

ニューラルネットワークを用いたNATM施工時の支保パターン選定構造のモデル化に関する研究

荒木義則¹・鈴木昌次²・宮崎智司³・日永田雅司⁴・古川浩平⁵・中川浩二⁵

¹正会員 工修 中電技術コンサルト(株)水工部(元山口大学助手) (〒734 広島市南区出汐2-3-30)

²正会員 工博 (株)大本組技術開発部(〒700 岡山市内山下1丁目1番13号)

³学生会員 山口大学大学院 工学部社会建設工学科

⁴正会員 日本道路公団 福岡建設局 建設部工務課(〒810 福岡市中央区天神2丁目14番13号)

⁵正会員 工博 山口大学教授 工学部社会建設工学科

NATM施工時における支保パターンの選定は、従来より経験工学的な方法で行われていた。そこで、これらの判断過程を一種のパターン識別と考え、ニューラルネットワークを用いてモデル化した。そして、支保パターン選定のためのネットワークモデルの構成や入力データの感度解析を行い、モデルの特性や有効性を検討した。さらに、ニューラルネットワークの判断過程を追跡し、モデルの検証を行った。

Key Words : NATM, neural network, support pattern, past records of construction, granite

1. はじめに

現在、NATMはわが国の山岳トンネルにおける標準的なトンネル掘削工法として定着している。また、近年では種々の補助工法の開発や計測技術の発達等によりNATMはより高度な技術体系をとりつつある。しかしながら、施工時の地山評価と支保設計に関しては未だに技術者の経験的な判断に依存するところが少なくない。施工時の地山評価と支保設計に関しては、トンネル切羽面の状態や施工状況を中心に地山を直接観察し、割れ目の状態や風化変質等の個々の項目を評価点方式で評価し、その平均点をもって標準支保パターンに対応させている例¹⁾がある。また、RMRやQシステムを日本国内の実情に対応させようとした研究^{2, 3)}やファジィ理論を応用して支保パターン判定のための基準式を提案した研究例⁴⁾もある。しかしながら、地山評価点の平均点方式では岩盤の特性を考慮することが困難であることや個々の評価項目の評価レベルが地山評価全体に与える影響を考慮できない点に問題がある。また、RMRやQシステムを日本国内で適用した場合には、現状の標準的な支保パターンとの対応付けにおいて、評価項目の内容やウエイトなどが曖昧になりすぎる点に問題がある。さらにファジィ理論を応用した例では評価結果が分布関数で与えられるため判定のための客観的な基準値を与えるに留まって

いる。

一方、技術者の行う支保パターンの判断過程は、地山評価において、地山岩種の特性や各評価項目毎の評価結果レベルに応じた取捨選択あるいはウエイト付けがなされ、定められた標準支保パターンに対応づけるといった一連の作業を短時間に処理する経験工学的な処理系であると推察される。また、この処理系は地山状況の評価を経験則に基づいて標準的な支保パターンに対応させる一つのパターン識別システムに置き換えることができると考えられる。パターン識別には従来から判別分析や数量化理論等の統計的手法が用いられてきた⁵⁾。これとは別に、最近では人間の脳の学習機能を模擬したニューラルネットワークモデルがパターン識別に有効であるという報告がなされており、土木の分野においても火山性土石流の発生予測⁶⁾やコンクリート構造物の点検等⁷⁾に応用されている。以上のような状況から、本研究ではニューラルネットワークを用いた支保パターン選定のモデル化を試み、モデルの構成や入力データに対する感度解析を行い、モデルの特性や有効性を検討すると共に、ニューラルネットワークの判断過程を追跡することによってモデルの検証を行った。

2. ニューラルネットワークと学習

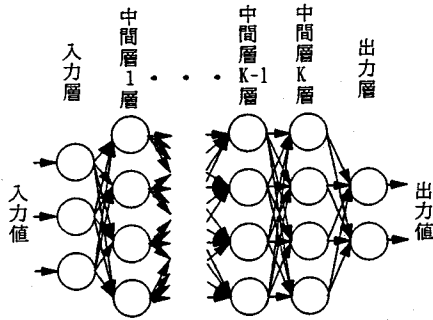


図-1 階層型ネットワーク

代表的なニューラルネットワークには、階層型と相互依存型があるが、ここではパターン識別に有効であるとされる階層型ネットワークを用いる⁸⁾。階層型ネットワークは、図-1のように入力層、中間層、出力層から構成される。各層はニューロン(神経細胞)からなり、個々のニューロンは、多入力1出力の非線形素子である。ニューロンの工学的モデルは図-2のように示される⁸⁾。図-2において x は、伝達されるニューロンへの入力信号であり、 v は出力信号である。また、 w はニューロン同士を結び付けるシナプス(ニューロンの出力部)の結合係数であり、入力信号がニューロンに与える影響の強さを表す。ここで、ニューロンの仮想的な内部状態変数 u は、式(1)のような入力信号と結合係数の積和で表される。

$$u = \sum_{j=1}^n w_j x_j \quad (1)$$

ここに、 n : ニューロンへのシナプス結合数

また、出力信号 v は、ニューロンの特性関数 f により、式(2)で表される。

$$v = f(u) \quad (2)$$

図-1の階層型ネットワークモデルに対して、第 $k-1$ 層 j 番目のニューロン $(k-1, j)$ から第 k 層 i 番目のニューロン (k, i) への結合係数を $w_{ij}^{k(k-1)}$ とすると、内部状態変数 u_i^k は式(3)となり、第 k 層 i 番目のニューロン (k, i) の出力 v_i^k は、式(4)のように表される。

$$u_i^k = \sum_{j=1}^n w_{ij}^{k(k-1)} v_j^{k-1} \quad (3)$$

$$v_i^k = f_i^k(u_i^k) \quad (4)$$

$(i = 1, 2, \dots, m)$




図-2 ニューロンの工学的モデル

表-1 日本道路公団の標準支保パターン

地山等級	掘削工法	掘削工法		ロックボルト		鋼製支保工		吹付厚 (cm)	覆工厚 (cm)	変形余裕量 (cm)			
		掘削長さ (上半) (m)	掘削長さ (下半) (m)	掘削長さ (上半) (m)	掘削長さ (下半) (m)	上半部	下半部			建込間隔 (m)	上半部	下半部	インバート
B	上半工法	2.0	3.0	1.5	2.0	なし	なし	5	30	0	0	0	0
C _I	上半工法	1.5	3.0	1.5	1.5	なし	なし	10	30	0	0	0	0
C _{II}	上半工法	1.2	3.0	1.5	1.2	H-125	なし	1.2	10	30	0	0	0
D _I	上半工法	1.0	4.0	1.2	1.0	H-125	H-125	1.0	15	30	45	0	0
D _{II}	上半工法	1.0以下	4.0	1.2	1.0以下	H-150	H-150	1.0以下	20	30	50	10	0

ここに、 m : 第 k 層のニューロン数

n : 第 $k-1$ 層のニューロン数

階層型ネットワークでは、教師データとしてあらかじめ与えられた入出力値に対する教師信号を用いた繰り返し学習によって結合係数を調整する。この過程を誤差逆伝播学習と言い、出力層のニューロンの出力信号と教師信号との二乗誤差エネルギーに対する最急降下法と等価であることが示されている⁹⁾。いま、入力層のニューロンからの出力信号を v^0 、出力層の出力信号を v^N とする。この時、 $v^N = g(v^0)$ の写像関係を定め、 $v = g(x)$ なる写像関係を学習するものとする。ネットワークへの入力として、 $v^0 = \hat{x}$ を与えたときの出力信号 $v^N = g(\hat{x})$ は、初期状態においては教師信号 $\hat{v} = g_d(\hat{x})$ とは一致しない。そこで、信号の逆伝播によって式(5)の二乗誤差エネルギー E を減少させる方向にネットワーク内の全ての結合係数を調節する。この時、準備した全ての教師信号に対して二乗誤差エネルギーが最小値となるまで繰り返し学習が必要となる。

$$E = \frac{1}{2} \sum_i (v_i^N - \hat{v}_i)^2 \quad (5)$$

3. 支保パターン選定構造のモデル化

技術者は、地山を直接観察する事によって、切羽および周辺の地質状況を評価し、土被り厚や施工状況等を考慮した上で支保パターンを選定している。ここでは、これらの地山状況や土被り厚等を入力データとして、支保パターンを選定するネットワー

表-2 切羽観察記録

①	切羽の状態	1. 安定	2. 視面から岩塊が抜け落ちる	3. 視面の押出しを生じる	4. 視面は自立せず崩れあるいは流出	5. その他
②	素掘面の状態	1. 自立 (骨筋不要)	2. 時間がつたつて破み崩れ落ちる (後骨筋)	3. 自立困難箇所後早期に支保する (先骨筋)	4. 掘削に先行して山を受けておく必要がある	5. その他
③	圧縮強度	1. $\geq 1000 \text{ kgf/cm}^2$ (ハンマー打撃はわかる)	2. $1000 > \geq 200$ (ハンマー打撃でくだける)	3. $200 > \geq 50$ (軽い打撃でくだける)	4. $50 \text{ kgf/cm}^2 > \geq 10$ (ハンマーでくだけ込む)	5. その他
④	風化変質	1. なし・健全	2. 岩目に沿って変色、強度や低下	3. 全体に変色、強度相対に低下	4. 土砂状、粘土状、腐砕、当初より未固結	5. その他
⑤	割れ目の傾度	1. 間隔 $d \geq 1\text{m}$	2. $1\text{m} > d \geq 20\text{cm}$	3. $20\text{cm} > d \geq 5\text{cm}$	4. $5\text{cm} > d$ 疎砕、当初より未固結	5. その他
⑥	割れ目の状態	1. 密着	2. 部分的に開口	3. 開口	4. 粘土をはき、当初より未固結	5. その他
⑦	割れ目の形態	1. ランダム方形	2. 柱状	3. 層状、片状板状	4. 土砂状、細片状、当初より未固結	5. その他
⑧	湧水	1. なし、湧水程度	2. 湧水程度	3. 渠中湧水	4. 全面湧水	5. その他
⑨	水による劣化	1. なし	2. 破みを生ず	3. 軟弱化	4. 崩壊・流出	5. その他
	掘削前後の方向性の異なる割れ目(をみて)	1. 水平 ($10^\circ > \theta > 0^\circ$) 2. さし目 ($30^\circ > \theta \geq 10^\circ$, $30^\circ > \theta \geq 60^\circ$) 3. さし目 ($60^\circ > \theta \geq 30^\circ$) 4. ぬれ目 ($60^\circ > \theta \geq 30^\circ$) 5. ぬれ目 ($30^\circ > \theta \geq 10^\circ$, $30^\circ > \theta \geq 60^\circ$) 6. 垂れ目 ($\theta \geq 90^\circ$) (最大傾斜角をとる)				
	掘削前後の方向性の異なる割れ目(をみて)	1. 水平 ($10^\circ > \theta > 0^\circ$) 2. 右から左へ ($60^\circ > \theta \geq 30^\circ$) 3. 右から左へ ($30^\circ > \theta \geq 10^\circ$, $30^\circ > \theta \geq 60^\circ$) 4. 左から右へ ($60^\circ > \theta \geq 30^\circ$) 5. 左から右へ ($30^\circ > \theta \geq 10^\circ$, $30^\circ > \theta \geq 60^\circ$) 6. 垂れ目 ($\theta \geq 90^\circ$) (切羽面のみかけの傾斜角をとる)				




図-3 切羽分割図

クモデルを構築する。

日本道路公団の定める標準支保パターン¹⁰⁾は、表-1に示すように地山等級に応じて定められており、地山が良好なものから不良なものへと変化するに従って、支保部材も増加し剛なものとなる。実際には、DⅢやEパターン等もあるが、これらは坑口付近や崖錐部などの特殊な部分に用いられるため本研究ではDⅡパターンとして一括して取り扱った。

支保パターン選定時の資料としては、岩質判定記録があり、通常は該当切羽における坑内観察の記録も添付される。これらの資料における地山情報の一つとして表-2に示す切羽観察記録がある。この切羽観察記録は、切羽や素掘面の状態・圧縮強度・風化変質・割れ目の状態・湧水等の9項目を1~4までのカテゴリーで評価し、卓越した割れ目の方向性に対して1~6までのカテゴリーで評価するものである。地山情報としては、この他にも切羽面周辺の亀裂、卓越割れ目の状況、脆弱部の位置、さらには発破後のズリの状況等があり、切羽スケッチや判定記事として記述されている。そこで著者らは、表-3に示すようなA~0までの15の判定項目を考え、これらの評価項目をニューラルネットワークの入力データとして用いることにする。なお、これらの入力データは、岩質判定記録から入手可能なものをすべて用いている。項目採用の理由は、具体的に次に示す通りである。

①項目 (A~K) : 切羽観察記録

表-3 地山判定項目

A	切羽の状態	1	2	3	4	5	6
B	素掘面の状態	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
C	圧縮強度	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
D	風化変質	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
E	割れ目の傾度	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
F	割れ目の状態	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
G	割れ目の形態	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
H	湧水	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
I	水による劣化	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
J	割れ目の方向性	縦断方向	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
K		横断方向	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
L	脆弱部の位置 (切羽スケッチ)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
M	発破後のズリの状況	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
N	土被り比	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
O	支保判定直前区間での支保パターン	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

表-4 発破後のズリの状況

カテゴリ-1	比較的大きな塊がある。
カテゴリ-2	主に小さく破砕されているが中に大きな塊がある。
カテゴリ-3	小さく破砕されている。

表-5 土被り比

カテゴリ-1	$5D < H$
カテゴリ-2	$2D < H \leq 5D$
カテゴリ-3	$1D < H \leq 2D$
カテゴリ-4	$H \leq 1D$

D=11.5m, H:土被り厚(m)

切羽観察記録は、切羽面の状況がなるべく客観性を持つように評価された定量的なデータであり、A~Iの9項目に、割れ目の方向性のJ, Kを加えた11項目よりなる。

②項目 (L) : 脆弱部の位置

支保判定においては、局所的な脆弱部の位置が重要であることが指摘されている¹¹⁾。しかし、現状の判定記録には明確に示されていない。そこで地質状況や施工状況および地山判定記事の中に記述してある情報と切羽スケッチから局所的な脆弱部の有無や位置を推定した。ただし、位置情報としては、天端、肩部、核部といった程度に判断できれば良く、必要以上に細分化するとかえって混乱を招くと考えられる。このため、位置情報は図-3に示すように切羽面を4分割し、各セクションでの脆弱部等の有無を調べた。

③項目 (M) : 発破後のズリの状況

発破後のズリの大小も、地山判定記録に必ず記載されている項目である。発破方法や薬量によってある程度左右されるが、表-4に示す程度のカテゴリーに分類する場合においては、地山の状況による影響が十分大きいと考えられる。

④項目 (N) : 土被り比

土被りは、トンネル位置での地山状況とともに支保判定の重要な要素であることが指摘されており、

表-6 支保パターン

カテゴリー 1	B パターン
カテゴリー 2	CI パターン
カテゴリー 3	CIIパターン
カテゴリー 4	DI パターン
カテゴリー 5	DIIパターン




図-4 支保パターンの分布状況

2D以下の極端に浅い場合では、力学的にも掘削後のトンネル挙動と密接に関係する¹²⁾。このため、表-5に示すカテゴリーに分類したものを入力データとした。

⑤項目(0)：支保判定直前区間での支保パターン

支保選定においては、直前掘削区間での地山挙動も考慮する必要がある。このためには、変位等の計測結果を用いることが望ましい。しかしながら、岩質判定の行われた近傍での計測がなされていない場合もある。さらには、計測時期の違い等を考慮するとネットワークが非常に複雑になる。このため、支保判定時において直前掘削区間で用いた支保パターンを代表として用いた。これは、切羽近傍の既掘削区間において例えば変位が予測以上に増大した場合は、同様な地山状況であっても支保パターンを変更して対応を図るといったことも想定されるためである。施工中の支保パターンの入力は、表-6に示すようなカテゴリーに分類したものをを用いた。

本研究では日本道路公団による2車線道路トンネルでの施工実績を用いる。ただし、トンネル切羽を対象とした岩盤分類や支保パターン判定では、地山岩種ごとの特性を考慮することが必要であると考えられる¹³⁾ため、ここでは花崗岩地山での施工実績に限定した。

ネットワークの学習には、教師データとして6トンネルにおける58回の地山判定記録を用いた。また、モデルの妥当性を検証するための試験データとして23回の地山判定記録を用いた。図-4は、本研究で使用したデータを支保パターン別にヒストグラムで示したものである。図-4より、CII・DIパター

表-7 モデルケース

モデル	層数	中間層数	中間層のニューロン数			
			3	4	5	6
1	3	1	3	4	5	6
2	4	2	5・5	5・6	6・6	7・6
3	5	3	5・5・6	6・6・6	7・6・6	

表-8 教師データの収束状況と正解率

行#	中間ニューロン数	3	4	5	6	7
		正解率 (%)	96.6	100	100	100
行#1	二乗誤差エネルギー	0.009	0.001	0.001	0.001	0.001
	中間ニューロン数	5・5	5・6	6・6	7・6	
行#2	正解率 (%)	96.6	100	100	100	
	二乗誤差エネルギー	0.009	0.001	0.001	0.001	
行#3	中間ニューロン数	5・6・6	6・6・6	7・6・6		
	正解率 (%)	100	100	100		
	二乗誤差エネルギー	0.017	0.001	0.001		

ンの学習用データが多いという特徴がある。

4. ネットワーク構造の影響

階層型ニューラルネットワークでは、中間層の層数や各層内のニューロン数等を調整して目的とするシステムに最適な構造とすることが必要となる。しかしながら、誤差逆伝播学習を用いるシステムでは現在のところ最適な数を決定する確立された方法がないとされている^{14), 15)}。ここでは試行錯誤的に中間層の層数および層内ニューロン数、ニューロンの入出力関数を変化させた数値実験を行い、ネットワークモデルに与える影響を検討するとともに、支保パターン選定のためのネットワークモデルを構築する。

ネットワークの学習には、表-3に示した全ての項目を入力データとして用いた。ネットワーク構造がモデルに与える影響の検討は、誤差逆伝播学習における収束状況と教師データの正解率さらに、未学習である試験データを用いた場合の正解率により総合的に判断する。計算に用いたモデルケースを表-7に示す。モデルケースでは、現場での実用性とネットワークの判断過程を追跡する目的から比較的単純なモデルとして、中間層を1層・2層・3層の3通りを考え、また層内ニューロン数もモデル1については、3~7まで変化させ、モデル2、3については、5、6、7を中心として変化させた。なお、ニューロンの入出力関数は、式(6)に示すようなシグモイド関数、関数パラメータ $u_0 = 1.0$ を用いている。また、最大許容学習回数は500回、誤差逆伝播学習の収束条件は式(5)において二乗誤差エネルギー $E \leq 0.001$ とした。

表-7に示したモデルケース毎に教師データを誤差逆伝播学習させた結果、表-8に示すような教師

表-9 教師データの正解率

試#1	中間ニューロン数	3	4	5	6	7
	正解率(%)	65.2	60.9	69.6	78.3	56.5
試#2	中間ニューロン数	5・5	5・6	6・6	7・6	
	正解率(%)	60.9	65.2	69.6	65.2	
試#3	中間ニューロン数	5・6・6	6・6・6	7・6・6		
	正解率(%)	56.5	65.2	65.2		

表-10 入出力関数と正解率の関係

関数	パラメータ	非線形関数 (シグモイド関数)				線形関数			
		0.5	1.0	1.5	2.0	0.5	0.23	0.15	
教師データ	収束回数	57	250	481	500	59	85	206	
教師データ	正解率(%)	100	100	100	100	100	100	100	
試験データ	B	1/4	2/4	2/4	1/4	1/4	2/4	1/4	
	C	8/10	8/10	7/10	7/10	7/10	6/10	5/10	
	D	6/7	7/7	7/7	5/7	5/7	7/7	6/7	
	E	1/2	1/2	1/2	1/2	1/2	0/2	0/2	
	総合計	17/23	18/23	17/23	16/23	17/23	15/23	12/23	
試験データ	正解率(%)	73.9	78.3	73.9	69.6	60.9	65.2	52.2	

データに対する収束状況とその正解率が得られた。表-8より、モデル1, 2, 3とも層内のニューロン数が最も少ない計算ケースでは、学習を最大学習回数である500回行っても二乗誤差エネルギーが0.001以下になっていない。これに対して、それ以外の計算ケースでは、二乗誤差エネルギーが0.001で教師データの正解率が100%となっており、正常な学習が行われている。このことから層内のニューロン数がモデルの学習能率と学習後の性能に与える影響は大きいと判断できる。

これらのモデルケースに対して、未学習である試験データを用いてテストを行った。その結果を表-9に示す。表-9より、モデルに応じて正解率が異なることがわかる。中でもモデル1の中間層1層で層内ニューロン数6個のネットワークモデルの正解率は78.3%と最も高い値を示した。

次に、最も正解率の高かったネットワークモデルを用いて、ニューロンの入出力関数である特性関数の関数パラメータを変化させ、どの程度ネットワークに影響を与えるかについて検討する。特性関数には、非線形関数と線形関数の2種類を考えた。ここで、非線形関数は、式(6)に示すようなシグモイド関数において関数パラメータ(u_0)を変化させた。

$$f(x) = \frac{1}{1 + \exp(-x/u_0)} \quad (6)$$

また線形関数は、式(7)に示した一次関数において、傾き(a)を変化させた同様の検討を行った。

$$f(x) = ax + 0.5 \quad (-1 \leq f(x) \leq 1) \quad (7)$$

ここで、図-5に関数パラメータ(u_0)および傾き(a)を変化させたときの関数をグラフ化したものを示す。非線形関数であるシグモイド関数の関数パラ




図-5 入出力関数

メータ(u_0)は、0.5, 1.0, 1.5, 2.0の4通りとし、パラメータが大きくなるに従って関数はなだらかな曲線となる。一方、一次関数は、シグモイド関数曲線に接するように傾き(a)を0.5, 0.23, 0.15の3通りに変化させてその影響を検討した。

学習を行ったネットワークモデルの判断状況を関数毎にまとめたものを表-10に示した。表-10より、教師データを用いた場合は、線形・非線形を問わず全ての関数において、正解率は100%の結果となった。

次に、学習済みのネットワークモデルに対して、試験データを用いた場合のネットワークの判断状況を検討する。学習におけるネットワークの収束状況は、非線形も線形も関数が急勾配であるほど学習回数は少なくなり、緩勾配になればなるほど収束条件を満足するための学習回数は多くなる特徴がある。これに対して試験データに対する正解率は、収束回数には比例しておらず、本検討の結果では、非線形関数で関数パラメータ($u_0 = 1.0$)の場合が最も高くなり、78.3%を示した。また、線形関数とシグモイド関数では、シグモイド関数の方が収束回数を多く必要とするものの判断能力は高くなることがわかる。また、他の構造モデルにおいても同様の結果が得られている。

以上のことから、今回の検討範囲内で試験データに対して最も正解率の高くなったニューラルネットワークモデルは、入力層、中間層、出力層が各1層から成り、中間層はニューロンが6個から成るモデルで、その特性関数は非線形関数であるシグモイド関数(パラメータ $u_0 = 1.0$)となった。このことから、本研究における階層型ネットワークモデルは、検討を行ったモデルの中では比較的単純なものとなり、むやみに複雑にすることはかえって逆効果となることが示された。

表-11 計算ケースの組み合わせ

計算 ケース		1	2	3	4	5	6	7	8	9	10
地山判定項目	切羽観察項目 (A~I:9項目)	○全評価	○全評価	○全評価	○全評価	○全評価	○全評価	○全評価	○全評価	○危険側	○安全側
	不連続面がある場合の割れ目の方向性 (J,K)		○	○	○	○	○	○	○	○	○
	脆弱部の位置(切羽スッチ) (L)			○					○	○	○
	発破後のズリの状況 (M)				○				○	○	○
	土被り比 (N)					○			○	○	○
	直前掘削区間の支保パターン (O)								○	○	○
									○	○	○

図-6は、本研究で得られた支保パターン選定のための最良のニューラルネットワークモデルであり、入力層のマトリックスは、表-6の地山判定入力項目に対応している。また入力層で■の部分、現場において技術者が評価したカテゴリーであることを示す。図-6では、入力層に示された地山状態に対してCIパターンが選択されている。以下では、このモデルを用いて考察を行う。

5. 入力データに対する感度解析

地山評価項目の中で、どの項目が支保パターンの判断に必要であるのか、またこれらの項目は支保パターンの判断にどのような影響を与えるのかについて、入力データの組み合わせを考えた検討を行う。入力データの組み合わせは、地山判定において最も重要な項目と考えられる切羽観察記録項目を中心とし、その他の項目の組み合わせを考慮して表-11に示すような10通りの計算ケースを考えた。従って、10通りの入力データに対してそれぞれネットワークモデルを再構築した。また、地山判定項目が支保パターンに与える影響は、試験データによるニューラルネットワークの判断状況から全体の正解率と支保パターン毎の正解率により判断した。

なお、切羽観察記録は切羽全体に対して、項目毎の評価をするものである。これに対して実際の切羽は、風化の進行した部分や堅硬な部分の混在するものが少なくない。このため、全体の評価として明確なカテゴリー付けができない場合を生じ、切羽観察記録の同じ項目に2つ以上の評価が下される場合もある。そこで、このような記録の取扱いについても最適な方法を見出す必要がある。表-11の切羽観察項目における全評価とは、記載された全てのカテゴリーを扱うことであり、危険側または安全側とは、同一項目内で2つ以上の地山評価があった場合、地山評価が最も悪い場合または良い場合のカテゴリーを扱うことを意味する。

次に、このネットワークモデルを使って試験デー

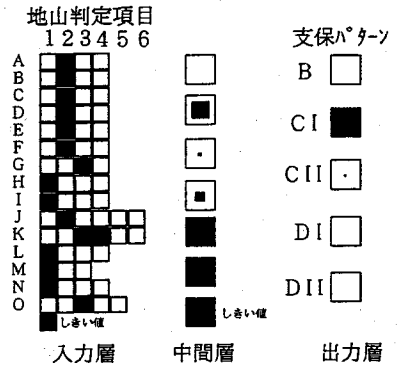


図-6 3層ニューラルネットワーク

タに対して支保パターンを判定させた結果を表-12に示した。ここで、○は正解、×は不正解を表し、各支保パターンおよび全体における正解数と正解率を示した。

ケース1は、切羽観察記録(A~I:9項目)を用いた場合であり、計算ケースの中で最も入力データが少なく、正解率も43.5%と低い値を示した。

ケース2は、切羽観察記録(A~I:9項目)に割れ目の方向性(J,K:2項目)を加えた場合であり、ケース1に比べて正解率は60.9%とかなり高くなった。

ケース3, 4, 5は、それぞれケース2に切羽スッチによる脆弱部の位置(L)、発破後のズリの状況(M)、土被り比(N)を加えた場合であり、正解率はケース2と比べてあまり変化が見られなかった。

ケース6は、ケース3に土被り比(N)を加えた場合であり、正解率は65.2%とケース3よりも高くなった。

ケース7は、ケース6に発破後のズリの状況(M)を加えた場合であり、正解率は69.6%とケース6よりも高くなった。

ケース8は、ケース7に支保判定直前区間の支保パターン(O)を加えたもので、表-3の地山判定項目を全て用いた場合であり、正解率は78.3%を示し、計算ケースのなかで最も高い値となった。

ケース9は、ケース8の全ての項目のなかで切羽観察記録の同一項目内で2つ以上の地山評価があった場合、地山評価が最も悪くなる危険側のカテゴリーを扱った場合であり、正解率は73.9%を示した。これは、ケース8よりも若干低い値ではあるが非常に高い正解率であるといえる。

ケース10は、ケース9とは逆に地山評価が良い方の安全側のカテゴリーを扱った場合であり、正解率は60.9%と低い値を示した。

表-12 計算ケースと正解率

計算ケース		1	2	3	4	5	6	7	8	9	10	
支保パターン	CI	1	○	○	○	○	○	○	○	○	○	○
		2	×	×	×	×	×	×	×	×	×	×
		3	×	×	×	×	×	×	×	×	×	×
		4	×	×	×	×	×	×	×	×	×	×
		合計	1/4	2/4	1/4	1/4	1/4	1/4	1/4	2/4	2/4	1/4
	CII	5	○	○	○	○	○	○	○	○	○	○
		6	○	○	○	○	○	○	○	○	○	○
		7	○	○	○	○	○	○	○	○	○	○
		8	○	○	○	○	○	○	○	○	○	○
		9	○	○	○	○	○	○	○	○	○	○
		10	○	○	○	○	○	○	○	○	○	○
		11	○	○	○	○	○	○	○	○	○	○
		12	○	○	○	○	○	○	○	○	○	○
		13	○	○	○	○	○	○	○	○	○	○
14		○	○	○	○	○	○	○	○	○	○	
	合計	4/10	6/10	7/10	6/10	7/10	7/10	7/10	8/10	7/10	5/10	
DI	15	○	○	○	○	○	○	○	○	○	○	
	16	○	○	○	○	○	○	○	○	○	○	
	17	○	○	○	○	○	○	○	○	○	○	
	18	○	○	○	○	○	○	○	○	○	○	
	19	○	○	○	○	○	○	○	○	○	○	
	20	○	○	○	○	○	○	○	○	○	○	
	21	○	○	○	○	○	○	○	○	○	○	
	22	○	○	○	○	○	○	○	○	○	○	
	合計	5/7	6/7	6/7	6/7	5/7	6/7	7/7	7/7	7/7	7/7	
DII	23	×	×	×	×	×	×	×	×	×	×	
	24	×	×	×	×	×	×	×	×	×	×	
	合計	0/2	0/2	0/2	0/2	0/2	1/2	1/2	1/2	1/2	1/2	
総合計		10/23	14/23	14/23	13/23	13/23	15/23	16/23	18/23	17/23	14/23	
正解率(%)		43.5	60.9	60.9	56.5	56.5	65.2	69.6	78.3	73.9	60.9	




図-7 ニューラルネットワークの判断状況

以上より、ニューラルネットワークによる支保パターンの判定は、表-3に示した地山判定項目を全て入力することにより、試験データに対して7割以上の正解率を得ることができるようになった。また、切羽観察記録において危険側評価を用いたケース9の正解率は、ケース8の全評価の場合と比べて若干低くなったものの正解率は7割以上を示したのに対して、安全側評価を用いたケース10では6割程度の低い正解率となった。鈴木らの研究¹¹⁾によると技術者は、切羽観察項目の危険側を重視していることが明かにされている。このことからニューラルネットワークの判断は技術者の判断とこの部分においては一致すると言える。

一方、表-12において○、×で表した各試験データのネットワークの判断にはいくつかの誤判断があり、中には全ての計算ケースにおいて不正解となった入力データが存在している。そこで、ニューラルネットワークの判断が技術者の行った地山判定

表-13 誤判断を示した切羽データ

切羽NO.	支保パターン	ネットワークの判定
2	CI	CII
4	CI	CII
5	CII	CI and DI
6	CII	DI
23	DII	DI

と異なるケースに着目し、誤判断を示した入力データについて分析を行う。まず、ニューラルネットワークの判断状況を代表的な特徴をもつ出力層ニューロンの出力値で表したものを図-7に示す。図-7より、正解値を示したデータは、ニューロンの出力値が1.0に近く、極めて正確な判断をしているのがわかる。それに対して、誤判断を示したデータは、No.2, 4, 5, 6, 23と5件あり、No.5を除いて断定的な間違った判断をしていることがわかる。その判断結果を表-13に示した。No.2, 4, 6のデータは、1ランク下位の支保パターンを示し、No.23は、逆




図-8 数量化Ⅲ類によるグループ分類

に1ランク上位の支保パターンを示した。またNo. 5のデータは、1ランク上・下の2つのパターンとなりどちらとも言えない判断を示した。このようなニューラルネットワークの判断の特徴を分析するにあたり、これらのデータに含まれる特徴を抽出し、その他の切羽データとの違いの有無を明らかにする必要がある。そこで数量化理論Ⅲ類を用いて23個の試験データに対してグループ分類を行った。図-8に、グルーピングの結果を示す。図-8より、C Iパターン(□)とC IIパターン(△)のグループは、その分布境界が明瞭ではなく重複していることがわかる。このため、誤判断を示したNo. 2(■), 4(■), 5(▲), 6(▲)のデータは、数量化Ⅲ類により明確に分類できなかった。このことから、本研究で用いたデータでは、C IとC IIパターンがデータ自身の特徴からは明確に分離できない場合もあることがわかる。従って、これらを明確に判断するためには、さらに何らかの入力項目を追加することが必要と言えよう。しかしながら、数量化理論Ⅲ類では、混在し分離できない切羽についてもその多くを正しく判断していることはネットワークの有効性を示すものである。

一方、No. 23(★)のデータは、図-8においては明らかにD Iパターン(○)の分類に属しており、これはニューラルネットワークの判断結果とも一致している。このことからNo. 23のデータは、ここで用いたデータの範囲では客観的にはD Iパターンであると判断できる。従って、No. 23に関しては、ここに用いたデータの範囲以外の何らかの理由により判断された特殊な事例と考えた方が妥当であろう。

このように、本研究で用いたネットワークモデルでは、数量化理論Ⅲ類によって分類の困難なデータに対しても対応できる場合が多く、なおかつ特殊な教師データが存在していても、その他の教師データから学習した範囲内で妥当な判断を下すことが可能であることが示された。




図-9 ウェイト差の算出

6. ネットワークモデルにおける判断過程の追跡と工学的検証

構築されたニューラルネットワークを実用面で利用する場合には、いわゆるブラックボックスとして扱われることになる。しかしながら、その前提条件として、ネットワーク自身が工学的に検証されることが必要である。このためには、前章で行った感度解析が一つの方法であり、不正解となったケースについて合理的な理由付けができたと言える。しかし、モデルの判断過程を明らかにし、その工学的妥当性まで評価されれば、モデルの有用性はより高まる。また、このことはネットワークモデルの今後の展開においても有益な情報を与えることになる。このための方法として、各層におけるニューロンのシナプスウェイト差(以下ウェイト差)をとり、値の大小関係によって判断経路を読み取る方法を提案する。

ここでウェイトとは、入力層と中間層また中間層と出力層のニューロンをそれぞれ連結しているシナプス結合の強さであり、ウェイトの大きさは、特性関数と同様にネットワークのふるまいに影響を与える重要な要因である。即ち、ウェイト差が大きい項目が各層間の信号伝達経路を支配し、経路を変化させながら出力層に到達すると考えるものである。いま、図-9に示すようなネットワークモデルにおいて、ある支保パターンとなる出力層の1つのニューロンに着目すると、中間層ニューロンとのウェイト値(結合係数)は、正值または負値を持つものに分類できる。ここで、正值を持つ中間層のニューロンは、出力値が大きければ大きいほど、負値を持つ中間層のニューロンは、出力値が小さければ小さいほど出力層のニューロンの出力値は大きくなる。また、中間層の正值となるニューロンと入力層のある1つ

のニューロンのウェイト値を $+w_{ij}^{k(k-1)}$ とし、同様に負値となるニューロンとのウェイト値を $-w_{ij}^{k(k-1)}$ とすると、入力層のニューロンが出力層のニューロンに与える影響は式(8)に示すようなウェイト差で与えられる。

$$\Delta w_i^k = \sum_{j=1}^n (+w_{ij}^{k(k-1)}) - \sum_{j=1}^n (-w_{ij}^{k(k-1)}) \quad (8)$$

ここに、 Δw_i^k : 出力ニューロンに影響を与えるウェイト差

このウェイト差を用いて、地山判定項目毎に最も大きくなるウェイト差とそのカテゴリーを支保パターン毎に整理したものを図-10に示した。例えば各支保パターン毎にウェイト差の大きい順に上位3項目を取り上げると、CIパターンは、水による劣化(I)のカテゴリー1、直前掘削区間の支保パターン(0)のカテゴリー2、土被り比(N)のカテゴリー1が大きなウェイト差を示している。以下同様に、CIIパターンは、土被り比(N)のカテゴリー1、脆弱部の位置(L)のカテゴリー3、素掘面の状態(B)のカテゴリー2となり、DIパターンは、圧縮強度(C)のカテゴリー3、割れ目の頻度(E)のカテゴリー3、素掘面の状態(B)のカテゴリー3となり、DIIパターンは、土被り比(N)のカテゴリー4、直前掘削区間の支保パターン(0)のカテゴリー5、割れ目の状態(F)のカテゴリー4となった。すなわち、これらのウェイト差の大きいところにチェックされている地山判定項目は、一つのプロトタイプとして、それに対応する支保パターンとなる可能性が高いと考えられる。

次に、上記のニューラルネットワークによる支保パターンの判断過程が工学的に妥当であるかを評価するための一つの試みとして、表-14に示す日本道路公団の地山分類基準¹⁶⁾と比較する。両者の比較に当たり、ネットワークの判断過程を示した図-10の岩質判定項目軸とカテゴリー軸を用いて、切羽観察記録項目(A~I)のみを2次元表示したものを図-11(a)に示した。また、表-14に示した地山分類基準の記述文章を読みとって、切羽観察記録の各項目のカテゴリーへの対応づけを行った結果を図-11(b)に示した。図-11(a)(b)に示されるマトリックスの行は切羽観察項目(A~Iの9項目)を表し、列はカテゴリーを表している。図-11(a)より、ニューラルネットワークによる切羽観察記録の全体的な傾向としては、上位パターンであるCIパターンは、各項目のカテゴリーが全体的に左




図-10 支保パターンの判断に重量な項目とカテゴリー

表-14 日本道路公団の地山分類(抜粋)

地山等級	(5) 観察		(6) 開削後の状態	
	ハンマー打撃による割れ方	亀裂間隔(cm)	切羽の自立性	内空変位量(mm)
A	ハンマーが跳ね返る。強く叩いてかろうじて割れ、新鮮な面で割れる。	100~50以上	自立状態は非常に良く、反期に破れむことは無い。 ・縦み高さ<1.6m	微小
B	ハンマーで強く叩けば割れるが、ほとんどが亀裂あるいは崩落等に沿って比較的大きく割れる。	70~30	・斜面は自立、薬層面に局部的に崩落がみられるが、おおむね安定。 ・局部的に掘んだ箇所は部分的に支保を要する地山。 ・縦み高さ1.5~3.0m	微小
C	ハンマーで容易に割れる。亀裂面等に沿って比較的の小片に割れ、むしろ亀裂以外の面では割ることが困難である。	50程度以下	・斜面は自立する。 ・薬層面は発破後直ちにクラウン部に吹付けが必要となる地山。 ・縦み高さ2.0~4.0m	50以下
D	ハンマーで容易に崩れる。岩は脆く、指先で容易に割れる。	-	・斜面は自立する。 ・薬層面は天端付近で崩落し、先受け支保工が必要となる地山。 ・縦み高さ2.0~4.0m	60以下
E	ハンマーのわずかな打撃によって崩れる。ハンマーの先が突き刺さる。	-	・斜面は崩落が著しい。 ・薬層面は側方からの押し出しがある。 ・塑性範囲または縦み高さ3.0~6.0m	200以下
			・斜面は押し出しを生じ、顕著なものは崩壊する。 ・薬層面は周圧的な押し出しを生ずる。 ・塑性範囲>7.0m	400以下

側にあり、岩盤の状態としては、自立性が高く良好な状態であることを表している。また下位のパターンになるに従って各項目のカテゴリーは全体的に右側に寄って行くことが伺える。これはカテゴリーが下がるにつれて岩盤の状態が悪く自立性も低くなる一般的な特性が表現されており、図-11(b)に示した地山分類基準を対応させた切羽観察記録の全体的な傾向と良く一致している。また、図-11(a)と(b)の切羽観察項目を比較して、■でチェックされているカテゴリーが一致する項目数を調べ、正解率との関係を示したものを表-15に示す。表-15より、切羽観察記録の一致度が高ければ正解率は比較的高くなる傾向を示した。

以上のことから、構築したニューラルネットワークの全体的な傾向は、技術者が地山分類に従って切羽を評価しているという判断過程に良く対応していると言える。

7. 結論




図-11(a) ニューラルネットワークにおける切羽観察記録




図-11(b) 地山分類における切羽観察記録

図-11 ネットワークと地山分類の比較検討

表-15 切羽観察記録の一致度と正解率

支保パターン	CI	CII	DI	DII
一致がゴリ数	6	8	7	4
正解率(%)	50	80	100	50

本研究では技術者の行っている岩質判定及び支保パターンの決定が、従来より経験工学的な方法で決められてきたことに着目し、これらの判断過程を一種のパターン識別であると考えて、ニューラルネットワークを用いてモデル化した。そして、支保パターン選定のためのネットワークモデルを構築し、未学習データに対しても比較的高い正解率を与えるモデルを提案し、その有効性を示した。また、感度解析と判断過程の追跡によって、ネットワークの工学的妥当性を検証した。以下に結論を列挙する。なお、本研究で用いた教師データが花崗岩地山での支保判定に関する記録のみであるため、以下の結論は、花崗岩地山でのNATM施工時における支保パターン決定の範囲に限定される。しかしながら、同様な手法は、岩種を問わず有効と考えられ、今後、他岩種でのネットワークモデルの差異等についても明らかにされれば、岩種を問わず利用可能なモデルが作成できると思われる。

1) 地山評価におけるニューラルネットワークモデルの構造は、入力層、中間層、出力層の各1層からなる比較的単純な3層階層型ネットワークモデルが最も支保パターン選定に適していることが示された。

2) 今回用いた地山判定の要因はいずれも必要であり、具体的に、切羽観察記録、土被り比、脆弱部の位置、ズリの状況、直前掘削区間での支保パターンは、どれも重要な要因であることが分かった。

3) 地山判定を学習したニューラルネットワークモデルの感度解析から、切羽観察記録では危険側にチェックされているものが重視される傾向にあることが示された。これは、技術者に対するアンケートの分析結果¹¹⁾と一致している。

4) ニューラルネットワークの判断過程は、ニューロンのシナプスウェイト差をとることにより、その判断過程を追跡することが可能であり、ネットワークの判断過程は、技術者の工学的な判断と良く一致していることが示された。

5) 本研究における支保パターン選定モデルは、未学習データに対して7割以上の高い正解率で支保パターンを判断することができる。

本研究において、提案したニューラルネットワークを用いた支保パターン選定システムは、あくまでも限られた情報の中から最適な支保パターンを選定しており、現場における全ての情報を考慮することが出来ないため、ネットワークの判断は、支保パターン選定のための基準値を与えてくれるものと考えられる。従って最終的な支保パターンの決定は、専門技術者の総合的な判断にゆだねられるものである。また今後、多くの実績を用いて基本的なモデルを作れば、現場において有効的に利用できると考えられる。

参考文献

- 1) 結城則行, 日永田雅司, 古川浩平, 中川浩二: 山岳トンネルにおける切羽観察記録と支保工および補助工法との相関性に関する一考察, 土木学会論文集No. 492/VI-23, pp. 57-66, 1994. 6.
- 2) 三谷哲, 岩井孝幸: トンネル岩盤分類に関する一考察, トンネルと地下, 第9巻3号, pp. 7-19, 1983. 3.
- 3) Nakao, K and Koyama, S: Statistical weight analysis on the parameters for geomechanics classification of tunnelling, Proc. of JSCE, No. 346/III-1, pp. 107-115, 1984. 5.
- 4) 鈴木昌次, 古川浩平, 井上洋司, 中川浩二: ファジィ回帰モデルに基づくトンネル岩盤分類法の提案, 土木学会論文集 No. 418/III-13, pp. 181-190, 1990. 6.
- 5) 鈴木昌次, 古川浩平, 井上洋司, 中川浩二: NATM施工実績に基づく事前設計の評価に関する一考察, 土木学会論文集 No. 427/VI-14, pp. 261-270, 1991. 3.
- 6) 森山聡之, 平野宗夫, 上松泰介, 川原恵一郎, 白川朋道: ニューラルネットワークを用いた土石流発生予測について, 水工学論文集, 第36巻, pp. 705-708, 1992. 2.
- 7) 安田登, 白木渡, 松島学, 堤知明: ニューラルネットワークに基づいたコンクリート構造物点検技術者の思考過程の評価, 土木学会論文集 No. 496/V-24, pp. 41-49, 1994. 8.
- 8) 矢川元基: ニューラルネットワーク, pp. 1~19, 培風館, 1992. 5.
- 9) 高木英行: ニューラルネットワーク Part II 基礎入門編, 日本ファジィ学会誌, Vol. 4, No. 4, pp. 664-675, 1992. 8.
- 10) 日本道路公団: 設計要領第三集第9編トンネル, pp. 79, 1985. 10.
- 11) 鈴木昌次, 古川浩平, 井上洋司, 中川浩二: アンケートに基づくトンネル施工時の岩盤分類に関する研究, 土木学会論文集 No. 435/VI-15, pp. 51-60, 1991. 9.
- 12) 武田健策他, 水路トンネルの設計・施工, pp. 76-79, 山海堂, 1981. 1.
- 13) 鈴木昌次, 古川浩平, 井上洋司, 中川浩二: ファジィ回帰モデルに基づくトンネル岩盤分類と岩種特性, 土木学会論文集 No. 430/III-15, pp. 153-156, 1991. 6.
- 14) 那野比古: ニューロコンピュータ革命, 講談社, 1989. 1.
- 15) 平野広美: Cでつくるニューラルネットワーク, パーソナルメディア, 1991. 3.
- 16) 日本道路公団: 設計要領第三集第9編トンネル, pp. 34, 1985. 10.

(1994. 9. 12 受付)

A STUDY ON THE APPLICATION OF NEURAL NETWORK AS THE PROCESS OF SUPPORT SELECTION FOR TUNNEL CONSTRUCTION WITH NATM

Yoshinori ARAKI, Shoji SUZUKI, Tomoji MIYAZAKI, Masashi HIEDA,
Kohei FURUKAWA and Koji NAKAGAWA

Usually, the process of support pattern selection relies heavily on subjective judgment based on experiences of several engineers. It is considered that these judgment processes are similar to pattern discrimination, and the selection models of support patterns for tunnel construction were prepared by using the neural network. According to the analysis of input data and the best selection of support for models, the properties and effectiveness of models were discussed. And the judgment process of neural network was pursued and the verification of the modeling were carried out.