

## 인공신경망을 이용한 평면파괴 안정성 예측 A Prediction of the Plane Failure Stability Using Artificial Neural Networks

김방식<sup>1)</sup>, Bang-Sik Kim, 이성기<sup>2)</sup>, Sung-Gi Lee, 서재영<sup>3)</sup>, Jae-Young Seo,  
김광명<sup>4)</sup>, Kwang-Myung Kim

<sup>1)</sup> 충주대학교 토목공학과 교수, Professor, Dept. of Civil Engineering, Chungju. University.

<sup>2)</sup> (주)태조엔지니어링 부사장, Vice President, TESO Engineering Co., Ltd.

<sup>3)</sup> (주)태조엔지니어링 이사, Director, TESO Engineering Co., Ltd.

<sup>4)</sup> (주)태조엔지니어링 대리, Lead Engineer, TESO Engineering Co., Ltd.

**SYNOPSIS** : The stability analysis of rock slope can be predicted using a suitable field data but it cannot be predicted unless suitable field data was taken. In this study, artificial neural networks theory is applied to predict plane failure that has a few data. It is well known that human brain has the advantage of handling disperse and parallel distributed data efficiently. On the basis of this fact, artificial neural networks theory was developed and has been applied to various fields of science successfully. In this study, error back-propagation algorithm that is one of the teaching techniques of artificial neural networks is applied to predict plane failure. In order to verify the applicability of this model, a total of 30 field data results are used. These data are used for training the artificial neural network model and compared between the predicted and the measured. The simulation results show the potentiality of utilizing the neural networks for effective safety factor prediction of plane failure. In conclusion, the well-trained artificial neural network model could be applied to predict the plane failure stability of rock slope.

**Key words** : artificial neural networks, plane failure, error back-propagation algorithm, safety factor

### 1. 서 론

우리나라는 전 국토의 70% 이상이 산지로 구성되어 있어서 도로 및 토목 건설에 따른 사면의 발생은 필연적이다. 더욱이 최근 산업의 발달로 인한 인구의 증가와 따른 토지이용의 증대로 인위적인 사면이 만들어지고 있으며, 사면붕괴의 가능성을 증대시키고 있다. 암반사면의 안정성을 평가하는데 있어 기존의 다수 방법을 이용하고 있으며, 암반분류 및 안전율을 계산 후 시공 및 설계 그리고 보강을 하고 있는 추세이다. 정확한 암반사면의 안전율을 얻기 위해서는 암반의 절리, 층리, 단층 및 파쇄대 그리고 암반의 물성치 등을 파악한 후 안전율을 구하는 것이 일반적인 한계평형해석 방법이다. 그러나 암반의 물성치를 구하는데 있어 현장 여건상 정확한 값을 얻지 못하는 경우가 일반적이며, 이와 같은 신뢰도가 떨어진 내용의 자료를 가지고 사면의 안정성을 평가하다 보니 안전율의 오차가 발생할 가능성이 크며, 적은 입력값을 가지고는 안전율을 계산하기 어려운 실정이다. 퇴적암 지역은 층리를 따라 발생하는 평

면파괴가 일반적이며 이에 대한 보강공법을 제안하고 있다. 따라서 본 연구에서는 이러한 불확실하며, 제한된 입력 자료를 가지고도 암반사면의 평면파괴에 대한 안전율을 예측할 수 있도록 인공지능분야에서 적용되고 있는 인공신경망(artificial neural network) 이론을 도입하였다. 이 이론을 적용한 평면파괴 예측 안전율과 실제 현장에서 한계평형해석을 적용한 안전율과 비교·검토하여 안전율 예측의 적용 가능성에 대해 연구하였다. 본 연구에 적용한 자료는 퇴적암이 주를 이루는 30여 곳의 △△현장들에서 구한 것이며 인공신경망 반복학습 계산은 Visual Basic 6.0 프로그래밍 언어를 사용하였다.

## 2. 평면파괴 해석

평면파괴는 층리면과 같은 지질학적 불연속면이 경사면과 동일한 주향을 가지고 마찰각 보다 더 큰 각도로 굴착면 쪽으로 기울어져 있을 때 발생한다. 안전율의 계산은 정확하게 단일 블록의 경우와 같은 형태를 따른다.




그림 1. 암반사면의 평면파괴

사면내 불연속면과 인장균열의 위치는 현장관찰을 통하여 산정 하거나 다음과 같은 식(Hoek & Bray, 1981)으로 추정하며 우기시 균열면에 작용하는 정수압은 균열깊이의 1/2 위치 정수두로 고려한다.

Mohr-Coulomb 파괴기준을 적용한 안전율 산정식

$$FS = \frac{cA + (W \cdot \cos \alpha - U - V \cdot \sin \alpha) \tan \phi}{W \cdot \sin \alpha + V \cdot \cos \alpha} \quad (1)$$

$w$  : 불연속면의 경사각,

$\alpha$  : 사면의 경사각,  $b/H = \sqrt{\cot \alpha \cot w} - \cot \alpha$

Barton의 경험식을 이용할 경우의 안전율 산정식

$$FS = \frac{\sigma_n \tan (\phi_b + JRC \log \frac{JCS}{\sigma_n})}{W \cdot \sin \alpha + V \cdot \cos \alpha} \quad (2)$$

$\sigma_n$  : 절리면에 작용하는 연직응력 (=  $W \cos \alpha - U - V \sin \alpha$ )

$\phi_b$  : 절리면의 기본마찰각

위와 같은 해석시 안전율에 계산되는 입력값은 불연속면의 기하학적 특성과 불연속면의 물성치가 필요하다. 이러한 입력값을 얻는데는 현장 및 실내실험 등을 통해서 구한다. 현장 및 실내실험에서 구하지 못하는 항목이 존재할 경우 안전율 해석이 어려운 실정이며, 실제로 구한 입력항목에 오류가 존재하고 있어 이에 대한 신뢰성 문제가 해결되어야 한다. 본 연구에서는 입력항목이 부족할 경우 예측 할 수 있는 방안을 제시하기 위해 인공신경망이론을 적용하였다.

### 3. 인공신경망

#### 3.1 다층퍼셉트론

인공신경망(artificial neural network)은 인간 두뇌의 구조와 동작방식을 모델로 하여 간단한 기능을 하는 단위 처리기 사이를 연결시킨 망 구조로, 뇌의 신경세포를 단순화시켜 수학적으로 모델링한 인공 신경세포들과 그들간의 연결로 이루어져 있다. 인공신경망은 세포들간의 연결가중치(connection weight)를 조정하는 학습을 통해 얻어진 내적 지식을 이용하여, 새로운 상황에 일반화 시켜 이용자가 원하는 자료를 정확하게 출력하며, 학습되지 않았거나 학습된 자료의 일부 파손, 왜곡된 자료의 입력시에도 연결가중치에 저장된 자신의 내적 지식에 따라 적절한 결과를 출력한다.




그림 2. 다층퍼셉트론

인공신경망을 구성하는 처리소자들은 비선형 전달함수를 가지고 있어서 시스템의 비선형 특성을 학습할 수 있고 입력과 출력공간의 사상(mapping) 특성에 따라 연상기억(associative memory), 필터(filter), 변환(transformation), 인식(perception), 최적화(optimization) 등의 기능을 수행할 수 있다. 인공신경망은 입력층과 출력층을 거치면서 입력층에서 입력되는 여러 변수들 중에서 출력에 큰 영향을 미치는 변수를 학습규칙에 의하여 선택한 후 예측 안전율을 추정할 수 있다. 여기에서 사용되는 학습규칙은 일반화 델타규칙(generalized delta rule)이며 최급하강법(gradient descent method)에 의하여 행되는데, 최급하강법은 다층 퍼셉트론 인공신경망을 학습시켜 모형의 최적 매개변수를 구하는 방법이다.

다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하는 인공신경 회로망으로 그림 2와 같은 계층구조를 갖는다. Rosenblatt(1958)의 단층 퍼셉트론의 경우 학습 가능한 층이 하나만 존재하기 때문에 선형 분리(linear separable) 가능한 문제에만 적용 가능하다는 한계가 있는데, 이러한 한계를 벗어나기 위하여 다층 퍼셉트론을 이용한다. 네트워크는 입력층, 은닉층 및 출력층 방향으로 연결되어 있으며, 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향(feedforward)의 네트워크이다. 다층 퍼셉트론(multi-layer perceptron)은 단층 퍼셉트론과 유사한 구조를 가지고 있지만 은닉층과 각 유닛의 입출력 특성을 비선형으로 함으로써 네트워크의 능력을 향상시켜 단층 퍼셉트론의 여러 가지 단점들을 극복했다.

#### 3.2 오차 역전파 학습 알고리즘

오차 역전파 학습 알고리즘(error back-propagation learning algorithm)의 기본 원리는 입력층의 각 유닛(unit)에 입력패턴을 주면, 이 신호는 각 유닛에서 변환되어 은닉층에 전달되고 최후에 출력층에서 신호를 출력하게 되는 것이다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파되어 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다.

그림 3은 오차 역전파 학습 알고리즘 과정을 흐름도(flowchart)로 나타낸 것이다. 지도학습에서는 입력 및 원하는 출력 패턴이 네트워크에 제시된다. 네트워크는 입력층에 주어진 입력패턴이 출력층에 전파되면서 변화된 출력패턴을 목표패턴과 비교한다. 네트워크에서 출력된 패턴이 목표패턴과 일치하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우는 얻어진 출력패턴과 목표패턴의 차이를 감소시키

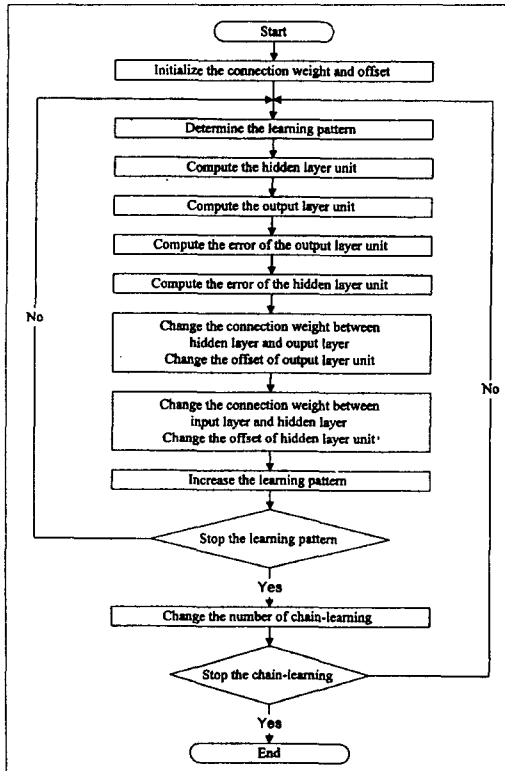


그림 3. 흐름도(flowchart)

는 방향으로 네트워크의 연결강도를 조절하여 학습을 한다. 인공신경망 학습은 현장 및 실험자료(사면높이, 사면경사, 파괴면 경사, 불연속면의 점착력, 불연속면의 마찰각, 암석의 단위중량, 인장균열의 심도)를 가지고 실시하였다. 예측값과 실측값의 제공오차로 표현되는 목적함수의 기울기를 구하여 반복학습에 의한 매개변수의 최소화를 꾀하였고, 이로서 오류 역전과 학습 알고리즘에 의한 최적화 해를 도입하였다.

네트워크에 은닉 유닛이 없는 경우는 델타 규칙과 동일하다. 즉 p번째의 입력, 목표출력 패턴이 제시되는 경우에 노드 i에서 노드 j로의 연결강도의 변화는 식(3)과 같이 표현된다.

$$\Delta_p W_{ji} = \eta(t_{pj} - o_{pj}) i_{pj} = \eta \delta_{pj} i_{pj} \quad (3)$$

$t_{pj}$  : p번째 목표출력 패턴의 j성분

$o_{pj}$  : p번째 입력패턴으로부터 네트워크가 계산한 출력의 j 성분

$i_{pj}$  : p번째 입력패턴의 i 성분

$\delta_{pj}$  : 목표출력과 실제출력의 오차

$$(\delta_{pj} = t_{pj} - o_{pj})$$

$\Delta_p W_{ji}$ : 입력층 i유닛으로부터 출력층 j 유닛의 연결강도 변화량

### 3.3 인공신경망 적용 모델

본 연구에서 사용된 인공신경망 모델은 비선형 연상기억모델로 입력층(input layer), 2층 중간층(hidden layer), 출력층(output layer)의 4개 층으로 이루어져 있는 다층 인식자 모델이다. 입력층은 안전을 예측을 위한 기본 자료를 입력하는 층으로 여기에 입력된 자료는 중간층을 거친 뒤 출력층을 통해 예측안전율로 나오게 된다. 이 과정은 그림 4에 나타내었다. 중간층처리소자의 개수, 연결강도(weight value, w), 학습률(learning rate,  $\eta$ ) 및 threshold value( $\theta$ )는 자유롭게 결정할 수 있도록 하였다. 예측안전율을 위한 입력자료로는 사면높이, 사면경사, 불연속면 경사, 불연속면의 점착력, 불연속면의 마찰각, 암석의 단위중량, 인장균열의 심도를 적용하였다. 또한 입력값이 4~6개, case 별로 안전율을 예측해 보았다.




그림 4. 적용한 인공신경망의 구조

오류역전과 학습 알고리즘의 적용을 위한 변수 값들과 다른 사항은 표 1과 같다. 이 입력값을 가지고 case 별로 반복학습을 실시하였다. 입력값은 평면파괴 해석에 적용하는 내용을 이용하였으며, 현장 여건상 구할 수 없는 경우를 가정하여 1~2가지 생략한 경우까지 고려하였다.

표 1. 인공신경망 모델의 구성

| 구분              | Case 1  | Case 2                                    | Case 3                                | Case 4                                | Case 5                             | Case 6                          |
|-----------------|---|---|---------------------------------------|---------------------------------------|------------------------------------|---------------------------------|
| 입력인자 갯수         | 6   | 6   | 6                                     | 5                                     | 5                                  | 4                               |
| 첫번째 은닉층 PE의 수   | 4   | 4   | 4                                     | 4                                     | 4                                  | 3                               |
| 두번째 은닉층 PE의 수   | 3   | 3   | 3                                     | 3                                     | 3                                  | 2                               |
| 출력인자 개수         | 1   | 1   | 1                                     | 1                                     | 1                                  | 1                               |
| 연결강도의 초기치       | -0.1 ~ 1.0 사이의 난수   |   |                                       |                                       |                                    |                                 |
| 학습률             | 0.5   |   |                                       |                                       |                                    |                                 |
| Threshold value | -0.1 ~ 1.0 사이의 난수   |   |                                       |                                       |                                    |                                 |
| 입력 인자 항목        | H, $\psi_D, \psi_f$<br>$\gamma, c, \Phi$  | Zw, H, $\psi_D$<br>$\psi_f, \gamma, \Phi$ | Z, H, $\psi_D$<br>$\psi_f, \gamma, c$ | H, $\psi_D, \psi_f$<br>$\gamma, \Phi$ | Z, H, $\psi_D$<br>$\psi_f, \gamma$ | H, $\psi_D$<br>$\psi_f, \gamma$ |
| 비 고             | H : 사면 높이, Z : 인장균열 심도, Zw : 인장균열내 지하수위<br>c : 불연속면의 점착력, $\Phi$ : 불연속면의 마찰각, $\gamma$ : 암석의 단위중량 |   |                                       |                                       |                                    |                                 |

### 3.4 안전율 예측의 선정

인공신경망의 학습을 반복하는 동안 최급하강법으로 오차를 수정해 간다. 그림 5는 각 변수들의 값으로 구성된 인공신경망 모델이 학습 진행되는 동안 학습횟수에 따른 오차(Ep)를 나타낸 것으로 매개변수가 최적화되어 가는 과정이라 할 수 있다. 반복 횟수는 10,000번 단위로 50,000번까지 수행하였으며 수행횟수를 증가시키면서 오차(Ep)값의 변화를 확인하였다. 그리고 오차값이 0에 수렴하는 정도를 확인하였다.




그림 5. 학습반복에 따른 오차(Ep)값의 변화

학습의 반복횟수가 10,000번 이상의 경우 오차 (Ep)는 점점 감소하여 0에 수렴함을 볼 수 있다. 그러나 Case 5와 Case 6의 경우는 30,000이상의 반복에서는 오차값이 약간씩 증가하는 경향을 보이나 100,000이상에서는 다른 Case와 같이 0에 수렴함을 확인하였다. 이와 같이 대부분의 경우에 오차값이 0에 수렴하는 것으로 보아 학습이 비교적 잘 되었다 할 수 있다. 이렇게 반복된 학습에서 각각의 경우별로 안전율을 예측해 보았다. 그리고 이 예측된 안전율의 신뢰도를 높이기 위해 통계분석을 실시하였다. 통계분석은 식(4~11)과 같이 현장자료의 예측결과에 대한 평균오차(mean error), 오차의 분산(error variance), 표준개산오차(standard error of estimates), 평균절대편차(mean absolute deviation), 평균절대백분율오차(mean absolute percent errors) 그리고 시계열오차(time series error)를 이용하였다. 이와 같은 통계분석 결과는 그림 6과 같이 계산되었다.

$$E_i = F_i - \hat{F}_i \tag{4}$$

$F_i$ : 실측 안전율,  $\hat{F}_i$ : 예측안전율,  $\bar{F}_i$ : 평균 안전율, N : 자료수

$$ME = \frac{1}{N} \sum_{i=1}^N (F_i - \hat{F}_i) \quad (5)$$

$$\text{Var. (E)} = \frac{1}{N} \sum_{i=1}^N (E_i - \bar{E}_i)^2 \quad (6)$$


$$MAD = \frac{1}{N} \sum_{i=1}^N |E_i| = \frac{1}{N} \sum_{i=1}^N |F_i - \hat{F}_i| \quad (7)$$

$$SSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i)^2} = \sqrt{\frac{1}{N} \sum_{i=1}^N (F_i - \hat{F}_i)^2} \quad (8)$$


$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|F_i - \hat{F}_i|}{F_i} \times 100 (\%) \quad (9)$$

$$TSE = \frac{1}{N} \sum_{i=1}^N \frac{F_i - \hat{F}_i}{F_i} \times 100 (\%) \quad (10)$$


$$R^2 = 1 - \frac{\sum_{i=1}^N (F_i - \hat{F}_i)^2}{\sum_{i=1}^N (F_i - \bar{F}_i)^2} \quad (11)$$




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4



(e) Case 5



(f) Case 6

그림 6. 통계분석 결과

통계분석결과 평균절대백분율오차(MAPE)는 0.026~ 7.092%의 범위로 조사되었으며, 계열오차(TSE)는 -126.55~15.00(%)로 오차가 크게 나타났다. 그러나 그 외 오차는 -1.0~1.0으로 적은 오차가 존재함을 알 수 있었다.

#### 4. 안전율 예측 결과

학습반복에서 횡수를 증가하면서 오차가 0에 수렴하는 것을 그림 5를 통해 확인할 수 있었으며, 각 반복횟수에서 각각의 안전율을 예측해 보았다. 그리고 이 예측안전율을 통계분석 하여 그림 6과 같이 나타남을 알 수 있었다. 이 통계분석을 이용하여 오차가 가장 적은 반복횟수에서 안전율을 예측하였다. 예측안전율은 인공신경망을 이용하여 계산된 값이며, 이 예측안전율을 실제 한계평형법을 이용한 실제 값과 비교·검토하였다. 이와 같은 결과는 그림 7과 같다.

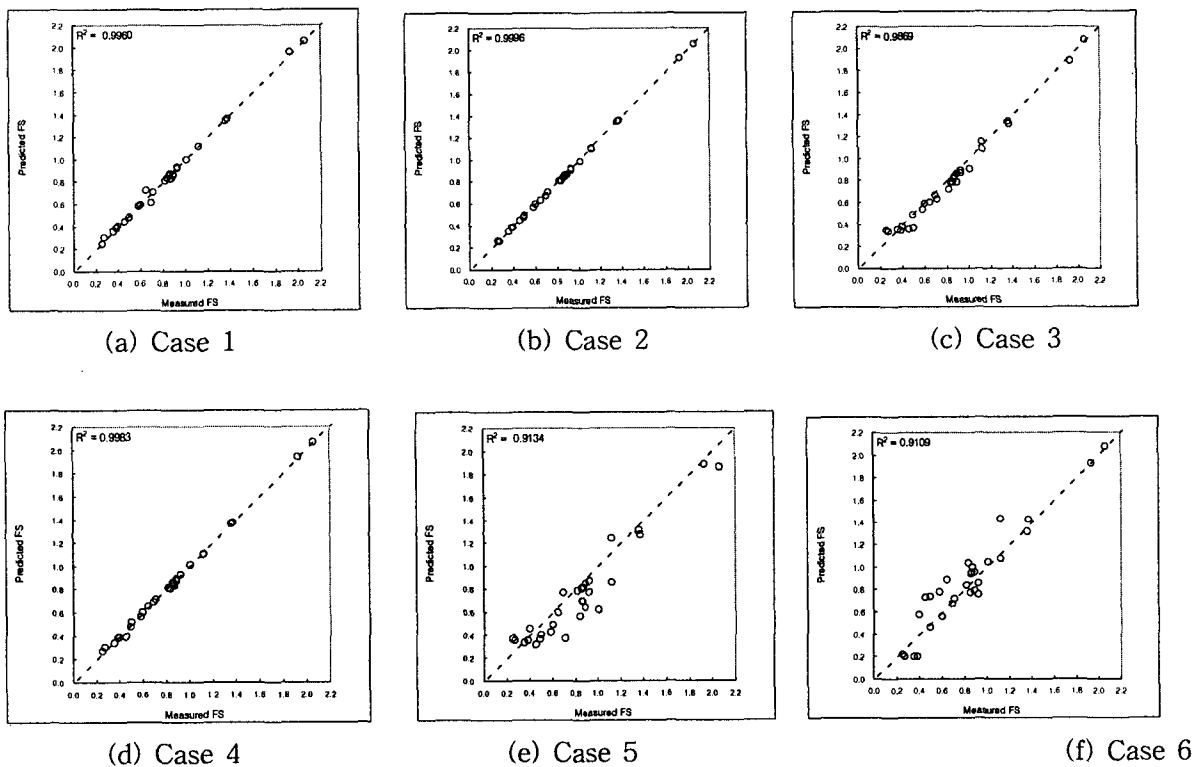


그림 7. 인공신경망을 적용한 예측안전율과 실측안전율

예측안전율은 실측안전율과 1:1 직선상에 나타내었으며, 1:1 직선에 근접 할 수록 기대치에 대한 실측치의 예측이 잘된 것을 볼 수 있다. 결정계수( $R^2$ )는 Case5와 Case 6을 제외하고 모두 0.990이상으로서 아주 높은 수치를 보여주고 있다.

입력값이 6개를 적용한 경우(Case 1~ Case 3)는 한계평형법에서 계산하는 항목을 전부 이용한 것으로 실측안전율과 거의 일치되는 값을 나타내고 있다. 입력값이 5개인(Case 4, Case 5) 경우, Case 4에서는 실측값보다 약간 큰 값으로 예측되나 평균절대백분율오차(MAPE)가 3.067%로 적은 오차를 나타내며, 결정계수( $R^2$ )가 0.9983으로 실측안전율과 거의 같은 안전율을 예측하고 있다. Case 5와 Case 6은 실측값과 약간의 오차를 가지며 예측되고 있다. 그러나 Case 6은 입력값이 4개 항목으로 실제 현장 및 실내에서 물성치를 구하지 못할 경우 1차적으로 확인 할 수 있는 예측 안전율로 이용 가능할 것으로 판단된다. 본 연구에서와 같은 내용을 근거로 평면파괴에서 입력값을 정확히 알지 못 할 경우라도 부족한 입력항목을 가지고 안정성 여부를 예측이 가능함을 알 수 있었다.

## 5. 결론 및 고찰

본 연구에서는 암반사면의 평면파괴의 안전율을 예측하기 위하여 인간 두뇌의 기능적 특성을 컴퓨터에 적용하기 위해 개발된 인공신경회로망 이론을 도입하고 그 적용성을 검토하였다. 인공신경회로망 모델은 일반화된 델타규칙으로 불리우는 오차역전파 학습 알고리즘을 이용하여 다층 신경회로망을 이용하였다. 예측안전율은 한계평형법(식(1))으로 계산된 실측안전율과 비교 · 검토하였다. 본 연구를 수행한 결과는 다음과 같다.

- (1) 인공신경망 이론을 이용한 예측안전율은 실측안전율과 결정계수( $R^2$ )가 0.9이상이며, 평균절대백분율오차(MAPE)가 0.026~ 7.092%의 오차값으로 계산되어 학습이 잘 된 것으로 확인되었다.
- (2) 입력값이 6개인 Case 1~ Case 3은 MAPE가 1.231~7.092%로 실측값과 유사한 안전율로 예측이 계산되며, 입력값이 5개인 Case 4도 MAPE가 0.196으로 실측값과 유사한 결과를 가진다.
- (3) Case 5는 실측값보다 적은 안전율로 예측이 되며, Case 6은 실측값과 보다 크게 안전율이 예측이 되었다.
- (4) Case 6은 입력값이 4개 항목으로 입력값을 전부 사용하지 않은 경우이다. 이 경우는 MAPE는 1.027%, 결정계수( $R^2$ )는 0.9109로 현장 및 실내에서 물성치를 구하지 못할 경우 1차적으로 확인 할 수 있는 예측 안전율로 이용 가능할 것으로 판단된다.
- (5) 평면파괴의 안정성 분석은 현장에서 입수 가능한 자료를 최대한 얻어 평가해야 한다. 그러나 현장 여건상 적합한 자료를 다량으로 조사하지 못할 경우, 지반공학적인 오류가 존재하는 경우가 일반적이라 할 수 있다. 이러한 경우 소량의 자료를 가지고 인공신경망 모델을 적용해서 안정성을 예측할 수 있을 것으로 기대된다.

## 참고문헌

1. 김광명(2002), 인공신경회로망을 이용한 암반사면의 쉐기파괴 안정성 예측, 석사학위논문, 인하대학교
2. 방은영, 윤정방(1996), 뉴럴네트워크와 토목공학에의 적용, 전산구조공학회지, 제 9 권, 제 3 호, pp. 29-33
3. 양형식, 김재철(1999), 인공신경망을 이용한 한국형 터널 암반분류, 한국암반공학회, Vol. 9. pp.214~220
4. 이윤규(2000), "인공신경회로망을 이용한 정규압밀점토의 응력-변형률 거동 예측", 박사학위논문, 인하대학교.
5. G. Lombardi, Geotechnical risks for project financing of tunnels in non-urban areas, ITA-AITES, Dec, 2001
6. James A. Freeman and David M. Skapura, "Neural Networks Algorithms, Applications and Programming Techniques, pp. 1~11
7. Rosenblatt, F.(1958), "The Perceptron : A theory of statistical separability in cognitive system", Cornell Aeronautic Lab., Inc., Rep., No.VG-1196-1, Buffal
8. White, H.(1989), Learning in Artificial Neural Networks : A Statistical Perspective, Neural Computation, 1, Winter, pp. 425-465
9. Zhang, Q., Song, J.R. and Nie, X.Y.(1991), "Application of neural Neural Network Models to Rock Mechanics and Rock Engineering," Int. Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts, Vol. 28, No.6, pp. 535-5