

미시추 구간의 정량적 지반 등급 분류를 위한 윈도우-쉬프팅 인공 신경망 학습 기법의 개발

신휴성¹, 권영철^{2*}

Development of a window-shifting ANN training method for a quantitative rock classification in unsampled rock zone

Hyu-Soung Shin, Young-Cheul Kwon

Abstract This study proposes a new methodology for quantitative rock classification in unsampled rock zone, which occupies the most of tunnel design area. This methodology is to train an ANN (artificial neural network) by using results from a drilling investigation combined with electric resistivity survey in sampled zone, and then apply the trained ANN to making a prediction of grade of rock classification in unsampled zone. The prediction is made at the center point of a shifting window by using a number of electric resistivity values within the window as input reference information. The ANN training in this study was carried out by the RPROP (Resilient backpropagation) training algorithm and Early-Stopping method for achieving a generalized training. The proposed methodology is then applied to generate a rock grade distribution on a real tunnel site where drilling investigation and resistivity survey were undertaken. The result from the ANN based prediction is compared with one from a conventional kriging method. In the comparison, the proposed ANN method shows a better agreement with the electric resistivity distribution obtained by field survey. And it is also seen that the proposed method produces a more realistic and more understandable rock grade distribution.

Keywords: artificial neural network, the window-shifting ANN training method, drilling investigation, electric resistivity survey, unsampled zone, rock classification

요 지 본 연구에서는 터널 설계구간의 대부분을 차지하는 미시추 구간의 지반 등급 분류를 정량적으로 수행할 수 있는 새로운 접근방법을 제안한다. 본 제안방법은 시추공에서 얻은 직접조사 결과와 시추구간의 전기 비저항 탐사결과를 이용해 인공 신경망을 학습시키고, 학습된 인공 신경망은 미시추 구간의 암반분류 등급을 추론하는데 적용된다. 지반등급 추론은 미시추 구간 영역에서 움직이는 격자형 창(window)의 중심점에서 이루어지며 창내 귀속된 전기 비저항들은 추론을 위한 참고자료로 사용된다. 인공 신경망 학습은 최신 RPROP(Resilient backpropagation) 인공 신경망 학습 알고리즘과 early-stopping 기법을 이용하여 수행되었다. 본 연구에서는 실제 시추조사가 이루어진 터널현장에 제안기법을 적용하여 미시추 구간의 지반 등급을 추론하였으며, 전통적인 지구통계학적 크리깅(kriging) 기법에 의한 결과와도 상호 비교하였다. 결과적으로 본 연구를 통해 학습된 인공 신경망은 전통 크리깅 방법에 비해 매우 구체적이고 현실적인 예측결과를 제공하였다. 또한, 인공 신경망 추론으로부터 얻어진 터널 중단 방향의 RMR과 Q-값의 분포에서는 전기 비저항 탐사로부터 추정된 취약지반 구간의 위치와 잘 일치하였으며, 두 값 상호간의 관계도 선행 연구 결과와 부합하였다.

주요어: 인공신경망, 윈도우 쉬프팅 인공신경망 훈련기법, 시추조사법, 전기비저항탐사, 미시추구간, 암반분류

1. 서 론

터널을 포함한 지반구조물을 시공하기 위해서는 계획 단계에서 일정간격으로 지반 조사를 실시하고 이 결과를 바탕으로 지반 특성을 파악하며 이를 설계에 반영한다. 특히 터널과 같은 지하 공간 개발을 위해서는 지반 등급 분류가 구간별 지보 패턴을 결정짓는 중요한 근거

자료로 활용되고 있으므로 지반 정보를 정도 높게 취득하는 것이 공사비 손실을 최소화하고 시공 중 혹은 공용 중 구조물 안전성을 확보하기 위해 중요하다

터널 공사를 위해 요구되는 지반 정보는 일반적으로 시추 조사와 물리 탐사를 통해 이루어진다. 시추 조사는 시추장비를 이용하여 해당 지점에서 직접 시료를 채취하고 관찰하며, 필요에 따라서는 실내에서 다양한 물리적 혹은 역학적 시험을 수행하여 정량적이고 신뢰성 높은 자료를 얻을 수 있는 장점이 있다. 반면에 시추 조사는 경제성과 시간적인 제약에 의해 극히 제한적인 범위

¹정회원, 한국건설기술연구원 지반연구실 선임연구원

²정회원, 한국건설기술연구원 지반연구실 선임연구원

* 교신저자: 권영철 (E-mail: kyc@kict.re.kr)

에서만 실시되며, 산악터널에서 요구되는 대심도 시추에서는 장비의 이동 곤란 등 시추 작업 자체가 불가능한 경우도 빈번히 발생한다. 따라서 이에 대한 보완적 방법으로 다양한 물리 탐사 기법이 이용되고 있다. 이 방법은 탄성파나 전기 비저항 등과 같은 물리량을 상호 비교하여 지반의 상대적인 양호/불량 정도를 파악할 수 있는 정성적이고 간접적인 지반조사법이다. 하지만 물리 탐사법은 조사 영역을 모두 표현할 수 있는 연속 값을 제공하며 시추 조사에 비해 조사범위가 매우 넓다는 장점이 있다. 사실상 건설 공사의 대부분을 차지하는 미시추 구간에서는 이러한 물리 탐사 결과 이외에 직접적인 지반 정보를 얻는 것이 상당히 어렵다. 현재, 물리 탐사 결과는 전문가나 유사 사례에서 얻은 경험을 통해 분석되고 사용되는 것이 일반적이기 때문에 자료분석 결과에 대한 많은 불확실성(uncertainty)을 내포하고 있으며 객관성 확보에 어려움이 있다. 결국 터널 미시추 구간의 불확실성은 굴착 및 지보 설계 등 공사비뿐만 아니라 시공 중 안전 사고 발생에도 큰 영향을 미치므로, 조사 단계에서 구한 모든 자료를 활용하여 미시추 구간의 지반 등급을 최대한 정확하고 보다 높은 신뢰 수준으로 예측하는 것이 필요하다.

현재 시행되고 방법 중, 복수의 시추공 자료를 이용하여 시추가 실시되지 않은 시추공 간의 정보를 내삽법 혹은 외삽법을 통해 단순 추정해 사용하는 방법이 가장 쉽고 간편한 방법이다. 이러한 방법은 자료 간의 상관관계를 무시하기 때문에 높은 정도의 예측을 하기는 어렵다는 점이 문제점으로 지적되고 있다(유광호, 1995a). 지반공학에서는 특정 지점의 지반 특성치가 인접한 주변 지반의 특성과 매우 밀접한 상호관계를 갖고 있으며, 따라서 이러한 상호관계를 고려하여 해당 지점의 특성치를 유추하고자 하는 지구 통계학적(geostatistics) 기법이 널리 사용되고 있다. 지구통계학의 가장 대표적인 방법은 크리깅(kriging)으로서, 이는 이미 알고 있는 주위 값들의 가중 선형조합으로 관심있는 지점의 특성값을 예측하는 방법이다. 예측상에서 크게 영향을 미치게 되는 특성값들간의 가중치는 대개 예측오차를 최소화 하면서 추정식이 편향되지 않도록 결정한다(최종근, 2002; Journel, 1986). 지구 통계학적 기법은 전통적인 적용 분야인 광산학과 지질학뿐만 아니라 지반 공학이나(Baecher, 1983; Soulie, 1984)나 지구 과학(Webster, 1984) 등에

폭넓게 사용되고 있다. 유광호(1995b)는 지시 크리깅 기법과 최적 분류를 위한 선택 기준으로 오차에 대응하는 비용(the cost of errors)을 사용하여 암반상태의 양호/불량 정도를 이분적으로 분류하고자 하는 연구를 수행하였으며, 다분적인 지반 등급까지 분류할 수 있는 방안에 대해서도 연구를 수행하였다. 또한, You and Lee(2006)는 본선에서 이격된 물리 탐사 자료 및 시추 자료를 최대한 활용해 2차원 다분적 지시 크리깅을 확장한 3차원 다분적 크리깅(three dimensional multiple indicator Kriging, 3D-MI kriging) 기법을 제안하였다. Öztürk and Nasuf (2002)는 터널 굴진을 위하여 시추구간과 미시추 구간에서 압축강도, RQD, 슈미트해머 강도, 순수 절삭비 등 암반의 역학적 특성을 파악하기 위해 크리깅 기법을 도입하였다. 최근들어 크리깅 기법은 터널을 포함한 지반 공학적 문제에 관련된 위험도 관리와 이에 따른 의사결정 등에 까지 그 적용 범위가 확장되고 있는 추세이다 (Sturk, et al., 1996; Ohtsu, et al., 2006).

그러나 지반등급 평가에 널리 사용되고 있는 지시 크리깅 방법은 시추공 조사에 의해 직접 조사된 정보만을 이용해 미시추 구간의 지반 특성을 통계적으로 유추하는 방법이므로, 물리 탐사 정보와 직접적으로 연계하여 미시추 구간의 지반 특성을 평가하기 어려운 단점이 있다. 따라서, 본 연구에서는 RMR, Q-값 및 전기 비저항 자료가 모두 유효한 지점에서 각 자료 상호 간의 상관성을 찾기 위해 인공 신경망 기법에 기반한 새로운 접근 방법을 제시하고자 한다. 결과적으로 시추구간의 지반 조사 및 물리 탐사 자료로 학습된 인공 신경망을 이용하고 미시추 구간의 전기 비저항 값을 참고 자료로 사용하여 터널 전 구간에 대한 정량적이고 연속적인 RMR 값과 Q-값 분포를 유추해 낸다. 본 논문에서는 인공 신경망에 대한 간단한 설명과 더불어 새롭게 제안된 인공 신경망 학습 자료의 준비 과정이 상세히 기술되며, 인공 신경망 학습에 사용된 최신 학습 알고리즘에 대해서도 언급된다. 마지막으로 본 연구를 통해 개발된 인공 신경망 기반 학습 기법에 대한 이해도를 높이기 위해 시추 조사와 전기 비저항 탐사가 이루어진 터널 현장에 개발 기법을 적용해 보고, 전통적인 크리깅기법과 상호 비교하며 제안된 기법의 특성과 적용 결과를 고찰한다.

2. 학습 자료의 준비를 위한 윈도우-쉬프팅 (WINDOW-SHIFTING) 기법

인공 신경망은 인간의 뇌 작용과 매우 유사한 작용을 한다. 인간의 뇌는 원인과 이 원인(cause)에 의해 나타나는 효과(effect)를 관찰하게 된다. 인간은 특정한 문제에 대한 원인과 효과를 학습하게 되면 유사한 문제에 대한 예측이 가능하게 된다. 인공 신경망은 인간의 뇌의 작용과 동일하게 주어진 문제에 대한 규칙(pattern)을 추론할 수 있도록 하는 훈련을 거쳐 유사한 문제에 대한 결과를 예측하도록 하는 해석기법이다. 인공 신경망은 크게 인간의 뇌의 기능을 하는 신경 세포인 뉴런(neuron)과 뉴런을 연결하는 수상돌기(dendrite), 활성화 기능의 축생(axon), 신호강도를 조절하는 시냅스(synapse)로 구성된다. 각각의 인공 신경 단위들은 입력값에 반응하여 결과를 연결된 다른 신경 단위에 전달해 주는 단순한 반응 메커니즘을 가지나, 이러한 단순한 기능을 수행하는 신경 단위들은 무수한 신경 단위들의 복잡한 상호 병렬 연결 조직을 통해 복잡한 현상 및 자료를 학습하여 규칙을 파악하고 추후 유사한 현상을 파악하여 결론을 추론할 수 있게 되는 것이다. 따라서 인공 신경망은 인간의 뇌처럼 주어진 자료를 통해 학습을 수행할 수 있으며, 학습을 통해 파악된 규칙을 기억하고 추후 학습에 사용되지 않은 유사 현상에 대해 예상결과를 추론할 수 있다 (Rumelhart and McClelland, 1896; Pao, 1989). 인공 신경망 기법의 응용에서는 노이즈를 포함한 규칙을 담고 있는 학습 자료의 준비가 중요하며, 편협되지 않고 일반화된 학습을 수행하기 위한 적절한 학습 알고리즘 및 학습 환경이 조성되어야 한다.

이러한 배경으로 지반 공학 문제의 해결을 위한 인공 신경망 적용에 있어서는 인공 신경망의 특성을 잘 이해해야 될 뿐만 아니라, 해결하고자 하는 문제를 잘 표현할 수 있는 문제의 원인과 결과에 해당하는 인자들을 효율적으로 설계하고 이에 대응한 학습 자료의 준비가 체계적으로 이루어져야 한다. 따라서, 본 연구에서 다루고 있는 터널 미시추 구간에서의 지반 등급 분포도 작성을 위해서는 먼저 실질적인 문제 파악과 준비 가능한 자료의 종류 및 수준 파악이 선행되어야 한다. 일반적으로 터널 패턴 설계를 위한 터널 공사 구간의 지반 등급 분류를 위해서는 시추조사 및 다양한 물리 탐사 조사법

을 병행하게 되며 미시추 구간의 정량적인 지반 등급 분류값 예측을 위하여 두 값 사이의 상관성을 기술자들의 직관에 의존해 평가한다. 하지만 그림 1과 같이 시추 조사와 물리 탐사 결과가 서로 일대일 대응되지 않기 때문에 시추 조사 결과와 물리 탐사 결과간 상관 관계를 수학적으로 표현하기는 불가능하다. 따라서 시추 조사가 수행되지 않은 물리 탐사 구간에 대한 정량적인 지반 등급 분류는 매우 어려운 일이다. 하지만 제한된 시추 조사 자료를 기반으로 미시추 구간에서 유효한 풍부한 물리 탐사 결과의 분포 경향을 종합적으로 고려하여 지반 등급 분포를 판단할 필요가 있다.

본 연구에서는 시추공의 시추 코어를 통해 평가된 각 시추공 심도별 지반 등급 분류값(RMR과 Q-값)과 전기 비저항 탐사를 통해 얻은 각 시추공 심도별 전기 비저항 값을 이용하여 학습자료를 작성한다. 또한 각 지점의 지반 등급 분류값은 인접지점의 지반 등급 분류값과 밀접한 연관성이 있다는 것에 착안하여 그림 2에서와 같이 자료를 얻고자 하는 지점(R5)을 중심으로 주변 측정(R1~R4, R6~R9)에서의 전기 비저항 값을 참고값(reference values)으로 활용한다. 따라서 R5지점의 전기 비저항과 지반등급간 단순한 일대일 상관관계로는 정의 불가능한 상황을 주변 측정에서의 다수의 전기 비저항을 함께 고려해 줌으로써 인위적으로 복잡도를 높여줌으로써 보다 고차원의 상관관계로 정의 가능토록 해준다. 이와 같이 확장된 전기 비저항 자료로 인공 신경망의 입력(원인)항을




그림 1. 지반등급 분류에서 시추공과 물리 탐사의 분포

구성하여 인공 신경망의 학습자료를 준비한다. 이러한 학습자료는 최신 인공 신경망 학습기법으로복잡한 고차원의 상관관계 규칙(pattern)을 인지해 낸다. 학습이 완료된 인공 신경망은 미시추 구간에서 전기 비저항의 조합을 참고자료로 하여 동일 지점에서의 RMR과 Q-값을 예측한다.

본 연구에서 제안한 윈도우-쉬프팅 학습자료 생성기법으로 학습자료를 작성하기 위해서 격자형 윈도우(matrix shape window)를 생성한다. 생성된 윈도우의 중심점은 그림 2에서 나타난 시추공 구간의 측정점(measuring point)간을 이동하며, 윈도우의 격자점들(R1~R9)에서의 전기 비저항과, R5 측정점에서의 지반 등급 분류값을 취하여 인공 신경망의 학습자료를 구성한다. 본 격자형 윈도우를 이용한 학습 및 추론기법의 핵심은 중앙점 주위의 전기 비저항들이 RMR 및 Q-값과 중앙점의 전기 비저항 사이에 형성되는 상관 관계를 수립하는데 좋은 참고 자료로 사용될 수 있다는 것이다. 학습 자료는 시추 조사가 수행된 구간에서 수집할 수 있으며, 학습된 인공 신경망은 학습 때 적용된 격자형 윈도우를 그림 2의 미시추 구간 예측 영역(predicted domain)상을 이동시키며 윈도우 중심점에서의 RMR과 Q-값을 예측하는데 적용된다. 본 제안 기법에서 만일 3-by-3 격자형 윈도우가 얻고자 하는 자료 패턴을 충분히 인지할 수 없다면 4-by-4

격자형 등, 보다 고차원의 격자를 구성하여 학습 자료의 복잡도를 상향 조정할 수 있다. 또 3차원 지반 조사가 수행된 경우라면 격자형 육면체를 구성하여 격자형 육면체를 3차원적으로 이동시키며 학습 자료를 구성하고 3차원 미시추 영역의 지반 등급을 추론할 수 있을 것이다. 이때 인공 신경망의 학습 알고리즘 등 요구되는 다양한 시스템이 2차원의 경우와 차이가 없으므로, 손쉽게 3차원으로서의 해석 영역을 확장시킬 수 있다.

그림 3은 본 연구에서 사용한 인공 신경망의 모식도를 나타내고 있다. R1~R9로 구성되는 학습 자료를 입력 노드로 설정하였으며, R5 지점에서의 RMR과 Q-값을 출력 노드로 설정하게 된다. R5는 예측하고자 하는 자료 포인트이며 다른 포인트(R1~R4, R6~R9)는 참고 자료가 된다. 그리고 R5에서의 지중 응력의 크기를 나타내는 깊이 D 역시 입력치의 하나로 사용된다. 결과적으로 그림 3과 같이 1개의 자료 점에서의 전기 비저항(R5)과 8개의 참고점에서의 전기 비저항(R1~R4, R6~R9) 그리고 자료점의 심도(D)를 학습자료의 입력 노드(총 10개)로 설정하였고 지반 등급 분류값인 RMR과 Q-값으로 구성된 2개의 출력 노드를 설정하였다. 또한 RMR과 Q-값을 출력층에 함께 고려함으로써 인공 신경망이 준비된 학습 자료를 통해 입력자료에 대한 두 개의 지반 등급 분류값의 상관 관계를 서로 보완해 가며 보다 객관적으로 파악할 수 있도록 하였다. 설정된 입력층과 출력층과 연계하여 2개의 중간 은닉층(15개 1차 은닉 노드와 10개의 2차 은닉 노드)을 설정하였다. 설정된 은

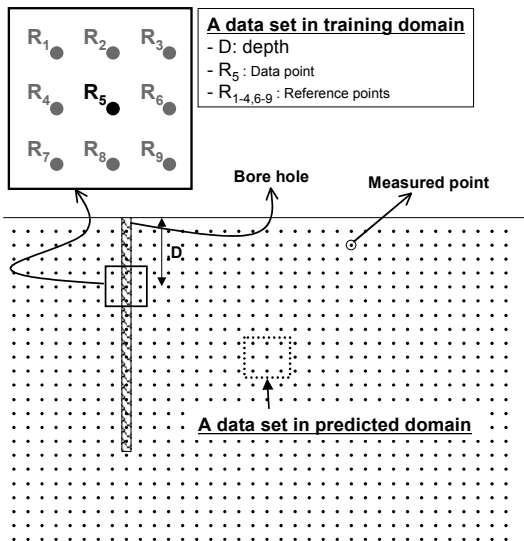


그림 2. 학습 자료 취득을 위한 Window-shifting 기법의 개략도

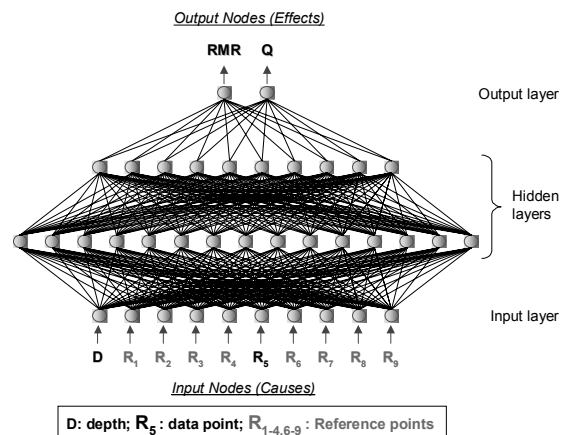


그림 3. 인공 신경망의 모식도

닉층의 구조는 주어진 학습자료에 대한 인공 신경망 구조 관련 매개변수 연구를 통해 결정되었다.

3. 학습 알고리즘

3.1 탄성 역전파(Resilient backpropagation, RPROP) 학습 알고리즘

본 연구에서 준비된 지반 조사 자료를 학습하는데 탄성 역전파(resilient backpropagation, RPROP)라고 불리는 최신 학습 알고리즘을 사용하였다. Riedmiller(1994)에 의해 최초로 제안된 RPROP는 표준 역전파의 틀을 기본으로 국부적 최적화 학습(local adaptive learning scheme) 개념을 채용한 학습 방법이다. RPROP의 기본 원리는 연결 강도의 미소 변화량의 편미분항 크기를 추정하는 것으로 매 학습 반복 단계마다 계산이 되는 연결 강도의 증분은 연결 강도의 증분의 방향을 나타내는 편미분항의 부호만을 고려하여 식 (1)의 Δ_j^i 값에 의해서 결정된다.

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_j^i(t), & \text{if } \frac{\partial E_p}{\partial w_{ij}}(t) > 0 \\ +\Delta_j^i(t), & \text{if } \frac{\partial E_p}{\partial w_{ij}}(t) < 0 \\ 0, & \text{else} \end{cases} \quad (1)$$

여기서, E_p 는 인공신경망 학습에 적용된 오차함수이며, w_{ij} 는 인공신경망의 각 노드간의 관계를 정의하는 연결강도를 의미한다. 이에 대한 자세한 정의와 설명은 참고문헌(Pao, 1989)을 참조할 수 있다.

RPROP의 두 번째 단계는 새로운 Δ_j^i 을 결정하는 것으로 이는 Delta-Bar-Delta(Jacobs, 1988)와 SuperSAB(Tollenaere, 1990)에서 사용된 학습률 결정 방법과 유사하게 각 연결강도에 대한 오차함수의 편미분 값의 부호에 좌우되는 식 (2)와 같은 계산과정에 의해 결정된다. 여기서 $\Delta_j^i(t) = \Delta_0$ 은 학습함수이다.

$$\Delta_j^i(t) = \begin{cases} \lambda^+ \times \Delta_j^i(t-1), & \text{if } \frac{\partial E_p}{\partial w_{ij}}(t) \times \frac{\partial E_p}{\partial w_{ij}}(t-1) > 0 \\ \lambda^- \times \Delta_j^i(t-1), & \text{if } \frac{\partial E_p}{\partial w_{ij}}(t) \times \frac{\partial E_p}{\partial w_{ij}}(t-1) < 0 \\ \Delta_j^i(t-1), & \text{else.} \end{cases} \quad (2)$$

다시 말하자면 적응 규칙(adaptation rule)은 다음과 같이 작용하게 된다. RPROP 학습 알고리즘은 매번 $\partial E_p / \partial w_{ij}$ 부호를 변경한다. 만일 바로 이전 단계에서 사용된 연결 강도의 증분이 너무 커서 오차 함수의 최소점(minima)을 지나쳤다면 Δ_j^i 값을 λ^- 에 의하여 감소시킨다. 통상적으로 감소항 λ^- 는 0.5 정도가 추천되고 있다(Riedmiller, 1994). $\partial E_p / \partial w_{ij}$ 항이 계속 같은 부호를 유지한다면 학습 속도를 가속시키기 위하여 연결 강도의 증분량을 인위적으로 약간 증가시킨다. 반면 부호가 바뀐다면 증가항 λ^+ 를 도입하고 $(\partial E_p / \partial w_{ij})^{t-1} = 0$ 과 같이 연결 강도의 변화를 억제시킨다. 통상적으로 증가항 λ^+ 는 1.2 정도의 값을 사용하고 있다(Riedmiller, 1994).

학습을 위한 매 반복 계산 단계마다 식 (2)에 의해 결정되는 모든 연결 강도는 초기값으로 4에서 시작한다. 이 값은 가중치가 비합리적인 국부 최소값(local minima)에 수렴되어 빠져 나오지 못하는 상황을 방지하기 위하여 연결 강도 증분의 최소값 A_{min} 과 최대값 A_{max} 을 설정하고 계산된 값이 너무 크거나 작지 않도록 의도적으로 조절한다. 본 연구에서는 최소값 A_{min} 은 1.0E-6으로 고정하였으며 초기값 4과 최대값 A_{max} 은 사용자가 결정하는 파라미터가 된다. Riedmiller(1994)은 각각의 값을 0.1과 50.0으로 추천하였다. 또한 본 학습 알고리즘에서 요구하는 학습 상수들에 대한 다양한 매개변수 연구를 통하여 RPROP와 학습 상수들간의 민감도를 고찰한 바(Shin, 2001)있으며, 이를 통해 Riedmiller(1994)가 제안한 학습 상수 값과 유사한 결과를 보였다.

3.2 인공 신경망의 학습

앞서 언급하였듯이 일반화된 학습을 수행하기 위하여 국부 최소점에 포획되는 위험이 적은 최신 학습 알고리즘인 RPROP 학습알고리즘을 적용하였다. 본 연구에 적용된 인공 신경망 모델은 비선형 연상 기억 모델로써 입력층, 2개의 은닉층, 출력층과 같이 총 4개의 층으로 구성된 다층 퍼셉트론이다. 기존 문헌에 보고된 내용을 기반으로 최적의 학습 환경을 조성하고 준비된 학습 자료의 입력값과 출력값은 선형으로 정규화하여 학습에 사용하였다. 또한, 최적의 학습 일반화를 확보하기 위하여 early-stopping기법(Skouras, et al., 1994; Prechelt, 1998)을 적용하였다. 이 기법은 준비된 자료(100%)를 학습 자료(95%)와 검증 자료(5%)로 구분하고 학습 자료를 이

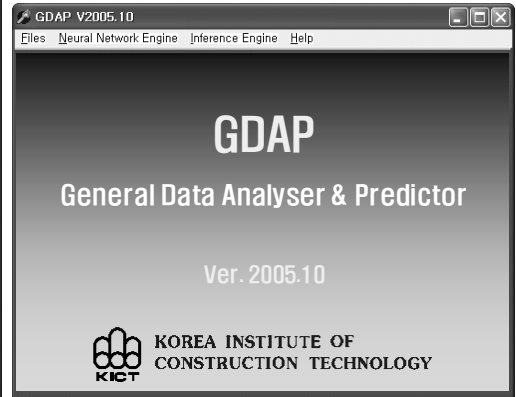
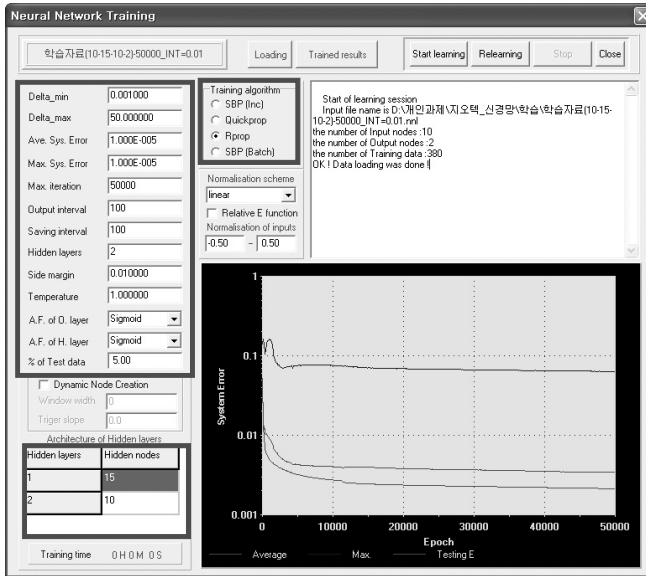


그림 4. 인공 신경망 학습엔진, GDAP

용한 반복 학습 수행 동안 지속적으로 검증 자료에 대한 오차율을 모니터링하면서 검증 자료에 대한 오차율이 상승하기 시작하는 시점에서 학습을 종료시키는 일반화 학습 방법이다. 학습을 위해 각 층별로 최적의 노드수를 설정하고, 설계 목적상 RMR값에 대한 예측값과 실측값의 제곱 오차로 표현되는 목적 함수의 기울기를 구하여 반복 학습에 의한 매개변수를 최소화한 최적화 해를 도입한다.

본 연구에서는 인공 신경망 학습엔진인 GDAP(Pande and Shin, 2004; Shin, et al., 1994)를 이용하여 학습을 수행하였다. GDAP는 다양한 학습 알고리즘을 주어진 문제에 따라 선택할 수 있으며 그림 4에 나타난 플랫폼과 같이 각 알고리즘에서 요구하는 학습 파라미터를 쉽게 설정하여 학습에 반영할 수 있다. 기타 인공 신경망 구조와 일반화 학습을 위한 다양한 학습 오차 변화 추이를 실시간으로 모니터링하며 학습을 종료하거나 재학습시킬 수 있다.

4. 현장 적용성 검토

4.1 적용 현장 현황

제안된 기법의 현장 적용성 평가를 위하여 실제 터널




그림 5. 적용 대상 터널의 계획도

현장에서 수행된 지반 조사 자료를 활용하였다. 본 터널은 연장 880 m의 산악 도로 터널이며, 그림 5와 같이 3공의 시추 조사를 실시하였다. 하지만 터널의 연장에 비하여 시추 조사의 수가 너무 적어 전체 터널 구간에 대해 합리적으로 RMR과 Q-값을 산정하기 어려운 상황이었다. 따라서 본 연구에서 제안한 기법을 이용하여 현장의 RMR과 Q-값의 분포를 예측하였으며, 결과 고찰을 통해 본 연구에서 제안한 방법의 상대적 타당성과 현장 적용 가능성을 검토하였다.

본 현장에서는 그림 6에 보인 바와 같이, 시추 조사 이외에 터널 라인을 따라 터널 전 구간에 걸쳐 2-D 전기 비저항 탐사가 실시되었다. 그림에서 중앙부에 위치한 시추공은 낮은 비저항을 보인 지역에서부터 높은 전기 비저항을 보인 낮은 지역까지 관통하고 있어 폭 넓은 양질의 인공 신경망 학습 자료를 구성할 수 있을 것으로 판단된다. 터널 갱구부에 위치한 두 개의 시추공도 학습 자료 준비에 활용되었다. 시추공에서 채취한 시료를 이용하여 지반 분류와 실내 실험을 실시하였으며, 시추공의 깊이 방향으로 RMR과 Q-값을 산정하였다. 이때 동일 RMR과 Q-값으로 평가되어 분할된 다수의 구간이 발생한다. 그러나 전기 비저항은 시추공 깊이 방향으로 일정 간격으로 연속적으로 변화한다. 따라서 RMR과 Q-값이 동일한 구간 내에서도 전기 비저항 값은 변화하므로 전기 비저항과 지반 등급 분류는 일대일 대응하지

않는다. 하지만 그림 2에서 보인 전기 비저항 ‘측정점’ 주변의 참고 자료들은 전기 비저항과 지반 등급과의 상관 관계를 가능하게 하고 복잡한 비선형성을 인위적으로 부여해 주는 중요한 역할을 한다. 이러한 비선형 상관 관계는 인공 신경망의 학습을 통해 인지되며, 미시추 구간의 지반등급을 예측하는데 적용된다.

4.2 인공 신경망의 학습

학습자료는 약 380개의 입력과 출력의 조합으로 이루어졌으며 총 자료 중에서 무작위로 추출된 5%의 자료는 학습 과정 중 학습의 타당성을 검증하기 위한 자료로 사용하였다. 따라서 총 자료의 95%만이 실제 학습에 사용되었다. 학습 진행 중 early-stopping 기법을 적용한 결과, 최적의 학습은 약 50,000회 인 것으로 나타났다. 학습된 인공 신경망을 이용하여 전기 비저항 탐사는 실




그림 6. 터널 종단방향의 전기 비저항 분포도

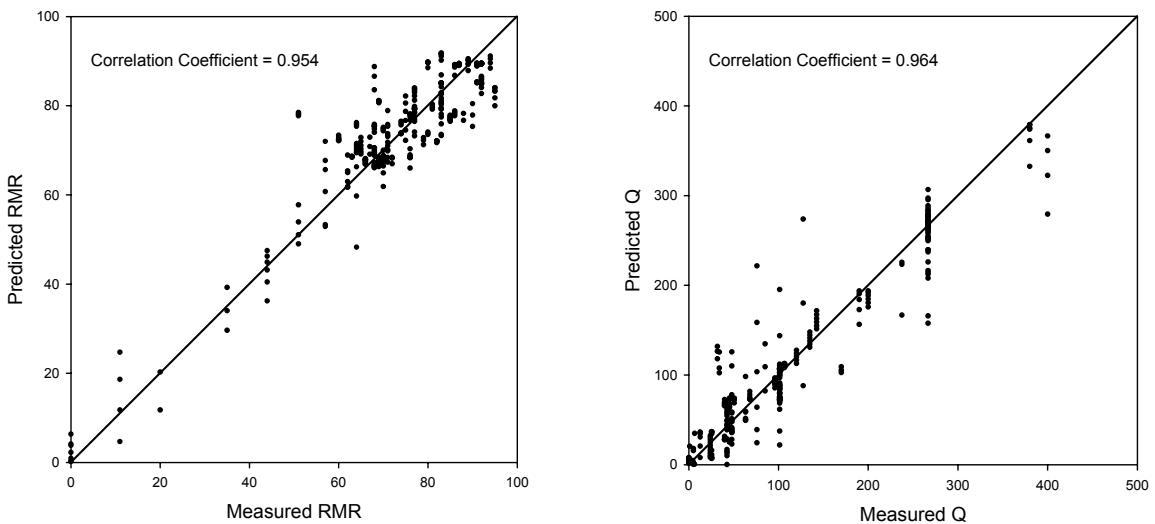


그림 7. RMR과 Q-값에 대한 예측값과 측정값의 비교

시되었으나 시추 조사는 실시되지 않은 미시추 구간의 RMR과 Q-값을 예측하였다. 본 현장에서는 총 35,326 개의 지점에서 RMR과 Q-값의 예측이 수행되었다.

학습 결과를 검증하기 위하여 학습 완료된 인공 신경망을 이용하여 학습에 사용된 학습자료와 학습에서 제외된 5%의 검증자료를 모두 포함한 자료에 대한 재추론을 실시하였다. 따라서 대상 구간 내 모든 자료가 예측에 사용되었다. 그리고 상관 계수는 RMR과 Q-값의 예측치와 측정치를 이용하여 평가하였으며 결과는 그림 7에 정리하였다. RMR과 Q-값의 상관계수는 각각 0.954와 0.964로 매우 높은 상관 계수 값을 보였다. 이러한 결과를 통해 인공 신경망의 학습은 적절히 수행되었으며, 학습의 질 역시 예측 작업을 수행하기에 충분하다고 판단되었다. 그러나 결과 분석시, 본 현장에서는 시추공의 개수가 불충분했으며, 평가된 결과는 매우 복잡한 형태를 가질 수 있다는 점을 고려할 필요가 있다.

4.3 학습된 인공 신경망에 의한 RMR과 Q-값의 예측

학습된 인공 신경망을 사용하여 미시추 구간의 RMR

과 Q-값을 예측하였다. 또한 일반적인 크리깅 기법을 적용하여 시추조사 자료만을 이용한 미시추 구간의 RMR과 Q-값 분포를 예측하였으며, 제안된 기법으로 평가된 결과와 상호 비교하였다.

그림 8은 크리깅을 이용하여 미시추 구간의 RMR 분포를 예측한 결과와 본 연구를 통해 학습된 인공 신경망을 이용하여 예측한 결과를 보이고 있다. 비교를 위하여 그림 6에 나타난 전기 비저항도 함께 도시하였다.

빨간색 영역은 RMR이 100 이상임을 나타내며 파란색 영역은 RMR이 20이하의 값을 보이는 곳을 나타내고 있다. 그림 8을 통해 인공 신경망을 이용한 경우가 크리깅 기법에 비해 보다 현실적인 예측을 하고 있다는 점을 확인할 수 있다. 또한, 인공 신경망에 의한 예측 결과에서는 RMR이 시추공과 상당한 거리가 있는 미시추 구간에서도 많은 변화를 보이고 있으나, 크리깅을 이용하여 예측한 RMR 분포는 전기 비저항 값을 직접 사용하지 못하기 때문에 시추공 사이의 미시추 구간에서는 매우 단순한 변화를 보이고 있었다. 그렇지만 이러한 결과만을 근거로 하여 인공 신경망에 의한 RMR 분포의 예측이 매우 만족스러운 결과를 얻을 수 있다는 결론을

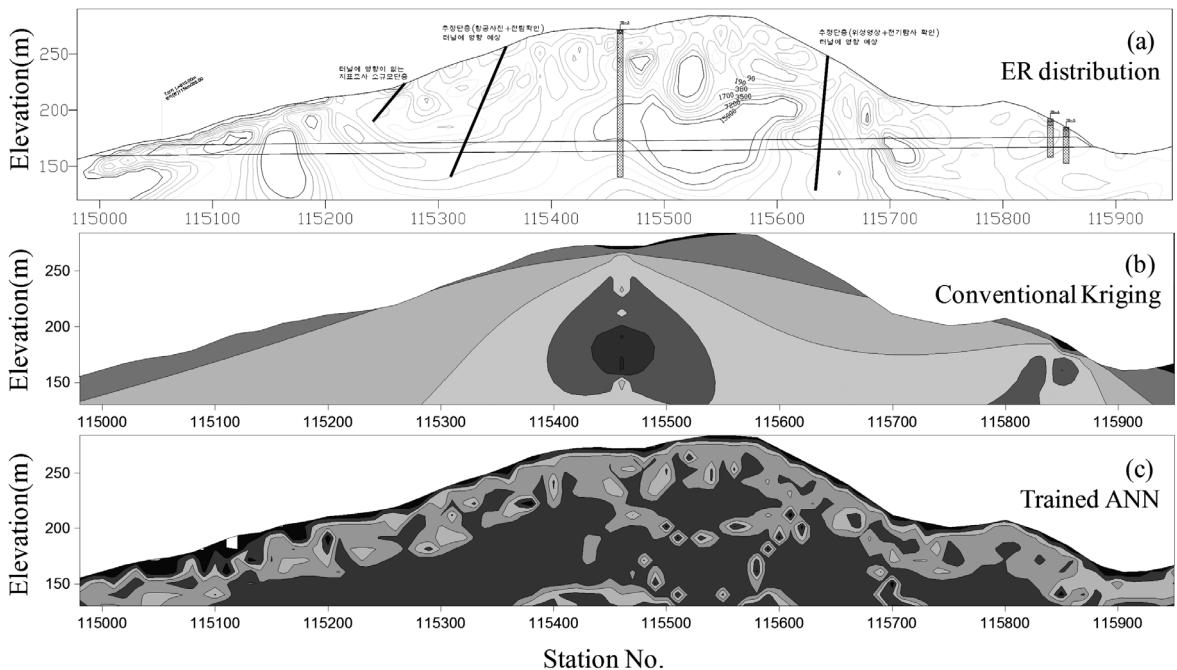


그림 8. 크리깅 기법과 학습된 인공 신경망에 의한 RMR의 분포도

내리기는 어렵다.

다음으로 RMR과 동일하게 Q-값의 예측 결과를 보여주는 것이 그림 9이다. 빨간 영역과 파란 영역은 각각 Q-값이 400을 넘는 경우와 100 이하인 경우를 나타내고 있다. 그림 9를 통해 알 수 있듯이 시추공 주변에서는 크리깅을 이용한 경우에도 Q-값의 분포를 예측할 수 있으리라 판단되지만 단순 2차 외삽에 의해 예측을 수행하는 시추공 사이의 미시추 구간에서는 그림 8의 결과와 같이 매우 단조로운 결과를 보이고 있었다.

인공 신경망에서 풍부한 학습 자료를 얻을 수 있는 경우에 예측 결과의 질이 향상될 수 있다는 것은 명백한 사실이다. 만일 시추공에서 얻은 자료가 대상 구간 전체의 RMR과 Q-값의 최대값과 최소값을 포함하는 경우에는 인공 신경망을 이용하여 예측한 결과의 신뢰도가 매우 높아질 것이다. 이는 학습 자료가 매우 풍부하거나 혹은 다양한 경우일수록 변수 값의 범위를 충분히 포함할 가능성이 높아지기 때문이다. 수 천개의 자료가 존재 하더라도 자료의 분포가 매우 좁은 범위인 경우에는 적절한 학습을 위한 충분한 자료라고 말하기 어렵다. 이는 인간의 뇌와 동일하게 인공 신경망이 외삽보다는 내삽

에서 더 뛰어난 결과를 얻을 수 있는 이유이기도 하다. 따라서 인공 신경망의 예측결과에 있어서 시추 조사 개소도 자료에 매우 중요한 영향을 미치지만 인공 신경망이 적용될 시추공의 위치가 더 큰 영향을 미치게 된다.

4.4 터널 종단방향 RMR과 Q-값 분포

본 절에서는 터널 종단 방향의 RMR과 Q-값의 분포를 인공 신경망에 의해 예측한 결과에 대해서 논의한다. 터널 종단방향의 RMR과 Q-값의 예측은 터널공사에 있어 지보 설계를 결정하는 중요한 인자이다. 그림 10은 예측 결과를 정리한 그림이다. 그림에서 원으로 표시한 지점은 각각 RMR과 Q-값이 가장 작게 예측된 지점을 보이고 있으며 이는 전기 비저항 탐사에 의해 평가된 취약 지역(그림 6의 점선)의 분포와 매우 잘 일치하고 있었다. 또한, RMR과 Q-값 상호 간에도 최소값의 위치에서 좋은 일치를 보이고 있었다. 이러한 점을 바탕으로 판단해보면 인공 신경망을 이용하여 예측한 RMR과 Q-값의 분포는 크리깅을 이용한 경우에 비해 매우 신뢰도 높은 결과를 얻을 수 있다고 할 수 있다. 현실적으로 본 연구 대상 지역과 같이 소수의 시추 조사 결과만이 존재하는

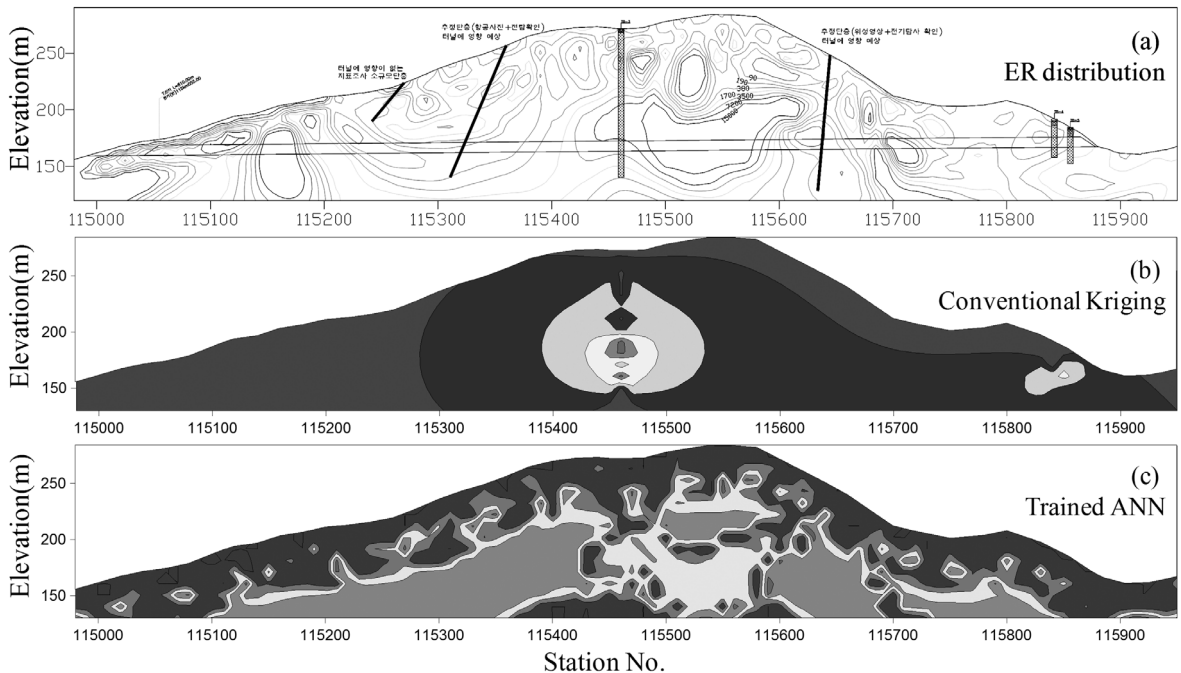


그림 9. 크리깅 기법과 학습된 인공 신경망에 의한 Q-값의 분포도

www.kci.go.kr

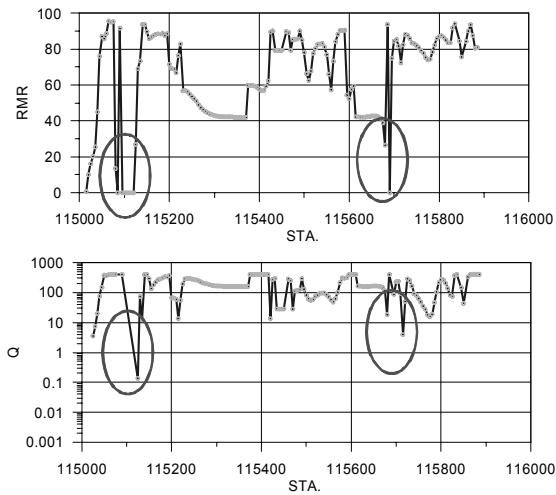


그림 10. 터널 종단 방향의 RMR 및 Q-값의 예측치 비교




그림 11. 인공 신경망에 의해 예측된 RMR과 Q-값의 상호관계

경우 크리깅 기법을 이용하여 예측하다면 그림 10과 같은 터널 종단방향의 분포도를 얻는 것이 불가능하다.

마지막으로 시추조사 및 전기 비저항 탐사 자료로부터 학습된 인공 신경망이 인지하고 있는 RMR과 Q-값의 상호 관계가 통상적으로 널리 사용되는 두 값 사이의 관계식 $RMR = 9 \ln Q + 44$ (Bieniawski, 1984)에 부합하는 지를 검토하였다. 그림 11에 보인 바와 같이 인공 신경망에 의해 얻어진 결과는 선행 연구 결과와 잘 일치하며, 이러한 결과를 통해 본 연구에서 사용한 인공 신경망은 주위의 전기 비저항 자료의 참고점을 이용하여 결과점 사이의 관계를 합리적으로 평가할 수 있다는 점을 알 수 있었다.

5. 최적 시추공 위치 선정

터널이 많이 시공되는 산악 지역에서는 일반적으로 장비의 투입이 곤란하고 시추 심도가 매우 깊게까지 요구되는 등 매우 불리한 시추 조사 조건을 갖는다. 따라서, 산악 지역의 지반 조사에서는 그림 12의 시추공 BH-2와 BH-3와 같이 갱구부에서 시추조사가 많이 이루어 지며 그 개수도 제한된다. 또한, 직접적으로 심도별 지반 등급이 평가되는 시추 조사와 전기 비저항 탐사 등과 같은 물리 탐사는 독립적으로 수행되며, 조사 완료 후, 터널 구간의 지반 등급 예측 및 상대적인 취약대 파악을 위해 시험 결과들이 독립적으로 검토된다.

본 연구에서는 최적의 시추공 타설 위치와 개수를 합리적으로 선정함으로써 경제적인 측면이나 열악한 현장 조건에 기인하여 매우 제한적으로 시행되는 시추 조사로부터 최대한 양질의 지반정보를 얻을 수 있는 방안을 제안한다. 본 방안은 터널의 지반 조사를 단계적으로 수




그림 12. 최적 시추공 위치 선정

행하는 방안으로 다음과 같다.

- (1) 전기 비저항 탐사 등 일반적으로 시행되는 물리 탐사 조사를 먼저 수행한다.
- (2) 물리 탐사 결과로부터 얻은 물리량 분포도를 작성한다.
- (3) 조사된 물리량(전기 비저항치 등) 분포도상에서 최대값과 최소값을 보이는 구간을 모두 포함할 수 있는 시추공 위치와 시추 방향을 선정한다.
- (4) 이와 같은 요령으로 물리량을 폭넓게 포함할 수 있는 최소한의 시추공 개수를 선정한다.

예를 들어 그림 12에서의 터널현장에서는 3공(BH-1~BH-3) 시추공이 타설되어 시추조사가 이루어졌으나, 앞서 기술한 단계별 지반조사 개념을 도입하면 이미 조사된 BH-1 시추공의 위치를 상대적으로 낮은 전기 비저항을 보이는 지역과 높은 값을 보이는 지역을 모두 포함할 수 있는 RBH-2로 수정될 수 있다. 이를 통해 1개의 시추공으로도 보다 폭 넓은 지반 등급을 포함한 지역의 지반 조사가 이루어 질 수 있으며, 이를 통해 준비된 인공 신경망의 학습 자료는 예측 가능한 미시추 구간의 지반 등급 범위를 극대화 시킬 수 있다. 그림 12는 기존 3개의 시추공(BH)과 제안된 방법으로 선정해 본 2개(RBH)의 최적 시추 위치를 나타낸다.

6. 결 론

본 연구에서는 전기 비저항 탐사 결과와 시추 조사 결과를 연계하여 미시추 구간의 지반 등급 분포를 평가할 수 있는 새로운 원도우-쉬프팅 인공 신경망 학습 기법을 제안하였다. 제안된 기법은 실제 현장에 적용하여 현장 적용성을 검토하였고, RMR 및 Q-값 상관 관계를 나타내는 기존 연구결과들과 비교하여 학습 완료된 인공 신경망의 추론 성능 및 타당성 여부를 확인하였다. 본 연구의 요약과 이를 통해 얻은 결과를 정리하면 다음과 같다.

1. 본 연구를 통해 격자창을 개념적으로 형성하고 시추 구간을 움직이며 격자점 위치의 시추 조사 결과와 전기 비저항의 조합으로 학습 자료를 구성하는 원도우-

쉬프팅 학습 기법을 제안하였다. 본 기법은 각 지점의 지반 등급 분류값은 인접 지점의 지반 등급 분류값과 밀접한 연관성이 있다는 것에 착안하여, 격자창의 중심점(그림 2의 R5) 외의 주변 축점의 비저항을 참고값으로 활용하는 것이다. 이를 통해 정의하기 곤란했던 전기 비저항과 RMR 및 Q-값 간의 복잡한 비선형성을 인위적으로 부여하고 인공 신경망을 이용하여 비선형 상관 관계를 학습하여 인지할 수 있도록 하였다. 학습 완료된 인공 신경망은 터널 설계를 위해 필수적으로 평가되어야 하는 미시추 구간의 지반 등급 분포를 예측하는데 적용된다.

2. RMR과 Q-값의 분포를 파악하기 위해 지시 크리깅 기법과 본 연구를 통해 훈련된 인공 신경망을 이용하여 동일한 현장에 적용해 본 결과, 인공 신경망이 시추공 주위뿐만 아니라 시추공 사이의 미시추 구간에서도 다양한 예측 결과를 보이는 것에 비해 크리깅 기법은 시추공 사이의 지반 등급 분류를 매우 단조롭게 예측하고 있었다. 따라서 본 연구를 통해 학습된 인공 신경망은 전통적인 일반 크리깅 기법에 비해 보다 현실적인 분포 예측을 수행할 수 있음을 확인하였다.
3. 인공 신경망을 통해 예측된 터널 종단 방향의 RMR과 Q-값은 전기 비저항 탐사 결과 얻어진 취약 지역과 위치적으로 잘 일치하였으며, 동시에 예측된 RMR과 Q-값의 상호 관계 역시 선행연구 결과와 부합한 것으로 나타났다.
4. 학습의 효과를 높이기 위해서는 시추공의 개수도 중요하지만 특히 시추공 위치를 합리적이고 신중하게 결정할 필요가 있으리라 판단되며, 또한 차후 신뢰도 높은 여러 입력 항목으로 심도 있는 연구를 수행한다면 보다 적합한 예측값을 얻을 수 있으리라 기대된다.
5. 본 연구를 통해 제안된 인공신경망에 기반한 기법의 적용가능 범위와 추론 신뢰도는 전기 비저항값과 시추결과의 조합으로 작성되는 학습자료의 질적, 양적 수준에 좌우되므로 보다 면밀한 전기 비저항 탐사의 수행과 가탐심도내에서의 제안 기법 적용이 매우 중요하며, 보다 다양한 지반조건을 파악할 수 있는 시추위치 선정과 가능한 한 시추조사를 폭넓게 수행하려는 노력이 요구된다.

참고문헌

1. 유광호 (1995a), “경계조건을 고려한 보통크리깅의 지하특성평가를 위한 응용”, 대한토목학회 논문집, 제19권, 제3호, pp. 645-652.
2. 유광호 (1995b), “다분적 암반분류를 위한 정성적 자료의 지구통계학적 연구 - I. 이론”, 한국지반공학학회 논문집, 제 11권 2호, pp. 71-77.
3. 최종근 (2002), 공간정보 모델링, 구미서관, p. 286.
4. Baecher, G. B. (1983), “Statistical analysis of rock mass fracturing”, Journal of Mathematical Geology, Vol. 15, No. 2, pp. 329-347.
5. Bieniawski, Z. T. (1984), Rock mechanics design in mining and tunneling, Balkema, Boston, p. 271.
6. Jacobs, R. A. (1988), “Increased rates of convergence through learning rate adaptation”, Neural Networks, Vol. 1, No. 4, pp. 295-307.
7. Journel, A. G. (1986), “Geostatistic: Models and tools for the earth sciences”, Mathematical Geology, Vol. 18, No. 1, pp. 119-140.
8. Ohtsu, H., Sakai, Y., Saegusa, H., Onoe, H., Ijiri, Y. and Motoshima, T. (2006), “Risk Evaluation of Water Inrush During Shaft Excavation in Fractured Rock Masses 275”, Proc. of ISRM International Symposium 2006, 4th Asian Rock Mechanics Symposium, CD-ROM.
9. Öztürk, C. A. and Nasuf, E. (2002), “Geostatistical assessment of rock zones for tunneling”, Tunneling and Underground Space Technology, Vol. 17, pp. 275-285.
10. Pande, G. N. and Shin, H. S. (2004), “Artificial Intelligence v. Equations”, Proceedings of Institute of Civil Engineers in Civil Engineering, Vol. 157, No. 1, pp. 39-42.
11. Pao, Y. H. (1989), Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Publishing Company, USA.
12. Prechelt, L. (1998), “Automatic early stopping using cross validation: quantifying the criteria”, Neural Networks, Vol. 11, pp. 761-767.
13. Riedmiller, M. (1994), “Advanced supervised learning in multi-layer perceptrons - from backpropagation to adaptive learning algorithms”, International Journal of Computer Standards and Interfaces, Vol. 16, pp. 265-278.
14. Rumelhart, D. E., McClelland, J. L. (1986), Parallel distributed processing, Cambridge, MA: Exploitation in the MIT Press.
15. Shin, H. S. (2001), Neural network based material models for finite element analysis, Ph.D. thesis:C/Ph/250/01. Department of Civil Engineering, University of Wales Swansea.
16. Shin, H. S., Lim, J. J., Chang, S. H. and Bae, G. J. (1994), “Assessment of the major causes for tunnel collapses by using a neural network based sensitivity analysis”, Proceeding of Annual Conference of Korea Institute of Civil Engineers, pp. 512-517.
17. Skouras, K., Goutis, C. and Bramson, M. J. (1994), “Estimation in linear-models using gradient descent with early stopping”, Statistics and Computing, Vol. 4, No. 4, pp. 271-278.
18. Soulie, M. (1984), Geostatistic applications in geotechnics, Advanced geostatistics in the mining industry, D. Reidel Publishing, Holland, pp. 703-730.
19. Sturk, R., Olsson, L. and Johanson, J. (1996), “Risk and decision analysis for large underground projects, as applied to the Stockholm ring road tunnels”, Tunnelling and Underground Space Technology, Vol. 11, No. 2, pp. 156-164.
20. Tollenaere, T. (1990), “Fast adaptive Backpropagation with good scaling properties”, Neural Networks, Vol. 3, No. 5, pp. 561-573.
21. Webster, R. (1984), Elucidation and characterization of spatial variation in soil using regionalized variable theory, IEEE Trans. Sys., Man, Cybern, pp. 903-914.
22. You, K. H. and Lee, J. S. (2006), “Estimation of rock mass classes using the 3-dimensional multiple indicator kriging technique”, Tunnelling and Underground Space Technology, Vol. 21, p. 229.

접수일(2009.5.13), 수정일(1차: 2009.5.20), 게재확정일(2009.5.25)