

인공신경망을 이용한 굴착단계별 흙막이벽체의 최대변위 예측시스템 개발

Development of a System Predicting Maximum Displacements of Earth Retaining Walls at Various Excavation Stages Using Artificial Neural Network

김 홍 택*¹ Kim, Hong-Taek

박 성 원*² Park, Sung-Won

권 영 호*³ Kwon, Young-Ho

김 진 홍*⁴ Kim, Jin-Hong

Abstract

In the present study, artificial neural network based on the multi-layer perceptron is used and an optimum model is chosen through the process of efficiency evaluation in order to develop a system predicting maximum displacements of the earth retaining walls at various excavation stages. By analyzing the measured field data collected at various urban excavation sites in Korea, factors influencing on the behaviors of the excavation wall are examined. Among the measured data collected, reliable data are further selected on the basis of the performance ratio and are used as a data base. Data-based measurements are also utilized for both learning and verifying the artificial neural network model. The learning is carried out by using the back-propagation algorithm based on the steepest descent method. Finally, to verify a validity of the formulated artificial neural network system, both the magnitude and the occurring position of the maximum horizontal displacement are predicted and compared with measured data at real excavation sites not included in the learning process.

요 지

본 연구에서는, 흙막이벽체의 변위 예측시스템 개발을 위하여 다층퍼셉트론을 이용해 임의의 인공신경망 모델을 구축하고 그 성능을 평가하여 최적의 모델을 선정하였다. 인공신경망 모델의 학습과 검증에 위해 국내 도심지에 실제 시공이 완료된 다양한 현장의 계측자료를 수집하였고, 수집된 계측자료의 분석을 통해 흙막이벽체의 거동에 영향을 미치는 인자를 조사하였다. 아울러 실행비를 기준으로 선별한 신뢰성 있는 계측자료를 조사된 영향인자를 토대로 데이터베이스화하여 인공신경망 모델의 학습과 검증에 사용하였으며, 학습은 최급강하법을 기초로 하는 역전파 알고리즘을 이용하여 수행하였다. 학습에 포함되지 않은 현장들에 대하여 흙막이벽체의 최대수평변위와 그 발생위치를 예측하고 이를 계측치와 비교하여, 제시한 변위 예측시스템의 적용성을 부분적으로 확인하였다.

Keywords : Excavation walls, Maximum wall displacements, Various excavation stages, Artificial neural network, Back propagation algorithm, Performance ratio

*1 정회원, 홍익대학교 공과대학 토목공학과 교수

*2 (주)다산컨설턴트 지반공학부

*3 정회원, (주)한라건설 기술연구소

*4 정회원, (주)한석엔지니어링 상무이사

1. 서론

고도의 경제성장과 더불어 최근 도심지에서는 토지활용의 극대화를 위해 건물 등 기존 구조물에 인접하여 대규모, 도심도의 굴착공사가 활발하게 이루어지고 있다. 이러한 도심지에서의 근접시공시 굴착에 따른 발생변위로 인해, 인접구조물 또는 흙막이 구조물 자체의 안정성 등이 영향을 받을 수 있다. 일반적으로 흙막이 구조물 설계시 변위 예측은 탄소성 해석법, 유한요소법, 또는 유한차분법 등을 이용해 이루어지고 있으며, 시공 중에는 계측을 통해 발생변위에 따른 흙막이 구조물의 안정성을 평가하고 있다. 그러나 지반물성치 등 설계시 요구되는 입력자료는 제한적 시추조사 및 시험 등에 의한 결과에 의존할 수밖에 없어, 다양한 특성을 지닌 현장여건을 제대로 반영하기 어려운 근본적인 문제점으로 인해, 예측된 변위와 실제 시공시 발생하는 변위는 크기상으로 적지 않은 차이를 종종 나타내고 있다. 따라서 현 시점에서는 상당기간 축적되어 온 다양한 특성을 지닌 지하굴착 흙막이 시공현장의 계측자료를 수집하여 체계적으로 정리하고, 또한 이 자료를 신뢰성 있고 효율적인 기법을 이용해 정밀한 분석을 시행할 필요성이 대두되며, 이를 통해 향후 지속적으로 이용될 지하굴착 흙막이 공법의 해석 및 설계 기법을 보다 합리적으로 진일보시키는 작업이 요구된다.

이와 같은 목적으로 본 연구에서는, 최근에 타 분야에서도 다수 적용된 바 있는 인공신경망(artificial neural network) 이론을 이용하여 흙막이벽체의 최대수평변위 및 그 발생위치를 보다 합리적으로 예측하기 위한 시스템을 구축하였다. 인공신경망 이론은 인공지능의 한 분야로 추론 및 판단 측면에서 신속성 및 정확성을 지니고 있기 때문에 최근 토목공학 분야에 그 적용이 활발해지고 있으며 (Flood & Kartam, 1994), 또한 인공신경망 스스로가 계측 자료의 상호관련성을 인식·분류함으로써 관계 규명을 명확하게 해주기 때문에 흙막이벽체의 변위 예측에 효과적인 역할을 기대할 수 있는 장점을 지니고 있다. 본 시스템 구축을 위해 다양한 굴착현장의 계측자료를 우선 수집하였고, 수집된 계측자료의 분석을 통해 흙막이벽체의 거동에 영향을 미치는 인자를 조사하였다. 또한 실행비(performance ratio)를 기준으로 선별한 신뢰성 있는 계측 자료를 조사된 영향인자를 토대로 데이터베이스(이하 D/B)화하여 인공신경망 모델의 학습과 검증에 사용하였으며, 학습은 최급강하법(steepest descent method)을 기초로 하는 역전파 알고리즘(back propagation algorithm)

을 이용하여 수행하였다. 아울러 학습에 포함되지 않은 시공이 기 완료된 현장에 대하여, 선정된 최적의 인공신경망 모델을 이용하여 굴착단계별 벽체의 최대수평변위와 최종굴착단계에서의 최대수평변위 발생위치를 예측하고 이를 현장계측치와 비교하여, 본 연구 인공신경망을 이용한 흙막이벽체 변위 예측시스템의 적용성을 부분적으로 확인하였다.

2. 인공신경망

2.1 개요

인공신경망은 고도로 복잡한 인간의 두뇌를 구성하고 있는 기본단위인 뉴런(neuron)의 개념을 도입한 Ramón y Cajal의 작업을 기초로 인식과정 또는 신경생태를 수학적인 모형으로 일반화시키기 위해서 개발된 병렬 정보처리 시스템이다(Haykin, 1998). 생물학적인 뉴런은 세포본체(cell body), 축색돌기(axon) 및 수상돌기(dendrite) 등으로 구성되며, 여러 뉴런 사이에는 시냅스(synapse)라는 연결 물체가 있어 어떤 자극에 대한 반응을 다른 뉴런에게 전달해주는 매개체 역할을 한다. 인공신경망은 이와 같은 생물학적인 신경세포망의 기능을 모사한 것으로서 인공뉴런과 인공시냅스로 구성된다. 인공신경망에서의 정보처리는 다수의 인공뉴런에서 일어나며, 인공뉴런 사이의 신호는 인공시냅스인 연결링크(connection link)를 통해서 전달된다. 또한 각각의 연결링크는 인공뉴런들 사이의 연결 강도를 나타내는 시냅틱 가중치(synaptic weight)를 가지고 있으며, 각 뉴런에서의 정보처리는 전달된 신호와 가중





그림 1. 생물학적 뉴런과 인공뉴런의 구조

치의 곱의 총합에 활성화 함수(activation function)를 적용하여 출력신호를 발생시킨다. 그림1은 생물학적 뉴런과 인공뉴런의 구조를 도시한 것이다.

이러한 원리를 기초로 작동되는 인공신경망은 지식이 학습과정(learning process)을 통해 획득되며, 가중치에 의해 표현되는 뉴런들 사이의 연결강도를 사용하여 획득된 지식을 저장한다는 점에서 인간의 두뇌와 비슷한 면이 있으나, 처리속도, 다양성 및 능력 등의 측면에서 생물학적 신경망과 차별적으로 작동된다(Haykin, 1998).

2.2 지반공학 분야에서 인공신경망 이론의 적용성

지반공학 분야의 정보는 대상 재료의 성질을 비교적 자세하게 파악할 수 있는 여타 공학분야와는 달리, 자연상태의 암석과 토질을 대상으로 하므로 현장조사와 시험으로도 제한된 자료밖에 파악할 수 없는 특성을 지니고 있다. 또한 지반-구조물 사이의 거동에 대한 공학적 모델링의 어려움으로 인해, 지반거동 해석시 경험적 방법 또는 탄성론에 근거를 둔 해석기법이 주로 사용되고 있으므로, 정확한 지반거동을 나타내기에는 많은 한계점을 지니고 있다(Toll, 1990).

인공신경망은 학습한 자료를 바탕으로 추론을 수행하는 능력을 지니고 있기 때문에 기존의 방법으로 D/B화하기 어려운 불확실한 정보의 처리가 가능하므로, 현장자료를 바탕으로 한 지반거동의 추론에 적합하다. 따라서 지반거동에 대한 예측시 인공신경망을 통해 가용한 관련자료를 활용하여, 기존의 방법과는 다른 새로운 측면에서 지반거동의 특성 및 안정성 등을 파악할 수 있다고 판단된다.

3. 흙막이벽체 변위 예측시스템 개발

3.1 개요

인공신경망을 이용한 흙막이벽체 변위 예측시스템을 개발하기 위하여 본 연구에서는 이미 시공이 완료된 16개 현장 68개 측정에서의 현장계측자료를 수집하였고, 이를 인공신경망의 학습자료로 사용하였다. 수집된 계측자료를 분석하여 흙막이벽체의 움직임에 영향을 주는 인자들의 추출작업을 실시하였고, 이를 토대로 실행비를 기준으로 선별한 신뢰성 있는 흙막이벽체 관련 계측자료를 D/B화하였다. 결정된 영향인자를 이용하여 다층역전파 인공신경망 모델을 설계하였고, 구축된 D/B를 이용하여 다층

역전파 인공신경망의 매개변수연구를 실시하였다. 또한 학습효율 및 추론결과를 근거로, 본 연구에 가장 적합한 다층역전파 인공신경망 모델을 결정하였다.

3.2 계측자료 분석

1) 흙막이 지지공법

수집된 자료를 토대로 다양한 굴착현장에 적용된 흙막이 지지공법을 분류하면 그림2와 같다.

그림2의 분류결과를 살펴보면, 굴착현장의 특성에 따라 다양한 지지공법이 적용되었으나, 1종류의 지지공법이 적용된 현장이 주를 이루었고, 인접하여 구조물이 존재하는 경우 등 현장 주변조건과 굴착조건 등에 따라 strut (이하 버팀보) + Ground anchor(이하 지반앵커), 또는 soil nail(이하 쏘일네일) + 지반앵커 등 지지공법을 병용하여 시공된 현장이 전체 중 9%의 비율을 차지하고 있다.

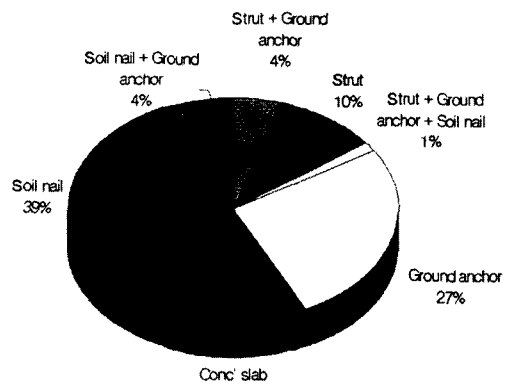


그림 2. 수집된 굴착현장에 적용된 흙막이공법의 분류

2) 지반조건

수집된 현장계측자료를 토대로, 최종굴착깊이(H)에 대한 각 지층별 두께의 구성비율을 정리하면 그림3과 같다.




그림 3. 각 지층별 두께의 구성비율

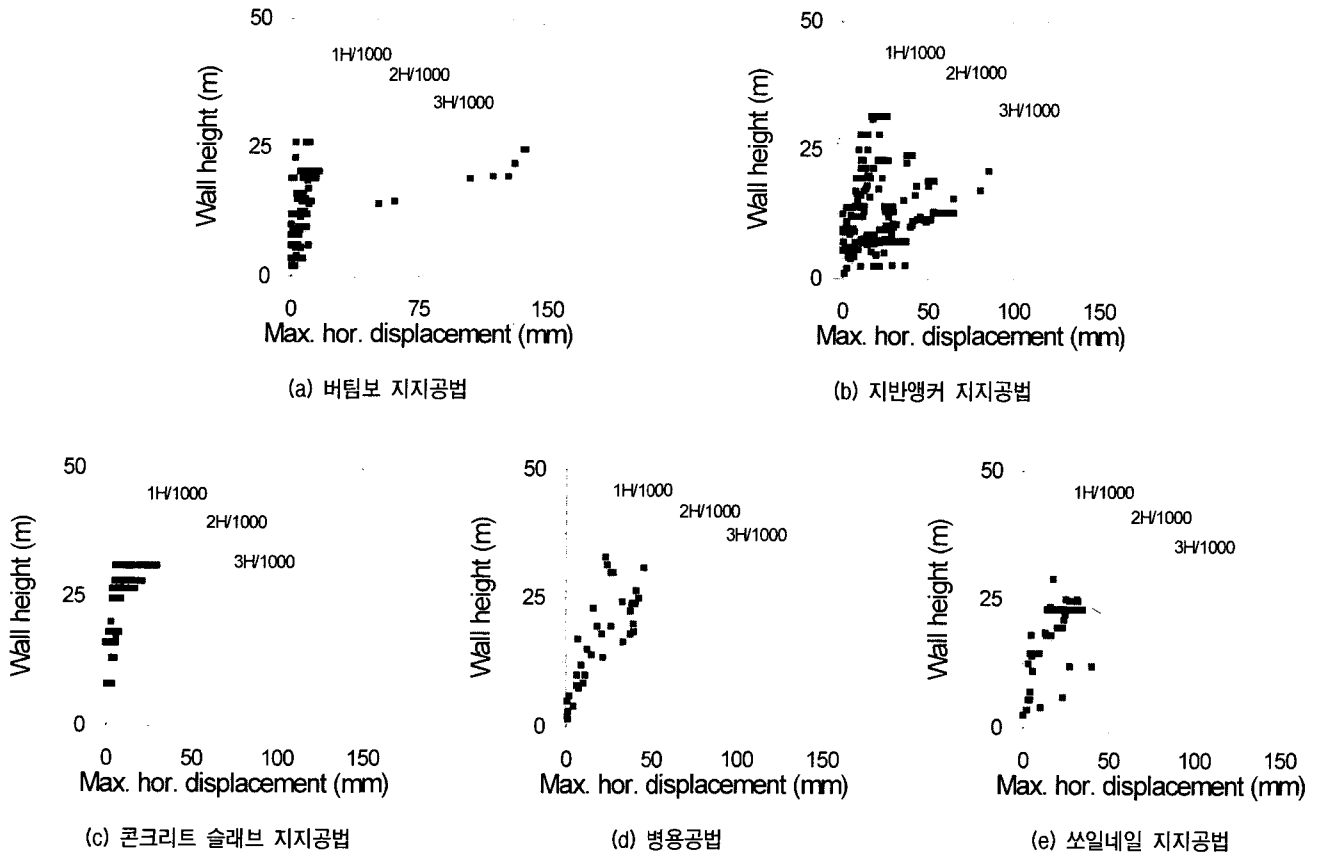


그림 4. 지지공법별 흙막이벽체의 최대수평변위

그림3에서 토층의 구분은 일반적으로 가장 많이 사용하는 표준관입저항치(N치)를 기준으로 한 것이며, 암층의 구분은 코어채취율(TCR)을 기준으로 구분한 것이다. 여기서 그림3의 결과를 살펴보면, 대체적으로 각 토층이 고루 분포하는 경향을 보이고는 있으나, 이 중 통일분류법(USCS) 상 SM, SC, GW에 속하고, 상대밀도는 조밀한 특성을 나타내는 풍화잔류토층이 상대적으로 큰 비율을 차지하고 있음을 알 수 있다.

3.3 영향인자와 흙막이벽체 거동특성과의 상관관계

1) 지지공법에 대한 영향

흙막이 지지공법에 따른 흙막이벽체의 발생변위 거동 특성은 그림4와 같으며, H는 최종굴착깊이를 의미한다.

버팀보 지지공법의 경우(그림4(a) 참조), 흙막이벽체의 최대수평변위는 대부분 최종굴착깊이의 0.1% 이내인 비교적 안정적인 거동을 나타내지만, 일부 현장의 최대수평변위는 일반적인 변위허용기준인 3H ~ 4H/1000 정도를 초과하였다. 안정기준을 초과한 현장조건은 배면에 인접하여 고층빌딩이 존재하고, 또한 굴착공사가 동절기에 진

행되었지만 지하수위 계측결과 단기간에 급작스런 지하수위 상승을 기록하고 있는 것으로 보아 지하수위의 영향이 큰 것으로 판단된다. 지반앵커 지지공법의 경우에는(그림4(b) 참조), 특정기준을 제시하기가 여의치 않은 광범위한 벽체의 거동을 나타내고 있다. 지반앵커 지지공법으로 시공된 현장의 경우 현장조건과 지반조건에 특이할 만한 사항은 없었으며, 벽체의 거동은 지반앵커에 가한 긴장력 및 긴장시기 등에 큰 영향을 받는 것으로 추정되었으나, 이에 대한 시공관련 자료는 확보할 수 없었다. 그림4(c)에 도시된 콘크리트 슬래브 지지공법은 실제구조물의 슬래브로 벽체를 지지하면서 굴착하는 역타(top down) 공법을 의미하며, 이와 같은 공법의 특성상 비교적 안정적인 벽체 거동을 나타내고 있다. 최종굴착깊이가 깊은 경우 또는 현장조건에 제약이 있는 경우에는 일반적으로 병용공법(그림4(d) 참조)이 적용되었으며, 병용된 공법의 종류에는 큰 영향이 없이 대체적으로 안정적인 벽체 거동을 나타내고 있다. 쏘일네일 지지공법의 경우(그림4(e) 참조)에는 대체로 벽체 최상부에서 최대수평변위가 발생하는 전형적인 쏘일네일 벽체 거동을 나타내고 있지만, 일부 현장에서는 일반적인 변위허용기준인 3H~4H/1000 정도에

근접하는 한계상태에 도달하였던 것으로 나타났다. 이와 같은 한계상태에 해당되는 2개 현장의 경우, 특이할 만한 사항은 차수 및 지반보강 공법을 실시하지 않았다는 점과 흙막이벽체 배면에 성토에 의한 상재하중이 존재한다는 점이다. 따라서 본 연구에서는 배면에 존재하는 상재하중에 대한 영향을 주요 영향인자로 채택하려고 하였으나, 수집된 상재하중 관련자료가 제한적이고 또한 자료내용의 구체성이 미흡하여 채택하지 못하였다.

2) 차수 및 지반보강 공법에 대한 영향

수집된 계측자료를 토대로 채택된 차수 및 지반보강 공법에 따라 흙막이벽체의 거동에 대한 영향을 분석하여 보았다. 채택된 차수 및 지반보강 공법별 분포는 그림5와 같다.

그림5의 결과를 분석하면, SCW(이하 쏘일시멘트벽체) 차수 및 지반보강 공법이 33%로 주를 이루고 있으며, Jet Grouting(이하 제트그라우팅) 공법이 28%, LW(이하 약액주입) 공법이 19%의 순으로 분포하고 있다. 또한 현장의

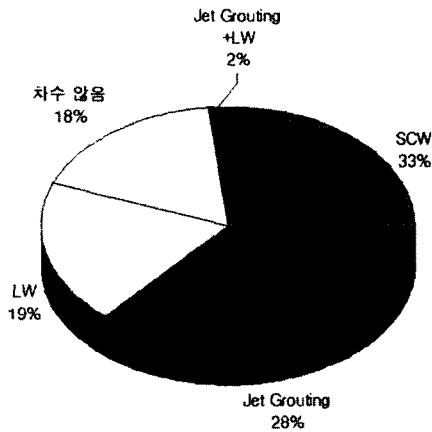


그림 5. 차수 및 지반보강 공법의 분포




그림 6. 변위허용기준을 초과하는 축점에 대한 차수 및 지반보강 공법의 분포

특성에 따라 차수 및 지반보강 공법을 실시하지 않은 경우 (18%)와, 제트그라우팅 및 약액주입 공법이 병용하여 적용된 경우(2%)도 있다.

또한 변위허용기준을 3H/1000로 가정하는 경우, 이를 초과하여 최대수평변위가 발생된 12개 축점에 실시된 차수 및 지반보강 공법의 분포는 그림6과 같다.

그림6의 결과를 살펴보면, 쏘일시멘트벽체 차수 및 지반보강 공법이 실시된 축점이 34%로 가장 많았고, 약액주입 공법은 33%, 제트그라우팅 공법은 25%의 순으로 분포하였다. 약액주입 공법이 전체적 분포에서는 낮은 비율을 차지했지만, 변위허용기준을 초과하는 차수 및 지반보강 공법의 분포에서는 높은 비율을 차지하고 있는 것으로 보아, 약액주입 공법이 실시된 축점에서 변위 발생이 상대적으로 큰 것으로 나타났다.

3.4 계측자료의 신뢰성 확보

수집된 계측자료에는 계측과정상의 오차 또는 계측기 자체의 오차 등이 포함될 수 있으며, 오차가 포함된 학습자료는 변위 예측시스템의 학습 및 예측의 정확도에 문제점을 발생시킬 수 있다. 따라서, 수집된 계측자료의 신뢰성 확보를 위해 굴착에 따른 실행비(R_p , Bruce & Jewell, 1987)를 기준으로 계측자료의 D/B화에 앞서 계측자료를 선별하였다. 굴착현장의 실행비는 식(1)과 같이 표현된다.

$$R_p = \frac{\text{outward max. hor. displacement}}{\text{final excavation depth}} \quad (1)$$

$$= \frac{\delta_{\text{horizontal}}}{H}$$




그림 7. 쏘일네일링 공법 수치해석에 사용된 단면(FLAC^{2D})

표 1. 쏘일네일링 공법 수치해석에 사용된 입력자료(FLAC^{2D})

구 분	해 석 모 델	입 력 물 성 치				
		항 목	제 1 단면	제 2 단면	제 3 단면	
매립토층	Mohr-Coulomb	단위중량 (t/m ³)	1.8	1.75	1.8	
		내부마찰각 (°)	30	25	23	
		점착력 (t/m ²)	0	0	0	
		전단탄성계수 (t/m ²)	1926	1111	1151	
		체적탄성계수 (t/m ²)	4169	3333	2497	
퇴적토층	Mohr-Coulomb	단위중량 (t/m ³)	1.8	1.8	1.7	
		내부마찰각 (°)	30	28	25	
		점착력 (t/m ²)	0.5	0.5	0	
		전단탄성계수 (t/m ²)	2303	714	1926	
		체적탄성계수 (t/m ²)	5005	3333	4159	
풍화잔류토층	Mohr-Coulomb	단위중량 (t/m ³)	1.85	1.9	1.9	
		내부마찰각 (°)	33	30	30	
		점착력 (t/m ²)	0.5	2	0	
		전단탄성계수 (t/m ²)	2120	2222	3078	
		체적탄성계수 (t/m ²)	4587	6666	6666	
암 층	Mohr-Coulomb	단위중량 (t/m ³)	2.0	2.2	2.3	
		내부마찰각 (°)	40	38	38	
		점착력 (t/m ²)	3	6	5	
		전단탄성계수 (t/m ²)	3843	7686	19266	
		체적탄성계수 (t/m ²)	8338	16615	41692	
쏘일네일	cable	단면적 (m ²)	4.91×10 ⁻⁴			
		탄성계수 (t/m ²)	2.04×10 ⁷			
		항복강도 (t/m ²)	30000			
숏크리트 전면벽체	beam	단위중량 (t/m ³)	2.4			
		탄성계수 (t/m ²)	2.35×10 ⁶			
		벽체폭 (m)	0.075			
		단면2차모멘트 (m ⁴)	3.25×10 ⁻⁵			
H (최종굴착깊이, m)		-	19.5	25.5	25.5	
쏘일네일 및 숏크리트 제원		쏘일네일 길이 (m)	11.0	12.0	11.0	
		네일 첫단 설치깊이 (m)	1.0	1.0	1.0	
		숏크리트 두께 (cm)	7.5	7.5	7.5	
		설치간격(m)	연직방향(S _v)	1.0	1.5	1.0
			수평방향(S _H)	1.0	1.5	0.8

※ S_{bond} 계산 대표식:

$$S_{bond} = \frac{\pi \cdot D \cdot (\sigma \cdot \tan \phi + c) \cdot L}{S_H \cdot L}$$

여기서, D = 천공직경, L = 쏘일네일 길이

K_{bond} 계산 대표식:


$$K_{bond} = \frac{S_{bond}}{L \cdot \epsilon}$$

여기서, ε = 변형률


흙막이벽체의 거동특성에 따라 쏘일네일링 공법이 적용된 흙막이벽체와 일반적인 지지공법이 적용된 흙막이벽체 등 2종류로 구분하였으며, 각 흙막이 공법의 이상화된 실행비의 변화를 얻기 위해 또한 계측자료의 선별기준을 설정하기 위해 수치해석 모델링(쏘일네일링 공법의 경우는 그림7 및 표1 참조, 일반적인 지지공법의 경우는 그림8 및 표2 참조)을 실시하였다.

수치해석 모델링을 통해 얻어진 굴착에 따른 실행비의 변화는 그림9와 같으며, 그림9에서 가로축은 단계별 굴착 깊이(h)를 최종굴착깊이(H)로 정규화 시킨 것이고, 세로축은 각 굴착단계의 실행비를 최대실행비로 정규화 시킨 것이다.


그림9의 (a)는 쏘일네일링 공법이 적용된 흙막이벽체의 실행비 변화를 나타낸 것이고, (b)는 일반적인 지지공



(a) 지반앵커의 경우




(b) 버팀보 + 지반앵커의 경우




(c) 버팀보의 경우

그림 8. 일반적인 지지공법 수치해석에 사용된 단면(PENTAGON^{2D})

법이 적용된 흙막이벽체의 실행비 변화를 나타낸 것이다. 각각에 대해 잔차자승합(sum of squares of residuals)이 가장 작은 곡선으로 회귀분석을 실시하였다. 이 회귀곡선을 기준으로 95%의 신뢰도를 갖는 현장계측결과를 선별하




(a) 쏘일네일링 공법




(b) 일반적인 지지공법

그림 9. 공법별 수치해석 모델링의 실행비에 대한 회귀분석 결과



(a) 쏘일네일링 공법



(b) 일반적인 지지공법

그림 10. 공법별 95% 신뢰도 구간

표 2. 일반적인 지지공법 수치해석에 사용된 입력자료(PENTAGON^{2D})

(a) 지반앵커 제원

구 분	설치깊이(m) (지표면으로부터)	지반앵커 길이 (m)	자유장 (m)	정착장 (m)	긴장력 (ton)	수평설 치간격 (m)
제 1 앵커	1.7	27.5	17.5	10.0	39.705	1.6
제 2 앵커	3.7	26.5	16.5	10.0	39.802	1.6
제 3 앵커	6.1	25.0	15.5	9.5	44.864	1.6
제 4 앵커	8.6	24.0	14.5	9.5	45.518	1.6
제 5 앵커	11.2	22.5	13.5	9.0	40.175	1.6
제 6 앵커	13.4	21.5	12.5	9.0	40.828	1.6
제 7 앵커	16.1	20.0	11.5	8.5	40.528	1.6
제 8 앵커	18.2	18.5	10.5	8.0	40.752	1.6
제 9 앵커	20.7	17.0	9.5	7.5	41.021	1.6
제10 앵커	23	15.5	8.5	7.0	41.801	1.6
제11 앵커	25.8	14.0	7.5	6.5	44.931	1.6
제12 앵커	28.6	12.5	6.5	6.0	42.290	1.6

(b) 기타 입력자료

구 분	해석 모델	입 력 들 성 치	
풍화진류 토층	Mohr-Coulomb	단위중량 (t/m ³)	1.85
		내부마찰각 (.)	26
		점착력 (t/m ²)	2
		전단탄성계수 (t/m ²)	2435
		체적탄성계수 (t/m ²)	5275
연암층	Mohr-Coulomb	단위중량 (t/m ³)	2.1
		내부마찰각 (.)	40
		점착력 (t/m ²)	5
		전단탄성계수 (t/m ²)	3846
		체적탄성계수 (t/m ²)	8333
경암층	Mohr-Coulomb	단위중량 (t/m ³)	2.1
		내부마찰각 (.)	42
		점착력 (t/m ²)	5
		전단탄성계수 (t/m ²)	11538
		체적탄성계수 (t/m ²)	25000
지반앵커	truss	단면적 (m ²)	6.33×10 ⁻⁴
		탄성계수 (t/m ²)	2.04×10 ⁷
		항복강도 (t/m ²)	30000
버팀보	frame	단면적 (m ²)	1.53×10 ⁻²
		탄성계수 (t/m ²)	2.04×10 ⁷
		단면2차모멘트 (m ⁴)	1.33×10 ⁻⁴
전면벽체 (H-pile +토류판)	frame	단위중량 (t/m ³)	2.4
		탄성계수 (t/m ²)	2.35×10 ⁶
		단면적 (m ²)	0.0153
		단면2차모멘트 (m ⁴)	8.74×10 ⁻⁵

여 계측자료를 D/B화하였다. 95% 신뢰도 범위는 그림10과 같으며, 신뢰도는 식(2)와 같이 추정치 분산의 제곱근을 이용하여 선정하였다.

$$\sqrt{Var(\hat{y})} = \sqrt{[1 + x^T(X^T X)^{-1}x] \sigma^2} \quad (2)$$

여기서, \hat{y} 는 추정치, $Var(\hat{y})$ 는 추정치의 분산, σ 는 표준편차를 각각 나타내며, 또한

$$x = \begin{bmatrix} 1 \\ x_1 \\ x_2 \\ x_3 \\ x^3 \end{bmatrix}, X = \begin{bmatrix} 1 & x_1 & x_1^2 & x_1^3 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ 1 & x_n & x_n^2 & x_n^3 \end{bmatrix} \text{이다.}$$

신뢰도 95% 구간은 회귀곡선으로부터 $\pm 2 \times \sqrt{Var(\hat{y})}$ 의 범위를 가지며, 각각에 대한 상위한계선(Upper Limit Line, ULL, 그림8 참조)과 하위한계선(Lower Limit Line, LLL, 그림8 참조)은 식 (3) 및 (4)와 같다.

$$\begin{aligned} ULL : y &= 0.305318 + 0.838843x - 1.78818x^2 + 1.91063x^3 \\ LLL : y &= -0.363834 + 1.21926x - 2.15492x^2 + 2.00349x^3 \end{aligned} \quad (3)$$

$$\begin{aligned} ULL : y &= 0.340287 + 0.0454807x - 0.7201913x^2 + 1.58732x^3 \\ LLL : y &= -1.11209 + 3.21819x - 4.37485x^2 + 2.95854x^3 \end{aligned} \quad (4)$$

3.5 계측자료의 D/B화

흙막이벽체의 거동특성 분석과 계측자료의 분석결과 등을 토대로, 계측자료를 쏘일네일을 적용한 흙막이벽체




그림 11. 굴착현장 계측자료의 D/B화를 위한 표준현장단면

표 3. 쏘일네일링 공법이 적용된 흙막이벽체의 영향인자

조 건	항 목	번호	
굴착조건	(1) 굴착깊이 (m)	[1]	
	(2) 흙막이벽체 경사각 (.)	[2]	
	(3) 흙막이벽체 배면경사각 (.)	[3]	
지반조건	(4) 매립층의 두께(m)	[5]	
	(5) 퇴적층의 두께(m)	[6]	
	(6) 풍화잔류토층의 두께(m)	[7]	
	(7) 풍화암층의 두께(m)	[8]	
	(8) 연암층의 두께(m)	[9]	
	(9) 보통암층의 두께(m)	[10]	
	(10) 경암층의 두께(m)	[11]	
	(11) 지하수위(m)	[12]	
	(12) 인접터널과의 이격거리(m)	[13]	
	(13) 인접건물과의 이격거리(m)	[14]	
지지조건	(14) 쏘일네일 설치유형	uniform	[15]
		상장(上長)-하단(下短)	
		상단-하장	
	(15) 평균 쏘일네일 길이(m)	[16]	
	(16) 평균 수평설치간격 (cm)	[17]	
	(17) 평균 연직설치간격(cm)	[18]	
	(18) 쏘일네일 설치각도(.)	[19]	
	(19) 쏘일네일 설치단수	[20]	
	(20) 병용공법	지반앵커	[21]
		지반앵커 설치단수	[22]
		버팀보	[23]
		버팀보 설치단수	[24]
		Raker	[25]
		Raker 설치단수	[26]
	(21) 전면벽체	H-pile	[27]
		쑏크리트	
	(22) 쑏크리트의 두께(cm)	[28]	
	(23) 차수 및 지반보강 공법	SCW	[29]
		Jet Grouting	[30]
LW		[31]	

와 쏘일네일을 적용하지 않은 흙막이벽체로 구분하고, 그림11과 같은 표준현장단면을 설정한 다음, 이에 따라 선별된 계측자료를 표3 및 4와 같이 각각 D/B화하였다.

3.6 인공신경망을 이용한 변위 예측시스템 개발

다층역전파 인공신경망은 입·출력층과 은닉층의 구조, 학습률(learning rate, η) 및 모멘텀 상수(α)로 표현되는 학습상수 또한 학습회수 등이 학습효율 및 추론능력에 영향을 미칠 것으로 판단된다(Eberhart & Dobbins, 1990). 본 연구에서는 기 구축된 D/B를 대상으로 쏘일네일링 공

표 4. 일반적인 지지공법이 적용된 흙막이벽체의 영향인자

조 건	항 목	번호	
굴착조건	(1) 굴착깊이 (m)	[1]	
	(2) 흙막이벽체 경사각(.)	[2]	
지반조건	(3) 매립층의 두께(m)	[3]	
	(4) 퇴적층의 두께(m)	[4]	
	(5) 풍화잔류토층의 두께(m)	[5]	
	(6) 풍화암층의 두께(m)	[6]	
	(7) 연암층의 두께(m)	[7]	
	(8) 보통암층의 두께(m)	[8]	
	(9) 경암층의 두께(m)	[9]	
	(10) 지하수위(m)	[10]	
	(11) 인접터널과의 이격거리(m)	[11]	
	(12) 인접건물과의 이격거리(m)	[12]	
	(13) 버팀보	[13]	
	(14) 버팀보 설치단수	[14]	
	지지조건	(15) 지반앵커	[15]
(16) 지반앵커 설치단수		[16]	
(17) Raker		[17]	
(18) Raker 설치단수		[18]	
(19) 콘크리트 슬래브		[19]	
(20) 슬래브 설치단수		[20]	
(21) 차수 및 지반보강 공법		SCW	[21]
		Jet Grouting	[22]
		LW	[23]

법이 적용된 흙막이벽체의 변위 예측(이하 모델 A)과 쏘일네일링 공법 이외의 일반적인 지지공법이 적용된 흙막이벽체의 변위 예측(이하 모델 B)에 가장 적합한 다층역전파 인공신경망 모델을 각각 결정하기 위하여, 인공신경망 실험모델을 표5와 같이 임의로 설정하고 학습을 수행하였다. 각각의 모델에 대해 입력층의 노드수는 31개와 23개로, 은닉층 노드수는 식 (5)와 (6)(Masters, 1993)을 이용하여 설정하였고, 출력층의 노드수는 흙막이벽체 거동특성을 대표하는 굴착단계별 최대수평변위와 최종굴착단계에서의 최대수평변위 발생위치(흙막이벽체 최상단으로부터의 연직거리) 등 2개이다. 여기서 은닉층의 층수는 김등(1998)의 연구결과를 토대로 단층으로 고정시킴으로써, 은닉층 노드수와 학습률, 모멘텀 상수 등을 최적 인공신경망 모델 선정의 주요 지표로 삼고자 하였다.

$$\sqrt{(i^2 + j^2)} = k \tag{5}$$

$$\sqrt{(i \times j)} = k \tag{6}$$

여기서, i 는 입력층의 노드수, j 는 출력층의 노드수, k 는 은닉층의 노드수를 각각 나타낸다.

$$AIER(\%) = \frac{1}{n} \sum \frac{|K_m - K_p|}{K_m} \times 100 \quad (7)$$

표 5. 인공신경망 실험모델

모델명	입력층	은닉층	출력층	학습률(η)	모멘텀 상수(α)	시스템 오차	
모델 A	1~5	31	31	2	0.1	0.5~0.9	0.001
	6~10				0.2		
	11~15				0.3		
	16~20				0.4		
	21~25				0.5		
	26~30	31	8	2	0.1	0.5~0.9	0.001
	31~35				0.2		
	36~40				0.3		
	41~45				0.4		
	46~50				0.5		
모델 B	1~5	23	23	2	0.1	0.5~0.9	0.001
	6~10				0.2		
	11~15				0.3		
	16~20				0.4		
	21~25				0.5		
	26~30	23	7	2	0.1	0.5~0.9	0.001
	31~35				0.2		
	36~40				0.3		
	41~45				0.4		
	46~50				0.5		

학습상수와 은닉층의 노드수, 학습패턴의 크기 등을 변화시켜 가며 학습을 수행함으로써 각각의 변화에 따른 인공신경망 모델의 학습효율 및 추론능력에 미치는 영향에 대하여 평가하고 이를 최적 인공신경망 모델의 학습상수 결정에 사용하고자 하였다. 학습패턴의 크기에 대한 영향 평가는 본 연구에서 구축된 계측자료의 D/B에 추후 학습 패턴이 더 추가 될 수 있으므로 이에 대한 영향을 평가하고자 한 것이다. 본 매개변수연구에 사용된 학습종료 조건은 시스템오차 0.001 이하이다.

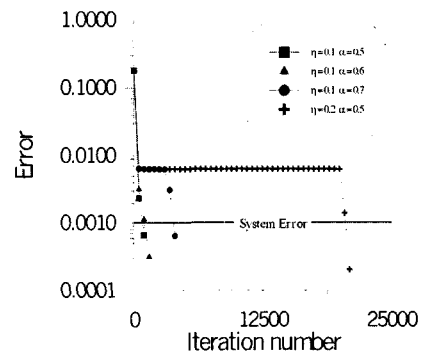
모델 A 및 B 각각에 대해 학습을 수행하고, 각 모델에 대한 학습회수, 학습오차(learning error) 및 수렴경향도 등을 토대로 우수한 모델을 선정하여, 굴착단계별 벽체의 최대 수평변위와 최종굴착단계에서의 최대수평변위 발생위치를 추론하여 보았다. 추론된 최대수평변위와 발생위치는 식(7)과 같은 추론오차율 산정식을 이용하여, 각 인공신경망 모델에 대한 학습자료의 평균 추론오차율(Average Inference Error Rate, AIER, 배규진 등, 1998)을 산정하고 이를 최적 인공신경망 모델 선정의 주요지표로 삼았다.

여기서, n 은 추론자료수이며, K_m 은 실제 계측자료의 값, K_p 는 예측된 값을 각각 나타낸다.

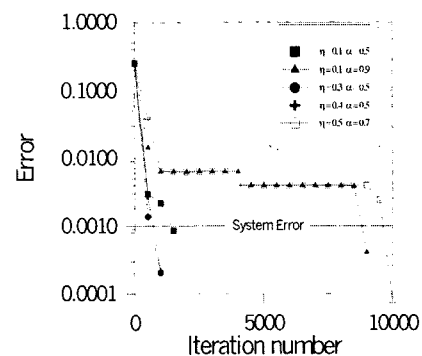
1) 학습상수와 은닉층의 노드수에 대한 영향

높은 값의 학습률은 많은 양의 연결가중치 변화를 주기 때문에 학습속도가 빨라지지만 발산의 위험성이 있으므로 그 값을 0.1~0.5 범위로 고정시켰고, 모멘텀 상수는 학습속도를 빠르게 하는 학습률 허용한도 내에서 발산의 위험을 줄여주는 역할을 하기 때문에 0.5 ~ 0.9 범위로 고정시켰다. 학습에 사용된 학습패턴은 30패턴, 시스템오차는 0.001, 최대 학습반복회수는 50000회로 하였다. 그림12는 학습상수의 변화에 따라 학습오차가 시스템오차 이하로 수렴하는 모델 A의 오차수렴 경향을 보여주고 있다.

은닉층의 노드수가 31개인 모델 A-1~25(그림12(a) 참조)는 학습상수의 변화에 따라 민감한 반응을 보이며, 학습률이 높아질수록 시스템오차에 수렴하지 못하는 경향을 보이지만, 은닉층수가 8개인 모델 A-26~50(그림12(b))

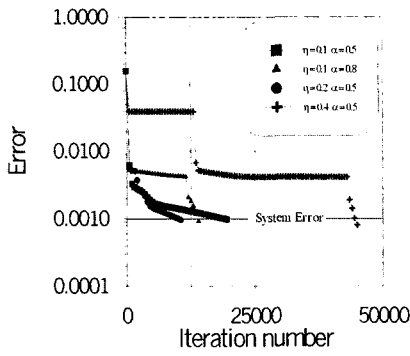


(a) 은닉층의 노드수 : 31개




(b) 은닉층의 노드수 : 8개

그림 12. 학습상수의 변화에 따른 모델 A의 오차수렴 경향

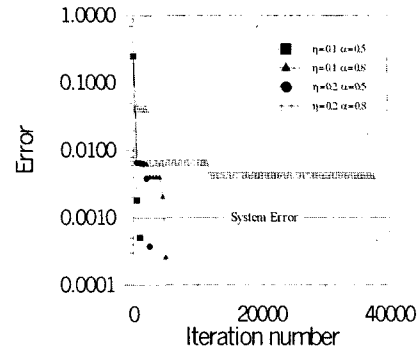


(a) 은닉층의 노드수 : 23개

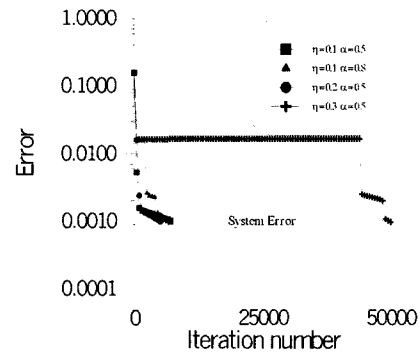


(b) 은닉층의 노드수 : 7개

그림 13. 학습상수의 변화에 따른 모델 B의 오차수렴 경향



(a) 모델 A (은닉층의 노드수 : 8개)



(b) 모델 B (은닉층의 노드수 : 7개)

그림 14. 학습패턴의 크기 변화에 따른 오차수렴 경향


참조)은 학습상수의 변화에 관계없이 시스템오차 이내로 수렴하는 경향을 보인다.

또한 은닉층수가 23개인 모델 B-1~25(그림13(a) 참조)는 학습률 보다는 모멘텀 상수의 변화에 따라 민감한 반응을 보이며, 모멘텀 상수가 높아질수록 시스템오차에 수렴하지 못하는 경향을 보인다. 은닉층 수가 7개인 모델 B-26~50(그림13(b) 참조)은 은닉층 수가 23개인 경우 보다 학습률과 모멘텀 상수의 변화에 민감하지 않은 경향을 보인다.

2) 학습패턴 크기에 대한 영향

학습패턴의 크기에 대한 영향을 평가하기 위해 학습패턴을 30, 60, 90개 등으로 변화시켜가며 학습을 시켰다. 학습패턴 크기의 변화에 따라 학습오차가 시스템오차 이하인 인공신경망 모델의 오차수렴경향은 그림14와 같다.

그림14의 결과를 분석하면, 학습패턴의 크기가 증가함에 따라 은닉층 노드수가 31개인 모델 A-1~25, 23개인 모델 B-1~25는 시스템오차 이내로 수렴하지 못하였으며, 은닉층 노드수가 8개인 모델 A-26~50(그림14(a) 참조), 7개인 모델 B-26~50(그림14(b) 참조)은 학습률과 모멘텀 상수의 변화에 따라 상당히 민감한 학습오차를 나타내었다.



	A-26	A-27	A-28	A-29	A-31	A-32	A-33	A-34	A-36
■ (최종공작 단계) 최대수렴범위 오차	70.96	74.54	72.07	81.65	75.7	79.5	82	82.74	82.27
■ 최대수렴범위 발생위치 오차	21.06	25.62	24.3	27.82	26.45	27.3	27.77	37.12	26.21
□ 평균오차	46.01	50.01	48.19	54.73	51.08	53.4	54.89	59.93	54.24

(a) 모델 A의 추론결과



	B-26	B-27	B-28	B-29	B-31	B-36
■ (최종공작 단계) 최대수렴범위 오차	16.14	16.22	15.79	15.82	16	15.46
■ 최대수렴범위 발생위치 오차	15.01	14.98	14.91	14.72	14.92	14.71
□ 평균오차	15.59	15.6	15.35	15.17	15.48	15.09

(b) 모델 B의 추론결과

그림 15. 인공신경망 모델의 추론결과

3) 추론 오차율의 비교

학습상수와 학습패턴의 변화에 따른 각 모델들의 오차 수렴 경향을 토대로 학습오차가 시스템오차 이하인 모델 A-26, 27, 28, 29, 31, 32, 33, 34, 36과 B-26, 27, 28, 29, 31, 36에 대하여 학습에 사용된 학습패턴으로 인공지능망의 추론능력을 평가하였으며, 결과는 그림15에 도시되어 있다.

그림15의 추론결과를 살펴보면, 모델A의 경우, A-26의 평균오차는 46.01%(그림15(a) 참조)이고, 모델B의 경우, B-36의 평균오차는 15.09%(그림15(b) 참조)로 각각 가장 작은 값을 나타내었다.

3.7 변위 예측시스템 개발

매개변수연구결과를 근거로 하여 본 연구의 목적에 가장 적합한 최적의 인공지능망 모델을 결정하였고, 결정된 모델을 이용하여 변위 예측시스템을 개발하였다. 그림16은 본 연구에서 개발한 변위 예측시스템에 사용된 인공지능망의 구조를 나타낸 것이다.

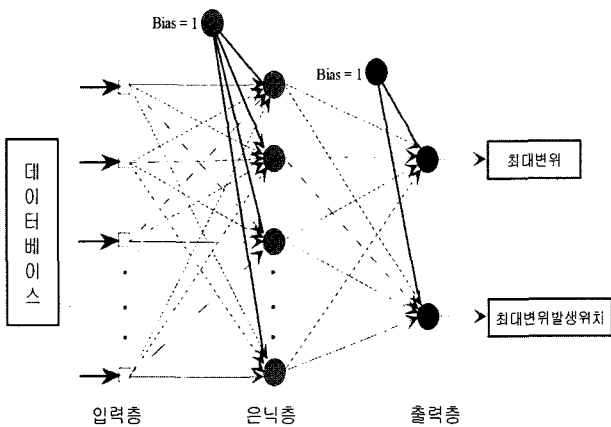


그림 16. 변위 예측시스템에 사용된 인공지능망 모델의 구조

쏘일네일링 공법이 적용된 흙막이벽체에 대한 변위 예측시스템에 사용된 인공지능망 모델(모델 A)의 구조와 일반적인 지지공법에 대한 변위 예측시스템에 사용된 인공지능망 모델(모델 B)의 구조는 입력층과 단층의 은닉층, 그리고 출력층 등으로 이루어졌다. 모델 A는 모델명 A-26(은닉층의 노드수 = 8, 학습률 = 0.1, 모멘텀 상수 = 0.5), 모델 B는 모델명 B-29(은닉층의 노드수 = 7, 학습률 = 0.1, 모멘텀 상수 = 0.8)로 결정하였다. 모델 B의 경우 재추론 오차율은 모델 B-36이 모델 B-29보다 작지만, 학습 오차 수렴 경향과 추론오차를 종합적으로 평가하여 모델 B-29로 결정하였다.

4. 변위 예측시스템의 신뢰성 검증

4.1 변위 예측시스템의 학습

개발된 변위 예측시스템에 실행비를 통해 선별된 계측 자료를 이용하여 학습을 실시하였다. 모델 A-26을 이용한 변위 예측시스템을 위한 학습패턴은 100 패턴으로, 모델 B-29를 이용한 변위 예측시스템을 위한 학습패턴은 161 패턴으로, 또한 학습조건은 각각 학습최대 반복회수 5.0×10^6 과 시스템오차 1.0×10^{-5} 을 적용하였다. 그림17은 선정된 모델이 적용된 변위 예측시스템의 학습오차 수렴경향이다.

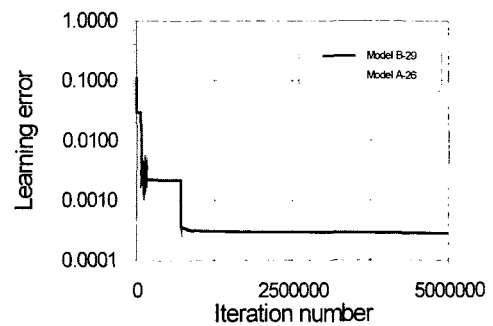


그림 17. 선정된 인공지능망 모델의 학습오차 수렴경향

두 모델 모두 시스템오차인 1.0×10^{-5} 에 도달하지 못하였고, 모델 A-26을 이용한 변위 예측시스템의 최종 학습오차는 0.000289이고, 모델 B-29를 이용한 변위 예측시스템의 최종 학습오차는 0.000283이다.

4.2 신뢰성 검증

1) 최대수평변위 및 발생위치에 대한 예측

본 연구를 통해 개발된 인공지능망 변위 예측시스템의 신뢰성을 검증하기 위하여, 학습에 포함되지 않은 실제의 8개 현장들에 대해 최종굴착단계에서의 최대수평변위 및 발생위치(벽체 최상단으로부터의 연직거리)를 예측하고, 이를 계측치와 서로 비교하였다. 본 신뢰성 검증에 적용된 실제 현장들의 개요를 정리하면 표6과 같고, 예측치와의 비교결과는 그림18과 같다.

그림18의 비교결과를 분석하면, 모델 A의 평균예측오차는 최대수평변위의 경우 4.79%이고, 발생위치에 대해서는 6.16%를 나타내고 있다. 모델 B의 경우, 평균예측오차는 최대수평변위에 대해 9.62%, 발생위치에 대해서는 11.85%를 각각 나타내고 있으며, 이와 같이 변위 예측시스

표 6. 신뢰성 검증에 적용된 실제 현장들 개요

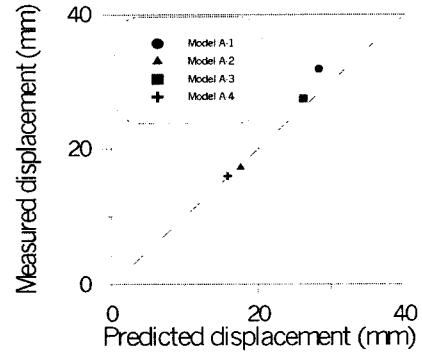
모델명	번호	굴착 깊이 (m)	지시공법	지하 수위 (GL-m)	차수 및 지반보강 공법	인접 터널 (m)	인접 건물 (m)	최대 수평 변위 (mm)	발생 위치 (GL-m)
모델 A	1	24.7	쏘일네일	18.9	SCW	-	20	31.9	5
	2	23		23.5	Jet Grouting	-	9	17.3	2
	3	30		12	Jet Grouting	17.9	35	27.5	10
	4	23		4.7	LW	25	55	16.0	4.5
모델 B	1	24	버팀보+지반앵커	14.3	SCW	-	30	38.5	17
	2	20.4	버팀보	21.6	SCW	-	-	13.5	7.5
	3	23	지반앵커	24	Jet Grouting	-	25	22.3	4
	4	31	콘크리트 슬래브	25	-	-	-	13.6	9

표 7. 지반조건을 기준으로 한 학습패턴에 대한 유사성 분류


모델명	번호	유사학습 패턴 (개)	비율 (%)	변위예측 오차 (%)
모델 A	1	10	9.43	11.45
	3	3	2.83	4.76
	2, 4	86	81.14	0.95~2.0
	기타	7	6.60	-
합계		106	100	
모델 B	1	3	1.60	5.08
	2	15	8.02	0.8
	3	42	22.46	13.01
	4	6	3.21	20.23
	기타	121	64.71	-
합계		187	100	

템의 예측오차는 현장별로 비교적 넓은 범위의 오차를 나타내고 있다. 일반적으로 인공지능망의 예측오차는 학습패턴에 대한 영향이 적지 않은 부분을 차지하는 것으로 알려져 있으며, 따라서 변위 예측시스템의 학습에 사용된 100개(모델 A) 및 161개(모델 B)의 학습패턴들을 신뢰성 검증에 적용된 8개 현장(표6 참조)의 지반조건을 기준으로, 표7과 같이 유사성 분류를 실시하여 학습패턴의 영향을 분석하였다.

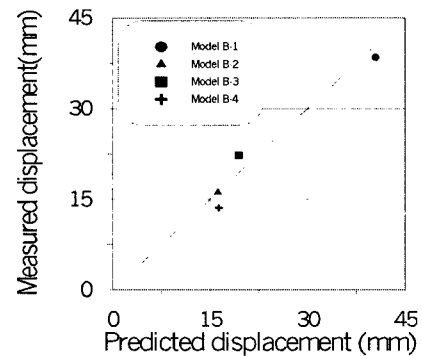
표7의 결과를 분석하면, 모델 A는 예측오차가 비교적 작은 현장 2 및 4와 유사한 현장의 학습패턴이 81.14%로 가장 많은 비율을 차지하고 있으며, 모델 B 역시 유사한 학습패턴이 많을수록 예측오차의 크기는 줄어드는 것을 알 수 있다. 따라서 본 연구에서 수집된 계측자료에 추가하여



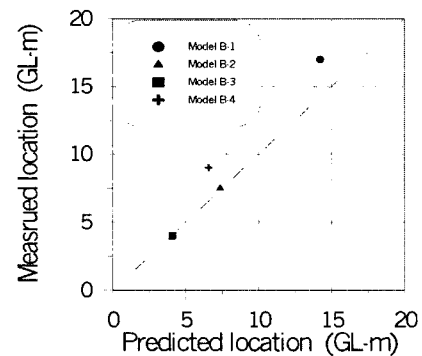
(a) 모델 A의 최대수평변위 예측결과



(b) 모델 A의 최대수평변위 발생위치 예측결과



(c) 모델 B의 최대수평변위 예측결과



(d) 모델 B의 최대수평변위 발생위치 예측결과

그림 18. 예측치와의 비교결과

보다 다양한 조건의 광범위한 현장계측자료가 향후 수집되어 학습이 수행된다면, 예측오차는 훨씬 줄어들 것으로 판단된다.

2) 실행비의 예측

신뢰성 검증에 적용된 현장들(표6 참조)중 모델 B의 현장 4에 대해, 초기굴착단계로부터 최종굴착단계까지의 굴착단계별 실행비의 변화를 본 연구 제시 인공지능망 변위 예측시스템을 이용하여 예측하였다. 본 학습에 사용된 학습패턴의 수는 단계별 굴착관련 계측자료가 확보된 43개이며, 그림19에 도시된 실행비 예측결과와 모델 B의 현장 4에 대한 실제 계측결과 비교를 분석하면, 굴착단계별 최대수평변위 예측에 대한 평균오차는 11.48%이다.




그림 19. 실행비 예측결과

5. 요약 및 결론

본 연구에서는 국내 도심지 굴착현장에서 수집된 흙막이벽체의 계측자료와 인공지능망 중 다층퍼셉트론을 이용하여 흙막이벽체의 변위 예측시스템을 개발하고 그 적용성을 평가하여, 기존 방법에 의한 변위 예측의 한계를 극복하고자 노력하였다.

구축된 모형의 학습 및 검증을 위한 입력자료는 기 시공이 완료된 현장의 계측자료를 수집, 분석하여 흙막이벽체의 거동에 영향을 미치는 인자를 조사하였고, 도출된 영향인자를 근거로 선별된 계측자료를 D/B화하였다. 흙막이벽체의 거동특성상 쏘일네일링 공법(모델 A)과 일반적인 지지공법(모델 B) 등 두 가지로 변위 예측시스템을 구분하고, 각 공법에 대해 각각 50개 모델을 설정하여, 역전과 알고리즘으로 학습시키고 검증한 후 각각의 성능을 비교, 평가하여 최적의 인공지능망 모델을 선정하였다. 계속해서 선정된 최적모델에 구축된 D/B를 이용하여

학습을 시켰으며, 아울러 학습에 포함되지 않은 시공이 완료된 현장에 대하여, 선정된 최적의 인공지능망 모델을 이용하여 굴착단계별 벽체의 최대수평변위와 최종굴착단계에서의 최대수평변위 발생위치를 예측하고 이를 현장계측치와 비교하여, 본 연구 인공지능망을 이용한 흙막이벽체 변위 예측시스템의 적용성을 부분적으로 확인하였다. 본 연구에서 도출된 주요결과 및 추후과제를 정리하면 다음과 같다.

- 1) 매개변수연구결과 본 연구 흙막이벽체의 변위 예측시스템에 적합한 최적의 인공지능망 구조는, 쏘일네일링 공법의 경우 단층의 은닉층과 학습률 0.1, 모멘텀 상수 0.5인 구조이고, 또한 일반적인 지지공법의 경우에는 단층의 은닉층과 학습률 0.1, 모멘텀 상수 0.8인 구조임을 알 수 있었다.
- 2) 수집된 계측자료의 신뢰도를 높이기 위해, 총 6개 굴착 단면에 대한 수치해석적 모델링을 시행하여 굴착단계별 실행비를 산출하였고, 이를 근거로 현장계측자료의 D/B화에 앞서 수집된 현장계측자료를 95%의 신뢰도 범위에서 선별하였다.
- 3) 인공지능망 이론을 이용한 흙막이벽체의 변위 예측시스템은 기존의 변위 예측기법에 비해 입력과정이 간편하고 해석시간이 짧은 특징이 있으며 또한 다양한 현장 특성이 고려되는 장점이 예상되며, 최종굴착단계에서의 최대수평변위에 대한 본 연구에서의 예측결과는 실제 현장 계측치와 비교하여, 쏘일네일링 공법이 적용된 흙막이벽체에서는 평균오차율 5.48%, 일반적인 지지공법이 적용된 흙막이벽체에서는 평균오차율 10.74%를 나타내었다. 또한 초기굴착단계에서부터 최종굴착단계까지의 단계별 예측에서는 평균오차율 11.48%를 나타내었다.
- 4) 추론오차율은 예측이 시행되는 굴착현장과 유사한 학습패턴이 많을수록 낮아지므로, 보다 정확한 변위 예측시스템 구축을 위해서는 보다 다양한 현장특성이 포함되는 충분한 학습자료의 지속적인 확보가 요구된다.
- 5) 제시된 인공지능망을 이용한 흙막이벽체의 변위 예측시스템은, 초기설계단계 또는 굴착공사 도중 추가굴착에 따른 변위예측에 적절히 활용 가능할 것으로 판단된다. 학습자료의 지속적 확보와 더불어, 향후 흙막이벽체 설계 및 굴착공사에 대한 보다 다양한 정보를 제공하기 위해서는 본 연구결과 등을 토대로 한 전문가 시스템의 개발이 필요할 것으로 사료된다.

감사의 글

본 논문은 한국학술진흥재단 지원(자유공모과제:1998-001-E01930)에 의한 연구성과의 일부임을 밝히며, 이에 감사드립니다.

참고 문헌

1. 김홍택, 강인규, 박성원 (1998), "인공신경망을 이용한 쓰일네일링 굴착벽체의 변형 예측기법에 관한 기초연구", 대한토목학회 학술발표회 논문집, pp. 401-404.
2. 배규진, 김창용, 신휴성, 문현구 (1998), "터널굴착 현장에 인접한 지상구조물의 안정성 평가용 전문가 시스템의 개발(1)", 한국지반공학회지, 제14권, 제2호, pp. 107-123.
3. Bruce, D.A. and Jewell, R.A. (1987), "Soil Nailing: Application and Practice", Ground Engineering, Vol. 20, No. 1, pp. 10-33.
4. Flood, I. and Kartam, N. (1994), "Neural Networks in Civil Engineering. I: Principles and Understanding", Journal of Computing in Civil Engineering, ASCE, Vol. 8, No. 2, pp. 131-148.
5. Flood, I. and Kartam, N. (1994), "Neural Networks in Civil Engineering. II: System and Application", Journal of Computing in Civil Engineering, ASCE, Vol. 8, No. 2, pp. 149-162.
6. Eberhart, R.C. and Dobbins, R.W. (1990), Neural Network PC Tools, Academic Press Inc.
7. Haykin, S. (1998), Neural Networks, Prentice-Hall, Inc., New Jersey.
8. Masters, T. (1993), Practical Neural Network Recipes in C++, Academic Press, San Diego, Calif.
9. Toll, D.G. (1990), "Do geotechnical engineers need expert systems?", Ground Engineering, Vol. 23, No. 3, pp. 32-36.

(접수일자 1999. 9. 8)