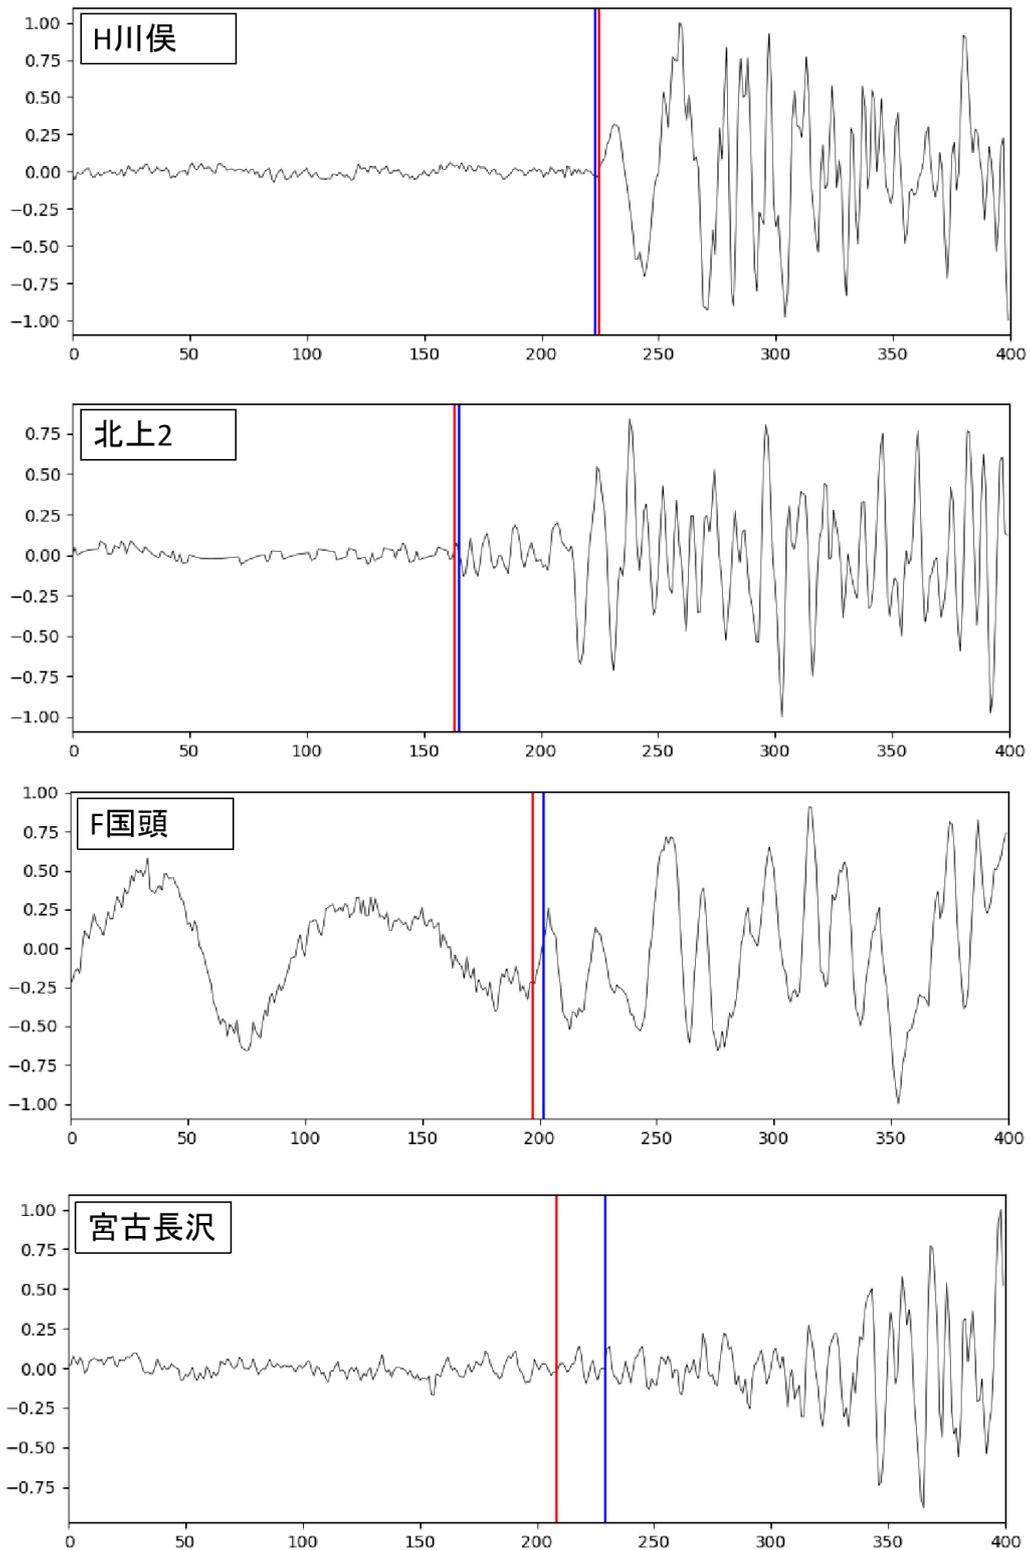


図 6 P 相検測モデルによる波形の検測例. U/D 成分を表示. 波形は 2Hz 以上のハイパスフィルタをかけたのち最大絶対値で規格化したもの. 縦軸は-1~1 の値をとる規格化された振幅. 横軸はサンプル数 (1/100 秒). 青線が人手による精査済みの検測値 (真値), 赤線がモデルによる検測値 (予測値).

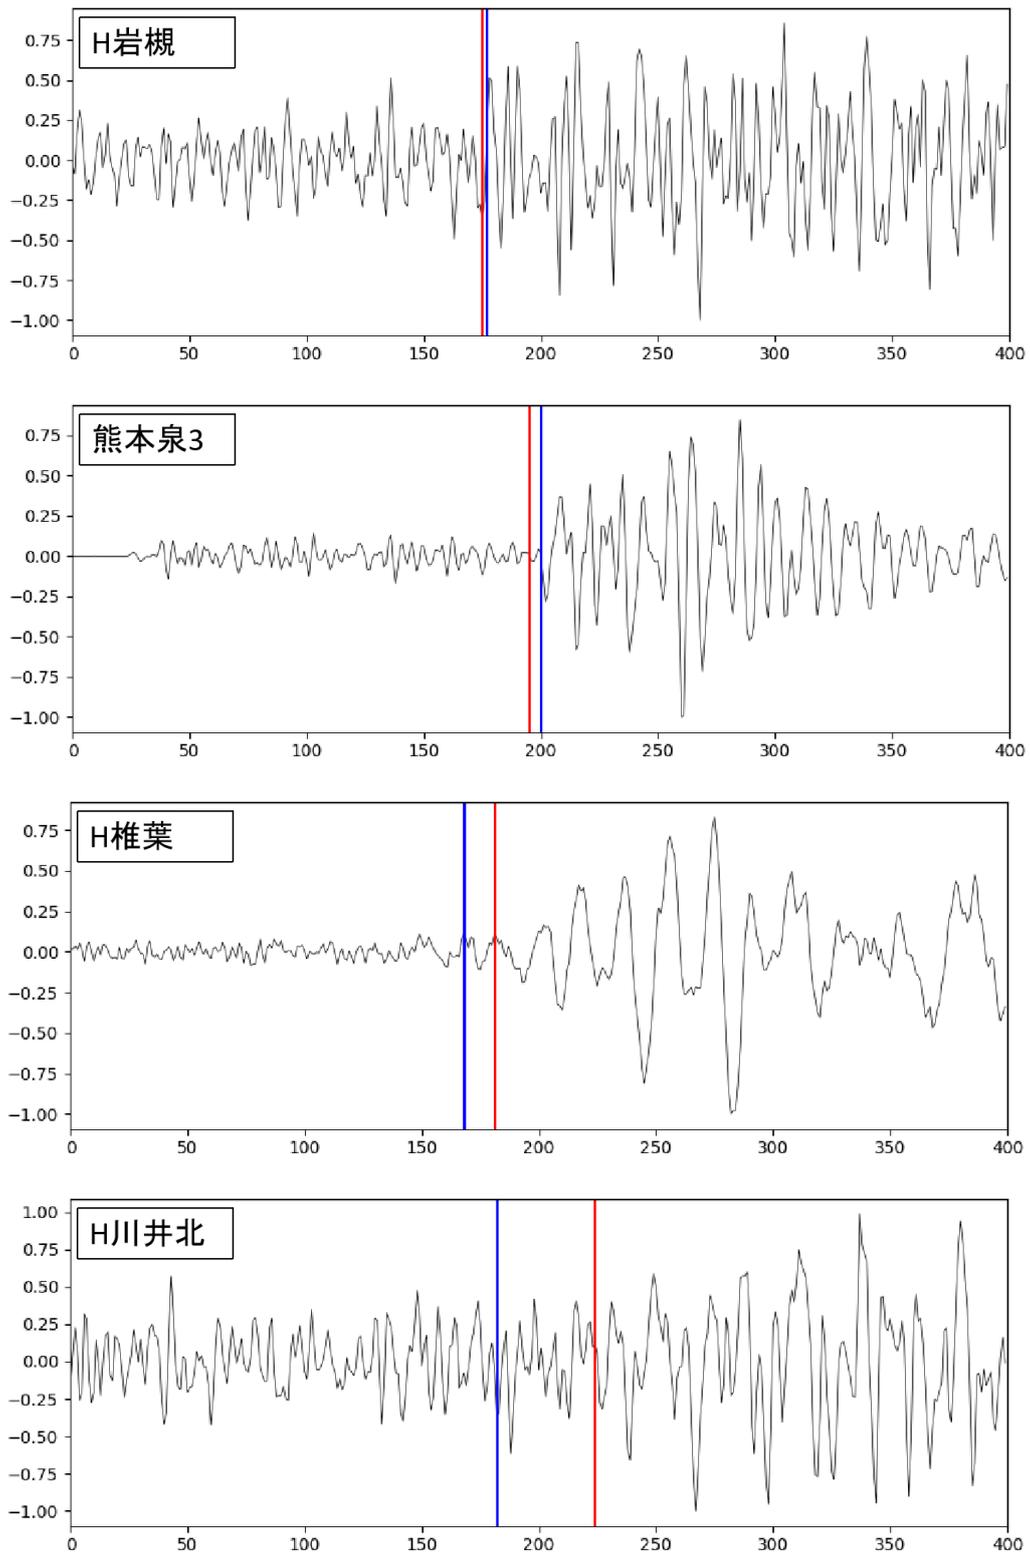


図7 S相検測モデルによる波形の検測例. N/S成分を表示. 波形は2Hz以上のハイパスフィルタをかけたのち最大絶対値で規格化したもの. 縦軸は-1~1の値をとる規格化された振幅. 横軸はサンプル数(1/100秒). 青線が人手による精査済みの検測値(真値), 赤線がモデルによる検測値(予測値).

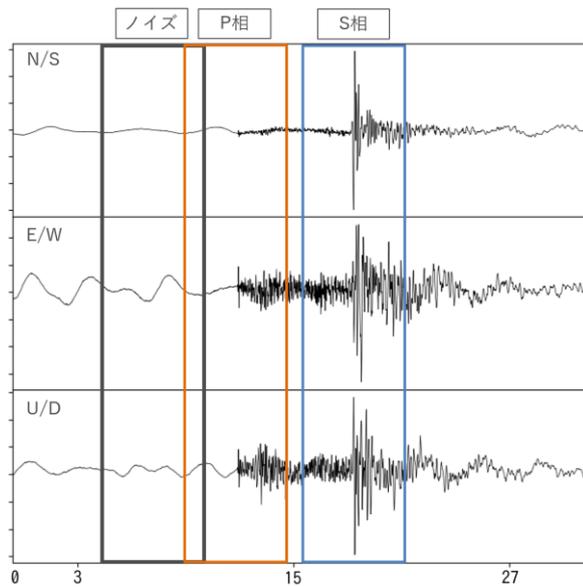


図 8 N/P/S 識別モデルの学習データの切り出しのイメージ。縦軸は振幅，横軸は時間（秒）。

表 5 N/P/S 識別モデルの学習に用いたデータ数

	訓練	検証	テスト
N	309,043	38,858	38,875
P	309,045	38,858	38,873
S	309,082	38,873	38,878

1. 訓練データから波形と，対応する N/P/S のラベルのセットをランダムに 480 個選び，波形を入力層に供給
2. モデルの出力とラベルがより一致するように（損失：カテゴリ交差エントロピーが小さくなるように）パラメータを更新
3. 1., 2. を繰り返し，訓練データを全て使い切る（1 エポック）ごとに損失を検証データについて確認
4. 10 エポック以上検証データについての損失に改善が見られなかった場合に学習を打ち切り，最も損失が小さいエポックのモデルを最良モデルとして選択

図 10 に N/P/S 識別モデルの学習経過のグラフを示す。訓練データについての損失は，エポックが増加するにつれ単調減少している。一方，検証データについての損失は，損失が最小値となったエポック以降は逆

に増加傾向となり，モデルが過学習に陥っている。

2.2.6 精度検証

テストデータに対するモデルの予測値と真値から，多クラス分類の評価として用いられる混同行列（Confusion Matrix）を求めた（表 8）。また，混同行列より各種評価指標を求めた（表 9）。モデルの正解率，適合率，再現率いずれも 98%以上となり，いずれかのクラスに過度に偏ることなく高精度で N/P/S を識別できている。また，図 11 にモデルの Precision-Recall トレードオフ曲線を示す。この曲線は各クラスについて，そのクラスと判断するための予測確率の閾値を 0 から 1 まで少しずつ変化させていったときの適合率と再現率を求め，プロットしたものである。右上に張り付くようなグラフになるほど，適合率と再現率が同時に高くなりうる性能が良いモデルであるとされる。N/P/S 識別モデルは，軸範囲を 0.0 から 1.0 とするとほぼ右上に張り付く四角形のグラフに見えたため，軸範囲を 0.95 から 1.0 に限定している。識別能力は，高い方から順に P, S, N となっている。これは P 相より S 相の方が SN 比が低く，識別しにくいという知見とも一致している。また N は便宜上ノイズと呼んでいるが，学習に用いたのは，あくまでも P 相より 3.5 秒前を中心とした 4 秒間の波形であり，多くは定常ノイズである。データ間に共通する特徴が明確でないため，P, S に比べ性能が低くなっていると推察される。

2.2.7 識別例

学習済みのモデルにテストデータを入力し，N/P/S の識別を行わせた例を図 12~15 に示す。モデルは波形が入力されると N/P/S=0.1/0.3/0.6 のようにそれぞれのクラスの予測確率を出力する。ここでは，最も高い確率となったクラスをモデルの予測値とする。相が明瞭な波形については，ほぼ 1.0 の予測確率かつ正しく識別できていた。図 12 の波形は，N/S, E/W 成分の中央付近に地震ではない何らかの変化点を含む例だが，モデルは正しく N と識別している。図 13, 図 14 は一見して P なのか S なのかを判別するのは難しいが，モデルは正しく識別できている。モデルが P 相の変化点と S 相の変化点について，両者を識別するための特徴量をうまく抽出していると推察される。図 15 の波形は，真値が N のところ予測値は P，とモデルが誤って識別した例である。

1次元畳み込みニューラルネットワークを用いた地震波形検測

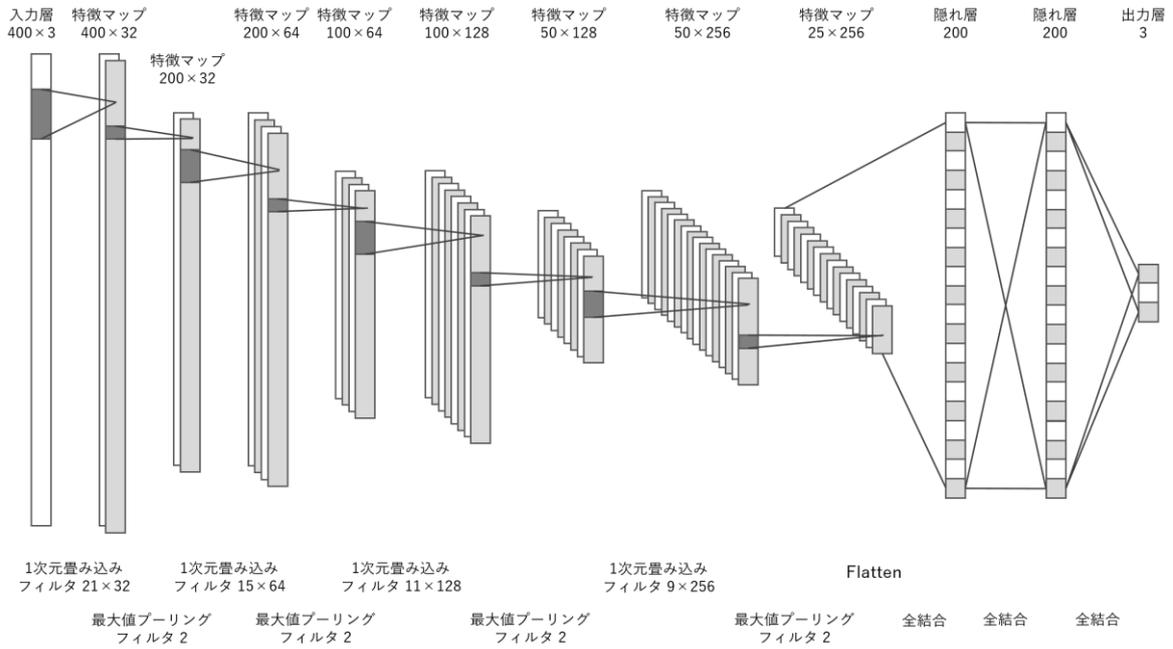


図9 モデルの設計イメージ. 各層にデータの形状×チャンネル数を付記.

表6 モデルの設計. C: 一次元畳み込み層, B: バッチ正規化層, P: 最大値プーリング層, F: 全結合層を表す.

	L1	L2	L3	L4	L5	L6	L7
層	CBP	CBP	CBP	CBP	FB	FB	F
フィルタ数/ユニット数	32	64	128	256	200	200	3
フィルタサイズ	21	15	11	9	-	-	-
活性化関数	ReLU	ReLU	ReLU	ReLU	ReLU	ReLU	Softmax

表7 モデルの学習設定

損失関数	カテゴリ交差エントロピー (Categorical Crossentropy)
最適化手法	Adam (学習率: 0.001)
バッチサイズ	480
モデル採用	10エポック連続で損失に改善が見られなければ早期終了し, 検証データに対する損失が最小となるモデルを採用

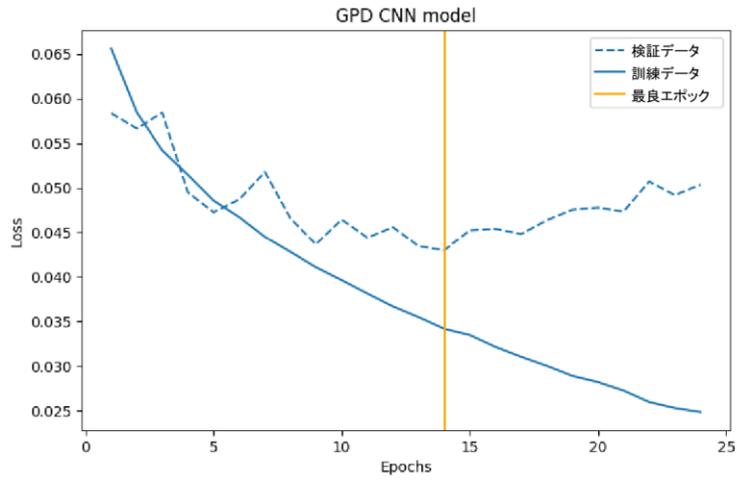


図 10 N/P/S モデルの学習経過. 縦軸が損失 (カテゴリ交差エントロピー), 横軸がエポック数. 青実線が訓練データに対する損失で, 青破線が検証データに対する損失. 検証データに対する損失が最小となる位置に橙の垂直線を描画している.

表 8 N/P/S 識別モデルの混同行列

		予測値		
		N	P	S
真値	N	38,125	259	446
	P	248	38,429	161
	S	313	109	38,410

表 9 N/P/S 識別モデルの指標

	N	P	S
正解率 (Accuracy)	0.987		
適合率 (Precision)	0.985	0.991	0.984
再現率 (Recall)	0.982	0.989	0.989

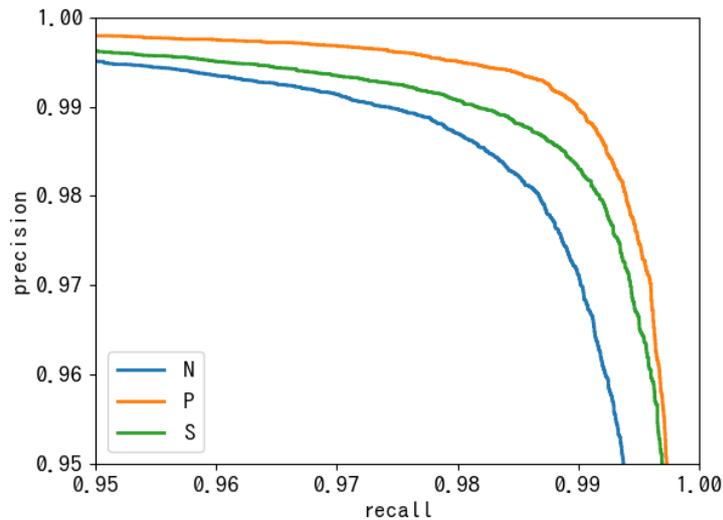


図 11 Precision-Recall トレードオフ曲線. 青 : N, 橙 : P, 緑 : S. 縦軸は適合率, 横軸は再現率. それぞれ, 分類する閾値を変化させていったときの適合率, 再現率を算出しプロット. 軸範囲を 0.95 から 1.0 に限定している.

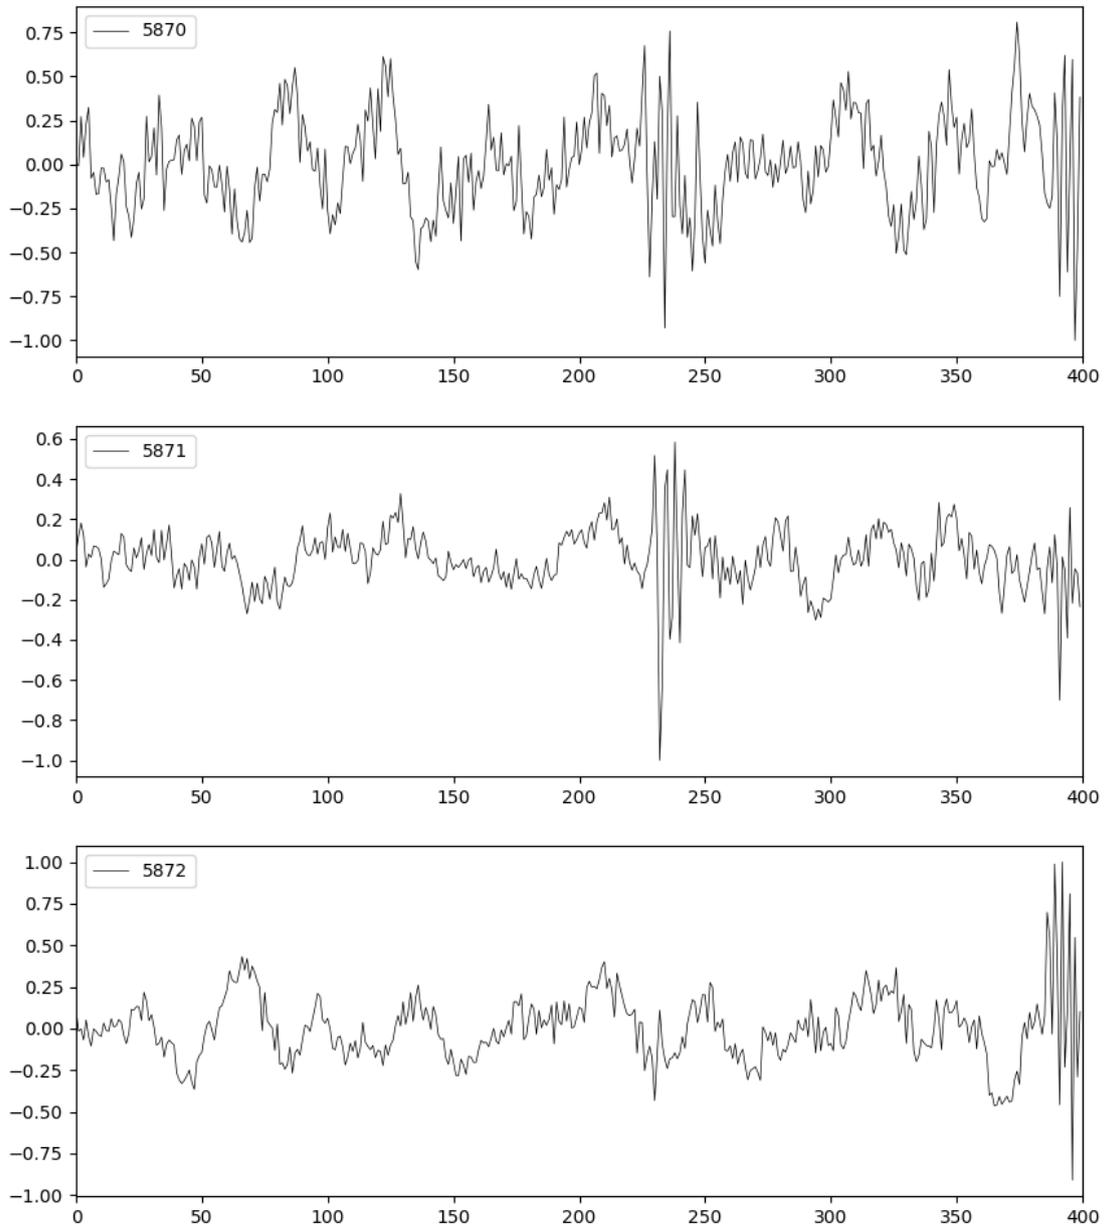


図 12 N/P/S 識別モデルによる波形の識別例 1 (H 高萩). N/S, E/W, U/D 成分を表示. 波形は 2Hz 以上のハイパスフィルタをかけたのち最大絶対値で規格化したもの. 縦軸は-1~1 の値をとる規格化された振幅. 横軸はサンプル数 (1/100 秒). 人手による精査済みの検測値を青線で示している (検測値がなければ青線なし). モデルから出力された予測確率 N/P/S=**0.9505**/0.0494/0.0001, 最も高い確率となったクラスをモデルの予測値としたとき, 真値: N, 予測値: N.

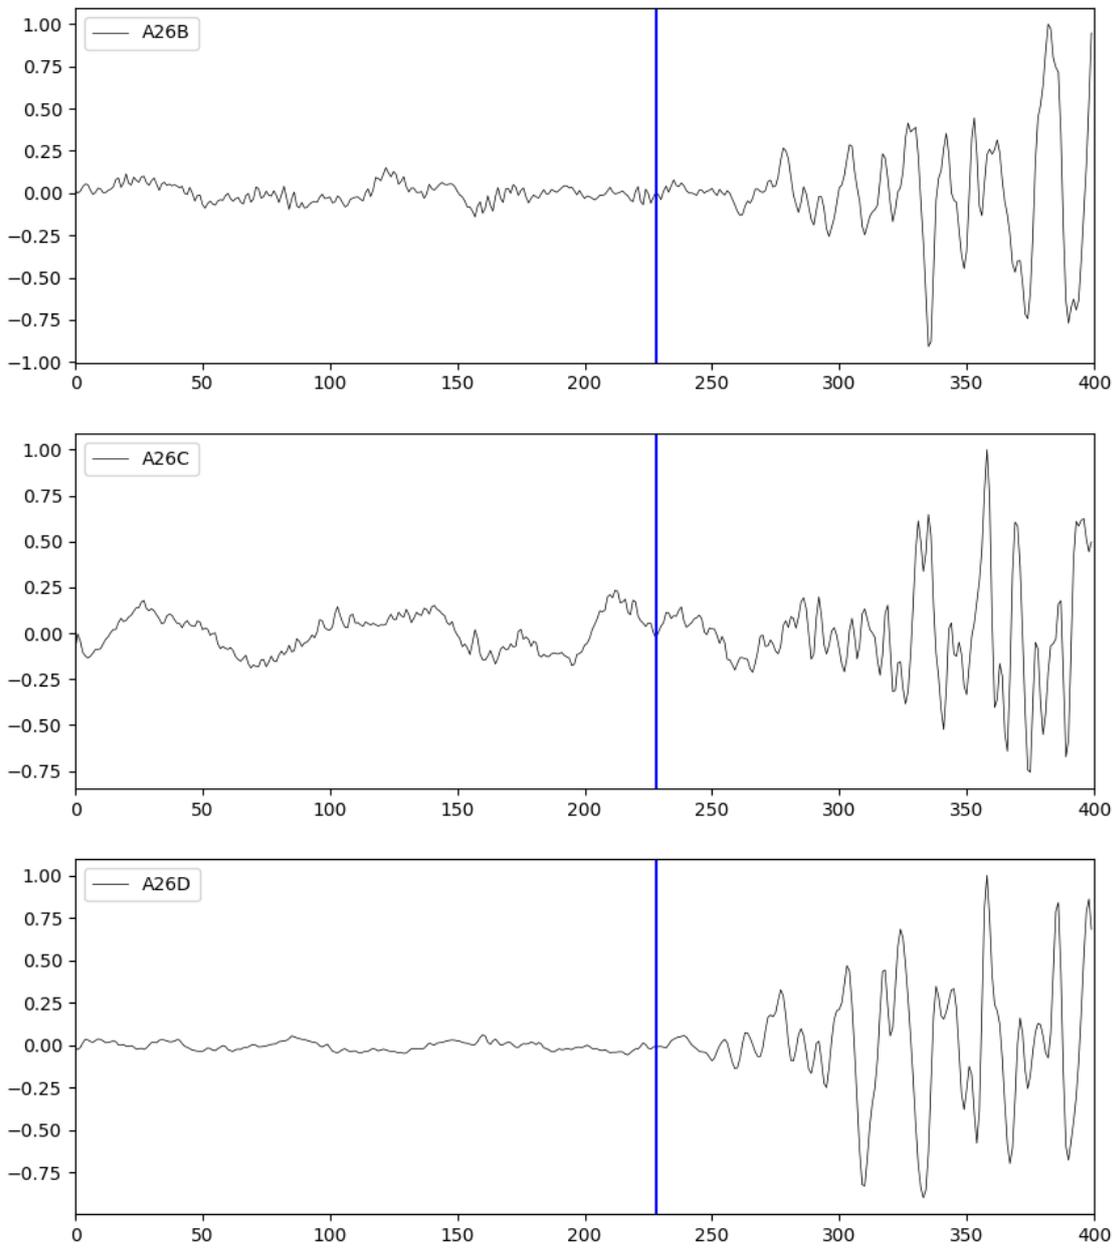


図 13 N/P/S 識別モデルによる波形の識別例 2 (与那久部良). N/S, E/W, U/D 成分を表示. 波形は 2Hz 以上のハイパスフィルタをかけたのち最大絶対値で規格化したもの. 縦軸は-1~1 の値をとる規格化された振幅. 横軸はサンプル数 (1/100 秒). 人手による精査済みの検測値を青線で示している (検測値がなければ青線なし). モデルから出力された予測確率 N/P/S=0.0/1.0/0.0, 最も高い確率となったクラスをモデルの予測値としたとき, 真値 : P, 予測値 : P.

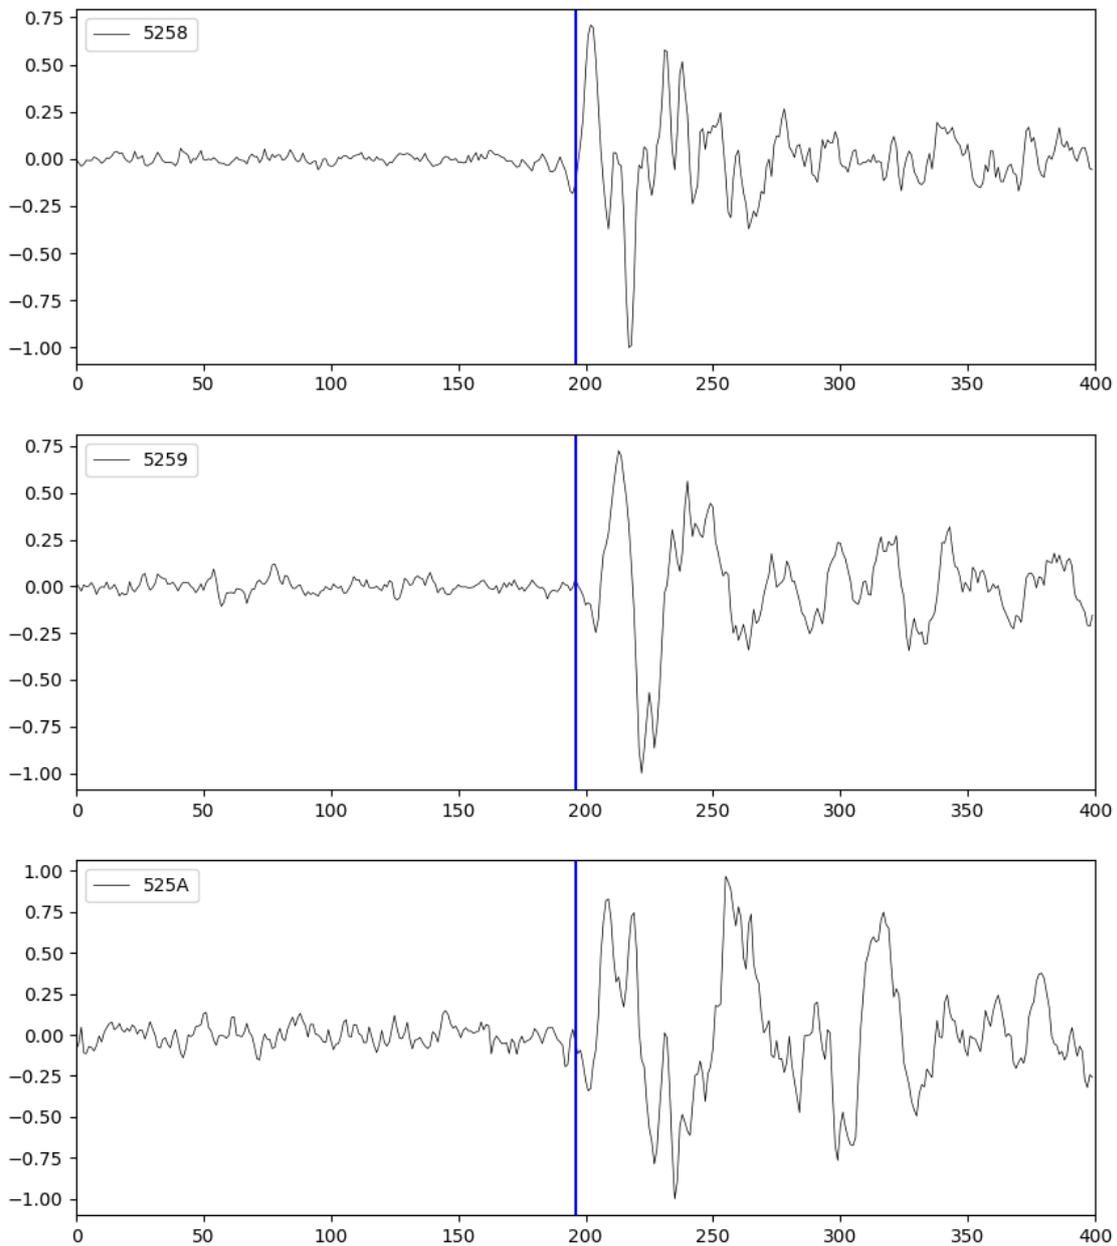


図 14 N/P/S 識別モデルによる波形の識別例 3 (H 唐桑). N/S, E/W, U/D 成分を表示. 波形は 2Hz 以上のハイパスフィルタをかけたのち最大絶対値で規格化したもの. 縦軸は-1~1 の値をとる規格化された振幅. 横軸はサンプル数 (1/100 秒). 人手による精査済みの検測値を青線で示している (検測値がなければ青線なし). モデルから出力された予測確率 $N/P/S=0.0001/0.0/0.9999$, 最も高い確率となったクラスをモデルの予測値としたとき, 真値: S, 予測値: S.

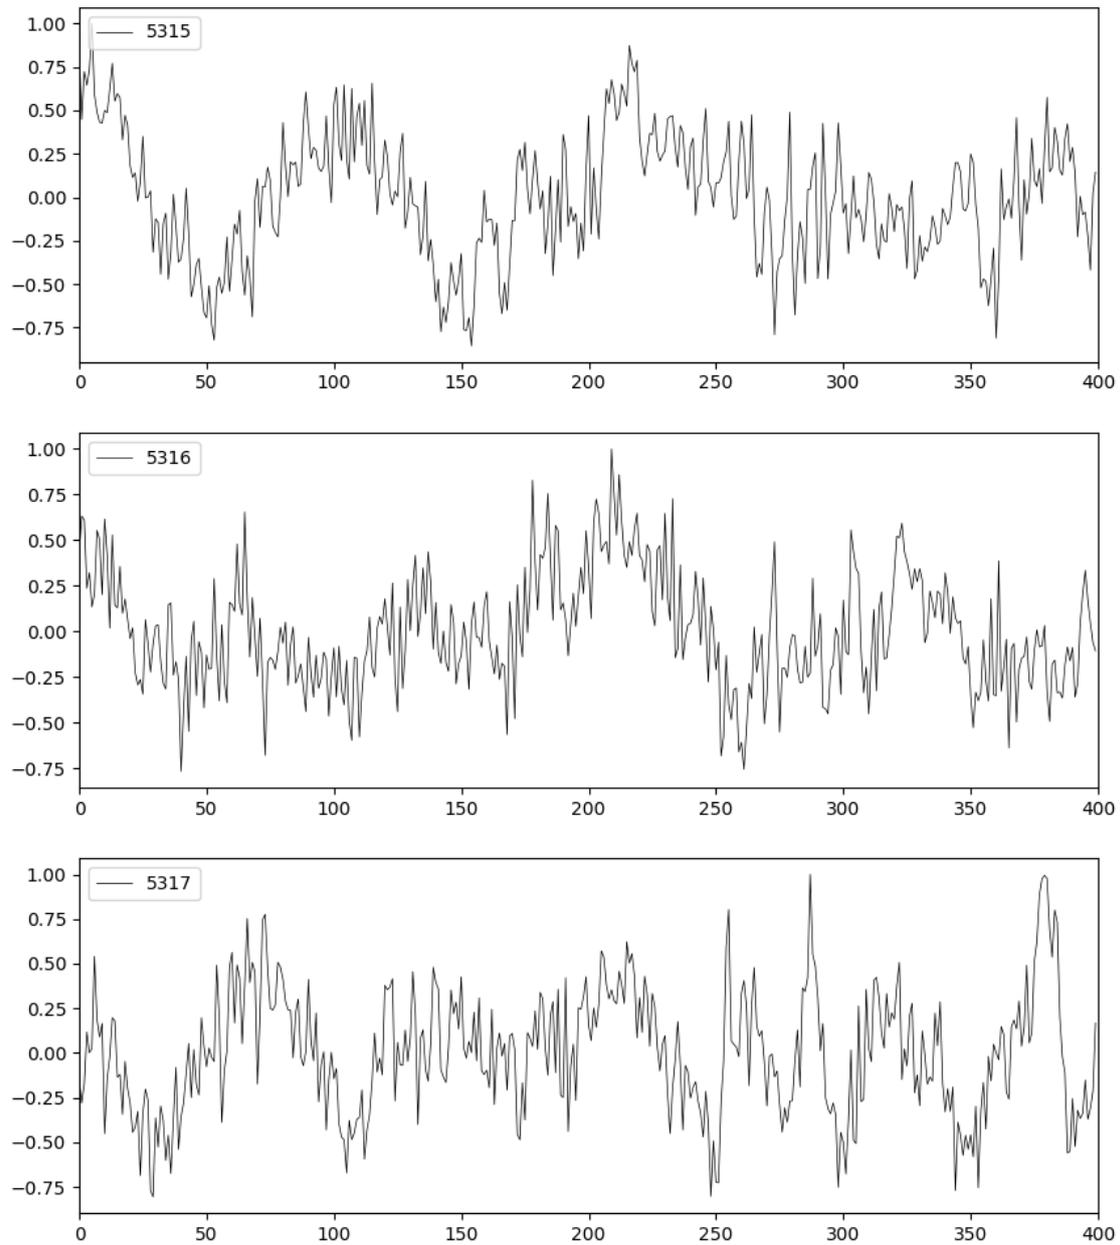


図 15 N/P/S 識別モデルによる波形の識別例 4 (H 長沼). N/S, E/W, U/D 成分を表示. 波形は 2Hz 以上のハイパスフィルタをかけたのち最大絶対値で規格化したもの. 縦軸は-1~1 の値をとる規格化された振幅. 横軸はサンプル数 (1/100 秒). 人手による精査済みの検測値を青線で示している (検測値がなければ青線なし). モデルから出力された予測確率 $N/P/S=0.0871/0.9129/0.0$, 最も高い確率となったクラスをモデルの予測値としたとき, 真値 : N, 予測値 : P.

2.2.8 連続波形への適用

N/P/S 識別モデルは 4 秒間の波形に対し N/P/S の確率を出力するため、4 秒間の窓を連続波形上で 1 秒ずつスライドさせてモデルに入力することで、各時刻での N/P/S の確率を求められる。これにより、P あるいは S の確率が閾値を上回る時刻に P 相または S 相があると判断することができる。2019 年 6 月 18 日の山形県沖の地震 (M6.7) 近傍の地震観測点 (TU.AT2: 東) 温 2) での、本震直前より 15 分間の連続波形に対し、N/P/S 識別モデルによる識別を適用した (図 16)。相を判定する閾値は 0.95 (95%) とした。余震が連発しているような事例であるが、おおむね適切に P 相、S 相を分類できている。連続波形に適用した定量的な評価は 3 章で述べる。

3 1次元 CNN モデルの PF 法への適用

現行の PF 法の一次検測処理に対し、学習済みの CNN モデルを CNN 検測、デノイザの 2 種類の方法で適用し、震源の変化を検証する。

3.1 CNN 検測として

N/P/S 識別モデルは 2.2.8 項で行ったように、連続地震波形に対し P 相、S 相の確率を逐次出力することができる。相の確率が高くなったところをトリガーとし、そのトリガー周囲の波形を P・S 検測モデルに入力すれば、PF 法の一次検測と同様の検測値を得ることができる。このように、N/P/S 識別モデルと P・S 検測モデルを組み合わせ、「CNN 検測器」として PF 法の一次検測を置き換え、震源がどう変化するかを検証する。

3.1.1 方法

以下の手順で N/P/S 識別モデルと P・S 検測モデルを組み合わせ、一次検測器として PF 法の一次検測を置き換え、震源計算を行う。イメージを図 17 に示す。

1. 4 秒間の窓を連続波形上で 1 秒ずつスライドさせて波形を切り出す
2. 4 秒間の波形を N/P/S 識別モデルに供給
3. N/P/S 識別モデルから出力された P の確率が閾値 (TH) 以上である場合は P トリガーとする。S も同様。
4. P トリガーの場合は P 相検測モデルに 4 秒間の波形を入力し、検測値を出力する。S トリガー

の場合は S 相検測モデルで同様のことを行う。

5. 出力された検測値から PF 法の震源計算を行う

3.1.2 検証

N/P/S 識別モデルのトリガーの閾値を TH=0.9, 0.8, 0.7, 0.6 と変化させ、それぞれ震源計算を行った。これらは (TH=0.9) のように表記する。対象期間は 2019 年 4 月 1 日の 0 時から 24 時間とした。低周波イベントを除いた一元化震源を真値とし、真値と、各手法で決定された震源の震源時が ±5 秒以内、かつ震源の緯度・経度がそれぞれ ±0.5 度以内の場合に震源が一致するとした。また、各手法で決定された震源のうち、真値にないものは過剰として扱う。

3.1.3 結果

表 10 に各手法による検測値数、震源数、一元化震源との比較状況についての表を示す。検測値数については TH=0.6 では PF 法よりも多く、TH を大きくするほど減少し PF 法を下回る。また、過剰については TH=0.9 では PF 法よりも少ないが、TH=0.8 以下では PF 法よりも多い。一致については、TH=0.6 から 0.9 のいずれについても、PF 法より少ない。傾向として、PF 法 (CNN 検測) は PF 法と比べて、過剰を増加させ、一致を減少させてしまう結果となった。

3.2 デノイザとして

PF 法によりトリガー・検測された一次検測値には、ノイズの誤検知による検測値も多数含まれる。ここでは、N/P/S 識別モデルをデノイザとして PF 法の一次検測の後に追加し、ノイズによる検測値を削減することによる震源の変化を検証する。

表 10 一元化震源、PF 法、PF 法 (CNN 検測) の検測値数、震源数。および一元化震源と比較したときの一致、過剰の数。TH=0.6 などは、CNN 検測のトリガー閾値を表す。

	検測値数	震源数	一致	過剰
一元化震源	-	465	-	-
PF法	1,243,804	556	412	144
TH=0.6	1,511,187	585	358	227
TH=0.7	1,207,246	536	352	184
TH=0.8	914,960	483	335	148
TH=0.9	592,208	428	297	131

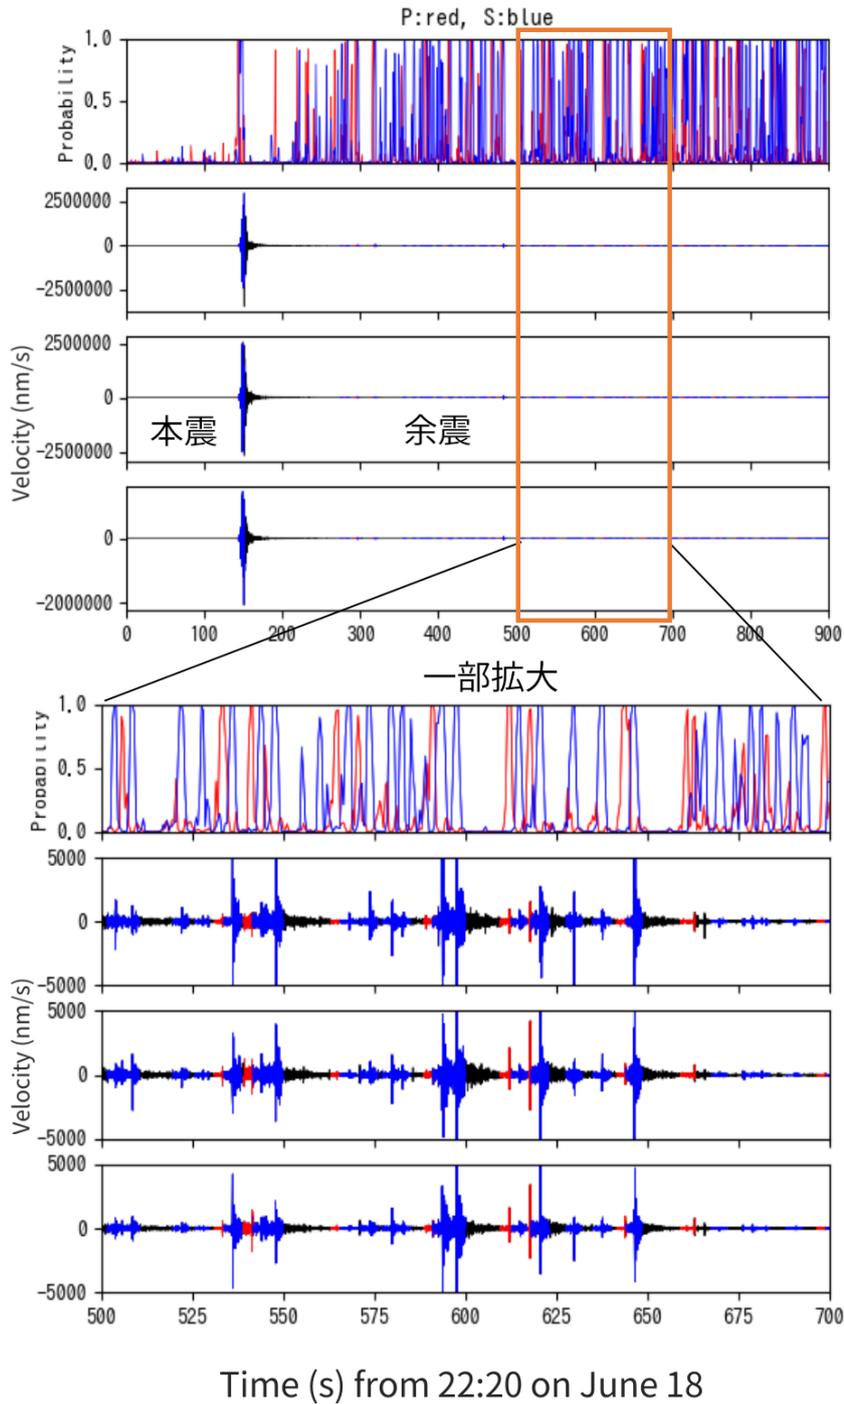


図 16 連続波形に対するモデルの適用例（東）温 2）. 縦軸において、Probability がモデルの各相に対する予測確率、Velocity が速度波形の振幅（nm/s）を示す。横軸はサンプル数（1/100 秒）。Probability において、赤が P 相の予測確率、青が S 相の予測確率を示す。Velocity において、モデルが 95%以上の確率を予測したクラスを相として選択し、その区間を P 相は赤、S 相は青で着色している。

3.2.1 方法

以下の手順でデノイザとして N/P/S 識別モデルを適用する。イメージを図 18 に示す。

1. 連続地震波形データに PF 法の一次検測を実行し、一次検測値を出力
2. 一次検測値を中心とした 4 秒間の波形を切り出し、N/P/S 識別モデルに供給
3. N/P/S 識別モデルから出力された N の確率が閾値（以降 TH）以上である場合は対応する検測値を一次検測値より除去
4. ノイズ除去済みの検測値から、PF 法の震源計算を行う

3.2.2 検証

PF 法と PF 法（デノイザ：TH=0.9, 0.95, 0.98）の 4 つについて震源計算を行った。対象期間は 2019 年 4 月 1 日の 0 時から 24 時間とした。低周波イベントを除いた一元化震源を真値とし、真値と、各手法で決定された震源の震源時が±5 秒以内、かつ震源の緯度・経度がそれぞれ±0.5 度以内の場合に震源が一致するとした。また、各手法で決定された震源のうち、真値にならないものは過剰として扱う。

3.2.3 結果

各手法による検測値数、震源数、一元化震源との比較状況を表 11 に示す。ノイズ除去により検測値数はいずれも PF 法より少なくなっている。TH=0.9, 0.95 については過剰をそれぞれ約 33%, 26%削減できているが、一致もそれぞれ約 7%, 4%減らしてしまっている。一方、TH=0.98 については、過剰を約 29%削減で

表 11 一元化震源、PF 法、PF 法（デノイザ）の検測値数、震源数。および一元化震源と比較したときの一致、過剰の数。TH=0.9 などは、デノイザのトリガー閾値を表す。

	検測値数	震源数	一致	過剰
一元化震源	-	465	-	-
PF法	1,243,804	556	412	144
TH=0.9	557,111	479	382	97
TH=0.95	666,146	503	397	106
TH=0.98	810,620	512	410	102

きており、一致は 2 個（約 0.5%）の減少にとどまっている。これは、デノイザによって、PF 法による正しい震源をほぼ減らすことなく、ノイズの誤検知による誤った震源を削減できたことを意味する。

図 19 に PF 法による震源、PF 法（ノイズ除去：TH=0.98）による震源、一元化震源をこの順にプロットしたものを示す。一元化震源である緑のプロットに隠れずに見えている赤、青のプロットが誤震源、あるいは位置が不正確な震源である。台湾周辺、秋田県周辺、北海道の周辺で赤色のプロットが目立つ。これは、ノイズ除去により PF 法の誤震源が削減されていることを意味する。これらの領域は日々の検測業務でもノイズが多いと知られており、その事実とよく合致する。一方で、内陸部には青色のプロットが散見される。これは、ノイズ除去によって削減できなかった誤震源である。N/P/S 識別モデルはノイズの学習データとしてほとんど定常ノイズしか用いていないため、発破や地動ノイズによる波形などをノイズと識別できていない可能性がある。これらを確認するため、PF 法の過剰を削減できた場合、削減できなかった場合について波形を確認した。

削減できた誤震源の波形の例

モデルによるデノイズの結果、PF 法の誤震源が削減できた例があった。図 20 に除去されたノイズの波形を示す。波形は UD 成分で、フィルターはかけていない。赤線は PF 法による P 相検測値、青線は S 相検測値である。地震波形に見えないこのような波形も PF 法の一次検測では検測してしまうことがあるが、デノイザによって除去できた。

削減できなかった誤震源の波形の例

図 21 に除去されなかった発破の波形（上 2 つ）とノイズの波形（下 2 つ）を示す。発破については全くノイズ除去されず、PF 法で決定された震源がそのまま過剰として残っていた。また、図 21 の下 2 つのようなノイズについても、ほとんどノイズ除去されず、PF 法の誤震源が過剰として残っていた。さらに、実際には地震と思われるが一元化震源には登録されていない事例もあった。これは本来は過剰な震源ではないと思われ、このような場合にはノイズ除去によって削減されなかった。

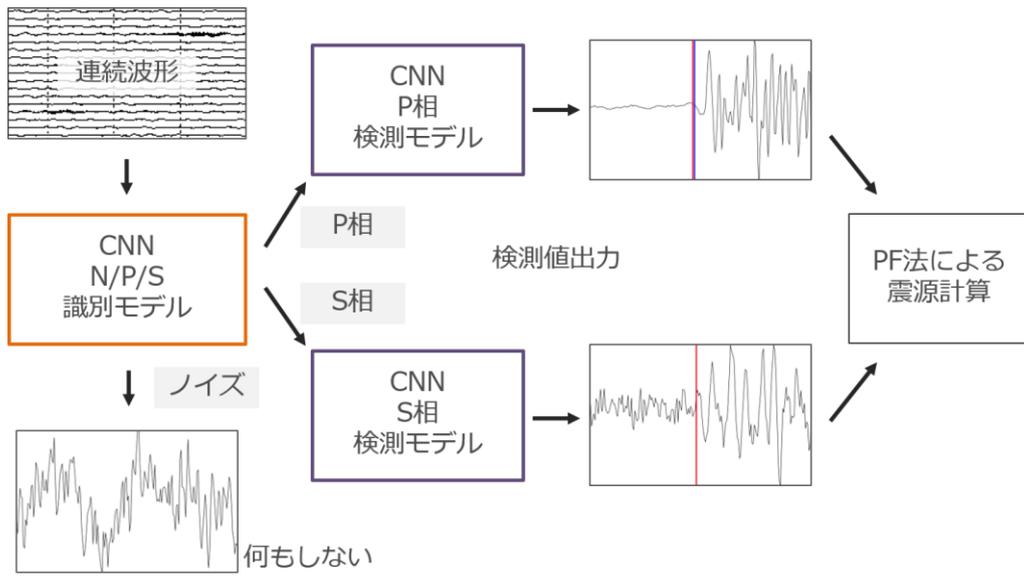


図 17 N/P/S 識別モデル，P・S 検測モデルを組み合わせて用いた震源計算のイメージ。



図 18 PF 法への，デノイザとしての N/P/S 識別モデルの適用イメージ。

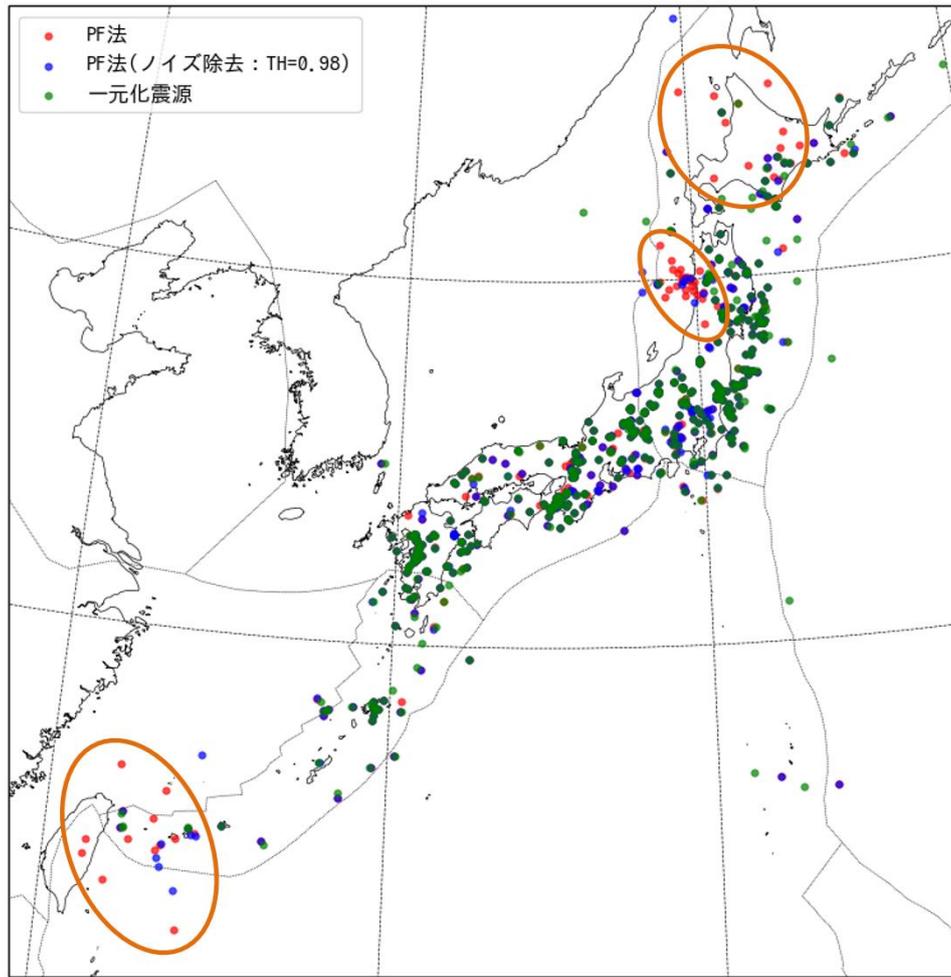


図 19 PF 法 (赤), PF 法 (ノイズ除去: TH=0.98) (青), 一元化震源 (緑) の震源プロット. ノイズの誤検知による誤震源を削減できている箇所を橙線で囲んでいる.

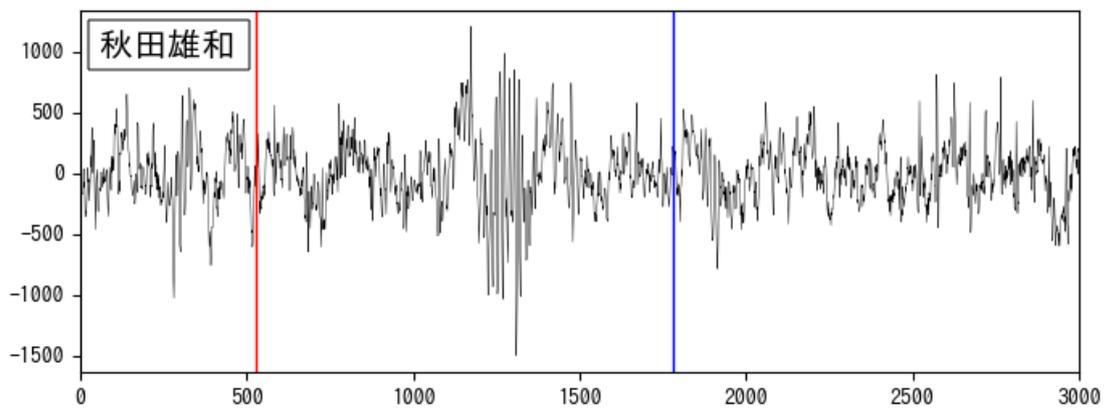


図 20 N/P/S 識別モデルによりノイズとして除去された波形. UD 成分. 縦軸は振幅のカウント値. 横軸はサンプル数 (1/100 秒). 赤線, 青線はそれぞれ, PF 法による P 相, S 相に対応する.

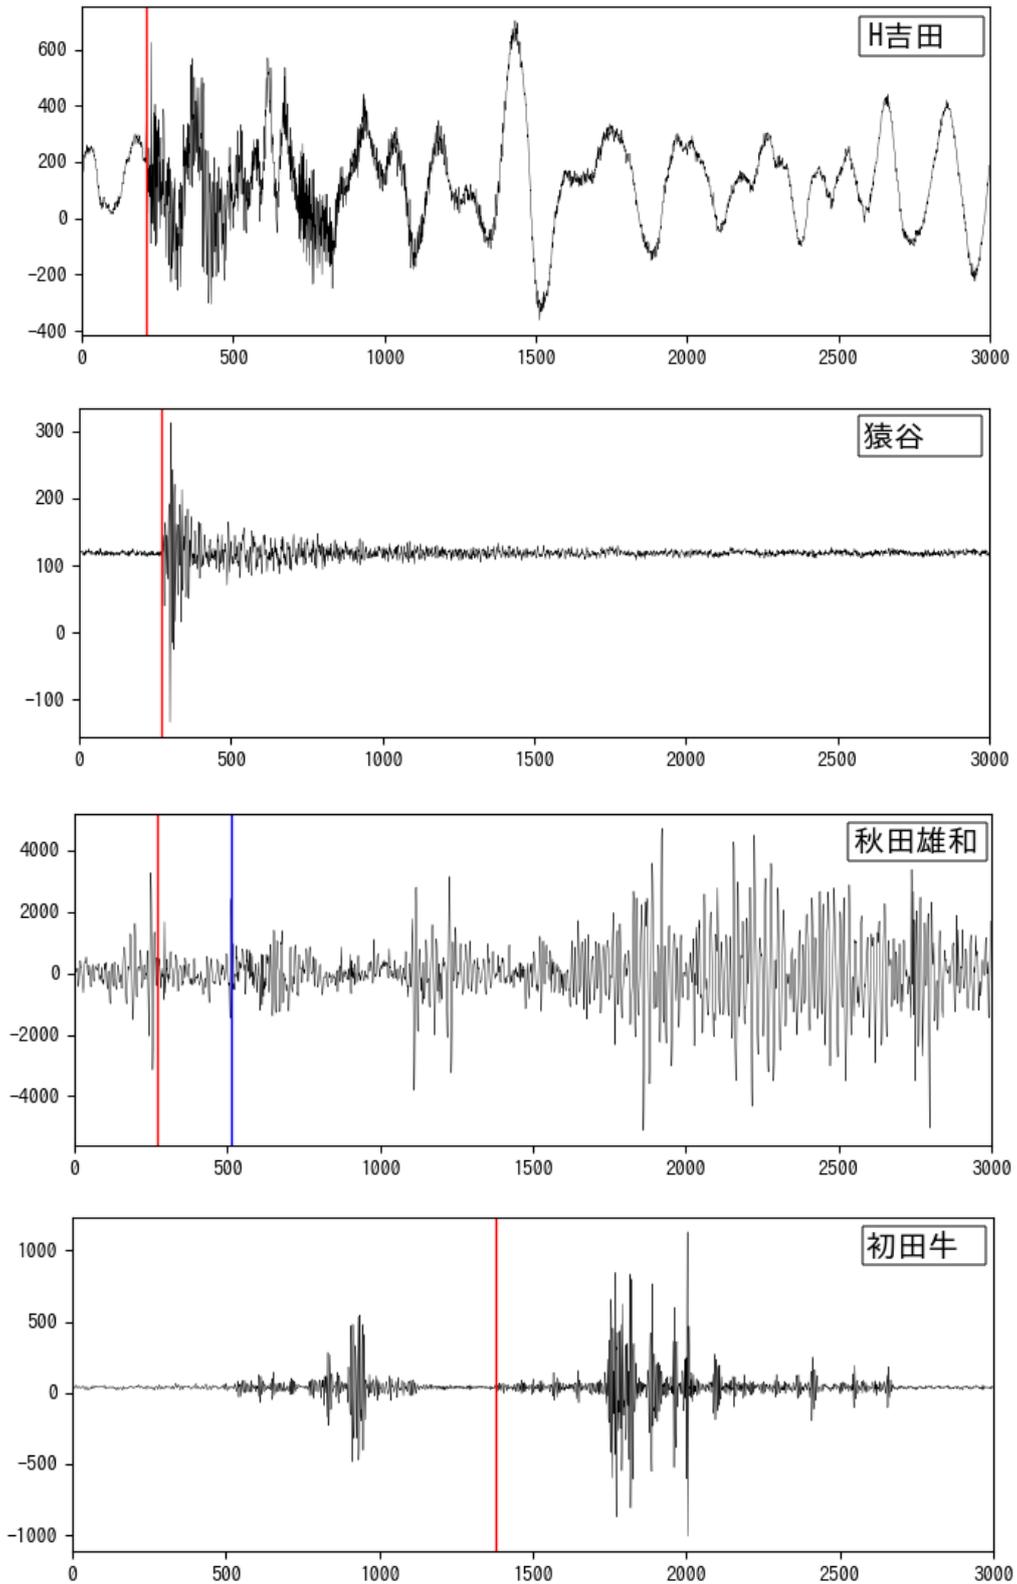


図 21 N/P/S 識別モデルによりノイズとして除去されなかった波形. UD 成分. 縦軸は振幅のカウント値. 横軸はサンプル数 (1/100 秒). 赤線, 青線はそれぞれ, PF 法による P 相, S 相に対応する. (上 2 つ) 発破波形. (下 2 つ) ノイズ.

なお、PF法に比べ減ってしまった一致について波形を目視確認したが、はっきりとした地震波形の検測値を除去していたり、ノイズレベルの高い地震波形の検測値を除去していたりと、共通点が見えなかった。

3.3 考察

本研究で学習したモデルは、手動で検測されたP相・S相付近の波形のみを学習データに用いている。実際の連続波形データには学習データとは性質の異なるデータが多く含まれる。CNN検測として利用した場合には、モデルにとって未学習であるような波形データを入力した際にP相またはS相だと誤検知してしまい、結果として存在しない震源を定めてしまうことにより過剰な震源が増え、また余計な検測により震源がずれることにより一致した震源が減ってしまったと考えられる。一方で、デノイザとして用いた場合には、PF法により検測された相が正しいかどうかを識別することとどまるため、新たな検測値を追加することはなく、ノイズによる検測値を削減することで過剰な震源を減らすよう働く。一致をPF法に比べほとんど減らさずに済んだのは、PF法によって検測された正しい検測値まわりの波形は、学習データと性質が近く、モデルが正確に識別できるからであると考えられる。

4 結論

本研究では、CNNを用いて地震波形のP・S検測モデルとN/P/S識別モデルを作成し、一元化震源の検測値と地震波形データを用いてモデルを学習させた。その結果、テストデータに対しては高精度に検測・識別できることを確認した。次に、N/P/S識別モデルとP・S検測モデルを組み合わせ、CNN検測としてPF法の一次検測を置き換えた場合は一元化震源との一致を大幅に減らしてしまい、過剰な震源はそれほど削減できないかむしろ増加してしまった。一方、デノイザとしてPF法の一次検測値からノイズによる検測値を削減する場合は、一致をほとんど減らさず、過剰な震源をある程度削減することができた。PF法の性能向上にはデノイザとしての使い方が有望である。しかし、今回の結果では、依然として過剰な震源が多く残っている。これらをさらに削減するためには、より多様なデータをモデルに学習させる必要がある。今回のモデルは、ノイズについてはP相直前の定常ノイズしか学習していないため、発破波形、インパルス的なノイズ等

を追加すべきである。また、地震の見逃しを増やさないためにもノイズレベルの高い地震波形を追加すべきである。これらのデータの多様化に伴い、層を深くするなどモデルの表現力を上げる必要も考えられる。

5 今後の展望

今後は、以下の課題に取り組みたい。

- ・ 定常ノイズ以外の多様なノイズデータの収集
- ・ ノイズレベルの高い地震波形の収集
- ・ より表現力の高いモデルを構築し、収集したデータを学習させて精度を高める
- ・ 現行システムに導入できるよう実行環境を含めたモデルのパッケージング

さらに、同様の技術を用いて、低周波地震の検出や多様な震動波形の分類などにも適用できる可能性がある。ただし、各々にふさわしいデータを収集する必要がある。

謝辞

本研究は気象研究所地方共同研究の枠組みで実施されたものである。

国立研究開発法人防災科学技術研究所、北海道大学、弘前大学、東北大学、東京大学、名古屋大学、京都大学、高知大学、九州大学、鹿児島大学、国立研究開発法人産業技術総合研究所、国土地理院、国立研究開発法人海洋研究開発機構、公益財団法人地震予知総合研究振興会、青森県、東京都、静岡県、神奈川県温泉地学研究所、2016年熊本地震合同観測グループのオンライン臨時観測点（河原、熊野座）、米国大学間地震学研究連合（IRIS）の観測点（台北、玉峰、寧安橋、玉里、台東）および気象庁のデータを用いた気象庁地震カタログを使用した。気象研究所の小寺様には査読をいただき、きめ細やかなご指摘をいただいた。また、大阪管区気象台地震火山課の皆様には研究の後押しや検測についての多く知見をいただいた。ここに記して深くお礼申し上げる。

文献

清本真司・溜淵功史・足達晋平・上野寛・森脇健・塩津安政・横田崇 (2013): 地域地震センターデータ処理システム (REDC) における自動震源処理とその結果について、

験震時報, **77**, 15-29.

溜渕功史・森脇健・上野寛・東田進也 (2016): ベイズ推定を用いた一元化震源のための自動震源推定手法, 験震時報, **79**, 1-13.

横田崇・周勝奎・溝上恵・中村功 (1981): 地震波データの自動検出方式とオンライン処理システムにおける稼働実験, 東京大学地震研究所彙報, **56**, 449-484.

Allen, R. V. (1978): Automatic earthquake recognition and timing from single traces, *Bull. Seism. Soc. Am.*, **68**, 1521-1532.

Ross, Z. E., M.-A. Meier, and E. Hauksson (2018a): P Wave Arrival Picking and First-Motion Polarity Determination With Deep Learning, *J. Geophys. Res.*, **123**, 5120-5129.

Ross, Z. E., M.-A. Meier, E. Hauksson, and T. H. Heaton (2018b): Generalized Seismic Phase Detection with Deep Learning, *Bull. Seism. Soc. Am.*, **108**, 2894-2901.

Tamaribuchi, K. (2018): Evaluation of automatic hypocenter determination in the JMA unified catalog, *Earth Planets Space*, **70**, 141.

(編集担当 青木重樹)