

불연속 암반내 터널굴착의 안정성 평가 및 암반분류를 위한 인공 신경회로망 개발

문현구¹⁾ · 이철욱²⁾

Development of Artificial Neural Networks for Stability Assessment
of Tunnel Excavation in Discontinuous Rock Masses
and Rock Mass Classification

Hyun Koo Moon and Chul Wook Lee

ABSTRACT

The design of tunnels in rock masses often demands more informations on geologic features and rock mass properties than acquired by usual field survey and laboratory testings. In practice, the situation that a perfect set of geological and mechanical input data is given to geomechanics design engineer is rare, while the engineers are asked to achieve a high level of reliability in their design products. This study presents an artificial neural network which is developed to resolve the difficulties encountered in conventional design techniques, particularly the problem of deteriorating the confidence of existing numerical techniques such as the finite element, boundary element and distinct element methods due to the incomplete and vague input data. The neural network has inferring capabilities to identify the possible failure modes, support requirements and its timing for underground openings, from previous case histories. Use of the neural network has resulted in a better estimate of the correlation between systems of rock mass classifications such as the RMR and Q systems. A back-propagation learning algorithm together with a multi-layer network structure is adopted to enhance the inferential accuracy and efficiency of the neural network. A series of experiments comparing the results of the neural network with the actual field observations are performed to demonstrate the abilities of the artificial neural network as a new tunnel design assistance system.

1. 서 론

터널 등 지하 암반구조물 설계시 현지 암반의 지질구조 및 역학적 조건에 대한 정보를 완벽하게 갖추기는 대단히 어렵다. 따라서 암석역학에 기초한 지하구조물 설계는 항상 분석 대상 물질에 대한 자료가 결핍된 상황 또는 한정된 자료에 의존해야 하는

상황에 처하게 된다. 특히 현지 암반에 분포하는 절리, 층리, 단층 및 파쇄대 등 불연속면에 대한 자료는 설계 단계에 있어 항상 불충분한 상태에 있다고 볼 수 있다. 따라서 “data limited problem”으로 표현되는 암반 공학적 문제의 속성은 불연속면 뿐만 아니라 다른 암반조건에 대한 부분적이며 한정적인 정보에 의해 더욱 현저히 나타나며 결과적으로 설계의 신빙성을

*1993년 4월 접수

1) 정회원. 한양대학교 공과대학 자원공학과 조교수

2) 학생회원. 한양대학교 공과대학 자원공학과 대학원 석사과정

저해하는 근본 원인을 제공하게 된다.¹⁾ 설계를 위한 완벽한 자료의 확보가 현실적으로 불가능하다면 방법은 주어진 자료로부터 설계의 오류와 불확실성을 방지 또는 감소시킬 수 있는 전혀 새로운 개념을 도입하는데 있다. 즉 현장시험과 조사를 통해 암반에 관한 정보를 확장하는 방법을 제외할 경우, 합리적인 해결책을 도출해낼 수 있는 새로운 접근방법은 한정된 자료로부터 필요한 정보를 추론하는 방법이다.²⁾

지하구조물의 경우 비슷한 지질조건에서의 시공경험과 안정성에 대한 전문가의 예측이 설계에 큰 영향을 미친다. 이러한 경험과 예측을 구현하는데 필요한 지식기반을 구축하기 위해, 퍼지(fuzzy) 방법론, 전문가 시스템(expert system), 신경회로망(neural network) 등이 연구되어 왔다.²⁻⁴⁾ 이 중 신경회로망은 신경학 연구로 밝혀진 인간의 뇌를 전산모델로 구현한 것으로, 모델을 학습시킴으로써 인간의 인식과정을 흉내내도록 설계되었다. 따라서 신경회로망은 어떠한 문제를 정의하면서 전 범위에 걸쳐 인과관계를 명확히 할 수 있는 데이터가 정의될 경우, 원래의 입력과 출력의 관계에 대한 단순한 모사의 단계를 넘어서 이를 기초로 논리적인 추론을 수행하게 된다.⁵⁾ 암석역학 분야에서도 이러한 기능을 이용하여 지하공동의 파괴형태를 예측하는데 사용된 바 있으며, 사암 시료의 실험을 통해 구한 탄성 압축률(compressibility)을 예측하는데 적용되기도 하였다.^{4,6)}

터널설계의 초기과정에서는 현재의 지질조건과 굴착과정에서의 안정성의 관계가 구체적이고 논리적인 추론과정을 거쳐 파악되어야 한다. 이러한 작업은 안정성에 가장 큰 영향을 미치는 변수가 무엇인지를 밝혀냄으로써 이후에 시행될 역학적인 분석의 범위를 줄이는 역할을 한다. 대략적인 안정성의 파악이 이루어진 후에는 필요한 보강패턴을 정하는 작업이 필요하게 되며, 이러한 암반의 보강패턴을 체계적으로 제시하는 방법으로는 Q시스템이 있다.⁷⁾ 그러나 Q시스템은 절리와 지하수 및 현장응력과 같은 각 변수들의 등급이 지나치게 세분되어 있으므로 Q값을 구하는 과정에서 사용자가 정확한 값을 선택하는 작업이 어렵게 되어 있다.⁸⁾ 이러한 이유로 좀 더 일반적인 선택기준을 가진 암반분류법인 RMR과의 상관관계를 파악하려는 시도가 있어 왔다.^{8, 11)}

본 연구에서는 터널설계 과정에서 요구되는 안정성의 예측, 그리고 보강기준 제시를 위한 RMR과 Q

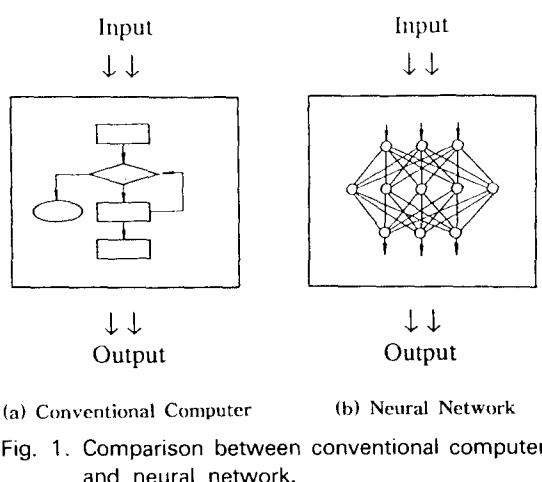
시스템 사이의 상관관계 파악을 연구 목표로 설정하였다. 이를 위해 각기 다른 3개의 신경회로망 모델을 구성하였으며, 이 모델을 통해 추론되어 나온 결과를 분석 평가하였다.

2. 인공 신경회로망에 대한 고찰

2.1 신경회로망의 개요

인간 두뇌의 신경세포를 모방하여 신경컴퓨터(neurocomputer)를 만들어 보려는 시도는 1940년대부터 나타나기 시작하였다. 1943년 McCulloch와 Pitts에 의해 최초의 수학적인 신경회로망 모델이 제시된 후, 1958년에는 Rosenblatt 등에 의해 퍼셉트론(Perceptron)이 개발되었지만, 단층(single layer) 학습구조의 한계점이 드러나게 되어 한동안 연구가 침체되는 시기를 거쳤다. 그러나 70년대 이후 Rumelhart와 McClelland 등이 다층(multi-layer)의 학습이 가능한 오류역전파 학습법칙(error back-propagation learning rule)을 개발하면서 이와 같은 한계점이 극복되어 현대 신경회로망 이론의 틀이 형성되었다.

신경회로망이란 인간의 신경 조직을 모델로 하여 간단한 계산만이 가능한 단위처리기들(processing elements) 사이를 서로 병렬로 연결시킨 정보처리 형태를 의미한다. 이러한 방식은 단위처리기들 간의 연결수가 많으므로, 복잡한 형태를 표현하거나 정보를 분산하여 표현하는 것이 가능하다. 또한 연상작용을 구현할 수 있으므로 학습되지 않은 입력이나 변형된 입력에 대해서도 적절한 출력을 계산해내는 특징을



(a) Conventional Computer

(b) Neural Network

Fig. 1. Comparison between conventional computer and neural network.

지니고 있다.

신경회로망과 기존의 폰 노이만 방식 컴퓨터의 수행과정을 비교해보면 다음과 같다. 폰 노이만 방식 컴퓨터는 기억장소를 참조할 수 있는 하나의 처리기로 구성되어 있으므로, 데이터나 명령어가 Fig. 1(a)와 같이 정해진 순서에 의해 저장된 기억장소로부터 일정한 처리과정을 거쳐 특정 영역의 기억장소에 저장된다. 이에 비해 신경회로망은 여러 개의 단위처리기가 Fig. 1(b)와 같이 상호 병렬로 연결되어 작업을 처리하며, 결과 역시 주어진 입력을 통해 전체 네트워크가 평형상태에 도달하는 방식으로 일어진다. 이것은 기존의 계산에서 프로그래밍에 해당하는 과정이, 신경회로망에서는 입력시킨 데이터 사이의 관계에 의해서 자체적으로 수행되는 것을 의미한다.¹²⁾

2.2 신경회로망의 구조

생물학적인 신경조직의 기본요소는 신경세포(neuron)이며, 그 형태는 Fig. 2(a)와 같이 세포체(cell body)로 이루어진 중심부와 축색돌기(axon), 수상돌기(dendrite)로 이루어진 신경섬유로 되어 있다. 신경세포는 수상돌기가 인접세포로부터 신호를 받아들이고 축색돌기가 신호를 내보내는 작용을 함으로써 신호를 한 방향으로 전달하게 되는데, 이들의 연결부위를 시냅스(synapse)라 한다. 각 신경세포는 이렇게 보내진 신호를 입력으로 하여 신호들의 합이 적당한 수준의 임계값을 초과할 때만 출력력을 생성하는 일종의 임계처리기라고 볼 수 있다. 이와같은 신경세포의 생물학적인 특성을 기반으로 하여 신경회로망 모델을 구현할 수 있다. 신경회로망에서는 Fig. 2(b)와 같이 신경세포의 역할을 단위처리기가 수행하며, 시냅스는 각 단위처리기를 연결하여 주는 연결강도(weight)로 표현한다.¹³⁾

단위처리기는 입력장치 혹은 다른 단위처리기로부터 연결강도가 곱해진 일련의 신호를 받아들인 다음, 이 값을 모두 합하여 활성화 함수(activation function)를 통해 새로운 출력력을 내보내는 작용을 한다. 단위처리기의 특성은 임계값과 비선형의 활성화 함수가 결정하게 된다. 활성화 함수는 Fig. 3과 같이 신경회로망의 종류에 따라 여러가지 형태가 존재한다.

2.3 역전파 신경회로망(back-propagation neural network)

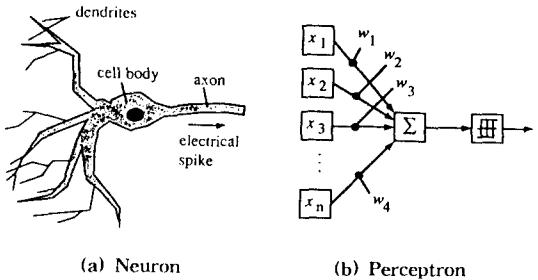


Fig. 2. Neuron and Perceptron.
(from E. Rich, Artificial Intelligence, McGraw-Hill, Inc., 1991).

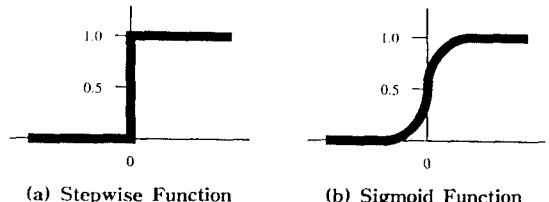


Fig. 3. The stepwise activation function of Perceptron, and the Sigmoid activation function of the back-propagation unit.
(from E. Rich, Artificial Intelligence, McGraw-Hill, Inc., 1991).

신경회로망은 학습방법에 따라 지도학습과 자율학습으로 구분된다. 본 연구에서는 지도학습을 사용하는 신경회로망 중 널리 사용되는 역전파 신경회로망을 사용하였다.

역전파 신경회로망은 두 가지 단계로 동작하는데 학습단계와 산출단계가 있다. 먼저 학습단계에서는 입력패턴과 목적패턴이 다수의 입-출력쌍으로 주어지고, 이 입-출력쌍의 관계를 잘 표현해 주도록 연결강도의 크기를 수정한다. 이러한 작업은 각 입력패턴에 대해 출력력을 먼저 계산한 후, 원하는 출력과 실제 출력의 차이를 줄이는 방향으로 연결강도를 조절함으로써 수행된다. 조절과정이 끝나면 새로운 입-출력쌍이 주어지고 같은 과정으로 학습이 반복된다. Fig. 4는 입력층(input layer), 중간층(hidden layer), 출력층(output layer)으로 구성된 다층 역전파 신경회로망의 구조를 보여주고 있다.

다층 역전파 신경회로망의 학습은 일반적으로 다음의 과정을 거치게 된다. 먼저 입력층(layer i)에 하나의 입력패턴이 주어지면, 중간층(layer j)에 있는

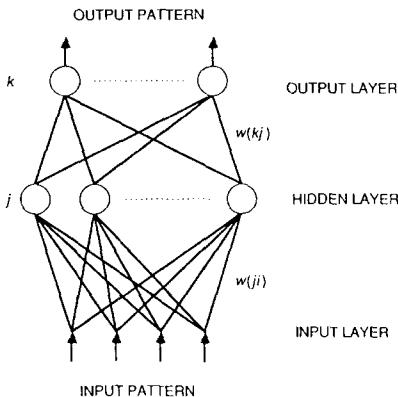


Fig. 4. A schematic depiction of a semilinear feed-forward connectionist net (from Y. Pao, Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Inc., 1989).

단위처리기로 들어가는 순입력(net input)이 다음과 같이 계산된다.

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

여기서 w_{ji} 는 j 층과 i 층을 연결하는 연결강도이며 학습과정에서 적절하게 결정된다. o_{pi} 는 i 층에 있는 단위처리기에서 나오는 출력을 나타내며, net_{pj} 는 활성화 함수를 거친 후 다음과 같이 계산되어 j 층 단위처리기의 출력 o_{pj} 가 된다.

$$o_{pj} = f(net_{pj}) \quad (2)$$

보통 활성화 함수로는 Fig. 5와 같이 0~1 사이의 출력 범위를 갖는 Sigmoid함수가 사용되며 다음과 같이 표현된다.

$$o_{pj} = \frac{1}{1 + e^{-(net_{pj} + \theta_j)}} \quad (3)$$

여기서 θ_j 는 j 층 단위처리기들의 임계값을 의미한다. o_{pj} 는 다시 (1), (2), (3)의 과정을 거쳐 o_{pk} 를 계산함으로써, 임의의 입력패턴은 입력층으로부터 최종 출력층까지 전달되어 출력패턴이 계산된다. 일반적으로 출력패턴 o_{pk} 는 입력패턴과 쌍으로 주어지는 목적패턴 t_{pk} 와 일치하지 않으므로 하나의 패턴 p 에 대해 패턴 오차 E_p 를 다음과 같이 정의한다.

$$E_p = \frac{1}{2} \sum_k (t_{pk} - o_{pk})^2 \quad (4)$$

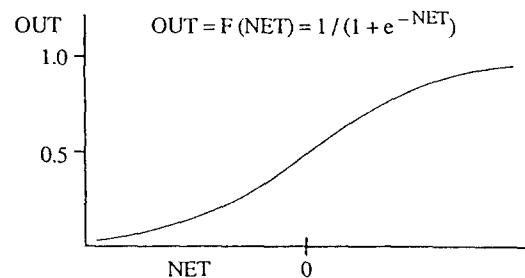


Fig. 5. The Sigmoid activation function.

일단 E_p 가 구해지면 E_p 를 최소화하는 방향으로 연결강도와 임계값을 조정한다. 이러한 연결강도의 조정과정이 끝나면 또 다른 입-출력쌍이 주어지며 같은 방법으로 연결강도를 재조정한다. 이때 시스템 전체의 오차 E_t 는 E_p 를 모두 합하여 구하며 학습에 입-출력쌍으로 사용된 패턴 수를 P 라 할 때 다음과 같이 구해진다.

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

시스템의 학습은 패턴오차 E_p 를 서서히 작게 해서 전체적으로는 시스템오차 E_t 를 최소화하도록 연결강도를 조정하는 방식으로 이루어진다. 이러한 학습과정이 수렴하도록 연결강도의 미소변화량을 다음과 같이 정의한다.

$$\Delta_p w_{kj} = -\eta \frac{\partial E_p}{\partial w_{kj}} \quad (6)$$

여기서 n 는 학습률(learning rate)을 의미하며 학습의 빠르기에 관계된다. (6)의 미소변화량은 합성함수의 미분공식을 사용하여 다음과 같이 구할 수 있다.

$$\begin{aligned} \Delta_p w_{kj} &= -\eta \left(\frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial w_{kj}} \right) \\ &= -\eta \left(\frac{\partial E_p}{\partial net_{pk}} \frac{\partial}{\partial w_{kj}} \sum_k w_{kj} o_{pj} \right) \\ &= -\eta \left(\frac{\partial E_p}{\partial net_{pk}} o_{pj} \right) \\ &= -\eta \delta_{pk} o_{pj} \end{aligned} \quad (7)$$

E_p 는 (1), (2), (4), (6), (7)과 같이 표현되므로 연쇄법칙을 이용하면 미소변화량을 구하는데 필요한 δ

를 출력층인 k 층과 중간층인 j 층에서 다음과 같이 구할 수 있다.

$$\delta_{pk} = (t_{pk} - o_{pk})f'_k(\text{net}_{pk}) \quad (8)$$

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

활성화 함수로 (3)의 Sigmoid함수를 사용할 경우 미분이 가능하므로 (8)과 (9)는 각각 다음과 같이 구해진다.

$$\delta_{pk} = (t_{pk} - o_{pk})o_{pk}(1 - o_{pk}) \quad (10)$$

$$\delta_{pj} = o_{pj}(1 - o_{pj}) \sum_k \delta_{pk} w_{kj} \quad (11)$$

학습과정에서 필요한 연결강도 변화량은 (6)에서 정의한 입-출력쌍의 미세변화량을 모두 합하여 계산하며, 이러한 학습과정은 반복적으로 이루어진다.

$$\Delta w_{kj} = \sum_p \Delta_p w_{kj} \quad (12)$$

최종적으로 학습의 진행속도를 빠르게 하기 위해 판성향(momentum rate) α 를 고려하게 되면, $n+1$ 번째 반복단계에서의 연결강도의 수정량은 다음과 같이 정의된다.

$$\Delta w_{kj}(n+1) = \eta \delta_k o_j + \alpha \Delta w_{kj}(n) \quad (13)$$

각 반복학습 때마다 모든 입-출력쌍이 한번씩 주어지게 된다. 위의 과정이 되풀이되면서 학습이 진행되다가 시스템오차가 정해진 범위에 들어가면 학습이 모두 끝나게 된다. 학습이 끝나면 신경회로망은 내부의 연결강도를 통해 입-출력쌍의 상관관계를 표현하게 된다. 산출단계에서는 학습단계에서 형성된 입-출력쌍의 상관관계에 의해 새로운 입력에 대해 적절한 결과를 출력한다.^{14,15)}

3. 터널 굴착의 안정성 예측

터널을 굴착하는 과정에서 암반의 파괴거동을 예측하고 보강시기를 결정하는 문제는 꼭 해결해야 할 중요한 작업이지만 설계자가 구체적인 기준을 제시하기엔 지질조사자료가 부족한 경우가 많다. 기존의 시공경험에서 얻어진 자료를 활용하여 도움을 얻는 방법도 가능하지만 수많은 시공자료들의 상관관계를

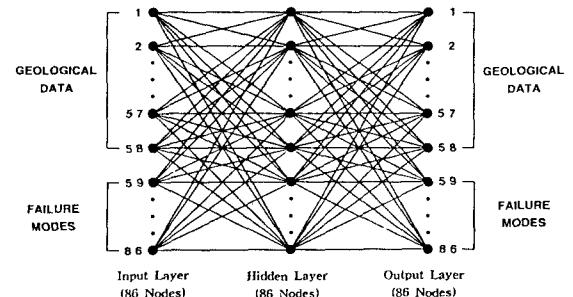


Fig. 6. The structure of neural network NNET-1.

파악하여 현재의 환경에 제대로 활용하기엔 어려움이 따르게 된다. 이러한 문제점을 해결하기 위해 실제 시공사례들을 바탕으로 학습 가능한 신경회로망을 개발하고, 학습에 사용한 입력자료와는 다른 지질조건에 대해 적용해봄으로써 신경회로망의 추론능력을 확인해 보았다.

3.1 모델 설정

본 연구에서 암반의 파괴거동을 예측하는데 사용된 신경회로망 NNET-1은 Lee & Sterling이 사용한 신경회로망과 같은 구조이며, 보강시기를 예측하는데 쓰인 신경회로망 NNET-2는 NNET-1의 단점을 보완한 것이다.

NNET-1에서는 스칸디나비아반도의 실제 시공사례인 Cecil의 자료를 기초로 Lee & Sterling이 재작성한 자료를 학습에 사용하였다.⁴⁾ Lee & Sterling은 Cecil의 모든 사례를 58개 항목의 지질자료와 28개 항목의 파괴거동으로 구분하였다. 각 입력패턴과 목적패턴은 지질자료와 파괴거동을 합해 모두 86개 항목으로 구성되었으며 항목마다 해당사항이 있을 때는 '1'을 해당사항이 없을 때는 '0'을 대입하였다. NNET-1은 Fig. 6과 같이 입력층-중간층-출력층으로 이루어졌으며 각 층은 지질자료 항목과 파괴거동 항목을 대표하는 86개의 단위처리기로 구성되어 있다. 학습을 간단히 하기 위하여 입력층-중간층과 중간층-출력층 단위처리기들 사이의 연결만이 허용되었다.

학습이 시작되면 한 학습주기마다 각 입력패턴과 목적패턴이 신경회로망에 주어지고, 내부에서 계산된 출력패턴과 주어진 목적패턴의 차이인 패턴오차 혹은 이들의 합인 시스템오차를 미리 설정한 기준치와 비교하게 된다. 이때 패턴오차나 시스템오차가 기준치

보다 클 경우 학습 알고리즘에 따라 연결강도가 수정된다. Lee & Sterling은 몇 개의 패턴오차가 0.0001에 도달할 때까지 실험을 수행하였으며, 본 실험에서는 95개의 패턴오차가 합해진 시스템오차가 0.0095에 이를 때까지 학습을 진행하였다. 이때 학습주기는 5000회 정도였고 소요된 총 시간은 PC486/33 MHz 시스템으로 OS/2 2.0상에서 대략 65시간 정도였다. 그러나 일단 학습이 완료된 신경회로망을 실험에 적용하여 결과를 얻는데는 수초 이내의 대단히 짧은 시간이 소요되었다. NNET-1의 경우는 실험결과가 출력층에서 0에서 1사이의 값으로 계산되며, 이 값의 크기가 출력층에서 각 항목이 갖게 되는 상대적인 중요성을 의미한다. 출력된 결과는 Lee & Sterling의 실험결과 및 Cecil의 유사한 현장자료와의 비교로 검증을 시도하였다.

신경회로망 NNET-2에서는 입력자료로 Cecil의 현장 지질조사자료 중 92가지 사례를 사용하였으며 학습에 쓰일 입력패턴을 구성하기 위해 각 사례에서 구체적으로 명시된 39개 항목의 지질자료를 선정하였다.¹⁶⁾ 입력자료를 39개 항목으로 선정한 이유는 본래 현장 지질조사자료에 기록된 내용만을 그대로 학습에 사용함으로써 자료의 작성과정에서 개입될 수 있는 작성자의 주관성을 배제하기 위함이었다. 입력되는 자료의 형태는 아날로그형과 디지털형으로 구분된다. 아날로그형은 '절리군의 수'나 'RQD'처럼 사례별 자료에 정량적인 수치로 기술되어 있는 경우에 사용하였으며, 디지털형은 '신선암의 강도'와 같이 정성적인 표현으로 기술되었거나 '불연속면의 주향'과 같이 하나 이상의 항목에 해당사항이 있을 때 적용하였다. 따라서 각 입력패턴에서 공동의 깊이, 사양, 절리군의 수 그리고 RQD는 실제 수치를 직접 대입하였고, 그 외의 항목은 해당항목에는 '1'을 비해 해당항목에는 '0'을 대입하였다. 입력패턴에 어떠한 범위의 수치가 입력되어도 실제 NNET-2 내부의 계산과정에는 '0'과 '1' 사이로 정규화된 값이 사용된다. 출력자료는 각 사례별 자료에 기록된 불안정한 부분의 위치와 시간-안정성-보강 등급을 기준으로 10개 항목으로 선정하였다. NNET-2는 각층의 단위처리기의 수를 줄이는 대신 중간층을 하나 추가하여 Fig. 7과 같이 입력층-중간층1-중간층2-출력층으로 이루어진 4층 역전파 신경회로망으로 구성하였다.

본 실험에서는 학습주기가 10000회에 도달할 때까

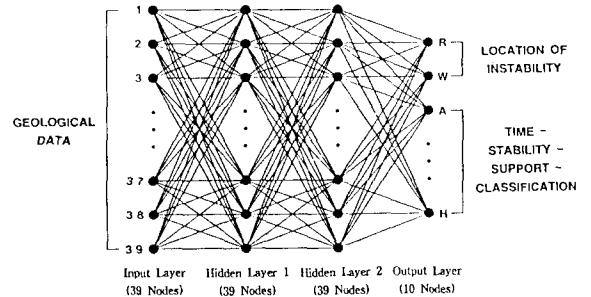


Fig. 7. The structure of network NNET-2.

지 학습을 수행함으로써 시스템오차를 0.058까지 감소시켰다. 그 이상의 학습주기가 시스템오차의 감소율에 미치는 영향은 무시할 수 있는 정도였다. 학습을 수행하는데 소요된 시간은 PC486/33 MHz 시스템으로 OS/2 2.0상에서 약 16시간 정도였다. NNET-2의 경우도 출력층에서의 실험결과는 0에서 1사이의 값으로 계산되었으며, 출력된 결과는 Cecil의 현장 지질자료 중 관련부분과 비교함으로써 검증을 시도하였다.

3.2 실험

첫번째 실험은 현장에서 몇 가지 지질자료만이 제한적으로 관찰가능할 때 신경회로망의 추론기능을 이용하여 부족한 지질자료를 구하고 암반의 파괴거동을 예측하기 위해 수행되었다. 실험을 위해 다음과 같은 조건을 가정하였다. – "The opening is located at medium depth, the rock is sound and the dip angles of the major discontinuities are 30-60° and 60-90°". 가정된 조건을 실험에 적용하기 위해 86개 항목 중 'medium depth', 'sound rock', 'discontinuity dip 30-60°, 60-90°'에서는 '1'을 그리고 나머지 항목들에서는 '0'의 값을 갖는 입력패턴을 작성하여 신경회로망 NNET-1을 통해 계산하였다. 이때 NNET-1의 출력패턴은 Table 1의 두번째 열과 같으며 세 번째 열은 동일한 입력패턴을 적용했을 때 Lee & Sterling의 실험결과이다. 네번째 열부터는 출력패턴과 유사한 사례들을 유사도가 큰 순서대로 배열하였다. 유사도는 NNET-1의 출력패턴과 입력자료로 쓰인 목적패턴들과의 내적으로 계산하였다.

가정된 지질조건에 대해 Cecil¹⁶⁾은 현장 관찰자료에서 다음과 같은 결론을 내리고 있다. – "Very large risk for large roof falls, possible collapse of opening

Table 1. Neural network experiment 1

	Input	Ouput	Lee& Sterling's Ouput	Similar Case 1	Similar Case 2	Similar Case 3	Similar Case 4
- OVERBURDEN							
1. shallow	0	0.00	0.00	0	0	1	1
2. medium	1	1.00	0.41-1.00	1	1	0	0
3. deep	0	0.00	0.00	0	0	0	0
4. very deep	0	0.00	0.00	0	0	0	0
- INTACT ROCK STRENGTH							
5. sound	1	1.00	0.41-1.00	1	1	1	1
6. altered or weathered	0	0.00	0.00	0	0	0	0
- ROCK MASS STRUCTURE							
7. massive	0	0.00	0.01-0.10	0	0	0	0
8. one set of weak plane	0	0.00	0.00	0	0	0	0
9. two sets	0	0.01	0.00	0	0	1	1
10. three sets	0	0.00	0.11-0.20	1	1	0	0
11. random	0	0.00	0.00	0	0	0	0
12. crushed	0	0.00	0.00	0	0	0	0
13. earth-like	0	0.00	0.00	0	0	0	0
- AVERAGE SPACING/SPAN							
14. s/a>1.0	0	0.00	0.00	0	0	0	0
15. 0.1< s/a<1.0	0	0.00	0.21-0.30	0	0	0	0
16. s/a<1.0	0	1.00	0.41-1.00	1	1	1	1
- DISCONTINUITY TIGHTNESS							
17. very tight	0	0.00	0.00	0	0	0	0
18. tight	0	0.18	0.01-0.10	1	1	1	1
19. moderately open	0	0.00	0.00	0	0	0	0
20. open	0	0.54	0.41-1.00	0	0	0	0
21. very wide	0	0.00	0.00	0	0	0	0
- DISCONTINUITY PERSISTENCY							
22. continuous	0	0.95	0.41-1.00	1	1	1	1
23. discontinuous	0	0.51	0.01-0.10	1	1	1	1
- DISCONTINUITY TYPE							
24. joint	0	0.98	0.41-1.00	1	1	1	1
25. bedding	0	0.00	0.00	0	0	0	0
26. cleavage or schistosity	0	0.00	0.00	0	0	1	0
27. fault or shear zones	0	0.00	0.41-1.00	0	0	0	0
- DISCONTINUITY FILLINGS							
28. none	0	0.77	0.41-1.00	1	1	1	1
29. none-softening clay	0	0.00	0.00	0	0	0	0
30. softening clay	0	0.00	0.01-0.10	0	0	0	0
31. other low friction material	0	0.00	0.00	0	0	0	0
32. sandy or gravelly material	0	0.00	0.00	0	0	0	0
- DISCONTINUITY PLANENESS							
33. plane	0	0.96	0.41-1.00	1	1	1	1
34. curved	0	0.00	0.00	0	0	0	0
35. irregular	0	0.00	0.00	0	0	0	0

Table 1. Continued

	Input	Ouput	Lee& Sterling Ouput	Similar Case 1	Similar Case 2	Similar Case 3	Similar Case 4
- DISCONTINUITY ROUGHNESS							
36 slickensided	0	0.00	0.01-0.10	0	0	0	0
37 smooth	0	0.17	0.41-1.00	1	1	1	1
38. rough	0	0.06	0.00	0	0	0	0
- DISCONTINUITY DIP							
39. within 30	0	0.00	0.00	0	0	0	0
40. within 60	1	1.00	0.41-1.00	1	1	1	1
41. within 90	1	1.00	0.41-1.00	1	1	1	1
- DISCONTINUITY STRIKE							
42. in 30 deg	0	0.99	0.41-1.00	1	1	1	1
43. in 60 deg	0	0.86	0.41-1.00	1	1	1	1
44. in 90 deg	0	0.24	0.00	0	0	0	0
- SHEAR ZONING OR FAULTING**							
45. category A	0	0.00	0.00	0	0	0	0
46. category B	0	0.00	0.21-0.30	0	0	0	0
47. category C	0	0.00	0.00	0	0	0	0
48. category D	0	0.00	0.01-0.10	0	0	0	0
49. category E	0	1.00	0.00	1	1	1	1
- RQD							
50. excellent (90%)	0	0.02	0.00	0	0	0	0
51. good (75%)	0	0.00	0.00	0	0	1	1
52. fair (50%)	0	0.00	0.00	1	1	0	0
53. poor (25%)	0	0.00	0.00	0	0	0	0
54. very poor (<25)	0	0.01	0.00	0	0	0	0
- GROUND WATER CONDITION							
55. dry or minor inflow(<5l/min)	0	0.99	0.01-0.10	1	1	1	1
56. medium inflow	0	0.00	0.41-1.00	0	0	0	0
57. large inflow or high inflow	0	0.00	0.00	0	0	0	0
58. exceptionally high inflow	0	0.00	0.00	0	0	0	0
- MODE OF INSTABILITY							
- LOCATION							
59. roof	0	0.01	0.41-1.00	0	0	1	1
60. face	0	0.00	0.00	0	0	0	0
61. wall	0	0.00	0.00	1	1	0	1
62. crown	0	0.00	0.00	0	0	0	0
63. intrados	0	0.00	0.00	0	0	0	0
64. above springline	0	0.00	0.00	0	0	0	0
65. entire section	0	0.00	0.00	0	0	0	0
- VOLUME OF FALL OUT							
66. small	0	0.00	0.00	1	0	0	0
67. moderate(mid)	0	0.00	0.00	0	0	0	0
68. large(heavy)	0	0.00	0.00	0	0	1	1
- MODES							
69. stable	0	0.02	0.00	0	0	0	0

Table 1. Continued

	Input	Ouput	Lee& Sterling's Ouput	Similar Case 1	Similar Case 2	Similar Case 3	Similar Case 4
70. collapse	0	0.00	0.01-0.10	0	0	0	0
71. overbreak	0	0.01	0.00	1	1	1	1
72. small block fall	0	0.00	0.00	0	1	0	1
73. large block slip	0	0.00	0.00	0	0	0	0
74. wedge shaped fall	0	0.00	0.00	0	0	0	0
75. earth-like fall	0	0.00	0.00	0	0	0	0
76. dome-/vault-shaped formation	0	0.02	0.41-1.00	0	0	0	0
77. slabby	0	0.00	0.00	0	0	0	0
78. drummy	0	0.00	0.00	0	0	0	0
79. slabbing	0	0.00	0.00	0	0	0	0
80. popping	0	0.00	0.00	0	0	0	0
81. bumping	0	0.00	0.00	0	0	0	0
82. rock burst	0	0.00	0.00	0	0	0	0
83. squeezing	0	0.00	0.00	0	0	0	0
84. swelling	0	0.00	0.00	0	0	0	0
85. disintegration	0	0.00	0.00	0	0	0	0
86. progressive loosening	0	0.00	0.00	0	1	0	0

- **category A. multiple occurrences of weakness zones containing clay or chemically disintegrated rock, very loose structure.
 B. single weakness zone containing clay or chemically disintegrated rock.
 C. multiple shear zones in clay free rock, loose surrounding rock.
 D. single shear zone in clay free rock.
 E. no shear or fault.

and likely loss of intrados and roof if unsupported". NNET-1이 추론해낸 실험결과에서 유사사례 1과 유사사례 2는 부족한 지질자료 항목에 대해 Lee & Sterling이 추론한 지질조건과 대체로 비슷한 형태를 제시해주었다. 반면 유사사례 3과 유사사례 4는 지질조건은 차이가 있었지만 암반의 파괴거동에서 "Large volume of roof fall out"을 나타냄으로써 Cecil의 관찰결과에 근접한 양상을 보여주었다.

실험결과에서 NNET-1은 부족한 지질자료에 대해 학습한 자료를 기초로 신빙성 있는 기준을 제시할 수 있음이 증명되었다. 이와 함께 암반의 파괴거동을 예측함으로써 설계의 초기단계에서 보강이 필요한 부분을 밝혀줄 수 있음을 보여주고 있다.

두번째 실험과 세번째 실험에서는 암반의 안정성에 영향을 미치는 지질조건의 변화에 따른 신경회로망의 반응을 구체적으로 관찰함으로써 새로이 구성한 신경회로망 NNET-2의 신뢰도를 검증해 보았다.

두번째 실험은 현장 지질조사자료에서 정량적인 값들을 변화시켰을 때 NNET-2가 그에 따른 적절한 보강시기의 변화를 예측할 수 있는지 파악하기 위해 수행되었다. 실험에 사용된 대상은 스웨덴의 Rätan Hydroelectric Project의 방수로터널자료이며, 자세한 내용은 Cecil의 현장자료 Case 87에 보고되어 있다.¹⁶⁾ 입력자료는 Case 87자료를 Table 2와 같이 정리하여 사용하였다. Case 87-1, Case 87-2, Case 87-3자료는 절리군의 수를 하나씩 증가시키고, 그에 따라 RQD를 변화시켜가면서 작성하였다. 실험결과는 Table 3에 기록되어 있으며 입력자료의 변화에 따른 안정성과 보강시기의 변화를 관찰할 수 있었다.

Cecil은 현장사례를 종합하면서 안정성의 문제를 "supported", "unsupported"와 같이 보강의 실시여부에 따라 판단하였다. 그는 현장의 이러한 관찰결과를 기초로 불연속면이 터널의 안정성에 끼치는 영향에 대해 다음과 같은 결론을 내리고 있다. – "Cases

Table 2. Neural network input for experiment 2

	Case 87	Case 87-1	Case 87-2	Case 87-3
– OVERBURDEN				
1. depth (m)	50	50	50	50
– INTACT ROCK STRENGTH				
2. sound	1	1	1	1
3. altered	0	0	0	0
– ROCK MASS STRUCTURE				
4. number of discontinuity sets	0	1	2	3
5. random discontinuity	0	0	0	0
6. crushed discontinuity	0	0	0	0
7. earth-like discontinuity	0	0	0	0
– SPECIFICATION OF OPENING				
8. spacing (m) / span (m)	0.2655	0.2655	0.2655	0.2655
9. spacing (m) / height(m)	0.3614	0.3614	0.3614	0.3614
– DISCONTINUITY TIGHTNESS				
10. tight	1	1	1	1
11. open	0	0	0	0
– DISCONTINUITY PERSISTENCY				
12. continuous	0	0	0	0
13. discontinuous	1	1	1	1
– DISCONTINUITY PERSISTENCY				
14. joint	1	1	1	1
15. bedding plane	0	0	0	0
16. cleavage or schistosity	0	0	0	0
17. fault or shear zone	0	0	0	0
– DISCONTINUITY FILLING OR COATING				
18. none	1	1	1	1
19. none-softening clay	0	0	0	0
20. softening clay	0	0	0	0
21. other low frictional material	0	0	0	0
22. sandy or gravelly material	0	0	0	0
23. alteration along joint	0	0	0	0
– DISCONTINUITY PLANENESS (INTERMEDIATE SCALE)				
24. plane	1	1	1	1
25. curved	0	0	0	0
26. irregular	0	0	0	0
– DISCONTINUITY ROUGHNESS				
27. slickensided	0	0	0	0
28. smooth	0	0	0	0
29. rough	1	1	1	1
– DISCONTINUITY DIP				
30. 0° - 30°	0	0	0	0
31. 30° - 60°	0	0	0	0
32. 60° - 90°	1	1	1	1
– DISCONTINUITY STRIKE				
33. 0° - 30°	0	0	0	0
34. 30° - 60°	0	0	0	0
35. 60° - 90°	1	1	1	1
– ROCK MASS PROPERTY				
36. primary RQD	100	50	30	20

Table 2. Continued

	Case 87	Case 87-1	Case 87-2	Case 87-3
- GROUND WATER PROPERTY				
37. dry or minor inflows (<5 l/min)	1	1	1	1
38. medium inflows (<100 l/min)	0	0	0	0
39. large inflows (>100 l/min)	0	0	0	0

Table 3. Neural network output from experiment 2

	Case 87	Case 87-1	Case 87-2	Case 87-3
- LOCATION OF INSTABILITY				
· roof	0.00	0.00	0.06	0.88
· wall	0.00	0.00	0.00	0.00
- TIME-STABILITY-SUPPORT CLASSIFICATION				
A. stable at blasting, no anticipated falls, no support	1.00	0.99	0.58	0.02
B. minor falls or overbreak at blasting, support not considered necessary for prevention of loosening	0.00	0.00	0.00	0.00
C. stable at blasting, support in anticipation of loosening	0.00	0.00	0.00	0.00
D. stable at blasting, unsupported, gradual deterioration and subsequent support	0.00	0.00	0.00	0.00
E. falls at blasting, support in anticipation of progressive loosening	0.00	0.00	0.00	0.00
F. falls at blasting, no support immediately after blasting, progressive loosening, support applied to prevent further loosening	0.00	0.00	0.00	0.00
G. falls at blasting, support shortly after blasting to prevent or stop progressive loosening	0.00	0.00	0.00	0.00
H. support shortly after blasting, failure of support thereafter, additional support	0.00	0.00	0.00	0.00

involving multiple discontinuity sets are most often associated with support. Single sets of discontinuities are frequently of no concern to the stability of an opening".

두번째 실험에서 구한 NNET-2의 출력자료를 위의 결론과 비교해보면, 절리군의 수가 증가할수록 천정부근에 불안정성이 높아짐을 알 수 있다. 이와 함께 가장 안정한 상태인 등급 A의 중요성이 줄어드는 반면, 보강의 필요성이 더욱 증대되는 등급 C의 중요성이 증가함으로써 Cecil의 관찰결과와 일치하고 있다.

세번째 실험은 현장 지질조사자료에서 정성적인

값들을 변화시켰을 때 신경회로망 NNET-2가 적절한 보강시기의 변화를 예측할 수 있는지 파악하기 위해 수행되었다. 실험에 사용된 대상은 스웨덴의 Vietas Hydroelectric Project의 도수로 터널자료이며, 자세한 내용은 Cecil의 현장자료 Case 29에 보고되어 있다.¹⁶⁾ 입력자료는 Case 29자료를 Table 4와 같이 정리하여 사용하였다. Case 29-1에서는 신선암의 강도, Case 29-2에서는 불연속면의 밀착정도, Case 29-3에서는 불연속면의 거칠기, Case 29-4에서는 굴착방향에 대한 불연속면의 주향, Case 29-5에서는 지하수 상태를 각각 변화시켰다. 실험결과는 Table 5에 나타난 바와 같이 각 항목의 선택에 따른 보강시기의 변화가 출

Table 4. Neural network input for experiment 3

	Case 29	Case 29-1	Case 29-2	Case 29-3	Case 29-4	Case 29-5
- OVERBURDEN						
1. depth(m)	80	80	80	80	80	80
- INTACT ROCK STRENGTH						
2. sound	1	0	1	1	1	1
3. altered	0	1	0	0	0	0
- ROCK MASS STRUCTURE						
4. number of discontinuity sets	1	1	1	1	1	1
5. random discontinuity	0	0	0	0	0	0
6. crushed discontinuity	0	0	0	0	0	0
7. earth-like discontinuity	0	0	0	0	0	0
- SPECIFICATION OF OPENING						
8. spacing (m)/span (m)	0.1600	0.1600	0.1600	0.1600	0.1600	0.1600
9. spacing (m)/height (m)	0.3077	0.3077	0.3077	0.3077	0.3077	0.3077
- DISCONTINUITY TIGHTNESS						
10. tight	1	1	0	1	1	1
11. open	0	0	1	0	0	0
- DISCONTINUITY PERSISTENCY						
12. continuous	0	0	0	0	0	0
13. discontinuous	1	1	1	1	1	1
- DISCONTINUITY TYPE						
14. joint	0	0	0	0	0	0
15. bedding plane	0	0	0	0	0	0
16. cleavage or schistosity	1	1	1	1	1	1
17. fault or shear zone	0	0	0	0	0	0
- DISCONTINUITY FILLING OR COATING						
18. none	1	1	1	0	1	1
19. none-softening clay	0	0	0	1	0	0
20. softening clay	0	0	0	0	0	0
21. other low frictional material	0	0	0	0	0	0
22. sandy or gravelly material	0	0	0	0	0	0
23. alteration along joint	0	0	0	0	0	0
- DISCONTINUITY PLAENESS (INTERMEDIATE SCALE)						
24. plane	0	0	0	0	0	0
25. curved	0	0	0	0	0	0
26. irregular	1	1	1	1	1	1
- DISCONTINUITY ROUGHNESS						
27. slickensided	0	0	0	1	0	0
28. smooth	0	0	0	0	0	0
29. rough	1	1	1	0	1	1
- DISCONTINUITY DIP						
30. 0° - 30°	0	0	0	0	0	0
31. 30° - 60°	1	1	1	1	1	1
32. 60° - 90°	0	0	0	0	0	0
- DISCONTINUITY STRIKE						
33. 0° - 30°	0	0	0	0	1	0
34. 30° - 60°	1	1	1	1	0	1
35. 60° - 90°	0	0	0	0	0	0
- ROCK MASS PROPERTY						
36. primary RQD	90	90	90	90	90	90
- GROUND WATER PROPERTY						
37. dry or minor inflows (<5 l/min)	1	1	1	1	1	0
38. medium inflows (<100 l/min)	0	0	0	0	0	0
39. large inflows (>100 l/min)	0	0	0	0	0	1

Table 5. Neural network output from experiment 3

	Case 29	Case 29-1	Case 29-2	Case 29-3	Case 29-4	Case 29-5
- LOCATION OF INSTABILITY						
. roof	0.00	0.00	1.00	0.00	0.94	0.99
. wall	0.00	0.98	0.00	0.37	0.00	0.00
- TIME-STABILITY-SUPPORT CLASSIFICATION						
A. stable at blasting, no anticipated falls, no support	0.00	0.00	0.00	0.00	0.00	0.00
B. minor falls or overbreak at blasting support not considered necessary for prevention of loosening	1.00	0.18	0.45	0.46	0.90	0.94
C. stable at blasting, support in anticipation of loosening	0.00	0.00	0.00	0.00	0.00	0.00
D. stable at blasting, unsupported, gradual deterioration and subsequent support	0.00	0.00	0.00	0.00	0.00	0.00
E. falls at blasting, support in anticipation of progressive loosening	0.00	0.00	0.00	0.00	0.00	0.00
F. falls at blasting, no support immediately after blasting, progressive loosening, support applied to prevent further loosening	0.00	0.00	0.00	0.02	0.00	0.00
G. falls at blasting, support shortly after blasting to prevent or stop progressive loosening	0.00	0.00	0.07	0.00	0.89	0.28
H. support shortly after blasting, failure of support thereafter, additional support	0.00	0.98	0.00	0.04	0.00	0.00

력되었다.

(i) Case 29-1에서 변화시킨 신선암의 강도에 대해 Cecil이 현장의 관찰결과에서 기술한 내용은 다음과 같다. – “Low intact rock strength may affect tunnel stability by leading to failure of intact rock material during or after blasting. Such behavior is believed to be at least partly responsible for the wall fall out”. 신선암을 풍화암으로 변화시켰을 때 NNET-2의 출력은 측벽에서 불안정성이 상당히 크게 증가하였다. 비교적 안정한 상태인 Case 29에서 나타났던 등급 B의 수치는 가장 크게 줄어든 반면, 가장 시급한 보강이 요구되는 등급 H의 수치가 크게 증가하였다.

(ii) Case 29-2에서 변화시킨 불연속면의 밀착정도에 대해 Cecil은 현장의 관찰결과에서 다음과 같이 기술하고 있다. – “It is plainly evident that a tight rock structure is necessary, but not sufficient, condition for a stable opening. Relatively ‘open’ joints

were observed in 55 of the 74 supported tunnels and in only one of the 16 unsupported tunnels. Relatively ‘tight’ joints occurred in 19 of the 74 supported tunnels and 15 of the unsupported tunnels”. 밀착절리를 열린절리로 변화시킴으로써 NNET-2의 출력은 천정 부근에서 불안정성이 가장 크게 증가하였으며, 안정한 등급 B의 수치도 큰 폭으로 감소하였다. 암반 내에 진행중인 이완현상을 방지하기 위해 발파 직후 신속한 보강이 필요한 등급 G에 다소 변화가 나타났다.

(iii) Case 29-3에서 변화시킨 불연속면의 거칠기에 대한 Cecil의 관찰결과는 다음과 같다. – “Slickensided discontinuities are consistently related to supported tunnels. The positive correction can be attributed to the low friction along slickensides that are frequently clay-coated”. 거친절리에서 Slickensided 절리로 전환됨으로써 NNET-2의 출력은 측벽

부근의 불안정성이 다소 증가하였으며, 등급 B의 수치는 상당히 줄어들었다. 반면, 발파 후 즉각적이지는 않지만 이완을 방지하기 위해 보강이 필요한 등급 F와 가장 위험한 등급 H에 변화가 나타나기 시작하였다.

(iv) Case 29-4에서 변화시킨 불연속면의 주향에 대한 Cecil의 관찰결과는 다음과 같다. – “The chance that a discontinuity set striking sub-parallel(0-30°) to the tunnel axis will lead to instability is greater than that for discontinuity sets that strike normal to the tunnel axis”. 불연속면의 주향이 굴착방향과 30° 이내로 거의 평행한 경우 NNET-2의 출력은 천정부근에서 불안정성이 크게 증가하였다. 발파 직후 신속한 보강이 필요한 등급 G에 안정한 등급 B와 거의 비슷한 정도의 큰 수치증가가 나타났다.

(v) Case 29-5에서 변화시킨 지하수 상태에 대한 Cecil의 관찰결과는 다음과 같다. – “Ground water can have an adverse effect on stability by reducing both the strength of rock materials(physical-chemical effects) and the strength of the rock mass(development of high pore pressures)”. 암반내 지하수의 유입량이 크게 늘어날 경우 NNET-2의 출력은 천정부근의 불안정성이 상당히 크게 증가하였다. 안정한 등급 B의 수치는 약간의 감소를 보인 반면, 발파 직후 신속한 보강이 필요한 등급 G에 다소의 수치증가가 나타났다.

세번째 실험에서는 Cecil이 터널의 안정성에 영향을 미친다고 보았던 요인들을 각각 변화시키면서 신경회로망 실험을 수행하였다. 출력된 결과는 모두 천정 혹은 측벽 부근의 불안정성이 높아졌으며, 보강의 필요성이 공통적으로 증가하였다. 이러한 현상은 모두 현장의 관찰결과와 일치하는 것으로서 학습된 NNET-

2의 신빙성에 대한 검증이 이루어졌다고 볼 수 있다.

4. 암반분류법의 상관관계 정의

주어진 지질조건으로부터 터널내부암반의 파괴동이 파악되고 보강시기가 결정되면, 보강을 어떠한 방법으로 얼마나 시행해야 하는가에 대한 선택이 필요하게 된다. 이를 위해 주로 암반분류법을 이용하게 된다. 대부분의 암반분류법들은 프로젝트가 진행되는 동안 경험했던 특정한 지질조건에 적합하게 개발되었으므로 암반분류법의 개발환경과 유사한 조건을 가진 프로젝트를 수행할 경우에는 많은 도움을 받을 수 있다. 그러나 이러한 접근 방법은 경험적이고 프로젝트에 의존적이라는 단점을 지닌다.¹⁷⁾ 따라서 이러한 단점을 해결하기 위해 암반분류법들 사이의 상관관계를 정의함으로써 각 분류법이 지니고 있는 ‘지역성’을 극복하려는 노력들이 있었다. 특히 가장 널리 사용되는 암반분류법인 RMR과 Q시스템 사이의 관계가 주로 연구의 대상이 되었다.⁸⁻¹¹⁾ 이것은 RMR의 단점인 과도한 보강패턴을 지양하고, Q시스템의 단점인 세분화된 입력자료들에 대한 선택의 어려움을 동시에 극복하며 합리적인 보강선택의 기준을 마련하고자 함이었다.¹¹⁾ 그 동안 연구되었던 RMR과 Q시스템 사이의 관계식들을 정리해보면 Table 6과 같다.

(14)-(17)의 관계식들은 모두 자연대수형태를 취하므로 반대수도표상에서는 선형으로 표현되어 비선형의 분포형태를 가진 현장자료와는 정확하게 일치하지 않는다. 이러한 현장자료와 근접한 상관관계를 정의하기 위해 관계식이 아닌 연결강도로 자료들 사이의 관계를 정의할 수 있는 신경회로망을 개발하였으며,

Table 6. Correlations between the RMR and the Q-index

개발시기	개발자	개발 대상	관계식	
1976	Bieniawski ⁸⁾	62가지 스칸디나비아반도 사례 28가지 남아프리카공화국 사례 21가지 미국 사례(토목용 터널)	$RMR = 9 \ln Q + 44$	(14)
1978	Rutledge and Preston ⁹⁾	7가지 뉴질랜드 터널 프로젝트	$RMR = 5.9 \ln Q + 43$	(15)
1984	Abad et al. ¹⁰⁾	187가지 스페인 석탄광산 사례	$RMR = 10.5 \ln Q + 41.8$	(16)
1986	Keiser ¹¹⁾	캐나다 철도터널 프로젝트	$RMR = 8.7 \ln Q + 38$	(17)

실제 시공자료를 적용하여 RMR로부터 Q값을 구하는 실험을 수행하여 보았다.

4.1 모델 설정

RMR을 개발하기 위해 Bieniawski가 사용하였던 자료는 본래 1973년에 조사된 49가지 사례와 1984년에 추가된 62가지 석탄광산자료, 그리고 1987년에 수집된 78가지 터널자료를 모두 합해 351가지에 이른다. 이 자료들은 모두 데이터베이스화되어 있으며 자료의 일부가 보고되었다.¹⁸⁾ 이 중에서 RMR과 Q값이 각각 구해진 사례는 104가지이며 프로젝트 형

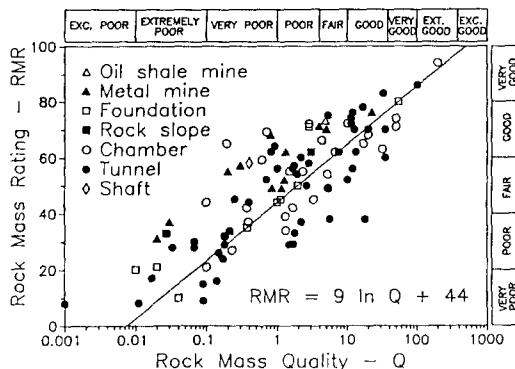


Fig. 8. Correlation between the RMR and Q systems.

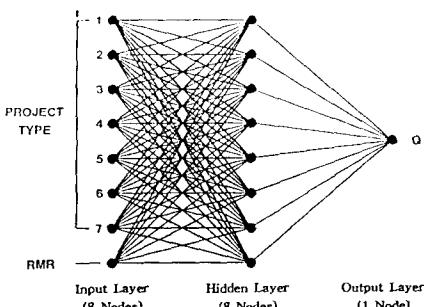


Fig. 9. The structure of neural network NNET-3.

태별로 구분하여 상관관계를 파악해보면 Fig. 8의 양상을 보인다.

실험에 사용된 신경회로망 NNET-3의 입력패턴은 데이터베이스 항목에 기술된 프로젝트 형태 7가지의 적용여부와 RMR로 구성하였으며, 출력패턴은 Q값으로 구성하였다. 입력패턴은 각 프로젝트 항목에 해당여부에 따라 '0'과 '1'이 입력되었으며 RMR은 실제 현장에서 측정한 수치가 입력되었다. 목적패턴은 역시 동일한 장소에서 측정한 Q값으로 작성되었다. NNET-3는 Fig. 9와 같이 입력층-중간층-출력층으로 이루어진 3층 역전파 신경회로망으로 구성하였다.

본 실험에서는 10만회의 학습주기가 되자 시스템 오차가 0.00998이 되었고, 그 이상의 학습주기에 의한 시스템오차의 변화는 무시할 수 있을 정도였다. 학습을 수행하는데 소요된 시간은 PC486/33 MHz 시스템으로 OS/2 2.0상에서 약 16시간 정도였다.

4.2 실험

실험에서는 코네티컷주 하트포드에 시공되었던 Park River터널의 현장자료를 비교대상으로 선정하였다. 자세한 자료는 Bieniawski에 의해 보고되어

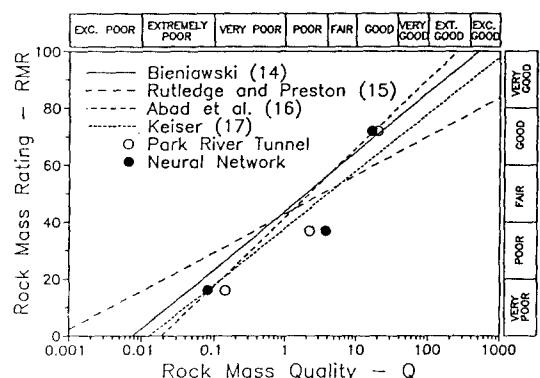


Fig. 10. Comparison between the RMR and the Q values for Park River tunnel.

Table 7. Correlation between the RMR and the Q values for Park River tunnel

Rock Condition	Geomechanics Classification	Q system	Neural Network
Best average conditions: region 1 and 2	RMR=72	Q=20	Q=16.61
Worst average conditions: sta 23+00 to 31+00	RMR=37	Q=2.2	Q=3.75
Fault zones: region 3	RMR=16	Q=0.14	Q=0.08

있다.¹⁹⁾ 현장자료에는 암반조건이 서로 다른 세 구역에서의 RMR과 Q값이 측정되어 있다. 이때의 RMR을 학습된 신경망에 대입하여 계산된 Q값과 현장의 측정자료, 그리고 (14)-(17)식을 각각 비교하였다(Table 7, Fig. 10).

신경회로망 NNET-3가 출력한 Q값을 Fig. 10에서 확인해보면 현장자료의 세 구역에서 모두 문헌에 보고된 측정치에 근접하고 있음을 알 수 있다. 이러한 경향은 반대수도표상의 다른 선형상관관계식들이 정확히 표현하지 못하는 비선형 자료에 대해서도 신경회로망은 관계식에 의존하지 않는 특성을 살려서 신뢰성 있는 결과를 추론해내고 있음을 보여준다.

5. 토 론

본 연구에서 수행된 신경회로망 모델의 실험결과와 의미를 요약하면 다음과 같다.

(1) 터널의 안정성 평가 및 암반분류법의 상관관계 파악에 신경회로망을 적용할 경우, 문헌에 보고된 자료와 동일한 양상을 보임으로써 타당성 있는 해석 결과가 도출되었다. 터널의 경우 유사한 사례를 통해 부족한 지질자료에 대한 기준을 제시하였으며 암반의 파괴거동을 예측하였다. 또한 적절한 보강시기를 결정하기 위해 정량적인 지질자료와 정성적인 지질자료를 변화시킨 실험 모두에서 실험결과는 현장 관찰자료와 일치하였다. 암반분류법의 경우도 기존의 관계식들이 정확히 표현하지 못하는 현장자료의 RMR과 Q값 사이의 비선형 상관관계를 정의할 수 있었다.

(2) 실험을 통해 파악된 신경회로망의 가장 큰 장점은 학습에 사용된 자료가 아닌 현장자료에 대해서도 학습된 자료사이의 관계를 기초로 추론이 가능하다는 점이었다. 이러한 신경회로망의 기능을 이용하여 한정된 현장 지질자료로부터 설계에 필요한 미지의 변수들에 대한 신빙성 있는 선택이 가능하게 되었으며 지질조사자료의 변화에 따른 암반의 파괴거동이나 터널의 안정성을 파악하는 작업이 수행될 수 있었다.

(3) 실험에서 분석된 결과를 통해 알게 된 신경회로망의 또 다른 특성은 학습이 갖는 통계적인 성질이라고 볼 수 있다. 입출력자료의 구조가 비교적 단순한 경우라도 자료간의 연결상태나 상호영향(interaction)을 미치는 정도가 복잡하게 분포할 경우 특정한 관계식을 정의하기가 어렵게 된다. 이러한 적용분야

에서 신경회로망은 통계적 분석과 같이 경향을 파악하는 효과를 볼 수 있음이 확인되었다. 이 때 신경회로망이 출력한 계산결과는 학습시키는 자료의 내용에 가장 크게 영향을 받았다. 즉 입력자료 사이의 관계가 일관성이 있고 모든 범위에 걸쳐 고루 존재할 때 가장 학습이 효과적으로 수행되었으며 출력결과의 신빙성도 높아졌다.

(4) 신경회로망은 단위처리기들 사이의 연결강도를 변화시키는데 학습의 많은 시간을 할애하므로 단위 처리기가 많은 경우에는 학습시간이 기하급수적으로 증가한다. 따라서 NNET-2에서는 정량적인 자료와 정성적인 자료가 동시에 표현되는 새로운 입력자료 구조를 채택함으로써 중간층을 추가하면서도 학습시간을 줄일 수 있었다. 이러한 중간층의 추가는 비선형성을 증가시킴으로써 더욱 다양한 입력자료 사이의 관계를 파악하는 것이 가능하도록 해주었다. NNET-1은 입력패턴과 출력패턴이 같은 형태로 구성되어 있으므로 지질자료의 부족한 부분을 파악하는데는 적절한 구조였지만 암반의 파괴거동이나 안정성을 예측하는 작업에는 NNET-2와 같이 입력과 출력을 상이하게 분리하는 형태가 효과적이었다.

6. 결 론

본 연구에서는 암반터널의 안정성과 보강문제에 대해 신경회로망의 적용가능성을 시험해보았다. 현장 지질조사자료를 기초로 한 입력자료에서 불연속면의 성질들을 변화시키면서 터널내부 암반의 파괴거동과 안정성의 변화에 따른 보강시기 문제를 예측하였고, 문헌에 보고된 실측자료와 비교를 시도하였다. 터널의 안정성에 주로 영향을 미치는 요인들은 불연속면과 관계된 특성들임이 확인되었고, 이러한 경향은 현장의 관찰결과와도 잘 일치하였다. 신경회로망의 이러한 능력은 불연속면의 특성이 터널의 안정성에 미치는 영향을 정량적인 상대성을 통해 파악함으로써 암반의 파괴 메커니즘을 규명하기 위해 모형실험에 소요되는 시간과 비용을 크게 절약해줄 수 있을 것으로 기대된다. 또한 합리적인 보강패턴의 선택에 참고가 되도록 RMR과 Q값의 관계파악을 시도함으로써 서로 다른 두 암반분류법 사이의 상관관계를 새로이 정의하였다.

터널이 굴착될 현장에 실제로 분포하는 불연속면에

대한 자료를 완벽하게 갖추는 작업은 사실상 거의 불가능하다. 따라서 유사한 조건에서 시공되었던 많은 자료들을 학습시킨 신경회로망을 사용하여 터널의 안정성을 평가하는 방법은, 설계자의 주관적인 오류를 방지하고 시공 기술진의 know-how와 시공결과 및 현장 관찰에 기초한 경험적 직관을 체계적으로 정량화 함으로써 설계와 시공간의 괴리를 해소할 수 있는 좋은 방법일 뿐만 아니라 보강에 대한 기준도 제시할 수 있으리라고 본다. 이와 함께 수치해석에 필요한 입력변수의 범위를 정하는데 적용함으로써 터널설계 보조시스템의 역할도 수행할 수 있으리라고 기대된다. 터널설계 작업이 효율적으로 수행되기 위해서는 이러한 모든 과정이 하나로 통합된 터널설계 전문가시스템을 개발하기 위한 노력이 뒤따라야 한다고 본다.

참고문헌

- 1) Starfield, A.M. & Cundall, P.A. (1988) Towards a methodology for rock mechanics modelling, Int. J. Rock Mech. Min. Sci. & Geomech. Abstr. Vol. 25, pp. 99-106.
- 2) Fairhurst, C. & Lin, D. (1985) Fuzzy methodology in tunnel design, Proc. 26th US. Symp. on Rock Mech., pp. 269-278.
- 3) Zhang, Q. et al. (1988) An expert system for classification of rock masses, Proc. 29th US. Symp. on Rock Mech., pp. 283-288.
- 4) Lee, C. & Sterling, R. (1992) Identifying probable failure modes for underground openings using a neural network, Int. J. Rock Mech. Min. Sci. & Geomech. Abstr. Vol. 29, pp. 49-67.
- 5) Wasserman, P.D. (1989) Neural computing: Theory and practice, ANZA Reserch, Inc., pp. 230.
- 6) Zhang, Q., et al. (1991) Application of neural network models to rock mechanics and rock engineering, Int. J. Rock Mech. Min. Sci. & Geomech. Abstr. Vol. 28, pp. 535-540.
- 7) Barton N., et al. (1974) Engineering classification of rock masses for the design of tunnel support, Rock Mech. and Rock Eng., 6, pp. 189-236.
- 8) Bieniawski, Z.T. (1976) Rock mass classifications in rock engineering, Exploration for Rock Engineering, ed. Z.T. Bieniawski, A.A. Balkema, Johannesburg, pp. 97-106.
- 9) Rutledge, J.C. & Preston, R.L. (1978) Experience with engineering classifications of rock, Proc. Int. Tunneling Symp., Tokyo, pp. A3.1-A3.7.
- 10) Abad, J. et al. (1983) Application of geomechanical classification to predict the convergence of coal mine galleries and to design their supports, Proc. 5th Int. Congr. Rock Mech, ISRM, Melbourne, Vol. 2, pp. E15-E19.
- 11) Keiser, P.K., et al. (1986) Evaluation of rock classifications at B.C. Rail Tumbler Ridge tunnels, Rock Mech. and Rock Eng., 19, pp. 205-234.
- 12) 김대수 (1992) 신경망 이론과 응용 (I), 하이테크정보, pp. 364.
- 13) Eberhart, R. & Dobbins R. (1990) Neural network PC Tools; A practical guide, Academic Press, pp. 414.
- 14) Rumelhart D.E. et al. (1986) Learning internal representations by error propagation. Parrallel Distributed Processing: Explorations in the microstructure of cognition. Vol. 1: Foundations, MIT Press, pp. 318-364.
- 15) Pao, Y. (1989) Adaptive pattern recognition and neural networks, Addison-Wesley , pp. 309.
- 16) 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. pp. 415.
- 17) Hudson, J.A. (1989) Rock mechanic principles in engineering practice, CIRIA, pp. 72.
- 18) Bieniawski, Z.T. (1989) Engineering rock mass classifications, John Wiley & Sons, Inc., pp. 251.