

深層学習によるP波検出・到達時刻決定・初動極性決定

Automatic P-wave Detection, Phase Picking, and Polarity Determination based on Deep Learning

原将太⁽¹⁾・深畑幸俊・飯尾能久

Shota HARA, Yukitoshi FUKAHATA and Yoshihisa IIO

(1) 京都大学大学院理学研究科

(1) Graduate School of Science, Kyoto University, Japan

Synopsis

P-wave arrival time and first-motion polarity are fundamental observations in seismology, which are used to determine hypocenter locations and focal mechanisms of earthquakes. In this study, we develop three convolutional neural network (CNN) models that perform P-wave event detection (E-Taro), phase picking (P-Jiro), and first-motion polarity determination (F-Saburo). In training and testing the CNN models, we use about 130 thousand 250 Hz and about 40 thousand 100 Hz waveform data observed in western Japan. For the 250 Hz (100 Hz) waveform data, E-Taro has the accuracy of 98.1% (97.3%); the difference between the arrival times determined by human experts and P-Jiro is -0.005 s (-0.012 s) in average with a standard deviation of 0.038 s (0.077 s); F-Saburo has the accuracy of 97.9% (95.4%). Finally, by applying the three CNN models to continuous waveform data, we showed the arrival time and first-motion polarity can be obtained without helps of human experts. The results of the CNN models are in good agreement with human experts.

キーワード: 機械学習, 畳み込みニューラルネットワーク, P波自動検出, 初動極性, Grad-CAM

Keywords: machine learning, convolutional neural network, automatic P-wave detection, first-motion polarity, Grad-CAM

1. はじめに

1.1 背景

地震計は一般に, 地面の振動を一定のサンプリング間隔で連続的に記録する. 地震が発生した場合には, P波・S波などの特徴的な相(Phase)を伴ってその振動が記録される. 各観測点で得られたP波の到達時刻データを解析することで, 震源の位置や発震時刻を推定することができる. さらに, 各観測点で, P波到達直後の上下動速度が上向き(押し; Up)か下向き(引き; Down)かを調べることで, 地震のメカニ

ズム解が推定できる(例えば, Stein and Wysession, 2003). 地震のメカニズム解は, 震源にかかっていた力(応力)と直接的に関係するもので, その地震の共役な断層面の向きとずれの方向を示す. P波到達直後の上下動速度の向き(押しまたは引き)のことをP波の初動極性, あるいは単に初動極性と呼ぶ. 従来は, 人間の専門家がP波の到達時刻及び初動極性を目で読み取り手動で決定することで解析に使用するデータを作成してきた. しかし, 近年では観測データ量が膨大となってきたことから, 増加する観測データを自動処理するアルゴリズムの開発の重要性が高まってきて

いる。

地震計で観測された波形を自動処理するためには、まず観測された波形にP波やS波など地震の波が含まれているか否かを判断するイベント検出(Event detection)という技法が必要となる。イベント検出については、波形中の短時間の振幅の平均(STA, Short time average)と長時間の振幅の平均(LTA, Long time average)の比STA/LTAから地震波を検出する手法(Allen, 1978, Baer and Kradolfer, 1987など)や、事前にいくつかのテンプレート波形を用意しておき、他の波形との類似度を表す相互相関を計算することでイベントを検出するテンプレートマッチング(Template matching)といった手法が挙げられる(Shelly et al., 2007; Schaff and Waldhauser, 2010; Matsuzawa et al., 2015など)。

次に、観測波形が例えばP波を含んでいる場合、その到達時刻をできる限り正確に決定する必要がある。この到達時刻決定(Phase picking)については、前述のSTA/LTAや、ノイズとシグナルをそれぞれAR(Auto regression, 自己回帰過程)でモデル化するAR-AIC(Akaike, 1974; Sleeman and Van Eck, 1999など)、波形の歪度(Skewness)や尖度(Kurtosis)を利用する手法(Küperkoch et al., 2010など)が例に挙げられる。

さらに、P波の初動極性決定(First-motion polarity determination)については、推定されたP波到達時刻の後の極大値または極小値を初動極性として決定するPhasePapy(Chen and Holland, 2016)、ベイズ的方法に基づいて定義される振幅確率関数と時刻確率関数の積から決定する手法(Pugh et al., 2016)が例として挙げられる。

日本では、マルチチャンネルの地震波形データを扱うためのデータ収集と保存に役立つソフトウェアパッケージ"WINシステム"(ト部・東田, 1991; ト部, 1994; Uehira, 2001)が広く使用されている。WINシステムにはSTA/LTAに基づく自動検出アルゴリズムが搭載されており、P波の到達時刻を自動的に決定することができる。また、堀内ら(2009)もP波の到達時刻及び初動極性を自動決定するためにSTA/LTAを改良したアルゴリズムを開発しており、彼らの作成した商用ソフトウェアはいくつもの研究で用いられている(例えば、Matsumoto et al., 2018; Katoh et al., 2018; Okada et al., 2019)。

一方、これらの自動検出アルゴリズムの精度は専門家による手動の判断には及ばず、そのため専門家によるチェックを経てから使用されるのが一般的である。さらに、WINシステムより精度が高いとされる堀内ら(2009)のシステムを用いた場合には、ある地域のデータに最適化されたアルゴリズムを別の地域のデータに適用する際に再び専門家による精巧な

パラメータの調整技術が必要とされる。従って、増大する観測データを処理するために、人間と同程度の性能を有し、かつ別の地域のデータに適用してもその性能を保つことができる自動検出アルゴリズムが強く求められている。

近年、深層学習(ニューラルネットワーク)を用いた自動処理アルゴリズムの開発が様々な分野で進められている。深層学習は大量のデータの分析を通じて、自動処理において重要な特徴量をコンピュータ内部で独自に発見することができ、自然言語処理(例えば、Sutskever et al., 2014)や画像認識(例えば、Krizhevsky et al., 2012)のような数学的に定式化することが難しい分野への応用でも成功を収めている。

深層学習の流行はコンピュータの処理速度の向上に伴って2012年ごろから始まった。深層学習の地震学への応用も2018年頃から急速に進んでおり、P波の自動検出や初動極性決定(例えば、Zhu and Beroza, 2018; Ross et al., 2018a, bなど)以外にも、地震の検出と震源位置決定(Perol et al., 2018)、余震分布の予測(DeVries et al., 2018)、地震と微動とノイズの識別(Nakano et al., 2019)、余効変動の予測(Yamaga and Mitsui, 2019)など様々な研究が進められている。

本論文では、まず2章で深層学習について簡単に説明し、3章では本研究で使用した地震波形データについて述べる。続く4～6の各章では、P波検出モデル(E-Taro)、P波到達時刻決定モデル(P-Jiro)、P波初動極性決定モデル(F-Saburo)について順次説明する。7章では、E-TaroとP-Jiroの性能比較や、事前に与えられた到達時刻に対するF-Saburoの感度を検証した後、開発した3つのCNNモデルを合わせて用いることにより、P波の到達時刻と初動極性を自動検出した結果を示す。なお、6章で述べるF-Saburoによる初動極性の自動決定については既にHara et al. (2019)として出版されている。また、本報告自体も、修士論文として執筆された原(2020)をコンパクトにまとめたものである。

2. 深層学習について

本章では、深層学習(Deep learning)について簡単に説明する。さらに、決定プロセスの可視化に役立つGrad-CAMと呼ばれる手法について紹介する。

2.1 ニューラルネットワーク

深層学習とは、大量のデータに対して多層のニューラルネットワークのモデルをフィッティングさせる機械学習の手法の一つであり、自動処理において重要な特徴量をコンピュータ内部で独自に発見することができる。ニューラルネットワークとは、人間

の脳の神経細胞(ニューロン)とその神経回路網を数学的なモデルで表現したものである。初期にはニューラルネットワークはパーセプトロン(Rosenblatt 1958)と呼ばれていた。近年のコンピュータの処理能力の向上により、ニューラルネットワークの層の数を多くする深層化が可能となったことで、既存の手法を上回る性能を得られるようになった。例えば、自然言語処理(例えば、Sutskever et al. 2014)や画像認識(例えば、Krizhevsky et al. 2012)のような数学的に定式化することが難しい分野への応用でも成功を収めている。

ニューラルネットワークは、入力層と隠れ層、出力層から構成され、入力層に入ってきた情報(例えば画像や地震波形データ)に、線形変換及び非線形の活性化関数を掛ける操作を繰り返すことにより出力を得る。本研究で使用した畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)は、Fukushima (1980)やLeCun et al. (1998)によって導入されたモデルで、生物が局所的なパターンを単純型細胞で検知し、その情報を総合することで視覚情報を安定的に処理しているとする階層仮説をもとに提案された。

通常のニューラルネットワークでは、ある層の一つのニューロンは前の層の全てのニューロンと結合していたが、CNNでは、ある層のニューロンが前の層の一部のニューロンとのみ結合している畳み込み層と呼ばれる構造を用いる。それにより、入力データの局所的な情報の抽出が効果的に行え、より高精度な画像認識が可能となる(Krizhevsky et al. 2012)。通常、CNNモデルは隠れ層で畳み込み層を使用し、その後全結合層が配置される形でモデルが構築される。つまり、入力層、畳み込み層、全結合層、出力層の順に配置されてデータ処理がなされていく。本研究で実際に用いたCNNモデルについては第4、5、6章でそれぞれ説明する。

Zhu and Beroza (2018)や、Ross et al. (2018a, b)をはじめとする先行研究でもCNNが用いられている。CNNモデルで具体的にどのような数学的処理が行われているのかについては、Hara et al. (2019)および原(2020)を参照して頂きたい。

2.2 Grad-CAM

深層学習には最適化されたパラメータの解釈が難しく、内部で行われる数学的処理の意味が理解できないという問題がある(ブラックボックス性)。実際に深層学習を用いたソフトウェアを使用する際、この問題はユーザーに不安感を与えることに加え、研究面でもある操作を可能とするアルゴリズムが存在することまでは示せても、そのようなアルゴリズム

を作成するための知識を共有出来ないことが問題となる。この問題の解決を目指した手法の一つがGrad-CAM (Selvaraju et al. 2017)である。

Grad-CAMは、CNNがデータの局所的な情報を抽出することに着目し、畳み込み最終層の値を微小変化させた際の出力層の値の変化を用いて、CNNモデルが重要視している部分を可視化する手法である。具体的な数学的手続きについては、Selvaraju et al. (2017)および原 (2020)を参照して頂きたい。

3. データ

本研究では、西日本で観測された250 Hz及び100 Hzのサンプリング周波数の地震波形データの上下動成分(垂直変位)を用いた。250 Hzの波形は満点システムと呼ばれる臨時の稠密地震観測網(三浦ら, 2010; 飯尾, 2011; 飯尾ら, 2017)で、100 Hzの波形は防災科学技術研究所や産業技術総合研究所、気象庁、京都大学の定常観測網で観測されたデータである。

観測地域は山陰地方と近畿地方北部の2つからなる(Fig. 1)。観測期間は、山陰地方では2014年10月から2016年3月、近畿地方北部では2016年4月から9月である。

観測された波形のうち、P波の到達時刻と初動極性が専門家によって決定されている波形をCNNモデルの訓練・テストに用いた。専門家による検測があった地震数は、山陰地方で6,770個(M: -1.3~6.2)、近畿地方北部で1,374個(M: 0.0~4.2)である(Figs. 1 and 2)。波形データ数は、山陰地方について、250 Hzが103,823個、100 Hzが30,231個、近畿地方について、250 Hzが23,377個、100 Hzが9,938個であり、合計すると、250 Hzが127,200個、100 Hzが40,169個である(Fig. 2)。専門家によって決定された到達時刻と初動極性はCNNモデルのパラメータの最適化を行う際に用いた。サイト特性や機器特性は考慮しなかった。

観測された波形は、個々に振幅が大きく異なる。そのため、前処理として全ての波形に対し、以下の式(1)で表されるz-score正規化を行った。

$$A_{\text{zscore}}(t) = \frac{A(t) - \mu}{\sigma} \quad (1)$$

ここで、 μ と σ はそれぞれ、観測された波形の振幅 $A(t)$ の平均値と標準偏差である。この正規化により、地震波形データごとに震源からの距離や地震のマグニチュードなどに応じて変化する振幅値が正規化され、CNNモデルの訓練が容易になる。元の地震波形データの最大振幅は数桁の範囲で異なり、正規化を行わずにCNNモデルへ地震波形データを入力すると、コスト関数がほとんど減少しなかった。




Fig. 1 Location map of the seismic stations used in this study. The left and right diagrams show the San-in region and the northern Kinki region, respectively. Cross marks are temporary stations (250 Hz) and open circles are permanent stations (100 Hz). In the San-in and northern Kinki regions, the numbers of the temporary stations are 131 and 42, respectively, and those of the permanent stations are 90 and 78, respectively. Small blue and pink dots are epicenters determined by the San-in and northern Kinki seismic networks, respectively, for the period from October 2014 to March 2016 in the San-in region and from April 2016 to September 2016 in the northern Kinki region. In determining the epicenters, both the permanent and temporary stations are used. This figure is the same as Fig. 1 of Hara et al. (2019), in which the same observed data were used.

4. P波検出モデル(E-Taro)

本章では、P波の到達を検知するCNNモデル(E-Taro)について説明する。観測波形を500点(250 Hzで2秒間、100 Hzで5秒間)ごとの波形窓に切り取り、専門家により検出されたP波の到達時刻が含まれている波形窓を"P-wave", P波到達前のノイズやP波到達後のコーダ波などが含まれている波形窓を"Noise"とラベル付けし、その波形窓とラベルの組をE-Taroに学習させた。学習済みのE-Taroの性能を、ラベルの一致

率から評価した。

より現実的な状況として、数分間の連続波形からP波の到達を検出するためには連続波形をスキャンする必要がある。E-Taroは500点の波形窓に対し、P波が到達したか否かを一つの確率値で出力するため、波形窓ごとに異なる階段状の出力値が得られる。そこで、波形窓を少しずつずらして連続波形を切り出す、つまり一つの連続波形を複数回スキャンすることで検出精度を高めることができる(4.4節)。最後に、未知のイベントを検出する可能性について議論する。




Fig. 2 Number of seismic events with hypocenter depths (left) and magnitudes (right). The light blue and pink bars indicate the numbers of events determined in the San-in and the northern Kinki regions, respectively. The hypocenters were determined by the temporary and permanent stations shown in Fig. 1. The number of data used in this study is 103,823 for 250 Hz and 30,231 for 100 Hz in the San-in region, and 23,377 for 250 Hz and 9,938 for 100 Hz in the northern Kinki region.

4.1 データの作成方法とCNNモデル

まず、E-Taroに与える入力データの作成方法について説明する．本研究で使った連続地震波形データは250 Hz, 100 Hzに対して共に3分間、それぞれ45,000点、18,000点である．この3分間の連続波形に対してz-score正規化をした上で、以下の順で入力データの準備を行った．

1. 専門家によって読み取られた到達時刻を中心に、元の連続地震波形データから前後1750点ずつ、計3500点の波形を切り出す．
2. 到達時刻が常に波形の中心にあると、E-Taroは波形の特徴ではなく、中央に到達時刻が存在するというデータの作成方法の特徴を学習してしまう．この問題を解決するため、切り出した波形に-500から+500までの一様乱数 n を加えることで最大500点の摂動を与え、波形窓のどこに到達時刻が来てもP波の検出ができるようにする．
3. 摂動を与えた波形から2500点の波形を切り出す．具体的には、3500点の波形 $d[i](i = 1, \dots, 3500)$ のうち $d[j](j = 500 - n, \dots, 3000 - n)$ を切り出す．摂動は最大500点であるため、取得できるのは2500点だけになる．
4. Fig. 3に示したように、切り出した2500点のデータを①から⑤まで500点ずつに分ける．そして、500点ずつに切り分けた各波形に、専門家によって検出されたP波の到達時刻を含む波形窓には"P-wave", それ以外の波形窓には"Noise"のラ

ベルを付ける．ここで与えた摂動から、乱数 n が $n < -250$ の時②に"P-wave", $-250 < n < 250$ の時③に"P-wave", $250 < n$ の時④に"P-wave"のラベルが付き、それ以外の波形には"Noise"のラベル付けがなされる．つまり、1波形ごとに4つの"Noise"ラベルの波形と1つの"P-wave"ラベルの波形が生成される．

5. ラベル付けした波形の順番をランダムに入れ替えて入力データとすることでE-Taroの学習を行う．

次に、本研究で用いたCNNモデル(E-Taro)の概形をFig. 4に示す．E-Taroを含め、本研究のCNNモデルは250 Hzと100 Hzの地震波形データに対してそれぞれ学習を行った．つまり、E-Taro, P-Jiro, F-Saburoのそれぞれに対し二つずつモデルを作成した．データの作成方法で述べた通り、E-Taroに入力する地震波形データは500点で、これは250 Hzの波形に対しては2秒間、100 Hzの波形に対しては5秒間の時間窓に相当する．出力層は入力した500点の波形にP波の到達時刻が入っているか("P-wave"), 入っていないか("Noise")の2値を確率的に分類する．例えば、入力した500点の波形に対し、「"P-wave"の確率が80%, "Noise"の確率が20%」のように値を出力する．なお、一つの時間窓に対して複数の"P-wave"があることは検出できない．連続波形をスキャンさせることで二つのピークが得られれば、それを別の"P-wave"と解釈することはできると考えられる．




Fig. 3 Preparation of input data to analyze. After giving perturbation less than 500 data points to continuous seismic waveform data, we cut 2500 data points, which are divided into 5 time windows: each has 500 data points. The window containing the P-wave arrival time, determined by human experts, is labeled "P-wave" and the others are labeled "Noise". For each waveform, four "Noise" label windows and one "P-wave" label window are generated.




Fig. 4 The CNN model of E-Taro to detect P-wave arrival. The input data has a size of 500×1 . The output has two probability values, “P-wave” and “Noise”. Input data are processed by three convolution layers, shown by rectangles, and two fully connected layers. Flattening converts two-dimensional data of the final convolution layer to one-dimensional data. “ReLU” and “Softmax” represent the activation functions used for respective layers.

4.2 専門家の検出との一致率

まず、山陰地方と近畿地方北部の地震波形データを区別せずに用いてE-Taroの性能を調べた。訓練には両地域のデータの8割を使用し、1割を検証データとして、残りの1割をテストデータとして用いた。本章では、CNNモデルの性能評価にAccuracyを用いる。Accuracyは以下の式(2)によって定義される。

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

ここで、 TP 及び TN はそれぞれTrue “P-wave”とTrue “Noise”の略で、E-Taroと専門家が共に“P-wave”または“Noise”と検出した波形数を意味し、 $FN(FP)$ はE-Taroが“Noise”(“P-wave”)と検出した一方、専門家は“P-wave”(“Noise”)と検出した波形数を意味する。 $TP + TN + FP + FN$ は全波形数である。前節で説明したように、「専門家が“P-wave”と検出した」とは、「専門家が検出した到達時刻が、切り出した500点の波形窓に含まれていた」ことを意味する。E-Taroの出力は確率値であり、“P-wave”の出力が50%を越えた波形 (“Noise”の出力が50%未満の波形)を TP 及び FP に分類した。

地域を区別せず適用した場合、E-Taroは250 Hzと100 Hzの波形に対しそれぞれ98.1%と97.3%のAccuracyを示した(Table.1)。誤検出した波形については、E-Taroは“Noise”と判断したが、波形のラベルは“P-wave”だった FN が FP と比べて多い傾向にあった。

FN はE-TaroがP波の到達を見逃した可能性のあるグループだが、P波の到達時刻が切り出した波形窓の端にある場合、ノイズとP波の違いを判断するのが難しいことが原因として考えられる。一方、 FP は、E-Taroが誤ってP波が到達したと判断した可能性に加え、これまで検出されていなかった新しいイベントを発見した可能性を含む。なお、P波到達後はS波が到達しているはずだが、 FP の割合はほぼ0%であるため、E-

Table 1 Performance of the CNN model (E-Taro) for all data. “P” and “N” represent “P-wave” and “Noise”, respectively. For example, P_{CNN} means the E-Taro determines the waveform window to label “P-wave”. Because of the method creating waveform windows, the sum of P_{human} and N_{human} should be 20% and 80%, respectively. The number of the test data is 12,720 for 250 Hz and 4,017 for 100 Hz.

	250 Hz		100 Hz	
	P_{CNN}	N_{CNN}	P_{CNN}	N_{CNN}
P_{human}	18.4%	1.6%	17.7%	2.3%
N_{human}	0.3%	79.7%	0.4%	79.6%
AC	98.1%		97.3%	

TaroがP波とS波を区別できている可能性が高い。この可能性については、連続波形への適用(4.4節)で確認した。また、訓練データを換えて何度かE-Taroを訓練し直した場合も、Accuracyは0.1%程度の変化に留まっていた。

4.3 連続波形への適用

E-Taroの目標は、連続波形からP波の到達の有無を検出することである。連続波形に対しても、適当な開始点から500点ずつE-Taroを適用していくことになる。例えば、3分間の250 Hzの連続波形からP波の検出を試みる場合、データ点数は45,000点なので、連続波形を1回だけスキャン("1 scan")させる場合は前から500点ずつ計90回E-Taroを適用すれば良い。しかし、E-Taroは500点の波形窓に対して1つの確率値を出力する仕組みになっているため、500点ごとに波形窓を区切って検出させるだけでは誤検出が起り易くなる。この問題を解決するために、波形窓を少しずつずらしオーバーラップさせて数回検出させることで、計算コストは増えるものの、検出精度を高めることができる。例えば、2回スキャン("2 scans")させる場合は、波形をずらす間隔を500点から250点ずつに減らすことで、各時刻についてE-Taroが2回ずつ適用され、計179回E-Taroを適用して2で割って規格化することで出力値を得る。波形をずらす間隔を1点ずつにした場合は、(両端の499点ずつを除く)各時刻についてE-Taroが500回適用される"500 scans"とな

る。帰納的に、" n scans"は $500/n$ 点ずつ波形をオーバーラップさせ、連続波形の点数が W の時、計 $W \times n / 500 - (n - 1)$ 回E-Taroを適用した結果を n で割って規格化することである。このようにして、個々の時間窓に対するP波の到達の確率値が得られる。ある連続波形に対するE-Taroの適用結果をFig. 5に示した。

Fig. 5の結果から、"1 scan"は出力が矩形状であり、"500 scans"に近づくに従って連続的な出力となっていることが分かる。しかし、"500 scans"を行うには"1 scan"の500倍近く計算時間がかかる。7章も含む本節以降では、250 Hzの波形は"4 scans"による、100 Hzの波形は"10 scans"による結果を用いた。その一例をFig. 6に示す。

Fig. 6の上段の波形は、ノイズが小さくP波の到達を正しく検知できているが、P波到達から約1～2分後に再び出力値が大きくなった例である。再び出力値が大きくなったところでは、通常のノイズと比べて周波数が高くなっているように見えることから、これまで検知されていない新しい地震イベントである可能性がある。250 Hzの上段の波形は出力値が0.5を下回っているが、連続波形に適用する際は波形全体をzscore正規化してからE-Taroに読ませているため、前半の地震波を取り去った波形にzscore正規化をしてE-Taroを適用することで出力値が上昇する可能性がある。250 Hzの中段の波形は、多少ノイズがある中で正しくP波を検知できているが、P波到達の約1分後に出力値が50%を上回っている部分がある。これ




Fig. 5 Comparison of the results of E-Taro, where the number of scans is changed. E-taro is applied to a normalized continuous waveform of 250 Hz with a duration of 3 minutes (light blue line). The black line shows the output value labeled "P-wave" by E-Taro. " n scans" means that E-Taro is applied n -times to the waveform by adding an offset of $500/n$ points in each time. Hereafter, we use "4 scans" for 250 Hz waveforms data and "10 scans" for 100 Hz waveforms data.




Fig. 6 Examples of the results of E-Taro. The light blue line shows the normalized continuous waveform, and the black line shows the output value by E-Taro. Each waveform has a length of 3 minutes: 45,000 data points for 250 Hz and 18,000 data points for 100 Hz.

も新しいイベントである可能性がある。

250 Hzの下段と100 Hzの中段と下段の波形は、ノイズが大きい波形に対する適用結果である。単に振幅が大きいだけのノイズであれば問題なくP波を検知できることが分かる。E-Taroのモデル内部でフィルタ処理をかけるような操作が行われており、地震波の周波数とノイズの周波数を区別している可能性がある。

Fig.5, Fig. 6の結果では、特にP波周辺で出力値が高くなっており、振幅の大きいS波周辺で出力値が大きくなることはなかった。正解データの作成には専門家によって決定されたP波の到達時刻を用いたため、E-TaroはP波とS波の違いを見分けられるようになったと考えられる。また、Fig.5の結果から、"500 scans"を行えばP波の到達時刻を検出できる可能性がある。この検証のため、次章で紹介するCNNモデル(P-Jiro)との性能比較を6章で行う。

5. 到達時刻決定モデル(P-Jiro)

本章では、E-Taroや他の手法によって検出されたP波の到達時刻をより正確に修正することの可能なCNNモデル(P-Jiro)について説明する。到達時刻の検出アルゴリズムについては、前述のSTA/LTAやAR-AIC法など様々な方法が提案されており、ある程度の成功を収めている。P波の検出では波形の"類似性"に注目した手法が多く存在したが、P波の到達時刻決定では、AR-AIC法のようにノイズとP波の波形の違いを異常値検出のような形で求める研究も存在す

る。

本研究では、前章で作成したE-Taroによって暫定的にP波の到達時刻を得られるため、P-Jiroの目標はE-Taroで得られた到達時刻をより正確な時刻に修正することである。

5.1 データの作成方法とCNNモデル

P-Jiroに与える地震波形データの作成方法は以下の通りである。波形は上下動成分のみを用いた。

- 到達時刻が常に波形の中心にあると、P-JiroはE-Taroと同様に波形の特徴ではなく中央に到達時刻が存在するというデータの作成方法の特徴を学習してしまう。そのため、本章でも地震波形データに対し、専門家によって決定されたP波到達時刻を中心に、一様分布から生成された乱数 $r \in [-0.5 \text{ s}, 0.5 \text{ s}]$ を用いて最大 $\pm 0.5 \text{ s}$ の範囲の摂動を与えた(Fig. 7)。これはRoss et al. (2018a)と同様の設定である。
- 到達時刻をずらした地震波形データ(500点)にz-score正規化を行い、入力データとした。
- 正解データ(出力時に比較するデータ)としては到達時刻を中心とする標準偏差0.01 s (250 Hz)及び0.02 s (100 Hz)のガウス分布(Fig. 7の緑線)を用いる。これは専門家によって決定された到達時刻に多少の誤差があることを考慮したもので、Zhu and Beroza (2018)で用いられた方法を参考している。




Fig. 7 Preparation of input waveform data for P-Jiro (black line). Perturbation within the range of ± 0.5 s is given to continuous waveform data, in which the P-wave arrival time is originally set at the center of the data length. After shifting the central data point, 500 data points are cut out and used as input data. The right answer in training P-Jiro is given in the form of a Gaussian distribution with standard deviations of 0.01 s (250 Hz) and 0.02 s (100 Hz) with a mean at the P-wave arrival time. The figure shows cases of 250 Hz.

P波の到達時刻決定CNNモデル（P-Jiro）の概形を Fig. 8に示す．P-Jiroも250 Hzと100 Hzの地震波形データに対してそれぞれ作成した．Fig. 8に示したように、出力層には500個のノードが存在し、それぞれのノードに対して確率値が出力される．P-Jiroにより出力された確率値が最も高い点を、P-Jiroによって決定され

たP波の到達時刻とする．

5.2 専門家の検出との比較

まず、山陰地方と近畿地方北部の地震波形データを区別せずに用いてP-Jiroの性能を調べた．訓練には両地域のデータの8割を使用し、1割を検証データとして、残りの1割をテストデータとして用いた．




Fig. 8 The CNN model of P-Jiro to determine the phase (P-wave) arrival time. The input data has a size of 500×1 . The output has 500 probability values to judge P-wave arrival at each data point. The time with the highest probability is used for the P-wave arrival time. Input data are processed by five convolution layers, shown by rectangles, and two fully connected layers. Flattening converts two-dimensional data of the final convolution layer to one-dimensional data. “ReLU” and “Softmax” represent the activation functions used for respective layers.




Fig. 9 Comparison of the phase picking time by P-Jiro with that by experts. Δt is defined by $t_{\text{human}} - t_{\text{P-Jiro}}$.

テストデータに対するP-Jiroの検出結果は、Fig. 9のようになった。250 Hz (100 Hz)の波形に対し、平均は-0.005 s (-0.012 s)、標準偏差は0.038 s (0.077 s)となった。先行研究として挙げたZhu and Beroza (2018)は100 Hzの波形に対して標準偏差0.052 s、Ross et al. (2018a)

は標準偏差0.021 sを達成している。本研究の特に100 Hzの結果の標準偏差が大きいのは、専門家の決定した一部の到達時刻が大幅にずれていることが大きく寄与しているためと考えられる(後述)ので、P-Jiroの精度は彼らのCNNモデルの精度と同等と言える。




Fig. 10 Examples of results of P-Jiro (a phase picking CNN model). The vertical black line is the arrival time read by an expert. The orange line is the probability value output by P-Jiro. The maximum output, indicated by the vertical red line, is the P-wave arrival time determined by P-Jiro. "M" and "d" on the top of each diagram represent the magnitude of the earthquake and the distance from the hypocenter, respectively. The upper two rows show examples where arrival times read by experts are considered to be incorrect, and the lower two rows show examples where it is difficult to determine the arrival time.

テストデータの波形とP-Jiroの到達時刻の検出結果の例をFig. 10に示した。上の2段は、専門家による到達時刻検出(縦の黒線)がずれていると考えられる波形の例である。例えば最も左上の波形は、0.1秒程度専門家の検出が早かったと考えられる。一方、上の2段の波形に対するP-Jiroの出力(橙色の線)に基づく到達時刻検出(赤の縦線：橙色の線の最大値)は、専門家の読み取った検出時刻を改善できているように見える。

下の2段の波形は、初動極性の検出が難しそうな例である。例えば最も右下の波形は、もし到達時刻が専門家の検出通りであれば初動極性は引き(Down)になるが、P-Jiroの検出通りであれば押し(Up)となり、検出されたP波の到達時刻に依存して初動極性の検出結果が変わる可能性がある。

Fig. 9に示した250 Hzと100 Hzのヒストグラムの概形は似通っているにも関わらず、標準偏差については100 Hzのデータに対し0.077 sと大きくなっている。この原因として、Fig. 9の100 Hzの結果において、 $\Delta t = -0.2$ s付近に存在する小さい山が影響していると考えられる。例えば、Fig. 10の100 Hzのコラムの上から二つめの波形は、専門家とP-Jiroとで検出結果が0.2 s程度異なる。そこで、 $\Delta t < -0.018$ sとなっている波形に対して、専門家もしくはP-Jiroの決定した到達時刻を $t = 0$ sに合わせた上で、波形の振幅の絶対値を足し合わせて波形数で割り、比較した(Fig. 11)。

Fig. 11では、P-Jiroにより決定された到達時刻で合わせた結果(橙線)では $t = 0$ sのタイミングから振幅が増加している一方、専門家の到達時刻で合わせた結果(青線)は約 $t = 0.2$ sずれたタイミングから振幅

が増加している。到達時刻が正しく検出されていれば、 $t = 0$ のタイミングで振幅が増加する様子が見えるはずである。この結果から、100 Hzの波形の一部は専門家による到達時刻の検出結果が間違っている（おそらくは、必要性が特になかったために必ずしも正確にピックアップしなかった）と考えられる。 $\Delta t < -0.018$ sの波形を除くテストデータに対する標準偏差は、250 Hz (100 Hz)の波形に対し、平均は -0.003 s (-0.001 s)、標準偏差は0.028 s (0.051 s)となった。Zhu and Beroza (2018)は100 Hzの波形に対して標準偏差0.052 sであり、P-Jiroの100 Hzの波形に対する結果とほぼ一致した。

また、Fig. 11は $\Delta t < -0.018$ sの波形のみに対する結果だが、全てのテストデータについて同様の和をとった結果がFig. 12である。Fig. 12において、予想通りP波の到達直後に振幅の絶対値が増加する傾向が明瞭に見て取れる。但し、250 Hz、100 Hz共にP-Jiroによる補正後の振幅の絶対値(橙線)のピークが専門家による検出を用いた振幅の絶対値(青線)のピークよりも多少高くなっている。Fig. 11に示されたような波形の到達時刻が正しく修正されることがFig. 12のピークの増加に寄与したと考えられ、ここからP-Jiroは専門家よりもP波の到達時刻をより正しく検出できた可能性がある。

6. 初動極性決定モデル (F-Saburo)

E-TaroやP-Jiro、あるいは他の既存の手法によって決定されたP波の到達時刻を基に、P波の初動極性を




Fig. 11 Comparison of the sums of absolute values of amplitude for the waveforms with $\Delta t < -0.18$ in Fig. 9. The summation was taken by adjusting the P-wave arrival time determined by experts (blue) or P-Jiro (orange) to $t = 0$ s. "Abs waveforms" means the absolute value of waveform amplitude.




Fig. 12 Comparison of the sums of absolute values of amplitude for all the waveforms in Fig. 9. The summation was taken by adjusting the P-wave arrival time determined by experts (blue) or P-Jiro (orange) to $t = 0$ s. "Abs waveforms" means the absolute value of the waveforms' amplitude.

決定するCNNモデル(F-Saburo)について説明する．初動極性の決定アルゴリズムについては，1.1節で紹介したPhasePAppyアルゴリズムやPugh et al. (2016)のベイズの手法のように，事前に決定された到達時刻に基づいた手法がよく使われる．F-Saburoでも専門家が事前に決定した到達時刻を用いる．本章の内容は，Hara et al. (2019)で既に述べられているが，F-SaburoはE-taro, P-Jiroと一連のものであるので，本論文の一部として改めて簡易に記述した．より詳しくは，同論文を参照して頂きたい．

6.1 CNNモデル

F-Saburoの概形をFig. 13に示す．F-Saburoも250 Hzと100 Hzの地震波形データに対して同様の形状で構

築した．入力する地震波形データは事前に決定されているP波の到達時刻を中心に150点とした．この点の数は検証データに対する精度を考慮して決定したもので，250 Hzのデータに対しては100点程度で，100 Hzのデータに対しては150点以上用いた場合に精度が飽和する傾向があったことが理由である．150点は，到達時刻を中心に0.6秒間(250 Hz)及び1.5秒間(100 Hz)のデータを使用したことを意味する．用いた波形は上下動成分のみであり，入力波形の150点の振幅に対しz-score正規化を行った．

6.2 専門家の検出との一致率

山陰地方と近畿地方北部の地震波形データを区別せずに用いてF-Saburoの性能を調べた．訓練には両




Fig. 13 The CNN model of F-Saburo to determine P-wave first-motion polarity. The input data has a size of 150×1 . The output has two probability values, "Up" and "Down". Input data are processed by seven convolution layers shown by rectangles and two fully connected layers. Flattening simply converts data of the final convolution layer with two dimensions to data of one dimension. "ReLU" and "Softmax" represent the activation functions used for respective layers. Modified from Hara et al. (2019).




Fig. 14 (a) Match examples. Waveform examples, for which the polarities determined by the CNN model and human experts coincides, are shown. (b) Mismatch examples. Waveform examples, for which the polarities determined by the CNN model and human experts do not coincide, are shown. The vertical dashed line in each diagram represents the *P*-wave arrival time determined by human experts. “M” and “d” on the top of each diagram represent the magnitude of the earthquake and the distance from the hypocenter, respectively. The output of the final “softmax function”, which represents the probability (or reliability) of the estimated polarity in percentage, is also shown together with the CNN polarity determination for each trace. Modified from Hara et al. (2019).

地域のデータの8割を使用し、1割を検証データとして、残りの1割をテストデータとして用いた。

F-Saburoの性能の評価には、4章と同様に次式で定義されるAccuracyを用いた:

$$AC = \frac{TU + TD}{TU + TD + FU + FD} \quad (3)$$

ここで、*TU*(*TD*)はそれぞれF-Saburoと専門家が共にUp (Down)と検出した波形数を意味し、*FD*(*FU*)はCNNがDown (Up)と検出した一方、専門家はUp (Down)と検出した波形数を意味する。F-Saburoの出力値は確率値であり、“Up”の出力が50 %を越えた波形が*TU*及び*FU*に含まれる。その結果、F-SaburoのAccuracyは250 Hzに対し97.9%, 100 Hzに対し95.4%だった。また、訓練データを入れ換えて何度かF-Saburoを訓練し直した場合も、Accuracyは0.1%程度の変化に留まっていた。

この結果は、250 Hzの波形に対するF-SaburoのAccuracyが100 Hzの波形に対するそれと比べて約2.5%高いことを示している。つまり、F-Saburoにとっては250 Hzの波形の方が人と同様の決定をしやすいと考えられる。サンプリング周波数が高い波形はノ

イズと信号の区別がつけやすく、到達時刻や初動極性の検出がより容易であるためと考えられる。但し、F-Saburoが約2% (250 Hzデータ)から約5% (100 Hzデータ)の確率で専門家による検出と一致しない点に注意する必要がある。

6.3 誤検出について

F-Saburoと専門家の検出結果が一致した波形(*TU*と*TD*)をFig. 14(a)に、一致しなかった波形(*FU*と*FD*)をFig. 14(b)に示した。ここでは一致した波形と一致しなかった波形を同数示したが、実際には大部分が一致した波形であり、一致しなかった波形の数は全体の数%に過ぎない。Fig. 14(a)から、F-Saburoは、波形のノイズが大きい場合でも専門家と同様に初動極性を検出できることが分かる。一方、一致しなかった例を集めたFig. 14(b)では、左下の波形の初動極性は押し(Up)であると考えられるが、F-Saburoは出力確率が58.6 %と低めながらも引き(Down)と決定していることが分かる。一方、左上の波形では、逆に専門家の検出(Up)が失敗しているように思われるが、断定することは難しい。検出結果が一致しなかった例か




Fig. 15 Relation of the polarity probability estimated by the CNN models to the accuracy and the number of estimated polarities for 250 Hz (left) and 100 Hz (right) data. In each diagram, the horizontal axis represents the probability of the polarity estimated by the CNN models; the vertical axis represents the number of the estimated polarities (histogram) and the accuracy of the estimates (solid line) for each probability bin. Note that the scale of the histogram (“Number of estimated polarities”) is logarithmic. Modified from Hara et al. (2019).

らは、地震波形データの真の初動極性を明確に決定するのは必ずしも容易ではないことが分かる。

本研究では、F-Saburoの訓練において専門家の検出結果が常に正しいと仮定していたが、実際には専門家も低い確率で誤検出していると考えられる。例えば、カリフォルニア南部で1981年から1998年まで集められたデータに対し、Hardebeck and Shearer (2002)は専門家による初動極性検出結果の10～20%が誤検出であると報告した。山陰地方では、Yukutake et al. (2007)は2000年に発生した鳥取県西部地震の余震について、専門家の誤検出を2～3%まで許容してメカニズム解を求めた。Iwata (2018)は専門家によって検出された初動極性データから応力場を推定した。この研究では、副産物として専門家の誤検出の確率が得られるが、それは約1%だった。但し、誤検出の確率は推定されたメカニズム解と矛盾する初動極性の数から計算されており、メカニズム解は専門家の検出した初動極性に合わせて決定されることから、実際の誤検出の確率はもう少し高かったと考えられる。本研究でも、使用した専門家の検出結果の一部が誤っている可能性はあるが、一部の訓練データが誤っていてもCNNモデル(F-Saburo)は正しく訓練できていると考えられる。

6.4 出力確率と一致率の関係

6.1節で述べたように、F-Saburoの出力は確率値である。Fig. 14の各波形の上には決定した初動極性(UpまたはDown)の隣に確率値が示されている。Fig. 15に、Table. 2のテストデータに対してF-Saburoの出力した確率値とAccuracyの関係を示した。確率値とAccuracy

には正の相関があり、F-Saburoの出力確率は正確性の指標として使える可能性がある。言い換えると、出力確率値に閾値を設定することで、より信頼性の高い検出結果を得られると考えられる。例えば、確率値の低い初動極性には“判定不能”のようなラベルをつけることができる。Fig. 15では、F-Saburoの出力確率と検出された初動極性の数の関係をヒストグラムによって示しており、F-Saburoによって検出されたほとんどの初動極性は95 %以上の確率値を有することが分かる。95 %以上の確率値を有する初動極性に絞った場合、F-SaburoのAccuracyは99.3 % (250 Hz)と98.5 % (100 Hz)だった。

7. 3つのCNNモデルを用いた連続波形からの到達時刻と初動極性の検出

本章では、これまで作成した3つのCNNモデル(E-Taro, P-Jiro, F-Saburo)を合わせて用いることで、3分間の連続波形からP波を検出し、その到達時刻と初動極性を決定できるかどうか検証する。専門家の検出結果の利用を極力少なくしたところが、4～6章に述べたモデルとの違いである。まず、E-TaroとP-Jiroについて、P波の検出とP波の到達時刻決定の2つの面から性能の比較を行う。

7.1 P波のイベント検出 : E-Taro vs P-Jiro

E-Taroが連続波形からP波の検出が可能であることは、4.3節で確認した。一方、P波の到達時刻を決定するP-JiroもE-Taroのように連続波形からP波の検出をすることが可能である可能性がある。もし可能で

あれば、E-Taroは不要となる。なお、以下の計算では、P-Jiroの計算コストがE-Taroと比べて高いため、250 Hzの波形も100 Hzの波形も"2 scans"による結果を用いた。

Fig. 16に示したように、P-Jiroの出力は楕状になり、専門家によるP波到達時刻の周辺で高い値を示しているものの、それ以外の部分でも大きな出力値が多数存在することが分かる。P波の到達時刻をより正確に修正する、というP-Jiroの本来の目的に対する性能は、250 Hzの波形に対するモデルの方が標準偏差が低く有効であると考えられたが、イベント検出については250 Hzの方が多くのノイズを拾ってしまっていることが分かる。この結果と4.3節に示したFig. 5及びFig. 6を比較すると、P波のイベント検出に対してはE-Taroの方が有効であると考えられる。

7.2 P波到達時刻の決定 : P-Jiro vs E-Taro

P波のイベント検出については、P-JiroよりもE-Taroの方が有効であることが分かった。次に、4.4節でも言及したが、E-Taroに"500 scans"させることで、P波の到達時刻を決定できる可能性を検証する。全てのテスト波形に対してE-Taroによる"500 scans"を行い、出力の最大値をP波到達時刻として決定した結果を専門家の検出時刻との差として表したヒストグラムと、P-Jiroによるそれとを比較したのがFig. 17である。Fig. 17では、特に100 Hzの結果について、P-JiroがE-Taroよりも高い性能を有することが分かる。一

方、E-Taroは500点の波形窓ごとにP波到達の確率値が出力されるので、P波到達のタイミングを正確に検出するには不十分だが、暫定的にP波の到達時刻を調べるのには有効である。

また、一つの例としてある波形に対するE-Taroの出力値(黒線)及び最大値(緑の縦線)と専門家によって検出されたP波到達時刻(赤の縦線)をFig. 18に示した。E-Taroの出力値は連続波形中では尖鋭に見えるが、拡大すると非常になだらかな出力値となっており、この例に示されるように、"500 scans"ではP波の到達時刻を精度よく決定できるとは考えづらい。

以上の結果から、P波の検出にはE-Taroが有効である一方、P波の到達時刻の決定に対してはP-Jiroの方が有効であることが確認できた。連続波形からE-Taroを用いてP波の到達を検出し、暫定的に決定されたP波の到達時刻をP-Jiroを用いて修正することで、正確なP波の到達時刻を決定できると考えられる。

7.3 P波初動極性の決定 ~F-Saburo vs 到達時刻のずれ~

E-TaroとP-Jiroを用いて、連続波形からP波の到達時刻を概ね正確に決定できることを前節までに示した。しかし、より正確とされるP-Jiroも、専門家の検出結果と多少のずれが残っていた。本節では、F-Saburoが初動極性を検出する際に、到達時刻の検出にずれがあった場合、どのような挙動を示すか検証する。




Fig. 16 Results of P-Jiro to detect P-wave arrival from continuous waveforms. The blue lines are continuous waveforms and the orange lines are output values of P-Jiro. "2 scans" is used both for the 250 Hz and 100 Hz waveforms because of computation costs. So many points were detected as P-wave arrival, which means that P-Jiro is unsuitable for the detection of P-wave.




Fig. 17 Comparison of P-Jiro (blue) and E-Taro (orange) with experts in determining the P-wave arrival time. Δt is defined by $t_{\text{human}} - t_{\text{CNN}}$, where t_{human} denotes the P-wave arrival time determined by experts, and t_{CNN} denotes that by P-Jiro or E-Taro. We use "500 scans" for E-Taro.

到達時刻の検出にずれがある場合の波形例については、ずれがほとんどない場合も含めてFig. 10に示されている。Fig. 10に示された波形に対し、F-Saburoを適用した結果と、その波形に対するGrad-CAMを用いた注目度の可視化を行った。ここで、F-Saburoへの入力については、専門家による到達時刻を中心に150点を切り出した。

Grad-CAMをF-Saburoに適用した結果はFig. 19のようになった。なお、本研究で開発したF-Saburoは、畳

み込み層のフィルターサイズが大きいため、Grad-CAMの出力がほとんど一定値になってしまい、出力結果の解釈が難しかった。そのため、入力層は 150×1 のまま、 $140 \times 10, 140 \times 10, 120 \times 10, 110 \times 10, 100 \times 10, 90 \times 10$ と構成される6つの畳み込み層、 1×900 の1つの全結合層を有する別の初動極性決定モデルを作成し、Grad-CAMを適用した。Fig. 19では、1秒間の地震波形データを示しているが、F-Saburoには150点だけデータを切り出して入力しているため、250 Hz




Fig. 18 Result of E-Taro to determine P-wave arrival time from a continuous waveform. We investigate whether "500 scans" can detect the P-wave arrival time. The waveform (blue) and output (black) are the same as those in the lower right of Fig. 5. The bottom diagram is a magnification of the top diagram. The red vertical line is the arrival time determined by an expert. The green line represents the time when the output of E-taro takes the maximum.

の波形についてはGrad-CAMの出力が0.6秒間で途切れていることに注意が必要である。これまで、F-Saburoによる初動極性検出では、検出が正しいかどうかのみ議論してきた。実際にどのようなプロセスでCNNモデルが判断したかの詳細な内容を理解することは現在の深層学習の研究段階では難しいが、Grad-CAMを用いることにより、それぞれの波形に対してF-Saburoがどの部分を重視してUpまたはDownのラベルを付けるに至ったかを考えることが可能となる。

Fig. 19において、左上と右の上から2番目の波形は専門家の到達時刻検出がずれている例を選出したものであるが、Grad-CAMの出力はP波が到達していると考えられる時刻の付近で最大となっていることが分かる。F-Saburoは初動極性自体も正しく読み取れているようで、専門家によって検出された到達時刻に過度に依存することなく、柔軟に真のP波到達時刻を見極めて初動極性を判別できることが分かった。与えた到達時刻に過度に依存すると、到達時刻検出の精度が悪い際に初動極性検出も引き摺られるように精度が落ちてしまう恐れがあったが、F-Saburoは到達時刻検出の精度がいくらか悪くても精度が大幅に落ちることは少ないと考えられる。

一方、Fig. 19の下半分の波形は、到達時刻の検出が

ほぼ正しいと考えられる波形の例で、Grad-CAMの出力の最大値は一つの例(右コラム3段目)を除きP波初動到達の直前にあることが分かる。P波初動極性の定義は初動到達直後の変位方向であるため、この出力は直感的には理解しがたい。しかし、P波初動極性を専門家が検出する際は、検出した到達時刻の直前に小さい振幅が隠れていないか注意することは一般的であり、F-SaburoにはP波初動極性を検出する際の特徴を教えていなかったにも関わらず、専門家がP波初動到達直前を重視する判断基準を自ら発見していたと考えられる。Fig. 19の結果から、F-Saburoが検出された到達時刻のずれに柔軟に対応して初動極性を決定できることが分かった。

7.4 3つのCNNモデルによる到達時刻と初動極性の検出

これまで、E-Taro、P-Jiro及びF-Saburoの3つのCNNモデルについて、その役割と性能について議論を進めてきた。最後に、これまでに訓練してきたこれらのCNNモデルを順次用いることで観測された連続波波からの形からP波の到達時刻と初動極性を検出してみる。検出の流れはFig. 20の通りである。




Fig. 19 Output of Grad-CAM applied to the waveforms shown in Fig. 10. The vertical line at $t = 0$ represents the arrival time determined by experts. Since only 150 points are cut out and input to F-Saburo, the length of the output of Grad-CAM is 0.6 seconds for 250 Hz waveforms. The part of larger outputs of Grad-CAM can be interpreted as the part where F-Saburo focuses.




Fig. 20 (Left) Flow chart for detecting the arrival time and first-motion polarity of P-wave from a continuous waveform. First, E-Taro is applied to a continuous waveform for 3 minutes, and the time at which the output value becomes the maximum is set as the provisional arrival time of the P-wave. Next, P-Jiro is applied to the 500 data points centered on the provisional arrival time, and the maximum value of the output is taken as the arrival time determined by the CNN models. Finally, F-Saburo is applied to the data of 150 points centered on the arrival time, and the first-motion polarity is determined. (Right) One example of applying the CNN models to an observed waveform. The details are explained in Fig. 21.

Fig. 20にあるように、まず3分間、つまり45,000点(18,000点)の250 Hz (100 Hz)の連続波形に対してE-Taroを"4 scans" ("10 scans")で適用し、矩形状の最大値の中央を暫定的な到達時刻とする。例えば、"4 scans"では最大値が125点、"10 scans"では最大値が50点続くため、それぞれ最大値の中央である63点目と25点目を暫定的な到達時刻とする。ここで、P波の検

出については、誤検出を防ぐためにE-Taroの出力確率に50 %の閾値を設定する。4.2節では、50 %の閾値でP波とノイズを約98 %の確率で見分けることができることを示した。次に、E-Taroによる暫定到達時刻を中心とする500点のデータに対してP-Jiroを適用し、その出力の最大値をCNNモデルによって決定されたP波の到達時刻とする。さらに、その到達時刻を中心




Fig. 21 One example of applying the CNN models to an observed waveform. (Top) Result of E-Taro applied to a continuous waveform of 45,000 data points (250 Hz). The black broken line indicates the output value of E-Taro, and the red broken line indicates the provisional arrival time by E-Taro. (Bottom) Result of P-Jiro applied to the waveform window of 500 data points centered on the provisional arrival time determined by E-Taro, shown by red lines in the top. The yellow broken line is the output value of P-Jiro, and the black broken line represents the arrival time when the output of P-Jiro takes the maximum.

とする150点のデータに対してF-Saburoを適用し、P波の初動極性を決定する。初動極性決定でも、誤検出を防ぐためにF-Saburoの出力確率に95 %の閾値を設定する。6.6節では、F-Saburoは95 %の閾値を設定することでAccuracyが約99 %となることを示した。

Fig. 20の右側に示した、CNNモデルの適用結果の例を拡大したのがFig. 21である。Fig. 21の例では、E-Taroによって決定された暫定的なP波到達時刻(赤破線)は初動の直後になってしまい、正確とは言えない位置を示している。この赤破線を中心に500点のデータを切り出したのがFig. 21の下図であり、P-Jiroを用

いてP波の到達時刻を正確に修正できている(黒破線)。この黒破線を中心に150点のデータを切り出し、F-Saburoを適用すると、初動極性の検出結果はUpと示された。

このように、3つのCNNモデルを組み合わせることで、専門家の判断を介在させることなく、観測された連続波形から地震イベントを検出し、P波の到達時刻と初動極性を決定することが可能である。同様の手順により、専門家の検出結果の存在する地震イベントに対し、専門家がP波到達を検出しなかった観測点の波形も含めてCNNモデルを適用した結果




Fig. 22 Results of the CNN models (E-Taro, P-Jiro and F-Saburo) applied to the waveforms of the earthquake with the most polarities read by human experts for each region (northern Kinki or San-in). The red cross denotes the epicenter of the earthquakes. Black crosses denote observation points where the maximum probability output by E-Taro is less than 50 %. (Left) Δt is defined by $t_{\text{human}} - t_{\text{CNN}}$, where t_{human} denotes the P-wave arrival time determined by experts, and t_{CNN} denotes that by E-Taro and P-Jiro. Plus (+) marks denote observation points at which P-wave arrival was not detected by experts. (Right) Plots of first-motion polarities determined by F-Saburo, using the arrival time determined by E-Taro and P-Jiro. Blue and light blue circles represent Up and Down, respectively, where circles with red borders represent mismatch examples (experts' decision was different from F-Saburo). The color significantly changes at 95 % probability. Squares represent observation points at which the first-motion polarity has not been determined by experts (plus marks in the left column).

の例をFig. 22～Fig. 24に示す。それぞれ、地域ごとの専門家の初動極性検出結果が1～3番目に多い地震に対応している。

Fig. 22の結果は、P波の到達時刻・初動極性検出共に、多くの観測点で専門家による検出とほぼ合致し、CNNモデルが上手く機能していることを示している。但し、近畿地方北部の結果(上段)について、到達時刻決定(Phase picking)は10個の観測点で $|\Delta t|$ が0.1秒以上異なっているが、その主な原因は専門家の決定した到達時刻がずれているためと考えられる(5.2節を参照)。一方、初動極性の分布を見ると、多くの観測点でCNNモデルは専門家と同様の初動極性を決定しており、ほとんど影響を受けていないことが分かる。さらに、専門家が検出していない観測点(四角)についても周囲と同様の初動極性を検出しているため、CNNモデルは検出データ数の増加にも貢献できるだろう。山陰地方の結果(下段)では、到達時刻決定についてほとんどの波形で Δt が ± 0.1 s以内に収まっている。初動極性を検出した観測点数も専門家による結

果と比べて増加し、近畿地方北部の結果と比べて綺麗に極性分布が求まっているように見える。また、初動極性が一致しなかった観測点は2点のみで、メカニズム解の節面付近に分布している。

Fig. 23でも、特に初動極性決定について、山陰地方・近畿地方北部共に精度良く決定できている。近畿地方北部では、Fig. 22と同様に $|\Delta t|$ が0.1秒以上の観測点の多くが緑丸である一方、全ての観測点で初動極性の検出結果は一致している。山陰地方では、到達時刻決定についても全観測点のうち2点以外は Δt が ± 0.1 s以内に収まっており、その2点についても初動極性が周囲の観測点と同じUpと決定されているため、CNNモデルが上手く機能したことを示している。

Fig. 24では、近畿地方北部について、震央から北東方向の琵琶湖周辺に専門家による検出がされていない観測点が多く分布している。これらの観測点ではE-Taroの出力確率についてもしばしば最大で50 %を越えず、誤検出を防ぐために設定した閾値が上手く機能したと考えられる。山陰地方では、到達時刻決




Fig. 23 Result of the CNN models (E-Taro, P-Jiro and F-Saburo) applied to the waveforms of earthquake with the second-most polarities read by experts for each region. For further explanations, see the caption of Fig. 22.

定は $\Delta t < -0.1$ sの観測点が多くなっている。そのうち東部の一つの観測点(赤い緑の水色丸)は、専門家が初動極性をUpと検出したのに対し、CNNモデルがDownと検出したことを意味する。この観測点の周囲はUpを示す青丸の領域であるため、CNNモデルの誤検出であると考えられる。しかし、多くの観測点で正確に初動極性を決定できている可能性が高く、データ数の増加に貢献できる可能性も高い。

今後の課題としては、3つのCNNモデルが波形ごとにP波の到達時刻と初動極性を決定した後、その地震イベントを他の観測点の波形と関連付ける必要がある。震源から地震波が伝わる速度は大雑把には一定であることから、それぞれの観測点で検出された到達時刻は震源から観測点までの距離に比例して遅くなっていく。3つのCNNモデルは観測点ごとに到達時刻及び初動極性を決定することしかできないため、検出された到達時刻が非常に近い観測点をグループとしてまとめることが必要となる。必要となる情報は、各観測点の位置と各観測点における到達時刻及

び浅部の地下構造であり、この作業はCNNモデルを使用せずに行うことができると考えられる。また、本研究では地震波形データの上下動成分のみを使用してP波の到達時刻及び初動極性を決定したが、Zhu and Beroza (2018)やRoss et al. (2018b)で行われているように、地震波形データの3成分を入力データとすることでCNNモデルの精度を向上させたり、P波だけでなくS波の到達時刻を検出できたりする可能性がある。

本章では、3つのCNNモデルを用いることで到達時刻及び初動極性を精度よく決定し、観測データを増加させられる可能性を示した。特に7.1節と7.2節での議論より、連続波形から到達時刻を決定する際には、2つの段階に分けて段階ごとにCNNモデルを用意することで、誤検出を抑えつつ精度よく到達時刻を決定できることが分かった。一つのCNNモデルに全ての処理を任せるのではなく、それぞれの処理を分割した複数のCNNモデルを用いることで、高精度な自動処理が可能になると考えられる。




Fig. 24 Result of the CNN models (E-Taro, P-Jiro and F-Saburo) applied to the waveforms of earthquake with the second-most polarities read by experts for each region. For further explanations, see the caption of Fig. 22.

8. 結論

本研究では、3つのCNNモデル(E-Taro, P-Jiro, F-Saburo)を用いてP波到達時刻と初動極性を自動で検出するアルゴリズムを開発した。CNNモデルの訓練のため、山陰地方と近畿地方北部で観測され、人間の専門家によって到達時刻と初動極性が共に検出されている地震波形データ(250 Hzと100 Hz)を用いた。

まず、500点の波形窓にP波の到達時刻が含まれているか否かを判断するイベント検出のためのCNNモデル(E-Taro)を作成し訓練した。その結果、250 Hzと100 Hzのデータに対し、それぞれ98.1 %と97.3 %のAccuracyを達成した(Table. 1)。次に、暫定的に検出されたP波の到達時刻をより正確に修正するCNNモデル(P-Jiro)を訓練した結果、専門家の検出結果との時間差について250 Hz (100 Hz)の地震波形データに対し、平均 -0.005 s (-0.012 s)、標準偏差0.038 s (0.077 s)の結果を得た(Fig. 9)。これは先行研究(Zhu and Beroza 2018; Ross et al. 2018a)と同等の結果である。さらに、P波の到達時刻を与えた上で、初動極性を決定するCNNモデル(F-Saburo)を訓練した結果、Accuracyは250 Hz (100 Hz)の地震波形データに対して97.9 % (95.4 %)となった。

個々のCNNモデルの精度について検証した後、それぞれのモデル間の性能の比較を行った(7章)。まず、P波の検出について、連続波形に対してE-Taroの代わりにP-Jiroをスキャンさせたところ、P-Jiroが様々なノイズを検出してしまうことがわかり、E-Taroの有用性が確かめられた(Fig. 16)。一方、到達時刻決定について、E-Taroを連続的にスキャン("500 scans")させることでP-Jiroの代わりとして用いることができるか調べた。その結果、専門家の検出結果との比較(Fig. 17)と連続波形への適用例(Fig. 18)で、P-Jiroの方がより正確であることが確かめられた。初動極性決定については、Selvaraju et al. (2017)のGrad-CAMと呼ばれる手法を用いて、F-Saburoによる初動極性の決定プロセスの可視化を試みた。Grad-CAMの適用は地震学への応用研究としては初めての試みである。その結果、F-Saburoが到達時刻の検出結果のズレに柔軟に対応していることや、多くの波形に対して初動到達直後よりもむしろ直前を重視していることが分かった(Fig. 19)。この特徴は専門家による初動極性検出の判断基準に近く、初動極性検出のやり方をF-Saburoに指導していないにも関わらず、人間と同様の判断方法を身につけるに至ったと考えられる。

最後に、本研究で作成した3つのCNNモデル(E-Taro, P-Jiro, F-Saburo)を用いて、専門家を介させずに観測された連続波形からP波の到達時刻と初動

極性を検出できるか調べた(Fig. 20)。得られた到達時刻と初動極性の検出結果を専門家による検出結果と比較してみると(Fig. 22~Fig. 24)、3分間に渡る連続波形からほぼ正確に到達時刻と初動極性を検出できることが分かった。到達時刻の決定(Fig. 22~Fig. 24の左コラム)では、ほとんどの観測点で $|\Delta t| < 0.1$ sとなり、正しく検出できていると考えられる。なお、いくつかの観測点では $|\Delta t| > 0.1$ sとなり(赤丸及び緑丸)、CNNモデルが検出に失敗した可能性もあるが、主には専門家の検出結果がずれていたためであると考えられる(5.2節を参照)。また、Fig. 22の山陰地方の初動極性検出結果(右下)の不一致(赤丸)は、メカニズム解の節面付近での初動極性決定が難しいことが反映されている(Hara et al., 2019)。自動処理を行う際には、CNNモデルの出力確率に閾値(本研究の検証ではE-Taroは50 %, F-Saburoは95 %を閾値とした)を設けることで誤検出を抑えることができる。

CNNモデルによるP波到達時刻と初動極性を決定する自動処理アルゴリズムの開発では、一つのCNNモデルで全ての処理を行うのではなく、それぞれの処理を分割した複数のCNNモデルを作成することによって、より高精度な自動処理が可能になると考えられる。

謝 辞

本研究は、Abadi et al. (2016)によって開発されたTensorflowとBeyreuther et al. (2012)によって開発されたObspyを用いた。また、気象庁、防災科学技術研究所、産業技術総合研究所及び京都大学の観測点の地震波形データを使用した。

参考文献

- 飯尾能久 (2011): 次世代型地震観測システムの開発と運用—満点(万点)を目指して—, 京都大学防災研究所年報 第54号A: p17-24.
- 飯尾能久・米田 格・澤田麻沙代・伊藤喜宏・片尾 浩・富坂和秀・長岡愛理・松本 聡・宮崎真大・酒井慎一・加藤愛太郎・林 能成・山品匡史・大久保慎人・野口竜也・香川敬生 (2017): 鳥取県西部地域における満点地震観測, 京都大学防災研究所年報 第60号B: p70-76.
- ト部 卓・東田進也 (1991): ワークステーションによる微小地震観測網波形験測支援システム, 日本地震学会春季大会予稿集, C22-P18.
- ト部 卓 (1994): 多チャネル地震波形データのための共通フォーマットの提案. 日本地震学会秋季大会予稿集, P24.

- 原 将太 (2020): 深層学習によるP波の検出と到達時刻および初動極性の決定, 京都大学大学院理学研究科修士論文.
- 堀内茂木・堀内優子・飯尾能久・中村洋光・長谷見晶子 (2009): 人間と同程度に高精度な地震波自動読み取りシステムの開発. 日本地球惑星科学連合大会予稿集, S150-001.
- 三浦勉・飯尾能久・片尾浩・中尾節郎・米田格・藤田安良 近藤和男・西村和浩・澤田麻沙代・多田光弘・平野憲雄・山崎友也 富阪和秀・辰己賢一・加茂正人・澁谷拓郎・大見士朗・加納靖之 (2010): 近畿地方中北部における臨時地震観測, 京都大学防災研究所年報 第53号B: p203-212.
- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D. G., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., Wicke, M., Yu, Y., & Zheng, X. (2016): TensorFlow: A system for large-scale machine learning. In: 12th USENIX symposium on operating systems design and implementation (OSDI) vol. 16, pp 265-283
- Akaike, H. (1974): Markovian representation of stochastic processes and its application to the analysis of autoregressive moving average processes, *Ann. Inst. Stat. Math.* 26, no. 1, 363-387.
- Allen, R. V. (1978): Automatic earthquake recognition and timing from single traces. *Bulletin of the Seismological Society of America*, 68(5), 1521-1532.
- Baer, M., and U. Kradolfer (1987). An automatic phase picker for local and teleseismic events, *Bull. Seismol. Soc. Am.* 77, no. 4, 1437-1445.
- Beyreuther, M., Barsch, R., Krischer, L., Megies, T., Behr, Y., & Wassermann, J. (2010): ObsPy: A Python toolbox for seismology. *Seismological Research Letters*, 81(3), 530-533.
- Chen, C., & Holland, A. A. (2016): PhasePapy: A robust pure Python package for automatic identification of seismic phases. *Seismological Research Letters*, 87(6), 1384-1396.
- DeVries, P. M., Viégas, F., Wattenberg, M., & Meade, B. J. (2018): Deep learning of aftershock patterns following large earthquakes. *Nature*, 560(7720), 632.
- Fukushima, K. (1980): Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological cybernetics*, 36(4), 193-202.
- Hara, S., Fukahata, Y., & Iio, Y. (2019): P-wave first-motion polarity determination of waveform data in western Japan using deep learning. *Earth, Planets and Space*, 71(1), 127.
- Katoh, S., Iio, Y., Katao, H., Sawada, M., Tomisaka, K., Miura, T., & Yoneda, I. (2018): The relationship between S-wave reflectors and deep low-frequency earthquakes in the northern Kinki district, southwestern Japan. *Earth, Planets and Space*, 70(1), 149.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012): Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- Küperkoch, L., Meier, T., Lee, J., Friederich, W., & EGEDOS Working Group. (2010): Automated determination of P-phase arrival times at regional and local distances using higher order statistics. *Geophysical Journal International*, 181(2), 1159-1170.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998): Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Matsumoto, S., Yamashita, Y., Nakamoto, M., Miyazaki, M., Sakai, S., Iio, Y., Shimizu, H., Goto, K., Okada, T., Ohzono, M., Terakawa, T., Kosuga, M., Yoshimi, M., Asano, Y. (2018): Prestate of stress and fault behavior during the 2016 Kumamoto earthquake (M7. 3). *Geophysical Research Letters*, 45(2), 637-645.
- Matsuzawa, T., Asano, Y., & Obara, K. (2015): Very low frequency earthquakes off the Pacific coast of Tohoku, Japan. *Geophysical Research Letters*, 42(11), 4318-4325.
- Nakano, M., Sugiyama, D., Hori, T., Kuwatani, T., & Tsuboi, S. (2019): Discrimination of seismic signals from earthquakes and tectonic tremor by applying a convolutional neural network to running spectral images. *Seismological Research Letters*, 90(2A), 530-538.
- Okada, T., Iio, Y., Matsumoto, S., Bannister, S., Ohmi, S., Horiuchi, S., Sato, T., Miura, T., Pettinga, J., Ghisetti, F., & Sibson, R. H. (2019): Comparative tomography of reverse-slip and strike-slip seismotectonic provinces in the northern South Island, New Zealand. *Tectonophysics*.
- Perol, T., Gharbi, M., & Denolle, M. (2018). Convolutional neural network for earthquake detection and location. *Science Advances*, 4(2), e1700578.
- Pugh, D. J., White, R. S., & Christie, P. A. F. (2016): Automatic Bayesian polarity determination. *Geophysical Journal International*, 206(1), 275-291.
- Rosenblatt, F. (1958): The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Ross, Z. E., Meier, M. A., & Hauksson, E. (2018a): P wave arrival picking and first-motion polarity determination

- with deep learning. *Journal of Geophysical Research: Solid Earth*, 123, 5120-5129.
- Ross, Z. E., Meier, M. A., Hauksson, E., & Heaton, T. H. (2018b): Generalized seismic phase detection with deep learning. *Bulletin of the Seismological Society of America*, 108(5A), 2894-2901.
- Schaff, D. P., & Waldhauser, F. (2010): One magnitude unit reduction in detection threshold by cross correlation applied to Parkfield (California) and China seismicity. *Bulletin of the Seismological Society of America*, 100(6), 3224-3238.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017): Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 618-626).
- Shelly, D. R., Beroza, G. C., & Ide, S. (2007): Complex evolution of transient slip derived from precise tremor locations in western Shikoku, Japan. *Geochemistry, Geophysics, Geosystems*, 8(10).
- Sleeman, R., & Van Eck, T. (1999): Robust automatic P-phase picking: an on-line implementation in the analysis of broadband seismogram recordings. *Physics of the earth and planetary interiors*, 113(1-4), 265-275.
- Stein, S., Wysession, M. (2003): *An introduction to seismology, earthquakes, and earth structure*. Blackwell Pub, Malden.
- Sutskever, I., Vinyals, O., & Le, Q. V. (2014): Sequence to sequence learning with neural networks. *Advances in NIPS*.
- Uehira, K. (2001). Improvement of WIN system. *Abst Jpn Earth Planet Sci Joint Meeting Ss-P002*.
- Zhu, W., & Beroza, G. C. (2018): PhaseNet: a deep-neural-network-based seismic arrival-time picking method. *Geophysical Journal International*, 216(1), 261-27.

(論文受理日 : 2020年8月31日)