

(24) 階層型ニューラルネットワークの 構造最適化に関する研究

A STUDY ON SELF-OPTIMIZATION OF LAYERED NEURAL NETWORKS

伊藤則夫¹、白木渡²、安田登³
Norio Itoh, Wataru Shiraki, Noboru Yasuda

¹ 正会員 (有) シー・エー・イー 代表取締役 (〒680 鳥取県岩美郡国府町分上2丁目210)

² 正会員 工博 鳥取大学助教授 工学部土木工学科 (〒680 鳥取県鳥取市湖山町南4丁目101)

³ 正会員 工博 東京電力㈱ 電力技術研究所 主管研究員 (〒230 神奈川県横浜市鶴見区江ヶ崎町4番1号)

In developing a neural network system, one of the most important problems is how to determine the optimum size of system. There are two efficient self-optimization techniques for obtaining a layered with optimum size : compact structuring and forgetting. In this study, optimal layered neural network systems for judgement of classes of rock strength are developed by using the compact structuring and forgetting techniques. The effectiveness of these self-optimization techniques is examined by some numerical calculations.

*Key Words : Self-optimized layered neural network, Forgetting
Compact structuring, classes of rock strength*

1 まえがき

階層型ニューラルネットワークの土木分野への応用に関する研究は年々増加の一途をたどっている。しかし、それらの研究の多くは市販のソフトウェアパッケージを使用しており、問題に応じた最適なシステムの構築を合理的に行っている例はほとんどない。確かに、階層型ニューラルネットワークシステムを構築するに際して、入力層および出力層については入手できるデータ項目数、システムに要求される性能から構造を決定することができる。しかし、最適な中間層細胞数をどの程度にすればよいかは明確ではなく、これを決定するためには、従来、多めの数から検討を始め、徐々に中間層細胞数を減らし、学習可能な最小の数を試行錯誤的に見つける方法がとられてきた。また、要求される性能に対する必要最小限の入力項目を抽出することはデータ収集に要する費用を削減するために重要であるが、これも専門家の経験に基づく判断、あるいは試行錯誤的方法によらざるを得ないのが現状である。

試行錯誤的方法は非常に手間がかかるだけでなく、中

間層細胞数のとりかたにより学習が妨げられる場合もあることが経験的にわかっており、必ずしもこの方法で最適な細胞数が決定できるとは限らない。また、必須入力項目の抽出も専門家の十分な助言が得られない場合、これを組み合わせ問題として力任せに行うことは現実的でない。

本論文ではダム基礎岩盤の岩級判定問題を例として、最適な中間層細胞数の決定に自己最適化ニューラルネットワークの手法¹⁾を応用し、その有効性を明らかにする。さらに、入力層～中間層の結合重みを観察することにより、必須入力項目の抽出を簡素化する方法について報告する。

2 自己最適化ニューラルネットワーク

(1) バイアスニューロン

自己最適化ニューラルネットワークについて説明する前に階層型ニューラルネットワークにおけるバイアスニューロンの役割について簡単に述べる。

細胞の入力に対する応答特性を表わす代表的なモデル




図 1 バイアスニューロン

として、式(1)で表わされるようなシグモイド関数が一般的に用いられている。

$$f(x) = \frac{1}{1 + \exp\{-(\sum x_i w_i - \theta)/T\}} \quad (1)$$

ここに、 $f(x)$ ：出力される刺激

$\sum x_i w_i$ ：入力される刺激の重みつき総和

θ ：しきい値

T ：温度

ところで、式(1)は 式(2)のように考えても等価である。

$$f(x) = \frac{1}{1 + \exp\{-(\sum x_i w_i + 1 \cdot w_b)/T\}} \quad (2)$$

すなわち、入力及び中間の各層にもう1つ細胞があり、この細胞が常に一定値(1.0)を出力しているならば、この細胞と上層の細胞の結合重み(w_b)がしきい値($-\theta$)と等価であると考えることができる。このように考えることで、学習の過程において重みとしきい値の両方に対して必要であった修正を、重みについてのみ行えばよいことになり都合がよい。この細胞をバイアスニューロンと呼んでいる。

(2) コンパクト構造化

コンパクト構造化学習法¹⁾では学習パターンに対する細胞の出力系列間の関係を相関係数および分散を用いて定量的に扱い、相関の高い細胞同士および分散の低い細胞とバイアスニューロンを合成することにより、ネットワークの最適化を自動的に行う。

図 2(a)のように、細胞 i, j とこれらを入力とする細胞 k があり、 i, j の出力系列 $\{Y_i\}$ と $\{Y_j\}$ の相関が高いものとする。この場合には式(3)のような線形回帰式を用い、式(4)に示すように細胞 j から k への結合重みを、細胞 i 及びバイアスニューロンから細胞 k への結合重みで近似することができる。これにより図 2(b)に示すように細胞 j を削除することができる。

$$Y_j = aY_i + b \quad (3)$$




図 2 コンパクト構造化における合成

$$W_{ki, new} = W_{ki, old} + aW_{kj} \quad (4)$$

$$W_{kb, new} = W_{kb, old} + bW_{kj}$$

また、図 2(a)で細胞 i の出力系列 $\{Y_i\}$ の分散が小さいとき細胞 i の出力はほぼ一定であり、平均値で近似することができる。従って、式(5)に示すようにバイアスニューロンから細胞 k への結合重みを修正し、図 2(c)のように細胞 i を削除することができる。

$$W_{kb, new} = W_{kb, old} + \bar{Y}_i w_{ki} \quad (5)$$

(3) 忘却

バックプロパゲーション法(BP法)による階層型ニューラルネットワークの学習は各層の細胞が上位層のすべての細胞と密に結合された状態で行われる。しかし、実際の問題を解決するために必ずしもすべてが結合されている必要はない。忘却²⁾はネットワーク内の不必要な結合を削除し、必要な結合のみを残す構造最適化手法である。

忘却による学習は、BP法による結合重みの修正量に式(6)のように重みを減衰させる項を付加することで行われる。

$$\Delta w_{ij, Forget} = \Delta w_{ij, BP} - \varepsilon \cdot \text{sgn}(w_{ij}) \quad (6)$$

$$\text{sgn}(w_{ij}) = \begin{cases} 1 & (w_{ij} > 0) \\ 0 & (w_{ij} = 0) \\ -1 & (w_{ij} < 0) \end{cases} \quad (7)$$

ここで、 $\Delta W_{ij, Forget}$ ：忘却による結合重みの変化量

$\Delta W_{ij, BP}$ ：BP法による結合重みの変化量

ε ：忘却量

この忘却により、すべての結合は一律に弱められるが、

学習の本来の修正により必要な結合だけが生き残る。結合重みが十分小さくなった結合は不必要な結合として削除する。また、下層からの結合がすべて消滅した細胞は出力が一定となるのでバイアスニューロンと見なすことができる。更に、出力が他のどの細胞にも繋がらない細胞は削減してもネットワーク全体としては等価である。

表 1 岩級判定システムの入出力データ

	項 目	単位	
入 力 デ ー タ	1 岩種		ランクデータ 1～4
	2 硬さ区分		ランクデータ 1～5
	3 コア形状		ランクデータ 1～7
	4 割目性状		ランクデータ 1～4
	5 風化区分		ランクデータ 1～4
	6 変質区分		ランクデータ 1～4
	7 採取率	%	
	8 最大コア長	Cm	
	9 RQD(10cm)	Cm	
	10 RQD (5cm)	Cm	
	11 RCI	Cm	
	12 粘土比率	%	
	13 分離面頻度	本/m	
	14 孔口深度	m	
	15 Y座標	m	標高
	16 X座標	m	ダム軸からの離れ
出力データ	岩級区分		B,CH,CM,CL,D

3 岩級判定システムへの応用

(1) システムの構築

自己最適化ニューラルネットワークの手法をダム基礎岩盤の岩級判定システムに応用し、その効果を確認める。この検討はダム立地地点の基礎岩盤の強度及び透水性を推定することを目的とした研究の一環として行われたものである。

データにはダム計画地点において実施された多くのボーリング調査結果のうち、水平方向に約200m、深度方向で約250mの範囲にある7本(延べ900m)のボーリング調査により得られたコアの性状を使用した。

表 1 にシステムの入出力項目を示している。ボーリングコアのデータは1m区間ごとに整理されているが、

表 2 データ数量

		岩 級 区 分					合計
		B	CH	CM	CL	D	
学 習 用	B 1	5	8	9			22
	B 2		6	12	1		19
	B 3		11	11	6		28
	B 4		14	2	4		20
	B 5		5	6	2		13
	合計	5	44	40	13		102
検 証 用	B 6		12	8	5		25
	B 7		20	17	1		38
	合計		32	25	6		63

表 3 自己最適化ニューラルネットワークによる学習状況および検証結果

	初期ネット ワーク構造			学習後ネット ワーク構造			学習状況	検証結果	コンパクト 構造化		忘却 忘却量
	入力 層	中間 層	全結 合数	入力 層	中間 層	全結 合数			相関 係数	分散	
BPシステム1	16	40	885	16	40	885	81:79.4%	39:61.9%	—	—	—
BPシステム2	16	20	445	16	20	445	89:87.3%	39:61.9%			
BPシステム3	16	10	225	16	10	225	87:85.3%	49:77.8%			
BPシステム4	16	4	93	16	4	93	84:82.4%	53:84.1%			
システム1-1	16	40	885	15	4	89	84:82.4%	53:84.1%	0.900	0.010	—
システム1-2	16	20	445	15	4	89	82:80.4%	55:87.3%			
システム1-3	16	10	225	15	1	26	71:69.6%	53:84.1%			
システム1-4	16	5	115	15	1	26	71:69.6%	49:77.8%			
システム1-5	16	40	885	16	14	313	88:86.3%	48:76.2%	0.950	0.005	—
システム1-6	16	20	445	16	7	159	85:83.3%	50:79.4%			
システム1-7	16	10	225	16	3	71	81:79.4%	54:85.7%			
システム1-8	16	5	115	16	1	27	71:69.6%	51:81.0%			
システム1-9	16	40	885	15	33	221	89:87.3%	51:81.0%	—	—	0.005
システム1-10	16	20	445	16	14	120	86:84.3%	55:87.3%			
システム1-11	16	10	225	15	10	78	77:75.5%	48:76.2%			
システム1-12	16	5	115	11	5	33	72:70.6%	53:84.1%			
システム1-13	16	40	885	16	40	358	89:87.3%	51:81.0%	—	—	0.002
システム1-14	16	20	445	16	20	253	88:86.3%	51:81.0%			
システム1-15	16	10	225	16	10	133	84:82.4%	50:79.4%			
システム1-16	16	5	115	14	5	79	77:75.5%	51:81.0%			

透水性の計測が5m区間に対して行われるため、これに対応して5m区間の平均的な入出力データを作成し、これを使用することとした。このとき、入力項目の岩種から変質区分及び岩級区分の7つのランクデータは最頻値を、孔口深度、Y座標は区間の中央の値を、その他は、はずれ値を除いた平均値を使用した。使用するデータの数量を表2に示す。

システムの入力層には入力項目数に対応した16の細胞を設け、出力層には岩級区分の5ランク（B、CH、CM、CL、D）に対応した5つの細胞を設けた。中間層は細胞数をそれぞれ40、20、10、5とした4つの場合について検討した。

(2) 中間層の最適化

4種類の間層構造を持つネットワークにコンパクト構造化、忘却のパラメータを変えて学習を行った。学習回数はどのシステムも300回とした。学習後の各システムの構造を表3に示す。

システム 1-1~1-8 はコンパクト構造化のみを取り入れたものである。システム 1-1~1-4 は細胞からの出力の相関係数が0.9以上のものを相関合成の対象とし、分散が0.01以下のものを分散合成の対象とした。システム 1-5~1-8 は相関係数0.95以上および分散0.005以下をそれぞれ合成の対象として、システム 1-1~1-4 に比べてコンパクト構造化の効果を弱めている。また、システム 1-9~1-16 は忘却のみを取り入れたものであり、システム 1-9~1-12 では忘却量を0.005、システム 1-13~1-16 では忘却量を0.002として前者に比べ後者の忘却効果を弱めている。

表3のBPシステム1~4は比較のために自己最適化学習を使用しないで学習したものである。コンパクト構造化を用いたシステム 1-1~1-4 で入力層細胞が1つ減っているのは最大コア長とRCIの相関係数が高く、最大コア長が入力項目から削除されたためである。最大コア長を残しRCIを削除しても結果は同じである。忘却によってもいくつかの入力項目が削除されている。自己最適化学習の結果削除された入力項目を表4に×印で示す。

表3からわかるように、どのシステムも学習は70~87%できている。検証用データに対する認識も大半は76~87%の正解率が得られたが、自己最適化学習を行わず、中間層に多くの細胞を設けたBPシステム1、2では正解率62%と、他のシステムと比べ極端に低くなっている。また、元々中間層細胞が少ないものに自己最適化学習を行った場合（システム 1-3,1-4,1-8,1-12 など）は結合が極端に減り、学習率は低下しているが検証正解率はさほどには悪くなっていない。

なお、自己最適化学習の中間層への影響をみると、コンパクト構造化の手法を用いたときは多くの細胞が削除されているのがわかる。しかし、忘却手法を用いたとき

には結合の数は減少しているが、細胞数の減少はさほど多くないことがわかる。ただし、入力項目を多く削除したのは忘却手法を用いたシステムである。

検討に用いた忘却率が適当であったかどうかであるが、忘却率を0.01としたときには入力から出力に至るすべての結合が切断され、学習ができないケースが見られた。忘却は学習を抑制しているとも言え、大きな忘却率を使用することは学習の妨げにもなる。

この問題については中間層細胞数は4つ程度が適当と思われるが、他の問題についても中間層細胞数を多めに設定し自己最適化学習を行うことにより、そう間違いない構造が得られるものと思われる。

以上に示した結果から、従来、中間層細胞は少ない方が汎化能力に優れているといわれていることの正しさを再認識した。また、大ざっぱに入力層細胞と同程度として決めてきた中間層細胞が実際には多すぎたのではないかと考えられる。

(3) 入力項目の最適化

これまで、筆者らはシステムにとって必要十分な入力項目を抽出するために感度解析²⁾の手法を用いてきた。しかしながら、感度解析を行うことにより入力が出力へ与える影響の傾向を読みとることはできたが、入力項目の要不要を確定するには至っていない³⁾。

本研究において、自己最適化学習により得られた結果を利用し入力層と中間層の間の結合重みを観察することにより必須入力項目の抽出について検討することとした。なお、自己最適化学習法自体が不要な入力項目を削除する能力を持っているので、すでに最大コア長とRCIはいずれか一方だけでよいことが明らかである。また、システム 1-11、1-12、1-16 から岩種、変質区分、コア採取率、粘土比率、X座標、Y座標は削除しても認識正解率は低下しないこともわかっている。

表 4 自己最適化により削除された入力項目

	シ ス テ ム							
	1-1	1-2	1-3	1-4	1-9	1-11	1-12	1-16
岩種						×	×	
硬さ区分								
コア形状								
割れ目性状								
風化区分								
変質区分							×	×
コア採取率							×	
最大コア長	×	×	×	×				×
RQD(10cm)								
RQD(5cm)								
RCI								
粘土比率					×			
分離面頻度								
孔口深度								
Y座標							×	
X座標							×	




図 3 入力層～中間層の結合重み2乗和

図3は入力層の各細胞と中間層細胞を結ぶ結合重みの2乗和をシステム 1-1～1-16 まで加算し、図示したものである。棒グラフの積み上げられた1つの箱が1つのシステムに対応する。また、表 5 には重み2乗和の値とその順位を示している。ただし、順位は小さい順に振っている。

表4、表5により以下のようなシステムを作成する。

- ・ システム 2-1：表5で重み2乗和下位5番までの項目を使用しない。
- ・ システム 2-2：表5で重み2乗和が下位9番までの項目を削除する。
- ・ システム 2-3：表4で×印を付された項目すべてを使用しない。
- ・ システム 2-4：表5で重み2乗和下位5番まで、および、表4で×印を付された項目すべてを使用しない。

ただし、最大コア長はRCIとの相関が強いことがわかっていてすべてのシステムで使用しないこととした。なお、システム 2-2で下位9番までを削除したのは、10番目がX座標となり、これはY座標と対すべきものと考え、X座標も使用することとしたためである。

それぞれのシステムの入力項目は表5で○印で示している。なお、表5のBP4は表3のBPシステム4と同じである。

ここでは自己最適化学習は用いず、中間層細胞は入力項目数に関わらず4つで統一した。また、学習回数はすべて300回とした。構築したシステムの学習状況及び検証用データに対する認識状況を表6に示している。

学習率は77～85%で良いものと悪いもので8%の

表 5 入力データの選択

	重み2乗和		システム				
	2乗和	順位	BP4	2-1	2-2	2-3	2-4
岩種	99	2	○				
硬さ区分	128	4	○			○	
コア形状	801	16	○	○	○	○	○
割れ目性状	218	7	○	○		○	○
風化区分	382	13	○	○	○	○	○
変質区分	161	5	○				
コア採取率	219	8	○	○			
最大コア長	213	6	○				
RQD(10cm)	310	9	○	○		○	○
RQD(5cm)	534	15	○	○	○	○	○
RCI	330	11	○	○	○	○	○
粘土比率	54	1	○				
分離面頻度	483	14	○	○	○	○	○
孔口深度	100	3	○			○	
Y座標	342	12	○	○	○		
X座標	312	10	○	○	○		
入力項目数			16	10	7	9	7

表 6 システムの学習状況及び検証結果

	入力項目数	学習率	検証正解率
BPシステム4	16	87:85.3%	55:87.3%
システム2-1	10	82:80.4%	54:85.7%
システム2-2	7	81:79.4%	49:77.8%
システム2-3	9	79:77.5%	58:92.1%
システム2-4	7	83:81.4%	58:92.1%
データ数		102	63

開きはあるが、もっとも悪いシステム 2-3でも8割弱は学習できており、検証結果は良好であるから、学習に関して優劣を付ける必要はない。検証正解率に着目したと

表 7 システム 2-4 学習状況

		推定岩盤等級					合計
		B	CH	CM	CL	D	
岩盤等級	B	4	1				5
	CH	1	39	4			44
	CM		9	31			40
	CL			4	9		13
	D						0
合 計		5	49	39	9	0	102

きにはBPシステム4とシステム2-1、およびシステム2-3とシステム2-4は同じような汎化能力を持っていることができる。

システム2-2は他のシステムに比べて認識正解率が10%～15%劣っている。これは、有益なデータを切り捨ててしまった結果ということができる。実際、重み2乗和の下位4項目（岩種、硬さ区分、粘土比率、孔口深度）までは明らかに他と比べて結合重みが小さいが、それ以外のものは重みだけから要不要を判断するのは困難である。入力データ項目を他のシステムと比べると割れ目の性状、RQD(10cm)の2項目の欠落をあげることができる。

システム2-3は自己最適化学習の結果から必ずしも必要ではないと判断された項目を除いたものであるが、すべてのデータを使用した場合よりむしろ汎化能力が高まっている。過剰な中間層細胞がシステムの汎化能力を下げる原因になると同様に、不必要なデータもシステムに対してノイズとして働き汎化能力の低下の原因になる場合もあると言えそうである。

システム2-4はシステム2-1とシステム2-3で共通する入力項目を選択したものである。表7はシステム2-4の学習状況を、また、表8はシステム2-4による検証用データの認識結果を示したものである。表8からわかるように未知のデータに対して非常に高い精度で推定を行っている。結局、当初用意されたデータの半分以上で高い汎化能力を持つシステムが構築できた。

4 あとがき

本研究において、階層型ニューラルネットワークの構造決定に当たり、自己最適化学習法を適用することで、これまであまり深く考えることなく決めていた中間層細胞数を合理的に、かつ短時間で決定できることを示した。そして、これまで漠然といわれていたものより遙かに小さな細胞数で十分に学習を行うことができ、汎化能力を高められることを確認した。

表 8 システム 2-4 検証結果

		推定岩盤等級					合計
		B	CH	CM	CL	D	
岩盤等級	B						0
	CH		30	2			32
	CM		2	23			25
	CL			1	5		6
	D						0
合 計		0	32	26	5	0	63

自己最適化学習法では不要な細胞なり結合をどんどん切り捨てていくため、初期値として大きな細胞数を与えたとしても計算にはさほど時間がかからない。このような計算を何度か行うことにより最適な中間層細胞数が得られるのである。結果としてネットワークの規模が小さくなり、その後の検討が効率的に行えるようになる。

また、自己最適化学習法を用い、かつ入力中間層間の重みを調べることにより、要求される性能を満たすための必要最小限の入力項目を抽出できることを示した。

必ずしも重要でないデータであっても、それがシステム上にある限り結果に何らかの影響を及ぼしている。そしてそれがシステムに対して無害であるとは限らない。入力データ項目を適正に少なくすることはデータ作成に要する費用の削減のみでなく、システムの能力を高めるためにも有効であると考ええる。

この研究は東京電力（株）、日本工営（株）で実施しているダム計画地点の地盤調査のデータを使用して行ったものである。貴重なデータを提供していただいた両社の関係各位に、また、自己最適化ニューラルネットワークに関してご指導をいただいた鳥取大学工学部電気電子工学科の徳高教授、岸田助教授、藤村助手に深く感謝の意を表します。

参考文献

- 1) 中川、岸田、徳高、藤村、河相、白木、伊藤：自己最適化ニューラルネットワークの応用，鳥取大学工学部研究報告，Vol.26，No.1，pp.111-118，1995年11月。
- 2) 武長 他：感度解析を用いたニューラルネットワークの入力層の最適化とその数字認識への応用，電気学会論文集，D.111巻1号，pp36-44。
- 3) 白木、安田、篠原、伊藤：地熱資源有望地域選定へのニューラルネットワークの適用，構造物の安全性・信頼性 JCOSAR'95 論文集，Vol.3，pp575-582