

터널 발파에서 비장약량 및 진동속도 예측을 위한 신경망 이론의 적용

정 용훈, 이 정인
서울대학교 지구환경시스템공학부

1. 서 론

발파에 의한 터널에서의 암반굴착 작업은 천공의 위치와 장약량 등이 표기된 터널 발파패턴도를 기초로 이루어지게 되며, 발파패턴도의 적정성에 따라 발파 효율 및 발파에 의한 진동과 소음 수준, 그리고 안정성이 결정되어진다. 그러나 현재 국내 터널 현장에서의 실제 발파작업은 현장 발파기술자의 시공 경험에 크게 의존하고 있는 실정이다. 이런 경험적 기술에 의한 발파작업에서는 현장 암반의 조건이나 주변 구조물에 대한 허용진동속도, 터널 굴착면의 안정성 등을 정량적으로 고려하지 못하고 있을 뿐만 아니라, 각 개인마다 고려하는 요소들에 차이가 많았다.

발파에 의해 파쇄된 암석의 부피당 사용된 총 화약량을 나타내는 비장약량은 균열 빈도의 세제곱근에 반비례하며(Scott, 1996), 암반 상태, 절리면 간격, 절리면 방향, 비중과 경도로 구성된 발파용이도 지수에 비례하는 것으로 알려져 있다(Lilly, 1986). 한편 터널 발파작업시 발생하는 발파진동을 주변 보안물건에 대한 허용 진동수준이하로 제어하기 위한 지발당 장약량의 제한은 경험적으로 구한 발파진동전파식으로부터 산정하고 있다. 그러나 발파에서의 비장약량 산정과 최대 발파진동속도의 예측에 있어서 현장의 지질조건과 발파조건을 종합적으로 고려한 체계적인 연구는 매우 부족한 실정이다. 따라서 터널 발파에서 발파 효율의 향상과 최종 굴착면의 안정성 확보 등을 위해 고려해야 하는 요소(암반조건, 발파조건)의 제시와 정량적 표현이 필요하다.

최근에 들어서 암반공학에서 신경망 이론의 응용 가능성이 제시되고 있다. Huang 외(1998)는 암석 역학 분야에서의 신경망 이론의 적용 가능성을 제시하였으며, Meulenkamp 외(1999)는 암석의 경도를 바탕으로 강도를 예측하는 데 신경망을 적용하였다. 특히 Sou-Sen Leu 외(1998)는 불연속면의 특성(주향, 경사, 간격, 틈새, 상태), 암석강도, 암질지수, RMR 등 14개의 변수를 신경망의 입력 변수로 설정하여 터널 발파의 비장약량 예측 가능성을 제시하였다. 그리고 Yang 외(1997)는 인공신경망과 상대강도효과(RSE) 개념을 이용하여 지하 공동의 안정성 해석에 고려된 변수들의 중요도를 연구하였다. 이상과 같이 신경망 이론이 다양한 암반공학 분야에 적용되고 있으나, 국내에서는 아직 터널 발파에서 비장약량 산정과 발파진동속도를 예측하기 위한 기법으로 인공신경망을 적용한 연구는 거의 없는 실정이다.

따라서 본 연구에서는 일정한 발파 패턴과 기폭 패턴을 가지는 현장에서 지질 조건에 관한 자료를 직접 획득하여 측정자에 따른 오차를 줄이면서, 터널 발파에서의 비장약량과 발파에 의해 발생하는 발파진동의 최대진동속도를 예측하는데 인공신경망의 적용 가능성을 연구하였다. 그리고 상대강도효과(RSE) 개념을 적용하여 하나의 터널 발파 현장에서의 비장약량과 발파진동속도에 영향을 미치는 지질 조건을 확인하였다.

2. 인공신경망 모델 설계

2.1. 신경망 학습 자료

본 연구에서 사용한 자료는 중부내륙(여주-구미) 고속도로 제9공구 이화터널의 시점부에서 직접 조사한 것이다. 이 지역은 시대 미상의 백화리각섬암 및 상내리층, 이들과 부정합 관계에 놓여있는 시대 미상의 옥천계 지층인 백화산층, 조봉층, 이화령층과 이들을 관입한 중생대 백악기 지층인 흑운모 화강암으로 구성되어 있다. 주된 암석은 흑운모 화강암이며 풍화되어 있었다.

현장에서 사용된 발파공 패턴은 V-cut이었으며, 발파공 패턴과 기폭 패턴은 Fig. 1에 제시하였다. 본 연구는 일정한 하나의 터널 현장 자료를 가지고 수행되었으므로 이상의 조건들은 입력변수에서 제외하였다. 그 외에 고려한 입력변수는 기존의 연구를 조사하여 결정하였다. 터널 발파에서 비장약량을 예측하기 위해서는 14개의 입력변수를 고려하였으며, 발파에 의한 최대진동속도를 예측하기 위해서는 18개의 변수를 설정하였다. 이는 Table 1에 제시하였으며, 전자는 (A~F), 후자는 (A~J)가 입력변수로 고려되었다.

터널 발파에서의 비장약량 예측 모듈에서 사용한 학습 자료는 총 25개였으며, 최대 발파진동속도 예측 모듈에서 사용한 학습 자료는 총 27개였다.




Fig. 1. Tunnel blast pattern.

Table 1. Description of input and output parameters in ANN.

| Parameter | Description | Data Type | Range (unit) | |
|----------------------------|-----------------------------|----------------|----------------------|---------|
| Input | A. Tunnel orientation | Numeric | 0 ~ 360 | |
| | B1. Major discontinuity | dip direction | Numeric | 0 ~ 360 |
| | | B2. dip | Numeric | 0 ~ 90 |
| | | B3. spacing | Logic | 1 ~ 5 |
| | | B4. separation | Logic | 1 ~ 5 |
| | | B5. condition | Logic | 1 ~ 5 |
| | C1. Secondary discontinuity | dip direction | Numeric | 0 ~ 360 |
| | | C2. dip | Numeric | 0 ~ 360 |
| | | C3. spacing | Logic | 1 ~ 5 |
| | | C4. separation | Logic | 1 ~ 5 |
| | | C5. condition | Logic | 1 ~ 5 |
| | D. Rock strength | Logic | 1 ~ 5 | |
| | E. R.Q.D. | Logic | 1 ~ 5 | |
| | F. RMR | Numeric | 0 ~ 100 | |
| | G. Drilling length | Numeric | (m) | |
| H. Blasting quality | Numeric | (%) | | |
| I. Charge weight per delay | Numeric | (kg) | | |
| J. Distance | Numeric | (m) | | |
| Output | Powder factor | Numeric | (kg/m ³) | |
| | Particle Velocity | Numeric | (cm/sec) | |

2.2 매개변수 연구

인공신경망은 신경망을 구성하는 뉴런의 종류와 연결 형태, 그리고 연결 링크에 가중치를 부여하는 방식 등에 따라 여러 유형으로 나뉜다. 이러한 분류 중에서, 본 연구는 역전파 학습 알고리즘을 이용하는 다층 퍼셉트론을 이용하였다. 또한 활성화함수는 시그모이드(sigmoid) 함수를 사용하였다.

인공신경망은 학습률과 관성항과 같은 학습 상수, 입·출력층의 뉴런의 수 그리고 은닉층의 구조에 따라서 학습 능률 및 예측 능력이 큰 차이를 나타낸다. 그러므로 터널 발파에서 비장약량과 최대 발파진동속도 예측을 위한 최적의 인공신경망 구조를 결정하기 위하여 은닉층 구조, 학습률, 관성항을 변화시킨 모델에 대하여 학습을 수행하였다.

그 결과 터널 발파에서 비장약량 예측을 위한 최적 신경망은 학습률과 관성항이 각각 0.95, 0.95이며 신경망의 구조가 14-4-4-1인 모델이었다. 그리고 발파에 의한 최대진동속도 예측을 위해서는 학습률과 관성항이 각각 0.95, 0.80이며 신경망의 구조가 18-5-5-1인 모델이었다.

2.3 신뢰성 검증

학습에 사용되지 않은 자료를 사용하여 터널 발파에서의 비장약량과 발파진동의 최대진동속도 예측에 최적으로 선정된 신경망의 예측 능력을 검증하였다. 그리고 발파진동의 최대진동속도 예측 모델에 대해서는 학습자료에 의해 회귀분석된 발파진동식의 결과와 비교하였다.

2.3.1. 비장약량 예측 모델

터널 발파에서의 비장약량 예측에 선택된 신경망(구조:14-4-4-1, 학습률:0.95, 관성항:0.95)의 예측

능력을 검증하기 위하여 학습에 사용되지 않은 Table 2의 4개의 자료를 사용하였다. 이 자료에 대하여 신경망에서 학습된 결과와 실제 발파에서의 결과를 비교한 것이 Table 3이다. 터널 발파에서의 비장약량 예측에서는 실제 발파의 측정값과 신경망을 이용한 예측값의 오차의 평방평균은 0.0433 kg/m³이었다. 이는 학습에 사용된 자료에서의 오차의 평방평균 0.000737 kg/m³과 비교하여 큰 값이다. 이는 학습에 사용된 자료의 수가 적음으로 인하여 신경망의 일반화가 덜 되었음에 기인한 것으로 판단하였다. 그러나 예측된 비장약량은 실제 측정값에 대하여 0.04 kg/m³의 절대오차를 가졌으며, 평균 4.72 %의 상대오차를 나타냈다. 이 때 절대 오차와 상대오차는 다음과 같이 정의된다.

$$\text{Absolute Error} = T_i - O_i \quad (1)$$

$$\text{Relative Error} = \frac{T_i - O_i}{T_i} \quad (2)$$

여기서 T_i 와 O_i 는 각각 학습에 사용된 목표 출력과 인공신경망에 의해 학습된 출력을 의미한다. 이로부터 학습된 신경망이 지질 조건의 변화를 고려하여 만족할 수준으로 예측 가능하다고 판단하였다.

Table 2. Testing sets of powder factor prediction.

| Sample Number | S-11 | S-12 | S-13 | S-14 | |
|-------------------------|---------------|------|------|------|-----|
| Tunnel Orientation | 90 | 90 | 90 | 90 | |
| Major Discontinuity | Dip Direction | 259 | 086 | 081 | 257 |
| | Dip | 82 | 86 | 88 | 87 |
| | Spacing | 2 | 2 | 3 | 2 |
| | Separation | 2 | 2 | 2 | 2 |
| | Condition | 2 | 2 | 2 | 3 |
| Secondary Discontinuity | Dip Direction | 346 | 005 | 357 | 340 |
| | Dip | 77 | 73 | 77 | 78 |
| | Spacing | 1 | 2 | 2 | 1 |
| | Separation | 3 | 3 | 2 | 2 |
| | Condition | 3 | 3 | 3 | 3 |
| Rock Strength | 3 | 4 | 5 | 2 | |
| R.Q.D. | 1 | 2 | 2 | 2 | |
| RMR | 38 | 52 | 39 | 44 | |

Table 3. Comparison of experimental value and ANN output of powder factor.

| Sample Number | Powder Factor (kg/m ³) | | Error | |
|---------------|------------------------------------|------------|-------------------------------------|--------------------|
| | Measured value | ANN output | Absolute Error (kg/m ³) | Relative Error (%) |
| S-11 | 0.94 | 0.89 | 0.05 | 5.32 |
| S-12 | 0.98 | 0.94 | 0.04 | 4.08 |
| S-13 | 0.83 | 0.78 | 0.05 | 6.02 |
| S-14 | 0.87 | 0.90 | -0.03 | -3.45 |

2.3.2. 진동속도 예측 모델

(1) 발파진동 측정결과

신경망의 학습에 사용된 27개의 발파진동의 최대진동속도 자료를 가지고 발파진동식을 결정하였다. 먼저 자승근 환산거리에 대한 해석 결과 50 % 평균 회귀 분석식은 식 (3)이며, 안전율을 고려한 발파 설계에 이용하게 되는 95 % 발파진동식은 식 (4)이다.

$$V = 780.0 \left(\frac{D}{W^{1/2}} \right)^{-1.964} \quad (50 \%) \quad (R = 0.887) \quad (3)$$

$$V = 1552.9 \left(\frac{D}{W^{1/2}} \right)^{-1.964} \quad (95 \%) \quad (R = 0.887) \quad (4)$$

또한 삼승근 환산거리에 대한 해석을 수행한 결과는 식 (5)와 (6)이다. 식 (5)는 50 % 평균 회귀 분석식이며, 식 (6)는 95 % 발파진동식이다.

$$V = 1544.8 \left(\frac{D}{W^{1/3}} \right)^{-2.043} \quad (50 \%) \quad (R = 0.890) \quad (5)$$

$$V = 3045.6 \left(\frac{D}{W^{1/3}} \right)^{-2.043} \quad (95 \%) \quad (R = 0.890) \quad (6)$$

(2) 예측능력 검증

터널 발파에서의 최대 발파진동속도의 예측에 선택된 신경망(구조:18-5-5-1, 학습률:0.95, 관성항:0.80)의 예측 능력을 검증하기 위하여 학습에 사용되지 않은 Table 4의 4개의 자료를 사용하였다. 이 자료에 대하여 신경망의 출력 결과와 실제 발파에서의 결과를 비교한 것이 Table 5이다. 이 경우 실제 발파의 측정값과 신경망을 이용한 예측값의 오차의 평방평균은 0.0156 cm/sec이었다. 이는 학습에 사용한 자료에서의 오차의 평방평균 0.00361 cm/sec와 비교하여 큰 값이다. 인공신경망의 예측에 의한 비장약량은 실제 측정값에 대하여 절대오차가 0.013 cm/sec이었다.

Fig. 2은 학습에 사용된 자료에서 얻은 발파진동식 식 (2.3)~(2.6)으로 예측한 값, 신경망에 의한 예측값과 실제 측정값을 보여준다. 발파진동식에 의해 예측된 값은 실제 진동값에 비하여 60 %이상 더 큰 값을 예측하고 있음을 쉽게 확인할 수 있다. 이는 발파진동식이 변화될 지질 조건들을 충분히 고려하지 못함에 기인한 것으로 판단하였다. 그러므로 신경망에 의해 예측된 발파진동속도는 국부적인 지질 조건이 반영된 일부 발파진동 측정자료로부터 회귀분석한 발파진동식에 의한 값보다 다양한 지질 조건에 의해 영향을 받는 발파진동속도를 더 정확히 예측할 수 있는 것으로 나타났다.

3. 상대강도효과(RSE)

상대강도효과(RSE_{ki})는 하나의 출력변수 k에 대한 여러 입력변수 i의 영향 정도를 나타낸다. RSE_{ki}의 값이 클수록, 출력변수에 대한 입력변수의 영향이 더 크다. 또한 RSE_{ki}의 부호는 입력변수가 출력변수에 어떻게 영향을 미치는지를 의미한다. 즉 그 값이 0이면 출력변수와 입력변수가 어떠한 관계도 가지지 않음을 의미하지만, 양과 음인 경우에는 입력 변수가 출력변수에 각각 긍정적, 부정적인 방향으로 작용함을 의미한다. (Yang 외, 1998)

Table 4. Testing sets of peak particle velocity prediction.

| Sample Number | | S-21 | S-22 | S-23 | S-24 |
|------------------------------|---------------|------|------|------|------|
| Tunnel Orientation | | 090 | 090 | 090 | 090 |
| Major Discontinuity | Dip Direction | 086 | 086 | 086 | 081 |
| | Dip | 86 | 86 | 86 | 88 |
| | Spacing | 2 | 2 | 2 | 3 |
| | Separation | 2 | 2 | 2 | 2 |
| | Condition | 2 | 2 | 2 | 2 |
| Secondary Discontinuity | Dip Direction | 005 | 005 | 005 | 357 |
| | Dip | 73 | 73 | 73 | 77 |
| | Spacing | 2 | 2 | 2 | 2 |
| | Separation | 3 | 3 | 3 | 2 |
| | Condition | 3 | 3 | 3 | 3 |
| Rock Strength | | 4 | 4 | 4 | 5 |
| R.Q.D. | | 2 | 2 | 2 | 2 |
| RMR | | 52 | 52 | 52 | 56 |
| Drilling Length (m) | | 1.70 | 1.70 | 1.70 | 2.2 |
| Blasting Quality (%) | | 88.2 | 88.2 | 88.2 | 81.8 |
| Distance (m) | | 70.0 | 80.5 | 93.5 | 93.9 |
| Charge weight per delay (kg) | | 2.56 | 2.56 | 2.56 | 3.20 |

Table 5. Comparison of experimental value and ANN output in peak particle velocity.

| Sample Number | Peak Particle Velocity (cm/sec) | | Error | |
|---------------|---------------------------------|------------|-------------------------|--------------------|
| | Experimental value | ANN output | Absolute Error (cm/sec) | Relative Error (%) |
| S-21 | 0.28 | 0.265 | 0.015 | 5.36 |
| S-22 | 0.20 | 0.193 | 0.007 | 3.50 |
| S-23 | 0.14 | 0.166 | -0.026 | -18.57 |
| S-24 | 0.20 | 0.195 | 0.005 | 2.50 |

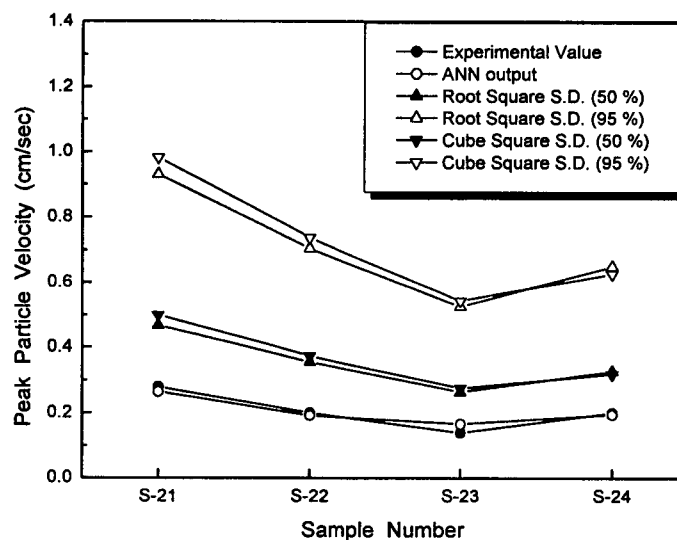


Fig. 2. Comparison of measured value, ANN output and equation results in peak particle velocity.




Fig. 3. Mean RSE of testing samples (powder factor).

3.1. 터널 발파에서의 비장약량

터널 발파에서 비장약량 예측을 위한 신경망의 개발에 사용된 25개의 학습 자료에 대하여 비장약량에 대한 각 입력변수들의 평균 RSE를 Fig. 3에 도시하였다. 그림에서 각 막대에 그려진 선의 길이는 자료들간의 분산을 의미한다. 학습 자료를 수집한 터널 현장의 경우 14개의 입력 변수들을 비장약량에 영향을 많이 주는 순서로 배열하면 다음과 같다.

- 주 불연속면의 상태(B5), 경사(B2), 간격(B3)
- 암질지수(E), 두 번째 불연속면의 경사(C2)
- 두 번째 불연속면의 상태(C5), 틈새(C4), 경사 방향(C1), 간격(C2)
- RMR(F), 주 불연속면의 틈새(B4), 경사 방향(B1), 터널 굴착 방향(A)

3.2. 터널 발파에서의 진동속도

터널 발파에서 최대 발파진동속도 예측을 위한 신경망의 학습에 사용된 27개의 자료에 대하여 발파진동속도에 대한 각 입력변수들의 평균 RSE는 Fig. 4에서 확인할 수 있다. Fig. 4는 본 연구에서 고려된 18개의 입력 변수 중에서 발파원과 측정점 간의 거리(J)에 의해 발파진동속도가 가장 크게 좌우됨을 보여준다. 또한 두 번째 불연속면의 간격(C3), 경사(C2), 주 불연속면의 경사(B2)와 암석 강도(D) 순으로 영향을 주지만, 이 변수들은 자료들간의 분산이 매우 컸다. 반면에 터널의 굴진 방향(A)과 RMR(F)이 가장 영향을 주지 않는 변수였다.

터널 발파에서 주위 보안 구조물에 대한 허용진동속도를 만족시키며 발파를 수행하여 발파 효율을 최대로 하는 것이 중요하다. 그래서 발파 효율에 따른 발파 진동에 의한 최대진동속도에 영향을 주는 입력변수를 연구할 필요가 있다. 신경망의 학습 자료 중 발파 효율이 매우 좋은 자료(1, 2, 5, 6번)와 좋지 않은 자료(15, 19, 20번)에 대한 RSE를 살펴보았다. 여기서 발파 효율이 매우 좋은 자료는 천공장에 대한 굴진장의 비가 95 %이상인 경우이며, 좋지 않은 자료는 80 % 미만인 경우로 분류하였다.

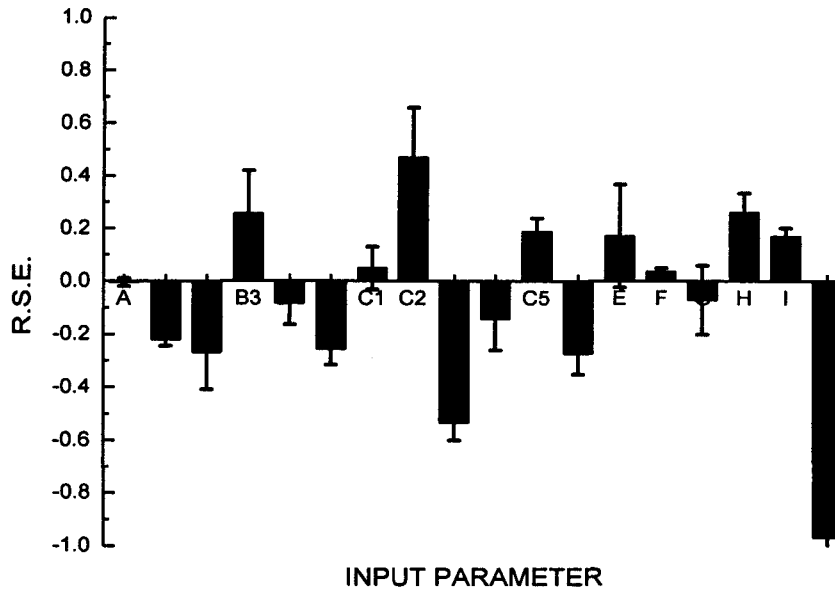


Fig. 4. Mean RSE of testing samples (peak particle velocity).

Fig. 5은 발파 효율이 좋은 자료의 RSE이며, Fig. 6는 좋지 않은 자료의 RSE이다. Fig. 5과 Fig. 6로부터 발파효율에 상관없이 자료를 수집한 터널 현장에서는 발파원과 측정점 간의 거리(J)가 다른 입력 변수들과 비교하여 최대진동속도에 가장 큰 음의 영향을 주는 것을 알 수 있다. 이는 기존의 발파 진동식과 동일하게 거리가 멀어질수록 발파에 의한 최대진동속도는 감소함을 의미한다. 또한 발파 효율이 좋은 자료들과 좋지 않은 자료들 모두 각 입력 변수에 대한 RSE의 값을 연결한 곡선의 형태는 서로 유사하였다. 그러나 RSE의 분산은 Fig. 5이 Fig. 6에 비하여 작았다. 이는 발파 효율이 좋지 않은 경우에 분산이 큰 입력 변수들의 변화 정도가 최대진동속도에 더 많은 영향을 미침을 의미한다.




Fig. 5. RSE of the good blasting quality group.

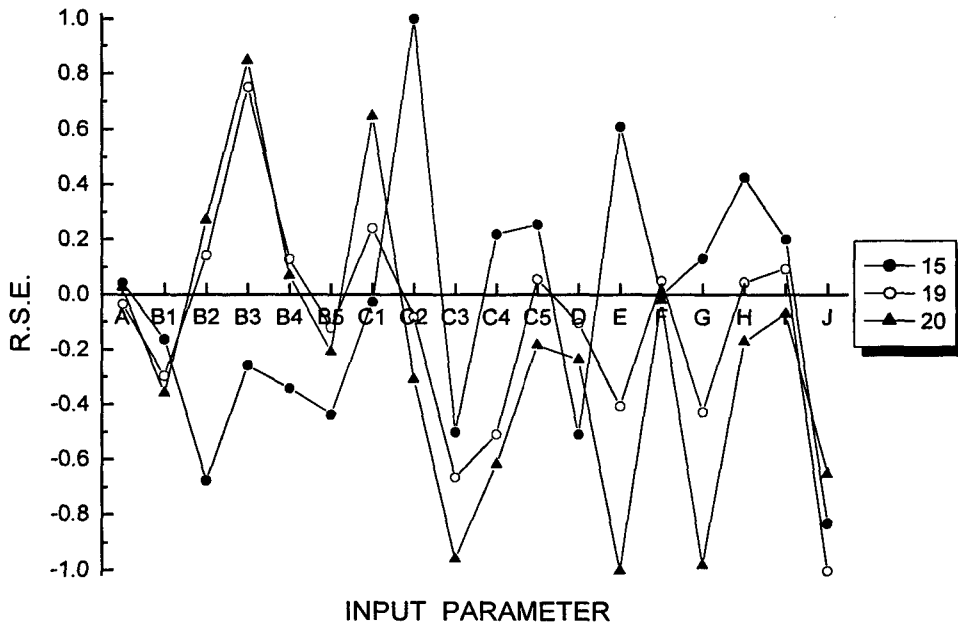


Fig. 6. RSE of the poor blasting quality group.

4. 결론

본 연구에서는 터널 현장에서 직접 지질 조건과 발파 조건을 조사하고 비장약량과 최대진동속도를 측정된 자료를 이용하여 인공신경망의 적용 가능성을 살펴보았다. 또한 출력변수에의 입력변수들의 영향 정도를 파악하는 상대강도효과(RSE) 개념을 이용하여 터널 발파에서의 비장약량과 발파에 의한 최대진동속도에 영향을 미치는 입력 변수를 조사하였다. 이 연구에서 얻은 결론을 요약하면 다음과 같다.

1) 터널 발파의 비장약량 예측 능력의 검증 결과 실제 발파의 측정값과 인공신경망을 이용한 예측값의 오차의 평방평균은 0.0433 kg/m^3 로 학습에 사용된 자료에 대한 오차의 평방평균보다 크게 계산되었다. 이는 학습에 사용된 자료의 수가 적음으로 인하여 신경망의 일반화가 덜 되었음에 기인한 것으로 판단된다. 그러나 예측된 비장약량은 측정된 비장약량에 대하여 4.72%의 상대 오차를 가졌다. 이로부터 학습된 신경망이 지질 조건의 변화를 고려하여 만족할 수준으로 예측 가능한 것으로 사료된다.

2) 발파에 의한 최대진동속도 예측 능력의 검증 결과 실제 발파의 측정값이 인공신경망을 이용한 예측값과 나타낸 오차의 평방평균은 0.0156 cm/sec 이었다. 이 경우도 학습에 사용된 자료의 경우보다 크게 계산되었으나 상대 오차는 5%미만이였다. 반면에 신경망의 학습에 사용된 27개의 자료를 바탕으로 얻은 발파진동식에 의한 예측값과는 0.150 cm/sec 의 오차의 평방평균을 나타내었다. 그러므로 인공신경망에 의해 예측된 발파진동속도는 국부적인 지질 조건이 반영된 일부 발파진동 측정자료로부터 회귀분석한 발파진동식에 의한 값보다 다양한 지질 조건에 의해 영향을 받는 발파진동속도를 더 정확히 예측할 수 있는 것으로 나타났다.

3) 터널 발파에서의 비장약량은 본 연구에서 고려한 14개의 지질 조건 중에서 주 불연속면의 특성(경사 방향, 경사, 간격, 상태)과 암질지수에 의하여 많은 영향을 받았다. 그러나 터널의 굴진 방향에 대해서는 거의 영향을 받지 않음을 확인하였다.

4) 본 연구에서 고려한 18개의 입력변수 중에서 발파원과 측정점 간의 거리에 의해 터널 발파에서의 최대진동속도가 가장 크게 좌우되는 것으로 나타났다. 또한 두 번째 불연속면의 간격, 경사, 주 불연속면의 경사와 암석 강도 순서로 영향을 주지만, 이 변수들은 자료들간의 분산이 매우 컸다. 반면에 터널의 굴진 방향과 RMR 값은 발파진동의 크기에 거의 영향을 주지 않는 것으로 나타났다.

참 고 문 헌

1. Huang Yi and Stefan Wanstedt, 1998, The introduction of neural network system and its applications in rock engineering, *Engineering Geology* 49, 253-260.
2. Lilly P., 1986, An empirical method of assessing rock mass blastability, *Large Open Pit Mining Conf.*, Newman, 89-92.
3. Meulenkamp F. and Alvarez Grima M., 1999, Application of neural networks for the prediction of the unconfined compressive (UCS) from Equotip hardness, *Int. J. Rock Mech. Min. Sci.* 30, 207-222.
4. Scott A., 1996, 'Blastability' and Blast Design, 5th Int. Symp. on Rock Fragmentation by Blasting, Montreal, 27-36.
5. Sou-Sen Leu, Sheng-Feng Lin, Ching-Kuang Chen and Shih-Wen Wang, 1998, Analysis of powder factors for tunnel blasting using neural networks, *FLAGBLAST* 2, 433-448.
6. Yang Y. and Zhang Q., 1997, A Hierarchical Analysis for Rock Engineering Using Artificial Neural Networks, *Rock Mech. Rock Eng.*, 30(4), 207-222.
7. Yang Y. and Zhang Q., 1998, The Application of Neural Networks to Rock Engineering System (RES), *Int. J. Rock Mech. Min. Sci.* 35(6), 727-745.