

인공신경망기법을 이용한 굴착에 따른 지표침하평가

Prediction of Deep Excavation-induced Ground surface movements using Artificial Neural Network

유충식¹⁾, Chung-Sik Yoo, 최병석²⁾, Byoung-Seok Choi

¹⁾ 성균관 대학교 토목공학과 부교수, Assoc. Prof. Dept. of Civil Engrg., Sungkyunkwan Univ.

²⁾ 성균관 대학교 토목공학과 석사과정, Graduate student. Dept. of Civil Engrg., Sungkyunkwan Univ.

SYNOPSIS : 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 perspective of 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 effecting used for a first-order prediction of ground movements associated with deep-excavation.

Key words : deep-excavation, parametric study, finite element analysis, artificial neural network

1. 서론

도심지의 굴착 공사는 굴착에 따른 주변 지반의 거동을 야기하고 나아가서 주변 건물 및 매설관에 대한 손상을 야기 시키므로 설계 단계에서는 굴착에 따른 지반 거동을 평가하고 이를 토대로 주변 건물 및 매설관의 손상여부를 검토하는 등 계획적인 주변 영향평가가 필요하다. 많은 연구자들이 굴착으로 인해 발생하는 지반 거동 예측에 관한 연구를 수행하였으나, 대부분의 연구는 흙막이벽체의 최대변위 예측에 주안점을 둔 것이 대부분이다. 따라서 현재 실무에서 주변 건물 및 매설 관에 대한 손상 평가 시 사용하는 지표침하예측 방법은 다소 낙후되거나 제한적인 실정이다. 이러한 측면에서 본 연구에서는 도심지 지하 굴착에 따른 주변 영향 평가기법 개발의 일환으로 굴착에 따른 지표변위 곡선을 예측하는 기법을 제시하였다. 본 기법은 지반 공학 분야에도 활발히 적용되고 있는 인공신경망(Artificial Neural Network)을 이용하였다. ANN 구축을 위해 다양한 경우에 대한 유한 요소 모델의 해석을 수행하여, 학습 패턴을 확보 하였으며, 설계 파라메타(은닉층 뉴런수, 은닉층 수, 학습률, 모멘텀)의 조절을 통해 최적화 하여 학습 된 신경망은 임의의 굴착 및 지반 조건하에 흙막이 벽체와 지표의 수평 및 수직 변위의 정확한 예측이 가능하였고, 현장 계측 데이터를 이용한 학습을 통해 보다 현실적인 ANN을 구현할 수 있는 가능성을 확인하였다.

2. 유한 요소 해석을 이용한 데이터 베이스 구축

본 절에서는 굴착에 따른 지표 변위 특성에 대한 연구를 수행하고, 인공 신경망 학습을 위한 데이터

베이스 구축 과정에 대해 다루었다.

2.1 현장 조건 및 해석 조건

그림 1은 깊이 20m, 폭 30m의 버팀보 굴착의 이상화 된 2차원 평면을 나타내고 있다. 표 1은 본 연구에서 유한 요소 해석 시 적용한 지반의 역학적 특성을 정리한 것이다. 유한 요소 모델에 대한 내용과 검증 과정은 앞서 발표된 논문에 상세히 기술된 바 있다(유충식 등 2002).




표 1. 유한요소 해석에 사용한 역학적 특성

	c(kPa)	ϕ (deg)	ϕ_v (deg)	ψ (deg)	E_s (kPa)
매립토	3	28	20	10	15,000
충적토	15	35	28	6	35,000
풍화토	50	38	32	6	50,000
풍화암	100	45	40	6	500,000


그림 1. 굴착 현장 조건

2.2 지표 변위 특성


지표 변위에 주된 영향 인자는 흙막이 벽체의 강성, 켈틸레버 굴착 깊이(굴착 시점에서 최 상단 지보재 사이의 거리), 무지보 굴착 깊이(최 하단 지보재와 굴착 저면 사이의 거리)와 지반 강성이 되며, 본 절은 위의 영향 인자에 따른 지표 변위 특성에 대한 내용이다.

2.2.1 단계별 굴착의 특성

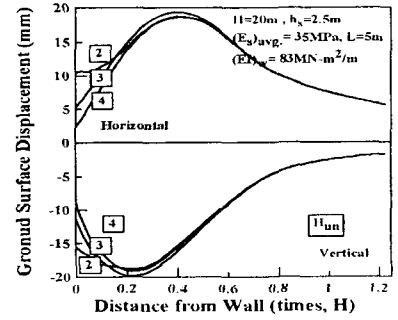
단계별 굴착이 이루어지는 굴착공사의 특성상, 각 단계에서의 시공과정은 최종단계에서의 벽체 및 지표 변위 유형에 많은 영향을 미친다. 굴착 단계는 크게 최 상단 지보재가 설치되기 전과 그 후 굴착 완료까지로 크게 나누어 질 수 있으며, 각 단계의 시공 특성은 굴착 시점부터 최 상단 지보재 설치 전까지의 깊이(켈틸레버 굴착 깊이)와 그 후 지보재 설치시기(무지보 굴착 깊이)로 볼 수 있다고 발표 되었다(유충식 등 2002). 이를 토대로 유한 요소 모델은 켈틸레버 굴착 깊이와 지보재 설치시기를 다양하게 조절하여 해석을 수행하였고, 해석된 결과는 어떤 지반 강성과 벽체 강성에 관계없이 동일한 경향을 나타내는 것을 볼 수 있었다.



(a) 최상단 지보재 설치 전



(b) 지보재 설치 후



(c) 굴착 완료 후

그림 2. H_m 에 따른 굴착 시 인접 지표 변위 경향

그림 2는 최 상단 지보재가 설치되기 전까지 굴착 깊이를 2, 3, 4m로 조절하여 해석한 결과를 보여 주고 있다. 이 굴착 깊이는 최 상단 지보재가 설치되기 전 단계에 큰 영향을 미치는 것을 볼 수 있으며, 그 후의 측방 배부름 단계에는 큰 영향이 없음을 볼 수 있다. 위 결과를 통해 최 상단 지보재가 설치되기 전 지표의 거동은 향후 굴착 과정에 따른 지표 거동과 구분 가능함을 볼 수 있으며, 본 연구에서는 최 상단 지보재 설치 이전의 캔틸레버 단계와 그 이후의 측방 배부름 단계로 구분하여 표현하였다.

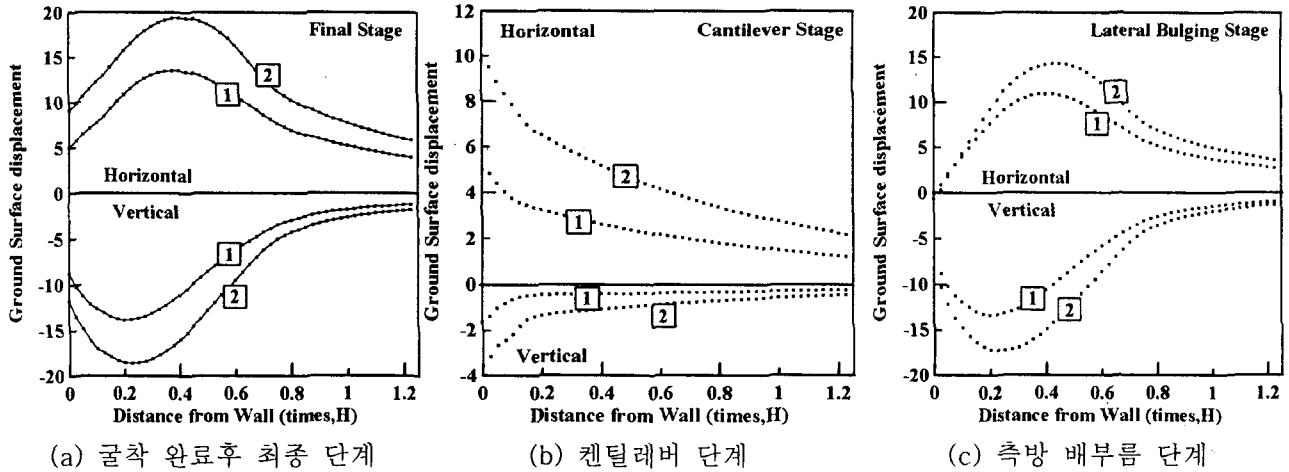


그림 3. 굴착에 따른 지표 변위의 단계별 분석

그림 3은 표 2의 굴착 조건으로 유한 요소 모델을 해석한 결과이다. 위 그림에서 볼 수 있듯이 최 상단 지보재가 설치되기 전의 변위의 값과 그 이후의 변위 값을 합산한 결과는 굴착 완료 후 지표 변위와 동일하게 됨을 볼 수 있다(그림 3(a)). 위의 결과는 모든 경우 굴착의 공통된 특성이며, 본 연구에서는 캔틸레버 단계와 측방 배부름 단계로 구분하여 지표 변위를 예측하고, 최종 단계의 지표 변위 값은 두 단계 변위 값의 합으로 표현하였다.

표 2. 굴착 조건

Case	조건	$(EI)_w$ (kN-m ² /m)	H_{in} (m)	L (m)	E_s (kPa)
1		242	4	6	표 1의 조건
2		72	3	4	표 1의 150%

2.2.2 지표 변위 곡선 정규화

굴착 깊이는 현장에 따라 동일하지 않으며, 굴착 깊이의 변화에 따라 유한 요소 모델을 바꾸는 비효율적인 면을 피하고자, 본 연구에서는 굴착 깊이를 정규화 시켜 표현 하였으며, 예측 된 지표 변위를 보다 합리적으로 실무에 활용하기 위해, 지표 변위 유형을 정규화 시켰고, 정규화 된 변위 곡선에 현장에서 직접 계측 된 최대 변위의 값을 곱하게 되면 해당 현장 상황을 합리적으로 반영할 수 있으며, 유한 요소 모델을 바꿔야하는 비효율적인 작업을 피할 수 있게 된다. 이러한 이유로 본 연구에서는 각 굴착 특성에 따라 캔틸레버 단계와 측방 배부름 단계로 각각 나누어 해석된 지표 변위를 아래 식 (1)과 같이 정규화 시켜 신경망 학습에 필요한 데이터베이스를 구축하였다.

$$x_{normalized} = \frac{x}{x_{max}} \quad (1)$$

2.3 데이터 베이스 구축 방법

본 절에서는 굴착 특성 및 지반 특성에 따라 굴착에 따른 지표 및 벽체 변위의 예측 기법의 개발을 위한 데이터베이스 구축 과정을 기술하였다

2.3.1 입력정보와 목적패턴

본 연구에서는 인공 신경망을 통해 굴착 특성에 따른 지표 및 흙막이 벽체의 변위 유형을 예측하는 기법을 연구하였으며, 신경망의 학습은 보편화 되어 활용되고 있는 지도학습의 일종인 일반화 된 델타 규칙을 따르는 오류 역전파 방식으로 수행하였다. 지도학습은 입력정보에 대하여 정확한 목적패턴이 제시 되어야 하며, 본 연구에서는 입력정보를 앞 절에서 살펴 본 4개의 영향인자(흙막이 벽체의 강성, 켈틸레버 굴착 깊이, 무지보 굴착 깊이, 지반의 강성)로 구성하였고, 이에 따르는 목적패턴은 굴착 특성에 따른 벽체의 수평 변위, 지표의 수평 및 수직 변위로 구성하였다. 그림 4와 5는 이에 대한 내용이다.




그림 4. 굴착 및 지반 조건

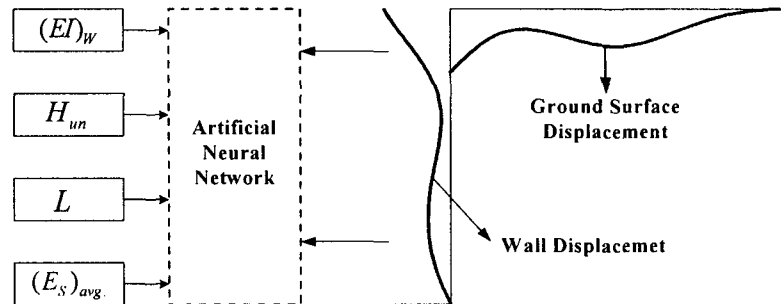


그림 5. 신경망 학습을 위한 입력정보와 목적패턴

인공신경망의 학습 시 많은 수의 데이터는 신경망 뉴런의 비선형 함수에 대한 정확한 이해를 가능하게 하여 보다 정확한 지반의 거동을 예측하고, 충분한 수의 데이터 확보는 신경망 학습의 정확도와 직결된다. 본 논문에서는 신경망의 학습을 위한 데이터베이스 구축을 위해 실험으로 그 결과의 정확성이 검증된 유한 요소 모델의 해석을 통하여 총 207 case의 다양한 굴착 조건에 대한 지표 및 흙막이 벽체의 변위 값을 확보하였다.

표 3. 입력 정보

굴착 특성 (영향인자)	데이터 범위	데이터의 정규화
흙막이 벽체 강성 $(EI)_W$	17 - 430 (kN-m ² /m)	0 - 1
켈틸레버 굴착 깊이 H_{un}	2 - 4 (m)	0 - 1
무지보 굴착 깊이 L	3 - 6 (m)	0 - 1
지반 강성 E_S	표 1 값을 각각 30%, 50% 증가	0 - 1

표 3은 입력 정보로 사용 된 다양한 굴착 조건의 범위를 나타낸 것이다. 일반적으로 현장에서 적용하는 굴착 특성을 최대한 반영하고자 하였다. 굴착 특성에 따라 유한 요소 모델화 하여 해석을 수행하여 얻어진 지표 및 흙막이 벽체 변위 유형을 입력 정보에 대한 목적 패턴으로 이용하였으며 변위 유형의 정확한 표현을 위해, 굴착 깊이의 1.25배의 범위 안에 50개 지점의 유한요소해석결과를 사용하였다.

2.3.2 데이터의 정규화

본 연구에서 사용된 신경망 뉴런의 활성화함수는 비선형적인 패턴인식에 효과적인 로그시그모이드 함수이며 신경망의 학습 후 수렴정도를 높이기 위해서는 학습시키기 전에 데이터를 0 과 1 사이의 값으로 정규화 시키는 것이 필요하다. 식 2의 정규화 방법은 이미 적용된 바 있는 Master(1993)의 방법이다. 학습 데이터 중 최대 값과 최소 값을 x_{max} 와 x_{min} 이라고 한다면 임의 값 x 는 x_{norm} 으로 정규화 된다.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

위 식 2을 통해 확보된 데이터의 입력 정보는 표 2와 같이 정규화 되어 신경망 학습에 적용 되었다. 또한 데이터의 정규화는 입력정보에 국한되지 않고 목적 패턴에도 적용되어야 한다. 목적 패턴에 적용된 정규화 방법은 입력정보의 정규화 방법을 따르지 않았으며 목적 패턴의 확보 시, 각 지점에 대한 값들을 해당 결과의 최대값으로 나누어 0 과 1 사이의 값으로 표현된 데이터를 직접 학습 데이터로 사용함으로, 표 4와 같이 위의 과정을 통해 건물 손상 평가의 지표가 되는 5 종류의 목적 패턴을 확보 하였다. 본 논문에서는 목적 패턴에 따라 5가지의 신경망 학습하여 예측 기법을 제시하였다.




그림 6. 입력노드와 출력 뉴런

표 4. 목적 패턴의 종류

굴착 단계	목적패턴
켄틸레버 단계 (최 상단 지보재 설치 이전)	지표의 수평변위 유형
	지표의 침하 유형
측방배부름 단계 (지보재 설치 후)	지표의 수평변위 유형
	지표의 침하 유형
최종단계 (굴착 완료 후)	흙막이 벽체의 수평 거동

3. 인공신경망의 최적화




그림 7. 신경망 파라메타에 따른 시스템 오차

인공 신경망은 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. 4개의 입력 노드에 대한 50 개의 출력 뉴런은 모든 신경망에 동일하게 적용되었으며, 신경망 설계 파라메타의 조절을 통해 각 신경망을 최적화 시켰다.

그림 7은 흠막이 벽체 변위 예측 신경망의 각 설계 파라메타들을 변화 시키며 신경망을 설계하였을 때 시스템의 오차의 변화율을 보여 주고 있으며, 그 설계 파라메타의 조절과정은 먼저 은닉층의 수를 하나로 하고, 모멘텀(0.8)과 학습률(0.2)은 일반적으로 많이 쓰이는 수치를 설계에 이용하였다. 뉴런수를 변화 시키며 학습하였을 때 은닉층의 뉴런 수가 200개인 경우의 오차가 가장 작았으며, 벽체 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 7과 같이 변화시켰을 때 모멘텀은 0.8, 학습률은 0.2 의 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 5에서는 벽체 변위 예측 신경망 과정과 동일한 방법으로 각각의 신경망 구조의 최적화를 위해 결정된 설계 파라메타를 정리 하였다.

표 5. 신경망 설계 시 결정된 파라메타

Type	Hidden Layer	Lr	M	MSE
Cantilever H.disp.	3(200)	0.2	0.8	7.4E-07
Cantilever V.disp.	3(150)	0.4	0.8	9.4E-07
Lateral bulging H.disp.	3(150)	0.4	0.9	8.9E-07
Lateral bulging V.disp.	3(150)	0.2	0.9	7.1E-07
Wall H. disp.	3(200)	0.2	0.8	2.2E-07

*Lr - 학습률, M - 모멘텀.

4. 신경망의 검증

인공 신경망을 최적화 된 구조로 학습 시키면, 신경망은 학습에 이용된 데이터에 대한 정확한 예측을 하게 됨은 자명한 사실이다. 신경망의 최적화 과정을 통해 얻어진 시스템 오차의 정도를 보면 학습에 사용된 데이터의 입력 정보를 통한 목적 패턴의 예측 결과를 예상할 수 있으며, 확인 절차는 무의미 하다고 볼 수 있다.

표 6. 신경망의 검증을 위한 입력 정보

굴착 특성 (영향인자)	데이터의 범위	데이터의 정규화
흠막이 벽체 강성 $(EI)_w$	20, 60, 120, 300 (kN-m ² /m)	0.01359 - 0.70419
첸틸레버 굴착 깊이 H_{un}	4 (m)	1
무지보 굴착 깊이 L	4 (m)	0.3333
지반 강성 E_s	표 1 값을 20% 증가	0.4

신경망의 시스템 오차는 학습에 사용된 데이터들에 대한 목적 패턴과 예측 패턴 간의 차를 의미하는 것으로, 신경망 예측의 정확성을 검증하기 위해서는 학습 패턴으로 사용하지 않은 입력 정보에 대한 예측 결과와 실제 값과의 비교 과정이 필요하다. 본 절에서는 신경망 검증을 위한 자료의 확보를 위해 학습에 사용된 데이터베이스에 포함 되지 않은 굴착 특성으로 형성된 유한 요소 모델을 해석하였다(표 6).

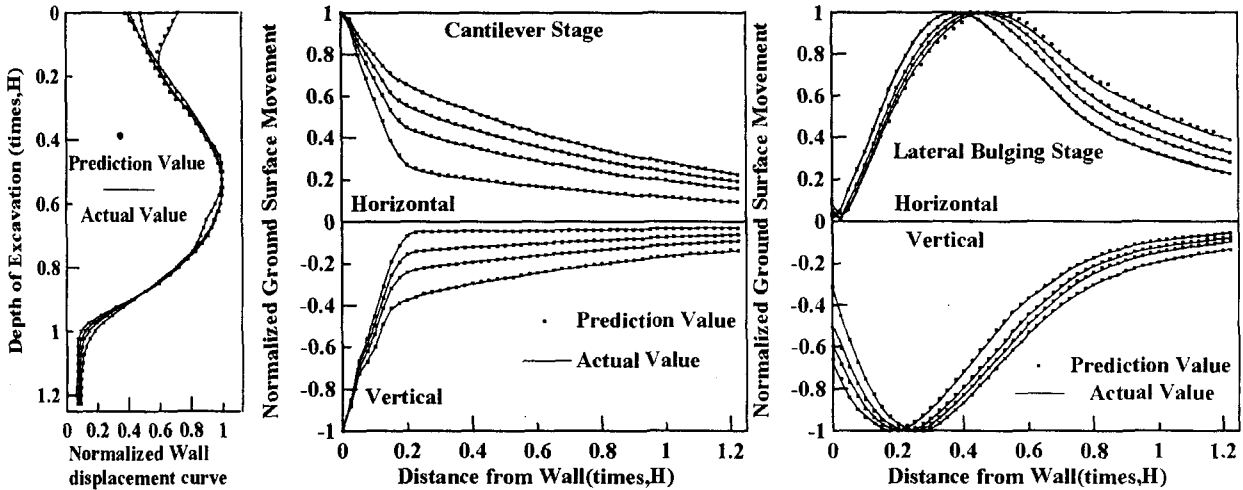


그림 8. 최적화 된 신경망의 예측 결과와 임의의 굴착 조건에 대한 변위 곡선의 비교

표 6은 신경망의 검증을 위해 사용된 입력 정보이며, 최적화 된 신경망 구조로 예측된 변위는 유한 요소 모델의 해석 결과 값과 비교 시, 그림 8에서 볼 수 있듯이 모든 신경망 구조는 목표 패턴을 정확히 예측함을 볼 수 있으며, 각 신경망은 흙막이 벽체의 수평 변위 99.2%, 캔틸레버 단계 지표 변위 99.4%, 측방 배부름 단계의 지표 변위 98.5%의 정확도를 보였다.




그림 9. 최적화 된 신경망의 예측 결과와 임의의 굴착 조건에 대한 실제 변위 곡선의 비교

그림 9는 실제 데이터와의 비교를 나타낸 그림으로 좌측부터 굴착이 완료 된 최종 단계와 캔틸레버 단계, 측방 배부름 단계를 표현하였으며, 최적화 된 신경망을 통해 각 단계별로 예측된 정규화 된 곡선에 최대 변위 값을 곱하여, 실제 변위 유형을 예측하고, 캔틸레버 단계와 측방 배부름 단계의 실제 변위 유형을 합하여, 굴착 완료 후 최종 변위 곡선을 예측한 결과는 임의의 굴착 조건으로 유한 요소 모델을 해석한 결과와 흡사한 크기와 경향을 보였다. 또한 각 단계별 변위 유형도 실제 해석 값을 정확히 예측하는 것을 볼 수 있다.

5. 결 론

본 논문에서는 굴착에 따른 주변의 영향 평가 기법 개발의 일환으로, 체계적인 지표 변위 예측에 관한 내용을 다루었다. 먼저 굴착 특성에 관한 연구를 통해, 합리적인 지표 변위 예측을 위한 방안으로 지표 변위는 켄틸레버 단계와 측방 배부름 단계로 구분하는 것이 바람직하며, 지표 변위 곡선을 정규화함으로써 예측된 곡선의 활용범위를 확대하였으며, 지표 변위 예측 방법으로 Matlab Tool을 이용한 신경망 구조를 선택하였다. 신경망 학습을 위해 다양한 굴착 조건과 지반 조건으로 검증된 유한 요소 모델을 구성하고 해석하였으며, 그 결과 얻어진 데이터베이스는 일반적으로 시공되는 굴착 현장 상황을 최대한 반영하였고, 신경망의 정확성 확보를 위해 다양한 조건하에 충분한 경우(207case)의 학습 패턴으로 구성하였다. 인공 신경망 구조는 4가지 입력 정보로 흙막이 벽체 강성, 켄틸레버 굴착 깊이, 무지보 굴착 깊이, 지반 강성으로 선택 하였고, 출력패턴은 충분한 지표 변위 유형의 표현이 가능한 50개의 neuron으로 구성되었으며, 켄틸레버 단계와 측방 배부름 단계별로 정규화 된 수평, 수직 변위 곡선을 예측하는 4개의 신경망 구조들은 설계 파라메타의 조절을 통해 최적화 되었고, 학습 된 신경망을 통해 예측된 지표 변위의 결과는 임의의 굴착 조건에 대한 지표 변위 결과와 유사함을 볼 수 있었으며, 이를 통해 본 논문에서 제시한 지표 변위 예측 기법은 타당성이 검증되었고, 실제 현장의 지표 변위 데이터를 확보하고 신경망의 학습에 이용하는 과정을 통해, 실무에 적용될 가능성을 확인하였다.

감사의 글

성균관대 산업설비 안전성평가 연구센터(SAFE)의 연구비 지원에 감사드립니다.

참고문헌

1. 유충식 2002. 지반굴착과 주변 구조물 손상평가 - 기본개념, 한국 지반 공학 회 봄 학술 발표회 논문집 pp. 263-270
2. 유충식, 최병석 2002. 인공신경망기법을 이용한 굴착에 따른 지표변위 예측, 한국 지반 공학 회 가을 학술 발표회 논문집 pp. 451-458
2. ABAQUS (ver. 5.8) 1999. Hibbitt, Karlsson & Sorensen, Inc.
3. 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.
4. 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
5. 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.
6. Cording, E.J. and O'Rourke, T.D. 1977. Excavation, Ground Movements, and Their Influence on Buildings. *Protection of Structures Adjacent to Braced Excavation*, ASCE Annual Convention, San Francisco (preprint)
7. Goh, A. T. C. 1994. Seismic liquefaction potential assessed by neural network. *J. Geotech. Engrg.*, ASCE, Vol. 120, No. 9, pp. 1467-1480.
8. Lefteri H. Tsoukalas and Roert E. Uhrig. 1997. *Fuzzy and Neural Approaches in Engineering*, John Wiley & Sons, Inc. pp. 229-288.
9. Master, T. 1993. *Practical neural network recipes in C++*, Academic press, San Diego, Calif.
10. Werbors, Beyond Regression. 1974. *New tools for Prediction and Analysis in the Behavior Sciences*, Ph.d. Dissertation, Harvard University.