論 文

ニューラルネットワークによる岩相解析

芦田 讓*・伊藤 晃**

(Received September 22, 1995 ; accepted July 26, 1996)

Well log analysis by use of neural network

Yuzuru Ashida and Akira Itoh

Abstract : The present paper proposes the algorithm for well log data analysis by use of neural network.

The designated network is the layered network which consists of an input layer, one hidden layer and an output layer. The unit numbers of input layer and output layer are equal to well log curve to be inputted and the lithology to be outputted, respectively. The well log analysis procedure by use of neural network is divided into two stages, that is, training period and recognition period. During the training period, the initial weights which combine the units in each layer with those in the previous layer, are modified using the error back propagation algorithm so as to minimize the difference between the teacher's signal and the actual signal from output layer. The training period continues until the designated training counts are reached, or the residual between the teacher's signal and the actual signal from output layer becomes smaller than the designated value. After the completion of training period, the network is ready to analyze the new input data using the weight values.

As a result of studies using the synthetic and the actual data, it was clarified that the proposed algorithm analyzed the well log data with good accuracy.

Key words : Well log, Log analysis, Neural network

1. 緒 言

近年、高度な数学的手法を用いて、現象をできるだけ正確に記述し、それを解いていくという従来の情報処理技術とは異なる新しい情報処理の研究が盛んに行われている。例えば、人間の神経細胞の機能を模したニューラルネットワーク、主観的な判断能力に基づいたファジィシステム、生物の進化のメカニズムをヒントにした遺伝的アルゴリズムなどがある。このうち、ニューラルネットワークの研究は、1940年代初めから行われ、パーセプトロンの出現によりピークを迎える。しかし、Minsky

らによりパーセプトロンの限界が指摘され、一時その研究は停滞状態に入る。その後、1980年代に Rumelhart らによる誤差逆伝播の研究や、Hopfield の相互結合型ネットワークの提案により再び研究は隆盛となり現在に至っている。

ニューラルネットワークの適用分野としては、制御、パターン認識、力学的挙動のモデリングおよび最適化問題などがある。

本論文では、まず、誤差逆伝播アルゴリズムによる学習機能付の階層型ニューラルネットワークについて紹介し、ついで、検層データからの岩相判定について述べる。

2. ニューラルネットワークとは

ニューラルネットワークの種類としては、階層型と相互結合型がある。階層型ネットワークは、通常、各々 1

* 京都大学工学部 Department of Engineering, Kyoto University

** 京都大学大学院 Graduate School of Engineering, Kyoto University

個の入力層と出力層および単数もしくは複数個の中間層あるいは隠れ層で構成される。各層は神経細胞のニューロンに相当するユニットが階層状に並び、階層内のユニット間の結合はなく、階層間における結合は入力層から出力層へと進行する。一方、相互結合型ネットワークは、任意のユニット間に両方向の結合があるものである(麻生, 1988; 市川, 1993; Russell and Jackson, 1993)。

いま, m 層からなる階層型ネットワークを考え, Fig. 1 に示すように, 第 $k-1$ 層の第 i ユニットの第 k 層の第 j ユニットの結合の重みを $W_{ij}^{k-1,k}$, 第 k 層の第 j ユニットの入力値の総和を I_j^k , 出力値を O_j^k , しきい値を θ_j^k とする。層間のユニットの結合は, 前の層の各ユニットからの出力値に重みをかけたものの総和としきい値との差を, ある応答関数に通して出力する。入出力の応答関数を f とすると, 階層型ネットワークのアルゴリズムは (1) 式で表される。

$$\left. \begin{aligned} I_j^k &= \sum_i W_{ij}^{k-1,k} O_i^{k-1} - \theta_j^k \\ O_j^k &= f(I_j^k) \end{aligned} \right\} \quad (1)$$

ここでは, 応答関数として (2) 式で示されるシグモイド関数を用いる。

$$f(x) = 1 / \{1 + \exp(-x)\} \quad (2)$$

(1) 式のしきい値については, 出力層を除く各層に常に 1 を出力する特殊なユニットを設け, それを第 0 ユニットのすれば, 第 k 層の第 j ユニットのしきい値 θ_j^k は (3) 式で表される。

$$\theta_j^k = -W_{0j}^{k-1,k} \quad (3)$$

3. 誤差逆伝播による学習アルゴリズム

特定の問題を解くための固定したアルゴリズムを組み込んだ従来の伝統的な計算機プログラムと異なり, ニューラルネットワークによる処理では適切な解答に近

Fig. 1 Schematic map of relationship among input signal, output signal and threshold value to some unit.

づくような学習アルゴリズムを用いる。学習のアルゴリズムはネットワークにすべての入力と正解(教師信号)とを提示し, 出力層からの実際の出力と正解との差が最小になるように, 各ユニット間の重みの値を変化させていくものである(麻生, 1988)。

いま, 出力層のユニットからの出力 O_j^m と正解 y_j との誤差のエネルギー r を (4) 式で定義する。

$$r = \sum_j (O_j^m - y_j)^2 \quad (4)$$

r が最小になるように, 最急降下法により重み W を ΔW だけ修正する。 ΔW は ε を微小量として (5) 式で表せる。

$$\Delta W_{ij}^{k-1,k} = -\varepsilon \partial r / \partial W_{ij}^{k-1,k} \quad (5)$$

(5) 式中の $\partial r / \partial W_{ij}^{k-1,k}$ は (1) 式より

$$\begin{aligned} \partial r / \partial W_{ij}^{k-1,k} &= (\partial r / \partial I_j^k) (\partial I_j^k / \partial W_{ij}^{k-1,k}) \\ &= (\partial r / \partial I_j^k) O_i^{k-1} \end{aligned} \quad (6)$$

である。さらに, (6) 式中の $\partial r / \partial I_j^k$ は

$$\begin{aligned} \partial r / \partial I_j^k &= (\partial r / \partial I_n^{k+1}) (\partial I_n^{k+1} / \partial O_j^k) (\partial O_j^k / \partial I_j^k) \\ &= \sum_n (\partial r / \partial I_n^{k+1}) W_{jn}^{k,k+1} f'(I_n^k) \quad (k \neq m) \end{aligned} \quad (7)$$

$$\partial r / \partial I_j^k = 2(O_j^m - y_j) f'(I_j^m) \quad (k = m) \quad (8)$$

である。 $\partial r / \partial I_j^k = d_j^k$ とおき, 学習信号と呼ぶと, 修正量 ΔW は (9), (10), (11) 式で計算できる。

$$\Delta W_{ij}^{k-1,k} = -\varepsilon d_j^k O_i^{k-1} \quad (9)$$

$$d_j^k = (\sum_n W_{jn}^{k,k+1} d_n^{k+1}) f'(I_j^k) \quad (10)$$

$$d_j^m = 2(O_j^m - y_j) f'(I_j^m) \quad (11)$$

また, (10), (11) 式中の $f'(I_j^k)$ および $f'(I_j^m)$ は, (2) 式から

$$O_j^k = f(I_j^k) = f(x) = 1 / \{1 + \exp(-x)\}$$

だから

$$f'(x) = f(x) \{1 - f(x)\} = O_j^k (1 - O_j^k) \quad (12)$$

で求められる。

誤差逆伝播のアルゴリズムは以下のとおりである(芦田・佐々, 1994)。

- (1) 複数個の入力データとそれに対する正解を用意する。
- (2) 各ユニット間の重みの初期値を与えて, ネットワークを作動させて出力層からの出力値を得る。
- (3) (11), (12) 式から出力層における実際の出力値 O_j^m と正解 y_j より d_j^m の値を求める。
- (4) (10) 式を用いて, 各層の各ユニット間の学習信号 d_j^k を得る。
- (5) (9) 式より各ユニット間の重みの修正値 $\Delta W_{ij}^{k-1,k}$ を計算する。

実際の重みの値の修正においては, 局所極小値に陥るのを防ぎ, かつ収束を速めるために (13) 式のモーメント法を用いる。

$$\Delta W_{ij}^{-1k}(t+1) = -\alpha d_j^k O_i^{-1k} + \beta \Delta W_{ij}^{-1k}(t) \quad (13)$$

ここで、 t は修正の回数であり、 α は学習レートパラメータ、 β はモーメンタムパラメータと呼ばれる小さな定数である。本論文においては、各ユニット間の重みの初期値は $-0.3 \sim 0.3$ の間の一様乱数により設定し、学習レートパラメータ α は 0.1 、モーメンタムパラメータ β は 0.9 とした。

ニューラルネットワークにおける学習のアルゴリズムにおいて最も重要なことは、各ユニット間の重みの初期値をいかにしてランダムに与えるかということ、および複数個の入力データを学習させるときに、いかにして学習をランダムに行うかという点である。これらをランダムにすることは、各ユニットの機能分化を促すために必要である(麻生, 1988)。

4. 適用例

ニューラルネットワークの適用において重要なことは、適用しようとする対象データに対してどのようなネットワークを構築するか、また正解(教師信号)をどのように与えるかということである(芦田, 1995)。検層データによる岩相判定のためのネットワークとして、入力層のユニット数は検層種目の数、出力層のユニット数は判定する岩相の種類に設定する(McCormack, 1991)。岩相判定は、出力層のユニット中で最大の出力を与えるユニットにあらかじめ指定された岩相により判定する方法と中間的な岩相の判定の場合には、出力値の最大値ではなく、出力値の大きさの比率で判断する方法とがある。中間層の数およびそのユニット数は、学習に必要な計算時間および学習後のネットワークの判定能力により決定する。

4.1 検層種目が2個、岩相が3個の場合の例

検層種目として自然電位と比抵抗の2個、岩相として砂岩、頁岩、石灰岩の3個がある場合を考える。各岩相

Table 1 Learning data in the case of 2 well log curves and 3 lithologies.

No.	Lithology	S.P.(mv)	Resistivity (Ω m)	Teacher's signal
1	Sandstone	17	3	1 0 0
2	Sandstone	20	2	1 0 0
3	Shale	60	2	0 1 0
4	Shale	60	8	0 1 0
5	Limestone	40	20	0 0 1
6	Limestone	25	6	0 0 1
7	Limestone	60	20	0 0 1

とその自然電位値と比抵抗値および出力層における教師信号の値をTable 1に示す。また、本論文で用いた階層型ネットワークをFig.2に示す。

4.1.1 中間層の数の決定

中間層数の変化による学習能率および学習効果を調べるために、Table 1の7種類のデータのうちの5番目のデータを除いた6個のデータを用い、中間層のユニット数を10に固定し、中間層数が1, 2, 3の各場合について学習を行った。その時の学習曲線をFig. 3(a)~(c)に示す。これによると、中間層の数が少ないほど早く学習が終了しているのがわかる。線形分離の問題であれば中間層はなくてもよいが、そうでない場合には中間層の数についての一般的な法則はない。もっとも、中間層の数が多くなると、当然学習時間は多くかかるし、また少なすぎるとネットワークの機能分化が困難になることは予想できる。この場合には、中間層の数はFig. 3の結果から計算時間が短く、かつ、ユニットの機能が速く分化する1個を採用した。

4.1.2 中間層のユニット数の決定

中間層の数を1個とし、そのユニット数が5, 10, 20個の場合の学習曲線をFig. 4に示す。この場合には学習過程においてあまり顕著な違いは認められない。経験上、ユニット数はあまり急激に変化させるのではなく、2~3倍あるいは1/2~1/3倍の範囲で徐々に増減させていくのがよいと考えられる。したがって、ここでは機能分化の程度が同程度で、計算時間が短いことからユニット数は5個とした。

4.1.3 学習データの選定

学習データの違いにより、どのように学習効果が異なるかを調べるために、Table 1の中からTable 2(a), (b)に

Fig. 2 Layered network in the case of 2 well log curves and 3 lithologies.

Fig. 3 Effect of training due to the change of hidden layer.

- (a) Number of hidden layers is 1.
- (b) Number of hidden layers is 2.
- (c) Number of hidden layers is 3.

Table 2 Two kinds of learning data for checking the efficiency of training by different learning data.

(a)

No.	Lithology	S.P.(mv)	Resistivity (Ω m)	Teacher's signal
1	Sandstone	17	3	1 0 0
2	Shale	60	8	0 1 0
3	Limestone	40	20	0 0 1

(b)

No.	Lithology	S.P.(mv)	Resistivity (Ω m)	Teacher's signal
1	Sandstone	20	2	1 0 0
2	Shale	60	2	0 1 0
3	Limestone	25	6	0 0 1

示す3個の岩相からなる2種類のデータを抽出した。これらのデータを中間層が1個、そのユニット数が5個のネットワークに学習させる。その時の学習曲線をFig.5 (a), (b)に示す。Fig.5(a)では少ない学習回数ではほぼ単調に収束しているのに対し、(b)ではしばらく振動した後に収束に向かう。この学習効果の違いは、入力データに似かよったデータがあるか否かによると考えられる。すなわち、Table 2(a)のデータでは砂岩、頁岩、石灰岩の自然電位値および比抵抗値が、それぞれ17, 60, 40 mV および 3, 8, 20 Ω m と明らかな違いがあるのに対し、(b)のデータでは、それぞれの値が20, 60, 25 mV および 2, 2, 6 Ω m と相似かよった値をとるために、ネットワークが分化するのに時間がかかるためと考えられる。2種類のデータを学習した後のネットワークにTable 1の7組のデータを入力して岩相判定を行った。Table 3 (a), (b)は、それぞれTable 2(a)および(b)のデータを入力

Fig. 4 Effect of training due to the change of unit number in hidden layer.

- (a) Unit number is 5.
- (b) Unit number is 10.
- (c) Unit number is 20.

して学習した場合の岩相判定結果であり、左から右へ入力データの値、出力層からの出力値および正解と推測結果を示す。Table 3 中のデータ番号の右肩についた*は学習時に使用したデータであることを示す。Table 3(a)では6番目の岩相を正しく判定していないが、(b)では正しく判定している。これは、Table 2(a)では砂岩と石灰岩の自然電位値および比抵抗値は、それぞれ17 mV、3 Ω m および 40 mV、20 Ω m として学習している。これに対し、6番目の入力データの自然電位値および比抵抗値は、25 mV および 6 Ω m である。したがって、このデータは砂岩により近いと判断されたと考えられる。一方、Table 2(b)では、このデータは石灰岩として学習しており、当然のことながら正しく岩相判定されている。Table 3(b)の4番目のデータは、一応泥岩と判定されているが、出力値では石灰岩もかなり大きな値となっている。Table 2(b)の学習データによると、このデータは泥

岩と石灰岩の中間的な岩相であることがわかる。したがって、出力層のユニット中に中間的な岩相を指定しなかった場合には、岩相の判定にあたっては必ずしも出力値の最大値で判定するのではなく、出力値の大きさの比率で判断した方がよいと考えられる。

4.1.4 岩相の推定

Table 1 の入力データを用い、中間層が1個、そのユニット層を5とし、1万回の学習を行った後のネットワークを用いて自然電位値を0~60 mV、比抵抗値を0~20 Ω m の範囲で1刻みで合計1281 (61×21) 個のデータを入力して岩相判定を行った。その結果を Fig. 6 に示す。Fig. 6(a)は Table 1 中の7個のデータをすべて用いて学習を行った後の重みによる判定結果であり、(b)、(c)は、それぞれ5番目のデータおよび、2、3、6、7番目のデータを除いたデータによる学習後の重みによる判定結果である。

Table 3 Result of estimation of lithology.

(a) Learning data is one in Table 2 (a).

Input data	S.P. (mv)	Resistivity (Ωm)		Teacher's signal	
Output value	Unit 1	Unit 2	Unit 3		Estimation
No. 1*	17	3		1 0 0	
	0.9872225	0.0097190	0.0102457		1 0 0
2	20	2		1 0 0	
	0.9835371	0.0377396	0.0030781		1 0 0
3	60	2		0 1 0	
	0.0440786	0.9852719	0.0028570		0 1 0
4*	60	8		0 1 0	
	0.0095575	0.9821131	0.0150935		0 1 0
5*	40	20		0 0 1	
	0.0099258	0.0165985	0.9820380		0 0 1
6	25	6		0 0 1	
	0.9024857	0.0217575	0.0361131		1 0 0
7	60	20		0 0 1	
	0.0021971	0.2202984	0.9198410		0 0 1

(b) Learning data is one in Table 2 (b).

Input data	S.P. (mv)	Resistivity (Ωm)		Teacher's signal	
Output value	Unit 1	Unit 2	Unit 3		Estimation
No. 1	17	3		1 0 0	
	0.9504616	0.0036843	0.0840729		1 0 0
2*	20	2		1 0 0	
	0.9780183	0.0053824	0.0209922		1 0 0
3*	60	2		0 1 0	
	0.0031431	0.9840481	0.0100254		0 1 0
4	60	8		0 1 0	
	0.0000201	0.9514131	0.9351373		0 1 0
5	40	20		0 0 1	
	0.0000964	0.0534130	0.9998285		0 0 1
6*	25	6		0 0 1	
	0.0270302	0.0178336	0.9713799		0 0 1
7	60	20		0 0 1	
	0.0000054	0.8318225	0.9971606		0 0 1

Fig. 5 Learning effect due to the difference of learning data.

- (a) Learning data is one in Table 2 (a).
 (b) Learning data is one in Table 2 (b).

Table 4 Learning data in the case of 5 well log curves and 4 lithologies.

No.	Lithology	Resistivity (Ωm)	Transit time ($\mu sec/ft$)	Density (g/cm^3)	γ ray (API)	Neutron (SNU)	Teacher's signal
1	Coal	350	141	1.31	15	86	1 0 0 0
2	Coal	700	145	1.30	20	80	1 0 0 0
3	Coal	110	120	2.15	98	190	1 0 0 0
4	Coal	150	137	1.86	70	123	1 0 0 0
5	Sandstone	180	94	2.29	40	320	0 1 0 0
6	Sandstone	185	94	2.24	28	320	0 1 0 0
7	Sandstone	210	92	2.27	37	354	0 1 0 0
8	Sandstone	250	83	2.29	38	480	0 1 0 0
9	Shale	60	92	2.45	148	253	0 0 1 0
10	Shale	110	80	2.50	92	320	0 0 1 0
11	Shale	100	89	2.39	120	246	0 0 1 0
12	Conglomerate	270	83	2.29	28	394	0 0 0 1
13	Conglomerate	260	86	2.30	40	480	0 0 0 1
14	Conglomerate	130	95	2.37	78	480	0 0 0 1

岩相は最大の出力値を与える出力層中のユニットに指定された岩相により決定した。図中の数字1は砂岩, 2は頁岩, 3は石灰岩を表す。また, ○印は学習に用いたデータを示す。

Fig. 6 から以下のことがわかる。

- (1) Fig. 6 (a)と(b)の境界が全く一致していることか

ら, Table 1 の5番目のデータはこの場合の境界の決定には全く関与していない。

- (2) 境界の位置は与えた教師信号の中間的な位置に設定される。ここには示さないが, 出力層の出力値をみると, 境界に近づくほど, 出力層のユニットの出力値は平均化される傾向がある。

Fig. 6 Recognition result of lithology.

- (a) Learning data is one in Table 1.
- (b) Learning data is one that excludes 1 sample data in Table 1.
- (c) Learning data is one that excludes 4 sample data in Table 1.

4.2 検層種目が5個、岩相が4個の場合の例

ここでは検層種目として Table 4 に示す比抵抗値 (Ωm), 速度検層 (μ sec/ft), 密度検層 (g/cm^3), ガンマ検層 (API), 中性子検層 (SNU) の5種目の14個のデータ, 岩相として石炭, 砂岩, 泥岩, 礫岩の4種類が

Fig. 7 Layered network in the case of 5 well log curves and 4 lithologies.

ある場合について考える。この場合の階層型ネットワークを Fig. 7 に示す。Fig. 8(a), (b)には, 14個のデータのうち, それぞれ4, 10番目のデータを除いた12個, および3, 7, 9, 14番目のデータを除いた10個のデータを用いて, 8万回まで学習を行った場合の学習曲線を示す。Fig. 8(a)では入力データが多いこともあって学習効果が現れるのに時間がかかっているのがわかる。12個および10個のデータに対する学習後のネットワークを用いて Table 4 の14個のデータの岩相判定を行った結果を, それぞれ Table 5(a), (b)に示す。Table 5 中のデータ番号の右肩についた*は, 学習時に使用したデータであることを示す。Table 5(a)では14個のデータを未学習データを含めてすべて正しく判定している。しかし, (b)では未学習データの12番目の砂岩 (Table 4 中の7番目のデータ) を礫岩と誤認している。もっとも, 出力層の最大値をとると礫岩となるが, 出力値そのものは0.4197055と0.5504931で, あまり大きな差異はない。したがって, もともとこのデータは砂岩と礫岩の中間的な岩相であると考えられる。このことは, Table 4 の未学習の7番目の砂岩は, 学習した12番目の礫岩と検層データが非常に似かよっていることから裏付けられる。一方, 7番目と12番目のデータを学習した Table 5(a)では当然のことながら両方とも正しく識別している。

したがって, この場合の学習結果から以下のことが考察できる。

- (1) 出力層からの出力値からの岩相判定においては, 入力データにおいて中間的な岩相が同定できる場合には, 出力層中に中間的な岩相のためのユニットを指定しておいた方がよい。また, 入力データにおいて中間的な岩相が同定できない場合には, 出力値か

Table 5 Result of estimation of lithology.

(a) Learning data is one that excludes 2 sample data in Table 4.

Input data	Resistivity (Ωm)	Transit-time ($\mu\text{ sec/ft}$)	Density (g/cm^3)	γ ray (API)	Neutron (SNU)	Teacher's signal	
Output value	Unit 1	Unit 2	Unit 3	Unit 4			Estimation
No. 1*	350	141	1.31	15	86	1 0 0 0	
	0.9986634	0.0004846	0.0001900	0.0002012			1 0 0 0
2*	700	145	1.30	20	80	1 0 0 0	
	0.9988723	0.0003019	0.0002577	0.0002493			1 0 0 0
3*	110	120	2.15	98	190	1 0 0 0	
	0.9825746	0.0002806	0.0073594	0.0003155			1 0 0 0
4*	180	94	2.29	40	320	0 1 0 0	
	0.0158832	0.9859713	0.0125521	0.0095770			0 1 0 0
5*	185	94	2.24	28	320	0 1 0 0	
	0.0118242	0.9986308	0.0017437	0.0018522			0 1 0 0
6*	210	92	2.27	37	354	0 1 0 0	
	0.0049577	0.9808035	0.0055507	0.0216415			0 1 0 0
7*	250	83	2.29	38	480	0 1 0 0	
	0.0000005	0.9570872	0.0001485	0.0422137			0 1 0 0
8*	60	92	2.45	148	253	0 0 1 0	
	0.0069653	0.0012585	0.9937340	0.0023050			0 0 1 0
9*	100	89	2.39	120	246	0 0 1 0	
	0.0042825	0.0100892	0.9862399	0.0053028			0 0 1 0
10*	270	83	2.29	28	394	0 0 0 1	
	0.0000096	0.0303143	0.0000815	0.9749100			0 0 0 1
11*	260	86	2.30	40	480	0 0 0 1	
	0.0000037	0.0746301	0.0002159	0.9235168			0 0 0 1
12*	130	95	2.37	78	480	0 0 0 1	
	0.0001000	0.0003678	0.0082504	0.9988940			0 0 0 1
13	150	137	1.86	70	123	1 0 0 0	
	0.9978566	0.0002546	0.0006363	0.0002516			1 0 0 0
14	110	80	2.50	92	320	0 0 1 0	
	0.0003509	0.5473132	0.9113077	0.0549808			0 0 1 0

らの岩相の判定にあたっては、出力値の最大値から判定するのではなく、出力値の大きさの比率から中間的な岩相を同定した方がよい。

- (2) 学習データの選定にあたっては、学習の時間は多くなるけれども、岩相境界付近のデータをできるだけ多くした方が学習後のネットワークの判定能力は

高くなる。

4.3 ネットワークの汎化能力のチェック

階層型ネットワークには、入力データと正解とを与えて学習させることにより数式化が困難な現象を制御、判断できるという簡便性、一度学習すると入力データを与えるだけで迅速に回答が得られるという適用の迅速性お

(b) Learning data is one that excludes 4 sample data in Table 4.

Input data	Resistivity (Ωm)	Transit-time ($\mu sec/ft$)	Density (g/cm^3)	γ ray (API)	Neutron (SNU)	Teacher's signal	
Output value	Unit 1	Unit 2	Unit 3	Unit 4			Estimation
No. 1*	350	141	1.31	15	86	1 0 0 0	
	0.9960576	0.0051284	0.0000021	0.0013706			1 0 0 0
2*	700	145	1.30	20	80	1 0 0 0	
	0.9950460	0.0033650	0.0000021	0.0021952			1 0 0 0
3*	150	137	1.86	70	123	1 0 0 0	
	0.9874959	0.0001387	0.0005229	0.0001690			1 0 0 0
4*	180	94	2.29	40	320	0 1 0 0	
	0.0089292	0.9636276	0.0013019	0.0295852			0 1 0 0
5*	185	94	2.24	28	320	0 1 0 0	
	0.0104332	0.9731663	0.0007862	0.0386865			0 1 0 0
6*	250	83	2.29	38	480	0 1 0 0	
	0.0000131	0.7833644	0.0048290	0.2412321			0 1 0 0
7*	110	80	2.50	92	320	0 0 1 0	
	0.0003053	0.0204450	0.8503130	0.0029140			0 0 1 0
8*	100	89	2.39	120	246	0 0 1 0	
	0.0106624	0.0001054	0.9839272	0.0001353			0 0 1 0
9*	270	83	2.29	28	394	0 0 0 1	
	0.0001970	0.0018382	0.0007364	0.9986993			0 0 0 1
10*	260	86	2.30	40	480	0 0 0 1	
	0.0000775	0.0163333	0.0014039	0.9844886			0 0 0 1
11	110	120	2.15	98	190	1 0 0 0	
	0.7391312	0.0000118	0.2465341	0.0000085			1 0 0 0
12	210	92	2.27	37	354	0 1 0 0	
	0.0035740	0.4197055	0.0008446	0.5504931			0 0 0 1
13	60	92	2.45	148	253	0 0 1 0	
	0.0109579	0.0000334	0.9923588	0.0000860			0 0 1 0
14	130	95	2.37	78	480	0 0 0 1	
	0.0003995	0.0258533	0.0035395	0.9124460			0 0 0 1

よび未学習の入力データに対してもある程度妥当な出力が得られるという汎用性が存在する（芦田・佐々，1994）。

ここでは，学習後のネットワークが未学習のデータに対してどの程度の汎用性を持っているかを調べる。そのために因果関係を与える n 個のデータに対し， $n-1$ 個のデータから求めたネットワークの重みを用いて，除いた

1 個のデータの回答を予測し，その予測が正しいか否かを調べる。この操作を n 個のすべてのデータに対して行う。Table 4 の14個のデータを用いて行った計算結果を Table 6 に示す。Table 6 によると，7 番目と8 番目のデータの岩相の予測は正しく行われていない。これは4.2 節の計算結果からも指摘されたように，これらのデータは予測された岩相と正しい岩相との中間的な岩相

Fig. 8 Learning effect due to the difference of learning data.

- (a) Learning data is one that excludes 2 sample data in Table 4.
 (b) Learning data is one that excludes 4 sample data in Table 4.

Table 6 Check of ability for generalization of neural network.

No.	Teacher's signal	Estimation
1	1 0 0 0	1 0 0 0
2	1 0 0 0	1 0 0 0
3	1 0 0 0	1 0 0 0
4	1 0 0 0	1 0 0 0
5	0 1 0 0	0 1 0 0
6	0 1 0 0	0 1 0 0
7	0 1 0 0	0 0 0 1
8	0 1 0 0	0 0 0 1
9	0 0 1 0	0 0 1 0
10	0 0 1 0	0 0 1 0
11	0 0 1 0	0 0 1 0
12	0 0 0 1	0 0 0 1
13	0 0 0 1	0 0 0 1
14	0 0 0 1	0 0 0 1

であると判断される。

5. 結 言

本論文では誤差逆伝播のアルゴリズムによる学習機能を備えた教師付階層型ニューラルネットワークによる物理検層データの岩相判定について述べた。その結果以下のことが結論として得られた。

- (1) 中間的な岩相については、入力データとしてその

岩相データが与えられる場合には、出力層に中間的岩相のためのユニットを加え、出力値の最大値で岩相判定を行うか、あるいは、入力データとしてその岩相が与えられない場合には、出力値の大きさの比率で中間的な岩相を判定すれば、正確に岩相判定が行える。

- (2) 学習データの選定にあたっては、学習の時間は多くなるけれども、岩相境界付近のデータをできるだけ多くした方が学習後のネットワークの判定能力は高くなる。

計算時間については、計算速度を cpu アクセラレータにより 50 MHz にした NEC PC-9801RX21 を用いて、14 組の検層データを 8 万回学習するのに 53 分かかり、また学習後のネットワークによりそのデータの岩相を判定するのに 1.2 秒かかった。

文 献

- 1) 芦田 譲・佐々宏一, 1994: ニューラルネットワークによる波形認識. 物理探査, 47 (1), 42-48.
- 2) 芦田 譲, 1995: ニューラルネットワークの反射法地震探査データ処理への適用. 材料, 44 (502), 880-884.
- 3) 麻生英樹, 1988: ニューラルネットワーク情報処理. 50-54, 産業図書.
- 4) 市川 紘, 1993: 階層型ニューラルネットワーク. 16-76, 共立出版.
- 5) McCormack, M. D., 1991: Neural computing in geophysics. The Leading Edge, Jan., 11-15.
- 6) Russell B. and Jacksontyo T. (八名和夫監訳), 1993: ニューラルコンピューティング入門. 14-89, 海文堂.