

지질공학적 특성을 고려한 터널 붕락 분석과 합리적인 터널 붕락 추론에 관한 기본 연구

A Basic Study on the Tunnel Collapse Analysis and the Reasonable Inference of Tunnel Collapse Considering a Characteristic of Engineering Geology

마 상 준*¹ Ma, Sang-Joon 서 경 원*² Seo, Kyoung-Won
배 규 진*³ Bae, Kyu-Jin 이 석 원*¹ Lee, Seok-Won

Abstract

Discontinuities in a rock mass such as fault, joint, bedding plane, fissure, fracture and other mechanical defects generally play an important role in a stability of tunnel in the stage of design and excavation of tunnel. However, due to an inherent uncertainties in a rock mass, designers and/or constructors of tunnel have undergone many trial-and-errors in the procedure of tunnel design and construction. In order to reduce trial-and-errors, the Geo-Predict, developed in this study broadly consisted of two main modules; inference module for a collapse pattern of tunnel learned by using the data obtained from foreign countries and inference module for a collapse magnitude of tunnel based on the data obtained in Korea. The data of tunnel collapse and overbreak from 104 tunnelling sites including 84 sites in foreign countries and 20 sites in Korea were selected as the learning data for the Geo-Predict system. Opinions of many geotechnical experts and tunnel collapse data based on an uncertain geotechnical information to be obtained in tunnels were used as a knowledge-base for the Geo-Predict system. The Geo-Predict system was proven to have a capability to estimate the collapse type of tunnel effectively. This paper introduces the consistency and the functions of the Geo-Predict and presents the application of the Geo-Predict to two tunnel sites in the Korea High Speed Railway and one site in the subway.

요 지

터널 시공과 굴착과정에서 파쇄대, 절리, 연약대, 균열 등 암반에서의 불연속면은 터널 안정성에 중요한 역할을 한다. 본 연구에서는 지반 고유의 특징인 불확실성에 의한 터널 설계와 시공 과정에서 겪는 많은 시행오차를 최소화하기 위해서 국내외 터널 붕락 현장의 지반조사 자료를 분석하여 터널 붕락 유형 및 규모를 제시할 수 있는 Geo-predict 시스템을 개발하였다. Geo-predict 시스템은 총 104개 터널 붕괴/붕락자료(국외 84개, 국내 20개)를 분석한 자료를 데이터베이스로 인공지능망 학습을 통해서 터널 붕괴 형태와 규모를 추론하는 시스템이다.

본 논문에서는 Geo-predict의 개발과정 및 구성·기능을 소개하였으며 104개 터널 현장 자료를 지반조건별로 분석하고 이를 데이터베이스화하여 인공지능망을 이용한 추론 시스템을 구축하고, 2개 고속전철 터널현장과 1개 지하철 시공현장에 적용성 평가를 실시하여, 터널의 붕락 가능 형태 및 붕락 규모를 추론하였다.

Keyword : Tunnel collapse pattern, Tunnel collapse magnitude, Neural network, Site investigation

*1 정희원, 한국건설기술연구원, 선임연구원
*2 정희원, 한국건설기술연구원, 연구원
*3 정희원, 한국건설기술연구원, 수석연구원

1. 서론

터널 설계나 시공시 지반내에 존재하는 각종 불연속면은 터널 굴착 공정에서 안정성, 경제성 등에 중요한 영향을 미치지만 지반이 가지는 불확실성으로 인해 지반의 지질학적, 역학적, 수리학적 자료는 항상 불충분하게 제공된다. 그러므로, 터널 막장 전방의 미굴착 지역에 존재하는 불연속면 등은 터널 공사에 항상 위험 요인으로 작용하게 되며, 터널 굴착시 예상하지 못한 불리한 지반조건에 의해 발생하는 터널 붕락이나 붕괴는 터널의 경제적인 시공에 큰 장애요인이다. 이러한 장애요인을 사전에 파악하기 위하여 현재 수치해석 방법이나 선진보어링, 시추 등 각종 실내의 시험을 통한 여러 가지 방법이 적용되고 있지만 대부분의 방법들은 효과에 비해 많은 시간과 비용이 소요된다. 최근에는 이를 극복하기 위한 방법으로 전문가 지식을 기반으로 발생 가능성이 높은 현상을 추론하는 전문가 시스템 개발에 많은 연구가 수행되고 있는데, 현재 지반공학분야에서 불확실한 지반정보를 이용하여 터널 공사시 암반 분류나 지반침하 등에 관한 정보를 가장 근사하게 추론할 수 있는 방법으로 퍼지시스템, 전문가시스템, 인공신경망 등의 인공지능 기법이 적용되고 있다.

본 연구에서는 인공신경망을 이용한 터널 붕락 형태와 규모 추론을 위한 전문가 시스템을 구축하고 이를 지하철

및 고속철도 현장에 적용시켜 보았다. 그리고 전문가 시스템의 데이터베이스를 구축하기 위하여 국내외 터널 붕락 사례를 조사하고 지반조건별로 발생하는 터널 붕락 형태 및 붕락 규모를 조사 분석하였다.

2. 터널 붕락 현황 분석

본 연구를 위하여 국외터널 붕락 사례(Cecil, 1964)와 국내터널 붕락 사례를 수집하였는데, 국외터널 자료는 1960년대에 Cecil에 의해 수집된 스웨덴과 노르웨이의 13개 대형 프로젝트 건설에 따른 터널굴착과 지보와의 관계 연구에 사용된 현장자료이다. 국내터널 자료는 1980년대 이후에 지하철, 도로터널, 철도터널 및 전력구 건설시 터널의 붕락 및 붕괴 사고때 조사되었던 지반조사 자료이다. 수집한 자료는 외국터널 92개 현장과 국내터널 52개 현장으로 총 144개 현장자료이며 이중 자료의 신뢰성이 있는 외국터널 84개 현장, 국내터널 20개 현장 등 총 104개 현장자료를 대상으로 분석을 하였다.

국내외 터널 붕락 분석 자료는 조사의 시간적 차이 등으로 인해서 지반분류 방법, 조사내용 등이 상이하므로 국외터널과 국내터널의 지반조사 항목이 같은 부분은 동일하게 분석하였으나 대부분의 조사항목 및 분류기준 등이 상이함으로 별도로 분석하였다. 아래 그림 1~4는 국내외터




그림 1. 붕락 현장의 절리군 수




그림 2. 붕락 현장의 지하수 유출 정도




그림 3. 붕락 현장의 지반분류




그림 4. 붕락 현장의 RQD

널 붕락 현장에서 공통적으로 지반조사가 실시되었던 항목들에 대한 분석 결과이다.

그림 1의 붕락 현장에서의 절리군수는 1~2개의 주절리군과 불규칙절리가 발달하는 것으로 조사되었다. 그림 2의 붕락 현장의 지하수 유출정도는 No water에서 Minor flow가 전체의 50%이상을 차지하고 있다. 터널지반의 암반종류는 그림 3과 같이 화강암과 같은 심성암과 규암이나 변성사암(metamorphosed arkose) 같은 변성암류가 특히 많이 분포한다. 붕락 지점에서 조사된 RQD는 그림 4와 같이 50% 이하가 전체의 절반 이상을 차지한다. 이 중에서 국내에서 조사되었던 터널 현장은 대부분 30% 이하로 극히 불량하였고 외국터널의 경우 50% 이상이 대부분이다. 그림 5의 국외터널의 붕락 현장에서의 불연속면은 주로 절리와 단층이 대부분을 차지하고 있다. 그림 6의 국외터널 붕락 형태는 여굴과 붕괴를 제외하고는 대부분 절리군에 의한 붕락이 주로 발생되었는데 이는 조사터널의 심도가 깊으므로 풍화암이나 연암에서 암반의 풍화에 의한 막장면의 붕락보다는 신선한 암반층에서 막장면 주변의 절리군에 의해 형성된 블록이 터널 굴착에 따른 주변 응력의 재배치와 중력하에서 개별암 블록의 미끄러짐과 회전에 의한 절리암에서 무지보 지반에서 주로 발생하는 붕락의 경향을 보였다(Ma. S. J., etc. 2000).

다음 그림 7~11은 국내 터널 붕락 자료 중에서 외국터

널 자료와 비교가 곤란한 항목을 분석한 자료이다. 그림 7은 조사자료의 굴착심도별 터널 붕락 분포현황을 보여주는데 굴착심도 30m 이하가 전체의 80%이상을 차지하고 있는데 이것은 조사터널이 주로 지하철과 같이 천심도에서 굴착된 터널이 많았기 때문이다. 그림 8의 지반 풍화도에 따른 분류는 그림 7과 같이 30m이하의 천심도 터널이 많으므로 풍화암층과 연암층이 주로 분포한다. 붕락 현장의 절리군 상태 및 절리간격은 그림 9 및 10과 같이 RMR 분류 기준의 4~5 등급의 불량한 상태이므로 절리면의 전단강도 등을 기대할 수 없는 형편이다. 국내 조사자료의 터널 붕락 형태를 그림 15의 분류에 따라 분석하면 벤치파괴를 제외하고 고른 붕락 형태를 보였다. 이것은 그림 9의 국외터널 붕락처럼 절리면의 조합에 의한 낙반(fall) 보다는 천심도에서 굴착된 터널이 많으므로 연약한 암반층에서 지반의 강도와 불연속면 등 전체적인 터널막장의 자립조건이 불리하기 때문에 붕락이 발생한 것으로 분석되었다.

3. 터널 붕락 추론 시스템 개발

3.1 인공신경망 소개

본 연구에서 적용한 인공신경망 기법은 각 입력값 노드 사이의 연결강도를 조정하는 학습을 통하여 얻어진 내부




그림 5. 국외터널 붕락 현장의 불연속면 종류




그림 7. 붕락터널의 굴착 심도




그림 6. 국외터널 붕락 형태 분석




그림 8. 붕락터널의 암반 풍화도에 따른 분류




그림 9. 봉락터널의 절리상태를 RMR 분류법의 절리상태에 따른 분류



그림 10. 봉락터널의 절리간격에 따른 분류




그림 11. 국내 터널 봉락형태 분석

지식을 학습되지 않은 새로운 상황이나 자료의 일부가 불충분하거나 왜곡된 경우에도 연결강도에 저장된 내부지식에 따라 적절한 결과를 추론할 수 있는 기법이다. 따라서 불확실성이 많이 내재하는 지반의 특성상 지반조건에 의해 발생하는 터널봉락의 유형과 규모 등을 추론하는데 있어서 여러 가지 인공지능 기법중 가장 적합한 방법이라고 판단된다.

본 연구에 사용된 인공지능망 기법은 백프로퍼게이션 (back propagation)으로써 학습 알고리즘의 기본 원리는 다음과 같다. 입력층의 각 유닛(unit)에 입력패턴을 주면, 이 신호는 각 유닛에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 이 위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해나간다. 지도학습에서는 입력 및 원하는 출력(목표출력) 패턴(벡터)이 네트워크에 제시된다. 네트워크는 입력층에 주어진 입력패턴이 출력층에 전파되면서 변환 출력패턴을 목표패턴과 비교하여 네트워크에서 출력패턴이 목표패턴과 일치하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우는 얻어진 출력패턴과 목표패턴의 차이를 감소시키는 방향으로 네트워크의 연결강도를 조절하여 학습을 한다.

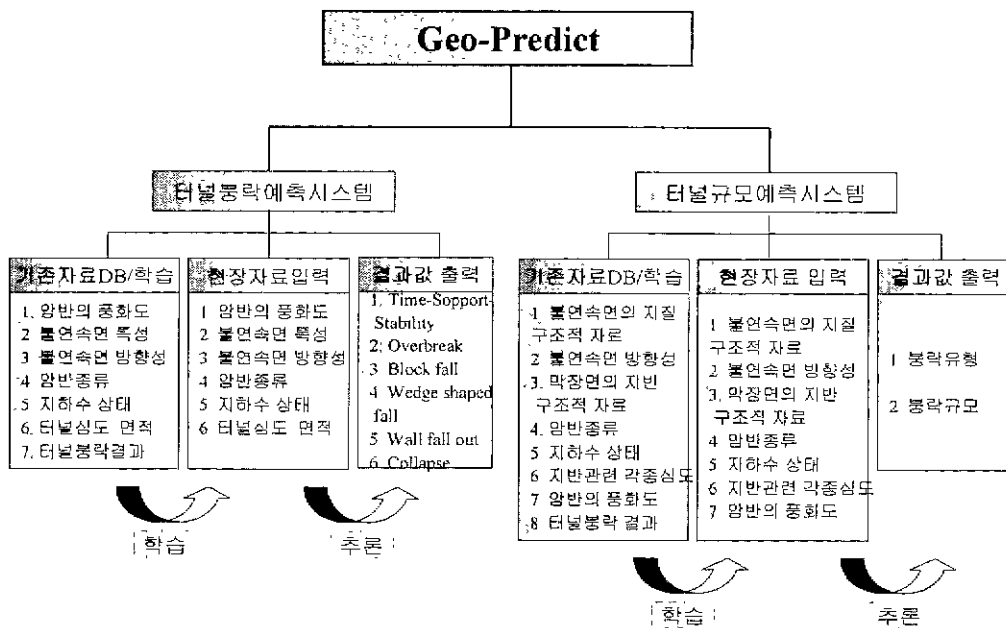


그림 12. Geo-Predict 구성도

표 1. Cecil(1964)의 지반분류 기준그림

Intact rock strength	Rock mass structure	Average discontinuity spacing
<ul style="list-style-type: none"> • sound • altered or weathered 	<ul style="list-style-type: none"> • massive • one discontinuity set • two discontinuity set • three discontinuity set • random, crushed, earthquake 	<ul style="list-style-type: none"> • less than 2m • 2m-1ft • 1ft-3ft • greater than 10ft
Discontinuity tightness	Joint discontinuity	Discontinuity type
<ul style="list-style-type: none"> • light • open 	<ul style="list-style-type: none"> • continuous • discontinuous 	<ul style="list-style-type: none"> • Joint • Bedding plane • cleavage or shistosity • fault, shear zone
Discontinuity filling		Degree of discontinuity planess
<ul style="list-style-type: none"> • none • non-softening clay • other low friction material • sandy or gravity material • alteration along joints 	<ul style="list-style-type: none"> • plane • curved • Irregular 	Degree of discontinuity roughness
<ul style="list-style-type: none"> • slickensided • smooth • rough 		
Dip of discontinuity	Strike of discontinuity	RQD
<ul style="list-style-type: none"> • 0-30° • 30-60° • 60-90° 	<ul style="list-style-type: none"> • 0-30° • 30-60° • 60-90° 	percent
Instability	<ul style="list-style-type: none"> • None(N), Wall(W), Roof(R), Both(B) 	

그림 13. 터널 붕락 형태 추론 모듈의 입력값

3.2 Geo-Predict의 입출력값 설정

Geo-Predict의 인공신경망 구성은 크게 국외터널 자료를 이용한 터널 붕락 추론모듈(module)과 국내 터널 붕락 자료를 이용한 터널 붕락규모 추론모듈로 구성되어 있는데 이 두 시스템은 붕락·붕괴가 발생한 터널 현장 자료의 학습을 통해서 지반조건별 터널 안정성에 대한 경향을 분석, 이를 바탕으로 대상터널의 붕락 형태 및 규모를 추론할 수 있다. 두 시스템은 각각 기존의 현장자료를 데이터베이스화하고 이를 인공신경망을 통하여 학습을 하고 새로운 현장자료를 이용하여 결과값을 추론하는 모듈로 구성되어 있다(그림 12 참조)

터널 붕락 추론모듈은 Cecil(1964)에 의해 조사된 북유럽 지역의 터널막장 조사 자료를 이용한 추론 시스템으로 터널 붕락 현장의 자료조사시 그림 13의 항목으로 분류하였는데 일반적으로 여굴, 터널 붕락이나 변위 발생 등은 화약사용량이나, 천공방법과 보강순서 및 방법, 터널 단면적 등에 따라 매우 달라지지만 이러한 지반보강이나 발파 자료 등은 자료 여건상 인공신경망 학습을 위한 입출력 항목으로 설정하기에는 수집자료의 한계점이 있었다. 본 연구에서는 인공신경망 학습자료를 위하여 Cecil의 지반분류 기준에 맞추어서 입력 항목을 54개의 세부항목으로(그림

13 참조) 분류하였다. 인공신경망의 학습을 통하여 추론되는 결과는 6개 항목으로 Cecil(1964)의 분류를 참고(표 1 참조)하였다.

터널 붕락 규모 추론 모듈은 국내 터널현장에서 수집된 자료를 바탕으로 터널 붕락에 영향을 미치는 지반특성들을 64개 항목으로 분류하고 결과값으로 터널 붕락 형태, 붕락 규모의 2개 항목으로(그림 14 참조) 분류하였다. 결과 항목중 터널 붕락 형태는 굴착단계에 따라서 무지보 상태에서의 붕락, 1차 숏크리트 타설 후 붕락, 하반굴착 도중 발생하는 붕락, 마지막으로 터널 라이닝 타설 후 인링 폐합을 한 후 발생하는 붕락으로 나눌 수 있는데(HSE, 1996, 박광준, 1993), 본 연구에서는 무지보 상태에서 불리한 지반 조건에 의해 발생하는 붕락을 대상으로 붕락 자료를 수집 및 분석하여 발생과정과 위치 등을 고려하여 그림 15와 같이 5가지의 붕락 형태로 분류하였다. 그리고, 추론 결과 항목중 붕락 규모는 사고 발생시 현장에서 추정된 주변 지반층의 붕락 또는 붕괴 체적량이다.

3.3 모델설정 및 신뢰성 분석

앞 절에서 설명한 바와 같이 인공신경망은 중간층의 구조 및 학습상수들에 의해 추론능력 및 학습시간 등이 큰 차

그림 14. 터널 붕락 규모 추론 모듈의 입력값




그림 15. 터널 붕락 형태 분류

이가 있으므로 최적의 인공신경망 구조를 얻기 위하여 Geo-Predict내의 기 구축된 터널 붕락 데이터베이스를 이용하여 터널 붕락 추론 모듈은 1~84번 현장자료를 학습 조건별로 34개의 모델을 만든 후 학습을 수행하였다. 학습 수행 후에는 1~20번의 20개 현장 자료를 재 추론하여 실제값과 추론값을 상호 비교하여 각 항목별 오차율과 각 모델별 평균오차율을 분석하였다. 분석결과 평균오차율이 가장 작은 모델은 C-30번 모델로서 평균 21%의 오차율을 보였으며 C-26번 모델이 평균 47%로 가장 큰 오차를 보였다. 각 모델별 조사값과 추론값에 대한 평균 오차율과 학습 시간, 학습능력 등을 분석하여 C-4번 모델을 터널붕락 추론모듈의 표준모델로 결정하였다. 이 모델의 신뢰성 검증은 Geo-Predict내의 데이터베이스를 이용하여 1~84번 현장 자료중 1~69번 현장의 69개 현장 자료만 데이터베이스화하고 최적모델로 설정된 C-4번 모델 구조에 오차율 0.000001에 이르도록 104242회의 학습을 수행하고 검증을 위해서 데이터베이스되지 않은 나머지 15개 현장 자료를 입력하여 결과값과 추론값을 비교하였다. 추론한 결과와 실제 결과와 비교한 평균오차율은 결과 항목중 Overbreak가 31%로 가장 큰 오차율을 보였으며 Collapse가 4%의 오차율을 보였고 평균 17%의 오차율을 보였다.

터널 붕락 규모 추론모듈도 최적 인공신경망 구조를 결정하기 위하여 앞절에서와 같이 우선 데이터베이스화된 국내터널 붕락 현황 자료를 은닉층 구조와 학습상수를 달

리하면서 25개 모델을 만들고 각 모델별 학습조건들을 변화시키면서 학습을 수행하였다. 학습된 모델 중에서 최적의 인공신경망 모델 구조를 결정하기 위하여 각 모델별로 학습 수행 후 데이터베이스내의 1~20번 현장자료의 20개 데이터를 재 추론하였다. 분석 결과, 평균오차율이 가장 큰 모델은 학습모델 33번으로써 평균 69%로 나타났고, 평균오차율이 가장 작은 모델은 학습모델 15번으로 26%로 나타났다. 또한 붕락 형태에 관한 오차율보다는 붕락 규모에 대한 오차율이 매우 크게 나타났다. 이는 학습자료 입력 시 터널 붕락 형태(P)에 관한 입력은 크게 범주형의 단위로 나누었기 때문에 비교적 정확한 자료가 입력되었지만, 붕락 규모(V)는 실측이 불가능하고 조사자에 의해 추정된 자료가 입력되기 때문으로 상대적으로 불확실한 자료가 입력되기 때문인 것으로 분석된다. 터널 붕락 규모 추론 모듈의 최적 인공신경망 모델은 평균오차율, 표준편차, 학습수행 능력 등을 고려하여 학습모델 14번(학습률 0.1, 모멘텀상수 0.9, 은닉층 구조 128-128)으로 결정하였다. 개발된 시스템과 결정된 모델의 신뢰성 검증을 위하여 Geo-Predict내의 데이터베이스를 이용하여 20개 현장자료중 1~15번의 자료를 매개변수 연구를 통하여 최적 모델로 선정된 학습모델 15번의 학습조건(학습률: 0.3, 모멘텀 상수: 0.7, 중간층구조: 128-128)에 맞추어서 시스템오차 0.000001까지 107987회를 학습하였다. 학습 후 실제 조사값과 추론된 결과값과의 비교를 위하여 학습된 인공신

경망으로 나머지 16~20번 현장의 5개 자료를 제 추론하여 조사값과 비교하여 보았다. 결과값의 터널 붕락 형태(P) 추론은 39%의 오차율을 보였고, 붕락 규모(V)의 오차율은 45%의 오차를 보여 평균 42%의 오차율을 보였다.

4. Geo-Predict의 현장 적용성 연구

본 연구에서는 앞에서 논술한 바와 같이 국내외 터널 붕락 자료를 지반 특성별로 분석하고 이를 데이터베이스화 하였다. 구축된 데이터베이스는 인공지능망을 통하여 학습을 하고 현장자료를 제공하면 터널 붕락 형태 및 규모를 추론할 수 있는 전문가시스템을 개발하였다. 개발된 시스템은 현장 적용성 연구를 위하여 지하철 1개소, 고속철도 터널 2개소에 현장 적용성 평가를 실시하였다. 현장 적용성 평가는 먼저 최적의 인공지능망 모델로 지반조건을 입력하여 터널 붕락 형태와 터널 붕락 규모를 추론하고 이를 조사자가 현장에서 조사한 결과와 상호 비교분석 하였다.

4.1 사례1-지하철○○공구 터널 지반상태

본 지역은 중생대 대보화강암이 기반암으로 넓게 분포하고 있으며, 터널 구간은 암반이 심하게 풍화되어 균열 및 파쇄대가 다수 발달되어 있으며 불연속면들은 점토질로 충전되어 있다. 붕락지점의 터널상부는 풍화암층이며 굴착은 상반중벽분할(CD)공법이 적용되고 있었고, 붕락사고 이전의 계측결과에 의하면 선진도강 막장면 후방에서의 변위속도가 일정하여 안정화된 상태로 판단되었으나 예측하지 못한 파쇄대의 존재로 터널붕락이 발생하였다. 붕락이 발생한 지점은 풍화암과 연암의 경계부에 풍화




그림 16. 사례 1 터널 붕락 현장 종단면도

및 변질된 절리의 발달이 심하고, 지하수 유입이 있었다. 터널막장에서는 진행방향을 중심으로 좌측부는 절리의 발달이 적은 연암층이고 우측부는 파쇄대가 심하게 발달되어 있다(그림 16 참조)

4.2 사례2-경부고속철도 ○○터널 지반상태

본 터널구간은 옥천누층군에 속하며 세일층이 주로 분포한다. 시추자료에 의하면 암반은 풍화암내지 연암이 분포하고 층리 및 잔절리의 발달로 RQD 값이 50%이하로 나타난다. 본 터널구간에서 가장 문제가 되는 구간은 터널 중간에 위치한 계곡부로 상당한 폭의 단층이 존재할 것으로 예상되었다.

터널은 NATM 개념의 터널공법에 따라 굴착되고 있으며 터널굴착 초기에는 계곡부 존재와 암반의 풍화에 따른 지반강도의 약화, 세일층리 및 불연속면 등으로 터널 굴착시 상당한 문제가 있을 것으로 예측되었으나 굴착결과 계곡부위도 폭이 수 cm의 단층대로써 터널굴착에 큰 영향을 주지 못하였고 지하수 유출도 거의 없었다. 터널내에서 실시한 내공변위량도 수 mm의 변위만 발생되었고 터널굴착 공정을 약 10개월간 모니터링한 결과 터널 굴착시 불리한 지반조건에 의해 발생하는 터널붕락 및 과대 여굴 발생은 거의 발생하지 않았다. 일부구간에서 세일의 층리와 같은 불연속면의 영향으로 여굴이 발생하기도 하였으나 굴착공정에 영향을 미치지 못하는 못하였다. 사례1터널과 사례3터널은 터널붕락의 영향으로 작업 중단이 되기도 하였지만 사례2터널 현장은 발파작업시 세일의 층리면 영향으로 여굴만 주로 발생되었다.




그림 17. 사례3 터널 막장관찰도

4.3 사례3-경부고속철도 ○○터널 지반상태

본 터널은 총 연장 6.3km이며 480m의 사경을 가지고 있는데 터널붕락이 발생한 구간은 사경 ○○지점으로써 사경 막장의 2/3 이상이 활석층과 흑연대가 발달하고 있었다 (그림 17 참조). 붕락구간은 지하수의 유입으로 활석 및 흑연이 발달한 부분으로 막장자립이 불가능한 상태이며 암반의 점착력 및 전단강도가 매우 낮은 지반조건이었다. 붕락지역은 심하게 파쇄된 흑연/활석층을 통과하는데 이 층은 매우 연약하며 수직에 가까운 불연속면이 분포되어 있어 RMR 값이 20~30점으로 매우 불량하게 나타났다. 두 개의 주요 불연속면 방향성은 320/60과 074/85이고 이 불연속면은 사경지역을 통과하는 단층지역으로 생각된다. 터널막장의 우측 하부에서 더 단단한 암반이 육안으로 관찰되었으므로 붕락은 단층지역 상반에서 발생한 것으로 분석된다. 터널막장에 있는 두 단층의 교차지역은 쉐기형 암반이 주변 암반으로부터 분리되기에 충분한 공간을 제공하였다.

4.4 추론값과 조사값의 비교

표 2에는 위 절에서 설명한 각기 다른 지반조건을 갖는 터널 현장에 대하여 터널 붕락 형태와 붕락 규모를 인공신경망을 이용한 Geo-Predict 시스템으로 각 지반조건을 입력한 후 최적모델로 선정된 매개변수를 기초로 추론한 결과와 사고 발생 후 조사자에 의한 조사 결과를 상호 비교 분석 하였다.

4.4.1 터널붕락 형태 추론

표 2에서 T-S-S(Time-Stability-Support), 즉 터널 굴착 경과 시간에 따른 지보설치 및 안정성 관계는 큰 오차를 보이지 않고 추론값과 조사값이 거의 일치하였다. 이것은 데이터베이스된 자료 즉, 인공신경망 학습에 이용된 자료와 사례현장들이 모두 지반조건이나 보강에 관계없이 붕락 혹은 여굴이 발생된 현장의 지반조사 자료를 사용했기 때문으로 분석된다. 그리고 터널 붕락 추론 모델의 다른 결과들 중에서 Overbreak, Block fall 항목은 큰 오차를 보이고 있다. 이것은 Geo-Predict의 터널붕락 추론 모델의 데이터 베이스는 주로 산악터널의 신선한 암반에서 불연속면의 조합에 의해 발생한 터널붕락 혹은 파대여굴이 발생했던 자료(그림 6 참조)인데 비하여 사례1은 천심도의 풍화암

내지 연암에서 굴착된 터널이고 사례3은 산악터널이지만 터널막장 전구간에 활석과 흑연이 존재하여 전단강도 등 암반의 자립이 사실상 불가능한 특수한 지반이었기 때문에 추론값과 조사값이 오차를 보인 것으로 분석되고 사례 2 터널은 층리가 발달한 지반에서 굴착된 터널이지만 산악터널이고 비교적 신선한 암반에서 굴착된 터널이기 때문에 추론값과 조사값이 큰 오차를 보이지 않고 있다. 그리고 Wall fall, Wedge fall 항목은 사례 1, 2, 3 현장에서 전문가 시스템을 이용한 추론값과 조사자에 의한 조사값이 모두 비슷한 결과를 보였다.

4.4.2 터널붕락규모 추론

그림 12의 개념도에서 보듯이 터널붕락 규모 추론 모델은 국내에서 발생되었던 터널붕락 자료를 기본 자료로 이용하여 그림 15와 같이 분류한 터널붕락 형태와 터널붕락 규모를 추론하였다. 표 1에서 인공신경망을 이용한 터널 붕락 형태 추론은 조사값과 추론값이 큰 오차를 보이지 않고 비슷한 붕락 패턴을 보였으나 붕락규모 추론은 사례1, 사례2, 사례3 현장에서 모두 조사값보다 추론값이 크게 분석되었다. 이것은 인공신경망 학습을 위한 입력자료의 문제로 분석된다. 앞장에서도 언급하였듯이 터널 붕락이 발생할 때 특히 붕락 규모는 화약사용량, 천공방법, 지보시간 등에 따라 상당한 차이를 보이는데 비하여 본 시스템에 입력된 자료는 현장여건 등으로 붕락 규모에 영향을 미치는 요인들이 충분히 입력되지 못했기 때문으로 분석된다. 또한, 지반조건이라는 불확실성이 내재된 자료를 입력할 때는 터널 붕락의 원인과 결과가 체계적으로 분류되어야 좋은 결과를 얻을 수 있는데 지반의 특성상 정량적인 자료 보다는 주로 정성적인 자료가 많이 입력되었기 때문으로 분석된다. 또한 인공신경망 학습자료가 모두 터널 붕락이 발생했을 경우에 조사된 지반조사 자료가 입력되었으므로 사례2 터널과 같이 지반조건이 양호하고 굴착 후 일부 여굴이 발생한 현장에서도 실제 조사값보다 추론값이 과장되게 추론되었다.

5. 결론

본 연구에서는 터널 굴착시 불합리한 지반조건하에서 발생하는 터널붕락 형태나 규모, 위험구간을 예측하기 위하여 국내외 터널붕락 자료를 수집하여 지반 조건별로 발생하는 터널붕락 형태를 분석하여 보았다. 분석된 자료는

표 2. 인공신경망의 추론값과 조사값

항목		터널 붕락 추론 모듈						터널 붕락 규모 추론 모듈	
		T-S-S	Overbreak	Block fall	Wall fall	Wedge fall	Collapse	형태	규모
사례1	조사값	7	0	1	0	0	0	3	200
	추론값	5.25	1.83	1.04	-0.01	0.00	0.00	4.75	289.43
사례2	조사값	2	1	0	0	0	0	4	10
	추론값	1.01	0.11	-0.07	-0.01	-0.04	0.01	2.11	40
사례3	조사값	8	1	0		0	1	3	25
	추론값	7.13	2.29	0.69	-0.02	-0.01	0.08	3.57	35.44

(T-S-S : Time-Stability-Support의 관계에 따라 1~8 등급을 분류(Cecil, 1964), Overbreak : 여굴 정도에 따라 0~3 등급으로 분류, Block fall : 낙진 형태에 상관없이 천장부, 측면부에서 불연속면에 의해 발생하는 붕락, 특히 퇴적암지대에서 층리와 수직결리의 조합에 의한 중력 낙하, Wall fall : 터널 측벽에서 발생하는 전도형 파괴, Wedge fall : 불연속면의 조합에 의한 쉐기럼의 붕락, Collapse : 락장면의 지립이 불가능한 연약대 등에서 락장 전진 혹은 일부에서 발생하는 붕락 형태 · 그림 15 참조, 규모 : 터널 붕락 규모(m³))

데이터베이스를 구축, 인공신경망을 이용하여 터널붕락 형태와 규모를 추론 할 수 있는 Geo-Predict를 개발하고 이를 지하철 현장 및 고속철도 현장에 적용시켜 보았으며 본 연구를 통하여 다음과 같은 결론을 얻었다.

- (1) 국외터널 자료는 2/3이상이 지하양수발전소 건설에 따른 도수터널이며 터널이 위치한 지반의 암석 종류는 심성암류와 변성암류가 대부분을 차지하고 있다. 터널막장에서의 지하수 상태는 "no water"에서 "large water"사이에서 균등하게 분포하고 있으며 막장 주변의 절리군의 분포는 1~2개의 주절리군과 불규칙 절리가 발달하는 것으로 분석되었다. 터널 막장 주변의 RQD는 50% 이상이 전체의 절반이상을 차지하고 있으며 붕락심도는 50m이상의 심도가 70%이상을 차지한다.
- (2) 국내터널 자료는 지하철 터널과 도로터널에 관한 자료가 많았으며 터널지반의 암반종류는 심성암류와 편마암류가 많았다. 지하수는 "minor water"에서 "minor flow"가 많았고, 절리군은 두 개 이상이며 조사막장의 RQD는 모두 50% 이하로 암질이 불량하였다. 터널심도는 30m이하의 천심도가 주를 이루었고 암반을 풍화도에 따른 분류를 하면 풍화암과 연암이 대부분이며 절리상태와 절리간격을 RMR 분류기준에 의해 분류하면 4~5등급의 열악한 상태였다.
- (3) 본 연구에서는 국내외 터널 붕락 자료를 데이터베이스화하고 인공신경망을 이용하여 지반조건에 따른 터널 붕락 형태와 붕락 규모를 추론할 수 있는 전문가 시스템인 Geo-Predict를 개발하였다.

- (4) 개발된 Geo-Predict를 실제 현장의 3개 터널에 적용한 결과, 터널 붕락 추론 모듈의 T-S-S, wall fall, wedge fall 항목은 조사값과 추론값이 유사하였으며, overbreak, block fall 항목은 큰 차이를 보였다. 이것은 데이터베이스된 자료들이 모두 붕락 현장에서 조사된 자료가 입력되었으므로 터널 굴착 경과 시간과 지보와 안정성과의 분석은 유사한 값을 갖는 것으로 추론되었고, 기타 다른 항목들은 데이터베이스된 자료들은 대부분 지하심부에서 절리군의 조합에 의한 붕락이 발생한 자료가지만 사례연구에 인용된 자료들은 모두 천부의 풍화암 내지 연암의 자료들이 입력되었으므로 조사값과 추론값이 큰 차이를 보이는 것으로 분석된다.
- (5) 터널 붕락 규모 추론 모듈에서 터널을 중심으로 분류된 붕락 형태는 조사값과 추론값이 비슷하였으나 붕락 규모 추론은 큰 차이를 보였다. 입력된 데이터베이스는 모두 터널 막장에서 조사된 지반조사 항목들이 입력되었지만 터널붕락 규모에 영향을 미치는 천공방법, 화약사용량, 지보 설치 시간 등 지반특성 외적인 자료들이 입력되지 못했기 때문에 조사값보다 과장되게 추론된 것으로 분석된다.

참고문헌

1. 대한토목학회(1992), "지하철5호선 5-14공구 터널사고원인 및 복구 대책 연구용역", pp. 7~36
2. 마상준, 서경원(1999). "NATM 개념 터널에서의 붕락 패턴에 관한 국내외 사고사례 조사 및 분석", 터널기술, 제1권 제2호 pp. 81~91
3. 삼부토건주식회사(1996), "서울지하철 5호선 5-18공구 건설공사 한강하저터널 지반분석 및 보강공법", pp. 91~123
4. 양형식, 김재철(1999). "인공신경망을 이용한 한국형 터널 암반분류",

- 터널과 지하공간, 제9권, 제3호, pp. 214~220
5. 친병식, 정덕교(1999), "국도3호선 터널공사 공사 중 붕락구간에 대한 지반보강, '99학술발표회", pp. 14~22
 6. 한국건설기술연구원(1998), "Neural Network을 이용한 터널 설계 적정성 평가용 Expert System 개발(I)". pp. 10~30
 7. 한국건설기술연구원(1999), "고속전철 교량/터널 구조 및 유지관리 시스템 개발", pp. 73~137
 8. 한국지반공학회(1993). "345KV 당인리-중계 펌프장간 지중 T/L 전력구 전선공사 붕락지역 사고원인 및 보강방안 연구 검토", pp. 2~61
 9. Chencho Lee(1992), "Identification of Failure mechanism of Underground Openings by Approximate Reasoning System", A Thesis Submitted to the Faculty of the School of the University of Minnesota. pp. 18~53
 10. HSE(Health and Safety Executive, 1996). "Safety of New Austrain Tunnelling Method(NATM) Tunnels", pp. 14~21
 11. Kwang Joon Park and In Keun Lee(1993), "Modes and Causes of Collapse of Subway Tunnels", Proceeding of March 1993 National Conference of Geotechnical Engineering and Tunnelling Technology, Seoul Korea, pp. 41~48
 12. Ma. S. J., Bae K. J., Seo. K. W., Lee. S. W(2000) "A study on the application management system in tunnel construction", EUROCK 2000 Symposium 14th National Symposium on Rock Mechanics and Tunnelling, pp 513~519
 13. Owen Sinclair Cecil(1964), "Correlations of Rock Bolt-Shotcrete Support and Rock Quality Parameters in Scandinavian Tunnels", Ph D Thesis, Univ Illinois, pp. 251~374
 14. Yang. Y and Zhang. Q(1997), "A Hierarchical Analysis for Rock Engineering Using Artificial Neural Networks", Rock Mechanics. Rock Engineering, 30(4), pp. 207~222

(접수일자 2000. 6. 29)