

가속신경망에 의한 암반물성의 추정

김남수¹⁾ · 양형식²⁾

Estimation of Engineering Properties of Rock by Accelerated Neural Network

Nam-Soo Kim, Hyung-Sik Yang

ABSTRACT A new accelerated neural network adopting modified sigmoid function was developed and applied to estimate engineering properties of rock from insufficient geological data. Developed network was tested on the well-known XOR and character recognition problems to verify the validity of the algorithms. Both learning speed and recognition rate were improved. Test learn on the Lee and Sterling's problem showed that learning time was reduced from tens of hours to a few minutes, while the output pattern was almost the same as other studies. Application to the various case studies showed exact coincidence with original data or measured results.

1. 서 론

지하암반을 이용한 구조물의 크기가 점차 커지고 용도가 다양해짐에 따라 지하구조물의 안정성 확보와 경제적인 시공을 위하여 보다 상세하고 합리적인 암반분류가 필요하게 되었다. 지금까지 주로 통계적 경험법인 RMR이나 Q방식으로 암반을 분류하고 지보패턴을 결정하고 있다. 암반분류를 하기 위해서는 지하암반의 절리, 층리, 단층 및 파쇄대에 대한 정밀한 측정이 이루어져야 하나, 암반의 불확실성과 현장조사의 한계에 따라 설계 초기에는 지질자료가 충분하지 못하고 암반분류의 신뢰도도 떨어지고 있는 실정이다.

암반분류에 있어 가장 큰 문제점인 불확실한 지질정보를 근사하게 추론할 수 있는 방법으로서 퍼지 시스템(fuzzy system), 전문가시스템(expert system), 인공신경망(artificial neural network) 등 인공지능(artificial intelligence)이 적용되고 있다(Zhang et al., 1991, 양 외, 1995). 신경망은 세포들간의 연결가중치(connection weight)를 조정하는 학습을 통해 얻어진 내적지식을 이용하여, 새로운 상황에 일반화시켜 원하는 자료를 추론하며, 학습되지 않았거나 학습된 자료의 일부파손, 왜곡된 자료의 입력시에도 연결가중치에 저장된 내적지식에 따라 적절한 결과를 출력한다. 현재 암반공

학 분야에서도 사암 시료의 탄성압축률을 예측하고, 지하암반의 파괴거동을 추정하는 신경망 모델이 발표되어 있다. 그러나 종래의 오류역전파 학습알고리즘(error back propagation learning algorithm, EBP)은 학습시간이 지나치게 길고, 지역극소점에 빠질 가능성 이 많은 등 학습알고리즘 자체의 한계점이 있다.

본 연구에서는 기존 신경망 모델의 단점을 극복하기 위하여 가속화된 신경망 학습알고리즘을 제시하고, 개선된 학습알고리즘을 적용하여 기존 신경망 학습알고리즘과 학습시간, 인식률 등을 비교하였다. 개발된 신경망은 현장 사례에 적용하여 설계의 기초자료로 이용하였다.

2. 인공신경망

2.1 인공신경망의 구조

인간 두뇌의 신경조직은 약 천억 개의 신경세포의 집합체로 구성되어 있다. 신경세포의 기본 요소인 뉴런의 크기나 형태는 여러가지가 있지만 기본 구조는 비슷하여 신경돌기(dendrites)를 통하여 들어온 신호를 뉴런이 축삭(axon)을 통하여 전달하는 구조이다.

1) 정회원, 전남대학교 대학원 자원공학과 박사과정
2) 정회원, 전남대학교 자원공학과 부교수

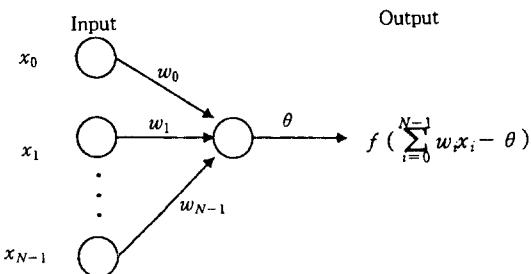


Fig. 1. McCulloch and Pitts Model.

McCulloch와 Pitts는 생물학적인 신경세포의 특성을 모형화한 인공뉴런의 모델을 제안하였다(Fig. 1). 이 모델은 하나의 뉴런에 여러 개의 입력과 1개의 출력이 연결된 구조를 갖는 신경모델로서, 입력 x_i ($i=0, 1, 2 \dots N-1$)는 다른 뉴런으로부터의 입력펄스의 유무에 따라 1 또는 0의 값을 가지며, $w_0, w_1, \dots w_{N-1}$ 은 연결가중치로서 신경세포들 간의 연결강도에 해당되고, 출력은 뉴런의 임계값(θ)보다 크면 흥분(1), 작으면 억제(0) 신호를 출력하게 된다.

신경망은 신경세포들 간의 연결가중치를 일정한 규칙에 따라 조절(학습단계) 하고, 연결가중치에 저장된 내적 지식에 따라 적절한 결과를 출력(산출단계)한다.

2.2 오류역전파 신경망

복잡한 추론에는 입력층과 출력층 외에 한 개 이상의 은닉층(중간층, hidden layer)이 있는 다층 퍼셉트론(perceptron)이 적용된다(Fig. 2). 다층 퍼셉트론은 학습방법으로 역전파(back-propagation) 학습알고리즘을 사용한다.(Rummelhart *et al.*, 1986)

역전파 학습알고리즘에서는 입력패턴이 신경망의 입력층에 주어졌을 때 각 층에 대해서 입력함수와 활성화 함수를 이용하여 출력층에서의 출력값과 오차를 산출하는 전방향 진행(forward pass) 학습단계와 원하는 출력과 실제 출력과의 차이를 계산해서 이를 역전파시키면서 각 층 사이의 연결강도를 조정하는 역방향 진행(reverse pass) 학습단계가 있다. 연결강도 조정 후 다시 입력하여 계산하면 처음 시도 때보다 오차가 작아지고 총 오차의 합이 정해진 오차한계에 도달할 때까지 계속 반복 실행한다.

역전파 학습알고리즘의 학습과정은 먼저 전방향 진행이 일어난다.

입력층 각 처리기에서 출력되는 값 o_{pi} , 입력층과 중간층 사이의 연결강도 w_{ji} 를 이용하여 중간층 처리기 j

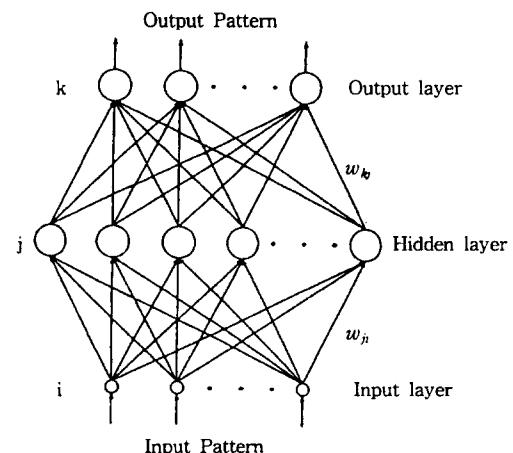


Fig. 2. The structure of multi-layer perceptron.

의 입력 net_{pj} 를 구하고, 활성화함수인 sigmoid함수를 이용하여 중간층 처리기 j 의 출력 o_{pj} 를 구한다.

$$net_{pj} = \sum_i w_{ji} o_{pi} \quad (1)$$

$$o_{pj} = f_j(net_{pj}) = \frac{1}{1 + e^{-(net_{pj} + \theta_j)}} \quad (2)$$

중간층 처리기의 출력 o_{pj} , 중간층과 출력층 사이의 연결강도 w_{kj} 를 이용하여 출력층 처리기 k 의 입력 net_{pk} 를 구한다. 다음 net_{pk} 와 sigmoid함수를 이용하여 출력층 처리기 k 의 출력 o_{pk} 를 구한다.

$$net_{pk} = \sum_j w_{kj} o_{pj} \quad (3)$$

$$o_{pk} = f_k(net_{pk}) \quad (4)$$

실제 출력패턴 o_{pk} 와 입력패턴과 쌍으로 주어지는 목적패턴 t_{pk} 의 차이인 패턴오차 E_p 를 델타 규칙에 의해 (5)식과 같이 정의한다. 그리고 전체 패턴에 대한 오차의 제곱의 총합인 시스템오차(system error) E_t 는 (5)식을 모두 합하여 (6)식과 같이 나타낸다.

$$E_p = \frac{1}{2} \sum_k (t_{pk} - o_{pk})^2 \quad (5)$$

$$E_t = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (t_{pk} - o_{pk})^2 \quad (6)$$

출력층에서 산출된 오차가 지정치 보다 크면 이를 줄이는 방향으로 네트워크의 역방향으로 입력층까지 역전파하여 연결강도를 수정함으로써 시스템오차를 최소화한다.

먼저 출력층 연결강도를 조정한다. 출력층에서의 연결강도의 미소변화량은 (7)과 같이 정의한다.

$$\Delta_{p}w_{kj} = -\eta \frac{\partial E_p}{\partial w_{kj}} = \eta \delta_{pk} o_{pi} \quad (7)$$

η 는 학습률로 연결가중치의 조절량을 결정하는 0과 1 사이의 값을 갖는 상수이다. 학습률은 신경망의 학습능력을 결정하는 상수로 학습의 진행속도에 관련된다. δ_{pk} 는 (8)과 같다.

$$\delta_{pk} = (t_{pk} - o_{pk}) f_k(\text{net}_{pk}) = (t_{pk} - o_{pk}) o_{pk}(1 - o_{pk}) \quad (8)$$

중간층 처리기 δ_{pj} 는 (9)식과 같고 중간층 처리기에서의 연결강도의 미소변화량은 (10)식과 같다.

$$\delta_{pj} = f'_j(\text{net}_{pj}) \sum_k \delta_{pk} w_{kj} = o_{pj}(1 - o_{pj}) \sum_k \delta_{pk} w_{kj} \quad (9)$$

$$\Delta_{p}w_{ji} = \eta \delta_{pj} o_{pi} = \eta o_{pj}(1 - o_{pj}) \sum_k \delta_{pk} w_{kj} o_{pi} \quad (10)$$

신경망의 학습과정에서 필요한 연결강도의 변화량은 미소변화량을 모두 합하여 (11)식으로 계산한다.

$$\Delta w_{ji} = \sum_p \Delta_{p}w_{ji} \quad (11)$$

이상과 같은 과정을 거쳐서 $(n+1)$ 단계에서 출력층과 중간층에서의 최종적인 연결강도의 수정량은 (12)식과 같다.

$$\Delta w_{ji}(n+1) = \eta \delta_{pj} o_{pi} + \alpha \Delta w_{ji}(n) \quad (12)$$

여기서 n 은 학습의 횟수, α 는 관성항(momentum rate)으로 이전의 연결가중치를 저장하고 있어 신경망의 연결가중치 변화에 관성을 줌으로써 학습시간을 단축하고 연결가중치가 아주 얇은 지역 극소에 빠지는 것을 어느 정도 방지할 수 있고 신경망의 학습성능을 향상시키는 역할을 한다.

어떤 입력패턴이 주어질 때 전방향에서 역방향 진행까지의 과정을 하나의 학습주기라 하고 반복적인 학습과정이 이루어지다가 시스템이 안정될 때 즉 오차의 총합인 시스템오차가 정해진 기준치에 도달하면 학습이 모두 끝나게 된다.

2.3 가속신경망

본 연구에서 적용한 가속신경망은 학습속도를 개선하기 위하여 경험적으로 오차함수를 조정하여 보다 급격

한 기울기를 갖도록 조정한다. 오류역전파 학습알고리즘에서 연결강도의 값을 변경하는 방법은 상위층에서 역전파된 오차를 (13)식과 같이 해당 처리기 j 의 출력 o_{pj} 에 대한 sigmoid함수의 미분값으로 곱하는 것이다.

$$\Delta_{p}w_{kj} = \eta \delta_{pk} o_{pi} = \eta(t_{pk} - o_{pk}) o_{pk}(1 - o_{pk}) o_{pj} \quad (13)$$

이때 미분값 $o_{pk}(1-o_{pk})$ 은 o_{pk} 값이 0.0이나 1.0에 가까워지면 그 값이 0이 된다. 그런데, 이러한 경우에 오차가 더 클 수 있음에도, 이 오차의 적은 부분만을 역전파하여 전체적으로 학습속도를 느리게 한다. 이와 같은 문제점을 해결하기 위해서 (14)식과 같은 δ_{pj} 를 변경하는 새로운 알고리즘을 사용한다.

$$\begin{aligned} \Delta_{p}w_{ji} &= \eta \delta_{pj} o_{pi} \\ \delta_{pj} &= \sum_k \delta_{pk} w_{kj} (f'_j(\text{net}_{pj}) + 0.1) \end{aligned} \quad (14)$$

위와 같은 학습규칙의 변경이 타당하기 위해서는 해당 오류함수가 단조증가 또는 단조감소여야 한다. 따라서 해당 오류함수를 다음과 같이 유도한다.

$$\begin{aligned} \Delta_{p}w_{kj} &= -\eta \frac{\partial E_p}{\partial w_{kj}} = -\eta \frac{\partial E_p}{\partial o_{pk}} \cdot \frac{\partial o_{pk}}{\partial \text{net}_{pk}} \cdot \frac{\partial \text{net}_{pk}}{\partial w_{kj}} \\ &= -\eta \frac{\partial E_p}{\partial o_{pk}} \cdot f'_k(\text{net}_{pk}) \cdot o_{pj} \end{aligned} \quad (15)$$

이때 식 (13)과 식 (15)은 같아야 하므로 다음과 같은 식이 성립한다.

$$\frac{\partial E_p}{\partial o_{pk}} = -[(t_{pk} - o_{pk})(f'_k(\text{net}_{pk}) + 0.1)] / f'_k(\text{net}_{pk}) \quad (16)$$

그러므로 (16)식의 양변을 적분하면 (17)식과 같은 새로운 오류함수를 얻을 수 있다.

$$E_p = \sum_k [1/2 \cdot (t_{pk} - o_{pk})^2 + 0.1 [1/2 \cdot (1 + t_{pk}) \ln \frac{1+t_{pk}}{1+o_{pk}}]$$

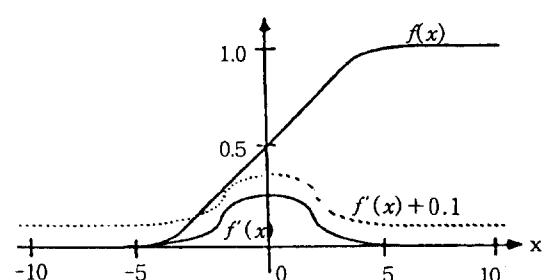


Fig. 3. Altered sigmoid function.

$$+ 1/2 \cdot (1 - t_{pk}) \ln \frac{1 - t_{pk}}{1 - o_{pk}}]] \quad (17)$$

변경된 알고리즘의 sigmoid함수는 Fig. 3과 같다.

3. 검증

3.1 XOR과 문자인식

가속신경망과 표준학습알고리즘(general error back-propagation)의 학습속도와 인식률을 비교하기 위하여 XOR 문제와 문자인식(character recognition) 문제에 적용하였다.

XOR 문제의 속도 비교에서 실험에 사용된 신경망은 3층 역전파신경망으로 구성되었으며, 각각의 입력층, 은닉층, 출력층 처리기의 수는 $2 \times 2 \times 1$ 이다. 문자인식 문제에 사용된 신경망의 구조는 $64 \times 32 \times 5$ 이고 3층 역전파신경망으로 구성되었다. 이때 학습률을 0.1, 0.3, 0.5, 0.7, 0.9로 변경하면서 각각의 학습률에 대해 10번씩, 각 학습실험에 대해 10번씩 인식실험을 하였다. 학습종료 조건으로서 허용오차를 0.1로 하였다.

Table 1과 2는 XOR과 문자인식 문제에 대하여 시스템오차를 0.1로 설정하여 학습한 결과이다. 표준 학습 알고리즘에서는 학습률 η 를 0.1, 0.3, 0.5, 0.7, 0.9로 변경시켰을 때 학습률이 커질수록, 학습의 반복횟수가 줄어들면서 학습시간이 단축되었다. 가속학습알고리즘에서는 학습시간이 모두 1초 이하로 빨라서 학습률 η

의 영향을 판단하기 어려웠다. 표준학습알고리즘에서 XOR 문제는 입력층-은닉층-출력층 처리기의 수가 작아서 학습시간에 크게 구애받지 않지만, 문자인식과 같이 처리기의 수가 커지면 학습시간이 크게 증가한다. 가속학습알고리즘은 처리기의 수가 상당히 커져도 1초 이내에 학습이 이루어졌다.

표에서 표준학습알고리즘보다 가속학습알고리즘의 인식률이 외연상 떨어지는 것으로 나타난다. 즉 목적패턴과 출력패턴과의 오차가 더 크게 나타나는데 실제에 있어서는 가속학습알고리즘의 학습 반복횟수가 현저히 적기 때문에 전체 시스템오차한계에 도달하는 속도와 학습률은 현저히 뛰어나다.

Table 3은 학습편차를 감소시키기 위해서 시스템오차를 0.001로 설정하여 XOR, 문자인식 문제를 가속 학습알고리즘으로 학습한 결과이다. 학습률을 변경시켰을 경우 각 조건의 학습에 사용된 반복횟수와 허용오차에 도달하는 학습시간, 표준편차를 이용한 인식률을 보면 학습 허용오차를 0.1에서 0.001로 줄여서 학습하더라도, 학습시간은 표준 학습알고리즘보다 짧은 시간이 소요되며 인식률도 향상시킬 수 있다.

가속학습알고리즘을 이용하면 표준학습알고리즘보다 학습의 반복횟수가 줄어들어 학습시간이 단축되고, 인식률도 향상됨을 알 수 있다.

3.2 암반물성 추론

Table 1. Comparison of general and accelerated EBP for XOR problem (system error=0.1)

learning rate η	General EBP			Accelerated EBP		
	epoch (frequency)	learning time (s)	recognition (s.d.)	epoch (frequency)	learning time (s)	recognition (s.d.)
0.1	3120	10.7	0.024	98.3	<1	0.138
0.3	987	3.3	0.027	60.1	<1	0.135
0.5	562	1.8	0.024	53.5	<1	0.131
0.7	422	1.5	0.024	88.6	<1	0.134
0.9	328	<1	0.023	64.4	<1	0.169

Table 2. Comparison of general and accelerated EBP for character recognition problem (system error=0.1)

learning rate η	General EBP			Accelerated EBP		
	epoch (frequency)	learning time (s)	recognition (s.d.)	epoch (frequency)	learning time (s)	recognition (s.d.)
0.1	1150	57.2	0.012	13.8	<1	0.069
0.3	389	19.1	0.012	12.2	<1	0.074
0.5	243	11.8	0.011	11.7	<1	0.064
0.7	212	9.8	0.013	11.1	<1	0.065
0.9	178	7.6	0.012	10.4	<1	0.069

다음으로 가속신경망을 이용하여 지질자료가 일부 부정확하거나 결여된 경우의 암반물성을 추론하는 모델을 개발하고 이를 검증하고자 하였다. 추론능력과 정확도를 비교하기 위하여 먼저 Lee와 Sterling (1992)이 사용한 데이터베이스와 문제에 그대로 적용하여 그들의 결과와, 같은 문제에 대한 문과 이(1993)의 연구 결과와도 비교하였다.

이들의 모델은 비교적 정확한 추론이 가능하였지만 학습시간이 지나치게 길어서 하나의 패턴을 학습하는데 수백에서 수십 시간이 소요되어 새로운 데이터를 추가하여 다시 신경망을 학습시키기는데 많은 애로가 있다.

실험에 사용된 데이터베이스는 스칸디나비아 지역의 실제 시공 사례인 Cecil(1970)의 자료와, Barton 등의 자료를 기초로 Lee와 Sterling이 재작성한 데이터베이스이다. Lee와 Sterling은 Cecil의 기초 사례에 overburden, spacing and tunnel span ratio, shear zoning or faulting, ground water condition, modes of instability 등을 추가하여 58개 항목의 지질자료와 28개 항목의 파괴거동으로 구분하였다.

신경망은 지도학습의 3층 역전파 학습알고리즘을 사용하였고, 각각의 입력패턴과 목적패턴은 86개의 항목으로 구성되었다. 또, 입력패턴은 각각의 항목에 해당될 때는 1을, 해당사항이 없을 때에는 0을 대입하였다.

목적패턴은 입력패턴과 같은 패턴으로 구성하였으며, 입력층-은닉층-출력층 처리기는 $86 \times 86 \times 86$ 으로 구성하였다. 본 실험에서는 하나의 패턴오차를 0.0001로 가정하고 시스템오차가 95개의 패턴오차를 합한 0.0095에 도달할 때 학습을 종료하였다.

비교실험에 사용된 입력패턴은 1) 터널은 중간 정도의 심도에 위치하고 2) 암석은 신선하며 3) 중요 불연속면의 경사는 $30\text{-}60^\circ$ 와 $60\text{-}90^\circ$ 들이다.

신경망의 학습 결과, 학습시간이 10분 정도여서 학습시간이 크게 단축되었고, 또 인식률도 거의 비슷하였다.

Table 4는 Lee와 Sterling의 데이터베이스를 학습하는 시간의 비교표로서 IBM 386 시스템을 이용한 Lee와 Sterling의 경우는 310시간 이상이 소요되었으며 IBM 486을 사용한 문과 이의 경우는 35시간이 소요되었다. 저자들은 거의 같은 시스템을 사용하였음에도 불구하고 10분 가량에 머물고 있음을 볼 수 있다.

학습에 사용된 가정 이외에 터널 폭에 대한 평균 불연속면 간격은 $s/a < 1.0$, 불연속면의 연결정도는 열려 있음, 불연속면의 영속성은 연속, 불연속면의 종류는 절리, 불연속면의 충전물은 없음, 불연속면의 평탄정도는 평탄함, 불연속면의 경사 30° 이내, 파쇄대 내의 전단영역은 category E, 지하수 조건은 건조함 등을 추론하였으며 (Table 5) 이러한 결과는 동일한 데이터베이스를 사용하

Table 3. Comparison of accelerated EBP for XOR and character recognition problems (system error=0.001)

η	XOR				Character recognition	
	epoch (frequency)	learning time (s)	recognition (s.d.)	epoch (frequency)	learning time (s)	recognition (s.d.)
0.1	105	1.1	0.015	16.6	<1	0.01
0.3	103	<1	0.013	15.3	<1	0.01
0.5	98	<1	0.013	14.4	<1	0.01
0.7	98	<1	0.013	14.1	<1	0.01
0.9	80	<1	0.014	13.2	<1	0.01

Table 4. Comparison of learning time with Lee & Sterling's database

	Lee & Sterling's	Moon & Lee's	Author's
System configuration	PC 386/25 MHz	IBM PC 486DX2-66MHz 16M RAM	IBM PC 486DX2-66MHz 8M RAM
Operating system		IBM OS/2 Ver 2.1	MS DOS Ver 6.22
Programming language		MS-C Ver 6.0 OS/2 MODE	WATCOM C/C++ Ver 10.0
System error	0.0001	0.0095	0.0095
Learning time	310 Hr	35 Hr	10 min

Table 5. Nonzero items from test results on Lee & Sterling's problem

Item		Authors'		Lee & Sterling	Moon & Lee
		Input	Output		
△ overburden	2. medium	1	1.00	0.41-1.00	1.00
△ Intact rock strength	5. sound	1	1.00	0.41-1.00	1.00
△ Average spacing/span	15. 0.1< s/a < 1.0	0	0.01	0.21-0.30	0.00
	16. s/a < 1.0	0	1.00	0.41-1.00	1.00
△ Discontinuity tightness	20. open	0	0.76	0.41-1.00	0.54
△ Discontinuity Persistency	22. continuous	0	0.99	0.41-1.00	0.95
	23. discontinuous	0	0.06	0.01-0.10	0.51
△ Discontinuity type	24. joint	0	0.97	0.41-1.00	0.98
	27. fault or shear zones	0	0.10	0.41-1.00	0.00
△ Discontinuity fillings	28. none	0	0.35	0.41-1.00	0.77
△ Discontinuity planeness	33. plane	0	0.89	0.41-1.00	0.96
△ Discontinuity roughness	37. smooth	0	0.33	0.41-1.00	0.17
△ Discontinuity dip	40. within 60	1	1.00	0.41-1.00	1.00
	41. within 90	1	1.00	0.41-1.00	1.00
△ Discontinuity strike	42. in 30 deg	0	0.83	0.41-1.00	0.99
	43. in 60 deg	0	0.59	0.41-1.00	0.86
△ Shear zoning faulting	49. category E	0	0.81	0.00	1.00
△ Ground water conditioning	55. dry or minor inflow (<5 l/min)	0	0.98	0.01-1.10	0.99
	56. medium inflow	0	0.00	0.41-1.00	0.00
<input type="checkbox"/> MODE OF INSTABILITY					
△ Location	59. roof	0	0.07	0.41-1.00	0.01
△ Modes	76. dome-/vault-shaped formation	0	0.02	0.41-1.00	0.02

여 동일한 문제에 적용한 문과 이의 연구 결과와는 거의 일치하였고, Lee와 Sterling과는 몇 개의 조건에서는 상이한 결과가 나타났지만 대체적으로 일치하였다.

4. 사례연구

4.1 데이터베이스 자체 사례

임의 사례에 대한 예측능력을 확인하기 위하여 데이터베이스에 포함되어 있는 Cecil의 사례 1과 10에 대하여 각각 적용하였다. 이 경우 적용된 사례는 데이터베이스에서 제외하고 학습시켰으며 각각의 사례에 대해서도 암반물성의 일부와 불연속면의 성질 등을 별도로 미지수화하여 적용하였다.

Table 6은 Cecil의 사례 1에 대하여 RQD를 미지수로 하고 사례 1을 제외한 나머지 데이터베이스로 학습시킨 결과를 원래의 자료와 비교한 것이다. 그러나 RQD는 원래의 값 fair 보다 excellent가 더 높게 추론되었다. Table 7은 같은 사례 1을 불연속면의 성질 중

에서 discontinuity filling과 discontinuity roughness를 미지수로 하여 추론한 것이다. 이 경우에도 대체로 추론이 원래의 값과 일치하지 않는 결과를 보였다.

Table 8과 9는 사례 10에 대하여 같은 방법으로 RQD와 discontinuity filling, discontinuity roughness를 미지수로 하여 해석한 결과이며 원래의 자료와 일치하지 않는 결과를 얻고 있다. 그래서 사례 1과 10을 데이터베이스에 첨가해서 학습을 시켰으나 마찬가지로 일치하지 않은 결과를 얻었다.

4.2 RMR 추정

데이터베이스에 포함되어 있는 Cecil의 사례 1과 10에 대하여 임의로 몇 개의 항목을 미지수로 하여 각각 적용하였으나 대체로 만족스럽지 못한 추론을 하였다. 이는 각각의 항목이 독립적인 변수인데 이를 학습시켜서 또 다른 독립적인 항목을 추론하는 것은 불가능하기 때문이다. 그래서 Cecil의 95가지 사례에 대해 각

각 불연속면의 방향성에 대한 보정을 하지 않은 기초 RMR 분류를 실시하였다. 분류된 RMR 값을 5개 등급으로 하여 해당되는 등급은 1을 해당되지 않는 등급은 0을 입력하여서 86개 항목에 추가하여 총 91개 항목으로 학습을 시켰다.

Table 10은 사례 21, 6, 1, 8에 대하여 각각 데이터 베이스에서 제외하고 학습시켜서 신경망의 RMR 값을 추정하여 원래의 값과 비교한 것이다. 사례 21은 RMR

B class도 추론하였으나 A class가 더 우세하였고 나머지 사례는 원래의 RMR 분류와 일치하는 추론이 이루어졌다.

4.3 국내 현장 사례

여천시 소재의 S석산 사면에 대하여 암반조사를 실시하고 자료 일부를 이용하여 신경망 모델을 적용하였다. 미지수는 직접 계측이 어려워 Schmidt hammer로

Table 6. Selected items from the results of AEBP application on the case #1 of Cecil's database

Item	Input	Output	Truth	Item	Input	Output	Truth	Item	Input	Output	Truth
<input type="checkbox"/> Intact rock strength				<input type="checkbox"/> Discontinuity type				<input type="checkbox"/> Strike			
sound	1.0	0.97	1	joint	1.0	1.00	1	≤ 30	1.0	0.99	1
altered	0.0	0.18	0	bedding	0.0	0.00	0	≤ 90	1.0	0.98	1
<input type="checkbox"/> Rock mass structure				fault				<input type="checkbox"/> RQD			
massive	0.0	0.00	0	<input type="checkbox"/> Discontinuity	fillings			excellent	0.0	0.32	0
one set	0.0	0.00	0		none	0.0	0.07	fair	0.0	0.02	1
two set	1.0	1.00	1		nonsoftening	1.0	0.90	<input type="checkbox"/> Water			
three set	0.0	0.00	0		planeness				dry	1.0	0.88
<input type="checkbox"/> Discontinuity tightness				plane				medium	0.0	0.00	0
very tight	0.0	0.00	0	irregular				0	<input type="checkbox"/> Modes of instability		
tight	0.0	0.00	0	<input type="checkbox"/> Discontinuity roughness				roof	1.0	1.00	1
open	1.0	1.00	1	slickensided				wall	0.0	0.18	0
<input type="checkbox"/> Discontinuity persistency				smooth				small	1.0	0.96	1
continuous	1.0	1.00	1	rough				rock burst	0.0	0.00	0
discontinuous	0.0	0.00	0	<input type="checkbox"/> Dip ≤ 90				disinte-	1.0	0.46	1
								gration			

Table 7. Selected items from the results of AEBP application on the case #1 of Cecil's database

Item	Input	Output	Truth	Item	Input	Output	Truth	Item	Input	Output	Truth
<input type="checkbox"/> Intact rock				<input type="checkbox"/> Discontinuity type				<input type="checkbox"/> Strike			
sound	1.0	0.96	1	joint	1.0	1.00	1	≤ 30	1.0	0.92	1
altered	0.0	0.28	0	bedding	0.0	0.00	0	≤ 90	1.0	0.99	1
<input type="checkbox"/> Rock mass structure				fault				<input type="checkbox"/> RQD			
massive	0.0	0.00	0	<input type="checkbox"/> Discontinuity	fillings			excellent	0.0	0.00	0
one set	0.0	0.00	0		none	0.0	0.09	fair	1.0	0.97	1
two set	1.0	1.00	1		nonsoftening	0.0	0.11	<input type="checkbox"/> Water			
three set	0.0	0.01	0		clay	0.0	0.11		dry	1.0	0.79
<input type="checkbox"/> Discontinuity tightness				plane				medium	0.0	0.00	0
very tight	0.0	0.00	0	irregular				0	<input type="checkbox"/> Modes of instability		
tight	0.0	0.00	0	<input type="checkbox"/> Discontinuity roughness				roof	1.0	1.00	1
open	1.0	1.00	1	slickensided				wall	0.0	0.23	0
<input type="checkbox"/> Discontinuity persistency				smooth				small	1.0	0.98	1
continuous	1.0	1.00	1	rough				rock burst	0.0	0.00	0
discontinuous	0.0	0.00	0	<input type="checkbox"/> Dip ≤ 90				disinte-	1.0	0.66	1
								gration			

추정한 암석강도, 절리간격으로부터 추산한 RQD, 사면이기 때문에 원천적으로 적용이 불가능한 불연속 간격/터널 폭 및 터널 파괴모드 등이다.

RQD의 추정은 다음 식에 의하였다.

$$RQD = 115 - 3.3J_v \quad (j_v : \text{체적당 절리수}) \quad (18)$$

앞서 4가지 사례와 유사한 방법으로 적용한 결과를 계

측 추론치와 비교하여 Table 11에 표시하였다. Table 11에서 강도와 평균간격/평균 폭비, RQD 등의 미지수가 거의 정확하게 추론되어 있음을 볼 수 있다. 불연속 면의 연장이나 RQD 등에서는 다소의 자료분산이 이루어지고 있음을 볼 수 있지만 추론에 지장을 일으킬 정도는 아니었다. S 현장의 사례는 기존의 데이터베이스와는 완전히 무관한 것임에도 근사한 추론이 이루어졌

Table 8. Selected items from the results of AEBP application on the case #1 of Cecil's database

Item	Input	Output	Truth	Item	Input	Output	Truth	Item	Input	Output	Truth	
<input type="checkbox"/> Intact rock			<input type="checkbox"/> Discontinuity type			<input type="checkbox"/> Strike						
sound	1.0	1.00	1	joint	0.0	0.03	0	≤ 30	0.0	0.63	0	
altered	0.0	0.00	0	cleavage	1.0	1.00	1	≤ 90	1.0	0.87	1	
<input type="checkbox"/> Rock mass structure			<input type="checkbox"/> fault			1.0	1.00	1	<input type="checkbox"/> RQD			
massive	0.0	0.00	0	<input type="checkbox"/> Discontinuity	fillings			excellent	0.0	0.00	0	
one set	1.0	0.97	1	none	0.0	0.00	0	very poor	0.0	0.00	1	
two set	0.0	0.00	0	nonsoftening	1.0	0.99	1	<input type="checkbox"/> Water				
three set	0.01	0.01	0	<input type="checkbox"/> Discontinuity	planeness			dry	1.0	1.00	1	
<input type="checkbox"/> Discontinuity tightness			<input type="checkbox"/> plane			1.0	1.00	1	medium	0.0	0.00	0
very tight	0.0	0.00	0	irregular	0.0	0.13	0	<input type="checkbox"/> Modes of instability				
tight	0.0	0.00	0	<input type="checkbox"/> Discontinuity	roughness			roof	1.0	1.00	1	
open	1.0	1.00	1		1.0	1.00	1	wall	0.0	0.00	0	
<input type="checkbox"/> Discontinuity persistency			<input type="checkbox"/> smooth			0.0	0.00	0	moderate fall	1.0	1.00	1
continuous	1.0	1.00	1	rough	0.0	0.01	0	small block fall	0.0	0.06	0	
discontinuous	0.0	0.00	0	<input type="checkbox"/> Dip ≤ 60	1.0	1.00	1	wedge shape fall	1.0	1.00	1	

Table 9. Selected items from the results of AEBP application on the case #10 of Cecil's database

Item	Input	Output	Truth	Item	Input	Output	Truth	Item	Input	Output	Truth	
<input type="checkbox"/> Intact rock strength			<input type="checkbox"/> Discontinuity type			<input type="checkbox"/> Strike						
sound	1.0	1.00	1	joint	0.0	0.00	0	≤ 30	0.0	0.00	0	
altered	0.0	0.00	0	cleavage	1.0	1.00	1	≤ 90	1.0	0.99	1	
<input type="checkbox"/> Rock mass structure			<input type="checkbox"/> fault			1.0	1.00	1	<input type="checkbox"/> RQD			
massive	0.0	0.00	0	<input type="checkbox"/> Discontinuity	fillings			excellent	0.0	0.00	0	
one set	1.0	1.00	1	nonsoftening	0.0	0.03	1	very poor	1.0	0.94	1	
two set	0.0	0.00	0	other low friction	0.0	0.00	1	<input type="checkbox"/> Water				
three set	0	0.00	0	<input type="checkbox"/> Discontinuity	planeness			dry	1.0	1.00	1	
<input type="checkbox"/> Discontinuity tightness			<input type="checkbox"/> plane			1.0	1.00	1	medium	0.0	0.00	1
very tight	0.0	0.00	0	irregular	0.0	0.00	0	<input type="checkbox"/> Modes of instability				
tight	0.0	0.00	0	<input type="checkbox"/> Discontinuity	roughness			roof	1.0	1.00	1	
open	1.0	1.00	1	slickensided	0.0	0.93	1	wall	0.0	0.00	0	
<input type="checkbox"/> Discontinuity persistency			<input type="checkbox"/> smooth			0.0	0.00	0	moderate fall	1.0	0.94	1
continuous	1.0	1.00	1	rough	0.0	0.00	0	small block fall	0.0	0.16	0	
	0.0	0.00	0	<input type="checkbox"/> Dip ≤ 60	1.0	1.00	1	wedge shape fall	1.0	1.00	1	

으로 Lee와 Sterling의 데이터베이스를 국내 암반물성 추론에 이용할 수 있을 것으로 생각된다.

5. 결 론

암반구조물의 설계에 필요한 지질자료가 부족한 경우 인공지능에 의하여 자료를 추론하고 암반을 분류하

Table 10. RMR class item from the results of AEBP application of database

Database number	Item (RMR class)	Input	Output	Truth
21	A	0.0	0.70	1.0
	B	0.0	0.63	0.0
	C	0.0	0.13	0.0
	D	0.0	0.00	0.0
	E	0.0	0.00	0.0
6	A	0.0	0.00	0.0
	B	0.0	0.80	1.0
	C	0.0	0.03	0.0
	D	0.0	0.00	0.0
	E	0.0	0.00	0.0
1	A	0.0	0.00	0.0
	B	0.0	0.09	0.0
	C	0.0	0.99	1.0
	D	0.0	0.00	0.0
	E	0.0	0.00	0.0
8	A	0.0	0.00	0.0
	B	0.0	0.00	0.0
	C	0.0	0.09	0.0
	D	0.0	0.98	1.0
	E	0.0	0.00	0.0

기 위하여 가속화된 신경망 모델을 개발하였다. 개발된 신경망 모델을 잘 알려진 XOR과 문자인식 문제에 적용한 결과 기존 모델보다 학습속도와 인식률이 현저히 향상되었다. 이러한 학습속도와 인식률의 향상은 Lee와 Sterling, Moon과 Lee 등이 적용하였던 대형 모델에서는 더욱 부각되어 수십에서 수백 시간이 걸리던 것이 수 분 내외로 향상되었다.

한편 데이터베이스 내의 몇몇 사례에 대해 암반물성을 추론한 결과 추론 대상이 독립적인 변수일 경우 해당 사례를 데이터베이스에 포함하거나 제외하더라도 잘 추론하지 못하였다. 반면 각각의 사례에 대해 종속 변수인 RMR 값을 구해서 데이터베이스에 추가하여 학습시켜서 임의의 사례에 대한 RMR을 추정한 결과는 계측결과와 일치하여 종속변수에 대해서는 정확하고 신속한 추론이 이루어짐을 확인하였다.

Cecil의 데이터베이스와 RMR 분류를 한 항목을 추가하여 만든 데이터베이스를 일반 국내 사례에 대해 암반물성 추정과 암반분류 모델을 적용한 결과는 문헌자료 및 계측결과와 각각 일치하여 정확하고 신속한 추론이 이루어짐을 확인하였다.

이로부터 가속인공신경망은 현장 자료의 축적으로 데이터베이스가 확장되더라도 빠른 시간에 쉽게 학습이 가능하며, 암반구조물의 초기 설계과정이나 시공과정에 있어서 상당수의 지질자료가 결핍되어도, 합리적인 자료의 추론이나 파괴거동의 예측, 암반분류가 가능하여 현장에서의 적용이 기대된다.

Table 11. Nonzero items from the results of AEBP application on the S quarry slope

Item	Input	Output	Truth	Item	Input	Output	Truth	Item	Input	Output	Truth
<input type="checkbox"/> Intact rock strength				<input type="checkbox"/> Discontinuity persistency				<input type="checkbox"/> Discontinuity roughness			
sound	0.0	1.00	1	continuous	0.0	0.37	0	smooth	1.0	1.00	1
altered	0.0	0.00	0	discontinuous	1.0	1.00	1	rough	0.0	0.00	0
<input type="checkbox"/> Rock mass structure				<input type="checkbox"/> Discontinuity type				Strike			
massive	0.0	0.00	0	joint	1.0	1.00	1	≤ 30	0.0	0.02	0
two set	0.0	0.00	0	bedding	0.0	0.00	0	≤ 90	1.0	1.00	1
three set	1.0	1.00	1	fault	0.0	0.00	0	<input type="checkbox"/> RQD			
random	0.0	0.03	0	<input type="checkbox"/> Discontinuity fillings				good	0.0	0.00	0
<input type="checkbox"/> Average space/span				none	0.0	0.00	0	fair	0.0	0.74	1
0.1~1.0	0.0	0.06	0	nonsoftening clay	1.0	1.00	1	<input type="checkbox"/> Water			
<0.1	0.0	1.00	1	softening clay	0.0	0.09	0	dry	1.0	1.0	1
<input type="checkbox"/> Discontinuity tightness				<input type="checkbox"/> Discontinuity planeness				medium	0.0	0.0	0
very tight	0.0	0.00	0	plane	0.0	1.00	1	<input type="checkbox"/> Discontinuity roughness			
tight	1.0	0.99	1	curved	0.0	0.00	0	dry	1.0	1.0	1
open	0.0	0.01	0	irregular	0.0	0.00	0	medium	0.0	0.0	0

감사의 글

이 논문의 현장계측과 사례연구는 신화산업(주)이 참여한 산학협동재단의 지원으로 이루어졌으며 회사와 재단의 관계자에 감사드린다. 계측에는 대학원생 김형근, 김보현, 전양수의 도움을 크게 입었다.

참 고 문 헌

1. 문현구, 이철우, 1993, 불연속암반내 터널굴착의 안정성 평가 및 암반분류를 위한 인공신경회로망 개발, 터널과지하공간(한국암반공학회지), 3:63-79
2. 양형식, 이희근, 김호영, 김남수, 1995, 암석역학 전문가 시스템(ROMES)에 의한 암반분류 연구, 터널과지하공간(한국암반공학회지), 5:41-47
3. Cecil III, O. S., 1970, Correlation of rock bolt-shotcrete support and rock quality parameters in Scandinavian tunnels, Ph.D. Thesis, University of Illinois, Urbana.
4. Lee C. and Sterling, R., 1992, Identifying probable failure modes for underground opening using a neural network, Int. J. Rock Mech. Min. Sci. & Geomech. Abstr., 29:49-67.
5. Rummelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, Learning internal representations by error propagation. in Rummelhart, D.E. and McClelland (eds), Parallel Distributed Processing : Explorations in the Microstructure of Cognition., 1: 318-362, MIT Press.
6. Zhang, Q., Song, J. and Nie, X., 1991, Application of Neural Network Models to Rock Mechanics and Rock Engineering, Int. J. Rock Mech. Min. Sci. & Geomech. Abstr., 28:535-540.