

인공신경망 기법을 이용한 터널 붕괴 예측에 관한 기초 연구

A Basic Study on the Prediction of Collapse of Tunnels Using Artificial Neural Network

김 홍 흠¹ Kim, Hong-Heum

임 희 대² Lim, Heui-Dae

Abstract

Collapse of a tunnel can occur anytime, anywhere due to the special characteristics of tunnel structures and unexpected geological conditions during construction. Tunnel collapse will lead to economic losses and casualties. So various studies are continually being conducted to prevent economic losses, casualties and accidents. In this study, we analyzed data from 56 domestic construction tunnel collapse sites, and input factors to be applied to the artificial neural network were selected by the sensitivity analysis. And for the artificial neural network model design studies were carried out with the selected input factors and optimized ANN model to predict the type of tunnel collapse was determined. By using it, in 12 sites where tunnel collapse occurred applicability evaluation was conducted. Thus, the tunnel collapse type predictability was verified. These results will be able to be used as basic data for preventing and reinforcing collapse in the tunnel construction site.

요 지

터널에서의 붕괴는 터널 구조물의 특수성 및 예상치 못한 지반조건의 변화로 인해 언제 어디서든 발생할 수 있다. 그로 인한 경제적인 손실과 인명피해를 줄이기 위하여 사고를 미연에 방지하기 위한 방안에 대한 다양한 연구들이 계속 진행되고 있는 실정이다. 본 연구에서는 붕괴예측을 위하여 국내 터널 붕괴 현장 56개소의 시공데이터를 분석하고 인공신경망 기법에 적용할 입력인자를 민감도 분석으로 선정하였다. 또한 인공신경망 모델 설계는 선정된 입력인자로 학습을 수행하고 터널 붕괴 유형 예측에 최적화된 모델을 결정하였다. 이 모델을 이용하여 붕괴가 발생한 총 12개소에 적용성 평가를 실시하여 터널 붕괴 유형 예측 가능성을 검증하였다. 이러한 결과는 터널 시공 현장에서 붕괴 예방을 위한 기초 자료로서 활용 될 수 있을 것이다.

Keywords : Collapse, Tunnel, ANN (Artificial neural network), Sensitivity analysis, Training

1 정회원, 감사원 기술서기관 (Member, Deputy Director, Board of Audit and Inspection of the Republic of Korea, Tel: +82-2-2684-2016, Fax: +82-2-2011-2345, khh0753@korea.kr, Corresponding author, 교신저자)

2 정회원, 충남대학교 토목공학과 교수 (Member, Prof. Dept. of Civil Engrg., Chung Nam National Univ.)

* 본 논문에 대한 토의를 원하는 회원은 2016년 8월 31일까지 그 내용을 학회로 보내주시기 바랍니다. 저자의 검토 내용과 함께 논문집에 게재하여 드립니다.

1. 서론

터널은 자연적으로 생성된 지반 및 암반을 대상으로 하기 때문에 대상 재료의 불확실성과 불균질성, 불연속성, 구조적 복잡성 등 매우 다양한 특성을 가지므로 교량, 건축물들과 같은 일반적인 토목구조물들과는 다른 큰 차별성을 가진다. 터널시공이 이루어지는 대상이 이렇게 복잡한 특성을 갖기 때문에 그 특성을 명확히 판단하는 즉, 인간이 제조하는 재료와는 달리 지반 및 암반이 어떻게 거동할지를 예측하는데 있어서 터널 굴착 시 지반이나 암반에 대한 명확한 거동특성을 분석하는 것은 매우 어렵다고 할 수 있다. 특히 과거 여러 차례 큰 지구구조적인 지각운동과 변성작용을 겪은 국내 지질학적 특성으로 인해 터널공사는 단층대, 지층의 변화가 심한 연약대, 계곡부, 공동, 용출수 구간 등 취약구간에서 대규모 및 소규모의 붕괴사고가 발생하고 있다. 이와 같은 터널의 특수성으로 인하여 시공 중 이나 시공 후 터널 붕괴의 발생으로 인해 막대한 경제적 손실 및 인명피해가 발생하고 있다. 터널의 붕괴에 대한 사례는 국외뿐만 아니라 국내에서도 계속적으로 보고되고 있는 실정이다(Anderson, 1997; Lee et al., 2007).

현장에서 획득 가능한 자료는 지반조건, 구조물 현황 및 구조물의 안정성 등의 다양한 정보를 내포하고 있다. 이러한 다양한 정보를 이용한 터널 붕괴 예측에 관한 연구(Shin et al., 2009)가 진행되었지만 실제 시공 현장에서의 적용은 미흡한 실정이다.

본 연구에서 개발하고자 하는 터널 붕괴 예측 시스템은 시공 현장에서 획득 가능한 지반 및 터널 정보(기하학적 특성과 지반조건, 불연속면조건, 지하수조건, 굴착조건, 지보/보강수준 등)를 이용하여 인공신경망 기법(artificial neural network)을 통해 정량적인 터널 붕괴 유형을 예측하는 것이다. 이를 바탕으로 터널 붕괴 가능성을 예측할 수 있으므로 시공 현장에서 사전 보강 및 대책 수립으로 붕괴에 대한 피해관리가 가능할 것으로 판단된다.

터널 붕괴 예측 시스템 개발을 위한 기초 연구방법은 첫 번째로 기존 국내 터널 붕괴현장의 시공데이터 수집과 DB화를 구축하고, 터널 붕괴에 영향을 미치는 주요원인 인자들에 대한 민감도 분석을 수행하여 터널 붕괴 유형을 결정할 수 있는 입력요소와 출력요소를 선정하였다. 둘째는 선정된 요소들을 통해 터널 붕괴 유형을 예측할 수 있는 최적화된 인공신경망 모델 설계

및 검증을 수행하였다. 그리고 마지막으로 현장 적용성 평가를 통해 붕괴유형의 예측 가능성을 검증하였다. 적용 프로그램은 다양한 분야에서 사용하고 있는 NeuroDimension 社에서 개발한 인공신경망 상용 소프트웨어인 Neuro Solutions™ version 4.3.2를 인공신경망 모델 구축을 위한 도구로 사용하였다(Hwang, 2004; Nam, 2008).

2. 국내 터널 붕괴 현황 및 고찰

먼저 터널 붕락과 관련된 선행 연구 결과들을 검토해 보았다. 여러 연구 들 중 터널 붕락에 영향을 주는 여러 요소들을 영향인자로 분류한 Jeong(2008) 및 Kim(2011)의 연구에서는 Table 1과 같이 환산단면적, 환산심도비, 암석강도, RQD/N치, 막장풍화도, 절리면 상태, 불연속면의 기하학적 상태, 지하수 유입량, 환산지하수위, 굴착방법, 굴착성능(여굴), 지보패턴 수준, 보조공법 유무, 붕괴 유형, 붕괴 규모 등 15개 항목이 터널 붕락에 영향을 미치는 영향인자로 선정하였다.

이후 Korea Institute of Construction Technology(2009)의 연구에서 국내 56개소의 터널 붕괴 현장 자료를 수집하고, 영향인자 분류와 분석을 실시하여 Table 2와 같이 정리 하였다.

조사된 총 56개소의 터널 붕괴 현장자료를 터널의 용도별로 구분해 보면 도로터널 42.9%, 지하철터널 42.9%, 철도터널 7.1%, 기타(여수로, 전력구) 7.1%로 구성되어 있으며 Fig. 1과 같다.

터널 붕괴 데이터베이스 자료에 대한 통계 분석은 Fig. 2와 같다.

터널 붕괴 자료 주요인자 분석 결과, 터널 환산 단면적은 70~120m²가 55.4%로 가장 높게 나타나며, 45m² 이상의 터널이 전체 터널의 89.3%로 터널의 대단면화 추세의 경향을 보였다. 터널환산심도는 중심도(4.5~2.5)가 44.6%로 가장 높게 나타났으며, 중심도 및 저심도(2.5~1.0)가 전체의 83.9%를 차지하고 있다. 암종은 일축 압축강도 150~100MPa에서 44.6%로 가장 높게 나타났으며, 100MPa 미만이 55.4%로 나타났다. 암질상태(RQD)는 25~10에서 37.5%로 가장 높게 나타나며, 25이하가 75%를 차지하고 있다. 막장풍화도는 심한풍화에서 53.6%로 나타나며, 보통풍화 이하가 전체 풍화도의 96.4%를 차지하고 있다. 불연속면 상태는 불리한 조건(IV 등급) 이하가 73.2%를 차지하고, 터널 굴진방향에 대한

불연속면의 방향성은 굴진방향의 역경사 45°~90°에서 30.4%로 가장 높게 나타났다. 지하수 유입량은 집중용수(flowing)와 벽면을 타고 흐름(dripping)이 전체의 약 73.2%를 차지하고, 환산 지하수위는 1~5에서 64.3%로 가장 높게 나타났다. 굴착조건 지반은 토사지반이 50%로 나타났으며, 토사지반, 팽창성지반, 막장자립 불량지반이 89.3%로 나타났다. 굴착성능(여굴량)은 양호(100%~105%)가 58.9%로 가장 높게 나타났다. 지보 패턴 수준은 설계기준 패턴과 적용패턴이 동일한 경우에서 58.9%로 가장 높게 나타났다. 보조공법 적용은

풍화암 및 풍화토에서 89.3%로 나타났다. 붕괴유형은 천정부 붕괴가 46.4%로 가장 많이 발생한 것으로 나타났다. 붕괴규모는 0~50m³에서 35.7%로 가장 많이 발생하였다.

터널 시공 시 굴착으로 인해 지반은 지반변형과 응력의 재배치가 발생하고 지반의 거동이 일어난다. 지반의 거동은 지반조건, 지질상태, 주변 지하수 유입상태, 굴착방법, 막장상태 등의 다양한 조건들에 따라 발생한다. 그러나 지반의 이상거동이 발생하면 응력의 평형이 깨지면서 구조물의 파괴가 일어날 수 있다. 기존 붕괴사

Table 1. Classification table for tunnel collapse effect factor

Item	Contents			Value	
(1) Geometrical characteristic	(1-1) Tunnel equivalent section area (m ²)			0~10	
	Under 20[0], 20~45[2], 45~70[4], 70~120[6], 120~200[8], more than 200[10]				
	(1-2) Depth ratio (Z ₀ /D)			0~10	
	Under 7[0], 4.5~7[3], 2.5~4.5[6], 1~2.5[8], more than 1[10]				
(2) Condition of ground	(2-1) Rock type	Rock type	Hammer strike	Unconfined compressive strength	0~10
		Diabase, Quartz, Quartzite	Very strong blow	> 150 MPa [0]	
		Granite, Gneiss, Conglomerate	Strong blow	100 ~ 150 MPa [3]	
		Marble, Schist, Limestone	1st blow	50 ~ 100 MPa [6]	
		Shale, Slate	Hammer crushed	10 ~ 50 MPa [8]	
		Tuff, Siltstone	Hand crushed	10 MPa > 0 [10]	
	(2-2) RQD / N values	75 < RQD < 100 [0]			0~10
		50 < RQD < 75 [2]			
		25 < RQD < 50 [4]			
		10 < RQD < 25 [6]			
		RQD<10	N ≥ 50 [8] N < 50 [10]		
	(2-3) Weathered degree	Fresh (F) [0]			0~10
		Slightly weathered (SW) [3]			
		Moderate weathered (MW) [6]			
		Highly weathered (HW) [8]			
Completely weathered (CW)					
(3) Conditions of discontinuities	(3-1) Conditions of discontinuities	I grade [0]			0~10
		II grade [3]			
		III grade [6]			
		IV grade [8]			
		V grade [10]			
	(3-2) Geometrical condition of discontinuities	Dip dir. 45°~90° [0]			0~10
		Dip dir. 20°~45° [3]			
		Reverse dip dir. 45°~90° [6]			
		Reverse dip dir. 20°~45° [8]			
		Dir. 45°~90° of strike parallel to tunnel axis [10]			

Table 1. Classification table for tunnel collapse effect factor (Continued)

Item	Contents			Value	
(4) General conditions of groundwater	(4-1) General conditions of groundwater	General conditions		ℓ/min	
		Completely dry		< 5 [0]	
		Damp		5~10 [3]	
		Wet		10~25 [6]	
		Dripping		25~125 [8]	
		Flowing		> 125 [10]	
	(4-2) Groundwater level	< 0 [0]			0~10
		0~1 [2]			
		1~5 [4]			
		5~10 [6]			
		10~20 [8]			
		> 20 [10]			
(5) Conditions of excavation	(5-1) Method of excavation	Full face [0]			0~10
		Long bench [3]			
		Short bench [6]			
		Mini bench [8]			
		Multiple bench [10]			
	(5-2) Performance of excavation	Blast excavation over break(%)	Mechanical excavation Operation efficiency(%)	Excavation result	0~10
		< 100	< 100	Very good [0]	
		100~105	100~105	Good [3]	
		105~110	105~110	Moderate [6]	
		110~120	110~120	Poor [8]	
		120 <	120 <	Very poor [10]	
	(6) Support & Reinforcement	(6-1) Support pattern	Support	Standard	Grade
Shotcrete thickness (cm)			12 cm	Standard<application = 0 Standard=application = 1 Standard>application = 2	
Rockbolt length (m)			4 m		
Rockbolt distance (m)			1.5 m		
Steel rib distance (m)			1.5 m		
Round length (m)			1.0~1.5 m		
(6-2) Reinforcement of ground		Hard rock [0]			0~10
		Soft rock [3]			
		Weathered rock [6]			
		Weathered soil [8]			
		Does not apply [10]			
(7) Type of collapse		(a-1)	Crown failure [1]		1~4
	(a-2)	Weakness strata failure [2]			
	(a-3)	Full face failure [3]			
	(a-4)	Overburden failure [4]			

례를 살펴보면, 토사지반이나 팽창성 지반에 시공되는 터널은 지하수 영향이 가장 큰 붕괴요인으로 작용하고 있으며, 연약지반 통과 터널은 연약대의 방향성에 의해 슬라이딩 형태의 붕괴가 발생하였다. 또한 암반에 시공되는 터널은 대부분 파쇄대, 단층대 그리고 굴착방향에 불리한 방향성을 갖는 불연속면에 의해 암반이 슬라이딩 형태와 썩기파괴의 붕괴가 발생하였다. 국내에서 발

생된 붕괴는 대부분 저심도 구간에 위치하며, 주변 지반은 풍화암과 풍화토로 분포하고 있다. 그러므로 저심도에서의 터널 시공은 대부분 불량한 지반조건으로 인해 막장 자립에 불리하게 작용하거나, 굴착면으로 지하수 유입이 과다한 경우에 붕괴가 일어났다. 또한 불량한 지반에서의 신속하고 적절한 지보보강이 이루어지지 않았을 때 붕괴가 발생하였다.

Table 2. Database for tunnel collapse cases

No	Input factor													Output factor
	1	2	3	4	5	6	7	8	9	10	11	12	13	Type of collapse
	Tunnel equivalent section area	Depth ratio (Z ₀ /D)	Rock type	RQD/N values	Weathered degree	Conditions of discontinuities	Geometrical condition of discontinuities	General conditions of groundwater	Ground water level	Method of excavation	Performance of excavation	Support pattern	Reinforcement of ground	
1	0	0	8	6	8	8	8	10	4	10	8	10	6	1
2	6	8	10	6	10	8	6	6	4	6	8	0	8	1
3	8	8	3	10	8	8	8	0	4	6	8	10	6	4
4	8	10	8	6	6	6	6	8	6	8	6	5	6	3
5	6	8	3	6	6	6	6	8	4	6	6	10	6	2
6	6	8	8	6	8	6	8	3	6	3	6	5	6	3
7	4	6	8	6	6	6	3	6	4	6	6	5	6	4
8	6	6	6	10	3	8	3	8	6	8	6	0	8	2
9	2	6	3	4	3	6	3	3	6	6	3	5	6	3
10	4	6	3	4	6	6	8	8	6	8	3	5	3	3
11	6	6	3	4	6	8	6	8	8	6	3	5	6	2
12	8	0	3	6	6	8	8	10	8	8	8	5	6	3
13	6	10	3	10	8	8	10	10	4	8	8	5	8	1
14	4	8	3	4	6	8	8	8	10	3	3	5	3	1
15	6	8	3	4	6	6	8	8	6	6	6	5	8	1
16	6	8	3	6	8	6	6	8	4	6	6	5	8	4
17	4	6	8	6	8	8	6	8	10	10	6	5	8	2
18	4	8	8	6	8	8	6	8	10	10	6	5	8	2
19	4	6	3	8	8	8	6	8	4	6	3	10	6	2
20	6	6	8	6	8	8	3	8	6	6	6	0	6	4
21	4	6	3	4	8	8	6	10	4	6	6	5	8	1
22	4	8	8	8	6	3	0	6	4	6	3	5	8	4
23	2	8	6	10	8	6	3	6	4	8	6	5	8	1
24	6	8	6	10	6	8	6	6	4	3	6	5	6	1
25	4	8	3	4	8	8	0	10	2	6	3	10	6	4
26	2	6	3	6	6	10	10	6	6	6	6	5	6	1
27	4	6	10	4	8	6	8	8	4	3	6	5	6	1
28	8	8	3	8	8	8	3	8	8	6	6	0	6	1
29	6	6	8	10	10	8	3	6	4	6	6	5	8	1
30	6	6	6	10	8	8	6	10	4	6	6	10	8	3
31	6	6	6	4	6	6	6	10	6	10	3	5	3	2
32	6	6	3	6	6	8	10	8	4	6	6	5	3	1
33	6	6	8	4	8	8	6	6	4	8	6	5	8	1
34	6	8	8	6	8	8	6	8	4	10	6	0	8	2
35	6	8	3	8	6	8	3	10	2	8	6	0	6	4
36	2	8	8	8	8	6	0	8	4	6	3	5	8	2
37	6	8	8	8	8	8	0	6	6	6	6	5	6	1
38	4	6	3	4	8	8	0	10	4	6	3	0	6	4
39	6	6	8	6	8	6	3	8	4	6	6	5	8	1
40	6	8	8	8	8	8	10	8	4	6	8	5	8	1
41	6	8	6	8	8	10	10	8	4	8	6	0	8	1
42	6	0	3	6	8	8	6	6	4	8	8	10	8	1
43	6	6	6	4	8	8	8	8	4	6	8	5	8	2
44	2	6	3	6	6	6	6	10	4	8	6	5	8	1
45	4	8	8	10	8	8	8	3	6	6	6	5	6	1
46	6	3	8	8	10	8	8	8	4	6	6	0	8	2
47	6	3	8	10	10	8	0	10	4	6	8	0	8	4
48	6	6	3	8	8	10	10	10	4	8	6	5	6	4
49	6	8	3	10	8	8	10	8	4	6	6	5	6	1
50	6	6	8	6	6	8	3	8	4	3	3	0	3	1
51	6	0	3	6	6	8	6	6	4	10	6	5	6	1
52	8	6	8	8	6	10	8	8	4	8	6	4	6	2
53	8	3	6	4	6	10	10	10	6	8	6	4	6	2
54	10	8	6	6	8	10	10	10	4	8	8	4	6	2
55	6	6	3	6	8	10	8	10	4	8	3	10	6	1
56	6	6	3	2	6	8	8	8	4	3	3	10	3	1

3. 터널 붕괴 예측 모델 개발

3.1 연구 방법 및 적용 이론

인공신경망 기법을 이용한 터널 붕괴 예측시스템 개발을 위한 기초 연구는 다음의 두 단계로 수행하였다. 1단계는 터널붕괴 유형을 예측하는 모듈과 2단계는 1단계에서 예측된 붕괴 유형에 대한 현장 적용성 검증을




Fig. 1. Classification of tunnel structure

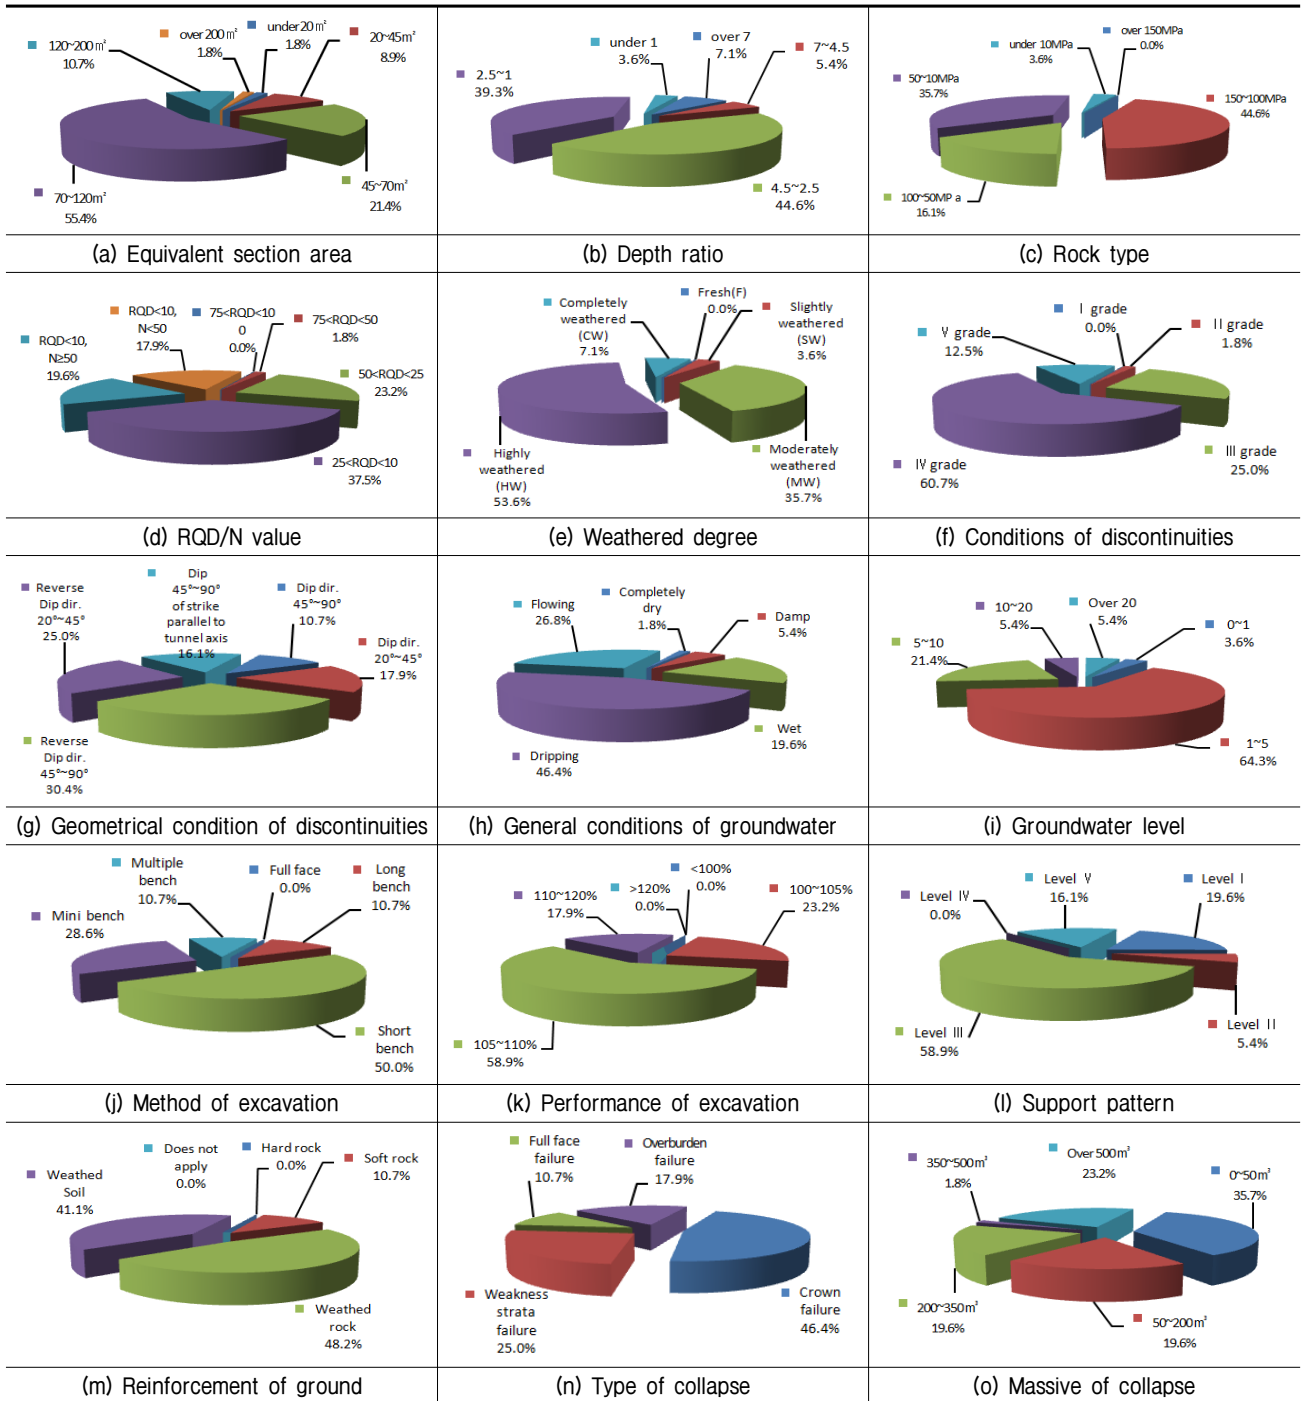


Fig. 2. Statics analysis of input parameters for tunnel collapse

수행하여 터널 붕괴 유형의 예측 가능성을 확인하였다.

인공신경망은 인간이나 동물들이 가지고 있는 생물학적인 뇌의 신경 세포(neuron)를 모델화하여 인공적으로 지능을 만드는 것이다. 즉, 인간의 뇌에 존재하는 생물학적 신경세포와 이들의 연결 관계를 단순화시켜 수학적으로 모델링하여 인간의 두뇌가 나타내는 지능적 형태를 구현하는 것이다. 병렬 분산 정보처리 시스템인 인간의 두뇌를 수학적으로 모델링하여 만든 인공적인 두뇌를 공학이나 기타 여러 분야에 적용시키려고 하는 것이 인공 신경망의 연구 목적이며, 현재 여러 과학 분야에서 성공적으로 적용되고 있다(Kim, 2011).

본 연구에서 인공 신경망 기법의 학습방법 중 하나인 오차 역전파(Error Back Propagation, EBP) 학습 알고리즘을 터널 붕괴 예측에 적용하여, 인공 신경망 기법이 터널붕괴의 합리적인 예측방법으로 적용될 수 있는지의 가능성을 검토하였다.

3.2 모델 요소 선정

인공신경망의 입력요소(input factor) 및 출력요소(output factor) 선정은 기존 연구에서 터널 붕괴에 영향을 주는 다양한 인자(Kim, 2011; Jeong, 2008)를 적용하였으며, Table 3과 같다. 입력요소는 기하학적 특성[터널환산단면적, 터널환산 심도비], 지반조건[암종, RQD/N치, 막장 풍화도], 불연속면조건[불연속면 상태, 불연속면 기하학적 특성], 지하수조건[지하수 유입량, 지하수위비], 굴착조건[굴착방법, 굴착성능], 지보/보강수준[지보패턴

수준, 보조공법]으로 총 13개의 입력요소로 선정하였으며, 각 인자들은 0~10점으로 수치화하여 데이터베이스를 구축하였다. 출력요소는 붕괴유형별로 천정부 붕괴(1), 연약대 붕괴(2), 전막장 붕괴(3), 토피층 함몰(4)로 분류하였고, 1~4로 수치화하여 데이터베이스를 구축하였다.

인공신경망 설계 시 입력요소가 많을수록 기하급수적으로 많은 입력자료(input data)를 필요로 하게 된다. 또한 앞서 선정한 입력요소 중에서 인공신경망 설계 시 붕괴유형 결과에 미치는 민감도(영향도)가 낮은 입력요소를 배제함으로써 인공신경망 모델의 크기, 네트워크의 복잡성 및 학습시간을 단축하여 효과적인 모델을 설계할 수 있다.

본 연구에서는 최적의 입력요소 선정을 위해 기존 연구를 토대로 선정한 13개 항목의 입력요소와 출력요소 사이의 관계에 대해 민감도 분석(sensitivity analysis)을 수행하였다. 민감도 분석은 모델의 입력요소와 출력요소 사이에서 상관관계를 도출하는 방법이다. 즉 신경망 입력요소 항목에 약간의 변화를 발생시켜 출력요소에 일치하는 변화를 백분율(%)로 나타내어 판단한다. 이를 통하여 각 입력요소 항목에 대해 출력요소에 미치는 민감도 즉, 영향 정도를 알 수 있다.

민감도 분석은 총 2단계로 걸쳐 수행되었으며 결과는 Fig. 3(a)와 Fig. 3(b)에 나타나 있다. Fig. 3(a)은 1단계 결과로서 상관계수가 가장 크게 나타난 $r = 0.982$ 의 경우 터널환산단면적(8.26%), 터널환산심도비(6.14%), 암종(6.23%), RQD/N치(7.45%), 막장풍화도(6.46%), 불연속면

Table 3. Input and output factors

Item	No.	Contents	Value
Input factor	1	Tunnel equivalent section area (m^2)	0~10
	2	Depth ratio (Z_0/D)	0~10
	3	Rock type	0~10
	4	RQD / N values	0~10
	5	Weathered degree	0~10
	6	Conditions of discontinuities	0~10
	7	Geometrical conditions of discontinuities	0~10
	8	General conditions of ground water	0~10
	9	Ground water level	0~10
	10	Method of excavation	0~10
	11	Performance of excavation	0~10
	12	Support pattern	0~10
	13	Reinforcement of ground	0~10
Output factor	1	Type of collapse	1~4

의 상태(13.30%), 불연속면의 기하학적 특성(8.04%), 지하수 유입량(12.37%), 지하수위(6.96%), 굴착방법(5.89%), 굴착성능(7.34%), 지보패턴수준(6.17%), 보조공법(5.38%)으로 나타났다. 상대적으로 큰 값을 보이는 불연속면의 상태(13.30%), 지하수 유입량(12.37%)을 제외하고는 4개의 입력요소 즉, 터널환산단면적, RQD/N치, 지하수 유입량, 굴착성능은 7.34~8.26%로 유사한 민감도를 나타내고 있다. 1단계에서는 총 13개 입력요소 중에서 민감도 결과값이 상대적으로 작은 7%미만의 입력요소(터널환산심도비, 압중, 막장풍화도, 지하수위, 굴착방법, 지보패턴수준, 보조공법)를 제외시켰다. 2단계에서는 선정된 6개의 입력요소를 이용하여 동일한 방법으로 민감도 분석을 수행하였다. Fig. 3(b)는 2단계 분석결과로서 상관관계수가 0.880인 경우 터널환산단면적(22.45%), RQD/N치(11.55%), 불연속면의 상태(8.18%), 불연속면의 기하학적 특성(23.88%), 지하수 유입량(21.86%), 굴착성능(12.07%)으로 나타났다. 최종 입력요소는 민감도가 10% 이하로 다른 입력요소들에 비해 값이 작은 불연속면 상태 인자를 제외시키고, 5개의 주요 입력요소(터널환산

단면적, RQD/N치, 불연속면의 기하학적 특성, 지하수 유입량, 굴착성능)를 선정하였다. Table 4는 최종 입력요소 및 출력요소를 보여주고 있다.

3.3 모델설계 및 학습

- 자료의 분할

본 연구에서 자료의 분할은 전체데이터를 무작위로 훈련세트(training set), 교차검증세트(cross validation set), 시험세트(testing set)로 구분하였다. 훈련세트는 각 모형의 가중치를 결정하기 위한 데이터이며 학습을 위해 주어진 데이터이다. 교차검증세트는 은닉층의 뉴런의 수를 결정하기 위한 자료이며, 이 자료를 이용하여 모델을 선정할 수 있다. 시험세트는 학습에 대한 모형의 효율성을 평가하기 위해 사용되는 자료이다. 본 연구에 적용한 자료의 분할 비율은 총 데이터(56개)에 대해서 각각 70%(훈련세트, 39개), 20%(교차검증세트, 11개), 10%(시험세트, 6개)로 적용하였다.

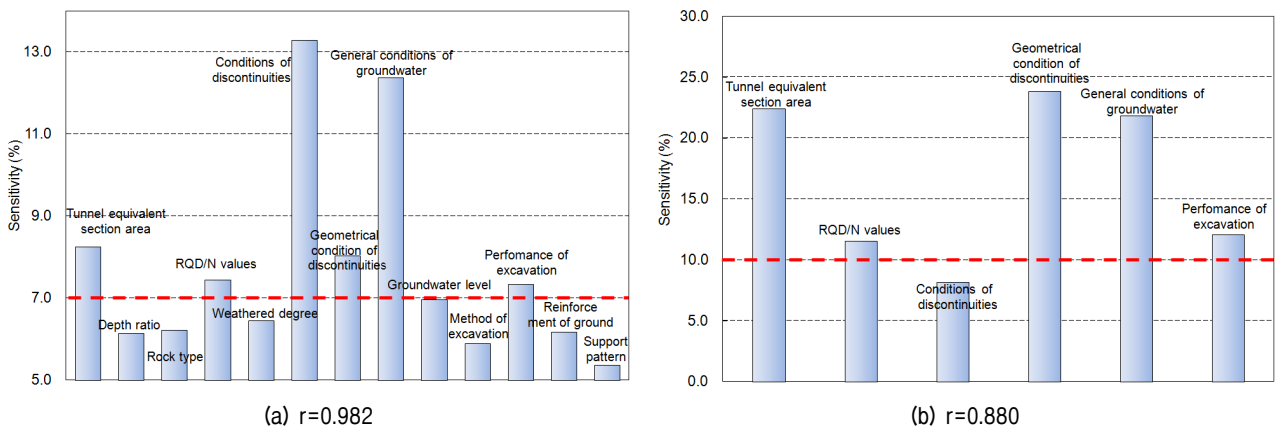


Fig. 3. Results of sensitivity analysis

Table 4. Final input and output factors

Item	No.	Contents	Value
Input factor	1	Tunnel equivalent section area (m ²)	0~10
	2	RQD / N values	0~10
	3	Geometrical condition of discontinuities	0~10
	4	General conditions of ground water	0~10
	5	Performance of excavation	0~10
Output factor (Type of collapse)	1	Crown failure	1
	2	Weakness strata failure	2
	3	Full face failure	3
	4	Overburden failure	4

- 모델 설계

인공신경망 모델의 설계는 신경망을 구성하는 운영인자들을 결정하는 단계로 은닉층 노드 수와 은닉층 수 등의 결정을 포함하며, 입력층과 출력층의 노드 수는 일반적으로 모델의 입력요소와 출력요소 수에 의해 결정된다. 본 연구에서 이용한 입력층의 노드 수는 총 5개 (터널환산단면적, RQD/N치, 불연속면의 기하학적 특성, 지하수 유입량, 굴착성능)로 결정하였으며, 출력층은 붕괴유형(천장부 붕괴, 연약대 붕괴, 전막장 붕괴, 토피층 함몰)으로서 4개의 노드 수를 갖는다. 본 연구에서는 신뢰성 있는 신경망 모델을 개발하기 위해 다양한 은닉층의 수를 검토하였다. 또한 각 은닉층에서 최적의 노드 수를 결정하는 과정 중에서는 인공신경망이 여러 종류의 연결강도를 경험할 수 있도록 충분히 학습을 하는 것과 과잉훈련(over training)을 피하기 위하여 너무 적게 학습하는 것 사이에서 균형을 찾아내는 것이 중요하다. Caudill(1988)에 의하면 일반적으로 5개의 입력요소인 모델의 경우에 어떤 연속함수를 나타내기 위해 필요한 은닉층의 노드 수는 11개 이하 이어야 한다고 제시하고 있다. 본 연구에서는 각각의 은닉층 노드수를 1~11로 변화시킨 조건으로 학습을 수행하였다.

- 학습

학습 또는 훈련(training)이라 함은 처리 요소들 간의 연결강도를 최적화하는 과정을 말한다. 즉, 인공신경망에 주어진 자료를 바탕으로 처리요소들 간의 연결강도를 스스로 조정하는 과정을 학습이라고 한다. 학습의 목표는 설계한 모델의 비선형적인 문제에 대하여 최종 해답을 알아내는 것이다. 신경망에서 쓰이는 전이함수는 비선형적이며 대개 아날로그이다. 신경망에서 많이 쓰이는 대표적 비선형 함수는 시그모이드(sigmoid) 함수와 쌍곡탄젠트(tanh) 함수이다.

본 연구에서는 두 조건의 전이함수를 이용하여 설계한 모델 적용에 더 적합한 전이 함수를 선택하고자 하였다. 인공신경망에 사용된 최적의 운영인자들의 결정은 Table 5와 같이 각각의 인자들을 변화시켜 학습시킨 후 시험(testing)을 통하여 얻어진 신경망의 예측값(desired

data)과 결과값(output data)의 상관관계를 이용하여 최적의 해석 조건을 결정하였다. 해석 조건 방법은 은닉층(hidden layer)과 은닉층 노드수(hidden nodes)를 일정하게 유지하고 모멘텀 상수(momentum term)를 0.7, 0.8, 0.9 각각의 조건에서 학습률(learning ratio)을 0.1~0.9로 변화시켜 학습시킨 후 시험을 통하여 얻어진 신경망의 예측값과 결과값의 상관관계 값을 이용하여 전이함수, 모멘텀 상수, 학습률을 결정하였다. 은닉층 노드수 및 은닉층은 결정된 전이함수, 모멘텀 상수, 학습률을 고정하고 은닉층의 경우 1~6까지, 은닉층 노드수의 경우 1~11로 변화시켜 결정하였다. Lee and Im(2002)에서 일반적인 모멘텀 상수 범위를 0.7~0.9로 제시된 바가 있어, 본 연구에서도 모멘텀 상수를 0.7~0.9로 적용시켰다.

설계된 인공신경망의 수행을 평가하기 위한 주요기준으로 상관계수(correlation coefficient, r)를 사용하였다. 상관계수는 -1~1의 범위를 가지며, r=-1 일 때는 출력값과 예측값의 크기는 같으나 방향성이 서로 다른 것을 의미하고 r이 1에 가까울수록 인공신경망의 예측의 정확도가 높은 것을 나타낸다. Nam(2008)은 Neuro Sloution™에서는 상관계수(r)가 0.88 이상일 경우 출력값과 예측값의 상관성이 높은 것으로 판단할 수 있다고 하였으며, 본 연구에서는 상관계수 값이 0.88 이상인 운영인자들을 결정하였다.

3.4 모델 해석 결과 및 검증

학습에 영향을 미치는 운영인자 즉, 전이함수, 모멘텀 상수, 학습률, 은닉층의 노드수, 은닉층 수를 변화시켜 가며 최적의 조건을 갖춘 인공신경망을 설계하였다. Fig. 4는 학습한 인공신경망 모델 최적 운영인자 결정을 보여주는 결과 그래프이다. Fig. 4(a)는 모멘텀 상수에 대한 전이함수와 학습률의 변화에 대한 상관관계를 보여주고 있다. 쌍곡탄젠트 함수가 시그모노이드 함수보다 상관계수 r=0.891로 더 높은 상관성을 보이므로 전이함수는 쌍곡탄젠트 함수로 결정하였다. Fig. 4(b)는 Fig. 4(a)에서 결정된 쌍곡탄젠트에 대한 모멘텀 상수별

Table 5. Artificial neural network design step

Transfer function	Momentum	Learning ratio	Hidden nodes	Hidden layer
Sigmoid function, Tanh function	0.7, 0.8, 0.9	0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11	1, 2, 3, 4, 5, 6

로 학습률의 변화에 대한 상관관계를 보여주고 있다. 모멘텀 상수 0.9에서 학습률 0.5일 때 상관계수 $r = 0.891$ 로 가장 높게 나타났다. 그러므로 최적 운영인자는 쌍곡탄젠트 함수, 모멘텀 상수 0.9, 학습률 0.5로 결정하고 은닉층 노드수와 은닉층 수 선정에 적용하였다. Fig. 4(c)는 은닉층 노드수를 1~11로 변화시켰을 때의 상관관계를 보여주고 있으며, 노드수 7에서 수렴하는 경향을 보이고 노드수 10에서 $r = 0.938$ 로 가장 높은 상관계수 값을 나타냈다. Fig. 4(d)는 쌍곡탄젠트 함수, 모멘텀 상수 0.9, 학습률 0.5, 은닉층 노드수 10의 조건으로 은닉층 수를 1~6으로 변화시 상관관계를 보여주고 있으며 은닉층의 수가 2개일 때 $r = 0.938$ 로 가장 높게 나타났다.

Table 6은 터널 붕괴 예측을 위한 인공신경망 모델의 주요 운영인자를 정리한 것이며, 상관계수 $r = 0.88$ 이상의 높은 상관성을 보여주고 있다. 터널 붕괴 예측을 위한 최적의 인공신경망 설계는 전이함수 쌍곡탄젠트 함수, 모멘텀 상수 0.9, 학습률 0.5, 은닉층의 노드수 10개, 은닉층 수 2개(은닉층 1개당 노드수 10개)로 설계

하였다.

설계한 모델의 검증은 시험세트(testing set)와 교차검증세트(cross validation set)를 이용하여 인공신경망 모델의 적합성을 결정한다. 평균제곱오차(MSE : Mean Squared Error)는 모델의 정확도를 평가하는 방법으로써 오차들의 평균적인 크기를 의미한다. 독립변수와 종속변수가 각각 한 개일 경우, 일반적인 통계분석에서 사용되는 분산의 제곱근과 동일하다. 그러므로 0에 가까울수록 모델의 정확도가 높음을 의미한다. 평균제곱오차는 신경망의 학습 성능을 비교하는 수단으로 사용되었으며 0에 근접하게 수렴할수록 학습 성능이 더 좋음을 의미한다. Fig. 5는 터널붕괴 예측모델의 최적 운영인자를 이용하여 인공신경망을 학습하는 과정에서 학습 횟수(epoch)에 따른 평균제곱오차를 나타낸 것이다. 본 연구에서는 교차검증세트에 대하여 MSE 0.01, 학습회수 1,000회에 도달하면 학습이 중단되는 것으로 설정하였으며, 검증 결과는 Fig. 5에서 볼 수 있듯이 학습 횟수가 늘어날수록 평균제곱오차 값이 0에 가까이 수렴하는 경향을 보

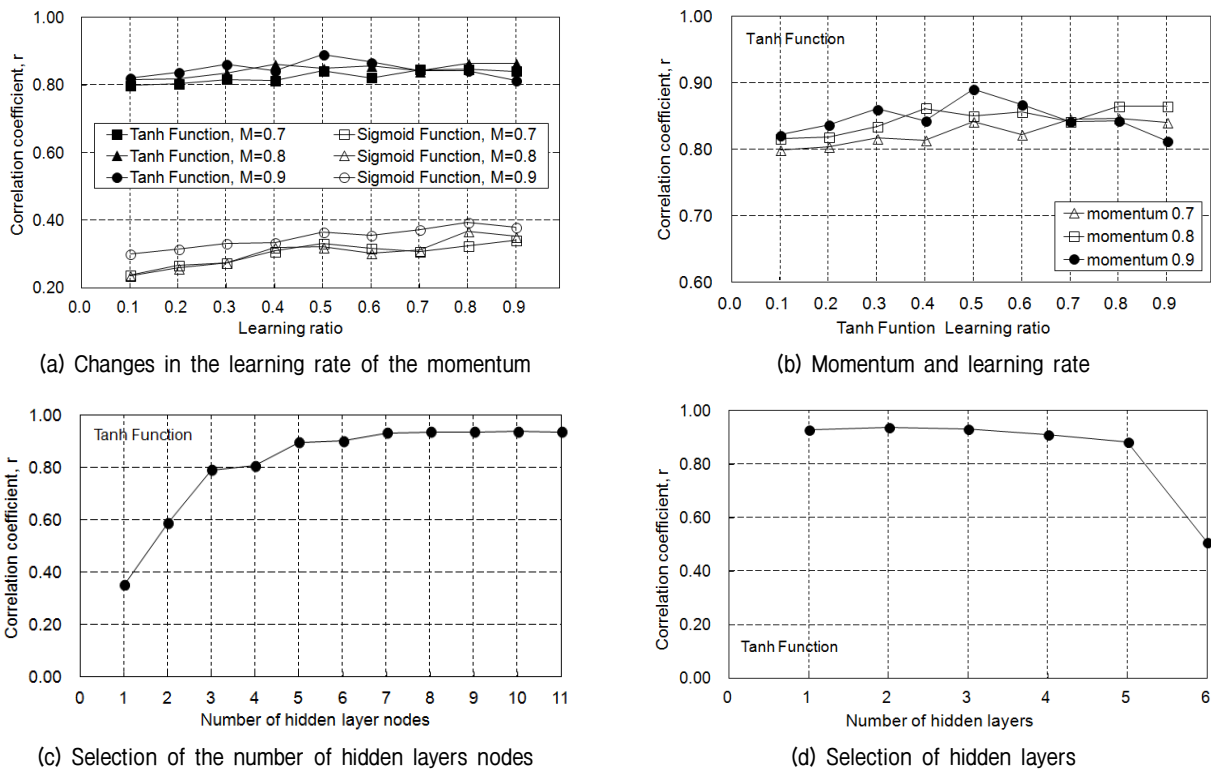


Fig. 4. Correlation results for selection of operation factors

Table 6. Result of operation factors and correlation coefficient in the artificial neural networks

Model	Transfer function	Momentum	Learning ratio	Hidden nodes	Hidden layer
Collapse prediction	Tanh function ($r = 0.891$)	0.9 ($r = 0.891$)	0.5 ($r = 0.891$)	10 ($r = 0.938$)	2 ($r = 0.938$)

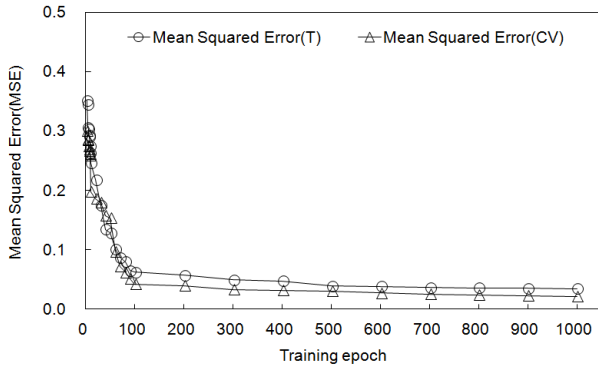


Fig. 5. Mean square error and learning rate

이므로 학습에 대한 신뢰도가 높은 것으로 검증되었다.

4. 터널 붕괴 예측 모델 현장 적용성 검증

현장 적용성 검증은 인공지능망기법으로 설계된 모델의 터널 붕괴 예측 가능성과 현장 적용성 유무를 판단하기 위해 수행하였다. 적용성에 이용된 자료는 Korean Tunnelling Association(2010)에 수록된 총 12개소의 붕괴 현장에 대해 붕괴 유형별(천정부 붕괴, 연약대 붕괴,

전막장 붕괴, 토피층 함몰)로 3개소씩 선정하여 모델에 적용할 입력자료(단면적, RQD/N값, 불연속면의 기하학적 특성, 지하수 유입량, 굴착성능)와 출력자료(붕괴유형)를 데이터베이스화 하였다. 각 값들은 붕괴사례집의 자료들을 이용하여 각 터널별로 Table 1의 터널붕락 영향인자 분류표를 이용하여 수치화 하였으며, Table 7에 각 터널의 입력값 및 예상 출력값을 정리하였다.

터널 붕괴 예측 모델 적용성 검증 결과는 붕괴유형에 대한 백분율로 표시되며, 가장 높은 수치를 보이는 유형을 예측 결과값으로 선정하였다. Table 8은 터널 붕괴 예측 모델 결과를 정리한 것으로 실제 현장 결과값(output data)과 예측값(desired data)이 모두 일치하는 것으로 나타났다. 그러므로 본 연구를 통해 터널 붕괴에 영향을 끼치는 인자들을 이용하여 인공신경망을 통한 터널 붕괴에 대한 예측 가능성을 확인하였다. 터널 붕괴는 단일 원인뿐만 아니라 복합적인 원인들에 의해 발생되며, 붕괴유형 역시 단일 유형에서 복합 유형으로 발생한다. 본 연구에서 붕괴 유형의 백분율로 수치화된 값은 예측된 주요 붕괴 유형 및 추가 발생 가능한 붕괴유형 가능성을 시사해 주는 것으로 판단된다.

Table 7. In site input and output data for application verification

No.	Project	Collapse type	Input factor					Output factor
			Tunnel equivalent section area	RQD / N values	Geometrical condition of discontinuities	Groundwater level	Performance of excavation	Type of collapse
1	Seoul - Chuncheon highway 6 section	Crown failure	4	10	10	8	0	1
2	Gwirae - Maeji road expansion	Crown failure	4	6	8	10	3	1
3	Busan Newport railway	Full face failure	2	10	0	10	6	3
4	Boryeong city Bypass road	Crown failure	6	4	8	10	6	1
5	Gangdong - Pohang road expansion	Overburden failure	6	4	10	10	6	4
6	Seoul - Chuncheon highway 4 section	Weakness strata failure	4	8	6	10	8	2
7	Seoul - Yangyang expressway	Weakness strata failure	2	6	10	10	3	2
8	Korail Youngdong line Dongbaeksan - Dogye tunnel	Full face failure	2	6	3	10	3	3
9	Seoul metro line 5-16 section	Overburden failure	4	2	8	10	3	4
10	Seoul metro line 5-36 section	Full face failure	4	4	3	10	3	3
11	Busan subway line 1-9 section	Weakness strata failure	4	8	3	0	3	2
12	KTX Gyeongbu line 12-4 section	Overburden failure	4	2	10	8	3	4

Table 8. In-situ result data

NO.	Collapse type	Output data	Crown failure	Weakness strata failure	Full face failure	Overburden failure	Desired data
1	Crown failure	1	96%	0%	4%	0%	1
2	Crown failure	1	94%	0%	6%	0%	1
3	Full face failure	3	3%	0%	97%	0%	3
4	Crown failure	1	95%	0%	0%	5%	1
5	Overburden failure	4	2%	8%	0%	90%	4
6	Weakness strata failure	2	4%	85%	0%	11%	2
7	Weakness strata failure	2	0%	73%	12%	15%	2
8	Full face failure	3	3%	0%	93%	4%	3
9	Overburden failure	4	3%	2%	0%	95%	4
10	Full face failure	3	0%	0%	98%	2%	3
11	Weakness strata failure	2	9%	81%	8%	2%	2
12	Overburden failure	4	6%	4%	0%	90%	4

5. 결론

본 연구에서는 기존의 터널 붕괴에 영향을 미치는 요소들을 다양하게 고려하여, 특별한 정의 없이 적용할 수 있는 방법인 인공신경망 기법을 적용하여 보다 효율적이고, 신뢰성 높은 터널 붕괴를 예측하는 방법을 제시하고자 하였다. 결론은 다음과 같다.

총 56개소의 터널 붕괴 현장에서 붕괴의 원인이 될 수 있는 터널 단면적, 환산심도, 터널 직경, 일축압축강도, RQD, 불연속면 조건 및 상태, 지하수 조건과 수위, 굴착 방법 및 여굴량, 지보패턴 및 보조공법, 붕괴유형 자료들을 이용하여 통계분석을 실시하였다.

붕괴 유형 예측 인공신경망 모델 설계에 필요한 입력 요소는 붕괴유형과 붕괴 영향인자들 간의 민감도 분석 결과에 따라 총 5개 항목(터널단면적, RQD/N값, 불연속면의 기하형상, 지하수 유입량, 굴착성능)을 선정하였다. 입력요소(붕괴영향인자)와 출력요소(붕괴유형) 자료를 이용한 인공신경망 모델 설계는 학습을 통해 운영인자들을 변화시켜 출력값과 예측값의 상관성을 분석하여 운영인자들을 결정하였으며, 모델의 검증은 평균제곱오차(MSE) 값을 이용하여 수렴 경향도로 모델의 신뢰도를 판단하였다. 설계된 모델은 0.881의 상관계수 (r) 값을 보였고, 평균제곱오차 값이 0에 가까이 수렴하는 경향을 보였다. 그러므로 인공신경망 모델의 적합성 및 신뢰도를 확인 할 수 있었다. 검증을 통한 터널 붕괴 예측모델은 쌍곡탄젠트 함수(전이함수), 0.9(모멘텀 상수), 0.5(학습률), 2(은닉층의 수), 10(은닉층의 노드수)로 결정하였다.

붕괴 예측 인공신경망 모델의 적용성 검증은 모델 설계에 적용되지 않은 총 12개의 시공현장 붕괴 데이터들을 데이터베이스화하여 해석을 수행하였다. 적용 결과는 각각의 붕괴유형별 백분율로 표시되며, 12개소 현장 결과값과 예측값이 모두 일치하는 것으로 나타났다. 그러므로 제안하고자 하는 인공신경망 모델은 붕괴 유형 예측이 가능하며 모델의 적합성 및 신뢰도를 확인 할 수 있었다.

본 연구에서 인공신경망 기법을 통한 터널 붕괴 예측 시스템은 적용성 검증을 통해 붕괴 유형 예측 가능성을 확인 할 수 있었다. 본 연구 결과는 기초적인 연구 결과로서 다양한 지질, 지반 및 주변 환경 등의 여러 요인들을 고려할 수 있는 효율적이고 신뢰성 있는 터널 붕괴 예측과 설계 및 시공에 적용 가능하도록 터널 붕괴 예측 시스템을 완성하기 위해서는 추후 지속적인 연구와 보완이 수행되어야 할 것으로 판단된다.

참고문헌 (References)

1. Anderson, J. (1997), "HSE Report on NATM Safety", Tunnel & Tunnelling, March, pp.49-51.
2. Caudill, M. (1988), "Neural Networks Primer, Part III", AI EXPERT, 3(6), pp.53-59.
3. Hwang, M.G. (2004), "Application of Artificial Neural Networks to Soil Flushing Method", Master's thesis, University of Myongji, pp.1-24.
4. Jeong, Y.S. (2008), "Development of Tunnel Collapse Risk Index by Neural Network", Master's thesis, University of Hoseo, pp. 20-40.
5. Kim, J.K. (2011), "A Case Study on the Estimation of a Proper Tunnel Support Pattern Using Back Analysis based on Artificial

- Neural Network, Doctoral thesis, University of Suwon, pp.20-27.
6. Kim, Y.Y. (2011), "A Study on Quantified Management for Tunnel Construction Hazard based on KICT Tunnel Hazard Index (KTH-Index)", Master's thesis, University of Dongguk, pp.10-12.
 7. Korean Institute of Construction Technology (2009), "Development of Technologies for Minimizing and Prevention the Disaster on Tunnel Construction VI", report, KICT 2009-071, pp.43-64.
 8. Korean Tunnelling Association (2010), "Case Histories of Tunnel Collapse", CIR, pp.93-263.
 9. Lee, S.B. and Im, Y.D. (2002), "Fuzzy Neural Network Genetic Evolution", INSOL MEDIA, pp.107-144.
 10. Lee, S.G., Kim, N.Y., and Jeon B.H. (2007), "A Study on the Collapse Pattern of Road Tunnel under Construction", *The Journal of Engineering Geology*, Vol.17, No.1, March, pp.115-123.
 11. Nam, K.M. (2008), "A Study on the Estimation of the Blast Vibration Velocity in the Structure Using the Artificial Neural Network", Master's Thesis, Chungnam National University, pp.21-52.
 12. Shin, H.S., Kwon, Y.C., Jung, Y.S, Bae, G.J., and Kim, Y.Y. (2009), "Methodology for Quantitative Hazard Assessment for Tunnel Collapses based on Case Histories in Korea", *International Journal of Rock Mechanics and Mining Science*, Vol.45, No.5, pp.1072-1087.

Received : October 28th, 2015
 Revised : December 18th, 2015
 Accepted : January 30th, 2016