

## 대구지역 퇴적암의 일축압축강도 예측을 위한 인공신경망 적용

임성빈<sup>1)</sup> · 김교원<sup>\*1)</sup> · 서용석<sup>2)</sup>

<sup>1)</sup>경북대학교 지질학과, <sup>2)</sup>충북대학교 지구환경과학과 · 기초과학연구소

### Application of Artificial Neural Networks for Prediction of the Unconfined Compressive Strength (UCS) of Sedimentary Rocks in Daegu

Sung-Bin Yim<sup>1)</sup> · Gyo-Won Kim<sup>\*1)</sup> · Yong-Seok Seo<sup>2)</sup>

<sup>1)</sup>Dept. of Geology, Kyungpook National University,

<sup>2)</sup> Dept. of Earth and Environmental Sci. · Institute for Basic Sciences, Chungbuk National University

암석의 물리적 특성과 슈미트반발경도 결과로부터 일축압축강도를 예측하기 위한 인공신경망 이론의 적용과 최적 모델 구성에 대하여 연구하였다. 대구지역의 퇴적암(사암, 셰일) 시료 55개가 사용되었으며, 이들 중 인공신경망 학습을 위하여 45개가 사용되었고 학습결과의 검증을 위하여 10개의 시료가 이용되었다. 인공신경망에 의한 추산 결과와 비교하기 위하여 통계적 방법을 통한 회귀분석을 통하여 역학특성의 상관식을 도출하였으며, 인공신경망의 유효성 검증을 위하여 모델 구축 시에 사용하지 않은 새로운 자료에 대해 예측을 실시하고 통계적 방법에 의한 결과 및 실내 시험 결과와 비교하였다. 본 연구에 사용한 인공신경망모델에는 백프로파게이션 학습 알고리즘(back-propagation learning algorithm)이 적용되었으며, 인공신경망의 학습효율 및 예측능력에 영향을 미치는 입출력층 및 은닉층의 구조, 학습율, 시스템오차율 등을 달리 하며 학습을 시행하였다. 그 결과 통계적 분석 보다는 인공신경망의 학습에 의한 예측결과가 더 나은 예측능력을 나타냈다.

**주요어:** 인공신경망, 백프로파게이션 학습 알고리즘, 일축압축강도, 슈미트반발경도, 퇴적암

This paper presents the application of a neural network for prediction of the unconfined compressive strength from physical properties and schmidt hardness number on rock samples. To investigate the suitability of this approach, the results of analysis using a neural network are compared to predictions obtained by statistical relations. The data sets containing 55 rock sample records which are composed of sandstone and shale were assembled in Daegu area. They were used to learn the neural network model with the back-propagation learning algorithm. The rock characteristics as the learning input of the neural network are: schmidt hardness number, specific gravity, absorption, porosity, P-wave velocity and S-wave velocity, while the corresponding unconfined compressive strength value functions as the learning output of the neural network. A data set containing 45 test results was used to train the networks with the back-propagation learning algorithm. Another data set of 10 test results was used to validate the generalization and prediction capabilities of the neural network.

**Key words:** artificial neural network, back-propagation learning algorithm, unconfined compressive strength, schmidt hardness number, sedimentary rock

\* Corresponding author: gyokim@knu.ac.kr

## 서 론

현대사회가 고도 산업화됨에 따라서 국토의 효율적인 이용, 사회 간접자본의 확충 및 새로운 공간 창출 등이 요구되면서 고속철도, 지하철 등의 교통시설을 위한 터널과 산업폐기물시설, 에너지 저장시설, 공장 및 발전소 등을 위한 지하공간에 대한 수요가 증대하고 있다. 특히 터널, 암반사면, 지하구조물 및 지하철 등 암반을 대상으로 하는 공사에 있어서 설계 시 암반의 물리적, 역학적 특성의 평가는 구조체의 안전성을 좌우하는 매우 중요한 부분이라고 할 수 있다.

하지만 다양한 생성환경에 따라 서로 다른 지질특성을 보이는 암반은 쉽게 예측할 수 없는 가변성과 불확실성을 내포하고 있으며, 이러한 암반의 특성을 하나의 대표값으로 규정짓는 것은 많은 문제점들을 가지게 되며 이를 극복하기 위하여 새로운 해석적 기법들이 요구되고 있다. 암반의 불확실성을 감소시키기 위한 방법 중의 하나로 최근 암반공학에서는 통계적 기법을 도입하고 확률론을 이용한 연구가 진행되었으며, 기존의 방법으로는 해결하기 어려웠던 부분을 극복하기 위하여 암반을 대상으로 한 인공신경망의 적용에 관한 연구도 수행되고 있다.

1990년대 초반 Zhang et al.(1991)에 의해 암석역학과 암반공학의 연구에 인공신경망이 적용된 후, Toll(1996), Yuanyou et al.(1997), Huang and Wánstedt(1998), Yang and Zhang(1998) 등에 의해 발전되어 왔다. 특히 Meulenkamp and Alvarez(1999)는 암석의 경도(Equotip hardness)를 이용한 암석의 일축압축강도 추정에 인공신경망을 사용하였으며, 암석학적 특성을 바탕으로 한 편암류의 강도 예측에 관한 연구가 Singh et al.(2001)에 의해 이루어 졌다. 국내에서는 1990년대 중반 김남수와 양형식(1996)에 의해 암반의 물성추정에 인공신경망이 이용되었으며, 이인모 등(1997)은 암반의 투수계수 예측에 인공신경망을 적용하였다. 이후 김현우 등(1999), 양형식과 김재철(1999)에 의해 한국형 터널 암반분류와 터널 건전도 평가 시스템 개발에 있어서 인공신경망이 적용되었으며, 세일의 강도예측에 관한 연구가 김영수 등(2003)에 의해 수행되었다.

본 연구에서는 대구지역의 사암과 세일을 대상으로 물리적, 역학적 특성들 중 일축압축강도와 상관성을 가

진다고 판단되는 비중, 흡수율, 공극률, 탄성파속도 및 슈미트반발경도를 측정하고, 이에 대한 회귀분석을 통해 각각의 특성과 일축압축강도 사이의 상관식을 도출한 후 오차율을 분석하였다. 또한 인공신경망의 학습을 통해, 측정된 물리적 특성과 슈미트 반발경도를 이용하여 일축압축강도를 예측하고 실내시험에 의한 일축압축강도 및 도출된 상관식과 비교함으로써 인공신경망의 효율성 및 적용성을 검증하고자 한다.

## 물성 및 역학시험

본 연구에서는 대구지하철 1호선 공사 시 시추조사에 의해 획득된 사암 및 세일의 코어시료를 사용하였으며, 시료의 크기는 NX-size의 원주형 시료로 노선의 구간간에 걸쳐 다양한 심도의 시료를 추출하였다. 물성시험 및 역학시험은 동일 시료를 사용하였으며 사암시료 22개와 세일시료 33개, 총 55개의 암석시료에 대해 시험을 시행하였다. 이 중 무작위로 추출된 사암시료 17개, 세일시료 28개의 시험결과는 인공신경망의 학습용, 나머지 10개의 시험결과는 검증용으로 구분하였다. 세일의 경우 일반적으로 층리에 의한 이방적 역학성을 보이지만 본 연구에서는 설계시의 일반적 시험방법을 따르기 위하여 시추코어를 그대로 사용하였다.

## 물리적 특성과 일축압축강도

일축압축강도에 영향을 미치는 암석의 물리적 특성은 여러 가지가 있으나, 본 연구에서는 비중(Specific gravity,  $G_s$ ), 흡수율(Absorption,  $w_a$ ), 공극률(Porosity,  $n$ ) 등의 기본 물성값과 P파속도(P-wave velocity,  $V_p$ ), S파속도(S-wave velocity,  $V_s$ )를 측정하였다.

측정된 개별 시료의 물리적 특성과 일축압축강도 사이의 관계를 회귀분석을 통해 일차와 이차의 관계식으로 도출하였으며, Table 1에 관계식을 나타내었다. 상관계수는 0.439 ~ 0.845의 분포로 비교적 낮은 상관성을 보이며, 사암은 P파, 세일은 S파와의 관계식이 가장 적합하게 나타난다. 세일의 상관성이 낮은 이유로는 대구 지역의 지층경사가 지역에 따라 차이가 남에 따라 강도 이방성의 영향을 보이는 것과, 코어 내부의 잠재적 결함이 영향을 미친 것으로 판단된다.

**Table 1.** Relationship between physical properties and uniaxial compressive strength( $\sigma$ ) of sedimentary rocks in Daegu area.

| Type           |           |                | Correlation                                      | R     |
|----------------|-----------|----------------|--|-------|
| $G_s - \sigma$ | Sandstone | Linear Eq.     | $\sigma = 6232.2G_s - 15237.6$                   | 0.518 |
|                |           | Polynomial Eq. | $\sigma = 34059.1G_s^2 - 175345.6G_s + 226678.4$ | 0.559 |
|                | Shale     | Linear Eq.     | $\sigma = 13521.1G_s - 35827.5$                  | 0.508 |
|                |           | Polynomial Eq. | $\sigma = 36236.2G_s^2 - 187586G_s + 243150.8$   | 0.511 |
| $w_a - \sigma$ | Sandstone | Linear Eq.     | $\sigma = -498.5w_a + 2021.3$                    | 0.749 |
|                |           | Polynomial Eq. | $\sigma = 162.2w_a^2 - 1099.1w_a + 2341.6$       | 0.796 |
|                | Shale     | Linear Eq.     | $\sigma = -413.8w_a + 1792.1$                    | 0.447 |
|                |           | Polynomial Eq. | $\sigma = 102.6w_a^2 - 877.3w_a + 2146.5$        | 0.482 |
| $n - \sigma$   | Sandstone | Linear Eq.     | $\sigma = -213.8n + 2054.5$                      | 0.761 |
|                |           | Polynomial Eq. | $\sigma = 29.7n^2 - 482.2n + 2416.6$             | 0.812 |
|                | Shale     | Linear Eq.     | $\sigma = -165.4n + 1818.1$                      | 0.439 |
|                |           | Polynomial Eq. | $\sigma = 14.5n^2 - 325n + 2130.6$               | 0.555 |
| $V_p - \sigma$ | Sandstone | Linear Eq.     | $\sigma = 0.3V_p - 12.1$                         | 0.839 |
|                |           | Polynomial Eq. | $\sigma = 0.000022V_p^2 + 0.1V_p + 402.5$        | 0.845 |
|                | Shale     | Linear Eq.     | $\sigma = 0.2V_p + 748.9$                        | 0.532 |
|                |           | Polynomial Eq. | $\sigma = 0.00001V_p^2 + 0.094V_p + 907.7$       | 0.535 |
| $V_s - \sigma$ | Sandstone | Linear Eq.     | $\sigma = 0.43V_s - 341.3$                       | 0.781 |
|                |           | Polynomial Eq. | $\sigma = 0.00015V_s^2 - 0.68V_s + 1578.1$       | 0.829 |
|                | Shale     | Linear Eq.     | $\sigma = 0.31V_s + 285.5$                       | 0.551 |
|                |           | Polynomial Eq. | $\sigma = 0.000034V_s^2 + 0.098V_s + 585.1$      | 0.561 |

**슈미트반발경도와 일축압축강도**

슈미트반발경도(Schmidt hardness number)는 반발치(Rebound value, R) 또는 슈미트반발지수(Schmidt hardness value, SHV)라고도 하며, 반발중추가 암석의 종류와 성질에 따라 튀어오른 거리에 대한 백분율로 표시되며 암석의 강도를 나타내는 척도로 사용될 수 있다. 본 연구에서는 암석시료에 대해 10회 타격 후 상위 50%에 속하는 측정치의 평균값을 사용하였다. 일반적으로 밀도가 증가하면 슈미트반발경도는 증가하고, 반발경도가 크면 일축압축강도는 증가한다. 슈미트반발경도를 측정하여 일축압축강도를 간접적으로 구하는 식은 다음 식(1)과 같다.

$$\sigma (MPa) = 10^{(0.0008 \times R \times \gamma)} \tag{1}$$


여기서, R=슈미트반발경도,  $\gamma$  =건조밀도

**통계적 방법의 검증**

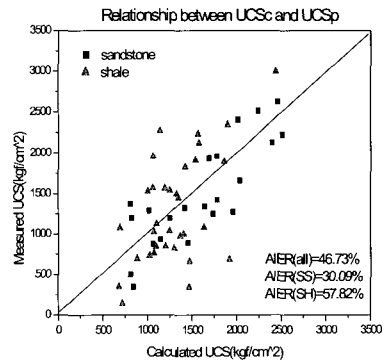
암석의 일축압축강도를 추정하기 위한 물성시험 및 역학시험에 대한 회귀분석결과 도출된 상관식에 대해 식(2)와 같은 평균추론오차를 산정식을 이용하여 각각의 상관식에 대한 계산치의 평균추론오차율(Average Inference Error Rate, AIER)을 산정하고, 이를 통계적 방법의 검증 지표로 삼았다.

**Table 2.** Relationship between calculated UCS from physical properties and measured UCS.

|         |   |           |       |                        |           |       |
|---------|---|-----------|-------|------------------------|-----------|-------|
| Type    | Calculated UCS from Specific gravity and measured UCS |           |       |                        |           |       |
|         | By linear equation                                    |           |       | By polynomial equation |           |       |
|         | All   | Sandstone | Shale | All                    | Sandstone | Shale |
| AIER(%) | 57.11   | 44.42     | 65.57 | 56.03                  | 41.01     | 66.06 |
| Type    | Calculated UCS from Absorption and measured UCS       |           |       |                        |           |       |
|         | By linear equation                                    |           |       | By polynomial equation |           |       |
|         | All   | sandstone | shale | All                    | sandstone | shale |
| AIER(%) | 44.79   | 28.05     | 55.90 | 40.30                  | 23.54     | 51.47 |
| Type    | Calculated UCS from Porosity and measured UCS         |           |       |                        |           |       |
|         | By linear equation                                    |           |       | By polynomial equation |           |       |
|         | All   | sandstone | shale | All                    | sandstone | shale |
| AIER(%) | 43.72   | 27.37     | 54.63 | 40.34                  | 21.77     | 52.72 |
| Type    | Calculated UCS from P-wave velocity and measured UCS  |           |       |                        |           |       |
|         | By linear equation                                    |           |       | By polynomial equation |           |       |
|         | All   | sandstone | shale | All                    | sandstone | shale |
| AIER(%) | 45.59   | 20.70     | 62.18 | 48.84                  | 22.60     | 63.00 |
| Type    | Calculated UCS from S-wave velocity and measured UCS  |           |       |                        |           |       |
|         | By linear equation                                    |           |       | By polynomial equation |           |       |
|         | All   | sandstone | shale | All                    | sandstone | shale |
| AIER(%) | 43.19   | 25.75     | 54.81 | 46.73                  | 30.09     | 57.82 |



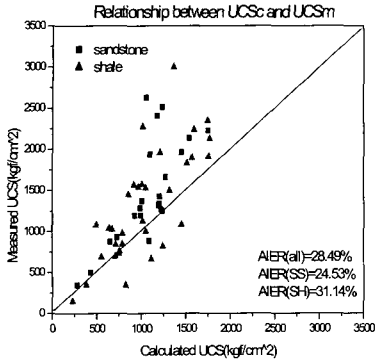
(a)



(b)

**Fig. 1.** Relationship between calculated uniaxial compressive strength ( $\sigma_c$ ) from S-wave velocity and measured uniaxial compressive strength ( $\sigma_m$ ); (a) By linear equation (b) By polynomial equation

## 인공신경망의 적용 및 분석



**Fig. 2.** Relationship between calculated uniaxial compressive strength ( $\sigma_c$ ) from Schmidt hardness value and measured uniaxial compressive strength ( $\sigma_m$ )

$$AIER(\%) = \frac{1}{n} \sum_{i=1}^n \frac{|\sigma_m - \sigma_c|}{\sigma_m} \times 100 \quad (2)$$

여기서  $n$  = 추론자료 수,

$\sigma_m$  = 실험된 일축압축강도,

$\sigma_c$  = 계산된 일축압축강도

암석의 물리적 특성에 의한 상관식에 의해 계산된 일축압축강도( $\sigma_c$ )와 실험에 의한 일축압축강도( $\sigma_m$ ) 사이의 관계를 검토해 본 결과를 Table 2에 요약하였다. 사암과 셰일 모든 자료를 사용한 경우는 S파속도( $V_s$ )에 의해 계산된 일축압축강도( $\sigma_c$ )가 평균추론오차를 43.19%, 사암의 경우는 P파( $V_p$ )에 의해 계산된 일축압축강도( $\sigma_c$ )가 20.70%, 셰일의 경우는 공극률( $n$ )에 의해 계산된 일축압축강도( $\sigma_c$ )가 54.63%로 가장 낮게 나타났다. 모든 경우에서 셰일보다는 사암의 일축압축강도가 더 잘 예측되는 것을 알 수 있다. Fig. 1은 S파속도의 회귀식에 의해 계산된 일축압축강도( $\sigma_c$ )와 실제 측정된 일축압축강도( $\sigma_m$ ) 사이의 관계를 나타낸 그래프이다.

슈미트반발경도를 이용하여 식(1)에 의해 계산된 일축압축강도와 실험된 일축압축강도 사이의 관계를 Fig. 2에 나타내었다. 평균추론오차는 사암, 셰일 각각 24.53%, 31.14%로 나타났다.

### 학습 알고리즘

본 연구에 사용된 인공신경망의 학습 알고리즘은 백프로퍼게이션 학습 알고리즘으로서 이것은 기존의 퍼셉트론과 같은 한계점을 극복하기 위하여 입력층과 출력층 사이에 은닉층(hidden layer)을 사용하여 다중 네트워크를 구성하고, 모든 입력패턴에 대하여 발생하는 오차함수를 최소화하는 방향으로 연결강도를 조정하는 최소자승(least mean square) 알고리즘의 비선형적 확장형이다. 네트워크 형태를 살펴보면 입력되는 입력패턴은 입력층, 은닉층, 출력층의 방향으로 전달되며, 출력층에 전달된 출력패턴은 원하는 출력패턴과 비교하여 오차를 감소하는 방향으로 출력층에서 은닉층, 은닉층에서 입력층의 역방향으로 연결강도를 조정한다. 일반적인 백프로퍼게이션 학습 알고리즘의 학습과정(김대수, 1992)은 Fig. 3과 같다.

### 인공신경망 모델의 구성

백프로퍼게이션 학습 알고리즘을 이용한 인공신경망은 입출력층과 은닉층의 구조, 학습률 및 모멘텀상수로 표현되는 학습상수 및 시스템 오차값 등이 학습효율 및 추론 능력에 영향을 미친다(Eberhart & Dobbins, 1990). 따라서 본 연구에서는 일축압축강도를 추정하기에 가장 적합한 인공신경망 모델을 결정하기 위하여 총 69개의 학습 모델을 설정하여 학습을 수행하였다.

#### (1) 입력변수

본 연구에서는 입력변수의 패턴을 2가지로 분류하였다. 첫 번째는 암종, 비중, 공극률, P파속도, 슈미트반발경도를 사용한 모델 1(M1), 두 번째는 암종, 비중, 함수율, 공극률, P파속도, S파속도, 슈미트반발경도의 총 7개의 입력변수를 사용한 모델 2(M2)이며, 입력데이터는 특성치에 직접 반영하기 위하여 정량적인 데이터를 무차원화하여 입력하였다. 입력변수의 범위는 Table 3에 나타내었다.

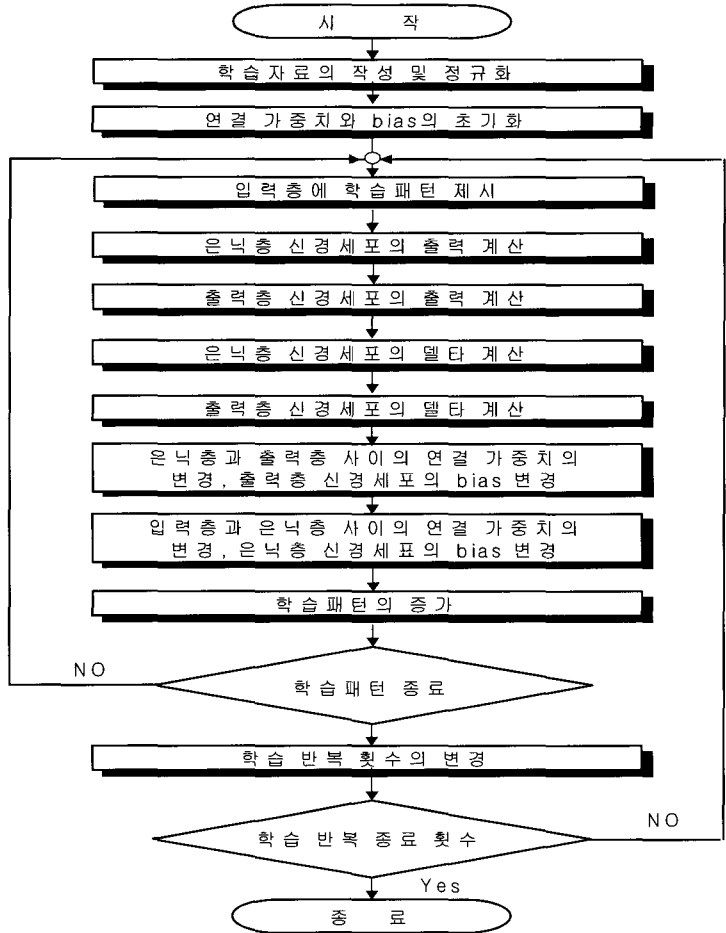


Fig 3. Learning process of Back-propagation algorithm

Table 3. Ranges of input variables for learning process

| Rock type | Code | $G_s$            | $w_a(\%)$        | $n(\%)$           | $V_p$<br>(m/sec)     | $V_s$<br>(m/sec)     | Schmidt<br>hardness<br>number |
|-----------|------|------------------|------------------|-------------------|----------------------|----------------------|-------------------------------|
| Sandstone | 1    | 2.544 ~<br>2.773 | 0.280 ~<br>3.929 | 0.757 ~<br>9.446  | 1497.33 ~<br>7559.52 | 1779.66 ~<br>5636.09 | 20 ~ 56                       |
| Shale     | 2    | 2.709 ~<br>2.844 | 1.068 ~<br>4.530 | 0.195 ~<br>11.067 | 857.27 ~<br>9156.52  | 786.03 ~<br>6086.71  | 16 ~ 56                       |

**Table 4.** Structure, learning constant and learning result of converged artificial neural network system models

| No. | Model    | Input-layer | Hidden-layer | Output-layer | Learning rate | Momentum constant | System error | Learning time(H:M:S) | Learning steps |
|-----|----------|-------------|--------------|--------------|---------------|-------------------|--------------|----------------------|----------------|
| 21  | M2H25    | 7           | 25           | 1            | 0.6           | 0.7               | 0.01         | 20:7:52              | 537,620        |
| 23  | M2H30    | 7           | 30           | 1            | 0.6           | 0.7               | 0.01         | 41:41:25             | 859,350        |
| 25  | M2H35    | 7           | 35           | 1            | 0.6           | 0.7               | 0.01         | 27:21:48             | 578,085        |
| 37  | M2H20H10 | 7           | 20-10        | 1            | 0.6           | 0.7               | 0.01         | 46:59:8              | 751,793        |
| 54  | M2H35    | 7           | 35           | 1            | 0.4           | 0.7               | 0.1          | 5:20:6               | 157,027        |
| 55  | M2H35    | 7           | 35           | 1            | 0.6           | 0.7               | 0.1          | 8:49:35              | 247,239        |
| 56  | M2H35    | 7           | 35           | 1            | 0.8           | 0.7               | 0.1          | 11:7:38              | 253,864        |
| 57  | M2H35    | 7           | 35           | 1            | 0.4           | 0.7               | 0.05         | 8:33:36              | 163,553        |
| 58  | M2H35    | 7           | 35           | 1            | 0.6           | 0.7               | 0.05         | 14:1:23              | 277,770        |
| 59  | M2H35    | 7           | 35           | 1            | 0.8           | 0.7               | 0.05         | 14:58:32             | 301,801        |
| 60  | M2H35    | 7           | 35           | 1            | 0.4           | 0.7               | 0.01         | 6:3:43               | 210,009        |
| 61  | M2H35    | 7           | 35           | 1            | 0.8           | 0.7               | 0.01         | 32:4:26              | 406,517        |
| 63  | M2H20H10 | 7           | 20-10        | 1            | 0.6           | 0.7               | 0.1          | 25:1:37              | 531,959        |
| 66  | M2H20H10 | 7           | 20-10        | 1            | 0.6           | 0.7               | 0.05         | 41:9:45              | 745,040        |

(2) 은닉층의 구조 및 노드수

본 연구에서는 은닉층의 개수를 단층과 다층(2층)으로 구분하였다. 은닉층이 단층인 경우 노드수를 5개에서 50개까지 5개 간격으로 변화시켰다. 다층(2층)인 경우는 두 번째 은닉층의 노드수를 5개부터 첫 번째 은닉층의 노드수가 될 때 까지 5개씩 늘리면서 학습을 시행하여 최적구조를 선정하였다.

(3) 목표시스템오차값, 학습률 및 모멘텀상수

각각 다른 인공신경망 모델에 대하여 먼저 목표시스템오차값 0.01, 학습률 0.6, 모멘텀상수 0.7로 두고 학습을 시행하였다. 그리고 은닉층이 단층인 경우와 다층인 경우 각각 예측능력이 가장 우수한 인공신경망 모델에 대하여 다른 목표시스템오차값과 학습률을 추가 적용하였다. 추가된 목표시스템오차값은 0.05, 0.1 그리고 학습율을 0.4, 0.8이다. 이상의 각 매개변수를 변화시켜 가며 학습을 수행함으로써 각각의 변화에 따른 인공신경망 모델의 학습효율 및 예측능력을 평가하고 이를 기준으로 최적 인공신경망 모델을 결정하였다.

인공신경망 학습 결과

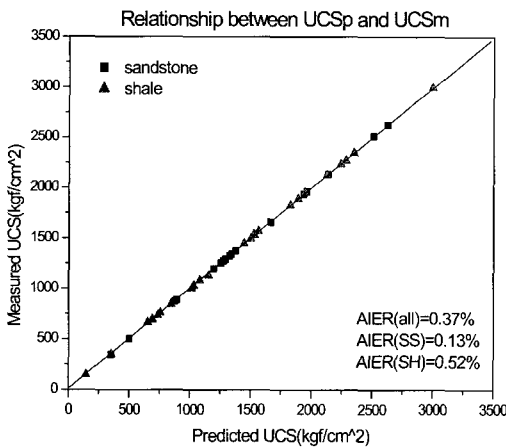
총 69개의 인공신경망 모델 중 학습률이 우수한 모델 14개에 대한 학습 결과를 Table 4에 나타내었다. 학습시간은 모델당 대체로 5시간에서 47시간 정도 소요되었고, 연구의 효율성을 위하여 학습모델에 따라서 발산과 수렴으로 구분하였다. 발산이란 48시간 내에 결과가 시스템 오차 안에 들지 않거나, 계산과정에서 시스템 오차가 일정하게 감소하지 않고 진동하는 경우를 의미한다. 입력변수를 5개로 한 모델1(M1)은 모두 48시간을 초과하였으며, 입력변수를 7개로 한 모델2(M2) 중 총 14개의 모델이 48시간 내에 목표시스템오차에 도달하였다.

(1) 수렴모델 결과 및 검증

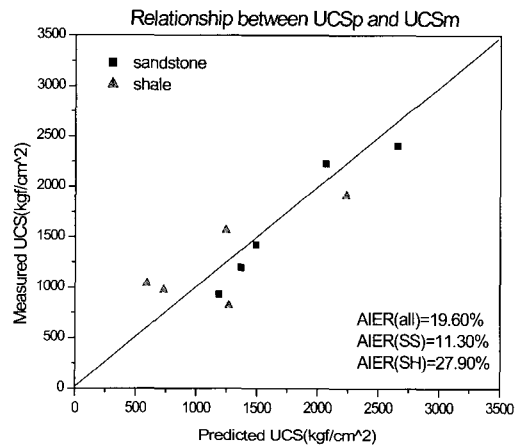
암석의 일축압축강도 예측을 위한 최적의 인공신경망 모델을 선정하기 위하여 각각의 수렴된 모델을 대상으로 예측된 일축압축강도에 대해 식 (2)와 같은 추론오차율 산정식을 이용하였다. 각 인공신경망 모델에 대한 학습자료의 평균추론오차율을 산정하고 이를 최적 인

**Table 5.** Summary of artificial neural network system's results

| No. | Model              | Average Inference Error Rate(AIER, %) |           |       |                     |           |       |
|-----|--------------------|---------------------------------------|-----------|-------|---------------------|-----------|-------|
|     |                    | Use learning data                     |           |       | Use predictive data |           |       |
|     |                    | All                                   | Sandstone | Shale | All                 | Sandstone | Shale |
| 21  | M2H25(0.01-0.6)    | 0.14                                  | 0.13      | 0.15  | 30.35               | 32.37     | 28.33 |
| 23  | M2H30(0.01-0.6)    | 0.15                                  | 0.03      | 0.22  | 25.9                | 18.04     | 33.77 |
| 60  | M2H35(0.01-0.4)    | 0.18                                  | 0.02      | 0.28  | 51.27               | 43.61     | 58.95 |
| 25  | M2H35(0.01-0.6)    | 0.12                                  | 0.02      | 0.19  | 22.34               | 13.03     | 31.66 |
| 61  | M2H35(0.01-0.8)    | 0.09                                  | 0.04      | 0.12  | 20.3                | 12.87     | 27.85 |
| 57  | M2H35(0.05-0.4)    | 1.16                                  | 1.23      | 1.11  | 50.6                | 42.31     | 58.9  |
| 58  | M2H35(0.05-0.6)    | 0.73                                  | 0.41      | 0.92  | 22.36               | 12.7      | 32.03 |
| 59  | M2H35(0.05-0.8)    | 0.37                                  | 0.13      | 0.52  | 19.6                | 11.3      | 27.9  |
| 54  | M2H35(0.1-0.4)     | 2.1                                   | 1.07      | 2.73  | 51.69               | 42.54     | 60.84 |
| 55  | M2H35(0.1-0.6)     | 1.81                                  | 1.07      | 2.26  | 22.67               | 12.25     | 33.09 |
| 56  | M2H35(0.1-0.8)     | 0.74                                  | 0.24      | 1.04  | 18.97               | 10.19     | 27.15 |
| 37  | M2H20H10(0.01-0.6) | 0.23                                  | 0.06      | 0.33  | 34.81               | 22.9      | 46.71 |
| 66  | M2H20H10(0.05-0.6) | 0.91                                  | 1.02      | 0.84  | 27.02               | 29.01     | 25.03 |
| 63  | M2H20H10(0.1-0.6)  | 1.72                                  | 2.02      | 1.54  | 25.09               | 27.86     | 22.31 |



(a)



(b)

**Fig. 4.** Relationship between predicted uniaxial compressive strength( $\sigma_p$ ) of No. 59 M2H35(0.05-0.8) and measured uniaxial compressive strength( $\sigma_m$ ); (a) Using learning data (b) Using predictive data

공신경망 모델의 지표로 삼았다. 각 모델별 분석 결과는 Table 5에 요약하였다. Fig. 4는 은닉층 35개, 학습율 0.8, 모멘텀상수 0.7, 시스템오차 0.05의 단층모델인 No.59 M2H35(0.05-0.8)에 의해 예측된 일축압축강도와 측정된 일축압축강도 사이의 관계를 나타낸 것이다.

(2) 일축압축강도의 예측을 위한 최적 인공신경망 모델 선정

인공신경망의 학습에 사용한 자료를 이용하여 재추론한 결과 평균추론오차율이 모두 3% 이하로 매우 뛰어난 예측능력을 보였으나, 최적 인공신경망 모델의 판



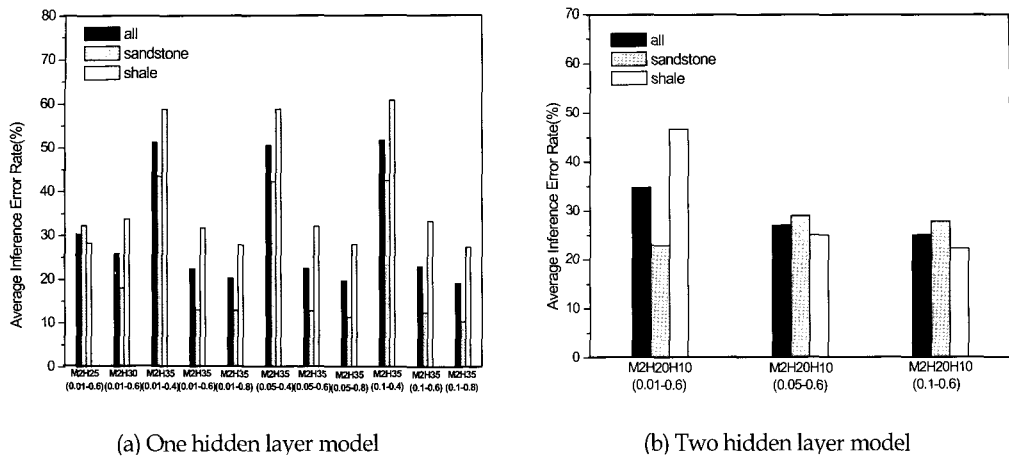


Fig. 5. Average inference error rates of artificial neural network system model

단에서는 학습용 자료의 예측결과는 제외하고 인공신경망의 학습과정에서 전혀 접하지 않은 추론용 자료의 예측결과만을 최적모델 판단의 기준으로 하였다.

단일 은닉층을 가진 모델에 대한 평균추론오차를 비교한 결과를 Fig. 5에 나타내었다. 은닉층의 구조에 따른 변화는 크게 차이를 보이지 않으나 학습률이 0.4인 경우는 예측능력이 현저하게 감소하며, 전반적으로 세일 보다는 사암의 예측능력이 우수한 것으로 나타난다. 사암과 세일 전체의 경우에는 No.56 M2H35(0.1-0.8)의 구조일 때 평균추론오차가 18.97%로 가장 높은 예측능력을 보였으며, 사암의 경우와 세일의 경우도 각각 평균 추론오차율 10.19%와 27.15%로 No.56 M2H35(0.1-0.8)의 구조가 가장 적합한 모델로 판단된다. 은닉층이 다층(2층)인 경우 목표시스템오차가 낮을수록 더 나은 예측능력을 나타내었다. 사암과 세일 전체의 경우에는 평균추론오차율 25.09%로 No.63 M2H20H10(0.1-0.6)의 구조가 가장 예측능력이 높았으며, 사암은 No.37 M2H20H10(0.01-0.6), 세일은 No.63 M2H20H10(0.1-0.6)의 구조가 각각 평균추론오차율 22.9%와 22.31%로 가장 높은 예측능력을 보여 적합모델로 판단된다.

### 결론

대구지역에 분포하는 퇴적암을 대상으로 물성시험과 역학시험을 실시한 자료를 기초로 하여 암석의 물성특성 및 슈미트반발경도와 일축압축강도 사이의 통계적

분석 및 인공신경망을 이용한 일축압축강도의 예측을 시행하였다.

(1) 암석의 물리적 특성 및 슈미트 반발경도와 일축압축강도 사이의 통계적 분석 결과 사암은 P속도와, 세일은 슈미트반발경도와와의 관계에서 평균추론오차율(AIER)이 각각 20.7%, 31.14%로 가장 높은 상관성을 보인다.

(2) 전체 시료를 대상으로 한 추론 결과를 살펴보면 인공신경망의 은닉층이 단층인 경우 No.56 M2H35(0.1-0.8)모델이 평균추론오차율(AIER) 18.97%, 은닉층이 다층(2층)인 경우 No.63 M2H20H10(0.1-0.6) 모델이 25.09%로 가장 우수한 예측능력을 보였으며, 다층보다는 단층모델이 일축압축강도의 예측에 있어서는 더 적합하다.

(3) 암종에 따른 인공신경망의 예측능력은 사암의 경우 은닉층이 단층인 No.56 M2H35(0.1-0.8)의 구조가 평균추론오차율 10.19%, 세일의 경우 은닉층이 2층인 No.63 M2H20H10(0.1-0.6)의 구조가 평균추론오차율 22.31%로 가장 높은 예측능력을 보였으며 세일보다는 사암에 대한 예측능력이 우수한 것으로 나타났다.

(4) 이상과 같이 인공신경망을 이용하여 대구지역 퇴적암의 일축압축강도를 예측한 결과 사암과 세일의 최적 구조에서 평균추론오차율이 10.19%, 22.31%로 다소 높게 나타나 신뢰성이 다소 부족한 것으로 판단된다. 하지만 실험치의 오차를 감안한다면 향후 더 많은 실험 결과의 자료화와 더 다양한 신경망 구조에서의 학습 및 신경망 모델에 관한 연구 등이 진행되어야 할 것으로 사료된다.

## 사 사

본 연구는 건설교통부가 출연하고 한국건설교통기술평가원에서 위탁시행 한 2004년도 건설핵심기술연구개발사업 (과제번호: CI04A1010001-04A0201-00130)의 일환으로 수행되었다.

## 참 고 문 헌

- 김남수, 양형식, 1996, 가속신경망에 의한 암반물성의 추정, 터널과 지하공간, Vol.6, pp.316-325.
- 김대수, 1992, 신경망 이론과 응용(I), 하이테크 정보.
- 김영수, 김동락, 이상웅, 허노영, 2003, 인공신경망을 이용한 암석의 강도 예측, 대한토목학회 정기학술대회, pp.4747-4751.
- 김현우, 김영근, 이희근, 1999, 인공신경망을 이용한 터널 건전도 평가시스템 개발, 터널과 지하공간 Vol.9, pp.48-55.
- 양형식, 김재철, 1999, 인공신경망을 이용한 한국형 터널 암반분류, 터널과 지하공간, Vol.9, pp.214-220.
- 이인모, 조계춘, 이정학, 1997, 인공신경망을 이용한 암반의 투수계수 예측, 한국지반공학학회논문집, Vol.13, No.2, pp.77-89.
- Eberhart, R. C., and Dobbins, R. W., 1990, Neural Network PC Tools, Academic Press Inc.
- Huang, Y. and Wánstedt, S., 1998, The introduction of neural network system and its applications in rock engineering, Engineering Geology, Vol.49, pp.253-260.
- Meulenkamp, F. and Alvarez, G. M., 1999, Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness, Int. J. Rock Mech. Min. Sci., Vol.36, pp.29-39.
- Singh, V. K., Singh D. and Singh, T. N., 2001, Prediction of strength properties of some schistose rock from petrographic properties using artificial neural networks, Int. J. Rock Mech. Min. Sci., Vol.38, pp.269-284.
- Toll, D., 1996, Artificial Intelligence Application in Geotechnical Engineering, Electronic journal of

Geotechnical Engineering, Premiere Issue.

- Yang, Y. and Zhang, Q., 1998, The Application of neural networks to Rock Engineering System (RES), Int. J. Rock Mech. Min. Sci., Vol.35, pp.727-745.
- Yuanyou, X., Yanming, X. and Ruigeng, Z. R., 1997, An engineering geology evaluation method based on an artificial neural network and its application, Engineering Geology, Vol.47, pp.149-156.
- 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., Vol.28, pp.535-540.

투 고 일 2004년 11월 23일

심 사 일 2004년 11월 28일

심사완료일 2005년 3월 10일

임성빈

경북대학교 지질학과

702-701 대구광역시 북구 산격동 1370

Tel: 053)950-5357

E-mail: bins123@daum.net

김교원

경북대학교 지질학과

702-701 대구광역시 북구 산격동 1370

Tel: 053)950-5357

E-mail: gyokim@knu.ac.kr

서용석

충북대학교 지구환경과학과

361-763 충북 청주시 흥덕구 개신동 산48

Tel: 043-261-2765

Fax: 043-276-9645

E-mail: ysseo@cbu.ac.kr