

ニューラルネットを用いた地電流データからの電車ノイズ除去

小金山 美賀[†] 長尾 年恭^{††} 城 和 貴^{†,††}

短期地震予知の手法として、近年、VAN 法という観測方法で採取された地電流データから地震前兆シグナルを検出し、短期的な地震予知を行う方法が注目されている。しかし、我が国では、地電流データ中の多くを占める電車ノイズの影響で、地電流データから地震前兆シグナルを検出することが困難になっている。そこで、我々は、ニューラルネットを利用して、地電流データから地震前兆シグナルを自動的に検出し、実用的かつ信頼性の高い短期地震予知を行う研究に着手している。本論文では、その第 1 ステップとして、地震前兆シグナルを検出する際に問題となっている電車ノイズを除去するニューラルネットの構築法とその評価について報告する。

Reduction of Train Noise from Telluric Current Data by Neural Networks

MIKA KOGANEYAMA,[†] TOSHIYASU NAGAO^{††} and KAZUKI JOE^{†,††}

The method of detecting seismic electric signals (SESSs) in telluric current data (TCD) observed by the VAN method has attracted notice recently as a method for short-term earthquake prediction. However, since most of the TCD collected in Japan is affected by train noise, detecting SESSs in TCD itself is considered as an extremely arduous job. The goal of this research is to obtain a practicable and reliable method for short-term earthquake prediction by detecting SESSs in TCD using neural networks automatically. In this paper, we describe the method of constructing neural networks to reduce train noise from TCD, which is considered as the main problem for the effective use of the VAN method in Japan, and validate the method by experiment.

1. はじめに

阪神大震災以来、短期地震予知の早期実現が切望されているが、これは旧来の地震学の枠組みの中でとらえた統計的手法を用いたのでは困難であるといわれている¹⁾。そこで、理化学研究所地震国際フロンティア²⁾では、従来までの地震予知の手法とは異なった手法で短期地震予知を行おうとしている。その手法とは、VLF, LF 帯電磁放射観測、大気静電場観測、FM 放送電波による電離層観測、VAN 法^{3),4)}による地電流観測などの電磁気学的手法であるが、その中で我々は、VAN 法による地電流観測に注目している。地電流とは地球表層部に流れる微弱な直流電流のことである。VAN 法を用いて観測される地電流データには、地震

前兆を示すシグナルが含まれていることがあり、このシグナルを利用して短期地震予知を行うことができるのではないかと考えられている。

しかし、我が国で地電流データを利用するためには 2 つの問題点があげられる。1 つは、VAN 法の専門家であれば、実際に地電流データから地震前兆シグナルを認識することは可能であるが、それを時系列データと見なしたときの数理モデル化には至っておらず、また、ここ数年間に我が国で観測された地電流データは膨大な量(アスキー形式で数 TB)にのぼり、手作業によるモデル化はきわめて困難になっているという点である。もう 1 つは、我が国の地電流データには電車によるノイズが多く含まれているという点である。先に、VAN 法の専門家ならば、地電流データから地震前兆シグナルを認識することが可能であると述べたが、実際に識別が可能であるのは電車ノイズが観測されていないときで、電車ノイズと地震前兆シグナルが同時に観測されているときは、VAN 法の専門家であっても地震前兆シグナルを認識することは困難である。一方、地電流データから地震前兆シグナルのような

[†] 奈良女子大学大学院人間文化研究科
Graduate School of Human Culture, Nara Women's University

^{††} 東海大学地震予知研究センター
Earthquake Prediction Research Center, Tokai University

特殊なパターンを検出することは、パターン認識技術にほかならない。これまでに、工学的手法を用いた地電流データの解析は行われていないが、パターン認識のような工学的手法を用いれば、地震前兆シグナルの自動検出が可能ではないかと考えられる。

このような背景から、我々は、地電流データや、地震前兆シグナル、電車ノイズのようなモデル化が困難であるデータを学習させることのできるニューラルネットに注目した。我々は、初の工学的手法としてニューラルネットを用いて、地電流データから地震前兆シグナルを自動的に検出することにより、短期地震予知の自動化の実現を最終目的とした研究に着手している。

本論文では、地電流データ中の地震前兆シグナルの自動検出を行う第1ステップとして、長野県・松代観測点で観測された地電流データから電車ノイズを除去するニューラルネットの構築法と、その実装・評価について報告する。

2. 地電流データ

2.1 観測方法

地電流データは、深さ約 2m に埋設された長さ 40cm、太さ 3cm 程度の鉛—塩化鉛平衡電極を用いて、2 地点間の電位差を測定したものである。測定には同一地点で直交方向に最低 2 本ずつ（合計 4 本）の長さ 30~200m オーダーの測線と、最低 2 本の長さ数 km に達する測線（長基線）が必要であり、図 1 のように配置されている。

データは 10 秒ごとに測定され、1 日 1 回地震国際フロンティアに転送される。長基線観測では NTT 専用回線を導線として使用することによって、遠距離間の地電位差測定を可能にしている。観測点は東海・北陸地方を中心に、平成 10 年度までに 42 地点設置さ

れている。各観測点には、8 本または 16 本の測線がそれぞれ異なった方向に配置されている。これらの測線を dp.1m, dp.2, ..., dp.16 (dp: dipole の略) とする。1 つの観測点に複数の測線を配置しているのは、電極そのもののノイズを評価するためであり、遠方起源の変化はすべての測線に観測されるが、もし平行な測線の片方だけが変化すれば、それは電極そのもののノイズであるということが判断できる。

測定されたデータは、1 日単位で dp. ごとに時系列データグラフで表される。グラフの縦軸は電圧 (mV)、横軸は時間 (×10 秒) を示す。たとえば図 2 は、長野県・松代観測点で観測された dp.2 および dp.7 の地電流データである。dp.2 と dp.7 のデータの大きさが違うのは、電極間の距離と、地下の電気の流れやすさ（電気伝導度）が違うためである。

2.2 電車ノイズ

電車ノイズの発生には規則性があり、形状にも類似性があることから、地電流データとその地電流データが観測された観測点付近の電車の時刻表を利用することによって、電車ノイズを特定することができる。

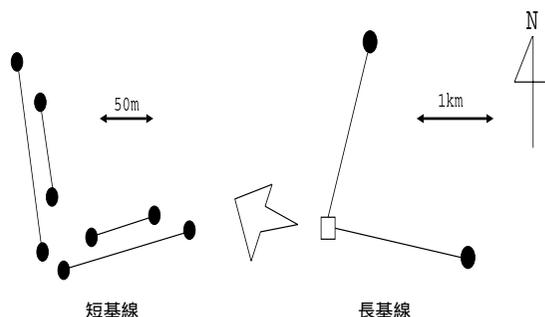


図 1 長基線ならびに短基線の配置図

Fig.1 Arrangement of long and short dipoles.

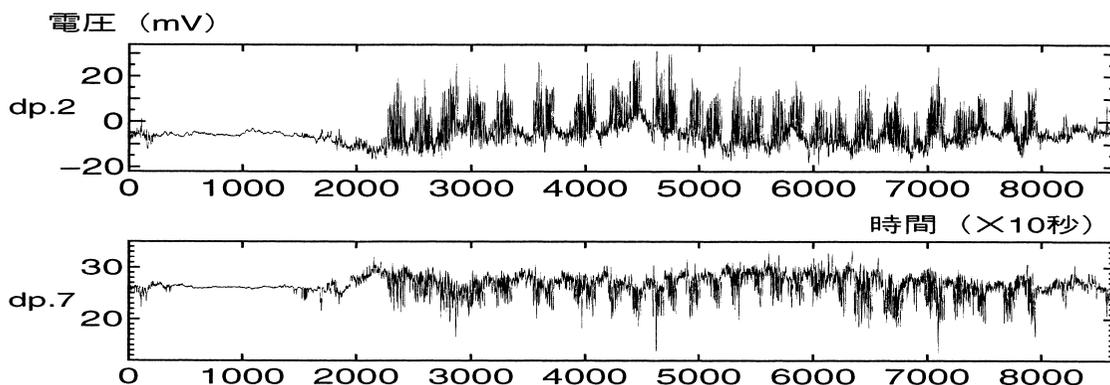


図 2 地電流データ（長野県・松代観測点）

Fig.2 TCD (Matsushiro, Nagano).

表 1 長野電鉄松代駅時刻表

Table 1 Timetable of Nagano Railway Matsushiro Station.

	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
上り	31	10 48	27	7	8	8	15	8	13	13	13	13 53	35	0	39	53
下り	31	10 48	27	7	8	8 55		8 53	53	53	50	53	35	6 37	17	31

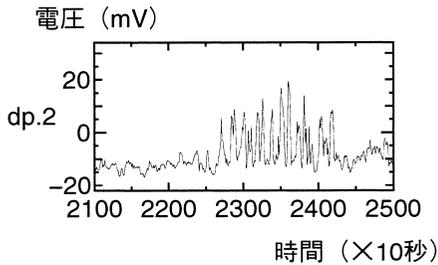


図 3 21,000 秒から 25,000 秒の範囲を拡大した dp.2 の地電流データ

Fig. 3 TCD of dp.2 enlarged from 21,000 to 25,000 seconds.

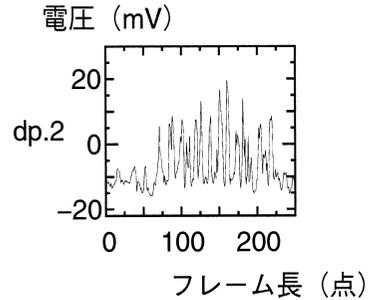


図 4 典型的な電車ノイズ

Fig. 4 Typical train noise.

図 2 の長野県・松代観測点の地電流データは、電車のノイズが最も鮮明に観測されているデータの 1 つである。この地電流データと長野電鉄松代駅の時刻表(表 1)を使うと、松代観測点の地電流データ中の電車ノイズを特定することができる。その方法を松代駅 6 時 31 分発の始発電車を例にあげて説明する。地電流データは横軸 0 秒のときが 0 時を表しているの、6 時 31 分は 23,460 秒となる。松代観測点の dp.2 の地電流データの 21,000 秒から 25,000 秒の部分拡大した図 3 を見ると、22,200 秒から 24,400 秒くらいの範囲に特徴的な波形が現れているのが分かる。この波形が 6 時 31 分の始発電車に該当する電車ノイズである。

図 4 は、dp.2 で観測された松代駅 6 時 31 分発の電車によるノイズをフレームに格納したもので、典型的な電車ノイズを表している。フレームの縦軸は電圧 (mV) を、横軸はフレーム長 (点) を示している。フレーム長は、サンプリングタイム 10 秒とした点の数を表すものとする。典型的な電車ノイズのフレーム長は 120~250 点程度で、時間にすると約 20 分~50 分である。表 1 を見ると、上り電車と下り電車が同時に松代駅を発車しているときがあることが分かる。一般に、上下の電車が同時に発車したときの電車ノイズのほうが、上下いずれかの電車が単独で発車したときの電車ノイズよりもフレーム長が長い。

2.3 地震前兆シグナル

岩石に圧力をかけると、岩石が破壊する前に電流が流れることが室内実験により明らかにされている^{5),6)}。

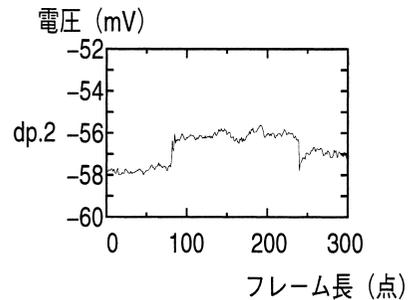


図 5 典型的な地震前兆シグナル

Fig. 5 Typical SES.

地震も一種の岩石破壊現象であるため、大地震が起こる前にも地中に電流が流れると考えられる。我々は、その異常な電流変化を地震前兆シグナルと呼んでいる。VAN 法を用いて地電流データを観測することにより、地電流データから地震前兆シグナルを観測することができるようになった。図 5 は、松代観測点で 1999 年 1 月 17 日の午前 1 時半ごろに観測された dp.2 の地震前兆シグナルをフレーム長 300 点のフレームに格納したものであり、典型的な地震前兆シグナルの波形を表している。典型的な地震前兆シグナルの特徴としては、1) 片振幅の波形である、2) シグナルの立ち上がり方は急激でも、終わりは急激ではない、3) 継続時間は 10 秒から数十分、まれに数時間、といったことが経験的に知られている。

VAN 法によって実際に行われた短期地震予知の例として、1993 年に起こったギリシャ・ピルゴス市の大地震についての予知がある。この地震が起こる前に、

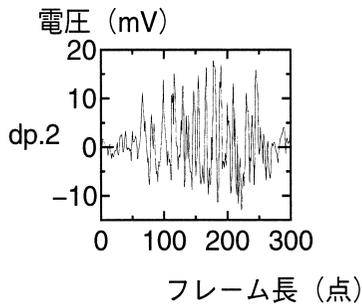


図6 地震前兆シグナルを含んだ電車ノイズ
Fig.6 Train noise adding an SES.

地電流データから地震前兆シグナルが観測されたことから、地震予知情報が流された。その予知情報を受けて、街の住人はあらかじめ避難をしていたため、街の建造物の半分が全半壊したにもかかわらず死傷者は出なかった⁷⁾。このような具体的事例から、VAN法による地震予知がきわめて有効であるということが分かっている。

2.4 我が国でのVAN法利用の問題点

我が国において、VAN法を用いて短期地震予知を行う際の問題点は、地電流データ中に電車ノイズが多く含まれているということである。電車ノイズが多く含まれていると、地電流データ中に地震前兆シグナルが観測されていても、電車ノイズと重なってしまうことが多い。図6は、電車ノイズと地震前兆シグナルが重なっているときのデータである。実際に観測されている地電流データからは電車ノイズと地震前兆シグナルが重なっているデータを見つけ出すことは難しい。そこで、松代観測点の電車ノイズと図5の地震前兆シグナルのデータ値を電車ノイズに対して正規化したものを足し合わせて人工的にデータを作成した。人間の目では、図6を見ても図5のシグナルを認識することはできない。したがって、地震前兆シグナルと電車ノイズが重なっている場合は、地電流データから地震前兆シグナルを発見することはきわめて困難である。

一方、パターン認識技術を用いることによって、特殊なパターンである地震前兆シグナルを、電車ノイズを含む地電流データから自動的に検出することが可能ではないかと考えられる。そこで我々は、パターン認識手法として近年注目を集めているニューラルネットを用いて、地電流データから地震前兆シグナルを検出する手順を提案する。

3. 地震前兆シグナル検出の手順

本研究の基本構想は、過去に採取された地電流データを学習データに使い、同データから専門家の読み

取った地震前兆シグナルを教師信号として与え、未知の地電流データが与えられると地震前兆シグナルを示す場所を検出するニューラルネットを構築することである。しかしながら、本基本構想をそのまま実現するニューラルネットを構築するには、技術的にも理論的にも現実的でない部分があり、きわめて困難である。

本基本構想を実現することが困難な理由として、学習に要する計算量の問題と、実際に存在する学習データセットの数の問題があげられる。まず、学習に要する計算量の問題であるが、学習データである地電流データ量は1日あたりバイナリデータで50MBにのぼり、観測が始まってから現在までの過去4年間ではアスキー形式で数TBに及んでいる。よって、このような莫大なデータをニューラルネットに学習させようとすれば、膨大な計算時間を要するため実質的には不可能である。次に、実際に存在する学習データセット数の問題であるが、全国42カ所の観測点で観測されたデータの中で学習データとして必要な、実際に地震前兆シグナルが観測されているデータの数は限られてくる。実際に我々が調査したところ、十数例しか見つけることができなかった。そのため、これだけの学習データセット数で、ニューラルネットが地震前兆シグナル検出の学習を完了することが可能であるか判断できない。

以上の考察から、本研究では、ニューラルネットによる地電流データから地震前兆シグナルの直接検出ではなく、構造的検出のアプローチをとることにした。構造的検出とは、まずニューラルネットによって地電流データに含まれる電車ノイズを検出し、検出された電車ノイズを地電流データから除去する、次に、電車ノイズが除去された地電流データから、別のニューラルネットにより地震前兆シグナルの検出を行うという手順である。構造的検出で用いる2つのニューラルネットに対しては、1日分の地電流データを一度に入力する必要はなく、フレーム長が数百点程度のフレームをスキャンしたデータを入力とすることで小規模な構成をとることができる。

このような構造的検出の手順を用いることにより、直接検出の手順に比べ計算量は大幅に削減される。また、構造的検出に用いる2つのニューラルネットは独立して学習可能であるため、直接検出の手順よりも柔軟性に富む。

構造的検出の手順を用いるためには、まず地電流データ中のノイズの多くを占めている電車ノイズを

ニューラルネットが認識できるかどうかの検証を行わなければならないが、電車ノイズを学習・認識させることが可能であることは実験により明らかにされている⁸⁾。そこで、構造的検出の第1段階である地電流データから電車ノイズを検出・除去する電車ノイズ除去フィルタをニューラルネットを用いて構築する。

4. 電車ノイズ除去フィルタの構築とその評価

本章では4.1節の要件を満足するニューラルネットによる電車ノイズ除去フィルタの構築法と、その実装・評価について報告する。

4.1 電車ノイズ除去フィルタの要件

- (1) 特定地域の電車ノイズに地震前兆シグナルが混入したデータを入力し、電車ノイズのみを除去して地震前兆シグナルが残ったデータを出力する。
- (2) 入力は固定長の時系列データとし、そのサイズは典型的な電車ノイズと地震前兆シグナルが十分に入る大きさとする。
- (3) 入力フレーム中のどの場所に電車ノイズと地震前兆シグナルがあっても、電車ノイズの除去が可能である。
- (4) 地電流データは直交している2つのdp.で観測されたデータを使う。

上記要件(1)は、電車ノイズ除去フィルタ構築の中心であるが、後述するように学習データをどのように集めるかという問題がある。要件(2)および(3)は、各観測地点で観測される複数の電車ノイズに共通な性質をニューラルネットに学習させ、1日の観測データの上に固定長のフレームをスキャンさせるということである。このように、フレーム内のどこに電車ノイズがあっても除去できるようなニューラルネットを構築した方が、各観測点1日あたり8,640点からなる地電流データを一度にニューラルネットに与えるよりも、学習計算量の観点からも有効と考えられる。要件(4)は、電車ノイズは各dp.によって異なる形状を持つが、地震前兆シグナルはdp.による影響を受けにくいという性質を利用して、電車ノイズ除去を容易にするために必須である。

4.2 地電流データのモデル化

4.1節であげた要件を満足するようなニューラルネットを構築するためには、電車ノイズと地震前兆シグナルが同じ時刻に記録されているデータ(学習データ)と、学習データと同じ観測点、同じ時刻に電車ノイズは記録されず、地震前兆シグナルのみが記録されているデータ(教師データ)が必要である。問題は、この

ような学習データと教師データをどのように集めるかである。地電流データ自体は膨大な量があるが、2.4節で述べたように、電車ノイズと地震前兆シグナルが重なっているようなデータを見つけ出すことは困難であるし、3章で述べたように、実際に地震前兆シグナルが観測されているデータは非常に少ない。また、当該教師データのようなデータはそもそも存在しない。

そこで、我々は、電車ノイズ除去を目的とした地電流データのモデル化を、次のように行った。

$$F(t) = N(t) + T(t) + E(t) \quad (1 \leq t \leq 8640)$$

ただし、 $F(t)$ は電車ノイズと地震前兆シグナルが混在している地電流データの時刻 t における値、 $N(t)$ は時刻 t における電車ノイズにも地震前兆シグナルにも関係しない自然ノイズの値、 $T(t)$ は時刻 t における電車ノイズの値、 $E(t)$ は時刻 t における地震前兆シグナルの値を示す。このモデルは、各 $N(t)$ 、 $T(t)$ 、 $E(t)$ が与えられれば、直流電流の性質としてきわめて妥当である。したがって、電車ノイズ除去後の地電流データを $G(t)$ とすると、

$$G(t) = N(t) + E(t) \quad (1 \leq t \leq 8640)$$

で表される。このとき、電車ノイズ除去フィルタを実現するニューラルネットは、

$$(F(t), F(t+1), \dots, F(t+K-1))$$

を学習データとして受け取り、

$$(G(t), G(t+1), \dots, G(t+K-1))$$

を教師データとして学習を行えばよい。ただし、 K は入力フレーム長である。

4.3 学習および教師データの人工的生成

次に、学習および教師データをどのように確保するかという問題を考えなければならないが、これは4.2節でのモデルにおける $N([t, t+K-1])$ 、 $T([t, t+K-1])$ 、 $E([t, t+K-1])$ を具体的に与えれば解決できる。そこで $N([t, t+K-1])$ 、 $T([t, t+K-1])$ 、 $E([t, t+K-1])$ を人工的に生成する手法について提案する。

まず、電車ノイズが観測される特定の観測点で、地震前兆シグナルの観測されていない日のデータ(たとえば長野県・松代観測点で観測された1999年8月20日のデータ)から、周期が4時間以上である低周波のノイズを、FFTを利用したフィルタにより除去したデータ(以後、これを基礎地電流データ(図7)と呼ぶ)を作る。これはモデルには関係なく、学習の高速化のための前処理⁸⁾である。次に、基礎地電流データの昼間の部分で、電車ノイズが観測されていない区間を抜

以後、 $(X(t), X(t+1), \dots, X(t+K-1))$ を $X([t, t+K-1])$ と表記する。

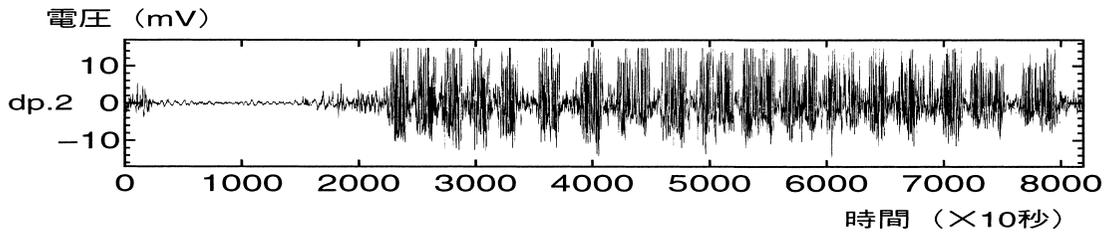


図7 基礎地電流データ

Fig.7 Basic TCD.

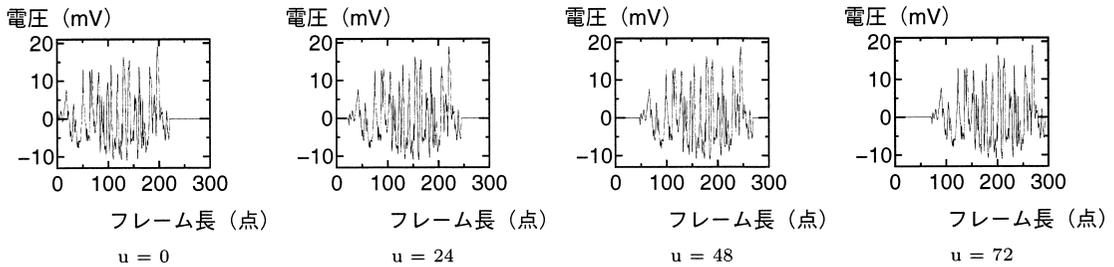


図8 電車ノイズ

Fig.8 Examples of train noise.

き出し、 K 点分適当に切り貼りして $N([t, t+K-1])$ を作成する。 $N(t)$ は人間の生活の影響による電流変化で、ホワイトノイズと仮定する。したがって、现阶段では $N(t)$ の厳密なモデル化は行っていない。

電車ノイズを表す $T([t, t+K-1])$ は、基礎地電流データの電車ノイズ 1 つを選び、 $T([t, t+L-1])$ に格納する。ただし、 L は電車ノイズの長さを表す。このとき、4.1 節要件 (2) より $K > L$ であるため、 $T([t+L, t+K-1])$ はすべて 0 を代入しておく。同様に、地震前兆シグナルを表す $E([t, t+K-1])$ は、基礎地電流データを作成した観測点で、地震前兆シグナルが観測された日の地電流データから地震前兆シグナル部分を切り出し、 $E([t, t+M-1])$ に格納する。ただし、 M は地震前兆シグナルの長さを表す。このとき、4.1 節要件 (2) より $K > M$ であるため、 $E([t+M, t+K-1])$ はすべて 0 を代入しておく。以上により、学習データとして、

$$F([t, t+K-1]) = N([t, t+K-1]) \\ + T([t, t+K-1]) \\ + E([t, t+K-1])$$

それに対応する教師データとして、

$$G([t, t+K-1]) \\ = N([t, t+K-1]) + E([t, t+K-1])$$

を人工的に作成できる。また、 $F([t, t+K-1])$ と $G([t, t+K-1])$ を作成するとき、電車ノイズを $T([t+u, t+u+L-1])$ (ただし、 $u+L < K$) に、地震前兆シグナルを $E([t+v, t+v+M-1])$ (た

だし、 $v+M < K$) に格納して、学習データと教師データを作成し、学習させることにより、時系列の変動に強いニューラルネットが構築できる。

たとえば、 $K = 300$, $L = 200$ として学習データと教師データを作成するとする。 K と L を時間に換算すると、 K は約 50 分、 L は約 33 分である。この 33 分間の電車ノイズを、50 分間の長さのフレーム中の異なった場所に格納する。たとえば、ある時刻 t における電車ノイズを $T([t+u, t+u+L-1])$ ($u = 0, 24, 48, 72$) に格納する。つまり、フレームの一番左端を 0 分 ($u = 0$) とし、4 分 ($u = 24$)、8 分 ($u = 48$)、12 分 ($u = 72$) に電車ノイズの先頭がくるようにそれぞれ格納すると、図 8 のようになる。同様に、同時刻における地震前兆シグナルを $E([t+v, t+v+M-1])$ ($v = 0, 45, 90, 135$) に格納した教師データは図 9 のようになる。ただし、 u と v の値は経験的なことから、学習可能である学習データを作成するための一例であり、最適な学習データを作成するためのものではない⁹⁾。このようにして作成した各電車ノイズに教師データをそれぞれ足し合わせ、学習データを作成する。たとえば、 $u = 24$ のときの電車ノイズに教師データをそれぞれ足し合わせた学習データは図 10 のようになる。

4.4 ニューラルネットの構築と評価

今回の実験で構築したニューラルネットは、三層フィードフォワード型構造で、学習則は誤差逆伝搬法を用いた。学習データと教師データには、長野県・松代観測点で 1999 年 8 月 20 日に観測された地電流データ

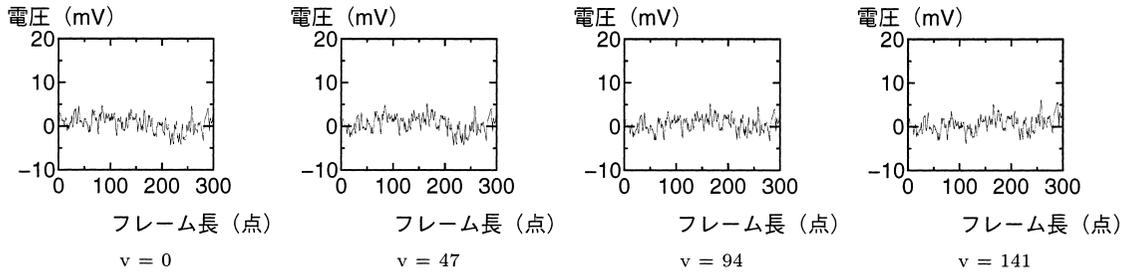


図 9 教師データ

Fig. 9 Supervising samples.

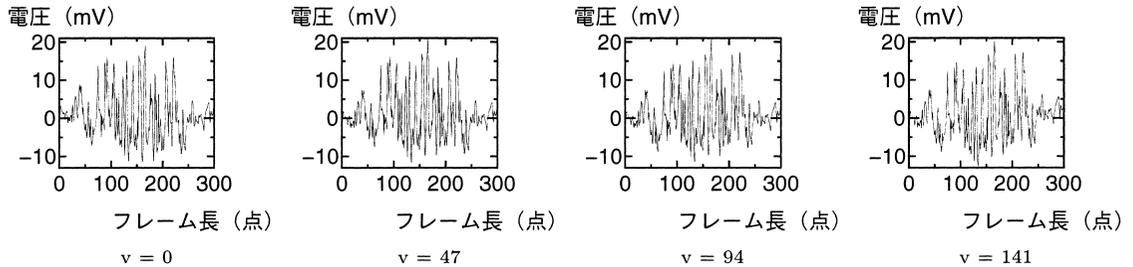


図 10 学習データ (u=24)

Fig. 10 Training samples (u=24).

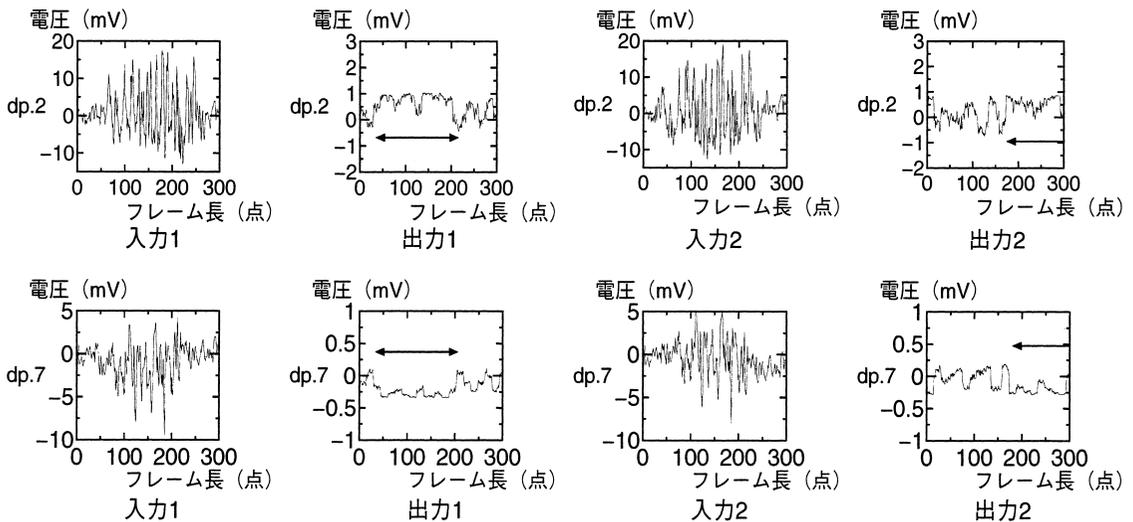


図 11 人工的に生成した地電流データ

Fig. 11 Artificially generated TCD.

と、学習データと同じ松代観測点の同じ dp. で 1999 年 1 月 17 日に観測された地震前兆シグナルを使用した。

松代観測点には、8 つの測線が設けられているが、その中で測線が直交している dp.2 と dp.7 のデータを使用し、2 つの dp. のデータをフレーム長 600 点のフレームに 300 点ずつ格納し、これを入力データとした。よって、入力層のセル数は 600 である。学習データと教師データは、各 dp. で 1999 年 8 月 20 日に観測され

た 24 種類の電車ノイズと、1999 年 1 月 17 日に観測された 1 種類の地震前兆シグナルから、4.3 節で提案した手法を用いて、各 dp. ごとにそれぞれ 1,320 個作成した。ただし、学習データと教師データの数は、この程度のデータ数で学習が可能であるという経験的な判断によるものであり、最適な学習データ数というわけではない⁹⁾。出力層では、入力データから電車ノイズが除去されたデータが、フレーム長 600 点のフレー

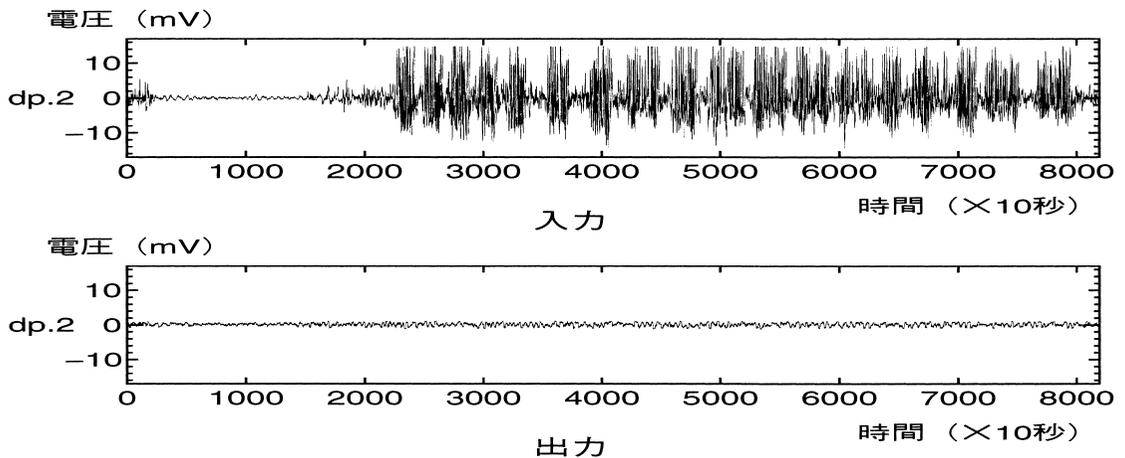


図 12 学習に用いた地震前兆シグナルを含まない地電流データ
Fig.12 TCD for training samples (not adding any SES).

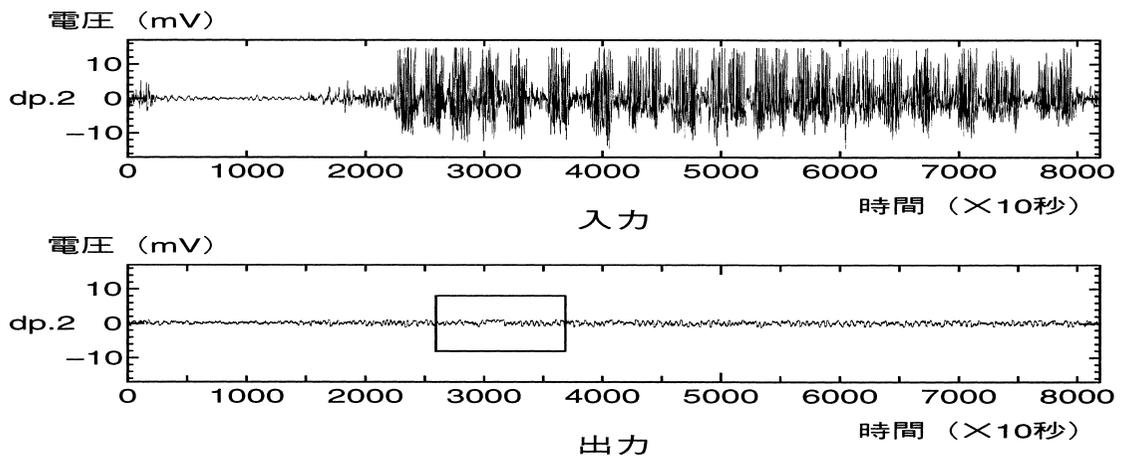


図 13 地震前兆シグナルを混入した学習に用いた地電流データ
Fig. 13 TCD for training samples (adding an SES).

ムに各 dp.ごとに 300 点ずつ出力される．よって，出力層のセル数は 600 である．また，中間層のセル数は経験的な判断から 300 とした．

十分学習が行われた後，次のような 4 つのデータを用いて，ニューラルネットが地電流データから電車ノイズのみを除去することができるかどうかを検証する実験を行った．

- (1) dp.2 と dp.7 の 1 つの電車ノイズと 1 つの地震前兆シグナルを，それぞれフレーム長 300 点のフレーム内に足し合わせて格納し，人工的に生成したデータ
- (2) 学習データとして用いた長野県・松代観測点で観測された 1999 年 8 月 20 日の dp.2 の地電流データ（地震前兆シグナルは含まれていない）

- (3) (2) の地電流データ中の適当な場所に，図 5 の地震前兆シグナルを混入させたデータ
- (4) 未知データである長野県・松代観測点で観測された 1999 年 8 月 23 日の dp.2 の地電流データ中の適当な場所に，図 5 の地震前兆シグナルを混入させたデータ

図 11 から図 15 は，それぞれ上記の 4 つのデータに対する実験結果である．図 11 の入力 1 は，上記データ 1 の地震前兆シグナルがフレーム内におさまっているときのデータで，入力 2 は，地震前兆シグナルの一部分がフレーム内に入っているときである．出力 1，出力 2 は，いずれも矢印の範囲に地震前兆シグナルを残したまま電車ノイズのみを除去したデータを出力している．よって，地震前兆シグナルがフレーム

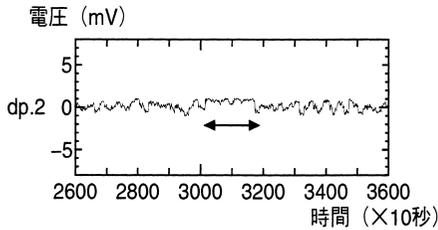


図 14 図 13 の地震前兆シグナルを格納した部分を拡大したデータ

Fig. 14 TCD around the box in Fig. 13 where is added the SES.

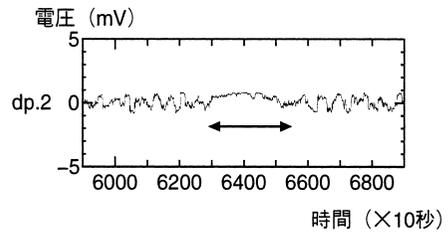


図 16 図 15 の地震前兆シグナルを格納した部分を拡大したデータ

Fig. 16 TCD around the box in Fig. 15 where is added the SES.

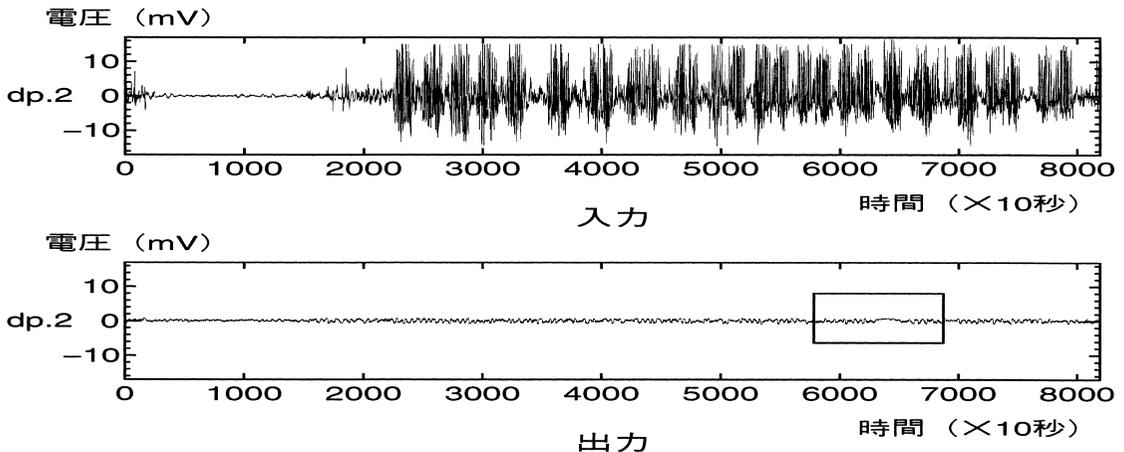


図 15 地震前兆シグナルを混入した未知の地電流データ

Fig. 15 Unknown TCD adding an SES.

内に完全におさまらず、一部分のみの場合でも、このフィルタが適用できることが分かる。図 12 では、上記データ 2 をフレーム長 300 点のフレームでスキャンし、電車ノイズ除去フィルタに入力することによって、入力データから電車ノイズのみを除去したデータを出している。図 13 では、上記データ 3 をフレーム長 300 点のフレームでスキャンし、電車ノイズ除去フィルタに入力した。図 13 の出力データ中の枠で囲んだ部分を拡大した図 14 を見ると、矢印の範囲に地震前兆シグナルを残したままで、電車ノイズのみを除去したデータを出している。さらに、未知データに対する実験として、図 15 では、上記データ 4 をフレーム長 300 点のフレームでスキャンし、電車ノイズ除去フィルタに入力した。図 16 を見ると、矢印の範囲に地震前兆シグナルは残したままで、電車ノイズのみを除去したデータを出している。よって、このフィルタは未知データに対しても適用できることが分かる。

以上の実験から、ニューラルネットによって構築した電車ノイズ除去フィルタによって、地電流データが

ら地震前兆シグナルを残して、電車ノイズのみを除去できることが判明した。

5. 結 論

本研究の最終目的は、ニューラルネットを用いて、VAN 法で観測された地電流データから地震前兆シグナルを自動的に検出することにより、短期地震予知の自動化を実現させることである。そこで我々は、第 1 ステップとして、地震前兆シグナルを検出する際に問題となる電車ノイズの除去がニューラルネットを利用して可能かどうかの実験を行った。その結果、限定された地域の地電流データではあるが、ニューラルネットによる電車ノイズの除去が可能であることが判明した。以上の結果より、3 章で述べた構造的検出の第 1 段階は成功したといえる。さらに、第 2 段階である電車ノイズを除去した地電流データから地震前兆シグナルを検出するニューラルネットを構築することによって、短期地震予知の自動化の実現が期待できる。

今後の課題として、より多くの学習データで十分な

学習を行うことにより、その学習データと同じ観測点で観測されたものの電車ノイズも除去できるようなフィルタを構築すること、さらに、より大規模なニューラルネットを利用することにより、どの観測点で観測された電車ノイズも除去できるフィルタを構築することがあげられる。

また、ニューラルネットによる地震前兆シグナルの直接検出は莫大な計算量を必要とするため、本論文では構造的検出を提案したが、誤差逆伝搬法によるニューラルネットとは別の方法を用いれば、地震前兆シグナルの直接検出が可能ではないかと考えている。たとえば、LVQ (Learning Vector Quantization) は誤差逆伝搬法のように莫大な計算量を必要としないため、有力な手法として検討を行っている¹⁰⁾。

参 考 文 献

- 1) 長尾年恭：地震予知研究の新展開，近未来社 (2001)。
- 2) <http://yochi.iord.u-tokai.ac.jp/>
- 3) Uyeda, S.: Introduction to the VAN method of earthquake prediction, *Critical Review of VAN*, Sir Lighthill, J. (Ed.), pp.3-28, World Scientific, London, Singapore (1996)。
- 4) Nagao, T., Uyeshima, M. and Uyeda, S.: An independent check of VAN's criteria for signal recognition, *Geophys. Res. Lett.*, No.23, pp.1441-1444 (1996)。
- 5) Yoshida, S., Uyeshima, M. and Nakatani, M.: Electric potential changes associated with slip failure of granite, Preseismic and coseismic signals, *J. Geophys. Res.*, No.102, pp.14883-14897 (1997)。
- 6) Yoshida, S., Clint, O.C. and Sammonds, P.R.: Electric potential changes prior to shear fracture in dry and saturated rocks, *Geophys. Res. Lett.*, No.25, pp.1577-1580 (1998)。
- 7) 長尾年恭：地震予知はできるか？—地電流による地震予知，日本混相流学会誌，Vol.9, No.2, pp.98-104 (1995)。
- 8) 小金山美賀，長尾年恭，城 和貴：地電流観測データのニューラルネットワークによる解析，情報処理学会 第 27 回 MPS 研究会，99-MPS-27, Vol.99, No.96, pp.1-4 (1999)。
- 9) Joe, K., Mori, Y. and Miyake, S.: Construction of a Large-scale Neural Network: Simulation of Handwritten Japanese Character Recognition on NCUBE, *Concurrency: practice and experience*, Vol.2, No.2, pp.79-107, John Wiley & Sons Inc. (1990)。
- 10) Fukuda, K., Koganeyama, M., Shouno, H., Nagao, T. and Joe, K.: Detecting Seismic

Electric Signals by LVQ based Clustering, *PDPTA2001*, pp.1305-1311 (2001)。

(平成 12 年 11 月 6 日受付)

(平成 13 年 2 月 13 日再受付)

(平成 13 年 4 月 5 日再々受付)

(平成 13 年 5 月 9 日採録)



小金山美賀 (学生会員)

1977 年生まれ。2000 年奈良女子大文学部情報科学科卒業。2001 年同大学院博士前期課程修了。現在同大学院博士後期課程在学中。短期地震予知，データ解析，パターン認識，ニューラルネット等の研究に興味を持つ。



長尾 年恭

1987 年東京大学大学院理学系研究科博士課程修了。理学博士。1988 年 6 月金沢大学理学部助手。1995 年 12 月東海大学海洋学部助教授。2000 年 4 月東海大学海洋研究所教授，地震予知研究センター長。大学院在学中に第 22 次日本南極地域観測隊・越冬隊 (1981 年 11 月より 1983 年 3 月まで) に参加，昭和基地で越冬。重力，地殻変動観測等に従事。1991 年 11 月より 1 年間，地震予知研究のためアテネ大学物理学部へ留学。専門は固体地球物理学，地震電磁気学，地球熱学。



城 和貴 (正会員)

大阪大学理学部数学科卒業。日本 DEC, ATR 視聴覚研究所 (日本 DEC より出向) (株) クボタ・コンピュータ事業推進室で勤務。1993 年奈良先端科学技術大学院大学情報科学研究科博士前期課程入学，1996 年同研究科後期課程修了，同年同研究科助手。1997 年和歌山大学システム工学部情報通信システム学科講師，1998 年同学科助教授。1999 年奈良女子大学理学部情報科学科教授。工学博士。画像処理，文字認識，ニューラルネット，並列計算機アーキテクチャ，自動並列化コンパイラ，並列計算機の解析モデル，視覚化等の研究に従事。IEEE 会員。