

터널거동 평가에서의 인공신경망 활용기법 연구 Prediction of Tunnel Behavior Using Artificial Neural Network

유충식¹⁾, Chung Sik Yoo, 김주미²⁾, Joo-Mi Kim

- 1) 성균관대학교 공과대학 토목환경공학과 정교수, Professor, Dept. of Civil and Envir. Engineering, Sungkyunkwan Univ.
- 2) 성균관대학교 공과대학 토목환경공학과 석사과정, Graduate Student, Dept. of Civil and Envir. Engineering, Sungkyunkwan Univ.

SYNOPSIS

This study investigated the applicability of the Artificial Neural Network (ANN) technique for prediction of tunnel behavior. For training data collection, a series of finite element analyses were conducted for actual tunnel project site. Using the data, optimized ANNs were developed through a sensitivity study on internal parameters. The developed ANNs can make tunneling related predictions such as tunnel crown settlement, shotcrete lining stress, ground surface settlement, and groundwater inflow rate. The results indicated that the developed ANNs can be used as an effective and efficient tool for tunnelling related prediction in practical tunneling situations.

Key words : Artificial Neural Network, tunnel performance, Sensitivity Analysis, Internal Parameter

1. 서론

도심지의 급속한 발달로 인하여 사회기반시설 및 지하구조물 확충을 위한 지하공간 창출의 대안으로 현재 많은 터널이 설계/시공되고 있다. 일반적으로 터널 시공시 터널굴착에 따른 지반 침하로 지상 구조물 및 지중 매설관에 피해를 주는 경우가 빈번히 발생하고 있어 주변지반의 거동, 구조물 영향 검토의 중요성이 대두되고 있고, 일반적으로 계측 및 수치해석등을 통하여 이러한 검토가 시행되고 있다.

터널거동 평가에 있어 계측 자료를 이용할 경우 학습된 내적지식을 일반화하여 새로운 상황에 대한 예측을 수행하는 전문가 시스템 인공신경망(Artificial Neural Network, ANN) 기법을 이용하여 한정된 계측자료를 통해 보다 효과적인 터널거동평가를 위한 연구가 수행되고 있다. 그 예로 Shi & Ortigao (1998)은 6.5km 연장의 Brasilia (in Brazil)터널을 적용 대상으로 하여 터널 굴착에 따른 지표 침하를 인공신경망 기법을 이용하여 평가하는 ANN 엔진을 구축하고 ANN 엔진 모델을 다르게 하여 최적화된 ANN 엔진 구축을 위한 연구를 수행하였다. 또한 Kim (2001)은 현장조사 자료와 RSE(Relative strength effect) 개념을 이용하여 입력변수의 상대적 중요도를 분석하여 터널굴착에 따른 지표 침하 예측을 위한 인공신경망 모델을 개발하였다. 또한, 터널 설계 검토시 수치해석을 이용할 경우 광역단위의 터널 현장을 고려할 때 주변지반 조건 및 환경에 따른 해석단면의 수가 급격히 많아져 해석에 어려움이 따른다. 최근 들어 이러한 수치해석의 한계를 보완하기 위해 ANN기법을 적용한 연구가 수행되었다. 성균관대학교 지반연구실에서는 터널위험도 평가시스템 IT-TMS를 개발하여 FEM(Finite Element

Analysis)-ANN 연계 기법을 통한 터널거동 평가 연구(Yoo, 2004)를 수행하였고 이를 IT-TMS 접목하여 가시화 하였다. 또한 Lee (2003)는 터널거동예측 시스템(TBPS)을 개발하여 이를 통한 터널거동 예측결과를 현장 계측 및 수치해석 값과의 상호 비교를 통해 ANN 기법을 적용한 연구를 수행하였다. 이러한 기존연구 결과를 통해 충분한 데이터가 있을 경우, 인공지능망 기법을 이용하여 터널굴착과 침하관계를 정립하는 방법이 효율적임을 입증하였다.

본 연구에서는 효율적인 터널 거동 평가를 위한 검토시 이미 건설 및 정보통신등 다양한 분야에서 적용성이 입증된 ANN 기법과 기존 수치해석을 연계하여 터널거동평가에서의 활용기법 연구를 수행하였다. 이를 위해 고속철도 ○-○○공구를 대상으로 하여 현장을 대표하는 최소 단면을 선정하였고 이에 대한 유한요소해석을 수행하여 인공지능망 학습 데이터로 구축하였다. 이 과정에서 다양한 민감도 분석을 통하여 터널거동 평가 항목의 영향을 미치는 인자들에 대한 중요도 분석을 수행하였다. 이러한 ANN 기법을 적용한 터널거동 평가를 수행하기 위해 Math Works Inc.에서 개발한 Matlab 6.1 (MATrix LABoratory) 프로그램을 사용하였으며 내적인자 연구결과와 입력파라미터를 시행착오를 통한 민감도분석 연구결과를 바탕으로 하여 FEM-ANN 연계 기법을 적용하기 위한 최적화된 ANN 엔진을 구축하였다. 본 연구에서는 터널 굴착시 터널 거동 및 주변 지반거동, 지하수 영향을 평가를 수행하였고 내적인자와 입력변수에 대한 민감도분석의 중요도를 판단하였으며 FEM-ANN 연계 기법의 효율성을 확인하였다.

2. FEM-ANN 기반의 터널거동 예측

2.1 FEM-ANN 기본 개요

FEM-ANN연계 기법은 터널 설계/시공에 있어 효율적인 평가를 위한 수단으로 제안되었다. 반복 학습을 통하여 새로운 상황에 대한 예측이 가능한 ANN 엔진 개발을 위해 FEM을 활용하여 ANN 엔진 개발시 필요한 학습데이터를 산정하는 것을 기본 개념으로 하는 FEM-ANN 연계 기법은 최소구간에 대한 해석만을 통하여 FEM 해석결과를 충분히 재현할 수 있는 ANN엔진이 구축될 경우 ANN 이론의 효율성을 부합하여 모든 단면에 대한 수치해석을 수행하는 것과 같은 결과를 산정할 수 있는 방법 중 하나이다.

본 연구에서 적용한 FEM-ANN 연계 기법의 과정은 다음과 같다. 터널현장에서 주변영향 및 지반조건의 변화가 큰 최소단면을 선정하고 이를 FEM(Finite Element Analysis)을 이용하여 해석을 수행, ANN 엔진의 학습데이터를 산정한다. 산정된 학습데이터를 이용하여 구축된 ANN 엔진을 통해 학습을 수행하고 터널현장의 전구간을 예측함으로써 시간적·경제적인 측면의 이점이 있다. 또한 이러한 FEM-ANN 연계 기법은 시공중 현장조건의 변화나 추가 단면에 대한 평가가 요구될 때 별도의 수치해석 없이 ANN만으로 신속하게 평가 할 수 있는 장점이 있다. 그림 1은 FEM-ANN연계기법의 개념도를 보이고 있다.

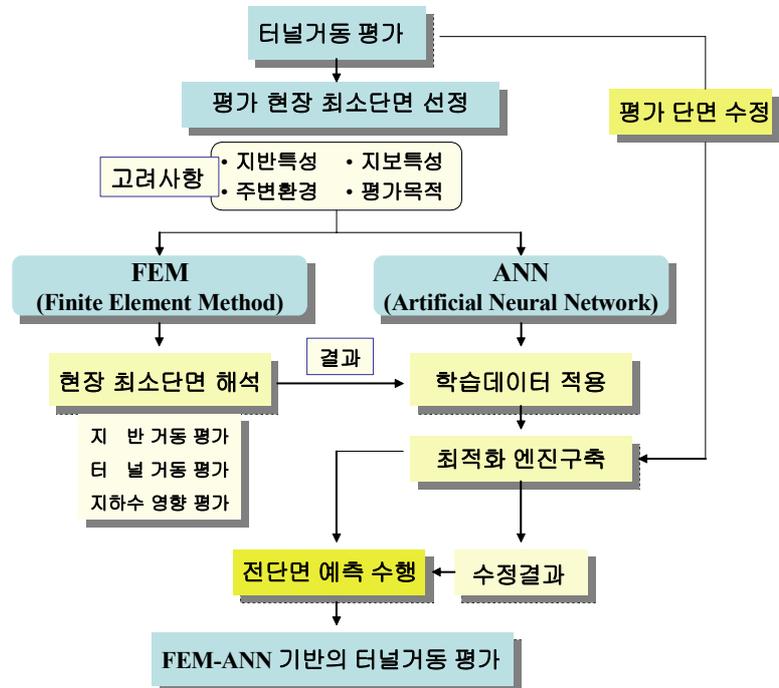


그림 1. FEM-ANN 연계 개념도

2.2 적용현장 및 터널개요

본 연구에서 적용한 터널 현장은 고속철도구간에 설계된 터널 구간으로서 터널 직경은 12.2m, 굴착 단면적은 100m²~120m²이며 터널 시공 총연장 5.6km로 복잡한 도심지를 관통하고 있다. 그림 2는 터널개요를 나타내며, 터널구간의 평면도와 종단면도는 그림 3과 그림 4에서 보여주고 있다. 적용 현장의 터널은 복선터널로 설계되어 있고 토피는 10.00~50.00m 정도로 계획되어 있으며 대부분 암반등급 III~IV를 통과하도록 설계되어 있다. 지표 상부 5~30m는 모래와 자갈, 실트질 점토가 섞인 혼합 매립층이 존재하며 그 아래로 1~50m 두께의 충적층과 2~20m 두께의 화강풍화토가 존재한다. 그림 4에서 볼수 있듯이 적용현장의 Section-B와 같이 시공 종점부는 점토층이 상부 토사 층에 존재하며 지상에는 고가등 오래된 구조물이 있다. 표 1은 터널구간의 지반조사결과를 토대로 나타난 각 지층별 지반 특성치를 보여주고 있고, 표 2는 대상 현장에 적용 설계된 지보패턴을 나타내고 있다.

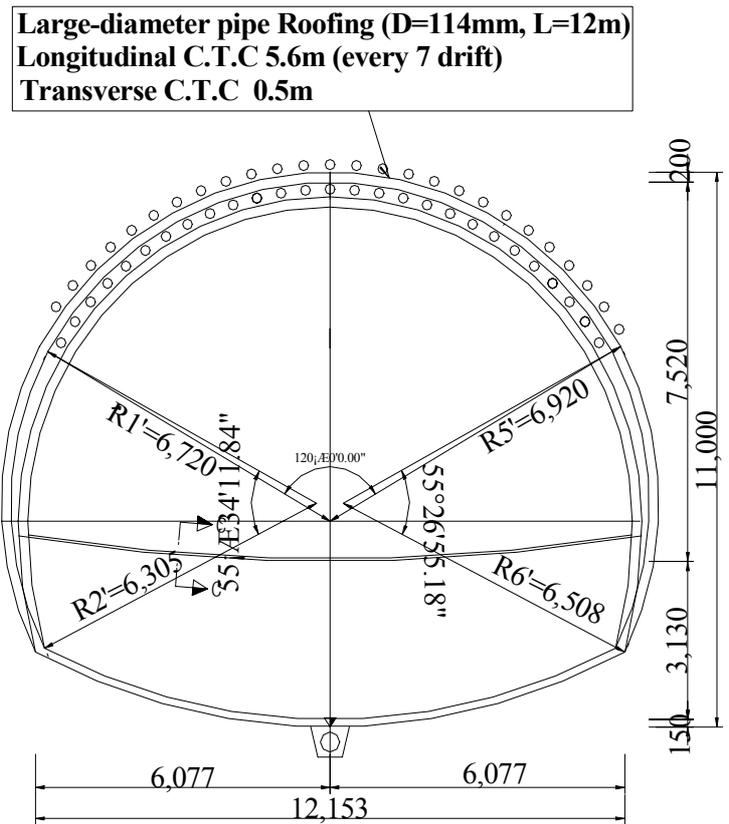


그림 2. 현장 터널 개요

표 1. 적용현장 암반등급별 지반 특성치

Class	γ (kN/m ³) 단위중량	c (kPa) 점착력	ϕ (deg) 내부마찰각	E (MPa) 지반변형계수	K_o 측압계수	K (m/sec) 투수계수	비고
I	26	1000	45	12000	1.2	1.9×10^{-8}	Hard Rock
II	25	500	40	8000	1.0	6.7×10^{-8}	Normal Rock
III	24	200	35	4000	0.8	1.8×10^{-7}	Soft Rock
IV	23	150	33	2500	0.6	5.0×10^{-7}	Weathered Rock
V	22	50	30	100	0.5	1.0×10^{-6}	Alluvium
VI	19	20	28	20	0.5	1.0×10^{-6}	Fill

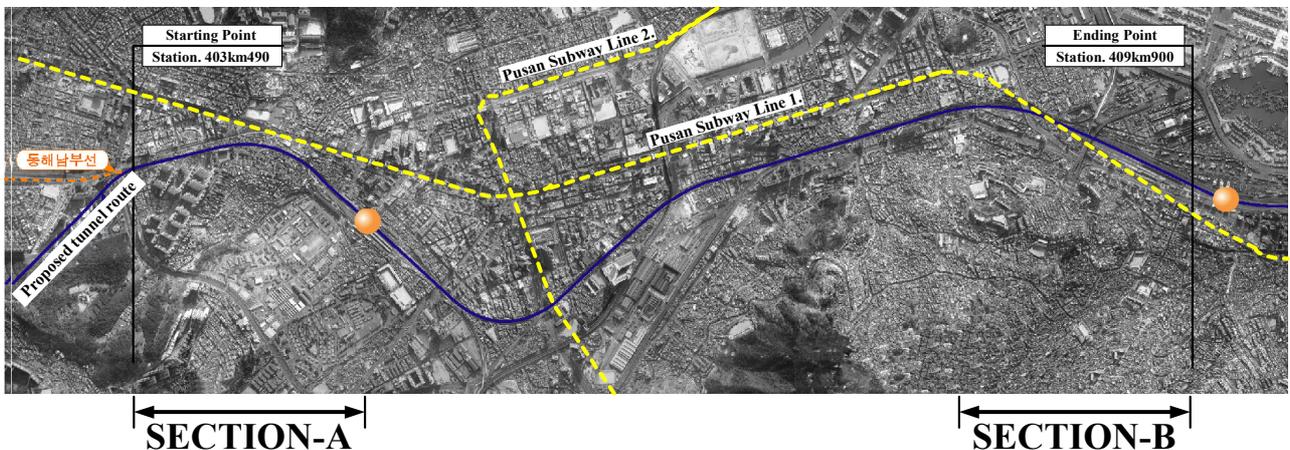


그림 3. 현장 전체 평면도

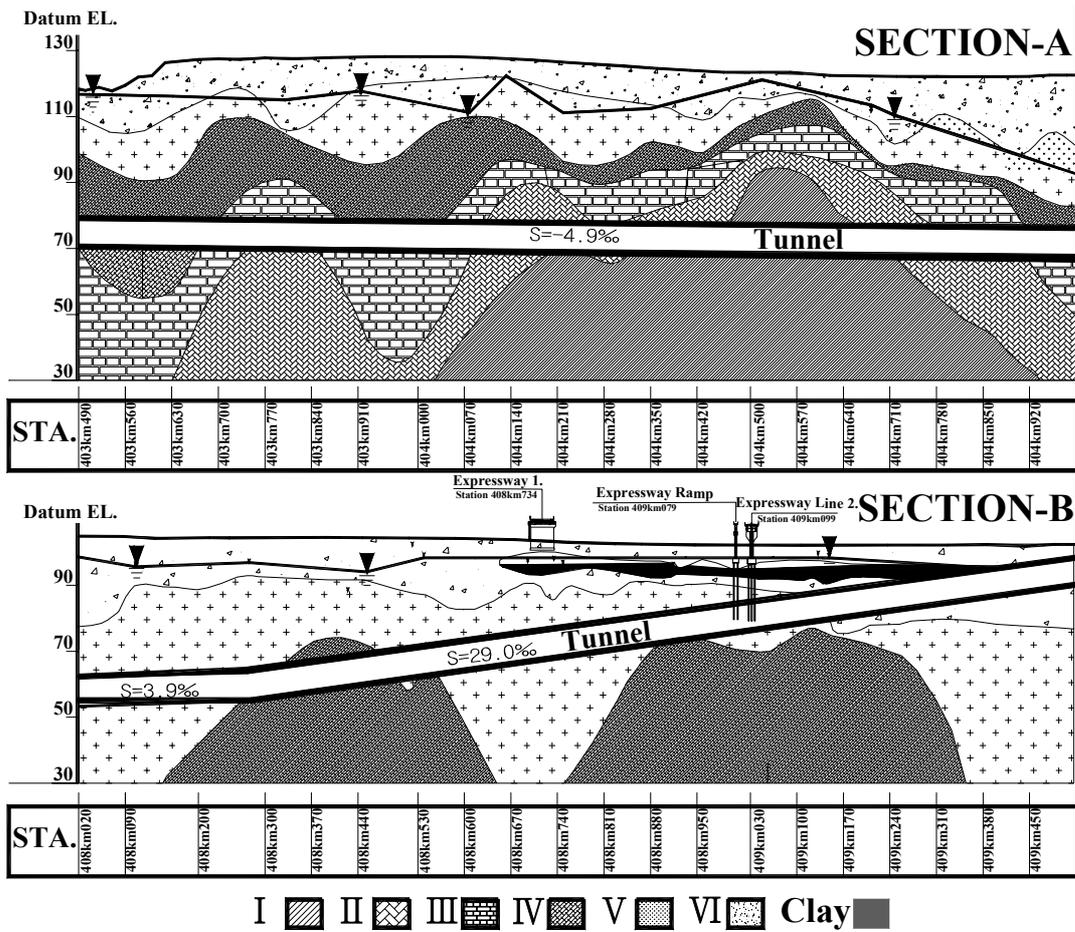


그림 4. 적용현장 주요 종단면도

표 2. 적용 지보패턴

Support pattern	Rock Quality		Shotcrete Thickness (mm)	Rock bolt		Excavation Type	Adv. ^c rate (m)	Remarks
	RMR ^a	Q ^b		Length (m)	Spacing (m)			
PD-1	81~100	>40	50	4.0	random	T/B ^d	1.5	Blasting
PD-2	61~800	10~40	80	4.0	1.5/2.0 ^c	T/B ^d	1.5	Blasting
PD-3	41~60	1~10	120	4.0	1.2/2.0 ^c	T/B ^d	1.2	Blasting
PD-4	21~40	0.1~1	160	4.0	1.0/1.5 ^c	T/B ^d	1.0	Forepolling drilling
PD-5	<20	0.01~0.1	200	4.0	0.8/1.2 ^c	T/B ^d	0.8	A-type pipe roofing ^g Drilling
PDS-5	<20	0.01~0.1	200	4.0	0.8/1.2 ^c	R/C ^e	0.8	A-type pipe roofing ^g Drilling
PDS-5-1	<20	0.01~0.1	200	4.0	0.8/1.2 ^c	R/C ^e	0.8	B-type pipe roofing ^h Drilling
PDS-6	<20	0.01~0.1	200	4.0	0.8/1.2 ^c	MD ^f	0.8	B-type pipe roofing ^h Drilling

Note: ^aRMR=Rock mass rating; ^bQ=Q-system; ^cAdv.=advance; ^cL/T=longitudinal/transverse; ^dT/B=top heading and bench excavation; ^eR/C=ring cut excavation; MD^f=multiple drift; ^gA-type pipe roofing=500 mm steel pipes; and ^hB-type pipe roofing=100 mm diameter grouted steel pipes

3. ANN 엔진 구축

3.1 유한요소해석

ANN 기법을 적용한 효율적인 터널거동 평가를 위한 첫 번째 작업으로 ANN 학습데이터를 유한요소 해석을 통하여 실제 평가 단면에 대한 해석값을 산정한다. 본 연구에서는 적용현장의 지반조건 및 터널 설계 특성을 고려하여 변화가 큰 87개의 최소단면을 선정하여 유한요소법에 근거한 상용프로그램 ABAQUS 6.4-1을 이용하여 해석을 수행하였으며, 터널시공과정은 하중 분배법을 토대로 모델링하였다. 터널거동 평가 및 지반거동 평가, 지하수 영향 평가를 위해 2차원 응력 및 침투 해석을 수행하였다. 응력해석에 있어 해석영역은 터널중심으로부터 폭 4D(D=터널직경)이상 높이 3D 이상으로 하였고 수직 경계면은 X방향 구속, 바닥면 경계조건은 X,Y방향 구속을 하였다. 지반 및 지보재의 이산화에 있어 지반의 경우 8절점 가감 적분 요소 (CPE8R)를 적용하였으며 록볼트는 3절점 2차원 트러스요소 (T2D3), 숏크리트는 3절점 보요소(B22)를 사용하여 해석에 적용하였다. Material Modeling은 지반에서는 Mohr-Coulomb 파괴규준과 Davis(1968)가 제안한 비관련흐름 법칙을 적용하였고 지보재의 경우 탄성거동으로 적용하였다. 침투해석에서는 지반을 8절점 쌍일차 간극수압 가감 적분 요소 (CPE8RP)로 모델링 하였으며 간극수압에 대한 경계조건을 부여하기 위해 수직 경계면 수압은 정수압분포로 구속하였고, 터널 굴착면은 수압을 '0'으로 적용하였다. 그림 5는 선정된 최소단면 중 일부의 유한요소망을 보이고 있다.

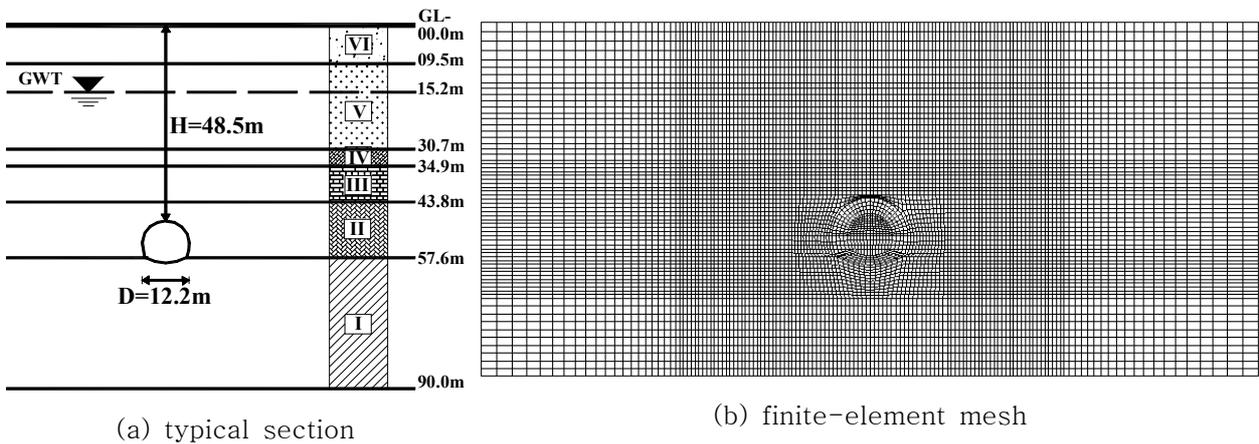


그림 5. 해석적용 단면의 유한요소망

3.2 Database 및 ANN Models 구축

ANN 엔진을 구축할 때 가장 처음으로 고려되어야 할 사항이 입력파라미터 산정이다. 일반적인 터널 거동 평가시 평가에 영향을 주는 주요 요인으로는 지반조건과 지보패턴, 토피고와 같은 터널 설계인자들이 있다. 바로 이러한 요소들은 터널거동 평가의 주요요인인과 동시에 ANN 모델의 입력파라미터가 된다.

본 연구에서는 터널거동과 그에 따른 지반거동을 평가하기위한 FEM 응력해석을 통한 ANN 모델과 터널굴착에 따른 지하수 영향을 평가하기 위해 FEM 침투해석을 통한 ANN 모델과 같이 총 두가지 형태의 ANN 엔진을 구축하였다. FEM 응력해석을 통한 첫 번째 ANN 모델 엔진을 통하여 터널굴착에 따른 터널거동평가로 터널내 천단변위(δ_{CR}), 내공변위(δ_{CO}), 숏크리트 힘압축응력(σ_{max} & σ_{min})과 터널거동에 따라 야기되는 지반거동에 대한 평가로 최대지표침하($S_{v,max}$)와 변곡점(i)을 예측할 수 있도록 하였다. 또한, FEM 침투해석을 통한 두 번째 ANN 모델을 통하여 터널굴착에 따른 터널내 지하수 유입량(q)과 최대 지하수위 저하량(H_D)을 평가할 수 있도록 하였다. 표 3은 본 연구에서 적용된 ANN 모델의 입력파라미터를 보여주고 있으며 각 파라미터는 0과 1사이의 값으로 정규화 되어 ANN 학습에 적용된다.

표 3. ANN 모델 Input Parameter

	Model input variable	Description
	H (m)	Cover Depth
	H _w (m)	Distance from groundwater table to tunnel to crown
	SP	Support pattern
	GT _{0.5D}	Ground Type at 0.5D upper part from crown
	GT _f	Ground Type at tunnel face
	GT _i	Ground Type at tunnel invert
	H _{L1} (m)	Layer 1 thickness of fill
	H _{L2} (m)	Layer 2 thickness of alluvium

ANN 엔진구축에 있어 본 연구에서는 적용학습데이터를 다음과 같은 두 가지의 Training set과 Validation set으로 구분하여 각각 80%와 20%의 데이터로 분할하였고 여기서 Training set은 ANN 모델의 학습을 위한 엔진구축 데이터로 사용되며 Validation set은 구축된 ANN 모델의 신뢰성 검증에 사용되는 데이터이다. Training set은 다시 70%의 Training set과 30%의 Testing set으로 구분된다. 앞서 거론된 80%의 Training set의 데이터를 ANN 학습데이터로 모두 적용하는 것이 아니라 80%의 데이터를 다시 70%와 30%의 Training set과 Testing set으로 구분하여 70%의 Training set은 ANN 학습을 위한 데이터로 쓰여지며 30%의 Testing set은 ANN 엔진구축을 위한 ANN 엔진의 내적인 학습인자 평가를 위한 데이터로 사용되는 것이다. 연구에 적용할 데이터 산정을 위해 적용현장 단면 중 주변 영향 및 지반특성 등 터널거동에 영향을 주는 주요 요인이 주변단면과 변화가 큰 95개의 단면을 선정하여 FEM 해석 통해 ANN 엔진구축에 필요한 데이터를 산정하였다. 산정된 데이터는 앞서 거론한 방법으로 각각 80%와 20%의 Training set 75단면과 Validation 20단면으로 구분하였으며 80%의 Training set 75단면을 다시 70%의 Training set 52 단면과 30%의 Testing set 23단면으로 구분하였다. 50 단면의 Training set 데이터와 앞서 기술한 입력파라미터를 적용하여 ANN 내적인자 연구를 수행하였다. 이와 같이 ANN 엔진 구축에 사용되는 학습을 위한 데이터와 검증을 위한 데이터는 0과 1사이 값으로 정규화 되어 Sigmoid 함수를 통해 다시 0과 1사이 값으로 정규화 된 Output Layer값으로 산출된다.

인공신경망의 모델을 구축하기 위해 훈련방법의 하나인 역전파 (Back Propagation Neural Network) 알고리즘을 적용하였으며 이는 일반화된 델타 규칙을 적용한다. 일반화된 델타 규칙은 출력 뉴런들의 전체 자승오차를 감소시키기 위해 설계되었고 오차의 최소값을 구하기 위해서, 가중치 표면의 기울기를 사용하는 최급 하강법이 사용된다. 한편, 다음 오차를 계산하기 위해, 알고리즘은 오차표면의 기울기를 검사하는데, 이는 오차표면의 가장 큰 기울기의 방향을 찾는 것으로서 오차를 줄이기 위한 방향을 결정하는데 사용된다. 이 알고리즘은 가장 가파른 방향의 기울기에서 음의 부호를 갖는 기울기를 선택하여 신경망 뉴런의 가중치와 임계치의 조절을 통해 최소 오차의 지점을 찾아 가는 방법을 취한다. 이러한 방법은 이미 지반공학적 문제를 해결하기 위한 연구에 다수 사용되어 그 효율성이 입증되었다(Goh 1994, Shi et al. 1997, Kim et al. 2001). 역전파 알고리즘을 적용하는 ANN 엔진은 다음과 같은 입력층, 은닉층, 출력층과 같이 세가지 요소로 구분되어 진다. 각 입력변수에 대응되는 마디들로 구성된 입력층(Input Layer)은 명목형(nominal) 변수에 대해서는 각 수준에 대응하는 입력마디를 가지게 되는데, 이는 통계적 선형모형에서 가변수(dummy variable)를 사용하는 것과 같다. 은닉층(Hidden Layer)은 입력층(Input Layer)으로부터 전달되는 변수값들의 선형결합(linear combination)을 비선형함수(nonlinear function)로 처리하여 출력층 또는 다른 은닉층에 전달한다. 마지막으로 출력층은 목표변수(target)에 대응하는 마디를 갖는다. 여기서 입력층과 은닉층의 뉴런의 개수는 입력층과 출력층의 모델 형태에 따라 제한적이며 인공신경망 기본 이론에 대한 내용은 Hagan(Oklahoma State University)의 “Neural Network Design”에 자세하게 수록되어있다. 이러한 인공신경망 모델을 구축하기 위해 본 연구에서는 Math Works Inc.에서 개발한 Matlab 6.1 (MATrix LABoratory) 프로그램을 사용하였다. 행렬과 벡터를 기본으로 작업을 수행하는 Matlab 6.1은 수치해석, 행렬연산, 신호처리 및 간편한 그래픽 기능 등을 통합하여 고성능의 수치계산 및 결과를 보기 쉽게 제공하고 M 파일을 써서 특정한 해를 구하는데 필요한 응용 프로그램을 쉽게 작성할 수 있는 프로그램이다.

3.3 ANN Internal Parameter 연구 (Training & Testing)

ANN 모델 구축에 있어 최적의 연결강도를 찾기 위해 본 연구에서는 ANN 내적인자의 상호 관계를 검토하여 최적의 인자 선정을 위해 ANN 내적인자 연구를 수행하였으며 연구에 필요한 주요 인자로는 모멘텀과 학습률, 초기 가중치가 있다. 이러한 인자의 설정을 위한 연구 방법으로 초기치에 대하여 모멘텀상수와 학습률을 서로 다르게 조합하여 시행착오법을 통해 최적의 연결강도를 찾아낸다. 앞서 거론한 역전파 알고리즘을 적용하여 최적의 연결강도 산정을 위한 ANN 내적인자 연구과정은 다음과 같다.

모멘텀상수와 학습률 및 은닉층의 뉴런수를 변화 시키면서 반복 학습한 ANN 엔진에 23단면의 Testing set 데이터로 예측을 수행하여 오차제곱평균(RMSE)값의 비교를 통해 최적의 연결강도를 찾기 위한 ANN 내적인자 연구를 수행하였고 그 결과는 그림 6과 같다.

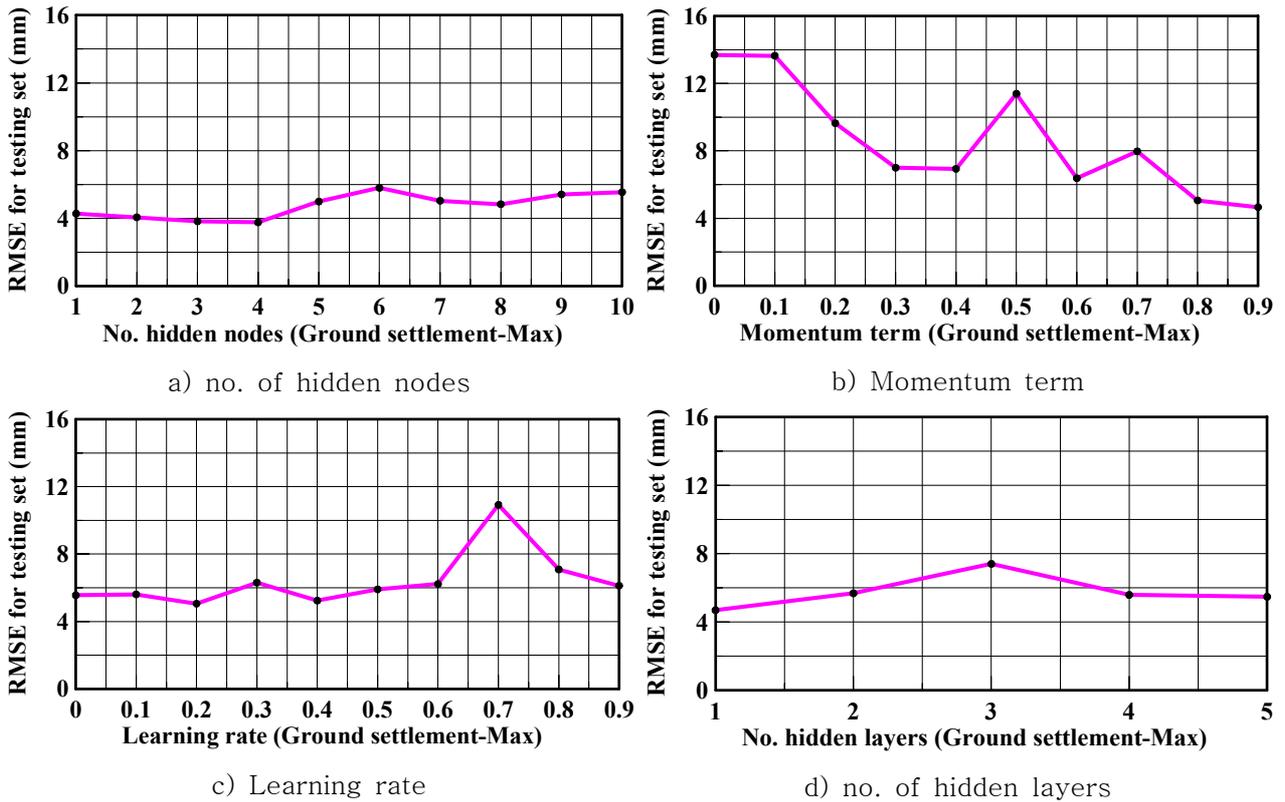
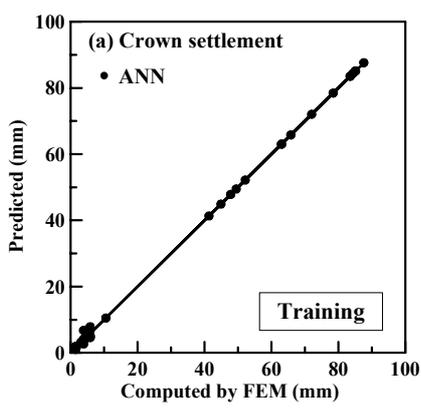
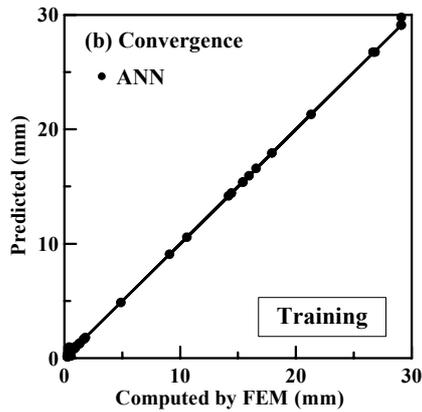


그림 6. ANN 내적인자 연구결과

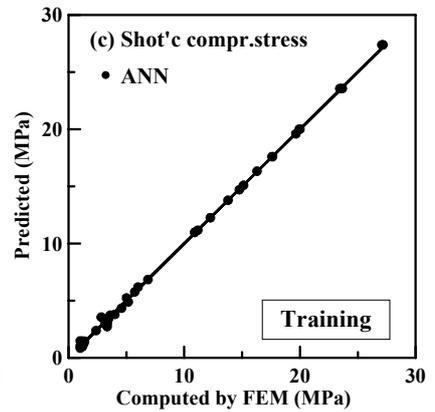
그림 6에서와 같이 최적의 연결강도를 찾기위한 ANN 내적인자연구는 은닉층 뉴런수가 4개, 모멘텀상수 0.8 그리고 학습률의 경우 0.2를 사용하는 것이 충분한 것으로 나타났다. 일반적으로 은닉층의 수는 적절한 가중치가 사용될 경우 하나의 은닉층으로도 가능하다고 보고(Hornik et al. 1989)되고 있지만 본 연구에서는 다층 출력구조의 ANN 모델 적용을 위해 학습효과를 고려하여 은닉층의 수를 4개를 사용하였다. 그림 7과 8은 ANN 내적인자연구 결과를 바탕으로 적용현장에 대한 ANN 학습을 수행한 결과이고 그림 9와 10은 학습된 ANN 모델에 대한 Testing set과 Validation set 단면에 대한 검증결과이다. 표 4는 회귀분석을 통한 결정계수 값과 RMSE, 오차절대값 평균인 MAE와 같이 세가지 방법을 사용하여 ANN 엔진의 신뢰성 확인 결과를 보여주고 있고 표 5는 평가모듈에 따른 신뢰검증에 사용된 데이터의 최대 및 최소 값을 나타내고 있다.



a) crown settlement

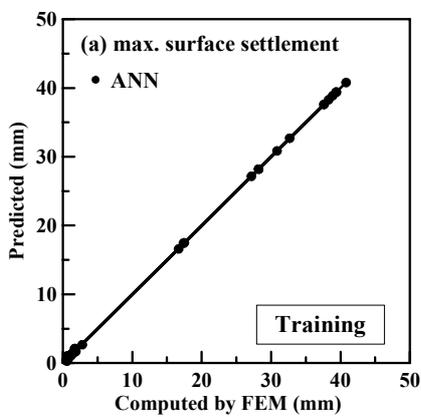


b) convergence

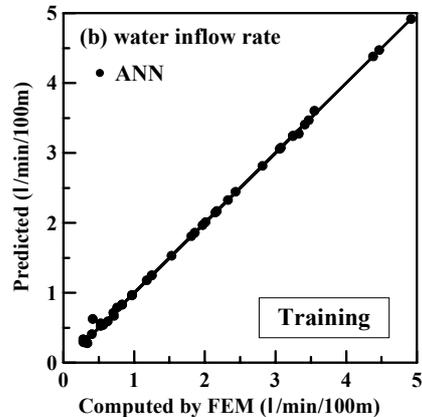


c) shot'c compr.stress

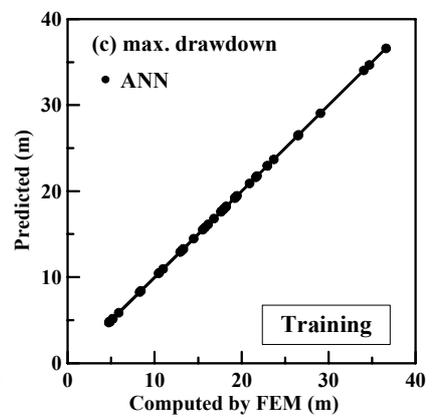
그림 7. 터널거동평가 학습 결과



a) max. surface settlement

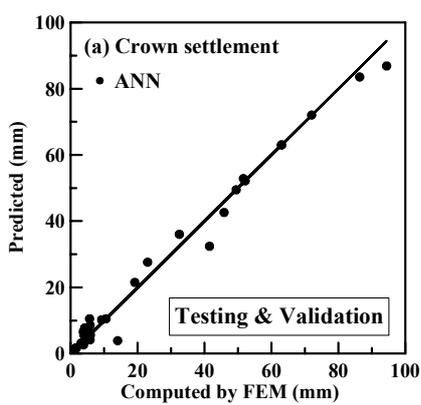


b) water inflow rate

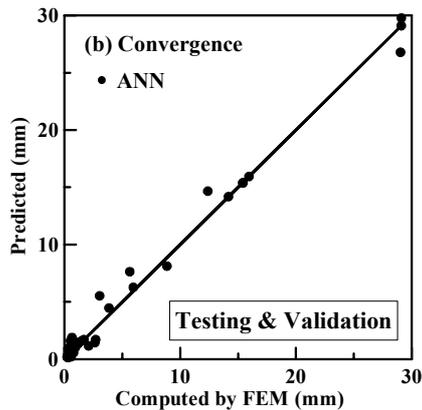


c) maximum drawdown

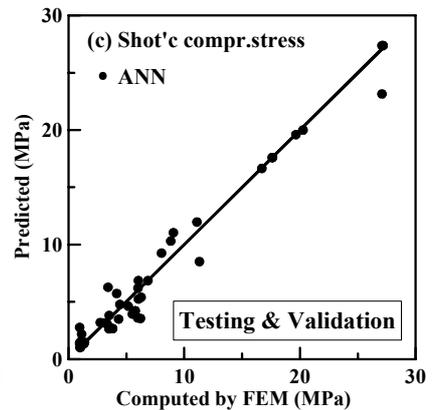
그림 8. 지반거동 및 지하수 영향평가 학습 결과



a) crown settlement

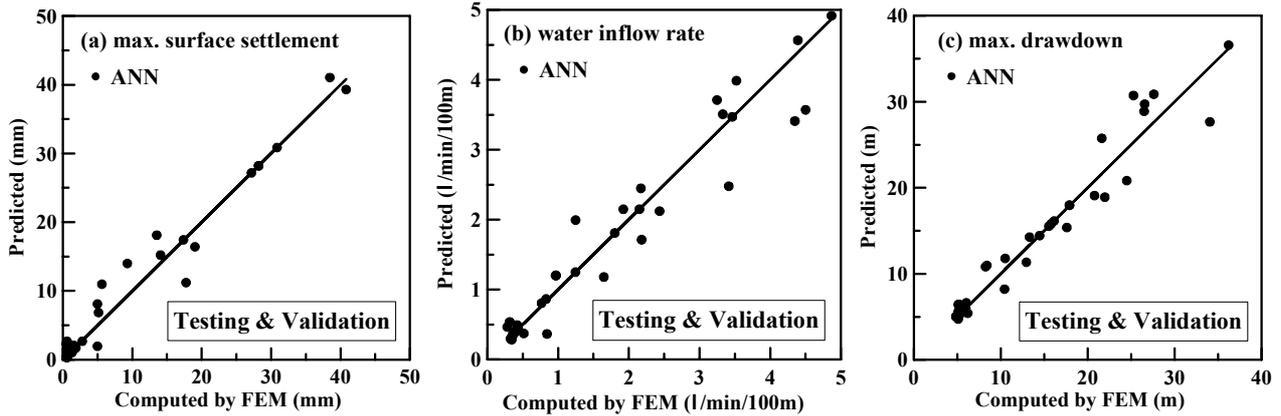


b) convergence



c) shot'c compr.stress

그림 9. 터널거동평가 검증 결과



a) max. surface settlement b) water inflow rate c) maximum drawdown

그림 10. 지반거동 및 지하수 영향평가 검증 결과

표 4. ANN 모델 학습 및 검증 결과

Category		Crown settlement	Convergence	Shot'c compr. stress	Max. surface settlement	Water inflow rate	Max. drawdown
R ²	Training	0.99	0.99	0.99	0.99	0.99	0.99
	Testing	0.99	0.97	0.96	0.96	0.90	0.87
	Validation	0.99	0.99	0.96	0.98	0.95	0.93
RMSE	Training	0.68 (mm)	0.21 (mm)	0.21 (MPa)	0.15 (mm)	0.04 (l/min/100m)	0.28 (m)
	Testing	2.54 (mm)	0.84 (mm)	1.23 (MPa)	1.94 (mm)	0.38 (l/min/100m)	2.06 (m)
	Validation	3.45 (mm)	0.94 (mm)	1.45 (MPa)	2.06 (mm)	0.46 (l/min/100m)	3.27 (m)
MAE	Training	0.58 (mm)	0.31 (mm)	0.37 (MPa)	0.33 (mm)	0.13 (l/min/100m)	0.31 (m)
	Testing	1.15 (mm)	0.75 (mm)	0.93 (MPa)	0.99 (mm)	0.52 (l/min/100m)	1.54 (m)
	Validation	1.47 (mm)	0.76 (mm)	0.99 (MPa)	1.13 (mm)	0.51 (l/min/100m)	1.38 (m)

표 5. 평가 데이터 적용범위

Data range	Crown settlement	Convergence	Shot'c compr. stress	Max. surface settlement	Water inflow rate	Max. drawdown
Maximum	115.52 (mm)	29.11 (mm)	27.37 (MPa)	45.1 (mm)	4.92(l/min/100m)	36.59 (m)
Minimum	1.06 (mm)	0.13 (mm)	0.86 (MPa)	0.27 (mm)	0.28(l/min/100m)	4.73 (m)

3.4 영향인자 평가연구 (Sensitivity Analysis)

ANN 기능을 활용하여 터널거동 평가를 위한 영향인자 연구를 Garson(1991)이 제시한 평가 방법을 이용하여 수행하였다. 그 과정으로 인공신경망 학습 데이터를 구축하기 위해 출력값에 영향을 주는 입력 파라미터를 터널 공학적으로 관점에서 주요 요인으로 거론 지층 및 지보패턴을 기준으로 하여 주요 요인의 세부항목을 시행착오를 거쳐 선정하였고 입력변수와 출력변수간의 상호 연결 가중치를 이용한 방법을 통해 학습에 적용된 입력파라미터의 상대적 중요성을 판단하여 최적의 ANN 엔진을 구축하기 위하여 영향인자 평가를 수행하였다. 평가 단면으로 ANN 신뢰성 검증에 적용된 단면 중 신뢰도가 높은 단면을 추출하여 평가에 적용하였다. 이는 영향인자 검토시 정확한 결과 값을 얻기 위해 상대적 신뢰도

가 낮은 예측결과의 Noise 작용을 배제하기 위해서이다. 표 6은 각 평가항목에 따른 영향인자 평가 결과를 보이고 있다.

표 6. 영향인자 평가 결과

Category	Relative Importanc for Input Variables (%)							
	H	H _w	SP	GT _{0.5D}	GT _f	GT _i	H _{L1}	H _{L2}
δ_{CR}	13.97	-	15.43	19.60	18.96	11.56	7.25	13.23
δ_{CO}	12.30	-	13.60	18.93	20.29	10.83	8.29	15.76
σ_{max} & σ_{min}	17.14	-	10.36	19.05	24.37	9.39	4.61	15.08
$S_{v,max}$	14.45	-	6.91	22.82	22.88	7.83	8.34	16.77
q	-	14.16	12.21	17.43	28.27	6.00	8.91	13.02
H _D	-	18.71	10.24	9.37	14.96	9.89	13.99	22.84

입력데이터와 출력데이터와의 상호 연결 가중치를 통해 산정되는 영향인자 평가 결과는 적용 입력파라미터 전체의 중요도를 100%로 하여 각각의 입력파라미터에 대한 상대적 중요도를 백분율을 이용하여 나타내고 100%에 가까울수록 상대적 중요도가 높은 인자이며 0%에 가까울수록 중요도가 낮은 인자이다. 표 6에서 볼 수 있듯이 응력해석을 바탕으로한 터널굴착에 따른 터널거동에 있어 천단변위(δ_{CR}) 및 내공변위(δ_{CO})의 경우 터널 관통지층 및 터널천단 상부 0.5D지층의 영향이 큰 것으로 나타났다. 슛크리트 휨 압축응력(σ_{max} & σ_{min})의 경우도 천단변위 및 내공변위와 비슷한 결과를 보이고 있으나 관통부 지층의 중요도가 상대적으로 더 크게 나타났다. 그리고 지표 침하($S_{v,max}$)의 경우 터널 관통지층 및 터널천단 상부 0.5D지층과 더불어 충전층의 지층2의 중요도가 높은 것으로 나타났다. 이러한 평가 결과의 타당성을 뒷받침 할 수 있는 이유로는 적용현장 터널의 경우 대부분 충전층의 지층 5와 풍화암질의 지층 4를 통과하고 있고 현장 토피고가 작게는 10m에서 크게는 50m임을 고려할 때 충전층의 두께가 두꺼울수록 터널의 관통지층이 충전층에 근접하다는 것을 들 수 있다. 터널거동에 대한 영향인자 평가를 토대로 현장 여건을 고려할 때 터널굴착시 최소 영향 범위를 0.5D로 가정할 경우 터널 관통지층 이외에도 관통지층보다 지반조건이 안 좋은 근접한 상부지층의 고려가 중요 검토사항임을 알 수 있다. 또한, 터널 거동에 따른 지반거동역시 지반 침하가 주된 평가 요인이므로 터널 하부지층보다 상부지층의 영향 큰 것을 알 수 있다. 침투해석을 바탕으로 한 지하수 영향인자평가에서는 터널내 유입량의 경우 터널 막장 관통지층의 종류가 가장 큰 영향을 주었으며 지하수위 저하량의 경우 터널상부 지층 1,2의 영향이 가장 큰 것으로 나타났다. 평가 결과의 원인으로 지반에 따른 투수계수비의 차이를 들 수 있고 상부지반인 혼합층 일수록 투수계수가 큰 점을 고려할 때 상부 토사지층이 지하수 저하량에 중요 검토사항이 됨을 알 수 있다.

이러한 민감도 분석을 통한 영향인자 평가결과 주요 인자들은 이미 터널 공학적으로 각 평가시 주요 요인으로 거론되고 있어 그 결과의 타당성을 입증하였고 이러한 결과는 ANN 모델 구축을 위한 중요한 영향 요소인 입력데이터로 적용되지만 그 결과는 실제 터널 현장에서 설계 및 시공시 중요 검토사항으로 적용될 수 있다는 점을 알 수 있었다.

4. 결론

본 연구에서는 건설 및 정보통신등 다양한 분야에서 효율성이 입증된 ANN기법을 적용한 터널 거동 평가를 수행하여 적용 인자들에 대한 중요성을 인식하였고 올바른 ANN 엔진구축을 위해 ANN 내적인자 연구를 수행하였다. ANN 학습률을 위한 ANN 내적인자와 예측에 영향을 주는 입력변수에 대한 민감도 분석 연구를 수행하여 최적의 ANN 엔진구축을 목적으로 한 본 연구에서는 Math Works Inc.에서 개발한 Matlab 6.1 (MATrix LABoratory) 프로그램을 사용하여 내적인자 연구결과인 은닉층4개, 은닉층

node 수 4개, 모멘텀상수 0.8과 학습률 0.2를 바탕으로 ANN 엔진을 구축하였다. 또한 터널거동 평가를 위한 ANN 적용 입력과라미터를 터널공학적인 관점에서 주요 영향요인인 지반조건 및 지보패턴등을 시행착오를 통한 민감도분석 연구결과를 이용하여 FEM과 ANN 연계 기법을 적용을 위한 최적화된 ANN 엔진을 구축하였다. 본 연구를 통하여 최적의 ANN엔진을 통한 터널 거동 평가를 수행하였고 내적인자와 민감도 분석을 통해 입력변수에 대한 중요도를 판단하였으며 FEM-ANN 연계 기법의 효율성을 확인하였다.

참고문헌

1. 유충식, 전영우, 김재훈, 박영진, 유정훈(2003), "GIS 기반의 터널 시공에 따른 주변건물/매설관 손상 평가시스템-개발 및 적용" 2003 한국지반공학회 봄학술발표회 논문집, pp.233~240
2. 유충식, 김주미,(2004), "인공신경망 기법을 이용한 터널 설계/시공 위험도 평가 연구", 2004 대한토목학회 학회지
3. 김홍택, 박성원, 권영호, 김진홍(2000), "인공신경망을 이용한 굴착 단계별 흙막이 벽체의 최대변위 예측 시스템 개발", 2000 한국지반공학회논문집, pp.83~97
4. 배규진, 김창용, 신휴성, 홍성완(1997), "인공 지능을 이용한 터널 인접 구조물의 안전진단 시스템 개발", 1997대한토목학회 논문집, pp.141~149
5. Kim, C.Y., Bae, G.J., Hong, S.W., Park, C.H., Moon, H.K., and Shin, H.S.(2001), " Neural network based prediction of ground surface settlement due to tunnelling." *Computers and Geotechnics*, 28(6-7), 517~547
6. Hagan, M.T and Demuth, H.B,(1996), "Neural Network Design", *PWS Publishing Co*, Boston
7. Garson, G.D. (1991). "Interpreting neural-network connection weights." *AI Expert*, 6(7), 47-51
8. Goh, A. T. C (1994). "Neural-network modeling of CPT seismic liquefaction data." *J. of Geotech. Eng.*, 122(1), 70-73
9. Jingsheng Shi, J.A.R. Ortigao and Junli Bai., 1998. Modular Neural Networks for Predicting Settlements during Tunneling, *Journal of Geotechnical and Geoenvironmental Engineering*, 389-391.