

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

小金山 美賀* 長尾 年恭† 城 和貴*
kogane@ics.nara-wu.ac.jp

* 奈良女子大学 理学部 情報科学科 † 東海大学 地震予知センター

概要

我々は、VAN法を用いて観測した地電流データをニューラルネットワークにより自動的に解析し、短期地震予知を行う研究に着手している。本稿では、予備実験として、地電流データから地震前兆波を検出しやすくするために、地電流データに含まれている電車のノイズ波を学習、識別するニューラルネットワークを構築し、その検証について報告する。さらに、元データにfftを用いたフィルタリングを行うことによって、学習の高速化が可能であるかどうかを検証する。

Geoelectric Potential Data Analysis by Neural Networks

Mika Koganeyama* Toshiyasu Nagao† Kazuki Joe*
* Nara Women's University † Tokai University

Abstract

Aiming at short time prediction of earthquakes by neural networks, we analyse geoelectric potential data observed by VAN method. In this paper, as preliminary experiments, to make easy to find precursors waves of earthquakes, neural networks that learn and recognize train noise are constructed, and the validation is reported. In addition, the possibility of learning speed-up with filtering original data by fft is studied.

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、と言われている。そこで、短期地震予知を行うために、地震国際フロンティアでは、VAN法[1][2]を用いて地球表層部に流れる微弱な電流である地電流データを測定している[3]。VAN法は、従来の地電流観測と大きく異なり、ノイズ除去のために多大の努力を払った地電流観測方法である。地電流観測に含まれるノイズとシグナルを区別するためには、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)が必要となる。これによって、はじめて電極の不安定性や近傍で発生したノイズ、降雨などの影響を除去することができる。ただし、遠方起源のノイズ除去には、解決すべき問題点が残る。現在は、このデータを地震予知の専門家の目で見ることによって、地震の前兆波形を発見し、地震予知を行っている。しかし、現在までに1日40Mバイトの

バイナリデータが4年分、すなわち、アスキーデータで数Tバイトという莫大なデータが集められており、人間の目でそのような莫大なデータをすべて解析することは不可能である。よって、莫大なデータを処理するためには、人間が認識している地震の前兆波形を、何らかの方法を用いてモデル化し、コンピュータによって認識の自動化を行うことが急務の課題である。

本研究グループでは、VAN法を用いた地震予知の自動化を提案している。VAN法を用いて観測した地電流データから、コンピュータによって自動的に地震の前兆波形を検出し、地震予知を行うことを目的として、本稿では、ニューラルネットワークによる地電流データの学習と識別による予備実験について報告する。

地電流データは、一般的に地震の前兆波形だけでなく、地球規模の影響による波形、人間の生活の影響による波形、電車のノイズによる波形など、さまざまな波形で構成されており、その中から地震の前兆波形だけを抽出しなければならない。一般に、1つの母集団のさまざまなカテゴリの中から、特定の

カテゴリーを識別する方法として、2種類のアプローチがある。1つは、特定のカテゴリー以外のものを除去していき、母集団中の特定のカテゴリーが占める割合を増やし、識別させやすくする方法であり、もう1つは、特定のカテゴリーそのものを取り出す方法である。当然のことではあるが、後者では、識別対象のカテゴリーに、極めて顕著な特徴が含まれていなければならない。今回のデータの場合、データの構成波形中の約90%が電車のノイズによる波形であることが分かっている。さらに、地震前兆波形の明確なモデル化もなされておらず、特定するのが難しいため、後者の方法を用いるのは困難である。よって、前者の方法を用いるために、本稿では、電車のノイズをニューラルネットワークにより学習、認識することができるかどうかを実験により検証する。

以下、第2章では、VAN法で得られる地電流データについて説明し、第3章では、電車のノイズ波形を学習、認識するニューラルネットワークの構築法とその実験結果について報告し、第4章では、学習の高速化のための地電流データの前処理について考察する。

2 地電流データ

長さ40cm、太さ3cm程度の鉛-塩化鉛平衡電極が深さ約2mに埋蔵され、2地点間の電位差を測定する。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。平成10年度までに観測点は42地点あり、各観測点は8チャンネルまたは16チャンネルとなっている。図1は長基線ならびに短基線の配置図を示している。




図1: 長基線ならびに短基線の配置図

今回の実験で使用したデータは、電車のノイズがもっとも分りやすく現われている長野県・松代で観測されたチャンネル2の地電流データである。図2に実験で使用した松代の地電流データを示す。また、表1に長野電鉄松代駅の上り及び下りの時刻表を1999年8月20日の示す。これらを照らし合わせると、どの部分が電車のノイズによる波形なのかを見つけることができる。

図2のグラフは1点を10秒として表しているのので、たとえば、始発電車の6時31分、すなわち点2346の前後、点2220から点2440くらいの範囲で波形が変化しているのが分かる。これが電車のノイズによる波形である。




図3: ニューラルネットワーク

3 ニューラルネットの構築と実験

電車のノイズ波形を学習、認識させるためのニューラルネットワークとして、本稿では、古典的な三層フィードフォワード型を採用し、学習則はバックプロパゲーション法を用いた。入力層は、地電流データの連続する時系列データを受け取り、出力層では、それぞれ上り電車、下り電車、電車なしの3状態を出力するものとする。

3.1 入力層・中間層・出力層の構成

入力データとしての松代の1999年8月20日チャンネル2のデータを使用する。2で示したグラフと時刻表を用いて、電車のノイズが現われている範囲を

0時0分 2時46分4秒 5時33分2秒 8時20分 11時6分4秒 13時53分2秒 16時40分 18時26分4秒 22時13分2秒




図 2: 松代の地電流データ

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

表 1: 長野電鉄松代駅時刻表

切り取り、その部分のデータ値を入力値とする。入力データ数、すなわち入力層のセル数は 300 とし、切り取った範囲のデータ数が 300 に満たない場合は 0 詰めにして、基本学習データとする。多くの場合、1 回当たりの電車のノイズは 300 フレームよりもかなり少ない。その電車ノイズに相当するフレームのみを用いて学習させたのでは、学習終了後のニューラルネットワークが時系列の変動に弱いものになってしまう [4]。そこで、入力層 300 フレームに対して、基本学習データのある一定間隔ずつずらして、300 フレームすべてに対して、学習データが入力されるような学習データセットを作成した。この学習データセットで学習させることにより、時系列変動に強いニューラルネットワークが構築される。中間層のセル数は、経験的なことから判断して、入力層のセル数の半分の 150 とした。出力層で識別したいことは、上り電車によるノイズが現われたとき、下り電車によるノイズが現われたとき、電車によるノイズが現われていないときの 3 状態であるため、出力層のセル数は 3 とした。それぞれの出力セルは、該当する部分の出力値が 1、それ以外は 0、上り下りの電車両方によるノイズが現われたときは、上り電車によるノイズが現われたときと、下り電車によるノイズが現われたときの両方の出力値が 1 となるように学習される。

3.2 実験

3.1 で準備した入力データの input.dat ファイルと、教師データの teach.dat ファイル、入力セル数、中間

セル数、出力セル数などを定義した system.dat ファイル、ウェイトの学習係数や、慣性係数の増分などのパラメータ値を定義した param.dat ファイルを用意し、これらのファイルを用いて、ニューラルネットワークで、総誤差が 0.001 以下になるまで繰り返し学習をさせた。ウェイトの初期値は乱数で与えられ、パラメータ値はオンラインで変更できるようにした。また、100 イタレーションごとにその時点での学習回数と誤差を error.dat ファイルに記録するようになった。

実験の結果、誤差が 0.001 以下になったのは学習回数 7023 回のときであった。このときのウェイト値を用いて、学習データに対して、認識実験をしたところ、正解率は 100%であった。

次に、同じ松代で観測されたチャンネル 2 の違う日、1999 年 8 月 21 日と 1999 年 8 月 22 日の全時系列データを 300 フレームずつ入力、さらに、それを 10 ずつずらして入力していったときのそれぞれの出力値と時刻表とを比較して認識率を求めると、8 月 21 日のデータでは 95.7%、8 月 22 日のデータでは 99.0%となった。

以上の実験結果より、ニューラルネットワークで電車のノイズを学習し、認識することが可能であることが分かった。

4 学習の高速化

地電流データの構成波形には、地球規模の影響による波形、人間の生活の影響による波形などの地震




図 4: フィルタリング処理後の新しいデータセットのグラフ

とは直接関係のない余分な波形も含まれている。よって元データに何らかの前処理を加え、余分な波形を取り除くことによって学習を高速化することができる可能性がある。

前処理の方法として、fft を用いたフィルタリングを行う。fft とは離散フーリエ変換の一種で、fft を用いることによって元データを周波数領域で表し、周波数領域で処理することによって、特定の波形を容易に取り除くことができる。そこで、fft を用いてハイパスフィルターとローパスフィルターを構築し、元データに適用することで、電車ノイズ波に直接関係がないと思われる周期 81920 秒から 79.380 秒の周波数成分と、10.315 秒から 10.004 秒の周波数成分を除去し、新たなデータセットを作成した。図 4 に新しいデータセットのグラフを示す。3 で行った実験の中間層のセル数を 150 から 5 にし、15000 回学習させ、オリジナルデータで学習を行った場合と、新しいデータセットで学習を行った場合の学習データに対する認識率をそれぞれ求めると、オリジナルデータの場合は 56.7%、新しいデータセットの場合は 65.1% となった。

実験の結果より、認識率を比較すると、オリジナルデータよりも、新しいデータセットで学習を行った場合のほうが、同じ学習回数でも認識率が高くなっていることから、元データから電車ノイズ波以外の余分な波形を取り除くという前処理を行うことによって、学習の高速化が達成されたといえる。

5 結論

VAN 法によって観測された地震予知用の地電流データに対して、ニューラルネットワークを用いて、地震の前兆波形を検出する方法を提案した。我が国においては、電車のノイズが非常に大きいため、地震の前兆波形を検出するのが困難であると予想された。そこで、ニューラルネットワークが電車のノイズを認識し、それを取り除くことで地震前兆波形を

検出しやすい新たなデータを生成することが可能であることを実験的に示した。さらに、fft を用いて、ハイパスならびにローパスのフィルタリング処理を行い、電車ノイズ波以外の余分なデータを取り除くことによって、ニューラルネットワークの学習の高速化が可能であることを示した。

今後の課題として、どのような電車のノイズでも除去できるようなニューラルネットワークを構築し、地震の前兆波形を検出しやすい新たなデータを生成し、そのデータを用いて地震の前兆波形を識別するようなニューラルネットワークを新たに構築する。これらを統合的なニューラルネットワークにし、地震予知を行うことがあげられる。

参考文献

- [1] VAROSTOS, P and K. ALEXOPOULOS: *Physical properties of the variations of the electric field of the preceding earthquakes, I.* Tectonophysics, No.110, pp.73-98 (1984a).
- [2] VAROSTOS, P and K. ALEXOPOULOS: *Physical properties of the variations of the electric field of the preceding earthquakes, II, Determination of epicenter and magnitude.* Tectonophysics, No.110, pp.95-125 (1984b)
- [3] 上田誠也: 地電流による地震予知, 固体物理, Vol.25, No.4 (1990).
- [4] Erik McDermott, Hitoshi Iwamida, Shigeru Katagiri, Yohichi Tohkura: *Shift-Tolerant LVQ and Hybrid LVQ-HMM for Phoneme Recognition*, Readings in Speech Recognition, Morgan Kaufmann, pp.425-438 (1990).