

인공신경망을 이용한 한국형 터널 암반분류

양형식¹⁾ · 김재철²⁾

Rock Mass Rating for Korean Tunnels Using Artificial Neural Network

Hyung-Sik Yang & Jae-Chul Kim

ABSTRACT In this study, the validity of items of RMR system is evaluated and the applicability of this system to the data measured in Korean sites is discussed. Database was constructed from 139 sites, which are composed of subways, railway tunnels and road tunnels. These sites are located nationwide. Analysis shows that original classification of Bieniawski is valid although it was derived empirically. But it has considerable rating difference (error) in the result of Korean application. Thus new classification systems of KRMR1 and KRMR2 are suggested, which are deduced from the Korean database. The former includes adjusted ratings and the latter adopts two more items. These are deduced by artificial neural network because it is difficult to select 'characteristic value' to estimate rock quality.

Key words : RMR, Rock classification, neural network, tunnel, Korea

초 록 본 연구에서는 RMR system 항목들의 타당성을 평가하였고 국내현장에서 측정된 데이터에 대한 적용성을 검토하였다. 데이터베이스는 전국에 걸쳐 지하철, 철도, 도로 터널로 구분하여 139개 현장으로부터 작성하였다. Bieniawski의 원 분류는 경험적으로 도출되었지만 비교적 타당한 것으로 분석되었다. 그러나 국내 현장에 적용할 때에는 상당한 차이가 있어서 국내의 데이터베이스로 추론한 새로운 암반분류 시스템 KRMR1과 KRMR2를 제안하였다. KRMR1에서는 인자들의 등급비중을 조정하였으며 KRMR2에는 2개의 인자를 추가하였다. 이 과정에서 암반의 성질을 평가하는 '특성치'의 선택이 어려워 인공신경망을 이용하여 추론하였다.

핵심어 : RMR, 암반분류, 인공신경망, 터널, 한국

1. 서 론

현재 세계적으로 널리 사용되고 있는 RMR 암반분류의 타당성을 검토하고 한국의 지질상황에 적합한지 여부를 추론하기 위하여 인공신경망을 이용하였다.

현재 터널 암반분류에 가장 보편적으로 적용되고 있는 RMR 분류 등은 한국의 지질상황에 기초하지 않은 암반 분류법으로서 이를 한국의 터널 암반 분류에 그대로 적용하였을 때 문제점이 있을 수 있다. 또 RMR의 조사 항목이나 배점에 있어서도 이론적인 근거 없이 직관에 의해 선정이 되어 있으며 이러한 인자들로서 결정되는 단일 특성치가 없으므로 그 타당성을 판정할 수단이 마땅하지 않은 것이 현실이다.

이러한 점을 고려하여 인공 신경망을 이용하여 주관적인 판단을 배제시키고 기존 암반분류의 항목별 배점 타당

성 및 조사항목들의 대표성을 검토하였다. 인공신경망은 다층 오류 역전파 학습알고리즘을 사용하고 실수형으로 입력하는 방식을 적용하였다.

본 연구를 위하여 전국에 걸쳐서, 고속도로, 국도, 철도, 지하철 등의 다양한 터널 종류별로 데이터를 취득하여 편중된 데이터에 의한 오류를 최소한으로 줄였다.

2. 신경망 이론의 국내 암반공학분야 적용 사례

터널설계 과정에서 지질조건과 굴착과정의 안정성이 검토되어야 한다. 초기단계에서 안정성에 큰 영향을 미치는

1) 정회원, 전남대학교 자원공학과 교수

2) 학생회원, 전남대학교 자원공학과

원고 접수일 : 1999년 6월 21일

원고 심사 완료일 : 1999년 8월 5일

변수가 무엇인지를 알 수 있다면 이후에 시행될 역학적 분석의 범위를 줄일 수 있다. 인공신경망은 학습이 어렵지만 비선형적인 관계를 가지는 현상의 많은 변수들을 종합하여 판단할 수 있는 큰 장점이 있다.

이(1993)는 오류역전파 신경망을 이용하여 터널굴착의 안정성을 연구하였다. 스칸디나비아 반도의 실제 시공사례인 Cecil(1970)의 자료를 기초로 58개 항목의 지질자료와 28개 항목의 파괴거동을 모델링하였다. 이 모델로 현장에서 몇 가지 지질자료만이 제한적으로 관찰 가능할 때 신경회로망의 추론기능을 이용하여 부족한 지질자료를 구하고 암반의 파괴거동을 예측하였으며, 현장 지질조사자료에서 정량적인 값과 정성적인 값들을 각각 변화시켰을 때 신경망이 그에 따른 적절한 보강시기의 변화를 예측할 수 있음을 보였다.

양과 김(1996)은 오류역전파 신경망의 최대단점인 학습시간의 문제를 해결하기 위해 새로운 Sigmoid 함수를 이용한 ‘가속 오류 역전파 신경망’을 적용하였다.

이로써 수 십 시간씩 소요되었던 학습시간이 수 분 정도로 단축되어도 오차가 같은 정도의 결과를 얻을 수 있었다. 이 모델로 Cecil의 데이터베이스와 RMR 분류 결과를 추가하여 만든 데이터베이스를 일반 국내 사례에 대해 적용하여 정확하고 신속한 추론이 이루어짐을 확인하였다.

한편 권(1998)은 암염 및 칼륨 광산 내의 지하공동에 대한 거동 예측을 실시하였다.

3. RMR 분류

Bieniawski(1973)에 의해 제안된 RMR 분류법과 Barton 등(1974)에 의해 제안된 Q분류법은 RSR 분류법

의 변수별 등급 부여 방식과 Lauffer의 자립시간 개념을 계승하여 독자적으로 제안되었으며, 두 분류법 모두 록볼트, 슛크리트와 같은 최신 터널 보강재의 물량을 정량적으로 결정할 수 있는 자료를 제공한다. Q 분류법은 특히 터널 및 지하공동을 대상으로 개발되었고 RMR 분류법은 최초에는 터널을 대상으로 개발되었으나 암반사면, 기초, 지반 절취도 평가 및 광산터널 문제에도 활용되고 있다. Table 1은 현재 적용되고 있는 주요한 암반분류이다 (Bieniawski, 1979).

RMR 분류법에서는 현장에서 측정 가능하거나 시추자료로부터 구할 수 있는 다음 5 가지의 변수에 대하여 각각 등급 점수를 부여하고 이를 합산하여 기초 RMR 값을 계산한다.

$$RMR_{BASIC} = R_{UCS} + R_{RQD} + R_{JS} + R_{JA} + R_W \quad (1)$$

- R_{UCS} : 무결암의 단축압축강도 등급
- R_{RQD} : RQD 등급
- R_{JS} : 불연속면의 간격 등급
- R_{JA} : 불연속면의 상태 등급
- R_W : 지하수의 상태 등급

총 RMR은 기초 RMR 등급에 암반의 용도별로 불연속면의 방향과 암반구조의 방향이 적합한지 여부에 따라서 조정한다. 암반을 분류할 때 모든 변수들의 중요도가 동일하지 않기 때문에 Bieniawski는 중요도에 따라 변수들에서 서로 다른 점수범위를 할당하였다. 이러한 평점은 49개의 사례조사를 통하여 결정되었다. RMR의 실제적인 의미를 나타내는 특성치는 터널이나 공동의 자립시간과 최대무지보 폭 또는 최대 굴착가능 폭의 조합으로 표시된다(Fig. 1).

4. 암반분류를 위한 신경망

Table 1. Major rock mass classifications

| Name | Originator and date | Country of origin | Applications |
|----------------------|----------------------|-------------------|-----------------------------|
| Rock loads | Terzaghi, 1946 | USA | Tunnels with steel supports |
| Stand-up time | Lauffer, 1958 | Austria | Tunneling |
| RQD | Deere, 1964 | USA | Core logging, tunneling |
| Intact rock strength | Deere & Miller, 1966 | USA | Communication |
| RSR concept | Wickham et al., 1972 | USA | Tunneling |
| RMR system | Bieniawski, 1973 | S. Africa & USA | Tunnels, mines, foundations |
| Q system | Barton et al., 1974 | Norway | Tunneling, large chambers |
| Strength/block size | Franklin, 1975 | Canada | Tunneling |
| BGD | ISRM, 1981 | International | General |




Fig. 1. Relationship between the stand-up time and span for various rock mass ratings

4.1 신경망 시뮬레이터의 구현

신경망 시뮬레이터는 입력층, 은닉층, 출력층의 세 개의 층을 가지며 실수형 입력자료를 입력받아 학습을 실시하고 오류역전파 알고리즘 및 목적패턴과 출력패턴을 비교하는 감독 학습방법을 구현하도록 하였다. 데이터를 추가할 때에는 학습시간의 단축을 위하여 기존의 연결강도를 불러서 사용할 수 있도록 User-interface를 첨가하였으며 학습의 결과를 테스트하기 위하여 User-interface를 하나 더 첨가하였다(Fig 2). 입력 데이터는 특성치에 직접 반영하기 위하여 정량적인 데이터를 무차원화하여 입력하는 방식을 택하였다.

4.2 시뮬레이터의 안정성 검토

신경망 시뮬레이터의 안정성을 검토하기 위하여 RMR

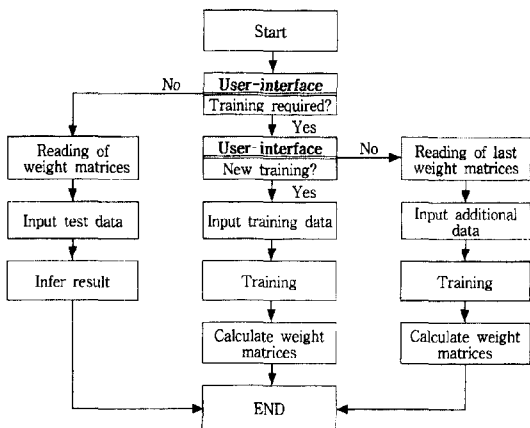


Fig. 2. Flow chart of neural network simulator for rock classification

추론에 적용하였다. 입력층은 무결암강도, RQD, 불연속면 간격, 지하수 상태, 불연속면 상태 등 5개의 노드(Node)를 가지며 은닉층은 5개, 출력층은 1개의 노드를 갖는다. 입력 데이터는 우리 나라 터널 현장에서 실측된 데이터로서 정량적인 변수는 등급화하기 전의 값을 그대로 사용하였으며, 출력 데이터는 단일 특성치를 얻을 수가 없어서 기존의 기초 RMR 값으로 하였다. 이를 이용하여 학습을 실시하였고 테스트용 데이터는 학습할 때 이용한 데이터의 일부, 임의로 만든 데이터(DATA 1, DATA 2, DATA 3)로 구성하였다(Table 2). Table 2의 신경망 학습 검토 결과를 분석하면, 여러 가지의 학습데이터로 테스트한 결과 원래의 값과 유사한 결과를 얻는 것으로 나타났다.

먼저 학습데이터를 그대로 입력한 경우 오차가 제일 작았으며 일반적인 값을 넣었을 경우에는 약간의 오차를 보이지만 상당히 근접하는 추론을 하였다. 가장 큰 오차를 보인 DATA 3의 경우 극단적으로 RMR 값이 낮게 추론되도록 하였으나 실제로 RMR 값이 10점 이하인 경우는 일반적인 방법으로 터널의 굴착이 불가능할 뿐만 아니라 극히 드문 경우이므로 신경망 학습의 결과가 만족스러운 정도로 나오는 것을 확인할 수 있다. 더욱 안정적인 해를 얻기 위해서는 암반 상태가 극단적으로 불리한 현장의 데이터는 물론 유리한 현장의 데이터도 보충하여야 할 것이다.

4.3 시뮬레이션

시뮬레이션을 위하여 입력층과 은닉층에 각각 13 개, 출력층에 1 개의 노드를 가지는 모델을 만들었다. 입력층은 RMR 기본 조사항목 5 개에 객관적이면서 암반의 특성을 반영할 수 있는 단위중량, 탄성파속도, 흡수율, 영률, 포아송비, 점착력, 내부마찰각, 인장강도 등의 인자들을

Table 2. Result of test run of the neural network

| Index | Data Input | DATA 1 | DATA 2 | DATA 3 |
|--|------------|--------|--------|--------|
| Intact rock strength (kg/cm ²) | 1370 | 1500 | 2800 | 10 |
| RQD (%) | 78 | 70 | 95 | 20 |
| Spacing of discontinuities(m) | 10 | 15 | 18 | 5 |
| Groundwater (point) | 7 | 10 | 15 | 1 |
| Condition of discontinuities (point) | 25 | 20 | 30 | 1 |
| Real RMR | 64 | 70 | 99 | 10 |
| Estimated RMR | 62 | 67.5 | 96.8 | 14.5 |
| Error | 1.6 | 2.5 | 3.2 | 4.5 |




Fig. 3. The structure of neural network

Table 3. Variations of tunnel database

| Type | Area | RMR |
|----------|-------------|--------------|
| Road | 65 Seoul | 12 0~10 0 |
| Railroad | 28 Pusan | 9 11~20 2 |
| Subway | 46 Taegu | 5 21~30 12 |
| Total | 139 Kwangju | 15 31~40 10 |
| | Taejon | 7 41~50 17 |
| | Chungchong | 27 51~60 27 |
| | Kyongsang | 25 61~70 29 |
| | Cholla | 39 71~80 25 |
| | Total | 139 81~90 16 |
| | | 91~100 1 |
| | | Total 139 |

첨가하여 총 13 개의 노드로 하였다. 출력층은 총점을 추론할 수 있도록 1 개의 노드만으로 구성하였다(Fig. 3).

각각의 학습주기는 하나의 입력패턴과 목적패턴이 신경망에 주어지고, 학습알고리즘에 따라 패턴 오차가 구해지면 출력패턴과 목적패턴의 차이를 줄이는 방향으로 학습이 진행된다. 학습이 종료되는 시점은 패턴 오차의 합인 시스템 오차가 정해진 기준치에 도달하거나 일정수의 반복을 한 후 학습이 종료된다.

사례들은 한국의 지질을 대표할 수 있도록 전국에 걸쳐서 수집하였으며, 또한 국도, 고속도로, 철도, 지하철 등 다양한 터널에서 총 139 개의 사례를 수집하였다. Table 3는 수집된 데이터의 내역이다.

4.4 문제 제기 및 방법론

첫째 - Bieniawski의 RMR 배점 체계는 타당한가?

RMR 점수 배점은 스칸디나비아 반도의 각종 현장에서 얻은 데이터를 제안자가 나름대로 분석하고 정리하였지만 경험적으로 결정된 것이며 그 가중치도 입증되어 있지 않다.

둘째 - RMR 분류항목(조사항목)은 적절한가?

위에서 설명한 방법에 의해 결정된 분류 항목들의 점수 배점 또한 중요한 문제이지만 근본적으로 조사 항목에 관한 부분에 대해서도 의문을 가질 수 있다. RMR 조사항목 역시 스칸디나비아 반도의 각종 현장에서 얻은 데이터를 제안자가 임의로 선택한 것이다. 현재의 조사 항목 이외에도 밀도, 내부마찰각, 점착력, 인장강도 등은 실제로 수치해석 입력 값으로 쓰이고 있으며, 터널 암반분류의 결정과 관계가 있는 인자들은 여러 가지이다. 그러나 RMR에서는 나머지들은 무시하고 5가지만으로 암반을 분류하고 있다. 두 가지 문제의 해결을 위하여 신경망을 이용한 시뮬레이션을 통해 검증을 실시하였다.

먼저 점수 배점의 타당성을 검토하기 위해 기초 RMR 5 가지 인자 이외에 8 가지를 더 포함하여 총 13가지 자료로 데이터베이스를 만든 후 이를 학습시킨다. 여기에서 기초 RMR은 신선암강도, RQD, 불연속면 간격, 불연속면 상태, 지하수 상태 5 가지 인자들만으로 암반을 분류하므로 이 인자들에 임의의 값을 부과하면서 그때의 추정 RMR의 값이 변화하는 패턴을 관찰하였다. 이는 다변수 중에서 해당되는 변수만을 변화시키면서 그 변수들의 가중치를 판단하기 위한 것이다. 이러한 가중치는 다수의 학습과 실행으로 근사하게 된다. 이 연구에서 학습종료의 조건은 평균표준편차가 2.5 이하로 수렴했을 때로 하였다.

4.5 검토결과

분류항목 각각의 점수 배점에 대한 학습 및 중간 과정의 배점을 정리하면 Table 4와 같다. 표를 분석하면 각각 인자들의 값이 Bieniawski의 RMR과 큰 차이는 없지만 RQD와 불연속면의 간격이 상충되게 나타나는 것을 볼 수 있다. 이러한 결과의 원인은 지질적인 원인으로 Bieniawski의 데이터가 한반도와는 절리의 특성이 다른 지역의 데이터인 점과 배점을 작위적으로 판단한 것과 실

Table 4. Summary of neural network outputs

| Parameter | Classification | | | KRMRI |
|----------------------------|----------------|----------------|-------------|-------|
| | Bieniawski | Neural network | Percent (%) | |
| Intact rock strength | 15 | 16 | 15.2 | 15 |
| RQD | 20 | 32 | 30.4 | 30 |
| Spacing of discontinuity | 20 | 18 | 17.2 | 17 |
| Groundwater | 15 | 19 | 18.1 | 18 |
| Condition of discontinuity | 30 | 20 | 19.1 | 20 |
| Sum | 100 | 105 | 100.0 | 100 |

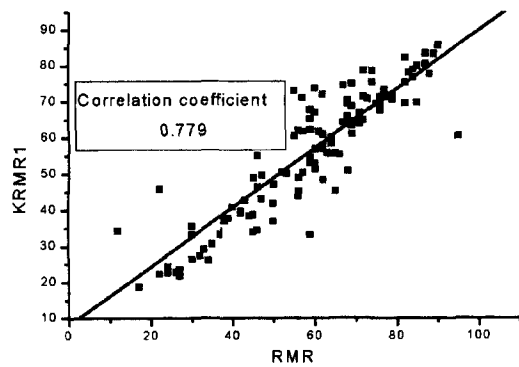


Fig. 4 Relationship between RMR and KRMR1

제 수치의 무차원 값으로 결정하는 신경망 시뮬레이터의 처리 방식 차이에서 비롯된 것으로 판단되었다.

Fig 4는 수집된 139개의 데이터를 KRMR1 암반분류 시스템에 의해 분류하였을 때 평가된 점수와 Bieniawski의 RMR 점수와 비교한 것이다. 상관계수는 0.779이며 상호간에 비교적 유사성이 많은 것을 나타내고 있다. 그러나 Bieniawski의 RMR에 의해 분류된 것과 KRMR1에 의해 분류된 것들의 점수 차가 최대 20점 이상 발생하는 경우가 있는 것으로 나타났으며 이러한 경우 터널설계에 중대한 영향을 미칠 수 있다.

두 번째 문제를 검증하기 위해 기초 RMR 조사항목 5개 이외에 밀도, 내부마찰각, 점착력, 인장강도 등의 인자를 첨가하여 총 13가지의 인자를 가지는 데이터 베이스를 작성하고 각각의 인자들과 RMR 사이의 상관계수를 계산하여 결과를 Table 5에 보였다.

표를 분석해 보면 기초 RMR 조사항목 5개가 높은 상관계수를 가지며 다음으로는 탄성파속도, 내부마찰각, 포아송비 등의 순으로 나타났다. 신경망을 이용하여 이러한 결과를 검증하기 위해 13가지의 인자를 가지고 있는 데이

Table 5. The Coefficient between RMR and parameters

| Index | Correlation Coefficient | Ranking |
|----------------------------|-------------------------|---------|
| Intact rock strength | 0.14691 | 5 |
| RQD | 0.58835 | 1 |
| Spacing of discontinuity | 0.40281 | 3 |
| Groundwater | 0.21127 | 4 |
| Condition of discontinuity | 0.57677 | 2 |
| Specific gravity | 0.02376 | 12 |
| P-wave velocity | 0.12040 | 6 |
| Water absorption | 0.03903 | 11 |
| Young modulus | 0.11072 | 8 |
| Poisson's ratio | 0.00611 | 13 |
| Cohesion | 0.05496 | 10 |
| Internal friction | 0.11452 | 7 |
| Tensile strength | 0.09502 | 9 |

터를 이용하여 학습을 실시하였다. 그 방법을 요약하면 아래와 같다.

1단계. 13가지의 인자를 가진 데이터를 이용하여 학습을 실시한 후 각각의 인자들을 단조 증가시키며 신경망에 입력하여 그래프를 그린다.

2단계. 단조 증가시키며 신경망에 입력하여 계산된 값의 변화의 폭이 5이하로 나타나는 낮은 상관성을 갖는 인자는 제외시키고 기초 RMR 인자와 탄성파속도, 내부마찰각 총 7개의 인자만을 포함하는 데이터를 만들어준다.

3단계. 그래프를 이용하여 목적패턴을 바꾸어 주고 7개의 인자를 갖는 데이터를 이용하여 신경망을 학습시킨다.

4단계. 학습된 신경망에 각각의 인자들을 단조증가하며 신경망에 입력하여 최종검토를 한다.

이러한 과정을 거쳐 유추된 결과를 정리하면 Table 6과 같다.

Fig. 5는 수집된 139개의 데이터를 새로운 KRMR2

Table 6 Summary of neural network output

| Index | Error | step 1 | step 1/1.19 | step 4 | Error | step 4 / 0.979 | KRMR2 |
|------------------------------|-------|--------|-------------|--------|-------|----------------|------------|
| Intact rock strength | | 16 | 13.4 | 14.2 | +0.6 | 14.5 | 15 |
| RQD | | 32 | 26.9 | 24.9 | -2.0 | 25.2 | 25 |
| Spacing of discontinuities | | 18 | 15.1 | 14.8 | -0.2 | 15.2 | 15 |
| Ground water | | 19 | 16.0 | 14.1 | -1.9 | 14.4 | 15 |
| Condition of discontinuities | | 20 | 16.8 | 13.7 | -3.1 | 14.1 | 15 |
| P-wave velocity | | 7 | 5.9 | 8.6 | +2.7 | 8.8 | 8 |
| Internal friction angle | | 7 | 5.9 | 7.6 | +1.7 | 7.8 | 7 |
| Sum | | 119 | 100.0 | 97.9 | -2.0 | 100.0 | 100 |

암반분류 시스템에 의해 분류하였을 때 평가된 점수와 Bieniawski의 RMR 점수와 비교하였으며 상관계수는 0.765이다. Bieniawski의 RMR에 의해 분류된 것과 KRMR2에 의해 분류된 것들의 점수차이가 20점 이상도 벌어지는 경우가 발생하는 것으로 이러한 경우 터널설계에 중대한 영향을 미칠 수 있다.

Fig. 6은 KRMR1의 분류방법과 KRMR2의 분류방법의 의해 평가된 점수들의 상관성을 그래프로 작성한 것이다. 상관계수는 0.981로 서로간의 상관성이 대단히 높은 것으로 나타났다. 이러한 원인은 현재의 입력자료가 암반분류를 만들 때의 데이터였기 때문이다.

KRMR1과 KRMR2의 관계를 회귀 분석한 결과 선형적인 관계를 가지는 것으로 나타났으며 아래와 같은 결과식으로 표현된다.

$$KRMR2 = 7.37 + KRMR1 \times 0.88 \quad (2)$$

이상의 두 가지 제안된 암반분류 방식은 결국 전국적으로 분포되어 있는 우리나라의 암반분류 데이터베이스를




Fig. 5 Relationship between RMR and KRMR2

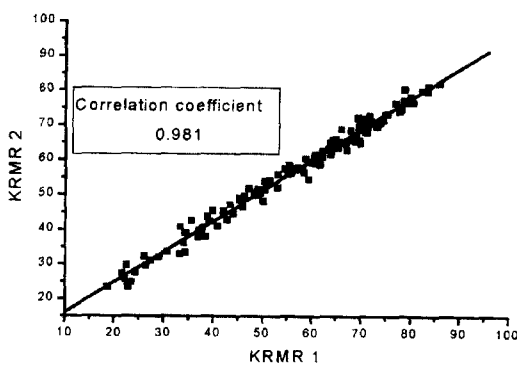


Fig. 6. Relationship between KRMR1 and KRMR2

만족한다. 추후 터널을 설계할 때 얻을 수 있는 데이터의 종류에 따라 KRMR1 또는 KRMR2를 선택적으로 적용하여 암반분류를 실시하고 지보량을 산정할 수 있을 것으로 생각된다.

5. 결 론

본 연구에서는 터널 암반분류에 널리 적용되고 있는 RMR의 타당성을 검토하고 한국의 지질상황에 적합한 분류 방식을 유도하기 위하여 인공지능망을 이용하였다. 학습방법으로는 오류역전파 학습알고리즘을 사용하였으며, 변수의 무차원 값을 입력하는 방식을 채택하였다. 신경망 학습을 위하여, 가장 중요시되는 데이터베이스는 우리나라의 전역에 걸친 현장 데이터를 취득하였으며 터널의 용도 역시 고속도로, 국도, 철도, 지하철 등으로 다양하게 하여 지역이나 종류의 편중으로 인한 오류를 줄였다.

연구를 통하여 얻어진 주요 결과는 다음과 같다.

1) 구성된 데이터베이스를 인공지능망으로 학습시켜 추론한 새로운 분류방식(KRMR1)을 제안하였다. KRMR1에서는 Bieniawski의 RMR과 항목은 같으나 RQD가 불연속면의 조건보다 더 중시되며 여타 인자의 배점도 조정하였다.

2) 인공지능망으로 상관계수를 구하여 그 중요도에 따라 터널 암반분류의 인자를 추가한 KRMR2를 제안하였다. 분류 항목으로는 기존의 5 인자 외에 탄성파속도와 내부마찰각이 특히 의미를 갖는 것으로 추론되었다.

6. 사 사

본 연구는 한국과학재단의 연구비 지원(KOSEF 971-0406-016-2, 인공지능회로망을 이용한 한국형 터널 전문가 시스템 구현 연구)에 의해 이루어졌으며 이에 깊은 감사의 뜻을 표한다. 또 신경망 이론에 대한 경험을 기꺼이 나누고 프로그램을 사용하도록 배려해 준 한국원자력연구소 권상기 박사에게 감사드린다.

참 고 문 헌

1. 권상기, 1998, An investigation of the deformation of underground excavations in salt and potash mines, 터널·암반역학위원회 박사학위 논문집, 83-114.
2. 양형식, 김남수, 1996, 가속신경망을 이용한 암반분류의 기초 연구, 터널과 지하공간, 제6권, 제4호, 316-325.

3. 이철욱, 1993, 인공신경회로망을 이용한 암반터널설계 전문가 시스템의 개발, 한양대학교 대학원 석사학위논문, 68p.
4. Barton N., Lien R. and Lunde J., 1974, Engineering Classification of Rock Masses for the Design of Tunnel Support, Rock Mech. and Rock Eng., Vol. 6/ 4, 189-236.
5. Bieniawski Z. T., 1976, Rock Mass Classification in Rock Engineering, Exploration for Rock Engineering, ed. Z. T. Bieniawski, A. A. Balkema, Johannesburg, 97-106.
6. Bieniawski Z. T., 1989, Engineering Rock Mass Classifications, John Wiley & Sons, Inc., 51-72.
7. 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. 415p

양 형 식



1979년 서울대학교 자원공학과, 공학사
 1981년 서울대학교 대학원 자원공학과, 공학석사
 1987년 서울대학교 대학원 자원공학과, 공학박사

Tel : 062-530-1724

E-mail : hsyang@chonnam.chonnam.ac.kr

현재 전남대학교 자원공학과 교수

김 재 철



1997년 전남대학교 공과대학 자원공학과, 공학사
 1998년 전남대학교 공과대학 자원공학과, 공학석사

Tel : 062-520-6375