

퍼지집합이론 및 뉴로-퍼지기법을 이용한 RMR 값의 추론

배규진¹⁾ · 조만섭²⁾

Inference of RMR Value Using Fuzzy Set Theory and Neuro-Fuzzy Techniques

Gyu-Jin Bae and Mahn-Sup Cho

Abstract. In the design of tunnel, it contains inaccuracy of data, fuzziness of evaluation, observer error and so on. The face observation during tunnel excavation, therefore, plays an important role to raise stability and to reduce supporting cost. This study is carried out to minimize the subjectiveness of observer and to exactly evaluate the natural properties of ground during the face observation. For these purpose, fuzzy set theory and neuro-fuzzy techniques in artificial intelligent techniques are applied to the inference of the RMR value from the observation data. The correlation between original RMR value and inferred RMR_{FU} and RMR_{NF} values from fuzzy set theory and neuro-fuzzy techniques is investigated using 46 data. The results show that good correlation between original RMR value and inferred RMR_{FU} and RMR_{NF} value is observed when the correlation coefficients are $|R|=0.96$ and $|R|=0.95$ respectively. From these results, applicability of fuzzy set theory and neuro-fuzzy techniques to rock mass classification is proved to be sufficiently high enough.

Keywords: fuzzy set theory, neuro-fuzzy techniques, RMR

초 록. 터널의 설계에는 지반조사 자료의 부정확성과 평가의 애매성 그리고 자료수집 과정의 오류(observer error) 등이 내재되어 있다. 그러므로 터널의 안정성과 경제적인 시공을 위해서는 시공 중 막장면의 조사가 매우 중요한 역할을 한다. 본 연구는 막장면 조사 시 지반의 고유 특성을 보다 정확하게 평가하고, 조사자의 주관성을 최소화시키기 위하여 수행되었다. 이러한 목적을 위하여 막장관찰 자료로부터 RMR값을 추론하고자 인공지능기법 중 퍼지집합이론과 뉴로-퍼지기법을 적용하였고, 46개의 학습자료에 대해 원래의 RMR값과 퍼지이론 및 뉴로-퍼지기법의 추론에 의한 RMR_{FU} 및 RMR_{NF} 값의 상관성을 분석하였다. 본 연구의 결과는 원래의 RMR값과 퍼지추론에 의한 RMR_{FU} 값 및 뉴로-퍼지기법에 의한 RMR_{NF} 값의 상관계수가 각각 $|R|=0.96$ 과 $|R|=0.95$ 로 상관성이 우수한 것으로 조사되었다. 이 결과로부터 암반평가를 위한 퍼지집합이론 및 뉴로-퍼지기법의 적용성이 충분함을 검증할 수 있었다.

핵심어: 퍼지이론, 뉴로-퍼지기법, RMR

1. 서 론

지하에 건설되는 터널의 특성상 지반조사 자료의 부정확성(inaccuracy)과 그 결과에 대한 평가의 애매성(fuzziness) 그리고 자료수집 과정의 오류(observer error) 등이 내재되어 있으므로 지상 구조물과 같은 정확한 설계를 기대할 수가 없다. 그러므로 본선 터널시공 중 조사된 막장면 조사(face mapping)결과에 따라 보조공법의 적용 여부 및 지보패턴의 변경 등을 어느 정도 허용할 수 밖에 없다. 그러나 조사자료의 부정확성과 지반의 비균질성 및 불연속성 등 미지의 파라미터들

때문에 기술자 및 전문가의 경험적인 지식과 주관적인 판단에 따라 암반분류 결과가 차이를 보일 수 있다. 이러한 문제점을 해결하기 위해 RMR값을 결정짓는 여러 요소들의 상관성 분석연구를 수행하여 간편한 RMR 적용방법에 관한 연구가 수행된 바 있고(구 외, 1994), 인공지능기법(artificial intelligent)은 학습을 도와주는 지식이나 패턴을 일치시키는 방식을 사용하고 있기 때문에 이러한 불확실성을 줄일 수 있는 방법으로 지반공학 분야에 많이 활용되고 있다(Toll, 1996).

특히 인공지능기법 중의 하나인 퍼지집합이론(fuzzy set theory)은 1965년에 미국 버클리대학의 Lofti A. Zadeh 교수가 발표한 이론으로서 불확실한 부분의 정량화 및 불확실한 조건 하에서의 문제 해결 혹은 의사결정을 위한 합리적인 방침을 주는 방법의 하나로 발전되고 있다. 1980년대에 이르러 Yu와 Zeng(1983),

¹⁾정회원, 한국건설기술연구원 토목연구부장

²⁾정회원, 한국건설기술연구원 토목연구부 선임연구원

접수일 : 2001년 6월 22일

심사 완료일 : 2001년 10월 30일

Nguyen와 Ashworth(1985), Nguyen(1985) 등에 의해 퍼지집합이론은 지반공학분야 중 암반분류에 적용되었다. 吉中 외(1989), 大野와 清水(1990) 등은 지반공학 분야에 퍼지집합이론을 적용한 사례들을 소개하였는데, 퍼지집합이론을 이용한 시스템 혹은 방법들의 타당성이 연구성과를 실부에 이용한 예가 없음을 지적하였다. 국내에서는 문과 이(1993), 김과 양(1996), 양과 김(1999) 등이 인공신경망을 이용하여 암반분류 및 암반투수계수 예측 등에 관한 연구를 수행한 바 있다. 그리고 이 외(1998), 성과 김(1999)은 교량 안전진단 등의 분야에 퍼지집합이론을 적용한 연구를 수행하였다. 터널의 암반 분류기법 및 보강공법 선정에 관하여, 한국건설기술연구원(2000)은 퍼지수량화이론Ⅱ류를 이용하여 터널 보강공법 선정을 위한 프로토타입의 전문가시스템을 개발하였다.

이상의 문헌조사로부터 국내에서도 암반분류에 관한 연구가 수행되었지만, 인공지능기법 중 퍼지집합이론 뿐만 아니라 뉴로-퍼지기법의 적용에 관한 연구는 초기 단계에 속하고 있다. 그리고 국외의 사례에서도 시공 현장에서 즉각적인 조사가 곤란한 항목(응력비, 탄성파속도 등)을 평가항목으로 적용한 경우가 많았으며, 정량적인 조사(RQD, 절리면 간격 등)에 관련되는 개인적 오류에 대한 고려가 미흡하였다. 따라서 본 논문에서는 국내 터널현장에서 일반적으로 적용되고 있는 RMR분류를 기반으로 한 퍼지집합이론의 적용성을 검토하기 위하여 국내의 46개 현장자료를 토대로 분석하여 보았다. 또한 신경망과 퍼지이론을 접목한 뉴로-퍼지기법을 지반공학분야에 도입하여 기존의 RMR값과 퍼지 추론에 의한 RMR_{FU} 값, 뉴로-퍼지기법 추론에 의한 RMR_{NF} 값과 상호 비교하는 방식으로 뉴로-퍼지기법의 적용성을 검증하여 보았다.

2. 퍼지이론 및 뉴로-퍼지기법

2.1 퍼지이론

퍼지추론은 애매한 상태의 자료를 표현하기 위하여 공학분야를 중심으로 여러 분야에서 적용되고 있다. 일반적인 집합과 다른 퍼지집합 이론을 이용하여 불확실성을 나타내며 퍼지시스템의 진행과정은 Fig. 1과 같다

(이와 오, 1995). 입력자료를 소속도를 가지도록 퍼지화시킨 다음 퍼지규칙을 통해 퍼지추론을 수행하게 되며, 마지막으로 추론한 값을 비퍼지화하여 결론을 도출하게 된다.

2.1.1 소속도함수

퍼지집합은 정성적인 모호한 표현에 대한 정도를 정량적으로 나타내기 위해서 소속도함수(membership function)를 사용한다. 예를 들어, X를 전체집합(universal set)이라고 하면 X의 원소 x가 퍼지집합 A에 속하는 정도를 나타내는 소속도 함수 μ_A 는 보통 식 (1)과 같은 형태로 정의된다.

$$\mu_A(X) : X \quad [0, 1] \tag{1}$$

따라서, 원소 $x \in X$ 에 대한 값 $\mu_A(x) \in [0, 1]$ 은 x가 퍼지집합 A에 속하는 정도(degree of membership, degree of support) 또는 등급(a grade of membership)을 나타낸다.

소속도 함수는 함수로 표현하는 경우와 이산형으로 표현하는 방법이 있는데, 예를 들어 $X = \{x \mid x \text{는 } 10 \text{ 이하의 자연수}\}$ 로 정의하고 A를 5와 가까운 자연수의 집합이라고 정의하면 퍼지 집합 A에 대한 X의 각 원소의 소속도 함수 값은 다음과 같이 정할 수 있다.

$$\mu_A(x) = 0.1/2 + 0.4/3 + 0.8/4 + 1/5 + 0.8/6 + 0.4/7 + 0.1/8 \tag{2}$$

2.1.2 퍼지추론

퍼지추론이란 "IF x is A THEN y is B"(A, B는 퍼지 집합)이 되는 규칙을 준 경우, 'x is A'의 입력에 대해서 y를 어떻게 추론하면 좋은가를 다루는 것이다. 일반적으로 전건부(前件部) 및 후건부(後件部)를 퍼지 명제형으로 표현하며, 이러한 추론규칙을 식 (3)과 같이 퍼지 IF-THEN 규칙이라고 칭한다.

$$\begin{aligned} \text{규칙 1 : IF } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ THEN } z \text{ is } C_1 \\ \text{규칙 2 : IF } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ THEN } z \text{ is } C_2 \end{aligned} \tag{3}$$

2.1.3 비퍼지화

퍼지근사추론법의 최종적인 추론결과는 여러 가지의 비퍼지화과정을 통하여 결정되는데, 식 (4)의 퍼지집합




Fig. 1. Typical procedures of a fuzzy logic system.

의 중심값(centroid value)을 구하는 방법이 가장 일반적으로 적용되고 있다.

$$\text{Centroid value} : z_0 = \int \mu_c(z)zdz / \int \mu_c(z)dz \quad (4)$$

2.2 뉴로-퍼지기법

퍼지시스템과 신경망의 결합은 "퍼지시스템을 위한 신경망"과 "신경망을 위한 퍼지논리"가 있다. 퍼지시스템을 위한 신경망의 결합은 퍼지시스템의 성능향상을 위해 신경망의 구조나 학습방법을 퍼지시스템에 사용하는 접근 방법으로 퍼지시스템의 소속함수와 규칙을 변형된 신경망으로 사상시켜 신경망을 학습시킴으로써 소속함수와 규칙을 조정할 수 있다. 퍼지 신경망의 모델로는 Fig. 2와 같은 ANFIS(adaptive network-based fuzzy inference system)을 이용하며, ANFIS는 최급강화법(gradient descent method)을 이용하여 소속함수 값들을 학습, 시스템에 전문가의 지식을 보다 정확하게 조정, 반영함으로써 결과 값을 최적화시키게 된다(성과 김, 1999).

Fig. 2로부터 출력값 y 는 식 (5)로 구할 수 있는데,

$$w_i = \prod_{j=1}^m \mu A_{ji}(x_j) = \mu A_{1i}(x_1) \cdot \mu A_{2i}(x_2) \cdot \mu A_{3i}(x_3) \cdots \mu A_{mi}(x_m)$$

$$\bar{w}_i = \frac{w_i}{\sum_{i=1}^n w_i} \quad (5)$$

$$y = \sum_{i=1}^n y_i = \sum_{i=1}^n \bar{w}_i f_i = \frac{\sum (w_i * f_i)}{\sum w_i}$$

여기서, x_j : 입력값
 A_{ji} : 전건부 소속함수 집합




Fig. 2. Structure of ANFIS.

- $\mu A_{ji}(x_j)$: 입력 x_j 의 집합 A에 대한 소속함수 값
- w_i : i 번째 규칙의 점화강도(적합도, firing strength)
- \bar{w}_i : 정규화된 w_i
- r_i : i 번째 규칙 후건부의 소속함수 값
- y_i : i 번째 규칙의 출력 값
- y : 출력 값
- f_i : ANFIS에서 퍼지규칙의 후건부를 나타내는 다항식이며, 퍼지규칙(IF-THEN)의 THEN-part에서 "Crisp"한 값을 가지는 zero-order Sugeno system에서는 $f_i = r_i$ 임

또한 결과의 소속함수 값 r_i 는 식 (6)에 따라 학습하며, 시스템오차 $E(E_{max})$ 가 될 때까지 학습을 수행한다.

$$r_i(t+1) = r_i(t) - l_r \cdot \frac{\partial E}{\partial r_i}$$

$$E = \frac{1}{2} (y_i - y'_i)^2 \quad (6)$$

여기서, y'_i : 목표 값
 l_r : 학습률(learning rate)
 t : 학습 횟수(time epoch)이다.

3. RMR 값 추론을 위한 퍼지이론 및 뉴로-퍼지기법의 구성

암반분류에 있어서 퍼지집합 이론 및 퍼지신경망 이론의 적용 타당성을 검증하고자 Bieniawski(1984)가 제안한 RMR 평가법에 대하여 검증을 수행하였다. 본 연구에서 사용한 프로그램은 FuzzyTECH professional program (FuzzyTECH Co. Ltd., Germany)으로서 소속도함수의 작성과 전·후건부의 처리를 사용자가 용이하게 작성하도록 되어 있으며, 인공지능망에 의한 학습을 통한 뉴로-퍼지기법을 적용할 수 있도록 구성되어 있다.

3.1 학습데이터 선정 및 분석

본 연구를 위하여 수집한 막장면 관찰자료는 RMR분류의 평가점수(rating) 및 항목별 실제 측정값들이 제시된 총 46개의 현장자료를 이용하였고, 광산경도 막장면 RMR평가자료(대한광업진흥공사, 1994)와 OO지하철의 막장면 RMR 평가자료를 무작위로 수집하여 학습자료로 사용하였다. Table 1에는 RMR평가법의 6가지 조사항목들을 나타내었고, Table 2에는 총 46개의 입력항목들 사이의 상관성과 해당 RMR평가 점수와의 상관성을 분석한 결과를 나타내었다.

총 46개의 입력항목들 사이의 상관성과 해당 RMR

Table 1. Classification parameters and their ratings of RMR system.

| Parameter | | Ranges of value | | | | | |
|---------------------------------------|-------------------------------|--|--|---|---|---|---------------|
| Strength of intact rock material | Point-load strength index | > 10 MPa | 4-10 MPa | 2-4 MPa | 1-2 MPa | For this low range - uniaxial compressive test is preferred | |
| | Uniaxial compressive strength | > 250 MPa | 100-250 MPa | 50-100 MPa | 25-50 MPa | 2-25MPa | 1-5MPa <1 MPa |
| Rating | | 15 | 12 | 7 | 4 | 2 | 1 0 |
| Drill core quality RQD | | 90%-100% | 75%-90% | 50%-75% | 25%-50% | < 25% | |
| Rating | | 20 | 17 | 13 | 8 | 3 | |
| Spacing of discontinuities | | > 2 m | 0.6-2 m | 200-600 mm | 60-200 mm | < 60 mm | |
| Rating | | 20 | 17 | 13 | 8 | 3 | |
| Condition of discontinuities | | Very rough surfaces. Not continuous. No separation. Unweathered wall rock. | Slightly rough surface. Separation < 1 mm. Slightly weathered walls. | Slightly rough surfaces. Separation < 1 mm. Highly weathered walls. | Slickensided surfaces. OR Gouge < 5 mm thick. OR Separation 1-5 mm. Continuous. | Soft gouge > 5 mm thick. OR Separation > 5 mm. Continuous. | |
| Rating | | 30 | 25 | 20 | 10 | 0 | |
| Ground water | | None | < 10 liter/min | < 10-25 liter/min | < 25-125 liter/min | > 125 | |
| Rating | | 15 | 10 | 7 | 4 | 0 | |
| Strike and dip orientations of joints | | Very favourable | favourable | fair | unfavourable | Very unfavourable | |
| Rating | | 0 | -2 | -5 | -10 | -12 | |
| RMR Rating | | 100-81 | 80-61 | 60-41 | 40-21 | < 20 | |
| Class No. | | I | II | III | IV | V | |
| Description | | Very good rock | Good rock | Fair rock | Poor rock | Very poor rock | |

Table 2. Correlation coefficient(|R|) between RMR value and input variables.

| | strength | RQD | joint spacing | joint condition | ground water | directional effect | RMR |
|--------------------|----------|---------|---------------|-----------------|--------------|--------------------|-----|
| strength | 1 | 0.75294 | 0.50107 | 0.5824 | 0.2411 | 0.04631 | |
| RQD | | 1 | 0.60281 | 0.70496 | 0.44685 | 0.29568 | |
| joint spacing | | | 1 | 0.58953 | 0.30549 | 0.63289 | |
| joint condition | | | | 1 | 0.54395 | 0.42865 | |
| ground water | | | | | 1 | 0.30123 | |
| directional effect | | | | | | 1 | |
| RMR | 0.66354 | 0.83834 | 0.77756 | 0.87465 | 0.63262 | 0.58123 | 1 |

평가 점수와의 상관성을 분석한 결과, Table 2에 나타난 바와 같이 입력항목들 사이의 상관성에서는 암석강도-RQD의 상관성이 가장 높은 것으로 나타났다. 그리고 RQD-절리면 상태, 절리간격-절리방향효과 등의 상관계수(|R|)가 약 0.6 이상의 비교적 높은 상관성을 보였다.

각 항목별 RMR평가 점수와의 상관성은 RMR-절리방향효과를 제외하고 모두 |R|=0.6 이상의 상관성을 보였으며, RMR-RQD 그리고 RMR-절리면 상태의 상관성이 높은 것으로 나타났다. 이상의 상관성을

가지는 현장자료를 이용하여 퍼지집합이론과 뉴로퍼지기법의 적용성을 분석하여 보았다.

3.2 퍼지추론부 구성

퍼지집합이론을 이용한 평가를 수행하기 위하여 RMR평가 조사항목 6개와 RMR값에 대하여 각각 5개의 언어변수를 부여하여 총 35개의 소속도 함수를 작성하였고, Table 1의 RMR분류기준에서 제시된 각 항목별 등급범위의 중심값을 기준으로 상호 중첩하도록 소속도 함수를 작성하였다. 소속도함수의 작성은 암석




Fig. 3. Structure of a fuzzy logic system.

Table 3. Linguistic description and properties of input and output variables.

| Input & Output Variables | | Term Linguistic Names | | | | | Min | Max | Unit |
|--------------------------|--------------------|-----------------------|--------------|------------------|----------------|-----------------|-----|------|--------------------|
| in1 | strength | very poor | poor | fair | good | very good | 0 | 2500 | kg/cm ² |
| in2 | RQD | very low | low | medium | high | very high | 0 | 100 | % |
| in3 | joint spacing | very poor | poor | fair | good | very good | 0 | 2000 | mm |
| in4 | joint condition | soft gouge | gouge | highly weathered | slightly rough | very rough | 1 | 5 | - |
| in5 | groundwater | flowing | dripping | wet | damp | completely dry | 1 | 5 | - |
| in6 | directional effect | very unfavourable | unfavourable | fair | favourable | very favourable | -12 | 0 | - |
| RMR01 | RMR | very poor | poor | fair | good | very good | 0 | 100 | - |

강도, RQD, 절리면 간격 및 절리면 방향성의 4개 항목에 대하여 RMR분류의 평가점수가 아닌 정량적인 실제 조사 값들을 적용하였다. 예를 들면, 암석강도는 0~2,500 kg/cm² 사이의 임의의 실험치를 입력할 수 있고, 실제 실험치가 "극경암"의 소속도함수를 초과하여도 2,500 kg/cm²으로 입력한 것과 동일한 결과를 나타내도록 하였다. 그리고 정량적인 평가기준이 없는 절리면 상태와 지하수 유입량의 두 경우에 한정하여 각 평가등급을 1.0~ 5.0까지의 등급별 소수점으로 입력할 수 있도록 하였다. Fig. 3과 Table 3에는 각각 시스템 구성도와 조사항목들의 평가등급별 언어변수 및 최소·최대 범위, 입력단위 등의 특성을 나타내었다.

Fig. 4~5에는 각각 입력 및 출력항목별 소속도 함수를 일반적으로 많이 사용되는 Z-type(λ)과 Lambda-

type(λ) 및 S-type(ρ)의 선형(linear shape)함수로 나타내었다. 각 항목들의 y-축에는 해당 등급의 소속정도(degree of support, DoS)를 0~1까지의 실수로 결정하였다. 인공지능망학습로부터 퍼지규칙에 대한 소속정도를 구하여 RMR분류에 의한 평가점수와 퍼지집합이론(DoS = 1.0)에 의한 평가점수 그리고 인공지능망에 의한 소속정도로부터 평가한 점수 등 3가지를 상호 비교·검토하여 보았다.

3.3 퍼지 규칙의 생성 및 퍼지신경망 학습

RMR분류에 대한 시스템 검증을 위하여 본 추론부에서는 35개의 입·출력 소속도함수로부터 간접법을 사용하여 2개의 규칙블럭(rule block, RB)과 총 250개의 규칙들을 생성하였으며, Table 4에는 각 규칙 블럭의 입·

출력항목에 대한 구성과 최종 출력항에 미치는 입력항의 영향을 기중치(weight)로 나타내었다.

3.3.1 RB1, RB2

6가지 조사항목들을 이용하여 RMR값의 결과에 대한 IF-THEN 규칙들을 아래의 예와 같이 생성하였고, 이때의 소속정도(DoS)는 1.0으로 설정하였다.

| IF | | | DoS | THEN |
|-----------|----------|----------------|------|-----------|
| strength | RQD | groundwater | | RMR |
| very_poor | very_low | flowing | 1.00 | very_poor |
| very_poor | very_low | dripping | 1.00 | very_poor |
| very_poor | very_low | wet | 1.00 | very_poor |
| very_poor | very_low | damp | 1.00 | poor |
| very_poor | very_low | completely_dry | 1.00 | poor |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |

3.3.2 Learn RB1, RB2

먼저 소속정도(DoS)를 0.0으로 작성한 IF-THEN 규칙들에 대해 인공신경망을 이용하여 46개의 데이터를 학습시켜 각 규칙들의 소속정도를 구성하였으며, 학습과정의 설정은 아래와 같다.

- 학습방식(learn method) : random method
- 최대 반복회수(iteration) : 1,000회
- neuron : 1, 2, 4, 6, 8, 12, 48의 7단계로 변화
- 학습정지 조건(error) : Max. Dev. = 10%

Fig. 6은 위의 학습설정 및 과정을 보여주는 그림이




Fig. 5. Membership function of RMR_{FU} and RMR_{NF} value.

Table 4. Properties of rule blocks.

| RB Title | Input Variables | weight | Rule Numbers | Output Var. |
|----------|--------------------|---------------|--------------|-------------|
| RB1 | strength | very positive | 125 | RMR |
| | RQD | very positive | | |
| | groundwater | very positive | | |
| RB2 | joint spacing | very positive | 125 | RMR |
| | joint condition | very positive | | |
| | directional effect | very positive | | |

*The input variable's influence on an output variable can be determined by the "weight"

며, 이와 같은 조건 하에서 뉴런 수의 변화는 학습시간(약 8.3분)과 최대편차(약 40.17%) 및 평균편차(13.8%)에 큰 영향을 주지 않았으며, 최종 RMR분류를 위한 학

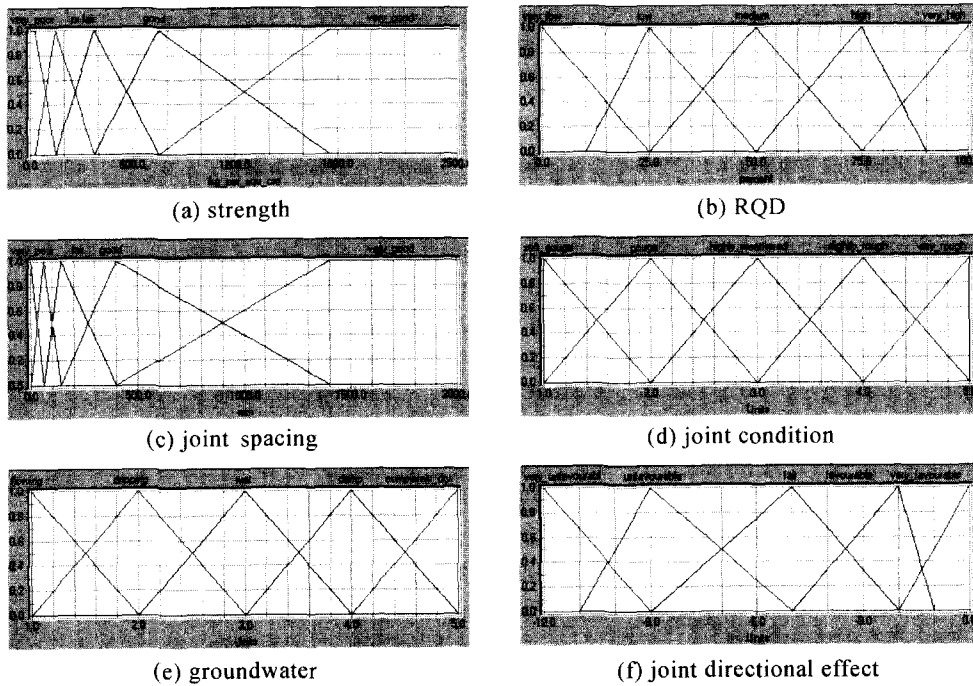


Fig. 4. Membership function of input variables.

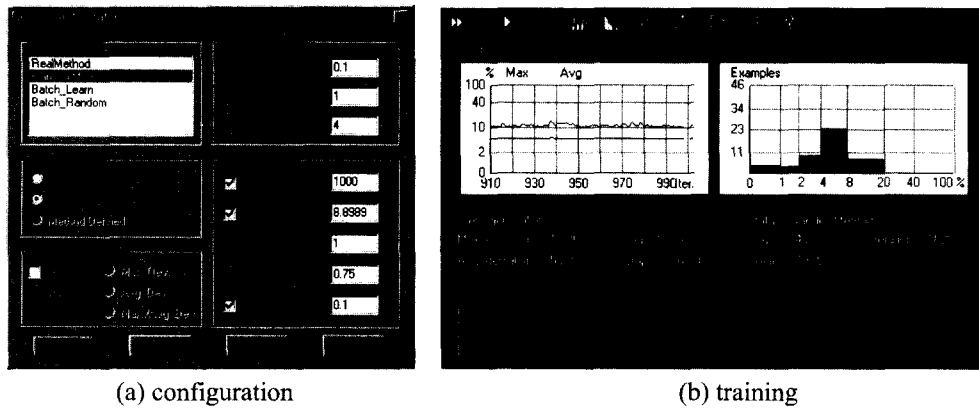


Fig. 6. Configuration and training of a neural network.

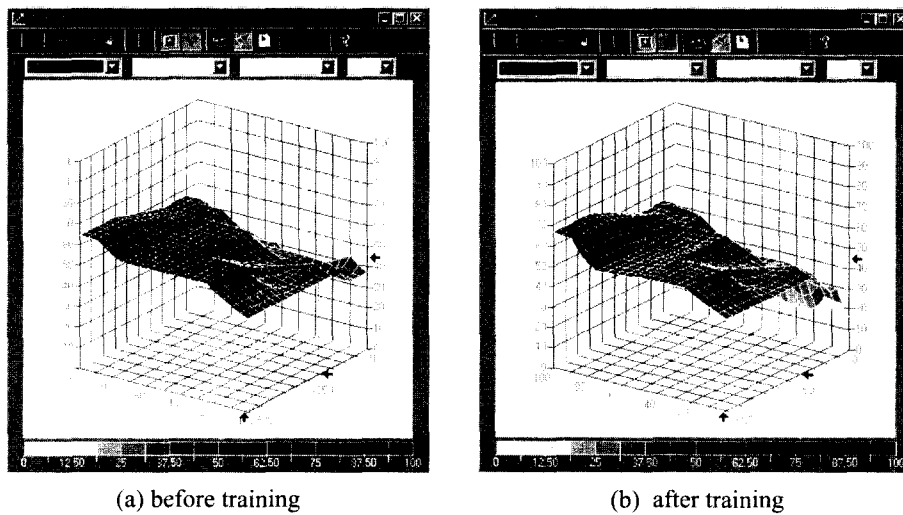


Fig. 7. Neuro-fuzzy input-output surface modeling.

습조건으로 입·출력 항목 수와 동일한 4개의 뉴런에 대해 학습을 수행하였다. 그리고 Fig. 7의 (a), (b)는 암석강도-RQD에 대한 RMR값의 surface modeling을 하나의 예로서 나타낸 것이며, (a)는 퍼지신경망의 학습 이전의 모델이고, (b)는 퍼지신경망 학습 이후의 모델로서 유사한 형상을 보이고 있다. 그러나 낮은 암석강도-RQD의 값들에서는 (a)의 학습 이전보다는 현장자료의 학습 결과를 토대로 신경망 학습을 통해 작성된 (b)에서 보다 값이 작지만, 폭이 넓어진 RMR값을 도출할 수 있다.

4. 퍼지이론 및 뉴로-퍼지기법에 의한 추론 결과

RMR평가의 조사항목들과 RMR값과의 관계에서 발

생된 250개의 규칙에 대하여, 먼저 학습모델 데이터를 퍼지집합이론에 따라 모든 규칙의 소속정도를 1.0으로 설정한 경우에 대하여 RMR값을 추론하여 보았다. 또한 소속정도를 퍼지신경망으로 학습시킨 후 수정된 소속정도를 이용하여 동일한 방식으로 RMR값을 추론하여 보았다.

4.1 추론결과와 항목별 상관성 분석

Fig. 8에는 6개의 각 조사항목들에 대한 기존 RMR 자료와 퍼지추론 결과 및 퍼지신경망추론에 의한 RMR_{FU}, RMR_{NF} 결과 및 오차율 분포를 나타내었고, y-축의 조사항목을 기준으로 x-축의 RMR 값들이 넓게 분산된 경우는 상호 상관성이 저하된 경우이다.

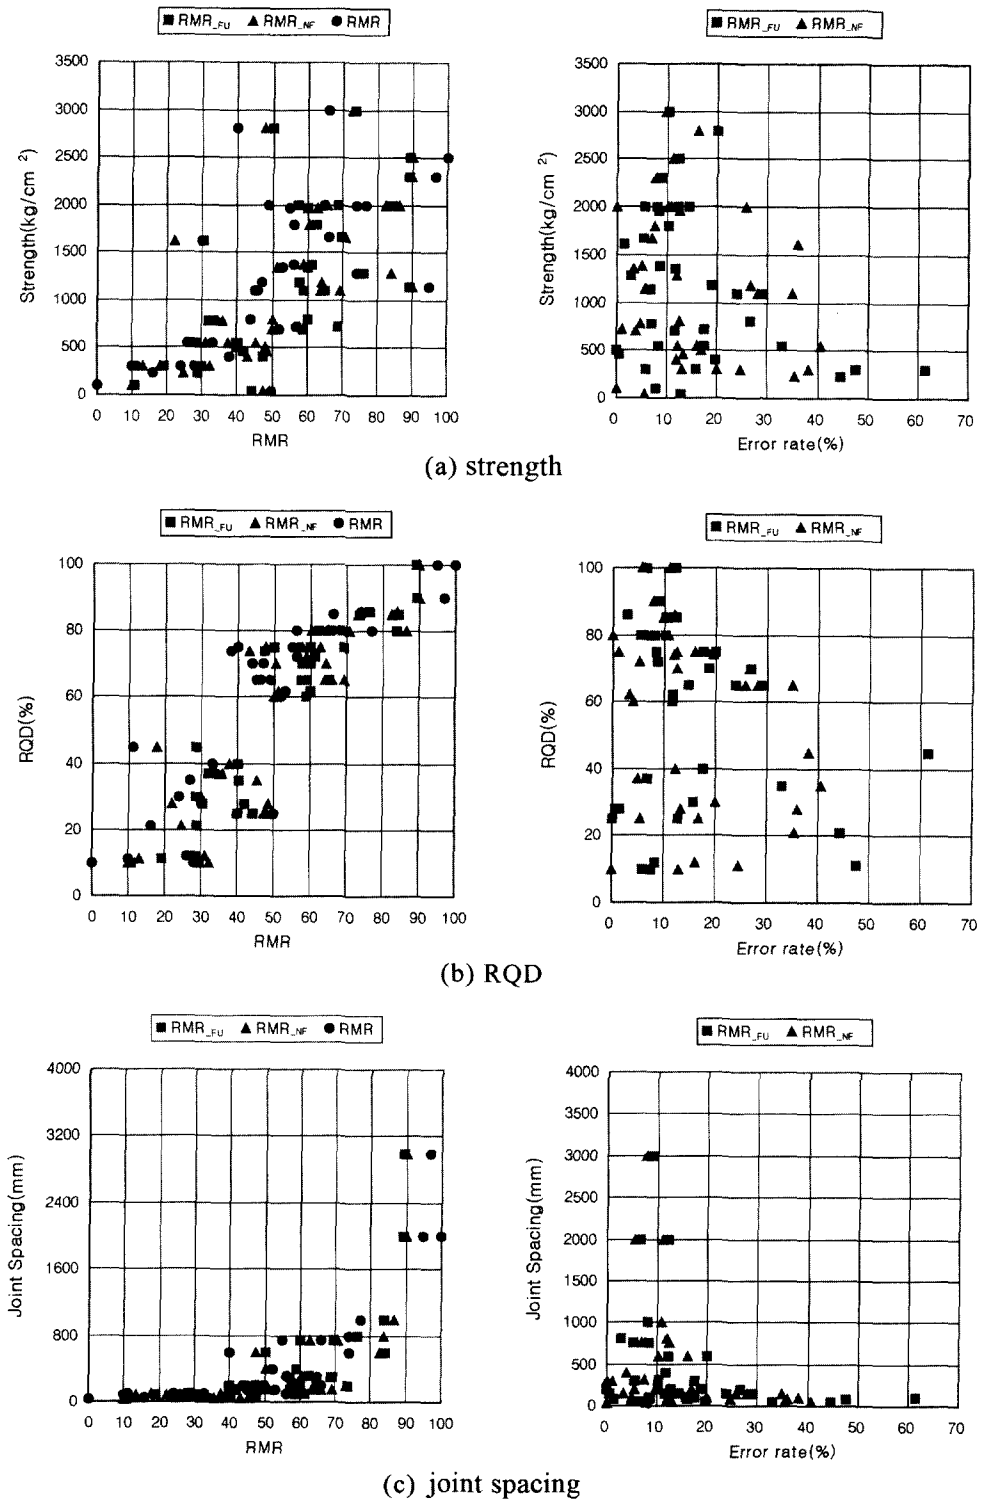
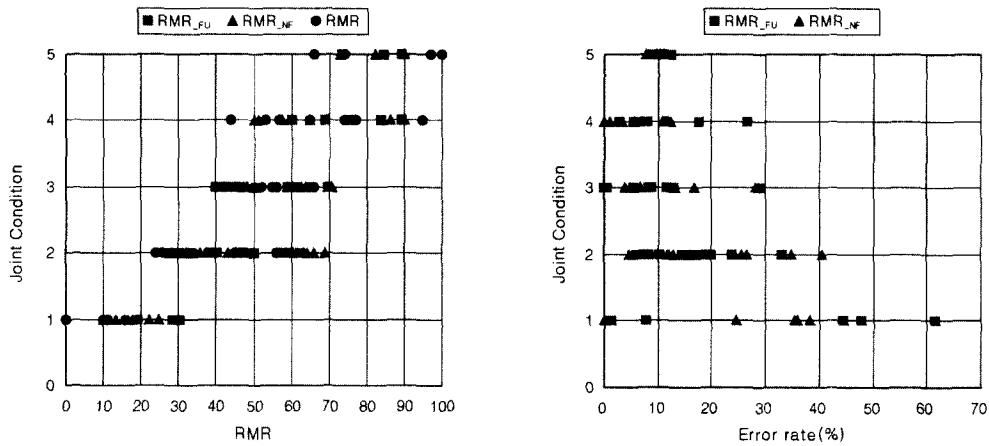
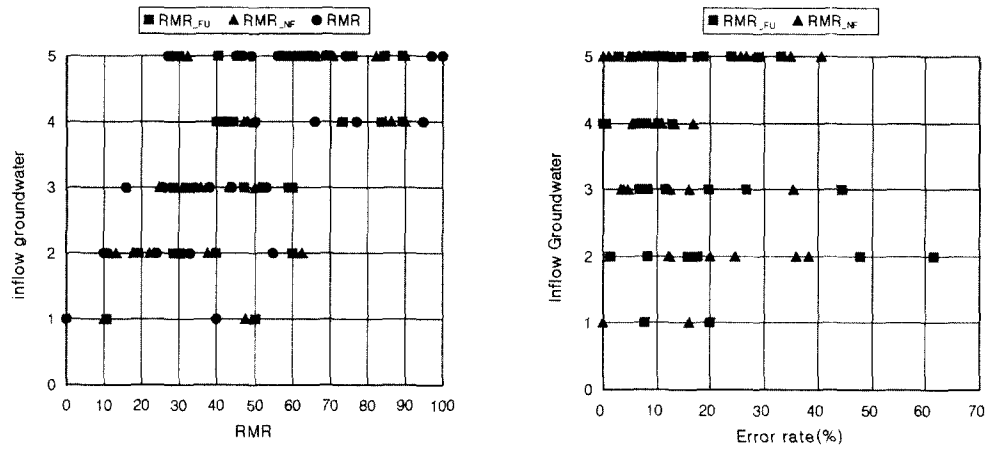


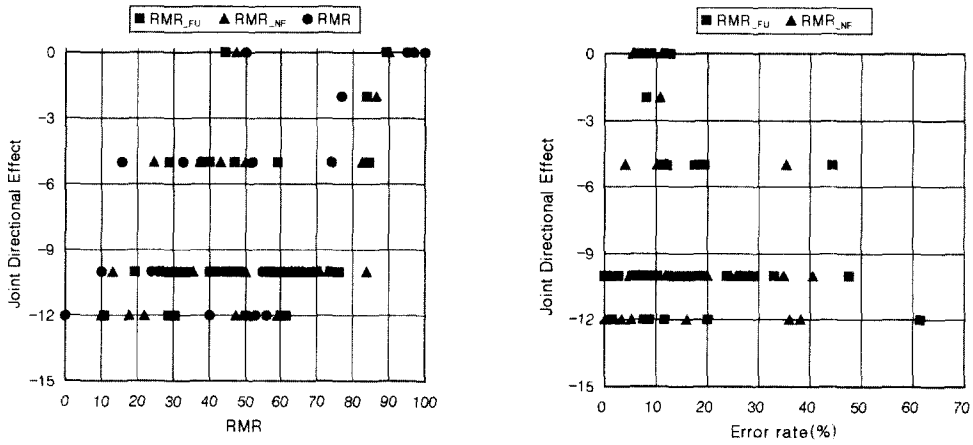
Fig. 8. Correlation of input variables for the RMR values and Error rate.



(d) joint condition



(e) Inflow groundwater



(f) joint directional effect

Fig. 8. Continued.

전체적으로 46개 현장자료 중 기존의 RMR값에 대한 퍼지집합이론 및 뉴로퍼지기법에 의해 추론된 RMR_{FU}, RMR_{NF}값들이 각각 76%와 74%가 상대적으로 증가하는 경향을 보였다. RMR값과 조사항목간의 상관성이 비교적 높은 것들로는 (a)암석강도, (b)RQD, (c)절리간격, (d)절리면 상태 등으로 분석되었고, (e)지하수 유입량과 (f)절리의 방향성의 경우 RMR_{FU}, RMR_{NF} RMR값들 모두에서 분산된 범위가 크을 알 수 있으며, 이상의 결과는 Table 2의 RMR값과 각 항목별 상관성 분석결과와 일치하는 경향을 보이고 있다.

그리고 각 조사항목별 기존의 RMR값과 추론된 RMR_{FU}, RMR_{NF}값들 사이의 오차율에서는 전반적으로 특별한 경향을 보이지 않고 있으나, 평균오차율 약 13% 정도를 기준으로 각 항목들의 값들이 작을수록 오차율은 증가하는 경향을 나타내었다.

4.2 추론된 RMR값들과 기존 RMR값의 상관성 분석

Fig. 9(a), (b)와 Table 5에는 기존의 RMR값과 추론된 RMR_{FU}, RMR_{NF}값들에 대한 상관성 분석결과를 나

타내었다. Fig. 9(a)의 상관성에서 보는 바와 같이 기존 RMR자료의 상관계수를 1.0로 하였을 때 전체적으로 퍼지추론에 의한 RMR_{FU}값과의 상관성(IRI = 0.96)이 퍼지신경망에 의한 RMR_{NF}값에 비해 상관성(IRI = 0.95)이 미소하나마 높은 것으로 분석되었다. 그러나 (b)의 RMR값에 대한 추론결과들의 오차율에서는 퍼지신경망에 의한 RMR_{NF}값의 평균오차(약 13.7%)가 퍼지추론에 의한 RMR_{FU}값의 평균오차(약 14.9%)보다 비교적 적은 것으로 분석되었다.

그리고 Table 5에 나타낸 바와 같이 퍼지추론에 의한 RMR_{FU}값과 퍼지신경망으로부터 추론된 RMR_{NF}의 사이의 상관성 분석에서도 높은 상관성(IRI = 0.97)을 가지고 있어 퍼지신경망의 학습결과에 대한 신뢰성이 비교적 높은 것으로 사료된다.

이 결과로부터 RMR분류의 6개 조사항목들에 대한 -12점~30점까지의 평가점수를 부여하여 산술적으로 구한 RMR값과 6개 항목 중 4개 항목에 항목별 실제 측정값을 퍼지이론 및 뉴로퍼지기법에 적용하여 추론하는 RMR값이 상호 유사한 경향을 보이고 있는 것으로 사

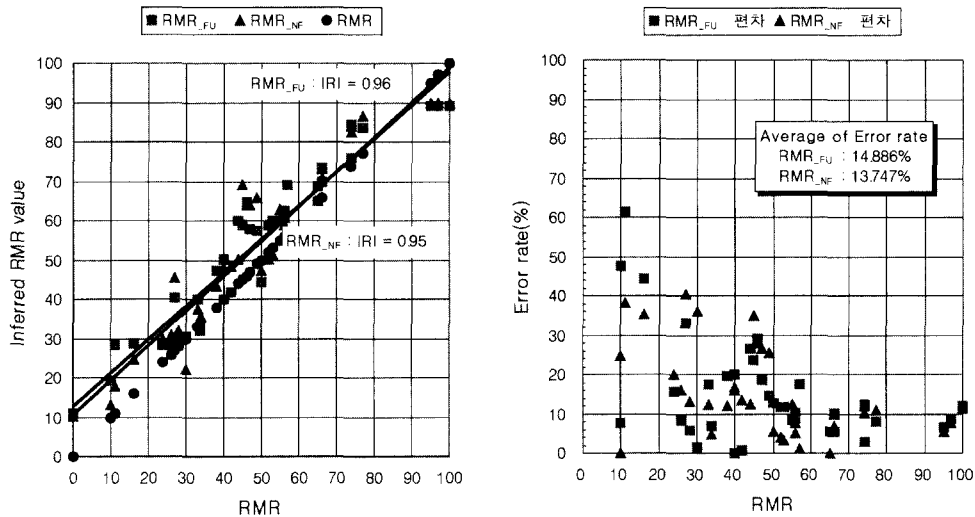


Fig. 9. Relationship and error rate between inferred RMR_{FU}, RMR_{NF} and the RMR values.

Table 5. Correlation coefficient between RMR value and RMR_{FU}, RMR_{NF} resulting from fuzzy set theory and neuro-fuzzy techniques.

| Corr. coeff.(IRI) | Strength | RQD | Joint spacing | Joint condition | Ground water | Joint Directional Effect | RMR | RMR _{FU} | RMR _{NF} |
|-------------------|----------|--------|---------------|-----------------|--------------|--------------------------|--------|-------------------|-------------------|
| RMR | 0.6635 | 0.8383 | 0.7775 | 0.8746 | 0.6326 | 0.5812 | 1 | | |
| RMR _{FU} | 0.7017 | 0.9149 | 0.6885 | 0.8656 | 0.6366 | 0.4744 | 0.9618 | 1 | |
| RMR _{NF} | 0.6844 | 0.8607 | 0.6894 | 0.8298 | 0.6971 | 0.4822 | 0.9542 | 0.9708 | 1 |

*RMR_{FU} : RMR value inferred from fuzzy set theory
 RMR_{NF} : RMR value inferred from neuro-fuzzy techniques

료된다.

5. 결 론

터널의 막장면 조사 시 지반의 고유 특성을 보다 정확하게 평가하고, 조사자의 주관성을 최소화시키기 위하여 인공지능기법 중 퍼지집합이론과 뉴로-퍼지기법을 암반분류에 가장 일반적으로 사용되는 RMR분류에 적용하여 보았다. 기존에 사용중인 산술적 RMR분류에 의한 값과 퍼지집합이론 및 뉴로-퍼지기법을 이용하여 추론된 RMR값을 상호 비교하여 보았고, 그 결과를 요약하면 다음과 같다.

퍼지집합이론으로 추론된 RMR값과 학습자료로 사용된 원래의 RMR값과 상호 비교·검토한 결과, 원래의 RMR값과 퍼지추론에 의한 RMR_{FU}값의 상관계수는 $IRI = 0.96$ 으로 높은 상관성을 보여주었고, 뉴로퍼지기법에 의해 추론된 RMR_{NF}값과 원래의 RMR값과의 상관계수도 $IRI = 0.95$ 로 퍼지이론에 의한 결과와 같이 높은 상관성을 나타내었다. 또한 RMR값에 대한 추론결과들의 오차율에서는 퍼지신경망에 의한 RMR_{NF}값의 평균오차와 퍼지추론에 의한 RMR_{FU}값의 평균오차가 각각 약 13.7%, 약 14.9% 정도로 비교적 낮게 나타났다.


이상의 결과들로부터 RMR분류의 6개 조사항목들에 대한 -12점~30점까지의 평가점수를 부여하여 산술적으로 구한 RMR값과 6개 항목중 4개 항목에 항목별 실제 측정값을 퍼지이론 및 뉴로퍼지기법에 적용하여 추론하는 RMR값이 상호 유사한 경향을 보이고 있는 것으로 사료된다.

이와 같이 터널의 막장면 평가에 퍼지집합이론을 적용함으로써 조사자의 육안관찰에 의한 정량적 그리고 정성적인 입력방식과 더불어 조사장비로부터의 아날로그 입력방식 등을 복합적으로 적용할 수 있으므로 조사자의 주관성과 오차를 최소화할 수 있을 것이다.

참고문헌


1. 구호본, 배규진, 문홍등, 홍성완, 1994, RMR 분류법의

- 국내 적용성 평가, 한국지반공학회 가을학술발표회, 209-216
2. 김남수, 양형식, 1996, 가속신경망에 의한 암반물성의 추정, 터널과 지하공간(한국암반공학회지) 6, 316-325
3. 대한광업진흥공사, 1994, 암반구조물의 전산설계연구, 연구보고서, 광진94-24, 167-202
4. 문현구, 이철욱, 1993, 불연속 암반내 터널굴착의 안정성 평가 및 암반분류를 위한 인공 신경회로망 개발, 터널과 지하공간(한국암반공학회지) 3, 63-79
5. 성영준, 김기봉, 1999, 퍼지신경망을 이용한 철근콘크리트 교량의 손상도 평가, 한국구조물진단학회지 3, 4, 129-137
6. 양형식, 김재철, 1999, 인공신경망을 이용한 한국형 터널 암반분류, 터널과 지하공간(한국암반공학회지) 9, 214-220
7. 이광형, 오길록, 1995, Fuzzy 이론 및 응용 I, II, 홍릉과학출판사
8. 이증빈, 박주원, 장영부, 1998, 퍼지근사추론법에 의한 손상구조물의 건전도 평가시스템 개발, 한국구조물진단학회 1998년도 봄 학술발표회, 제2권, 제1호, 41-48
9. 조만섭, 2001, 뉴로퍼지기법을 이용한 터널지반의 평가, 전북대학교 박사학위논문, 91-109
10. 한국건설기술연구원, 2000, Fuzzy 추론을 이용한 터널 보강공법 선정용 Expert System 개발(I), 연구보고서, 전기연 2000-113, 103-195
11. INFORM GmbH, 1999, FuzzyTECH Manual, 114-199
12. Nguyen, V. U. and E. Ashworth, 1985, Rock mass classification by fuzzy sets, Proc. 26th US Symposium on Rock Mechanics, Vol.1, 26-28 June. Rapid City, 937-945
13. Nguyen, V. U., 1985, Some fuzzy set application in mining geomechanics, Int. J. Rock Mechanics and Mining Science & Geomechanics Abstract 22. 6, 369-379
14. Yu, T. Z. and P. Z. Zeng, 1983, Classification system of fuzzy sets for rock engineering, Proc. Int. Symposium on Engineering Geology and Underground Construction 1, Lisbon, 2.1-2.9
15. Z. T. Bieniawski, 1984, Rock Mechanics Design in Mining and Tunneling, A.A. Balkema
16. 吉中龍之進, 櫻井春輔, 菊地宏吉, 1989, 岩盤分類とその適用, 岩盤工學 系(1), 土木工學社
17. 大野研, 清水則一, 1990, 地盤工學へのファジィ理論の應用, 日本ファジィ學會誌 2. 3, 300~312



배 규 진

1980년 경북대학교 농공학과 공학사
 1982년 연세대학교 대학원 토목공학과 공학석사
 1990년 연세대학교 대학원 토목공학과 공학박사
 Tel : 031-910-0162
 E-mail : gjbae@kict.re.kr
 현재 한국건설기술연구원 토목연구부장



조 만 섭

1991년 전북대학교 공과대학 자원공학과 공학사
 1993년 전북대학교 공과대학 자원공학과 공학석사
 2001년 전북대학교 대학원 자원공학과 공학박사
 Tel : 031-910-0162
 E-mail : mscho@kict.re.kr
 현재 한국건설기술연구원 선임연구원