

인공신경망을 이용한 암반의 투수계수 예측

Permeability Prediction of Rock Mass Using the Artificial Neural Networks

이 인 모*1

Lee, In-Mo

조 계 춘*2

Cho, Gye-Chun

이 정 학*3

Lee, Jeong-Hark

Abstract

A reasonable and economical method which can predict permeability of rock mass in underground is needed to overcome the uncertainty of groundwater behavior. For this purpose, one prediction method of permeability has been studied. The artificial neural networks model using error back propagation algorithm, one of the teaching techniques, is utilized for this purpose. In order to verify the applicability of this model, in-situ permeability results are simulated. The simulation results show the potentiality of utilizing the neural networks for effective permeability prediction of rock mass.

요 지

지하수 거동에 대한 불확실성을 극복하기 위해서 암반 지반의 투수계수를 예측할 수 있는 신뢰적이고 경제적인 방법이 필요하다. 이러한 목적을 위하여 암반의 투수계수 예측 방법에 대한 연구가 수행되어졌다. 인공 신경망 이론을 적용한 투수계수 예측 방법에 대한 일환으로 오차역전파 학습알고리즘을 이용한 투수계수 예측 방법에 대하여 연구를 수행하였으며, 이 방법의 타당성 검토를 위하여 현장투수시험 결과와 지반물성치들에 적용하여 검증을 실시하였다. 검증결과 평균오차 범위가 작아 비교적 정확한 투수계수 예측방법임을 보여주었다.

Keywords : Permeability, Rock mass, Groundwater, Artificial neural networks, Error back propagation

*1 정희원, 고려대학교 공과대학 토목환경공학과 교수

*2 정희원, 고려대학교 공과대학 토목환경공학과 석사과정 졸업

*3 정희원, 대림산업(주) 기술연구소 선임연구원

1. 서론

우리 나라는 1970년대 중반, 지하철 터널의 건설이 시작된 이후 현재에도 많은 공사가 추진되고 있고 앞으로도 더욱 많은 공사가 추진될 예정이다. 지상의 구조물과는 달리 터널과 같은 지하구조물의 건설은 주변지반환경 및 지하수 문제등 불확실한 요소를 내포하고 있기 때문에 어려움이 따른다. 특히 최근 들어 지하구조물(터널 등) 해석시 실무자들에게 관심사가 되는 것이 지하수 문제라 할 수 있다. 이러한 지하수 문제를 해결하기 위해서는 그 흐름에 영향이 큰 암반의 투수계수를 경제적이고 신뢰성 있게 예측하는 방법이 필요하다 하겠다. 기존의 투수계수 예측법은 경험식에 의존하는 방법으로서 지반이 토사로 이루어진 경우에 대하여 대부분의 적용이 개발되어져 있는 실정이다. 절리를 가진 암에서의 투수계수 예측에 관한 연구도 있기는 하나, 그 대부분이 실제에 적용하기가 불가능한 이론적인 경우가 대부분이었다. 그리고 투수계수 예측을 위한 현장 시험법은 시험을 실시한 지역의 투수계수에 대한 비교적 신뢰성이 있는 값을 제안하나 시험자체의 적용 가능성과 시간에 대한 문제를 간과할 수 없으며 시험비용이 커 경제적으로 부담이 크다고 할 수 있어서 많은 시험을 할 수 없는 것이 현실이다. 이에 본 논문에서는 암반의 투수계수에 영향을 미치는 여러 인자와 그들의 상관관계의 특별한 정의 없이 적용할 수 있는 방법인 인공신경망 이론을 이용하여 암반에서의 지반물성치들(심도, RQD, 절리간격, 절리상태등)로부터 투수계수를 예측할 수 있는 방법을 제시하고자 하며, 예제해석을 통하여 타당성 검토를 실시하고자 한다.

2. 투수계수 예측방법

2.1 투수시험에 의한 방법

지반의 투수성을 현장에서 구하는 방법으로는 ① 우물이나 시추공을 이용하는 공정법

(孔井法)과 ② tracer 등을 이용하는 유속실측법(流速實測法)이 있다. 공정법은 그 시험시의 조건에 의하여 가압법(加壓法, [lugeon 시험 등])과 비가압법(非加壓法, [양수시험이나 JFT 시험 등])으로 구별되며 암반에 있어서는 lugeon 시험이 자주 실시된다.

지반의 조건이 토질인 경우는 실내시험도 가능하나, 암반인 경우는 전적으로 현장시험에 의존하며, 비록 현장 실험을 실시했다 하더라도 절리의 발달정도에 절대적으로 영향을 받기 때문에 이 결과를 일반화한다는 것은 거의 불가능하다. 이를 보완할 수 있는 것이 암반의 기본물성치로부터 암반의 투수계수를 어느 정도 예측 가능하도록 하여, 제한된 숫자의 실험에 의하여 실측된 투수계수를 보완하는 것이 바람직한 접근법으로 생각된다.

2.2 암반에서의 경험적인 방법

Wei 등(1995)에 의해 심도, 절리의 빈도, 절리틈새, RQD 등이 암반의 투수계수에 영향을 미치는 주요 인자임을 알아냈으며, 투수계수는 심도가 깊어짐에 따라 감소하는 경향이 있음을 제시하였다. Snow(1968)는 댐 현장에서 5532 개의 주입 시험(injection test)을 통하여 심도에 따른 투수계수 감소는 절리틈새의 감소가 주된 원인이란 사실을 알아내었다. 이로부터 심도(Z)에 따른 투수계수와 절리틈새의 변화를 묘사하기 위하여 암반 절리의 연직거동에 대한 쌍곡선 함수(hyperbolic function)를 아래와 같이 적용시켰다(Wei and Hudson, 1988).

$$\frac{e}{e_0} = 1 - \frac{Z}{A+BZ} \quad (1)$$

$$\frac{k}{k_0} = \left(1 - \frac{Z}{A+BZ}\right)^3 \quad (2)$$

$$k_0 = \frac{1}{6} \lambda_{00} e_0^3 \quad (3)$$

여기서, e_0 는 표면 절리틈새, λ_{00} 는 불연속면의 평균빈도(average discontinuity frequency), k_0 는 지표면에서나 연직응력이 0인

암반절리에 대한 투수계수이고, A와 B는 상수들이다.

Snow의 현장 투수시험 결과들은 8개의 다른 압 형태를 포함하고 있다. 그는 절리틈새의 변화와 투수계수의 변화는 다른 압 형태에도 불구하고 같은 경향을 갖는다는 것을 알아내었다. 이 결과를 그림으로 나타내면 그림 1과 2와 같다. Wei 등은 이 그림의 곡선식을 식 1과 식

2의 형태를 가지는 다음과 같은 식을 구하였다.

$$\frac{e}{e_0} = 1 - \frac{Z}{58.0 + 1.02Z} \quad (4)$$

$$\frac{k}{k_0} = \left(1 - \frac{Z}{58.0 + 1.02Z}\right)^3 \quad (5)$$

여기서, 심도(Z)의 단위는 m이다.




그림 1. 깊이에 따른 절리틈새의 변화




그림 2. 깊이에 따른 투수계수의 변화

그러나 위의 공식들을 실제 현장에 적용하기 위해서는 초기의 절리틈새(e_0)와 투수계수(k_0)를 결정하는 것이 필요하다. 표면의 절리틈새나, 투수계수를 알기 위해서는 실험을 동반해야 하며, 투수계수나 깊이만의 함수로 보기에 는 우리가 따라 단지 깊이에 따라 polynomial로 줄어든다는 경향만을 알 수 있는 공식으로 볼 수 있다.

3. 인공신경망 이론을 이용한 투수계수 예측법

3.1 인공신경망(Artificial Neural Networks) 이론

최근 인간의 뇌가 대량의 복잡한 정보를 효율적으로 병렬처리 할 수 있을 뿐만 아니라 학습능력이 있다는 사실에 근거하여 문제 해결에 필요한 규칙의 개발이 필요 없는 새로운 계산 방법으로 인공신경망이 제안되었으며 여러 분야에서 성공적으로 응용되고 있다. 지금까지 알려진 바로는 인간의 두뇌는 $10^{10} \sim 10^{11}$ 개의 뉴런(neuron)으로 구성되어 있으며, 이러한 뉴런의 구조로부터 많은 수의 인공 뉴런으로 구성

된 인공신경망은 그림 3과 같이 한쪽 방향만의 신호 채널을 통하여 서로 연결된 처리기(processing element, PE)들이 병렬, 분산 정보처리를 할 수 있도록 모델링한 것이다. 그림 3에서 보듯이 인공신경망은 정보가 들어오는 입력층(input layer), 입력이 들어가는 뉴런에 미치는 영향의 크기를 조절해 주는 가중치(weight)와 이들 입력과 가중치로 들어온 정보를 결합하여 주는 결합 함수(combining function), 이 결합 함수로부터 나온 결과를 변환하여, 출력값을 결정하게 되는 전이 함수(transfer function) 등으로 구성되어 있다. 이 전이 함수는 다음 그림 4에 수록한 것과 같이 계단 함수(step func-

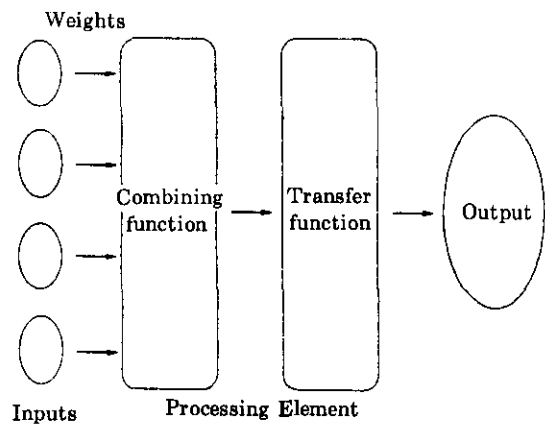


그림 3. 인공신경망의 모델




그림 4. 전이함수의 종류

tion), 임계논리 함수(threshold logic function), 시그모이드 함수(sigmoid function) 등 3종류의 비선형 함수를 많이 사용하고 있다.

이러한 인공 신경망은 학습과정(learning phase)과 회상과정(recall phase)의 두 가지 상태로 작동한다. 학습과정은 상호 연관된 입력과 출력 형태를 인공신경망이 인식하도록 뉴런사이의 연결강도를 조정함으로써 정보를 기억시키는 과정을 말하며, 회상과정은 학습과정이 끝난 상태에서 주어진 입력에 대해 계산된 값을 출력시키는 과정이다. 인공 신경망의 학습은 모든 뉴런의 상태값과 연결선의 연결도로

부터 자신에게 전달되는 자극의 합을 구한 다음 자신의 상태값을 계산함으로써 학습과정을 실시하고 회상과정에서는 단 한번의 계산으로 출력 뉴런의 값이 결정된다.

이와 같이 인공 신경망은 임의의 입력 N차원 공간을 출력 M차원 공간으로 mapping하는 것으로 생각할 수 있으며, 입력 및 출력 공간과 mapping 특성에 따라 연상기억, 변환, 분류, 인식, 최적화 등의 기능을 수행할 수 있다. 이러한 mapping은 어떻게 뉴런들 사이의 연결강도를 조정할 것인가를 결정하는 학습규칙(learning rule)에 따라 결정된다. 학습규칙은 주어

진 입력에 대하여 원하는 출력을 주입시키는 지도학습(supervised learning)과 원하는 출력 없이 학습을 실시하는 자율학습(unsupervised learning)으로 분류될 수 있다(Lippman, R. P, 1987).

입력층과 출력층 사이에 은닉층(hidden layer)이 존재한다면, 원래의 입력층은 확대되어지며, 은닉층에서 입력패턴의 재코드화가 이루어져 입력으로부터 요구되어지는 출력의 대응을 돕게된다. 즉 입력층으로부터 더 많은 처리기를 갖는 은닉층으로의 적절한 연결이 있으면 항상 이 은닉층을 통해 입력에서 출력으로의 어떤 대응을 수행하는 표현(representation)을 찾을 수 있게 되는 것이다(Rumelhart, D. E. etc, 1986). 이러한 다층 퍼셉트론(multi-layer perceptron)의 학습은 지도학습의 하나인 오차역전파(error back propagation: EBP) 알고리즘에 의해 수행되어지는데, 이 알고리즘은 신경망에서 구해진 실제 출력값(actual output)과 구하고자 하는 목표값(desired output) 간의 오차에 대한 평균제곱의 총합을 최소로 하도록 연결강도를 조정하는 델타규칙(delta rule)에 따른 것이다(Lippman, R. P, 1987; Wasserman, P. D., 1989).

EBP 알고리즘의 델타규칙의 적용을 위해서는 연결강도공간(weight space)에서 오차를 점진적으로 탐색해 나가는 점진적 기울기 감소(gradient descending search) 방법을 사용한다. 즉 델타규칙에 의해 연결강도의 변화는 연결강도 공간상에 주어지는 오차의 제곱의 높이로 하는 곡면에 대하여 기울기가 감소하게 되며, 이 오차의 제곱이 가장 많이 감소하는 방향으로 변화하게 되는 것이다. 이는 전향적(forward) 방향(입력층에서 출력층)으로 진행하며 주어진 입력 데이터에 대한 실제 출력값을 계산하고, 이에 대응하는 목표 출력값과의 오차를 하위층에 후향적(backward)으로 전달하면서 일률적으로 연결강도를 조정해 나가는 과정을 반복적으로 적용함으로써 신경망 전체를 학습시키는 알고리즘이다(Pao, Y. H., 1988).

이러한 EBP 학습 알고리즘은 몇 가지 단점을 가지고 있는데, 첫번째 문제점으로는 학습이 전역적 최소치(global minimum)가 아닌 국부 최소치(local minimum)에 빠질 가능성이 있다는 점이다. 즉 오차함수는 연결강도가 만든 다차원 공간상에서 매우 복잡한 형태를 갖게 되며, 경우에 따라 오차가 0이 되는 한 개의 골짜기 이외에 몇 개의 골짜기가 있을 가능성이 있다. 또한 기울기 감소 방법은 반드시 가장 낮은 골짜기를 목표로 하는 것이 아니라 지금 있는 점에서 보아 가장 급경사면을 따라 내려가는 것이므로 오차가 0이 아닌 지역최소점에 머무를 가능성이 높다(Pao, Y. H., 1988). 두번째 문제점은 EBP 학습 알고리즘이 포화영역에서는 잘 동작하지 않는다는 점이다. 이러한 단점을 보완하기 위하여 입력자료의 학습시 자료 전체에 대하여 일괄 수정을 가하며, 은닉층의 PE 개수를 증가시키거나, 학습율을 작게 하며, 연결강도의 초기치를 여러 가지로 랜덤하게 주어 학습회수를 늘리는 등의 방법을 사용한다. 인공 신경망 이론의 구체적 이론 및 수치계산 방법은 이정학 등(1994)의 논문에서 이미 수록하였으며 이를 참조하면 될 것이다.

3.2 투수계수 예측을 위한 신경망 모델

본 논문에서 사용한 신경망 모델은 입력층, 2개의 은닉층과 출력층을 갖는 4개의 층으로 이루어져 있으며, 각 층의 PE의 개수는 자유롭게 결정할 수 있도록 되어있다. 또한 입력 자료의 적절한 학습효과를 결정할 수 있도록 각층의 학습률 η 와 모멘텀 항 α 를 입력할 수 있도록 모델링한 것이다(이정학 등, 1994).

암반의 투수계수 예측을 위한 EBP 알고리즘의 적용성을 검토하기 위하여 현장 투수 시험으로부터 나온 결과를 이용하였다. 이러한 투수계수에 영향을 미치는 가능한 인자로는 투수 시험을 한 심도, RQD, 절리간격, 절리상태 등이 있다. 이를 다층 퍼셉트론으로 나타내면 그림 5와 같다.




그림 5. 투수계수 예측을 위한 신경망 모델

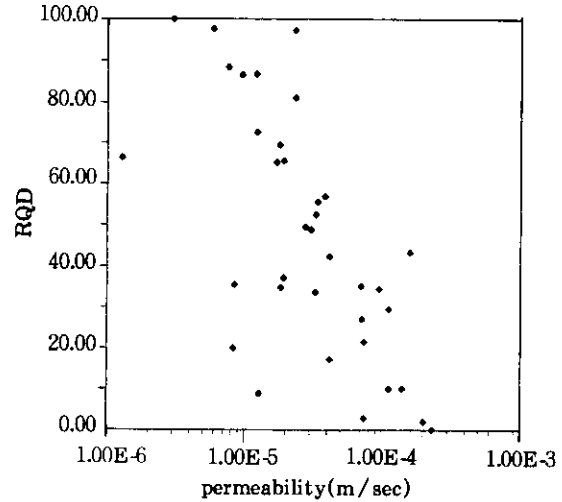
그림 5에서와 같이 입력층(물성치: 깊이, 절리간격, 절리상태, RQD 등)과 출력층(투수계수) 사이에 은닉층(Hidden Layer)이 존재함으로써 원래의 입력층은 확대되어지며, 은닉층에서 입력패턴의 재코드화가 이루어져 입력으로부터 요구되어지는 출력의 대응을 돕게된다.

4. 예제해석

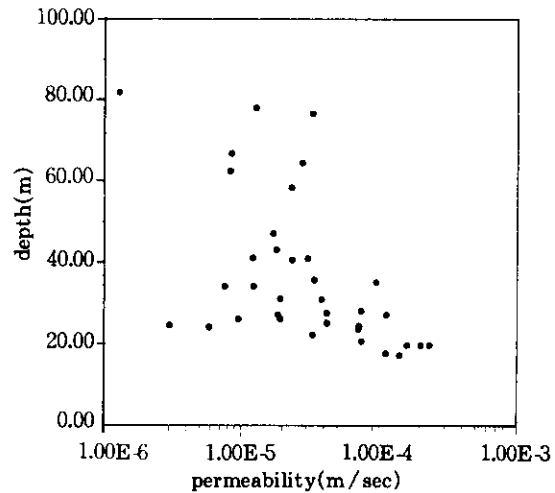
4.1 해석 방법

본 논문에서 사용한 투수계수와 인자에 대한 자료는 36개 세트로서 서울-부산간 경부고속전철 제00공구 구간에서 실시된 현장투수시험 결과들로부터 선별한 자료이며(한국철도기술협력회, 1993), 이를 도표로 나타내면 표 1과 같다. 그리고 이 자료들 중 절리간격과 절리상태는 RMR 분류법(Bieniawski, 1974)의 수치로 나타내어져 있어 실제 설계목적으로 행하는 RMR 수치를 차후 예측에도 이용할 수 있도록

하였다. 표 1에 실린 자료중 투수계수와 RQD의 상관관계를 그림 6(a), 투수계수와 심도의 상관관계를 그림 6(b)에 나타내었다.



(a) 투수계수와 RQD와의 상관관계



(b) 투수계수와 심도와의 상관관계

그림 6. 투수계수-RQD, 심도의 상관관계

그림 6을 참조할 때 투수계수와 RQD, 투수계수와 심도와의 관계는 각각이 약간의 경향을 가지고는 있으나 한 인자만을 가지고는 투수계수를 예측하기에는 범위의 폭이 너무 넓어 정

표 1. 투수계수와 지반물성치의 자료

번호	깊이 (m)	RQD (%)	절리 간격*	절리 상태*	투수계수 (m/s)
1	24.0	97.63	27	25	5.87E-06
2	24.5	100	21	23	3.03E-06
3	27.0	10	4	10	1.13E-04
4	25.0	17.17	7	11	4.17E-05
5	24.3	27	7	2	7.13E-05
6	19.5	43.3	15	12	1.60E-04
7	17.5	29.4	5	6	1.12E-04
8	28	21.5	5	2	7.40E-05
9	35.6	55.47	10	12	3.37E-05
10	40.85	48.7	9	5	3.03E-05
11	22.1	33.53	4	10	3.28E-05
12	34	72.5	10	20	1.23E-05
13	26	65.44	10	20	1.91E-05
14	34	88.38	10	25	7.59E-06
15	26	86.5	10	25	9.53E-06
16	27	34.63	8	10	1.84E-05
17	62.5	19.9	10	6	8.31E-06
18	78	8.73	5	8	1.28E-05
19	66.8	35.3	10	12	8.48E-06
20	81.9	66.25	20	20	1.29E-06
21	76.5	52.44	8	10	3.29E-05
22	64.5	49.37	5	12	2.76E-05
23	58.5	97.24	10	15	2.31E-05
24	35	34.3	10	6	9.52E-05
25	43	69.35	10	20	1.79E-05
26	40.5	80.95	10	20	2.33E-05
27	41	86.63	12	20	1.21E-05
28	47	65.1	8	20	1.70E-05
29	31	37.05	11	7	1.92E-05
30	30.85	56.81	11	8	3.82E-05
31	23.5	35	5	16	7.04E-05
32	19.5	2	5	4	2.02E-04
33	19.5	0	5	3	2.33E-04
34	20.5	2.75	5	5	7.43E-05
35	17	10	5	5	1.41E-04
36	27.5	42.2	8	11	4.15E-05

*RMR 분류법의 수치를 사용한 값

확한 예측이 불가능함을 알 수 있다. 이에 보다 정확한 투수계수를 예측하기 위해서는 투수계수와 관련이 있는 가능한 모든 인자를 이용하는게 필요하며, 여기에 적절한 방법이 인공신경망이라 할 수 있겠다. 표 1에 실린 자료를 투수계수 산정을 위한 자료로 모델링하였으며, RQD와 절리간격은 상관성이 있다고 보고 (Priest, 1993)가 되어있으므로 다음과 같이 5가지 Case로 나누어 예제해석을 실시하였고, 그 결과를 비교 검토함으로써 최적의 예측에 필요한 인자를 제시하고자 하였다.

- ▶ Case 1 : 심도, RQD로부터 투수계수 예측
- ▶ Case 2 : RQD, 절리상태로부터 투수계수 예측
- ▶ Case 3 : 심도, RQD, 절리상태로부터 투수계수 예측
- ▶ Case 4 : 심도, 절리간격, 절리상태로부터 투수계수 예측
- ▶ Case 5 : 심도, RQD, 절리간격, 절리상태로부터 투수계수 예측

본 예제해석에서는 학습을 시키기 위한 자료와 학습의 타당성 검토를 위한 자료를 구성하기 위해서 자료번호가 홀수인 경우(18개)와 짝수인 경우(18개)로 나누어 교대로 학습 및 검토를 실시하였다.

주어진 입력 자료들에 대한 EBP 학습 알고리즘의 적용을 위해서는 먼저 은닉층 PE의 수, 연결강도의 초기치, 학습률, 모멘텀 항등의 변수값들을 결정하여야 하며, 이들 중 학습률과 모멘텀 항은 대개의 경우 사용하는 적정치가 있으나, 그 외의 것들은 시행착오적 방법으로 구하여야 한다.

4.2 예제해석 결과 및 검토

EBP 학습 알고리즘의 적용을 위하여 여러 번의 반복을 통하여 구해진 변수 값들과 다른 사항을 함께 정리하면 표 2와 같다.

표 2에서 나타낸 변수들의 값으로 구성된 신경망으로부터 각 Case별로 예제해석을 통한 학습에 대한 평균오차는 그림 7과 같다.

표 2. Case별 변수값

구분	Case 1	Case 2	Case 3	Case 4	Case 5
입력인자 갯수	2개	2개	3개	3개	4개
첫번째 은닉층 PE의 수*	24	18	19	19	26
두번째 은닉층 PE의 수*	12	10	11	9	11
출력인자 갯수	1개	1개	1개	1개	1개
신경회로망 구성	2-24-12-1	2-18-10-1	3-19-11-1	3-19-9-1	4-26-11-1
연결강도의 초기치	-1.0~1.0 사이의 난수				
학습률*	0.2				
모멘텀 항*	0.9				
학습용 자료 갯수	각 18 set				
검토용 자료 갯수	각 18 set				
입력인자의 항목	심도 RQD	RQD 절리상태	심도 RQD 절리상태	심도 절리간격 절리상태	심도 RQD 절리간격 절리상태

*시행착오적으로 구한 변수값




그림 7. Case별 반복회수에 대한 평균오차

그림 5를 참고하면 Case 3과 Case 5가 학습이 잘됨을 보여주고 있으며, 나머지 Case들은 반복회수가 60,000번 이상 되어야 작은 오차값에 수렴함을 나타내고 있다. 학습자료로 들어간 인자들의 차이로 인하여 Case별로 반복회수에 대한 오차의 형태가 다른 곡선을 나타내며, 인자들이 같아도 은닉층 PE의 수가 다


르면 또한 다른 곡선을 갖는다. 그러나 학습이 잘된다고 해서 좋은 결과를 예측하지는 않으므로 검토를 위한 과정이 필요하다. 이와 같이 학습된 자료로부터 검토과정을 위하여 학습시키지 않은 자료의 투수계수를 Case별로 예측한 결과는 다음 그림 8~그림 12에 수록한 바와 같다. 이 결과는 홀수번째와 짝수번째의 자료를 교대로 학습 및 예측에 사용한 것이다.

이들 그림과 같이 인공신경망 이론을 이용하여 투수계수를 예측한 값과 현장 투수 시험으로부터 산정된 값의 오차에 대한 평균값(average summed square error; ASSE)을 식 6을 이용하여 Case별로 나타내면 표 3과 같다.

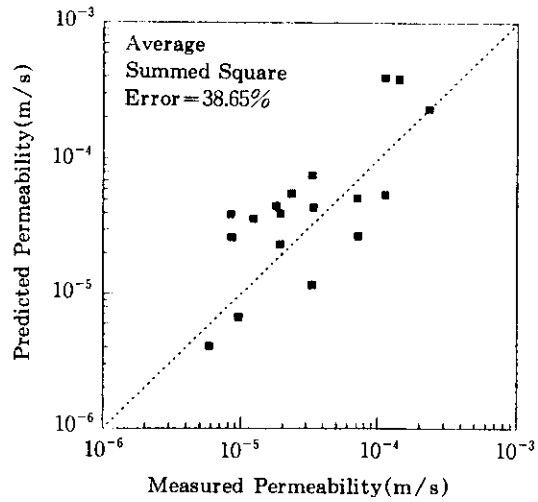
$$ASSE = \sum \frac{(K_m - K_p)^2}{n} \quad (6)$$

여기서 K_m 은 산정값, K_p 은 예측값, n 은 검토 자료의 개수이다.

각 Case별로 결과를 서로 비교해보면, 4가지 인자를 모두 가지는 Case 5가 가장 좋은 예측 결과를 보여주고 있으며, 이 경우를 제외하면 Case 3의 예측 결과가 가장 좋음을 알 수

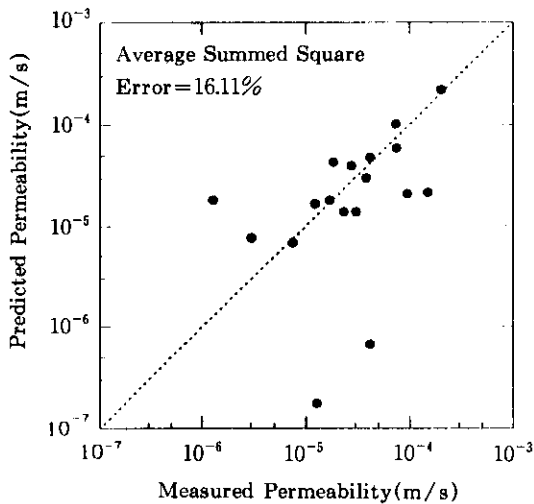


(a) 홀수번째 자료 학습

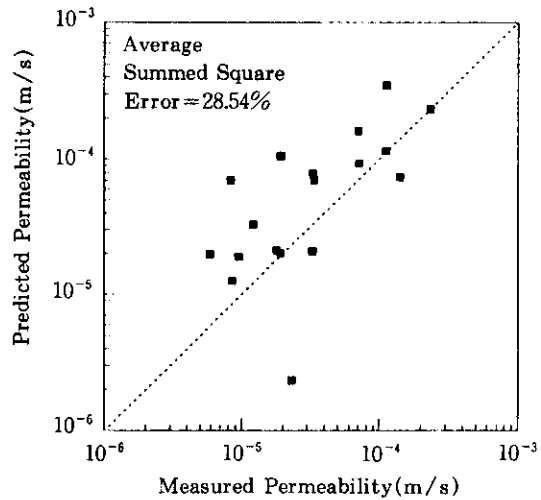


(b) 짝수번째 자료 학습

그림 8. 투수계수 예측값과 산정값에 대한 비교(Case 1) 입력자료 : 심도, RQD




(a) 홀수번째 자료 학습




(b) 짝수번째 자료 학습

그림 9. 투수계수 예측값과 산정값에 대한 비교(Case 2) 입력자료 : RQD, 질리상태

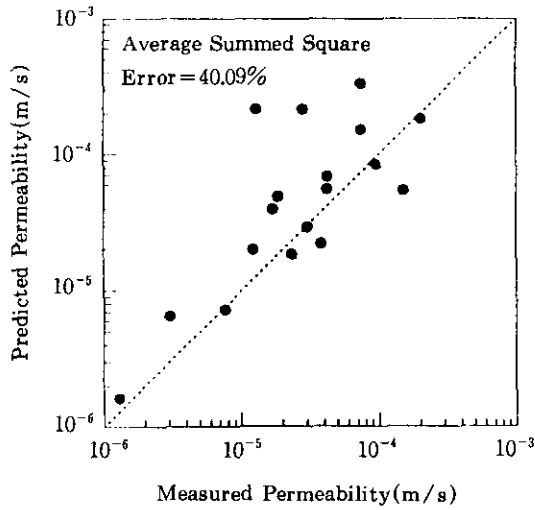


(a) 홀수번째 자료 학습




(b) 짝수번째 자료 학습

그림 10. 투수계수 예측값과 산정값에 대한 비교(Case 3) 입력자료 : 심도, RQD, 절리상태

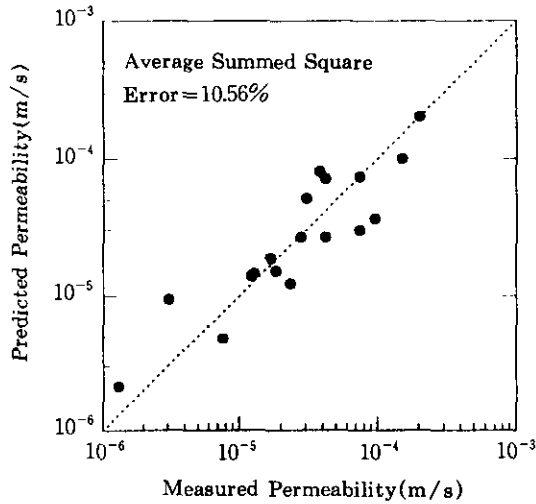


(a) 홀수번째 자료 학습




(b) 짝수번째 자료 학습

그림 11. 투수계수 예측값과 산정값에 대한 비교(Case 4) 입력자료 : 심도, 절리간격, 절리상태



(a) 홀수번째 자료 학습



(b) 짝수번째 자료 학습

그림 12. 투수계수 예측값과 산정값에 대한 비교(Case 5) 입력자료 : 심도, RQD, 절리간격, 절리상태

표 3. Case별 예측값의 산정값에 대한 평균오차

구분	평균오차(ASSE)		인자
	홀수번째 자료 학습	짝수번째 자료 학습	
Case1	12.61 %	38.65 %	심도, RQD
Case2	16.11%	28.54%	RQD, 절리상태
Case3	11.17%	12.65%	심도, RQD, 절리상태
Case4	40.09%	25.35%	심도, 절리간격, 절리상태
Case5	10.56%	11.24%	심도, RQD, 절리간격, 절리상태

있다. RQD는 절리간격을 이미 고려하고 있기 때문에 RMR의 수치로부터 고려된 절리간격은 사실상의 간격이 아니라 rating한 값이므로 RQD보다 적게 영향을 미치는 것으로 판단된다. 이는 입력자료의 갯수가 Case 3과 같이 3개인 Case 4가 Case 3에 비하여 나쁜 결과를 보이고 있음을 볼 때 어느 정도 이러한 이유와 부합한다고 사료된다. Case 1과 Case 2는 두가지 입력인자만으로도 비교적 좋은 결과를 보여

주고 있어 Case 3이나 Case 5와 같은 조건을 만족시키지 못하는 최악의 경우에도 투수계수를 예측함이 가능함을 보여주고 있다.

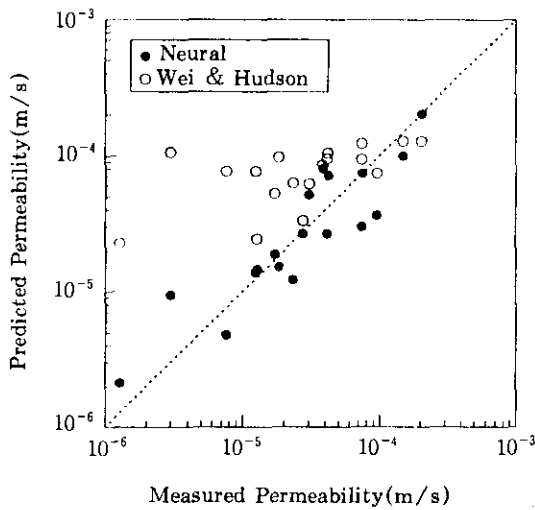
표 3에서 보듯이 평균오차의 범위가 10.56%~40.09%를 나타내고 있으나 기존의 투수계수 예측에 대한 변동계수(COV: coefficient of variation)의 분포가 90%~300%까지 넓게 분포함을 볼 때(Lee et al. 1983; Harr, 1987) 비교적 정확한 예측임을 알 수 있다. 참고로 Wei 등(1995)이 제시한 식 5를 사용하기 위해서는 K_f 를 정해야 하므로 본 논문에서는 표 1의 자료들 중 가장 낮은 심도에서 산정된 투수계수(번호 6)와 그 때의 심도를 식 5에 대입하여 K_f 를 구하였으며, 그 K_f 는 $3.04 \times 10^{-4} \text{m/s}$ 이었다. Wei 등이 제시한 식 5를 사용하여 투수계수를 예측한 결과와 본 예제해석의 Case 5에 대한 결과를 비교해 보면 표 4와 그림 13과 같다.

표 4와 그림 13을 참고하면 본 논문에서 제시한 방법이 투수계수 예측에 대한 더 좋은 결과를 보여주고 있음을 알 수 있다. 이와 같은 결과가 나오게 된 주요한 이유로는, Wei 등이

표 4. Wei 등의 예측값과 Case5의 예측값에 대한 결과 비교


구분		홀수번째 자료	짝수번째 자료
Case5	Average*	1.15	1.33
	COV	58%	54%
Wei & Hudson	Average*	5.43	3.89
	COV	153%	109%

* Average는 $[K(\text{예측값})/K(\text{측정값})]$ 를 산술평균한 값이다.



(a) 짝수번째 자료 학습

제한한 correlation 공식은 모든 인자를 한꺼번에 고려하는 것이 어려운 반면에 본 연구에서 시도한 인공신경망 이론은 예측에 조금이라도 도움을 줄 수 있는 모든 인자의 조합으로 예측 가능성을 탐지하고 이중 최적의 예측을 가능케 하는 인자만을 취사 선택할 수 있는 큰 이점이 있는데 기인한다고 할 수 있다.



(b) 홀수번째 자료 학습

그림 13. 투수계수 예측값과 산정값에 대한 비교 : Case 5와 Wei & Hudson

5. 결론 및 향후의 연구과제

본 논문에서는 인공 신경망 이론을 적용한 암반의 투수계수 예측 방법에 대한 일환으로 오차역전파(EBP) 학습알고리즘을 이용한 투수계수 예측 방법에 대하여 연구를 수행하였으며, 이 방법의 타당성 검토를 위하여 현장투수 시험 결과와 지반불성치(투수 시험을 한 심도, RQD, 절리상태, 절리간격)들에 적용하여 검증 을 실시하였다. 검증결과 평균오차 범위가 작아 비교적 정확한 투수계수 예측방법임을 보여 주었고, 해석사례중 4가지 인자 모두를 사용

한 해석사례가 가장 좋은 결과를 나타내었다. 또한 4가지 인자중 절리간격을 제외한 해석사례가 그 다음으로 좋은 결과를 보여, 본 해석에서는 RMR 분류법에서 제시하는 절리간격에 의한 Rating 값이 투수계수 예측에 신빙성이 적음을 보여주었다. 심도와 RQD, RQD와 절리상태의 두가지 입력인자만을 갖는 해석사례에서도 비교적 좋은 결과를 나타내어 여러 인자에 대한 자료없이 두개의 인자만을 이용하는 최악의 경우에도 투수계수에 대한 예측이 가능함을 보여주었다.

본 연구는 지반공학 분야에 신경 회로망 이

론의 적용 가능성을 살펴보기 위한 시도로서 지반의 투수계수 예측에 적용해 본 결과 그 적용 가능성이 입증되었다. 즉, 본 논문에서 제시한 방법은 지반조사시에 구해질 수 있는 심도, RQD, 절리상태(RMR 수치), 절리간격(RMR 수치) 등의 기본 물성치로부터 암반의 투수계수 예측이 가능하며, 이를 지하공간 등의 설계시에 초기 설계치로 이용이 가능함을 보여 주었다. 다만, 실무적용에 직접 이용할 수 있는 모델 개발을 위하여 더 많은 현장투수시험 자료와 다양한 지반에의 적용에 대한 검토가 차후 연구 과제라 할 수 있겠다.

감사의 글

본 연구는 1996년도 한국과학재단(과제번호 : 961-1201-003-1) 연구비 지원에 의하여 수행되었으므로 이에 감사를 표합니다.

참고 문헌

1. 이정학, 이인모(1994), "인공신경망 이론을 이용한 발목의 극한지지력 해석(1)-이론", 한국지반공학회지, 제10권, 제4호.
2. 이정학(1994), A Systematic Evaluation of Pile Bearing Capacity, 박사학위논문, 고려대학교.
3. 재단법인 한국철도기술협회(1993), 서울-부산간 경부고속전철 제00공구 실시설계 지질조사 보고서.
4. Bieniawski, Z. T. (1974), "Geomechanics Classification of Rock Masses and Its Application in Tunnelling", In Advanced in Rock Mechanics 2 (A), 27-32, Washington, D.C.: Nat. Acad. Sci.
5. E. Hoek & E. T. Brown(1980), "Underground Excavations in Rock", the Institution of Mining and Metallurgy.

6. Goh, A. T. C.(1994), "Seismic Liquefaction Potential Assessed by Neural Networks", Journal of Geotechnical Engineering Div., ASCE, Vol. 120, No. 9, pp.1467-1480.
7. Heitfeld, K.-H., Heitfeld, M., "In Situ Permeability Testing of Weathered(Soft) Rocks", Geotechnical Engineering of Hard Soils-Soft Rocks, Anagnostopoulos et al.
8. Lippmann, R. P.(1987), "An Introduction to Computing with Neural Nets", IEEE ASSP MAGAZINE, 4.
9. Makurat A., Barton N., Tunbridge L., Vik G., and Bandis S.(1990), "The measurement of mechanical and hydraulic properties of rock joints at different scales in the Stripa project", Proc. ISRM, Rock Joints (Edited by Loen, Baron and Stephansson), pp. 541-548, Rotterdam, Balkema.
10. Pao, Y. H.(1988), Adaptive Pattern Recognition and Neural Networks, Adisson-Wesley.
11. Priest, S. D.(1993), "Discontinuity Analysis for Rock Engineering", Chapman & Hall.
12. Rumelhart, D. E., McClelland, J. L. & the PDP Research Group(1986), "Parallel Distributed Processing", Exploration in the Microstructure of Cognition, Vol.1, Foundations, MIT Press.
13. Wasserman, P. D.(1989), Neural Computing: Theory and Practice, Van Nostrand Reinhold.
14. Wei, Z. Q., Egger, P., Descoedres, F.(1995), "Permeability Predictions for Jointed Rock Masses", Int. J. Rock Mech. Min. Sci. & Geomech. Abstr. Vol. 32, No. 3, pp.251-261.
15. Wei, Z. Q., Hudson, J. A.(1988), "Permeability of Jointed Rock Masses", Proc., ISRM Symp., Rock Mechanics and Power Plants, Madrid, pp.613-625.

(접수일자 1996. 10. 28)