

# 인공신경망기법을 이용한 깊은 굴착에 따른 지표변위 예측

## Prediction of Deep Excavation-induced Ground Surface Movements Using Artificial Neural Network

유 충 식<sup>1</sup> Yoo, Chung-Sik

최 병 석<sup>2</sup> Choi, Byoung-Seok

### Abstract

This paper presents the prediction of deep excavation-induced ground surface movements using artificial neural network(ANN) technique, which is of prime importance in the damage assessment of adjacent buildings. A finite element model, which can realistically replicate deep excavation-induced ground movements, was employed to perform a parametric study on deep excavations with emphasis on ground movements. The result of the finite element analysis formed a basis for the Artificial Neural Network(ANN) system development. It was shown that the developed ANN system can be effective for a first-order prediction of ground movements associated with deep-excavation.

### 요    지

본 연구에서는, 굴착 공사로 인한 주변 건물 손상 평가의 일환으로 지표 변위 유형의 효과적인 예측 방안을 제시하였다. 먼저 검증된 유한 요소 모델을 국내에서 행해지는 다양한 경우의 굴착 특성으로 해석한 결과를 통해 인접 지반의 거동에 대한 매개 변수 연구를 수행하였고, 인공신경망 엔진의 학습을 위한 데이터베이스를 구축하였다. 최적의 구조로 학습된 신경망 엔진은 간단한 굴착 특성으로 다양하게 나타나는 지표 변위 유형 예측에 효율적임을 검증하였다.

**Keywords :** Artificial neural network, Deep-excavation, Finite element analysis, Parametric study

### 1. 서 론

도심지에서의 지하 공간 건설 공사에서는 지하 굴착 혹은 터널 공사 시 해당 구조물 자체의 안전한 시공은 물론 주변 구조물에 미치는 영향을 최소화하여야 한다는 전제조건이 전반적인 공사의 계획 단계 및 설계 단계에 지대한 영향을 미치는 요소로 대두되고 있다. 이를 위해서는 굴착에 따른 인접 지반의 효과적인 지반 거동 예측이 선행되어야 할 과제로 대두되고 있다. 일반적으로 개착식 굴착 공법에 따른 인접 지반의 변위 예측은, 굴착에 따른 흙막이 벽체 변위를 통해 간접적

으로 추정하는 방법을 택하고 있는 실정이다. 이러한 흙막이 구조물 설계 시, 벽체 변위 예측 방법 또한 탄소성 해석법, 유한 요소법, 유한 차분법 등을 이용해 이루어지고 있으며, 시공 중에는 계측을 통해 발생 변위에 따른 흙막이 구조물의 안정성을 평가하고 있다. 그러나 제한된 지반 조사 자료, 해석 시, 다양한 굴착 특성 반영의 난해함 등의 이유로 예측 결과와 실제 변위와 적지 않은 차이를 종종 나타내고 있다.

본 연구의 목적은 굴착으로 인해 발생되는 지반 변위의 효과적인 예측 방안을 제시하기 위함이다. 이를 위해 최근 지반 공학 분야에서 규명되지 않은 비선형

1 정희원, 성균관대학교 토목환경공학과 교수 (Member, Prof., Dept. of Civil & Environ. Engng., Sungkyunkwan Univ., csyoo@skku.edu)

2 성균관 대학교 건축, 조경, 토목공학부 토목공학과 석사과정 (Graduate Student, Dept. of Civil & Environ. Engng., Sungkyunkwan Univ.)

적인 복잡한 문제 해결을 위해 다수 적용 된 바 있는 인공신경망이론을 이용하여 예측 엔진을 구축하였다. 먼저 다양한 조건의 유한 요소 해석을 통해 굴착에 따른 인접 지반의 거동에 영향을 미치는 굴착 특성을 고찰하고, 국내에서 행해지는 일반적인 굴착 특성을 충분히 포함하는 범위내의 굴착 특성으로 해석을 수행하여 인공신경망의 학습을 위한 데이터베이스를 구축하였다. 인공신경망은지도 학습의 일종인 일반화 된 델타 규칙을 따르는 오차 역전파 알고리즘을 통해 최적의 구조로 수행되었다. 본 연구에서 제세된 신경망 엔진을 이용한 지표 변위 예측

결과는 유한 요소 해석의 결과와 잘 일치하는 것으로 나타났으며, 인공신경망 기법은 지표 변위 예측에 매우 효율적으로 적용할 수 있는 것으로 판단된다.

## 2. 기존 연구 현황

### 2.1 굴착에 따른 지표 변위 예측

굴착 주변 지반의 침하는 여러 가지 요인에 의해 발생 가능하며 경우에 따라서는 이들 요인의 메카니즘이

표 1. 흙막이 벽체의 최대 수평 변위에 대한 여러 가지 제안

제안자	지반 조건	토류구조물	제안값
Peck (1969)	조밀한 모래 또는 잔적토	Sheet pile H-pile + 토류판	$\delta_{h,m} = 1.0\%H$
Goldberg 등 (1976)	연약~단단한 점토	-	$\delta_{h,m} = 0.5\%H$
NAVFAC DM-7.2 (1982)	조밀한 사질토, 빙적토(till)	버팀보 지지	< 0.2%H ( 앵커<버팀보 )
	단단한 균열 점토 (stiff fissured clay)	-	$\delta_{h,m} = 0.5\%H$ ( 시공성에 따라 그 이상 )
	연약 점토	-	$\delta_{h,m} = (0.5 \sim 3.0)\%H$
Clough 와 O'Rourke (1990)	단단한 점성토, 잔적토, 모래	강성이 대~소	평균 : $\delta_{h,m} = 0.2\%H$ 상한 : $\delta_{h,m} = 0.5\%H$
Ou 등 (1993)	실트질 모래와 점토의 혼합지반	지하 연속 벽과 버팀보 지지	$\delta_{h,m} = (0.2 \sim 0.5)\%H$
이종규 (1993)	암반을 포함한 다층지반	Sheet pile	$\delta_{h,m} = 0.2\%H$
김연정 (1998)	국내 다층 지반	버팀보 지지	$\delta_{h,m} = 0.17\%H$
		앵커 지지	$\delta_{h,m} = 0.13\%H$

주)  $\delta_{h,m}$  - 벽체의 최대 횡방향 변위, H - 굴착 깊이

표 2. 지반 침하와 영향범위에 대한 여러 가지 제안

제안자	지반조건	토류구조물	제안값
Terzaghi 와 Peck (1967)	느슨한 모래, 자갈	H-Pile + 토류판 Sheet Pile	$\delta_{v,m} = 0.5\%H$
O'Rourke (1975)	중간~조밀한 모래	H-Pile + 토류판	$\delta_{v,m} = 0.5\%H$ $D=2H$
John St. (1975)	단단한 점토	지하 연속벽 Top-down 공법	$\delta_{v,m} = 0.3\%H$ $D=3H$
Goldberg 등 (1976)	연약~중간점토	-	$\delta_{v,m} >> \delta_{h,m}$ $D>2H$
	매우 단단~굳은 점토	-	$\delta_{v,m} = (0.5 \sim 1.0)\delta_{h,m}$ $D<2H$ (모래)
Mana와 Clough (1981)	연약~중간 점토	버팀보 지지	$\delta_{v,m} = (0.5 \sim 1.0)\delta_{h,m}$
Clough와 O'Rourke (1990)	단단한 점토	강성이 대~소	$\delta_{v,m} = 0.3\%H$ $D=3H$
	모래, 조립토		$\delta_{v,m} = 0.3\%H$ $D=2H$
Chang Yu-Ou (1993)	실트질 모래 및 점토의 혼합지반	지하 연속벽, 버팀보	$\delta_{v,m} = (0.5 \sim 1.0)\%H$
이종규 (1993)	암반이 포함된 지반	H-pile + 토류판	$\delta_{v,m} = 0.2\%H$
양구승 (1996)	퇴적 지반	H-pile + 토류판	$\delta_{v,m} = 0.3\%H$ $D=2H$
	암반을 포함한 지반	H-pile + 토류판	$\delta_{v,m} = 0.2\%H$ $D=3H$
김연정 (1998)	국내 다층 지반	H-pile + 토류판	$V_v/V_h=0.65 \sim 0.75$ $\delta_{v,m} = 0.2\%H$ $\delta_{v,m}/\delta_{h,m}=0.85$

\*  $\delta_{v,m}$ -지반의 최대 침하, D-영향거리,  $V_v$ -지반 침하 체적  $V_h$ -벽체 횡방향 변위 체적

나 적용범위가 실로 광범위하여 이론해석에 의한 정확성이 아직은 어느 정도 결여된 분야라고 볼 수 있다. 그러나 굴착 주변 지반 침하의 가장 큰 원인은 지지벽체의 횡방향 변위이며 계측이나 계산으로 산정된 지지 벽체의 횡 방향 변위로부터 주변 지반 침하를 추정하거나 베텀 구조와 지반을 일체로 해석하는 등의 주변 지반 침하를 예측하는 다양한 방법들이 제시된 바 있다.

표 1과 2에 제시된 바와 같이 기존 연구는 정확한 지표 변위 유형에 대한 예측 보다는 최대 변위 예측에 주안점을 두었으며, 특정 지반과 흙막이 벽체에 대한 연구로 그 제한성이 있다. 또한 지표 변위 특성에 큰 영향을 주는 시공 과정에 대한 연구와 주변 건물손상 평가에 주 고려 대상인 지반의 수평 변위 예측에 대한 연구가 미비한 실정이다.

## 2.2 인공신경망의 공학 문제의 적용

인공신경망은 생물학적 신경 처리의 연구에 의해 개발된 구조이다. 신경망 구조는 신경 처리 과정에 대한 이론만큼 다양한 형태로 소개 되고 있다. 본 연구에서는 입력층, 은닉층, 출력층으로 구성되는 계층적 피드포워드(layered feed-forward) 신경망구조를 선택하였다. 피드포워드 신경망의 학습은 주로 지도 학습의 일종인 일반화 된 델타 규칙을 따르는 오차 역전파 방식으로 한다. 일반화된 델타 규칙은 가장 가파른 방향의 기울기에서 음의 부호를 갖는 기울기를 선택하여 신경망 뉴런의 가중치와 임계치의 조절을 통해 최소 오차 지점을 찾아 가는 것으로, 기존 연구에서 다수 제시된 바 있다. 인공신경망 이론은 인공지능의 한 분야로 추론 및 판단 측면에서 신속성과 정확성을 지니고 있으며, 인공신경망 자체에서 수집된 데이터의 상호 관련성을 인식하고 분류함으로서 명확한 관계의 규명이 가능

하여 기존의 방법으로 데이터베이스화하기 어려운 불확실한 정보의 처리가 가능하므로, 현장 자료를 바탕으로 한 지반 거동의 추론에 적합하다. 따라서 지반 거동에 대한 예측 시 인공신경망을 통해 활용한 관련 자료를 활용하여, 기존의 방법과는 다른 새로운 측면에서 지반 거동 특성을 파악할 수 있다. 인공신경망의 활용성은 국외뿐만 아니라 국내에서도 활발히 연구되었고, 효율성이 검증된 바 있다. 지반 공학 문제와 관련하여, 국외에서는 얇은 기초의 침하 예측(Shahin 등 2002), 흡입식 케이슨 설치 시 양압력에 대한 저항력 산정(Rahman 등 2001), 모래와 자갈층의 삼축 압축 상태 거동특성 분석(Penumadu 등 1998), 국내에서는 화강풍화토의 토량 변화율 추정(김영수 등, 2001), 해성점토의 압축 특성 분석(김병탁 등, 2002), 굴착 단계별 흙막이 벽체의 최대 변위 예측 시스템 개발(김홍택 등, 2000) 등 불명확한 지반 공학적 문제 해결에 인공신경망 기법이 사용된 바 있다.

## 3. 유한 요소 모델

본 절은 굴착 공사를 효과적으로 표현 가능한 유한 요소 모델의 구축 방안과 실대형 실험을 통한 유한 요소 모델의 검증 과정에 관한 내용이다.

### 3.1 대상 지반

본 연구에서는 그림 3에서 제시된 우리나라 도심지에서의 일반적인 굴착 조건을 대상으로 하였다. 보이는 바와 같이 굴착조건은 깊이 20m, 넓이 30m, 표 3은 본 연구의 유한요소 해석에 사용한 암반층을 포함한 국내 대표 지반의 역학적 특성을 정리하였다.

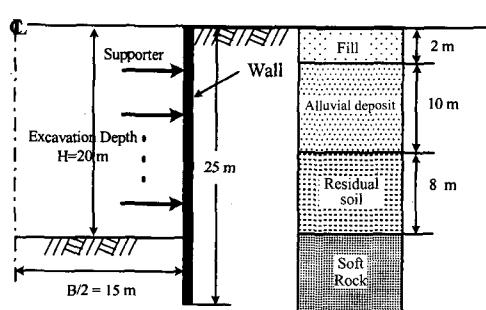


그림 1. 굴착 현장 조건

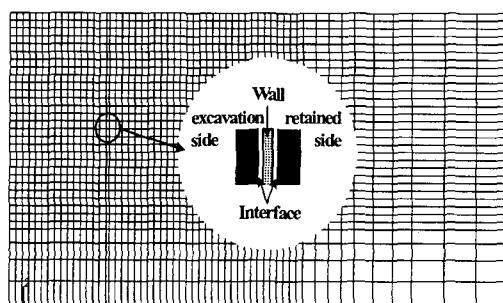


그림 2. 유한 요소망

표 3. 유한요소 모델의 역학적 특성(기본조건)

	C(kPa)	$\phi$ (deg)	$\phi_v$ (deg)	$\psi$ (deg)	$E_s$ (kPa)
매립토	3	28	20	10	15,000
총적토	15	35	28	6	35,000
풍화암	50	38	32	6	50,000
연암	100	45	40	6	500,000

주)  $c$ =접착력;  $\phi$ =내부마찰각;  $\phi_v$ =한계상태 내부마찰각;  $\psi$ =팽창각;  $E_s$ =변형계수

### 3.2 유한요소 모델

유한 요소 해석은 소성 지반 해석에 타당하고, 효과적인 상호면 모델링이 가능한 상용화 된 유한 요소 해석 코드 ABAQUS Ver 6.3(ABAQUS 1998)로 수행하였다. 지반과 벽체는 8절점사각형요소(CPE8R), 스트러트는 1 절점 스프링 요소(SPRING1)를 채택 하였다. 유한요소 망은 대략 5800 절점과 1870요소로 구성 되었고, 모델은 세로 방향으로 1.0H, 가로 방향으로 3.6H의 크기로 주변 영역을 굴착 중심면을 기준으로 대칭성을 이용해 간략하고, 예비 해석을 통하여 경계면은 해석의 결과에 영향이 없게 설계하였다. 실제 굴착 현상의 효과적인 구현을 위해 흙막이 벽체를 중심으로 굴착면과 배면 모두에 Contact pair를 사용하여 벽면과 지반의 상호작용을 표현하였다.

$$\sin \psi = \frac{\sin \phi - \sin \phi_{cv}}{1 - \sin \phi \sin \phi_{cv}} \quad (1)$$

여기서,  $\psi$  = 팽창각

$\phi$  = 내부마찰각

$\phi_v$  = 한계상태 내부마찰각

해석 시, 각 요소의 역학적 특성은, 지반의 경우 Davis (1968).에 의해 제안 된 비관련 흐름법칙과, Drucker-Prager 파괴 기준을 따르는 탄소성으로, 벽면과 베티드는 선형 탄성으로 가정하였다. 해석에 필요한 팽창각( $\psi$ )은 Row's stress-dilatancy 이론(1962)의 식 (1)로 산정하였고, 벽체와 지반의 Contact pair의 특성은 마찰 계수( $\mu$ )

가 slip rate( $v_{eq}$ )로 정의 되는 등방성 Coulomb 마찰 모델을 이용하여  $20^\circ$ 의 내부 마찰각을 가지는 마찰 모델식 (2)로 표현하였다.

$$\mu = \frac{\gamma_{eq}}{p} \quad (2)$$

여기서,  $\mu$  = 마찰계수  
 $p$  = contact pressure

### 3.3 유한 요소 모델의 검증

유한 요소 모델은 실제 현장의 계측 자료를 통해 검증된 후 사용되어야 하나, 도심지의 제한적인 주변 환경으로 인해 지표 변위 유형의 계측 데이터 확보가 어려운 실정이다. 따라서 본 연구에서 제시된 유한 요소 해석 모델은 미국 일리노이 대학에서 수행한 실대형 실험을 통한 결과와 비교하여 지반 모델 및 상호면 요소, 굴착 모델의 구현 방법을 검증하였다.

그림 3은 실대형 모형으로 총 굴착 깊이가 1.9m이고, 벽면은 두개의 앵커로 지지 되었고, 염지말뚝은 총 높이가 2.2m이며, 0.3m 근입 되어 졌고, 실제 굴착과 벽면을 1/4로 일반화하여 축소되었다. 염지 말뚝 모델은 철제 사각 단면으로 지지면 중앙에 위치되었고, 또한 0.3cm의 철판으로 흙막이 판을 모형화 하였다. 앵커는 0.63cm의 강봉을 사용하였고, 유연하고 팽창성 있는 판 안에 위치되어 지반과 분리 시켰다. 지반은 통일분류법에 따라 SP로 분류되는 균질한 중간질의 모래로 구성하였다. 표 5는 모델의 역학적 특성을 정리한 것이다. 해석

표 4. 실험 모델의 역학적 특성

	$\phi$ (deg)	$\phi_v$ (deg)	$\psi$ (deg)	$E_s$ (kPa)	$\gamma_s$ (kN/m <sup>3</sup> )
sand	40	35	6	$1234 \times (\sigma_3)^{0.5}$	18
벽체의 휨 강성 ( $EI_w = 14kN-m^2/m$ )					
앵커의 축 강성 $K = 28kN/m$					

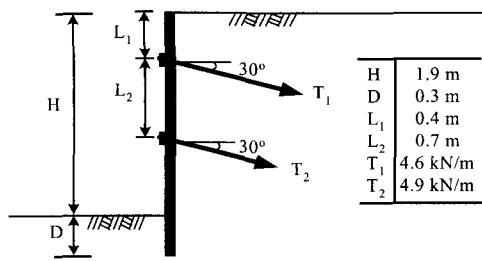


그림 3. 실대형 실험

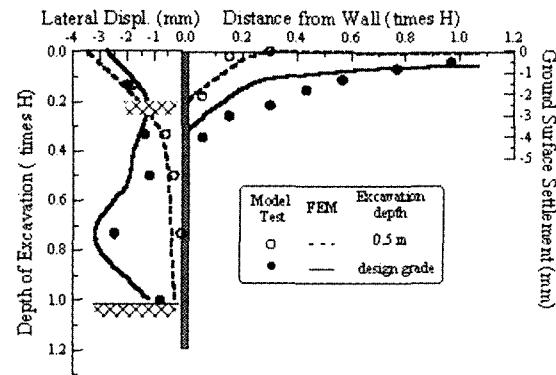


그림 4. 결과 비교

모델링은 앞서 언급하나 동일한 방법으로 수행하였으며 앵커는 2절점 스프링 요소를 이용하여 모델링 하였다. 그림 4는 해석 결과와 실험 결과를 비교하고 있는데 보이는 바와 같이 굴착 단계별로 다소의 차이는 있으나 변위량이나 침하 패턴이 잘 일치하는 것으로 나타났다.

#### 3.4 해석 조건

표 5는 본 연구에서 적용한 굴착 조건의 범위로서 굴착에 따른 인접지반의 거동에 영향을 미치는 굴착 특성을 고찰하고, 인공신경망 학습에 사용될 데이터베이스

표 5. 해석 조건

굴착 특성 (영향인자)	데이터 범위
흙막이 벽체 강성 ( $EI_w$ )	17 ~ 430 ( $kN\cdot m^2/m$ )
肯탈레버 굴착 깊이 $H_{un}$	2 ~ 4 (m)
무지보 굴착 깊이 L	3 ~ 6 (m)
지반 강성 $E_s$	표 4 값을 각각 30%, 50% 증가

를 구축하기 위해 일반적인 현장에서 채택하는 다양한 굴착 조건을 포함한다.

#### 4. 지반굴착에 따른 지표 변위 곡선 특성

##### 4.1 지표 변위 성분

굴착 공사로 인해 발생되는 지표 변위는 굴착 조건에 따라 발생되는 흙막이지지 벽체의 변위에 큰 영향을 받는다. 굴착 완료후의 지표 변위는 최 상단 지보재 설치 이전, 캔탈레버 형태의 벽체 변위에 영향을 받는 캔탈레버 단계와 그 이후 최 하단 지보재와 굴착 저면 사이에 발생하는 측방 배부를 형태의 벽체 변위에 영향을 받는 측방 배부를 단계의 변위로 나누어 진다(유충식, 2002). 본 절에서는 언급된 내용을 토대로 유한 요소 해석을 수행하여, 굴착에 따른 지표 변위 특성을 파악하였다.

그림 5는 동일한 굴착 조건에서 l(무지보 굴착 깊이)을 3m로 유지하고  $H_{un}$ (肯탈레버 굴착 깊이)의 변화에

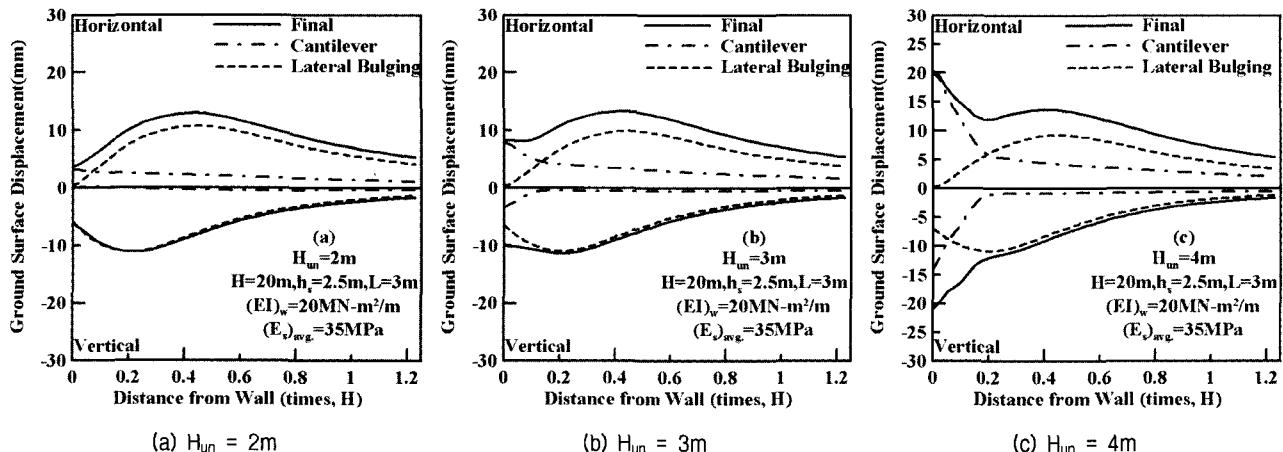


그림 5. L=3m일때,  $H_{un}$ 에 따른 지표 변위 유형

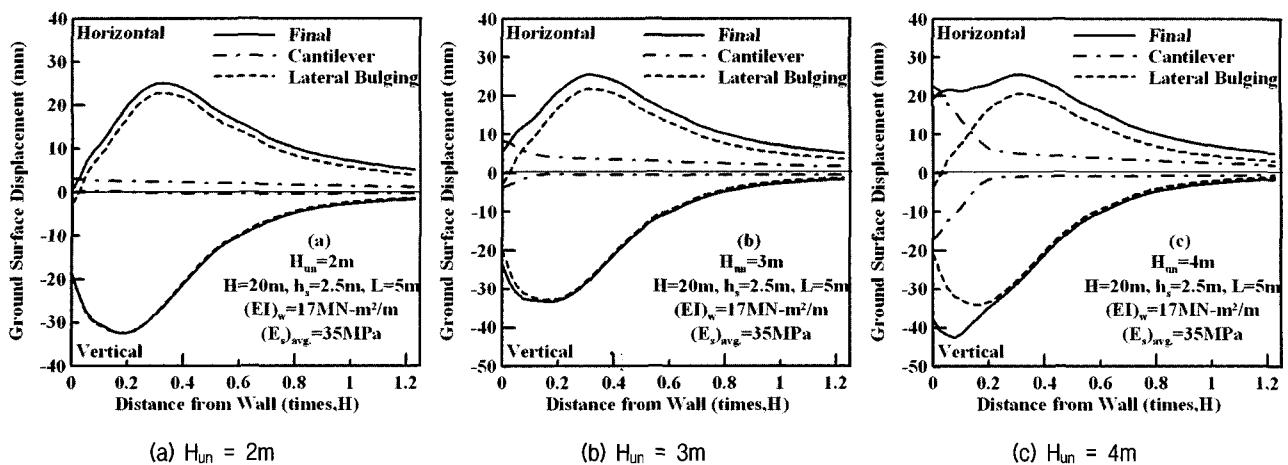


그림 6.  $L=5m$ 일때,  $H_{un}$ 에 따른 지표 변위 유형

따른 지표 변위 곡선에 대한 유한 요소 해석 결과로서 지표의 수평, 수직 변위에 대해 최종 굴착 완료 후, 캔틸레버 단계와 측방 배부름 단계의 지표 변위는 최종 굴착 완료 후의 변위에서 캔틸레버 단계의 변위를 제거하여 표현되었다. 그림 5(a)는  $H_{un}=2m$ 로 유지한 결과로서 캔틸레버 단계의 변위의 경우,  $H_{un}$ 이 작아서 캔틸레버 성분이 거의 발생하지 않는다. 따라서 굴착 완료 후의 지표 변위는  $L$ 의 영향을 받아 측방 배부름 단계의 변위와 거의 동일하게 아래로 불룩한 유형으로 나타났다. 반면에 그림 5(c)에서  $H_{un}=4m$ 의 경우, 최 상단 지보재가 늦게 설치된 관계로 캔틸레버 단계의 변위가 크게 발생하고, 이로 인해 굴착 완료 후의 지표 변위는 굴착 벽면에 가까울수록 커지는 포물선 유형으로 나타났다. 한편  $H_{un}$ 이 변화되더라도 측방 배부름 단계에서의 변위 곡선은 거의 일치하는 것으로 나타났는데 이는 지표 변위 곡선이 캔틸레버 성분과 측방 배부름 단계에서 무지보 굴착

깊이( $L$ )가 달라져도 유사한 경향을 보이고 있다. 이를 통해 굴착 완료 후에 발생된 지표 변위는 여러 굴착 특성에 영향으로 복잡한 형태로 나타나나, 캔틸레버 단계와 측방 배부름 단계로 구분하여 평가 할 수 있는 것으로 판단된다.

#### 4.2 지표 변위 곡선 특성 변화 경향

본 절에서는  $(EI)_w$ ,  $H_{un}$ ,  $L$ 이 지표 변위에 미치는 영향에 대해 알아보았다. 그림 7은 도일한 굴착 특성( $H_{un}=4$ ,  $L=5$ )에 대해  $(EI)_w$ 를 17, 140, 420  $MN\cdot m^2/m$ 로 변화시켜 유한요소 해석을 수행한 결과이다. 각 그림은 위질과 마찬가지로 단계별로 나누어 구성되었다. 그림에서 보이는 바와 같이  $(EI)_w$ 는 지표 변위 값 뿐만 아니라 지표 변위 유형에도 크게 영향을 미친다. 즉  $(EI)_w$ 가 커질수록 캔틸레버 단계의 변위 값은 측방 배부름 단계에 발생되

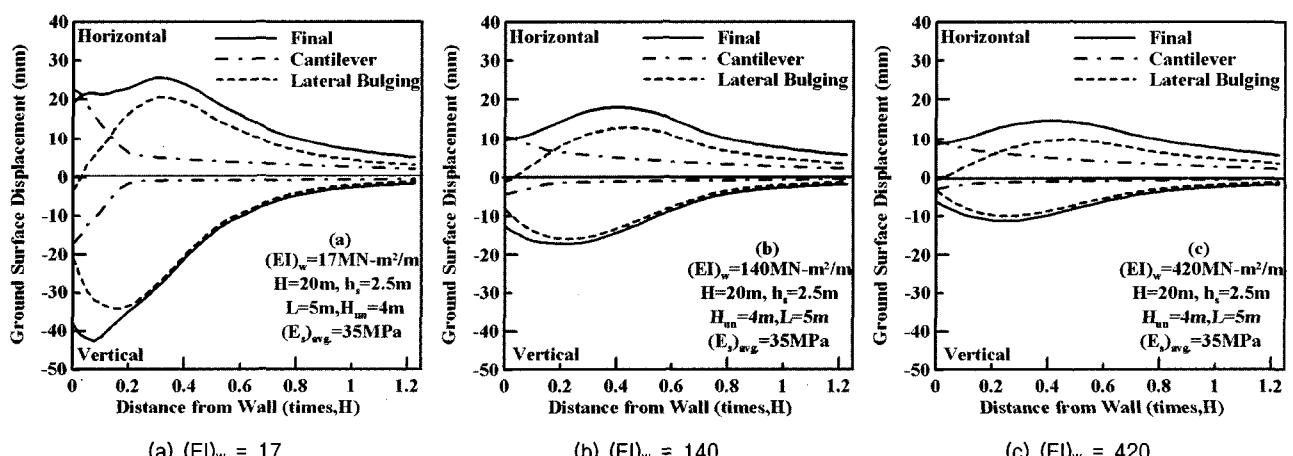


그림 7.  $(EI)_w$ 에 따른 지표 변위 유형( $(EI)_w, MN\cdot m^2/m$ )

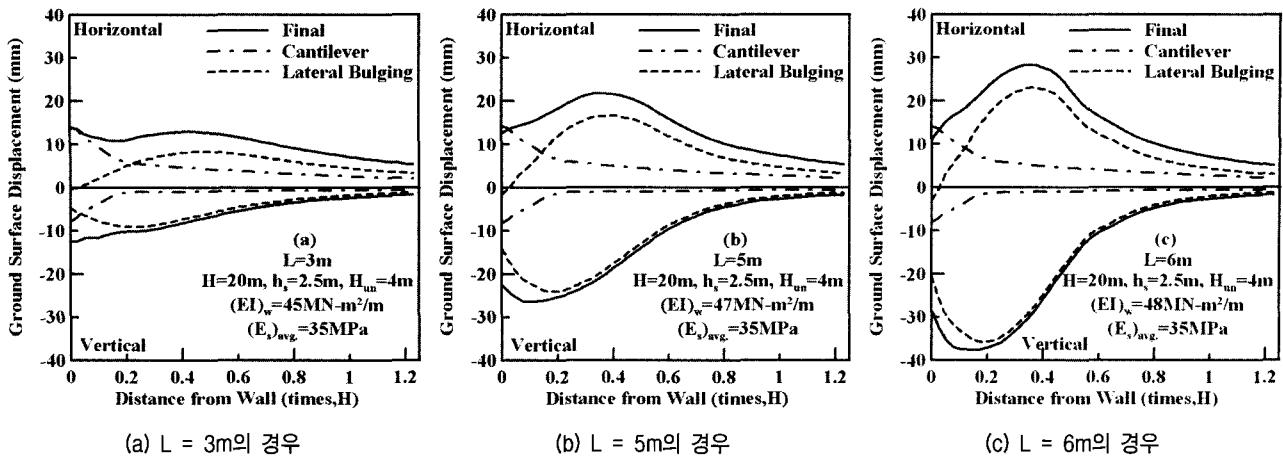


그림 8.  $L$ 에 따른 지표 변위 유형

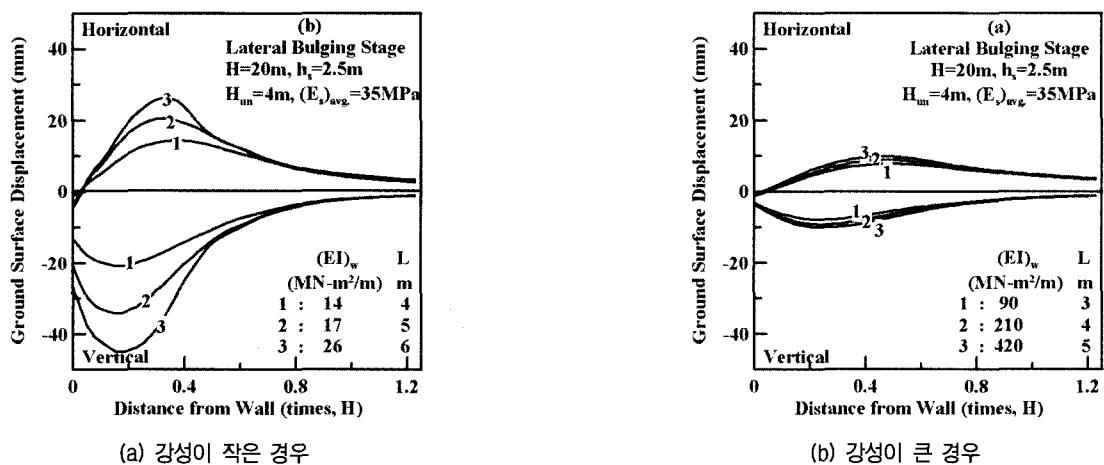


그림 9.  $E$ 과  $L$ 에 따른 측방 배부름 단계의 변위 분포

는 변위 값보다 상대적으로 작아 굴착 완료 후 지표 변위 유형에 큰 영향을 미치지 않은 경향을 보인다(그림 7(b), (c)). 반면  $(EI)_w$ 가 감소할수록 캔틸레버 단계에 과도한 변위가 발생하여 전체 지표 변위 유형은 굴착 벽면에 가까울수록 커지는 포물선 형태로 나타남을 알 수 있다(그림 7(a)).

그림 8은  $(EI)_w$ 와  $H_{un}$ 이 동일한 경우,  $L$ 을 각각 3m, 5m, 6m로 변화하여 해석을 수행한 결과로서 각 그림은 굴착 완료 후, 캔틸레버 단계, 측방배부름 단계로 나누어 구성되었다. 그림에서 보이는 바와 같이  $L$ 의 변화는 캔틸레버 단계에는 전혀 영향을 미치지 않는 것으로 나타났으며,  $L$ 이 감소할수록 측방 배부름 단계의 변위를 억제하여 굴착 완료 후의 지표 변위는 캔틸레버 단계의 영향을 받아 포물선 유형을 보이고(그림 8(a)), 반면에  $L$ 이 증가할수록 측방 배부름 단계의 변위가 크게 발생되는 관계로, 굴착 완료 후의 지표 변위에 큰 영향을 주

어 아래로 불록한 유형으로 나타났다(그림 8(c)).

그림 9는 측방 배부름 단계의 변위를 정리한 것으로, 그림 9(a)는 비교적 강성이 작은 흙막이 벽체, 그림 9(b)는 강성이 큰 벽체에  $L$ 을 변화 시켜 해석한 결과를 정리한 것으로  $L$ 이 지표 변위에 영향을 미치는 정도가 벽체의 강성에 따라 다소 다른 것을 보여 주고 있다. 그림에서 보이는 바와 같이 강성이 큰 경우  $L$ 은 측방 배부름 단계의 변위에 영향을 크게 미치지 않고(그림 9(b)), 강성이 작은 벽체의 경우  $L$ 은 측방 배부름 단계에 큰 영향을 미치는 것으로 나타났다(그림 9(a)). 한편 측방 배부름 단계의 지표 침하 곡선 유형의 경우 굴착 벽면으로부터 0.2-0.3H 구간에 최대 변위가 발생하는 아래로 불록한 형태를 보이고, 수평 변위 곡선 유형은 지표 침하 곡선과 유사한 형태로 0.3-0.4H 구간에 최대 변위가 발생하는 것으로 나타났다.

이러한 경향을 종합적으로 고찰해 보면, 최종 굴착 완

료 후의 지표 곡선은 캔틸레버 단계 및 측방 배부를 단계의 변위 성분 크기에 따라 포물선 혹은 아래로 볼록한 형태를 띠는 것으로 나타났다. 따라서 각 단계에서의 지표 변위 곡선의 합으로 굴착 완료 후 지표 변위 곡선을 표현하는 것이 바람직하다고 사료된다.

#### 4.3 정규화 된 지표 변위 곡선

효과적인 변위 예측을 위해서는 다양한 조건에 대한 변위의 정규화 과정을 통해 그 특성을 파악할 필요가 있다. 그림 10은  $(EI)_w$ 와 L에 따라 변하는 측방 배부를 단계의 지표 변위 값을 정규화하여 표현된 것이다. 4.2 절에서는 실제 변위 값은 굴착 특성에 따라 크게 변화하는 것을 살펴보았다. 반면 그림 10의 정규화 되어 표현된 측방 배부를 변위 유형은 모든 조건에서 굴착 면으로부터 다소 먼 지점에 최대 변위가 발생하는 오목한 형태로 유사하게 표현된다. 이러한 결과는 본 연구에서 살펴본 대상과 같은 굴착 조건에서 지표 변위 곡선은 정규화된 곡선으로 유사한 표현이 가능함을 의미하며 임의의 굴착 조건에서 변위의 최대 값을 예측하여, 정규화 된 지표 변위 유형에 곱해주면 굴착 완료 후의 지표 변위 분포의 예측이 가능하다는 장점이 있다.

### 5. 인공신경망(ANN)을 이용한 지표 변위 곡선 예측

본 절에서는 Matlab Tool을 이용하여 효과적인 지표 변위 예측을 위해 이용될 굴착 특성에 따른 지표의 최대 변위와 정규화 된 변위 특성을 예측하는 인공신경망을

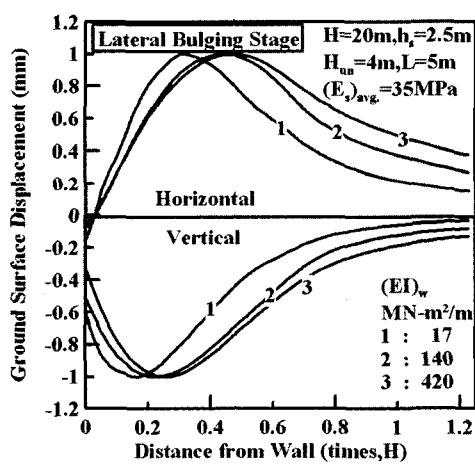
구현하였다.

#### 5.1 Matlab

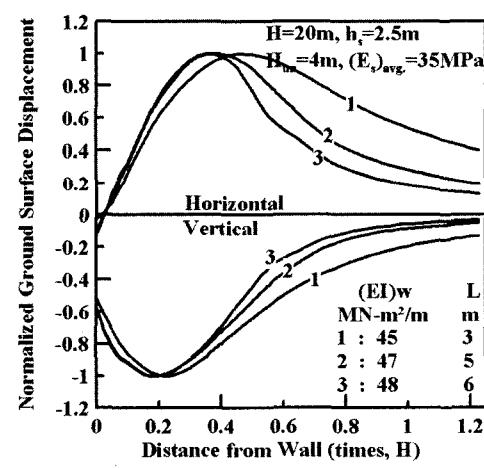
MATLAB은 MATrix LABoratory의 약어로서, 행렬을 기초로 하여 수학과 관련된 계산, 알고리즘 개발, 상황 모델링과 data 분석 여러 가지 과학과 공학적인 그래픽적 표현, GUI(graphical user interface)에 의한 application 개발 등에 다양하게 이용되고 있다. MATLAB은 사용자의 편의를 위한 toolbox를 가지고 있다. toolbox란 신호 처리, 통계학, 영상 처리, 제어, fuzzy logic, Neural Network, 재정, 화학 공정, simulink 등등 해당 전공부분의 내용을 심도 있게 지원하는 함수들의 도서관과 같다. 본 연구에서는 Neural Network 디렉토리를 사용하여 인공신경망을 구현하였다.

#### 5.2 데이터 베이스 구축

인공신경망을 통해 목적 패턴을 정확히 예측하기 위해서는 신경망 학습에 사용 될 효율적인 데이터베이스 구축이 선행되어야 한다. 체계적인 지표 변위 예측을 위해 3절의 결과를 반영하여 목적패턴에 따라 효과적인 입력정보를 구성하였다. 먼저 정성적인 지표 변위 특성은 캔틸레버 단계에서 벽체의 강성과 캔틸레버 굴착 깊이가 주된 영향 인자가 되며 이를 신경망의 입력 정보로 활용하였으며, 측방 배부를 단계에서는 벽체의 강성과 무지보 굴착 깊이를 입력 정보로 하여, 지표 변위 특성을 예측 하였다. 또한 정량적인 최대 지표 변위 값의 예



(a) 변수 =  $(EI)_w$



(b) 변수 =  $(EI)_w, L$

그림 10. 측방배부를 단계의 정규화 된 지표 변위 곡선

표 6. 목적패턴별 입력정보의 범위

굴착 단계	목적패턴	입력정보	범위	패턴 수
켄틸레버 단계	지표 수평 변위 경향	$(EI)_w$	17 ~ 430 ( $MN \cdot m^2/m$ )	69 case
	지표 수직 변위 경향	$H_{un}$	2 ~ 4 (m)	
축방배부름 단계	지표 수평 변위 경향	$(EI)_w$	17 ~ 430 ( $MN \cdot m^2/m$ )	23 case
	지표 수직 변위 경향	L	3~6(m)	
켄틸레버 단계	최대 수평 변위	$(EI)_w$	17 ~ 430 ( $MN \cdot m^2/m$ )	207 case
	최대 수직 변위	$H_{un}$	2 ~ 4 (m)	
축방배부름 단계	최대 수평 변위	L	3~6(m)	
	최대 수직 변위	$(E_s)_{avg}$	표 4의 30, 50% 증가	

축을 위한 신경망의 입력정보는 벽체의 휨 강성, 켄틸레버 굴착 깊이, 무지보 굴착 깊이에 지반 강성을 포함하여 구성하였다(표 6).

데이터베이스는 인공신경망의 지도 학습을 위해 입력정보에 따른 목적패턴으로 구성하였으며, 입력정보는 각 단계의 지표 변위의 영향인자로 구성되었다. 이에 대한 출력 패턴은 영향 인자를 토대로 유한 요소 모델을 해석한 결과를 이용하여 각 단계의 정규화된 지표 변위 곡선으로 구성하였다. 또한, 본 연구에서 사용된 신경망 뉴런의 활성함수는 비선형적인 패턴인식에 효과적인 시그모이드 함수이며 신경망의 학습 후 수렴정도를 높이기 위해 학습 전에 데이터를 0과 1 사이의 값으로 정규화하였다. 식 (3)의 정규화 방법은 이미 적용된 바 있는 Master(1993)의 방법으로, 학습 데이터 중 최대 값과 최소 값을  $x_{max}$  와  $x_{min}$ 이라고 한다면 임의 값  $x$ 는  $x_{norm}$ 으로 정규화된다.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3)$$

위 식 (3)을 통해 입력 정보는 0과 1사이의 값으로 정규화되어 신경망 학습에 적용되었다. 또한 데이터의 정규화는 입력정보에 국한되지 않고 목적 패턴에도 적용되어야 한다. 지표 변위 경향을 예측하기 위한 신경망의 목적 패턴에 적용된 정규화 방법은 입력정보의 정규화 방법을 따르지 않았으며 목적 패턴의 확보 시, 각 지점에 대한 값들을 해당 결과의 최대값으로 나누어 1보다 작은 값으로 표현된 데이터를 직접 학습 데이터로 사용하였으며, 총 50개 지점의 정규화된 지표 변위 값으로 표현되었다. 반면 최대 지표 변위를 예측하기 위한 신경망의 목적 패턴은 총 207 case의 최대 변위 값들을 입력 정보의 정규화 과정과 동일하게 식 (3)을 이용하여 0과 1 사이로 표현되었다.

### 5.3 인공신경망(ANN)엔진 구조의 최적화 및 학습

인공신경망은 설계 파라메타를 조절함으로써 예측의 정확성을 향상시키고, 학습에 소요되는 시간을 감소시킬 수 있으며, 신경망 설계 시 조절되는 요소들은 은닉층 뉴런수와 은닉층의 개수, 가중치의 학습률, 모멘텀으로 볼 수 있고, 이들의 적절한 조절을 통하여 효율적이고, 정확한 현상의 예측이 가능하게 된다.

그림 11은 켄틸레버 단계의 인접 지반의 수평변위 예측 신경망의 각 설계 파라메타들을 변화시키며 신경망을 설계하였을 때 시스템의 오차의 변화율을 보여 주고 있으며, 그 설계 파라메타의 조절과정은 먼저 하나의 은닉층으로 모멘텀(0.8)과 학습률(0.2)은 일반적으로 많이 쓰이는 수치를 설계에 이용하였다. 뉴런수를 변화시키며 학습하였을 때 은닉층의 뉴런 수가 200개인 경우의 오차가 가장 작았으며, 지반 수평 변위의 정확한 예측을 위해 은닉층의 수를 증가시켜 학습한 경우, 200개의 뉴런을 가진 3개의 은닉층이 신경망 구조에 포함 되었을 때 만족스런 예측 결과를 나타내었고 그 이상의 은닉층을 가지면 시스템의 오차는 증가하게 됨을 볼 수 있다. 200개의 뉴런을 가진 3개의 은닉층이 포함된 신경망 구조로 모멘텀과 학습률을 각각 그림 19와 같이 변화시켰을 때 모멘텀은 0.8, 학습률은 0.2의 경우, 시스템 오차는 최소가 되었다. 위 결과에서 보이는 바와 같이, 정확한 예측 결과를 위한 시스템 오차( $10^{-7}$ )의 신경망 설계를 위해 은닉층 뉴런 수 200개, 은닉층 수 3개, 모멘텀 0.8, 학습률 0.2의 신경망이 목표한 시스템의 오차에 근접함을 볼 수 있으며, 표 7은 위와 동일한 방법으로 각각의 신경망 구조의 최적화를 위해 결정된 설계 파라메타를 보여주고 있다.

최적화된 구조로 학습된 인공신경망은 학습에 이용된 데이터에 대한 정확한 예측을 하게 됨은 자명한 사실

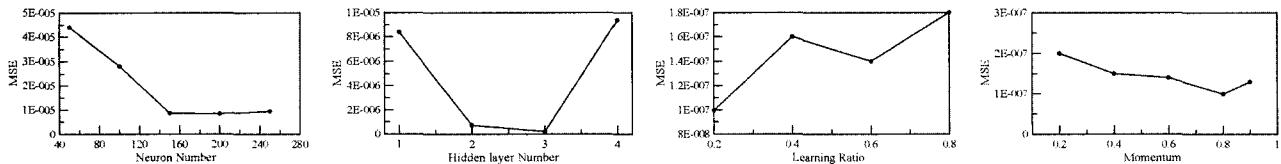


그림 11. 설계 파라메타에 따른 신경망의 시스템 오차

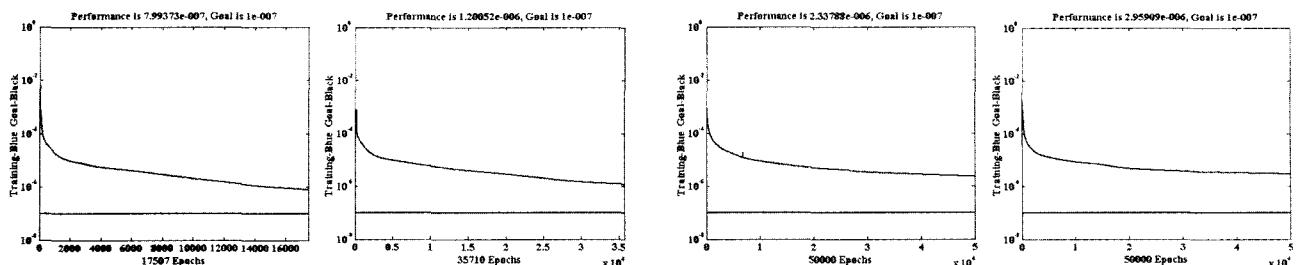


그림 12. 각 단계별 최대 변위 예측 신경망의 Mean Square Error 수렴 과정

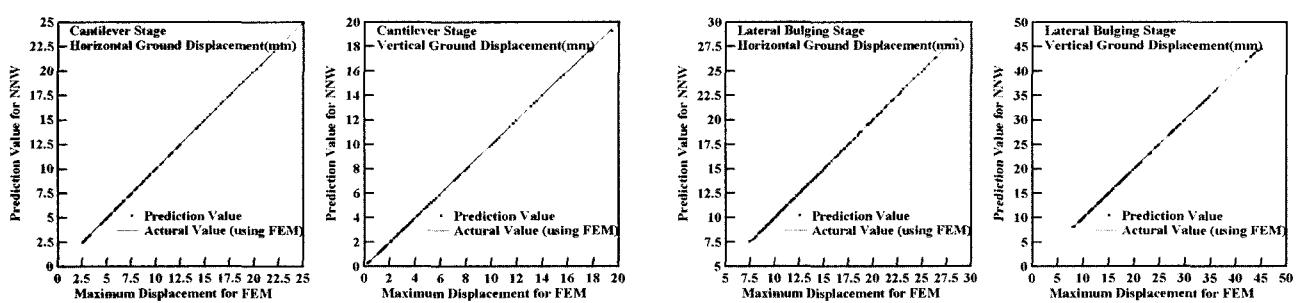


그림 13. 신경망을 통해 학습 시 사용된 데이터의 예측 결과

표 7. 최적화 된 신경망의 설계 파라메타

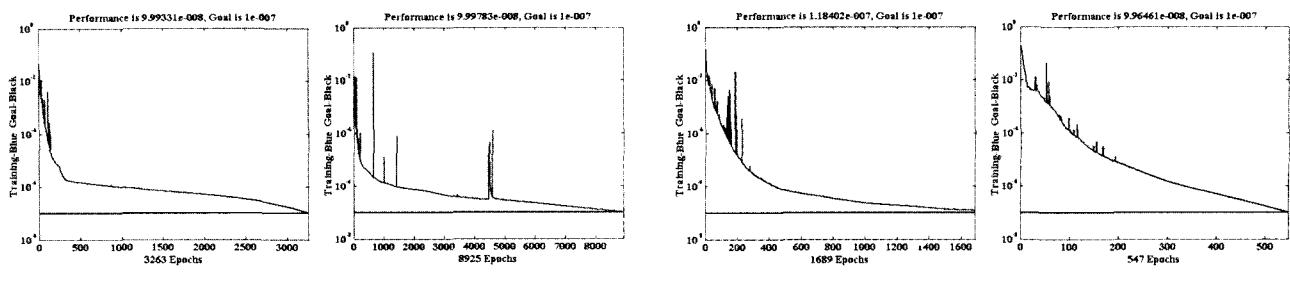
Type	Input node	Hidden Layer	Output Neuron	Lr	M	MSE
Norm. Cantilever H.disp.	2( $(EI)_w$ , $H_{un}$ )	3(200)	50	0.2	0.8	9.9E-08
Norm. Cantilever V.disp.		3(200)	50	0.2	0.9	9.9E-08
Norm. Lateral bulging H.disp.	2( $(EI)_w$ , $L$ )	3(200)	50	0.4	0.9	1.2E-07
Norm. Lateral bulging V.disp.		3(200)	50	0.2	0.8	9.9E-08
Max. Cantilever H.disp.	$(EI)_w$ , $(E_s)_{avg}$ $H_{un}$ , $L$	2(20-15)	1	0.4	0.8	7.9E-07
Max. Cantilever V.disp.		2(20-15)	1	0.2	0.7	1.2E-06
Max. Lateral bulging H.disp.		2(30-15)	1	0.2	0.9	2.3E-06
Max. Lateral bulging V.disp.		2(30-15)	1	0.4	0.9	2.9E-06

\*Lr – 학습률, M – 모멘텀, MSE – Mean Square Error

이다. 신경망의 최적화 과정을 통해 얻어진 시스템 오차의 정도를 보면 학습에 사용된 데이터의 입력 정보를 통한 목적 패턴의 예측 결과를 예상할 수 있으며, 이는 예측 기법의 정확성과도 깊이 연관 된다. 그림 12는 단계별 최대 변위 예측 신경망의 오차 수렴 과정을 보여 주고 있으며, 그림 13은 학습에 사용된 패턴에 대한 예

측의 정확성을 보여 주고 있다.

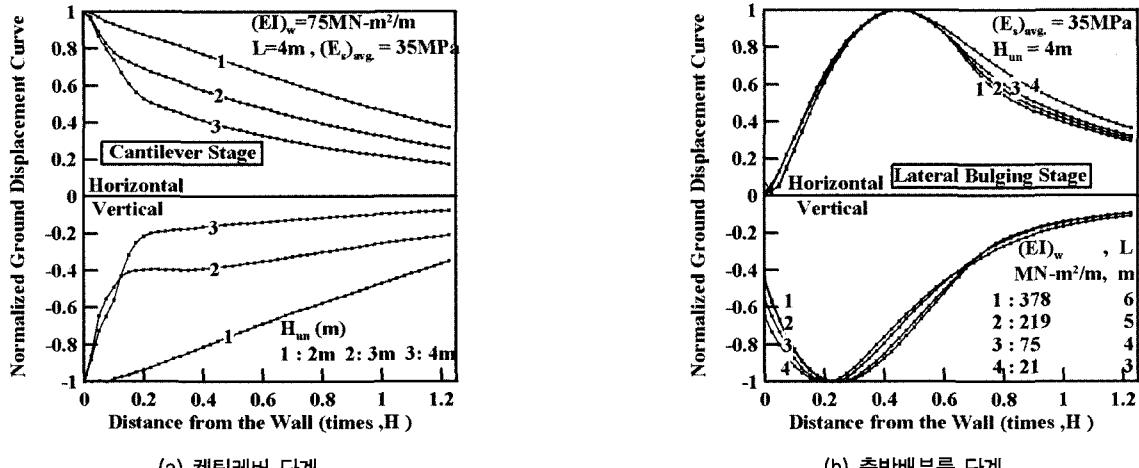
그림 14는 굴착 단계별 정규화 된 지표 변위 유형 예측 신경망의 오차 수렴 과정이며 모두 적정수준의 시스템 오차(1.0E-07)까지 도달하였으며, 그림 15는 유한 요소 해석 결과와 신경망을 통한 예측 결과와 비교를 통해 학습에 사용된 패턴의 정확성을 보여 주고 있다.



(a) 켄틸레버 단계의 수평, 수직 변위 특성

(b) 측방 배부름 단계의 수평, 수직 변위 특성

그림 14. 정규화 된 지표 변위 특성 예측 신경망의 Mean Square Error 수렴 과정



(a) 켄틸레버 단계

(b) 측방배부름 단계

그림 15. 신경망을 통해 학습 시 사용된 데이터의 예측 결과

## 6. 인공신경망(ANN) 엔진의 적용

### 6.1 개요

단계별 굴착의 효과적인 지표 변위의 예측을 위해 먼저, 최적화 되어 학습된 인공신경망을 통해 켄틸레버 단계와 측방 배부름 단계의 정규화 된 지표 변위 특성 곡선을 예측하였다. 현장 계측이나 예측을 통해 얻어진 각 단계의 최대 변위 값과 정규화 곡선의 곱으로 실제 변위 곡선을 예측한 후, 마지막으로 두 단계의 변위 곡선을

더하여 굴착에 따른 최종 지표 변위 곡선을 예측하는 방법을 택하였다(그림 16).

### 6.2 적용 예

#### 6.2.1 대상 굴착 특성

표 8은 인공신경망의 학습에 사용된 데이터 베이스에 포함 되지 않은 굴착 특성이다. 제시된 굴착 특성으로 본 논문에서 제시한 예측 기법에 따라 지표 변위를 추정하였다.

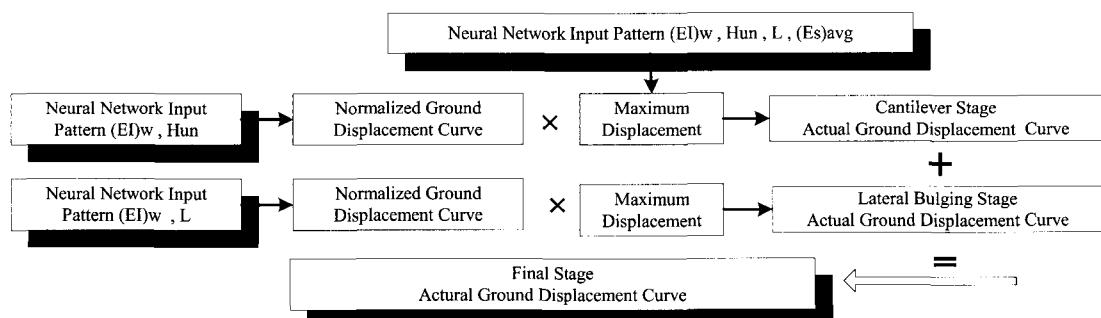


그림 16. 지표 변위 예측 기법

표 8. 신경망의 신뢰성 검증을 위한 입력 정보

굴착 특성 (영향인자)	데이터의 범위	데이터의 정규화
흙막이 벽체 강성 ( $EI_w$ )	20, 60, 120, 300 ( $MN \cdot m^2/m$ )	0.01359 – 0.70419
肯틸레버 굴착 깊이 $H_{un}$	4 (m)	1
무지보 굴착 깊이 L	4 (m)	0.3333
지반 강성 $E_s$	표 4 값의 20% 증가	0.4

### 6.2.2 단계별 최대 변위 및 정규화 된 지표 변위 유형 예측

표 9의 모든 굴착 특성의 정규화 된 데이터로 최대 변위 예측을 위해 최적화 된 인공신경망에 입력하여 예측한 결과, 동일한 굴착 조건의 유한 요소 해석 결과와 유사한 결과를 보임을 알 수 있다(그림 17).

표 8의 굴착 조건 중 벽체의 힘 강성과 켄틸레버 굴착 깊이의 정보를 인공신경망에 입력하여, 켄틸레버 단계에서 지표의 수평, 수직 변위 유형을 예측 하였으며, 무지보 굴착 깊이의 정보를 인공신경망에 입력하여, 측방 배부를 단계의 지표 변위 유형을 예측 하였다. 그 결과 그림 18에서 보이는 바와 같이 유한 요소 해석의 결과가 매우 유사하였다.

### 6.2.3 굴착 완료 후 지표 변위 예측

인공신경망을 통해 예측된 최대 지표 변위 값과 정규

화 된 지표 변위 유형을 이용하여 굴착 완료 후 발생할 지표 변위를 예측하였다. 이를 유한 요소 해석의 결과와 비교하였을 때, 인공신경망을 통해 간단한 굴착 특성으로 불규칙한 지표 변위 유형의 예측이 가능함을 볼 수 있다(그림 19).

그림 19는 쪽측부터 최종 지표 변위, 켄틸레버 단계의 지표 변위, 측방 배부를 단계의 지표 변위의 비교 결과를 나타낸 것이며, 최종 지표 변위는 두 단계의 지표 변위 예측 결과를 더하여 산정하였다. 점선은 본 논문에서 제시된 예측 기법의 결과이며, 동일한 굴착 조건으로 유한 요소 모델을 해석한 결과이다.

## 7. 결론 및 향후계획

본 연구에서는 인공신경망 알고리즘을 굴착에 따른 지표 변위 예측 기법에 적용하여, 기존 방법에 의한 변

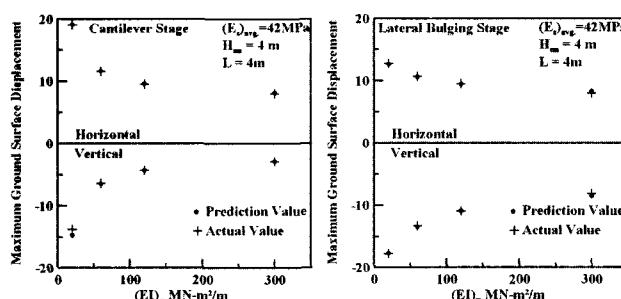


그림 17. 최대 변위 예측

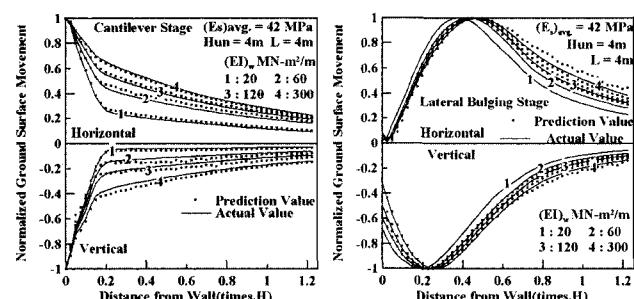


그림 18. 지표 변위 유형 예측

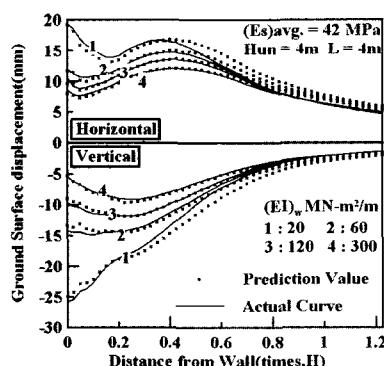
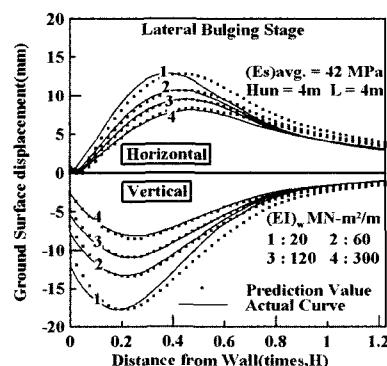
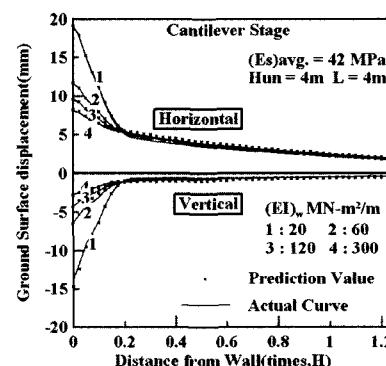


그림 19. 예측 기법을 통한 예측 결과와 실제 변위 곡선의 비교



위 예측의 한계를 극복하고자 노력하였다. 지표 변위 특성에 영향을 미치는 굴착 특성으로 흙막이 벽체의 휨강성과 켄털레버 굴착 깊이, 무지보 굴착 깊이로 선택하였으며, 유한 요소 모델의 해석을 통해 그 영향성이 검토 되었다. 이 과정에서 지반의 강성은 정량적인 지표 변위 값에는 미소하게 영향을 준다. 반면 지표 변위 특성에는 거의 영향을 미치지 않았고, 목적 패턴 별로 선택된 영향인자를 다양하게 적용하여 유한 요소 모델을 해석하여 얻어진 데이터베이스는 최적화 된 인공신경망 구조의 학습 자료로 이용되었다. 이를 통해 본 연구에서는 합리적인 지표 변위 예측 기법을 제시하였으며, 그 기법은 임의의 굴착 조건에 따른 지표 변위의 정확한 예측이 가능함을 볼 수 있었다. 본 연구에서 도출된 주요 결과 및 향후 계획을 정리하면 다음과 같다.

- (1) 단계별 굴착 특성에 따라 굴착 시 발생되는 지표 변위는 켄털레버 단계와 측방 배부름 단계의 변위로 구분되며, 최종 지표 변위는 두 단계 변위의 합으로 표현이 가능하다.
- (2) 최종 굴착 완료 후 지표 변위 곡선은 켄털레버 단계 및 측방 배부름 단계의 변위 성분 크기에 따라 포물선 혹은 아래로 불록한 형태를 띠는 것으로 나타났다.
- (3) 굴착 조건에 따라 굴착 완료 후 지표 변위는 다양한 형태로 발생되는 반면 켄털레버 단계와 측방 배부름 단계로 나누어 정규화 시켜 표현할 경우 유사한 형태를 보인다.
- (4) 검증된 유한요소 모델을 다양한 굴착 조건으로 해석된 결과로 구성된 데이터 베이스를 통해 최적화된 구조의 인공신경망을 학습 한 결과, 학습된 인공신경망은 간단한 굴착 조건의 입력을 통해 다양한 지표 변위 유형을 정확히 예측하였다.
- (5) 본 연구에서 제시된 인공신경망을 통한 지표 변위 예측 기법은 향후 영향 인자에 대한 조사를 수행하여 보완하고, 적합한 현장 계측 데이터와의 비교를 통해 검증 과정을 거친 후, 굴착에 따른 인접 구조물 손상평가에 활용 된다면, 보다 쉽고 간편하게 현장에서 활용 가능할 것이라 사료된다.

## 감사의 글

본 연구는 성균관대 산업설비 안전성평가 연구센터(SAFE)의 연구비 지원에 의해 수행되었으며 이에 감사

드립니다.

## 참 고 문 헌

1. 김병탁, 윤길립 (2002), “인공신경망 기법을 이용한 국내 해성점토의 압축 특성 분석”, 대한토목학회논문집, pp.133-147, 제 22 권 제2-C호 pp.133-147.
2. 김영수, 정성관, 암안식, 김병탁 (2001), “화강암 풍화토의 토량 변화율 추정을 위한 인공신경망의 적용”, 한국지반공학회논문집, 제 17권 제2호, pp.73-83.
3. 김연정 (1998), “도심지 굴착에 따른 흙막이 벽체의 거동과 결보기 토압”, 성균관 대학교 박사학위논문.
4. 김홍택, 박성원, 권영호, 김진홍 (2000), “인공신경망을 이용한 굴착 단계별 흙막이 벽체의 최대변위 예측 시스템 개발”, 한국지반공학회논문집, 제 16권 제1호 pp.83-97.
5. 유충식 (2002), 지반굴착과 주변 구조물 손상평가 - 기본개념, 한국지반공학회 봄 학술 발표회 논문집, pp.263-270.
6. ABAQUS (ver. 6.3) (2002), Hibbit, Karlsson & Sorensen, Inc.
7. Boscardin, M.D. and Cording, E.J. 1989. Building Response to Excavation Induced Settlement. *Journal of Geotechnical Engineering*, ASCE, Vol.115, No.1, pp.1-21.
8. Burland, J.B. (1995), Assessment of risk of damage to buildings due to tunneling and excavation. *Proc. 1st Int. Conf. On Earthquake Geotechnical Engineering*, IS-Tokyo.
9. Cording, E.J. (1985), Evaluation and control of ground movements around tunnels and excavations in *XII Int. Conf. on Soil Mechanics and Foundation Engineering*, San Francisco, California, pp.106-131.
10. Cording, E.J. and O'Rouke, T.D. (1977), Excavation, Ground Movements, and Their Influence on Buildings. *Protection of Structures Adjacent to Braced Excavation*, ASCE Annual Convention, San Francisco (preprint).
11. Dayakar Penumadu and Rongda Zhao (1999), Triaxial compression behavior of sand and gravel using artificial neural networks (ANN), *Computers and Geotechnics*, Volume 24, Issue 3, April 1999, pp.207-230.
12. Goh, A. T. C. (1994), Seismic liqufaction potential assessed by neural network. *J. Geotech. Engng.*, ASCE, Vol.120, No.9, pp. 1467-1480.
13. Lefteri H. Tsoukalas and Roert E. Uhrig. (1997), *Fuzzy and Neural Approaches in Engineering*, John Wiley & Sons, Inc. pp.229-288.
14. Master, T. (1993), *Practical neural network recipes in C++*, Academic press, San Diego, Calif.
15. MATLAB (ver. 6.1) (2001), The MathWorks, Inc.
16. M. S. Rahman, J. Wang, W. Deng and J. P. Carter. (2001), A neural network model for the uplift capacity of suction caissons, *Computers and Geotechnics*, Volume 28, Issue 4, June 2001, pp.269-287.
17. Mohamed A. Shahin, Holger R. Maier, Mark B. Jaksa (2002), Predicting Settlement of Shallow Foundations using Neural Networks. *Journal of Geotechnical Engineering*, September 2002. pp.785-793.
18. Werbors, Beyond Regression. (1974), *New tools for Prediction and Analysis in the Behavior Sciences*, Ph.d. Dissertation, Harvard University.

(접수일자 2003. 9. 4, 심사완료일 2004. 2. 15)