

(8) 弾性波探査におけるニューラルネットワークを用いた波形処理について

（株）間組技術研究所 正会員 ○ 京極孝子  
同 上 正会員 平井光之  
同 上 正会員 蓮井昭則

Waveform Data Processing by Neural Network on Seismic Survey

Takako KYOUGOKU, HAZAMA CORPORATION  
Mitsuyuki HIRAI, HAZAMA CORPORATION  
Akinori HASUI, HAZAMA CORPORATION

Abstract

On waveform data processing, it is important to discriminate useful data from noises. However, in much noisy condition, that is too difficult. For example, to detect P-wave arrivaltime analytically in such condition usually results in error. In this report as one of the method to make good use of expert's judgement, the applicabilty of neural network to above problem was investigated.

As a result, it was proved that neural network could recognize the intensity of signals and pick up P-wave arrival point. We think that neural network is usefull to process waveform data.

1. まえがき

弾性波探査においてノイズの多い環境下で得られた波形データは、一様なフィルタ処理で対応しきれない非定常な乱れを持つため、信頼性の点から初動読み取り等の波形処理は依然として人手に頼らざるを得ない。この問題に対し、現在各方面で研究が進められているニューラルネットワークを利用して波形の自動処理を行える可能性がある。

ニューラルネットワーク情報処理は、脳の持つ優れた情報処理能力の人工的実現を目指したものでありパターン認識等のように定式化が困難な問題の解法として期待されている。本報告は、その第一段階として、P波到達点を検出するネットワークを試作してニューラルネットワークの波形認識能力を評価するものである。

2. ニューラルネットワークの概要

階層型ニューラルネットワークは以下に示すような基本構造を持つ。

- ① 入力層、出力層、複数の中間層で構成される多層構造である。
- ② 各層は複数の細胞（ニューロン）から成る。




図-1：階層型ネットワークの例

③ 隣り合う層は、細胞間のシナプス結合で結ばれている。

ネットワークに入力したデータ（入力信号）は、シナプス結合での重み付け（シナプス荷重）と各細胞における出力調整を受けながら、出力層に向かって伝達される。細胞ごとの信号の入力、出力を図-2に模式図で示す。また、その入出力特性は次式で定義される。

$$S_{out} = \frac{1}{1 + \text{EXP}(- (S_{in} - \theta))}$$

$$S_{in} = \sum_{i=1} W_i X_i$$

- $S_{out}$  : 入力する信号の和
- $S_{in}$  : 出力される信号
- $X_i$  : 下層の各細胞から出力された信号
- $\theta$  : しきい値
- $W_i$  : シナプス荷重

ここで用いたバックプロパゲーションと呼ばれる学習則では、入力信号に対する望ましい出力（正解=出力教師信号）と自らの出力の二乗誤差を極小化するように全シナプス荷重を変化させる。図-3に学習の流れを模式図で示す。この学習を様々な入力信号について繰り返すことにより、特定のパターンで出力するネットワークが構築される。

### 3. P波到達点検出システム

本報告で試作したネットワークは図-4に示すように、各層50個の細胞を持つ4層構造である。このネットワークにデータ長50ポイントの波形の振幅値を入力すると、P波到達点でピークを持つ関数を出力するようにシステムの学習を進めた。

入力信号には、既に人手によりP波到達点を読みとった孔間弾性波探査およびAE計測の実測波形データを用いる。これらのデータを主に振幅の変化に注目して検出させるために振幅値の絶対値をとり、P波到達点を含むように50ポイントの長さで切り出す。これに対し、出力教師信号は、P波到達点でピークを持つ関数とし、入力信号と組み合わせる。




図-2 : 細胞における信号の入出力

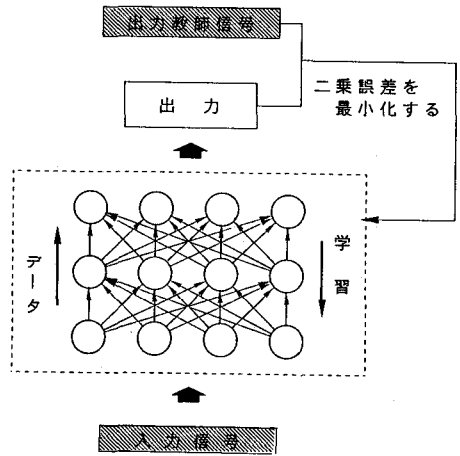


図-3 : 学習システム

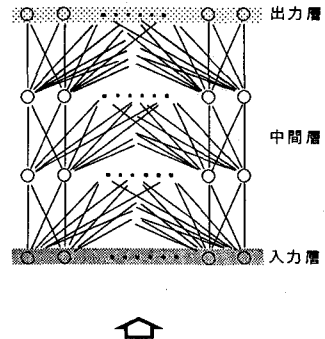


図-4 : P波検出ネットワークの構造

これらの入出力信号の組を、5～45ポイントの範囲でランダムにピークが分布するように1000組作成し使用した。

更に、5～45ポイントの範囲外でピークを出力させないために、ノイズ区間およびP波区間のみから切り出した入力信号に出力0の教師信号を与えたデータを200組作成し、追加使用した。

同一データに対する学習は、二乗誤差が一定値を下回るまで繰り返され、平均学習回数は10～20回程度である。全体の学習は、二乗誤差の変動が少なくなった時点で打ち切り、総学習回数はおよそ2万回であった。




図-5：学習に用いた入出力信号

#### 4. P波到達点検出結果

学習終了後のニューラルネットワークに前節で述べた入力波形を1000個与え、P波到達点の検出精度を評価する。ネットワークによるP波の検出点は、出力のピーク点と定義した。図-6に検出結果の例を示す。

1000個の入力波形において、検出値の正解（出力教師信号）に対する誤差は図-7のような分布を示す。入力波形の約50%において、誤差は±3ポイント以内に収まり、ネットワークが振幅の変化に対応して、P波到達点を検出する事が確認された。

図-8では人間が読み取った結果とニューラルネットワークの検出結果を比較する。縦軸・横軸共にP波到達点が生頭から何ポイント目に位置するかを表している。P波到達点が波形前半部にある場合、検出結果のバラツキが大きいのが、後半部に関しては比較的良い対応が見られる。




図-6：P波到達点検出結果例




図-7：検出値の誤差分布




図-8：検出値と正解の相関

図-9に学習が進んでいく過程で、P波到達点の検出を行った結果を示す。学習開始直後は、一点でしかP波到達点を検出しないが、徐々に波形全体で正しい検出を行うようになる。図-8に検出点が特定のポイントに集中し直線状に分布して見られるが、これは学習の過程で、ネットワークが局所的な最適解に収束してしまったため、ピークの現れ易い点が発生し、改善されずに残ったと考えられる。

### 5. 数学モデルとの比較

地震学の分野等では、時系列データを統計学的に処理することにより、P波到達点を自動検出する方法が採用されている。この手法のうち、横田らが提案したARモデル法のMUPEO<sup>1)</sup>と呼ばれるP波自動検出方式とニューラルネットワークの性能を比較してみる。MUPEOは、波形最前部のノイズをモデル化し、そのモデルから予測される推定値の誤差の時系列において、P波が混入したために現れる異常をP波到達点として検出する方法である。

MUPEOとニューラルネットワークに、同一の入力波形を20個与え、P波検出を行う。MUPEOには、ノイズのモデル化と予測誤差の計算のため、ニューラルネットワークより長い100ポイントのデータを与えるが、検出は同じ50ポイントの区間で行う。

両者の検出値の誤差分布を図-10に示す。両手法の誤差分布には顕著な差は見られない。ARモデル法では、S/N比の良好な波形においてP波到達点を高精度で検出するが、波形最前部以外のノイズ区間に非定常な乱れがあったり、S/N比が極端に低い場合、大きな誤差を生じる。一方、ニューラルネットワークでは、P波到達点付近で複数のピークを出力するケースがあり、検出値にバラツキをもたらす。しかし、このバラツキの範囲は狭く、ARモデル法よりも良好な結果を示す場合もあった。

P波検出能力に対し、処理能力の比較を行う。パソコン上での処理速度は、1データにつき、ニューラルネットワークでは1~2秒、MUPEOではノイズのモデル化を含めて約10秒程度かかる。ニューラルネットワークは学習に多くの時間を必要とするが、一度ネットワークを構築すると全てのデータに対応可能であるという利点を持ち、その処理速度の早さから、より大量のデータに対処可能であると考えられる。

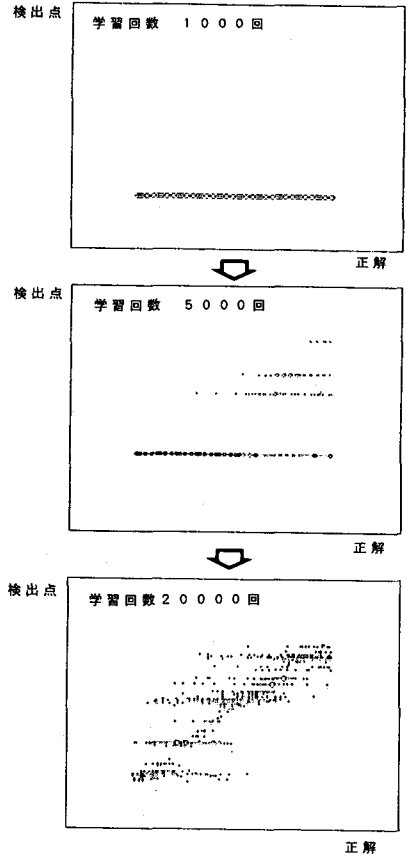


図-9：学習進行に伴う検出能力の向上




図-10：ARモデル法との比較

## 6. まとめ

P波検出結果から、信号の強弱の系列を認識するニューラルネットワーク構築が可能であると言える。しかし、P波検出システムを実際に適用する場合、試作したネットワークでは、取り扱うデータの長さが短く、精度も不十分である。現時点では図-11のように、P波到達点をしきい値設定等で予備検出するシステム、および検出結果の信頼性を判定するシステムと組み合わせる必要がある。

50ポイント以上の長さのデータを判定するような大規模ネットワークを作成するためには、学習時に膨大な量の入出力信号と多くの時間を必要とする。更に、このように大きなネットワークでは、学習を繰り返してもなかなか性能が向上しない。これは、入力信号のP波到達点を出力信号のピーク位置で検出する方法では、入力層と出力層の細胞は同数になり、従って取り扱うデータが長くなるにつれ、ネットワークは複雑化して学習の進行が困難になるためと考えられる。同じ数の入力細胞を持つネットワークでも、ノイズか、有用な信号かを判定する二者択一問題のように出力細胞の数が少なければ、ネットワークの複雑さは出力側で減少する。このように、検出方法を簡略化すれば、入力側で取り扱えるデータの量が増加する可能性は高く、ニューラルネットワークによる自動P波検出システムの実用性は向上すると考える。

## 7. あとがき

今回、試作したニューラルネットワークは、信号の強弱を認識して振幅値の異常分布の始まりを検出することに成功した。ARモデルとの比較からも検出能力の妥当性は評価されたと考える。しかし、信頼性や検出方式等の点で様々な課題が残されており、今後、より高性能のネットワークを構築する際、学習条件や出力教師信号の与え方、ネットワークの構造等に、何らかの改善を加える必要があるだろう。

- 参考文献：1) 横田崇，溝上恵，中村功：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，地震研究所彙法，55，1981  
2) 合原一幸：ニューラルコンピュータ，東京電気大学出版局  
3) 麻生英樹：ニューラルネットワーク情報処理，産業図書  
4) 横山博文：神経回路網の地震処理への適用，地震学会予稿集，No. 2，1998  
5) 赤池弘次，中川東一郎：ダイナミックシステムの統計的解析と制御，サイエンス社  
6) 日野幹雄：スペクトル解析，朝倉出版

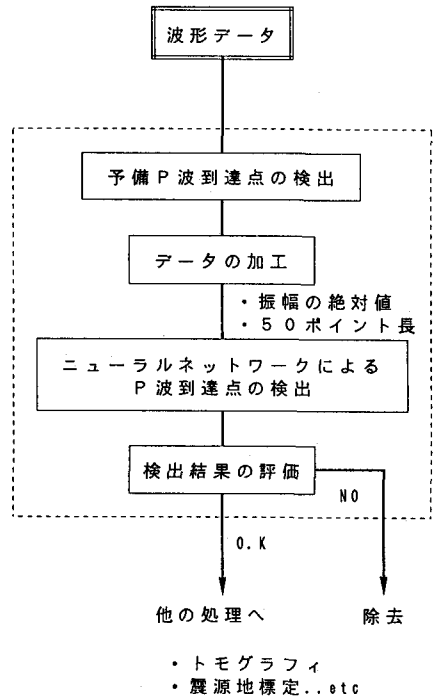


図-11：P波検出システム例