# 人工ニューラルネットワークを利用した 高ノイズ環境下における地震波検出手法の開発 The development of a method for seismic signal detection under high noise environment using an artificial neural network

コース	物質科学コース
学 籍 番	130385
号	
氏名	高橋 馨子
指 導 教	ミケレット ルジェロ
昌	

We have developed a community based MEMS sensor network, Citizen Seismic Network (CSN) to obtain detailed strong motion data that are closely linked to community's life. In this project, we developed a sensor unit that detects strong motion and processes the data. The unit is composed of 12 bit MEMS sensor and Raspberry pi computer. Since we expect the unit to be set under high noise environment (e.g. inside of house), it is important to discriminate between the earthquake signal and the other signals. We developed a method to detect and identify a seismic signal using an artificial neural network (ANN) which utilize a pattern recognition. To verify the veracity and reliability of our ANN detection algorithm, we used seismic datasets from traditional seismic networks in Japan and superimposed it with our sensor noise. 114 seismic datasets are analyzed by an ANN trained with 50 datasets. As the results, the ANN successfully detected over 95 per cent of seismic signal.

Citizen Seismic Network (CSN)プロジェクトでは,市民が地震・防災に対する理解を深めることを 目的に,家庭にも導入しやすい地震計として MEMS 加速度センサーと小型コンピュータ Raspberry Pi を用いた小型で安価なセンサーユニットを作製し,市民参加型の地震波計測コミュニティセンサー ネットワークを構築した.CSN センサーユニットの実用化にあたり,地震信号の検出能力向上は重要 な課題のひとつである.

近年,パターン認識の問題においてニューラルネットワーク(以下,ANN)は多くの分野で適応性が 検討されており,地震波検出へ応用する試みもなされている.本研究ではANNを用いて,高ノイズ環 境下に設置した安価なセンサーでも利用可能な地震波検出手法の開発および検証を行った.検証に は,横浜市強震計ネットワークで得られた強震記録にCSNセンサー特有のノイズを重ね,あたかも本 センサーで得られたかのような地震記録(以下,擬似データ)を作製し使用した.計 50の擬似データを 用いてANNを段階的に学習させ,学習済みのANNで114の擬似データを判定した結果,95%以上 を地震として検知することに成功した.図1にANNで2005年8月7日に保土ヶ谷観測点で観測さ れた記録を元に作成した擬似データを判定した結果を示す.また図2に検出に成功した地震と失敗し た地震の震度と最大振幅を示す.図2より検出に失敗した地震は震度1.5以下であることがわかる. つまり,CSNセンサーユニットで得られた地震のうち震度2以上のものであれば高確率で検出可能で あることが示唆された.以上より,高ノイズ環境下においてもANNを用いた地震検出手法は有用であ ると考えられる.



図1 地震判定成功例



判定值 F(t)

図2 判定地震の震度と入力波形の最大振幅

## 人工ニューラルネットワークを 利用した高ノイズ環境下における地震波 検出手法の開発

## 2016年度卒業論文 指導教員 ミケレット・ルジェロ 横浜市立大学国際総合科学部国際総合科学科 物質科学コース 130385 高橋馨子

### 目次

1序論	3	
1 -1 Citizen Seismic Network プロジェクトについて	••••	3
1 - 2 STA/LTA 検出法	••••	4
1 - 3ニューラルネットワーク	••••	6
1 - 4本研究の目的	••••	9
2データ 1	0	
3手法 1	1	
3 - 1 擬似データの作成	••	11
3 - 2ニューラルネットワークによる地震波検出	••	15
3 - 2 - 1入出力		15
3 - 2 - 2誤差逆伝搬法によるニューラルネットワークの学習		15
3 - 2 - 3中間層のニューロン数の設定		17
3 - 2 - 4学習データの抽出		17
3 - 2 - 5未知データの判定		22

4検証結果	23	
4 - 1 中間層のニューロン数		23
4 - 2 地震検出能力	••••	27
5議論	32	
6結論	38	
7謝辞	39	
8文献	40	

#### 1序論

我が国は地震活動が極めて活発であり、これまで地震に関する学術研究が盛んに行われてきたいくつ かの機関では大規模な強震観測網が展開されており、例えば防災科学研究所では全国約 20km 間隔 で 1,000 箇所以上の強震計を設置している。これらの観測網は多くの地震研究の発展や、緊急地震速 報などの実用的な技術の進歩に貢献している。しかしこれらの研究・技術は一般市民にとって非常に理解 か難しく、主体的に地震・防災について学ぶには敷居が高い、今後大地震が起こる可能性が高いと予想さ れている中、国家レベルにおける対策だけでなく、一般市民レベルにおいても地震・防災に対する理解を高 め、地震災害に備えることが重要である。

#### 1.1 Citizen Seismic Network プロジェクトについて

金・他 (2015)の先行研究ではこの問題を解決するアプローチとして、市販の安価な MEMS 加速度

センサーとコンピュータ Raspberry Pi を組み合わせた小型センサーユニットを作成し,各家庭や公 共施設に設置することで地域市民参加型地震波計測ネットワーク( Citizen Seismic Network, 以下, CSN )を構築することを提案した. CSN センサーユニットには,センサーの波形データを用いて 自らの体験を通して地震の仕組みについて学習できるアプリケーションがインストールされているほか,ソー シャル・ネットワーキング・サービスなどと連動させることで市民間のつながりもでき,各地域での地震防災コ ミュニティーネットワークの構築につながると考えられる.また,センサー設置地点の加速度データをサーバー に集約することで地域における高密度なセンサーネットワークを構築することも目指している.

現在 CSN プロジェクトでは横浜市内の公共ビルに 5 箇所,ボランティア家庭に 6 箇所,協力企業 に1 箇所の計 12 箇所に CSN センサーユニットを設置し観測を行っている.

CSN センサーユニットの実用化に向け、センサーが地震を感知した際にその情報を自動的に発信する 機能は非常に重要である。しかし通常の強震計と比べ MEMS 加速度センサーは機械ノイズが多く、また 設置場所が家庭や公共施設といった高ノイズ環境下であることからノイズと地震の識別が難しいことが問 題である。 1.2 STA/LTA 検出法

現在 CSN では従来型の地震検知手法である STA/LTA 検出手法を用いている.この手法は加速 度波形出力における短間平均(Short Term Average,以下 STA)と長時間平均(Long Term Average,以下 LTA)の振幅比が,ある閾値を超えることをトリガー条件としており,加速度の急 激な変化を捉える手法である.この方法は計算が早く地震自動検出によく採用されている.

しかし CSN センサーユニットの設置場所は家庭内のような高ノイズ環境下であるため、 STA/LTA

検出法ではノイズによる振幅が一定以上になると地震として誤検出してしまう点が問題である.以下の図 1は2015年5月24日19時~2015年5月25日19時(図は6時間ごとに分割)のCSNセンサーユニットのある自宅で計測された3成分加速度記録をベクトル絶対値M(t)としてプロットしたものと、M(t)に対するSTA/LTA検出を行なった結果の例である.地震検出パラメータとして、 ①STA window length(s):3 ②LTA window length (s):10 ③STA/LTA trigger on threshold (閾値):2 ④Skip ahead after end of event (s) (地震検 出後の不応期):0 の値を設定した.結果より,地震の検出は成功しているが,同時に地震以外のノイズ 部分において何度も誤検出してしまっていることがわかる.

また、Yoshida et al.(2005) では比較的強い地震においても STA/LTA 比が十分大きな値に ならずトリガー条件を満たさない場合があることか指摘されている.この原因は初動の振幅が小さくその後 ゆっくりと振幅が大きくなった場合、

STA/LTA 比にはほとんど影響を与えないためとされている.

以上のようにノイズの多い環境下では STA/LTA 検出法では正確な検出が困難である場合があるため,振幅の大きさに依存しない検出法が必要である.

5



図1: STA/LTA 検出例

#### 1.3 ニューラルネットワーク

ニューラルネットワーク(以下, ANN)とは人間の脳の神経回路を模擬した情報処理システムの総称で あり,単純な基準では判別しにくい複雑なパターンの認識機能に長けている.近年 ANN は多くの分野に てその適用性が研究されており,地震分野においては地震記録中の初動や反射波の認識に応用する取り 組みがされている. [Dai and MacBeth (1995), 芦田・佐々 (1994)]

ANN はネットワークのメカニズムによって階層結合型と相互結合型の大きく 2 つに分類できる.階層

結合型ではニューロン間の出力信号の流れは一方通行であるのに対し,相互結合型では信号の流れは 双方向で,任意のニューロン間で信号のやりとりができるという特徴がある.本研究では図 2に示すよう な階層結合型 ANN を用いた.ネットワークは入力層,中間層,出力層の 3層からなり,各層におかれた 複数のユニットは前後の層のユニットと接続している.それぞれのユニットは図 3に示すように前層の各 ユニットから重みつき入力をうけ,その総和から閾値を引いた値を応答関数に代入することで出力値を決定 する.つまり, x 層第 j ユニットへの入力の総和を  $I_j^x$ , 出力を  $O_j^x$ , x-1 層第 i ユ ニットから x 層第 j ユニットへの結合の重みを  $W_{i,j}^{x-1,x}$ , x 層第 j ユニットの閾値を  $\theta_j^x$  とし,応答関数を f とおくと,  $I_j^x$  と  $O_j^x$  は(1),(2)式で表せる.

 $I_{j}^{x} = \left(\sum_{i=0}^{N} W_{ij}^{x-1,x} O_{j}^{x}\right) - \theta_{j}^{x} \cdot \cdot \cdot (1)$  $O_{j}^{x} = f\left(I_{j}^{x}\right) \cdot \cdot \cdot (2)$ 

ここで N は x-1 層のユニット数とする、本研究では応答関数として(3)式に定義されるシグモ 1、関数を用いた.

 $f(x) = \frac{1}{1 + \exp(-x)} \cdot \cdot \cdot (3)$ 

ANN を特徴付けるパラメータは重みと閾値である。これらパラメータは、あらかじめ用意した入力層への 入力データと目標となる出力層からの出力値からなるデータセットを用い、学習することで決定される。つま り学習作業では、ある入力に対してあるべき出力パターンを再構成できるように ANN のパラメータを決め ていく.



図2:階層結合型ニューラルネットワーク



図3:ユニットにおける入出力関係

1.4 本研究の目的

通常の強震計と比べ CSN センサーユニットで使用している MEMS 加速度センサーは機械ノイズ が多く、また CSN センサーユニットの設置場所は家庭や公共施設といった高ノイズ環境下であることか ら、従来の STA/LTA 検出法ではノイズと地震の識別が難しいことか問題である.本研究では高ノイズ環 境下で観測された加速度記録から地震とノイズを識別するために、ANN を用いた地震波検出手法を構 築することを目的とする.

#### 2 データ

CSN プロジェクトでは現在 12 箇所で CSN センサーユニットを設置し加速度の観測を行っている

が、観測した地震数は ANN の学習や検出能力の検証に使用するには十分な数ではない、本研究では 既存の強震計より得られた地震データに本センサーのノイズを付加することであたかも CSN センサーユ ニットで得られたかのような地震データを作り出し、その波形を用いてアルゴリズムの検証を行った、横浜市 強震計ネットワーク(以下, YKN)の保土ヶ谷観測点にて1997年5月12日から2012年9月14 日得られた地震記録のうち、目視によって S 波初動を認識できるものを選び, ANN の学習および検証 に使用した.

#### 3 手法

3.1 擬似データの作成

本研究では YKN における,過去に得られた膨大な地震観測記録を CSN センサーユニットで得ら

れた記録の代わりとして使用することで、地震検出アルゴリズムの検証を行ったしかし YKN の強震計と CSN センサーユニットでは違いがある、両者の比較を表 1にまとめる、また両者で2016年2月5日に 得られた同一地震の波形を図 4に示す. CSN センサーユニットは強震計に比べ安価な加速度セン サーを用いているためサンプリング周波数が 50Hzと粗い、また図 4の地震発生前の波形をみてもわ かるように、 YKN ではほぼ静止状態であっても、 CSN センサーユニットでは機械ノイズが大きいため、 約1cm/s<sup>2</sup>の揺れを記録している.

したがって本研究では YKN における観測データを変換し、あたかも CSN センサーユニットで得ら

れたかのような記録(以下,擬似データ)を作成した.強震計データから擬似データを作成する方法を以下に 示す.まずサンプリング周波数を50Hzに統一させるためデータの間引きを行い,さらに単位が m/s<sup>2</sup> と なるよう変換する.次に,保土ヶ谷観測点にて地震の起きていない期間に CSN センサーユニットから得 た加速度3成分記録を用意し,そこからランダムにデータを切り出して先述の間引きをした強震計データに 付加する. 2016年2月5日にYKN で得られた地震(図 4-a)をもとに作成した擬似データを図 5 に示す.

以上の方法を用いて、YKN の保土ヶ谷観測点にて 1997年5月12日~2012年9月14日に 得られた地震記録のうち S波立ち上がり位置が明確なものを 164 記録選び,擬似データを作成した. そしてその擬似データのうち 2003年5月12日までに得られた 50 地震記録(以下,教師用擬似 データ)を ANN の学習に使用し、それ以降に得られた 114 地震記録(以下,検証用擬似データ)を ANN の検出能力検証に使用した.

12

#### 表1:強震計と CSN センサーユニットの比較

	横浜市強震計ネットワーク	CSN センサー
サンプリング周波数	100~400Hz( 観測期間によって異なる)	50Hz
bit 数	24	12
単位	cm/s²	m/s²
機械ノイズ	小さい	大きい(約 1cm/s <sup>2</sup> )



図4:2016年2月5日に保土ヶ谷観測点にて得られた地震波形.aはYKN,bはCSNセン

サーユニットにて得られた,同一地震の3成分を示す.なお比較のため両者の単位は cm/s<sup>2</sup> に統一した.



図5:図 4-aの YKN の波形をもとに作成した擬似データの例

3.2 ニューラルネットワークによる地震波検出

3.2.1 入出力

本研究では入力データとして、観測された加速度記録における 3 成分合成ベクトルの包絡波形

M(t) を使用したまず加速度の 3 成分記録からそれぞれの平均振幅を引き,移動中心を 0 にあわせる.そしてその 3 成分 x(t), y(t), z(t) から合成ベクトル (AMP)

 $AMP = \sqrt{x(t)^2 + y(t)^2 + z(t)^2}$ 

を算出し、AMP に移動平均フィルタをかけることでM[t]を計算した.ここでフィルタ係数は 10 とした.

本研究では入力層のニューロン数を 500 と設定した.つまり 50Hzサンプリングのデータを扱う場合,入力層には M(t) の 10 秒間分のデータが入力されることになる. ANN で扱えるデータはアナロ グ( 0~1)およびバイナリ( 0 / 1)数値であるため,タイムウィンドウ 10 秒間において M(t) の最大 値が1となるように正規化した値を入力した.

Dai and MacBeth(1995) でみられるように,既往研究では ANN を用いて地震の初動判別を

する際、初動部分入力時の目標出力を(1,0)、それ以外のノイズ入力時の目標出力を(0,1)として学 習データ設定し、学習を行う場合が多い、これらの学習データで設定した目標出力のことを教師信号という、 本研究でも出力層のニューロン数を2とし、同様の方法を用いて ANN の学習を行った. S 波の立ち上 がりが入力層 500 プロットのうちの 200 プロット目のニューロンにくるウィンドウを地震教師データ、 200 プロット目にS 波立ち上がりがみられないものをノイズ教師データとし、それぞれの教師データが入 力された際の教師信号  $(O_1, O_2)$  を (1,0) , (0,1) として与えることで学習データを作成した.

#### 3.2.2 誤差逆伝搬法によるニューラルネットワークの学習

ANN の学習とは、入力データとそれに対する教師信号をあらかじめ複数個用意しておいて、出力層からの出力と教師信号との誤差が最小になるように各ニューロンの重みや閾値を変化させていくことをいう. ANN の学習には誤差逆伝搬法(以下, BP)を用いた. BP では、まず ANN のパラメータの初期値を ランダムに仮定し,学習データの入力に対する ANN の出力層からの出力  $O_j^x$  と教師信号  $Y_j^{\Box}$  との誤差評価尺度 E ((4)式)を計算する.ここで N<sub>x</sub> は x 層におけるニューロン数を表す.

$$E = \sum_{n=1}^{N_x} |O_n^x - Y_n^x|^2 \cdot \cdot \cdot (4)$$

次にこの Eの値が最小になるように勾配法を用いてパラメータの修正を行う.

パラメータの修正方法についてユニットの重み  $W_{ij}^{k-1}$  の修正を例にして述べる. まず Eの  $W_{ij}^{k-1}$  についての偏微分を求める.

$$\frac{\partial O_j^x}{\partial I_j^x} = \frac{\partial f(I_j^x)}{\partial I_j^x} = \frac{\partial}{\partial I_j^x} \left\{ \frac{1}{1 + \exp(-I_j^x)} \right\} = f(I_j^x) \left\{ 1 - f(I_j^x) \right\} = O_j^x \left(1 - O_j^x\right) \cdot \cdot \cdot (6)$$

$$\frac{\partial I_n}{\partial W_{ij}^{x-1}} = \frac{\partial}{\partial W_{ij}^{x-1}} \left\{ \left( \sum_{i=0}^N W_{ij}^{x-1,x} O_j^{x-1} \right) - \theta_j^x \right\} = O_j^{i-1} \cdot \cdot \cdot (7)$$

より,(5)式は

$$\frac{\partial E}{\partial W_{ij}^{x-1}} = 2 \left( O_j^x - Y_j^x \right) O_j^x \left( 1 - O_j^x \right) O_j^i \cdot \cdot \cdot (8)$$

と表わせる.すなわちユニットの重み  $W_{ij}^{x-1}$  の修正量は(9)式で計算される.

$$\Delta W_{ij}^{x-1} = -\varepsilon \left( O_j^x - Y_j^x \right) O_j^x \left( 1 - O_j^x \right) O_j^{i-1} \cdot \cdot \cdot (9)$$

ここで ε は学習率であり,小さな正の数とする.また,収束特性を改善するためにモーメント法を用い,もう一 つのパラメータ,すなわちモーメンタムαを導入した.以上より重みの修正は

 $\Delta W_{ij}^{x-1}(n+1) = -\varepsilon \Big( O_j^x - Y_j^x \Big) O_j^x \Big( 1 - O_j^x \Big) O_j^{x-1} + \alpha \Delta W_{ij}^{x-1}(n) \cdot \cdot \cdot (10)$ 

として計算した.本研究では、Hirano(1991)に従い、 ε=0.75, α=0.8 とした.

以上の修正を繰り返し,誤差評価尺度 Eが 0.001 未満となった時点を学習完了とした.

#### 3.2.3 中間層のニューロン数の設定

ANN の学習は中間層のニューロン数に依存する.数が少ない場合学習時間は早いが,入力の特徴を 把握することが難しい.一方でその数を必要以上に設定した場合,学習時間も長くなるとともに,正しい学習 が得られない.本研究では中間層の数については Kermanshahi(1999)の試行錯誤法に従い決 定した.中間層のニューロン数を10から 100まで 10ずつ増やしていき,学習が収束したときの学習 誤差の値と反復回数を比較することで,最適なニューロン数の評価をすることとした.その結果,以後 ANN の中間層数は 30 とした.

3.2.4 学習データの抽出

#### 3.2.4.1 一段階学習

教師用擬似データ 50 個から学習データを作成した.地震教師データは S 波立ち上がり位置が

200 プロット目にくるウィンドウを切り出した。またノイズ教師データは、地震教師データのウィンドウを - 250 ,+ 250 ,+ 500 プロットずらしたものを選んだ。したがってひとつの地震記録から地震とノイズ 合わせて計 4 つの学習データを作成し,計 200 個の学習データを用いて ANN の学習を行った.学 習データの例を図 6 に示す.



図6:1つの擬似データから作成した学習データ例.aは地震教師データ,b~dは教師データから - 250,+250,+500 プロットずらして作成したノイズ教師データを示す.赤の直線はS波 立ち上がり位置を示す.

#### 3.2.4.2 多段階学習

ノイズ教師データを効率的に抽出するために、学習データを徐々に増加させる多段階学習を行った。多段 階学習は以下の一括学習法と分割学習法の2つの方法を試みた.

一括学習法での学習の流れを図 7 に示すまず学習用擬似データ 50 記録から地震教師データ

50 個( $S_0$ )とノイズ教師データ 150 個( $N_0$ )を作成し, $S_0 \ge N_0$ から ANN の学習1回目 を行う.ここまでは一段階学習と同様である.次に学習済みの ANN で,学習で用いた擬似データ 50 記 録の判定を行い,S 波立ち上がり部分以外で  $F(t) \ge 0.6$  となるときの入力データ全てを,新しくノイズ 教師データ ( $N_1$ ) として学習データに加える.そして  $S_0, N_0, N_1$  を用いて学習 2回目を行う.さら に再度この ANN で教師用擬似データ 50 記録の判定を行い,誤検出した入力データをノイズ教師 データ ( $N_2$ ) として学習データに加え, 3回目の学習を行い,学習を終了する.

分割学習法では山中・他 (2004)にならい、学習用擬似データを分割させ学習することでノイズ教師

データの抽出を行う.学習の流れを図 8に示す.まず学習用擬似データを A(5個), B(15個), C(30個)の 3グループに分割し,各グループから地震教師データ( $S_A, S_B, S_C$ )とノイズ教師デー タ( $N_A, N_B, N_C$ )を作成する.そして  $S_A, N_A$  を用いて ANN の1回目の学習をする.学習済みの ANN で, AとBの判定を行い,S波立ち上が)部分以外で  $F^{[t]\geq 0.6}$  となるときの入力データ全 てを新しくノイズ教師データ  $(N_1)$  として学習データに加える.そして  $S_A, S_B, N_A, N_B, N_1$  を用いて 2回目の学習を行う.今度はこの学習済み ANN を用いて A, B, Cの判定を行い,S波立ち上が) 部分以外で  $F^{[t]\geq 0.6}$  となるときの入力データ全てを新しくノイズ教師データ  $(N_2)$  として学習 データに加える.最後に  $S_A, S_B, S_C, N_A, N_B, N_C, N_1, N_2$ を用いて 3回目の学習を行い,学習を終 了する.

21



図7:一括学習法の流れ



図8:分割学習法の流れ

3.2.5 未知データの判定

前項で示した 3 つの方法で学習させたそれぞれの ANN を用いて,検証用擬似データ 114 記録の判定を行い,S 波到着の波形を識別できるか検証を行った.

未知データの S 波初動検出は,学習済みの ANN に未知データの包絡波形 M(t) を 500 プ ロットずつ入力し,そのときの出力層から得られた値をみて判定を行った.本研究で使用した記録はサンプリ ング周波数が 50Hzより, 0.02 秒間隔の離散データである.つまり始めに入力層の 1, 2~500 の 各ニューロンには M(0.00), M(0.02) ~ M(9.98) の 10 秒間のデータウィンドウの包絡波形 が入力される.次にデータを 1 サンプルずつずらし,入力層に M(0.02) ~ M(10.00) のデータが 入力される.判定したい包絡波形に対しこの作業を繰り返すことで記録の解析をする.出力層からの出力 値  $(O_1, O_2)$  は、Dai and MacBeth (1995)にならい,以下に定義した評価尺度式(11) に代入することで,未知データの評価を得た.F(t)が0.6 以上のとき地震検出とした.

 $F(t) = \frac{1}{2} \left[ O_1^2 + (1 - O_2)^2 \right] \cdot \cdot \cdot (11)$ 

#### 4 検証結果

#### 4.1 中間層のニューロン数

3-1 章で示した教師用擬似データ 50 個を用いて、ANN の学習をさせたこの際、中間層の ニューロン数を 10, 20~100 に変化させて、それぞれの場合で学習の収束状況を確認した.

まず学習収束状況の例として、中間層のニューロン数が 80 のときの学習収束状況を図 9 に示す. 学習誤差は学習反復回数が 30 回程度のとき急激に小さくなり、その後はゆっくりと 0 に近づいている. そして反復回数が 85 回目を迎えると誤差の値は 0.001 を下回り学習か終了している.このように ANN の学習はある地点で急速に収束する傾向がある.本研究ではこの収束するまでにかかる反復回数 が少ない方か効率的に学習できていると考えた.

表2はANNの中間層のニューロン数を10, 20~100と増やした場合の、学習か終了するまでの反復回数、学習誤差が急激に収束するまでの反復回数とそのときの学習誤差値を示している、学習終了までにかかる反復回数が 250回以下と比較的少ないのは、ニューロン数が 30, 40, 60, 80のときであり、そのなかでも学習誤差が素早く収束し、かつ、そのときの学習誤差 値が小さかったものはニューロン数が 30と 60のときであった.

次に ANN の中間層のニューロン数を30, 60 とし、3-2-4-1章で示した一段階学習で学習 させたときの、未知データの判定結果を表3に示す、未知データとして使用した検証用擬似データ 114 のうち、両者どちらも112 の地震を識別することができた.また S 波立ち上がり部分以外を地震として検 出した回数(以降誤検出数と呼ぶ)もほぼ同等であり、地震検出能力に大きな差はみられなかった.よって 以降、計算コストの少ないユニット数 30 を中間層のユニット数として適用した.

25



図9:中間層のニューロン数が 80 のときの学習収束状況

中間層の ニューロン	学習誤差が 0.001未満になるまで	学習誤差が急激ご収束 するまでの反復回数	学習誤差が急激ご収束 したときの学習誤差値
数	の反復回数		
10	1236	8	1.157
20	1161	12	0.731
30	234	11	0.188
40	132	3	0.613
50	反復回数が 4 万回を超えても 0.001まで収束しない	1985	3.938
60	152	12	0.052
70	1121	1121	0.015
80	85	33	0.227
90	372	359	9.89
100	424	415	0.205

#### 表2:中間層のニューロン数が 10~100 における学習の収束状況

	ニューロン数	30		二ユーロン数 60	
地震検出数	未検出数	誤検出数	地震検出数	未検出数	誤検出数
112(	2	68	112(98.2%)	2	65
98.2					
%)					

表3:中間層のニューロン数を 30, 60 としたときの,一段階学習の結果

4.2 地震検出能力

3-2-4-2章で示した一括学習と分割学習それぞれの方法で学習させた ANN を用いて,検証用 擬似データ 114 記録の判定を行った.ただし,一括学習の学習 3回目と分割学習の学習 3回目では, ANN の学習の反復回数が40,000回を超えても学習誤差が 0.001 未満とならなかった.ゆえに学 習誤差が急速に収束した際のパラメータ値を ANN の重さと閾値に適応した.

各学習回数における地震検出数,未検出数,誤検出数の結果を表 4 に示す.

一括学習と分割学習どちらの ANN を用いた場合でも、検証用擬似データのうち 95% 以上を地震と

して識別することに成功したことがわかる.また誤検出数は学習回数が増すにつれ減少した.地震検出結果の例を図 10 に示す.学習 1回目の結果(図 10-c,g)では S 波立ち上かり位置以外でも F(t)値が0.6以上となる部分があり,誤検出箇所が多く存在する.しかし,学習回数が増すと誤検出数は減少し,分割学習の学習3回目(図 10-h)においてはS 波立ち上かり部分のみを検出することに成功している.

一方で表4をみてわかるように、学習回数が増すにつれ、地震検出数はわずかに減少した.

また図 10をみてわかるように、判定値F(t)はS波初動部分だけでなく、その前後の約 3~4 秋こわ

たって  $F(t) \cong 1$  となった.ここで検出位置の正確性を評価するために、ANN による地震の検出時刻 を F(t) > 0.6 かつF(t)が最大となる時刻とし,目視での S波立ち上がり時刻との差を $\Delta T$  とした.一 括学習と分割学習の 3 回目の学習における  $\Delta T$  の平均と標準偏差を表 5 に示す.また図 11 に  $\Delta T$ のヒストグラムを示す.

29

		一括学習			分割学習	
	地震検出数	未検出数	誤検出数	地震検出数	未検出数	誤検出数
学習	112(98.2	2	68	111(97.3%	3	46
1回	%)			)		
目						
学習	110(96.4	4	59	110(96.4%	4	67
2回	%)			)		
目						
学習	110(96.4	4	18	109(95.6%	5	5
3回	%)			)		

表4:検証用擬似データ 114 記録の判定結果

表5:S波検出能力の検証

	<b>ΔT</b> 平均( <b>s</b> )	<b>ΔT</b> 標準偏差( <b>s</b> )
一括学習(学習 3回目)	-1.16	0.64
分割学習(学習 3 回目)	-0.87	0.68

ΔTはANN で検出した S波到着時間と目視で得た S波到着時間との差



図10:地震検出例

a YKN データの M(t)

b擬似データの M(t)

c一括学習の学習1回目のANN で判定した結果 F(t)

d一括学習の学習2回目のANN で判定した結果 F(t)

e一括学習の学習3回目のANN で判定した結果 F(t)

f 分割学習の学習1回目のANN で判定した結果 F(t)

g分割学習の学習2回目のANN で判定した結果 F(t)

h分割学習の学習3回目のANN で判定した結果 F(t)

赤線はS波到着位置を示す



ΔT (s)

b

а



ΔT (s)

図11:  $\Delta T$ のヒストグラム. aは一括学習した ANN での判定における  $\Delta T$ , bは分割学習した ANN での判定における  $\Delta T$ のヒストグラムを示す.

#### 5 議論

ANN の地震検出能力は多段階学習をすることによって誤検出数が減り,地震検出能力が向上した.

これは学習を段階的に分けることでノイズ学習データを効率良く増やせたためだと考えられる.また分割学習は一括学習より誤検出数が少なく,さらに表 5より,目視での 5 波到着時間との差も小さいことから検 出精度が高いといえる.図 12 は学習を繰り返した際に追加されたノイズ学習データの数を示している.追 加されたノイズ教師数の変移をみると,一括学習,分割学習どちらもノイズ教師データの追加数は学習3回 目においてはほとんど差がない.つまり ANN の学習では,学習データ数の多さではなくその選択が重要 であり,分割学習ではノイズ教師データの選択がより効果的に行われたと考えられる.

表6と図 13 に地震検出に失敗した地震を示すまず A, Bの地震においては本研究で検証したど

の ANN を用いても、地震検出をすることができなかった.これらの地震は S 波立ち上かり部分の揺れが 小さい.ゆえにノイズを付加した際に S 波開始地点か曖昧になり, S 波立ち上かり部分の波形の特徴が なくなってしまったため地震検出ができなかったと考えられる.

また表 6 のC, D, Eの地震では、ANN の学習回数が増すにつれ,地震として検出されなくなっ

た. Cの地震はA, Bと同様, S波立ち上がり部分の振幅が小さかったことが原因と考えられる.また DとEは, S波立ち上がり部分において振幅が急激に大きくなり,その後すぐに減少している点が共通し ている.この波形の特徴はノイズ波形によくみられるパターンであり, ANN 学習の過程でノイズとして認識 されるようになってしまったと考えられる.

図14 は検証用擬似データの震度と M(t) の最大振幅を示している。この図より、検出に失敗した地

震は最大振幅が3cm/s<sup>2</sup>以下と小さい点が共通していることがわかる.振幅が小さいとノイズの影響が 大きく出てしまうため検出に失敗したと考えらえる.この問題を改善するには使用するセンサーの性能をあ げるか,機械ノイズを軽減させる必要がある.しかし CSN 普及を目指すにあたりコスト面を考慮すると,前 者の方法は難しい.今後は機械ノイズを軽減するフィルタを開発し,地震検出能力の向上が必要である.

また本研究で開発の ANN ではS波初動部分だけでなく、その前後の約 3~4 秒にわたって

F(t)≅1 となった.つまり入力層の約50~250プロット目にS波の立ち上がり部分が存在したとき、 ANN はすべて S 波初動であると判定した.この検出の幅は多段階学習の回数が進むにつれて狭くなる傾向がある.山中・他 (2004)では学習に用いる地震記録を増やしても地震判定箇所に幅が生じる現象は改善されないとしている.よって多段階学習することでノイズ教師データ数が増えることにより,幅

が狭くなったと考えられる.今後はひとつの地震データから作成するノイズ教師データの数や位置を変える ことによって地震判定箇所の幅を狭めることができないか検証する.また入力層のニューロン数が及ぼす 影響も検証する.



図12:学習回数ごとに追加されたノイズ学習データ数の推移

		最大振幅	震度		一括学習			分割学習	1
	地震発生日時	(cm/s²)		1回目	2回目	3回	1回	2回目	3回目
						目	目		
А	2011/04/11	2.30	1.52	×	×	×	×	×	×
	20:43:34								
В	2011/04/11	1.94	0.96	×	×	×	×	×	×
	18:06:20								
С	2007/08/16	2.63	1.55	0	×	x	×	×	×
	04:15:38								
D	2006/04/21	1.81	0.61	0	×	x	0	×	×
	03:20:45								
Е	2005/03/17	1.83	0.87	0	0	0	0	0	×
	07:41:51								

表6:検出に失敗した地震

#### 2011/04/11 20:43:34

0 1	0	20	30	40	50	60	70	80	90	1
ノイズ付加後 5	M(t)	w/Wimin,	Anthen	man	houras	an ala mana	when	wholema	water	have
0,000,1	0	20	30	40	50	60	70	80	90	1
5-	11	η	I	I	I	1	I	1	I	I
		20	30	40	50	60	70	80	90	1
F(t)学習1-2-	-		1	1		1	1	-		
5- 		1						-	-	
0 F(t)学習1-3	0	20	30	40	50	60	1	80	90	- 10
5-										
0 F(t)学習2-1	0	20	30	40	50	60	70	80	90	1
5-		1M								
0 F(t)学習2-2	0	20	30	40	50	60	70	80	90	1
5-		1	1	1	1	1	1	1	1	
	0	20	30	40	50	60	70	80	90	1
5		1	1	i	i	1	i	1	I	I
1		_	_				_	_		

#### 2007/08/16 04:15:38



#### 2011/04/11 18:06:20

-,,	0.00.20						
ノイズ付加前 M(t)	I	( '	Ann		1		
		mm	www. here	Mann	mm	mm	m
5 5	10	15	20	25	30	35	4(
-	1		4	1		-	
ノイス付加後 M(t)		man	Ana Mar	AL March	mon a mou	~~ · · · · · · /	w
	and a second sec					a contracto	
	10	15	20	25	30	35	40
的学習1-1		15	20				
	'		$\square$				
-		A A					
	1.			1-	1.	1-	1.
) 5)学習1-2 5	10	15	20	25	30	35	40
- 1	1		۸'	1	1	1	1
-			- 11				
) (#201_3 5	10	15	20	25	30	35	40
- 1	1				1	1	1
_							
)	10	15	20	25	30	35	40
)字習2-1				-			
			- A				
_			AV I				
	10			25	20	25	
)学習2-2	10	15	20	2.5			-41
- '							
_							
) 5 1学習2-3 5	10	15	20	25	30	35	4(
- 1	1		1			1	1
-							
5	10	15	20	25	30	35	40

#### 2006/04/21 03:20:45



#### Е

#### 2005/03/17 07:41:51



#### 図 13:判定に失敗した地震 A~Eと判定値 F(t).各地震 の1段目は YKN の M(t).2 段目は擬似データ M(t).3~8 段目は一括学習,2 の学習 1~3 回目 の ANN の判定値 F(t).赤線は S 波到着位置を示 し,緑線は判定基準線である F(t)=0.6 を示す.



図14:検証用教師データの最大振幅と震度.赤点は判定に失敗したデータ.

#### 6 結論

人工ANN を用いた高ノイズ環境下における地震波検出手法を開発するために、ANN による S 波初

動検出のアルゴリズムについて検討を行い、その構造や学習方法の違いによる検出能力を比較、検証した. 検証用のデータには、横浜市強震計ネットワークの強震観測データに CSN センサーユニットのノイズを付加した擬似データを作成し使用した. ANN を学習させる際には、学習を段階的に繰り返し、間違って S波初動と検出してしまった入力波形をノイズ教師データとして抽出することで学習精度を高めることができた. とくに学習に用いる地震データを分割して学習することで、より効率よく学習データセットを作成できること が示唆された、結果、判定した地震のうち 95 %以上を地震として認識することに成功した。しかしノイズの 影響により揺れの小さい地震は、ノイズとして誤検出してしまうことがあった。今後は機械ノイズを軽減する フィルタを開発し、地震検出能力向上を目指す.

#### 7謝辞

本論文を作成するにあたり、ミケレット・ルジェロ教授には研究や発表についてのアドバイスなど丁寧なご 指導をいただきました、心より感謝しております.

また金亜伊准教授には本研究の実施機会を与えていただき、地震学や情報科学の基礎から研究に至 るまで熱心なご指導を賜りました、厚く御礼申し上げます.

そして大変有意義かつ的確なご意見をくださりました吉本和生教授に深謝いたします。

CSN プロジェクトを進めるにあたり、技術、開発などあらゆる面においてご指導いただいた上松大輝さ

ん、竹内達哉さんには大変感謝しております。

ニューラルネットワークの基礎からプログラム設計において,ご助言いただいたミケレット研究室の孫哲さ んに深く感謝いたします.

日々,研究室での学生生活において大変お世話になりました金研究室,吉本研究室,ミケレット研究室の皆様に感謝いたします.

本研究で用いた強震記録は、横浜市強震計ネットワークによるものです、記して感謝いたします、

最後に、執筆に携わってくださった全ての方々に感謝の意を示し、謝辞といたします.

#### 8 文献

芦田譲・佐々宏一 ,1994, ニューラルネットワークによる波形識別 ,物理探査,47,42-48

Dai, H. and C. MacBeth, 1995, Automatic picking of seismic arrivals in local earthquake data using an artificial neural network, Geophys.J.Int., 120, 758-774.

平野廣美,1991, C でつくるニューラルネットワーク,パーソナルメディア.

Kermanshahi, 1999, ニューラルネットワークの設計と応用, 昭晃堂.

金亜伊·上松大輝·岩本穂, 2015, MEMS 加速度センサーユニットを用いた市民参加型地震波計

測ネットワークの構築, IPSJ Interaction, 284-286.

山中浩明・枇谷亜紀・山中伸之,2004, ニューラルネットワークによる強震記録の初動走時の評価-

関東地方周辺での堆積層による走時遅れの推定一,物理探査,57,255-266.

- Yoshida, K.Sasatani, 2005, Issues in an STA/LTA Trigger Algorithm For Strong Motion Observation, Geophysical Bulletin of Hokkaido University, Sapporo, Japan, 69, 85-95.
- 吉田邦一·笹谷努,2006,強震観測における STA/LTA トリガー方式の問題点,北海道大学地 球物理学研究報告,69,85-95.